

SISTEMAS AUTOMÁTICOS DE VERIFICAÇÃO DE ASSINATURAS DINÂMICAS EM TEMPO REAL

Lee Luan Ling

Departamento de Comunicações
Faculdade de Engenharia Elétrica e de Computação
Universidade Estadual de Campinas
CP 6101
13083-970 Campinas – SP

RESUMO: Vários sistemas automáticos de verificação de assinaturas humanas são implementados e testados. Na aquisição de dados, um banco de dados de mais de dez mil assinaturas dinâmicas no formato $(x(t), y(t))$ é construído usando um digitalizador de mesa (“*graphics tablet*”). Na extração de características, inicialmente extraímos um conjunto de 42 características paramétricas da assinatura e, em seguida, avançamos a um conjunto de 49 características normalizadas que toleram inconsistências em assinaturas genuínas e, ao mesmo tempo, mantém seu poder de discriminação contra falsificações. Estudamos vários algoritmos de seleção e de ortogonalização de características de acordo com a disponibilidade de dados de treinamento e os níveis de complexidade dos sistemas. Para a decisão estudamos vários tipos de classificadores. Uma versão modificada do nosso classificador majoritário oferece aproximadamente uma taxa de erros iguais de 2,5% e, mais importante, um desempenho assintótico de 7% na taxa de aceitação falsa com uma taxa zero de rejeição falsa, usando apenas 15 características paramétricas selecionadas (Eq. 3), conforme indicado pela Figura 1-f. Além disso, testes experimentais mostraram que esta versão modificada do sistema é robusta em relação à variação da velocidade nas assinaturas.

ABSTRACT: On-line dynamic signature verification systems were designed and tested. A data base of more than ten thousand signatures in $(x(t), y(t))$ -form was acquired using a graphics tablet. We extracted a 42-parameter feature set at first, and advanced to a set of 49 normalized features that tolerate inconsistencies in genuine signatures while retaining the power to discriminate against forgeries. We studied algorithms for selecting and perhaps orthogonalizing features in accordance with the availability of training data and the level of system complexity. For decision making we studied several classifier types. A modified version of our majority classifier yielded approximately 2.5% equal error rate and, more importantly, an asymptotic performance of 7% false acceptance rate at zero false rejection rate, was robust to the speed of genuine signatures, and used only 15 parameter features (Eq. 3) as shown in Figure 1-f. In addition, Experimental results show

that this modified signature verification system is robust with respect to the speed variation in signatures.

1. INTRODUÇÃO

O projeto e a implementação de um sistema automático de verificação de assinaturas em tempo real envolve a aquisição de dados, a extração de características, a seleção de características, a decisão e a avaliação de desempenho. Tais procedimentos têm sido discutidos amplamente no artigo clássico de “survey” de Plamondon e Lorette (1989) e, mais recentemente, num artigo que é a continuação da publicação acima por Leclerc e Plamondon (1994). Além disso, vários outros artigos surgidos subsequentemente também descreveram trabalhos desenvolvidos na área de verificação de assinaturas, entre os quais citamos Dimauro *et alii* (1994), Plamondon (1994), Nelson *et alii* (1994), Fairhurst e Brittan (1994) e Yang *et alii* (1995).

Tendo como objetivo aproveitar algumas vantagens dos métodos sugeridos por outros autores e ao mesmo tempo, propor novas soluções para problemas de verificação de assinatura, neste artigo descrevemos um procedimento confiável e eficiente para projetar um sistema de verificação de assinatura em tempo real que engloba:

- a) a construção de um banco de dados confiável;
- b) a seleção de conjuntos de características ótimas com ou sem a disponibilidade de dados de falsificações;
- c) a implementação de procedimento de seleção de características independente dos classificadores utilizados;
- d) a obtenção de desempenho global e individual confiável do sistema;
- e) a obtenção de um modelo estatístico para assinaturas, a minimização de efeitos devido à inconsistência de assinaturas genuínas e à variação de falsificações e adaptação a limitações práticas, tais como, reposta em tempo real e limitação de memória.

Submetido em 11/06/96

1a. revisão em 03/12/96 2a. revisão em 27/05/97

Artigo aceito sob recomendação do Ed. Cons. Prof. Dr. Ricardo Tanscheit

2. AQUISIÇÃO DE DADOS

Um total de 5603 assinaturas genuínas foram coletadas de uma população de 105 indivíduos dentre os quais haviam 22 mulheres e 5 canhotos. Alguns indivíduos contribuíram somente com 13 assinaturas genuínas enquanto um indivíduo escreveu sua assinatura mais de 1000 vezes. Aproximadamente 90% das assinaturas no banco de dados genuínos foram coletadas sob condições “normais” da escrita. Por condição normal da escrita consideramos o modo de assinar de um indivíduo na maioria das vezes. Tendo em vista que um sistema de verificação de assinatura deve ser robusto em relação às variações da velocidade da escrita, coletamos também um conjunto de 240 assinaturas “rápidas” de 9 indivíduos que foram solicitados escrever suas assinaturas o mais rápido possível. O estudo mostra que a porcentagem de redução no tempo da escrita deste modo em relação ao tempo da assinatura em velocidades normais varia de 10 a 50%. Em relação ao tamanho das assinaturas, os menores retângulos necessários para acomodar a menor e a maior assinatura medem, respectivamente, 10 cm por 13 cm e 2 cm por 0,5 cm. Os tempos da escrita das assinaturas variam de 1 a 14 segundos.

A construção de um banco de dados de falsificação exige um planejamento cuidadoso. Empregamos três tipos de falsificações: **simples** (Plamondon e Lorette, 1989), **estaticamente habilitada** (“*statically skilled forgery*”) e **falsificação cronometrada** (“*timing forgery*”). Embora outros tipos de falsificações tenham sido sugeridos na literatura (Plamondon e Lorette, 1989), acreditamos que os 3 tipos de falsificações acima são mais comumente encontradas em aplicações práticas, particularmente em pontos comerciais. Em falsificação simples assumimos que os falsificadores sabem somente como soletrar assinaturas genuínas. Um total de 1148 falsificações simples foram coletadas. Uma falsificação é considerada estaticamente habilitada quando, além de possuir todas as informações geométricas sobre assinaturas genuínas, ao falsificador é permitido praticar imitações tanto no papel como no digitalizador. Um total de 3466 falsificações estaticamente habilitadas foram coletadas. Para falsificação cronometrada, além das informações estáticas sobre assinaturas genuínas, ao falsificador é dada informação sobre o tempo médio da escrita da assinatura genuína durante o período de treinamento. Em termos da falsificação cronometrada, um total de 1148 falsificações cronometradas foram coletadas.

Adicionalmente coletamos 248 assinaturas chinesas provenientes de 23 indivíduos, 26 assinaturas arábicas de 2 indivíduos, 13 assinaturas coreanas de um único indivíduo e 13 assinaturas hebraicas de um indivíduo.

3. EXTRAÇÃO DE CARACTERÍSTICAS

O primeiro conjunto de características proposto consiste em 42 características paramétricas personalizadas, das quais tem-se 13 características estáticas e 29 características dinâmicas, conforme descritas em Apêndice A. Algumas das 42 características foram inspiradas pela literatura de reconhecimento de manuscritos (Achmlal *et alii*, 1989; Bonnefoy *et alii*, 1981; Crane e Ostram, 1983; Lorette, 1984), sendo após adaptadas adequadamente para aplicações de verificação de assinaturas. As restantes das 42 características foram elaboradas baseadas nas experiências adquiridas durante o processo de coleta de assinaturas. A execução de um único processamento de dados de assinaturas realiza uma redução dos efeitos da resolução básica do digitalizador de mesa, através da

eliminação de amostras próximas. A resolução espacial do digitalizador pode afetar seriamente algumas características instantâneas, pois a obtenção das quais envolvem somente algumas amostras consecutivas. Conseguimos solucionar alguns problemas devido ao efeito de rotação e deslocamento da assinatura através do fornecimento de uma linha horizontal de referência para escrita, traçada no papel fixado na superfície do digitalizador.

Experimentos preliminares mostraram que o conjunto de 42 características é altamente sensível à variação em tamanho e velocidade das assinaturas genuínas. Assim sendo, um segundo conjunto composto de 49 características normalizadas foi implementado com o objetivo de retificar estas deficiências (Lee, 1992). O procedimento de normalização de características pode ser tão complexo quanto aqueles sugeridos em (Crane e Ostrem, 1983; Sato e Kogure, 1982) ou simples como uma normalização linear. Sabemos que a eficiência da normalização linear empregada depende do grau da validade das suposições temporais e espaciais abaixo formuladas. Não examinamos diretamente o grau de validade destas suposições, mas a qualidade dos nossos resultados de verificação de assinaturas fortemente sugere que a realidade aproxima-se estas suposições.

Suposição Temporal: O instante de um evento ocorrerá aproximadamente na mesma fração de duração da escrita de uma assinatura, independente da velocidade global da escrita.

Suposição Espacial: O dimensionamento (ou ajuste) linear dos deslocamentos horizontais e verticais, possivelmente com diferentes fatores constantes de ponderação, de uma assinatura de tamanho padrão restaurará a assinatura genuína no tamanho original.

De fato, não há acréscimo no tempo computacional ou esforço na obtenção das características normalizadas linearmente a partir das versões não normalizadas, visto que os fatores de normalização - duração total da escrita, deslocamento total horizontal e vertical - fazem partes do conjunto original de 42 características. A descrição detalhada das 49 características normalizadas encontram-se no Apêndice B.

4. SELEÇÃO DE CARACTERÍSTICAS

Na verificação de assinaturas relativamente poucos pesquisadores tentaram selecionar um subconjunto ótimo de características de um conjunto maior (Achmlal *et alii*, 1989; Crane e Ostrem, 1983). Além disso, estes métodos propostos dependem fortemente do tipo dos classificadores utilizados ou não foram efetivamente testados utilizando dados não genuínos. Três algoritmos de seleção de características serão descritos a seguir. O primeiro algoritmo seleciona características assumindo-se a disponibilidade apenas de assinaturas genuínas. Sejam $m(a, i)$ e $\sigma^2(a, i)$ o valor médio e a variância amostral da característica i , respectivamente, calculados usando somente o banco de dados do indivíduo a . A medida de distância para a característica i entre a assinatura do indivíduo a e a do indivíduo b é definida como

$$d_i(a, b) = \frac{|m(a, i) - m(b, i)|}{\sqrt{\sigma^2(a, i) + \sigma^2(b, i)}} \quad (1)$$

Diz-se que a característica i tem a ordem ou o grau de importância maior do que a característica j para a assinatura do indivíduo a se em relação a população P

$$d_i(a) = \min_{b \in P, b \neq a} \{d_i(a, b)\} > \min_{b \in P, b \neq a} \{d_j(a, b)\} = d_j(a) \quad (2)$$

Em outras palavras, ordenamos as características para o indivíduo a em termos das suas distâncias "maxmin" do resto da população inteira P . Seleção de k características ótimas é equivalente a selecionar as k características com maiores distâncias $d_i(a)$ definidas pela equação(2).

Quando ambos dados genuínos e falsificados estiverem disponíveis, substituímos a equação(1) por

$$d_i(a) = \frac{|m(a, i) - m(f, i)|}{\sqrt{\sigma^2(a, i) + \sigma^2(f, i)}} \quad (3)$$

Note que $m(f, i)$ e $\sigma(f, i)$ são, respectivamente, a média e o desvio padrão da características i , ambos computados utilizando o banco de dados de assinaturas falsificadas do indivíduo a . Quando os dados de falsificação estão disponíveis, a característica i será considerada mais importante do que a característica j se $d_i(a) > d_j(a)$. Uma lista extensa de 42 características ordenadas individualmente, em termos de grau de importância para cada um dos 22 indivíduos está disponível em Lee (1992). Idealmente a seleção de características deve ser feita baseada não somente na ordem da importância das características, mas também como são correlacionadas uma com a outra; vide a Seção 4.2.

Os resultados dos estudos experimentais confirmam que desempenhos melhores podem ser alcançados usando subconjuntos ótimos individualizados de características, ao invés de usar o conjunto todo. Porém, o uso de subconjuntos de características otimizados individualmente podem aumentar a complexidade do sistema e prolongar o tempo de resposta da verificação. Uma solução, embora sub-ótima, realizável para este problema é construir um subconjunto de características ideais, denominado *conjunto comum de características*, composto de características que são "boas" para a maioria da população. Um conjunto comum de características é particularmente atraente se o procedimento de procura é simples e a degradação em desempenho do sistema de verificação é suficientemente pequena em relação ao emprego dos conjuntos de características ótimas selecionadas individualmente. Nosso conjunto comum de características obtido consiste das m características com maiores frequências

de aparecimentos nas listas ótimas de m características individualizadas da população. A tabela 1 mostra um conjunto comum de 10 características selecionadas em ordem de preferência, de acordo com suas frequências de aparecimentos nas listas das 10 melhores características da população formada de 22 indivíduos.

4.1 Projeto de Classificadores

A tarefa principal para projetar um classificador é deduzir uma medida de distância entre duas quaisquer assinaturas que cause uma separação grande entre uma assinatura pertencente à classe de assinaturas genuínas de um indivíduo e outra da classe de falsificadas. Em geral, a distribuição de probabilidade conjunta das características não é conhecida a priori e é difícil de ser estimada. Conseqüentemente, muitos métodos comumente utilizados que envolvem medidas de distâncias probabilísticas não podem ser adotados. Em outras palavras, todas as medidas de distâncias sob esta circunstância em geral são elaboradas na forma mais ou menos "ad hoc". O classificador majoritário, ou a regra de decisão majoritária, descrito abaixo apresenta a vantagem de ser simples e de implementação fácil e, ao mesmo tempo, fornecem desempenho satisfatório para aplicações comerciais.

Seja m_i e σ_i representando, respectivamente, a média e o desvio padrão amostral da característica i no ensemble de assinaturas genuínas de um indivíduo. Denota-se n , α e t_i , respectivamente, o número total de características usadas no processo de decisão, um limiar fixo e o valor da característica i da assinatura candidata (T) sendo investigada. Define-se

$$N_\alpha = \left| \left\{ i : \frac{|t_i - m_i|}{\sigma_i} \leq \alpha, \text{ para } i = 1, 2, \dots, n \right\} \right| \quad (4)$$

onde $|A|$ denota a cardinalidade do conjunto A . Assim sendo, a regra de decisão majoritária é: " T é declarada como uma assinatura genuína se $N_\alpha \geq n/2$ e como uma falsificação se $N_\alpha < n/2$ ". Note que a regra de decisão majoritária é altamente não linear, visto que a região de decisão no espaço n dimensões de características normalizadas para aceitar uma assinatura como genuína é composto de n cilindros infinitos não-circulares centrados na origem, sendo que o eixo de cada um dos n cilindros paralelos a um dos eixos das n coordenadas das n características.

Tabela 1: Os conjuntos de 10 características comuns

	Preferência	1	2	3	4	5	6	7	8	9	10
Conjunto de 42 Características	Número da Característica	1	22	24	5	23	6	25	7	29	32
Conjunto de 42 Características	Frequência	20	19	14	12	12	11	11	9	9	8
Conjunto de 49 Características	Número da Característica	48	5	4	6	7	30	35	39	1	44
Conjunto de 49 Características	Frequência	17	11	10	10	10	9	8	8	7	6

Conforme mencionado anteriormente, o problema da inconsistência de assinaturas genuínas pode ser solucionado usando características normalizadas. Embora esta medida possa causar a redução da taxa de falsa rejeição do classificador majoritário para um dado α e um dado conjunto de n características, o método também provoca a redução da taxa de detecção de falsificações. Assim sendo, a utilidade das características normalizadas deve ser cuidadosamente avaliada em função do compromisso prático entre estas duas taxas já que elas são as medidas de desempenho de um classificador. Além disso, deve-se ressaltar que o processo de normalização pode remover algumas informações úteis das assinaturas primitivas. A intuição sugere que se pudéssemos reaproveitar, de alguma maneira, as informações úteis descartadas de uma assinatura genuína pelo processo de normalização, poderíamos obter um desempenho melhor no processo de decisão utilizando o classificador majoritário. Baseado neste raciocínio, projetamos duas versões de decisão majoritária modificada para operar em conjunto com as características normalizadas no tempo: “decisão majoritária suave” e “decisão majoritária abrupta” que são descritas a seguir (vide Apêndice C).

O procedimento de decisão suave majoritária consiste em comparar o tempo da escrita (t_w) da assinatura com a duração média da escrita (\bar{t}_w) calculada usando o conjunto de referência de assinaturas genuínas do indivíduo. Em outras palavras, se $|t_w - \bar{t}_w| > \beta \bar{t}_w$, onde um valor nominal para o parâmetro $\beta = 0,2$ é escolhido, as características dinâmicas do conjunto de 49 características não são normalizadas; caso contrário, as características dinâmicas são normalizadas da maneira usual. Finalmente é executada a regra de decisão majoritária convencional usando um subconjunto selecionado do conjunto de 49 características resultantes acima.

O classificador majoritário com decisão suave penaliza a assinatura que possui um tempo de escrita com maior desvio do que seu valor nominal, removendo o fator de normalização do tempo de escrita da assinatura usado por características dinâmicas. Esta medida é justificada visto que uma grande consistência é observada no “tempo de escrita” das assinaturas genuínas. Para a assinatura, mesmo sendo penalizada, ainda existe a possibilidade de que esta com t_w anormal seja classificada corretamente se a maioria das características do subconjunto selecionado comportam-se satisfatoriamente. Analogamente, algumas falsificadas podem não ser detectadas pelo mesmo motivo.

O classificador majoritário com decisão abrupta penaliza severamente assinaturas com $|t_w - \bar{t}_w| > \beta \bar{t}_w$. Em outras palavras, uma assinatura é declarada como uma falsificação simplesmente quando $|t_w - \bar{t}_w| > \beta \bar{t}_w$.

4.2 Consideração sobre Covariância de Características

Duas deficiências do classificador majoritário são observadas: o classificador pesa igualmente as características e não leva em consideração as correlações entre características. O método proposto para solucionar o problema de correlação é via representação de Karhunen-Loeve (K-L). Inicialmente, diagonalizamos a matriz de covariância amostral do conjunto de características obtidos dos dados de treinamento somente das assinaturas genuínas. Através da representação de Karhunen-Loeve, observamos que apenas 5 ou 6 combinações

lineares não correlacionadas das características são necessárias para cobrir a maioria (80% a 95%) das variâncias em assinaturas genuínas de um indivíduo. Em seguida, repetimos o mesmo procedimento para o ensemble de treinamento de falsificados e descobrimos que normalmente são aproximadamente 20 características K-L para cobrir grande volume de variância em assinaturas falsificadas. Um descrição detalhada dos experimentos realizados extensivamente sobre as características K-L e seus resultados podem ser encontrados em Aviczer (1991).

Também tratamos do problema de seleção de características levando em consideração a correlação entre características via redes neurais e o método estatístico “Jackknife”. Nosso estudo mostra que um classificador com um único neurônio já é capaz de fornecer um desempenho melhor (Lee e Berger, 1993a). As redes neurais mais genéricas naturalmente garantem ainda melhores desempenhos (Lee e Berger, 1993b). Além disso, observamos que um algoritmo “Jackknife” de seleção de características do tipo “bottom-up” é capaz de dimensionar classificadores majoritários para operar com um conjunto pequeno de características, porém, garantir um bom compromisso entre erros Tipo I e Tipo II (Chiu, 1992).

5. MODELO ESTATÍSTICO

Um bom modelo estatístico para assinaturas poderia ajudar no avanço da tecnologia de assinatura através de uma quantização precisa da variabilidade interclasse e da variabilidade intraclasse entre assinaturas (Plamondon e Lorette, 1989). Na realidade, infelizmente, as classes de falsificação são particularmente mais difíceis de serem caracterizadas visto que não são completamente conhecidas. Numa tentativa de propor algumas soluções para este problema, Kishon *et alii* (1991) recentemente propuseram um “modelo estatístico para verificação de assinaturas via computador” que resultou em bons resultados de verificação, porém somente para assinaturas relativamente consistentes. Não tentamos solucionar este problema complexo e fundamental que exige o desenvolvimento de um modelo estatístico para assinaturas humanas. Porém, através da introdução de um modelo estatístico para conjuntos de características paramétricas de assinaturas genuínas, podemos gerar uma quantidade grande de vetores de características simuladas para estimar os desempenhos assintóticos do nosso sistema de verificação de assinaturas. Postulamos um modelo estatístico aditivo do tipo

$$X = M + N, \quad (5)$$

onde $X = (X_1, X_2, \dots, X_n)$ é um vetor aleatório de dimensão n representando o conjunto de características paramétricas da assinatura, M é um vetor de dimensão n de constantes, N é um vetor gaussiano de dimensão n com a média zero e a matriz de covariância C . Neste trabalho, M é um vetor médio amostral obtido através do conjunto de dados genuínos do indivíduo. O procedimento e o resultado da avaliação do modelo estatístico proposto são descritos na próxima seção.

6. RESULTADOS EXPERIMENTAIS E CONCLUSÕES

A verificação de assinatura é um problema de classificação de padrões de duas classes, isto é, um problema de teste de hipóteses. A hipótese nula assume que a assinatura testada é verdadeira e a hipótese alternativa considera esta como sendo uma tentativa de imitação. Por tanto, para avaliar o desempenho de um sistema de verificação de assinaturas, dois

tipos de erros são definidos: erro de falsa rejeição (Erro Tipo I) e erro de falsa aceitação (Erro Tipo II) (Plamondon e Lorette, 1989). A curva característica de operação do receptor (COR), conforme exemplificada na figura 1, é o método comumente usado para mostrar o compromisso entre dois tipos de erros (Lee, 1992). A exigência chave para o desempenho de aplicações comerciais é que o erro Tipo II deve permanecer pequeno (por exemplo, $\leq 25\%$) quando o limiar de decisão é ajustado para resultar em zero o Erro Tipo I. Em seguida, apresentamos os resultados experimentais dos classificadores majoritários mostrando que os classificadores majoritários são adequados para aplicações em pontos comerciais. Resultados adicionais podem ser encontrados em Lee (1992).

A Figura 1-a ilustra a medida do desempenho dos classificadores majoritários que empregam quatro conjuntos distintos de 10 características e um conjunto de 13 características estáticas, todas selecionadas do conjunto de 42 características. A linha sólida e a linha tracejada intercalada de pontos representam os desempenhos dos conjuntos individualizados de 10 características selecionadas com e sem dados de referência de falsificações em disposição, respectivamente. A linha sólida com a marca * é o desempenho de um classificador majoritário usando somente um conjunto de 13 características estáticas. A linha tracejada é o desempenho do conjunto comum de 10 características selecionadas da base de dados de referência de assinaturas de 22 indivíduos, ou seja, 22 bancos de dados de 6 assinaturas genuínas e 8 falsificações estaticamente habilitadas para cada indivíduo. A curva de desempenho foi obtida com a avaliação da base de dados de teste composta de 5 assinaturas genuínas e 22 falsificações estaticamente habilitadas para cada indivíduo do ensemble dos mesmos 22 indivíduos acima. Finalmente, a linha pontilhada mostra o desempenho do mesmo conjunto comum de 10 características, porém, usando simultaneamente um mesmo banco de dados de 11 assinaturas genuínas para cada um dos 22 indivíduos tanto para o treinamento como para o teste do classificador.

Da figura 1-a concluímos que: (1) usando um banco de dados genuínos maior na seleção de características comuns resulta em um melhor desempenho do classificador majoritário; (2) nossos conjuntos comuns de características alcançam desempenho satisfatório para aplicações em pontos comerciais; (3) nossos algoritmos de seleção de características são capazes de prover subconjuntos individualizados com a discriminação excelente entre classes genuínas e falsificadas; finalmente, e talvez a mais importante, (4) os sistemas de verificação de assinaturas em tempo real que incluem características dinâmicas são superiores em relação às características estáticas, especialmente em aplicações em pontos comerciais onde nenhum erro Tipo I é exigido.

Também observamos que o classificador majoritário usando um conjunto individualizado de 34 características fornece um desempenho global ótimo em relação aos subconjuntos de características de quaisquer outros tamanhos selecionados entre as 42 características quando o algoritmo de seleção usa somente assinaturas genuínas. Quando ambos os dados genuínos e falsificados são usados no processo de seleção de características discriminantes, o desempenho do classificador majoritário usando os subconjuntos individualizados de 24 características selecionadas é o melhor do que o dos subconjuntos de quaisquer outras dimensões. Estes resultados mostram efetivamente que os dados de falsificação são desejáveis, visto que os dados de falsificação podem ajudar a melhorar o desempenho do classificador resultando numa

estrutura mais simples, já que menos parâmetros estão envolvidos no processo de classificação.

Para convalidar a eficiência do nosso modelo estatístico para características paramétricas da assinatura, o desempenho de um classificador majoritário baseado em dados simulados gerados pelo modelo descrito na Seção 5 foi comparado com aquele obtido com os dados reais. Conforme mostrado na Figura 1-b, para o conjunto ótimo de 10 características, o resultado da simulação é muito próximo àqueles dos dados reais. Resultados similares também foram observados na maioria dos subconjuntos de características com ordens diferentes, exceto nos casos de subconjuntos com ordem muito menor (por exemplo, 5 características), e daqueles com ordens muito grandes (por exemplo, 42 características). Mesmo assim, a maior discrepância em desempenho em termos da taxa de erros iguais (Erro Tipo I = Erro Tipo II) é de aproximadamente 5%. Uma possível explicação para estes resultados é que algumas características, tais como o número de “pen-ups” e o número de pontos isolados na assinatura, assumindo somente valores discretos, não podem ser aproximadas por variáveis gaussianas. A curva “Dados Reais” do desempenho do classificador majoritário na Figura 1-b foi obtida através de testes de 1000 assinaturas genuínas, todas coletadas de um mesmo sujeito, e 325 falsificações estaticamente habilitadas coletadas de 13 falsificadores. Comparando a Figura 1-b com a Figura 1-a, podemos concluir que nosso modelo estatístico é uma ferramenta útil, não apenas para calcular desempenhos assintóticos individuais, mas também para testar as implementações de novos classificadores e reduzir consideravelmente as cargas de coleção extensiva de amostras de assinaturas reais, tanto as genuínas como as falsificadas.

A Figura 1-c compara os desempenhos dos classificadores majoritários usando os subconjuntos individualizados dos 15 melhores características selecionadas dos respectivos conjuntos de 42 e 49 características e testados pelas assinaturas genuínas “rápidas”. As duas curvas de desempenho sugerem que um sistema confiável de verificação de assinaturas deve utilizar as características normalizadas com o objetivo fornecer desempenhos satisfatórios mesmo quando ocorrer uma variação significativa da velocidade de escrita da assinatura. As curvas de desempenho da Figura 1-c convalidam as suposições feitas na Seção 3 em relação ao processo de seleção de características.

A Figura 1-d apresenta o desempenho de um classificador majoritário versus o limiar de decisão para Banco de Dados Rápidos e Banco de Dados Globais usando as 15 melhores características individualizadas, selecionadas do conjunto de 49 características. Para aplicações em pontos comerciais, escolhemos um limiar de decisão 2,5 que resulta num erro Tipo I menor que 1% para assinaturas de velocidades normais (N) e um erro Tipo II de 20%. Note que o mesmo limiar de decisão resultou em 5% erro Tipo I para as assinaturas rápidas (S). Vale a pena mencionar que, na prática, a degradação poderia estar muito abaixo de 4% visto que relativamente um indivíduo raramente escreve sua assinatura com uma velocidade extremamente alta. Além disso, esperamos que o mesmo indivíduo também tolere pacientemente uma taxa de rejeição mais alta, devido a sua pressa na escrita. A partir da Figura 1-d, concluímos que usando um limiar no intervalo entre 2,5 e 3,0 para os melhores 15 parâmetros do conjunto de 49 características normalizadas, temos um classificador que fornece erros Tipo I e Tipo II adequados para pontos comerciais e, ao mesmo tempo, é robusto em relação à variação da velocidade de assinaturas genuínas.

Os resultados experimentais revelam que apenas 15% das assinaturas genuínas possuem durações de escrita desviadas dos seus valores nominais por mais de 18% ($\beta=0,18$). Sob as condições normais de escritas, poucos indivíduos possuem a duração das assinaturas desviada do seu valor nominal mais de 20%. As Figuras 1-e e 1-f mostram, respectivamente, o desempenho do classificador majoritário com pré-decisão suave e com pré-decisão abrupta definido na Seção 4.1. Comparando as Figuras 1-e e 1-f com 1-c podemos observar

que um melhoramento notável é alcançado com as regras de decisão majoritária modificada. O classificador majoritário pré-abrupto oferece o melhor desempenho dentre os classificadores estudados neste trabalho: aproximadamente 2,5% das taxas iguais de erros e, mais importante, para casos de pontos comerciais, um desempenho de 7% da taxa de aceitação falsa para uma taxa nula de rejeição falsa utilizando apenas 15 características paramétricas individualizadas selecionadas do conjunto de 49 características. Mais do que isso, este desempenho foi atingido apesar das condições não realísticas

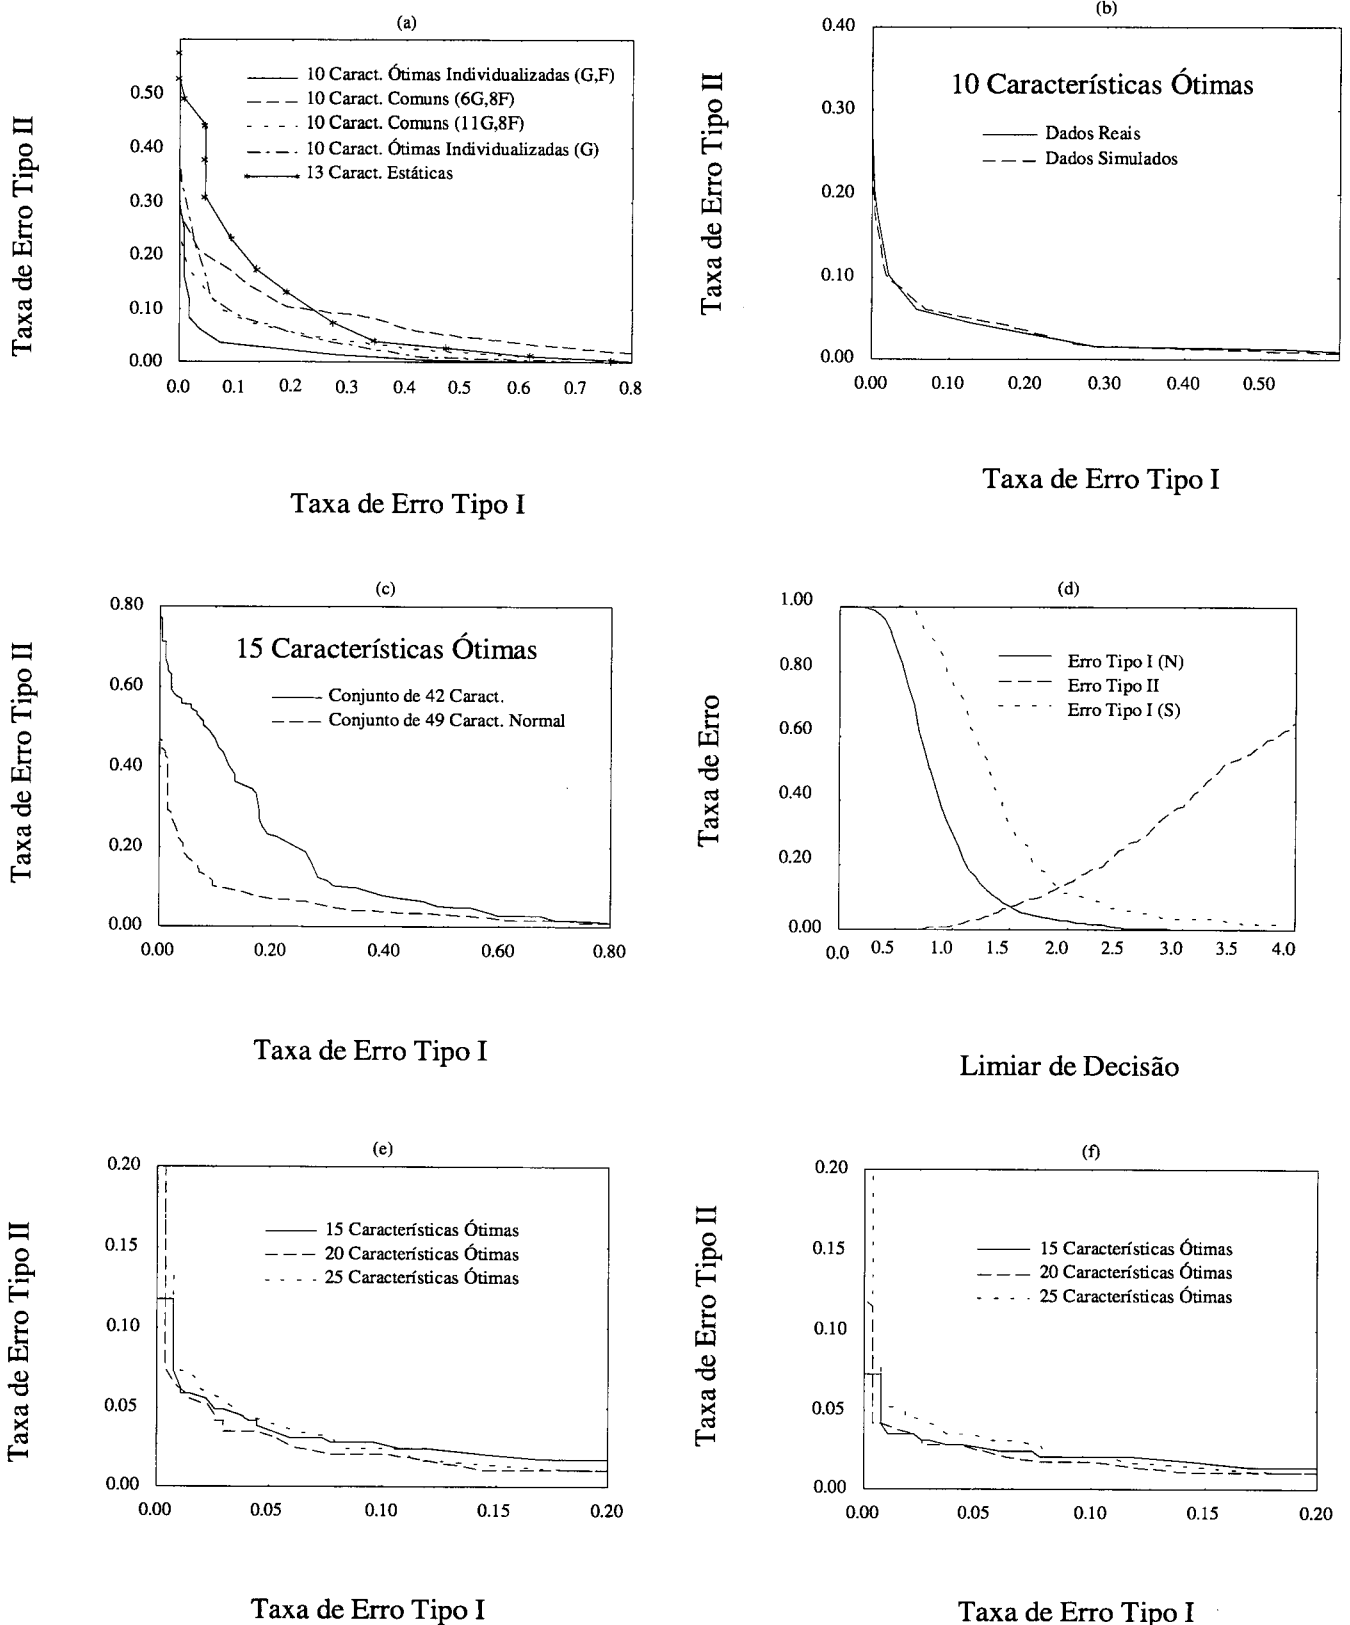


Figura 1: Comparação de desempenhos dos classificadores majoritários

impostas de que todos os falsificadores eram obrigados de produzir imitações com o mesmo tempo da assinatura genuína, sem mencionar ainda que cada falsificador foi submetido a um processo de treinamento, praticando intensamente as imitações estáticas antes que os dados das falsificações fossem efetivamente coletados. Em particular, o classificador majoritário pré-suave detecta aproximadamente 50% das falsificações cronometradas enquanto 99% das assinatura genuínas são classificadas com sucesso conforme mostrado pela curva de desempenho da Figura 2.

Nossos resultados fornecem uma base para um método de um sistema adaptativo de verificação de assinaturas dinâmicas em tempo real (Lee e Berger, 1996) adequada para aplicações em pontos comerciais em termos de desempenho, memória e custo. Além disso, as características genuínas podem ser facilmente atualizadas para adaptar as mudanças nas assinaturas de um indivíduo no tempo. Os resultados dos testes feitos sobre nosso sistema de verificação mostram que ele é adequado para tarefas em tempo real. Usando um PC com um processador 486, o algoritmo de verificação exige menos de 1,5 segundos para efetuar a verificação de uma assinatura, mesmo usando o algoritmo de códigos ainda não otimizado. Acreditamos que o algoritmo implementado em chips dedicados numa realização comercial do sistema proposto poderia diminuir ainda mais o tempo de verificação. Assim sendo uma implementação via um "smart card" aparentemente é plausível.

REFERÊNCIAS BIBLIOGRÁFICAS

- Plamondon, R. and G. Lorette (1989). Automatic signature verification and writer, identification - the state of the art. *Pattern Recognition*, Vol. 22, n° 2, pp. 107-131.
- Leclerc, F. and R. Plamondon (1994). Automatic signature verification: the state of the art. *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 8, n° 3, pp. 643-660.
- Dimauro, G., S. Impedovo and G. Pirlo (1994). Component-oriented algorithms for signature verification. *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 8, n° 3, pp. 771-793.
- Plamondon, R. (1994). The design of an on-line signature verification system: from theory to practice. *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 8, n° 3, pp. 795-811.
- Nelson, W., W. Turin and T. Hastie (1994) Statistical methods for on-line signature verification. *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 8, n° 3, pp. 749-770.
- Fairhurst, M. C. and P. Brittan (1994). An evaluation of parallel strategies for feature vector construction in automatic signature verification systems. *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 8, n° 3, pp. 661-678.
- Yang, L., B. K. Widjaja and R. Prasad (1995). Application of hidden markov model for signature. *Pattern Recognition*, Vol. 28, n° 2, pp. 161-170.
- Achemlal, M., M. Mourier, G. Lorette and J. P. Bonnefoy (1989). Dynamic signature verification. A. Grissonnanche (Editor), *Security and Protection in Information Systems*, pp. 381-389, Elsevier Science Publishers B. V. (North-Holland).
- Bonnefoy, J.P., P. Jounet, G. Lorette and M. Gaudaire (1981). Reconnaissance automatique, en temps reel de signatures manuscrites: definition et mise en oeuvre d'une methodologie generale. *Proc. 3rd Congres Rec. des Formes et Intel. Artif.*, pp. 267-275, Nancy-France.
- Crane, H. D., and J. S. Ostrem (1983). Automatic signature verification using a three-axis-force-sensitive pen. *IEEE Trans. Syst. Man. Cybernetics*, Vol. 12, pp. 329-337.
- Kishon, E., T. Hastie, M. Clark and J. Fan (1991). A Statistical Model for Signature Verification. *Proc. IEEE Conf. on Systems, Man and Cybernetics*, Charlottesville - VA.
- Aviczer, E. (1991). On-line signature verification model. M.

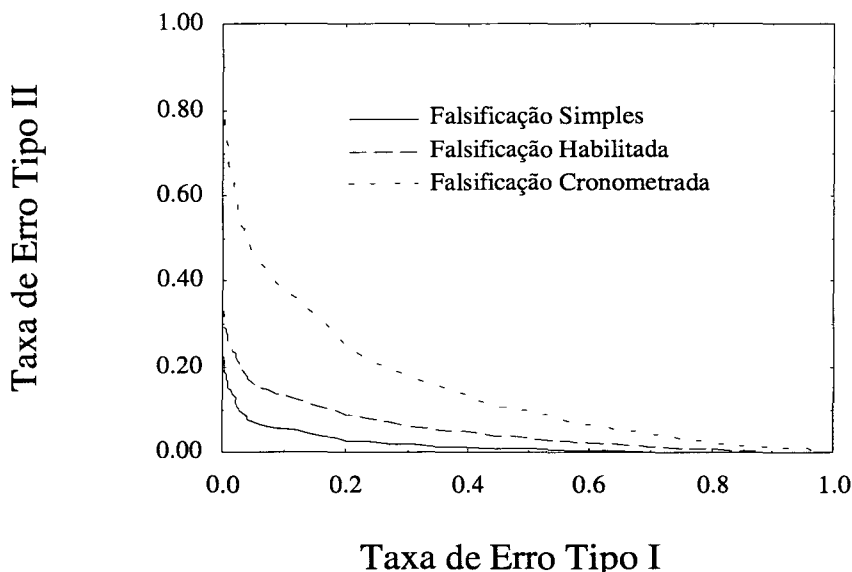


Figura 2: Taxas de erros versus tipo de falsificações

Lee, L. L. (1992). On-line systems for human signature verification. Ph.D. Dissertation, School of Electrical Engineering, Cornell University, Ithaca, USA.

Lee, L. L. and T. Berger (1996). Adaptive method and system for real time verification of dynamic human signatures. United States Letters Patent 07/790.965.

Lorette, G. (1984). On-line handwritten signature recognition based on data analysis and clustering. *Proc. of 7th Int. Conf. on Pattern Recognition*, Vol. 2, pp. 1284-1287, Montreal - Canada.

Sato, Y. and K. Kogure (1982). On-line signature verification based on shape, motion, and writing pressure. *IEEE Proc. 6th Int. Conf. on Pattern Recognition*, pp.823-826, Munich - Germany.

Lee, L. L. and T. Berger (1993a). Optimization of a signature verification system using neural network. *Proc. Int. Conf. of Artif. Neural Net. - ICANN*, Amsterdam, Netherlands.

Lee, L. L. and T. Berger (1993b). On two-pattern classification using a neural networks. *Proc. Int. Conf. on Signal Process. - ICSP'93*, Beijing - China.

Chiu, Y. J. (1992). On-line signature verification. M. Eng. Project Report, School of Electrical Engineering, Cornell University, Ithaca, USA.

APÊNDICE A: Conjunto de 42 Características

Antes de listarmos os conjuntos de 42 e 49 características, por conveniência introduzimos as seguintes definições:

- $x_0 = x(\text{primeiro "pen down"})$; $y_0 = y(\text{primeiro "pen down"})$;
 - $x_{end} = x(\text{último "pen up"})$; $y_{end} = y(\text{último "pen up"})$;
 - $x_{max} = x \text{ máxima}$; $y_{max} = y \text{ máxima}$;
 - $x_{min} = x \text{ mínima}$; $y_{min} = y \text{ mínima}$;
 - $d_x = |x_{max} - x_{min}|$; $d_y = |y_{max} - y_{min}|$;
 - Δ_x : deslocamento total de (x) em "pen downs";
 - Δ_y : deslocamento total de (y) em "pen downs".
1. Velocidade média de escrita (\bar{v});
 2. Máxima velocidade de escrita (v_{max});
 3. Instante de ocorrência da máxima velocidade de escrita ($t(v_{max})$);
 4. $t(1^{\text{º}}$ movimento da caneta) - $t(1^{\text{ª}}$ "pen down")
 5. Duração total da assinatura (T_s);
 6. Duração total de "pen downs" (T_w);
 7. Mínima velocidade de escrita na direção horizontal (x);

8. Instante de ocorrência da característica 7;
9. Número total de pontos isolados registrados;
10. Tempo médio de execução de um ponto isolado;
11. Número de "pen ups";
12. Instante de ocorrência da segunda "pen down";
13. Direção inicial;
14. Direção da 1ª à 2ª "pen down";
15. Direção da 1ª "pen down" à 2ª "pen up";
16. Direção inicial após a 2ª "pen down"
17. Direção da 1ª "pen down" à última "pen up";
18. Duração de $v_x > 0$;
19. Duração de $v_x < 0$;
20. Duração de $v_y > 0$;
21. Duração de $v_y < 0$;
22. Média de v_x positiva;
23. Média de v_x negativa;
24. Média de v_y positiva;
25. Média de v_y negativa;
26. Número total de eventos registrados de $v_x = 0$;
27. Número total de eventos registrados de $v_y = 0$;
28. $\text{Max } v_x - \text{avg } v_x$;
29. $\text{Max } v_y - \text{avg } v_y$;
30. $\text{Max } v_x - \text{min } v_x$;
31. $\text{Max } v_x - \text{min } v_y$;
32. $\text{Max } v_y - \text{min } v_y$;
33. $t(x_{max})/T_w$;
34. $t(x_{min})/T_w$;
35. $(x_{max} - x_{min}) * (y_{max} - y_{min}) = A_{min}$;
36. Comprimento da assinatura / A_{min} ;
37. $x_0 - x_{min}$;
38. $x_{end} - x_{max}$;
39. $x_{end} - x_{min}$;
40. $(x_{max} - x_{min}) / (y_{max} - y_{min})$;
41. Desvio padrão de x;
42. Desvio padrão de y;

APÊNDICE B: Conjunto de 49 Características Normalizadas

1. T_w / T_s ;
2. $t(v_{max}) / T_w$;
3. \bar{v} / v_{max} ;
4. (Duração de $v_x > 0$) / T_w ;
5. (Duração de $v_x < 0$) / T_w ;
6. (Duração de $v_y > 0$) / T_w ;
7. (Duração de $v_y < 0$) / T_w ;
8. (Duração de $v_x > 0$ em “pen ups”) / $(T_s - T_w)$;
9. (Duração de $v_x < 0$ em “pen ups”) / $(T_s - T_w)$;
10. (Duração de $v_y > 0$ em “pen ups”) / $(T_s - T_w)$;
11. (Duração de $v_y < 0$ em “pen ups”) / $(T_s - T_w)$;
12. Direção inicial normalizada (d_x / d_y);
13. Direção da 1ª à 2ª “pen down” / (d_x / d_y);
14. Direção do 1ª “pen down” à 2ª “pen up” / (d_x / d_y);
15. Direção inicial após a 2ª “pen down” / (d_x / d_y);
16. Direção antes da última “pen up” / (d_x / d_y);
17. Direção do 1ª “pen down” à última “pen up” / (d_x / d_y);
18. Número total de pontos isolados registrados;
19. Número de “pen ups”;
20. Instante de ocorrência da segunda “pen down” / T_s ;
21. Duração total da execução dos pontos / T_w ;
22. $t(\max v_y) / T_w$;
23. $t(\min v_y) / T_w$;
24. $t(\max v_x) / T_w$;
25. $t(\min v_x) / T_w$;
26. Número total de eventos registrados de $v_x = 0$;
27. Número total de eventos registrados de $v_y = 0$;
28. Número total de mudanças de inclinação em termos de quadrantes;
29. $\bar{v} / \max v_x$;
30. $\bar{v} / \max v_y$;
31. $(\text{Mín } v_x) / -$;
32. $(\text{Mín } v_y) / -$;
33. Primeiro instante de $v \neq 0$;

34. $A_{min} / (\Delta_x * \Delta_y)$;
35. Comprimento da assinatura / A_{min} ;
36. $(x_0 - x_{max}) / \Delta_x$;
37. $(x_0 - x_{min}) / \Delta_x$;
38. $(x_{end} - x_{max}) / \Delta_x$;
39. $(x_{end} - x_{min}) / \Delta_x$;
40. $(y_0 - y_{max}) / \Delta_y$;
41. $(y_0 - y_{min}) / \Delta_y$;
42. $(y_{end} - y_{max}) / \Delta_y$;
43. $(y_{end} - y_{min}) / \Delta_y$;
44. $[(x_{max} - x_{min}) / (y_{max} - y_{min})] / [\Delta_x / \Delta_y]$;
45. (Desvio padrão de x) / Δ_x ;
46. (Desvio padrão de y) / Δ_y ;
47. Duração da inclinação positiva / duração da inclinação negativa;
48. Distância da escrita com a inclinação nos quadrantes 1 e 3 / Distância da escrita com a inclinação nos quadrantes 2 e 4;
49. Duração total da alta curvatura da assinatura / T_w .

APÊNDICE C: Algoritmos

I) Algoritmo de extração de características: a extração de características dos conjuntos de 42 e 49 características deve seguir as definições mostradas nos Apêndices A e B, respectivamente.

II) Seleção de M características do conjunto de N características sem dados falsificados.

a) Para $i=1, \dots, N$, calcular $d_i(a)$ usando equação (2);

b) Selecionar aquelas M características com maiores $d_i(a)$'s.

III) Seleção de M características do conjunto de N características quando ambos os dados genuínos e falsificados estiverem disponíveis.

a) Para $i=1, \dots, N$, calcular $d_i(a)$ usando a equação (3);

b) Selecionar aquelas M características com maiores $d_i(a)$'s.

IV) Regra de decisão majoritária:

a) Calcular N_α conforme a equação (4) onde normalmente $1 < \alpha < 2$;

b) Se $N_\alpha \geq n/2$, a assinatura T avaliada é declarada como uma assinatura genuína;

c) Caso contrário ($N_\alpha < n/2$), T é considerada como uma tentativamente de falsificação.

V) Regra de decisão majoritária modificada com decisão suave:

- a) Avaliar $|t_w - \bar{t}_w| > \beta \bar{t}_w$, onde t_w = tempo da escrita, \bar{t}_w = duração média da escrita e $\beta = 0,2$;
- b) Se $|t_w - \bar{t}_w| > \beta \bar{t}_w$, então não normalizar as características dinâmicas do conjunto de características selecionadas através do algoritmo de seleção de características (Algoritmo II ou III);
- c) Aplicar a regra de decisão majoritária convencional sobre o conjunto de características selecionadas.

VI) Regra de decisão majoritária modificada com decisão abrupta:

- a) Avaliar $|t_w - \bar{t}_w| > \beta \bar{t}_w$, onde t_w = tempo da escrita, \bar{t}_w = duração média da escrita e $\beta = 0,2$;
- b) Se $|t_w - \bar{t}_w| > \beta \bar{t}_w$, então T é considerada como uma tentativa de falsificação.
- c) Caso contrário ($|t_w - \bar{t}_w| < \beta \bar{t}_w$), aplicar a regra de decisão majoritária convencional sobre o conjunto de características selecionadas.