

CESAR ROBERTO SANTOS

**ANÁLISE DE ASSINATURAS MANUSCRITAS
BASEADA NOS PRINCÍPIOS DA GRAFOSCOPIA**

Dissertação apresentada ao Programa de Pós-Graduação em Informática Aplicada da Pontifícia Universidade Católica do Paraná como requisito parcial para obtenção do título de Mestre em Informática Aplicada.

CURITIBA

2004

CESAR ROBERTO SANTOS

**ANÁLISE DE ASSINATURAS MANUSCRITAS
BASEADA NOS PRINCÍPIOS DA GRAFOSCOPIA**

Dissertação apresentada ao Programa de Pós-Graduação em Informática Aplicada da Pontifícia Universidade Católica do Paraná como requisito parcial para obtenção do título de Mestre em Informática Aplicada.

Área de Concentração: Metodologias e Técnicas de Computação

Orientador: Prof. Dr. Flavio Bortolozzi

Co-orientador: Prof. Dr. Edson José Rodrigues Justino

CURITIBA

2004

Santos, Cesar Roberto

Análise de Assinaturas Manuscritas Baseada nos Princípios da Grafoscopia. Curitiba, 2004. 132p.

Dissertação - Pontifícia Universidade Católica do Paraná. Programa de Pós Graduação em Informática Aplicada.

1. Análise pericial de documentos questionados. 2. Verificação de Assinaturas. 3. Redes Neurais. 4. Características grafométricas extraídas. I. Pontifícia Universidade Católica do Paraná. Centro de Ciências Exatas e Tecnologia. Programa de Pós-Graduação em Informática aplicada.

Dedico este trabalho a minha esposa Ceres pela paciência e compreensão demonstrada e também ao meu filho Nathan.

Agradecimentos

À Deus que me deu forças nos momentos de desânimo desta jornada.

À minha esposa, meu filho, e, também, aos meus pais que sempre me incentivam a continuar lutando pelos meus ideais.

Ao Professor Orientador Dr. Flávio Bortolozzi pelas contribuições seguras. Ao Professor e amigo Co-orientador Dr. Edson Justino pela ajuda na fundamentação teórica do trabalho, pelos questionamentos e contribuições construtivas, pelo incentivo e ainda pelo laço de amizade construído.

Ao Professor Dr. Robert Sabourin pela fundamentação teórica e contribuições seguras dadas a este trabalho.

Ao amigo e Professor Dr. Alceu de Souza Brito Jr. pelo incentivo a ingressar nesta jornada fornecendo a oportunidade de demonstrar meu potencial.

À Pontifícia Universidade Católica do Paraná pelo apoio financeiro, em especial ao Programa de Pós-Graduação em Informática Aplicada (PPGIA), pelo apoio estrutural que permitiu a realização deste trabalho.

Aos meus Colegas de estudos, Professores, e Funcionários do PPGIA.

A todos que direta ou indiretamente colaboraram na realização deste trabalho.

SUMÁRIO

| | |
|--|-------------|
| LISTA DE FIGURAS..... | VIII |
| LISTA DE TABELAS | XII |
| LISTA DE ABREVIATURAS E SIGLAS..... | XIII |
| LISTA DE SÍMBOLOS..... | XIV |
| RESUMO | XV |
| ABSTRACT | XVI |
| 1. INTRODUÇÃO | 1 |
| 1.1. DESAFIO | 2 |
| 1.2. MOTIVAÇÃO | 5 |
| 1.3. PROPOSTA..... | 6 |
| 1.4. CONTRIBUIÇÕES..... | 7 |
| 1.5. ORGANIZAÇÃO DA DISSERTAÇÃO | 7 |
| 2. FUNDAMENTAÇÃO TEÓRICA..... | 8 |
| 2.1. RECONHECIMENTO DE PADRÕES | 8 |
| 2.2. TIPOS DE ABORDAGENS NA VERIFICAÇÃO DE ASSINATURAS | 10 |
| 2.3. MÉTODOS DE VERIFICAÇÃO | 12 |
| 2.4. TEORIA DA CLASSIFICAÇÃO BAYESIANA..... | 14 |
| 2.4.1. <i>Teoria de Decisão Bayesiana</i> | 15 |
| 2.5. REDES NEURAS ARTIFICIAIS..... | 17 |
| 2.5.1. <i>Perceptron Multicamadas</i> | 18 |
| 2.5.2. <i>Melhorias de Desempenho da Rede Neural</i> | 19 |
| 2.5.3. <i>Aprendizagem em Redes MLP</i> | 23 |
| 2.5.4. <i>Métodos de Validação do Processo de Aprendizagem</i> | 30 |
| 2.6. SVM | 31 |
| 2.7. COMENTÁRIOS FINAIS | 35 |
| 3. ESTADO DA ARTE NA AUTENTICAÇÃO DE ASSINATURAS..... | 36 |
| 3.1. ABORDAGENS GLOBAIS..... | 36 |
| 3.2. ABORDAGENS LOCAIS | 38 |
| 3.3. ABORDAGENS GLOBAIS E LOCAIS..... | 41 |
| 3.4. VISÃO CRÍTICA DO ESTADO DA ARTE | 45 |
| 3.5. COMENTÁRIOS FINAIS | 46 |
| 4. METODOLOGIA..... | 48 |
| 4.1. REQUISITOS | 48 |
| 4.2. RECURSOS | 49 |

| | |
|--|------------|
| 4.3. GRAFISMO | 49 |
| 4.3.1. <i>Grafoscopia</i> | 50 |
| 4.3.2. <i>Grafologia</i> | 58 |
| 4.3.3. <i>Considerações sobre o Grafismo</i> | 63 |
| 4.4. MEDIDAS DE DISTÂNCIA | 65 |
| 4.4.1. <i>Distância Euclidiana</i> | 66 |
| 4.4.2. <i>Distância Euclidiana Quadrática</i> | 67 |
| 4.4.3. <i>Distância de Manhattan ‘Bloco-Cidade’</i> | 67 |
| 4.5. DICOTOMIA..... | 67 |
| 4.5.1. <i>Transformação Dicotômica</i> | 69 |
| 4.5.2. <i>Comparando Policotomia e Dicotomia</i> | 72 |
| 4.5.3. <i>Resumo da Abordagem Dicotômica</i> | 74 |
| 4.6. COMENTÁRIOS FINAIS | 74 |
| 5. MÉTODO PROPOSTO..... | 75 |
| 5.1. VISÃO DO PERITO NA ANÁLISE DE ASSINATURAS QUESTIONADAS | 75 |
| 5.2. ETAPAS NO PROCESSO DE VERIFICAÇÃO DE ASSINATURAS | 78 |
| 5.2.1. <i>Aquisição e Pré-processamento</i> | 79 |
| 5.2.2. <i>Segmentação</i> | 82 |
| 5.2.3. <i>Extração das Primitivas</i> | 84 |
| 5.2.4. <i>Cálculo das Distâncias entre as Primitivas</i> | 94 |
| 5.2.5. <i>Produção de Um Modelo</i> | 96 |
| 5.2.6. <i>Processo de Decisão</i> | 98 |
| 5.3. COMENTÁRIOS FINAIS | 102 |
| 6. EXPERIMENTOS REALIZADOS E ANÁLISES DOS ERROS..... | 103 |
| 6.1. PROTOCOLO DE AVALIAÇÃO..... | 103 |
| 6.2. OS EXPERIMENTOS | 106 |
| 6.2.1. <i>Determinação da Resolução do Grid na Segmentação</i> | 107 |
| 6.2.2. <i>Máxima Combinação de Amostras</i> | 107 |
| 6.2.3. <i>Balanceamento do Número de Amostras de Cada Classe</i> | 108 |
| 6.2.4. <i>Seleção do Conjunto de Primitivas</i> | 109 |
| 6.2.5. <i>Aumento na Quantidade de Autores e Variação nas Amostras</i> | 110 |
| 6.2.6. <i>Limiares de Rejeição e Aceitação</i> | 112 |
| 6.2.7. <i>SVM</i> | 113 |
| 6.2.8. <i>Comparativo do Método Proposto com a Análise Humana</i> | 114 |
| 6.3. ESTIMANDO A PROBABILIDADE DO ERRO | 115 |
| 6.4. COMENTÁRIOS FINAIS | 118 |
| 7. CONCLUSÃO E TRABALHOS FUTUROS..... | 120 |
| 7.1. CONCLUSÃO | 120 |
| 7.2. TRABALHOS FUTUROS..... | 121 |
| 8. REFERÊNCIAS BIBLIOGRÁFICAS..... | 123 |
| A. EXPERIMENTO COM KERNEL LINEAR DO SVM..... | 131 |
| B. EXPERIMENTO COM OUTRAS MEDIDAS DE DISTÂNCIAS..... | 132 |

Lista de Figuras

| | | |
|------------|--|----|
| Figura 1.1 | Exemplo de (a) assinatura genuína de um autor em específico, (b) variação intrapessoal medida pela sobreposição de três assinaturas genuínas do mesmo autor. | 3 |
| Figura 1.2 | Similaridade interpessoal (a) e (b). | 3 |
| Figura 1.3 | Exemplo de (a) assinatura original, (b) falsificação aleatória, (c) falsificação simulada, (d) falsificação simples. | 4 |
| Figura 1.4 | Separação entre as classes w_1 e w_2 no espaço \mathfrak{R}^2 . | 5 |
| Figura 2.1 | Modelo genérico do método de reconhecimento de padrões. | 10 |
| Figura 2.2 | Diagrama hierárquico de classificação dos tipos de abordagens de verificação de assinaturas. | 12 |
| Figura 2.3 | Modelo simplificado de um neurônio. | 17 |
| Figura 2.4 | Interpretação geométrica das regras de unidades escondidas em um espaço bi-dimensional de acordo com Lippmann [LIPPMANN, 1987]. | 21 |
| Figura 2.5 | Curvas de aprendizagem com relação ao excesso ou falta de treinamento. | 28 |
| Figura 2.6 | Probabilidade do erro para um problema de duas classes. | 29 |
| Figura 2.7 | Margem de separação máxima para duas classes. | 32 |
| Figura 2.8 | Superfície de decisão de um classificador polinomial. | 33 |
| Figura 4.1 | Assinatura de calibre reduzido (a) e de alto calibre (b). | 51 |
| Figura 4.2 | Assinatura cursiva com espaçamentos entre os nome e sobrenomes. | 51 |
| Figura 4.3 | Exemplo de assinatura inclinada em documento não-pautado. | 52 |
| Figura 4.4 | Exemplo de inclinação à direita (a) e à esquerda (b). | 53 |
| Figura 4.5 | Exemplo de assinatura de segmentos angulares (a) e com segmentos curvilíneos (b). | 53 |
| Figura 4.6 | Exemplo de mínimos gráficos. | 54 |
| Figura 4.7 | Exemplo de assinatura com escrita rápida (a) e lenta (b). | 54 |
| Figura 4.8 | Exemplo de assinatura com relação a início e fim abrupto: (a) Assinatura original; (b) Assinatura falsificada. | 55 |

| | | |
|-------------|--|----|
| Figura 4.9 | Exemplo de assinatura relacionada a elevação do objeto de escrita: (a) Assinatura original; (b) Falsificação com elevação do objeto de escrita. | 56 |
| Figura 4.10 | Exemplos de assinaturas sem tremores e com tremores: (a) Assinatura original; (b) Assinatura falsificada com traçado trêmulo. | 56 |
| Figura 4.11 | Exemplos de assinaturas sem pressão e com pressão (a) Assinatura original. (b) Falsificação simulada com pontos de pressão. | 57 |
| Figura 4.12 | Exemplos de assinaturas sem e com correções (a) Assinatura original. (b) Falsificação simulada com pontos corrigidos. | 57 |
| Figura 4.13 | Exemplos de assinaturas sob o ponto de vista da ordem, podendo ser uma assinatura: (a) clara; (b) confusa; (c) concentrada; (d) espaçada. | 60 |
| Figura 4.14 | Exemplos de assinaturas com relação a simetria: (a) Assinatura proporcional; (b) Assinatura desproporcional; (c) Assinatura mista. | 60 |
| Figura 4.15 | Exemplos de assinaturas com relação a dimensão: (a) Assinatura alta; (b) Assinatura baixa. | 61 |
| Figura 4.16 | Exemplos de assinaturas com relação a pressão: (a) Assinatura tensa; (b) Assinatura frouxa. | 61 |
| Figura 4.17 | Exemplos de assinaturas sob o ponto de vista da forma: (a) Assinatura caligráfica; (b) Assinatura arredondada; (c) Assinatura reta vertical; (d) Assinatura reta horizontal. | 62 |
| Figura 4.18 | Exemplos de assinaturas do ponto de vista de gestos característicos: (a) Gancho; (b) Clava; (c) Golpe de sabre e inflada; (d) Espiral; (e) Movimento em triângulo e laço; (f) Bucle; (g) Arco; (h) Guirlanda e serpentina. | 63 |
| Figura 4.19 | Precisão nas métricas de distância euclidiana, euclidiana quadrática e bloco-cidade. | 66 |
| Figura 4.20 | Hierarquia de tipos de características de acordo com Cha [CHA, 2001]. | 69 |
| Figura 4.21 | Transformação de: (a) Domínio das características (policotomia) para (b) Domínio das distâncias das características (dicotomia). | 70 |
| Figura 4.22 | Distribuição das distâncias das características no espaço 3D. | 71 |
| Figura 4.23 | Distribuição do erro <i>Tipo I</i> e <i>Tipo II</i> . | 72 |
| Figura 4.24 | Comparação entre (a) Domínio das características (policotomia) e (b) Domínio das distâncias das características (dicotomia) [CHA, 2001]. | 73 |

| | | |
|-------------|--|----|
| Figura 4.25 | Processo de Verificação e transformação dicotômica baseada em [CHA, 2001]. | 74 |
| Figura 5.1 | Modelo geral usado na perícia grafotécnica de verificação de autenticidade de assinaturas. | 76 |
| Figura 5.2 | Esquema do processo de decisão na verificação de assinaturas <i>off-line</i> baseado na visão pericial. | 77 |
| Figura 5.3 | Um comparativo nas etapas no processo de verificação de assinaturas: (a) processo de análise e decisão pericial; (b) processo computacional proposto. | 78 |
| Figura 5.4 | Estratégia de alinhamento a esquerda: (a) Assinatura Original (b) 3 assinaturas originais sobrepostas (c) Nível de coincidência de <i>pixels</i> . | 82 |
| Figura 5.5 | Exemplos de Segmentações utilizadas no método representando células verticais por horizontais: (a) 4x10; (b) 4x63; (c) 8x20; (d) 10x25; (e) 10x63; (f) 20x20; (g) 25x63. | 84 |
| Figura 5.6 | Primitiva de pontos de pressão (a) imagem original (b) imagem plotada no <i>grid</i> (c) valores de pressão encontrado em cada célula da imagem. | 86 |
| Figura 5.7 | Primitiva de início e fim abrupto (a) imagem original (b) imagem esqueletizada (c) pontos circulados correspondentes a início ou fim do segmento no <i>grid</i> (d) pontos de início e fim correspondentes na imagem original plotado no <i>grid</i> . | 88 |
| Figura 5.8 | Primitiva segmentos de tremor (a) processo de extração dos segmentos mais longos plotados no <i>grid</i> e utilização do código de cadeia (b) resultado do nível de tensão do segmento. | 89 |
| Figura 5.9 | Primitiva densidade de pixels (a) imagem limiarizada (b) imagem plotada no <i>grid</i> com segmento extraído para a contagem de <i>pixels</i> . | 90 |
| Figura 5.10 | Primitiva inclinação axial (a) Conjunto de elementos estruturantes que representam os tipos de inclinação axial da célula (b) Imagem esqueletizada com os valores correspondentes da inclinação axial. | 91 |
| Figura 5.11 | Primitiva implementada por Rigoll e Kosmala [RIGOLL & KOSMALA, 1998] ângulo absoluto e diferença angular. | 91 |
| Figura 5.12 | Diagrama do processo de extração da primitiva curvatura. | 92 |

| | | |
|-------------|--|-----|
| Figura 5.13 | Primitiva centro de gravidade (a) imagem limiarizada plotada no <i>grid</i> e alinhada a esquerda (b) centro de massa de cada célula (c) distância euclidiana d do centro de massa à origem. | 93 |
| Figura 5.14 | Descrição do processo de transformação dicotômica com relação as primitivas implementadas. | 95 |
| Figura 5.15 | Histograma de decisão no conjunto de validação com limiares de decisão. | 101 |
| Figura 6.1 | Exemplo do processo de comparação humana na similaridade entre 2 assinaturas. | 114 |

Lista de Tabelas

| | | |
|-------------|---|-----|
| Tabela 2.1 | Matriz de confusão de três classes | 30 |
| Tabela 2.2 | Alguns kernels do SVM comumente usados. | 34 |
| Tabela 3.1 | Resumo do estado da arte relevante para a dissertação. | 44 |
| Tabela 4.1 | Características combinadas da grafologia e da grafoscopia e as primitivas implementadas. | 64 |
| Tabela 5.1 | Segmentação com múltiplas resoluções. | 83 |
| Tabela 6.1 | Protocolo do número de assinaturas utilizado nos experimentos iniciais. | 104 |
| Tabela 6.2 | Protocolo do amostras utilizadas nos experimentos iniciais. | 105 |
| Tabela 6.3 | Protocolo do número de assinaturas utilizado nos experimentos finais. | 105 |
| Tabela 6.4 | Protocolo do amostras utilizadas nos experimentos finais. | 106 |
| Tabela 6.5 | Resultados com diferentes resoluções de <i>grid</i> . | 107 |
| Tabela 6.6 | Resultados obtidos com a máxima combinação da sub-base de 40 autores. | 108 |
| Tabela 6.7 | Resultados com variação do número de amostras por classe. | 108 |
| Tabela 6.8 | Resultado da seleção do melhor conjunto de primitivas. | 110 |
| Tabela 6.9 | Resultado do aumento da quantidade da autores e variação nas quantidade de amostras. | 111 |
| Tabela 6.10 | Resultados obtidos uso de limiares de rejeição. | 113 |
| Tabela 6.11 | Resultado comparativo de rede MLP com SVM. | 113 |
| Tabela 6.12 | Resultado da avaliação humana do processo de verificação de assinaturas em comparação com a abordagem proposta. | 115 |
| Tabela 6.13 | Estimação por intervalos das taxas de erro do conjunto de teste. | 116 |
| Tabela 6.14 | Tabela de Contingência 2×2 . | 117 |
| Tabela A.1 | Resultado entre SVM com kernel linear e polinomial | 131 |
| Tabela B.1 | Resultado do experimento com outras medidas de distâncias. | 132 |

Lista de Abreviaturas e Siglas

| | |
|--------|---|
| ART | <i>Adaptive Resonance Theory</i> |
| Dpi | <i>Dot per inch</i> |
| HMM | <i>Hidden Markov Model</i> |
| IC | Intervalo de Confiança |
| k-NN | <i>k Nearest Neighbors</i> |
| LARD | Laboratório de Análise e Reconhecimento de Documentos |
| MLP | <i>Multi-Layered Perceptron</i> |
| MMH | Hiperplano de Margem Máxima |
| MSE | Erro quadrático médio |
| PPGIA | Programa de Pós-Graduação de Informática Aplicada |
| PUC-PR | Pontifícia Universidade Católica do Paraná |
| RBF | Redes com Funções de Base Radial |
| RF | Fator de Confiabilidade |
| RNA | Rede Neural Artificial |
| SNNS | <i>Stuttgart Neural Network Simulator</i> |
| SRM | Minimização do Risco Estrutural |
| SV | Vetores de Suporte |
| SVM | <i>Support vector machine</i> |
| QV | Quantização Vetorial |
| VC | Dimensão Vapnik Chervonenkis |

Lista de Símbolos

| | |
|----------------|---|
| d | Dimensão do vetor do atributo. |
| $P(. /. .)$ | Probabilidade a <i>posteriori</i> . |
| $P(. .), P[.]$ | Probabilidade a <i>priori</i> . |
| $f(x)$ | Função de densidade e probabilidade. |
| w | Grupo ou classe. |
| x | Objeto, padrão de entrada ou atributo. |
| y_i | Saída da rede neural, rótulo da saída do SVM |
| $G(x)$ | Função discriminante de Bayes. |
| N, n | Número de classes ou autores. |
| T, T_1, T_2 | Limiares de Rejeição e Aceitação. |
| b | Bias. |
| p | Pesos dos neurônios. |
| η | Constante de aprendizagem. |
| β | Falsa aceitação. |
| α | Falsa rejeição. |
| Φ | Hiperplano de separação ótima. |
| $K(x_i, x)$ | Função do kernel. |
| C | Penalidade do erro no SVM. |
| ξ | Magnitude do erro de classificação. |
| \bar{p} | Vetor de pesos no SVM. |
| d_{ij} | Distância entre i e j |
| $\cdot(+)$ | Variáveis de distâncias entre características do mesmo autor. |
| $\cdot(-)$ | Variáveis de distância entre características de autores diferentes. |
| m | Exemplares de assinaturas de cada autor. |
| $\delta, d..$ | Medida de distância entre valores de características de duas assinaturas. |
| $f\bar{v}$ | Vetor de características extraída de uma imagem. |
| R_i | Decisão na verificação de assinaturas baseado na perícia grafotécnica. |
| θ | Média dos níveis de cinza celular. |
| F | Número de primitivas extraídas. |

Resumo

A verificação automática de assinaturas estáticas ou *off-line* trata especificamente de um problema em aberto devido a fatores como a variação entre assinaturas do mesmo autor, à semelhança entre a escrita de autores diferentes, além dos diversos tipos de falsificações. A abordagem proposta nesta dissertação para resolver este problema baseia-se na visão da grafoscopia e utiliza um classificador baseado em redes neurais artificiais, as características extraídas do grafismo, medidas de distâncias e um método dicotômico. Nesse modelo, somente duas classes são assumidas: autoria e não autoria. Para validar o experimento 180 autores fornecem assinaturas genuínas no treinamento e 60 outros provêm as falsificações, sendo que a combinação entre os dois conjuntos forma a base de dados para os experimentos. A abordagem apresentada propõe uma solução através do uso de um número reduzido de assinaturas por autor (em torno de 5), assim como a redução do número de classes, problema este encontrado em outros métodos relacionados a verificação de assinaturas. As seguintes etapas fazem parte da abordagem: aquisição dos dados (digitalização das imagens das assinaturas), pré-processamento (filtro para retirada de ruídos e preparação para extração de características aplicadas sobre as imagens digitalizadas), segmentação (imagem particionada em células para a extração das características), extração das características (seleção das propriedades relevantes que representam a assinatura, baseadas na grafoscopia e grafologia), cálculo de distâncias entre características (etapa na qual a distância entre os vetores de características pertencentes a duas amostras são primeiramente computadas e usada para verificar a autenticidade do autor), produção de um modelo (um conjunto de referência de assinaturas é gerado para utilização no processo comparativo, que usa rede neurais artificiais, em específico o *perceptron* multicamada com algoritmo *backpropagation*), e finalmente o processo de decisão (a saída do modelo produzido é avaliada, verificando se a assinatura pertence à determinada classe ou não). Os erros médios obtidos estão na faixa de 9,79% para falsa rejeição e de 6,71% para falsa aceitação.

Palavras-chave: 1. Análise pericial de documentos questionados. 2. Verificação de Assinaturas. 3. Redes Neurais. 4. Características grafométricas extraídas.

Abstract

The off-line signature verification is an open problem due mainly to the variability presented by samples from the same writer, the similarity among samples from different writers as well as to different forgery types. The proposed approach is based on the graphometry, neural networks, distance measures and the dichotomic method. In this method only two classes are used: genuine and forgery. A set of 180 writers composes the genuine database in the training and a subset of 60 writers composes the forgery database. The proposed solution uses a reduced number of samples for each author (around 5 samples per writer) and only two classes. This protocol is composed by an acquisition procedure (obtaining signatures images), preprocessing (preparing the acquired images for feature extraction), segmentation (image divided in cells for the features extraction), feature extraction (selection of the significant properties that represent the signature, based on graphometric analysis), feature distance measurement (stage in which the distance between the vectors feature belonging to two samples is computed and used to verify author authenticity), model production (signature reference set is generated by comparison process using neural network multilayer perceptron with backpropagation algorithm) and a decision process (the output of previous stage is evaluated, being verified if the signature belongs or not to the genuine class). The mean error rate obtained are 9,79%, in the false rejection and 6,71% in the false acceptance.

Key-words: 1. Document Questioned Expert's Approach. 2. Signature Verification. 3. Neural Networks. 4. Graphometric Features.

Capítulo 1

1. Introdução

A biometria é a utilização de características biológicas (face, íris, impressão digital) ou tratamento comportamental (assinatura e voz) para a verificação da identidade do indivíduo. Autenticação biométrica é entendida como uma alternativa, mais confiável, aos sistemas de segurança baseados em senha, pois é relativamente difícil de ser falsificada, roubada ou obtida. Em particular, a assinatura está relacionada ao comportamento biométrico: ela não é baseada em propriedades físicas, tal como a impressão digital ou a face de um indivíduo, mas apenas em características comportamentais [KHOLMATOV, 2003].

A assinatura constitui atualmente, no contexto jurídico, um dos meios para comprovar a intenção em transações envolvendo documentos [JUSTINO, 2002], ou seja, quando se assina qualquer documento, este ato representa a aceitação dos fatos, indicando a sua concordância. Esta premissa garante a utilização de assinaturas como recurso comprobatório em contratos, escrituras e cheques bancários, entre outros, pois representa uma marca ou selo pessoal do indivíduo.

Diversos tipos de documentos precisam ser assinados. Desta forma, técnicas confiáveis para verificação de assinaturas são requisitadas. Mesmo que a maioria das recentes pesquisas estejam focadas em assinaturas digitais de documentos eletrônicos (isto é, um código de chave codificado associado com um documento em sua versão eletrônica, especialmente projetado para evitar manipulação por pessoas não autorizadas), um grande número de documentos de papel assinados ainda é produzido diariamente [SANSONE & VENTO, 2000], tais como os cheques bancários.

Não se pode negar que o uso de cartões de créditos cresceu muito nos últimos anos em relação aos cheques bancários. Porém para cada transação eletrônica existem duas envolvendo cheques, principalmente, devido ao uso do cheque pré-datado (versão brasileira do capitalismo). Além disso, muitos comerciantes usam os cheques recebidos dos clientes como moeda, assim escapando de pagamentos de taxas bancárias [SILVA, 2003], o que garante a

aplicação do sistema proposto e a continuidade do uso de assinaturas neste tipo de documento, podendo ser usado também em recibos de cartão de crédito.

Muitas vezes, pelo fato de estar sujeita a uma análise subjetiva, que pode gerar discordâncias, a detecção de autenticidade de assinaturas constitui-se em uma tarefa complexa, pois a verificação manual para uma grande quantia de documentos é tediosa e facilmente influenciada por fatores físicos e psicológicos [XIAO & LEEDHAM, 1999]. No campo computacional, a verificação de assinaturas estáticas continua sendo um problema em aberto, não existindo um método totalmente aceito. Uma abordagem que incorpore a visão subjetiva de forma satisfatória, certamente encontrará aplicações práticas, principalmente no que diz respeito a sistemas de automação bancária e comercial.

Atualmente, com recursos computacionais mais eficazes, tarefas que há alguns anos pareciam inviáveis agora atraem novas pesquisas. Dentro deste contexto, a verificação de assinaturas é uma importante e desafiadora área de estudos na qual buscam-se soluções computacionais automatizadas relacionadas à autenticação, procurando estabelecer uma comparação segura entre um modelo de assinatura conhecido com um outro questionado.

O uso da análise grafotécnica pericial utilizada em ciências forenses representa um nicho de pesquisa que se encaixa perfeitamente na verificação de assinaturas manuscritas. Desta forma, os critérios técnicos dos peritos são empregados na análise das características da escrita, as quais podem ser conscientes ou inconscientes, como também na decisão da autenticidade.

1.1. Desafio

A abordagem proposta tem como desafio minimizar a complexidade que envolve alguns fatores relacionados à escrita da assinatura, como a variação intrapessoal, ilustrada na Figura 1.1(b), que decorre da instabilidade que existe entre assinaturas do mesmo autor. A assinatura de uma pessoa pode mudar ao longo do tempo devido a diversos fatores como o estado psicológico do autor ou a mudança do dispositivo de entrada [XIAO & LEEDHAM, 1999]. Outro fator de complexidade é a similaridade interpessoal, conforme ilustrada na Figura 1.2 que representa a semelhança entre assinaturas de autores distintos.




Figura 1.1: Exemplo de (a) assinatura genuína de um autor em específico, (b) variação intrapessoal medida pela sobreposição de três assinaturas genuínas do mesmo autor.



Figura 1.2: Similaridade interpessoal (a) e (b).

Alguns aspectos ligados à variação de escrita podem estar relacionados ao alfabeto, à forma de escrita de determinada região, condição social, país, estado físico ou mental e idade cronológica da população analisada [CHA, 2001].

Assinar não é um processo perfeitamente preciso com dados de características idênticas. A única certeza é que quando duas assinaturas são exatamente idênticas, uma delas é provavelmente uma cópia [RASHA, 1994].

Assinaturas, por representarem um caso especial de manuscritos, podem ser divididas nas categorias, cursivas ou rubricas, estas contendo caracteres especiais, distorcidos ou ainda uma representação simbólica, tais como desenhos estilizados. Neste caso, uma análise não contextual é necessária, pois não existe a interpretação de texto durante a verificação, conforme Sabourin e Genest [SABOURIN & GENEST, 1994], o que representa outro fator de complexidade.

As assinaturas podem ainda sofrer ações fraudulentas, sendo classificadas por peritos em documentos questionados quanto à sua autenticidade em genuína e não genuína [JUSTINO, 2002]. O uso da palavra falsificação é um termo legal que deve ser cuidadosamente usado nas conclusões apresentadas pelo perito em documentos questionados [JUSTINO, 2001]. Falsificações podem ser bastante diferentes de assinaturas genuínas tanto em aparência como em suas características, ou podem ser tão similares que mesmo peritos sentem dificuldades em distingui-las corretamente [XIAO & LEEDHAM, 1999], desta forma

dificultando a aplicação de sistemas computacionais na verificação de assinaturas [JUSTINO et al., 2003].

As assinaturas não genuínas, ou falsificações, normalmente podem ser classificadas em duas categorias: simples ou habilidosa conforme Faez [FAEZ et al., 1997]. Justino [JUSTINO, 2001] define uma terceira categoria, a aleatória, que é ilustrada na Figura 1.3 juntamente com os demais tipos. Estas categorias são definidas como:

- Simples: o falsificador simplesmente escreve o nome do autor, que pode ser semelhante ou não à original;
- Servil, simulada ou habilidosa: o falsificador simula uma assinatura genuína usando um modelo como referência, tentando chegar o mais próximo possível de seu traçado original;
- Aleatórias: o falsificador inventa uma assinatura ou utiliza a sua própria, a qual não possui semelhanças com a genuína.




Figura 1.3: Exemplo de (a) assinatura original, (b) falsificação aleatória, (c) falsificação simulada, (d) falsificação simples.

No processo que envolve a verificação automática de assinaturas o objetivo é discriminar entre uma assinatura genuína e todos os tipos de falsificações. Portanto, dadas duas classes w_1 , representando a classe de assinaturas genuínas de um autor e w_2 , representando a classe de assinaturas não genuínas, o desafio é basicamente separá-las. Porém, quando falsificações são submetidas ao sistema, principalmente as simuladas, a complexidade aumenta. Se um limiar de decisão puder ser definido, a classificação consiste em determinar em qual lado do limite qualquer novo dado deve se situar. A função matemática de tal limite de decisão é uma função discriminante, sendo que achá-la geralmente

não é trivial. Por esta razão, em um processo de aprendizagem algumas amostras de falsificações são identificadas erroneamente como pertencendo à classe w_1 , o que pode acontecer até mesmo com amostras de falsificações simples [JUSTINO et al., 2003], conforme a Figura 1.4.

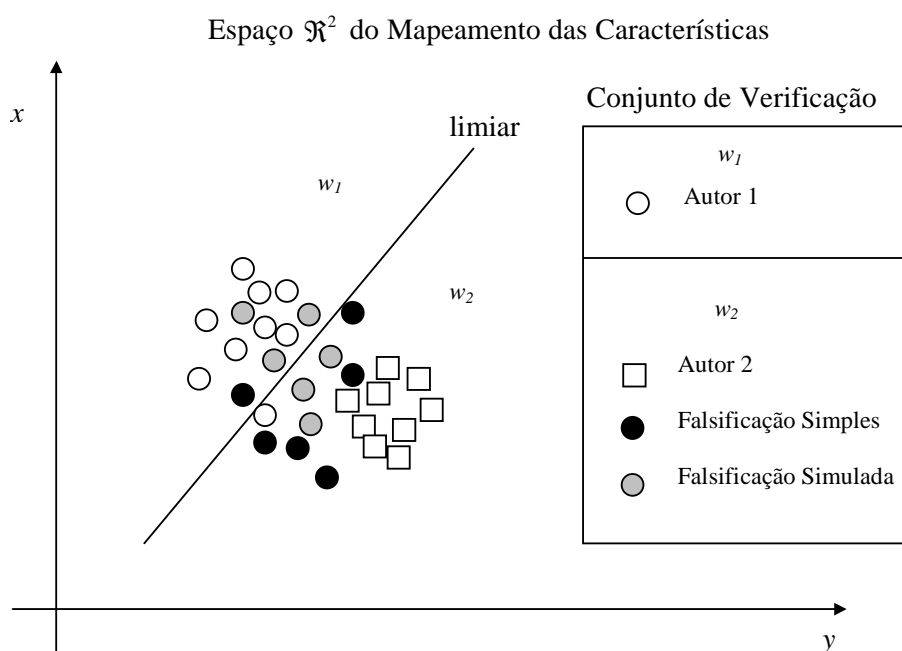


Figura 1.4: Separação entre as classes w_1 e w_2 no espaço \mathcal{R}^2 .

Em situações práticas a classe w_2 , que representa a classe de amostras não genuínas pode englobar os vários tipos de falsificações (simples, simuladas e aleatórias). As falsificações aleatórias são representadas por amostras de assinaturas genuínas que pertencem a um autor diferente.

1.2. Motivação

O direcionamento da abordagem proposta está baseado nos preceitos do grafismo, apresentados inicialmente por Chuang [CHUANG, 1977] e mais recentemente por Justino [JUSTINO, 2001], nos quais os subsídios e a visão que o perito grafotécnico possui para a resolução de problemas criminais são transcritos na extração das características.

O número de espécimes utilizado em qualquer abordagem relacionado ao reconhecimento de manuscritos que envolve treinamento de classificadores torna-se um problema quando transposto para sistemas práticos, em aplicações bancárias ou comerciais, que dispõem em geral de um número reduzido de amostras de cada classe, autor ou indivíduo. É inviável, então, solicitar diversas vezes aos usuários a produção de assinaturas para o sistema empregado (manual ou automatizado). Desta forma uma abordagem alternativa validada estatisticamente faz-se necessário, para um método ser aceito cientificamente e também para a sua utilização prática.

Atualmente métodos baseados em modelos pessoais [HUANG & YAN, 1997] [SABOURIN & GENEST, 1994], são geralmente adotados como solução nesta área. Entretanto, em aplicações reais existe, em geral um número bastante limitado de amostras que podem ser usados no treinamento de modelos pessoais (em torno de 4 a 6), o que inviabiliza a maioria destas abordagens, apesar de apresentarem excelentes resultados [JUSTINO et al., 2003].

Além da motivação prática, existe também o interesse despertado pelo caráter desafiador da área de pesquisa. A área de reconhecimento de padrões possui técnicas que são aplicadas na solução de problemas reais cujo comportamento não obedece aos princípios rígidos da lógica. Estes são alguns dos motivos que despertam o interesse nesta abordagem científica.

1.3. Proposta

A proposta deste trabalho é apresentar uma abordagem de verificação de assinaturas estáticas, com o objetivo de autenticar a assinatura de um escritor, ao contrário do reconhecimento de assinaturas no qual o objetivo é determinar quem é o autor da assinatura [CAVALCANTI et al., 2002]. Dentro deste contexto as seguintes metas são propostas:

- Minimizar a complexidade que envolve todas as etapas de um sistema de verificação de assinaturas;
- Reduzir o número de amostras genuínas por autor na produção de um modelo, simulando ambientes de aplicações não automatizadas, e somente o uso a *priori* de falsificações aleatórias;

- Utilização dos preceitos da grafoscopia na análise das características da escrita [JUSTINO, 2001] como alternativa para o problema proposto;
- Obter uma metodologia que reduza o número de modelos associados à autenticação de assinaturas.

1.4. Contribuições

Nesta subseção apresentam-se as contribuições deste trabalho de pesquisa as quais são:

- Uma alternativa para o número excessivo de assinaturas genuínas por autor. Problema este encontrado na maioria das abordagens relacionadas à verificação de assinaturas [JUSTINO, 2001], [HUANG & YAN, 1997];
- O uso de uma abordagem genérica que utiliza somente um único treinamento em todo o processo, independente do autor ou assinatura analisada;
- A implementação computacional dos princípios da grafoscopia tanto na extração das características quanto no processo de decisão.

1.5. Organização da Dissertação

Esta dissertação está organizada em sete capítulos. O primeiro contém uma introdução sobre verificação automática de assinaturas manuscritas. No segundo capítulo é apresentada uma fundamentação teórica de classificadores para verificação de assinaturas. No terceiro capítulo apresenta-se o resumo do estado da arte na autenticação das assinaturas. No quarto capítulo é elucidada a metodologia. No quinto as etapas da abordagem proposta. Os experimentos realizados neste trabalho para validar estatisticamente o método são mostrados no sexto capítulo. E finalmente no sétimo capítulo são apresentadas as conclusões e propostas para trabalhos futuros.

Capítulo 2

2. Fundamentação Teórica

Este capítulo apresenta uma base teórica dos processos de autenticação de assinaturas, contendo uma breve descrição de reconhecimento de padrões, tipos e métodos de abordagens relacionados ao problema. Também são apresentados os classificadores abordados, com um estudo de redes neurais, em específico redes MLP e dicas de configuração de parâmetros das mesmas. Ao final, é apresentada uma introdução do classificador SVM.

2.1. Reconhecimento de Padrões

Um padrão é uma descrição de um objeto que pode ser um conjunto de medidas ou observações normalmente representadas através de um vetor ou notação de matriz [RASHA, 1994]. No processo de verificação de assinaturas, uma assinatura é um exemplo de padrão que pode ser representado por uma matriz de *pixels*. O reconhecimento de padrões pode ser definido como a categorização de dados de entrada em classes identificáveis, via extração de características significantes ou atributos de detalhes relevantes. Conseqüentemente o objetivo fundamental do reconhecimento de padrões é a classificação. Um sistema de reconhecimento de padrões básico divide-se em duas fases. A primeira é a extração das características e a segunda a classificação [RASHA, 1994].

Características são quaisquer medidas extraíveis de um padrão que podem contribuir para a classificação, sendo que as mesmas podem ser representadas por valores contínuos ou discretos.

Na distinção entre diferentes classes, muitas características são requisitadas. Selecionar estas características pode ser uma difícil tarefa que exigirá significantes esforços computacionais. A seleção de características é o processo inicial para o reconhecimento de

padrões, que envolve geralmente um julgamento, ou seja, os descritores de uma assinatura devem conter informações representativas da classe a que ela pertence de modo a permitir diferenciá-la de falsificações [MARAR et al., 2002].

A chave é escolher e extrair características que [RASHA, 1994]:

- Sejam computacionalmente possíveis;
- Conduzam a um sistema com poucos erros de má-classificação;
- Reduzam a quantidade de informação manipulada, sem perda de desempenho.

Satisfazendo estes critérios na extração de características, ocorre o processo de treinamento, durante o qual apresenta-se repetidamente ao classificador um conjunto de padrões de entrada juntamente com a categoria à qual cada padrão apresentado pertence.

Posteriormente, na etapa de testes apresenta-se um novo padrão que pertence à mesma população de padrões utilizada no treinamento. O classificador deve ser capaz de identificar a classe daquele padrão particular, pela informação que ele extraiu dos dados de treinamento.

A fase de aprendizado é uma etapa muito importante do sistema de verificação. Se realizada adequadamente os modelos oriundos dessa fase possuem um conjunto rico de informações que permitem uma boa precisão do processo de verificação. Esta etapa possibilita a eliminação de redundâncias, o que por sua vez, propicia uma redução do tempo gasto no processo de decisão.

De acordo com Haykin [HAYKIN, 2001], os seres humanos têm habilidades inerentes ao reconhecimento de padrões, pois recebem dados do mundo a sua volta através dos sentidos e são capazes de reconhecer a fonte dos dados, quase que imediatamente e sem esforço. Eles podem, por exemplo, reconhecer um rosto familiar de uma pessoa, muito embora esta pessoa tenha envelhecido.

Em termos conceituais, Haykin [HAYKIN, 2001] define que um padrão é representado por um conjunto de m observações, que pode ser visto como um ponto x de um espaço de observações (de dados) m -dimensional. A extração de características é descrita por uma transformação que mapeia o ponto x para um ponto intermediário y no espaço de características q -dimensional, com $q < m$, como indicado na Figura 2.1.

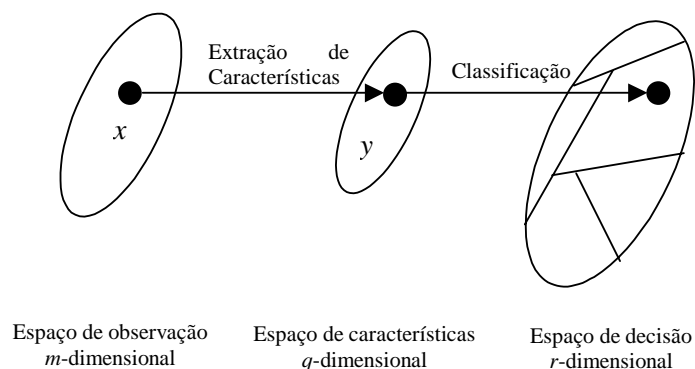


Figura 2.1: Modelo genérico de método de reconhecimento de padrões

Esta transformação pode ser vista como uma redução de dimensionalidade (compressão de dados), cuja utilização é justificada por simplificar a tarefa de classificação. A própria classificação é descrita como uma transformação que mapeia o ponto intermediário y para uma das classes em um espaço de decisão r -dimensional, em que r é o número de classes a ser distinguida.

2.2. Tipos de Abordagens na Verificação de Assinaturas

As abordagens relacionadas à verificação automática de assinaturas estão diretamente ligadas ao mecanismo de aquisição de dados. Se o processo de verificação ocorre no mesmo tempo em que a assinatura é escrita, o método é dito *on-line* ou dinâmico, neste caso há necessidade de um dispositivo de acesso especial para processamento quando a assinatura é produzida. Quando as informações são inicialmente adquiridas provavelmente de uma folha de papel por um digitalizador ou câmera para posterior análise da imagem, o método é dito *off-line* ou estático. A tarefa de verificação em sistemas *off-line* torna-se mais complexa que em *on-line*, principalmente pela quantidade de informações disponíveis [CAVALCANTI et al., 2002].

Os métodos estáticos apresentam duas classes de características extraídas da imagem de acordo com Justino [JUSTINO, 2001]. A classe primeira é chamada de estática, porque possui a capacidade de representar as características relacionadas à forma, como por exemplo, o comprimento e a altura máxima de uma assinatura. A segunda classe chamada de

pseudodinâmica, possui a capacidade de representar as características dinâmicas da escrita como tensão do traçado, inclinação e pressão. Métodos baseados em características estáticas são usados geralmente para identificar falsificações simples e aleatórias. A razão é que estes métodos mostram-se mais aptos para descrever características relacionadas à forma da assinatura. Já as abordagens pseudodinâmicas são capazes de capturar detalhes da movimentação da escrita, sendo portanto mais adequados para identificar falsificações habilidosas.

A abordagem usada para manipular características em uma imagem determina a eficiência de um método na resolução do problema. De acordo com Justino [JUSTINO, 2001] tais métodos podem ser:

- Globais: os quais usam as características gerais da imagem, sendo mais insensíveis às variações intrapessoais, porém com menor capacidade de distinção de falsificações simuladas;
- Locais: dependem de um processo de segmentação da imagem em partes a serem analisadas, descrevendo a particularidade do traçado e sendo mais eficientes na identificação de todos os tipos de falsificações.

A imagem de uma assinatura é basicamente uma coleção de pontos distribuídos sobre uma área bem definida e possuindo formas distintas.

As características globais, que podem capturar a natureza da distribuição destes pontos no espaço, são idealmente desejáveis para aspectos mais grosseiros da assinatura. Estas características não são capazes de capturar aspectos estruturais das imagens das assinaturas, essenciais para a detecção de traços de falsificações ou fotocópias, mas possuem poder suficiente para discriminar e eliminar erros de substituição [BAJAJ & CHAUDHURY, 1996].

O diagrama hierárquico da Figura 2.2 demonstra a classificação dos métodos de verificação automática de assinaturas, destacando os que fazem parte da abordagem proposta.

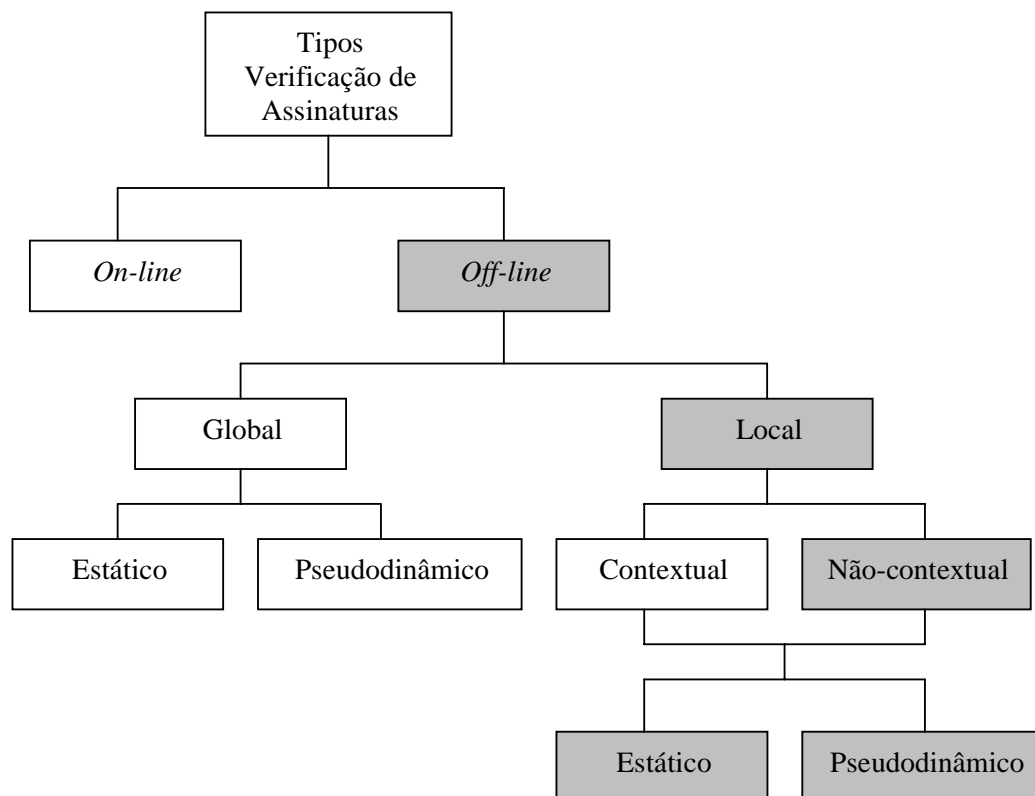


Figura 2.2: Diagrama hierárquico de classificação dos tipos de abordagens de verificação de assinaturas.

2.3. Métodos de Verificação

A escolha do tipo de representação (os tipos de primitivas) constitui uma etapa essencial na elaboração de um método de verificação. As dificuldades surgem principalmente em relação à maneira como são tratadas as entidades naturais usadas para obter a descrição matemática, induzida por um método teórico formal.

Essa indução possui dois reflexos: o dimensionamento do espaço representativo do fenômeno, que deve possuir propriedades para facilitar o processo de decisão, e a obtenção de um espaço de representação que permita uma implementação computacional [JUSTINO, 2001].

Os dois tipos de métodos formais mais comuns são:

- **Métodos estruturais:** buscam descrever informações geométricas de maneira estrutural, representando formas complexas a partir de componentes elementares, chamadas primitivas. Os métodos estruturais distinguem-se basicamente em dois grupos [JUSTINO, 2001]:
 1. Métodos estruturais propriamente ditos: a estrutura utilizada é um grafo que permite representar as formas, ou seja, as primitivas e as relações entre elas. A fase de decisão consiste na comparação do grafo representativo da forma do modelo com o grafo da forma em teste;
 2. Métodos sintáticos: a estrutura é usada para codificar a forma em uma lista, utilizando um alfabeto cujos componentes representam elementos da forma a descrever. A fase de decisão consiste na análise da lista com a ajuda de regras sintáticas, como as utilizadas em um texto escrito em uma linguagem natural.
- **Métodos estatísticos:** consistem em efetuar as medições do espaço métrico através da estatística. O aprendizado é executado através da separação de um conjunto de amostras em classes obedecendo a um conjunto de características comuns. A modelagem estatística se beneficia dos processos automáticos. Os principais métodos estatísticos são os paramétricos e os não-paramétricos [JUSTINO, 2001]:
 1. Paramétricos, trabalham com a hipótese de que as classes possuem uma distribuição de probabilidade com comportamento determinado. O método supõe o conhecimento prévio das leis que regem as probabilidades das classes envolvidas e ainda que seus parâmetros de estimação possuem normalmente um comportamento gaussiano. Esses métodos exigem uma base de dados de aprendizado para uma correta estimação dos parâmetros;
 2. Não-paramétricos, assumem que as leis de formação da probabilidade de uma classe são desconhecidas. O problema consiste em propor algoritmos de convergência que determinem o limiar ideal de decisão.

Mais recentemente a neurocomputação, mais especificamente as redes neurais artificiais, tem sido reconhecida como um método para resolver problemas de reconhecimento de padrões [RASHA, 1994]. A computação neural surgiu da necessidade de entender como os sistemas neurais biológicos armazenavam e manipulavam a informação. É importante destacar que uma rede neural é capaz de aprender as características estatísticas do ambiente no qual ela opera, desde que os dados utilizados para o seu aprendizado sejam suficientemente representativos do ambiente.

De acordo com Haykin [HAYKIN, 2001], o reconhecimento de padrões realizado por uma rede neural é de natureza estatística. Os padrões são representados por pontos em um espaço de decisão multidimensional, dividido em regiões, cada uma associada a uma classe. As fronteiras de decisão são determinadas pelo processo de treinamento e sua construção torna-se estatística pela variação inerente que existe dentro das classes e entre as mesmas.

As redes neurais são capazes de estimar as probabilidades *a posteriori*, das quais provêm a base para estabelecer regras de classificação e análise de desempenho estatístico [ZHANG, 2000].

2.4. Teoria da Classificação Bayesiana

Esta teoria é a base dos métodos de classificação estatística. Ela provê o modelo de probabilidade fundamental para os procedimentos de classificação, como a análise discriminante estatística [ZHANG, 2000]. Considera-se um problema geral de classificação de M grupos no qual cada objeto tem um vetor de atributos x de dimensão d , em que w denota a variável membro que toma um valor w_j se um objeto é pertencente à classe j . Define-se $P(w_j)$ como a probabilidade *a priori* da classe j e $f(x/w_j)$ como a função densidade de probabilidade. De acordo com a regra de Bayes:

$$P(w_j | x) = \frac{f(x | w_j)P(w_j)}{f(x)} \quad (2.1)$$

$P(w_j/x)$ é a probabilidade *a posteriori* da classe j dado o vetor x , e $f(x)$ é a função densidade de probabilidade:

$$f(x) = \sum_{j=1}^M f(x | w_j)P(w_j) \quad (2.2)$$

Supondo que um objeto com um vetor de características x é observado e uma decisão é feita sobre sua classe, a probabilidade do erro de classificação é:

$$P(\text{Erro} | x) = \sum_{i \neq j} P(w_i | x) = 1 - P(w_j | x) \quad , \text{considerando que } j \text{ é a classe correta.} \quad (2.3)$$

Conseqüentemente, se o propósito é minimizar a probabilidade do erro de classificação total (taxa de má classificação), temos a regra Bayesiana de classificação:

$$\text{Decida } w_k \text{ para } x \text{ se } P(w_k | x) = \max P(w_{i=1,2,\dots,M} | X) \quad (2.4)$$

A interpretação das saídas de redes neurais como probabilidades Bayesianas permite que as saídas de múltiplas redes possam ser combinadas para melhorar o nível de decisão, simplificando a criação de limiares de rejeição, desde que certas condições sejam satisfeitas:

- Hajam elementos de processamentos suficientes para realizar o mapeamento;
- Hajam dados em quantidade e qualidade;
- A aprendizagem convirja para o máximo global;
- As saídas estejam entre 0 e 1 com $\sum = 1$.

Classificadores estatísticos são baseados na teoria de decisão de Bayes, e o fato de que redes neurais podem prover estimativas de probabilidades a *posteriori* implicitamente estabelecem uma ligação entre redes neurais e classificadores estatísticos. A direta comparação entre eles pode não ser possível porque as redes neurais são métodos de modelos livres não-lineares enquanto que os métodos estatísticos são basicamente lineares e baseados no modelo, de acordo com Zhang [ZHANG, 2000].

Através da codificação apropriada dos valores de saída a rede neural pode modelar diretamente algumas funções discriminantes. Assim, o vetor de característica de entrada é mapeado em um valor associado com uma classe particular. Por exemplo, em um problema de classificação binária, a saída desejada é codificada como 1 sendo o dado da classe w_1 e -1 se ele é da classe w_2 . Então a rede neural estima a seguinte função discriminante $g(x)$ [DUDA & HART, 1973]:

$$g(x) = P(w_1 | x) - P(w_2 | x) \quad (2.5)$$

A regra discriminante é simples: associar x para w_1 se $g(x) > 0$ ou para w_2 se $g(x) < 0$. Qualquer aumento na função de probabilidade a *posteriori* pode ser usado para alterar a equação (2.5) para formar uma função discriminante diferente, mas essencialmente é a mesma regra de classificação.

2.4.1. Teoria de Decisão Bayesiana

De acordo com Fumera [FUMERA et al., 2000], um classificador N -classes é apontado para subdividir o espaço de características em N regiões de decisão D_i , $i = 1, \dots, N$, tal que os padrões da classe w_i pertencem à região D_i . Conforme a teoria de reconhecimento de

padrões estatísticos, tal região de decisão é definida para maximizar a probabilidade do correto reconhecimento, ou seja, a precisão do classificador, e conseqüentemente minimizar a probabilidade do erro do classificador. Para este fim, a regra de decisão de Bayes associa a cada padrão x a classe para a qual a probabilidade a *posteriori* $P(w_i/x)$ é máxima.

Uma otimização da probabilidade da taxa de erro provida pela regra de Bayes pode ser obtida usando a opção de rejeição, de acordo com Fumera [FUMERA et al., 2000].

Neste sentido, os padrões com maior probabilidade de serem mal classificados são rejeitados, ou não classificados, e manuseados com procedimentos mais sofisticados. Entretanto, altas taxas de rejeições geralmente consomem muito tempo em aplicações práticas. Desta forma um consenso entre erro e rejeição é necessário.

A formulação do melhor ponto entre erro-rejeição, ou seja, a regra de rejeição ótima, é apresentada por Chow [FUMERA et al., 2000]. Segundo esta regra um padrão é rejeitado se:

$$\max_{k=1,\dots,N} P(w_k | x) = P(w_i | x) < T, \quad (2.6)$$

onde $T \in [0,1]$. Em contrapartida, o padrão x é aceito e associado para a classe w , se

$$\max_{k=1,\dots,N} P(w_k | x) = P(w_i | x) \geq T, \quad (2.7)$$

O espaço de características é, portanto, subdividido em $N + 1$ regiões. A região de rejeição D_o é definida de acordo com a equação (2.6), enquanto as regiões de decisão D_1, \dots, D_n são definidas de acordo com a equação (2.7).

A regra de rejeição de Chow [FUMERA et al., 2000], desta forma, provê um ótimo ponto de erro-rejeição, somente se as probabilidades a *posteriori* das classes dos dados forem exatamente conhecidas. Infelizmente em aplicações práticas tais probabilidades são afetadas por estimativas de erros. Desta forma, Fumera [FUMERA et al., 2000] propõe o uso de múltiplos limiares de rejeição. A tarefa de classificação com N classes de dados é caracterizada pela probabilidade a *posteriori* estimada $P(w_i | x), i = 1, \dots, N$. Um padrão x é rejeitado se:

$$\max_{k=1,\dots,N} P(w_k | x) = P(w_i | x) < T_i, \quad (2.8)$$

enquanto ele é aceito e associado à classe w_i , se:

$$\max_{k=1,\dots,N} P(w_k | x) = P(w_i | x) \geq T_i \quad (2.9)$$

2.5. Redes Neurais Artificiais

Um sistema neural artificial básico é composto de neurônios agrupados em camadas. Um neurônio artificial pode consistir de valores de entradas, pesos, um valor limiar, e uma saída [WILSON, 1999]. O modelo de neurônio artificial i , denominado *perceptron*, pode ser visualizado na Figura 2.3. O modelo consiste de um combinador linear seguido por uma unidade não-linear. O combinador consiste em uma série de *sinapses* ou conexões (parâmetros ajustáveis) conectadas aos respectivos terminais de entrada, cujas saídas ponderadas são combinadas em um somador. Nesse somador também é conectado, como entrada, um sinal externo de polarização também conhecido como bias b . O bias tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo dela ser positiva ou negativa, respectivamente. A saída do somador, denominada de net_i , é a entrada da unidade não-linear ou função de ativação contínua e diferenciável [HAYKIN, 2001].

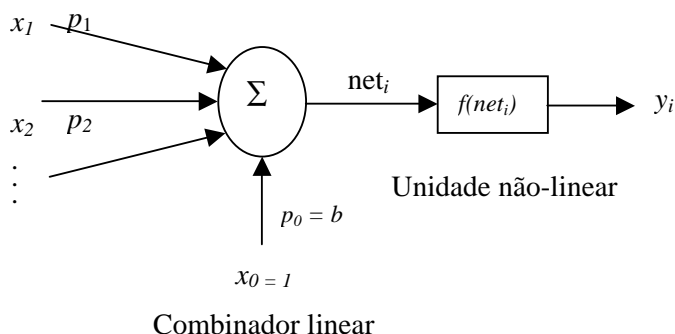


Figura 2.3: Modelo simplificado de um neurônio.

O modelo do neurônio é identificado pela característica de sua unidade não-linear:

$$net_i = \sum_{i=1}^n p_i x_i + b \quad (2.10)$$

sendo $f(net_i)$ a função de ativação, x_i o conjunto de entradas e p_i os pesos de cada uma das entradas. Algumas funções de ativação utilizadas são:

$$\text{linear: } idn(x) = x \quad (2.11)$$

$$\text{saturação: } sat(x) = \begin{cases} +1, & \text{se } x > 1 \\ x, & \text{se } -1 \leq x \leq 1 \\ -1, & \text{se } x < -1 \end{cases} \quad (2.12)$$

$$\text{sinal: } \text{sign}(x) = \begin{cases} +1, & \text{se } x > 1 \\ -1, & \text{se } x < 1 \end{cases} \quad (2.13)$$

$$\text{tangente hiperbólica: } \text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.14)$$

$$\text{sigmóide: } \text{sig}(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.15)$$

A função sigmoidal, que é a mais usada, possui esse nome devido ao formato em S (letra grega sigma) da função de ativação. Ela é uma função de fácil tratamento matemático, e usada em uma classe de redes neurais denominada MLP (Multilayer Perceptron), a qual utiliza o algoritmo de treinamento chamado algoritmo de Propagação Reversa (*Backpropagation algortihm*). A rede MLP corresponde a um modelo com unidades de processamento dispostas em camadas que se interconectam, uma após a outra, chegando até uma camada de saída. Com este algoritmo, o aprendizado ocorre de tal forma que os erros são inicialmente computados na camada de saída e então são consecutivamente computados nas camadas anteriores: daí o nome *backpropagation* [HAYKIN, 2001].

2.5.1. Perceptron Multicamadas

O Perceptron Multicamadas (MLP) é uma rede neural que consiste de uma camada de nós de entrada, uma ou mais camadas de nós-processadores ou computacionais (neurônios) ocultos ou escondidos e uma camada de saída também composta por nós computacionais. Os nós-fontes são utilizados para aplicação do sinal de entrada e os neurônios das camadas ocultas agem como detectores de características. Esses neurônios são ditos ocultos, pois eles são fisicamente inacessíveis pelas entradas ou pela saída da rede. Os neurônios de saída fornecem as respostas de rede neural aos sinais de entrada a ela apresentada [PRINCIPE et al., 2000].

O número de nós-fonte na camada de entrada é determinado pela dimensão do espaço de observação que é responsável pela geração dos sinais de entrada. O número de nós-computacionais na camada de saída é determinado pela dimensão da resposta desejada. Assim, o projeto de uma MLP requer a preocupação em pelo menos três aspectos [WALCZAK & CERPA, 1999]:

- A determinação do número de camadas ocultas;

- A determinação do número de neurônios em cada uma das camadas ocultas;
- A especificação dos pesos ou ponderações em cada sinapse que conecta os neurônios.

O primeiro e o segundo itens estão relacionados com a complexidade da rede neural. A determinação dos pesos nas sinapses é tarefa para um algoritmo próprio, por exemplo, o algoritmo *backpropagation*. Essa determinação dos pesos pode ser vista como o armazenamento de informações do conteúdo dos dados utilizados no processo de treinamento, quando acontece o aprendizado, nos pesos das sinapses.

2.5.2. Melhorias de Desempenho da Rede Neural

Walczak e Cerpa [WALCZAK & CERPA, 1999] descrevem que o projeto de uma rede neural é uma problemática na qual existe um grande número de arquiteturas físicas alternativas de redes neurais e métodos de treinamento que podem ser aplicados para um dado problema de negócios. O objetivo é incorporar uma quantidade significativa de conhecimento dentro do projeto de redes neurais mesmo antes do processo de aprendizagem ter começado.

O desempenho da generalização de aprendizagem supervisionada de redes neurais *backpropagation* geralmente melhora quando o tamanho da rede é minimizado com respeito aos pesos das conexões entre nós de processamento (elementos de entrada, escondidos, e camadas de saída). As seguintes situações resultam em uma pobre generalização das amostras: redes que são grandes demais tendem para a memorização dos dados de entrada e redes com poucas conexões não contêm elementos de processamento suficiente para corretamente modelar o conjunto de dados de entrada.

De acordo com Lippmann [LIPPMANN, 1987], o número de nós deve ser grande o suficiente para formar uma região de decisão que seja tão complexa quanto requerido pelos dados do problema, porém não deve ser tão grande a ponto de muitos pesos não serem confiáveis. Dentro deste contexto, a seleção de variáveis de entrada é uma importante e complexa tarefa para o projeto de redes neurais.

As redes neurais melhoram o desempenho com domínio adicional de conhecimento provido através de variáveis de entrada. Se uma quantidade suficiente de informação representando o critério de decisão crítica não é dada para uma rede neural, então a mesma não pode desenvolver um correto modelo do domínio. É comum acreditar que a aprendizagem

em redes neurais é capaz de determinar variáveis de entrada que são importantes e desenvolver um correspondente modelo através da modificação de pesos associados às conexões entre as camadas de entrada e camadas escondidas.

Walczak e Cerpa [WALCZAK & CERPA, 1999] estabelecem que o primeiro passo para determinar o conjunto ótimo de variáveis de entrada é voltado para o desempenho de aquisição de conhecimento padrão. O propósito primário da aquisição do conhecimento é para garantir que o conjunto das variáveis de entrada esteja suficientemente especificado, provendo o critério de todos os domínios relevantes para a rede. Se duas variáveis têm uma alta correlação, então uma destas duas variáveis pode ser removida do conjunto de variáveis sem afetar o desempenho da rede.

Em Petersen [PETERSEN et al., 2002] é discutido o problema que envolve um grande número de dimensões de entrada na classificação em processamento de imagens, especialmente quando os algoritmos são aplicados diretamente nos *pixels* dos dados.

O projeto de camadas escondidas depende da seleção do algoritmo de aprendizagem. Por exemplo, métodos de aprendizagem não supervisionada tais como ART normalmente requerem que a quantidade de nós da primeira camada escondida seja igual ao tamanho da camada de entrada. Já métodos supervisionados são geralmente mais flexíveis no projeto de camadas escondidas [WALCZAK & CERPA, 1999].

Embora seja possível projetar uma rede neural sem camadas escondidas, este tipo de rede pode somente classificar dados de entrada que são linearmente separáveis, os quais limitam severamente suas aplicações. Redes neurais artificiais que contêm camadas escondidas têm a habilidade para lidar de forma robusta com a não-linearidade e problemas complexos e, portanto, podem operar em problemas mais interessantes. É possível especificar, de forma geral, a quantidade de camadas escondidas correspondente à complexidade do domínio do problema a ser resolvido. Redes simples sem camadas escondidas criam um hiperplano. Já uma camada escondida combina hiperplanos de forma convexa nas áreas de decisão e duas camadas escondidas na rede combinam áreas de decisão de forma convexa que contêm regiões côncavas.

Uma interpretação geométrica adotada e modificada de Lippmann [LIPPMANN, 1987] na Figura 2.4 demonstra a capacidade do perceptron em separar regiões de decisão com uma, duas e três camadas em um espaço bidimensional. A segunda coluna desta figura indica o tipo de decisão que pode ser formada com diferentes redes. As próximas duas colunas apresentam regiões de decisão, as quais representam o problema do OU exclusivo e regiões

misturadas. Um simples perceptron pode formar somente a metade das regiões de decisão, desta forma não é capaz de solucionar problemas que não sejam linearmente separáveis, conforme a primeira linha da Figura 2.4, já uma rede com uma camada escondida pode formar limites de decisão mais complexos como mostrado na segunda linha da Figura 2.4.


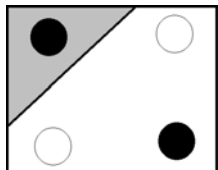
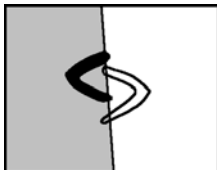

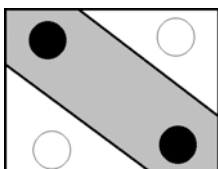
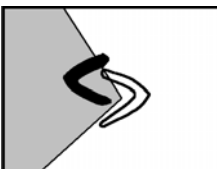

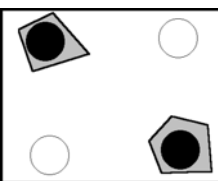

| Estrutura em Camadas Escondidas | Descrição da Região de Decisão | Problema do OU exclusivo | Classes com regiões misturadas |
|---|--|--|---|
|  <p data-bbox="347 813 434 846">Simples</p> | Metade do plano limitado pelo hiperplano |  |  |
|  <p data-bbox="363 1003 406 1037">Uma</p> | Regiões abertas |  |  |
|  <p data-bbox="363 1227 406 1261">Duas</p> | Complexidade limitada pelo número de unidades escondidas |  |  |

Figura 2.4: Interpretação geométrica das regras de unidades escondidas em um espaço bi-dimensional de acordo com Lippmann [LIPPMANN, 1987].

Na Figura 2.4 uma análise é feita com relação ao número de camadas e nós de acordo com Lippmann [LIPPMANN, 1987]. Em relação ao número de nós, dois nós são suficientes para resolver o OU exclusivo como na segunda linha da Figura 2.4. Mas na quarta coluna é demonstrado que nenhum número de nós com uma camada escondida pode separar as classes com regiões misturadas. Um perceptron com duas camadas escondidas forma arbitrariamente regiões de decisões complexas e separa as classes com regiões misturadas conforme a terceira linha da Figura 2.4. A análise acima demonstra que não mais que duas camadas escondidas são requeridas no *perceptron* como redes *feedforward* pelo fato de uma rede com duas camadas escondidas gerar arbitrariamente regiões de decisão complexas.

Uma heurística para determinar a quantidade de camadas escondidas requerida por uma rede neural é proposta por Walczak e Cerpa [WALCZAK & CERPA, 1999], o qual

acredita que com o aumento da dimensionalidade do espaço do domínio do problema, o número de camadas escondidas deveria aumentar correspondentemente. O número de camadas escondidas é heurísticamente determinado pelo número de passos intermediários, dependente da categorização prévia, para transportar as variáveis de entrada em um valor de saída. Portanto, o domínio de um problema que tem uma solução de uma equação não-linear padrão é possivelmente resolvível por uma rede neural com uma simples camada escondida.

Uma regra estabelecida com relação à quantidade de camadas escondidas é que uma grande quantidade delas habilita a rede neural a melhorar sua proximidade de ajuste, enquanto uma pequena quantidade melhora a suavidade ou a capacidade de extrapolação da rede.

Para se escolher o número de nós a ser incluído em uma camada escondida, deve-se levar em conta o tempo e a precisão do treinamento. Um grande número de nós nas camadas escondidas resulta em um período mais longo de treinamento, enquanto que poucos nós provêm um treinamento mais rápido, pelo custo de se ter um detector de característica menor.

Muitos nós escondidos em uma rede habilita a mesma a memorizar o conjunto de dados de treinamento, produzindo um pobre desempenho de generalização. Walczak e Cerpa [WALCZAK & CERPA, 1999] descrevem algumas heurísticas existentes para selecionar a quantidade de nós escondidos para uma rede tal como: usar 75% da quantidade de nós de entrada, usar 50% da quantidade de entrada e saída, ou usar $2n + 1$ nós na camada escondida em que n seria o número de nós na camada de entrada. Estas heurísticas de algoritmos não utilizam domínio do conhecimento para estimar a quantidade de nós escondidos e podem não ser as mais produtivas.

De acordo com Fujita [FUJITA, 1998], o número de unidades escondidas em uma rede neural *feedforward* é significativa na caracterização do desempenho da rede. Ela influencia a capacidade da rede, a habilidade da generalização, a velocidade de aprendizagem e, ainda, a resposta de saída.

Normalmente ocorre que uma rede tem um desempenho pobre até um número suficiente de unidades escondidas que representam a correlação entre o vetor de entrada e os valores de saída desejada, e com o aumento do número de unidades escondidas além do suficiente, aumenta-se o tempo de treinamento sem um correspondente aumento na precisão da saída.

2.5.3. Aprendizagem em Redes MLP

Um processo de aprendizagem na rede neural pode ser visto como um problema de alterar a arquitetura da rede e as conexões de pesos, tal que a rede neural possa eficientemente aprender. Desta forma a rede geralmente adquire conhecimento baseado nas conexões de pesos dos padrões de treinamento disponíveis. A habilidade das redes neurais, para automaticamente aprenderem, baseadas em padrões, faz delas uma área excitante e atrativa. Ao invés de seguir um conjunto de regras especificado por peritos humanos, a rede neural trata a aprendizagem baseada em regras de relação de entrada-saída de uma dada coleção de exemplos representativos. Esta é uma das maiores vantagens da rede neural sobre sistemas de tradicionais.

Para entender ou projetar um processo de aprendizagem, deve-se primeiro ter um modelo de ambiente no qual uma rede neural opera, isto é, identificar qual informação está disponível para a rede, o que seria um paradigma de aprendizagem. Em segundo deve-se entender como os pesos da rede são atualizados, ou seja, qual regra de aprendizagem governa o processo de atualização. Um algoritmo de aprendizagem se refere a um procedimento no qual regras de aprendizagem são usadas para ajustar os pesos.

Há três principais paradigmas de aprendizagem [RASHA, 1994]: supervisionado, não-supervisionado e híbrido. No supervisionado a rede é provida com a resposta correta na saída para cada padrão de entrada. Pesos são determinados para permitir à rede produzir respostas tão próximas quanto possíveis para as respostas corretas conhecidas. Aprendizagem por reforço é uma variação de aprendizagem supervisionada na qual basicamente a rede é provida somente com uma crítica (de fortalecimento ou enfraquecimento) na saída da rede.

Em contrapartida, a aprendizagem não-supervisionada não requer uma resposta correta associada com cada padrão de entrada no conjunto de dados da aprendizagem. Ela explora a estrutura dos dados, ou correlação entre dados nos padrões, e organiza os padrões dentro de categorias desta correlação.

Aprendizagem híbrida combina aprendizagem supervisionada e não-supervisionada. Parte dos pesos são geralmente determinados por aprendizagem supervisionada, enquanto outros são obtidos através de aprendizagem não-supervisionada.

A teoria da aprendizagem deve endereçar três visões fundamentais e práticas associadas com a aprendizagem das amostras: capacidade; complexidade das amostras, e

complexidade computacional. A capacidade se preocupa em compreender como muitos padrões podem ser armazenados, e também que funções e limites de decisão uma rede pode formar. A complexidade das amostras determina o número de padrões de treinamento necessários para treinar a rede para garantir uma generalização válida. A complexidade computacional refere-se ao tempo requerido para um algoritmo de aprendizagem estimar uma solução de padrões de treinamento.

2.5.3.1. Balanceamento de classes em redes MLP

Lawrence [LAWRENCE et al., 1998] tentam confrontar a idéia de que em métodos de classificação que utilizam redes MLP há problemas em relação às probabilidades *a priori* de classes individuais. Se o número de exemplos de treinamento que corresponde a cada classe variar significativamente entre as classes, a estimação precisa de uma probabilidade Bayesiana *a posteriori* requer que a rede seja: grande o suficiente, que o treinamento convirja para um mínimo global, possua dados de treinamento infinito, e que a probabilidade da classe *a priori* do conjunto de teste seja corretamente representada no conjunto de treinamento. Se o número de exemplos de treinamento para cada classe variar significativamente entre as classes, então há necessidade de um bias para predizer a classe mais comum, podendo conduzir a um pior desempenho de classificação para as classes mais raras.

Lawrence [LAWRENCE et al., 1998] citam que em alguns problemas de classes com baixa probabilidade *a priori*, nenhuma amostra foi classificada como estas classes depois do treinamento, concluindo que os problemas de balanceamento indicam que ou a estimação de probabilidade *a posteriori* Bayesiana é imprecisa, ou que tal estimação pode não ser a desejada.

Um método simples para aliviar esta dificuldade de desigualdade das probabilidades *a priori* das classes de acordo com Lawrence [LAWRENCE et al., 1998] é ajustar o número de padrões em cada classe, ou por sub-amostragem, neste caso removendo padrões de classes de alta frequência, ou por duplicação de padrões em classes de baixa frequência. Por sub-amostragem, padrões podem ser removidos aleatoriamente, ou heurísticamente removendo padrões em regiões de baixa ambigüidade. A sub-amostragem envolve uma perda de informação que pode ser prejudicial. Já a duplicação envolve uma grande base de dados e um maior tempo de treinamento para o mesmo número de épocas de treinamento (tempo de convergência pode ser maior ou menor).

Chan e Stolfo [CHAN & STOLFO, 1998] demonstram que a distribuição das classes, no treinamento, afetam o desempenho dos classificadores e a distribuição natural pode ser diferente da distribuição desejada do treinamento as quais maximizam o desempenho.

Japkowicz [JAPKOWICZ, 2000] tenta demonstrar que nem sempre os diferentes tipos de desbalanceamento de dados afetam o desempenho da classificação, assim como Weiss e Provost [WEISS & PROVOST, 2001] demonstram que conjuntos de dados balanceados nem sempre produzem os melhores resultados. Japkowicz demonstra que alguns métodos podem contornar problemas de balanceamento como:

- ‘*upsizing*’, método em que a classe representada por um pequeno conjunto de dados é aumentado, tal que se iguale ao tamanho da classe majoritária.
- ‘*downsizing*’, método, em que a classe representada por um grande conjunto de dados pode ser diminuída para igualar o tamanho da classe majoritária.

A conclusão de Japkowicz [JAPKOWICZ, 2000] é que o tamanho do conjunto de treinamento, com dados que são linearmente separáveis parecem ser insensitivos ao desbalanceamento, porém à medida que a complexidade aumenta o sistema torna-se sensitivo ao desbalanceamento de dados. Outra conclusão é que à medida que o tamanho do conjunto de treinamento aumenta, o grau de desbalanceamento tenderá a diminuir a taxa de erro. Isto sugere que em grandes domínios, o problema do balanceamento de classes pode não ser um impedimento para sistemas de classificação.

Especificamente, a visão da relativa cardinalidade de duas classes, que é freqüentemente um problema relacionado ao desbalanceamento de classes, pode de fato ser facilmente superado pelo uso de um grande conjunto de dados. Desta forma, o estudo de Japkowicz aponta que o desbalanceamento é um problema relativo dependente da complexidade do problema, representado pelos dados no qual o balanceamento ocorre, como também pelo tamanho global do conjunto de treinamento, em adição ao grau de balanceamento das classes presente nos dados.

Rasha [RASHA, 1994] e Lee [LEE, 1995] utilizam conjuntos com diferentes cardinalidades de amostras para cada classe durante a fase de treinamento em abordagens de verificação de assinaturas utilizando redes neurais. Lee [LEE, 1995] em experimentos com conjuntos de cardinalidades diferentes revela o desempenho superior com a incorporação de falsificações aleatórias na fase de aprendizagem, porém com amostras desbalanceadas.

2.5.3.2. Considerações sobre o treinamento em redes MLP

De acordo com Rasha [RASHA, 1994] muitos esforços são requeridos para projetar uma rede neural MLP. Durante o treinamento, pode-se notar que a estratégia de ajustar os pesos torna-se um processo muito lento, podendo permanecer em um mínimo local, ou tornando-se instável e oscilando entre soluções. A seguir são apresentados alguns parâmetros de treinamento a serem considerados:

- Treinamento por padrão ou por época: Quando se treina a rede, o erro é calculado e cada unidade na rede tem seus pesos ajustados tal que ele reduz o valor da função de erro. Os pesos da rede podem ser ajustados para cada padrão de treinamento e conseqüentemente implementa-se o treinamento por padrão. Uma alternativa é treinar por época. Uma época é uma varredura de todos os padrões no conjunto de treinamento. Conseqüentemente, uma correção acumulada do conjunto de pesos é executada depois de cada época de treinamento. Métodos de treinamento intermediário ou híbrido também são possíveis;
- Baixando a constante de aprendizagem η : η é a aprendizagem (ou termo de ganho) que especifica a largura do passo de treinamento. Se o termo de ganho começar com valores grandes, grandes serão os passos em relação aos pesos e superfície de erro para a solução. Se a superfície mudar rapidamente, um grande ganho pode causar uma oscilação no sistema, que poderá demorar ou impedir a convergência. Em contrapartida, se a superfície é relativamente suave, então haverá um grande ganho de velocidade de convergência;
- Vetores de treinamento em ordem seqüencial ou aleatória: este parâmetro é importante para otimizar a aprendizagem para que vários padrões sejam apresentados em diferentes ordens em diferentes ciclos. Pensando em alguns problemas, é valido destacar que uma ordem seqüencial de vetores de treinamento pode ser requerida para enfatizar certas propriedades, mas uma ordem aleatória de vetores de treinamentos é geralmente indicada.
- Supertreinamento (*Overtraining*): uma importante questão a ser considerada é quando parar o treinamento. Se a rede é treinada demasiadamente, o erro é minimizado por organizar os discriminantes muito especificamente, para o conjunto de treinamento. Desde que um conjunto de treinamento contenha apenas uma fração de exemplos possíveis de uma classe, estes discriminantes seriam firmemente focados em

características particulares do conjunto de treinamento. Quando tal rede for usada para classificar amostras que não foram utilizadas no treinamento, estes discriminantes altamente específicos tem uma pobre generalização e executam com menos precisão que uma rede que não foi supertreinada. Uma maneira para superar este problema é quebrar o treinamento em dois conjuntos. A primeira parte é usada para treinar de modo habitual. A segunda parte é usada a cada n ciclos para controlar a curva de aprendizagem. Quando o erro começar a subir neste segundo conjunto o treinamento é interrompido, e a rede é testada pelo conjunto de teste. Outra maneira de parar o treinamento é escolher um valor de erro e esperar que o valor seja atingido, o que pode causar uma sub-ajuste (*underfitting*) ou um sobre-ajuste (*overfitting*).

De acordo com Moody [MOODY, 1994] é mais fácil ocorrer um sobre-ajuste no treinamento com um conjunto pequeno de treinamento. Desta forma, deve-se tomar cuidado para não selecionar um modelo que seja grande demais, pois o mesmo resulta em um longo tempo de convergência e o desempenho global conseqüentemente nunca é perfeito.

Também conjuntos de dados limitados fazem a estimação do risco de predição mais difícil, se não houver dados suficientes disponíveis. Nestas situações, é preciso usar abordagens alternativas que habilitem a estimação do risco de predição dos dados separadamente como a re-amostragem, usando, por exemplo, validação cruzada tipo k -partições [PLUTOWSKI, 1996].

O erro esperado do treinamento e teste com relação à bias / variância para amostras finitas de treinamento é ilustrada na Figura 2.5. De acordo com Zhang [ZHANG, 2000] bias e variância são, na maioria das vezes, incompatíveis. Com um conjunto de dados fixado, o esforço em reduzir um implicará no aumento do outro.

Um bom compromisso entre bias e variância é necessário para construir um classificador baseado em redes neurais. Na Figura 2.5 notam-se regiões de sub-ajuste (bias elevado) e de sobre-ajuste (variância), em que técnicas de seleção do modelo ideal tentam encontrar o ponto ótimo entre falta e excesso de treinamento, os quais correspondem a um mínimo global dos erros do conjunto de teste ou curva de risco de predição.

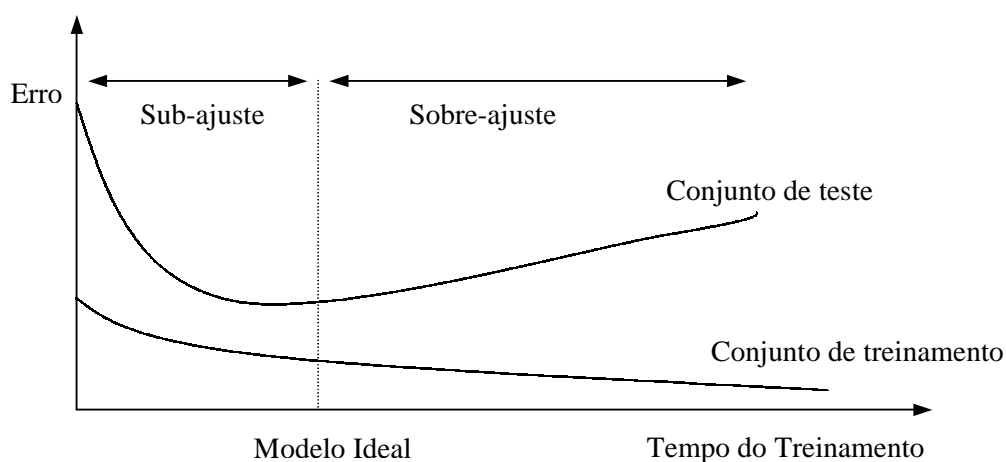


Figura 2.5: Curvas de aprendizagem com relação ao excesso ou falta de treinamento.

2.5.3.3. Estimando o desempenho de redes MLP

O objetivo de qualquer problema de classificação é classificar e prever com sucesso um novo dado. Entretanto, na maioria das formulações práticas uma regra de classificação pode não lidar perfeitamente com este problema. Há sempre a probabilidade de um erro de classificação. Um erro é uma má classificação: ao classificador é apresentado um caso e ele classifica-o incorretamente. Uma razão para isto é o fato de existirem características comuns para duas ou mais classes. Por exemplo, uma curva de distribuição normal de duas classes, disposta conforme Figura 2.6 de acordo com Rasha [RASHA, 1994].




Figura 2.6: Probabilidade do erro para um problema de duas classes.

As probabilidades do erro de classificação conforme a Figura 2.6 podem, por exemplo, ser calculadas como:

$$P(\text{erro}) = P(\text{escolher } w_1 \text{ e } x \text{ pertencer } w_2) + P(\text{escolher } w_2 \text{ e } x \text{ pertencer } w_1) \quad (2.16)$$

Em geral nos problemas de classificação de padrões pode haver dois tipos de erros de classificação:

- Falsa rejeição: o padrão de entrada é um membro da classe e é incorretamente classificado como não-membro da classe. β na Figura 2.6 representa a falsa rejeição para a classe w_2 , e α representa a falsa rejeição para classe w_1 ;
- Falsa aceitação: o padrão de entrada não é um membro da classe e é incorretamente classificado como membro da classe. β na Figura 2.6 representa a falsa aceitação para a classe w_1 , e α representa a falsa aceitação para classe w_2 .

Um limiar de decisão necessita ser estabelecido em qualquer problema de classificação. Na Figura 2.6 T representa este limiar. A escolha segue os critérios para minimizar a média do erro de falsa rejeição e falsa aceitação tentando minimizar o custo do erro.

Para avaliar as medidas de desempenho que levem em conta a probabilidade de um erro de classificação, a significância e o custo de um erro, algumas medidas de desempenho são necessárias como:

- Taxa de erro aparente: é a taxa de erro atual que o classificador aparentará, quando aplicado para todos os casos desconhecidos que ele tratar. Se um número ilimitado de classes estiver disponível, a taxa de erro verdadeira será computada como o número de amostras infinitamente abordadas. Entretanto, em casos práticos, o número de amostras disponíveis é finito, e relativamente pequeno. A taxa de erro aparente ou empírica é calculada, como notada na equação (2.17), como sendo o número de erros feitos pelo classificador em relação ao número de amostras.

$$\text{Taxa de erro aparente} = \frac{\text{n}^\circ \text{ erros}}{\text{n}^\circ \text{ amostras}} \quad (2.17)$$

Conseqüentemente quanto maior o de número de amostras, a taxa aparente estará mais próxima da taxa de erro verdadeira.

- Matriz de confusão: é uma matriz bi-dimensional usada para dispor os diferentes erros. A Tabela 2.1 ilustra uma matriz de confusão para três classes. A matriz de confusão lista a correta classificação contra a classificação predita para cada classe. Enquanto os elementos diagonais na matriz de confusão representam o número de classificações corretas, os elementos fora da diagonal representam o número de erros para um particular tipo de erro de má classificação. Portanto uma matriz de confusão desejada ter um valor máximo nos elementos diagonais e valor zero fora dela.

Tabela 2.1: Matriz de confusão de três classes

| Classes Preditas | Classes Verdadeiras | | |
|------------------|---------------------|----|----|
| | 1 | 2 | 3 |
| 1 | 50 | 0 | 0 |
| 2 | 0 | 48 | 5 |
| 3 | 0 | 2 | 45 |

2.5.4. Métodos de Validação do Processo de Aprendizagem

A essência do aprendizado *backpropagation* é codificar uma relação funcional entre entradas e saídas representada por um conjunto de exemplos rotulados. A esperança é que a rede torne-se bem treinada, de modo que ela aprenda bastante sobre o passado, para poder generalizar sobre o futuro. Sob esta perspectiva, o processo de aprendizado equivale a uma escolha de parametrização da rede para este conjunto de exemplos. Mais especificamente, pode-se ver o problema de seleção da rede como sendo um problema de escolha, dentro de um conjunto de estruturas de modelo candidatas (parametrizações), de acordo com um certo critério. Dentro deste modelo, o método *holdout* fornece um procedimento atrativo. Primeiro o conjunto de dados disponível é particionado aleatoriamente em um conjunto de treinamento e em um conjunto de teste. O conjunto de treinamento é depois particionado em dois conjuntos disjuntos: subconjunto de estimação, usado para selecionar o modelo; subconjunto de validação, usado para testar ou validar o modelo. Comumente utiliza-se um conjunto de validação para ajuste de parâmetros, como critério de parada também.

De acordo com Haykin [HAYKIN, 2001], o método de validação com divisão em duas partes (*holdout validation*) é um dos métodos mais comuns para estimar a generalização do erro. Este método, também chamado de teste de estimativa simples, particiona o conjunto

de dados em dois subconjuntos mutuamente excludentes, chamados de conjunto de treinamento e conjunto de teste. É comum designar 2/3 do conjunto de dados para o conjunto de treinamento e 1/3 para o conjunto de teste.

Provavelmente, a aplicação mais popular do método *holdout* é conhecida como parada com validação [PLUTOWSKI, 1996], do ponto de máxima generalização, e é aplicável para todo o procedimento de treinamento iterativo, pois a otimização da aprendizagem ocorre em pequenos passos com uma interatividade ocasionando a solução sobre os conjuntos de treinamento e validação. A forma básica consiste em medir o erro sobre um conjunto de validação após cada peso atualizado, continuando este processo enquanto o erro estiver decrementando, e parar quando o erro no conjunto de validação subir, ou se tornar estável o suficiente. Portanto, este método otimiza parcialmente o critério de aprendizagem no conjunto de treinamento, e na verdade, também otimiza o critério de aprendizagem no conjunto de validação. Desta forma o conjunto de treinamento é usado para prover informação independente da regra de atualização dos pesos. A parada com validação pode ser vista como o modo regular a generalização de um modelo durante o treinamento.

No método *holdout* como parada com validação nota-se que o conjunto de validação afeta o processo de aprendizagem. Portanto um terceiro conjunto de amostras independentes torna-se necessário (conjunto de teste) para obter uma estimativa precisa de desempenho de generalização do modelo treinado. Indiretamente com este método ocorre o processo de aprendizagem do conjunto de validação. Desta forma, para que se garanta que os dados de teste não sejam usados, o método de classificação opera com três conjuntos: conjunto de treinamento usado para construir a estrutura, conjunto de validação usado para otimizar ou ajustar parâmetros e também no critério de parada e o conjunto de teste usado para avaliar o desempenho.

2.6. SVM

Um problema encontrado em redes neurais artificiais, em específico em redes MLP é inferir uma relação entre número de camadas escondidas e as classes, o qual é determinado heurísticamente. Uma alternativa para este problema pode ser o SVM (*support vector machine*), pois representa o papel de classificador em problemas de reconhecimento de

padrões e tem sido utilizado recentemente em vários trabalhos relacionados a manuscritos como em Justino [JUSTINO et al., 2003] e Kholmatov, [KHOLMATOV, 2003] demonstrando alta performance com relação a ferramentas tradicionais de aprendizagem.

No SVM, os padrões de entrada são transformados para um vetor de características de alta dimensionalidade, cujo objetivo é separar no espaço as características linearmente. Neste caso o problema da aprendizagem é reduzido para o treinamento de um simples *perceptron*. Uma vez que o espaço adequado de características é definido, o SVM seleciona o hiperplano particular chamado hiperplano de margem máxima (MMH), o qual corresponde a maior distância de seus padrões no conjunto de treinamento. Estes padrões são chamados de vetores de suporte (SV).

A idéia principal é separar as classes com superfícies que maximizem a margem entre eles. A Figura 2.7 demonstra um conjunto de dados de duas classes w_1 e w_2 linearmente separáveis com margem de separação máxima Φ ou hiperplano de separação ótima [OSUNA et al., 1997].




Figura 2.7: Margem de separação máxima para duas classes

Para achar a superfície de decisão ótima, o algoritmo de treinamento dos vetores de suporte tenta separar da melhor forma possível os pontos de dados de ambas as classes, sendo que os pontos mais perto do limite entre as duas classes são selecionados, por serem mais importantes na solução do que os pontos que estão mais longes, os quais ajudam a definir a forma da melhor superfície de decisão que outros pontos.

Problemas complexos exigem funções mais complexas de classificadores para a sua solução como um classificador polinomial, que forma superfícies de decisão diferenciadas

conforme a Figura 2.8. Os vetores de suporte são representados por pontos com preenchimentos escuros.




Figura 2.8: Superfície de decisão de um classificador polinomial.

De acordo com Mukkamalla [MUKKAMALLA et al., 2002], o SVM é baseado na idéia de minimização do risco estrutural, o qual minimiza o erro de generalização, isto é, erros verdadeiros em amostras não-vistas. O número de parâmetros livres usado no SVM depende da margem que separa os pontos de dados, mas não do número de características de entrada afim de evitar o sobre-ajuste.

O SVM provê um mecanismo genérico de preencher a superfície de hiperplano por dados através de uso de uma função de *kernel*. O usuário pode prover uma função, tal como linear, polinomial, ou RBF, para o SVM durante o processo de treinamento, o qual seleciona vetores de suporte ao longo da superfície desta função. Esta capacidade permite classificar uma faixa de problemas maiores.

O limite de decisão entre duas classes é definido pelo SVM:

$$f(x) = \text{sign} \left(\sum_{x_i \in SV} y_i \alpha_i^0 K(x_i, x) + b_0 \right) \quad (2.18)$$

onde x é um padrão de entrada; x_i é o i^{th} vetor de suporte, SV é o conjunto de vetores de suporte; $y_i = \pm 1$ é o rótulo do padrão x_i ; b_0 é o bias do hiperplano; α_i^0 é o i^{th} multiplicador de Lagrange para o hiperplano ótimo; e finalmente $K(x_i, x)$ é a função do *kernel*, que pode mapear se necessário o dado de entrada para um alto espaço dimensional, conhecido como espaço de características. A função *kernel* é escolhida a *priori* e determina o tipo de classificador (linear, polinomial ou RBF). A Tabela. 2.2 aponta alguns *kernels* comumente usados.

Tabela 2.2 Alguns kernels do SVM comumente usados.

| Kernel | Expressão |
|------------------------|---|
| Linear | $K(x_i, x) = x \cdot x_i$ |
| Polinomial de grau d | $K(x_i, x) = (1 + x \cdot x_i)^d$ |
| Gausseano RBF | $K(x_i, x) = \exp\left(-\ x - x_i\ ^2\right)$ |

A idéia básica do SVM é mapear um espaço de entrada em um espaço de características de alta dimensionalidade. Este mapeamento pode ser feito linearmente ou não, de acordo com a função do *kernel* usada para o mapeamento. Neste novo espaço de características, o SVM constrói hiperplanos ótimos através dos quais as classes são separadas com objetivo de estabelecer uma margem maior entre cada classe e um erro mínimo na classificação. O hiperplano ótimo pode ser escrito como uma combinação de poucos pontos de características cujos pontos são chamados vetores de suportes do hiperplano ótimo [KHOLMATOV, 2003].

O SVM é baseado no princípio de minimização do risco estrutural (SRM). O princípio de indução (SRM) tem dois objetivos principais. Primeiro, controlar o risco empírico no conjunto de dados de treinamento e segundo controlar a capacidade da função de decisão usada para obter o valor deste risco. A função de decisão do SVM treinada linearmente $f(\bar{x})$ é descrita pelo vetor de pesos \bar{p} , um limiar b e padrões de entrada \bar{x} :

$$f(\bar{x}) = \text{sign}(\bar{p} \cdot \bar{x} + b) \quad (2.19)$$

Dado um conjunto de treinamento S_l composto por duas classes separadas, w_1 ($y_l = +1$) e w_2 ($y_l = -1$), o SVM acha o hiperplano com a máxima distância euclidiana. De acordo com os princípios do SRM, haverá apenas um hiperplano ótimo com a margem máxima Φ , definida como a soma das distâncias do hiperplano para os pontos mais próximos das classes. Este limiar do classificador linear é o hiperplano ótimo separador, conforme já demonstrado na Figura 2.7.

$$S_l = ((\bar{x}_1, y_1), \dots, (\bar{x}_l, y_l)), \bar{x}_i \in \mathfrak{R}^n, y_i \in \{-1, +1\} \quad (2.20)$$

No caso de conjuntos de treinamentos não-separáveis, o i^{th} ponto de dado tem uma variável ζ_i inativa, a qual representa a magnitude do erro de classificação. Uma função de penalidade $f(\zeta)$ representa a soma dos erros da má classificação:

$$f(\xi) = \sum_{i=1}^l \xi_i \quad (2.21)$$

A solução do SVM [JUSTINO et al., 2003], pode ser encontrada se mantiver o limite superior na dimensão VC (número de pontos máximo que pode ser separado para um conjunto de dados), e por minimizar o limite superior no risco empírico, isto é o número de erros de treinamento, com a seguinte minimização:

$$\min_{\bar{w}, b, \xi} = \frac{1}{2} \bar{p} \cdot \bar{p} + C \sum_{i=1}^n \xi_i \quad (2.22)$$

sendo que $C > 0$, determina uma negociação entre o erro empírico e o termo de complexidade. O parâmetro C é escolhido livremente. Um grande valor para C corresponde a uma associação de uma penalidade mais alta para os erros.

2.7. Comentários Finais

A teoria descrita neste capítulo é de fundamental importância para a elaboração do presente trabalho. Os tipos de abordagens e métodos relacionados a verificação de assinaturas fornecem uma visão clara do presente trabalho situando o mesmo no contexto de reconhecimento de padrões. A introdução a redes neurais e principalmente as dicas de melhorias de desempenho das redes MLP relacionado a arquitetura da rede neural, são de grande valia para o presente trabalho, assim como representa uma contribuição para trabalhos futuros. A introdução ao SVM fornece subsídios para os experimentos realizados. No capítulo seguinte são descritas algumas abordagens relacionadas a verificação de assinaturas, classificadas por tipos de abordagens.

Capítulo 3

3. Estado da Arte na Autenticação de Assinaturas

Existe um número considerável de trabalhos [JUSTINO, 2001], [SABOURIN & GENEST, 1994], [XIAO & LEEDHAM, 1999] e [BALTZAKIS & PAPAMARKOS, 2001] sobre o problema de verificação de assinaturas. Por ser uma área que atrai muitos pesquisadores e sendo um problema ainda em aberto, a verificação automática de assinaturas, tanto *on-line* quanto *off-line*, possui trabalhos com abordagens distintas no que se refere a características, classificador e métodos usados. Neste capítulo alguns trabalhos que se relacionam com o tema são descritos separadamente por tipos de abordagens, assim como uma visão crítica do estado da arte.

3.1. Abordagens Globais

Deng [DENG et al., 1999] apresentam um sistema de verificação de assinaturas *off-line* baseado em funções *wavelet*, utilizando um algoritmo de perseguição de contorno fechado para transformar as imagens de assinaturas em sinais unidimensionais. Os dados de curvatura de contorno são decompostos em sinais multiresolução usando transformada *wavelet*. Além disso, uma medida estatística é criada para decidir, sistematicamente, quais são os contornos fechados e os dados de frequências associados a estes contornos, demonstrando quais autores são mais estáveis e discriminantes relacionados a este critério. Baseando-se nestes dados, é calculado um valor de limiar ótimo que controla a precisão do processo de extração de características. O sistema utiliza imagens binárias na extração das características, usadas tanto em sistemas *on-line* quanto em *off-line*. A base de dados usada por Deng [DENG et al., 1999] é composta de 50 autores cada um com 20 assinaturas genuínas e 5 pessoas fornecem 10 tipos de falsificações dos 50 autores perfazendo um total de 3500 assinaturas.

Um outro método proposto por Bajaj e Chaudhury [BAJAJ & CHAUDHURY, 1996] utiliza três características globais. O uso de características globais dá-se pelo fato de que as mesmas trabalhavam com a forma da imagem, provendo um mecanismo mais rápido de acesso para os dados de assinatura, ao contrário de características locais que requerem técnicas computacionalmente onerosas para a determinação de similaridade. Bajaj e Chaudhury [BAJAJ & CHAUDHURY, 1996] usam momentos de projeção também usados por Marar [MARAR et al., 2002] e Ribeiro e Vasconcelos [RIBEIRO & VASCONCELOS, 1999], a qual utiliza uma medida estatística da distribuição dos *pixels* da assinatura e, ao contrário de outras características globais, é relativamente insensível a distorções e variações de estilo. Um outro tipo de característica, utilizado por Bajaj e Chaudhury [BAJAJ & CHAUDHURY, 1996] está relacionado com a distribuição extrema de pixels envolvendo os limites inferiores e superiores da assinatura, denominado envelopes. Para aumentar a confiabilidade da classificação, os resultados obtidos das três características são combinados em múltiplos classificadores. A verificação é feita com base no vetor destas 3 características utilizando três redes MLP. O uso de múltiplos classificadores introduz um elemento de redundância no esquema, pois os erros de classificação são compensados por um simples classificador, se, é claro, outros classificadores não proverem a correta decisão. As saídas dos três classificadores são combinadas para a decisão final, através da estratégia do vencedor leva tudo. O método tem a vantagem de combinar evidências providas por diferentes tipos de características, porque no caso de haver confusão na classificação quanto à característica outro conjunto pode auxiliar. A base de dados usada no experimento é composta por 10 autores, cada um provendo 15 assinaturas e somente 100 assinaturas aleatórias dos 10 autores.

Nota-se, também, que o modelo de redes neurais mais amplamente utilizado em problemas relacionados à verificação de assinaturas é a rede MLP e o algoritmo *backpropagation*, porém Ribeiro e Vasconcelos [RIBEIRO & VASCONCELOS, 1999] utilizam arquiteturas construtivas (as quais constroem sua própria estrutura incluindo unidades e camadas intermediárias) *Cascade-Correlation*, *Tower* e *Pyramid* sob a abordagem autoassociativa (em que as saídas são forçadas a reproduzir as entradas) sendo os resultados comparados com a rede MLP. Ribeiro e Vasconcelos acreditam que modelos de redes *feedforward* que atuam como classificadores não são adequados, pois a discriminação de classes neste tipo de rede é realizada por superfície de separação, a qual é gerada para particionar os dados de entrada. No entanto, tais superfícies são abertas. Já as redes *feedforward* que atuam como autoassociadores geram superfícies de separação fechadas, e

utilizam critérios de rejeição relacionados à maneira com que a entrada se aproxima da saída. Na extração de características Ribeiro e Vasconcelos [RIBEIRO & VASCONCELOS, 1999] utilizam momentos invariantes, inclinação e fator de pressão global da imagem. Ao final o resultado em uma base de dados reduzida com 21 autores demonstra algum ganho com relação à falsa rejeição, mas nenhum acréscimo à falsa aceitação.

3.2. Abordagens Locais

O número de assinaturas genuínas do mesmo autor no processo de treinamento torna-se um problema na maioria dos métodos propostos. Uma abordagem que procura minimizar este problema é proposta por Xiao e Leedham [XIAO & LEEDHAM, 1999], nesta abordagem uma rede neural MLP é usada como classificador. A base fundamental do método reside no fato que peritos forenses localizam primeiro as diferenças entre a assinatura de entrada e a assinatura genuína armazenada, comparando características locais, então analisam a variação destas características julgando se as mesmas são essenciais ou acidentais. Neste estudo, Xiao e Leedham [XIAO & LEEDHAM, 1999] tratam das partes estáveis da assinatura, ou seja, segmentos com menores variações, como também dos nós de resposta do classificador. Para alcançar estes objetivos, é usado um método para gerar falsificações artificiais das assinaturas genuínas assim como uma rede neural com realimentação apropriada dos pesos dos nós de resposta. Com relação às características, a distribuição dos pixels em quatro direções é utilizada dentro de um *grid*. Os resultados obtidos com poucos autores são aceitáveis, principalmente pelo número de assinaturas genuínas utilizadas (em torno de 9), porém é conveniente ressaltar que 9 autores voluntários são insuficientes para uma perfeita validação estatística.

Alguns trabalhos abordam o problema de falsificações aleatórias [MURSHED et al., 1995], em que o sistema é treinado somente com assinaturas genuínas. A alegação é que na prática nem sempre é possível obter assinaturas falsificadas, tornando-se impraticável quando aplicada em sistemas reais como aplicações bancárias. Para lidar com estas dificuldades alguns pesquisadores têm usado assinaturas de outros autores no sistema como sendo assinaturas falsas, as chamadas falsificações aleatórias. Neste caso, a taxa de falsa aceitação é artificialmente reduzida no contexto de falsificação, de acordo com Murshed. Por exemplo, se

um sistema é treinado com assinaturas genuínas do escritor 'a' e com falsificações aleatórias dos escritores 'b', 'c' e 'd', então o sistema adquire um conhecimento de características contidas nas assinaturas destes escritores. Durante a fase de avaliação quando o sistema é confrontado com assinaturas dos escritores 'b', 'c' e 'd' como sendo falsificações aleatórias, ele usa seu conhecimento adquirido durante o treinamento, e provavelmente classifica estas assinaturas como aleatórias. Ainda no trabalho de Murshed, nota-se que o desempenho final pode não ser o mesmo se introduzidas assinaturas de autores que não contribuem para a fase de treinamento. Durante o estágio de treinamento, o sistema aprende características das assinaturas genuínas de um dado escritor, formando tantas classes de categorias quantas são as características distintas. Quando o treinamento termina, o sistema tem conhecimento somente de assinaturas genuínas deste escritor. Semelhante a abordagem de Sansone e Vento [SANSONE & VENTO, 2000], no método de Murshed [MURSHED et al., 1995] o primeiro estágio centraliza a imagem e divide a mesma em regiões (*grid*). Em seguida segmentos gráficos de tamanho fixos são extraídos de cada região e modelada por uma rede neural para reduzir o tamanho destes segmentos. No estágio seguinte cada uma das regiões é modelada por uma rede Fuzzy ARTMAP. Finalmente, o estágio de decisão analisa os resultados produzidos para cada Fuzzy ARTMAP e toma a decisão sobre a autenticidade das assinaturas. Para dividir a assinatura de entrada durante o treinamento/verificação em regiões, uma identidade de *grid* é projetada para cada escritor, tal que sua forma reflete a média global das assinaturas de referências deste referido escritor. Neste método usa-se memória associativa através de uma rede *backpropagation* para a redução da dimensionalidade aplicada nas imagens e a saída do primeiro estágio forma um vetor com 768 entradas nas redes Fuzzy ARTMAP. A base de dados usada é composta por 200 assinaturas de 5 autores, com 40 assinaturas genuínas. Nesta abordagem, como na maioria dos trabalhos correlatos, demonstrase que os melhores desempenhos são obtidos com um número maior de assinaturas genuínas por autor no treinamento.

Também Zhang [ZHANG et al., 1998] propõem um método de verificação de assinaturas baseado na técnica de quantização vetorial, em que um número de *codebooks* é estabelecido para palavras de cada pessoa e a classificação é estabelecida num esquema de reconstrução chamada decodificador da população. Para este método usam-se 3770 assinaturas de 19 autores. As imagens são normalizadas em tamanho fixo de 240 por 120 pixels. Na extração de características duas técnicas são usadas. Na primeira, a imagem é segmentada em regiões de 24 x 12 e para cada região são contados os pixels. Na outra técnica,

usa-se a transformação de escala de cinza por região, sendo aplicada uma máscara de tamanho 3 x 3 sobre as regiões de tamanho 80 x 40. Zhang [ZHANG et al., 1998] enfatizam a necessidade de se coletar as assinaturas em tempos distintos, para tanto realizam experimentos diferenciados com amostras coletadas em períodos distintos.

Outra abordagem que utiliza a geração de assinaturas genuínas artificiais para treinamento é proposta por Huang e Yan [HUANG & YAN, 1997] com uma variante em que assinaturas artificiais com alto grau de distorção são incorporadas como falsificação no processo de treinamento. Um modelo de segmentação em células de tamanhos diferenciados é aplicado na extração das características locais. As características geométricas são obtidas do núcleo da assinatura, do contorno, da distribuição dos pixels, de fronteiras direcionais e da região de máxima pressão. A base de dados usada é de 3528 assinaturas de 21 autores sendo que cada autor cede 24 assinaturas genuínas e 6 outras pessoas produzem 24 falsificações dos 21 autores. Vários níveis de resolução do *grid* são testados, sendo um nível para cada rede, a qual compõe as características dentro do tamanho do *grid* em específico. Após o treinamento individual de cada rede, as saídas são passadas para uma outra rede neural cuja função é combinar as respostas de cada rede e produzir uma decisão.

Sabourin e Genest [SABOURIN & GENEST, 1994] propõem uma abordagem local com características estatísticas. Este método utiliza a técnica denominada *Extended-Shadow-Code* na qual as operações de projeções são definidas em um *grid*, ocorrendo simultâneas projeções para cada *pixel* preto nas barras horizontais, verticais e na diagonal. A projeção contém um conjunto de *bits* distribuídos ao longo de cada barra, os quais são contados. O método de verificação é estatístico e utiliza dois classificadores *knn* (vizinho mais próximo) e um classificador de mínimas distâncias. Com relação ao uso de uma base de dados Sabourin e Genest [SABOURIN & GENEST, 1994] utilizam 800 assinaturas, sendo 40 assinaturas produzidas por 20 autores distintos.

De acordo com Justino [JUSTINO et al., 2002] cada tipo de falsificação requisita um método de reconhecimento diferente. Métodos baseados em abordagens estáticas são usados para identificar falsificações aleatórias e simples. A razão é que estes métodos descrevem melhor as características relacionadas à forma da assinatura. A abordagem baseada na grafometria [JUSTINO et al., 2002] supre esta lacuna do uso de métodos de reconhecimentos diferentes, em relação à escolha do tipo de características, pois engloba características que possuem um tratamento local, as chamadas pseudodinâmicas. Justino utiliza a característica pseudodinâmica inclinação axial que descreve adequadamente o movimento da escrita, como

também utiliza características estáticas representadas pela densidade de pixels e a sua distribuição. Justino [JUSTINO et al., 2002] usam a imagem binária dentro de um *grid* para extrair as características. Na densidade de pixels, a contagem é efetuada em cada região do *grid* (célula), já a distribuição representa a distribuição geométrica dentro da célula. Na inclinação axial, os pixels pretos são projetados nos 4 sensores da periferia de cada célula, usando como base o eixo central da célula. Cada sensor prove um valor numérico que corresponde ao total de pixels projetados. Este valor numérico é normalizado pelo tamanho do sensor. Um conjunto de *codebooks* gerado para cada característica utiliza uma base de dados específica para a geração do léxico. No processo de quantização vetorial o algoritmo *k-means* é utilizado. Este procedimento tem como objetivo a redução da dimensionalidade dos vetores gerados, que são então enviados ao classificador HMM para o processo de aprendizagem. Como o treinamento é baseado em um modelo pessoal, Justino [JUSTINO et al., 2002] determina limiares de aceitação e rejeição levando em conta cada autor em específico, desta forma melhora os resultados. A base de dados deste experimento é composta por 5200 assinaturas de 100 autores sendo 4000 genuínas correspondendo a 40 assinaturas de 100 autores e 1200 falsificações simples e simuladas.

3.3. Abordagens Globais e Locais

Sistemas em que a aplicação enquadra-se em qualquer contexto despertam interesse de pesquisadores. Qi e Hunt [QI & HUNT, 1994], propõem a representação de características invariantes à mudança de escala nas assinaturas, sendo usadas características globais e geométricas como altura, largura, centro de gravidade, ângulo de inclinação e projeções, e ainda características locais representadas por um *grid*. No processo de verificação utiliza-se um sistema multi-escala baseado em distância euclidiana. Nesta abordagem 25 autores são usados, com 15 autores que provem 20 assinaturas genuínas e os 10 restantes cedem 15 falsificações perfazendo um total de 450 assinaturas para o treinamento e teste. Para esta verificação, utilizam-se somente medidas de distâncias.

Sansone e Vento [SANSONE & VENTO, 2000] propõem um sistema baseado em rede neurais com múltiplos estágios de decisão no processo de verificação. Cada estágio é representado por uma rede MLP usando um conjunto adequado de características. O primeiro

estágio adota somente características globais (a estrutura da assinatura) e é dedicado à eliminação de falsificações simples e aleatórias, mas, mesmo com a generalidade empregada, implica em um efeito não desejado, no qual algumas falsificações simuladas são aceitas como genuínas. O segundo estágio recebe apenas assinaturas não classificadas como falsas no primeiro estágio (isto é, aquelas assinaturas realmente genuínas, ou falsificações reproduzidas de uma maneira simulada que enganaram o primeiro estágio), e adota uma característica específica para esta tarefa, neste caso, são usadas regiões de alta pressão. Ambos os estágios empregam um critério para estimar a confiabilidade do desempenho do classificador, tal que, quando há incerteza quanto à assinatura, esta é remetida para um estágio que toma a decisão final, levando em conta a decisão dos estágios prévios junto com a correspondente estimativa de confiabilidade. Na avaliação da confiabilidade, o sistema usa limiares de rejeição. A base de dados do experimento é composta de 49 autores sendo 20 assinaturas genuínas por autor e um total de 1960 assinaturas.

Faez [FAEZ et al., 1997] propõem um método de verificação de assinaturas utilizando redes neurais baseado em características de descritores de forma: esqueleto da imagem, baixo envelope e alto envelope, e regiões de alta pressão, sendo esta última característica extraída em níveis de cinza. Sobre cada imagem de assinatura alinhada é sobreposto um *grid* de 5x10 extraíndo características locais da imagem. Uma rede MLP para cada descritor de forma, ou seja, cada característica é treinada, e no final cada nó de saída da rede fornece uma medida de confiança na decisão. Para encontrar a decisão ótima usa-se a decisão integral Fuzzy combinando as saídas individuais de cada rede. Faez [FAEZ et al., 1997] geram assinaturas genuínas artificiais, uma vez que a abordagem propõem o uso de quantidade reduzida de amostras por autor. A base de dados possui 50 autores: cada autor com 10 assinaturas genuínas e outras pessoas fornecendo 10 falsificações por autor, sendo 5 simuladas e 5 simples. No total 1000 assinaturas mais 40 assinaturas por autor geradas artificialmente são utilizadas

Baltzakis e Papamarkos [BALTZAKIS & PAPAMARKOS, 2000] propõem um novo método com habilidade de verificar e reconhecer a assinatura em um processo multi-estágio utilizando classificadores neurais. O sistema é baseado no uso de três grupos de características: as globais, nas quais se encaixam a altura da assinatura, área da imagem, largura da imagem, comportamento base, projeções vertical e horizontal, curvatura, pontos de borda, cruzamentos e laços. Outro grupo extrai informações locais do *grid*, no qual os pixels pretos são contados e normalizados em 0 ou 1 de acordo com a quantidade de *pixels* dentro de

cada região. Um outro grupo de característica utilizada é a textura com uso da matriz de co-ocorrência da imagem em nível de cinza dividindo em regiões para sua extração. No primeiro estágio, cada grupo de característica é dado entrada em uma rede MLP separadamente e a distância euclidiana também é extraída das características. O segundo estágio, composto das saídas das características do primeiro estágio e da distância euclidiana das características, representa quatro entradas em uma rede RBF baseada na qual a decisão final é tomada. A base de dados é composta de 2000 assinaturas de 115 autores. Cada autor prove 15 ou 25 assinaturas.

A Tabela 3.1 abaixo demonstra o resumo das abordagens apresentadas com seus respectivos diferenciais em termos de tipos de abordagens e características, que fazem parte do ponto de partida para este trabalho.

Tabela.3.1: Resumo do estado da arte relevante para a dissertação

| Referência | Características | Classificador |
|--------------------------------|--|--|
| [DENG et al., 1999] | Abordagem global <i>Wavelet</i> (Como características estáticas e pseudodinâmicas) | Medidas de Distância |
| [BAJAJ & CHAUDHURY, 1996] | Abordagem global Projeção de momentos verticais e horizontais Envelope baixo e alto da imagem da assinatura | Redes Neurais MLP |
| [RIBEIRO & VASCONCELOS, 1999] | Abordagem global Momentos invariantes, inclinação e pressão global. | Redes Neurais MLP, <i>Cascade-Correlation, Tower e Pyramid</i> |
| [XIAO & LEEDHAM, 1999] | Abordagem local Uso de distribuição de pixels nas quatro direções dentro de cada célula de um <i>grid</i> . | Rede Neural MLP |
| [MURSHED et al., 1995] | Abordagem local Segmentos gráficos do <i>grid</i> e uso de rede <i>backpropagation</i> como redutor de dimensionalidade | Rede Fuzzy ARTMAP |
| [ZHANG et al., 1998] | Abordagem local Características estáticas relacionadas a contagem de pixels em regiões de um <i>grid</i> | Quantização Vetorial e esquema de reconstrução |
| [HUANG & YAN, 1997] | Abordagem local Características geométricas com uso de um <i>grid</i> para extrair o núcleo da assinatura, distribuição de pixels, fronteiras direcionais e regiões de alta pressão. | Redes Neurais MLP |
| [SABOURIN & GENEST, 1994] | Abordagem local Características estáticas com uso de <i>grid</i> na contagem de pixels baseado nas projeções horizontais, verticais e diagonais das células. | k-NN e classificador de mínimas distâncias |
| [JUSTINO et al., 2002] | Abordagem local Características estáticas representadas por densidade de pixels e distribuição de pixels Característica pseudodinâmica representado pela inclinação axial | Quantização Vetorial e HMM |
| [QI & HUNT, 1994] | Abordagem global e local Características geométricas relacionadas à altura, largura, ângulo de projeção e inclinação e uso de um <i>grid</i> | Medidas de distância |
| [SANSONE & VENTO, 2000] | Abordagem global e local Contorno da assinatura e regiões de alta pressão | Redes Neurais MLP |
| [FAEZ et al., 1997] | Abordagem global e local Características geométricas usando envelope baixo e alto. Características pseudodinâmicas de pressão, parada e inclinação. | Comitê de redes MLP Combinando as saídas em uma decisão Fuzzy |
| [BALTZAKIS & PAPAMARKOS, 2000] | Abordagem local e global com três grupos de características: 1° grupo: largura, altura, área, comportamento base, projeções verticais, projeções horizontais, curvatura, pontos de borda, cruzamentos e bordas 2° grupo: contagem de pixels utilizando um <i>grid</i> 3° grupo: textura | Redes MLP no treinamento de cada grupo e rede RBF na decisão |

3.4. Visão Crítica do Estado da Arte

A visão crítica proposta busca contribuir para uma abordagem mais consistente e que possua conotação prática. Entretanto, uma comparação mais refinada em termos de resultados estatísticos em cada abordagem torna-se difícil, justamente pela diversidade de bases de dados e protocolos experimentais existentes, e também por não existir nenhuma base de dados internacional compartilhada, implicando um grande problema para a comparação de desempenho entre métodos [FANG et al., 2003] [MURSHED et al., 1995].

Os resultados apresentados por algumas abordagens mostram taxas de erros baixas, porém quando analisados profundamente demonstram que tratam apenas de alguns tipos de falsificações, desconsiderando, por exemplo, as falsificações simuladas [BALTZAKIS & PAPAMARKOS, 2000].

É comum ter soluções combinando diferentes tipos de classificadores, pois cada um contribui de maneira diferenciada na elaboração do resultado final [BALTZAKIS & PAPAMARKOS, 2000]. Em outros casos, é possível encontrar solução combinando um conjunto do mesmo tipo de classificador [BAJAJ & CHAUDHURY, 1996].

Muitas abordagens baseadas em características globais [DENG et al., 1999], [BAJAJ & CHAUDHURY, 1996] e [RIBEIRO & VASCONCELOS, 1999] demonstram ser mais rápidas no processo de extração de características, porém, de acordo com Justino [JUSTINO et al., 2002], métodos que utilizam características locais possuem capacidade discriminatória maior em relação à falsificações simuladas e simples. Com relação à base de dados, muitos métodos apresentam quantidades de autores reduzidos para validação estatística [XIAO & LEEDHAM, 1999], [BAJAJ & CHAUDHURY, 1996] e [MURSHED et al., 1995]. Já a quantidade de assinaturas genuínas usada por autor, no processo de aprendizagem, representa um problema, caso o número extrapole uma quantidade maior do que os normalmente aplicados em sistemas atuais, e desta forma dificulta a sua aplicação prática [SANSONE & VENTO, 2000], [MURSHED et al., 1995], [HUANG & YAN, 1997] [SABOURIN & GENEST, 1994] e [JUSTINO et al., 2003].

Existem algumas abordagens que utilizam técnicas de geração de amostras artificiais automaticamente [XIAO & LEEDHAM, 1999] e [FAEZ et al., 1997], como também a geração artificial automática de amostras de falsificações [HUANG & YAN, 1997]. Neste caso, há controvérsias com relação à incorporação destes tipos de amostras no processo de

verificação por não refletir a variação intrapessoal como também as eventuais falsificações do mundo real. Um caso extremo é o de Velez [VELEZ et al., 2003] que apresentam um método de geração de múltiplas assinaturas de cada indivíduo, baseado em uma assinatura correspondente. Neste processo, tenta-se emular a variação intrapessoal dentro das assinaturas de cada autor, as quais são aplicadas em diferentes combinações, usando para tanto uma assinatura original. Desta forma cada assinatura original gera 1936 padrões de assinaturas sintéticas.

Algumas abordagens utilizam um processo de redução da dimensionalidade do vetor de características como em Justino [JUSTINO, 2001] e Murshed [MURSHED et al., 1995]. Neste último, um processo de redução de dimensionalidade nas imagens ainda forma um vetor de saída com 768 posições como entrada para uma rede Fuzzy ARTMAP.

Métodos que incorporam *grids* [XIAO & LEEDHAM, 1999] e [JUSTINO, 2001], de certa forma já aplicam um processo de redução da dimensionalidade das características.

Outros como Drouhard [DROUHARD et al., 1994] acreditam que um classificador é mais eficiente se diminuir a dimensão do vetor de entrada (dados desnecessários) e a variação no vetor de entrada ser menos abrupta (dados com ruídos). Porém, características de um *grid*, submetidas diretamente ao classificador sem um processo de redução da dimensionalidade dos vetores de características, são abordadas por Xiao e Leedham [XIAO & LEEDHAM, 1999]. Xiao e Leedham utilizam um *grid* de 9x8 com 4 primitivas totalizando 288 posições de entrada em uma rede MLP. Os resultados obtidos nas taxas de erros são: 9,2% de erro na taxa de falsa rejeição e 17% de erro na taxa de falsa aceitação.

Já em Rasha [RASHA, 1994] a camada de entrada de uma rede MLP é composta de 5.600 neurônios correspondendo à própria imagem 160x35 pixels. Infelizmente não há uma maneira de determinar estes parâmetros, desde que eles são fortemente dependentes da aplicação.

3.5. Comentários Finais

Os trabalhos apresentados neste capítulo contribuem na elaboração do presente trabalho no que se refere ao tipo de abordagem empregada, escolha das características e classificadores. Desta forma é proposta uma abordagem local com características estáticas e

pseudodinâmicas baseadas no uso de técnicas grafométricas e uma rede neural MLP como classificador. No capítulo seguinte é descrita toda a fundamentação metodológica aplicada na abordagem proposta.

Capítulo 4

4. Metodologia

Neste capítulo é detalhada a metodologia aplicada na abordagem proposta para a verificação de assinaturas. É apresentado um estudo detalhado das técnicas forenses fundamentais na análise de documentos questionados, mais especificamente no processo de extração das características assim como medidas de distâncias, juntamente com a abordagem dicotômica usada para a produção de um modelo.

4.1. Requisitos

Uma análise mais profunda sobre a aplicação da maioria das abordagens para verificação de assinaturas impõe restrições, sendo limitada a um problema em específico. Esta redução de escopo contribui para o alcance de resultados desejáveis, porém o uso prático pode ficar comprometido quando o meio utilizado diferir do meio proposto. Esta abordagem não pretende acabar com este problema, porém a minimização faz parte da proposta.

A seguir são apresentados alguns requisitos, que devem ser objeto de um estudo detalhado em cada etapa do processo:

- Ser suscetível aos vários tipos de falsificações a que o sistema é submetido;
- Procurar a redução do número de classes no ambiente de classificação;
- Considerar uma limitação do espaço gráfico de 3 x 10 centímetros, que representa um retângulo destinado à assinatura no documento. Esta restrição imposta é pertinente à base de dados de laboratório utilizada por Justino [JUSTINO, 2001]. Todas as especificações técnicas do processo de aquisição da base de dados estão descritas em Justino [JUSTINO, 2001].

4.2. Recursos

O objetivo desta seção é descrever detalhadamente os subsídios necessários no desenvolvimento da solução para o problema proposto de verificação de autenticidade de assinaturas, levando em conta cada um dos requisitos estabelecidos. Ela subdivide-se em quatro partes principais, que vem ao encontro dos requisitos que a abordagem exige:

1. Dentro do grafismo o uso de técnicas grafométricas na extração de características geométricas locais, procurando transcrever a visão técnica na análise de similaridade, a qual foi amplamente estudada por Justino [JUSTINO, 2001];
2. A utilização de medidas de distância nas características extraídas no processo de aprendizagem;
3. A redução de escopo no processo de classificação exige uma técnica denominada dicotomia;
4. E finalmente a combinação de todos estes recursos que será abordada no capítulo 5 no processo de:
 - a. Produção de um modelo, que se faz necessário através de uma base de dados e ao uso de um classificador;
 - b. Verificação, que utiliza a grafoscopia relacionada à visão do perito grafotécnico no processo de decisão baseado em um comparativo de similaridade.

4.3. Grafismo

O grafismo engloba quatro campos de estudo: a grafoscopia que é o estudo da origem do documento gráfico; a grafologia, por sua vez, é o estudo da escrita visando a determinação da psique do escritor; a paleografia, é o estudo histórico da escrita; por fim, a caligrafia, que é o estudo artístico da escrita. A grafoscopia e a grafologia, são importantes para este trabalho, pois abordam o estudo das características pessoais de um escritor ligadas à sua escrita [JUSTINO, 2001].

4.3.1. Grafoscopia

A grafoscopia tradicional foi desenvolvida com o objetivo de esclarecer questões criminais. Tratando-se de um campo da criminalística, ela tem sido conceituada como a área cuja finalidade é a verificação da autenticidade e da autoria de um documento, a partir de características gráficas utilizadas na elaboração de um documento [JUSTINO, 2001].

Como a escrita está sujeita a inúmeras mudanças, decorrentes de causas variadas, ela exige conveniente interpretação técnica para o completo êxito dos exames grafoscópicos periciais. As variações do grafismo originam-se de causas normais, artificiais e ocasionais. As primeiras são aquelas que acompanham o próprio desenvolvimento humano, nos períodos abrangidos pela infância e adolescência, maturidade e velhice. Já as segundas, são transformações da escrita causadas pelo artificialismo ocorrido nos casos de falsificações e dissimulações gráficas. As causas ocasionais originam-se das moléstias, dos estados emocionais, de lesões na mão e de outros fatores físicos [JUSTINO, 2001].

Os elementos técnicos usados nos exames das identidades gráficas são:

- Genéricos: que se dividem em calibre, espaçamento, proporção, comportamento pauta, comportamento base, valores angulares, valores curvilíneos e inclinação axial;
- Genéticos: que se subdividem em dinâmicos (pressão, progressão) e trajetos (ataques, desenvolvimentos, remates, mínimos gráficos). Cada um desses elementos pode ser enquadrado. Em um exame grafoscópico, com convergência ou divergência (mínima, média, máxima).

No que se refere às assinaturas analisadas, elas nem sempre apresentam-se em perfeitas condições, ocorrendo casos em que existem recobrimentos, falhas devido a dobras ou desgastes de papel, ou outras anomalias, impedindo o levantamento de elementos técnicos suficientes para uma conclusão decisiva [JUSTINO, 2001].

Por mais que alguma semelhança nas assinaturas ou escrita de cada autor possa existir, elementos indicadores de individualidade estarão presentes na seqüência de letras de uma palavra. São características discriminantes observadas de perto pelo perito durante uma perícia. A seguir são apresentadas algumas dessas características individuais.

4.3.1.1. Calibre

É o tamanho da escrita relacionado com o espaço gráfico disponível, sendo uma característica intrínseca de cada autor. No contexto de assinaturas este tipo de característica é melhor visualizada em assinaturas cursivas. A Figura 4.1(a) mostra um exemplo de uma assinatura de reduzido calibre e outra assinatura de alto calibre 4.1(b).




Figura 4.1: Assinatura de calibre reduzido (a) e de alto calibre (b).

4.3.1.2. Espaçamento

Corresponde a interrupção do curso da escrita entre combinações de segmentos e letras. O espaçamento ocorre com certa frequência em assinaturas cursivas quando normalmente a escrita é formada por nome composto, conforme representado na Figura 4.2.




Figura 4.2: Assinatura cursiva com espaçamentos entre os nome e sobrenomes.

4.3.1.3. Alinhamento em Relação à Linha Base

Esta característica corresponde à capacidade do escritor de produzir linhas de textos alinhadas com uma linha guia horizontal fictícia (não-pautado) ou real (pautado). As assinaturas podem apresentar graus distintos de inclinação, usualmente para baixo em documentos pautados e não-pautados, confira na Figura 4.3.



Figura 4.3: Exemplo de assinatura inclinada em documento não-pautado.

4.3.1.4. Inclinação Axial

A inclinação axial é o ângulo de inclinação da escrita, em relação ao eixo vertical, sendo o eixo horizontal representado por uma linha de base imaginária. Essa inclinação pode ocorrer à esquerda ou à direita, conforme Figura 4.4(a) e (b). A inclinação axial da escrita pode ocorrer desde o princípio de uma palavra até o final da mesma, ou desde o princípio de uma oração, parágrafo ou página, até o final das mesmas. Não são raros os casos em que o escritor apresenta um misto dessa inclinação, isto é, inclinações à esquerda, à direita e alinhado ao eixo vertical (com inclinação axial nula). Se essa mudança de inclinação axial é habitual, ela pode ser considerada uma característica identificadora. Embora esteja longe de ser uma regra definitiva, uma escrita com inclinação axial à direita ou à esquerda pode indicar a existência de um escritor destro ou canhoto, respectivamente. No entanto, é comum entre os escritores canhotos, o posicionamento inclinado do documento, no momento da escrita. Esse procedimento tem como objetivo produzir uma inclinação axial nula, ou quase nula. Esse hábito pode ser considerado uma característica ou estilo do escritor [JUSTINO, 2002].

Muitos peritos quantificam as variações na inclinação axial encontradas por todo o documento, medindo os ângulos fisicamente e pondo os resultados no laudo pericial. Com isso, é possível trazer à luz diferenças sutis entre a escrita questionada e a analisada. Alguns cuidados devem ser tomados nesses casos, pois a variação intrapessoal (variações de escrita do mesmo escritor) pode conduzir a uma análise incorreta.




Figura 4.4: Exemplo de inclinação à direita (a) e à esquerda (b).

4.3.1.5. Segmentos Angulares e Segmentos Curvilíneos

Os segmentos angulares formam ângulos que mudam bruscamente de direção. Já os segmentos curvilíneos estão relacionados a uma escrita sem segmentos retos com formas arredondadas, conforme os exemplos de assinatura na Figura 4.5(a) e (b).



Figura 4.5: Exemplo de assinatura de segmentos com segmentos angulares (a) e com segmentos curvilíneos (b).

4.3.1.6. Mínimos Gráficos

Os mínimos gráficos são formados pelos pontos finais, vírgulas, os pingos nos 'i's, acentos (crase, circunflexo, til e agudo) e cedilhas. Uma pequena porção de escritura como um mínimo gráfico pode, em alguns casos, tornar-se uma característica identificadora relevante. Os pingos nas letras 'i's podem apresentar diferentes formas, dependendo do estilo de escrita do autor. Podem possuir um formato curvo e aberto para cima na forma de um traço (clave) horizontal ou vertical, pode estar inclinado à esquerda ou à direita, ou apresentar a forma de um simples ponto, confira na Figura 4.6.




Figura 4.6: Exemplo de mínimos gráficos.

4.3.1.7. Velocidade

A velocidade da escrita é frequentemente uma característica essencial para a identificação do autor. Está relacionada com os elementos técnicos genéticos da progressão. Um movimento rápido do objeto de escrita é difícil de ser duplicado por um falsificador, confira na Figura 4.7.



Figura 4.7: Exemplo de assinatura com escrita rápida (a) e lenta (b).

Os elementos seguintes descrevem alguns indicadores de escrita rápida e lenta:

- Rápida
 - Traçado tenso, sem tremor;
 - Alongamento na finalização dos traços;
 - Falta de legibilidade;
- Lento
 - Vacilação e tremor, escritura mais angular;
 - Cruzamentos dos 't' em posição correta;
 - Parada e recomeço abrupto (clave);
 - A escrita é feita de letras individuais e legíveis;
 - Movimento pode apresentar ornamentos.

4.3.1.8. Indícios de Falsificações

Na seqüência são apresentados alguns indicativos de falta de autenticidade dentro da grafoscopia relacionados a aspectos técnicos genéticos:

- Inícios e paradas abruptas – Estas características estão relacionadas com ataques e remates. Nos casos de falsificações, ocorrem quando o falsificador coloca a ponta da caneta em contato com o papel, e então inicia a escrita. Quando conclui a escrita ou algum trecho, ele interrompe a escrita e retira a caneta, encerrando o contato com o papel. Isto pode causar um início ou término abrupto, enfatizando ou determinando onde a caneta foi colocada em contato com a superfície do papel [JUSTINO, 2002], conforme demonstrado na Figura 4.8(b). Às vezes, este contato é tão prolongado, que acaba deixando no papel um pequeno borrão. Esse borrão será maior quando a caneta possuir uma tinta mais liquefeita ou o papel apresentar maior porosidade. Sendo assim, a assinatura pode apresentar marcas desnecessárias e estranhas, causadas por inícios e paradas de caneta. Normalmente o início e término de uma assinatura são caracterizados por linhas de traçados firmes, apresentando características de velocidade, Figura 4.8(a);




Figura 4.8: Exemplo de assinatura com relação a início e fim abrupto: (a) Assinatura original; (b) Assinatura falsificada.

- Elevação do objeto de escrita – O escritor pode interromper o percurso do traçado para efetuar uma correção na direção. Isto é ocasionado pela elevação da caneta em um ponto na escrita, eliminando temporariamente seu contato com o papel. Esta ação pode levar ao aparecimento de uma pequena descontinuidade no traçado, ou à sobreposição de duas linhas de tinta onde deveria haver uma só linha contínua [JUSTINO, 2002], confira na Figura 4.9 (a) e (b);



Figura 4.9: Exemplo de assinatura relacionada a elevação do objeto de escrita: (a) Assinatura original; (b) Falsificação com elevação do objeto de escrita.

- Tremor – A presença de tremores nos traços pode ser um indicativo de fraude. Usualmente as assinaturas, por se tratarem de desenhos estilizados, contam com a destreza de quem as criou, devido a um processo exaustivo de repetição. Portanto, o traçado apresenta características de firmeza e velocidade. Como a criação de uma assinatura não genuína é pouco mais que um desenho, apresentará, na maioria das vezes, um movimento lento da caneta com traçado trêmulo e inseguro, conforme a Figura 4.10(b);




Figura 4.10: Exemplos de assinaturas sem tremores e com tremores: (a) Assinatura original; (b) Assinatura falsificada com traçado trêmulo.

- Pressão – Esta característica resulta na variação de largura do traçado e na deposição de material de tinta ou grafite em uma dada região do mesmo. Conseqüências da pressão do objeto de escrita sobre o papel [JUSTINO, 2002]. É uma característica pseudodinâmica que geralmente não está presente nos locais em que o traçado é rápido, como ocorre nas assinaturas genuínas mostradas na Figura 4.11(a). Nestes casos a linha de tinta permanece constante em densidade e apresenta como resultado uma pressão constante. No entanto, em locais onde o movimento é lento haverá pequenos afinamentos das linhas, indicando irregularidade de pressão e dando indícios de falta de destreza, usuais nos casos de

falsificações. Tal procedimento pode ser conferido na Figura 4.11(b) em relação à assinatura original na Figura 4.11(a);



Figura 4.11: Exemplos de assinaturas sem pressão e com pressão (a) Assinatura original. (b) Falsificação servil com pontos de pressão.

- Correções – Retração é o processo em que o objeto de escrita repinta uma porção escrita da linha, normalmente na direção oposta. Um exemplo é um movimento descendente seguido por um movimento ascendente em cima da linha já existente. É considerada uma característica do escritor, enquanto representar um comportamento natural da experiência de escrita. Por outro lado, se acontecer como uma forma de conserto, para corrigir a forma de uma letra, pode ser um indicativo de falsificação, conforme Figura 4.12(b).



Figura 4.12: Exemplos de assinaturas sem e com correções (a) Assinatura original. (b) Falsificação servil com pontos corrigidos.

É importante salientar que alguns desses indicadores podem estar presentes em assinaturas genuínas de pessoas em idade avançadas ou enfermas. A mera presença destes indicadores não significa que a assinatura analisada não seja genuína, mas deverá contribuir na determinação global da autenticidade. É de se esperar que a assinatura de uma pessoa em idade avançada apresente traços mais trêmulos e vacilantes. Porém, se a assinatura questionada apresentar uma habilidade superior à esperada, uma possível fraude pode estar presente. Frequentemente, um falsificador, em decorrência de um nível de habilidade alta

inerente da sua escrita, pode produzir uma assinatura contendo menos indicações de falsificações que uma pessoa com um nível mais baixo de habilidade.

4.3.2. Grafologia

É o estudo da escrita visando a determinação da psique do escritor. Existem várias escolas grafológicas. Nesse trabalho são tratadas somente as que possam subsidiar os estudos em verificação de assinaturas. Para tanto, serão comentados somente os movimentos com abordagem científica, ou seja, o movimento clássico que se baseia na mímica e o movimento moderno psicanalítico, que se orienta por símbolos [JUSTINO, 2001].

- Mímica: nesta escola, a grafologia comporta dois estudos, o dos sinais e o das resultantes. Os sinais são tomados no conjunto da escrita, em que se considera a altura, a largura, a inclinação e a regularidade ou nos pormenores das palavras, das letras e dos sinais. Sendo assim, deve-se procurar os sinais de superioridade e de inferioridade, de caráter moral (costumes e sentimentos), vontade, senso estético, idade, sexo e algumas indicações patológicas.
- Simbólica: baseia-se principalmente nos estudos da avaliação e interpretação dos símbolos. Existem, indubitavelmente, relações entre os diversos símbolos grafológicos que compõem o traço individual e o psiquismo do escritor.

Os sinais usados pela escola mímica e simbólica assemelham-se aos utilizados pela grafoscopia, mas as análises das resultantes possuem abordagens diferenciadas. As duas primeiras avaliam a psique do escritor, a fim de estabelecer possíveis patologias. Já a última avalia a veracidade da autoria da escrita, com a finalidade de identificar possíveis fraudes.

São elementos básicos da grafologia:

- Campo gráfico: é o espaço bidimensional em que a escrita é produzida;
- Gesto gráfico ou movimento gráfico: é todo movimento de dedos e/ou da mão que o indivíduo faz para escrever. Cada movimento gráfico gera um traço gráfico;
- Traço: é o trajeto que a caneta descreve em um único gesto executado pelo escritor;
- Traço descendente, fundamental, pleno ou grosso: é todo traço descendente e grosso de uma letra;
- Traço ascendente, ou perfil: é o traço ascendente e fino de uma letra;

- Ovais: são os elementos em forma de círculo das letras ‘a’, ‘o’, ‘g’, ‘q’, etc;
- Hastes: são todos os traços plenos (movimento de descenso) das letras ‘l’, ‘t’, ‘b’, etc e do ‘f’ até a base da zona média. Também são consideradas hastes os traços verticais do ‘m’ e do ‘n’ maiúsculo e minúsculo;
- Lançadas inferiores: são todos os planos (descendentes) do ‘g’, ‘j’, ‘y’, etc e do ‘f’ a partir da zona média até embaixo;
- Bucles: são todos os traços ascendentes (perfis) das hastes e das lançadas inferiores e, por extensão, todo movimento que ascende cruzando a haste e unindo-se a ela formando círculo;
- Partes essenciais: é o esqueleto da letra, a parte indispensável da sua estrutura;
- Parte secundária ou acessória: é o revestimento da letra, ornamental ou não, necessária à sua configuração.

Nas letras, é preciso distinguir também as diferentes zonas:

- Zona inicial, área onde se encontra o ponto que inicia a letra;
- Zona final, área onde se encontra o ponto que termina a letra;
- Zona superior, área onde se encontra o ponto mais alto, ocupado pelas hastes, pelos acentos, pelas barras do ‘t’ e parte das maiúsculas;
- Zona média, área central, ocupada por todas as vogais minúsculas e pelas letras ‘m’, ‘n’, ‘r’ etc. cuja altura torna-se base para medir o nível da elevação das hastes e o nível do descenso das lançadas inferiores;
- Zona inferior, zona baixa da escrita a partir da base de todos os ovais descendentes das maiúsculas ou de outras letras.

O uso individual ou em conjunto destes elementos da grafologia está presente em algumas características encontradas tanto na escola mímica quanto na simbólica e que estão relacionadas ao contexto de assinaturas, sendo descritas a seguir.

4.3.2.1. Aspectos Gráficos

São fundamentais para a abordagem proposta e estão relacionadas com a escrita vista como grafia psicomotriz, ou seja, medindo-se o nível de tensão, rapidez, profundidade, irradiação (altura-extensão), relevo, estética, coesão, regularidade, inclinação, direção das

linhas, progressão e proporção. Quase todos esses aspectos do grafismo são mensuráveis, isto é, podem ser avaliados grafometricamente a partir de um modelo ou padrão. Tudo que exceda ou fique abaixo deste modelo é sintomático [JUSTINO, 2001].

4.3.2.2. Ordem

A distribuição dos elementos gráficos pode ser classificada em: clara, boa separação indicando uma uniformidade na distribuição de letras e palavras, conforme Figura 4.13(a); confusa, em que o texto aparece como uma massa não uniforme e embaralhada, conforme Figura 4.13(b); concentrada, em que na visão do conjunto prepondera o texto sobre os espaços em branco, Figura 4.13(c) e espaçada, em que na visão do conjunto preponderam os espaços em branco Figura 4.13(d);



Figura 4.13: Exemplos de assinaturas sob o ponto de vista da ordem, podendo ser uma assinatura: (a) clara; (b) confusa; (c) concentrada; (d) espaçada.

4.3.2.3. Proporção

Está relacionada à simetria da escrita, normalmente notada em assinaturas cursivas, podendo ser de três tipos: proporcional, é a assinatura em que as letras e as partes constitutivas da mesma apresentam pequenas desigualdades rítmicas, conforme Figura 4.14(a); desproporcional, é a assinatura onde as letras ou partes de letras apresentam desequilíbrio e translações mais ou menos exageradas, conforme Figura 4.14(b); mista, em que nota-se a existência simultânea da proporcionalidade e desproporcionalidade, afetando as letras maiúsculas, veja Figura 4.14(c).


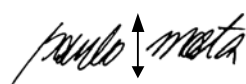


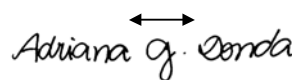
Figura 4.14: Exemplos de assinaturas com relação à simetria: (a) Assinatura proporcional; (b) Assinatura desproporcional; (c) Assinatura mista.

4.3.2.4. Dimensão

A dimensão traduz o grau de expansividade do escritor, podendo ser resumida em duas classes: a escrita alta, onde o corpo da escrita (zona média) ultrapassa as proporções em relação às hastes e as lançadas inferiores conforme Figura 4.15(a); a escrita baixa, em que o corpo da escrita, em proporção às letras, é mais larga do que alta conforme Figura 4.15(b).



(a)



(b)

Figura 4.15: Exemplos de assinaturas com relação a dimensão: (a) Assinatura alta; (b) Assinatura baixa.

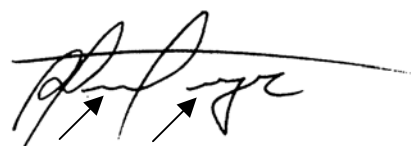
4.3.2.5. Pressão

A força ou intensidade do traço, por sua característica dinâmica, está em estreita relação com a rapidez, com a continuidade e com a irradiação do impulso gráfico. A pressão pode ser expressa por duas características: a escrita tensa, em que os movimentos gráficos são retos, firmes e seguros, conforme Figura 4.16(a); a escrita frouxa, onde existe um déficit de tensão nos movimentos, os quais são mais ou menos sinuosos, ondulados ou torcidos em qualquer direção, conforme Figura 4.16(b).

Um outro parâmetro mensurável, em relação à pressão, é a força da impressão do traço. Pode ser dividido em dois: o peso real, que é a soma da espessura do traço, a força e profundidade; o peso aparente, em que só é considerada a espessura do traço.



(a)



(b)

Figura 4.16: Exemplos de assinaturas com relação a pressão: (a) Assinatura tensa; (b) Assinatura frouxa.

4.3.2.6. Forma

Quanto à forma, existem três tipos identificáveis de escritas: a caligráfica, em que modelo caligráfico escolar é predominante, conforme Figura 4.17(a); a arredondada, em que os elementos curvos são preponderantes, Figura 4.17(b); a reta vertical, em que predominam os segmentos retos verticais ou levemente inclinados, Figura 4.17(c), a reta horizontal, quando predominam os segmentos em linha reta horizontal, conforme Figura 4.17(d).



Figura 4.17: Exemplos de assinaturas sob o ponto de vista da forma: (a) Assinatura caligráfica; (b) Assinatura arredondada; (c) Assinatura reta vertical; (d) Assinatura reta horizontal.

4.3.2.7. Gesto característico

Existem em cada indivíduo gestos que se repetem a cada instante, espécies de tique ou atitude que o caracteriza. Na escrita também existem modalidades de traços ou letras que chamam a atenção, porque imprimem ao traçado uma fisionomia especial que nenhum outro poderia reproduzir da mesma maneira. Os elementos gráficos que podem formar o gesto característico em assinaturas são: **gancho** - consiste no movimento de regressão encontrado nos finais das letras ou nas barras dos 't' conforme Figura 4.18(a); **clave** - carrega todo o golpe de energia sobre a zona final do traçado que fica em forma de ponta quebrada, confira na Figura 4.18(b); **golpe de sabre** - é o movimento promovido por um impulso da caneta, que pode afetar as barras dos 't' e as partes inferiores das letras (lançadas inferiores), confira na Figura 4.18(c1); **inflação** - que apresenta um tamanho exagerado, presente nas maiúsculas, Figura 4.18(c2); **espiral** - que está presente nas letras maiúsculas, conforme Figura 4.18(d); **laço** - que é uma espécie de movimento de retorno ao ponto de partida, confira na Figura

4.18(e1); **movimento em triângulo** - produzido principalmente nas lançadas inferiores dos 't', 'g', 'y' e nas barras dos 't', pode também aparecer na circunferência das letras da zona média, conforme Figura 4.18(e2); **bucle** - que se apresenta na circunferência das letras da zona média, nas maiúsculas e nas ligações, conforme Figura 4.18(f); **arco** - é encontrado preferencialmente nas zonas inicial, superior e média (nas ligações), visto na Figura 4.18(g); **guirlanda** - consiste num movimento em forma de arco aberto para cima, presente nos traços iniciais e finais e nas barras dos 't', conforme Figura 4.18(h1); **serpentina** - que afeta os traços iniciais e finais e as letras 'm' e 'n', conforme Figura 4.18(h2).




Figura 4.18: Exemplos de assinaturas do ponto de vista de gestos característicos: (a) Gancho; (b) Clava; (c) Golpe de sabre e inflada; (d) Espiral; (e) Movimento em triângulo e laço; (f) Bucle; (g) Arco; (h) guirlanda e serpentina.

É importante salientar o que foi dito anteriormente: a grafologia oferece um conjunto de características que avaliam os aspectos psicológicos de um escritor, usando como ferramenta a escrita.

4.3.3. Considerações sobre o Grafismo

Foram apresentadas nos itens anteriores, as várias formas de abordagens usadas no estudo do grafismo e as peculiaridades de cada uma delas, em particular as duas de maior importância para o estudo da assinatura manuscrita, a grafoscopia e a grafologia.

No caso da grafologia, a contribuição encontra-se no conjunto de características que determinam os aspectos psíquicos do autor, usados nesse caso como atributos que diferenciam

um autor do outro. O comportamento psicológico reflete-se nas características de sua escrita, e nesse caso essas características podem ser utilizadas como elementos discriminantes entre vários autores.

Já a grafoscopia, por tratar da autenticidade de documentos questionados, no qual se enquadram as assinaturas manuscritas, apresenta subsídios valiosos para a extração de características.

Projetar bons extratores de características para sistemas verificadores de assinaturas, ainda é um grande obstáculo, dada a complexidade do problema. A escolha de características significativas é em uma etapa essencial na elaboração de um método de verificação, e a representação computacional destas características afeta diretamente os resultados obtidos, pois a robustez do método é proporcional à qualidade das mesmas. A Tabela 4.1 apresenta uma relação entre a grafologia e grafoscopia, permitindo determinar um conjunto de características a serem adotadas pelo método de verificação automática proposto.

Tabela 4.1: Características combinadas da grafologia e da grafoscopia e as primitivas implementadas.

| Grafoscopia (genéticos / genéricos) | Grafologia (mímica / simbólica) | Primitiva Usada |
|--|--|---|
| Calibre | Altura / largura / dimensão | Densidade de <i>pixels</i> Centro de Gravidade |
| Proporcionalidade | Regularidade / proporção | |
| Espaçamento | - | |
| Comportamento Base | - | |
| Pressão | Pressão Real | Pontos de Pressão |
| Ataque / Remate | Gestos Característicos | Início e Fim Abrupto |
| Progressão | Pressão Aparente | Segmentos de Tremor |
| Inclinação Axial | Inclinação | Inclinação Axial |
| Valores Angulares e Curvilíneos | - | Curvatura |
| - | Ocupação do Espaço gráfico | - |
| Mínimos Gráficos | - | - |
| Comportamento Pauta | - | - |

Levando-se em consideração as restrições impostas pela aplicação e as limitações da base de dados do laboratório, pelo fato das amostras terem sido adquiridas em fundo branco e em tamanho fixo, algumas destas características não se aplicam ao problema proposto:

- Comportamento pauta – Essa primitiva está ligada diretamente à presença das linhas de base. Como nesse trabalho foram usadas imagens desprovidas dessa informação, ela será deliberadamente excluída do conjunto das primitivas tratadas;

- Mínimos gráficos – Por possuírem dimensões normalmente reduzidas, podem ser eliminados ou mesmo modificados durante o processo de digitalização ou pré-tratamento, resultando em instabilidade;
- Ocupação do espaço gráfico – Pela utilização da base de dados na qual as imagens possuem tamanho fixo, e o espaço destinado à assinatura é relativamente pequeno, o uso da ocupação do espaço gráfico está restrito à área em torno da assinatura. Com o uso da segmentação em células esse mapeamento é suprido.

Com base na Tabela 4.1, intrinsecamente as características estáticas se referem à forma como comprimento e altura e representam o comportamento estático da escrita, podendo serem representadas pela Densidade de *Pixels* e pelo Centro de Gravidade, e incorporam várias características da grafoscopia e grafologia. Já as características pseudodinâmicas como progressão, pressão e inclinação axial representam o comportamento dinâmico da escrita e portanto, estão relacionadas diretamente com os traços da assinatura. As características desta categoria usadas no presente trabalho são: pontos de pressão, início e fim abrupto, tremor, curvatura e inclinação axial.

4.4. Medidas de Distância

Em problemas de classificação, há uma dependência significativa das medidas de distância. As medidas de distância possuem propriedades invariantes, podendo também integrar características heterogêneas [CHA, 2001]. Existem dois pontos cruciais no desenvolvimento de um sistema automático de verificação de assinaturas computadorizado. O primeiro é alcançar uma representação que pode maximizar a distância entre assinaturas de indivíduos diferentes. O outro seria que assinaturas da mesma pessoa se mantenham constante uma vez que uma medida de distância seja definida corretamente [QI & HUNT, 1994].

Duas premissas são importantes no método proposto. Uma é selecionar características importantes da imagem e outra é selecionar uma apropriada medida de distância, cuja escolha envolve sempre uma subjetividade das características das variáveis e das escalas usadas para a medição. Dentre as diversas medidas utilizadas para determinar a distância entre elementos de

uma matriz de dados, as abordadas para o trabalho são: Euclidiana, Manhattan, 'city block' ou bloco-cidade e Euclidiana Quadrática.

De acordo com Novaes [NOVAES, 2002] a distância bloco-cidade se aproxima da distância euclidiana quando apenas um atributo diferencia dois objetos. Quando mais de um atributo for usado, a distância bloco-cidade tende a separar mais os objetos. Um exemplo hipotético utilizando um atributo nas três medidas de distâncias é mostrado na Figura 4.19.

O ato de classificar um padrão pode ser considerado como sendo uma tarefa de definição de pertinência, em que devemos associar um novo elemento a um dos conjuntos (classes) existentes, o que faz com que sua representação no espaço de características assuma a forma de agrupamento de pontos. Este aspecto de proximidade entre os elementos de um conjunto pode ser utilizado como parâmetro para a classificação de padrões. A definição de funções que sejam capazes de indicar uma medida de semelhança ou distância entre dois padrões constitui um meio de formalizar o processo de classificação.

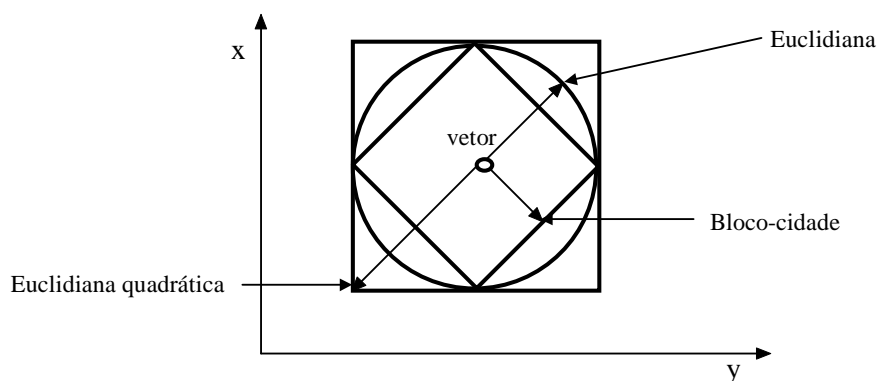


Figura 4.19: Precisão nas métricas de distância euclidiana, euclidiana quadrática e bloco-cidade.

4.4.1. Distância Euclidiana

É a função de distância mais intuitiva, sendo derivada do cálculo da distância geométrica entre dois pontos. A distância euclidiana é adequada para o tratamento de classes cujos elementos tendem a se agrupar próximos à média, ou seja, possuem variância desprezível. Problemas em que as classes apresentam comportamento semelhante, quanto à forma da função de distribuição de probabilidades e valores de variância também são indicados para o uso da distância euclidiana.

A distância euclidiana entre duas amostras x_i e x_j é a raiz quadrada do somatório dos quadrados das diferenças entre os valores de x_i e x_j para todas as variáveis, ou seja, para $k = 1, \dots, P$ [BARBEAU et al., 2002]:

$$d_{ij} = \sqrt{\sum_{k=1}^P (x_{ik} - x_{jk})^2} \quad (4.1)$$

4.4.2. Distância Euclidiana Quadrática

A distância entre duas amostras x_i e x_j é o somatório dos quadrados das diferenças entre os valores de x_i e x_j para todas as variáveis, ou seja, para $k = 1, \dots, P$ [BARBEAU et al., 2002]:

$$d_{ij}^2 = \sum_{k=1}^P (x_{ik} - x_{jk})^2 \quad (4.2)$$

4.4.3. Distância de Manhattan ‘Bloco-Cidade’

A distância de Manhattan se aproxima da distância euclidiana quando apenas um atributo diferencia dois objetos [NOVAES, 2002]. Pode-se dizer que ela é uma versão simplificada da distância euclidiana.

A distância entre duas amostras x_i e x_j é o módulo das diferenças entre os valores de x_i e x_j para todas as variáveis, ou seja, para $k = 1, \dots, P$ [BARBEAU et al., 2002]:

$$d_{ij} = \sum_{k=1}^P |x_{ik} - x_{jk}| \quad (4.3)$$

4.5. Dicotomia

A identificação da autoria da escrita, mais especificamente de assinaturas, tem grande utilização no sistema judiciário. Uma das fundamentações básicas na identificação da escrita é

que cada indivíduo possui uma escrita consistente e distinguível de outro indivíduo [CHA, 2001]. Desta forma, a individualidade da assinatura se encaixa neste contexto.

Para a identificação da autoria de escrita ou assinaturas, é necessário determinar a validade estatística da individualidade do autor, baseando-se no desempenho das características através da verificação, quantificação e análise estatística.

Considerando o problema de muitas classes, em que o número elevado de classes está relacionado à maioria dos métodos de identificação de padrões associados à verificação de assinaturas. Nota-se que os sistemas de verificação de assinaturas são frequentemente desenvolvidos usando um número de classes pequeno e finito, tirado de um universo maior de classes. Entretanto, de acordo com Cha [CHA, 2001] o agrupamento no subconjunto de classes não provê a validade da individualidade da escrita. Sem a validade da individualidade a dedução estatística é questionável devido ao resultado deste modelo não poder ser deduzido para a população inteira. Como o objetivo da abordagem proposta é a verificação de assinaturas através de um método com o uso mínimo de amostras por autor, a comparação da dedução estatística baseado no universo populacional não será aprofundada, simplesmente é mencionada a dificuldade de se estabelecer um modelo por classe quando o problema envolve toda a população. Por esta razão, é proposto um método dicotômico para estabelecer a distinção inerente de classes, diferindo dos métodos conhecidos como policotômicos.

No método dicotômico utiliza-se um classificador que coloca um padrão em uma de somente duas categorias para estabelecer a individualidade. O problema é modelado por duas classes: autoria ou não-autoria. Dadas duas amostras, a distância entre as características de dois documentos é computada e classificada como positiva (autoria) ou negativa (não-autoria). Simbolicamente, as variáveis de distância entre características de amostras do mesmo autor e as variáveis de distância entre características de amostras de autores diferentes podem ser representadas pela notação (+) e (-) respectivamente.

Uma vantagem do método dicotômico é a múltipla integração de tipos de características, as quais podem ter diversas origens. Vários tipos de características são mostrados na Figura 4.20, as quais podem ser integradas utilizando medidas de distâncias de acordo com Cha [CHA, 2001]. Na abordagem proposta somente características elementares são abordadas.

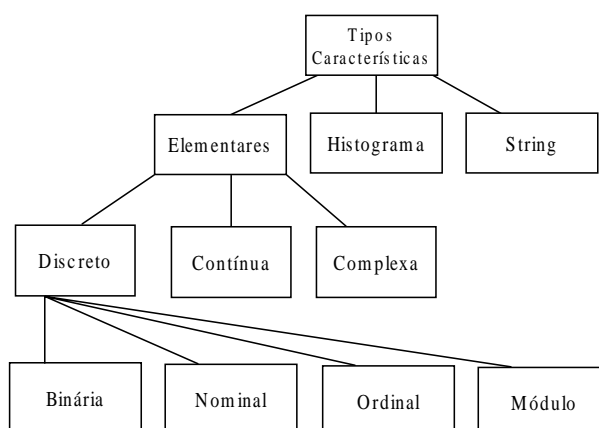


Figura 4.20: Hierarquia de tipos de características de acordo com Cha [CHA, 2001].

No domínio da distância das características (método dicotômico), todos os tipos de distâncias de características tornam-se valores escalares independente do tipo de característica. Em outras palavras, múltiplos tipos de características são integrados em valores escalares de distâncias de características para resolver o problema.

De acordo com Cha [CHA, 2001] é enigmático distinguir cada autor pelo número de classes, este universo é muito grande ou não-especificado em problemas de classificação. Para estabelecer a inerente distinção de classes, isto é, a validação da individualidade, o problema de muitas classes é tratado em uma dicotomia. Neste método usa-se a distância entre duas amostras da mesma classe e de duas classes diferentes, não havendo a necessidade de se observar todas as classes dentro do escopo.

4.5.1. Transformação Dicotômica

Em um problema de classificação de uma categoria representando toda a população, também chamado policotomizador, há m exemplares de assinaturas de cada n pessoas (n muito grande). Dado um exemplar de assinatura, x , de um autor desconhecido pertencente ao universo de n autores, a tarefa é determinar se x foi escrito por este autor. Como o número de classes é muito grande, este problema é aparentemente insuperável. O método dicotômico é proposto para resolver este problema, conforme a Figura 4.21.




Figura 4.21: Transformação de: (a) Domínio das características (policotomia) para (b) Domínio das distâncias das características (dicotomia).

O processo é demonstrado para três autores, $\{w_1, w_2, w_3\}$. Cada autor provê três assinaturas e três valores escalares de características são extraídas por assinatura. A Figura 4.21(a) mostra as assinaturas no gráfico para cada escritor.

Para transformar em espaço da distância, o processo é aplicado no vetor de distância de cada característica de assinaturas do mesmo autor e o mesmo é denotado por $x_{(+)}$. A amostra da distância entre autores é, em contrapartida, obtida medindo a distância das características entre duas assinaturas de autores diferentes, sendo representada por $x_{(-)}$ d_{ij} representa os i' autores de j' assinaturas.

$$\bar{x}_{(+)} = \bar{\delta}(d_{ij} - d_{ik}) \text{ onde } i = 1 \text{ até } n, j, k = 1 \text{ até } m \text{ e } j \neq k \quad (4.4)$$

$$\bar{x}_{(-)} = \bar{\delta}(d_{ij} - d_{kl}) \text{ onde } i, k = 1 \text{ até } n, i \neq k \text{ e } j, l = 1 \text{ até } m \quad (4.5)$$

onde n é o número de autores, m é o número de assinaturas por autor, δ é a medida de distância entre valores de características de duas assinaturas. A Figura 4.21(b) representa a transformação do espaço das características para o espaço das distâncias das características. Uma distância entre características do mesmo autor, W e uma distância entre características de autores diferentes, B , no domínio da característica na Figura 4.21(a), correspondem aos pontos W e B no domínio da distância das características na Figura 4.21(b), respectivamente. Desta forma, há somente duas categorias: distância entre características de duas assinaturas do mesmo autor e distância entre características de duas assinaturas de autores diferentes no domínio da distância da característica.

Seja $n_{(+)} = |x_{(+)}|$ e $n_{(-)} = |x_{(-)}|$ o tamanho da distância das classes dos mesmos autores e autores diferentes. Se n pessoas provem m assinaturas:

$$n_{(+)} = n \cdot C_2^m \quad (4.6)$$

representa o total de amostras positivas, e as amostras negativas é representada por:

$$n_{(-)} = m^2 \cdot C_2^n \quad (4.7)$$

já o total geral de amostras é calculado por:

$$n_{(+)} + n_{(-)} = C_2^{m \cdot n} \quad (4.8)$$

Uma maneira de representar figurativamente múltiplas características é plotar os valores das distâncias de cada característica em um vetor de distâncias multidimensional. A Figura 4.22 ilustra os valores de distâncias no espaço 3D $\{\text{dist}(b), \text{dist}(c), \text{dist}(e)\}$ figurativamente. Similarmente ao espaço unidimensional, a distância intraclasse tende em direção à origem enquanto a distância entre classes tende a se distanciar da origem.




Figura 4.22: Distribuição das distâncias das características no espaço 3D.

Utilizando o fato que a distância intraclasse é menor, o dicotomizador determina o limite de decisão intraclasse e entre classes. Uma boa maneira de representar a relação entre duas classes é calculando a curva entre duas distribuições, que descreve o comportamento de duas populações figurativamente sem perda de generalidade. O erro *Tipo I*, α ocorre quando o mesmo autor da assinatura é identificado como autor diferente e o erro *Tipo II*, β ocorre quando duas assinaturas de autores diferentes são identificados como mesmo autor como mostra a Figura 4.23.

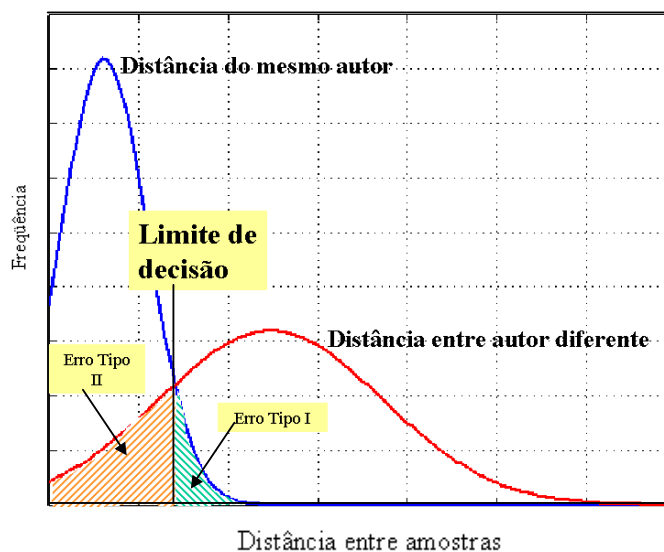


Figura 4.23: Distribuição do erro *Tipo I* e *Tipo II*.

Sendo o limite de decisão representado por T , α e β são calculados por:

$$\alpha = Pr(\text{dicotomizador}(d_{ij}, d_{kl}) \geq T \mid i = k) \quad (4.9)$$

$$\beta = Pr(\text{dicotomizador}(d_{ij}, d_{kl}) < T \mid i \neq k) \quad (4.10)$$

4.5.2. Comparando Policotomia e Dicotomia

Um inconveniente da abordagem dicotômica é que ela pode fracassar para detectar diferenças entre w_1 e w_2 as quais não diferem grandemente no domínio das distâncias, embora sejam diferentes geometricamente no espaço de características [CHA, 2001], conforme Figura 4.24.




Figura 4.24: Comparação entre (a) Domínio das características (policotomia) e (b) Domínio das distâncias das características (dicotomia) [CHA, 2001].

Para um melhor aproveitamento do método seria desejável que todas as distâncias entre elementos da mesma classe (autor) no domínio da característica pertencessem também à mesma classe, no domínio da distância da característica. Similarmente, o ideal seria que todas as distâncias entre duas classes diferentes no domínio da característica, pertencessem a classes diferentes no domínio da distância entre características. Infelizmente, isto nem sempre ocorre; classes perfeitamente agrupadas no domínio da característica podem não ser perfeitamente representadas pela dicotomia no domínio da distância [CHA, 2001]. A comparação na abordagem dicotômica é relativa para uma população e é crucialmente afetada pela escolha e diversidade da população. O objetivo inicial deste trabalho é validar a individualidade de assinaturas estatisticamente, não detectar as diferenças particulares de instâncias distintas.

Na abordagem dicotômica pode-se utilizar uma quantia ilimitada de amostras de cada classe, desde que estas novas amostras também sejam mapeadas dentre duas possíveis classes, em que a distribuição das amostras pode ser usada para a dedução da distribuição da população inteira, neste caso semelhante à abordagem policotômica.

Para Cha [CHA, 2001], o qual aborda a individualidade da escrita e a dedução estatística, o modelo dicotômico representa uma melhor dedução estatística do que o modelo policotômico. Cha [CHA, 2001] afirma que o modelo policotômico não é capaz de deduzir estes resultados para a população toda, pelo fato de existirem classes invisíveis.

Uma relação pode ser estabelecida entre aplicação e precisão. Quando há uma quantidade grande de amostras de cada indivíduo é difícil a sua aplicação. Desta forma, pode-se desejar transformar o domínio das características no domínio das distâncias das características, em que se obtêm grandes amostras para ambas as classes, tornando o problema tratável por uma dedução estatística. Os resultados porém nem sempre serão satisfatórios, de acordo com Cha [CHA, 2001].

Quando há um pequeno número de classes, em que se pode ter cada amostra de cada classe, o método policotômico pode ser usado para validar a individualidade das classes. Entretanto, nada impede de se utilizar o dicotomizador mesmo em problemas com poucas classes.

A abordagem proposta apresenta grandes diferenças do modelo individual policotômico. Nos modelos policotômicos um número de amostras genuínas de um autor em específico é capaz de representar a variação pessoal da classe w_1 , sendo capaz de discriminar outros autores e todos os tipos de falsificações, gerando um modelo pessoal robusto, conforme Figura 1.4.

4.5.3. Resumo da Abordagem Dicotômica

Na abordagem dicotômica [CHA, 2001], dada duas imagens de documentos aleatórios, o problema de verificação é determinar se as dois documentos foram escritos pela mesma pessoa com dois tipos de probabilidades de erros de confusão. A Figura 4.25 descreve o processo de transformação dicotômica, onde fv_i^j é a i -ésima característica de j -ésimo documentos do vetor de características fv , e fv_d o último vetor de característica do documento.

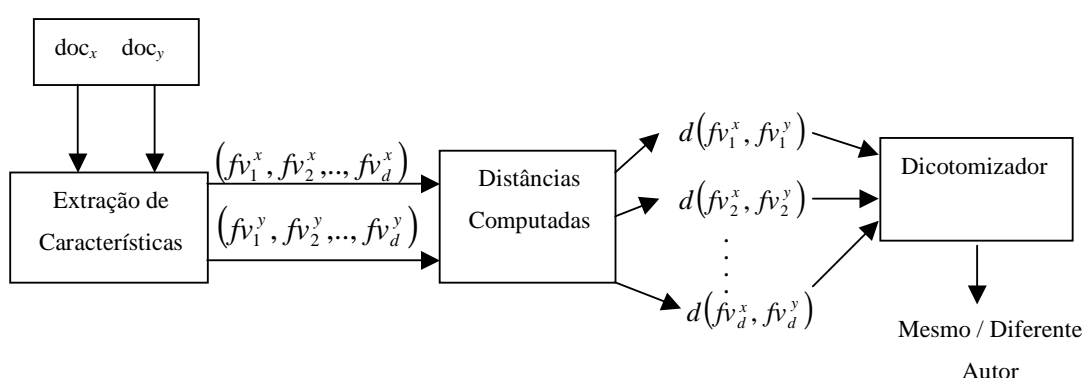


Figura 4.25: Processo de Verificação e transformação dicotômica baseada em [CHA, 2001].

Primeiro, as características são extraídas de ambas as imagens doc_x e doc_y :

$(fv_1^x, fv_2^x, \dots, fv_d^x)$ e $(fv_1^y, fv_2^y, \dots, fv_d^y)$. Então cada distância de característica é computada:

$\{d(fv_1^x, fv_1^y), \dots, d(fv_d^x, fv_d^y)\}$. O dicotomizador recebe o vetor das distâncias destas características como entrada. Após, o modelo é treinado e a saída representa a autoria.

4.6. Comentários Finais

A metodologia proposta apresentada neste capítulo relacionada ao problema de verificação de assinaturas é detalhada em pontos essenciais necessários para a abordagem como: o grafismo, englobando tanto a grafoscopia quanto a grafologia, o uso das medidas de distâncias e a dicotomia que representam os pilares do método proposto. No próximo capítulo é apresentado a visão do perito na análise de assinaturas questionadas, assim como as etapas que envolvem o método proposto.

Capítulo 5

5. Método Proposto

Neste capítulo é detalhado o método proposto para a verificação de assinaturas. É apresentado a visão do perito grafotécnico aplicada análise de assinaturas questionadas em comparação com um modelo computacional, assim como as fases que compõe o processo de verificação de assinaturas.

5.1. Visão do Perito na Análise de Assinaturas Questionadas

As técnicas forenses convencionais utilizadas na análise de documentos questionados por peritos grafotécnicos, mais especificamente em assinaturas, são de suma importância na elaboração de uma abordagem automática nesta área, conforme visto na seção 4.3. Com base neste estudo, procura-se montar uma estrutura que utilize todos os recursos da grafoscopia, procurando também simular a visão que o perito tem no processo de análise de um documento questionado, dentro de um método computacional. Para este propósito, somente duas classes do modelo são usadas pelos peritos, as que classificam uma assinatura em genuína w_1 ou não genuína w_2 , esta última representada pelos diversos tipos de falsificações (simples, simulada e aleatória), confira a Figura 5.1.

A idéia é baseada em um processo de comparação, em que o perito, de posse de algumas amostras genuínas do autor analisado, compara com a amostra questionada tendo como base características grafotécnicas. O processo de decisão é baseado em uma métrica de similaridade da amostra questionada em relação a todas as amostras genuínas.

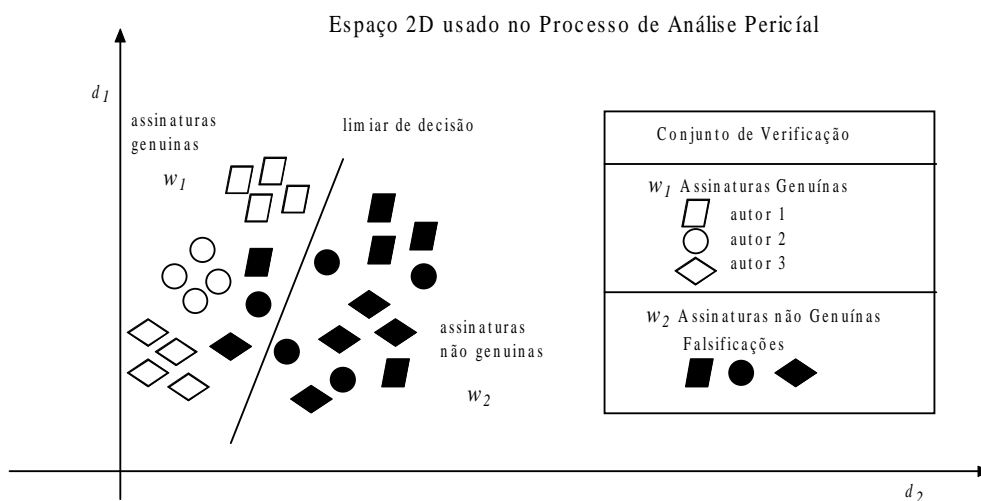


Figura 5.1: Modelo geral usado na perícia grafotécnica de verificação de autenticidade de assinaturas.

Com base no modelo da visão pericial, um modelo computacional pode ser estruturado. Matematicamente, o perito de posse de um conjunto de m assinaturas genuínas S_{ki} ($i=1,2,3,\dots,m$) usa as mesmas em comparação com uma assinatura questionada S_Q . O perito observa a medida de diferença D_i ($i=1,2,3,\dots,m$), entre as F características grafométricas do conjunto de assinaturas genuínas, $f_{V_{ki,j}(i=1,2,3,\dots,m)(j=1,2,3,\dots,F)}$ e características da assinatura questionada, $f_{V_{Qj}(j=1,2,3,\dots,F)}$. Após este procedimento toma a decisão R_i ($i=1,2,3,\dots,m$). O relatório final de decisão D depende da soma das decisões parciais, obtido através destas comparações, conforme a Figura 5.2.

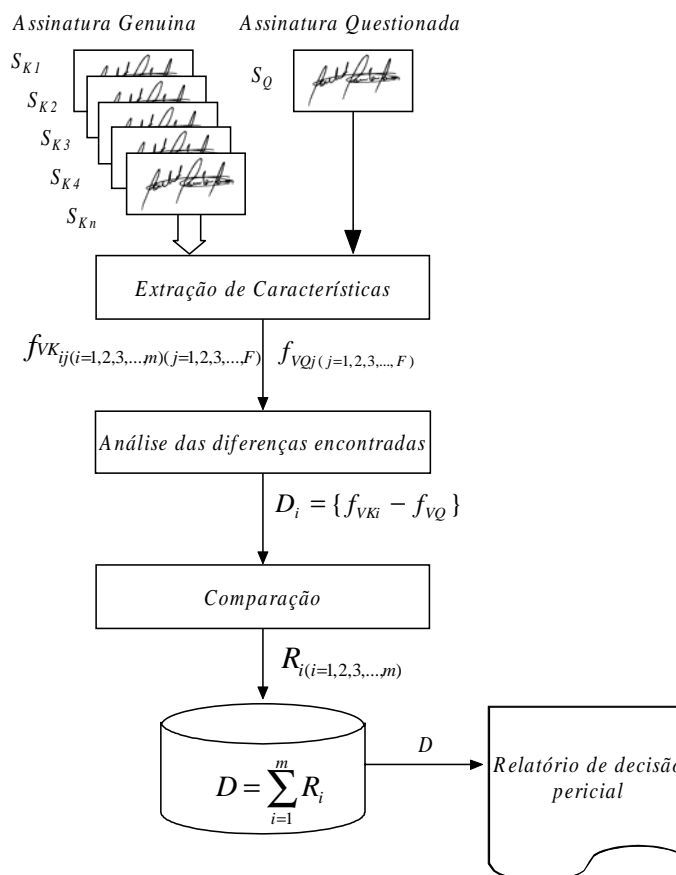


Figura 5.2: Esquema do processo de decisão na verificação de assinaturas *off-line* baseado na visão pericial.

O procedimento utilizado pelos peritos propicia o desenvolvimento de uma nova abordagem que incorpora as características da grafoscopia, dicotomia e medidas de distâncias. Cha [CHA, 2001] propôs um método para estabelecer a autoria da escrita, usando medidas de distâncias das características extraídas em um processo de dicotomização, o qual é a base para se produzir um método que discrimine assinaturas genuínas e falsificações. As etapas deste processo estão descritas na seção seguinte.

5.2. Etapas no Processo de Verificação de Assinaturas

Um sistema de verificação automática de assinaturas requer cuidados adicionais associados com algumas etapas, conforme a Figura 5.3(b) demonstra, em comparação com a análise pericial, Figura 5.3(a).

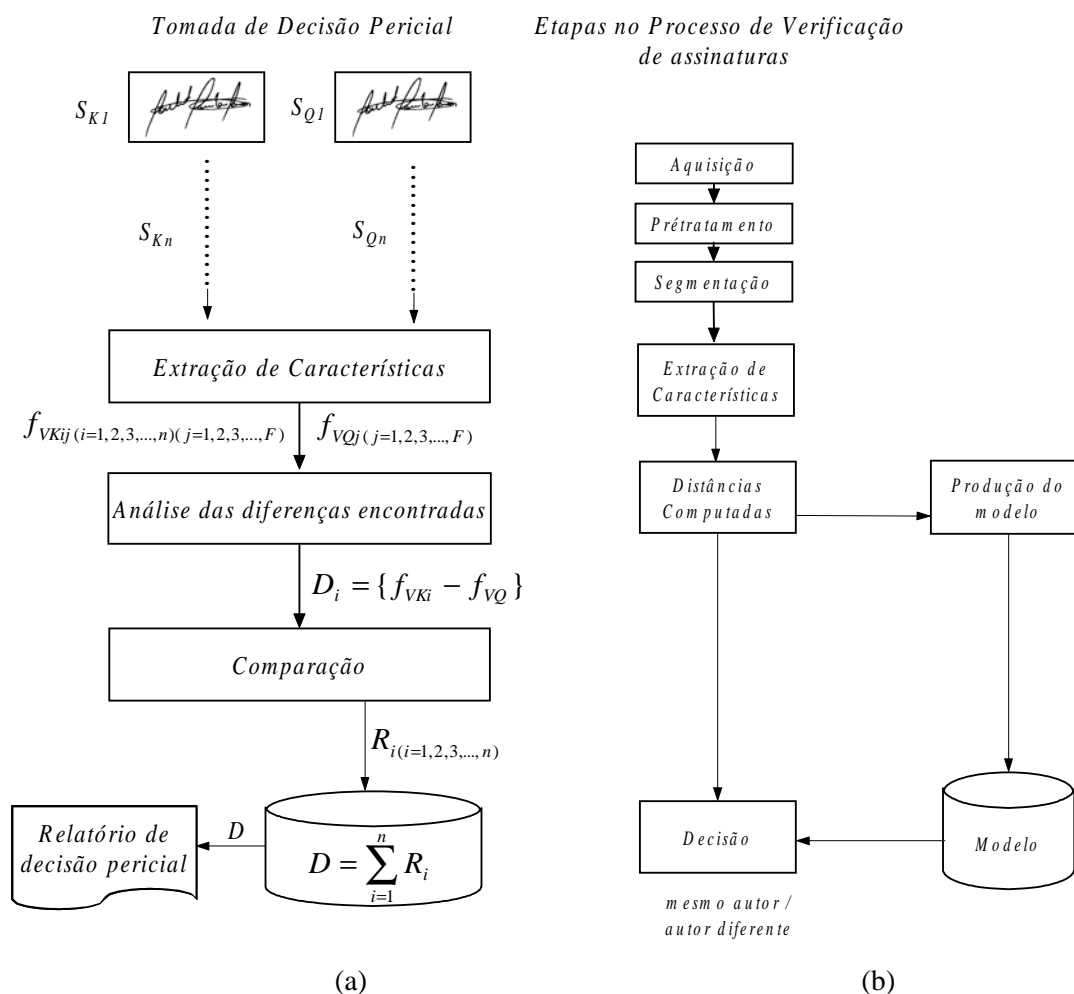


Figura 5.3: Um comparativo nas etapas no processo de verificação de assinaturas: (a) processo de análise e decisão pericial; (b) processo computacional proposto.

Na maioria das abordagens relacionadas a problemas de classificação de manuscritos, em específico na verificação de assinaturas, algumas etapas são essenciais e devem fazer parte do processo como um todo:

- **Aquisição dos dados**, a imagem da assinatura é produzida através de um scanner, e a assinatura aparece como uma imagem;
- **Pré-processamento**, preparação para extração de características através de alinhamento da imagem, limiarização e esqueletização;
- **Segmentação**, particionamento da imagem em células, através de um *grid*, para tratamento do traçado a nível local.
- **Extração de características (primitivas)**, nesta etapa são selecionadas as propriedades mais relevantes que representam a assinatura;
- **Distâncias entre característica**, diferença entre os vetores de características extraídas, usadas na entrada da produção do modelo e no processo de decisão.
- **Produção de um modelo**, um conjunto de referência de assinaturas é gerado para se realizar o processo comparativo;
- **Processo de decisão**, é avaliada a saída do modelo produzido, verificando se a assinatura pertence à mesma classe ou à classes diferentes.

A seguir cada uma das etapas é detalhada, demonstrando os aspectos genéricos e as particularidades encontradas em termos do método verificação de assinaturas proposto.

5.2.1. Aquisição e Pré-processamento

Pelo fato da maioria das imagens já terem sido coletadas, adquiridas, tratadas e estarem armazenadas no LARD (Laboratório Análise e Reconhecimento de Documentos) do PPGIA (Programa de Pós-Graduação de Informática Aplicada da PUC-PR), o processo de aquisição resume-se à coleta de 560 imagens adicionais, adquiridas conforme os moldes do trabalho de Justino [JUSTINO, 2001].

5.2.1.1. Base de dados

Um dos fatores importantes para avaliar o desempenho de um método para a verificação de assinaturas é a análise da composição da base de dados usada para validar os procedimentos de aprendizado e testes. Ela deve conter um número mínimo de autores que

permita a validação estatística. Outro fator relevante é o número de espécimes por autor a ser utilizado, que deve representar satisfatoriamente as variações de cada autor.

Na base do LARD, as imagens já estão recortadas em tamanho fixo de (3 x 10 cm), com 256 níveis de cinza em papel com fundo branco e densidade de 300 dpi, sem interferências de ruídos ou imagens pré-impressas. Possuindo inicialmente um total de 5200 imagens de assinaturas de 100 autores, em que cada autor cede 40 assinaturas originais e os 60 primeiros, 10 falsificações simples e 10 simuladas. Com a aquisição de 140 autores à base, cada um provendo 4 assinaturas genuínas, um total de 5760 imagens de assinaturas fazem parte da base de dados atualmente.

Um problema encontrado na confecção da base de dados, é a dificuldade de se coletar um número grande de amostras de assinaturas autênticas da mesma pessoa. Segundo Fang [FANG et al., 2003] uma razão seria devido à natureza confidencial de assinaturas pessoais. Outra razão é a variação dos padrões de assinaturas manuscritas no decorrer do tempo [KHOLMATOV, 2003].

De acordo com Fang [FANG et al., 2003] para se obter uma estimativa real das variações, as assinaturas deveriam ser coletadas em um número de sessões programadas sobre um longo período. Entretanto, isto é inviável. Conseqüentemente, o número de amostras de treinamento de um escritor é freqüentemente insuficiente. Na abordagem proposta este problema não se torna tão relevante devido à necessidade de um único treinamento. Desta forma assinaturas coletadas em períodos regulares ou irregulares tendem a possuir distâncias semelhantes de suas características iniciais, se comparadas com assinaturas da mesma época da coleta, fazendo com que as mesmas sempre se enquadrem na classe das genuínas.

O protocolo de divisão da base de dados que será apresentado nos resultados do capítulo 6 é baseado em Cha [CHA, 2001] como visto na secção 4.5. Nesta abordagem, as amostras passam a ser representadas pelas distâncias computadas entre características de duas assinaturas e, não mais as características extraídas de cada assinatura. Desta forma, ocorre uma combinação entre as distâncias de características das assinaturas com o objetivo de obter um número maior de amostras intra e interclasse.

5.2.1.2. Pré-processamento

O pré-tratamento ou pré-processamento, em decorrência do fato das imagens não apresentarem ruídos, resume-se em:

- **Limiarização das imagens em níveis de cinza.** Neste processo são utilizados métodos diferenciados dependendo da primitiva extraída. O método global por entropia de Abutaleb [ABUTALEB, 1989] é previamente aplicado na base em níveis de cinza com intuito de tornar o traçado mais espesso, juntamente com processos morfológicos de abertura e de fechamento para a retirada de pequenos ruídos ainda existentes. A aplicação deste método favorece as características estáticas e os segmentos mais relevantes. Já o método global de Otsu [OTSU, 1979], é usado mais especificamente para as características pseudodinâmicas, pois fornece uma representação mais fiel do traçado original;
- **Operação morfológica de abertura e fechamento.** O operador de abertura remove todos os pontos menores que o elemento estruturante utiliza. O operador de fechamento, ao contrario, preenche os buracos e concavidades menores. Ambos fechamento e abertura suavizam uma imagem [KHOLMATOV, 2003] e [JUSTINO, 2001].
- **Extração do núcleo da imagem da assinatura através de um processo de afinamento.** Neste método aplicado por Huang [HUANG & YAN, 1997], o intuito é de extrair primitivas invariantes a densidade do traçado. Huang [HUANG & YAN, 1997] usam a técnica nas imagens em níveis de cinza. No método proposto a técnica é aplicada nas imagens limiarizadas .
- **Mapeamento da imagem limiarizada sobre a imagem em níveis de cinza.** Para a extração de primitivas em níveis de cinza, uma sobreposição de imagem limiarizada por Otsu na imagem original em nível de cinza é aplicada, desta forma prevalece o fundo branco e o traçado em nível de cinza.
- **Centralização das imagens.** Neste processo há o deslocamento do centro de gravidade da imagem para corrigir variações de traçado na coleta das imagens.
- **Alinhamento à esquerda das imagens.** No processo de alinhamento à esquerda desloca-se a imagem da assinatura no canto esquerdo da área retangular após o deslocamento do seu centro de gravidade. Esta estratégia é aplicada devido ao nível de coincidência dos *pixels* de imagens sobrepostas, o que garante um maior aproveitamento na extração das características, conforme exemplo da Figura 5.4. O mesmo processo aplica-se em cada autor usado no conjunto de validação do sistema. Os autores cedem 3 assinaturas cada. Estas assinaturas são sobrepostas

computando-se o número de *pixels* que ocupam o mesmo espaço gráfico nas 3 imagens. Ao final observa-se um nível percentual de coincidência maior do que comparando o mesmo processo com imagens somente centralizadas.

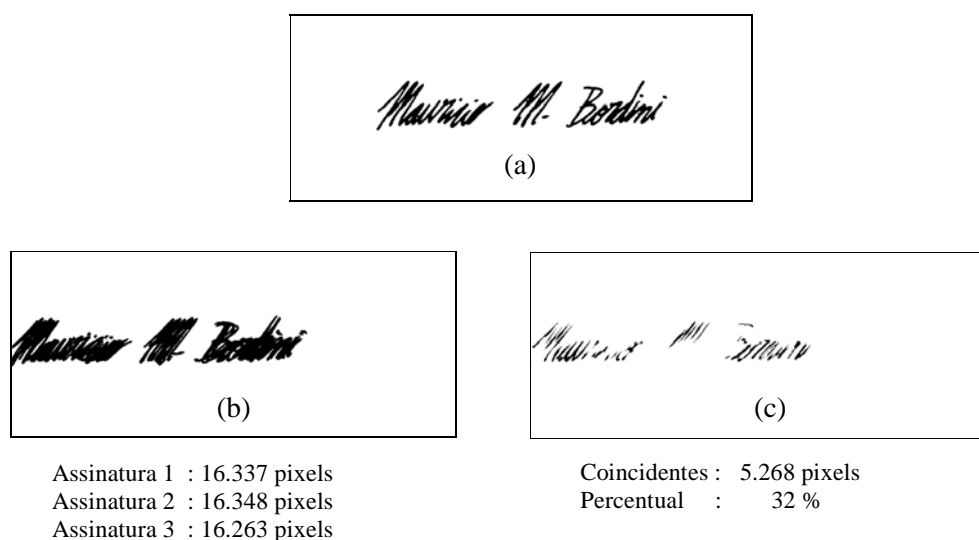


Figura 5.4: Estratégia de alinhamento a esquerda: (a) Assinatura Original (b) 3 assinaturas originais sobrepostas (c) Nível de coincidência de *pixels*.

5.2.2. Segmentação

Emprega-se uma grade ou *grid* como ferramenta de segmentação em todas as características extraídas. O *grid* é utilizado extensivamente em métodos de verificação automática de assinaturas *off-line* [SABOURIN & GENEST, 1994], [HUANG & YAN, 1997] e [JUSTINO, 2001]. Estes trabalhos também demonstram como os métodos baseados em *grid* podem ser adaptados para características grafométricas.

As características geométricas globais tratam uma imagem de assinatura como uma identidade integrada e não são capazes de prover informação estrutural de elementos de imagens, como o ângulo de um canto e a curvatura de um arco. Este tipo de informação estrutural é obtida usando um *grid* o qual é sobreposto em uma imagem [QI & HUNT, 1994].

Autores como Sabourin e Genest [SABOURIN & GENEST, 1994], Qi e Hunt [QI & HUNT, 1994] e Justino [JUSTINO, 2001] dividem a imagem em células para tratá-las localmente como primitivas. Um *grid* pode ser utilizado desde que não ultrapasse os limites da área destinada à assinatura, requisito que é satisfeito pela base utilizada.

Sendo os segmentos unidades elementares das assinaturas, esses possuem formas e comprimentos variados, tornando-se difícil a avaliação de sua importância no contexto geral da assinatura. A análise local de uma célula de *grid* permite a adoção de critérios de seleção desses segmentos. Deve-se lembrar também, que a ausência de segmentos pode ser relevante, como nos espaços em branco entre dois ou mais blocos de uma assinatura, ou mesmo a análise de ocupação do espaço gráfico. Todas estas características podem ser absorvidas através do uso do *grid*, já que se trata de uma segmentação abrangente [JUSTINO, 2001].

A Tabela 5.1 apresenta um conjunto de resoluções com relação à segmentação horizontal e vertical que são utilizadas no método.

Tabela 5.1: Segmentação com múltiplas resoluções.

| Resolução das células | Número de células verticais | Número de células horizontais | Número de pixels na vertical |
|-----------------------|-----------------------------|-------------------------------|------------------------------|
| Baixa | 4 | 10 | 100 |
| Baixa | 4 | 63 | 100 |
| Média | 8 | 20 | 50 |
| Média | 10 | 25 | 40 |
| Média | 10 | 63 | 40 |
| Alta | 20 | 20 | 20 |
| Alta | 25 | 63 | 16 |

A estratégia empregada é de utilizar toda a área horizontal e vertical, pré-fixando o tamanho do *grid* para todas as imagens desta forma preparando a fase seguinte de extração de primitivas as quais necessitam de tamanhos fixos, ao contrário de Justino [JUSTINO, 2001] que utiliza a área toda somente na vertical. Já na horizontal o limite é o início e fim da assinatura. Os exemplos das segmentações que se utiliza no método estão demonstrados na Figura 5.5.

Conforme capítulo 6, os melhores resultados são com resoluções médias de células quadradas, mais especificamente 8 linhas por 20 colunas, que corresponde a 50 x 50 *pixels*.

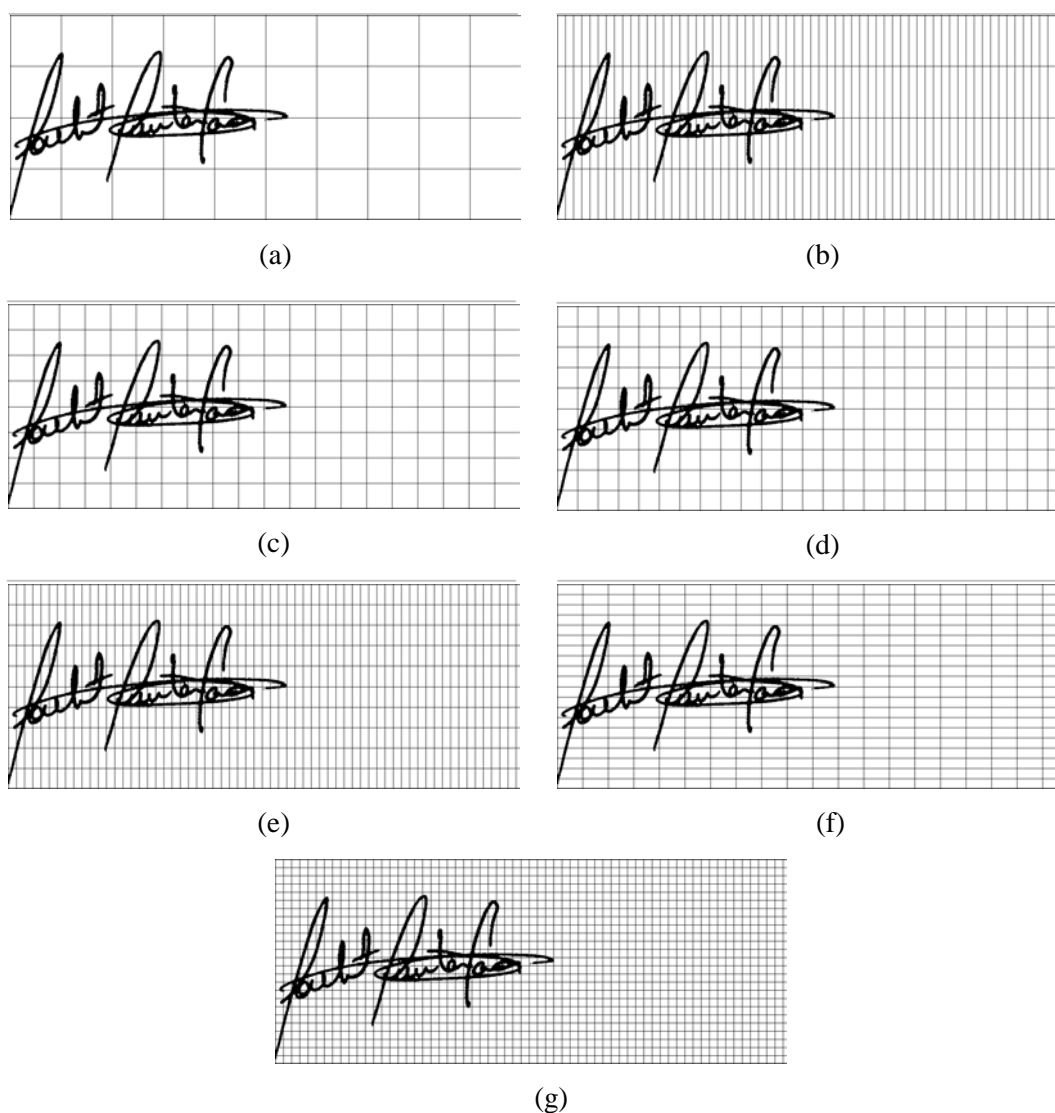


Figura 5.5: Exemplos de Segmentações utilizadas no método representando células verticais por horizontais: (a) 4x10; (b) 4x63; (c) 8x20; (d) 10x25; (e) 10x63; (f) 20x20; (g) 25x63.

5.2.3. Extração das Primitivas

Projetar bons extratores de características para sistemas verificadores de assinaturas, ainda é um grande obstáculo, dada a complexidade do problema [MARAR et al., 2002]. A escolha de características significativas constitui-se em uma etapa essencial na elaboração de um método de verificação, e a representação computacional destas características reflete

diretamente nos resultados obtidos, pois a robustez do método cresce proporcional à qualidade das mesmas. O estudo apresentado na seção 4.3 fornece subsídios para a escolha das primitivas relevantes.

As características estáticas referem-se à forma, tais como o comprimento e a altura. Elas são representadas também pelo comportamento estático da escrita, podendo perfeitamente serem representadas pela densidade de *pixels*, e pelo centro de gravidade, as quais incorporam várias características da grafoscopia e grafologia como calibre, proporção, espaçamento, altura, largura, dimensão, regularidade e proporção. Já as pseudodinâmicas, representam o comportamento dinâmico da escrita e portanto estão relacionadas diretamente com os traços da assinatura. As primitivas efetivamente implementadas desta categoria são: pontos de pressão, início e fim abrupto, segmentos de tremor, inclinação axial e curvatura. Uma descrição detalhada da implementação das primitivas é apresentada a seguir.

5.2.3.1. Pontos de Pressão

Nesta primitiva, ao invés de se usar imagens binárias, é usada a imagem original em níveis de cinza. A razão é que padrões em níveis de cinza contêm mais informações na pressão da caneta. Pressões mais altas correspondem as *pixels* mais escuros e possivelmente a alta velocidade corresponde a lançadas mais finas [FANG et al., 2003].

Huang e Yan [HUANG & YAN, 1997] utilizam pontos de pressão calculando a diferença entre a máxima e mínima intensidade de níveis de cinza, estabelecendo um limiar fixo, sendo que *pixels* que extrapolam este limiar correspondem a regiões com alta pressão. Já em Cavalcanti [CAVALCANTI et al., 2002], a informação de pressão é calculada baseada em *HPR* (regiões de alta pressão) dadas pela equação (5.1). Nesta equação, I é a imagem original, I_{hp} é a imagem com *HPR* e THP é o limiar de alta pressão. O THP é definido usando um histograma da imagem I .

$$I_{hp} = \begin{cases} 255, & \text{se } I(i, j) \geq THP \\ 0, & \text{caso contrário} \end{cases} \quad (5.1)$$

Para o problema proposto, a estratégia é encontrar todos os pontos de pressão que fazem parte do traçado. Desta forma, é determinada a média dos níveis de cinza θ com base na somatória dos níveis de cinza do traçado de cada *pixel* g_p da célula. Após, divide-se o resultado pela quantidade total de *pixels* do traçado dentro da mesma célula N_c , conforme equação (5.2). A partir deste limiar da pressão, é estabelecida a pressão celular g_{cel} para cada

5.2.3.2. Início e fim abrupto

O objetivo desta característica basicamente é estabelecer os pontos finais e os pontos iniciais de cada segmento, conforme exemplo descrito na seção 4.3.1.8. Malaviya e Peters [MALAVIYA & PETERS, 1997] tratam esta característica em caracteres manuscritos individuais.

A extração do início e fim abrupto segue as seguintes etapas:

- A imagem da assinatura é limiarizada através do algoritmo de Otsu [OTSU, 1979];
- A imagem limiarizada é esqueletizada;
- Um *grid* é aplicado na imagem esqueletizada;
- Os pontos de início e fim que cada segmento da assinatura possui são mapeados, através de um algoritmo que percorre os *pixels* dentro de cada célula da imagem esqueletizada. Uma máscara de 8-vizinhos é aplicada com objetivo de encontrar os *pixels* com um único vizinho, que representa o início ou final de um segmento $I_e(x,y)$
- Cada célula é dividida em sub-células com o objetivo de encontrar mais de um segmento inicial ou final. Neste caso, todos os segmentos são armazenados para uma posterior média;
- A imagem limiarizada é mapeada sobre a imagem original em níveis de cinza que resulta em uma terceira imagem resultante I_{RES} com fundo branco e segmentos pertencentes ao traçado em nível de cinza;
- O posicionamento exato de cada *pixel* candidato ao início e final abrupto $I_e(x,y)$ é encontrado com a sobreposição dos mesmos na imagem I_{RES} desta forma, podendo computar a pressão desta região através da equação (5.2) e equação (5.3);

Cada ponto mapeado apresenta um valor contínuo, representando a rigidez ou leveza nos pontos de início ou finalização do traçado. Valores discretos testados em experimentos, demonstram menor poder discriminante em termos de taxas de erro. O processo desde a esqueletização, até a marcação dos pontos correspondentes a prováveis paradas ou inícios abruptos, pode ser resumido conforme a Figura 5.7.

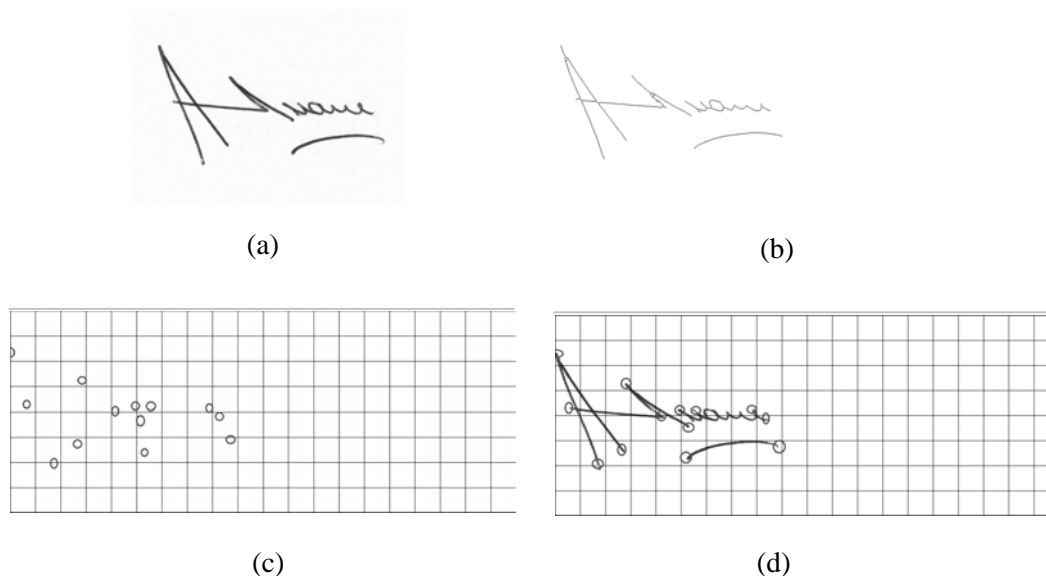


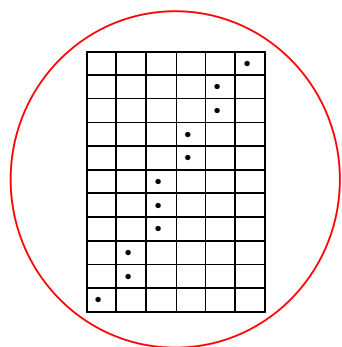

Figura 5.7: Primitiva de início e fim abrupto (a) imagem original (b) imagem esqueletizada (c) pontos circulos correspondentes a inicio ou fim do segmento no *grid* (d) pontos de inicio e fim correspondentes na imagem original plotado no *grid*.

5.2.3.3. Segmentos com Tremor

Representa uma característica pseudodinâmica caracterizada pela dinâmica do traçado, abordada por Justino [JUSTINO, 2001]. Inicialmente a imagem é limiarizada com o algoritmo de Abutaleb [ABUTALEB, 1989], o qual torna os segmentos mais espessos e desta forma pode-se medir o nível de tensão do traçado. Para isto seleciona-se o segmento mais significativo (ou mais longo) da imagem limiarizada. No segmento mais significativo é aplicado uma esqueletização. O cálculo da taxa de variação direcional T_x dos *pixels* conexos, é medido através do percurso dos segmentos baseado em código de cadeias com oito pontos de códigos. Neste ponto é computada as transições percorridas C_T , as quais são normalizadas pelo comprimento do segmento C_S , ou seja:

$$T_x = \frac{C_T}{C_S} \quad (5.4)$$

Conforme a figura 5.8 há uma descrição com um exemplo detalhado da primitiva segmentos de tremor.



Segmento analisado de acordo com código cadeia

Seqüência: 10100101010 (9 transições)

Comprimento: 11 pixels

Símbolo: $\frac{9}{11} = 0,818182$

(b)

Figura 5.8: Primitiva segmentos de tremor (a) processo de extração dos segmentos mais longos plotados no *grid* e utilização do código de cadeia (b) resultado do nível de tensão do segmento.

5.2.3.4. Densidade de *pixels*

Representa uma característica estática que é abordada por vários autores como Justino [JUSTINO, 2001], Baltzakis [BALTZAKIS & PAPAMARKOS, 2000] e Zhang [ZHANG et al., 1998]. Na abordagem proposta, a estratégia adotada é a contagem de *pixels* pretos Np dentro de toda extensão de cada célula ($m \cdot n$) em uma imagem limiarizada.

$$Cp = \frac{\sum_{k=0}^{m \cdot n} Np}{m \cdot n} \quad (5.5)$$

Esta primitiva possui a virtude de incorporar um descritor estatístico, o que propicia a sua insensibilidade às variações intrapessoais, conforme a Figura 5.9.




Figura 5.9: Primitiva densidade de pixels (a) imagem limiarizada (b) imagem plotada no *grid* com segmento extraído para a contagem de *pixels*.

5.2.3.5. Inclinação Axial

A inclinação axial é uma primitiva pseudodinâmica que é abordada por Qi e Hunt [QI & HUNT, 1995] e Justino [JUSTINO, 2001] e descreve o aspecto dinâmico do traçado. De acordo com Justino [JUSTINO, 2001] uma análise global da inclinação axial pode induzir a um processo de generalização, levando assim ao aumento da taxa de erro da falsa aceitação. Isso pode ocorrer principalmente envolvendo as falsificações simuladas.

Na extração desta primitiva uma análise local envolvendo cada célula é aplicada. O processo computa o número de ocorrências de cada um dos elementos estruturantes descritos na Figura 5.10(a). O elemento estruturante de maior ocorrência, dentro da célula, passa a representar o símbolo da mesma, Figura 5.10(b). Basicamente o processo representa uma normalização discreta dos símbolos que cada segmento forma na aplicação do elemento estruturante 8-vizinhos.

Nesta característica pseudodinâmica a imagem limiarizada, com o algoritmo de Abutaleb [ABUTALEB, 1989], é usada no processo de esqueletização I_e . Através de um algoritmo de busca, o segmento mais significativo dentro de cada célula do *grid*, é detectado, baseado em código de cadeias com oito pontos de códigos, é percorrido o segmento encontrado. Neste ponto, a variação angular é de 45° , caso a direção do próximo ponto do segmento em relação ao anterior seja no sentido anti-horário e -45° , caso a direção seja no sentido horário. Ao final o valor em graus encontrado corresponde à curvatura do segmento analisado. Podendo variar em uma escala de 495° até -495° , sendo estes últimos valores representando a mais de uma volta completa em um segmento, como por exemplo um bucle ou espiral demonstrado na Figura 4.18(f). Um ponto interesse nesta primitiva está relacionado com pequenas variações no sentido direcional do segmento, as quais não interferem no resultado final, conforme na Figura 5.12.

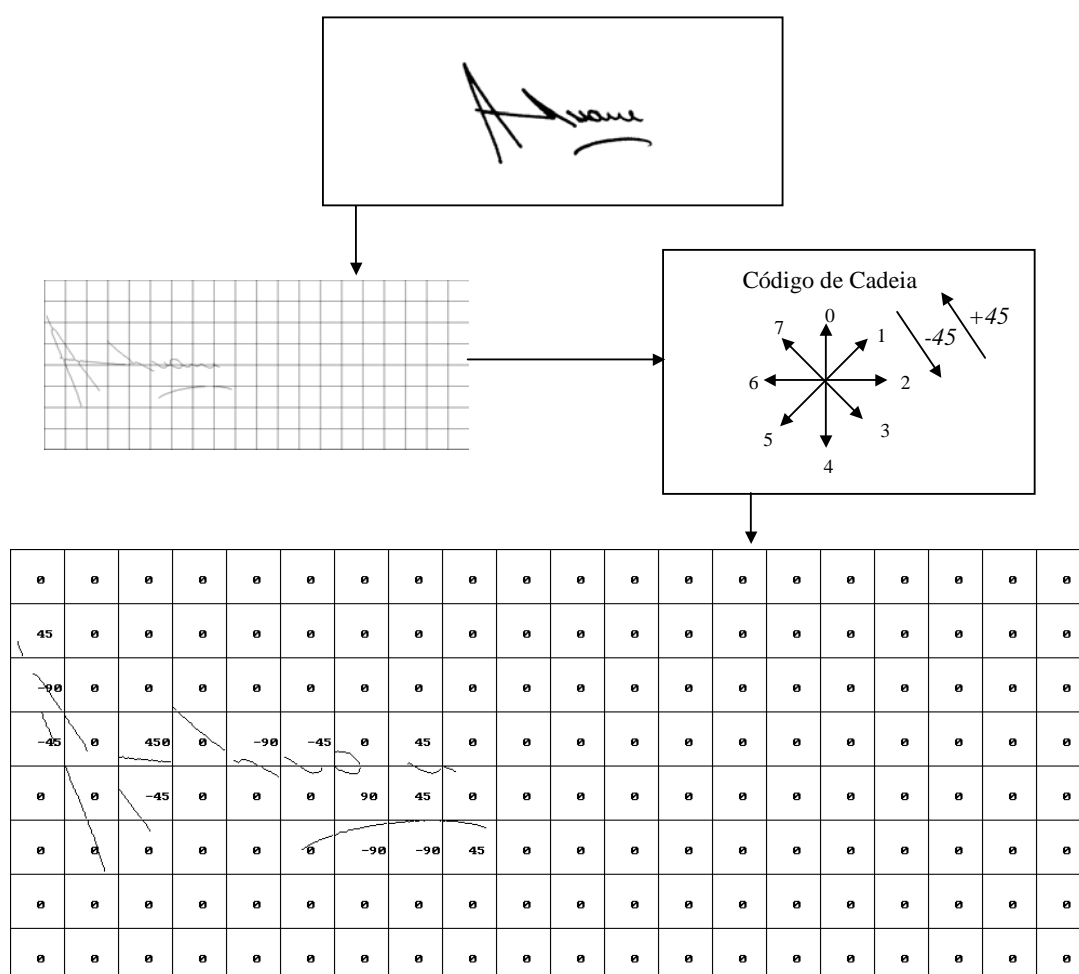


Figura 5.12: Diagrama do processo de extração da primitiva curvatura.

5.2.3.7. Centro de Gravidade

A característica do centro de gravidade é abordada por Justino [JUSTINO et al., 2003], e tem por objetivo determinar o posicionamento da concentração estatística de *pixels* dentro de cada célula. Na extração desta primitiva no método proposto, primeiramente é aplicado o *grid* sobre a imagem limiarizada, em seguida determina-se o centro de massa de cada segmento, ou seja, um ponto central de acordo com a maior concentração de *pixels*. Após esta etapa calcula-se a distância d da origem da célula até o ponto do centro de massa através da distância euclidiana. Para normalizar este processo, o valor encontrado é dividido pela distância da origem até o canto oposto da célula que corresponde à maior distância dentro da célula. A Figura 5.13 apresenta o processo de extração da primitiva centro de gravidade.

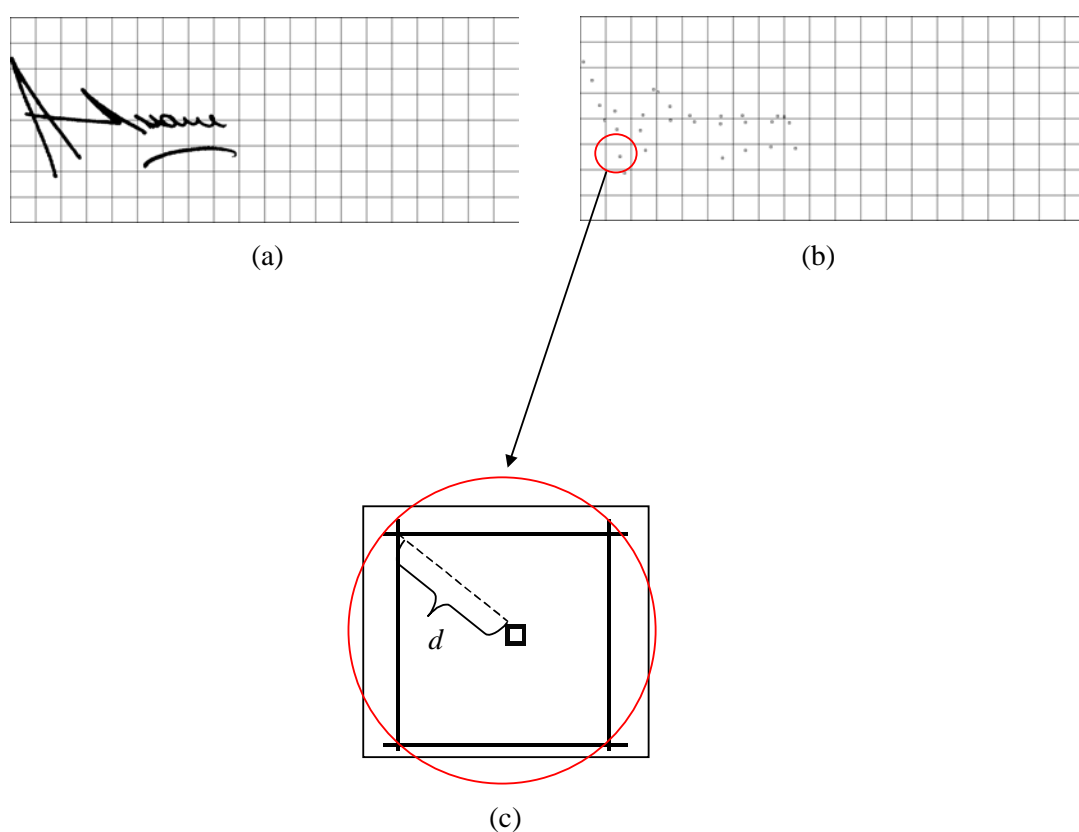


Figura 5.13: Primitiva centro de gravidade (a) imagem limiarizada plotada no *grid* e alinhada a esquerda (b) centro de massa de cada célula (c) distância euclidiana d do centro de massa à origem.

5.2.4. Cálculo das Distâncias entre as Primitivas

A classificação depende significativamente das medidas de distâncias, portanto é importante a escolha de uma medida de distância satisfatória. Neste experimento três tipos distintos de distâncias são testadas conforme seção 4.4: distância euclidiana, distância euclidiana quadrática e bloco cidade.

Após a extração, um vetor com as características é gerado. Pelo fato deste vetor ser de tamanho fixo, a maneira mais natural é compará-lo com o uso de medidas de distâncias. Entretanto isto produz uma métrica de similaridade pobre, desde que as características correspondentes no vetor são distorcidas devido à variação natural entre assinaturas genuínas. Conseqüentemente, há necessidade de um método que relacione características correspondentes de dois vetores de uma maneira não-linear.

Outro aspecto está associado à abordagem dicotômica, a qual propõe um modelo genérico de aprendizagem, com um único treinamento utilizado. Os resultados são indesejáveis se somente as características de vários autores são submetidas diretamente ao classificador. Desta forma, a utilização de medidas de distâncias entre as características extraídas é utilizada, pois distâncias entre características de amostras do mesmo autor independente do autor, tendem a ser menores do que distâncias de características entre autores diferentes [CHA, 2001].

No cálculo das distâncias, primeiramente, toda a base de dados é convertida dentro de um conjunto de vetores de características, os quais são obtidos de ambas as assinaturas S_{Ki} e S_Q , equação (5.6) e equação (5.7).

$$fv_{Ki(i=1,2,\dots,n)}^F = (f_{i_1}^F, f_{i_2}^F, \dots, f_{i_d}^F) \quad (5.6)$$

$$fv_Q^F = (f_1^F, f_2^F, \dots, f_d^F) \quad (5.7)$$

onde $F(1 \leq F \leq 7)$ representa o subconjunto de características e d o número máximo de células de cada características. O vetor de distâncias $D_{fi} (i=1,2,3,\dots,n)$ entre o vetor de características genuínas e o vetor de características de amostra questionada é computado para se obter a entrada no classificador (rede MLP ou SVM), no treinamento, validação e teste. Nesta abordagem, as medidas de distâncias usadas são: euclidiana, euclidiana quadrática e bloco cidade conforme equação (5.8), (5.9) e (5.10) respectivamente.

$$D_{f_{i(i=1,2,\dots,n)}} = \bigcup_{F=1}^7 \sqrt{(fv_{ki}^F - fv_Q^F)^2} \quad (5.8)$$

$$D_{f_{i(i=1,2,\dots,n)}} = \bigcup_{F=1}^7 (fv_{ki}^F - fv_Q^F)^2 \quad (5.9)$$

$$D_{f_{i(i=1,2,\dots,n)}} = \bigcup_{F=1}^7 |fv_{ki}^F - fv_Q^F| \quad (5.10)$$

Na Figura 5.14 é ilustrado o cálculo das distâncias e a transformação dicotômica utilizando $F = 7$. O processo pode ser descrito em: dada uma assinatura genuína x e outra assinatura questionada y , tomando como base um *grid* com células quadradas de tamanho 50×50 *pixels*, Aplica-se cada uma das primitivas sobre as duas imagens gerando um vetor com 160 posições ($d = 160$) representando o número de células. O vetor da primitiva densidade de *pixels* para a imagem x é representado por $(DEN_1^x \dots DEN_{160}^x)$, pontos de pressão $(PRE_{161}^x \dots PRE_{320}^x)$, início e fim abrupto $(ABR_{321}^x \dots ABR_{480}^x)$, segmentos de tremor $(TRE_{481}^x \dots TRE_{640}^x)$, inclinação axial $(INC_{641}^x \dots INC_{800}^x)$, curvatura $(CUR_{801}^x \dots CUR_{960}^x)$ e centro de gravidade $(BAS_{961}^x \dots BAS_{1120}^x)$. O mesmo procedimento é aplicado na imagem y . No final um vetor de até 1120 posições é usado com uma métrica de distância na entrada da produção do modelo, o qual é descrito na próxima seção.

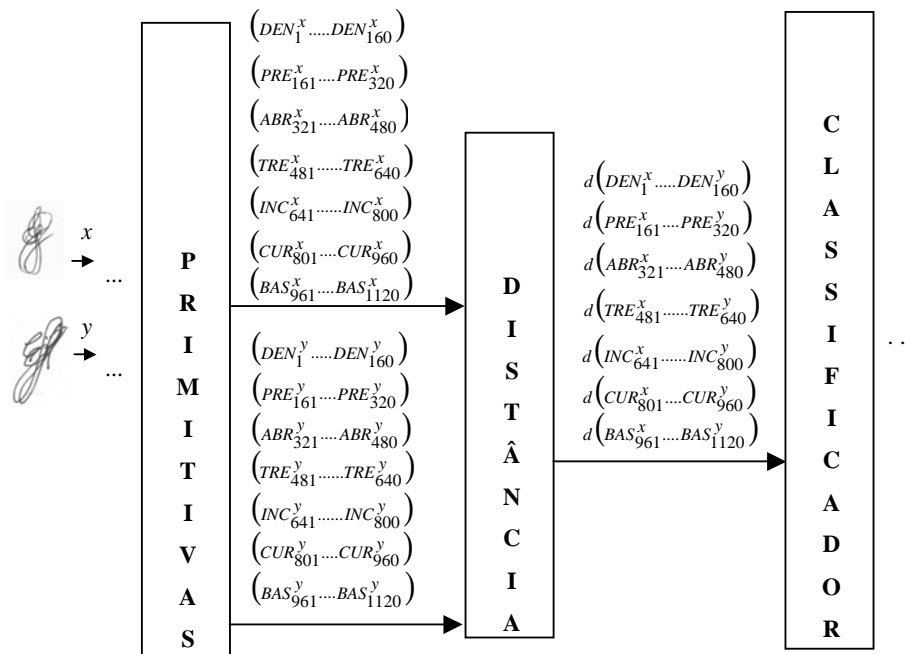


Figura 5.14: Descrição do processo de transformação dicotômica com relação as primitivas implementadas.

Em termos de resultados a Tabela B.1 no Anexo B, demonstra um comparativo entre distância euclidiana, euclidiana quadrática e *city-block*. A distância euclidiana apresenta os melhores resultados, e por isso é fixada em todos os experimentos.

5.2.5. Produção de Um Modelo

Há dois estágios na fase de produção de um modelo, um é o treinamento o outro é a verificação. No estágio de treinamento, as distâncias das características $d(fv_1^x, fv_m^y)$ são computadas usando pares de amostras de assinaturas. Na abordagem são usadas para suprir este estágio redes neurais artificiais (RNA) MLP e *support vector machines* (SVM).

Nas últimas décadas, redes neurais têm sido usadas extensivamente na área de reconhecimento de padrões, em específico na verificação de assinaturas [XIAO & LEEDHAM, 1999], [BAJAJ & CHAUDHURY, 1996], [SANSONE & VENTO, 2000] e [HUANG & YAN, 1997]. O SVM representa uma nova alternativa em problemas de classificação, aplicado em outros trabalhos com bons resultados [JUSTINO et al, 2003], [KHOLMATOV, 2003], e por isto também é utilizado.

Na rede MLP se ambas as assinaturas são escritas pelo mesmo autor, a saída da rede recebe o valor 1 como também no SVM. Caso contrário, se as assinaturas são escritas por autores diferentes é utilizado 0 na saída da rede MLP e -1 no vetor do SVM.

Os conjuntos de treinamento, validação e teste são normalizados entre 0 e 1 em ambos os classificadores, desta forma melhorando o tempo de convergência durante a fase de treinamento.

Usando a hipótese de que todas as distâncias entre duas amostras de assinaturas escritas pelo mesmo autor, independente do autor, são menores, o classificador é treinado para separar pequenas distâncias de características (genuínas) e grandes distâncias de características (falsificações).

A rede MLP e o SVM são compostos de duas saídas, uma para indicar que duas assinaturas pertencem para o mesmo autor, w_1 , e a outra para indicar que duas assinaturas são produzidas por autores diferentes, w_2 . No tratamento de limiares de rejeição e aceitação utiliza-se múltiplos limiares de rejeição [FUMERA et al., 2000].

No processo de aprendizagem, cada amostra resultante da distância das características computadas fornece um vetor de distância de características \vec{D} com posições variando de 160 (1 primitiva) até 1120 (7 primitivas), correspondendo a uma resolução de 8 células verticais por 20 horizontais, representando as entradas tanto na RNA quanto no SVM.

5.2.5.1. Topologia e Parâmetros da Rede Neural

Por ser um processo estocástico, a RNA necessita de critérios empíricos para escolha de topologia e arquitetura. Após os mesmos serem escolhidos, conforme é visto nesta seção, a topologia é fixada. Testes com variações da arquitetura MLP, tais como o termo *momentum* não demonstram os melhores resultados. Desta forma o *backpropagation* padrão é fixado nos experimentos.

Com relação à camada de saída dois neurônios são usados, uma vez que a abordagem trata somente duas classes: autoria e não-autoria.

Entretanto, no que se refere à camada escondida, a arquitetura varia de uma camada a duas camadas escondidas. No uso de uma camada escondida, 4 neurônios são usados baseados na estratégia de Oh e Suen [OH & SUEN, 2000] de duas vezes o número de nós da saída na camada escondida. Já com o acréscimo de outra camada escondida, o número de neurônios varia empiricamente de 4 a 80. Pelo melhor desempenho com o uso de duas camadas escondidas nos experimentos, admite-se que os dados não são linearmente separáveis.

O número de neurônios nas camadas escondidas em nenhum dos experimentos excede 50% do número de nós da camada de entrada [WALCZAK & CERPA, 1999], o que acarreta um longo período de treinamento.

O método *holdout* e critério de parada com conjunto de validação é usado para estimar o erro e ajuste de parâmetros. O conjunto de validação serve para ajustar os pesos da rede MLP, número de camadas escondidas, constante de aprendizagem e o número de épocas, sendo o esforço computacional reduzido, pois quando o desempenho da memorização e generalização fica em um patamar aceitável, isto é, quando o erro do conjunto de validação atinge o menor valor em termos de MSE e começa a subir, o treinamento é parado. Neste ponto o número de ciclos varia de 30 até 350 ciclos em todos os experimentos.

Com relação aos parâmetros livres: a constante de aprendizagem é definida entre 0.01 e 0.03, o erro mínimo aceitável do MSE é igual a 0.001 e os pesos são inicializados entre +0.001 e -0.001.

Para os experimentos, o software simulador SNNS [ZELL et al., 1994] é aplicado no processo de aprendizagem.

5.2.5.2. Parâmetros do SVM

Com o objetivo de estabelecer uma regularização empírica para o melhor valor da constante C , os valores variam de 0 a 1000. Os resultados dos experimentos do capítulo 6 demonstram a habilidade do procedimento de aprendizagem para discriminar entre w_1 e w_2 . Com relação ao kernel utilizado, experimentos com kernel polinomial apresentam resultados superiores ao kernel linear. Isto comprova que a abordagem representa um problema não-linear, conforme resultados da Tabela A.1 no Anexo A. O parâmetro d do kernel polinomial é iniciado com 1 e os parâmetros $-r$ e $-s$ em 0,01. Maiores detalhes sobre configurações e parâmetros do SVM podem ser encontradas em Joachims [JOACHIMS, 2000]. Os experimentos utilizam o pacote “freeware” SVMlight [SVM, 2003].

5.2.6. Processo de Decisão

Nesta etapa, avalia-se as saídas do modelo produzido, verificando se a assinatura pertence ou não a determinada classe, para isso utiliza-se uma função de probabilidade *a posteriori*, conforme apresentado na seção 2.4.

Neste estágio, o processo de decisão representando uma situação prática é aplicado. O mesmo baseia-se nos princípios da decisão pericial na análise grafotécnica, quando da análise de uma assinatura questionada, conforme seção 5.1.

Geralmente no procedimento executado pelo perito grafotécnico, um conjunto de comparações é realizado. No método proposto, cada amostra genuína conhecida (referência) é comparada com amostras de assinaturas questionadas. Para este propósito, um conjunto de assinaturas genuínas é usado como referência ou modelo, no processo comparativo, com o objetivo de produzir uma decisão final. O sistema proposto combina todas as saídas de classificação em uma regra de decisão baseada no voto majoritário [LAM & SUEN, 1997].

A combinação de resultados parciais pode ser implementada utilizando uma variedade de estratégias, dentre elas o voto majoritário. Trata-se de um modo simples usado de maneira mais efetiva para melhorar os resultados. Porém, o voto majoritário não usa nenhum conhecimento do comportamento *a priori* dos classificadores.

Lam e Suen [LAM & SUEN, 1997] demonstram a estratégia de combinação de decisão baseada em vários classificadores, nos quais as mesmas amostras são submetidas, e o voto majoritário é aplicado sobre as saídas destes classificadores (*experts*). Em Lam e Suen [LAM & SUEN, 1997], assume-se que N_{class} classificadores são empregados, e que para cada amostra de entrada, cada classificador produz uma única decisão, obtendo a identidade da amostra. Esta identidade pode ser uma das classes permitidas, ou uma rejeição quando nenhuma das identidades são consideradas possíveis. Em combinação de N_{class} classificadores, a amostra é associada à classe para qual há um consenso, ou quando V_m dos classificadores concorda na identidade, assim:

$$V_m = \begin{cases} \frac{N_{class}}{2} + 1 & \text{se } N_{class} \text{ é par} \\ \frac{N_{class} + 1}{2} & \text{se } N_{class} \text{ é ímpar} \end{cases} \quad (5.11)$$

Uma adaptação do voto majoritário é aplicada no método proposto. Fixa-se o classificador e somente as amostras variam, sendo o voto majoritário aplicado sobre as saídas do classificador. Como o número de saídas são duas (mesmo autor ou autores diferentes), a amostra questionada é submetida ao processo de decisão com 5 amostras verdadeiras usadas de referência N_{ref} . Desta forma assume-se que:

$$V_m = \left\lfloor \frac{N_{ref} + 1}{2} \right\rfloor \quad (5.12)$$

, na qual a decisão final baseia-se em $V_m \geq 3$, ou seja, se amostras pertencem ao mesmo autor, a soma das decisões é $V_m \geq 3$ para $x_{(+)}$, caso contrário $V_m \geq 3$ para $x_{(-)}$ testados.

5.2.6.1. Limiares de Rejeição e Aceitação

Com relação a limiares de rejeição, autores como Qi e Hunt [QI & HUNT, 1994] desconsideram limiares por acreditarem que os mesmos são utilizados para minimizar a taxa de erro total de cada função de verificação, porém menosprezando a taxa de má classificação. Segundo Qi e Hunt [QI & HUNT, 1994] estes limiares são baseados somente nas amostras de

treinamento e validação, embora utilizados para o desempenho, comparação e avaliação de diferentes esquemas de verificação. Para Gori e Scarselli [GORI & SCARSELLI, 1998] que tratam exclusivamente de redes MLP, critérios de limiares podem demonstrar excelente desempenho de discriminação, porém podem falhar na tarefa de rejeição.

Já em Kholmatov [KHOLMATOV, 2003], sistemas de verificação de assinaturas *off-line* seriam mais úteis se classificassem robustamente uma porção das assinaturas apresentadas como genuínas ou falsas e deixassem o resto (uma pequena porção) para inspeção, desta forma projetando um sistema que classificasse as assinaturas em três classes: genuína, falsa e incerta ou inconclusiva.

Sansone e Vento [SANSONE & VENTO, 2000] levam em conta a determinação de um limiar ótimo da rejeição e do erro, por considerarem requisitos do domínio da aplicação. Estes requisitos estão relacionados ao custo de má classificação, rejeição e correta classificação.

A introdução de uma opção de rejeição tem a intenção de rejeitar o maior percentual possível de amostras, as quais são má classificadas. Já o preço que se paga mesmo quando usada adequadamente é que este critério introduz um efeito contrário, pelo fato de que algumas amostras terem sido classificadas corretamente agora são rejeitadas.

Drouhard [DROUHARD et al., 1994] especifica que em sistemas que requerem uma decisão imediata, a adição de um critério de rejeição para a regra de decisão permite significantes melhoras no desempenho dos classificadores, por recusar o caso de uma classificação duvidosa. Entretanto, mesmo se o custo de uma rejeição for mais baixa que o de um erro, a taxa de rejeição deve ser a menor possível por duas razões. A primeira é que também se pode rejeitar boas decisões e se a taxa de rejeição de uma boa decisão for tão alta quanto das más decisões, o desempenho do classificador será diminuído ao invés de aumentado. O segundo problema da utilidade do classificador, em caso extremo, é ter uma taxa de erro de 0% e de rejeição de 100%. Neste caso, o classificador é inútil. Uma maneira para tratar este fenômeno é através de um fator de confiabilidade RF , no qual se considera a taxa de erro, assim como a taxa de rejeição na avaliação do desempenho do classificador.

No método proposto, os limiares que separam as assinaturas genuínas das falsas não são empiricamente escolhidos, e sim baseados no estudo de Fumera [FUMERA et al., 2000] demonstrado na seção 2.4.1. Para a determinação dos limiares (T_1, \dots, T_N) os mesmos são estimados usando o conjunto de validação finito.

Um histograma de decisão no conjunto de validação dos dados classificados corretamente é proposto baseado em [CHA, 2001] para determinação dos limiares. Desta forma as probabilidades da saída do classificador tendem a ser mais volumosas em direção ao valor 1 quando se referem à distância dos dados entre mesmos autores ou classes iguais, enquanto que as probabilidades, quando se tratam de autores ou classes diferentes tendem a ser mais volumosas em direção ao valor 0, conforme Figura 5.15.

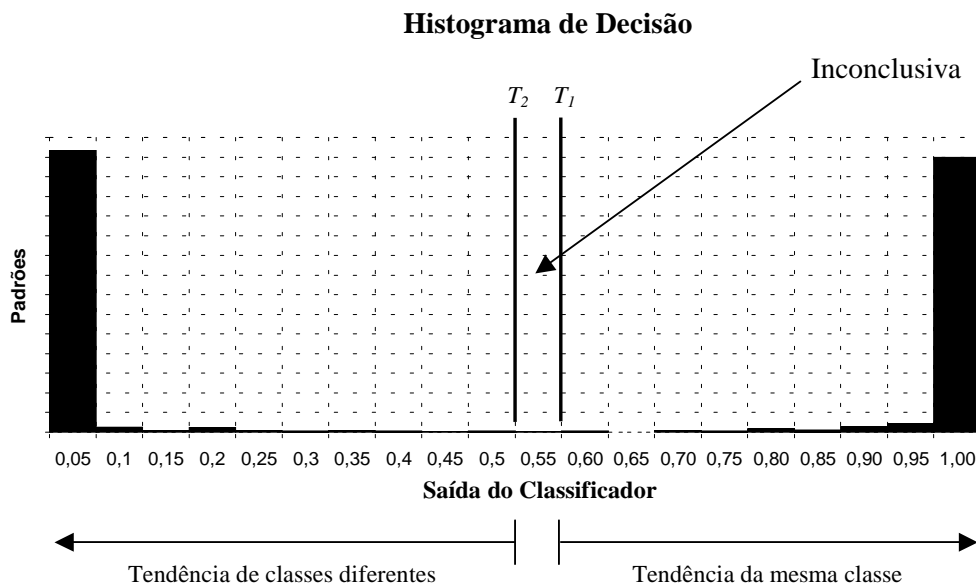


Figura 5.15: Histograma de decisão no conjunto de validação com limiares de decisão.

O critério utilizado na Figura 5.15 é o de submeter um conjunto de amostras de validação ao classificador. Baseado nas saídas corretamente classificadas estabelece-se o limiar da classe positiva como sendo o menor valor encontrado, ou seja, o que menos tende a 1, T_1 . Já o limiar da classe negativa é o maior valor encontrado nas amostras corretamente classificadas como negativas, ou seja, a amostra que menos tende a 0, T_2 .

A decisão, ao invés de ser tomada diretamente, é baseada nas saídas do classificador, as probabilidades são computadas tendo por base as equações (4.9) e (4.10), substituindo o limiar T por $T_1 < T$ e $T_2 \geq T$ respectivamente, permitindo a incorporação de limiares de rejeição no processo.

$$\alpha = Pr(\text{classificador } d(fv_1^x, fv_d^y) < T_1 / \text{autor}(x) = \text{autor}(y)) \quad (5.13)$$

$$\beta = Pr(\text{classificador } d(fv_1^x, fv_d^y) \geq T_2 / \text{autor}(x) \neq \text{autor}(y)) \quad (5.14)$$

Qualquer saída entre T_1 e T_2 é rejeitada ou considerada inconclusiva e separada para procedimentos mais sofisticados.

Ao contrário da maioria das abordagens que estabelecem um treinamento (ou uma rede quando o classificador for uma RNA) para cada classe, necessitando um limiar diferente para cada treinamento, a abordagem proposta preocupa-se em estabelecer dois únicos limiares de rejeição.

5.3. Comentários Finais

A visão do perito na análise de assinaturas questionadas analogamente como uma solução computacional para o método proposto apresentada neste capítulo fornece uma visão clara da abordagem proposta. Todas as etapas que envolve o processo de verificação de assinaturas são também detalhadas. Os resultados dos experimentos estão descritos no próximo capítulo.

Capítulo 6

6. Experimentos Realizados e Análises dos Erros

Neste capítulo são apresentadas as sub-base de dados e os conjuntos que fazem parte dos protocolos utilizados. São apresentados também os resultados obtidos pelos experimentos, como a análise dos erros.

6.1. Protocolo de Avaliação

A base de dados para os experimentos é subdividida em duas sub-bases. A primeira é usada para o processo de aprendizagem e seleção dos parâmetros ótimos, contendo inicialmente 40 autores e passando para 180 autores nos experimentos finais. Nesta sub-base, as amostras do conjunto de treinamento variam de aproximadamente 60% a 80%, já nos conjuntos de validação e teste as amostras variam de aproximadamente 10% a 20% de acordo com experimento. A segunda sub-base é composta por 60 autores com os quais são feitos os testes definitivos. As falsificações estão presentes nesta sub-base.

O protocolo utilizado para os experimentos iniciais em termos de assinaturas está demonstrado na Tabela 6.1, em que 40 autores são utilizados para o treinamento e 60 autores para o teste final com a técnica do voto majoritário. Na base de 40 autores o treinamento utiliza 20 assinaturas genuínas de cada autor, e a validação utiliza 10 assinaturas de cada autor. Já o teste usado para fins de ajustes de parâmetros, utiliza também 10 assinaturas de cada autor, perfazendo um total de 1600 assinaturas no processo de aprendizagem. No teste com o voto majoritário, 5 assinaturas de cada um dos 60 autores são utilizadas como referência, ou seja, como se estivessem previamente armazenadas em um sistema para posterior consulta e comparação com assinaturas questionadas, desta forma representando uma situação prática.

No teste com assinaturas questionadas, para cada um dos 60 autores utiliza-se 5 assinaturas genuínas, 5 falsificações simples, 5 falsificações simuladas e 5 falsificações aleatórias. Para as falsificações aleatórias utiliza-se somente 59 autores. No geral são utilizadas 1495 assinaturas, ou seja, 300 como referência e 1195 para o teste do voto majoritário.

Tabela 6.1: Protocolo do número de assinaturas utilizado nos experimentos iniciais.

| Assinaturas | | | | | | |
|--------------|---------------------|------------------------|---------|----------|-----------|-------------|
| Conjuntos | 40 Autores | 60 Autores | | | | 100 Autores |
| | | Teste Voto Majoritário | | | | |
| | Genuína / Aleatória | Genuína | Simples | Simulada | Aleatória | Total |
| Treinamento | 800 | | | | | 800 |
| Validação | 400 | | | | | 400 |
| Teste | 400 | 300 | 300 | 300 | 295 | 1595 |
| Referência | | 300 | | | | 300 |
| Total | 1600 | 600 | 300 | 300 | 295 | 3095 |

Pelo fato da abordagem proposta necessitar de combinação entre valores das distâncias das primitivas de acordo com o método proposto por Cha [CHA, 2001], as 1600 assinaturas da sub-base de 40 autores são submetidas a combinações baseadas nas distâncias das primitivas, de acordo com as equações (4.6) e (4.7), para amostras intraclasse e interclasse respectivamente. Já a sub-base de 60 autores 5 assinaturas questionadas genuínas, em relação às 5 assinaturas de referência, geram 25 amostras para cada autor, fornecendo um total de 1500 amostras genuínas para o teste do voto majoritário. As falsificações da mesma forma rendem 1500 amostras simples, 1500 simuladas e 1475 aleatórias, perfazendo um total de 5975 amostras para teste, conforme a Tabela 6.2. Isto representa o protocolo máximo utilizado nos experimentos, podendo variar para menos, ou seja, para um número menor de autores e assinaturas por autor dependendo do experimento.

Tabela 6.2: Protocolo de amostras utilizadas nos experimentos iniciais.

| Amostras | | | | | | | |
|--------------|------------|-----------|------------------------|---------|----------|-----------|-------------|
| Conjuntos | 40 Autores | | 60 Autores | | | | 100 Autores |
| | | | Teste Voto Majoritário | | | | |
| | Genuína | Aleatória | Genuína | Simples | Simulada | Aleatória | Total |
| Treinamento | 7.600 | 312.000 | | | | | 319.600 |
| Validação | 1.800 | 78.000 | | | | | 79.800 |
| Teste | 1.800 | 78.000 | 1.500 | 1.500 | 1.500 | 1.475 | 85.775 |
| Total | 11.200 | 468.000 | 1.500 | 1.500 | 1.500 | 1.475 | 485.175 |

Para os experimentos finais, o número de autores no conjunto de treinamento é aumentado de 40 para 180. Porém cada autor novo fornece somente 4 assinaturas, totalizando 560 assinaturas. Desta forma, há um decréscimo no número de assinaturas cedidas por cada autor em toda a primeira sub-base, conseqüentemente uma diminuição do número de amostras utilizadas. Para um melhor aproveitamento na aprendizagem devido à limitação da base de dados, os 180 autores são usados no treinamento, já a validação e teste são realizados com 40 autores. A diferenciação é em termos de assinaturas que cada autor fornece, ou seja, 4 assinaturas para treinamento, outras 4 para validação e outras 4 para teste. O protocolo da sub-base de 60 autores permanece o mesmo. A Tabela 6.3 demonstra o protocolo em termos de assinaturas utilizadas, enquanto que a Tabela 6.4 demonstra o protocolo em termos de amostras geradas.

Tabela 6.3: Protocolo do número de assinaturas utilizado nos experimentos finais.

| Assinaturas | | | | | | |
|--------------|---------------------|------------------------|---------|----------|-----------|-------------|
| Conjuntos | 180 Autores | 60 Autores | | | | 240 Autores |
| | | Teste Voto Majoritário | | | | |
| | Genuína / Aleatória | Genuína | Simples | Simulada | Aleatória | Total |
| Treinamento | 720 | | | | | 720 |
| Validação | 160 | | | | | 160 |
| Teste | 160 | 300 | 300 | 300 | 295 | 1355 |
| Referência | | 300 | | | | 300 |
| Total | 1040 | 600 | 300 | 300 | 295 | 2535 |

A Tabela 6.4 representa o protocolo máximo com o qual avalia-se o desempenho final do método. Nos experimentos propostos, existem variações para uma quantidade menor de amostras, com objetivo de reduzir o custo computacional.

Tabela 6.4: Protocolo das amostras utilizadas nos experimentos finais.

| Amostras | | | | | | | |
|-------------|-------------|-----------|------------------------|---------|----------|-----------|-------------|
| Conjuntos | 180 Autores | | 60 Autores | | | | 240 Autores |
| | | | Teste Voto Majoritário | | | | |
| | Genuína | Aleatória | Genuína | Simples | Simulada | Aleatória | Total |
| Treinamento | 1.080 | 16.110 | | | | | 17.190 |
| Validação | 240 | 780 | | | | | 1.020 |
| Teste | 240 | 780 | 1.500 | 1.500 | 1.500 | 1.475 | 6.995 |
| Total | 1.560 | 17.670 | 1.500 | 1.500 | 1.500 | 1.475 | 25.205 |

6.2. Os experimentos

Na abordagem proposta os resultados dos experimentos iniciais não são os esperados. Uma análise mostra que o número limitado de amostras de assinaturas disponíveis para o treinamento, não cobre o espaço de características. Isto limita a habilidade da rede em generalizar amostras não vistas. Com um acréscimo de 140 autores uma tendência de melhora é verificada.

A seguir apresentam-se os resultados obtidos pelos experimentos,. Os testes são divididos em vários grupos considerando os seguintes aspectos:

- determinação da resolução do *grid* na segmentação;
- máxima combinação de amostras baseado em Cha [CHA, 2001];
- balanceamento do número de amostras de cada classe;
- seleção do conjunto de primitivas;
- aumento na quantidade de autores e variação nas amostras;
- limiares de rejeição e aceitação;
- SVM;
- comparativo do método proposto com análise humana

O objetivo dos experimentos realizados é a redução das taxas de erro Tipo I e Tipo II, através do uso da matriz de confusão nos conjuntos de teste.

Em todos os experimentos, um teste inicial é realizado com o intuito de ajustar os parâmetros livres dos classificadores. Para isto, o conjunto de teste da primeira sub-base é usado.

6.2.1. Determinação da Resolução do *Grid* na Segmentação

Neste experimento são definidas as resoluções em termos de *grid* que serve de base para os demais experimentos. Para tanto, a primitiva densidade de *pixels* é fixada e o processo de treinamento ocorre somente para esta primitiva, devido à dificuldade prática com o teste de primitivas agrupadas, o qual requisita muito esforço computacional, pois o protocolo da Tabela 6.2 dos experimentos iniciais é utilizado para treinamento e teste. Os resultados estão apresentados na Tabela 6.5, a qual demonstra que a resolução 8 linhas por 20 colunas correspondendo a células quadradas de 50 x 50 *pixels* apresenta os melhores resultados, sendo deste modo esta resolução fixada para os demais experimentos.

Tabela 6.5: Resultados com diferentes resoluções de *grid*.

| Resolução | Densidade de <i>pixels</i> | | | | Erro Total (%) |
|-----------|--------------------------------|----------------------------------|--------|------------|----------------|
| | Falsa Rejeição Erro Tipo I (%) | Falsa Aceitação Erro Tipo II (%) | | | |
| | Verdadeiras | Simplex | Servis | Aleatórias | Total |
| 8x20 | 22,22 | 2,22 | 26,38 | 2,50 | 13,33 |
| 4x10 | 27,78 | 1,94 | 23,33 | 0,65 | 13,42 |
| 10x25 | 21,11 | 4,16 | 27,50 | 5,83 | 14,65 |
| 25x63 | 33,05 | 4,44 | 23,33 | 1,66 | 15,62 |
| 4x63 | 25,27 | 3,05 | 28,05 | 6,66 | 15,75 |
| 20x20 | 20,27 | 5,00 | 35,55 | 2,50 | 15,83 |
| 10x63 | 24,72 | 5,00 | 27,77 | 7,50 | 16,24 |

6.2.2. Máxima Combinação de Amostras

Baseando-se na combinação de amostras proposta por Cha [CHA, 2001], o protocolo da Tabela 6.2 é proposto e utilizado parcialmente nos experimentos iniciais. Um experimento com o protocolo completo é realizado e os resultados encontram-se na Tabela 6.6. Neste experimento as primitivas testadas são densidade de *pixels*, pontos de pressão, início e fim abrupto e segmentos de tremor.

Tabela 6.6: Resultados com a máxima combinação da sub-base de 40 autores.

| Tipo do Teste | Falsa Rejeição Erro Tipo I (%) | Falsa Aceitação Erro Tipo II (%) | | | Erro Total (%) |
|------------------|-----------------------------------|-------------------------------------|--------|------------|-------------------|
| | Genuínas | Simples | Servis | Aleatórias | Total |
| Voto Majoritário | 8,67 | 0,00 | 18,33 | 2,03 | 7,28 |

6.2.3. Balanceamento do Número de Amostras de Cada Classe

Com base nos estudos da seção 2.5.3.1, que trata do balanceamento das classes, é executado outro experimento com o objetivo de definir melhor a cardinalidade do número de amostras na abordagem. O protocolo da Tabela 6.2 dos experimentos iniciais serve de base para este experimento, porém é selecionado um número reduzido de amostras aleatórias. A técnica de ‘*downsizing*’ [JAPKOWICZ, 2000] é empregada conforme Tabela 6.7. Desta forma o número de amostras falsas passa para 253, procurando equiparar o tamanho das classes. Já no ‘*upsizing*’ [JAPKOWICZ, 2000] é aumentado o número de amostras dos mesmos autores para 840 procurando equiparar as classes. Os resultados demonstram que o melhor desempenho em termos de taxa de erro total é para as classes desbalanceadas, em específico para a base de dados testada com 780 amostras falsas e 240 verdadeiras, de acordo com a Tabela 6.7.

Tabela 6.7: Resultados com variação do número de amostras por classe.

| Técnica | Treinamento | | Teste | | | | Erro Total (%) |
|-----------------------|----------------------|--------------------|--------------------------------------|--|--------|------------|-------------------|
| | | | Falsa Rejeição Erro Tipo I (%) | Falsa Aceitação Erro Tipo II (%) | | | |
| | Amostras Genuínas | Amostras Falsas | Verdadeiras | Simples | Servis | Aleatórias | Total |
| desbalanceada | 240 | 780 | 11,00 | 5,33 | 37,00 | 5,42 | 14,68 |
| ‘ <i>downsizing</i> ’ | 240 | 253 | 3,00 | 9,00 | 51,33 | 16,95 | 20,07 |
| ‘ <i>upsizing</i> ’ | 840 | 780 | 4,33 | 15,93 | 54,40 | 18,03 | 23,17 |

6.2.4. Seleção do Conjunto de Primitivas

Nesta etapa são testadas todas as primitivas descritas na Tabela 4.1. Uma seleção das melhores primitivas mostra-se necessária, desta forma primitivas que não agregam poder discriminatório no treinamento são desconsideradas. Para este experimento a técnica utilizada é a FFS (*Forward Feature Selection*) [JOSSO et al., 2001], a qual descarta a possibilidade de se testar todos os subconjuntos ou combinações de primitivas. Apesar de ser esta a maneira ideal, o teste com todas as primitivas cria um enorme número de combinações aumentando o esforço computacional.

A técnica FFS [JOSSO et al., 2001] consiste em unir as primitivas com melhor desempenho individual. Este método não garante o melhor conjunto, mas pode ser uma boa maneira de selecionar algumas primitivas iniciais. Na busca de um melhor aproveitamento, agrega-se os melhores desempenhos e desta forma seleciona-se a primitiva com melhor desempenho, a partir daí testa-se com todas as demais. O melhor desempenho agrega-se à primitiva já selecionada. Novamente testa-se todas as primitivas restantes com o conjunto selecionado agregando a primitiva com melhor desempenho, e assim sucessivamente até que todos os testes sejam efetuados.

O objetivo final é avaliar a eficácia das primitivas separadamente e coletivamente. Para este experimento, o protocolo utilizado é o da Tabela 6.2 dos experimentos iniciais, porém parcialmente, ou seja, utiliza-se um sub-conjunto de 10 autores ao invés dos 40 para o treinamento, validação e teste. A redução de autores é com o intuito de otimizar o tempo de resposta para os experimentos iniciais. Os resultados encontram-se ordenados pelos melhores desempenhos conforme Tabela 6.8.

Tabela 6.8: Resultado da seleção do melhor conjunto de primitivas.

| Primitiva | Erro Tipo I (%) | Erro Tipo II (%) | | | Erro Médio (%) |
|---------------------------------------|-----------------|------------------|--------------|-------------|----------------|
| | | Simples | Simulada | Aleatória | |
| Dens/Press/Trem/Curv | 21,23 | 3,00 | 18,00 | 1,00 | 10,81 |
| Dens/Press/Trem/Curv/Par | 26,21 | 2,67 | 16,15 | 1,00 | 11,50 |
| Dens/Press/Incli | 26,01 | 5,67 | 15,01 | 0,36 | 11,76 |
| Dens/Press/Trem | 24,15 | 4,33 | 16,67 | 2,00 | 11,78 |
| Dens/Press | 26,21 | 5,67 | 13,67 | 1,67 | 11,81 |
| Dens/Press/Trem/Curv/Grav | 25,55 | 2,33 | 20,67 | 1,16 | 12,42 |
| Dens/Press/Trem/Curv/Incli | 22,01 | 6,67 | 21,00 | 2,04 | 12,93 |
| Dens/Press/Trem/Curv/Par/Incli | 22,00 | 3,33 | 23,03 | 3,90 | 13,06 |
| Dens/Press/Trem/Grav | 25,00 | 2,33 | 22,33 | 3,64 | 13,32 |
| Densidade | 33,01 | 3,00 | 17,70 | 0,27 | 13,50 |
| Dens/Press/Trem/Inicio/Grav/Incli/Par | 26,00 | 3,00 | 22,00 | 3,01 | 13,50 |
| Pressão | 42,03 | 1,00 | 12,03 | 0,36 | 13,86 |
| Press/Trem/Curv/Grav/Incli/Par | 25,00 | 2,00 | 23,67 | 5,06 | 13,93 |
| Dens/Press/Trem/Incli | 24,00 | 7,33 | 22,67 | 2,15 | 14,03 |
| Dens/Press/Trem/Par | 18,67 | 10,33 | 30,00 | 1,33 | 15,08 |
| Inclinação | 48,23 | 2,00 | 14,00 | 3,47 | 16,92 |
| Tremor | 49,15 | 2,33 | 15,03 | 1,69 | 17,05 |
| Gravidade | 68,00 | 4,33 | 12,03 | 0,44 | 21,20 |
| Inicio | 58,55 | 2,01 | 20,03 | 6,40 | 21,74 |
| Curvatura | 97,00 | 4,00 | 0,00 | 2,13 | 25,78 |

6.2.5. Aumento na Quantidade de Autores e Variação nas Amostras

Testes estatísticos requerem mútua independência dos dados, porém nos experimentos realizados esta premissa é quebrada, pelo número elevado de amostras do mesmo autor que o processo incorpora. Este excesso de amostras dificulta o poder de generalização no treinamento comprometendo os resultados.

A solução para este problema é a diminuição das amostras genuínas de cada autor nos conjuntos de treinamento, como também a incorporação de 140 novos autores na base de dados. Outra solução é diminuir a quantidade de amostras aleatórias, tentando minimizar o desbalanceamento elevado.

Em experimentos a partir do treinamento com 2 até 7 assinaturas genuínas, os melhores resultados são com 4 assinaturas genuínas, gerando 6 combinações de amostras genuínas.

A estrutura apresentada neste experimento é a que demonstra ser mais promissora. Desta forma a equação (4.6) tem o número de assinaturas m fixado em 4:

$$n_{(+)} = n \cdot C_2^m, \quad \text{para } m = 4. \quad (6.1)$$

Para uma diminuição mais significativa do número de amostras aleatórias no treinamento, visando um melhor balanceamento entre as amostras, a equação (4.7) sofre uma variação:

$$n_{(-)} = m^2 \cdot C_2^n, \quad \text{para } m = 1, \quad (6.2)$$

desta forma, gerando o menor número possível de combinações de amostras aleatórias e preservando pelo menos uma amostra aleatória de cada autor.

Com a diminuição de amostras genuínas, a eficiência do método está no aumento do número de autores. O protocolo de teste usado é o da Tabela 6.4, utilizada nos experimentos finais. A Tabela 6.9 demonstra os resultados obtidos com 4 assinaturas genuínas por autor, como também um comparativo da evolução na taxa de erro à medida que se incorpora novos autores.

Tabela 6.9: Resultado do aumento da quantidade da autores e variação nas quantidade de amostras.

| Variação das amostras genuínas e número de autores | | | | | | | | | |
|--|-------------|-----------|----------------------|---------------|-----------------|------------------|--------------|-------------|----------------|
| Treinamento | | | | | Teste | | | | |
| Autores | Assinaturas | | Amostras Treinamento | | 60 autores | | | | |
| | Genuína | Aleatória | Genuína | Aleatória | Erro Tipo I (%) | Erro Tipo II (%) | | | Erro Total (%) |
| | | | | | | Genuína | Simples | Simulada | |
| 40 | 4 | 1 | 240 | 780 | 12,33 | 0,33 | 32,00 | 3,73 | 12,09 |
| 50 | 4 | 1 | 300 | 1.225 | 10,33 | 1,33 | 30,67 | 6,78 | 12,27 |
| 60 | 4 | 1 | 360 | 1.770 | 7,00 | 4,67 | 36,33 | 8,14 | 14,03 |
| 70 | 4 | 1 | 420 | 2.415 | 6,67 | 3,33 | 36,33 | 7,12 | 13,36 |
| 80 | 4 | 1 | 480 | 3.160 | 8,00 | 2,00 | 32,67 | 6,78 | 12,36 |
| 90 | 4 | 1 | 540 | 4.005 | 8,33 | 2,33 | 36,67 | 8,14 | 13,86 |
| 100 | 4 | 1 | 600 | 4.950 | 8,33 | 2,00 | 33,00 | 8,47 | 12,95 |
| 110 | 4 | 1 | 660 | 5.995 | 8,00 | 2,67 | 33,00 | 9,49 | 13,29 |
| 120 | 4 | 1 | 720 | 7.140 | 8,33 | 3,67 | 27,00 | 7,80 | 11,70 |
| 130 | 4 | 1 | 780 | 8.385 | 6,00 | 5,00 | 26,00 | 8,14 | 11,28 |
| 140 | 4 | 1 | 840 | 9.730 | 7,00 | 1,33 | 25,67 | 6,78 | 10,19 |
| 150 | 4 | 1 | 900 | 11.175 | 11,33 | 1,67 | 19,00 | 6,10 | 9,52 |
| 160 | 4 | 1 | 960 | 12.720 | 11,33 | 2,00 | 14,67 | 5,42 | 8,35 |
| 170 | 4 | 1 | 1.020 | 14.365 | 10,67 | 2,67 | 16,67 | 5,76 | 8,94 |
| 180 | 4 | 1 | 1.080 | 16.110 | 10,33 | 1,67 | 15,67 | 4,41 | 8,02 |

6.2.6. Limiares de Rejeição e Aceitação

De acordo com a figura 5.15, dois limiares de rejeição são encontrados, tendo por base as probabilidades que o classificador retorna do conjunto de validação. Para o limiar T_1 , é encontrado o valor de 0,5546, já para o limiar T_2 , 0,4968. O critério usado é de que todo valor maior que T_2 e menor que T_1 que corresponde à taxa de rejeição R_t pode ser aplicado no processo de decisão da abordagem.

Como visto na seção 4.5.1, o desempenho do classificador é medido pela média da taxa de erro total, a qual pode ser expressa de acordo com Drouhard [DROUHARD et al., 1994] por E_t em termos de E_1 (taxa de erro tipo I), E_2 (taxa de erro tipo II) e $P[w_i]$ (probabilidade a priori da classe w_i), como :

$$E_t = E_1 \cdot P[w_1] + E_2 \cdot P[w_2]. \quad (6.3)$$

A taxa total de rejeição R_t , é obtida com uma equação semelhante à equação (6.3), com a taxa de erro E_i substituída pela taxa de rejeição R_i (R_1 rejeição de assinaturas genuínas e R_2 rejeição de falsificações aleatórias). Como demonstra Drouhard [DROUHARD et al., 1994], a taxa de rejeição e o erro total podem ser integrados em um único parâmetro, o fator de confiabilidade:

$$RF = 1 - \frac{E_t}{100 - R_t} \quad (6.4)$$

desta forma a melhor avaliação estatística dos resultados do classificador é encontrada.

De acordo com os limiares estabelecidos a taxa de rejeição total R_t do experimento é de 1,34% e sendo o erro médio total E_t de 7,48%, o fator de confiabilidade encontrado é $RF = 0,9241$. Já sem limiares de rejeição o fator de confiabilidade é de $RF = 0,9198$. A Tabela 6.10 apresenta os resultados com base na Tabela 6.4 que se utiliza nos experimentos finais.

A introdução do critério de rejeição na abordagem proposta melhora tanto o fator de confiabilidade, quanto o erro Tipo I, o erro Tipo II e a taxa de erro total.

Tabela 6.10: Resultados com o uso de limiares de rejeição.

| | Falsa Rejeição Erro Tipo I (%) | Falsa Aceitação Erro Tipo II (%) | | | Erro Total (%) | Fator Confiabilidade |
|--------------------------|--------------------------------------|--|--------|------------|-------------------|-------------------------|
| | Genuínas | Simples | Servis | Aleatórias | Total | |
| Com limiares de rejeição | 9,79 | 1,33 | 14,72 | 4,09 | 7,48 | 0,9241 |
| Sem limiares de rejeição | 10,33 | 1,67 | 15,67 | 4,41 | 8,02 | 0,9198 |

6.2.7. SVM

Com o objetivo de melhorar as taxas de erro, um experimento com o SVM é realizado tomando como base o protocolo da Tabela 6.4. A dificuldade no ajuste de parâmetros livres com relação a pesos, constante de aprendizagem encontrado na rede MLP, é minimizada na seleção do modelo do SVM, restringindo-se somente à escolha do *kernel*, e a penalidade representada pelo parâmetro *C*. O número de vetores de suporte encontrado no experimento com os sub-conjuntos de 40 até 180 autores varia de 337 até 1.345. Os resultados estão descritos na Tabela 6.11.

Tabela 6.11: Resultado comparativo de rede MLP com SVM.

| Variação de amostras genuínas número de autores | | | | | | | | | | |
|---|-----------------|------------------|--------------|-------------|----------------|-----------------|------------------|--------------|-------------|----------------|
| Autores | MLP | | | | | SVM | | | | |
| | Erro Tipo I (%) | Erro Tipo II (%) | | | Erro Médio (%) | Erro Tipo I (%) | Erro Tipo II (%) | | | Erro Médio (%) |
| | Genuína | Simples | Simulada | Aleatória | Total | Genuína | Simples | Simulada | Aleatória | Total |
| 40 | 12,33 | 0,33 | 32,00 | 3,73 | 12,09 | 10,33 | 1,00 | 31,44 | 7,80 | 12,64 |
| 50 | 10,33 | 1,33 | 30,67 | 6,78 | 12,77 | 10,67 | 1,67 | 29,77 | 6,78 | 12,22 |
| 60 | 7,00 | 4,67 | 36,33 | 8,14 | 14,03 | 9,67 | 0,67 | 26,76 | 6,78 | 10,97 |
| 70 | 6,67 | 3,33 | 36,33 | 7,12 | 13,36 | 10,00 | 0,33 | 25,42 | 5,76 | 10,37 |
| 80 | 8,00 | 2,00 | 32,67 | 6,78 | 11,86 | 9,33 | 0,67 | 24,41 | 5,08 | 9,87 |
| 90 | 8,33 | 2,33 | 36,67 | 8,14 | 13,86 | 9,33 | 0,00 | 28,43 | 4,75 | 10,62 |
| 100 | 8,33 | 2,00 | 33,00 | 8,47 | 12,95 | 9,33 | 0,00 | 25,75 | 4,07 | 9,79 |
| 110 | 8,00 | 2,67 | 32,00 | 9,49 | 13,04 | 9,00 | 0,67 | 24,41 | 5,76 | 9,96 |
| 120 | 8,33 | 3,67 | 27,00 | 7,80 | 11,70 | 8,33 | 0,33 | 23,08 | 5,76 | 9,37 |
| 130 | 6,00 | 5,00 | 26,00 | 8,14 | 11,28 | 9,00 | 0,00 | 19,40 | 4,75 | 8,28 |
| 140 | 7,00 | 1,33 | 25,67 | 6,78 | 10,19 | 10,67 | 0,33 | 19,40 | 5,08 | 8,87 |
| 150 | 11,33 | 1,67 | 19,00 | 6,10 | 9,52 | 11,33 | 0,33 | 17,73 | 5,76 | 8,78 |
| 160 | 11,33 | 2,00 | 14,67 | 5,42 | 8,35 | 12,67 | 0,00 | 18,06 | 4,07 | 8,70 |
| 170 | 10,67 | 2,67 | 16,67 | 5,76 | 8,94 | 12,00 | 0,33 | 17,39 | 4,07 | 8,44 |
| 180 | 10,33 | 1,67 | 15,67 | 4,41 | 8,02 | 11,33 | 0,00 | 16,72 | 3,39 | 7,86 |

6.2.8. Comparativo do Método Proposto com a Análise Humana

Baseado em Fang [FANG et al., 2003] um comparativo de desempenho com seres humanos é proposto. Para este fim, dois voluntários não especialistas são recrutados para executar a tarefa de verificação de assinaturas, estando os mesmos familiarizados com os métodos de verificação de assinaturas.

Tentando simular a maneira com que o computador aprende as características das assinaturas e baseado no protocolo utilizado no processo de aprendizado, a sub-base de 40 autores (1.600 assinaturas) é disponibilizada para os voluntários se familiarizarem com as peculiaridades e variações das assinaturas genuínas, como também com as falsificações aleatórias. Ou seja, uma assinatura genuína em relação às genuínas de outros autores, desta forma seguindo à risca o método de aprendizagem.

No processo de verificação, incluindo os autores não-vistos, a base de 60 autores é usada. Para aumentar o grau de dificuldade, somente assinaturas genuínas e falsificações simuladas são utilizadas. Durante o trabalho de verificação 50 combinações aleatórias entre 10 assinaturas genuínas e 10 falsificações simuladas, para cada um dos 60 autores, são mostradas na tela do computador de tempo em tempo.

Para este experimento são executadas um total de 3.000 avaliações compostas de 1.500 genuínas e 1.500 falsificações simuladas. O método consiste em comparar uma assinatura questionada com a assinatura genuína de referência, com o objetivo de determinar somente se as duas assinaturas pertencem ao mesmo indivíduo ou não, conforme o exemplo na Figura 6.1.




Figura.6.1: Exemplo do processo de comparação humana na similaridade entre 2 assinaturas.

Com relação às probabilidades, é preciso mencionar o fato da equiparação do número de assinaturas genuínas e falsificações simuladas. A probabilidade *a priori* de cada assinatura questionada pertencer ao mesmo autor é de 0,5.

A taxa de erro média dos dois voluntários encontrada é de 11,48% e 12,71%. A média global da taxa de erro dos mesmos é 12,09%. Comparado com o melhor desempenho da abordagem de 13,00% sem considerar os limiares de rejeição e aceitação, o resultado demonstra a taxa de erro em níveis semelhantes à análise humana. Os resultados estão resumidos na Tabela 6.12.

Tabela 6.12: Resultado da avaliação humana do processo de verificação de assinaturas em comparação com a abordagem proposta.

| Voluntários | Taxa Erro Falsa Rejeição (%) | Taxa Erro Falsa Aceitação (%) | Taxa Erro Médio (%) |
|--------------------|------------------------------|-------------------------------|---------------------|
| | Genuína | Falsificação Simulada | |
| Voluntário 1 | 7,77 | 15,18 | 11,48 |
| Voluntário 2 | 4,62 | 20,80 | 12,71 |
| Média Geral | 6,19 | 17,99 | 12,09 |
| Abordagem Proposta | 10,33 | 15,67 | 13,00 |

6.3. Estimando a Probabilidade do Erro

A probabilidade do erro da abordagem proposta é calculada para o protocolo de teste da Tabela 6.4, usada nos experimentos da rede MLP e do SVM. Sendo a população de interesse composta por pares de assinaturas produzidas pelo mesmo autor $n_{(+)}$ e pares de assinaturas produzidas por autores diferentes $n_{(-)}$. Uma amostra $n_{(+)}$ é obtida do par de duas assinaturas produzidas pelo mesmo autor. Uma amostra de $n_{(-)}$ é obtida do par de assinaturas produzidas por autores diferentes. Há dois tipos de probabilidades de erros relevantes para estimar o intervalo de confiança. A probabilidade do erro com que o sistema classifica duas assinaturas como membros de $n_{(+)}$ embora sejam membros de $n_{(-)}$, erro Tipo I, e a probabilidade do erro com que o sistema classifica duas assinaturas como membros de $n_{(-)}$ embora sejam membros de $n_{(+)}$, erro Tipo II.

Em adição aos erros estimados, ou seja, a estimativa por pontos, a previsão do desempenho é medida através de intervalos de confiança, os quais estabelecem uma margem

para mais e para menos para taxa de erro estimado. Segundo Guerra [GUERRA & DONAIRE, 1991], a estimação por intervalos fornece uma probabilidade para o verdadeiro valor do parâmetro. Algumas definições são:

- O intervalo $t_1 \leq p \leq t_2$ é denominado de intervalo de confiança (I.C.) ;
- Os extremos desse intervalo t_1 e t_2 são denominados de limites de confiança;
- A probabilidade conhecida $(1 - \alpha)$ é denominada de nível de confiança;
- O valor α é chamado de nível de significância e representa o erro que se está cometendo quando se afirma que a probabilidade do intervalo contém o verdadeiro valor do parâmetro populacional p é $(1 - \alpha)$.

A escolha do nível de confiança depende da precisão com que se deseja estimar o parâmetro. O nível utilizado normalmente varia de 90% a 99%, sendo que o aumento da confiança no intervalo implica o aumento de sua amplitude. Quanto maior for o nível de confiança (ou seja, quanto menor for o nível de significância), mais amplo será o intervalo.

Tomando como base as taxas de erro retornadas pela abordagem f , sendo o número de amostras da classe analisada n , relativamente grande, pressupõe uma distribuição normal e um desvio padrão populacional conhecido, sendo $z_{\alpha/2}$ o valor crítico da tabela de distribuição normal para o nível de confiança desejado. O intervalo de confiança para a proporção populacional p é calculado por [GUERRA & DONAIRE, 1991]:

$$f - z_{\alpha/2} \cdot \sqrt{\frac{f(1-f)}{n}} \leq p \leq f + z_{\alpha/2} \cdot \sqrt{\frac{f(1-f)}{n}} \quad (6.5)$$

Para as melhores taxas de erro encontradas na Tabela 6.11. aplica-se a equação (6.5), com um nível de confiança de 95%, ou seja, $\alpha = 0,05$, $z_{\alpha/2} \cong 1,960$ e $n = 1195$, que representa o número de decisões do teste com o voto majoritário. Os resultados encontram-se na Tabela 6.13.

Tabela 6.13: Estimação por intervalos das taxas de erro do conjunto de teste.

| Classificador | Intervalo de Confiança | | | | | |
|---------------|--------------------------|-------------|-------------------------|------------|-------------------------|------------|
| | Erro Tipo I (%) | | Erro Tipo II (%) | | Erro Total (%) | |
| MLP | $6,89 \leq p \leq 13,77$ | $f = 10,33$ | $5,55 \leq p \leq 8,95$ | $f = 7,25$ | $6,48 \leq p \leq 9,56$ | $f = 8,02$ |
| SVM | $7,74 \leq p \leq 14,92$ | $f = 11,33$ | $5,06 \leq p \leq 8,34$ | $f = 6,70$ | $6,33 \leq p \leq 9,39$ | $f = 7,86$ |

O objetivo do trabalho não é escolher qual o melhor classificador, porém um comparativo entre os mesmos é testado a fim de direcionar o trabalho na busca de taxas de

erros mais aceitáveis. Baseado nas taxas de erro encontrado na Tabela 6.11, é aplicado o teste de hipóteses de duas proporções e o teste de McNemar [DIETTERICH, 1998]. Ambos usados para demonstrar se um algoritmo de classificação possui resultados semelhantes a outro com certo grau de incerteza.

O teste é aplicado comparando a rede MLP com o SVM, levando em consideração a tabela de contingência, conforme a Tabela 6.14, necessária para ambos os testes.

A seguinte hipótese é testada: H_0 : indicando que não há diferença significativa entre os classificadores de rede Neural e SVM na abordagem proposta; e H_1 : indicando que os classificadores demonstram desempenhos diferentes para a abordagem proposta.

Tabela 6.14: Tabela de Contingência 2×2 .

| | |
|---|--|
| N_{00} :Número de amostras classificadas incorretamente por ambos classificadores | N_{01} : Número de amostras classificadas incorretamente pelo SVM mas não pela rede MLP. |
| N_{10} : Número de amostras classificadas incorretamente pela rede MLP mas não pelo SVM | N_{11} : Número de amostras classificadas corretamente por ambos classificadores |

O teste de McNemar tem uma distribuição qui-quadrado com 1 grau de liberdade [DIETTERICH, 1998]. A quantidade de χ^2 é calculado de acordo com:

$$\chi^2 = \frac{(n_{01} - n_{10} - 1)^2}{n_{01} + n_{10}} \quad (6.6)$$

A hipótese nula assume que o desempenho de dois algoritmos diferentes é o mesmo, isto é $n_{10} = n_{01}$. O *valor-P* de um valor qui-quadrado é calculado com o teste de McNemar, de acordo com a tabela de distribuição qui-quadrado [GUERRA & DONAIRE, 1991]. Quando o *valor-P* apresentar valores menores, ele sugere que a hipótese nula é improvável de ser verdadeira. Não se pode rejeitar a hipótese nula se a probabilidade $\chi^2 \geq 3,84$ que corresponde ao *valor-P* menor que 0,05 [DIETTERICH, 1998]. Estes valores correspondem a um teste significativo segundo Guerra & Donaire [GUERRA & DONAIRE, 1991].

O resultado da comparação da rede MLP com o SVM gera para χ^2 o valor de 0,00526 e para *valor-P* 0,9422, sendo superior a 0,05, demonstrando que a hipótese nula não pode ser rejeitada. Isto sugere que o uso da rede MLP e do SVM como classificadores, nesta aplicação, pode alcançar resultados semelhantes.

Outra forma simples de testar a hipótese comparativa dos classificadores que leva em consideração a falta de independência dos dados, pelo fato dos resultados serem obtidos a partir do mesmo conjunto de teste, é através do uso do teste de diferença de duas proporções [DIETTERICH, 1998]. Seja a probabilidade a *posteriori* da taxa de erro total da rede MLP e do SVM representados por P_{MLP} e P_{SVM} , respectivamente, as quais se referem à má classificação de n amostras do conjunto de teste. Como n é uma variável aleatória binomial, pode-se aproximar uma distribuição normal devido ao valor razoável de n . Pelo fato de P_{MLP} e P_{SVM} serem dependentes do mesmo conjunto de teste, z que representa o grau de diferença entre a rede MLP e o SVM, é calculado como:

$$z = \frac{n \cdot |P_{MLP} - P_{SVM}|}{\sqrt{n_{01} + n_{10}}} \quad (6.7)$$

o qual tem aproximadamente uma distribuição normal. A hipótese nula será rejeitada se $|z| > Z_{0,950} = 1,96$, ou seja, se o valor de α de acordo com a tabela normal distribuída for menor que 0,05 [GUERRA & DONAIRE, 1991], o qual corresponde a um teste provavelmente significativo.

O resultado da comparação da rede MLP com o SVM em termos do valor de z gera 0,1387 com valor α de 0,8897 sendo superior a 0,05, demonstrando desta forma que a hipótese nula não pode ser rejeitada e sugerindo desempenhos iguais na rede MLP e no SVM.

6.4. Comentários Finais

Experimentos realizados com o treinamento de falsificações simples e simuladas demonstram que o ganho em termos de resultados não é significativo. Estes testes são desconsiderados pelo fato da aquisição deste tipo de amostra ser dificultoso e discutível.

O resultado do experimento demonstrado na Tabela 6.6 apresenta uma taxa de erro médio superior aos demais experimentos, porém o esforço computacional deste experimento, não justifica o ganho em termos de desempenho.

Com relação ao uso de medidas de distâncias, experimentos demonstram que a distância euclidiana apresenta os melhores resultados, conforme Tabela B.1 no Anexo B. O ganho mínimo em termos de resultado dos experimentos não justifica um estudo mais aprofundado com relação à outras medidas de distâncias.

No experimento que trata os limiares de rejeição e aceitação, um aumento nos limiares acarreta melhores taxas de erro, em contrapartida, há uma rejeição maior. O uso de limiares de rejeição também é discutível, pois de acordo com Drouhard [DROUHARD et al., 1994], no caso extremo, o classificador com uso de limiares pode ter uma taxa de erro de 0% mas terá uma taxa de rejeição de 100%.

Para os casos de falsificações simuladas, os índices obtidos pelas redes não são sempre satisfatórios. Este fato pode ser explicado pela dificuldade inerente à construção de um sistema de verificação que rejeite este tipo de assinatura. Muitas vezes, até a análise humana não consegue fazer a distinção entre assinaturas genuínas e assinaturas falsas simuladas.

Já os melhores resultados obtidos com a utilização das falsificações aleatórias, deve-se também ao fato das mesmas fazerem parte do treinamento como a maioria das amostras.

O fato de se ter mínimos locais, dificulta o processo de treinamento em redes MLP, o qual pode ser minimizado com o uso do SVM. Ambos os classificadores fornecem boa precisão nos resultados. Em termos de performance, ambos classificadores também demonstram ser semelhantes para o problema proposto, de acordo com o teste de hipótese para duas proporções e o teste de McNemar.

O alto nível de erro na falsa rejeição (erro Tipo I, em torno de 10%) é produzido pela falta de habilidade do modelo de absorver a variação intrapessoal, como também por um número reduzido de autores usados na fase de treinamento.

A redução do número de amostras aleatórias do protocolo dos experimentos iniciais para os experimentos finais não reflete perda no desempenho. A união deste conjunto excluído não traz nenhum acréscimo, ou poder discriminante com o aumento do protocolo. Pelo contrário, quando muitas amostras de um mesmo autor são usadas no treinamento, o excesso destas amostras faz com que o sistema especifique o autor, perdendo o poder de generalização, ou seja, especialize as variações intrapessoal deste autor.

Capítulo 7

7. Conclusão e Trabalhos Futuros

Neste capítulo são apresentadas as conclusões obtidas com o trabalho, bem como sugestões para trabalhos futuros.

7.1. Conclusão

O trabalho proposto apresenta uma nova abordagem para a verificação de assinaturas estáticas baseadas nos preceitos da grafoscopia. Depois de detalhada a metodologia de extração de características, transformação dicotômica com o uso da distância euclidiana aplicada sobre as primitivas, produção do modelo e processo de decisão baseado na visão pericial, com os experimentos para validá-la estatisticamente, estas são as conclusões a que se chega:

- O objetivo principal do método proposto, a verificação automática de assinaturas, é atingido e apresenta resultados promissores, em torno de 8% na média de taxa de erro total, sem limiares de rejeição. O método é robusto para os diversos tipos de assinaturas e para as falsificações, principalmente nas falsificações simples e aleatórias, como também demonstra resultados semelhantes à análise humana.
- Por se tratar de um modelo genérico, o mesmo gera um menor esforço computacional pela não necessidade de re-treinamento. Esta característica minimiza a complexidade que envolve as etapas de um sistema de verificação de assinaturas.
- A problemática do número excessivo de assinaturas genuínas por autor no processo de treinamento discutido na maioria dos trabalhos apresentados no capítulo 3 pode ser superada com a abordagem proposta. No trabalho proposto é usada somente 5 assinaturas genuínas por autor no processo de decisão.

- A abordagem proposta simula a análise grafotécnica pericial manual tanto na análise das características quanto no processo de decisão, demonstrando de forma clara a comparação entre uma assinatura questionada e uma verdadeira através da visão do perito, deste modo procurando simular um ambiente prático que represente o mundo real.
- O modelo genérico, ao contrário dos trabalhos apresentados no capítulo 3, os quais são baseados em modelos pessoais, representa uma nova visão no tratamento da problemática da verificação de assinaturas estáticas e apresenta-se como promissor tanto pelos resultados, quanto pela abordagem adotada, a qual utiliza somente duas classes possíveis: autoria e não autoria em todo o processo.

O principal propósito deste trabalho é reportar um método robusto de verificação de assinaturas baseado nos princípios da grafoscopia. Dois importantes pontos emergem. O primeiro é o potencial apresentado pelo método de reduzir o número de amostras de assinaturas necessárias no treinamento e na validação. O segundo é a habilidade do modelo de absorver novos autores sem gerar novos modelos pessoais. Em termos de taxa de erro, os resultados mostrados são promissores, especialmente em termos de falsificações simples e aleatórias. É possível notar a capacidade da rede MLP e do SVM de classificar diferentes tipos de falsificações, sem prévio conhecimento das mesmas.

7.2. Trabalhos Futuros

Os trabalhos futuros propostos nesta área de pesquisa são os seguintes:

- A base de dados de um modo geral é composta de uma quantidade elevada de assinaturas, gerando por autor um número elevado de amostras no processo de aprendizagem pela combinação de pares de assinaturas. Porém, um aumento na quantidade de autores, com uma quantidade mínima de assinaturas, demonstra uma tendência na melhora de performance, o que pode ser explorado.
- Embora o método não tenha mostrado resultados experimentais superiores aos métodos existentes, há a possibilidade de combiná-lo com outros métodos para alcançar melhores resultados. Nenhum método simples pode resolver o problema de

verificação de assinaturas perfeitamente, e soluções práticas são frequentemente derivadas da combinação de diferentes métodos [FANG et al., 2003]. Abordagens locais tratam particularidades do traçado de autores em específico, sendo fundamentais em métodos que utilizam modelos pessoais. Um tratamento global pode fornecer um poder discriminante maior para uma abordagem mais genérica, a qual pode ser combinada em uma estratégia multi-estágio no processo de decisão, conforme [SANSONE & VENTO, 2000]. O primeiro estágio trataria as falsificações simples e aleatória e enquanto outro estágio trataria as falsificação simuladas e as amostras genuínas.

8. Referências Bibliográficas

- [ABUTALEB, 1989] ABUTALEB, A. S. *Automatic Thresholding of Gray-Level Pictures Using Two Dimensional Entropy*. Computers Graphics & Image Processing, No.47, 1989, 22-32 p.
- [BAJAJ & CHAUDHURY, 1996] BAJAJ, R.; CHAUDHURY, S. *Signature Verification Using Multiple Neural Classifiers*. Pattern Recognition. Vol. 30, No. 1, 1996, 1-7 p.
- [BALTZAKIS & PAPAMARKOS, 2000] BALTZAKIS, H; PAPAMARKOS, N. *A New Signature Verification Technique Based on a Two-Stage Neural Network Classifier*. Engineering Applications of Artificial Intelligence. Nr.14, 2000, 95-103 p.
- [BARBEAU et al., 2002] BARBEAU, J.; VIGNES-LEBBE, R.; STAMON, G. *A Signature based on Delaunay Graph and Co-occurrence Matriz*. In Proceedings of the ICCVG'2002, Pologne, 2002, 1-8 p.
- [CAVALCANTI et al., 2002] CAVALCANTI, G. C.; DORIA, R. C.; FILHO, E.C.B.C. *Features Selection for Off-Line Recognition of Different Size Signatures*. International Workshop on Neural Networks for Signal Processing (NNSP2002), Martigny, Velais-Switzerland, 2002, 335-364 p.
- [CHA, 2001] CHA, S. *Use of Distance Measures in Handwriting Analysis*. PhD Thesis, State University of New York at Buffalo, EUA, 2001.
- [CHAN & STOLFO, 1998] CHAN, P.; STOLFO, S. *Learning with Non-uniform Class and Cost Distributions: Effects and a Distributed Multi-Classifer Approach*. Workshop on Distributed Data Mining, Notes KDD-98, Technical Report, 1998, 1-9 p.

- [CHUANG, 1977] CHUANG, P. C. *Machine Verification of Handwritten Signature Image*. Proc. Int. Conf. On Crime Countermeasures-Sci, J. S. Jackson and R. W. De Vore, University of Kentucky, Lexington, 1977, 105-109 p.
- [DENG et al., 1999] DENG, P.; LIAO, H. M.; HO, C. W.; TYAN, H.; *Wavelet-based Off-line Signature Verification*. Computer Vision and Image Understanding, Vol.76, no. 3, 1999, 173-190 p.
- [DIETTERICH, 1998] DIETTERICH, T. *Approximate statistical tests for comparing supervised classification learning algorithms*. Neural Computation, Vol.10, no. 7, 1998, 1895-1923 p.
- [DROUHARD et al., 1994] DROUHARD, J.; SABOURIN, R.; GODBOUT, M. *Evaluation of a Training Method and of Various Rejection Criteria for a Neural Network Classifier Used for Off-Line Signature Verification*. IEEE International Conference on Neural Networks, Orlando, Florida, 1994, 4294-4299 p.
- [DUDA & HART, 1973] DUDA, R. O.; HART, P. E. *Pattern Classification and scene analysis*. John Wiley & Sons Inc., 1973.
- [FANG et al., 2003] FANG, B.; LEUNG, Y. Y.; TANG, K. W.; TSE, P. C. K; KWOK, Y. K.; WONG, Y. K. *Off-Line Signature Verification by the tracking of feature and stroke positions*. Pattern Recognition, Vol.36, 2003, 91-101 p.
- [FAEZ et al., 1997] FAEZ, KARIM; DEHGHAN, MEHDI; FATHI, MAHMOOD. *Signature Verification Using Shape Descriptors and Multiple Neural Networks*. IEEE Tencon – Speech and Image Technologies for Computing and Telecommunications, 1997, 415-418 p.
- [FUJITA, 1998] FUJITA, O. *Statistical Estimation of the Number of Hidden Units for Feedforward Neural Networks*. Neural Networks, Vol. 11, 1998, 851-859 p.

- [FUMERA et al., 2000] FUMERA, G.; ROLI, F.; GIACINTO, G. *Reject Option with multiple thresholds*. Pattern Recognition. Vol. 33, 2000, 2099-2101 p.
- [GORI & SCARSELLI, 1998] GORI, M.; SCARSELLI, F. *Are Multilayer Perceptrons Adequate for Pattern Recognition and Verification?*. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 20, No. 11, 1998, 1121-1132 p.
- [GUERRA & DONAIRE, 1991] GUERRA, JOSÉ MAURI; DONAIRE, DENIS. *Estatística Indutiva teoria e aplicações*. Liv. Ciência e Tecnologia, 2.ed., São Paulo, 1992, 129-177 p.
- [HAYKIN, 2001] HAYKIN, SIMON. *Redes Neurais Princípios e prática*. Bookman, 2.ed., Porto Alegre, 2001.
- [HUANG & YAN, 1997] HUANG, K.; YAN, H. *Off-line Signature Verification Based on Geometric Feature Extraction and Neural Network Classification*. Pattern Recognition, Vol.30, No.1, 1997, 9-17 p.
- [JAPKOWICZ, 2000] JAPKOWICZ, N. *Learning from Imbalanced Data Sets: A Comparison of Various Solutions*. International Workshop on Learning from Imbalanced Data Sets, Technical Report WS-00-05, 2000.
- [JOACHIMS, 2000] JOACHIMS, T. *SVM^{light} is an implementation of Support Vector Machines (SVMs) in C*. Version 5.0, User Manual, University of Dortmund, 2000.
- [JUSTINO, 2001] JUSTINO, E. *O Grafismo e os Modelos Escondidos de Markov na Verificação Automática de Assinaturas*. Tese de Doutorado, Pontifícia Universidade Católica do Paraná, Brasil, 2001.
- [JOSSO et al., 2001] JOSSO, B.; BURTON, D.; LALOR, M. *Wavelet strategy for surface roughness analysis and characterisation*. Computer Methods in Applied Mechanics and Engineering, Vol. 191, 2001, 829-842 p.

- [JUSTINO, 2002] JUSTINO, E. *A Análise de Documentos Questionados*. Relatório Técnico para obtenção do grau de professor Titular. Pontifícia Universidade Católica do Paraná, Brasil, 2002.
- [JUSTINO et al., 2002] JUSTINO, E.; SABOURIN, R. ; BORTOLOZZI, FLAVIO. *The Interpersonal and Intrapersonal Variability Influences on Off-Line Signature Verification Using HMM*. 15th Brazilian Sumposium on Computer Graphics and Image Processing (SIBGRAPI'02), Fortaleza, Brazil, 2002, 197-202 p.
- [JUSTINO et al., 2003] JUSTINO, E.; SABOURIN, R. ; BORTOLOZZI, FLAVIO. *An Off-Line Signature Verification Method Based on SVM Classifier and Graphometric Features*. In Proceedings 15th International Conference on Advances in Pattern Recognition (ICAPR2003), Calcuta, India, aceito para publicação 11 Dezembro, 2003.
- [KHOLMATOV, 2003] KHOLMATOV, A. *A Biometric Identity Verification Using On-Line & Off-Line Signature Verification*. Master's Thesis, Sabanci University, 2003.
- [LAM & SUEN, 1997] LOUISA, L.; SUEN, C. *Application of Majority Voting to Pattern Recognition: An Analysis of Its Behavior and Performance*. IEEE Transactions on Systems, Man and Cybernetics, Vol.27, No.3, 1997, 553-568 p.
- [LAWRENCE et al., 1998] LAWRENCE, I. B.; BACK, A.; TSOI, A. C.; GILES, C. L. *Neural Network Classification and Prior Class Probabilities*. Tricks of the Trade, Lecture Notes in Computer Science State-of-the-Art Surveys, Springer Verlag, 1998, 299-314 p.
- [LEE, 1995] LEE, L. L. *Neural Approaches for Human Signature Verification*. Third International Conference on Document Analysis and Recognition ICDAR'95, Montreal, Canadá, 1995, 1055-1058 p.
- [LIPPMANN, 1987] LIPPMANN, R. P. *An Introduction to Computing with Neural Nets*. IEEE Acoustics, Speech and Signal Processing Magazine, Vol. 4, No. 2, 1987, 4-22 p.

- [MALAVIYA & PETERS, 1997] MALAVIYA, A.; PETERS, L. *Fuzzy Feature Description of Handwriting Patterns*. In Pattern Recognition, Vol. 30, No. 10, 1997, 1591-1604 p .
- [MARAR et al., 2002] MARAR, J.F.; RODRIGUES, R.F.; COSTA, D.N. *Detecção de Falsificação em Assinaturas Humanas Baseada em Redes Neurais Artificiais*. II Congresso Brasileiro de Computação, Brasil, 2002.
- [MUKKAMALA et al., 2002] MUKKAMALA, S.; JANOSKI, G; SUNG, A.H. *Intrusion Detection Using Neural Networks and Support Vectors Machines*. Proceedings of IEEE International Joint Conference on Neural Networks, IEEE Computer Society Press, EUA, 2002, 1702-1707 p.
- [MOODY, 1994] MOODY, J. *Prediction Risk and Architecture Selection for Neural Networks*. From statistics to Neural Netowrks: Theory and Pattern Recognition Applications, V.Cherkassky J.Friedman and H. Wechsler (eds), Springer-Verlage, 1994, 147-165 p.
- [MURSHED et al., 1995] MURSHED, N.; BORTOLOZZI, F.; SABOURIN, R. *Off-Line Signature Verification Using Fuzzy ARTMAP Neural Networks*. IEEE International Conference on Neural Networks, Perth, Austrália, 1995, 2179-2184 p.
- [NOVAES, 2002] NOVAES, U. R. *Agrupamento de Dados através de Algoritmos Swarm*. Dissertação de Mestrado.Universidade Federal do Rio de Janeiro, Brasil, 2002.
- [OH & SUEN, 2002] OH, I.; SUEN, C. Y. *A Class-Modular Feedforward Neural Network for Handwriting Recognition*. Pattern Recognition, Vol. 35, 2002, 229-244 p.
- [OSUNA et al., 1997] OSUNA, E.; FREUD, R.; GIROSI, F. *Support Vector Machines: Training and Applications*. MIT Artificial Intelligence Memo 1602; MIT A. I. Lab, 1997.
- [OTSU, 1979] OTSU, N. *A Threshold Selection Method from Gray-level Histograms*. IEEE Transactions on Systems, Man and Cybernetics, v. SMC 9, No.1 ,1979, 62-66 p.

- [PETERSEN et al., 2002] PETERSEN, M. E.; RIDDER, D.; HANDELS, H. *Image Processing with Neural Networks – A review*. Pattern Recognition, Vol. 35, 2002, 2279-2301 p.
- [PLUTOWSKI, 1996] PLOTOWSKI, M. E. P. *Survey: Cross-Validation in theory and in practice*. Technical Report. Princeton, New Jersey, USA, 1996.
- [PRINCIPE et al., 2000] PRINCIPE, J. C.; EULIANO, N. R.; LEFEBVRE, W. C. *Neural And Adaptive Systems: Fundamentals through Simulations*. John Wiley & Sons Inc., 2000.
- [QI & HUNT, 1994] QI, Y.; HUNT, B.R. *Signature Verification Using Global and Grid Features*, Pattern Recognition, Vol. 27, No. 12, 1994, 1621-1629 p.
- [QI & HUNT, 1995] QI, Y.; HUNT, B.R. *A Multiresolution Approach to Computer Verification of Handwritten Signatures*, IEEE Transactions on Image Processing, Vol. 4, No. 6, 1995, 870-874 p.
- [RASHA, 1994] RASHA, ABAS. *A Prototype System for Off-Line Signature Verification Using Multilayered Feedforward Neural Networks*. Master's Thesis, RMIT Department of Computer Science, Melbourne, 1994.
- [RIBEIRO & VASCONCELOS, 1999] RIBEIRO, J.; VASCONCELOS, G. *Arquiteturas Construtivas Autoassociativas para a Verificação Automática de Assinaturas*, Proceedings of the 4th Brazilian Conference on Neural Networks, São José dos Campos, São Paulo, 1999, 263-268 p.
- [RIGOLL & KOSMALA, 1998] RIGOLL, G.; KOSMALA, A. *A Systematic Comparison Between on-line and off-line methods for signature verification with Hidden Markov Models*, 14th International Conference on Pattern Recognition, vol. 2, Australia, 1998, 1755-1757 p.

- [SABOURIN & GENEST, 1994] SABOURIN, R. ; GENEST, G. *An Extended-Shadow-Code Based Approach for Off-Line Signature Verification*. 12th IAPR International Conference on Pattern Recognition, Israel, 1994, 450-460 p.
- [SANSONE & VENTO, 2000] SANSONE, C.; VENTO, M. *Signature Verification: Increasing Performance by a Multi-Stage System*. Pattern Analysis & Applications, No.3, 2000, 169-181 p.
- [SILVA, 2003] Os exterminadores dos cheques, Veja, Editora Abril, No. 36, ed. 1819 2003, 98-99 p.
- [SVM, 2003] *SVM^{light} Support Vector Machine*, www.cs.cornel.edu/People/tj/svm_light , acessado em 1 de Setembro de 2003.
- [VELEZ et al., 2003] VELEZ, J. F.; SANCHEZ, A.; MORENO, A. B. *Robust Off-Line Signature Verification Using Compression Networks and Positional Cuttings*. IEEE Int. Workshop on Neural Networks for Signal Processing (NNSP'03), Toulouse, France, 2003.
- [WALCZAK & CERPA, 1999] WALCZAK, S.; CERPA, N. *Heuristic Principles for the Design Of Artificial Neural Networks*. Information and Software Technology. Vol. 41, No. 2, 1999, 109-119 p.
- [WEIS & PROVOST, 2001] WEIS, G. M.; PROVOST, F. *The Effect of Class Distribution on Classifier Learning: An Empirical Study*. Technical Report ML-TR-44. Rutgers University, EUA, 2001.
- [WILSON, 1999] WILSON, A. T. *Off-line Handwriting Recognition Using Artificial Neural Networks*. Technical Report, University of Minnesota Morris, EUA, 1999.
- [XIAO & LEEDHAM, 1999] XIAO, X; LEEDHAM, G. . *Signature Verification by Neural Networks with Selective Attention and a Small Training Set*. Applied Intelligence, Vol.11, No.2, 1999, 213-223 p.

- [ZELL et al., 1994] Zell, A. et al. *SNNS Stuttgart Neural Network Simulator*. User Manual, Version 4.2, University of Stuttgart, 1994.
- [ZHANG et al., 1998] ZHANG, BAI-LING; FU, MIN-YUE; YAN, HONG. *Handwritten Signature Verification based on Neural 'Gas' Based Vector Quantization*. Proc. 14th International Conference on Pattern Recognition, Brisbane, 1998, 1862-1864 p.
- [ZHANG, 2000] ZHANG, G. P. *Neural Networks for Classification: A Survey*. IEEE Transactions on Systems, Man, and Cybernetics. Vol. 30, No. 4, 2000, 451-462 p.

Apêndice

A. Experimento com Kernel Linear do SVM

O uso do classificador SVM é testado com kernel linear devido aos resultados promissores encontrado em Justino [JUSTINO et al., 2003], porém os resultados demonstram ser inferiores ao kernel polinomial.

Tabela A.1: Resultado comparativo entre SVM com kernel linear e polinomial.

| Variação de amostras genuínas número de autores | | | | | | | | | | |
|---|------------------------|------------------|--------------|-------------|----------------|---------------------|------------------|-------|---------|----------------|
| Autores | SVM(kernel polinomial) | | | | | SVM (kernel linear) | | | | |
| | Erro Tipo I (%) | Erro Tipo II (%) | | | Erro Médio (%) | Erro Tipo I (%) | Erro Tipo II (%) | | | Erro Médio (%) |
| | | Genuína | Simples | Simulada | | | Aleatória | Total | Genuína | |
| 40 | 10,33 | 1,00 | 31,44 | 7,80 | 12,64 | 8,00 | 2,00 | 33,44 | 6,44 | 12,47 |
| 50 | 10,67 | 1,67 | 29,77 | 6,78 | 12,22 | 9,33 | 1,33 | 29,77 | 8,14 | 12,14 |
| 60 | 9,67 | 0,67 | 26,76 | 6,78 | 10,97 | 8,00 | 2,00 | 30,10 | 7,12 | 11,81 |
| 70 | 10,00 | 0,33 | 25,42 | 5,76 | 10,37 | 8,33 | 1,00 | 28,43 | 6,10 | 10,97 |
| 80 | 9,33 | 0,67 | 24,41 | 5,08 | 9,87 | 6,67 | 0,33 | 28,43 | 5,76 | 10,29 |
| 90 | 9,33 | 0,00 | 28,43 | 4,75 | 10,62 | 7,00 | 1,00 | 30,43 | 5,08 | 10,87 |
| 100 | 9,33 | 0,00 | 25,75 | 4,07 | 9,79 | 7,33 | 1,33 | 31,10 | 5,08 | 11,21 |
| 110 | 9,00 | 0,67 | 24,41 | 5,76 | 9,96 | 7,33 | 0,67 | 29,10 | 6,78 | 10,97 |
| 120 | 8,33 | 0,33 | 23,08 | 5,76 | 9,37 | 8,33 | 0,67 | 24,75 | 6,10 | 9,96 |
| 130 | 9,00 | 0,00 | 19,40 | 4,75 | 8,28 | 6,67 | 1,67 | 22,07 | 5,76 | 9,04 |
| 140 | 10,67 | 0,33 | 19,40 | 5,08 | 8,87 | 7,33 | 1,33 | 21,74 | 5,76 | 9,04 |
| 150 | 11,33 | 0,33 | 17,73 | 5,76 | 8,78 | 9,33 | 0,67 | 20,40 | 6,44 | 9,21 |
| 160 | 12,67 | 0,00 | 18,06 | 4,07 | 8,70 | 9,67 | 1,00 | 20,74 | 5,42 | 9,20 |
| 170 | 12,00 | 0,33 | 17,39 | 4,07 | 8,44 | 10,67 | 1,00 | 20,74 | 5,08 | 9,37 |
| 180 | 11,33 | 0,00 | 16,72 | 3,39 | 7,86 | 10,67 | 0,33 | 20,07 | 3,73 | 8,70 |

B. Experimento com Outras Medidas de Distâncias

Com objetivo de melhorar ainda mais os resultados em termos de taxas de erros demonstrados, novas medidas de distâncias são implementadas e testadas, sendo que as medidas utilizadas são as descritas na seção 4.4. Para este experimento é utilizada a Tabela 6.4 usada nos experimentos finais. Porém o protocolo é parcialmente utilizado com um subconjunto de 40 autores. Os resultados apresentados referem-se ao conjunto de teste da base de aprendizagem e da base de teste final usada com o voto majoritário.

Tabela B.1: Resultado do experimento com medidas de distâncias.

| Distância | Teste base 40 | | Teste base 60 | | | | |
|------------|-----------------|------------------|-----------------|------------------|--------|------------|----------------|
| | Erro Tipo I (%) | Erro Tipo II (%) | Erro Tipo I (%) | Erro Tipo II (%) | | | Erro Total (%) |
| | Genuínas | Aleatórias | Genuínas | Simples | Servis | Aleatórias | Total |
| Euclidiana | 13,33 | 5,06 | 12,33 | 0,33 | 32,00 | 3,73 | 12,09 |
| City-block | 12,30 | 6,29 | 10,67 | 1,07 | 37,67 | 5,76 | 13,79 |
| Quadrática | 8,67 | 10,37 | 12,67 | 2,67 | 39,33 | 8,81 | 15,87 |