

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE INFORMÁTICA
TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS

SAMARONE JONATHAN CARDOSO
SERGIO DA SILVA SANTANA

RECONHECIMENTO DE CARACTERES MANUSCRITOS *OFF-LINE*
UTILIZANDO *SUPPORT VECTOR MACHINE (SVM)*

TRABALHO DE CONCLUSÃO DE CURSO

PONTA GROSSA

2019

SAMARONE JONATHAN CARDOSO
SERGIO DA SILVA SANTANA

RECONHECIMENTO DE CARACTERES MANUSCRITOS *OFF-LINE*
UTILIZANDO *SUPPORT VECTOR MACHINE (SVM)*

Trabalho de Conclusão de Curso apresentado como requisito parcial para a obtenção do título de Tecnólogo em Análise e Desenvolvimento de Sistemas, do Departamento Acadêmico de Informática, da Universidade Tecnológica Federal do Paraná.

Orientador: Profa. Dra. Simone Bello Kaminsk Aires

PONTA GROSSA

2019



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Câmpus Ponta Grossa
Diretoria de Graduação e Educação Profissional
Departamento Acadêmico de Informática
Tecnologia em Análise e Desenvolvimento de Sistemas



TERMO DE APROVAÇÃO

RECONHECIMENTO DE CARACTERES MANUSCRITOS OFF-LINE UTILIZANDO SUPPORT VECTOR MACHINE (SVM)

por

SAMARONE JONATHAN CARDOSO
SERGIO DA SILVA SANTANA

Este Trabalho de Conclusão de Curso (TCC) foi apresentado em 07 de Novembro de 2019 como requisito parcial para a obtenção do título de Tecnólogo em Análise e Desenvolvimento de Sistemas. Os candidatos foram arguidos pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Profa. Dra. Simone Bello Kaminski Aires
Orientadora

Prof. Dr. Erikson Freitas de Moraes
Membro titular

Profa. Dra. Helyane Bronoski Borges
Membro titular

Prof. MSc. Geraldo Ranthum
Responsável pelo Trabalho de Conclusão de
Curso

Prof. Dr. André Pinz Borges
Coordenador do curso

AGRADECIMENTOS

Agradecemos a Profa. Dra. Simone Bello Kaminsk Aires pela paciência e orientação prestada para o desenvolvimento deste trabalho.

Gostaríamos de deixar registrado também, nossos agradecimentos as nossas esposas Lilian Petroski e Alexandra Nunes Santana, pois acreditamos que sem o apoio delas seria muito difícil vencer esse desafio.

Agradecemos também, a todos, que sempre estiveram ao nosso lado nos incentivando e apoiando para atingirmos os nossos objetivos.

Aos professores da UTFPR, pelos ensinamentos que contribuíram para nossa formação profissional e moral.

RESUMO

CARDOSO, Samarone; SANTANA, Sergio. **Reconhecimento de caracteres manuscritos *off-line* utilizando *support vector machine* (SVM)**. 2019. 69 f. Trabalho de Conclusão de Curso (Tecnologia em Análise e Desenvolvimento de Sistemas) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2019.

Este trabalho investiga o uso de SVM's (*Support Vector Machine*) para reconhecimento de caracteres manuscritos maiúsculos do alfabeto latino. Utilizou-se para os experimentos dados *off-line* da base IRONOFF. Os dados foram tratados previamente pelas técnicas de pré-processamento por limiarização e *bounding box*. Para extração de características utilizou-se a concavidade e convexidade efetuando-se rotulação do *pixel* de fundo. Posteriormente foi aplicado o mecanismo de zoneamento perceptivo dividindo os caracteres em Z partes ($z = 0$, $z = 4$, $z = 5$ horizontal, $z = 5$ vertical e $z = 7$). Os dados foram divididos em conjuntos de treinamento e teste para a criação de SVM's generalistas e especialistas. Para os experimentos foi utilizada a ferramenta WEKA. Foram aplicadas as configurações de *kernel* (*linear*, *radial* e *sigmoid*) nas SVM's criando assim um total de 15 SVM's generalistas e 390 especialistas. As SVM's com configuração de *kernel linear* com os zoneamentos $z = 5h$ e $z = 5v$ obtiveram um melhor desempenho com médias de acerto de 94,4% e 94,7% respectivamente. Os resultados encontrados foram comparados com as Redes Neurais propostas por Aires em 2005, onde todos os resultados das SMV's foram superiores as das RN's. A maior diferença foi no zoneamento $z = 5h$ onde as RN's tiveram média de acerto de 82,4% e a SVM de 94,4% e a menor diferença foi no zoneamento $z = 7$ com médias de acertos de 88,9% e 94,1%, RN's e SVM's respectivamente.

Palavras-chave: Reconhecimento de Caracteres Manuscritos Maiúsculos. SMV. Kernel. IRONOFF.

ABSTRACT

CARDOSO, Samarone; SANTANA, Sergio. **Offline handwriting character recognition using support vector machine (SVM)**. 2019. 69 p. Work of Conclusion Course (Graduation in Systems Analysis and Development Technology) – Federal Technological University of Paraná. Ponta Grossa, 2019.

This work investigates the use of Support Vector Machine (SVM's) for recognition of uppercase handwritten characters of the Latin alphabet. The experiment made use of offline data from IRONOFF database. The data had already been gone through thresholding and bounding box preprocessing techniques. With regard to extraction of characteristics, concavity and convexity were obtained? detected? isolated? determined? observed? by labeling of the background pixel. Subsequently, the perceptual zoning mechanism was applied by dividing the characters into Z parts ($z = 0$, $z = 4$, $z = 5$ horizontal, $z = 5$ vertical and $z = 7$). The data was divided into training and testing sets to create generalist and expert SVMs. The experiments were performed through the use of the WEKA tool. Kernel configurations (linear, radial and sigmoid) were applied to SVMs thus creating a total of 15 generalist and 390 specialist SVMs. SVMs with linear kernel configuration with $z = 5h$ and $z = 5v$ zoning achieved better performance with 94.4% and 94.7% hit averages respectively. The results were compared with the Neural Networks proposed by Aires in 2005, where all SMV's results were superior to those of the NNs. The biggest difference was in the? zoning $z = 5h$, where, the Neural Networks had an average of 82.4% accuracy and the SVM of 94.4%, while the smallest difference was in the? zoning $z = 7$ with an average of accuracy? of 88.9% and 94,1% for NNs and SVMs respectively.

Keywords: Recognition of Uppercase Handwritten Characters. Support Vector Machine. SVM. Kernel. IRONOFF.

LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplos de palavras manuscritas e o contexto	13
Figura 2 - Sentença proferida contra os réus da Conjuração Mineira	13
Figura 3 - Receita médica	14
Figura 4 - Estilo de escrita de diversos escritores	16
Figura 5 - Similaridade entre caracteres distintos	16
Figura 6 - Parte da sentença proferida contra os réus da Conjuração Mineira	20
Figura 7 - Fluxo do pré-processamento	20
Figura 8 - Limiarização	21
Figura 9 – Extração de primitivas	22
Figura 10 - Zoneamentos	24
Figura 11 - Arquitetura dos dados para aprendizado de máquina.....	26
Figura 12 - Conjunto de treinamento binário e três diferentes hipóteses	27
Figura 13 - O Hiperplano ótimo separando os dados com margem máxima	28
Figura 14 - Mapeamento de dados para um espaço de características de mais alta dimensão através da função de <i>kernel</i>	29
Figura 15 - A caixa delimitadora do acento está sob a caixa delimitadora da letra ...	33
Figura 16 - Grade básica 3x3 para extração de características estatísticas e estruturais.....	34
Figura 17 - Linguagem vietnamita	34
Figura 18 - Um caractere de componente conectado pode ser escrito em mais de um componente conectado	35
Figura 19 - Caracteres de três componentes conectados podem ser detectados em dois componentes devido à sobreposição	35
Figura 20 - Um sistema híbrido OHR	36
Figura 21 - Representação do diagrama de blocos da metodologia proposta	37
Figura 22 - Representação esquemática da extração de características HOG.....	37
Figura 23 - Formas diferentes para a versão maiúscula das letras A e F	38
Figura 24 - Esquema de zoneamento obtido pela combinação de modelos de coluna e linha.....	39
Figura 25 - Transições em uma coluna do caractere “e”, e as observações direcionais para estimar a direção média das transições 3 e 5	39
Figura 26 - Amostra de possíveis entradas para os métodos	41
Figura 27 – Visão geral resumida.....	44
Figura 28 - Fluxograma do zoneamento	45
Figura 29 – Configurações da LibSVM.....	49
Figura 30 – SMV’s Generalista.....	50
Figura 31 – SMV’s Especialistas	50
Figura 32 – Visão geral da metodologia	51
Figura 33 - Matriz de confusão gerada pelo WEKA para a SVM generalista ($z = 5v$, <i>Kernel: linear</i>)	54

Gráfico 1 - Médias das SVM's Generalistas por zoneamento (<i>kernel linear</i> - %).....	55
Gráfico 2 - Médias das SVM's Especialistas por zoneamento (<i>kernel linear</i> - %).....	58
Quadro 1 - Rótulos do vetor de características	23
Quadro 2 - Funções de <i>Kernel</i> utilizadas com mais frequência	30
Quadro 3 - Resumo de resultados	42
Quadro 4 - Arquivos divididos por zoneamento.....	46

LISTA DE TABELAS

Tabela 1 – Conjuntos de treinamento e teste das SVM's generalistas	47
Tabela 2 – Conjuntos de treinamento e teste das SVM's especialistas para cada zoneamento.....	47
Tabela 3 – Acertos obtidos das SVM's Generalistas (%)	53
Tabela 4 - Acertos obtidos das SVM's Especialistas (%)	56
Tabela 5 – Taxas de acertos com zoneamento 5v e <i>kernel linear</i>	59
Tabela 6 – Comparação de resultados com Aires (2005)	60
Tabela 7 – Melhores resultados obtidos.....	62

SUMÁRIO

1 INTRODUÇÃO	12
1.1 DESCRIÇÃO DO PROBLEMA	15
1.2 OBJETIVOS	17
1.2.1 Objetivo Geral	17
1.2.2 Objetivos Específicos	17
1.3 JUSTIFICATIVA	17
1.4 ESTRUTURA DO TRABALHO	18
2 REFERENCIAL TEÓRICO	19
2.1 PRÉ-PROCESSAMENTO	19
2.1.1 Efeito Caixa (<i>Bounding Box</i>)	19
2.1.2 Limiarização	20
2.2 EXTRAÇÃO DE PRIMITIVAS	21
2.3 REPRESENTAÇÃO DE PRIMITIVAS	23
2.3.1 Mecanismos de Zoneamento	24
2.4 SUPPORT VECTOR MACHINE - SVM	25
2.4.1 Aprendizado de Máquina	25
2.4.2 Conceitos de Margens na SVM	27
2.4.3 Kernel's	29
2.5 WEKA	30
2.6 BASE IRONOFF	31
2.7 CONSIDERAÇÕES DO CAPÍTULO	31
3 REVISÃO DE LITERATURA	33
3.1 RECONHECIMENTO DE CARACTERES MANUSCRITOS	33
3.2 CONSIDERAÇÕES DO CAPÍTULO	43
4 METODOLOGIA	44
4.1 VISÃO GERAL DO SISTEMA	44
4.2 CRIAÇÃO DOS CONJUNTOS DE TREINAMENTO E TESTE	45
4.3 CONSTRUÇÃO DAS SVM'S	46
4.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO	52
5 RESULTADOS E DISCUSSÕES	53
5.1 RESULTADO DAS SVM'S GENERALISTAS	53
5.2 RESULTADO DAS SVM'S ESPECIALISTAS	55
5.3 SVM'S GENERALISTAS X SVM'S ESPECIALISTAS	58
5.4 COMPARAÇÃO DAS SVM'S COM AS RN'S	60
5.5 MELHORES RESULTADOS DAS SVM'S ESPECIALISTAS	62
5.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO	63
6 CONCLUSÃO	64
REFERÊNCIAS	67

1 INTRODUÇÃO

A visão humana recebe estímulos de luz que rebatem em uma superfície. Esses estímulos são então transformados em impulsos que chegam ao cérebro que, por sua vez, gera nossa compreensão da imagem. Muitas vezes há a necessidade de replicar esse processo para o meio digital onde se faz a captação de imagens com sensores, os quais necessitam de uma fonte de luz refletida, gerando assim dados binários que posteriormente podem ser trabalhados digitalmente (GONZALEZ; WOODS, 2010).

As imagens são o início da comunicação humana perene. Iniciou-se com pinturas chegando à escrita manuscrita, onde a escrita é definida como marcas gráficas em uma superfície, com o propósito de transmitir uma mensagem, ou seja, a comunicação entre humanos. Essa ferramenta foi o motor principal para o desenvolvimento de diversas civilizações e suas culturas. (GONZALEZ; WOODS, 2010).

O ato de escrever consiste na utilização de conjuntos de ícones, definidos como caracteres ou letras, consistente de formas já definidas e seguindo regras para combinação das mesmas no intuito de formar agrupamentos que irão compor a linguística de alto nível. Tendo, como exemplo, o alfabeto latino que para formar palavras segue regras de combinação de formas e também com letras individuais (AIRES, 2005).

Escrever manualmente é uma das formas mais natural de comunicação humana, gerando dados manuscritos que muitas vezes necessitam ser processados para passarem para o meio digital (AZEVEDO; ZANCHETTIN, 2012). A necessidade de que as máquinas reconheçam e interpretem as diversas formas de escrita em face da quantidade de informação geradas diariamente e que precisam ser transmitidas para o mundo digital. A exemplo, na Figura 1, temos cartas que necessitam de ter o CEP reconhecido e cheques bancários que necessitam identificar valores numéricos como data e valor para pagamento (GIL, 2014). Cartas e cheques ainda precisam ser conferidos por um funcionário para validação e digitalização da informação.

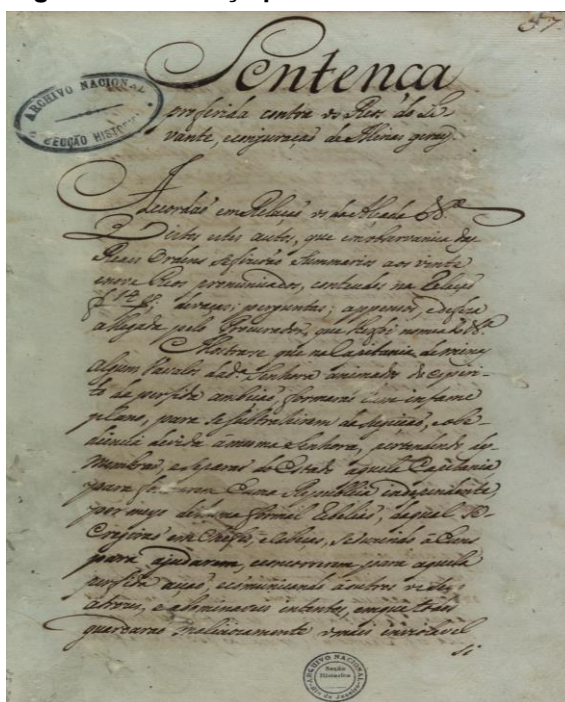
Figura 1 - Exemplos de palavras manuscritas e o contexto



Fonte: Oliveira Jr. (2006)

Dentro desse contexto de manuscritos ainda temos formulários, como fichas cadastrais, contratos por adesão entre outros, que são preenchidos a mão e posteriormente seus dados são copiados manualmente para um sistema. Outros exemplos são: documentos históricos (Figura 2), que necessitam ser digitalizados para preservação e facilidade de pesquisa, e receitas médicas apresentada na Figura 3. É importante observar que a digitalização de receitas tem uma complexidade maior, pois além de orientações há um léxico de palavras de uma determinada área profissional, onde pessoas sem experiência na área tem dificuldade na leitura e interpretação.

Figura 2 - Sentença proferida contra os réus da Conjuração Mineira



Fonte: www.arquivonacional.gov.br

Figura 3 - Receita médica

SUS **SEMSA** **MACAPÁ**
Secretaria Municipal de Saúde Prefeitura

RECEITUÁRIO 1ª Via Farmácia 2ª Via Paciente

Unidade de saúde: _____ Registro: _____
 Nome do paciente: Hanna Siqueira Categoria: _____

PRESCRIÇÃO:

① Bom Humor — OJ Caixa
 Aplicar no ambiente em que se vive no mínimo 10x ao dia, durante 365 dias de todos os anos de sua vida.

② Humoridade — OJ Vidro
 Tomar o vidro inteiro, uso contínuo...
 24/12/15

André A. Barros dos Reis
 Médico
 CRM - AP 1423

Fonte: www.polemicaparaiba.com.br

Tais processos de digitação de documentos são demorados e com possibilidade de falhas por depender do fator humano. Veloso (2009) afirma que o reconhecimento de manuscritos por máquinas é uma opção adequada para facilitar a interação homem-máquina, uma vez que, a escrita manual é uma das formas mais utilizadas na comunicação humana.

Em 1929 na Alemanha, os trabalhos pioneiros de Tauschek levou a criação da patente do *Optical Character Recognition* – OCR, posteriormente registrada também nos Estados Unidos em 1935 (PASSOS et al, 2015). As OCRs efetuam o reconhecimento de dados lendo um caractere a partir de uma imagem digitalizada. Esse sistema é dividido normalmente em duas formas, *on-line* e *off-line*. Sendo a *on-line* processada durante a captação dos dados, seja ela durante a escrita por canetas especiais ou outros métodos, levando em consideração velocidade, pressão e direção. Já na *off-line* as imagens entram no processo após serem digitalizadas por *scanner*, máquinas fotográficas, entre outros (GIL, 2014).

Passos et al (2015) afirmam que a crescente evolução dos computadores na década de 50 intensificaram as pesquisas na área de reconhecimento de caracteres, sendo propostos diversos algoritmos para resolução do problema que vem evoluindo constantemente na busca por taxas de acertos cada vez maiores, como apresentado

nos trabalhos de Tran et al (2010), Ahmad et al (2004), Tran (2012), Azevedo et al (2012), Santos et al (2008) e Passos et al (2015).

Vários sistemas utilizam as Cadeias Escondidas de Markov, Redes Neurais Artificiais (RNAs), ou um híbrido desses modelos para reconhecimento de caractere (AHAMD et al, 2004). Outros sistemas utilizam o classificador *Support Vector Machines* (SVM), que é um algoritmo de aprendizado e pode ser similarmente usado para aprender funções de reconhecimento (AHMAD; KHALID; YUSOF, 2002).

SVM se baseia em técnicas de aprendizagens apoiada na teoria de aprendizado estatístico desenvolvida por Vapnik em 1999, buscando soluções para o problema de classificações. Este trabalho utiliza o classificador SVM no reconhecimento de caractere, medindo suas taxas de acertos, erros e desvio padrão. Tal classificador foi selecionado com o objetivo de comparar os resultados da RNAs proposto por Aires (2005).

1.1 DESCRIÇÃO DO PROBLEMA

Apesar da capacidade de processamento elevada dos computadores atuais, ainda há grandes dificuldades para o domínio das máquinas sobre os textos manuscritos devido aos problemas como a variedade de estilos de escritas, até pessoas encontram dificuldade de ler textos de terceiros (MENEZES et al, 2014). Em função disso, muitos estudiosos da área refinam os sistemas de reconhecimento de manuscritos buscando torna-los mais eficientes e seguros (VELOSO, 2009).

Um problema no reconhecimento de caracteres é a variedade de formas de escritas, ou seja, é um dos obstáculos para os OCRs. “A grafia de cada indivíduo é única, sendo comparada, por muitos autores, como semelhante à impressão digital” (BENTO, 2016), conforme observa-se no exemplo de Aires (2005) na Figura 4.





Figura 4 - Estilo de escrita de diversos escritores

B	B	B	B
C	E	C	E
D	D	D	D
E	E	E	E
F	F	F	F

Fonte: Aires (2005)

Outro problema é o fato de muitos caracteres distintos terem forte similaridade entre si, como exemplo, C e E, B e E apresentados na Figura 5.

Figura 5 - Similaridade entre caracteres distintos

 Caractere: (C)	 Caractere: (E)
 Caracter: (B)	 Caractere: (E)

Fonte: Autoria própria (2019)

Há também o problema de se identificar o caractere isoladamente, ou seja, fora do contexto de uma palavra. Uma vez que, no reconhecimento de palavras uma possível técnica é a de segmentação da palavra em caracteres, e após o reconhecimento desses caracteres é feita união da sequência dos mesmos e uma busca por uma palavra no dicionário que se associe a palavra formada pelos caracteres (AIRES, 2005). No reconhecimento de palavras, um caractere que não foi reconhecido pode ser identificado no contexto da palavra/frase, já no reconhecimento de caractere isolado isso não é possível, dificultando o trabalho de reconhecimento.

1.2 OBJETIVOS

Esta Seção descreve os objetivos gerais e específicos deste trabalho.

1.2.1 Objetivo Geral

O objetivo geral deste trabalho é realizar o reconhecimento de caracteres manuscritos maiúsculos do alfabeto latino utilizando regiões perceptivas para construir SVM's especialistas (SVM - *Support Vector Machine*).

1.2.2 Objetivos Específicos

- Analisar métodos e técnicas de processamento de imagens;
- Aplicar percepção humana das formas no processo de reconhecimento de caracteres através do uso de regiões perceptivas (AIRES, 2005);
- Implementar múltiplas SVM's, de forma que cada SVM seja especialista em uma classe do problema. Isso é possível dado um léxico de pequena dimensão (26 classes de caracteres - A...Z);
- Utilizar três funções de *kernel's*: *linear*, *radial* e *sigmoid*, para avaliar qual obtém melhor desempenho na resolução do problema proposto;
- Comparar taxas de reconhecimento obtidas pelas SVM's com as taxas das RNA's propostas por Aires (2005).

1.3 JUSTIFICATIVA

Em função das características complexas e peculiares da escrita manuscrita, a busca por um classificador com melhores taxas de acerto motivou este trabalho a verificar e analisar as taxas de acerto e erros obtidas por 26 SVM's especialistas em reconhecimento de classes de caracteres. Chen, Wang e Wang (2009) dizem que SVM's são utilizadas para resolução de problemas de classificação, tais como reconhecimento de caractere, recuperação de *trademarks*, reconhecimento facial, reconhecimento de autoria, entre outros.

Nesse sentido, este trabalho pretende contribuir para o reconhecimento de caracteres utilizando o classificador *Support Vector Machine* (SVM), que se baseia em técnicas de aprendizagem de máquina, apoiada na teoria de aprendizado estatístico desenvolvida por Vapnik em 1999.

1.4 ESTRUTURA DO TRABALHO

Este trabalho encontra-se dividido em seis capítulos, sendo o Capítulo 1 a Introdução, descrição do problema, objetivos gerais e específicos, e a justificativa para o desenvolvimento do trabalho.

O Capítulo 2 apresenta o referencial teórico, o pré-processamento com as técnicas de efeito caixa (*bounding box*), limiarização. Extração de primitivas, representação de primitivas e seu mecanismo de zoneamento. As máquinas de vetores de suporte (SVM's – *Support Vector Machine*), com suas características de aprendizagem de máquina, conceitos de margens e *kernel's*. A ferramenta WEKA com sua biblioteca LibSVM e a base IRONOFF.

O Capítulo 3 descreve uma revisão de literatura, apresentando trabalhos de autores na área de reconhecimento de caracteres manuscritos.

O Capítulo 4 demonstra a metodologia utilizada para realizar este trabalho. Iniciando com uma visão geral do sistema, seguindo para a criação dos conjuntos de treinamento e teste, as construções da SVM's generalistas e especialistas.

O Capítulo 5 faz-se uma discussão dos resultados obtidos com os experimentos das SVM's generalistas e das SVM's especialistas, compra os resultados destas SVM's, posteriormente comparando os resultados das SVM's especialistas com as Redes Neurais propostas por Aires (2005). Ainda, apresenta os melhores resultados obtidos com as SVM's especialistas considerando zoneamento e configuração de *kernel*.

E no Capítulo 6 são apresentadas as considerações finais e trabalhos futuros.

2 REFERENCIAL TEÓRICO

Neste Capítulo serão apresentados os conceitos e métodos necessários para o desenvolvimento deste trabalho como pré-processamento, extração de primitivas, representação de primitiva e mecanismos de zoneamento, como também o classificador SVM, a ferramenta WEKA com a biblioteca LibSVM e a base de dados IRONOFF.

2.1 PRÉ-PROCESSAMENTO

Para que se possa trabalhar com as imagens é necessário aplicar métodos que permitam melhorar sua qualidade, tal etapa é definida como pré-processamento. Nessa etapa realiza-se uma padronização nas imagens aplicando alguns métodos específicos como a binarização, esqueletização, *bounding box*, algoritmos para eliminar ruídos, entre outros, deixando a imagem adequada para extração de informações, para que sejam trabalhadas posteriormente (MENEZES et al, 2014).

Primeiramente, as imagens necessitam passar por operações de tratamentos como realce de contraste, eliminação de ruídos, segmentação e limiarização para extrair o máximo possível de informações das características da imagem. Como as imagens iniciais, tratadas por Aires (2005), já estavam segmentada em caracteres isolados e sem ruído, a etapa de pré-processamento foi composta pelas técnicas descritas a seguir.

2.1.1 Efeito Caixa (*Bounding Box*)

Os caracteres manuscritos podem ter tamanhos diferentes e ainda alguns podem ter prolongamentos nas hastes das letras, em um ou em ambos os lados, dependendo de sua grafia. Como, por exemplo, o “A” na palavra da Figura 6. Devido a essas características há a necessidade de padronizar as imagens dos caracteres antes de sua classificação.


Figura 6 - Parte da sentença proferida contra os réus da Conjuração Mineira



Fonte: www.arquivonacional.gov.br

Para resolver esse problema, utiliza-se um delimitador, sendo que nas imagens utilizadas neste trabalho aplicou-se a técnica *Bounding Box*, ou efeito caixa, que consiste em construir um contorno ao redor do caractere, delimitando as bordas em todos os sentidos apenas à grafia, eliminando os espaços vazios (AIRES, 2005). A técnica é representada na Figura 7.

Figura 7 - Fluxo do pré-processamento




Fonte: Autoria própria (2019)

2.1.2 Limiarização

A operação de limiarização (*thresholding*) é o ato de converter as imagens originais em uma escala de cinza binária. Onde os *pixels* das imagens são separados em duas classes: branco e preto. Utiliza-se o menor valor para o preto, referindo-se ao traçado do caractere e o maior valor para o branco que, correspondente ao fundo (*background*) da imagem. Determina-se então, um limiar onde todos os valores que não correspondente ao branco são convertidos em preto, como exemplo da Figura 8, onde (a) é a imagem original, (b) histograma da imagem original e (c) imagem obtida após aplicação do limiar T. Para a base utilizada neste trabalho aplicou-se a técnica de OTSU que é descrita por ARTERO e TOMMASELLI (2000).

Figura 8 - Limiarização



Fonte: Artero e Tommaselli (2000)

Reis et al (2010) cita OTSU como sendo considerado um dos melhores métodos para limiarização, pois sugere que minimizando a soma das variâncias entre as classes do fundo e do traçado pode-se obter um limiar global com melhores resultados, mas Reis et al (2010) ainda salienta que, esses resultados são obtidos com um custo de complexidade elevado. Lopes (2010) afirma que a técnica não se restringe ao tipo do histograma, podendo ser aplicadas a unimodais, bimodais ou multimodais, tendo seus melhores desempenhos em imagens com variação de intensidade e que sua implementação é sequencial, gerando um bom desempenho computacional, e conclui apontando que o ponto negativo da técnica seria a sensibilidade ao ruído que podem afetar o limiar global.

2.2 EXTRAÇÃO DE PRIMITIVAS


A extração de primitivas é um dos fatores fundamentais para que um sistema de reconhecimento de caracteres alcance altos níveis de reconhecimento. Sendo que, define-se a extração de primitivas como o ato de extrair as informações mais relevantes dos dados brutos para efetuar a classificação, buscando minimizar a variabilidade dentro das classes e maximizar a variação dentre as classes (NUNES, 2004).

Aires (2005) afirma que as primitivas preceptivas são comumente utilizadas na representação global das propriedades dos caracteres, fazendo parte dessa classe, os ascendentes, descendentes, laços, traços, barras verticais, horizontais e inclinadas, segmentos de linhas, propriedades regulares, entre outros.

Quando se trabalham com caracteres manuscritos isolados as determinações de zonas ascendentes, descendentes e corpo não são aplicadas devido às suas características. Na base de dados, deste trabalho, utilizou-se as

primitivas perceptivas, devido a tolerância que essa tem às distorções e a variações de estilo de escritas, faz-se uma análise das partes côncavas e convexas evidenciando as propriedades topológicas e geométricas das formas e o método de tratamento do contorno das formas, o qual rotula os *pixels* do fundo da imagem para extrair para cada elemento um vetor de características (*feature vector*). O vetor é composto pela rotulação de cada *pixel* do fundo da imagem, sendo 24 situações diferentes mapeadas, verifica-se inicialmente os quatro vizinhos, norte-sul-leste-oeste (NSLO) para cada *pixel* em branco no caractere, como exemplificado na Figura 9.

Figura 9 – Extração de primitivas



Fonte: Autoria própria (2019)

Posteriormente, é realizada a verificação de falsos laços para a possibilidade de escape nas quatro direções de sondagem para os *pixels* determinados como fechados (laços) nas direções principais (NSLO) (AIRES, 2005). Conforme observa-se na rotulação do Quadro 1.

Quadro 1 - Rótulos do vetor de características

Rótulo	Tipo	Busca
0	Aberto à direita e acima	(NSLO)
1	Aberto à esquerda e acima	(NSLO)
2	Aberto à esquerda e abaixo	(NSLO)
3	Aberto à direita e abaixo	(NSLO)
4	Aberto à direita	(NSLO)
5	Aberto acima	(NSLO)
6	Aberto à esquerda	(NSLO)
7	Aberto abaixo	(NSLO)
8	Laço fechado	(NSLO)
A	Escape para direita e acima	Sondagem
B	Escape para esquerda e acima	Sondagem
C	Escape para direita e abaixo	Sondagem
D	Escape para esquerda e abaixo	Sondagem
E	Escape acima e direita	Sondagem
F	Escape acima e esquerda	Sondagem
G	Escapa abaixo e direita	Sondagem
H	Escape abaixo e esquerda	Sondagem
J	Aberto esquerda/direita	(NSLO)
K	Aberto acima/abaixo	(NSLO)
L	Fechado abaixo	(NSLO)
M	Fechado acima	(NSLO)
N	Fechado direita	(NSLO)
O	Fechado esquerda	(NSLO)

Fonte: Aires (2005).

2.3 REPRESENTAÇÃO DE PRIMITIVAS

Segundo Aires (2005), algumas das formas de representação de características são:

- Contagem e verificação que, consistem em contar os *pixels*, números de ascendentes, descendentes, laços, entre outros. Comumente utilizada em abordagens globais para destacar objetos não similares;
- Estruturas de grafos que constrói um grafo tendo as primitivas com nós e a relação espacial representada por arestas;

- Sequências, onde a imagem é representada por símbolos sequências pela ordem de ocorrência na imagem;
- Vetores de características e matrizes baseiam-se em dividir a imagem em zonas (*zoning*), as quais podem ser fixas ou variáveis, extraíndo das divisões vetores ou matrizes de dados.


Na base de dados, deste trabalho, foi utilizada a técnica de zoneamento (*zoning*), a qual é formada por um vetor de características composto por uma contagem dos rótulos encontrados conforme Quadro 1, somado a contagem de *pixels* pretos em cada região, posteriormente os dados são normalizados em relação ao tamanho da região (AIRES, 2005).

2.3.1 Mecanismos de Zoneamento

Buscando encontrar características únicas em cada caractere, Suen (1994) propôs dividir a imagem em parte distinta, dividindo-as em partes: direita, esquerda, acima, ao meio, e abaixo. Com as divisões, Suen (1994), encontrou padrões que os chamou de cruciais para o reconhecimento do caractere, sendo em alguns pontos o reconhecimento é considerado perfeito, ou seja, 100%. Esses pontos dependem do número de partições, sendo considerados efetivos quando abrangem partes absolutamente distintas das demais.

Neste trabalho foi utilizada a mesma técnica aplicada por Aires (2005), que propôs um mecanismo de zoneamento (*zoning*) não simétrico utilizando um vetor de características baseadas em convexidade e concavidade extraídas pela rotulação do *background*. Dividido a caixa com o caractere em Z partes, $z = 4$, $z = 5H$ (horizontal), $z = 5$ (vertical) e $z = 7$, exemplificado na Figura 10.

Figura 10 - Zoneamentos



Fonte: Autoria própria (2019)

2.4 SUPPORT VECTOR MACHINE - SVM

Máquinas de Vetores de Suporte (SVM, *Support Vector Machine*) são técnicas de aprendizagem de máquina que surgiram a partir da teoria de aprendizado estatístico desenvolvida por Vapnik em 1999. Teoria esta que segue paradigmas para selecionar classificadores que tenham uma boa generalização, com o objetivo de prever corretamente novos elementos apresentados. Existem vários exemplos na literatura nos quais os resultados são satisfatórios, ou superiores, a de outros classificadores (LORENA; CARVALHO, 2007). Alguns desses exemplos serão apresentados e discutidos no Capítulo 3.

2.4.1 Aprendizado de Máquina


Dentro da inteligência artificial há o conceito de aprendizado de máquina que busca o aprendizado através da repetição, isto é, o computador executa a mesma tarefa diversas vezes, melhorando seu desempenho a cada nova execução. Esse método é muito utilizado em resolução de problemas de classificação, quando se tem uma base prévia, a qual se utiliza para prever novos elementos, podendo ter um aprendizado supervisionado, não supervisionado ou por reforço (BORCHARTT, 2013).

No aprendizado supervisionado tem-se um conjunto de dados de entrada e saídas, o qual é composto por características e atributos da amostra e um identificador, comumente chamado de classe, onde a máquina irá utilizar esta informação para aprender a qual conjunto cada elemento pertence segundo suas características, utilizando essa informação para classificar novos elementos apresentados (BORCHARTT, 2013). Neste trabalho utiliza-se este método com os dados conforme o padrão apresentado na Figura 11, com atributos e classe.

No aprendizado não supervisionado os dados de entrada não possuem o atributo identificador, passando para a máquina o papel de agrupar os elementos segundo suas similaridades utilizando usualmente as distâncias entre os atributos. Técnica comumente utilizada para identificar padrões ou tendências, facilitando o entendimento dos dados (LORENA; CARVALHO, 2007).

O aprendizado com reforço segue os princípios do aprendizado supervisionado, porém, recebe um bônus ou ônus conforme seus acertos e erros durante a fase de aprendizagem (BORCHARTT, 2013).

Figura 11 - Arquitetura dos dados para aprendizado de máquina




Fonte: Adaptado de Lorena e Carvalho (2007)

A base de dados é dividida em duas partes, treinamento e teste. Para a etapa de aprendizagem da máquina é utilizado o conjunto de treinamento, o qual apresenta as características das classes. Já o conjunto de teste é utilizado para medir a acurácia, ou seja, a precisão na classificação de novos dados (LORENA; CARVALHO, 2007).

A SVM tem seu aprendizado baseado na teoria de aprendizado estatístico, proposto por Vapnik e Chervonenkis (1995), a qual quantifica os registros classificados erroneamente e utiliza o princípio da indução para gerar o modelo preditivo que minimize o erro sobre os dados de testes até um limite aceitável (BORCHARTT, 2013).

A Figura 12 representa um exemplo onde elementos: “círculo” e “triângulo” necessitam ser separados em duas classes. Na imagem têm-se três traços (a), (b) e (c) que são funções ou hipóteses para solucionar o problema. A Figura 12a representa uma hipótese que classifica o conjunto de treinamento corretamente, porém, com alguns ruídos. Na Figura 12c desconsideram-se pontos opostos das classes que estão muito próximos uns dos outros, cometendo assim muitos erros de classificação. A Figura 12b seria o meio termo entre (a) e (c) (LORENA; CARVALHO, 2007).

Figura 12 - Conjunto de treinamento binário e três diferentes hipóteses



Fonte: Lorena e Carvalho (2007)

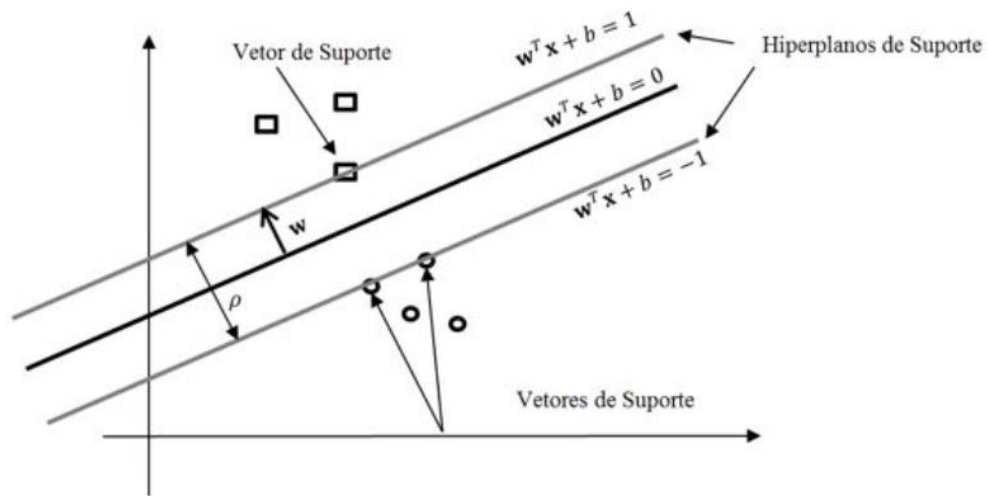
Em Bonesso (2013), a SVM tem como base o princípio da minimização do risco estrutural proposto por Vapnik e Chervonenskis (1974). O qual pode ser definido como uma função para minimização do risco médio do conjunto de treinamento e teste. Assim, a SVM busca um equilíbrio entre os tipos de amostras mais recorrentes e as peculiaridades e ruídos, permitindo uma generalização ou reconhecimento de padrões não utilizados no treinamento da SVM.

2.4.2 Conceitos de Margens na SVM

Durante o processo de treinamento a SVM utiliza-se de hiperplanos para separar as amostras conforme suas classes, traçando uma superfície de decisão entre as duas classes. Tendo como limiar as características às margens da classe, chamadas de vetores de suporte. Assim, criam-se os hiperplanos de suporte para separar as amostras, como apresentados na Figura 13. Maximizando o limite entre as classes reduz a probabilidade de generalização, evitando erro na classificação de novos dados, essa técnica é conhecida como Maximização de Margem (BONESSO, 2013).

Quando não há dados dentro do hiperplano que separa as classes as margens são chamadas de Margens Rígidas, porém, há a possibilidade de trabalhar com margens suaves, procedimento que permite que dados fiquem entre os Hiperplanos de suporte, no entanto, pode-se aumentar a ocorrência de erros de classificação.

Figura 13 - O Hiperplano ótimo separando os dados com margem máxima



Fonte: Bonesso (2013)

Bonesso (2013) descreve que se $x_i (i = 1, \dots, M)$ seja um conjunto de treinamento de duas classes linearmente separáveis w_1 (e w_2). Rotula-se as amostras como $(y_i = 1)$ para w_1 e $(y_i = -1)$ para w_2 , quando os dados são linearmente separáveis tem como função de decisão a equação (1):

$$D(x) = w^T x + b \quad (1)$$

Sendo w um vetor m – dimensional e b um termo independente. Em que m é dimensão dos dados e M o número de amostras de treinamento.

Os vetores $w^T x + b = 1$ e $w^T x + b = -1$, representados na Figura 13, são os hiperplanos de suporte e que auxiliam a SVM a definir o hiperplano ótimo que separa as duas classes (BONESSO, 2013).

Bonesso (2013) afirma que podem ter infinitas funções lineares para separar as amostras de treinamento. O objetivo da SVM é buscar um hiperplano ótimo que separa as amostras de treinamento. A equação (2) apresenta a função de decisão que busca maximizar as margens para chegar a um hiperplano ótimo.

$$D(x) = \sum_{i \in S} \alpha_i y_i x_i^T x + b \quad (2)$$


Onde α_i são os multiplicadores de Lagrange um vetor de dimensão m , sendo α_i diferente de zero. Esses parâmetros definem o hiperplano ótimo.

Nas margens suaves utiliza-se a mesma função da equação (2), porém, com um parâmetro definido pelo usuário, onde quanto maior valor maior a penalização associada aos erros cometidos. Assim, α_i não pode ser maior que esse parâmetro.

2.4.3 Kernel's

Na SVM o hiperplano ótimo busca maximizar a capacidade de generalização, no entanto, se os dados não podem ser separados linearmente pode baixar essa capacidade de generalização, assim, para melhor classificação dos dados altera-se o espaço original para uma dimensão mais alta conhecida como espaço de características. Essa mudança da dimensão é feita configurando a função de *kernel* que altera o espaço original para um espaço de produto escalar de alta-dimensão, possibilitando que os dados sejam separados linearmente (BONESSO, 2013). A Figura 14 exemplifica a função de *kernel*.

Figura 14 - Mapeamento de dados para um espaço de características de mais alta dimensão através da função de *kernel*



Fonte: Bonesso (2013)

Bonesso (2013) traz a função de decisão com a função do *kernel*, apresentada na equação (3), onde b é dado pela função da equação (4).

$$D(X) = \sum_{i \in S} \alpha_i y_i H(X_i, X) + b \quad (3)$$

$$b = y_i \sum_{i \in S}^M \alpha_i y_i k(x_i, x_j) \quad (4)$$

As funções de *kernel* mais utilizadas são apresentadas no Quadro 2.

Quadro 2 - Funções de *Kernel* utilizadas com mais frequência

Nome	Função	Parâmetros Livres
Kernel Linear	$K(x, x') = x^T x'$	
Kernel Polinomial homogêneo	$K(x, x') = (x^T x')^d$	$d \geq 2$
Kernel Polinomial não homogêneo	$K(x, x') = (x^T x' + 1)^d$	$d \geq 2$
Kernel RBF (Radial Basis Function)	$K(x, x') = \exp(-\gamma \ x \cdot x'\ ^2)$	$\sigma \geq 2$
Kernel Sigmóide	$K(x, x') = \tan(kx \cdot x' - \delta)$	

Fonte: Adaptada de Bonesso (2013)

Neste trabalho utilizou-se as funções: *linear*, *radial* (RBF) e *sigmoid*.

2.5 WEKA

O *Waikato Environment for Knowledge Analysis* (WEKA) surgiu em 1992 na Universidade de Waikato na Nova Zelândia pela necessidade de uma ferramenta de trabalho unificada que permitisse aos pesquisadores acesso fácil às técnicas de aprendizado de máquina. Sendo um sistema de código aberto voltado para a mineração de dados e aprendizado de máquina que alcançou ampla aceitação na academia e nos círculos empresariais (HALL et al, 2009).

O projeto WEKA fornece uma coleção abrangente de algoritmos de aprendizado de máquina e ferramentas de pré-processamento de dados para pesquisadores e profissionais que permite aos usuários testar e comparar rapidamente diferentes métodos de aprendizado de máquina em novos conjuntos de dados. E ainda, possibilita que os pesquisadores possam implementar novos algoritmos (HALL et al, 2009). Neste trabalho foi utilizada a versão 3.8.3 de 2018.

Para construção das SVM's (Support Vector Machines) no WEKA foi utilizada a biblioteca LibSVM que vem sendo desenvolvida desde 2000 e tem por objetivo facilitar o uso da SVM em aplicativos. A LibSVM ganhou ampla popularidade no aprendizado de máquina e em muitas outras áreas. Neste artigo, apresentamos todos os detalhes de implementação da LibSVM. Questões como a resolução de problemas de otimização SVM, convergência teórica, classificação multi-classe, estimativas de probabilidade e seleção de parâmetros são discutidas em detalhes (CHANG; LIN, 2011).

Neste trabalho foi utilizada a versão 1.9.8 disponível no repositório do WEKA.

2.6 BASE IRONOFF

A base IRONOFF gerada pela IRESTE (*Universit of Nantes – France*) em colaboração com *VISON OBJECTS* contém cerca de mil formas *on-line* e *off-line*, cada uma delas preenchida por um escritor diferente, totalizando 32.000 caracteres isolados e 50.000 palavras cursivas. No domínio online, as formas foram coletadas com uma resolução espacial de 300 dpi e uma taxa de amostragem de 100 pontos e armazenadas usando o formato UNIPEN. No domínio *off-line*, as imagens foram digitalizadas com uma resolução de 300 dpi com 8 bits por *pixel* (256 níveis) (VIARD-GAUDIN et al, 2002).

2.7 CONSIDERAÇÕES DO CAPÍTULO

Este capítulo apresentou os métodos e técnicas necessários para o desenvolvimento deste trabalho como pré-processamento, extração de primitivas e representação de primitiva, que são passos iniciais para o reconhecimento de caracteres manuscritos. Também foram aplicados os mecanismos de zoneamentos perceptivo propostos por Aires (2005), o qual divide as amostras em Z partes, $z = 4$, $z = 5H$ (horizontal), $z = 5$ (vertical) e $z = 7$, buscando uma melhor taxa de classificação dos caracteres manuscritos maiúsculos.

Discute-se ainda, neste capítulo, o classificador SVM, e seus conceitos, iniciando pelo aprendizado de máquina, o qual aprende pela repetição, tendo as

variações de aprendizado supervisionado, aprendizado não supervisionado e aprendizado com reforço. Após foi apresentada a SVM, que tem seu aprendizado baseado na teoria de aprendizado estatístico, proposto por Vapnik e Chervonenkis (1995) e o conceito de margens, que podem ser rígidas ou suaves e que definem os hiperplanos. Seguindo para as configurações de *Kernel's*, neste trabalho, utilizou-se *kernel's linear, radial, e sigmoid*.

Encerrando o capítulo foi demonstrada a ferramenta WEKA e sua biblioteca LibSVM e também uma explicação das características base de dados IRONOFF.


3 REVISÃO DE LITERATURA

Neste Capítulo são apresentados resumos de trabalhos que propõem metodologias para o reconhecimento de caracteres manuscritos. Os trabalhos utilizam algumas técnicas de extração de características como: Sete Momentos de HU, HOG, *Randon Invariantes* e Algoritmos de Canastra (2007). Como classificador os autores utilizaram técnicas de aprendizagem de máquina como SVM, MLP, Marckov, RNA e KNN. Em alguns trabalhos são comparados os resultados entre técnicas diferentes.

3.1 RECONHECIMENTO DE CARACTERES MANUSCRITOS

Tran, Franco e Ogier (2010) propõem o reconhecimento de caractere manuscritos acentuados utilizando SVM. Como apontado pelos autores, este problema vem sendo estudado há mais de 40 anos devido a seu impacto ao cotidiano e a economia, tendo grande interesse pelo alfabeto latino, os autores apontam que existe um *gap* nas pesquisas em relação aos caracteres acentuados. Assim, o trabalho apresentado foca nos caracteres acentuados da linguagem francesa conforme Figura 15.


Figura 15 - A caixa delimitadora do acento está sob a caixa delimitadora da letra



Fonte: Tran, Franco e Ogier (2010)

Para a extração de características dos caracteres os autores usam as técnicas proposta por Heutte et al (1998), que incluem 7 momentos invariantes de Hu, projeção horizontal, vertical, superior, inferior, direita e esquerda, interseções com linhas retas horizontais e verticais, buracos e arcos de côncavo, a parte superior, inferior, esquerda e direita de extremidades, os pontos finais e cruzamentos, tendo às características calculadas em cada célula 3x3 como na Figura 16.

Figura 16 - Grade básica 3x3 para extração de características estatísticas e estruturais



Fonte: Tran, Franco e Ogier (2010)

Tran, Franco e Ogier (2010) aplicam *Randon Invariantes* e *Zernike Moments*, buscando a eliminação de redundâncias. Assim, dividindo a carga do trabalho em duas partes: efetuando a separação da letra e do acento para o reconhecimento e unindo posteriormente as partes para ter a letra acentuada. Como classificador utilizaram a SVM, os autores fizeram uma análise em trabalhos que utilizam KNN e Redes Neurais. Após análise, selecionaram as bases de dados, UNIPEN e IRONOFF, utilizando 2.000 imagens, sendo 1.600 imagens escolhidas aleatoriamente para treinamento e 400 imagens para os testes. Realizados os testes de reconhecimento obtiveram as taxas de acerto para letras maiúsculas de 95,6% e após aplicação dos assentos o resultado obtido foi de 99,9% de acerto (TRAN; FRANCO; OGIER, 2010).

Posteriormente Tran (2012) publicou uma nova pesquisa onde aplicou as técnicas desenvolvidas para reconhecimento de caracteres acentuados na linguagem Vietnamita que também utiliza a alfabeto latino, porém, com uma gama maior de acentuações, como exemplificado na Figura 17. Dessa forma aumentando as cargas de trabalho para as SVM no contexto manuscrito como apresentado nas Figuras 18 e 19.

Figura 17 - Linguagem vietnamita




Fonte: www.chinhphu.vn

Figura 18 - Um caractere de componente conectado pode ser escrito em mais de um componente conectado



Fonte: Tran (2012)

Figura 19 - Caracteres de três componentes conectados podem ser detectados em dois componentes devido à sobreposição

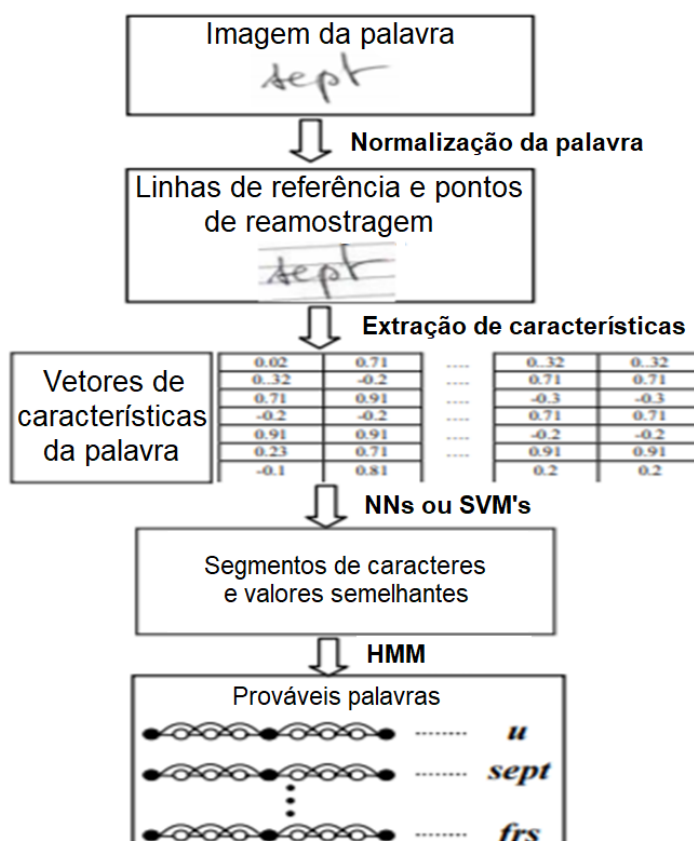


Fonte: Tran (2012)

Para extração de características Tran (2012) utilizou os 7 Momentos invariantes de HU, *Randon Invariantes* e *Zernike Moments*, tendo também reutilizado as imagens dos bancos IRONOFF e UNIPEN, dividindo-as em 1.600 para treinamento e 400 para testes, assim replicando as taxas de acerto mesmo quando aplicadas aos problemas dos casos de acentuação diversos, como presente na linguagem vietnamita.

Ahmad, Khalid e Poisson (2004) focaram em um sistema híbrido de SVM e HMM (*Hidden Markov Model*), devido a muitos sistemas já utilizarem HMM para reorganização de Redes neurais, assim, o sistema híbrido proposto pelo autor busca novos métodos e melhorias nos resultados ao utilizar SVM em substituições às redes neurais. Para esse objetivo o modelo é apresentado na Figura 20.

Figura 20 - Um sistema híbrido OHR

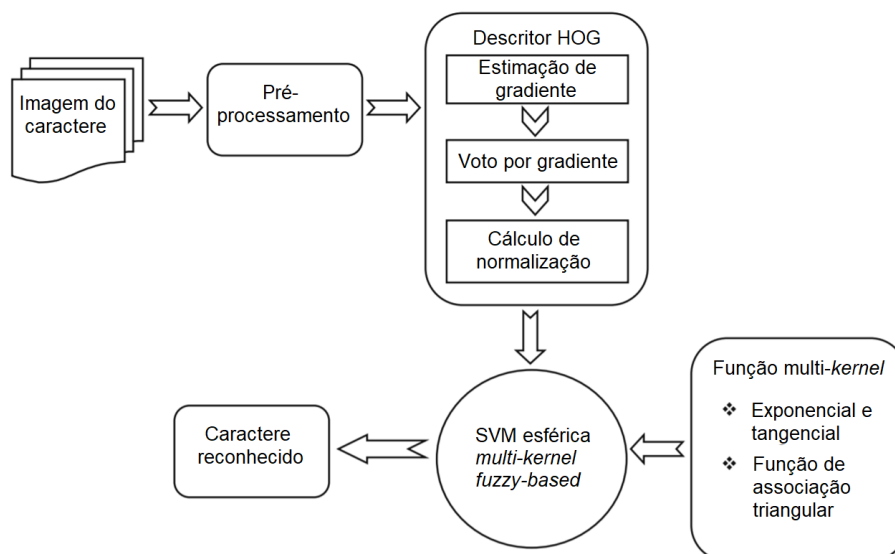


Fonte: Adaptada de Ahmad, Khalid e Poisson (2004)

As bases de dados utilizadas pelos autores foram UNIPEN e IRONOFF misturadas. Para letras maiúsculas usaram 42.778 imagens para treinamento e 20.172 imagens para testes obtendo assim as taxas de acerto de 98,83%, com o classificador gerado a partir da SVM. Após testes concluíram que em todos os experimentos os resultados mostraram que a SVM obtém taxas significativamente melhores devido à minimização do risco estrutural implementado pela maximização da margem de separação em função da decisão (AHMAD; KHALID; POISSON, 2004).

Sampath e Gomathi (2017) trabalham com SVM's para o reconhecimento de caracteres latinos propondo a metodologia de diagrama de blocos apresentada na Figura 21.

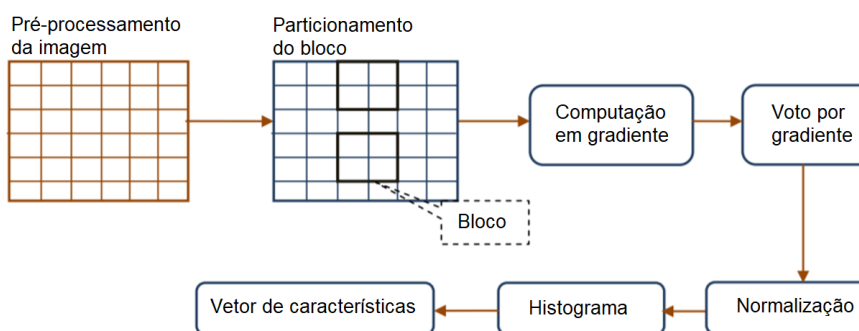
Figura 21 - Representação do diagrama de blocos da metodologia proposta



Fonte: Adaptada de Sampath e Gomathi (2017)

Para a extração de características, Sampath e Gomathi (2017) utilizaram técnicas de HOG, que divide a imagem em pequenas regiões chamadas de células, tendo cada célula um histograma do gradiente, instruções ou orientações de bordas, e cada célula é normalizada a fim de buscar uma melhor precisão, como apresentado no esquema da Figura 22.

Figura 22 - Representação esquemática da extração de características HOG



Fonte: Adaptada de Sampath e Gomathi (2017)

A base de dados usada por Sampath e Gomathi (2017) foi a CHARK74K que contém 64 imagens com textos compostos por caracteres maiúsculos, minúsculos e números dos quais são extraídos 7.705 caracteres para serem classificados. Após testes com SVM's utilizando diversas funções de *kernel's* para classificar as imagens obteve-se uma taxa de acerto de 99%.

Azevedo e Zanchettin (2012) evidência o constante estudo do reconhecimento de caracteres desde a invenção do computador e as dificuldades que esses processos enfrentam, devido à variedade de formas para transcrever as letras do alfabeto, como exemplificado na Figura 23.

Figura 23 - Formas diferentes para a versão maiúscula das letras A e F




Fonte: Azevedo e Zanchettin (2012)

A base de dados utilizada por Azevedo e Zanchettin (2012) é composta por: C-CUBE, que foi extraída dos bancos de dados do *Center of Excellence for document analysis and recognition* (CEDAR) e *United States Post Service* e, por dados de imagens extraídas utilizando o algoritmo de Camastra (2007), o que facilita o estudo comparativo por outros pesquisadores. Sendo composta por 22.274 letras maiúsculas para treinamento e 11.161 para teste.

Como classificador Azevedo e Zanchettin (2012) utilizaram uma arquitetura híbrida de MLP-SVM. Sendo a primeira classificação feita pela MLP e as imagens não reconhecidas são enviadas para uma SVM especialistas para reclassificação. Os caracteres maiúsculos classificados por 1 MLP e 32 SVM's, tiveram uma taxa de acerto de 90,48%, obtendo uma melhoria de 3,65% em relação às classificações apenas com MLP.

Santos et al (2008) propõem otimizar Cadeias Escondidas de Markov. Para extração de características efetuam uma varredura na imagem da esquerda para a direita e de cima para baixo, gerando linhas e colunas, onde chega-se a 34 características de traçado e 15 de fundo (*background*), como apresentado na Figura 24.


Figura 24 - Esquema de zoneamento obtido pela combinação de modelos de coluna e linha



Fonte: Santos et al (2008)

Santos et al (2008) utilizam ainda a Característica de Traçado (TC), técnica que separa em informações locais e globais, onde considera-se o *pixel* do traçado (ou em inglês, *foreground pixel*) e a variância com os *pixels* do fundo e vice-versa. Para cada transição a direção média e a estimativa média circular, como apresentado na Figura 25.

Figura 25 - Transições em uma coluna do caractere “e”, e as observações direcionais para estimar a direção média das transições 3 e 5



Fonte: Santos et al (2008)

Para buscar as informações de concavidade aplica-se a técnica de Característica de Fundo (CF) assim, destacando as propriedades topológica e geométrica das classes do carácter, representando cada característica um número de *pixel* branco que procura o limite até o preto do traçado ou o limite da menor caixa imposto sobre ele, rotulando somente se duas ou mais direções consecutivas o atingirem, para obter 9 possíveis configurações (SANTOS et al, 2008).

Para classificação utilizam-se Cadeias Escondidas de Markov, os quais buscam obter padrões desconhecidos através dos padrões já conhecidos. No trabalho buscam um modo eficiente de combinar os valores obtidos do traçado e fundo gerando um vetor de características de 47 posições (34 de traçado e 13 de fundo), estes ainda são mapeados para um vetor de 256 possíveis símbolos discretos disponíveis em um *codebook* (SANTOS et al, 2008).

Como base de dados Santos et al (2008) utilizou a NIST SD19 com 74.880 imagens para treinamento e 23.670 amostras para testes. Obtendo uma taxa de acerto média de 91,14% para caracteres maiúsculos, identificando que nos modelos combinados obtiveram resultados melhores em relação aos trabalhos anteriores.

Passos et al (2015) propõem avaliar três dos mais conhecidos classificadores utilizados no reconhecimento de caracteres manuscritos: Redes Neurais, SVM e K-vizinho. Assim, trabalhou com comparativos de resultados entre Rede Neurais, K-Vizinhos mais Próximos e SVM, para treinamento foram utilizados 26 caracteres escritos por 50 escritores diferentes obtendo-se através de OCR 1.300 caracteres, e para teste foram totalizadas 47 amostragens para cada método, como exemplificado na Figura 26. Os resultados obtidos foram: RNA 97,11, KNN 95,57% e SVM 98,87%, também um desvio padrão de 0,62, 0,58 e 0,58. Concluindo que o aprimoramento dos estudos pode levar a resultados mais consistentes e obtendo taxas maiores.

Figura 26 - Amostra de possíveis entradas para os métodos

Handwritten list of months in Portuguese, including some misspellings and repetitions:

- abril
- agosto
- fevereiro
- novembro
- maio
- dezembro
- janeiro
- março
- janeiro
- julho
- junho
- outubro
- fevereiro
- abril
- maio
- outubro
- agosto
- julho
- março
- setembro
- dezembro
- junho
- setembro
- novembro

Fonte: Passos et al (2015)

Após os testes foram obtidos os seguintes resultados, KNN taxa de acerto de até 95,57% desvio padrão 0,58, SVM taxas médias de 98% desvio padrão 0,58 e RNA acerto médio obtido de 97,11 com desvio de 0,62. Assim, os autores concluíram que o KNN apresenta grande diferença nas taxas em relação aos demais e que entre RNA e SVM apesar de terem diferenças estatísticas menores, as SVM se saem melhores (PASSOS et al, 2015).

O Quadro 3 apresenta uma visão geral dos trabalhos discutidos neste Capítulo.

Quadro 3 - Resumo de resultados

Autor	Ano	Local	Base de Dados		Extração de Características	Técnica de Aprendizagem de Máquina	% de Acertos	Desvio Padrão
			Nome	Nº de Imagens				
Ahmad et al	2004	IEEE Region 10 Conference TENCON	IRONOFF	10.679	Informação <i>on-line</i> na base	MLP	93,6	-
						TDNN	94,2	-
						SVM	95,46	-
			UNIPEN	28.000		MLP	92,8	-
						TDNN	93,5	-
						SVM	95,6	-
Tran; Franco; Ogier	2010	12th International Conference on Frontiers in Handwriting Recognition	UNIPEN e IRONOFF	1.600 (trein.) 400 (teste)	7HU, <i>Randon Invariantes e Zernike Moments</i>	SVM	95,6	-
Tran	2012	Proceeding SoICT '12 Proceedings of the Third Symposium on Information and Communication Technology	UNIPEN e IRONOFF	1.600 (trein.) 400 (teste)	7HU, <i>Randon Invariantes e Zernike Moments</i>	SVM	95,6	-
Azevedo; Zanchettin	2012	VIII Encontro Nacional de Inteligência Artificial - 2011 - Natal, RN	C-CUB	15.866 (trein.) e 7.972 (testes)	Algoritmo de Camastra (2007)	MLP-SVM	90,48	-
Santos et al	2008	XXXIV Conferencia Latinoamericana de Informática (CLEI 2008)	Nist sd19	74.880 (trein.) e 23.670 (teste)	Características do traçado e do fundo	Marckov	91,14	-
Passos et al	2015	XLVII Simpósio Brasileiro de Pesquisa Operacional	Caracteres de escritores	1.300	OCR	RNA	97,11	0,62
						KNN	95,57	0,58
						SVM	98,87	0,58
Sampath; Gomathi	2017	Sādhanā Published by the Indian Academy of Sciences	CHARK74K	64 imagens, extraídos 7.705 caracteres	HOG	Fuzzy SVM esférica	99,0	-

Fonte: Autoria própria (2019)

3.2 CONSIDERAÇÕES DO CAPÍTULO

Na revisão de literatura foram apreciados diversos trabalhos, os quais vêm buscando melhorar o desempenho das máquinas no reconhecimento de caracteres manuscritos. Neste Capítulo foram apresentados trabalhos que utilizam, principalmente, SVM's. Alguns destes trabalhos utilizam outras técnicas para comparação das SVM's, como exemplo, o trabalho de Passos et al (2015) que propõe uma comparação entre Redes Neurais, SVM e K-vizinho.

Os resultados dos trabalhos analisados estão apresentados no Quadro 3, o qual traz as principais informações de cada trabalho, ano de publicação, técnica, base de dados e número de amostras utilizadas e taxas de acerto alcançadas por cada técnica. Pode-se observar que nos trabalhos que realizaram uma comparação de técnicas para o reconhecimento de caracteres, as SVM's se sobressaíram as demais nas taxas de acertos.

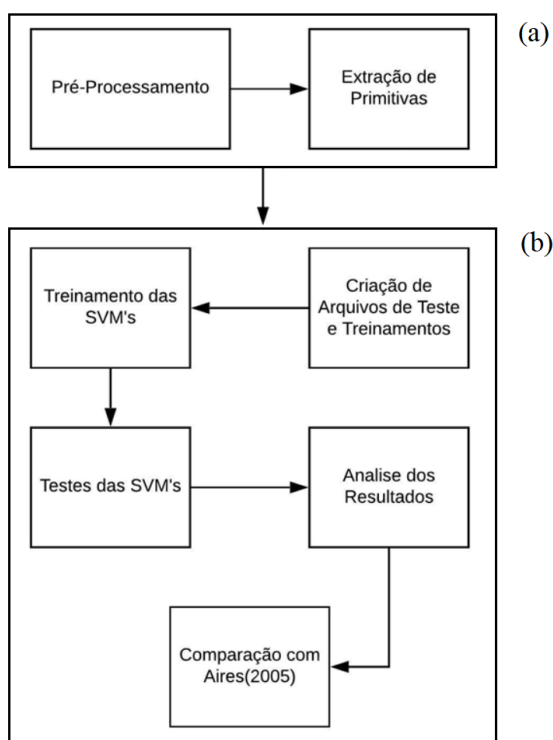
4 METODOLOGIA

Este Capítulo apresenta as etapas necessárias para o desenvolvimento do sistema de reconhecimento de caracteres. Serão abordados o pré-processamento, extração de primitivas e representação de primitiva, o mecanismo de zoneamento, a criação dos conjuntos de treinamento e teste utilizando zoneamento e configurações de *kernel's*, para construção das SVM's.

4.1 VISÃO GERAL DO SISTEMA

A Figura 27 apresenta uma visão geral do sistema de reconhecimento de caracteres manuscritos maiúsculos. É importante salientar que as etapas de pré-processamento e extração de características (Figura 27a) não foram realizadas neste estudo. Os vetores de características gerados de estudos anteriores serão utilizados para criação dos arquivos de teste e treinamento para construção das SVM's (Figura 27b).

Figura 27 – Visão geral resumida



Fonte: Autoria própria (2019)

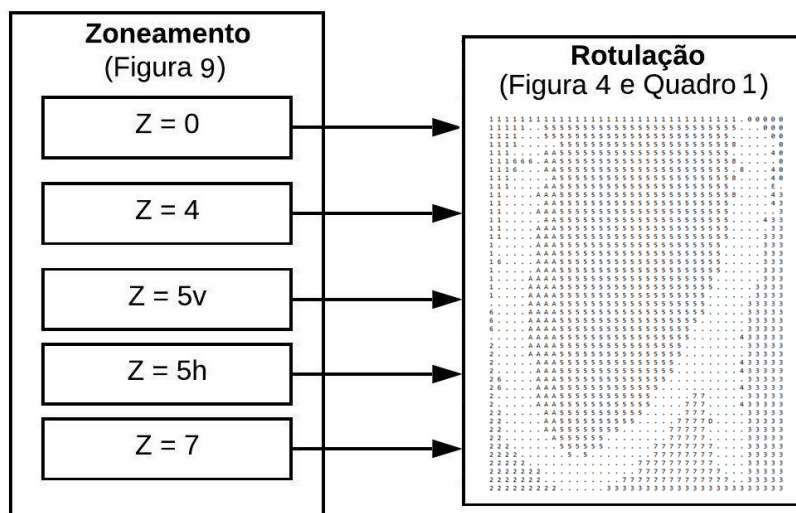
Para classificação das amostras, inicialmente criou-se SVM's treinadas com todas as 26 classes (A, ..., Z) seguindo as divisões de zoneamentos apresentadas no Capítulo 2.3.1 e as configurações de *kernel* do Capítulo 2.4.3 totalizando 15 SVM's, neste trabalho, identificadas como SVM's generalista. Posteriormente, foram criadas SVM's especialistas, onde cada SVM é especialista em uma classe de caractere, também seguindo as divisões de zoneamento e configurações de *kernel*, totalizando 390 SVM's especialistas. Ao final apresenta-se uma comparação das SVM's contruídas com as RNA's conforme os resultados obtidos por Aires (2005).

4.2 CRIAÇÃO DOS CONJUNTOS DE TREINAMENTO E TESTE

Para este trabalho foram utilizadas inicialmente 10.679 amostras de caracteres manuscritos maiúsculos da base dados IRONOFF que passaram por um processo de pré-processamento e extração de suas características seguindo os métodos apresentados no Capítulo 2.

Inicialmente utilizou amostras sem zoneamentos, identificadas aqui como $z = 0$. Posteriormente nestas amostras foram aplicados os zoneamentos perceptivos não simétricos propostos por Aires (2005) (*zoning*), onde cada amostra de caractere é dividida em Z partes ($z = 4$, $z = 5h$, $z = 5v$ e $z = 7$), como já discutido no Capítulo 2.3.1. Exemplificado na Figura 28.

Figura 28 - Fluxograma do zoneamento



Fonte: Autoria própria (2019)

Após o processo de zoneamento e extração de características gerou-se um vetor de características para cada amostra, separando estes em matrizes conforme a quantidade de partes do zoneamento como mostrado no Quadro 4.

Quadro 4 - Arquivos divididos por zoneamento

Arquivo	Zoneamento (Z)	Quantidade características (elementos do vetor)	Total de amostras (vetorizadas)
BN	Não zoneado	25	10.679
BN_4	Zoneamento em 4 partes (conforme Figura 22)	$25 \times 4 = 100$	10.679
BN_5v	Zoneamento em 5 partes na vertical (conforme Figura 22)	$25 \times 5 = 125$	10.679
BN_5h	Zoneamento em 5 partes na horizontal (conforme Figura 22)	$25 \times 5 = 125$	10.679
BN_7	Zoneamento em 7 partes (conforme Figura 22)	$25 \times 7 = 175$	10.679

Fonte: Autoria própria (2019).

A partir dos 5 arquivos do Quadro 4, efetuou-se um processo de separação por caractere e zoneamento gerando 130 novos arquivos (26 letras x 5 zoneamentos), cada um composto por aproximadamente 410 amostras de cada caractere, ou seja, 10.679 dividido por 26 caracteres. Esses arquivos foram utilizados para gerar os conjuntos de teste e treinamento para as SVM's generalista e SVM's especialistas.

4.3 CONSTRUÇÃO DAS SVM'S

Para a construção das SVM's generalistas as amostras foram separadas em conjuntos de treinamento e teste para cada zoneamento, sendo cada conjunto de treinamento composto por 300 amostras aleatórias de cada caractere e cada conjunto de teste de 100 amostras de cada caractere, apresentado na Tabela 1. Totalizando 5 conjuntos de treinamento, cada um com 7.800 amostras e 5 conjuntos de testes, cada um com 2.600 amostras.

Tabela 1 – Conjuntos de treinamento e teste das SVM's generalistas

Conjunto	TREINAMENTO		TESTE		
	Zoneamento	Amostras de cada caractere	Total de amostras	Amostras de cada caractere	Total
z = 0		300	7.800	100	2.600
z = 4		300	7.800	100	2.600
z = 5v		300	7.800	100	2.600
z = 5h		300	7.800	100	2.600
z = 7		300	7.800	100	2.600

Fonte: Autoria própria (2019)

Para a construção das SVM's especialistas as amostras foram separadas em conjuntos de treinamentos e testes para cada caractere e zoneamento, sendo composto cada conjunto de treinamento por 300 amostras de um determinado caractere mais 9 amostras de cada um dos demais caracteres, totalizando 525 amostras. Já os conjuntos de testes foram compostos cada um por 100 amostras de um determinado caractere mais 3 amostras de cada um dos demais caracteres, totalizando 175 amostras, conforme apresentados na Tabela 2. Os conjuntos de teste e treinamento, além de conter a quantidade de características, apresentadas no Quadro 4, também foi acrescentado uma classe com valores 0 ou 1, sendo atribuído 1 para o caractere no qual a SVM é especialista e 0 para as demais amostras.

Tabela 2 – Conjuntos de treinamento e teste das SVM's especialistas para cada zoneamento (continua)

Conjunto	TREINAMENTO			TESTE			
	Caractere	Amostras	Amostras de outros caracteres	Total de amostras	Amostras	Amostras de outros caracteres	Total de amostras
A		300	9 de cada	525	100	3 de cada	175
B		300	9 de cada	525	100	3 de cada	175
C		300	9 de cada	525	100	3 de cada	175
D		300	9 de cada	525	100	3 de cada	175
E		300	9 de cada	525	100	3 de cada	175
F		300	9 de cada	525	100	3 de cada	175
G		300	9 de cada	525	100	3 de cada	175
H		300	9 de cada	525	100	3 de cada	175
I		300	9 de cada	525	100	3 de cada	175

Tabela 2 – Conjuntos de treinamento e teste das SVM's especialista para cada zoneamento (conclusão)

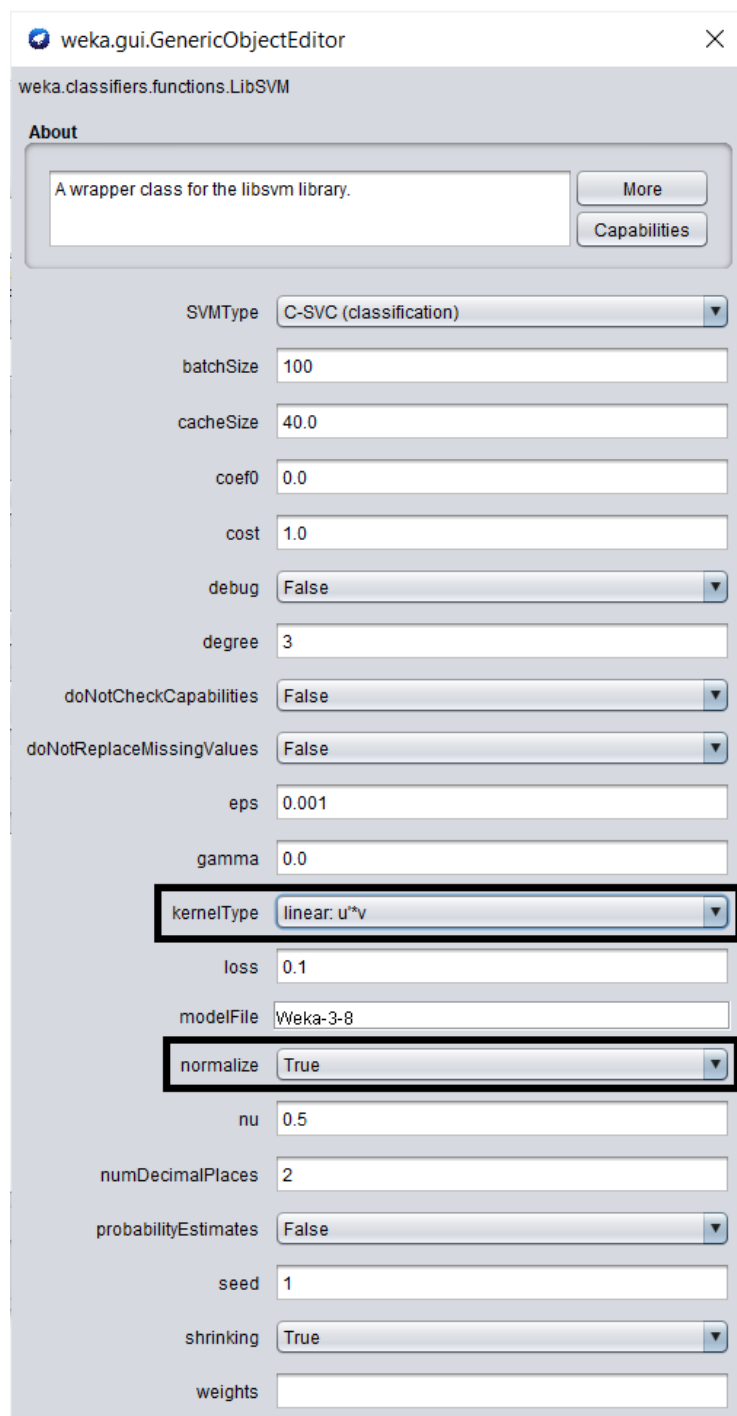
Conjunto	TREINAMENTO			TESTE		
	Caractere	Amostras	Amostras de outros caracteres	Total de amostras	Amostras	Amostras de outros caracteres
J	300	9 de cada	525	100	3 de cada	175
K	300	9 de cada	525	100	3 de cada	175
L	300	9 de cada	525	100	3 de cada	175
M	300	9 de cada	525	100	3 de cada	175
N	300	9 de cada	525	100	3 de cada	175
O	300	9 de cada	525	100	3 de cada	175
P	300	9 de cada	525	100	3 de cada	175
Q	300	9 de cada	525	100	3 de cada	175
R	300	9 de cada	525	100	3 de cada	175
S	300	9 de cada	525	100	3 de cada	175
T	300	9 de cada	525	100	3 de cada	175
U	300	9 de cada	525	100	3 de cada	175
V	300	9 de cada	525	100	3 de cada	175
W	300	9 de cada	525	100	3 de cada	175
X	300	9 de cada	525	100	3 de cada	175
Y	300	9 de cada	525	100	3 de cada	175
Z	300	9 de cada	522	100	3 de cada	175

Fonte: Aatoria própria (2019)

Todas as amostras apresentadas na Tabela 2 foram selecionadas aleatoriamente, sendo este processo efetuado para cada zoneamento, ou seja, $z = 0$, $z = 4$, $z = 5v$, $z = 5h$ e $z = 7$, obtendo-se um total de 130 (5 zoneamentos x 26 caracteres) conjuntos de treinamentos e 130 conjuntos de testes.

Para os treinamentos e testes foi utilizada a ferramenta WEKA com o pacote *LibSVM* como citado no Capítulo 2.5. As configurações utilizadas estão demonstradas na Figura 29, onde se utilizou o padrão *default* alterando apenas os parâmetros, *normalize* que normaliza novamente os dados utilizando apenas as amostras contidas no arquivo e o *kernelType* que altera a formar de cálculo conforme discutido no capítulo 2.4. Foram utilizados os *kernel's*: *linear*, *radial* e *sigmoid*.

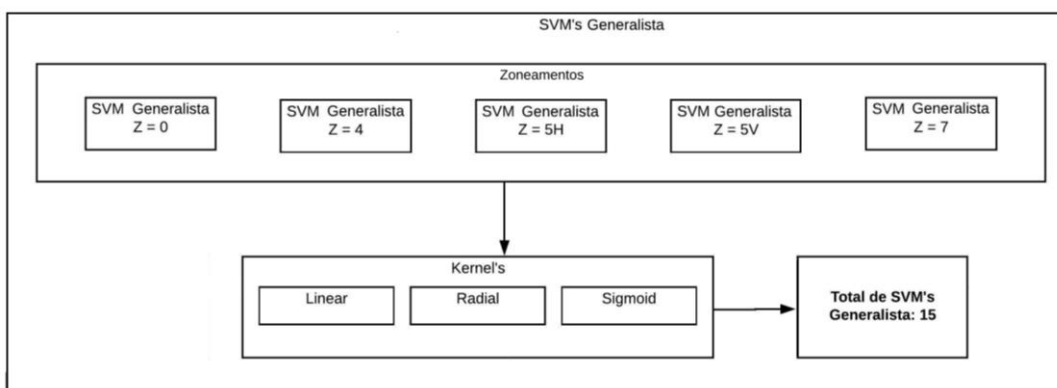
Figura 29 – Configurações da LibSVM



Fonte: Autoria própria (2019)

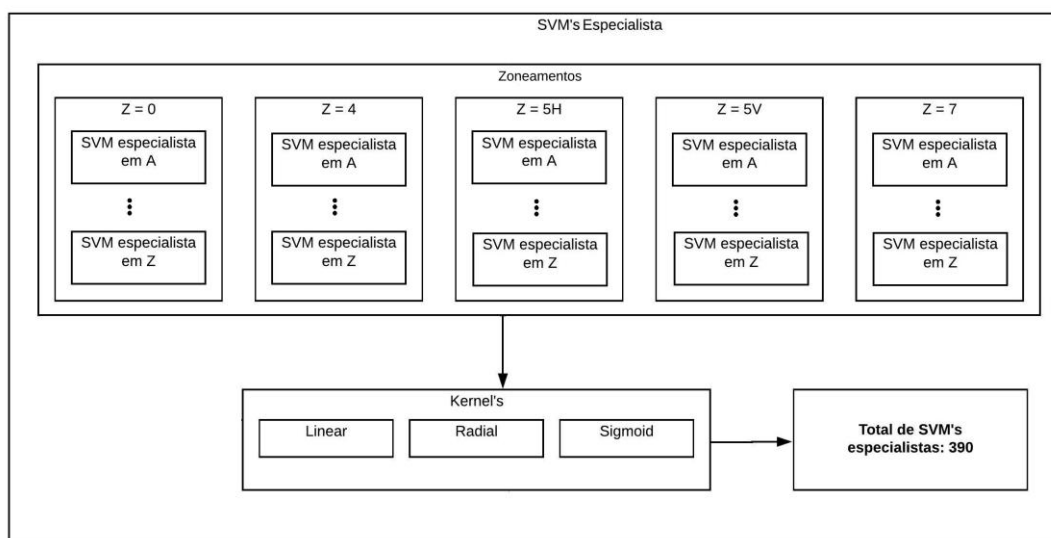
Foram construídas neste trabalho um total 405 SVM's, sendo 15 SVM's generalistas (5 zoneamentos x 3 *kernel's*) demonstradas na Figura 30, e 390 SVM's especialistas (26 caracteres x 5 zoneamentos x 3 *kernel's*), demonstradas nas Figuras 30 e 31. Os resultados obtidos serão apresentados nas Tabelas 4 e 5 no Capítulo 5.

Figura 30 – SMV's Generalista



Fonte: Autoria própria (2019)

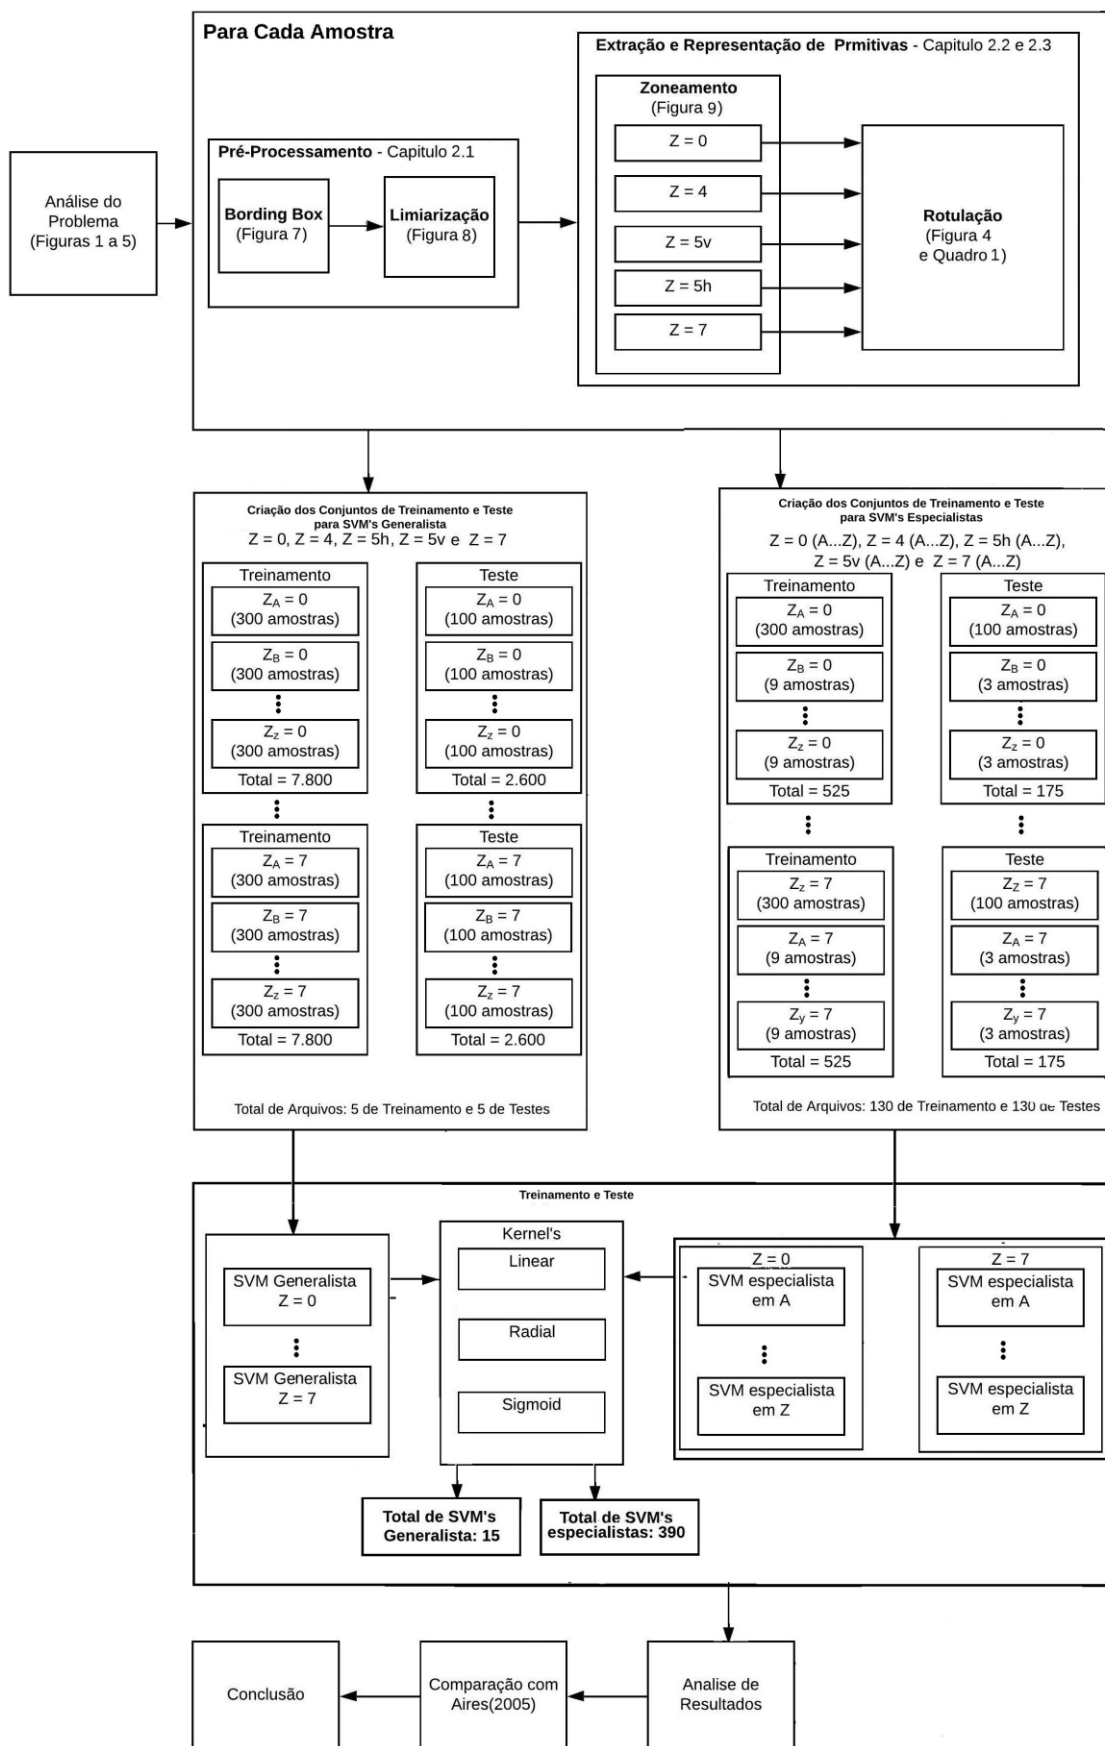
Figura 31 – SMV's Especialistas



Fonte: Autoria própria (2019)

A Figura 32 apresenta visão geral da metodologia descrita neste Capítulo.

Figura 32 – Visão geral da metodologia



Fonte: Autoria própria (2019)

4.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

As etapas de pré-processamento e extração foram efetuadas previamente a este trabalho. Neste trabalho foram realizadas as etapas de criação dos conjuntos de treinamento e teste para a construção das SVM's generalistas e especialistas, considerando o zoneamento e *kernel* e faz uma análise dos resultados obtidos e compara-os com os resultados das Redes Neurais propostas por Aires (2005).

5 RESULTADOS E DISCUSSÕES

Neste Capítulo serão apresentados os resultados obtidos nos experimentos realizados com as SVM's Generalistas e SVM's Especialistas para cada configuração de *Kernel* (*linear*, *radial*, *sigmoid*) e técnica de zoneamento perceptivo ($z = 0$, $z = 4$, $z = 5h$, $z = 5v$ e $z = 7$). Faz-se também uma seleção dos melhores resultados para uma comparação entre as SVM's e as RNA's propostas por Aires (2005).

5.1 RESULTADO DAS SVM'S GENERALISTAS

A Tabela 3 apresenta os resultados dos percentuais obtidos pelas SVM's generalistas, as quais como citado no Capítulo 4, foram treinadas para classificar todos os caracteres.

Tabela 3 – Acertos obtidos das SVM's Generalistas (%)

Z =	Linear	Radial	Sigmoid	Médias
0	76,8	67,9	61,8	68,8
4	86,7	77,2	72,5	78,8
5v	87,5	77,4	72,3	79,1
5h	87,5	77,2	72,4	79,0
7	78,3	59,7	59,7	65,9
médias	83,4	71,9	67,7	74,3
desvio padrão	5,3	7,9	6,4	6,4

Fonte: A autoria própria (2019)

As SVM's generalistas tiveram uma média geral acertos de 74,3%, sendo que o melhor desempenho foi de 87,5% de acerto alcançado com o *kernel linear* com o zoneamentos 5v e 5h. Valor inferior aos encontrados na literatura, conforme citado no Quadro 3. O menor desempenho foi de 59,7% obtido com os *kernel radial* e *sigmoid*, ambos com zoneamento $z = 7$.

O melhor resultado obtido com uma SVM generalista foi com a configuração de *kernel linear* e zoneamento 5v, onde a maior taxa de acerto foi de 96% com o caractere "A" e a menor de 74% com o caractere "D". As maiores confusões foram na classificação do caractere "D", sendo 10% confundidos com o "O" e com o


caractere "M" confundido 10% com o "H". A taxa de acerto na classificação do caractere "N" também foi baixa, apenas 76% sendo que 9% foram confundidos com o "W". Outras confusões foram na classificação do caractere "B" confundido 9% com o "D", o "K" com 9% confundido com "X" e com 7% de confusão, nas classificações do caractere "E" confundido com "C", "R" que foi confundido com o "A" e, na do caractere "W", confundido com o "U", conforme matriz de confusão apresentada na Figura 33.

Figura 33 - Matriz de confusão gerada pelo WEKA para a SVM generalista (z = 5v, Kernel: linear)

== Confusion Matrix ==																												
a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z	<-- classified as		
96	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0	0	0	1	0	0	0	0	a = A	
0	86	0	9	0	0	0	0	1	0	0	0	0	0	2	0	1	1	0	0	0	0	0	0	0	0	0	b = B ←	
0	0	92	0	2	0	1	0	0	0	1	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	c = C	
0	6	0	74	0	0	0	0	1	2	0	0	0	0	10	4	2	0	0	0	0	0	0	0	0	0	1	d = D ←	
0	0	7	0	82	2	4	0	1	2	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	e = E ←	
0	0	0	0	2	87	0	0	2	1	0	0	0	0	0	1	0	0	1	2	0	0	0	1	2	1	0	f = F	
1	1	2	0	1	2	84	0	2	0	0	0	0	0	0	1	2	0	0	1	0	0	0	2	0	1	0	g = G	
0	0	0	0	0	0	0	86	0	0	1	0	8	0	0	0	0	2	0	0	2	0	0	0	0	1	0	h = H	
0	0	0	0	0	0	0	88	6	0	2	0	0	0	0	0	0	0	1	0	0	1	0	1	0	2	0	i = I	
0	2	0	0	0	0	0	7	87	0	0	0	0	0	0	1	0	1	0	1	0	0	1	0	0	1	0	j = J	
0	0	0	1	0	0	0	2	1	0	91	1	1	0	0	0	0	0	0	0	0	0	0	0	2	0	1	k = K	
0	0	4	1	0	0	0	1	0	93	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	l = L	
2	0	0	0	0	0	0	10	0	0	1	0	82	2	0	1	0	0	0	0	0	0	1	0	1	0	0	m = M ←	
2	0	0	0	0	0	0	3	0	0	1	0	5	76	0	1	0	1	0	0	1	1	0	1	9	0	0	n = N ←	
0	0	0	0	0	0	0	0	0	0	0	0	0	97	0	1	0	0	0	1	1	0	0	0	1	0	0	o = O	
2	0	0	1	0	0	2	0	3	1	0	0	0	0	1	85	3	0	1	1	0	0	0	0	0	0	0	p = P	
0	0	0	1	0	0	1	0	0	0	0	0	0	0	2	2	93	1	0	0	0	0	0	0	0	0	0	q = Q	
7	0	0	0	0	0	0	1	1	0	1	0	1	0	1	1	87	0	0	0	0	0	0	0	0	0	0	r = R ←	
1	0	0	0	1	0	0	3	3	1	1	0	1	0	1	0	2	1	0	86	0	0	0	0	0	0	0	s = S	
0	0	0	0	1	0	1	0	0	2	0	0	1	0	0	1	0	0	0	90	1	0	0	3	0	0	0	t = T	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	0	0	0	0	91	1	5	0	0	0	0	u = U	
0	0	0	0	0	0	0	1	1	1	0	0	0	0	0	0	0	0	0	0	8	86	2	0	1	0	0	v = V	
0	0	0	0	0	0	0	1	0	0	0	0	6	0	0	0	0	0	0	0	7	1	85	0	0	0	0	w = W ←	
0	0	0	0	0	0	0	3	0	9	0	0	0	0	0	0	0	0	0	0	0	0	1	84	2	1	0	x = X ←	
0	0	0	0	0	1	0	0	1	2	1	0	0	0	0	0	0	0	1	0	0	0	0	0	94	0	0	y = Y	
0	1	0	0	1	0	0	0	1	2	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	93	0	z = Z	

Fonte: Autoria própria (2019)

As melhores médias de acertos das SVM's Generalistas foram com a configuração de *kernel linear*, e pode-se observar que quanto aplicada a técnica de zoneamento perceptivo aumenta a taxa de acertos. Porém, quando aplicado o zoneamento z = 7 essa taxa diminui, como podemos observar no Gráfico 1, onde são apresentadas as taxas médias de acerto das SVM's Generalistas com configuração de *kernel linear*.

Gráfico 1 - Médias das SVM's Generalistas por zoneamento (*kernel linear* - %)

Fonte: Autoria própria (2019)

5.2 RESULTADO DAS SVM'S ESPECIALISTAS

A Tabela 4 apresenta os percentuais de acerto de cada uma das 390 SVM's especialistas. É importante identificar que na primeira linha são apresentados os zoneamentos aplicados, na segunda linha o *kernel* utilizado (lin: *linear*, rad: *radial*, sig: *sigmoid*), e na primeira coluna o caractere em qual a SVM é especialista.

Tabela 4 - Acertos obtidos das SVM's Especialistas (%)

(continua)

Z =	0			4			5H			5V			7		
	caractere	lin	rad	sig	lin	rad	sig	lin	rad	sig	lin	rad	sig	lin	rad
A	91,4	84,0	82,9	95,4	88,6	85,7	97,1	88,6	88,0	96,0	87,4	85,1	96,6	81,1	72,6
B	91,4	84,6	84,0	93,7	88,6	85,7	94,9	91,4	87,4	96,0	85,7	85,7	93,1	84,6	78,9
C	94,9	94,3	92,6	97,1	88,6	92,6	97,7	94,3	93,1	97,1	93,1	90,9	95,4	88,0	88,6
D	94,3	93,1	86,3	95,4	88,0	82,9	96,6	91,4	84,6	97,1	89,1	86,3	96,0	84,6	65,1
E	88,6	88,6	88,6	92,0	89,7	89,7	92,6	90,3	89,7	91,4	90,9	89,7	90,9	85,1	86,3
F	90,9	85,1	85,1	92,0	87,4	85,1	90,9	88,0	86,9	95,4	86,9	84,0	94,3	88,6	84,6
G	89,1	86,3	80,0	93,7	86,9	84,6	92,0	88,0	84,6	93,1	88,0	83,4	93,1	82,9	65,7
H	87,4	86,9	85,7	95,4	85,1	85,1	94,3	85,7	84,6	94,3	86,3	84,6	91,4	86,9	69,1
I	90,3	84,0	81,7	92,0	83,4	70,9	93,7	84,6	69,1	91,4	82,9	69,1	92,0	76,6	58,3
J	89,7	86,3	87,4	94,3	90,9	85,7	92,0	89,7	85,1	93,1	89,7	84,6	92,0	87,4	72,0
K	82,3	78,3	73,7	94,3	88,0	85,1	94,3	88,0	74,3	95,4	85,1	77,1	95,4	81,1	57,7
L	97,1	95,4	95,4	97,1	94,9	94,3	96,0	94,3	93,7	97,1	93,7	93,1	98,3	93,7	91,4
M	91,4	90,3	89,1	93,7	90,3	89,1	91,4	89,1	88,6	94,3	88,6	89,1	92,6	86,9	78,3
N	88,0	86,9	85,1	93,1	88,0	86,9	92,6	87,4	85,7	92,0	88,6	86,9	92,0	85,7	79,4
O	95,4	93,7	92,0	97,7	94,3	92,0	98,3	93,7	92,6	98,3	94,3	92,6	96,6	89,7	88,6
P	85,1	85,1	84,6	93,7	89,7	88,6	94,9	87,4	86,3	94,3	88,6	86,3	93,7	90,9	85,7
Q	93,1	90,9	90,3	97,7	93,1	90,9	96,0	93,7	92,0	96,6	92,6	91,4	96,0	86,9	86,9
R	86,3	82,3	79,4	91,4	88,0	84,0	93,1	88,0	85,1	93,7	89,1	85,1	93,1	83,4	70,3
S	89,7	86,3	85,7	94,3	88,6	87,4	94,3	89,7	88,0	90,9	87,4	87,4	92,0	82,3	73,1

Tabela 4 - Acertos obtidos das SVM's Especialistas (%)

(conclusão)


Z =	0			4			5H			5V			7		
	caractere	lin	rad	sig	lin	rad	sig	lin	rad	sig	lin	rad	sig	lin	rad
T	96,6	93,7	94,9	97,1	93,1	93,1	95,4	93,1	92,6	97,7	92,6	90,9	96,0	92,6	92,0
U	96,0	95,4	95,4	96,6	95,4	94,9	96,6	95,4	93,7	97,7	95,4	94,9	96,0	94,3	89,1
V	87,4	85,7	84,0	91,4	84,6	84,6	92,6	84,0	83,4	92,0	83,4	84,0	90,9	85,1	84,0
W	94,9	92,0	89,7	93,7	93,1	91,4	94,9	92,6	92,0	93,1	92,0	92,0	93,7	92,6	88,0
X	82,3	72,0	61,1	89,1	84,0	66,9	92,6	85,7	72,6	88,6	85,7	65,1	91,4	69,7	57,1
Y	93,1	88,0	84,6	94,9	90,9	86,3	94,9	90,3	86,3	96,0	90,9	86,3	97,1	88,6	81,1
Z	92,0	89,7	89,1	97,1	95,4	94,3	95,4	94,3	92,6	98,3	94,9	92,6	96,6	93,1	85,7
média	90,7	87,6	85,7	94,4	89,6	86,8	94,4	90,0	86,6	94,7	89,3	86,1	94,1	86,2	78,1
desvio padrão	4,0	5,3	7,0	2,2	3,4	6,3	2,0	3,2	6,2	2,5	3,4	6,7	2,2	5,4	10,7

Fonte: Autoria própria (2019)

Obteve-se o melhor desempenho de 98,3%, com 4 ocorrências, todas utilizando o *kernel linear*, sendo uma com $z = 5h$ para letra “O”, duas com $z = 5v$ para as letras “O” e “V” e uma com $z = 7$ para a letra “L”. O menor desempenho foi 57,1% com o *kernel sigmoid* e $z = 7$ para letra “X”.

Identificou-se que os melhores desempenhos foram com o *kernel linear* com os zoneamentos 5h, 5v e 7, tendo estes o maior acerto de 98,3% e médias individuais acima de 94%, sendo que com $z = 5v$ com a melhor média de 94,7%. Sem zoneamentos obteve um melhor desempenho de classificação apenas na letra “W”. Com $z = 4$ os melhores desempenhos foram em 6 letras: “G”, “H”, “J”, “N”, “Q” e “S”. Com $z = 5v$ em 10 letras: “A”, “C”, “E”, “I”, “O”, “P”, “S”, “V”, “W” e “X”. Com $z = 5h$ em 10 letras: “B”, “D”, “F”, “K”, “M”, “O”, “R”, “T”, “U” e “Z”. Com $z = 7$ em apenas as 3 letras: “K”, “L” e “Y”. Todos com o *kernel linear*. O Gráfico 2 apresenta as médias de acerto das SVM’s Especialistas por zoneamento utilizando a configuração de *kernel linear*.

Gráfico 2 - Médias das SVM’s Especialistas por zoneamento (*kernel linear* - %)



Fonte: Autoria própria (2019)

5.3 SVM'S GENERALISTAS X SVM'S ESPECIALISTAS

Considerando-se os resultados apresentados pode-se observar que as SVM's generalistas e especialistas obtêm resultados melhores quando utilizado zoneamento perceptivo $z = 5v$ e configuração de *kernel linear*. Sendo que as SVM's

especialistas tiveram médias de acerto significativamente superiores as SVM's generalistas, uma vez que a média de acerto sobe de 87,5% na SVM generalista para 94,7% nas SVM's especialistas, como apresentado na Tabela 5.

**Tabela 5 – Taxas de acertos com zoneamento
5v e kernel linear**

Caractere	SVM Generalista	SVM Especialista z = 5
A	96,0	96,0
B	86,0	96,0
C	92,0	97,1
D	74,0	97,1
E	82,0	91,4
F	87,0	95,4
G	84,0	93,1
H	86,0	94,3
I	88,0	91,4
J	87,0	93,1
K	91,0	95,4
L	93,0	97,1
M	82,0	94,3
N	76,0	92,0
O	97,0	98,3
P	85,0	94,3
Q	93,0	96,6
R	87,0	93,7
S	86,0	90,9
T	90,0	97,7
U	91,0	97,7
V	86,0	92,0
W	85,0	93,1
X	84,0	88,6
Y	94,0	96,0
Z	93,0	98,3
média	87,5	94,7
desvio padrão	5,5	2,5

Fonte: Autoria própria (2019)

Nas SVM's especialistas todas as taxas de acertos foram superiores aos das SVM's generalistas, com exceção do caractere "A", onde ambas obtiveram valores iguais de 96%. A melhor taxa de acerto das SVM's generalistas foi de 97% na classificação do caractere "O" onde as SVM's especialistas obtiveram 98,3%, sendo este, também, o resultado para a classificação do caractere "Z". Resultados estes que foram os maiores alcançados pelas SVM's especialistas.

Na Tabela 5 pode-se observar que a menor taxa de acerto das SVM's generalistas foi na classificação do caractere "D" com apenas 74%, já na SMV's especialistas essa taxa sobe para 97,1%. As SVM's especialistas em "X" teve a menor taxa de acerto com 88,6%, ainda assim, maior que na SVM generalista que obteve 84%.

Quando se observa o desvio padrão nas taxas de acerto por caracteres das SVM's generalistas e especialistas, as SVM's especialistas se mostram melhores com 2,5 pontos percentuais, enquanto as SVM's generalistas este valor sobe para 5,5, nos casos apresentados na Tabela 6.

5.4 COMPARAÇÃO DAS SVM'S COM AS RN'S

Nesta seção são comparados os resultados obtidos por Aires (2005) utilizando Redes Neurais (RN's) especialistas e os resultados deste trabalho obtidos pelas SVM's especialistas com *kernel linear* e zoneamentos perceptivos. A Tabela 6 apresenta a comparação destes resultados.

Tabela 6 – Comparação de resultados com Aires (2005)

(continua)

Z =	4		5H		5V		7	
	RN	SVM	RN	SVM	RN	SVM	RN	SVM
A	86,6	95,4	85,1	97,1	89,6	96,0	89,6	96,6
B	76,1	93,7	68,7	94,9	86,6	96,0	83,6	93,1
C	89,6	97,1	88,1	97,7	67,2	97,1	97,0	95,4
D	92,5	95,4	82,1	96,6	89,6	97,1	94,0	96,0
E	85,1	92,0	77,6	92,6	85,1	91,4	85,1	90,9
F	91,0	92,0	82,1	90,9	89,6	95,4	91,0	94,3
G	92,5	93,7	83,6	92,0	80,6	93,1	91,2	93,1
H	76,1	95,4	82,1	94,3	69,7	94,3	73,1	91,4

Tabela 6 – Comparação de resultados com Aires (2005)

(conclusão)

Z =	4		5H		5V		7	
	RN	SVM	RN	SVM	RN	SVM	RN	SVM
I	77,6	92,0	64,2	93,7	77,6	91,4	77,6	92,0
J	80,6	94,3	74,6	92,0	79,1	93,1	83,6	92,0
K	86,6	94,3	80,6	94,3	83,6	95,4	89,6	95,4
L	97,0	97,1	94,0	96,0	92,5	97,1	97,0	98,3
M	82,1	93,7	86,6	91,4	91,0	94,3	89,6	92,6
N	76,1	93,1	83,6	92,6	76,1	92,0	76,1	92,0
O	97,0	97,7	97,0	98,3	98,5	98,3	98,5	96,6
P	92,5	93,7	97,0	94,9	91,0	94,3	94,0	93,7
Q	83,6	97,7	61,2	96,0	70,1	96,6	88,1	96,0
R	82,1	91,4	85,1	93,1	92,5	93,7	98,5	93,1
S	92,5	94,3	91,0	94,3	85,1	90,9	85,1	92,0
T	98,5	97,1	97,0	95,4	98,5	97,7	98,5	96,0
U	85,1	96,6	89,6	96,6	85,1	97,7	94,0	96,0
V	97,0	91,4	91,0	92,6	98,5	92,0	94,0	90,9
W	83,6	93,7	68,7	94,9	67,2	93,1	80,6	93,7
X	83,6	89,1	79,1	92,6	83,6	88,6	82,1	91,4
Y	85,1	94,9	85,1	94,9	95,5	96,0	91,0	97,1
Z	89,6	97,1	68,7	95,4	77,6	98,3	88,1	96,6
média	86,9	94,4	82,4	94,4	84,7	94,7	88,9	94,1
desvio padão	6,8	2,2	10,0	2,0	9,5	2,6	7,1	2,2

Fonte: Autoria própria (2019)

Observa-se que a SVM obteve resultados de acertos melhores na classificação de caracteres maiúsculos manuscritos com médias de acertos superiores as Redes Neurais em todos os zoneamentos. Sendo que a maior diferença foi no zoneamento $z = 5h$ onde as RN's tem média de acerto de 82,4% e a SVM de 94,4% e a menor diferença no zoneamento $z = 7$ com médias de acertos de 88,9% e 94,1%, RN e SVM respectivamente.

Com os resultados obtidos por Aires (2005) identifica-se que o melhor desempenho das RN's foi com o zoneamento $z = 7$ com uma taxa de acerto média de 88,9% e desvio padrão de 7,1 pontos, sendo o melhor resultado no reconhecimento dos caracteres "O", "R" e "T" que alcançaram taxas de acerto de 98,5%. Já, as SVM's, no zoneamento $z = 7$, tiveram a menor média de acertos com

94,1% e desvio padrão de 2,2 pontos, encontrado maior dificuldade para reconhecimento dos caracteres “E” e “V” com taxa de 90,9% em ambos.

5.5 MELHORES RESULTADOS DAS SVM’S ESPECIALISTAS

Se fosse possível considerar somente o melhor zoneamento e a melhor configuração de *kernel*, das SVM’s especialistas, para cada classe de caractere teríamos os valores apresentados na Tabela 7. Onde a configuração de *kernel linear* foi a melhor. As SVM’s treinadas com amostras sem zoneamentos ($z = 0$) apresentaram as menores taxas de acerto. O zoneamento $z = 4$ obteve as melhores taxas de acertos em 6 caracteres. Já os zoneamentos $z = 5h$ e $z = 5v$ foram melhores em 9 caracteres cada um. O zoneamento $z = 7$ foi melhor em apenas 2 caracteres, “L” e “Y”.

Tabela 7 – Melhores resultados obtidos

(continua)

Caractere	Zoneamento	Kernel	Taxa de acerto %
A	5h	linear	97,1
B	5v	linear	96,0
C	5h	linear	97,7
D	5v	linear	97,1
E	5h	linear	92,6
F	5v	linear	95,4
G	4	linear	93,7
H	4	linear	95,4
I	5h	linear	93,7
J	4	linear	94,3
K	5v	linear	95,4
L	7	linear	98,3
M	5v	linear	94,3
N	4	linear	93,1
O	5h	linear	98,3
P	5h	linear	94,9
Q	4	linear	97,7
R	5v	linear	93,7
S	4	linear	94,3

Tabela 7 – Melhores resultados obtidos

			(conclusão)
Caractere	Zoneamento	Kernel	Taxa de acerto %
T	5v	linear	97,7
U	5v	linear	97,7
V	5h	linear	92,6
W	5h	linear	94,9
X	5h	linear	92,6
Y	7	linear	97,1
Z	5v	linear	98,3
média			95,5
desvio padrão			2,0

Fonte: Autoria própria (2019)

As SVM's treinadas com amostras sem zoneamentos ($z = 0$) apresentaram as menores taxas de acerto. O zoneamento $z = 4$ obteve as melhores taxas de acertos em 6 caracteres: "G", "H", "J", "N", "Q" e "S". Já os zoneamentos $z = 5h$ e $z = 5v$ foram melhores em 9 caracteres cada um. O zoneamento $z = 7$ foi melhor em apenas 2 caracteres, "L" e "Y".

Com um sistema dinâmico onde se utilizasse a melhor configuração (zoneamento/kernel) poderia chegar a uma taxa média de acertos de 95,5% e desvio padrão de 2 pontos percentuais.

5.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo efetuou-se uma análise dos resultados obtidos nos experimentos com SVM's generalistas e especialistas com os zoneamentos preceptivos e configuração de *kernel*. Onde as SVM's especialistas tiveram resultados superiores as das SVM's generalistas. Identificando também que, a configuração de *kernel linear* foi a que alcançou as melhores taxas de acertos nas SVM's generalistas e especialistas. Então, foram comparados os resultados obtidos neste trabalho com as RN's propostas por Aires (2005), sendo utilizadas as SVM's especialistas, as quais obtiveram resultados superiores às RN's. Também, propôs-se que havendo uma forma de selecionar as melhores configurações de zoneamento e *kernel* poderia-se aumentar as taxas de acerto das SVM's especialistas.

6 CONCLUSÃO

Como discutido no início deste trabalho, tem-se a crescente necessidade de que as máquinas reconheçam e interpretem as diversas formas de escrita devido às mais diversas informações que são produzidas e necessitam ser transmitidas para o mundo digital, como cartas, receitas, cheques, formulários, entre outros. Efetuar esse processo manualmente consome muito tempo e mão de obra. Sendo assim, há a necessidade de um sistema que efetue esse trabalho de forma automatizada, reconhecendo as palavras manuscritas.

Quando o reconhecimento é efetuado com palavras há possibilidade de interpretação e de associação com palavras já conhecidas para reconhecer os caracteres, mas, quando se trabalha com o caractere isolado, fora do contexto de uma palavra, aumenta-se a dificuldade da máquina no reconhecimento do caractere manuscrito devido a grande quantidade de variedade de estilos de escrita (MENEZES et al, 2014).

Conforme apresentado no Capítulo 3, no Quadro 1 há vários estudos que buscam aperfeiçoar o processo de reconhecimento de caractere manuscrito. Dentro desse contexto, este trabalho busca colaborar com a comunidade através de um estudo de caso com o reconhecimento de caractere manuscritos da base IRONOFF. Para isso, foi proposto utilizar SVM para classificar e buscar uma melhor configuração de *kernel* e qual o melhor zoneamento perceptivo do caractere para obter melhores taxas de precisão no reconhecimento de caracteres manuscritos maiúsculos. Utilizando como medida uma comparação com as taxas alcançadas pelas Redes Neurais Artificiais propostas por Aires (2005).

Para cumprir os objetivos deste trabalho, foram construídas 15 SVM's generalistas (com todas as classes de letras) e 390 SVM's especialistas para reconhecimento de caracteres manuscritos maiúsculos do alfabeto latino utilizando regiões perceptivas ($z = 0$, $z = 4$, $z = 5h$, $z = 5v$, $z = 7$) e 3 *kernel's* (*linear*, *radial* e *sigmoid*). Para os experimentos, utilizou-se a base de dados IRONOFF e a ferramenta WEKA com a biblioteca LibSVM. Construídas as SVM's, os resultados alcançados foram comparados com os dados obtidos por Aires (2005) no experimento com redes neurais, conforme apresentado no Capítulo 5, Tabela 6.

Conclui-se que SVM's especialistas têm um melhor desempenho em relação as SVM's generalistas, com todas as classes de caracteres maiúsculos, como pode-se observar no Capítulo 5 nas Tabelas 3, 4 e 5. E que o zoneamento eleva o desempenho das SVM's, sendo os melhores resultados obtidos com zoneamento 5h e 5v, respectivamente, como discutido no capítulo 5. A escolha do *kernel* também contribui para aumentar a taxa de reconhecimento da SVM, sendo que neste trabalho as maiores taxas de acerto foram com o *kernel linear*, tanto para a SVM generalistas quanto para as SVM's especialistas.

Quando comparados os resultados das SVM's com os resultados obtidos por Aires (2005) com redes neurais (RN), pode-se observar um número maior de acertos das SVM's, destacando-se o zoneamento 5h que obteve uma média de acerto de 94,4% contra 82,4% as RN's e desvio padrão de 2,0 versus 10,0 da RN's. Ainda no zoneamento 5h, podem-se apontar alguns resultados como nos caracteres "Q", "I" e "Z" com taxas de reconhecimento nas SVM's de 96,0%, 93,7% e 95,4% e nas RN's de 61,2%, 64,2% e 68,7%. As RN's se sobressaíram, no zoneamento 5h, em relação as SVM's apenas, no reconhecimento dos caracteres "P" e "T" com 97% de acerto em ambos, enquanto as SVM's com 94,9% e 95,4% respectivamente. Representando assim, as maiores diferenças de resultados entre os experimentos nesse zoneamento, como apresentado na Tabela 8.

Analisando os resultados apresentados no Capítulo 5 na Tabela 6, verifica-se que quando confrontadas as SVM's, construídas neste trabalho, com RN's propostas por Aires (2005), as SVM's tiveram taxas de acerto melhores em 87,5% dos casos comparados, ou seja, em 91 dos 130 resultados comparados.

Como resultado final deste trabalho, reuniu-se na Tabela 8 do Capítulo 5 as melhores taxas de acerto no reconhecimento de caracteres manuscritos maiúsculos obtidos pelas SMV's especialistas, levando em consideração o zoneamento e a configuração de *kernel*. Sendo que, a configuração de *kernel linear* foi superior a *radial e sigmoid* e os melhores zoneamentos foram com $z = 5h$ e $z = 5v$. Resultados que apontam que quando aplicada a técnica de zoneamento, melhora do desempenho da SVM no reconhecimento do caractere, porém, excessos de divisões como $z = 7$ dificultam o reconhecimento.

Quando analisados os dados da Tabela 7, pode-se concluir que sendo possível definir dinamicamente o melhor zoneamento perceptível e também o melhor

kernel para cada classe de caractere, seria possível aumentar a taxa média de acertos para 95,5%.

Para trabalhos futuros sugere-se que a partir dos resultados obtidos neste trabalho seja criado um comitê das 26 SVM's especialistas para reconhecimento de caracteres manuscritos maiúsculos. Neste comitê, as SVM's seriam alinhadas de forma que cada uma verificasse se o caractere pertence a sua classe, sendo a decisão final tomada com base nos resultados apresentado por cada uma das SVM's.

Uma possível pesquisa é a aplicação de novos métodos para extração de características, pré-processamento para os ajustes de inclinação e rotação dos caracteres, buscando evitar as confusões por similaridade entre eles. Podendo ainda, as características extraídas passarem por uma árvore decisão, onde seriam elencado quais as características quem têm mais impacto nas amostras, diminuindo a quantidade destas, aperfeiçoando os dados de entradas nos classificadores.

Outro estudo poderia utilizar as Redes CNN (Rede Neural Convolutacional) em conjunto com as SVM's (*Support Vector Machine*). A CNN seria responsável por extrair as características dos caracteres resultando em um vetor que seria posteriormente enviado para as SVM's especialistas, que, então, fariam a classificação dos caracteres. Abrindo-se assim, novos leques de discussões para buscar desenvolver técnicas mais refinadas para o reconhecimento de caracteres manuscritos.

REFERÊNCIAS

AHMAD, A. R.; KHALIA, M.; GAUDIN, C. V.; POISSON, E. Online handwriting recognition using support vector machine. In: IEEE REGION 10 CONFERENCE TENCN. 11., 2004, Chiang Mai, 2004. p. 312-314.

AHMAD, A. R.; KHALID, M.; YOUSOF, R. **Machine Learning Using Support Vector Machines**. 2002. Disponível em <<https://www.semanticscholar.org/paper/Machine-Learning-Using-Support-Vector-Machines-Ahmad-Khalid/3fac5ce5ff0f1ee917f0f3d4599f84cf046e0207>>. Acessado em: 30 set. 2018.

AIRES, S. B. K. **Reconhecimento de caracteres manuscritos baseado em regiões perceptivas**. 2005. 97 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Informática Aplicada, Pontifícia Universidade Católica do Paraná. Curitiba, 2005.

ARTERO, A. O.; TOMMASELLI, A. M. G. Limiarização automática de imagens digitais. **Boletim de Ciências Geodésicas**, Curitiba (PR), v. 6, n. 1, p. 38-48, 2000.

AZEVEDO, W. W.; ZANCHETTIN, C. **Um Modelo Híbrido MLP-SVM para Reconhecimento de Caracteres Manuscritos Cursivos**. 2012. Disponível em: <<http://docplayer.com.br/65725685-Um-modelo-hibrido-mlp-svm-para-reconhecimento-de-caracteres-manuscritos-cursivos.html>>. Acesso em: 04 nov. 2018.

BENTO, C. A. M. A. **Análise grafológica da escrita aplicada à população prisional**. 2016. 00 f. Dissertação (Mestrado) – Instituto de Ciências Biomédicas Abel Salazar da Universidade do Porto. Portugal, 2016.

BORCHARTT, T. B. **Análise de imagens termográficas para a classificação de alterações na mama**. 2013. 118 f. Tese (Doutorado) – Programa de Pós-Graduação em Computação, Universidade Federal Fluminense. Niterói, 2013.

BONESSO, D. **Estimação dos parâmetros do kernel em um classificador SVM na classificação de imagens hiperespectrais em uma abordagem multiclasse**. 2013. 108 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul. Porto Alegre, 2013.

CAMASTRA, F. ASVM-based cursive character recognizer. **Pattern Recognition**, Napoli, v. 40, n. 12, p. 3721–3727, fev. 2007.

CHANG, C.; LIN, C. LIBSVM: A library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, n. 3, p. 1-27, abr. 2011.

CHEN, J.; WANG, C.; WANG, R. Adaptive Binary Tree For Fast SVM Multiclass Classification. **Neurocomputing**, Amsterdam, v. 72, ed. 13, p. 3370-3375, ago. 2009.

GIL, A. M. **Reconhecimento de dígitos manuscritos**: busca de classificador com máxima taxa de acerto. 2014. 92 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Amazonas. Manaus, 2014.

GONZALES, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. 3. ed. São Paulo: Pearson Prentice Hall, 2010.

HALL, M.; et al. The WEKA Data Mining Software: An Update. **SIGKDD Explorations**, v. 11, n. 1, p. 10-18, 2009.

HEUTTEA, L.; PAQUETA, T.; MOREAUB, J. V.; LECOURTIER, A.; OLIVIER, C. A structural/statistical feature based vector for handwritten character recognition. **Pattern Recognition Letters**, Amsterdam, v. 19, ed. 7, p. 629-641, mai. 1998.

LOPES, F. M. **Um modelo perceptivo de limiarização de imagens digitais**. 2003. 97 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Informática, Universidade Federal do Paraná. Curitiba, 2003.

LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, Porto Alegre (RG), v. 14, n. 2, p. 43-67, 2007.

MENEZES, C. S.; ALMEIDA, L. L.; SILVA, F. A.; PAZOTI, M. A.; ARTERO, A. O. **Redes Neurais Classe Modular Aplicadas no Reconhecimento de Caracteres Manuscritos**. 2014. Disponível em: <<http://revistas.unoeste.br/revistas/ojs/index.php/ce/article/viewArticle/1095>>. Acesso em: 02 set. 2018.

NUNES, C.M. **seleção de primitivas utilizando algoritmo subida de encosta otimizado em problemas de reconhecimento de caracteres**. 2004. 95 f. Dissertação (Mestrado) – Programa de Pós-graduação em Informática Aplicada, Pontifícia Universidade Católica do Paraná. Curitiba, 2004.

OLIVEIRA JR, J. J. **Reconhecimento de palavras manuscritas usando análise multi-vistas**. 2006. 91 f. Dissertação (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande. Campina Grande, 2006.

PASSOS, U. R. C; MATIAS, I. O; ANDRADE, M.; PASSOS, C. E. S. O. Um estudo comparativo entre técnicas de inteligência computacional para o reconhecimento ótico de caracteres manuscritos. In: XLVII SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL. 8., 2015, Porto de Galinhas. Porto de Galinha: Universidade Federal de Pernambuco, 2015. p. 3137-3148.

REIS, B.; et al. Análise de técnicas de limiarização adaptativa para realidade aumentada embarcada. In: WORKSHOP DE REALIDADE VIRTUAL E AUMENTADA, 2010, São Paulo. **Anais do WRVA** São Paulo: MACKENZIE, 2010.

SANTOS, M.; OLIVEIRA, L. E. S.; SABOURIN, R.; KOERICH, A. L.; BRITTO JR, A. A. Combinando Características Complementares em Modelos Escondidos de Markov: uma otimização para o reconhecimento de caracteres manuscritos. In: XXXIV CONFERENCIA LATINOAMERICANA DE INFORMÁTICA, 2008, Santa Fé, 2008. p. 260-269.

SAMPATH, A. K.; GOMATHI, N., S. Fuzzy-based multi-kernel spherical support vector machine for effective handwritten character recognition. **Sādhanā Published by the Indian Academy of Sciences**, India, v. 42, n. 9, p. 1513-1525, set. 2017.

SUEN, C.Y., GUO, J., LI, Z.C. Analisis and Recognition of Alphanumeric Handprints by parts. **IEEE, Transactions on Systems, Man, and Cybernetics**, v. 24, p. 614-631, abr. 1994.

TRAN, D. C. An efficient method for on-line Vietnamese handwritten character recognition. In: PROCEEDINGS OF THE THIRD SYMPOSIUM ON INFORMATION AND COMMUNICATION TECHNOLOGY. 8., 2012, Ha Long, 2012. p. 135-141.

TRAN, D. C.; FRANCO, P.; OGIER, J. Accented handwritten character recognition using SVM – Application to French. In: INTERNATIONAL CONFERENCE ON

FRONTIERS IN HANDWRITING RECOGNITION. 11., 2010, Kolkata, 2010. p. 65-71.

VELOSO, L. R. **Sistema de reconhecimento de palavras manuscritas dependente do usuário**. 2009. 144 f. Tese (Doutorado) – Doutorado em Engenharia Elétrica, Universidade Federal de Campina Grande. Campina Grande, 2009.

VIARD-GAUDIN, C.; LALLICAN, P. M.; KNERR, S.; BINTER, P. **The IRESTE On/Off (IRONOFF) Dual Handwriting Database**. 2002. Disponível em <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=791823>>. Acessado em: 25 set. 2018.