

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SÃO PAULO

GUILHERME CANCIAN DE ARAUJO

ESTUDO DE UM CLASSIFICADOR DO TIPO MÁQUINA DE VETORES DE SUPORTE
PARA A CLASSIFICAÇÃO DE SINAIS MIOELÉTRICOS PROVENIENTES DO
ANTEBRAÇO

SÃO PAULO

2017

Guilherme Cancian de Araujo

ESTUDO DE UM CLASSIFICADOR DO TIPO MÁQUINA DE VETORES DE SUPORTE
PARA A CLASSIFICAÇÃO DE SINAIS MIOELÉTRICOS PROVENIENTES DO
ANTEBRAÇO

Dissertação apresentada como pré-requisito de
conclusão do curso de mestrado profissional
em Automação e Controle de Processos do
Instituto Federal de Educação, Ciência e
Tecnologia de São Paulo.

Orientador: *Prof. Dr. Ricardo Pires*

São Paulo, 2017

Catalogação na fonte
Biblioteca Francisco Montojos - IFSP Campus São Paulo
Dados fornecidos pelo(a) autor(a)

A658e	<p>Araujo, Guilherme Cancian de Estudo de um classificador do tipo máquina de vetores de suporte para a classificação de sinais mioelétricos provenientes do antebraço / Guilherme Cancian de Araujo. São Paulo: [s.n.], 2017. 82 f. il.</p> <p>Orientador: Ricardo Pires</p> <p>Dissertação (Mestrado Profissional em Automação e Controle de Processos) - Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, IFSP, 2017.</p> <p>1. Reconhecimento de Sinais Mioelétricos. 2. Máquina de Vetores de Suporte. 3. Prótese Biônica. I. Instituto Federal de Educação, Ciência e Tecnologia de São Paulo II. Título.</p> <p>CDD 629.8</p>
-------	---



ATA DE EXAME DE DEFESA DE DISSERTAÇÃO

Nome do Programa: **Mestrado Profissional em Automação e Controle de Processos**

Nome do(a) Aluno(a): Guilherme Cancian de Araújo

Nome do(a) Orientador(a): Prof. Dr. Ricardo Pires

Nome do(a) Coorientador(a):

Título do Trabalho: "Estudo de um classificador do tipo máquina de vetores de suporte para a classificação de sinais mioelétricos provenientes do antebraço"

Abaixo o resultado de cada participante da Banca Examinadora

Nome completo dos Participantes Titulares da Banca	Sigla da Instituição	Aprovado / Não Aprovado
Prof. Dr. Ricardo Pires – Orientador	IFSP – SPO	<i>aprovado</i>
Prof. Dr. Alexandre Brincalpe Campo – Membro Interno	IFSP – SPO	APROVADO
Prof. Dr. Ulysses Fernandes Ervilha - Membro Externo	USP	APROVADO
Nome completo dos Participantes Suplentes da Banca	Sigla da Instituição	Aprovado / Não Aprovado
Prof. Dr. Alexandre Simião Caporali – Membro Interno	IFSP – SPO	
Prof. Dr. Luis Mochizuki - Membro Externo	USP	

Considerando-o: APROVADO
 NÃO APROVADO

Assinaturas

São Paulo, 03 de agosto de 2017

Ricardo Pires

Presidente da Banca

Alan N. C.

Membro Interno

Ulysses Ervilha

Membro Externo

Observações:

DEDICATÓRIA

Dedico este trabalho a todos os deficientes físicos do Brasil e do mundo, bem como a todos os estudiosos de soluções de reabilitação.

AGRADECIMENTOS

Agradeço primeiramente à minha mãe e irmã por sempre me incentivarem e me confortarem durante os momentos difíceis. Além disso, gostaria de agradecer ao meu professor e orientador Ricardo Pires por toda a ajuda durante a realização deste trabalho. Finalmente, agradeço a todo o corpo docente do Instituto Federal de Educação, Ciência e Tecnologia de São Paulo por todo o conhecimento que me foi passado.

EPÍGRAFE

“Pensar é o trabalho mais árduo que há. Talvez seja essa a razão para tão poucos se dedicarem a isso.”

“Henry Ford”

RESUMO

O presente trabalho aborda o estudo e o desenvolvimento de um classificador utilizando Máquina de Vetores de Suporte para o reconhecimento de diferentes movimentos da mão humana. Para isso, foram utilizados sinais mioelétricos gerados pelos músculos do antebraço. Tais sinais são provenientes de uma base de dados pública. O classificador desenvolvido foi projetado para o reconhecimento de oito padrões diferentes, por isso ele possui oito Máquinas de Vetores de Suporte organizadas em cascata. Cada uma ficou responsável por separar uma classe em relação a todas as outras. Para estudar o classificador, alguns testes foram realizados variando-se o número de vetores apresentados para o treinamento do classificador, o número de amostras utilizadas para calcular as características temporais que formam os vetores e o tipo de *kernel*. Os *kernels* utilizados foram: linear, quadrático e polinomial de terceira ordem. Após a etapa de treinamento, 100 vetores de cada uma das oito classes foram apresentados para o classificador com o objetivo de medir a precisão obtida. Como resultado, foi observado que, dentro das condições de estudo, o classificador desenvolvido foi capaz de atingir índices de acerto de até 99,62%. Com isso é possível concluir que as classes de movimentos estudadas são linearmente separáveis e, portanto, é viável a utilização de máquinas de vetores de suporte para a classificação desses padrões.

Palavras-chave: Reconhecimento de sinais mioelétricos, Máquina de Vetores de Suporte, Prótese biônica

ABSTRACT

The following research work studies the behavior of a Support Vector Machine when classifying grasp patterns of the human hand. To do so, myoelectric signals captured from the muscles of the forearm were used. These signals are from a public database. The classifier was designed to recognize eight different grasp patterns; therefore, the algorithm of the designed classifier is composed of eight Support Vector Machine organized in cascade, and each of which is responsible for segregate a specific class from all others. In order to study the classifier, some tests were performed varying the number of vectors used to train it, the number of samples used to calculate the time domain features, which are the vector`s components, and the kernel type. The used kernels were: linear, quadratic and third order polynomial. After training the classifier, one hundred of vectors of each class were presented to the classifier in order to measure its performance. As a result, the developed classifier was able to reach up to 99,62% of accuracy. This implies that the studied classes are linearly separable, which leads to conclude that Support Vector Machines are appropriate to classify the studied patterns.

Key-words: Myoelectric pattern recognition, Support Vector Machine, Bionic prosthetics

SUMÁRIO

1. INTRODUÇÃO	13
1.1. OBJETIVO	15
1.2. OBJETIVOS ESPECÍFICOS	15
1.3. ORGANIZAÇÃO TEXTUAL	15
2. FUNDAMENTOS TEÓRICOS	17
2.1. MÁQUINA DE VETORES DE SUPORTE	17
2.1.1. HIPERPLANO ÓTIMO	18
2.1.2. CLASSIFICADOR	23
2.2. FUNÇÕES <i>KERNEL</i>	23
2.2.1. INTRODUÇÃO ÀS FUNÇÕES <i>KERNEL</i>	23
2.2.2. <i>KERNEL</i> MATEMATICAMENTE	25
2.3. MÁQUINAS DE VETORES DE SUPORTE EM CASCATA	27
2.4. SINAL MIOELÉTRICO	29
2.4.1. DEFINIÇÃO	29
2.4.2. CARACTERÍSTICAS DOS SINAIS MIOELÉTRICOS	29
2.4.3. RUÍDOS PRESENTES NOS SINAIS MIOELÉTRICOS	31
2.4.3.1. RUÍDO DEVIDO À MOVIMENTAÇÃO DOS ELETRODOS	31
2.4.3.2. RUÍDO AMBIENTE	31
2.4.3.3. RUÍDO DA REDE ELÉTRICA	32
2.5. CARACTERÍSTICAS TEMPORAIS APLICADAS NO CLASSIFICADOR MVS	32
2.5.1. VALOR MÉDIO ABSOLUTO (VMA)	33
2.5.2. NÚMERO DE CRUZAMENTOS NO EIXO REAL (NCR)	33
2.5.3. COMPRIMENTO DA FORMA DE ONDA (CFO)	34
2.5.4. NÚMERO DE MUDANÇAS DE SINAL DA DERIVADA (NMSD)	34
2.6. TIPOS DE ELETRODOS PARA AQUISIÇÃO DE SINAIS MIOELÉTRICOS	35
2.6.1. ELETRODO AGULHA	35
2.6.2. ELETRODO DE SUPERFÍCIE	36
2.6.2.1. ELETRODOS DESCARTÁVEIS	37
2.6.2.2. ELETRODOS REUTILIZÁVEIS	38
2.7. INSTALAÇÃO DE ELETRODO DE SUPERFÍCIE	39
3. REVISÃO BIBLIOGRÁFICA	40

4. METODOLOGIA	44
4.1. BASE DE DADOS DE SINAIS MIOELÉTRICOS	44
4.2. PROGRAMA COMPUTACIONAL DESENVOLVIDO PARA O ESTUDO	47
4.2.1. PROGRAMA COMPLETO	48
4.2.2. VETOR UTILIZADO PELO CLASSIFICADOR	48
4.2.3. CLASSIFICADOR EM CASCATA.....	50
4.2.4. ETAPA DE TREINAMENTO DO CLASSIFICADOR EM CASCATA.....	50
4.2.5. ETAPA DE CLASSIFICAÇÃO DE SINAIS MIOELÉTRICOS	53
5. RESULTADOS E DISCUSSÃO	54
5.1. <i>KERNEL</i> LINEAR	54
5.2. <i>KERNEL</i> QUADRÁTICO	55
5.3. <i>KERNEL</i> POLINOMIAL DE TERCEIRA ORDEM	56
5.4. COMPARAÇÃO DOS RESULTADOS OBTIDOS	57
5.5. COMPARAÇÃO COM OUTROS TRABALHOS	58
6. CONCLUSÃO	61
6.1. SUGESTÃO PARA TRABALHOS FUTUROS	62
REFERÊNCIAS BIBLIOGRÁFICAS	63
APÊNDICE A – Resultados dos testes utilizando o <i>kernel</i> linear	71
APÊNDICE B – Resultados dos testes utilizando o <i>kernel</i> quadrático	75
APÊNDICE C – Resultados dos testes utilizando o <i>kernel</i> polinomial de terceira ordem	79

LISTA DE FIGURAS

Figura 1 - Exemplo de classes linearmente separáveis.....	17
Figura 2 - Exemplo de classes não separáveis linearmente.....	18
Figura 3 - Vetores w e u	18
Figura 4 - Produto escalar entre os vetores w e u	19
Figura 5 – Representação matemática da margem de separação	21
Figura 6 - Classes não linearmente separáveis	24
Figura 7 - Novo espaço vetorial com o emprego de uma possível função <i>Kernel</i>	24
Figura 8 - Plano de separação das classes no novo espaço vetorial.....	25
Figura 9 - Ideia básica do emprego de <i>Kernel</i>	26
Figura 10 - Classificador em cascata.....	28
Figura 11 - Espectro de frequência do músculo Tibialis Anterior	30
Figura 12 - Sinal mioelétrico gerado durante a abertura e o fechamento de uma mão.....	30
Figura 13 - Eletrodo tipo agulha.....	35
Figura 14 - Unidade motora muscular.....	36
Figura 15 - Eletrodo descartável.....	37
Figura 16 - Eletrodo reutilizável do tipo barra	38
Figura 17 - Eletrodo reutilizável de sucção	38
Figura 18 - Localização do eletrodo de superfície	39
Figura 19 – Classe mão fechada (MF).	45
Figura 20 – Classe dedo polegar flexionado (PF).....	45
Figura 21 – Classe dedo Indicador flexionado (IF).	45
Figura 22 – Classe dedo médio flexionado (MEF).....	46
Figura 23 – Classe dedo anular flexionado (AF).....	46
Figura 24 – Classe dedo mínimo flexionado (MINF).	46
Figura 25 – Classe dedos indicador e polegar flexionados (PIF).....	46
Figura 26 – Classe dedos médio, anular e mínimo flexionados (MAMF).....	47
Figura 27 - Localização dos eletrodos.	47
Figura 28 - Diagrama de fluxo do programa desenvolvido	49
Figura 29 - MVS conectadas em cascata para distinguir até oito classes diferentes	51
Figura 30 - Algoritmo de treinamento do classificador	52
Figura 31 - Etapa de teste do classificador em cascata.....	53
Figura 32 - Desempenho do classificador para o <i>kernel</i> linear.....	55
Figura 33 - Desempenho do classificador para o <i>kernel</i> quadrático.....	56
Figura 34 - Desempenho do classificador para o <i>kernel</i> polinomial de terceira ordem	57

LISTA DE ABREVIATURAS E SIGLAS

<i>AF</i>	Classe dedo anular flexionado
<i>CFO</i>	Comprimento da forma de onda
<i>IF</i>	Classe dedo indicador flexionado
<i>MAMF</i>	Classe dedos médio, anular e mínimo flexionado
<i>MEF</i>	Classe dedo médio flexionado
<i>MF</i>	Classe mão fechada
<i>MINF</i>	Classe dedo mínimo flexionado
<i>MVS</i>	Máquina de vetores de suporte
<i>NCR</i>	Número de cruzamentos no eixo real
<i>NMSD</i>	Número de mudança de sinal da derivada
<i>PF</i>	Classe dedo polegar flexionado
<i>PIF</i>	Classe dedos polegar e indicador flexionado
<i>VMA</i>	Valor médio absoluto

1. INTRODUÇÃO

A amputação é a remoção total ou parcial de um dos membros do corpo humano. Tal fatalidade pode ocorrer devido a traumas ou a enfermidades (JAIN; ROBINSON, 2008; DEAN, 1991). Diversas doenças podem trazer como consequência a amputação, como por exemplo, o diabetes, o câncer ou as doenças circulatórias (WAINSTEIN, 2012; KULKARNI; PANDE; MORRIS, 2006). Os traumas que levam à remoção de um membro ocorrem geralmente em ambientes de trabalho durante a operação de máquinas, como prensas ou serras (GAINE; SMART; ZACHARY, 1997). Outra grande causadora de amputações traumáticas são as guerras e os conflitos, como a guerra do Iraque e Afeganistão (STANSBURY et al., 2008; SMURR et al., 2008; EPSTEIN; HEINEMANN; MCFARLAND, 2010). Acidentes veiculares também são responsáveis por grande parte das amputações realizadas (WANI et al., 2012; CALIL, 2009).

A perda de um membro pode afetar a vida de uma pessoa de maneira significativa. Tarefas até então corriqueiras podem se tornar barreiras praticamente insuperáveis sem a devida ajuda. Caso seja perdido um membro superior, tarefas simples, como comer, banhar-se, vestir-se e usar o banheiro passam a se tornar complexas e difíceis de serem realizadas sem a ajuda de outra pessoa (GRECH; DEBONO, 2014; LIU, 2010). Por isso, muitas das pessoas que sofreram algum tipo de amputação acabam perdendo parte da sua independência e adquirindo alguma depressão. No caso da perda de um membro inferior, a locomoção é extremamente prejudicada e ações como caminhar, agachar-se e correr tornam-se praticamente inviáveis (GRECH; DEBONO, 2014; LIU, 2010).

Além dos problemas de mobilidade, problemas psicológicos e relacionados à saúde também são consequências da perda de um membro. Dentre os problemas psicológicos, destacam-se a síndrome do membro fantasma, a depressão e a vergonha (AMPUTEE COALITION OF AMERICA, 2016; BRADWAY, 1984; SRIVASTAVA, 2010; GRECH; DEBONO, 2014; LIU, 2010). Em relação aos problemas ligados à saúde, destacam-se as enfermidades cutâneas, infecções e dores no membro residual, que

podem ser vitalícias (AJUBADE; AKINNIYI; OKOYE, 2013; PASCALE; POTTER, 2014; SUBEDI et al., 2016).

Dentre as soluções existentes para resolver parte dos problemas gerados pela perda de um dos membros e melhorar a qualidade de vida do amputado, destaca-se: o uso de próteses estéticas, que são passivas e priorizam a aparência do usuário; e o uso de próteses biônicas, que são equipamentos acionados através de sinais mioelétricos, ou seja, sinais provenientes da contração muscular. Estes sinais podem ser gerados tanto por músculos intactos quanto por resíduos musculares que ficam presentes no coto após a amputação (O'NEILL; MORIN; SCOTT, 1994). Tais dispositivos são utilizados para substituir o membro perdido e fazer com que o amputado retome parte dos seus movimentos e atividades que até então estavam comprometidos (GAINÉ; SMART; ZACHARY, 1997; MILLSTEIN; BAIN; HUNTER, 1985; GRIMMER, 2016; LÉVESQUE; GAGNON, 1987). Além de contribuir com a mobilidade, as próteses possuem um papel estético importante, pois impactam diretamente na aparência do usuário.

Uma prótese biônica é constituída por dois sistemas: mecânico e eletrônico. O sistema mecânico é responsável por simular a forma e a movimentação da mão humana. O sistema eletrônico, por sua vez, é composto por um sensor mioelétrico e por um sistema de processamento. O sensor mioelétrico é encarregado pela aquisição dos sinais musculares provenientes do músculo ou do resíduo muscular alvo. Já o sistema de processamento é responsável pela filtragem e interpretação do sinal muscular capturado pelo sensor, fazendo com que a prótese execute o movimento que o usuário deseja (ZECCA et al., 2002).

A interpretação do sinal mioelétrico é realizada através de um algoritmo computacional, como uma rede neural ou uma lógica difusa (KHZERII; JAHED; SADATI, 2007; AMARAL et al., 2012; CHAN et al., 2000; KHEZRI; JAHED, 2007; REAZ; HUSSAIN; YASIN, 2006; CHOWDHURY et al., 2013). Esta parte é de fundamental importância para o funcionamento adequado da prótese, pois um algoritmo que interprete o estímulo do usuário de maneira incorreta pode gerar consequências desastrosas, como objetos derrubados e o próprio usuário sendo ferido.

Diante deste cenário, o presente trabalho aborda o estudo e o desenvolvimento de um algoritmo que utiliza Máquinas de Vetores de Suporte na interpretação de sinais mioelétricos visando ao acionamento de próteses biônicas. O algoritmo foi desenvolvido no MATLAB. Os sinais utilizados para o treinamento e teste do classificador são provenientes de uma base de dados pública (KHUSHABA, 2012). É importante destacar que todo o processamento e análise foram feitos de forma *off-line* e não em tempo real.

1.1. OBJETIVO

Estudar a viabilidade do uso de Máquinas de Vetores de Suporte para a classificação de sinais mioelétricos provenientes do antebraço, visando à ativação de próteses biônicas e utilizando as características temporais: Número de Mudanças de Sinal da Derivada (NMSD), Número de Cruzamentos no Eixo Real (NCR), Valor Médio Absoluto (VMA) e Comprimento da Forma de Onda (CFO).

1.2. OBJETIVOS ESPECÍFICOS

- A. Estudar a variação da taxa assertiva do classificador utilizando os *Kernels* Linear, quadrático e polinomial de terceira ordem para verificar qual é o mais adequado para classificar sinais mioelétricos provenientes do antebraço;
- B. Estudar a variação da taxa assertiva do classificador variando o número de vetores apresentados para o seu treinamento;
- C. Estudar a variação da taxa assertiva do classificador variando o número de amostras utilizadas para calcular as componentes NMSD, NCR, VMA CFO do vetor utilizado pelo classificador.

1.3. ORGANIZAÇÃO TEXTUAL

As próximas seções explicam toda a teoria e os passos realizados para o desenvolvimento deste trabalho. A seção 2 possui os fundamentos teóricos necessários

para o entendimento de todos os assuntos aqui presentes; a seção 3 consiste na revisão bibliográfica de artigos e livros que possuem informações relevantes para o desenvolvimento desta dissertação; a seção 4 trata dos métodos utilizados no presente estudo; a seção 5 retrata os resultados obtidos através dos estudos realizados; e, finalmente, a seção 6 apresenta as conclusões obtidas.

2. FUNDAMENTOS TEÓRICOS

Neste capítulo são apresentados os conceitos básicos para o entendimento deste trabalho. Primeiramente será discutido o funcionamento do classificador do tipo Máquina de Vetores de Suporte definido por Cortes e Vapnik (1995); em seguida, serão discutidas as características temporais utilizadas pelo classificador desenvolvido; finalmente, será dada uma breve introdução sobre sinais mioelétricos e as suas características.

2.1. MÁQUINA DE VETORES DE SUPORTE

De acordo com Cortes e Vapnik (1995), trata-se de um tipo de classificador, com aprendizagem supervisionada, capaz de distinguir duas classes linearmente separáveis. Caso as classes não sejam linearmente separáveis, é possível utilizar funções *Kernel* para mapeá-las num espaço vetorial de maior dimensão, onde a probabilidade da existência de uma fronteira linear seja maior (HAYKIN, 2014, p. 281).

Dado um conjunto com vetores de treinamento pertencentes a duas classes A e B, o algoritmo de treinamento constrói um modelo que é capaz de classificar vetores inseridos posteriormente. A Figura 1 mostra duas classes, A e B, linearmente separáveis, enquanto que a Figura 2 mostra duas classes, C e D, não linearmente separáveis.

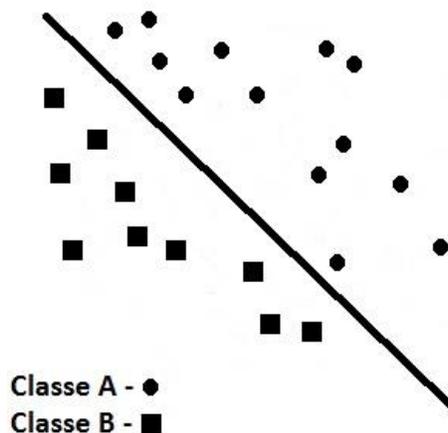


Figura 1 - Exemplo de classes linearmente separáveis

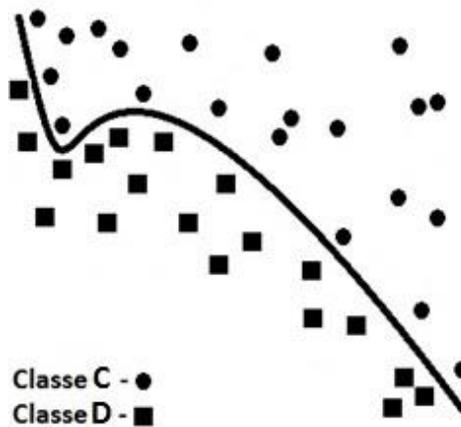


Figura 2 - Exemplo de classes não separáveis linearmente

Para a classificação de vetores pertencentes a duas classes distintas, o classificador do tipo Máquina de Vetores de Suporte utiliza um hiperplano. Pontos pertencentes a um determinado lado do hiperplano serão classificados como pertencentes a uma determinada classe.

2.1.1. HIPERPLANO ÓTIMO

Considere dois vetores: \vec{w} , que é perpendicular ao hiperplano, e \vec{u} , que representa uma amostra a ser classificada. Ambos são mostrados na Figura 3.

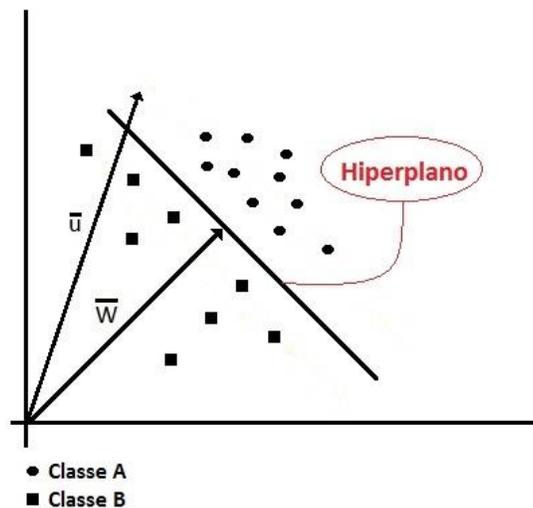


Figura 3 - Vetores \vec{w} e \vec{u} .

Fazendo o produto escalar dos vetores \vec{w} e \vec{u} obtém-se o valor “c” (Equação 1) que representa a distância entre a projeção do vetor \vec{u} em \vec{w} e a origem do sistema, conforme a Figura 4.

$$\vec{W} \cdot \vec{u} = c \quad (1)$$

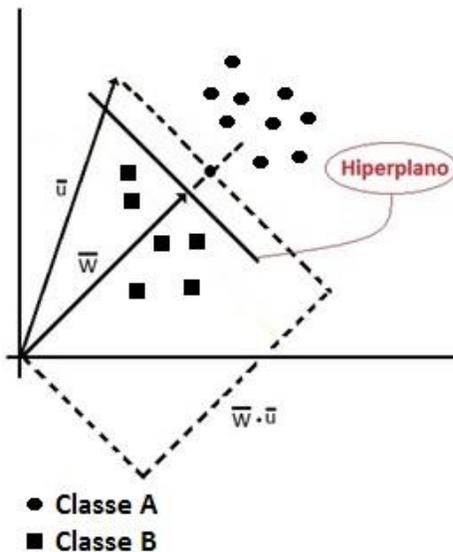


Figura 4 - Produto escalar entre os vetores \vec{w} e \vec{u} .

Comparando o valor “c”, obtido através da Equação 1, com a constante “h” que representa o comprimento do vetor \vec{w} , obtém-se duas equações classificadoras da Máquina de Vetores de suporte, representadas a seguir:

$$\text{Se } \vec{W} \cdot \vec{u} \geq h, \text{ então } \vec{u} \text{ pertence à classe A} \quad (2)$$

$$\text{Se } \vec{W} \cdot \vec{u} < h, \text{ então } \vec{u} \text{ pertence à classe B} \quad (3)$$

Caso o produto escalar dos dois vetores seja maior ou igual a constante “h” (tamanho do vetor \vec{w}), a amostra pertencerá à classe “A”. Caso o produto escalar seja menor que a constante, a amostra pertencerá à classe B. Desta maneira têm-se duas

equações que podem ser utilizadas para a classificação de amostras apresentadas a MVS.

Reescrevendo a regra de classificação, obtém-se as Equações 4 e 5, que na verdade representam a mesma coisa, mas de forma diferente.

$$\text{Se } \vec{W} \cdot \vec{u} + b \geq 0, \text{ então } \vec{u} \text{ pertence à classe A} \quad (4)$$

$$\text{Se } \vec{W} \cdot \vec{u} + b < 0, \text{ então } \vec{u} \text{ pertence à classe B} \quad (5)$$

Desta maneira, o objetivo do algoritmo de treinamento é obter os valores \vec{w} e b que geram o hiperplano ótimo.

Modificando as equações 4 e 5 para atender aos seguintes requisitos:

- Para todos os elementos \vec{X}_A pertencentes à classe A, a Equação 4 resultará em um valor maior ou igual a +1;
- Para todos os elementos \vec{X}_B pertencentes à classe B, a Equação 5 resultará em um valor menor ou igual a -1.

Chega-se às Equações 6 e 7.

$$\vec{W} \cdot \vec{X}_A + b \geq +1 \quad (6)$$

$$\vec{W} \cdot \vec{X}_B + b \leq -1 \quad (7)$$

Por conveniência matemática, pode-se introduzir uma variável y_i que resulta em +1 para elementos pertencentes à classe A e -1 para elementos pertencentes à classe B. Multiplicando as Equações 6 e 7 por y_i , obtém-se as Equações 8 e 9.

$$y_i \cdot (\vec{W} \cdot \vec{X}_A + b) \geq +1 \quad (8)$$

$$y_i \cdot (\vec{W} \cdot \vec{X}_B + b) \geq +1 \quad (9)$$

Como pode ser observado, as Equações 8 e 9 são iguais. Com isso, chega-se à Equação 10 que será utilizada como uma restrição no cálculo do hiperplano ótimo.

$$y_i \cdot (\vec{W} \cdot \vec{X}_A + b) - 1 \geq 0 \quad (10)$$

Fazendo com que a Equação 10 resulte exatamente em zero para todos os elementos que forem Vetores de Suporte, temos:

$$y_i \cdot (\vec{W} \cdot \vec{X}_{sp} + b) - 1 = 0 \quad (11)$$

Onde \vec{X}_{sp} representa um Vetor de Suporte.

O objetivo do algoritmo de treinamento é maximizar a margem de separação. Para calcular o tamanho desta margem, devem-se considerar dois Vetores de Suporte: \vec{X}_{spA} , pertencente à classe A, e \vec{X}_{spB} , pertencente à classe B (Figura 5). A representação matemática da margem de separação H em função dos dois Vetores de Suporte é dada pela Equação 12 (lembrando que o vetor \vec{W} é normal ao hiperplano ótimo).

$$H = (\vec{X}_{spA} - \vec{X}_{spB}) \cdot \frac{\vec{W}}{\|\vec{W}\|} \quad (12)$$

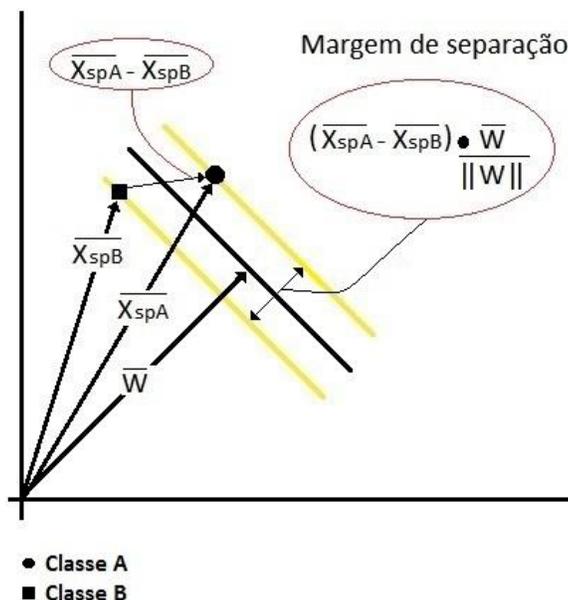


Figura 5 – Representação matemática da margem de separação

Utilizando a condição descrita pela Equação 11 na Equação 12, tem-se a Equação 13.

$$H = (\overrightarrow{X_{spA}} - \overrightarrow{X_{spB}}) \cdot \frac{\overrightarrow{W}}{\|W\|} = \frac{2}{\|W\|} \quad (13)$$

Lembrando que o objetivo do algoritmo de treinamento é maximizar a margem de separação, então, de acordo com a Equação 13, isso significa minimizar o módulo do vetor \overrightarrow{W} . Por conveniência matemática, pode-se dizer que minimizar o módulo do vetor \overrightarrow{W} é a mesma coisa que a operação descrita pela Equação 14.

$$MIN(\frac{1}{2}\|W\|^2) \quad (14)$$

Onde MIN significa minimizar.

Utilizando Multiplicadores de Lagrange é possível minimizar a Equação 14 submetida à restrição descrita pela Equação 11. Desta maneira, chega-se à Equação 15.

$$L = \frac{1}{2}\|W\|^2 - \sum \alpha_i \cdot [y_i(\overrightarrow{W} \cdot \vec{x}_i + b) - 1] \quad (15)$$

Derivando a Equação 15 em função do vetor \overrightarrow{W} e igualando a zero para achar o mínimo, obtém-se a Equação 16; diferenciando a mesma Equação em função de “b” tem-se a Equação 17.

$$\overrightarrow{W} = \sum \alpha_i \cdot y_i \cdot \vec{x}_i \quad (16)$$

$$\sum \alpha_i \cdot y_i = 0 \quad (17)$$

Substituindo as Equações 16 e 17 na Equação 15, chega-se à Equação 18 que deve ser maximizada para achar o hiperplano de separação das classes. Uma das técnicas para maximizar a equação 18 pode ser encontrada em Platt (1998).

$$L = \sum \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j (\vec{x}_i \cdot \vec{x}_j) \quad (18)$$

2.1.2. CLASSIFICADOR

Após a maximização da Equação 18, obtém-se \vec{W} que é representado pela Equação 16. Substituindo \vec{W} nas equações de decisão representada pelas Equações 4 e 5, chega-se à Equação 19 e 20 que serão utilizadas para classificar um elemento apresentado à Máquina de Vetores de Suporte.

$$\text{Se } (\sum \alpha_i \cdot y_i \cdot \vec{x}_i) \cdot \vec{u} + b \geq 0, \text{ então } \vec{u} \text{ pertence à classe A} \quad (19)$$

$$\text{Se } (\sum \alpha_i \cdot y_i \cdot \vec{x}_i) \cdot \vec{u} + b < 0, \text{ então } \vec{u} \text{ pertence à classe B} \quad (20)$$

2.2. FUNÇÕES *KERNEL*

Esta seção apresenta o conceito básico de *Kernel*. Ela está dividida em duas subseções: Introdução às funções *Kernel* e *Kernels* matematicamente. A subseção Introdução às funções *Kernel* explica as principais ideias da utilização de funções *kernel* em conjunto com classificadores do tipo Máquina de Vetores de Suporte; já a subseção *Kernels* matematicamente mostra todo o conceito matemático do funcionamento de *Kernels* em conjunto com Máquinas de Vetores de Suporte.

2.2.1. INTRODUÇÃO ÀS FUNÇÕES *KERNEL*

Funções *Kernel* podem ser empregadas em conjunto com a Máquina de Vetores de Suporte para transformar classes não linearmente separáveis em classes

linearmente separáveis. Basicamente, as funções *Kernel* mudam o espaço vetorial original para um espaço de maior dimensão (HAYKIN, 2014, p. 281). É importante ressaltar que o emprego de uma função *Kernel* não garante a linearização da fronteira entre as classes. A Figura 6 mostra duas classes cujos elementos são coplanares. Como pode ser notado, não existe uma fronteira linear de separação entre as classes.

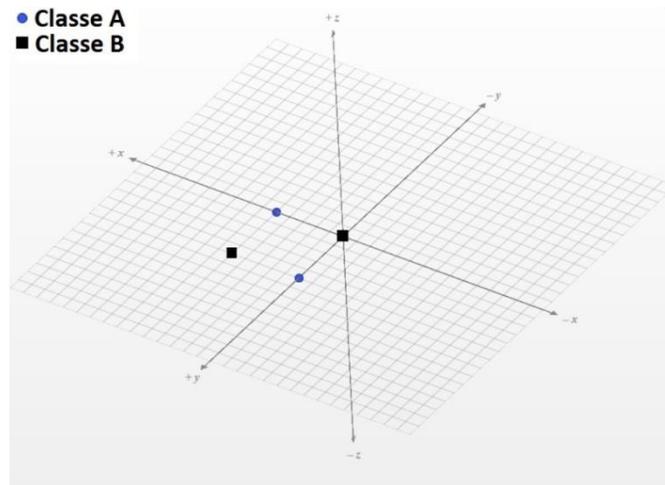


Figura 6 - Classes não linearmente separáveis

Com o emprego de uma possível função *Kernel*, o espaço vetorial da Figura 6 poderia ser transformado num novo espaço vetorial mostrado na Figura 7, onde uma das classes seria deslocada no eixo Z.

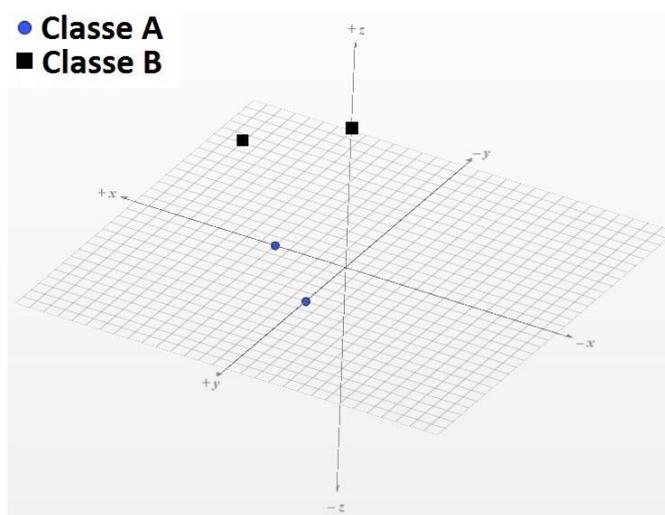


Figura 7 - Novo espaço vetorial com o emprego de uma possível função *Kernel*

A partir do novo espaço vetorial mostrado na Figura 7, um plano poderia ser utilizado para separar ambas as classes, conforme a Figura 8.

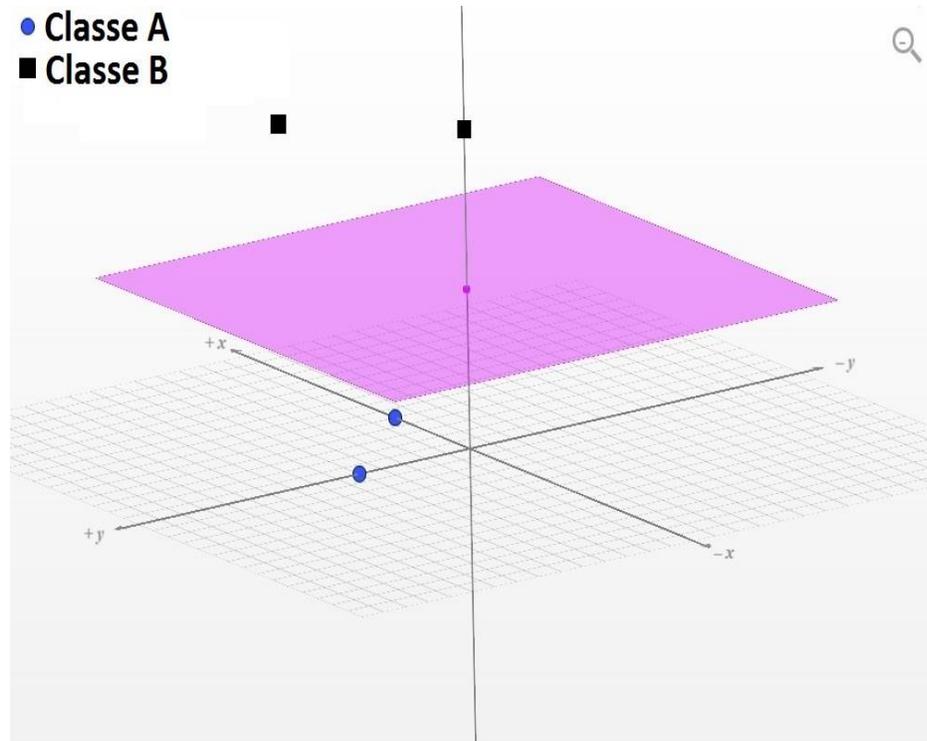


Figura 8 - Plano de separação das classes no novo espaço vetorial

2.2.2. KERNEL MATEMATICAMENTE

O emprego de uma MVS em conjunto com uma função Kernel é composta de duas ideias resumidas abaixo. Tais ideias também são representadas na Figura 9.

1. Mapeamento não linear de um vetor x num espaço vetorial de maior dimensão denominado "Espaço de Características do *Kernel*".
2. Construção do hiperplano para separar o vetor mapeado no espaço vetorial de saída.

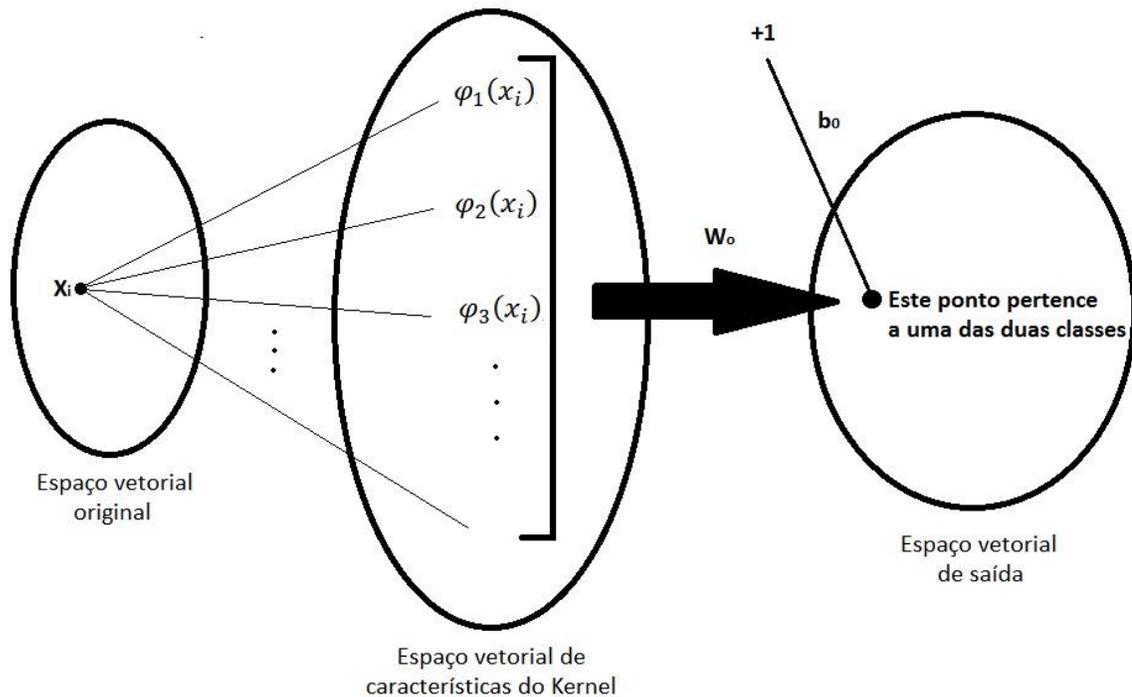


Figura 9 - Ideia básica do emprego de *Kernel*

Considere que x seja um vetor presente no espaço vetorial original de dimensão m e $\Phi(x)$ seja o vetor de funções não lineares $\{\varphi_j(x)\}_{j=1}^{\infty}$ capazes de transformar o espaço vetorial original em outro espaço vetorial de maior dimensão denominado “Espaço de Características do *Kernel*”. Com essa transformação, pode-se definir um hiperplano como sendo a superfície de separação das classes:

$$\sum_{j=1}^{\infty} w_j \varphi_j(x) = 0 \quad (21)$$

Onde $\{w_j\}_{j=1}^{\infty}$ representa um vetor de pesos que transforma o espaço vetorial de maior dimensão no espaço vetorial de saída.

Adaptando a Equação 16 para expressar o vetor de pesos, tem-se:

$$w = \sum_{i=1}^{N_s} \alpha_i d_i \Phi(x_i) \quad (22)$$

Onde N_s é o número de vetores de suporte e $\Phi(x)$, denominado vetor de transformação, é definido como:

$$\Phi(x_i) = \{\varphi_1(x_i), \varphi_2(x_i), \varphi_3(x_i), \dots\}^T \quad (23)$$

Desta maneira, substituindo as equações 22 em 21, pode-se representar a superfície de decisão no espaço de saída como:

$$\sum_{i=1}^{N_s} \alpha_i d_i \Phi^T(x_i) \Phi(x_i) = 0 \quad (24)$$

A partir da Equação 24 acima, pode-se concluir que o escalar $\Phi^T(x_i) \Phi(x_i)$ representa um produto vetorial. Desta maneira, pode-se definir a função *kernel* como sendo:

$$K(x, x_i) = \Phi^T(x_i) \Phi(x_i) \quad (25)$$

Finalmente, pode-se representar a superfície de separação como sendo:

$$\sum_{i=1}^{N_s} \alpha_i d_i K(x, x_i) = 0 \quad (26)$$

2.3. MÁQUINAS DE VETORES DE SUPORTE EM CASCATA

Máquinas de Vetores de Suporte são capazes de distinguir apenas duas classes diferentes. Uma das maneiras para resolver essa limitação é a utilização de um algoritmo classificador composto por várias MVS organizadas num determinado padrão (RIFKIN; KLAUTAU, 2004; ALY, 2005; HSU; LIN, 2002). Neste trabalho, foi utilizado o classificador conhecido como algoritmo um contra todos, onde várias MVS são conectadas em cascata, possibilitando o reconhecimento de várias classes. A Figura 10

mostra o diagrama de blocos de um classificador de n Máquinas de Vetores de Suporte organizadas em cascata.

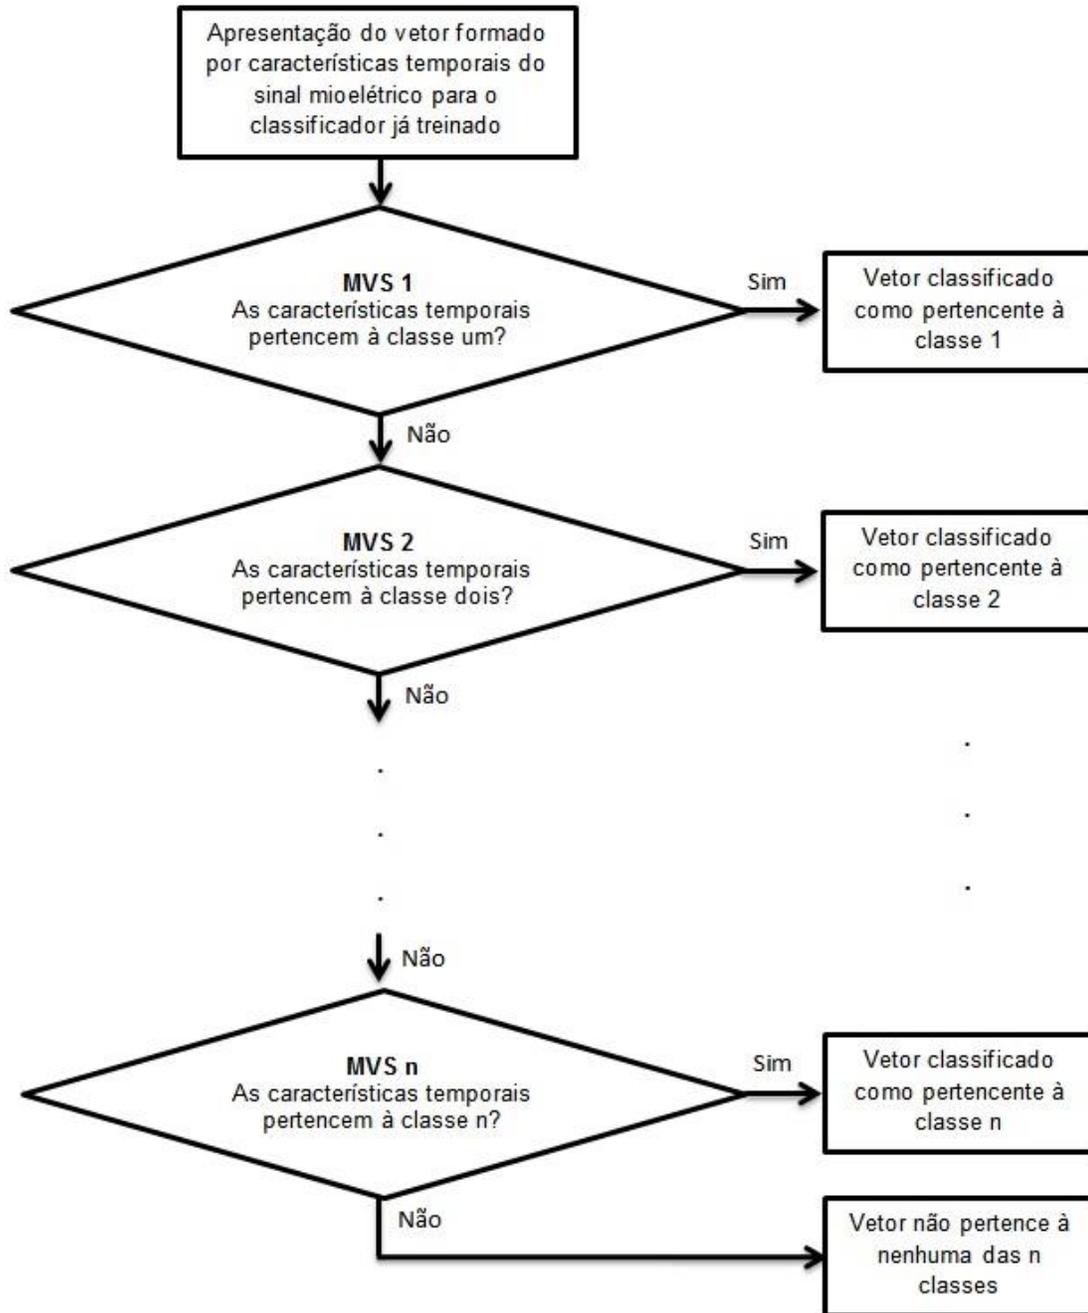


Figura 10 - Classificador em cascata

Para o classificador funcionar adequadamente, cada MVS deve ser treinada para reconhecer uma classe específica em relação a todas as outras. Ou seja, se a primeira

MVS da Figura 10 for responsável por reconhecer elementos de uma Classe A, devemos treiná-la com elementos de duas classes: elementos da Classe A e elementos de uma classe temporária que contém todos os outros elementos (exceto os da Classe A). Desta maneira, caso um elemento de uma Classe B seja apresentado ao classificador em cascata, a primeira MVS irá reconhecê-lo como pertencente à classe temporária e o passará para a MVS seguinte tentar classificá-lo.

2.4. SINAL MIOELÉTRICO

Esta seção aborda conceitos relacionados aos sinais mioelétricos. Ela está dividida em três subseções que tratam da definição, das características e dos ruídos presentes em sinais mioelétricos.

2.4.1. DEFINIÇÃO

Segundo Criswell (2011), trata-se de sinais produzidos pelo potencial de ação da unidade motora muscular. Este potencial elétrico é transmitido para as fibras musculares que então se estendem ou se contraem. Ou seja, sempre que um músculo, voluntário ou involuntário, é contraído ou relaxado, sinais elétricos são gerados.

Desta maneira, a partir de eletrodos e sensores mioelétricos, torna-se possível a aquisição dos sinais gerados durante a movimentação muscular. Tais sinais podem ser processados e utilizados para a ativação dos mais diversos dispositivos, como próteses biônicas, vídeo games e robôs.

2.4.2. CARACTERÍSTICAS DOS SINAIS MIOELÉTRICOS

De acordo com De Luca (2002), a amplitude do sinal mioelétrico pode variar entre 1 e 10 mV dependendo do músculo alvo, do organismo da pessoa e da intensidade da contração muscular. Devido a sua baixa amplitude, o sinal mioelétrico se mostra extremamente susceptível a ruídos.

De Luca (2002) também informa que o espectro de frequências do sinal mioelétrico situa-se na faixa de 0 a 500 Hz, enquanto que a faixa dominante está entre 50 e 150 Hz. A Figura 11 retrata o espectro de frequência do sinal mioelétrico produzido pela *Tibialis Anterior* durante uma contração com 50% da força máxima. A Figura 12 mostra o sinal mioelétrico gerado durante a abertura e o fechamento de uma mão.

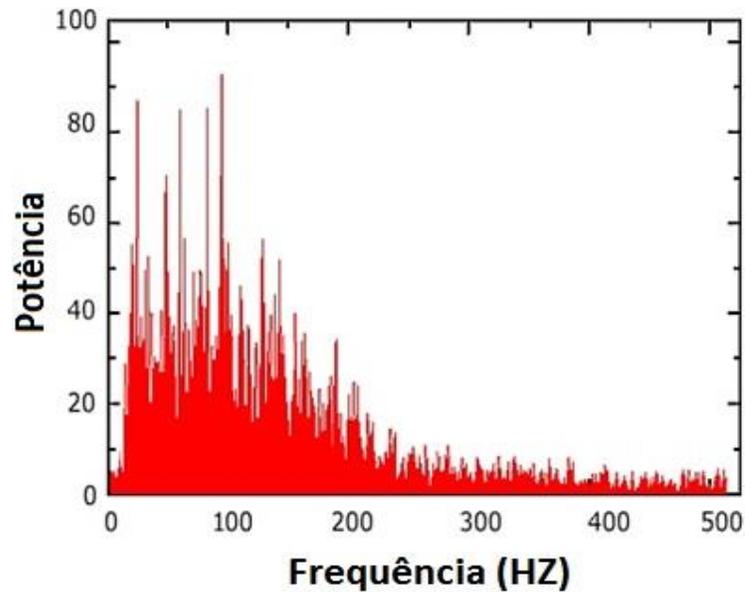


Figura 11 - Espectro de frequência do músculo Tibialis Anterior

Fonte: DE LUCA, 2002, p. 2

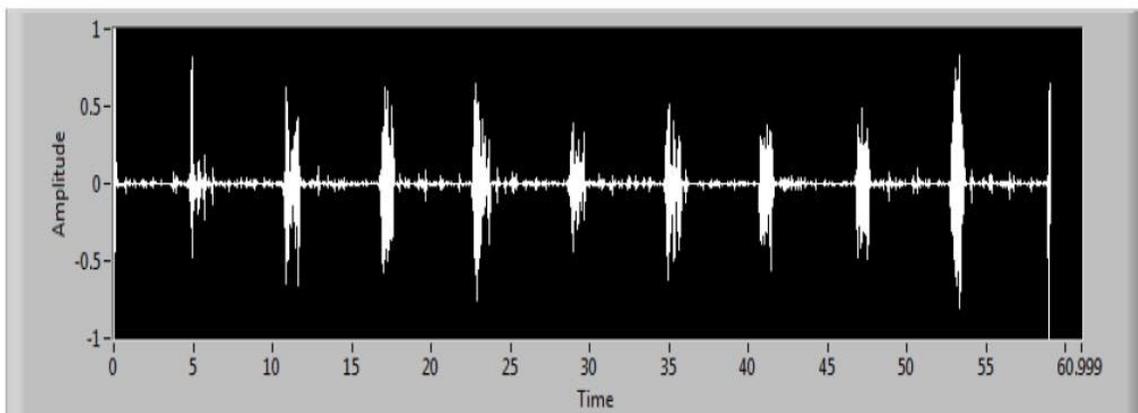


Figura 12 - Sinal mioelétrico gerado durante a abertura e o fechamento de uma mão

Fonte: SHROFFE E. H. D; MANIMEGALAI P., 2013, p. 35

2.4.3. RUÍDOS PRESENTES NOS SINAIS MIOELÉTRICOS

Devido a amplitude do sinal mioelétrico ser da ordem de grandeza de milivolts, ele se torna extremamente susceptível aos mais diversos tipos de ruídos, como ruídos provenientes da rede elétrica e ruídos provenientes de dispositivos eletrônicos próximos, tornando-se necessário a utilização de filtros para remover a parte indesejada que esteja presente no sinal (DAY, 2002).

2.4.3.1. RUÍDO DEVIDO À MOVIMENTAÇÃO DOS ELETRODOS

Trata-se de um ruído gerado pelo deslocamento involuntário do sensor mioelétrico que está localizado sobre a pele do usuário. A própria movimentação ou locomoção do usuário pode fazer com que o sensor se desloque sobre a sua pele, gerando assim ruídos que são capazes de interferir no sinal captado (DE LUCA et al., 2010). Além disso, a movimentação dos cabos que se ligam ao sensor também pode interferir no sinal captado. Este problema pode ser parcialmente resolvido fixando o eletrodo de forma adequada sobre a pele da pessoa e utilizando filtros que atenuem as frequências indesejadas, mas, mesmo assim, ele não será totalmente eliminado, pois movimentações e vibrações sempre irão ocorrer. De acordo com De Luca (2002), o ruído gerado pelo deslocamento do eletrodo está compreendido entre 0 e 20Hz. Por isso, um filtro passa-alta poderia ajudar na atenuação dessas frequências.

2.4.3.2. RUÍDO AMBIENTE

Trata-se de um ruído eletromagnético que é proveniente de aparelhos eletroeletrônicos próximos ao sensor mioelétrico. Televisões, celulares, computadores e outros dispositivos podem ser fontes desse tipo de interferência. Ele apresenta frequências variando de zero até milhares de Hertz. Uma das maneiras para reduzi-lo é através da utilização de componentes eletrônicos de qualidade boa e técnicas adequadas de desenvolvimento de circuitos eletrônicos e layouts de placas de circuito

impresso. Além disso, a utilização de amplificadores diferenciais durante a aquisição do sinal mioelétrico ajuda na amenização desse ruído (DE LUCA, 2002).

2.4.3.3. RUÍDO DA REDE ELÉTRICA

Este ruído é proveniente da rede de transmissão de energia, que oscila a uma frequência de 50 ou 60 Hz, dependendo do país. A amplitude deste ruído pode ser até três vezes maior que a amplitude do sinal mioelétrico proveniente da contração muscular. Trata-se do ruído que mais interfere e compromete o sinal mioelétrico devido à sua grande amplitude. Desta maneira, torna-se extremamente necessário a implementação de um filtro que atenuate as faixas de frequência próximas a 60 HZ, no caso do Brasil. Um filtro do tipo Notch pode auxiliar na redução deste tipo de interferência. Filtros adaptativos também têm sido empregados na remoção de ruídos provenientes da rede elétrica (MALBOUBI et al., 2010).

2.5. CARACTERÍSTICAS TEMPORAIS APLICADAS NO CLASSIFICADOR MVS

Para a utilização de uma Máquina de Vetores de Suporte na classificação de um determinado conjunto de dados, é necessário que esses dados sejam aplicados diretamente nas entradas da MVS ou que sejam aplicadas características desses dados. No caso da classificação de sinais mioelétricos, pode-se aplicá-los diretamente ou apresentar características como frequência e valor médio absoluto. Dependendo do que é apresentado nas entradas da MVS, ela pode se comportar de maneira diferente, obtendo assim uma maior ou menor taxa assertiva durante a classificação. De acordo com Gauthaam e Kumar (2011), o sucesso de qualquer sistema classificador é dependente das características aplicadas nas suas entradas.

Muitos estudos realizados na última década (GAUTHAAM; KUMAR, 2011; GEETHANJALI et al. 2009) têm basicamente utilizado quatro características do sinal mioelétrico como entrada para classificadores: Valor Médio Absoluto (VMA), Número de Cruzamentos no Eixo Real (NCR), Comprimento da Forma de Onda (CFO) e Número

de Mudança de Sinal da Derivada (NMSD). Cada uma das características mencionadas anteriormente está definida a seguir.

2.5.1. VALOR MÉDIO ABSOLUTO (VMA)

Pode ser definido como a soma do módulo do sinal amostrado por um intervalo determinado de tempo. Tal soma é então dividida pelo número de amostras utilizadas. Em outras palavras, trata-se da média do módulo do sinal amostrados A Equação 27 representa a definição do VMA:

$$VMA = \frac{1}{n} \sum_{i=1}^n |y_i| \quad (27)$$

Onde:

- i é o número da amostra;
- y_i é a amostra de número i ;

2.5.2. NÚMERO DE CRUZAMENTOS NO EIXO REAL (NCR)

É definido como o número de vezes que as amostras do sinal mioelétrico assumiram o valor zero. O NCR ocorre toda vez que a condição representada pela Equação 28 é satisfeita:

$$NCR = \sum_{i=1}^{n-1} NUM((y_i > 0 \ \&\& \ y_{i+1} < 0) \ || \ (y_i < 0 \ \&\& \ y_{i+1} > 0)) \quad (28)$$

Onde:

- i é o número da amostra;
- y_i é a amostra de número i ;
- $||$ é o operador lógico “OU”

- $\&\&$ é o operador lógico “E”
- $NUM(\text{condição})$ é uma função que resulta em 1 caso a condição seja verdadeira. Caso contrário, resulta em 0;

2.5.3. COMPRIMENTO DA FORMA DE ONDA (CFO)

É definido como o módulo da diferença entre dois valores amostrados consecutivamente. A Equação 29 mostra a definição matemática para o CFO.

$$CFO = \sum_{i=1}^{n-1} |y_{i+1} - y_i| \quad (29)$$

Onde:

- i é o número da amostra;
- y_i é a amostra de número i ;

2.5.4. NÚMERO DE MUDANÇAS DE SINAL DA DERIVADA (NMSD)

Trata-se do número de vezes que a derivada da onda muda de sinal num determinado intervalo de tempo. A definição do NMSD é mostrada na Equação 30.

$$NMSD = \sum_{i=1}^{n-1} NUM((y_i > y_{i-1} \&\&y_i > y_{i+1}) || (y_i < y_{i-1} \&\&y_i < y_{i+1})) \quad (30)$$

Onde:

- i é o número da amostra;
- y_i é a amostra de número i ;
- $||$ é o operador lógico “OU”
- $\&\&$ é o operador lógico “E”

- NUM(condição) é uma função que resulta em 1 caso a condição seja verdadeira. Caso contrário, resulta em 0;

2.6. TIPOS DE ELETRODOS PARA AQUISIÇÃO DE SINAIS MIOELÉTRICOS

Esta seção mostra os tipos de eletrodos que podem ser utilizados para a aquisição de sinais mioelétricos. Ela está dividida em duas subseções que tratam de eletrodos do tipo agulha e de eletrodos descartáveis.

2.6.1. ELETRODO AGULHA

Eletrodos do tipo agulha são intramusculares. Ou seja, a pele precisa ser penetrada para que o músculo seja alcançado. A Figura 13 mostra exemplos de eletrodos do tipo agulha.

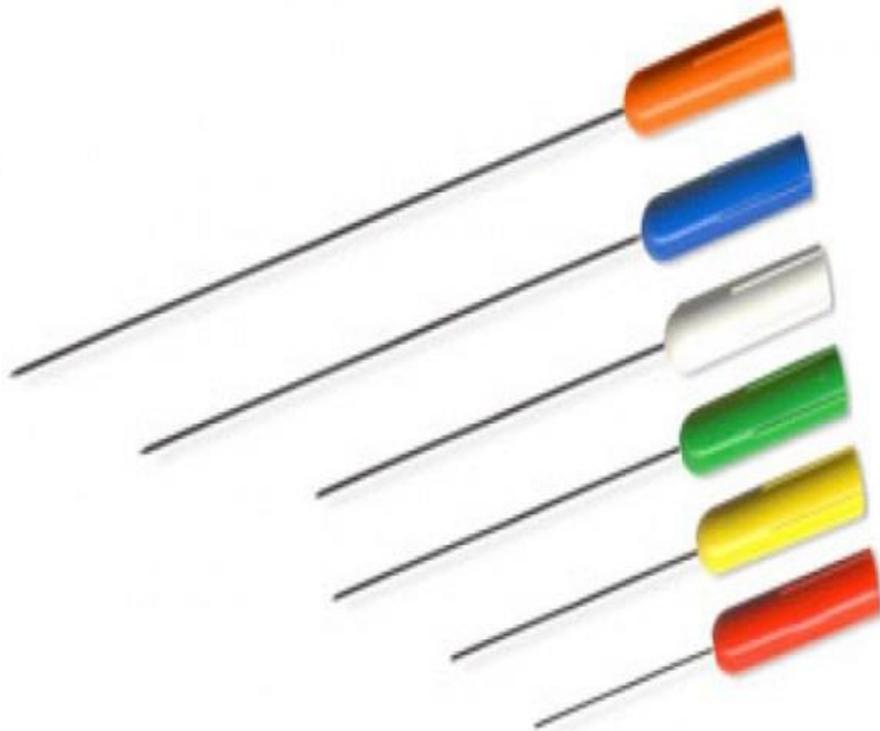


Figura 13 - Eletrodo tipo agulha

A grande vantagem deste tipo de eletrodo é que ele é capaz de captar os sinais provenientes de uma única unidade motora muscular. Uma unidade motora muscular é o conjunto de um neurônio e das fibras musculares por ele inervadas. A Figura 14 retrata uma unidade motor muscular.

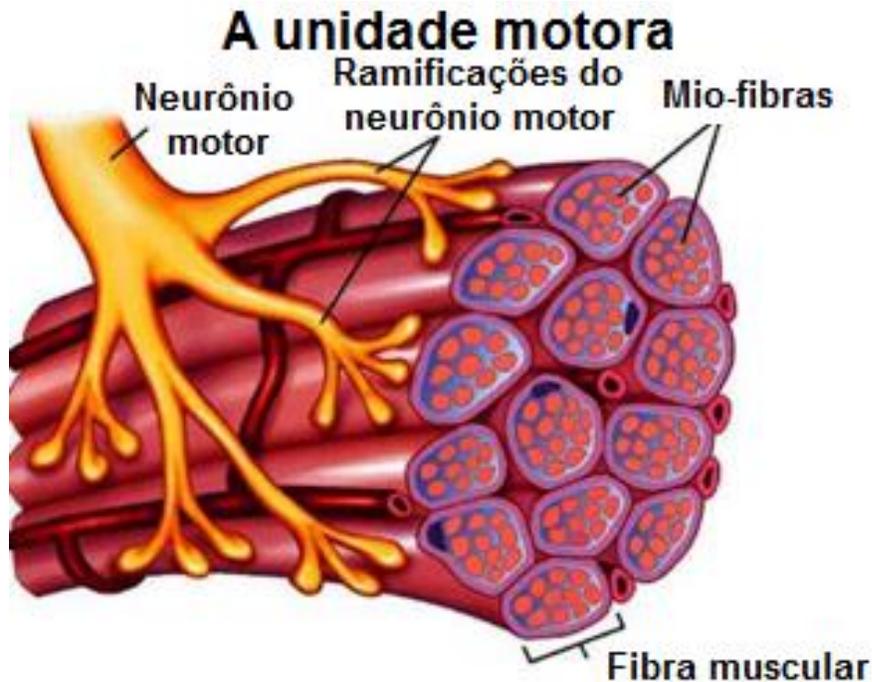


Figura 14 - Unidade motora muscular

Fonte: De Luca, 2002, p. 2

Uma das desvantagens deste tipo de eletrodo é a necessidade de intervenção médica para a sua instalação. Isto acaba dificultado a utilização deste tipo de eletrodo com próteses biônicas.

2.6.2. ELETRODO DE SUPERFÍCIE

São eletrodos que não são intramusculares, ou seja, eles são colocados sobre a superfície da pele. Este tipo de eletrodo não requer auxílio de um profissional qualificado para a sua fixação. Os eletrodos de superfície vêm, cada vez mais, sendo

empregados para o controle de dispositivos, como próteses. Basicamente, existem dois tipos de eletrodos de superfície: eletrodos descartáveis e eletrodos reutilizáveis.

2.6.2.1. ELETRODOS DESCARTÁVEIS

Como o próprio nome diz, estes eletrodos são utilizados apenas uma vez e depois se tornam inutilizáveis. Geralmente eles são fixados na pele com o auxílio de um adesivo. Este tipo de eletrodo possui uma espécie de geleia em seu centro. Esta substância é responsável pela condução dos potenciais elétricos capturados na superfície da pele para o eletrodo. Para utilizar este tipo de eletrodo é necessária a preparação da pele; pelos devem ser removidos e a pele deve ser limpa. A Figura 15 retrata um eletrodo descartável.



Figura 15 - Eletrodo descartável

Este tipo de eletrodo é extremamente barato. Entretanto, dependendo da frequência do uso, ele acaba se tornando inviável.

2.6.2.2. ELETRODOS REUTILIZÁVEIS

Tais eletrodos podem ser utilizados diversas vezes. Também não precisam de gel para fazer interface entre a pele e o dispositivo. Muitas vezes eles são compostos por mais de uma superfície de detecção. Alguns eletrodos reutilizáveis já possuem até sistema de pré-amplificação do sinal mioelétrico. A Figura 16 mostra um eletrodo reutilizável do tipo barra. Um eletrodo reutilizável de sucção é mostrado na Figura 17.



Figura 16 - Eletrodo reutilizável do tipo barra



Figura 17 - Eletrodo reutilizável de sucção

Vale ressaltar que existem outros tipos de eletrodos reutilizáveis além dos mostrados nas Figuras 16 e 17.

2.7. INSTALAÇÃO DE ELETRODO DE SUPERFÍCIE

Os eletrodos de superfície não podem ser simplesmente posicionados sobre o músculo alvo, pois o seu posicionamento e localização influenciam na aquisição do sinal (ROY; DE LUCA; SCHNEIDER, 1986; MESIN; MERLETTI; RAINOLDI, 2009). A instalação do eletrodo sobre a pele do usuário requer um conhecimento prévio do músculo alvo. De acordo com JAMAL (2012), o eletrodo deve ser posicionado entre a unidade motora e o tendão de inserção. Além disso, um estudo realizado por Choi et al. (2005) informa que a distância entre dois eletrodos consecutivos deve ser 18 milímetros e o eixo longitudinal formado por eles deve estar paralelo com as fibras musculares. A Figura 18 retrata a localização de um eletrodo de superfície sobre a pele do usuário.

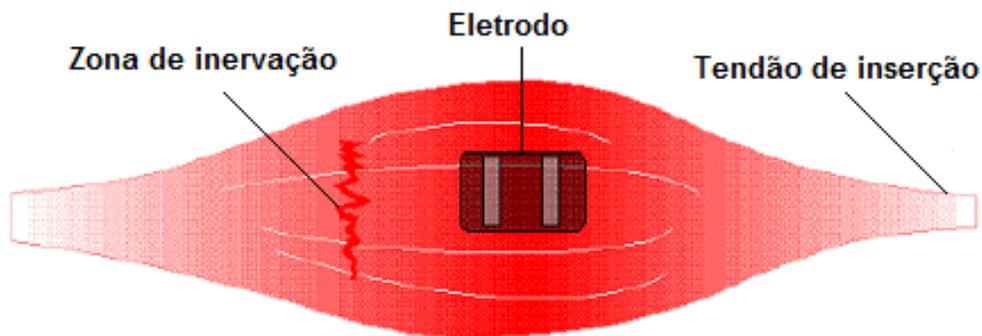


Figura 18 - Localização do eletrodo de superfície

Fonte: DE LUCA, 2002, p. 8

3. REVISÃO BIBLIOGRÁFICA

Gauthaam e Kumar (2011) realizaram uma revisão sobre os métodos tradicionais utilizados para a ativação de próteses biônicas através de sinais mioelétricos. Estes métodos consistem na aquisição do sinal biológico; o pré-processamento do sinal; o cálculo das suas características temporais; e, por último, a apresentação dessas características para um classificador que é responsável pelo reconhecimento do padrão do sinal capturado. O estudo retrata que a aquisição do sinal muscular pode ser feita através de sensores mioelétricos. Também é informado que a etapa de pré-processamento é utilizada para a remoção de ruídos e componentes indesejadas do sinal mioelétrico através de filtros. Além disso, fica claro que o cálculo das características temporais é fundamental para o desempenho do classificador, pois dependendo das características utilizadas, o algoritmo pode se comportar de maneiras diferentes. O autor comenta que características temporais como a média absoluta, variância e o número de vezes que o sinal cruza o eixo real são parâmetros frequentemente utilizados para a classificação de sinais biológicos. Finalmente, é informado que o classificador é o componente que apresenta a maior importância no esquema que foi apresentado, pois ele é responsável pelo reconhecimento e interpretação do sinal.

Geenthanjali et al. (2009) desenvolveu um sistema de aquisição e classificação de sinais mioelétricos utilizado para controlar uma prótese de mão. O sistema de aquisição, que possui quatro canais, é constituído de amplificadores de instrumentação INA128, filtro de rejeição de sinais DC e filtro passa-banda com frequências de corte 100-500Hz. O filtro passa banda foi construído através da conexão de um filtro passa-baixa e um filtro passa-alta, ambos com dois polos. Dois métodos de classificação de padrões foram usados e comparados: Redes Neurais e *Nearest Neighbour Classifier*. Os parâmetros de entrada dos classificadores foram: a média absoluta do sinal mioelétrico, o número de vezes que este sinal cruza o eixo real, o número de vezes que a derivada deste sinal inverte o sentido e, finalmente, o comprimento da forma de onda do sinal apresentado. Para a realização dos testes e comparação dos classificadores, algumas pessoas realizaram alguns movimentos e os seus sinais biológicos foram

captados e classificados através do sistema desenvolvido. Os movimentos realizados foram: fechar a mão, abrir a mão, flexionar o punho, estender o punho, desvio ulnar e desvio radial. Como resultado, ficou demonstrado que, dentro das condições de realização do experimento, o classificador *Nearest neighbour classifier* obteve maior precisão em relação à rede neural.

Ibarra et al. (2012) desenvolveu um sistema para o reconhecimento de padrões de sinais mioelétricos através de redes neurais. A aquisição dos sinais foi feita com uma placa NI DAQ-6211 e eletrodos superficiais conectados a amplificadores diferenciais. Os eletrodos foram posicionados sobre o bíceps, tríceps e punho de 20 pessoas saudáveis e com idades variadas. Os movimentos realizados foram: pronação e supinação do antebraço, mão fechada e mão relaxada. Após a aquisição, os sinais foram filtrados com um filtro passa-banda do tipo Butterworth e frequência de corte 20Hz e 1000Hz. Em seguida, a transformada rápida de Fourier foi calculada e os coeficientes obtidos foram utilizados como entrada do classificador. Como resultado, foi constatado que a localização dos eletrodos influencia diretamente na eficiência do classificador, ou seja, dependendo da localização dos eletrodos, o classificador pode ter um desempenho melhor ou pior. Além disso, nas condições do estudo, a eficiência máxima obtida pela rede neural foi em torno de 90% de acerto.

O'NEILL (1994) estudou a diferença entre os sinais mioelétricos gerados por pessoas que sofreram algum tipo de amputação em algum dos membros superiores e pessoas com membros intactos. O sistema de aquisição utilizado era constituído de eletrodos bipolares de Ag/AgCl com 4mm de diâmetro e espaçados 10mm um do outro; um filtro passa-banda analógico do tipo Butterworth e com frequência de corte 10Hz e 1000Hz; e uma placa de aquisição DT2821 com frequência de amostragem de 2,5KHz. Durante a aquisição dos sinais mioelétricos, uma tela com um gráfico da média absoluta do sinal era mostrada para o paciente. O objetivo do teste era constriar o músculo alvo e manter a média do sinal em um determinado valor. Após a aquisição do sinal, foi calculada a frequência média e a mediana para a comparação; além disso, foi realizada uma análise de variância. O trabalho envolveu 32 pessoas com amputações variadas. Foi concluído que não existe diferença estatística entre pessoas que sofreram

amputação e pessoas com membros intactos. Entretanto, os autores deixaram claro que existe uma diferença espectral aparente quando os dois sinais são visualizados.

Tsenov et al. (2006) realizaram uma comparação entre diferentes técnicas de inteligência artificial aplicadas na classificação de sinais mioelétricos capturados no antebraço. Foram comparados: Perceptron de Múltiplas Camadas, *Radial Basis Function* e *Learning Vector Quantization*. Quatro movimentos foram utilizados para a comparação: dedo indicador flexionado, dedo médio flexionado, polegar flexionado e mão fechada. As características temporais do sinal utilizadas como entrada dos algoritmos classificadores foram: valor médio absoluto, comprimento da forma de onda, número de vezes que o sinal cruza o eixo real, valor absoluto máximo, valor absoluto mínimo e a diferença entre os valores absolutos máximo e mínimo. De acordo com os resultados obtidos, o algoritmo que obteve o melhor desempenho no cenário estudado foi o Perceptron de Múltiplas Camadas, respondendo da maneira esperada em aproximadamente 98% das vezes.

Luo e Yang (2005) aplicaram lógica difusa para a classificação de sinais mioelétricos e controle retroalimentado de toque de uma prótese biônica. O principal objetivo do trabalho foi desenvolver um algoritmo apto a reconhecer quando o usuário quer que uma prótese de mão realize algum movimento e evitar que os objetos manuseados pela mão biônica sejam danificados. Como resultado, o algoritmo respondeu de maneira adequada em 90% dos casos de teste.

Hargrove et al. (2007) realizaram um estudo para diferenciar o desempenho de classificadores de sinais mioelétricos utilizando sinais captados por 16 canais de eletrodos intramusculares e eletrodos de superfície. Cinco classificadores de sinais mioelétricos foram estudados: Perceptron de Múltiplas Camadas, Perceptron Linear, Análise de Discriminante Linear, *Gaussian Mixture Model* e *Hidden Markov Model*. Além disso, 10 tipos diferentes de contração muscular foram empregados. A conclusão obtida foi que não houve diferença significativa em nenhum dos classificadores, tanto utilizando sinais captados por eletrodos de superfície quanto utilizando sinais captados por eletrodos intramusculares. A taxa assertiva de todos os classificadores utilizados ficou entre 95% e 99%. Além disso, apesar do emprego de 16 canais de aquisição, o autor afirma que apenas três são suficientes para os classificadores obterem uma

excelente precisão de até 97% de acerto. A redução de canais também diminuiu o tempo de processamento e tornou os classificadores mais rápidos e apropriados para o uso em tempo real.

Yoshikawa, Mikawa e Tanaka (2007) estudaram a utilização de uma Máquina de Vetores de Suporte na classificação de sinais mioelétricos para ativação de uma prótese biônica. Oito pessoas participaram dos testes de desempenho do classificador. Sete padrões de movimentos foram empregados: Supinação, pronação, mão fechada, mão aberta, mão relaxada, contração do punho e extensão do punho. Para a aquisição dos sinais musculares, o autor utilizou dois eletrodos de barras paralelas fixados no antebraço. Os sinais foram amostrados a uma taxa de 2KHz e algumas características dos sinais foram utilizadas como entrada da MVS. Tais características são: valor médio absoluto, coeficiente *Cepstrum* e coeficiente *Delta Cepstrum*. Além disso, a função *Radial Basis Function* foi utilizada como *Kernel*. Como resultado, o algoritmo MVS obteve uma taxa assertiva acima de 90% para as oito pessoas submetidas aos testes.

4. METODOLOGIA

Neste capítulo são apresentados os métodos utilizados no desenvolvimento deste trabalho. O presente capítulo está dividido em duas partes: Base de Dados de Sinais Mioelétricos e Programa Computacional Desenvolvido para o Estudo.

4.1. BASE DE DADOS DE SINAIS MIOELÉTRICOS

Para a realização dos testes de desempenho da Máquina de Vetores de Suporte na classificação de sinais mioelétricos, foram utilizados sinais provenientes de uma base de dados pública (KHUSHABA, 2012). Esta base de dados é uma iniciativa do pesquisador Rami Khushaba da universidade de tecnologia de Sidnei, Austrália.

Os sinais disponibilizados por esta base foram captados através de oito canais e utilizando eletrodos de superfície modelo Bagnoli-8, produzidos pela empresa Delsys. Uma placa de aquisição de dados, modelo BNC-2090, com conversor analógico-digital de 12 bits, produzido pela empresa National Instruments, foi utilizada para realizar a aquisição dos sinais mioelétricos a uma taxa de amostragem de 4000 Hz. Os sinais foram digitalizados para o computador através do software EMGWork da empresa Delsys. Além disso, foi utilizado um filtro Notch para atenuar ruídos provenientes da rede elétrica e um filtro de banda com frequências de corte iguais a 20 e 450Hz para remover ruídos que não fazem parte do espectro de frequências do sinal mioelétrico, que, de acordo com De Luca (2002), se localiza entre 0 e 500 Hz.

A base de dados utilizada disponibiliza 15 classes diferentes obtidas de oito pessoas com idades entre 20 e 35 anos, duas mulheres e seis homens. Neste estudo apenas os sinais do indivíduo número um foram usados. Durante a aquisição, os voluntários mantiveram os músculos contraídos durante 20 segundos (contração isométrica). Os sinais de cada classe foram adquiridos três vezes para cada indivíduo.

Apesar das 15 classes disponíveis, apenas oito foram utilizadas: mão fechada (MF), dedo polegar flexionado (PF), dedo indicador flexionado (IF), dedo médio flexionado (MEF), dedo anular flexionado (AF), dedo mínimo flexionado (MINF), dedo polegar e indicador flexionados (PIF) e, finalmente, dedo mínimo, anular e médio

flexionados (MAMF). A escolha das classes que representam os dedos flexionados individualmente (PF, IF, MEF, AP e MINF) se baseia no refinamento da prótese, ou seja, a capacidade de detectar a movimentação de um único dedo. Já a escolha das classes MF, PIF e MAMF se baseia na opinião do autor, que acredita que dentro das classes existentes, são as usadas com mais frequência. Apesar da utilização de apenas oito padrões de movimento da mão humana, as técnicas apresentadas neste trabalho podem ser utilizadas para qualquer número de classes. As Figuras 19, 20, 21, 22, 23, 24, 25 e 26 mostram as oito classes utilizadas.



Figura 19 – Classe mão fechada (MF).

Fonte: KHUSHABA, 2012.

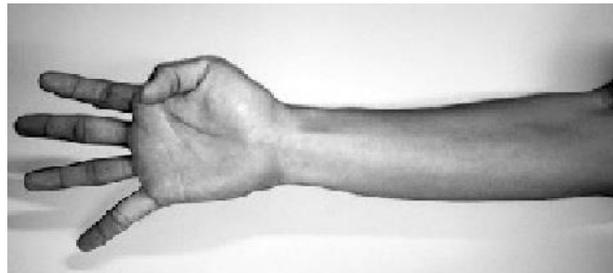


Figura 20 – Classe dedo polegar flexionado (PF).

Fonte: KHUSHABA, 2012.

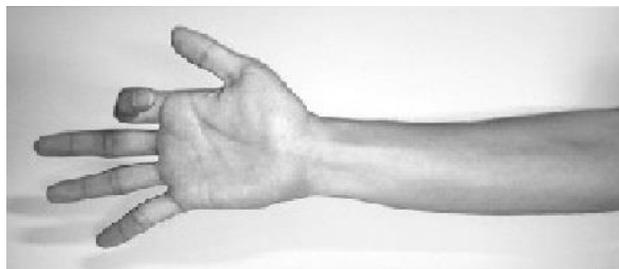


Figura 21 – Classe dedo Indicador flexionado (IF).

Fonte: KHUSHABA, 2012.

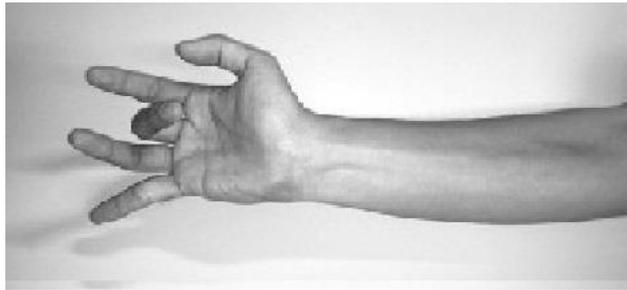


Figura 22 – Classe dedo médio flexionado (MEF).
Fonte: KHUSHABA, 2012.

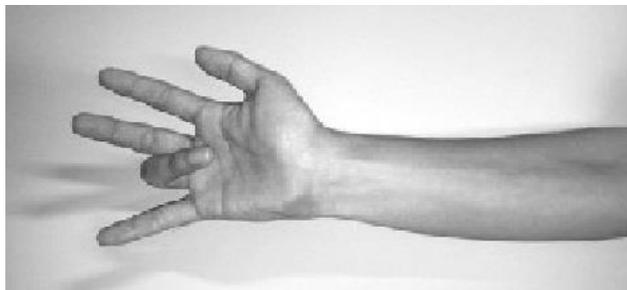


Figura 23 – Classe dedo anular flexionado (AF).
Fonte: KHUSHABA, 2012.

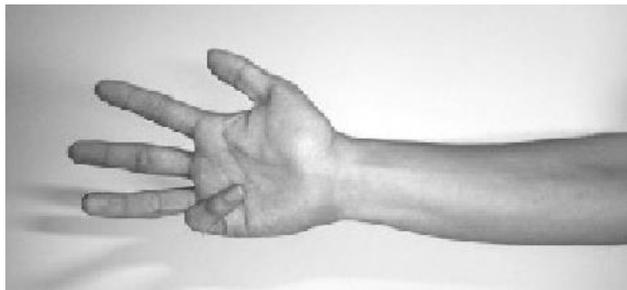


Figura 24 – Classe dedo mínimo flexionado (MINF).
Fonte: KHUSHABA, 2012.

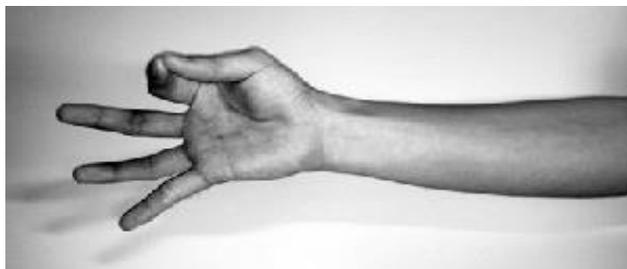


Figura 25 – Classe dedos indicador e polegar flexionados (PIF).
Fonte: KHUSHABA, 2012.

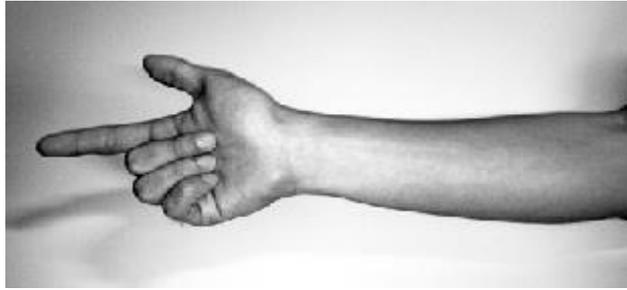


Figura 26 – Classe dedos médio, anular e mínimo flexionados (MAMF).

Fonte: KHUSHABA, 2012.

Para captar os sinais elétricos, os oito eletrodos foram colocados ao redor do antebraço. O eletrodo de referência foi fixado próximo ao punho. A Figura 27 mostra a localização de todos os eletrodos.

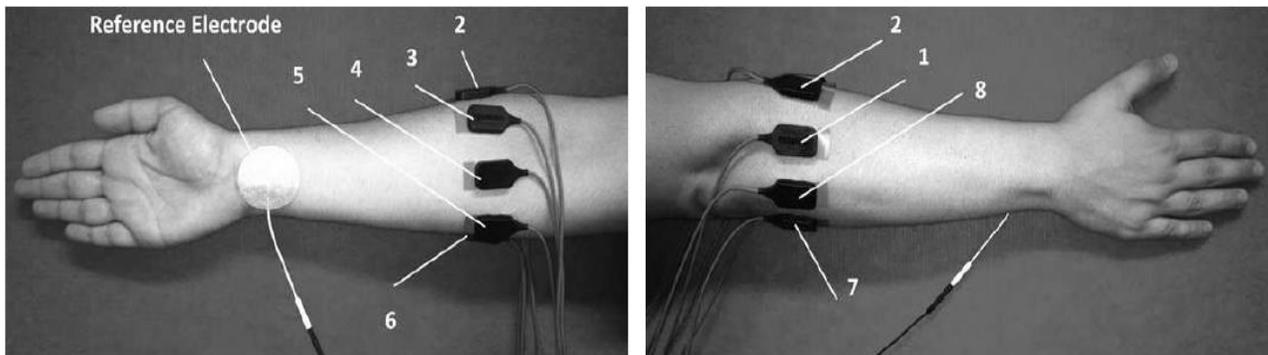


Figura 27 - Localização dos eletrodos.

Fonte: KHUSHABA, 2012.

4.2. PROGRAMA COMPUTACIONAL DESENVOLVIDO PARA O ESTUDO

Para verificar se Máquinas de Vetores de Suporte podem ser utilizadas na classificação dos oito padrões (MF, PF, IF, MEF, AF, MINF, PIF e MANF) de mão humana a partir de sinais mioelétricos provenientes do antebraço utilizando os parâmetros VMA, NMSD, CFO e NCR, foi desenvolvido, no MATLAB, um programa computacional para automatizar todos os testes e apresentar todos os resultados para uma análise posterior. A seguir é apresentado o funcionamento do programa desenvolvido.

4.2.1. PROGRAMA COMPLETO

O programa desenvolvido executa todos os passos necessários para o estudo do desempenho de Máquinas de Vetores de Suporte na classificação de sinais mioelétricos que foi realizado neste trabalho. Os parâmetros do programa são: tipo de *kernel*, que pode ser linear, quadrático ou polinomial de terceira ordem; número de vetores que serão utilizados na etapa de treinamento; e número de amostras que serão utilizadas para calcular as componentes dos vetores.

Após a apresentação dos parâmetros para o programa computacional desenvolvido, amostras suficientes de cada uma das oito classes são selecionadas randomicamente. Em seguida, as características temporais (VMA, NMSD, CFO e NCR) são calculadas para as amostras selecionadas e, finalmente os vetores são formados. Esses vetores são utilizados para treinar todas as MVS do classificador. Logo após o treinamento, mais amostras são selecionadas e, a partir delas, mais vetores são formados para serem utilizados durante a etapa de classificação e medição de desempenho do classificador. O diagrama de blocos mostrado na Figura 28 retrata detalhadamente o funcionamento do programa desenvolvido.

4.2.2. VETOR UTILIZADO PELO CLASSIFICADOR

Por existirem 8 canais de aquisição e a partir de cada canal serem calculadas quatro características do sinal mioelétrico (VMA, NMSD, CFO e NCR), o vetor utilizado pelo classificador possui 32 componentes. A partir deste vetor, o classificador verifica se um determinado conjunto de amostras pertencente a uma determinada classe.

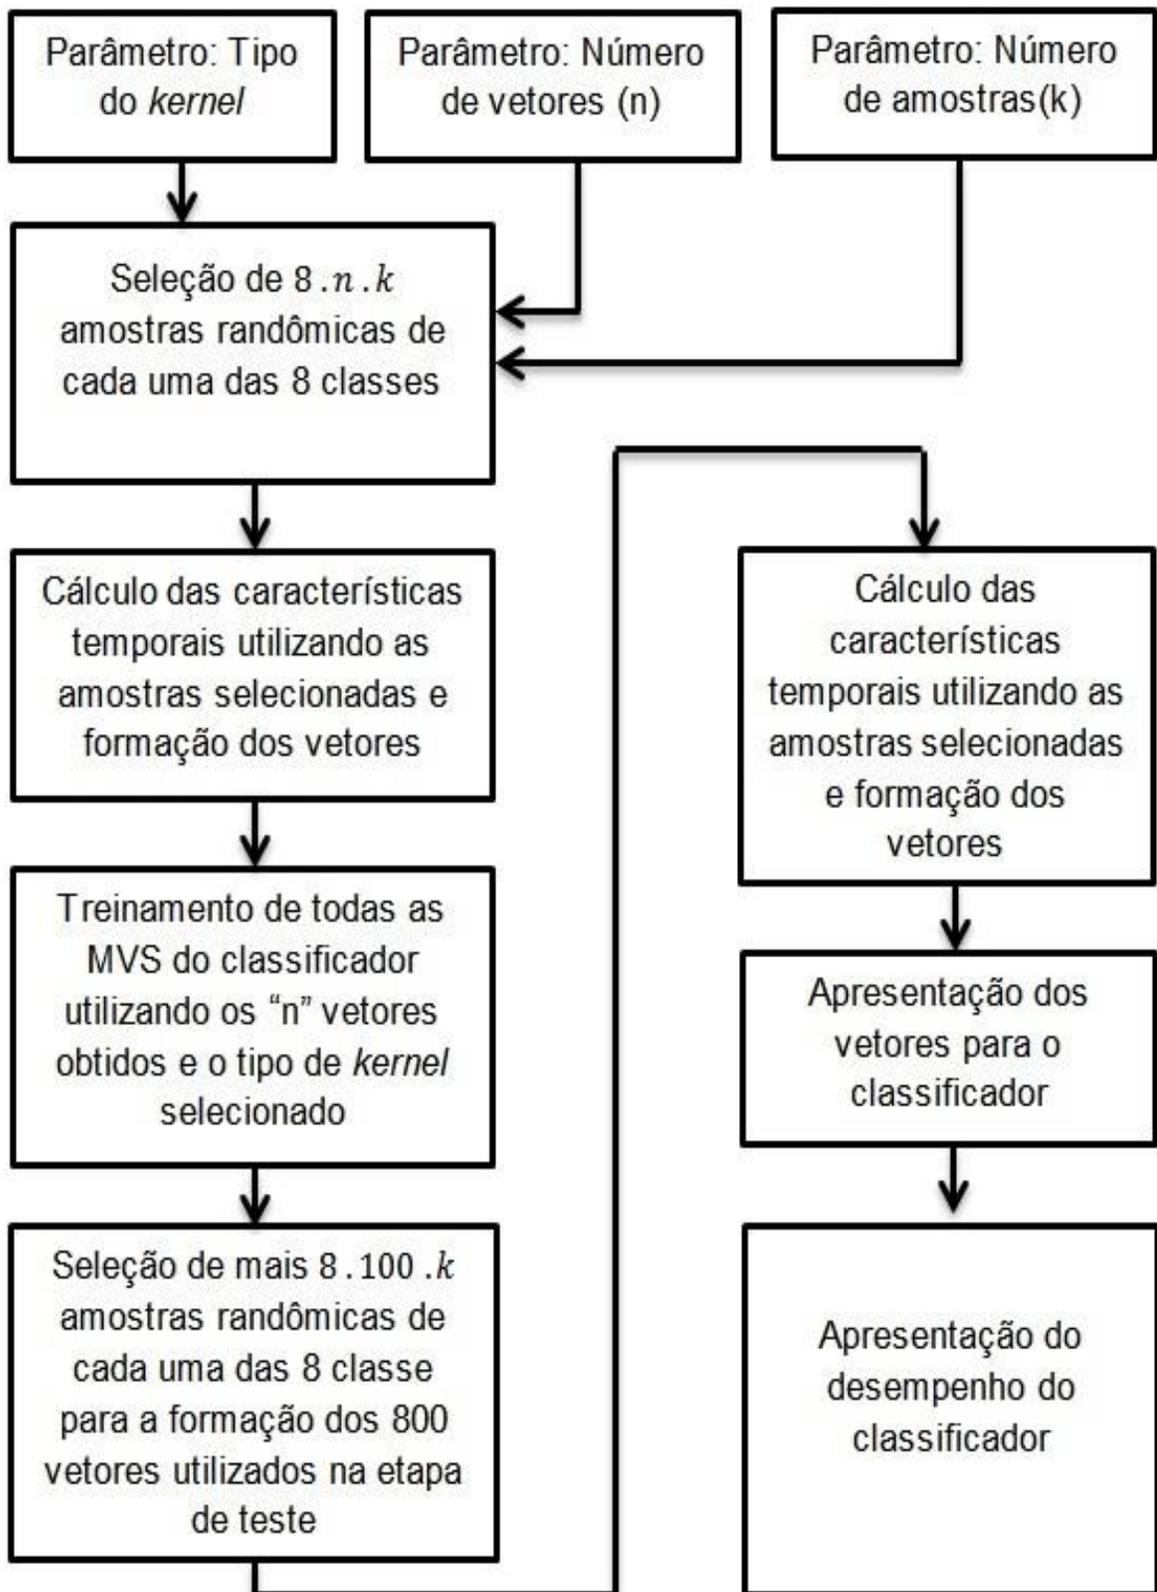


Figura 28 - Diagrama de fluxo do programa desenvolvido

4.2.3. CLASSIFICADOR EM CASCATA

Por ser capaz de distinguir apenas duas classes, o classificador desenvolvido é constituído de oito Máquinas de Vetores de Suporte conectadas em cascata. Cada uma das MVS é responsável por determinar se o vetor apresentado pertence a uma determinada classe ou não. A seção 2.3 explica detalhadamente o funcionamento do classificador formado por MVS organizadas em cascata. A Figura 29 apresenta o funcionamento das oito MVS conectadas em cascata. Apesar de este estudo ter utilizado apenas oito classes de movimentos e oito MVS para distingui-las, este número pode ser aumentado seguindo a mesma lógica.

4.2.4. ETAPA DE TREINAMENTO DO CLASSIFICADOR EM CASCATA

Para treinar o classificador em cascata, o programa automatizado seleciona aleatoriamente amostras da base de sinais mioelétricos. Em seguida, todas as características temporais (VMA, NCR, CFO e NMSD) das amostras selecionadas são calculadas. Finalmente, estas características temporais são utilizadas para formar os vetores que serão utilizados para o treinamento das oito Máquinas de Vetores de suporte do classificador em cascata. Cada MVS é treinada para separar uma classe específica de todas as outras. Portanto, todas as MVS recebem vetores de todas as classes para o seu treinamento. O diagrama de blocos do algoritmo de treinamento é mostrado na Figura 30.

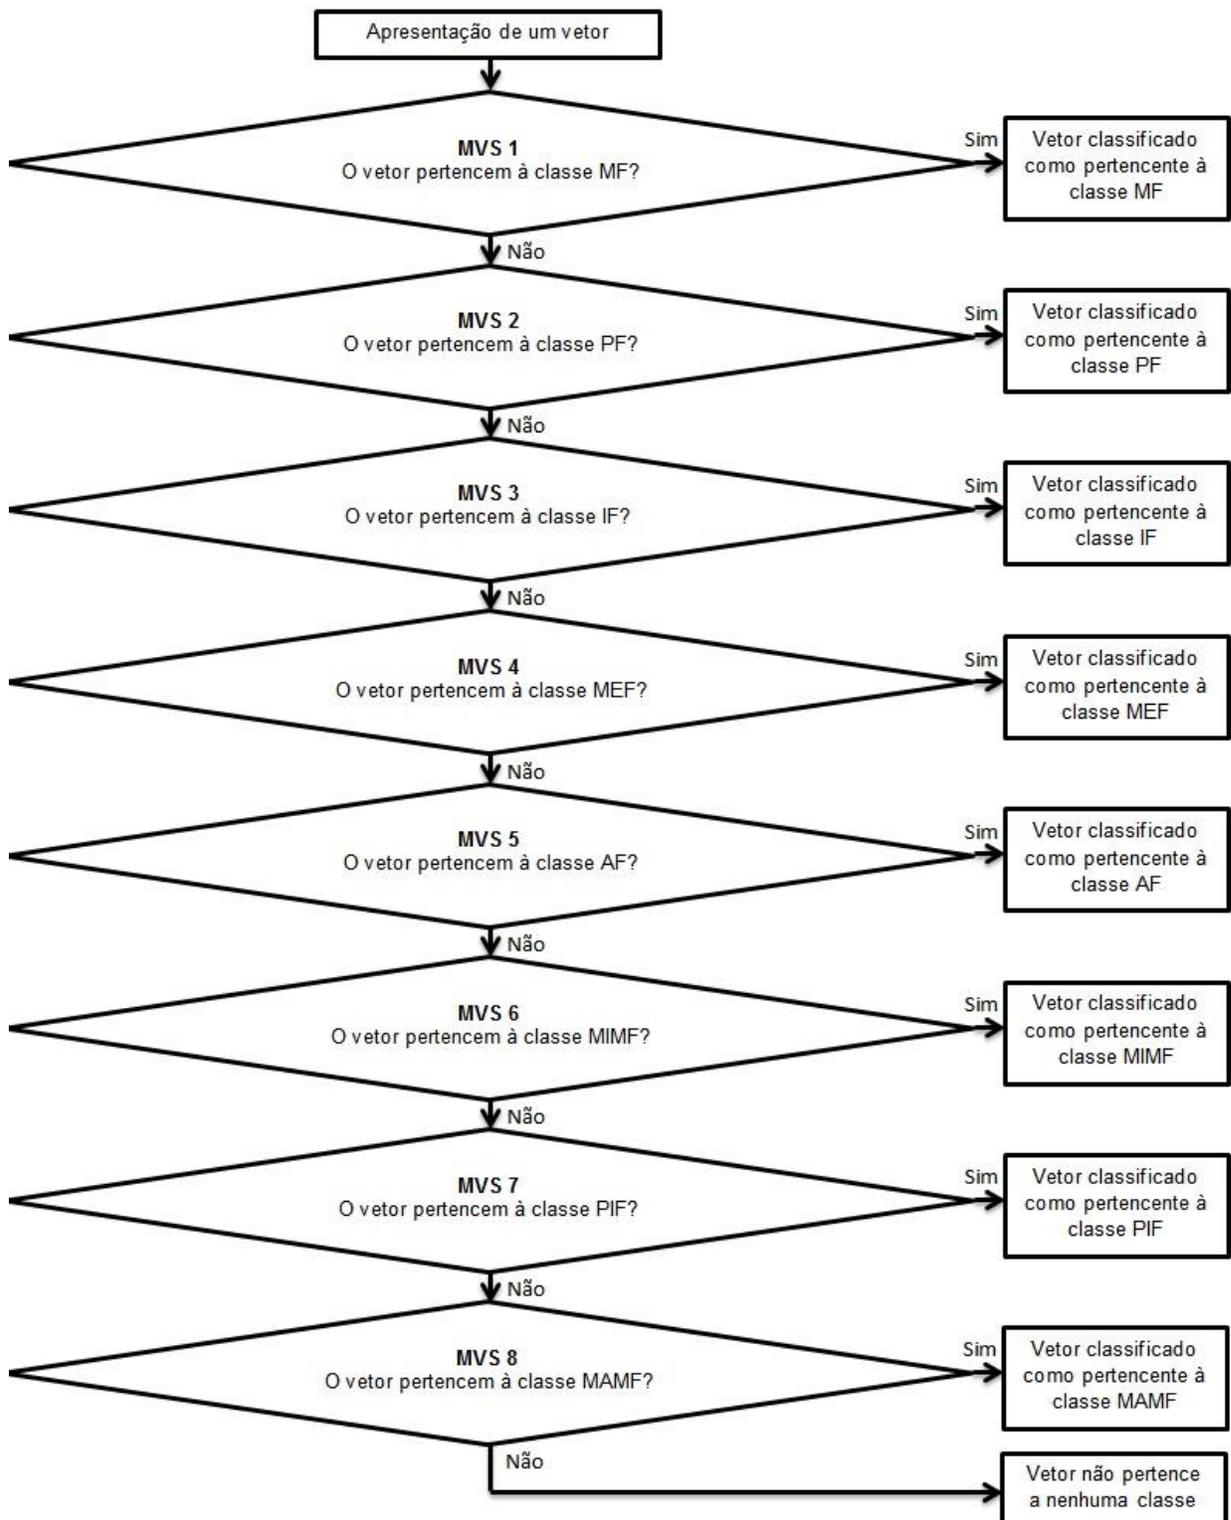


Figura 29 - MVS conectadas em cascata para distinguir até oito classes diferentes

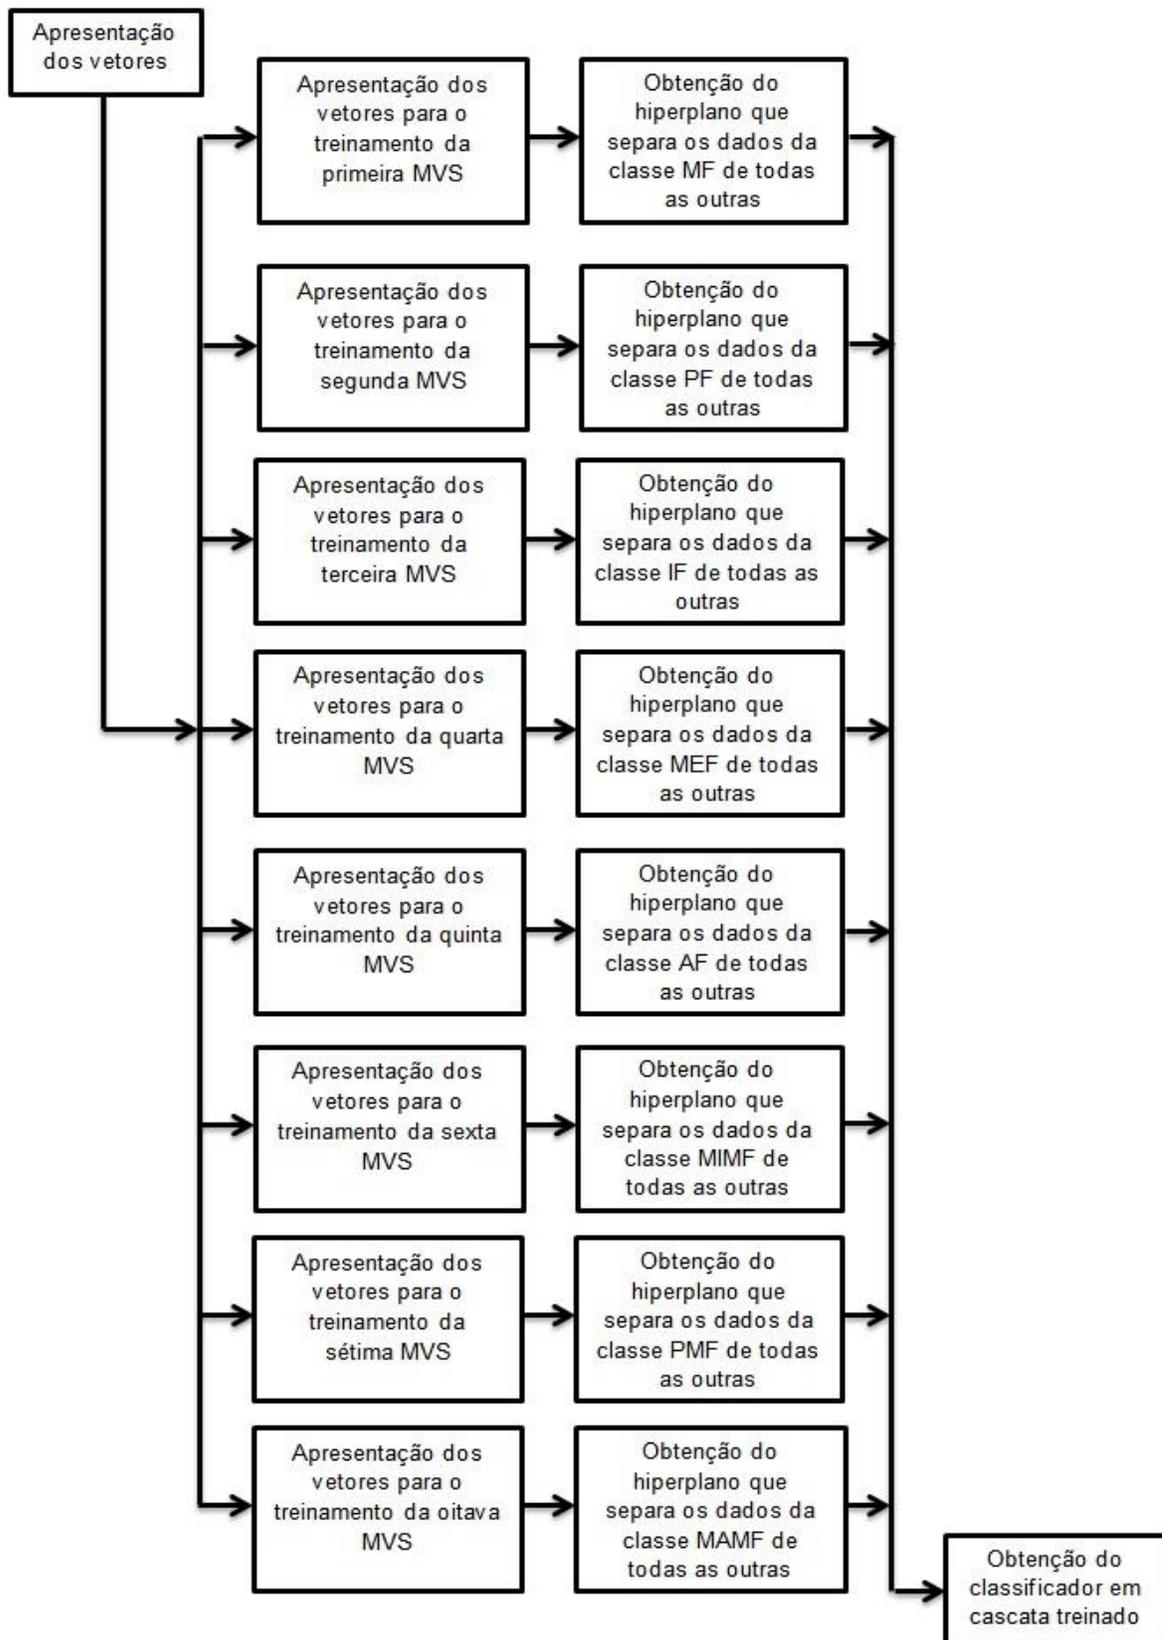


Figura 30 - Algoritmo de treinamento do classificador

4.2.5. ETAPA DE CLASSIFICAÇÃO DE SINAIS MIOELÉTRICOS

Após o treinamento do classificador em cascata, o programa desenvolvido seleciona automática e randomicamente mais amostras (diferentes das utilizadas na etapa de treinamento), calcula as suas características temporais (VMA, NCR, CFO e NMSD), monta os vetores que serão classificados para então apresentá-los ao classificador em cascata. No final da etapa de classificação, o desempenho obtido pelo classificador é mostrado. A Figura 31 mostra o processo de classificação.

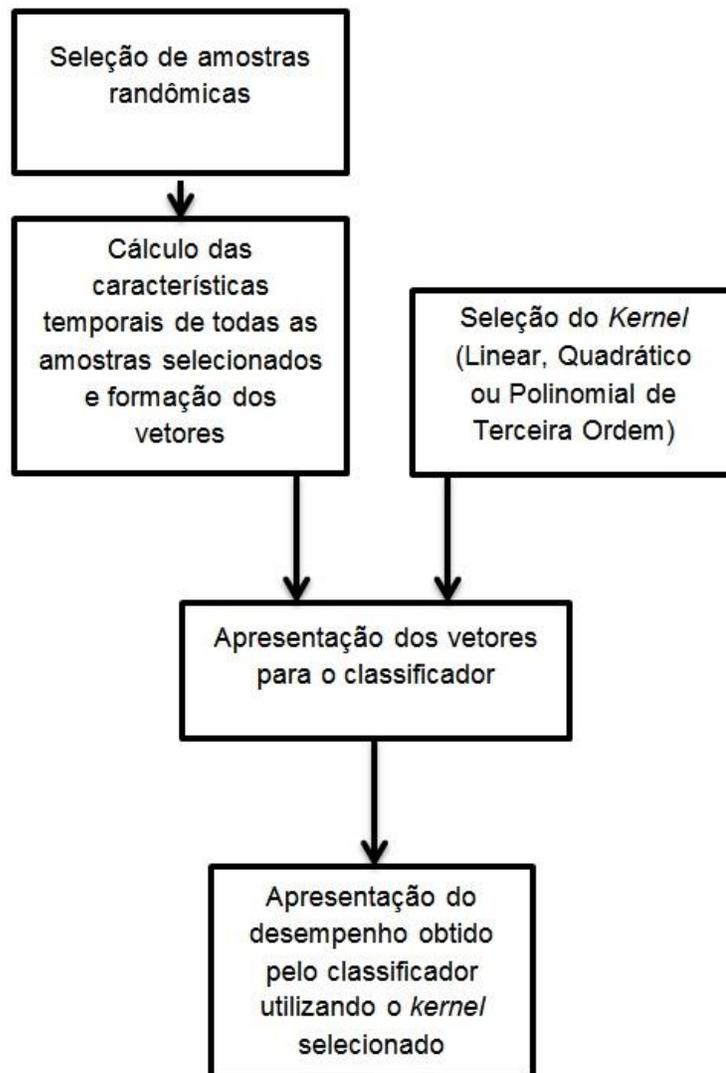


Figura 31 - Etapa de teste do classificador em cascata

5. RESULTADOS E DISCUSSÃO

Para verificar se Máquinas de Vetores de Suporte podem ser utilizadas na classificação dos oito padrões (MF, PF, IF, MEF, AF, MINF, PIF e MANF) de mão humana a partir de sinais mioelétricos provenientes do antebraço utilizando os parâmetros VMA, NMSD, CFO e NCR, foram realizados vários testes.

O programa automatizado foi executado variando-se: o número de vetores utilizados para o treinamento, o número de amostras que são utilizadas para calcular as componentes VMA, NMSD, CFO e NCR dos vetores e o tipo de *Kernel*. Os *Kernels* utilizados foram: linear, quadrático e polinomial de terceira ordem. O número de vetores utilizados para o treinamento variou de 20 até 200 em intervalos de 20. Já o número de amostras utilizadas para calcular as componentes dos vetores variou de 100 até 1000 em intervalos de 100.

5.1. *KERNEL* LINEAR

O gráfico mostrado na Figura 32 apresenta os resultados do teste de desempenho para o *kernel* linear, retratando o número de vezes que o classificador foi capaz de classificar corretamente em relação ao número de vetores apresentados para o treinamento e em relação ao número de amostras usadas para calcular as componentes dos vetores (VMA, NMSD, CFO e NCR). O Apêndice A mostra separadamente o índice de acerto do classificador para cada uma das oito classes estudadas utilizando o *kernel* linear.

Como pode ser observado na Figura 32, o desempenho do classificador aumenta quando o número de vetores ou o número de amostras aumenta. Dentro das condições de estudo e para o *kernel* linear, o maior índice de acerto obtido pelo classificador foi de 99,37% utilizando 160 vetores de cada classe para a etapa de treinamento e 1000 amostras para o cálculo das componentes dos vetores. Já o menor índice de acerto foi de 56,62% utilizando 20 vetores de cada classe para o treinamento e 100 amostras.

Além disso, é importante retratar que índices de acerto acima de 90,00% foram obtidos para o menor número de vetores testado, ou seja, 20 vetores. Isso significa que, mesmo para um treinamento com poucos vetores, o classificador foi capaz de atingir índices de acerto próximos a 100,00% utilizando o *kernel* linear.

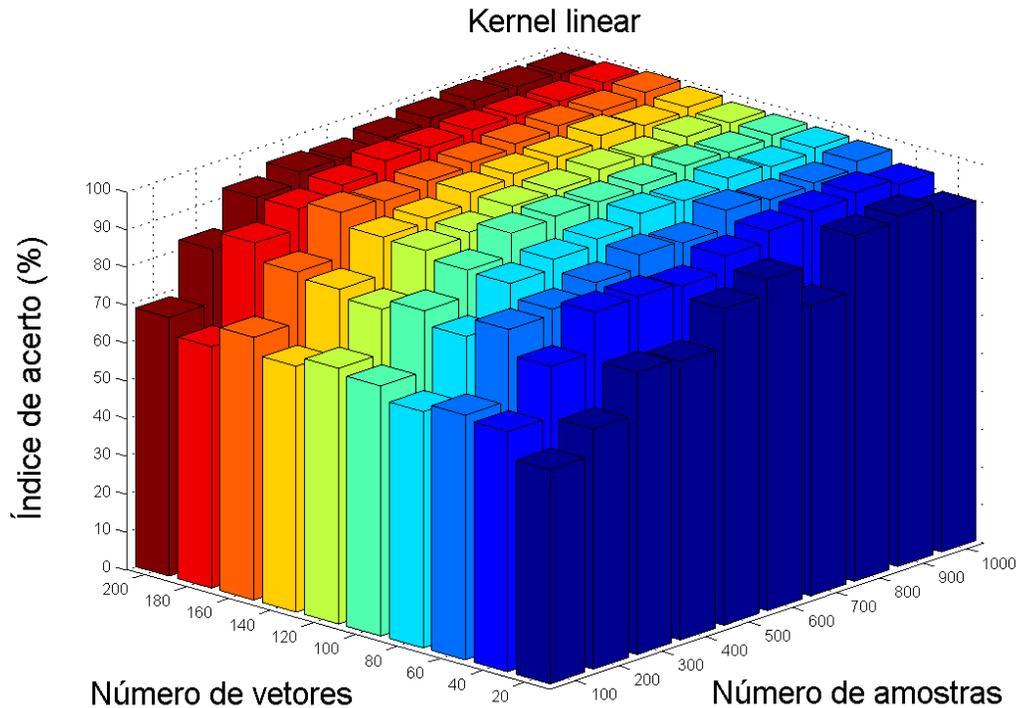


Figura 32 - Desempenho do classificador para o *kernel* linear

5.2. KERNEL QUADRÁTICO

O gráfico mostrado na Figura 33 apresenta os resultados do teste de desempenho para o *kernel* quadrático, retratando o número de vezes que o classificador foi capaz de classificar corretamente em relação ao número de vetores apresentados para o treinamento e em relação ao número de amostras usadas para calcular as componentes dos vetores (VMA, NMSD, CFO e NCR). O Apêndice B mostra separadamente o índice de acerto do classificador para cada uma das oito classes estudadas utilizando o *kernel* quadrático.

Como pode ser observado na Figura 33, o desempenho do classificador aumenta quando o número de vetores ou o número de amostras aumenta. Dentro das

condições de estudo e para o *kernel* quadrático, o maior índice de acerto obtido foi de 99,62% para 200 vetores de cada classe utilizados na etapa de treinamento e 1000 amostras para o cálculo das componentes desses vetores; já o menor índice de acerto foi de 32,75% para 20 vetores de cada classe para o treinamento e 100 amostras. Assim como para o *kernel* linear, o classificador utilizando o *kernel* quadrático também obteve taxas assertivas acima de 90,00% para apenas 20 vetores de cada classe sendo utilizados durante a etapa de treinamento.

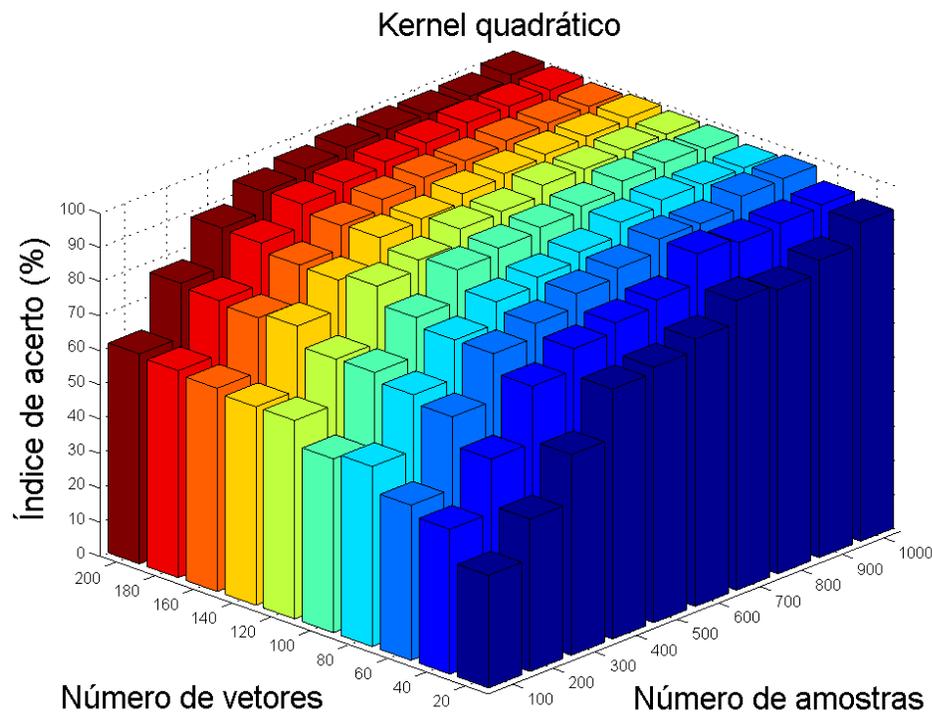


Figura 33 - Desempenho do classificador para o *kernel* quadrático

5.3. KERNEL POLINOMIAL DE TERCEIRA ORDEM

O gráfico mostrado na Figura 34 apresenta os resultados do teste de desempenho para o *kernel* polinomial de terceira ordem, retratando o número de vezes que o classificador foi capaz de classificar corretamente em relação ao número de vetores apresentados para o treinamento e em relação ao número de amostras usadas para calcular as componentes dos vetores (VMA, NMSD, CFO e NCR). O Apêndice C

mostra separadamente o índice de acerto do classificador para cada uma das oito classes estudadas utilizando o *kernel* polinomial de terceira ordem.

Assim como para os *kernels* linear e quadrático, de acordo com a Figura 34, fica claro que o desempenho do classificador aumenta quando o número de vetores ou o número de amostras aumenta. Dentro das condições de estudo e para o *kernel* polinomial de terceira ordem, o maior índice de acerto obtido pelo classificador foi de 99,00% utilizando 200 vetores de cada classe para o treinamento e 1000 amostras para o cálculo das componentes dos vetores. O menor índice de acerto obtido foi de 18,25% para 20 vetores de cada classe utilizados para o treinamento e 100 amostras.

Com o *kernel* polinomial de terceira ordem, o classificador só foi capaz de obter taxas assertivas acima de 90,00% quando 40 vetores de cada classe foram utilizados para a etapa de treinamento.

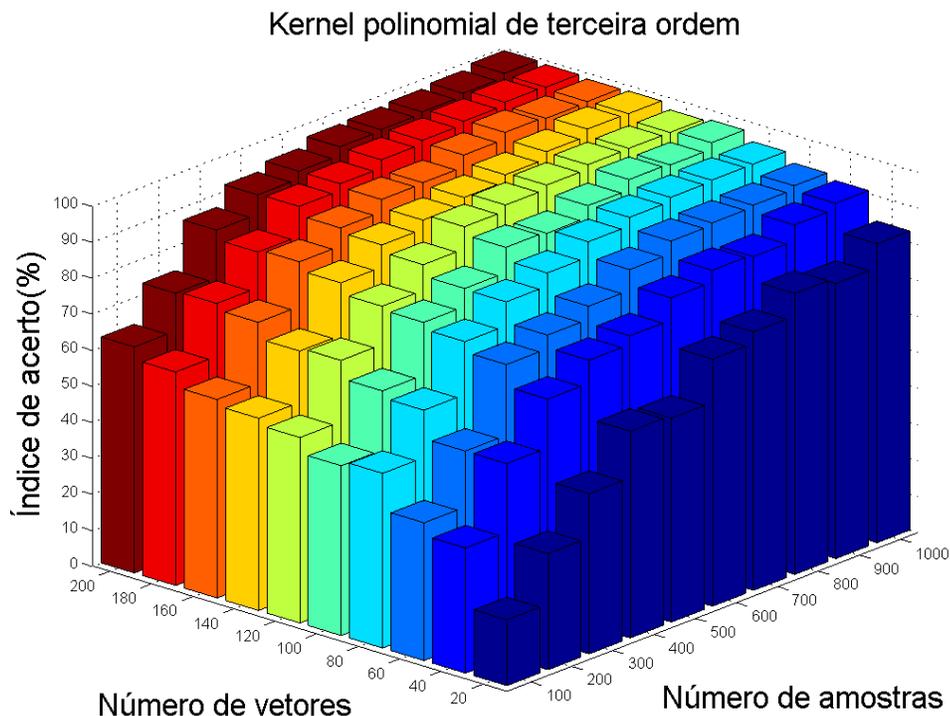


Figura 34 - Desempenho do classificador para o *kernel* polinomial de terceira ordem

5.4. COMPARAÇÃO DOS RESULTADOS OBTIDOS

Como pode ser observado nas Figuras 32, 33 e 34, o classificador com *kernel* linear atingiu, em média, índices de acerto maiores utilizando menos vetores para o treinamento e menos amostras para o cálculo das componentes desses vetores. Por exemplo, com apenas 40 vetores de cada classe sendo utilizados para o treinamento, o classificador com *kernel* linear foi capaz de obter índices de acerto acima de 95,00%. Já para o *kernel* quadrático, índices de acerto acima de 95,00% só foram obtidos utilizando 60 ou mais vetores de cada classe para o treinamento. Com o *kernel* polinomial de terceira ordem, taxas assertivas acima de 95,00% só foram obtidas quando 100 ou mais vetores de cada classe foram utilizados para o treinamento. Isso indica que, para uma possível aplicação em tempo real, o *kernel* mais indicado seria o linear, pois o tempo de treinamento e processamento seria menor comparado com os outros *kernels* estudados.

5.5. COMPARAÇÃO COM OUTROS TRABALHOS

Várias pesquisas vêm sendo realizadas para estudar o comportamento de algoritmos e técnicas de classificação aplicadas no reconhecimento de movimentos da mão humana através de sinais mioelétricos. A falta de padronização das condições de realização das pesquisas e experimentos, como classes de padrões e fontes de sinais mioelétricos diferentes, gera uma grande dificuldade durante a comparação dos resultados obtidos nos estudos. Apesar destas dificuldades, esta seção tem por objetivo tentar fazer uma comparação justa entre os resultados obtidos neste trabalho com os resultados obtidos por outros pesquisadores.

Em Geenthanjali et al. (2009), foi estudado os classificadores K vizinhos mais próximos (do inglês: *K Nearest Neighbor Classifier*) e Redes Neurais; enquanto que o presente trabalho estudou o desempenho de um classificador formador por MVS organizadas em cascata. A precisão obtida em Geenthanjali et al. (2009) foi de 78,66% para a Rede Neural e 84,53% para o K vizinhos mais próximos. Já a maior precisão obtida neste trabalho foi de 99,62% para o classificador utilizando o *kernel* quadrático. É importante lembrar que tanto as classes quanto a fonte dos sinais mioelétricos utilizadas em ambos os trabalhos são diferentes, portanto isso pode ter contribuído com

as diferenças observadas. Também é importante ressaltar que tanto o presente trabalho quanto o estudo realizado em Geenthanjali et al. (2009) utilizaram as mesmas características temporais para a formação dos vetores utilizados pelos classificadores. Além disso, para aplicações em tempo real, o classificador SVM seria mais adequado do que o classificador K vizinhos mais próximos estudado em Geenthanjali et al. (2009), pois de acordo com RAIKWAL e SAXENA (2012), a complexidade da Máquina de Vetores de Suporte durante a etapa de classificação é menor do que a complexidade do algoritmo K vizinhos mais próximos. Isso torna a MVS mais propícia para a aplicação em sistemas embarcados que precisam realizar a classificação em tempo real, como ocorre nas próteses biônicas.

Em Tsenov (2006), os classificadores Perceptron de Múltiplas Camadas, *Radial Basis Function* e *Learning Vector Quantization* foram aplicados no reconhecimento de movimentos da mão humana; já o presente trabalho estudou o desempenho de um classificador formado por Máquinas de Vetores de Suporte organizadas em cascata. Os classificadores utilizados em Tsenov (2006) foram treinados para reconhecer quatro classes diferentes a partir de nove características do sinal mioelétrico: média absoluta, variância, comprimento da forma de onda, norma, número de cruzamentos no eixo real, valor máximo absoluto, valor mínimo absoluto, valor médio e a diferença entre os valores máximo e mínimo. No presente trabalho, o classificador desenvolvido foi treinado para reconhecer até oito classes diferentes utilizando apenas quatro características do sinal mioelétrico: número de cruzamentos no eixo real, número de mudanças de sinal da derivada, média absoluta e comprimento da forma de onda. Como resultado, em Tsenov (2006), o Perceptron de Múltiplas Camadas atingiu um índice de acerto igual a 92,64%, o classificador Radial Basis Function obteve uma taxa assertiva de 83,82% e o classificador Learning Vector Quantization obteve uma precisão de 88,23%; já o classificador desenvolvido neste estudo foi capaz de atingir índices de acerto de até 99,625% com a utilização do *kernel* quadrático.

Em Yoshikawa, Mikawa e Tanaka (2007), foi desenvolvido um classificador formado por Máquinas de Vetores de Suporte utilizando o algoritmo todos-contra-todos para o reconhecimento de sete classes de movimento da mão humana; já no presente trabalho foi desenvolvido um classificador formado por Máquinas de Vetores de Suporte

organizadas em cascata, também conhecido como algoritmo um-contra-todos, para o reconhecimento de oito classes de movimento da mão humana. Em Yoshikawa, Mikawa e Tanaka (2007) foram utilizadas três características do sinal mioelétrico: média absoluta, coeficiente *Cepstrum* e coeficiente delta *Cepstrum*. No presente trabalho foram utilizadas quatro características: número de cruzamentos no eixo real, número de mudanças de sinal da derivada, média absoluta e comprimento da forma de onda. Como resultado, o algoritmo desenvolvido em Yoshikawa, Mikawa e Tanaka (2007) foi capaz de atingir índices de acerto de até 95,70%. Já o algoritmo desenvolvido neste trabalho foi capaz de atingir índices de acerto de até 99,62% quando o *kernel* quadrático foi utilizado. É importante lembrar que tanto as classes quanto a fonte dos sinais mioelétricos utilizadas em ambos os trabalhos são diferentes.

6. CONCLUSÃO

O presente trabalho abordou o projeto, o desenvolvimento e o estudo de um classificador formado por Máquinas de Vetores de Suporte organizadas em cascata. O objetivo principal do classificador desenvolvido foi o reconhecimento de oito classes de movimento da mão humana a partir de quatro características temporais de sinais mioelétricos provenientes do antebraço. As oito classes utilizadas foram: mão fechada; polegar flexionado; indicador flexionado; médio flexionado; anular flexionado; mínimo flexionado; médio, anular e mínimo flexionados; e polegar e médio flexionados. As características temporais utilizadas foram: valor médio absoluto; número de mudança de sinal da derivada; número de cruzamentos no eixo real; e comprimento da forma de onda.

Um conjunto de testes foi realizado para estudar o desempenho do classificador desenvolvido variando o tipo de *kernel*, o número de vetores utilizados durante o treinamento e o número de amostras do sinal mioelétrico utilizadas para calcular as componentes dos vetores. Os *kernels* utilizados foram: linear, quadrático e polinomial de terceira ordem. O número de vetores utilizados na etapa de treinamento variou de 20 até 200 em intervalos de 20. O número de amostras utilizadas para o cálculo das componentes dos vetores variou de 100 até 1000 em intervalos de 100. Como resultado, foi constatado que o classificador desenvolvido foi capaz de atingir índices de acerto de até 99,62% para o *kernel* quadrático, 99,37% para o *kernel* linear e 99% para o *kernel* polinomial de terceira ordem. Também foi possível concluir que o classificador com *kernel* linear foi capaz de obter maiores taxas de acerto utilizando menos vetores para o treinamento e menos amostras. Além disso, foi possível observar que, para todos os *kernels* utilizados, o índice de acerto do classificador aumentou quando o número de vetores ou amostras aumentou.

Baseado nos resultados obtidos foi possível constatar que existem fronteiras lineares bem definidas separando as oito classes de movimentos estudadas. Com isso, se torna viável a utilização de Máquinas de Vetores de Suporte na classificação desses padrões.

6.1. SUGESTÃO PARA TRABALHOS FUTUROS

O presente trabalho utilizou todos os oito canais de sinais presentes na base de dados (KHUSHABA, 2012). Uma sugestão para um trabalho futuro seria o estudo do impacto da redução do número de eletrodos (canais de aquisição) no índice de acerto do classificador desenvolvido. Uma das vantagens da diminuição do número de canais seria a diminuição do tempo de processamento do algoritmo, isso o tornaria mais adequado para aplicações que exigem classificação em tempo real. Além disso, a redução do número de canais de aquisição baratearia o custo da prótese e diminuiria o espaço necessário para os eletrodos.

REFERÊNCIAS BIBLIOGRÁFICAS

AJIBADE, A.; AKINNIYI, O. T.; OKOYE, C. S. Indications and complications of major limb amputations in Kano, Nigeria. GHANA MEDICAL JOURNAL. v. 47, n. 4, p. 185-188 .2013.

ALY, M. Survey on multiclass classification methods. NEURAL NETW. P. 1-9. 2005.

AMARAL, T. G.; DIAS, O. P.; WOLCZOWSKI, A.; PIRES, V. F. Neural network based identification of hand movements using biomedical signals. In: INTELLIGENT ENGINEERING SYSTEMS (INES), 2012 IEEE 16TH INTERNATIONAL CONFERENCE. p. 125-129.

AMPUTEE COALITION OF AMERICA. People With Amputation Speak Out. Disponível em: <http://www.amputee-coalition.org/wp-content/uploads/2014/11/lsp_people-speak-out_120115-113243.pdf>. Acesso em: 13/07/2016.

BRADWAY, J. K.; MALONE, J. M., RACY, J.; LEAL, J. M.; POOLE, J. Psychological adaptation to amputation: an overview. ORTHOTICS AND PROSTHETICS. v. 38, n. 3, p. 46-50. 1984

CALIL, A. M; SALLUM, A. A; DOMINGUES, C. A; NOGUEIRA, L. S. Mapeamento das lesões em vítimas de acidentes de trânsito: Revisão sistemática da literatura REVISTA LATINO-AMERICANA DE ENFERMAGEM. v. 17, n.1, p. 120-125, 2009.

CHAN, F. H.; YANG, Y. S.; LAM, F. K.; ZHANG, Y. T.; PARKER, P. A. Fuzzy EMG classification for prosthesis control. IEEE TRANSACTIONS ON REHABILITATION ENGINEERING. v.8, n. 3, p. 305-311. 2000.

CHOI, Gi-Won et al. Development of Surface Myoelectric Sensor for Myoelectric Hand Prosthesis. In: POWER ELECTRONICS SPECIALISTS CONFERENCE. 2006. p. 1-5.

CHOWDHURY, R. H.; REAZ, M. B.; ALI, M. A. B. M.; BAKAR, A. A.; CHELLAPPAN, K.; CHANG, T. G. Surface electromyography signal processing and classification techniques. SENSORS. v. 13, n. 9, p. 12431-12466. 2013.

CORTES, C; VAPNIK, V. Support-vector networks. Machine learning, v.20, n.3, p.273-297, Set. 1995.

CRISWELL, E; Cram`s Introduction to Surface Electromyography. 2ed. Massachusetts: Jones and Bartlett Publishers, 2011. 412p.

DAY, Scott. BORTEC BIOMEDICAL LTD. Important factors in surface EMG measurement. - 2002.

DEAN, G. A. Amputations: statistics and trends. ANNALS OF THE ROYAL COLLEGE OF SURGEONS OF ENGLAND. v. 73, n.3, p. 137-142, 1991.

DE LUCA, J. C. DELSYS INCORPORATED. Surface Electromyography Detection and Recording - 2002.

EPSTEIN, R. A.; HEINEMANN, A. W.; MCFARLAND, L. V. Quality of life for veterans and servicemembers with major traumatic limb loss from Vietnam and OIF/OEF conflicts. JOURNAL OF REHABILITATION RESEARCH AND DEVELOPMENT. v. 47, n. 4, p. 373-385. 2010.

GAINES, W. J.; SMART, C.; ZACHARY, M. B. Upper limb traumatic amputees Review of prosthetic use. JOURNAL OF HAND SURGERY. v. 22, n. 1, p. 73 – 76, 1997.

GAUTHAM, M.; KUMAR, S. S. Emg Controlled Bionic Arm. In: NATIONAL CONFERENCE ON INNOVATIONS IN EMERGING TECHNOLOGY, 2011, Perundurai. Proceedings... Perundurai: IEEE, 2011. p.111 – 114.

GEENTHANJALI, P.; RAY, K. K.; SHANMUGANATHAN, P. V. Actuation of Prosthetic Drive Using EMG Signal. In: TENCON, 2009, Singapura. Anais... Singapura: IEEE, 2009. p. 1 – 5.

GRECH, C.; DEBONO, R. F. The lived experience of persons with an amputation. MALTA JOURNAL OF HEALTH SCIENCES (2014).

GRIMMER, M.; HOLGATE, M.; HOLGATE, R.; BOEHLER, A.; WARD, J.; HOLLANDER, K.; SEYFARTH, A. A powered prosthetic ankle joint for walking and running. BIOMEDICAL ENGINEERING ONLINE. v. 15, n. 3, p. 37 - 52. 2016

HARGROVE, L. J.; ENGLEHART, K.; HUDGINS, B. A Comparison of Surface and Inramuscular Myoelectric Signal Classification. IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. v. 54, n. 5, p.847 - 853 , Maio 2007.

HAYKIN, Simon. NEURAL NETWORK AND LEARNING MACHINES. 3 ed. Canadá: PHI Learning, 2014.

HSU, C. W.; LIN, C. J. A comparison of methods for multiclass support vector machines. IEEE TRANSACTIONS ON NEURAL NETWORKS, v.13, n.2, p. 415-425. 2002.

IBARRA, J. C. G.; MONTALVO, C. S.; OCHOA, O. V.; GONZALEZ, H. G. P. EMG Pattern Recognition System Based on Neural Networks. In: MEXICAN INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE: ADVANCES IN ARTIFICIAL INTELLIGENCE AND APPLICATIONS, n. 11, 2012, San Luis Potosi. Proceedings... San Luis Potosi: IEEE, 2012. p. 71 – 74.

JAMAL, M. Z. Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis. Editado por Ganesh R. Naik. Computational Intelligence in Electromyography analysis - A Perspective on Current Applications and Future Challenges. Disponível em: <<http://dx.doi.org/10.5772/52556>>. Acesso em: 09/05/2016

JAIN, A. S.; ROBINSON, Douglas P. H. Upper Limb Amputation. 15p. Ninewells Hospital and Medical School, Dundee, 2008.

KHEZRI, M.; JAHED, M. Real-time intelligent pattern recognition algorithm for surface EMG signals. BIOMEDICAL ENGINEERING ONLINE. v. 6, n. 1, 45, p. 1-12 . 2007.

KHUSHABA, Rami N.; KODAGODA, Sarath. Electromyogram (EMG) feature reduction using mutual components analysis for multifunction prosthetic fingers control. In: CONTROL AUTOMATION ROBOTICS & VISION (ICARCV), 2012 12th International Conference on. IEEE, 2012. p. 1534-1539.

KHUSHABA, R. Electromyogram Repository. Em: <<https://onedrive.live.com/?authkey=%21Ar1wo75HiU9RrLM&id=AAA78954F15E6559%21312&cid=AAA78954F15E6559>>. Acesso em: 10/06/2015.

KHZERII, M.; JAHED, M.; SADATI, N. (2007). Neuro-fuzzy surface EMG pattern recognition for multifunctional hand prosthesis control. In: INDUSTRIAL ELECTRONICS, IEEE INTERNATIONAL SYMPOSIUM: IEEE, 2007, p. 269-274.

KULKARNI, J.; PANDE, S.; MORRIS, J. Survival rates in dysvascular lower limb amputees. *INTERNATIONAL JOURNAL OF SURGERY*. n. 4, v.4, p. 217 – 221. Agosto 2006.

LEVESQUE, C.; GAGNON, C. G. An Above-Knee Prosthesis for Rock Climbing. *ORTHOTICS AND PROSTHETICS*. v.41, n. 1, p. 41-45. 1987.

LIU, F.; WILLIAMS, R. M.; LIU, H. E.; CHIEN, N. H. The lived experience of persons with lower extremity amputation. *JOURNAL OF CLINICAL NURSING*. v. 19, n. 15-16, p. 2152-2161. Janeiro 2010.

LUO, Z.; YANG, G. Study of Myoelectric Prostheses Based on Fuzzy Control and Touch Feedback. In: *INTERNATIONAL CONFERENCE ON NEURAL NETWORKS AND BRAIN*, 2005, China. Proceedings... Beijing: IEEE, 2005. p. 1815 – 1819.

LYONS, R. G; *Understanding Digital Signal Processing*. 3. ed. New Jersey: Prentice Hall, 2010. 925p.

MALBOUBI, M.; RAZZAZI, F.; SH, M. A.; DAVARI, A. Power line noise elimination from EMG signals using adaptive Laguerre filter with fuzzy step size. In: *17th Iranian Conference of Biomedical Engineering (ICBME)*, 2010, Iranian... Iran: IEEE, 2010. p. 1-4.

MESIN, L.; MERLETTI, R.; RAINOLDI, A. Surface EMG: the issue of electrode location. *JOURNAL OF ELECTROMYOGRAPHY AND KINESIOLOGY*. v. 19, n. 5, p. 719-726. 2009.

MILLSTEIN, S., BAIN, D., & HUNTER, G. A. A review of employment patterns of industrial amputees-factors influencing rehabilitation. *PROSTHETICS AND ORTHOTICS INTERNATIONAL*. v. 9, n. 2, p. 69-78. 1985.

O'NEILL, P. A.; MORIN, L. E.; SCOTT, R. N. Myoelectric Signal Characteristics from Muscle in Residual Upper Limbs. TRANSACTIONS ON REHABILITATION ENGINEERING., v. 2, n. 4, p. 266 – 270, Dezembro 1994.

PASCALE, B. A., & POTTER, B. K. Residual limb complications and management strategies. CURRENT PHYSICAL MEDICINE AND REHABILITATION REPORTS. v. 2, n. 4, p. 241-249. 2014

Platt, J. Sequential minimal optimization: A fast algorithm for training support vector machines. 1998.

RAIKWAL, J. S.; SAXENA, K. Performance Evaluation of SVM and K-Nearest Neighbor Algorithm over Medical Data set. INTERNATIONAL JOURNAL OF COMPUTER APPLICATIONS. v. 50, n. 14, p.35 - 39 , Julho 2012.

REAZ, M. B. I.; HUSSAIN, M. S.; MOHD-YASIN, F. Techniques of EMG signal analysis: detection, processing, classification and applications. BIOLOGICAL PROCEDURES ONLINE. v. 8, n.1, p. 11-35. 2006.

RIFKIN, R.; KLAUTAU, A. In defense of one-vs-all classification. JOURNAL OF MACHINE LEARNING RESEARCH. v. 5 n. 1, p. 101-141. Janeiro 2004.

ROY, S. H.; DE LUCA, C. J.; SCHNEIDER, J. O. C. H. E. N. Effects of electrode location on myoelectric conduction velocity and median frequency estimates. JOURNAL OF APPLIED PHYSIOLOGY. v.61, n. 4, p. 1510-1517. 1986.

SHROFFE E. H. D; MANIMEGALAI P. Hand Gesture Recognition Based on EMG Signals Using ANN. INTERNATIONAL JOURNAL OF COMPUTER APPLICATION. v.2, n. 3, p. 31-39. 2013.

SMURR, L. M.; GULICK, K.; YANCOSEK, K.; GANZ, O. Managing the upper extremity amputee: a protocol for success. JOURNAL OF HAND THERAPY. v. 21, n. 2, p. 160-176. 2008

SRIVASTAVA, K.; SALDANHA, D.; CHAUDHURY, S.; RYALI, V. S. S. R.; GOYAL, S.; BHATTACHARYYA, D.; & BASANNAR, D. A study of psychological correlates after amputation. MEDICAL JOURNAL ARMED FORCES INDI. v. 66, n.4, p. 367-373. 2010

STANSBURY, L. G.; LALLISS, S. J.; BRANSTETTER, J. G.; BAGG, M. R.; HOLCOMB, J. B. Amputations in US military personnel in the current conflicts in Afghanistan and Iraq. JOURNAL OF ORTHOPAEDIC TRAUMA. v. 22, n.1, p. 43-46. Janeiro 2008.

SUBEDI, N.; HEIRE, P.; PARMER, V.; BEARDMORE, S.; OH, C.; JEPSON, F.; ALI, S. I. Multimodality imaging review of the post-amputation stump pain. THE BRITISH JOURNAL OF RADIOLOGY. v. 89, n.1068. 2016.

TSENOV, G.; ZEGHBIB, A.G.; PALIS, F.; SHOYLEV, N.; MLADENOV, V. Neural Networks for Online classification of Hand and Finger Movements Using Surface EMG signals. In: SEMINAR ON NEURAL NETWORK APPLICATIONS IN ELECTRICAL ENGINEERING, n.8, 2006, Belgrade. Proceedings... Belgrade: IEEE, 2006. p. 167 – 171.

WAINSTEIN, A. J.; OLIVEIRA, T. A.; GUELFY, D. C.; GONTIJO, B. R.; CASTRO, E. V.; CARVALHO, R. A.; PAZ, N. M.; LACERDA, L. T. Limb amputation for squamous cell carcinoma of the skin: factors involved in this poor evolution. REVISTA DO COLÉGIO BRASILEIRO DE CIRURGIÕES. V.39, n. 3, p. 173 – 177, 2012.

WANI, M. L.; WANI, S. N.; GANIE, F. A.; SINGH, S.; LONE, R. A.; WANI, U. D. N. Peripheral vascular injuries due to blunt trauma (road traffic accident): management and outcome. INTERNATIONAL JOURNAL OF SURGERY. v. 10, n. 9, p. 560 - 562. 2012.

YOSHIKAWA, M.; MIKAWA, M.; TANAKA, K. A Myoelectric Interface for Robotic Hand Control Using Support Vector Machine. In: INTERNATIONAL CONFERENCE ON ROBOTS AND SYSTEMS, 2007, Estados Unidos. Proceedings... San Diego: IEEE, 2007. p. 2723 – 2728.

ZECCA, M.; MICERA, S.; CARROZZA, M. C.; & DARIO, P. Control of multifunctional prosthetic hands by processing the electromyographic signal. CRITICAL REVIEWS™ IN BIOMEDICAL ENGINEERING. v. 30, n. 4-6, p. 459-.485. 2002

APÊNDICE A – Resultados dos testes utilizando o *kernel* linear

Número de vetores	20									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	100	96	96	96	100	100	100	100	100	100
ClasseL_I1 (%)	54	56	74	70	93	83	66	87	95	91
ClasseL_L1 (%)	60	62	70	76	91	88	88	95	90	100
ClasseM_M1 (%)	71	70	83	76	80	100	74	97	94	94
ClasseMRL1 (%)	51	71	80	70	87	82	85	100	97	92
ClasseR_R1 (%)	43	58	65	75	68	80	66	82	94	81
ClasseT_I1 (%)	32	46	62	64	77	79	75	89	86	79
ClasseT_T1 (%)	46	49	67	62	74	88	60	81	86	81
Média total (%)	56.625	63.5	74.625	73.625	83.75	87.5	76.75	91.375	92.75	89.75

Número de vetores	40									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	94	90	100	100	99	99	100	100	100	100
ClasseL_I1 (%)	85	81	90	85	84	86	94	92	98	88
ClasseL_L1 (%)	76	91	98	86	86	96	99	95	95	99
ClasseM_M1 (%)	60	86	93	85	88	93	91	99	95	96
ClasseMRL1 (%)	72	69	89	91	89	89	98	94	96	99
ClasseR_R1 (%)	55	65	77	83	95	90	97	91	95	93
ClasseT_I1 (%)	42	58	83	87	77	84	80	97	97	96
ClasseT_T1 (%)	24	75	69	84	74	88	88	89	90	81
Média total (%)	63.5	76.875	87.375	87.625	86.5	90.625	93.375	94.625	95.75	94

Número de vetores	60									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	98	100	99	100	100	100	100	100	100	100
ClasseL_I1 (%)	89	90	93	93	93	84	98	94	88	100
ClasseL_L1 (%)	78	92	91	91	98	99	96	99	99	100
ClasseM_M1 (%)	55	76	82	88	94	78	100	96	93	97
ClasseMRL1 (%)	73	90	88	89	91	93	98	99	100	98
ClasseR_R1 (%)	57	70	84	81	88	89	91	97	96	94
ClasseT_I1 (%)	35	74	77	88	79	90	92	86	96	96
ClasseT_T1 (%)	33	76	66	75	90	94	90	86	89	91
Média total (%)	64.75	83.5	85	88.125	91.625	90.875	95.625	94.625	95.125	97

Número de vetores	80									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	95	98	100	100	100	100	100	100	100	100
ClasseI_I1 (%)	90	84	93	95	93	100	96	99	96	98
ClasseL_L1 (%)	84	91	89	97	96	97	98	99	98	100
ClasseM_M1 (%)	46	57	94	87	94	98	97	100	99	100
ClasseMRL1 (%)	76	92	96	92	99	100	100	100	99	100
ClasseR_R1 (%)	41	74	78	89	95	85	92	94	92	99
ClasseT_I1 (%)	25	76	85	85	88	93	94	98	97	91
ClasseT_T1 (%)	43	56	74	84	76	91	83	87	89	91
Média total (%)	62.5	78.5	88.625	91.125	92.625	95.5	95	97.125	96.25	97.375

Número de vetores	100									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	93	100	100	100	100	100	100	100	100	100
ClasseI_I1 (%)	80	96	96	97	98	98	96	98	100	98
ClasseL_L1 (%)	84	91	99	98	96	100	99	100	98	97
ClasseM_M1 (%)	60	66	86	96	98	96	98	97	98	94
ClasseMRL1 (%)	75	88	94	99	99	96	97	98	98	100
ClasseR_R1 (%)	54	72	81	92	89	94	92	97	94	98
ClasseT_I1 (%)	47	76	78	91	93	92	98	96	95	98
ClasseT_T1 (%)	36	68	78	86	91	87	88	92	92	96
Média total (%)	66.125	82.125	89	94.875	95.5	95.375	96	97.25	96.875	97.625

Número de vetores	120									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	97	100	100	100	100	100	100	100	100	100
ClasseI_I1 (%)	92	91	89	93	100	98	99	99	98	100
ClasseL_L1 (%)	89	94	98	98	100	97	99	100	99	100
ClasseM_M1 (%)	64	78	92	84	98	98	95	99	100	99
ClasseMRL1 (%)	78	88	95	95	97	98	99	100	99	100
ClasseR_R1 (%)	49	74	91	94	88	90	94	97	99	96
ClasseT_I1 (%)	34	60	80	88	92	93	98	89	96	96
ClasseT_T1 (%)	38	50	83	84	85	90	92	87	92	90
Média total (%)	67.625	79.375	91	92	95	95.5	97	96.375	97.875	97.625

Número de vetores	140									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	95	98	100	99	100	100	100	100	100	100
ClasseI_I1 (%)	94	95	98	97	96	100	100	100	98	98
ClasseL_L1 (%)	91	93	97	96	98	100	100	100	100	100
ClasseM_M1 (%)	54	83	89	95	96	96	99	97	97	100
ClasseMRL1 (%)	80	93	94	98	98	100	98	100	100	100
ClasseR_R1 (%)	48	70	84	85	95	93	90	97	100	99
ClasseT_I1 (%)	28	58	89	89	92	93	99	98	91	99
ClasseT_T1 (%)	30	62	80	81	89	90	91	99	95	93
Média total (%)	65	81.5	91.375	92.5	95.5	96.5	97.125	98.875	97.625	98.625

Número de vetores	160									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	98	100	100	100	100	100	100	100	100	100
ClasseI_I1 (%)	92	95	98	100	98	98	98	99	100	99
ClasseL_L1 (%)	89	94	97	100	99	98	97	98	100	100
ClasseM_M1 (%)	69	84	97	88	95	96	100	98	100	100
ClasseMRL1 (%)	76	90	96	100	99	100	100	98	99	100
ClasseR_R1 (%)	51	69	93	90	92	94	95	100	98	100
ClasseT_I1 (%)	37	64	91	91	94	96	99	99	97	99
ClasseT_T1 (%)	44	67	86	82	86	89	90	94	93	97
Média total (%)	69.5	82.875	94.75	93.875	95.375	96.375	97.375	98.25	98.375	99.375

Número de vetores	180									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	94	100	99	100	100	100	100	100	100	100
ClasseI_I1 (%)	91	98	99	97	99	100	99	99	100	99
ClasseL_L1 (%)	84	96	99	97	100	97	100	99	99	100
ClasseM_M1 (%)	54	87	92	91	98	97	98	96	98	100
ClasseMRL1 (%)	80	91	97	99	99	100	100	100	99	100
ClasseR_R1 (%)	51	77	90	91	95	96	95	99	100	99
ClasseT_I1 (%)	27	75	82	92	96	97	97	95	98	100
ClasseT_T1 (%)	30	75	82	93	93	90	94	94	88	92
Média total (%)	63.875	87.375	92.5	95	97.5	97.125	97.875	97.75	97.75	98.75

Número de vetores	200									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	96	99	99	100	100	100	100	100	100	100
ClasseI_I1 (%)	87	95	93	96	97	96	99	98	96	100
ClasseL_L1 (%)	85	66	98	99	97	99	100	100	100	100
ClasseM_M1 (%)	58	85	90	98	93	96	100	100	98	99
ClasseMRL1 (%)	81	95	97	97	100	97	100	100	100	98
ClasseR_R1 (%)	52	85	87	89	95	94	95	98	98	98
ClasseT_I1 (%)	41	71	87	93	87	92	99	97	99	98
ClasseT_T1 (%)	47	64	88	90	90	98	90	96	96	91
Média total (%)	68.375	82.5	92.375	95.25	94.875	96.5	97.875	98.625	98.375	98

APÊNDICE B – Resultados dos testes utilizando o *kernel* quadrático

Número de vetores	20									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	73	71	62	93	95	94	94	84	91	97
ClasseI_I1 (%)	26	42	65	75	73	80	84	82	89	93
ClasseL_L1 (%)	27	33	72	66	67	79	89	78	89	89
ClasseM_M1 (%)	49	61	62	80	76	79	88	86	96	91
ClasseMRL1 (%)	27	44	53	59	79	59	79	86	81	90
ClasseR_R1 (%)	21	25	54	64	76	75	78	77	92	98
ClasseT_I1 (%)	26	41	43	70	70	74	78	83	87	91
ClasseT_T1 (%)	13	38	56	75	59	82	84	85	67	93
Média total (%)	32.75	44.375	58.375	72.75	74.375	77.75	84.25	82.625	86.5	92.75

Número de vetores	40									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	75	86	94	81	94	98	99	96	99	95
ClasseI_I1 (%)	45	51	75	86	91	84	96	86	93	95
ClasseL_L1 (%)	38	54	79	84	83	89	96	94	94	93
ClasseM_M1 (%)	40	60	74	83	87	81	97	96	96	92
ClasseMRL1 (%)	36	51	74	86	81	87	93	93	90	87
ClasseR_R1 (%)	43	50	56	82	73	74	93	91	93	98
ClasseT_I1 (%)	33	58	75	72	80	83	90	94	90	96
ClasseT_T1 (%)	27	53	67	70	77	86	87	89	91	95
Média total (%)	42.125	57.875	74.25	80.5	83.25	85.25	93.875	92.375	93.25	93.875

Número de vetores	60									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	80	91	91	98	100	98	96	99	99	100
ClasseI_I1 (%)	56	61	84	82	83	88	100	88	92	98
ClasseL_L1 (%)	40	82	83	77	92	95	94	96	99	98
ClasseM_M1 (%)	41	64	86	92	91	92	92	95	98	96
ClasseMRL1 (%)	39	58	81	87	88	87	92	95	96	98
ClasseR_R1 (%)	45	58	74	82	84	87	95	91	97	96
ClasseT_I1 (%)	33	60	76	77	82	91	95	91	97	96
ClasseT_T1 (%)	27	55	63	75	82	85	89	96	99	98
Média total (%)	45.125	66.125	79.75	83.75	87.75	90.375	94.125	93.875	97.125	97.5

Número de vetores	80									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	84	93	96	99	100	99	97	100	100	98
ClasseI_I1 (%)	44	62	75	74	85	91	89	99	91	96
ClasseL_L1 (%)	58	67	76	89	94	97	98	97	97	98
ClasseM_M1 (%)	61	70	88	88	95	88	95	97	100	99
ClasseMRL1 (%)	59	70	83	89	87	91	96	95	95	97
ClasseR_R1 (%)	38	71	77	83	80	82	97	94	93	94
ClasseT_I1 (%)	43	58	69	87	78	88	96	97	99	95
ClasseT_T1 (%)	32	57	74	80	89	93	92	95	97	96
Média total (%)	52.375	68.5	79.75	86.125	88.5	91.125	95	96.75	96.5	96.625

Número de vetores	100									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	81	97	96	99	98	99	99	100	100	99
ClasseI_I1 (%)	45	68	72	88	89	96	93	98	97	97
ClasseL_L1 (%)	59	68	87	87	96	96	95	100	99	97
ClasseM_M1 (%)	59	69	86	96	96	90	95	99	99	100
ClasseMRL1 (%)	49	63	89	92	97	92	98	98	100	99
ClasseR_R1 (%)	39	67	72	89	86	93	92	98	98	98
ClasseT_I1 (%)	35	71	84	87	93	93	96	99	100	99
ClasseT_T1 (%)	38	65	72	93	89	95	98	94	98	97
Média total (%)	50.625	71	82.25	91.375	93	94.25	95.75	98.25	98.875	98.25

Número de vetores	120									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	87	93	98	100	97	99	100	100	100	99
ClasseI_I1 (%)	44	73	82	93	94	94	96	96	99	96
ClasseL_L1 (%)	60	71	91	91	97	99	97	100	100	98
ClasseM_M1 (%)	65	76	88	94	94	98	99	100	99	98
ClasseMRL1 (%)	62	70	88	85	95	95	99	98	96	98
ClasseR_R1 (%)	64	67	91	92	94	91	98	98	98	99
ClasseT_I1 (%)	42	58	82	89	95	90	98	98	99	100
ClasseT_T1 (%)	38	59	79	78	90	93	95	92	97	99
Média total (%)	57.75	70.875	87.375	90.25	94.5	94.875	97.75	97.75	98.5	98.375

Número de vetores	140									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	93	95	97	100	100	100	100	100	99	100
ClasseI_I1 (%)	56	74	79	93	86	95	98	96	95	100
ClasseL_L1 (%)	58	84	90	98	92	97	97	97	100	98
ClasseM_M1 (%)	70	81	88	93	98	99	95	99	100	100
ClasseMRL1 (%)	46	74	90	89	96	94	98	95	100	100
ClasseR_R1 (%)	48	67	78	87	95	97	98	98	98	99
ClasseT_I1 (%)	46	64	79	93	90	92	95	100	99	97
ClasseT_T1 (%)	45	73	80	89	91	94	96	99	97	99
Média total (%)	57.75	76.5	85.125	92.75	93.5	96	97.125	98	98.5	99.125

Número de vetores	160									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	93	97	98	100	100	100	100	100	98	100
ClasseI_I1 (%)	55	63	82	90	94	95	96	98	97	94
ClasseL_L1 (%)	58	73	93	88	95	97	98	97	100	99
ClasseM_M1 (%)	62	78	75	96	98	100	99	100	100	99
ClasseMRL1 (%)	60	76	94	93	97	93	96	100	98	100
ClasseR_R1 (%)	51	70	81	94	93	98	94	97	99	99
ClasseT_I1 (%)	45	75	79	90	92	98	96	97	98	100
ClasseT_T1 (%)	49	67	82	87	92	93	96	95	97	97
Média total (%)	59.125	74.875	85.5	92.25	95.125	96.75	96.875	98	98.375	98.5

Número de vetores	180									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	93	94	100	99	100	100	100	100	99	100
ClasseI_I1 (%)	62	78	92	94	93	96	100	100	100	100
ClasseL_L1 (%)	59	83	91	97	100	100	99	99	99	99
ClasseM_M1 (%)	73	78	88	94	99	99	97	98	100	100
ClasseMRL1 (%)	62	82	85	94	97	95	99	100	100	100
ClasseR_R1 (%)	45	66	81	93	88	97	95	98	98	99
ClasseT_I1 (%)	45	55	78	92	94	97	98	100	100	99
ClasseT_T1 (%)	43	71	88	93	97	95	97	99	98	97
Média total (%)	60.25	75.875	87.875	94.5	96	97.375	98.125	99.25	99.25	99.25

Número de vetores	200									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	87	96	97	100	100	99	100	100	100	100
ClasseI_I1 (%)	56	77	79	89	94	96	94	94	97	100
ClasseL_L1 (%)	67	78	91	91	97	97	100	97	98	100
ClasseM_M1 (%)	59	75	93	95	100	99	99	100	99	100
ClasseMRL1 (%)	68	85	92	97	99	99	96	99	98	99
ClasseR_R1 (%)	58	69	81	98	93	97	98	99	96	99
ClasseT_I1 (%)	51	73	89	91	97	96	99	98	100	100
ClasseT_T1 (%)	43	62	84	92	88	97	98	95	97	99
Média total (%)	61.125	76.875	88.25	94.125	96	97.5	98	97.75	98.125	99.625

APÊNDICE C – Resultados dos testes utilizando o *kernel* polinomial de terceira ordem

Número de vetores	20									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	51	70	63	89	65	78	81	82	92	93
ClasseI_I1 (%)	10	42	43	58	57	79	89	80	82	86
ClasseL_L1 (%)	11	18	18	29	51	61	81	81	77	72
ClasseM_M1 (%)	25	32	37	70	66	69	65	77	90	85
ClasseMRL1 (%)	9	25	60	57	61	56	55	71	61	87
ClasseR_R1 (%)	8	18	34	67	43	65	56	66	70	84
ClasseT_I1 (%)	18	25	55	46	45	80	68	85	72	84
ClasseT_T1 (%)	14	28	46	43	65	61	79	82	67	73
Média total (%)	18.25	32.25	44.5	57.375	56.625	68.625	71.75	78	76.375	83

Número de vetores	40									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	60	68	87	93	89	92	87	86	93	98
ClasseI_I1 (%)	33	52	61	82	81	80	92	85	93	84
ClasseL_L1 (%)	35	41	64	67	72	81	88	79	80	88
ClasseM_M1 (%)	45	61	67	76	75	78	82	90	94	93
ClasseMRL1 (%)	32	62	68	71	74	79	86	86	88	89
ClasseR_R1 (%)	22	52	55	66	64	83	83	85	82	92
ClasseT_I1 (%)	32	51	77	65	74	84	84	84	95	92
ClasseT_T1 (%)	19	43	59	69	79	80	81	83	88	90
Média total (%)	34.75	53.75	67.25	73.625	76	82.125	85.375	84.75	89.125	90.75

Número de vetores	60									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	72	76	90	94	85	94	94	95	98	95
ClasseI_I1 (%)	38	59	68	71	76	88	92	89	97	88
ClasseL_L1 (%)	43	43	71	69	79	78	90	94	89	92
ClasseM_M1 (%)	33	63	80	73	87	88	90	97	99	89
ClasseMRL1 (%)	43	56	80	83	81	91	86	91	92	98
ClasseR_R1 (%)	23	51	59	68	74	87	87	91	86	94
ClasseT_I1 (%)	23	47	66	80	85	85	91	81	88	89
ClasseT_T1 (%)	31	35	73	79	79	81	90	87	80	92
Média total (%)	38.25	53.75	73.375	77.125	80.75	86.5	90	90.625	91.125	92.125

Número de vetores	80									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	84	88	96	89	92	96	97	97	96	93
ClasseI_I1 (%)	43	66	71	83	90	88	97	90	98	100
ClasseL_L1 (%)	46	63	73	85	80	89	98	96	89	97
ClasseM_M1 (%)	50	68	75	85	84	94	94	98	92	95
ClasseMRL1 (%)	52	65	81	84	89	92	93	97	95	92
ClasseR_R1 (%)	33	52	70	67	82	90	89	90	99	91
ClasseT_I1 (%)	44	50	80	85	90	90	95	95	97	97
ClasseT_T1 (%)	36	41	64	85	85	87	82	91	91	92
Média total (%)	48.5	61.625	76.25	82.875	86.5	90.75	93.125	94.25	94.625	94.625

Número de vetores	100									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	67	81	93	96	98	95	97	100	99	98
ClasseI_I1 (%)	52	65	71	75	90	86	94	95	93	94
ClasseL_L1 (%)	48	68	84	75	81	94	92	91	95	99
ClasseM_M1 (%)	52	66	81	82	93	82	93	95	100	98
ClasseMRL1 (%)	44	61	82	87	88	95	94	99	96	100
ClasseR_R1 (%)	47	53	78	85	88	87	95	94	96	97
ClasseT_I1 (%)	40	57	65	87	90	93	91	96	92	94
ClasseT_T1 (%)	27	57	71	78	93	85	87	96	92	97
Média total (%)	47.125	63.5	78.125	83.125	90.125	89.625	92.875	95.75	95.375	97.125

Número de vetores	120									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	79	94	86	97	98	99	99	99	95	98
ClasseI_I1 (%)	48	78	70	84	93	93	96	89	97	94
ClasseL_L1 (%)	58	74	81	84	89	90	97	98	98	96
ClasseM_M1 (%)	59	67	86	90	96	96	94	97	98	98
ClasseMRL1 (%)	57	72	82	90	95	93	98	99	94	98
ClasseR_R1 (%)	36	55	78	84	92	92	96	94	93	98
ClasseT_I1 (%)	43	52	72	78	88	99	89	96	98	95
ClasseT_T1 (%)	32	56	78	83	88	90	92	99	99	95
Média total (%)	51.5	68.5	79.125	86.25	92.375	94	95.125	96.375	96.5	96.5

Número de vetores	140									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	89	94	86	98	99	100	98	99	99	100
ClasseI_I1 (%)	53	66	76	92	95	88	94	97	97	99
ClasseL_L1 (%)	52	73	86	88	91	95	95	97	100	99
ClasseM_M1 (%)	55	67	86	87	95	99	95	99	99	97
ClasseMRL1 (%)	59	81	78	93	93	90	89	97	98	98
ClasseR_R1 (%)	44	51	84	72	94	91	97	95	99	99
ClasseT_I1 (%)	35	57	76	89	79	92	94	95	97	96
ClasseT_T1 (%)	40	52	85	87	80	86	94	93	98	98
Média total (%)	53.375	67.625	82.125	88.25	90.75	92.625	94.5	96.5	98.375	98.25

Número de vetores	160									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	90	94	96	98	100	97	100	100	99	100
ClasseI_I1 (%)	50	76	83	90	93	96	93	98	99	97
ClasseL_L1 (%)	60	69	82	92	94	96	97	99	98	95
ClasseM_M1 (%)	47	77	88	86	96	96	97	100	99	99
ClasseMRL1 (%)	63	78	90	88	93	86	99	98	99	97
ClasseR_R1 (%)	49	68	75	81	91	93	92	95	99	99
ClasseT_I1 (%)	42	61	86	88	93	94	96	98	95	99
ClasseT_T1 (%)	40	54	76	93	84	88	98	99	95	99
Média total (%)	55.125	72.125	84.5	89.5	93	93.25	96.5	98.375	97.875	98.125

Número de vetores	180									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	90	89	96	98	98	99	98	98	99	99
ClasseI_I1 (%)	52	70	82	85	86	96	98	97	98	94
ClasseL_L1 (%)	69	72	85	89	91	99	99	100	98	99
ClasseM_M1 (%)	59	85	87	95	99	100	99	99	100	100
ClasseMRL1 (%)	64	80	79	94	94	98	96	96	99	100
ClasseR_R1 (%)	53	69	82	90	92	92	98	100	100	99
ClasseT_I1 (%)	46	73	81	96	96	93	95	98	98	99
ClasseT_T1 (%)	41	53	78	89	95	92	94	96	99	99
Média total (%)	59.25	73.875	83.75	92	93.875	96.125	97.125	98	98.875	98.625

Número de vetores	200									
Número de amostras	100	200	300	400	500	600	700	800	900	1000
ClasseHC_1 (%)	90	97	96	99	100	98	100	100	100	100
ClasseI_I1 (%)	66	72	86	89	90	96	95	95	97	100
ClasseL_L1 (%)	60	73	88	95	97	98	96	95	98	99
ClasseM_M1 (%)	67	81	89	90	96	100	97	98	98	100
ClasseMRL1 (%)	70	76	85	94	96	98	95	99	96	97
ClasseR_R1 (%)	49	66	82	88	91	94	98	98	99	100
ClasseT_I1 (%)	46	65	84	91	92	95	99	97	99	99
ClasseT_T1 (%)	54	56	81	88	89	91	93	95	96	97
Média total (%)	62.75	73.25	86.375	91.75	93.875	96.25	96.625	97.125	97.875	99