Mateus Ymanaka Barretto

Aplicação de máquinas de vetor de suporte e modelos auto-regressivos de média móvel na classificação de sinais eletromiográficos

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Mestre em Engenharia.

CONSULTA
FD-4875

São Paulo
2007

OK

Janus

Universidade de São Paulo

RELATÓRIO DE DEFESA

Aluno: 3142 - 3508996 - 3 / Página 1 de 1

Relatório de defesa pública de Dissertação do(a) Senhor(a) Mateus Ymanaka Barretto no Programa: Engenharia Elétrica, do(a) Escola Politécnica da Universidade de São Paulo.

Aos 10 dias do mês de dezembro de 2007, realizou-se a Defesa da Dissertação do(a) Senhor(a) Mateus Ymanaka Barretto, apresentada para a obtenção do título de Mestre em Engenharia Elétrica - Área: Sistemas Eletrônicos, intitulada:

"Aplicação de máquinas de vetor de suporte e modelos auto-regressivos de média móvel na classificação de sinais eletromiográficos"

Após declarada aberta a sessão, o(a) Sr(a) Presidente passa a palavra aos examinadores para as devidas argüições que se desenvolvem nos termos regimentais. Em seguida, a Comissão Julgadora proclama o resultado:

Codpes/Ou.: 63773

PTC

Nome dos Participantes da Banca	Vínculo do Docente	Sigla da Unidade	Resultado
Cinthia Itiki	Presidente	EP - USP	Aprovado
Andre Fabio Kohn	Titular	EP - USP	Aprovado
Mauro Roberto Ushizima	Titular	Externo	Aprovado

Resultado Final: APROVADO

Parecer da Comissão Julgadora *

O candidato demonstrou domínio sobre o assunto e segurança ao responder às perguntas da banca. O trabalho apresenta boa qualidade e inovações na área.

Eu, Elisabete Aparecida Fernandes da Silva Ramos, Técnico Acadêmico, lavrei a presente ata, que assino juntamente com os(as) Senhores(as). São Paulo, aos 10 dias do mês de dezembro de 2007.

Andre Fabio Kohn

Mauro Roberto Ushizima

Cinthia Itiki
Orientador(a)

* Obs: Se o candidato for reprovado por algum dos membros, o preenchimento do parecer é obrigatório.

Título homologado pela Comissão de Pós-Graduação em 03/3/2008

Presidente da Comissão de Pós-Graduação

Prof. Dr. Paulo Eigi Miyagi
Presidente da Comissão de Pós-Graduação

Mateus Ymanaka Barretto

Aplicação de máquinas de vetor de suporte e modelos auto-regressivos de média móvel na classificação de sinais eletromiográficos

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Mestre em Engenharia.

Área de Concentração:
Sistemas Eletrônicos

Opção:
Engenharia Biomédica

Orientadora:
Cinthia Itiki

São Paulo
2007

SYSNO: 1662453
09/05/08

FICHA CATALOGRÁFICA

Barretto, Mateus Ymanaka
Aplicação de máquinas de vetor de suporte e modelos auto-regressivos de média móvel na classificação de sinais eletromiográficos / M.Y. Barretto. -- São Paulo, 2007.
78 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Telecomunicações e Controle.

1.Eletromiografia 2.Modelos lineares 3.Redes neurais I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Telecomunicações e Controle II.t.

aos meus pais politécnicos, que foram sempre um exemplo de vida.

Agradecimentos

À Profa. Cinthia por todas as oportunidades que me proporcionou de aprendizado, desenvolvimento e crescimento.

Aos meus familiares e à minha namorada pelo incentivo e apoio em todos os momentos.

Aos amigos e colegas do LEB (Bruno, Camila, Carlos, Diego, Fernando, Paulo, Rinaldo, Rogério e Sandro) pela companhia agradável no dia-a-dia e sua prontidão em ajudar sempre que necessário.

Ao Prof. André e ao Prof. Newton pelas sugestões ao desenvolvimento da pesquisa.

Aos professores da EPUSP, fundamentais à minha formação acadêmica.

À FAPESP pela bolsa de mestrado no. 05/57398-0, concedida pelo período de março de 2006 a dezembro de 2007.

Resumo

O diagnóstico de doenças neuromusculares é feito pelo uso conjunto de várias ferramentas. Dentre elas, o exame de eletromiografia clínica fornece informações vitais ao diagnóstico. A aplicação de alguns classificadores (discriminante linear e redes neurais artificiais) aos diversos parâmetros dos sinais de eletromiografia (número de fases, de reversões e de cruzamentos de zero, freqüência mediana, coeficientes auto-regressivos) tem fornecido resultados promissores na literatura. No entanto, a necessidade de um número grande de coeficientes auto-regressivos direcionou este mestrado ao uso de modelos auto-regressivos de média móvel com um número menor de coeficientes. A classificação (em normal, neuropático ou miopático) foi feita pela máquina de vetor de suporte, um tipo de rede neural artificial de uso recente. O objetivo deste trabalho foi o de estudar a viabilidade do uso de modelos auto-regressivos de média móvel (ARMA) de ordem baixa, em vez de auto-regressivos de ordem alta, em conjunção com a máquina de vetor de suporte, para auxílio ao diagnóstico. Os resultados indicam que a máquina de vetor de suporte tem desempenho melhor que o discriminante linear de Fisher e que os modelos ARMA(1,11) e ARMA(1,12) fornecem altas taxas de classificação (81,5%), cujos valores são próximos ao máximo obtido com modelos auto-regressivos de ordem 39. Portanto, recomenda-se o uso da máquina de vetor de suporte e de modelos ARMA (1,11) ou ARMA(1,12) para a classificação de sinais de eletromiografia de agulha, de 800ms de duração e amostrados a 25kHz.

Palavras-chave: Eletromiografia clínica. Máquina de vetor de suporte (SVM). Discriminante linear de Fisher (DLF). Auto-regressivo de média móvel (ARMA). Auto-regressivo (AR).

Abstract

The diagnosis of neuromuscular diseases is attained by the combined use of several tools. Among these tools, clinical electromyography provides key information to the diagnosis. In the literature, the application of some classifiers (linear discriminant and artificial neural networks) to a variety of electromyography parameters (number of phases, turns and zero crossings; median frequency, auto-regressive coefficients) has provided promising results. Nevertheless, the need of a large number of auto-regressive coefficients has guided this Master's thesis to the use of a smaller number of auto-regressive moving-average coefficients. The classification task (into normal, neuropathic or myopathic) was achieved by support vector machines, a type of artificial neural network recently proposed. This work's objective was to study if low-order auto-regressive moving-average (ARMA) models can or cannot be used to substitute high-order auto-regressive models, in combination with support vector machines, for diagnostic purposes. Results point that support vector machines have better performance than Fisher linear discriminants. They also show that ARMA(1,11) and ARMA(1,12) models provide high classification rates (81.5%). These values are close to the maximum obtained by using 39 auto-regressive coefficients. So, we recommend the use of support vector machines and ARMA(1,11) or ARMA(1,12) to the classification of 800ms needle electromyography signals acquired at 25kHz.

Key-words: Clinical electromyography. Support vector machine (SVM). Fisher linear discriminant (FLD). Auto-regressive moving average (ARMA). Auto-regressive (AR).

BARRETTO, Mateus Ymanaka. **Aplicação de máquinas de vetor de suporte e modelos auto-regressivos de média móvel na classificação de sinais eletromiográficos**. São Paulo. 2007. (Mestrado) Escola Politécnica da Universidade de São Paulo, São Paulo, 2007.

ERRATA

P.	LINHA	ONDE SE LÊ	LEIA-SE
2	9	mas sofre bastante	mas sofrem bastante
12	2 a 3	resultados produzidos por cada tipo de tratamento	resultados que cada tipo de tratamento produz
18	6 a 8	Já a amplitude de MUAP não apresenta uma dependência tão grande do número de fibras musculares, pois a amplitude reflete somente as	Apesar de a amplitude de um MUAP também depender do número de fibras musculares da unidade motora, ela reflete predominantemente a atividade das
20	20 a 21	observada em um padrão	de cada neurônio durante a formação do padrão
24	8	corte em 10kHz.	corte em 10kHz. A freqüência de corte do passa-altas não foi informada pelos responsáveis pela captação dos sinais do banco de dados, mas acredita-se que tenha sido escolhida uma freqüência próxima de 2Hz, que é tradicionalmente utilizada para sinais de EMG de agulha com fins diagnósticos [56].
33	19 a 20	Os vetores x_i que se encontram	No caso de padrões linearmente separáveis, os vetores x_i que se encontram
34	10	dependendo de em qual lado do hiperplano	dependendo do lado do hiperplano no qual

39	8	núcleo polinomial [8] de ordem 2.	núcleo polinomial [8] de ordem 2. A escolha da ordem foi feita com base em testes preliminares, que resultaram em taxas de acerto de classificação piores para ordens 3 e 4.
40	6	total de 1595 modelos.	total de 1595 modelos. Optou-se por fazer uma varredura por todos esses modelos pois trabalhos anteriores demonstraram que os melhores resultados de classificação não são obtidos para as ordens indicadas pelos critérios de escolha da ordem de modelos auto-regressivos, como o AIC e o BIC [57,58].
42	2	confirme descrito	conforme descrito
42	7 a 9	Além das taxas obtidas para os 54 sinais, também estão as taxas parciais somente para sinais normais, patológicos, neuropáticos e miopáticos.	Na figura 4.1.a, está a taxa de acerto calculada sobre todos os 54 sinais testados. Na figura 4.1.b está a porcentagem de sinais corretamente classificados dentre os 18 sinais normais testados. As figuras 4.1.c, 4.1.d e 4.1.e mostram, de forma análoga, os resultados em relação aos 36 sinais patológicos, aos 18 sinais neuropáticos e aos 18 sinais miopáticos, respectivamente.
62	5	Pattichis e Elia [6], utilizaram	Pattichis e Elia [6] utilizaram
64	1 a 2	esses autores utilizaram sinais de EMG de superfície, cujas características são muito diferentes dos sinais de agulha utilizados neste trabalho.	a metodologia utilizada para aquisição, captação e processamento dos sinais de EMG diferem muito de trabalho para trabalho.
64	4 a 5	conseqüentemente,	cujas patologias diferiam, provavelmete, em

		seria previsível que os resultados da classificação variassem bastante de um trabalho para outro.	diversos aspectos, desde a etiologia até o estágio de evolução. Por isso, algumas patologias seriam mais facilmente identificadas do que outras.
64	17 a 19	Entretanto, com a SVM, é possível, a partir do modelo ARMA(1,11), alcançar uma taxa de acerto de 81,5%, sensivelmente superior à taxa de 64,8% obtida com o modelo AR	Entretanto, é possível alcançar uma taxa de acerto de 81,5% com a SVM a partir do modelo ARMA(1,11). Essa taxa é sensivelmente superior à taxa de 64,8% obtida com o modelo AR.
64	23	avaliados.	avaliados. Além disso, pode-se dizer que os as taxas obtidas com a SVM são estatisticamente melhores que as obtidas com o DLF, com um nível de significância de 2,5%.
65	11	com a SVM.	com a SVM. Entretanto, os dados dessa tabela não permitem afirmar estatisticamente que a SVM seja melhor que o DLF neste caso.
67	1	patológicos ,observa-se	patológicos, observa-se
68	2	auto-regressivo ARMA(20,0).	auto-regressivo ARMA(20,0). Na separação entre sinais normais e patológicos, demonstra-se que a SVM teve um desempenho estatisticamente superior ao do DLF, com um nível de significância de 0,5%, enquanto não há diferença estatística entre a SVM e o DLF na separação entre sinais neuropáticos e

			miopáticos.
70	5	ao AR(50).	ao AR(50). Também não é possível garantir estatisticamente que a SVM seja melhor que o DLF, utilizando-se um nível de significância menor que 10%.
72	2	classificação.	classificação. A redução do número de coeficientes é importante porque, quando os cálculos a serem realizados envolvem inversões de matriz, a dimensão das matrizes (relacionada ao número de coeficientes) exerce grande influência no tempo de processamento e na magnitude dos erros computacionais. Além disso, há uma redução de 4 vezes no tempo de cálculo dos coeficientes ARMA(1,12) em comparação aos coeficientes AR(39) quando se utiliza o método de Gauss-Newton. Porém, esse tempo não seria restritivo no caso de se classificar um sinal de teste, já que, para um modelo AR(39), o tempo de cálculo dos coeficientes deverá ser menor que 30s, utilizando-se um computador com processador de 2GHz.
72	22 a 23	literatura [6,11-12,16-18].	literatura [6,11-12,16-18]. Também seria interessante que os sinais fossem classificados por análise visual de um especialista, visto que alguns dos sinais podem não apresentar características de uma dada patologia. Um sinal captado em um músculo saudável de um indivíduo que possuísse uma patologia, por exemplo, não apresentaria características dessa patologia.

			Além disso, poderia ser sugerido que, em trabalhos futuros, se fizesse uma análise levando em conta que sinais patológicos classificados como normais são um resultado mais indesejado do que sinais normais classificados como patológicos, visto que, neste último caso, mais exames poderiam ser solicitados para confirmação do diagnóstico. O conceito de especificidade (porcentagem de verdadeiros-negativos) e sensibilidade (porcentagem de verdadeiros-positivos) poderia ser aplicado durante a primeira etapa de classificação entre normais (negativos) e patológicos (positivos), mas não faria muito sentido caso se tentasse aplicá-lo à segunda etapa entre neuropáticos e miopáticos.

Referências adicionais:

[56] WEBSTER, J. G., *Medical Instrumentation*, 3.ed., New York: Wiley, 1998.

[57] SHIROTA, C., ITIKI, C., "Estudo da ordem de modelos auto-regressivos para sinais eletromiográficos normais, miopáticos e neuropáticos", *Anais do XVIII Congresso Brasileiro de Engenharia Biomédica (CBEB2002)*, 5: 352-354, São José dos Campos: Universidade do Vale do Paraíba, 2002.

[58] BARRETTO, M. Y., ITIKI, C., "Influência da análise de componentes principais na classificação de sinais eletromiográficos", *Anais do XX Congresso Brasileiro de Engenharia Biomédica (CBEB2006)*, 358-361, São Pedro: Sociedade Brasileira de Engenharia Biomédica, 2006.

Sumário

1. Introdução 1
2. Eletromiografia e doenças neuromusculares 9
2.1. Diagnóstico de doenças neuromusculares 9
2.2. Eletromiografia 11
2.2.1. Atividade de inserção 14
2.2.2. Atividade espontânea 15
2.2.3. Potenciais de ação de unidade motora 18
2.2.4. Padrão de interferência 20
3. Materiais e métodos 24
3.1. Obtenção dos sinais 24
3.2. Modelagem ARMA 25
3.2.1. Método de Gauss-Newton 26
3.3. Discriminante linear de Fisher 27
3.3.1. Discriminante linear de Fisher para duas classes 29
3.3.2. Discriminante linear de Fisher para três ou mais classes 30
3.4. Máquinas de vetor de suporte 32
3.4.1. Hiperplano ótimo de separação para padrões linearmente separáveis 33
3.4.2. Hiperplano ótimo de separação para padrões não-separáveis 35
3.4.3. Construção de SVMs para reconhecimento de padrões 36
3.5. Estratégia de classificação 40
4. Resultados 42
4.1. Primeira etapa de classificação 42
4.2. Segunda etapa de classificação 46
4.3. Resultados finais da classificação 48
4.3.1. Modelos auto-regressivos 53
4.3.2. Modelos de média móvel 55
4.3.3. Modelos auto-regressivos de média móvel próximos ao eixo das ordenadas 55
4.3.4. Modelos auto-regressivos de média móvel próximos ao eixo das abscissas 58
5. Análise 62
Referências 74

1. Introdução

As doenças neuromusculares podem ser divididas em dois grandes grupos: as miopatias e as neuropatias. Miopatias são patologias ligadas ao mau funcionamento das fibras musculares [1], células constituintes dos músculos, que são responsáveis por qualquer movimento realizado pelo corpo humano. Neuropatias são patologias relacionadas aos motoneurônios, que são neurônios responsáveis por conduzir a informação do sistema nervoso central para os músculos [1]. Os motoneurônios, portanto, também estão diretamente relacionados com o funcionamento correto dos músculos.

Pessoas atingidas por doenças neuromusculares apresentam como um dos primeiros sintomas a fraqueza muscular e a dificuldade em coordenar os movimentos de certos membros. Se nenhum tratamento eficaz é realizado, o quadro começa a evoluir, reduzindo cada vez mais a força muscular do paciente, que passa a ser incapaz de realizar ações simples como erguer um copo d'água ou abrir uma porta. Quando os músculos ligados a funções vitais como a respiração ou ingestão de alimentos são afetados, o paciente passa a depender de aparelhos para sobreviver.

Dada a gravidade dessas doenças, é importante que seu diagnóstico seja realizado o mais cedo possível. Além disso, dada a grande diversidade de doenças neuromusculares, é preciso que sua origem (muscular ou nervosa) seja descoberta, visto que o tratamento mais adequado varia segundo o tipo da patologia [2].

Atualmente, uma ferramenta muito utilizada em clínica com a finalidade de auxiliar o diagnóstico de doenças neuromusculares é o exame de eletromiografia

(EMG) [3]. O sinal de EMG é gerado a partir da atividade elétrica dos músculos [4]. Contudo, ainda que o sinal de EMG seja gerado diretamente nos músculos, as suas características permitem a identificação não só de miopatias, mas também de neuropatias [3].

Os sinais de EMG podem ser divididos em duas modalidades, dependendo do tipo de eletrodo utilizado na sua captação: de superfície e de agulha. Cada um fornece informações diferentes e complementares. Os sinais captados por meio de eletrodos de superfície representam a atividade global de um grande número de fibras musculares [5], mas sofre bastante atenuação devido às camadas de tecido entre o músculo e o eletrodo. Os sinais captados por eletrodos de agulha, por sua vez, representam com maior fidelidade a atividade de um grupo menor e mais específico de fibras musculares [3]. Em clínica, é mais comum o uso de EMG de agulha no diagnóstico de doenças neuromusculares [3-4]. Essa modalidade de sinais de EMG é usada nesta dissertação.

Dependendo da força de contração, diferentes informações sobre o sinal de EMG podem ser obtidas. Para fins de diagnóstico, é comum utilizarem-se sinais captados durante contrações fracas [6-9] e fortes [10-13]. Durante as contrações fracas, captam-se potenciais de ação de unidade motora (MUAPs, do inglês *motor unit action potentials*) isolados, sendo que uma unidade motora é definida como um motoneurônio e as fibras musculares que este inerva [4]. Para uma contração fraca, poucas unidades motoras são recrutadas. Por isso, é possível observar cada um dos potenciais correspondentes às unidades motoras próximas à extremidade do eletrodo [6]. Durante as contrações fortes, observam-se os chamados padrões de interferência, que consistem em uma série de MUAPs sobrepostos, visto que, para a realização de uma contração forte, ocorre o aumento da taxa de disparo e o

recrutamento de unidades motoras adicionais [9]. Esses eventos colaboram para a sobreposição dos diversos MUAPs, gerando padrões de interferência, que são usados nesta dissertação.

Para a análise de sinais de EMG é comum o uso de parâmetros obtidos nos domínios do tempo e da freqüência. Os parâmetros do domínio do tempo, obtidos diretamente do sinal de EMG, compreendem o valor médio retificado, a amplitude máxima, o número de reversões (ou *turns*, em inglês) e de cruzamentos de zero, entre outros [8,14-15]. Os parâmetros do domínio da freqüência, por outro lado, são obtidos a partir do espectro do sinal. Dentre esses parâmetros podem ser citados a freqüência mediana, os coeficientes de assimetria e curtose [14-15], e a própria densidade espectral de potência [7].

Além dos parâmetros dos domínios do tempo e da freqüência, um conjunto de parâmetros que vem sendo freqüentemente empregado para a classificação diagnóstica de sinais de EMG é composto dos coeficientes do modelo auto-regressivo (AR) [6,10-11,16-20].

Inbar e Noujaim [10] fizeram a classificação de sinais de EMG de superfície representados pelos coeficientes de modelos AR de ordem 20, utilizando o discriminante linear de Fisher. Em primeiro lugar, os indivíduos normais foram separados dos indivíduos patológicos (neuropáticos e miopáticos), com uma taxa de acerto de 87,5%. Em segundo lugar, fizeram a separação entre indivíduos neuropáticos e miopáticos, obtendo uma taxa de acerto de 75%.

Ike [19] utilizou coeficientes de modelos AR de ordem 30 junto a parâmetros no domínio da freqüência para classificar sinais de EMG de agulha, separando-os em normais, neuropáticos e miopáticos. A classificação feita com memórias associativas levou à taxa de acerto de 74,1%, sendo o processo realizado em duas etapas:

primeiramente foram separados os sinais normais dos patológicos e, em seguida, os sinais patológicos foram classificados entre neuropáticos e miopáticos.

Pattichis e Elia [6] realizaram a classificação em uma única etapa de sinais de EMG de agulha representados por vários parâmetros. Obtiveram taxas de acerto de até 81,2% na discriminação entre indivíduos normais, neuropáticos e miopáticos. Para isso utilizaram três arquiteturas diferentes de redes neurais: um mapa auto-organizável (*self-organizing map*), uma rede de função de base radial (*radial basis function*) e um perceptron multicamada (*multilayer perceptron*) treinado pelo algoritmo de retropropagação do erro (*error back-propagation*). No entanto, quando foram utilizados somente 12 coeficientes AR, o melhor resultado obtido foi de apenas 56,2%. Essa taxa foi obtida com o perceptron.

Abou-Chadi et al. [11] utilizaram sinais de EMG de superfície e um modelo AR de ordem 20. Também foram utilizadas três arquiteturas de redes neurais: um perceptron multicamada treinado com retropropagação do erro, um mapa auto-organizável e uma rede neural probabilística, que consiste em um classificador bayesiano colocado em uma arquitetura de rede neural [11]. A melhor taxa de acerto obtida na discriminação entre indivíduos normais e miopáticos foi 90,0%, que foi alcançada tanto pelo perceptron quanto pela rede probabilística.

Pires [18] classificou sinais de EMG de agulha representados por um modelo AR de ordem 33. O classificador utilizado foi o perceptron multicamada treinado pelo algoritmo de retropropagação e os sinais foram separados em duas etapas entre normais, neuropáticos e miopáticos. As entradas da rede foram obtidas utilizando-se o algoritmo "*branch and bound*" e análise de componentes principais. As taxas de acerto de até 85,2% mostraram que a metodologia se adequa ao problema em questão, levando a resultados coerentes com a literatura.

Finalmente, Güler e Koçer [17], utilizando sinais de EMG de agulha e de superfície, com modelos AR de ordem 50, fizeram a separação entre indivíduos normais, neuropáticos e miopáticos. Para isso, utilizaram o tradicional perceptron multicamada treinado por retropropagação do erro e uma máquina de vetor de suporte (SVM, do inglês *support vector machine*). A SVM mostrou possuir um desempenho melhor que o perceptron, produzindo uma taxa de acerto 94,4%.

Dentre todos os trabalhos observados na literatura que utilizam coeficientes AR como entradas dos classificadores, nota-se que os melhores resultados são obtidos quando se escolhem modelos AR com ordens altas [17-18]. O modelo AR é um caso particular de modelo auto-regressivo de média móvel (ARMA). Sabe-se que um modelo ARMA é capaz de representar um modelo AR de ordem infinita [21]. Esse fato, aliado às ordens altas obtidas na literatura, motiva a investigação da possibilidade do uso de modelos ARMA no lugar dos modelos AR.

Além disso, a utilização de modelos ARMA é fundamentada pela ampla gama de aplicações, por exemplo, na caracterização de *codecs* de vídeos [22] ou na modelagem de fenômenos climáticos [23]. Utilizam-se também modelos ARMA com vários sinais biológicos, como o eletroencefalograma, com a finalidade de detecção de hipoxia [24] ou determinação do estado de alerta de um indivíduo normal [25]. Os modelos ARMA também foram utilizados com o objetivo de modelar potenciais evocados somato-sensitivos [26] e visuais [27]. Também representaram sinais de EMG captados no estômago [28].

A aplicação de modelagem ARMA à grande diversidade se sinais mencionados acima, aliada à relação entre modelos AR e modelos ARMA apresentada anteriormente, motivou a utilização de modelos ARMA em vez de modelos AR neste

mestrado, buscando avaliar sua contribuição no auxílio ao diagnóstico de doenças neuromusculares a partir de sinais de EMG.

Outro aspecto importante a ser observado na classificação diagnóstica de sinais de EMG é o classificador utilizado. Dentre os trabalhos que classificam os sinais de EMG com base em seus coeficientes AR, constata-se a utilização do discriminante linear de Fisher [10-11,29], de memórias associativas [19] e de redes neurais artificiais [6-8,11-12,16-18]. Dentre as redes neurais, as máquinas de vetor de suporte (SVMs) levaram às mais elevadas taxas de acerto [17].

A SVM é uma arquitetura de redes neurais artificiais desenvolvida há menos de 15 anos [30-31] e que pode ser utilizada em tarefas de reconhecimento de padrões e regressão não linear [32].

Apesar de seu surgimento recente, essa ferramenta já vem sendo utilizada em diversas áreas de pesquisa, com resultados promissores. Utilizam-se SVMs, por exemplo, na classificação de textos com base em seu conteúdo [33-34]. Também se utilizam SVMs na classificação de imagens, por exemplo, na detecção de faces [35-36] e no reconhecimento de caracteres manuscritos [37]. Outra utilização bastante comum de SVMs é a classificação de proteínas em grupos funcionais a partir da seqüência dos aminoácidos que a compõem [38-39].

Além disso, é possível encontrar aplicações diretas de SVMs a sinais biológicos como, por exemplo, na classificação de intenção de movimento a partir de sinais de eletroencefalografia [40] e na construção de uma interface entre o cérebro e o computador [41]. Outro sinal ao qual se têm aplicado SVMs é o sinal de eletrocardiografia, por exemplo, para detecção do complexo QRS [42].

Quando utilizadas na classificação diagnóstica de sinais de EMG, as SVMs já foram aplicadas a parâmetros no domínio do tempo (duração, amplitude pico-a-pico,

área sob a curva, número de cruzamentos de zeros e reversões) [8], à densidade espectral de potência [16] e aos coeficientes AR [17], e forneceram um desempenho superior ao perceptron na separação entre sinais normais, neuropáticos e miopáticos. Sua maior vantagem em relação ao mais tradicional perceptron multicamada é o fato de que o número de neurônios ocultos é definido automaticamente. Portanto, economiza-se tempo computacional ao se utilizar uma SVM em vez de um perceptron, visto que em geral a escolha do número de neurônios na camada oculta do perceptron é um processo demorado [16-17,32].

Neste mestrado, portanto, a classificação dos sinais de EMG, representados por modelos ARMA, será feita com SVMs e os resultados poderão ser comparados com os obtidos com o discriminante linear de Fisher, uma técnica tradicionalmente adotada [10-11].

Neste primeiro capítulo foi apresentada a motivação para este trabalho, contendo uma revisão bibliográfica referente às técnicas estudadas e adotadas nesta dissertação, justificando assim sua escolha.

No segundo capítulo é feita uma revisão a respeito de doenças neuromusculares, descrevendo brevemente as várias ferramentas utilizadas para seu diagnóstico. Dentre essas ferramentas, está o exame de eletromiografia, que é detalhado por ser a ferramenta estudada nesta dissertação. São descritos os diversos usos deste exame, além de suas principais características e uso no auxílio ao diagnóstico de doenças neuromusculares.

No terceiro capítulo, é descrita a metodologia utilizada no trabalho, a partir da obtenção dos sinais de eletromiografia. Em seguida, apresenta-se a teoria a respeito de modelagem paramétrica, e o método de Gauss-Newton, utilizado para a estimatitiva dos coeficientes de um modelo auto-regressivo de média móvel. Ao final,

são descritos os dois classificadores estudados neste trabalho: o discriminante linear de Fisher e a máquina de vetor de suporte.

No quarto capítulo são apresentados os resultados parciais e globais obtidos aplicando a metodologia descrita anteriormente.

No quinto capítulo, os resultados são analisados e discutidos, comparando-se os desempenhos de ambos os classificadores. Também é analisada a influência da ordem escolhida para o modelo ARMA no resultado da classificação e a taxa de acerto para cada uma das categorias de sinal consideradas (normal, neuropático e miopático). Ao final, os resultados são comparados com a literatura e são apresentadas as conclusões do trabalho, acompanhadas de sugestões para trabalhos futuros na área.

2. Eletromiografia e doenças neuromusculares

Neste capítulo, pretendem-se apresentar alguns conceitos relativos à eletromiografia e às doenças neuromusculares. Esta revisão se faz necessária já que esta dissertação está sendo apresentada à Escola Politécnica da USP, onde muitos alunos e pesquisadores não têm familiaridade com esses tópicos.

2.1. Diagnóstico de doenças neuromusculares

As doenças neuromusculares apresentam a fraqueza muscular como um dos principais sintomas clínicos. Em alguns casos específicos, também são perceptíveis a miotonia (incapacidade do músculo de relaxar), a câibra, a dor e a fasciculação [1,43]. Porém, para um diagnóstico mais preciso, incluindo sua origem (neurogênica ou miogênica), são necessários diversos exames, que vão desde a anamnese (entrevista com o paciente) até exames laboratoriais como atividade enzimática no plasma sangüíneo ou biópsia do tecido muscular [1]. Alguns desses exames serão descritos nos parágrafos a seguir.

Durante a anamnese, busca-se obter informações a respeito de sintomas. Além da localização e da intensidade do sintoma, que evidenciam os eventuais grupos musculares envolvidos, é importante saber a quanto tempo o sintoma está presente, se ele é constante ou intermitente e se está progredindo ou regredindo. As informações obtidas durante a anamnese fornecem os elementos básicos para que o clínico indique exames mais detalhados [47].

Além da anamnese, outra forma simples e eficaz de se obterem dados sobre a doença é um exame físico, que compreende inspeção, palpação, exame de reflexos e avaliação de força muscular. Durante a inspeção, procura-se observar, por exemplo, perda de massa muscular, presença de movimentos espontâneos, ou alterações na posição de repouso. A palpação permite avaliar a textura do músculo. Os reflexos de tendão podem ser ausentes, reduzidos, normais, ou hiperativos, dependendo da etiologia. A avaliação da força muscular pode ser feita por meio de ações simples como levantar-se do chão ou de uma cadeira, subir em um degrau, ou andar sobre os calcanhares [47].

Às vezes, recorre-se a uma biópsia para auxiliar no diagnóstico de miopatias. A biópsia pode ser dividida em três partes. A primeira consiste na retirada da amostra de tecido muscular, que deve ser obtida de um músculo afetado, mas não destruído pela doença. A segunda parte é o tratamento do tecido, com técnicas de coloração, por exemplo. Finalmente, faz-se a interpretação da histologia [46].

Exames laboratoriais podem identificar, por exemplo, mioglobinúria, que é a presença de mioglobina em níveis elevados no plasma sangüíneo e, conseqüentemente, na urina. A mioglobina, que possui a função de armazenar oxigênio e liberá-lo quando sua concentração está baixa, é encontrada, normalmente, dentro das fibras musculares. Quando essas fibras são danificadas, há liberação de mioglobina para o plasma sangüíneo, resultando em mioglobinúria [47].

Danos causados em fibras musculares também costumam provocar elevação da concentração sangüínea de enzimas que, em situações normais, só seriam encontradas em altas concentrações dentro das fibras musculares. Tipicamente a

enzima mais analisada com esse fim é a creatina quinase [47], responsável pela fosforilação da creatina e importante para o metabolismo da energia no músculo [1].

Dois outros tipos de exames freqüentemente utilizados no auxílio ao diagnóstico de doenças neuromusculares são o estudo de velocidade de condução de nervo e o exame de eletromiografia (EMG).

O estudo de velocidade de condução baseia-se na gravação de respostas evocadas em músculos ou nervos a partir da estimulação de nervos. Além de possibilitar a distinção entre vários tipos de patologia, esse estudo permite avaliar a gravidade e evolução da doença com o passar do tempo. [44].

O exame de EMG, que é um dos temas deste trabalho, será detalhado na seção a seguir.

2.2. Eletromiografia

Eletromiografia (EMG) é um método de registro e estudo da atividade elétrica muscular [43-44]. Sua importância é evidenciada em diversas aplicações clínicas [43], principalmente no diagnóstico de doenças neuromusculares e na localização de lesões em nervos.

Também se utilizam sinais de EMG, no estudo da marcha humana. Nesse caso, é possível observar quais músculos estão sendo ativados em cada momento, assim como a duração e força da contração. O estudo da marcha humana é importante quando se estão avaliando pessoas que apresentam alterações no caminhar. Dentre as causas dessas alterações, podem ser citadas lesões na medula, derrame, trauma cerebral, distrofia muscular, artrite e muitas outras. Para que se escolha a forma de tratamento mais adequada é importante que se

conheçam os grupos musculares que estão afetando a marcha. Além disso, é possível obter uma avaliação quantitativa dos resultados produzidos por cada tipo de tratamento, por meio da análise de sinais de EMG captados periodicamente [48].

Outra aplicação encontrada para sinais de EMG é o controle de próteses artificiais. Essas próteses possuem eletrodos no encaixe com a parte residual do membro amputado. Esses eletrodos captam os sinais de EMG que serão responsáveis pelo controle dos movimentos da prótese. O tipo de movimento a ser feito pelo equipamento pode ser definido ou pela origem, ou pela amplitude do sinal captado [49].

Sinais de EMG também são aplicados no estudo da fadiga muscular [4]. A identificação de ocorrência de fadiga muscular é importante, por exemplo, quando se está realizando estimulação neuromuscular funcional. Neste caso, os músculos são ativados por estímulos elétricos externos, em situações de paralisia parcial ou total de algum membro [49].

A princípio, os sinais de EMG podem ser captados por eletrodos de superfície ou de agulha. Os sinais captados por meio de eletrodos de superfície representam a atividade global de um grande número de fibras musculares [5], mas sofre bastante atenuação devido às camadas de tecido entre o músculo e o eletrodo. Os sinais captados por eletrodos de agulha, por sua vez, representam com maior fidelidade a atividade de um grupo menor e mais específico de fibras musculares [3]. Nas aplicações envolvendo a marcha humana, o controle de próteses e a fadiga muscular, são utilizados eletrodos de superfície, que são não-invasivos e que não apresentam risco de infecção. No entanto, em eletromiografia clínica, são utilizados eletrodos de agulha, que auxiliam o diagnóstico de doenças neuromusculares [3-4].

Dentre os diversos tipos de eletrodos de agulha, podem ser citados: concêntricos unipolar e bipolar, monopolar, eletrodo de fibra única, macroeletrodo, multieletrodo de fibra única e multieletrodo [43]. Em clínica, os eletrodos mais comumente utilizados são os concêntricos, ilustrados na figura 2.1 e descritos a seguir.

Os eletrodos concêntricos unipolares são agulhas com alguns décimos de milímetros de espessura contendo, em seu interior, um fio isolado, com sua ponta exposta na extremidade do eletrodo. A tensão medida consiste na diferença de potencial entre o fio interno e o revestimento metálico do eletrodo. Em geral, o paciente é aterrado por um eletrodo de superfície [44]. Os eletrodos concêntricos bipolares são semelhantes aos unipolares, exceto pelo fato de possuírem, em seu interior, dois fios paralelos isolados entre si. A diferença de potencial medida entre os dois fios internos é registrada e o revestimento externo da agulha é aterrado [43].

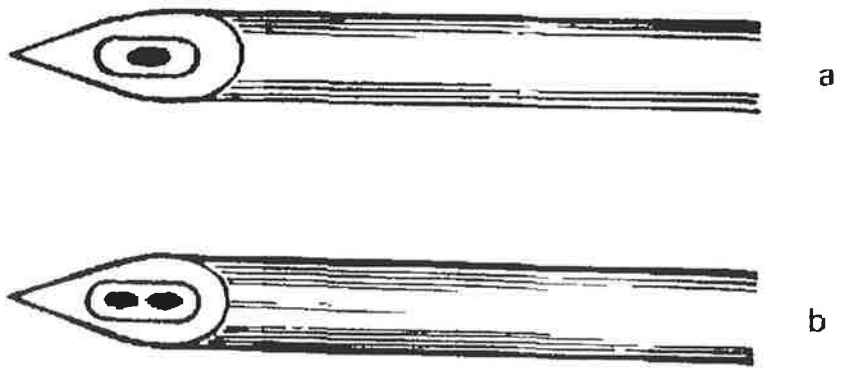

Figura 2.1 – Eletrodos concêntricos (a) unipolar e (b) bipolar. (adaptado de [43], p. 16)

Em eletromiografia clínica, os sinais captados pelos eletrodos são amplificados de 100 a 1000 vezes e filtrados de 2Hz a 10kHz [43]. Muitas vezes, os sinais resultantes apresentam alterações nas doenças neuromusculares. Essas alterações serão discutidas nas seções seguintes.

Para melhor entendimento das diferenças típicas entre os sinais de EMG nas doenças neuromusculares, é preciso compreender o que é uma "unidade motora". A unidade motora é a unidade funcional do sistema motor e é formada por um motoneurônio e pelas fibras musculares por ele inervadas. As fibras musculares pertencentes a diferentes unidades motoras intercalam-se em um mesmo músculo, sendo que um eletrodo geralmente capta a atividade de mais de uma unidade motora ao mesmo tempo [1].

Um exame de EMG pode ser dividido em quatro etapas de observação da atividade mioelétrica: inserção, repouso, contração fraca e contração forte. A seguir, serão descritos os sinais que são mais comumente observados em cada etapa do exame de de eletromiografia clínica. Supõe-se a utilização de eletrodos de agulha.

2.2.1. Atividade de inserção

Quando o eletrodo é inserido em um músculo ou é movimentado em seu interior, são captados potenciais gerados pelo movimento do eletrodo, que causa despolarização das fibras musculares em sua proximidade [3]. Em indivíduos normais, esses potenciais duram, no máximo, 300ms após o movimento do eletrodo ter cessado [45].

A figura 2.2 mostra um exemplo de sinal captado durante a inserção do eletrodo em um indivíduo normal. Neste caso, nota-se que os potenciais cessam algumas dezenas de milissegundos após o movimento do eletrodo.

Figura 2.2 – Atividade de inserção captada em um indivíduo normal. As setas indicam os momentos em que o eletrodo é movimentado. (adaptado de [3], p. 183)

2.2.2. Atividade espontânea

Depois de cessada a atividade de inserção, enquanto o músculo é mantido em repouso, podem ser captadas diversas formas de potenciais, que podem ser divididas em três grupos: potenciais normais; potenciais anormais de fibras musculares e potenciais anormais de unidades motoras [3].

O primeiro grupo compreende essencialmente ruído de placa terminal e espículas de placa terminal. Esses dois potenciais, mostrados na figura 2.3, são observados em músculos normais, quando o eletrodo é posicionado na região em que o axônio do motoneurônio inerva a fibra muscular [3,45]. Essa região também é chamada de placa terminal.

Dentre os potenciais anormais de fibras musculares, podem ser citados fibrilações, ondas positivas, descargas repetitivas complexas e descargas miotônicas [3,43-44]. Exemplos desses potenciais estão apresentados na figura 2.4.

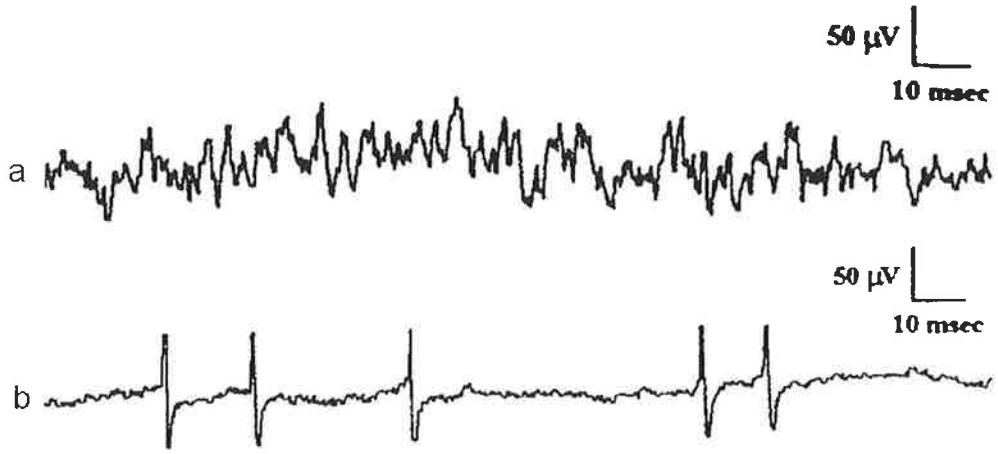

Figura 2.3 – Potenciais normais captados durante atividade espontânea: (a) ruído de placa terminal e (b) espículas de placa terminal. (adaptado de [3], p. 183)

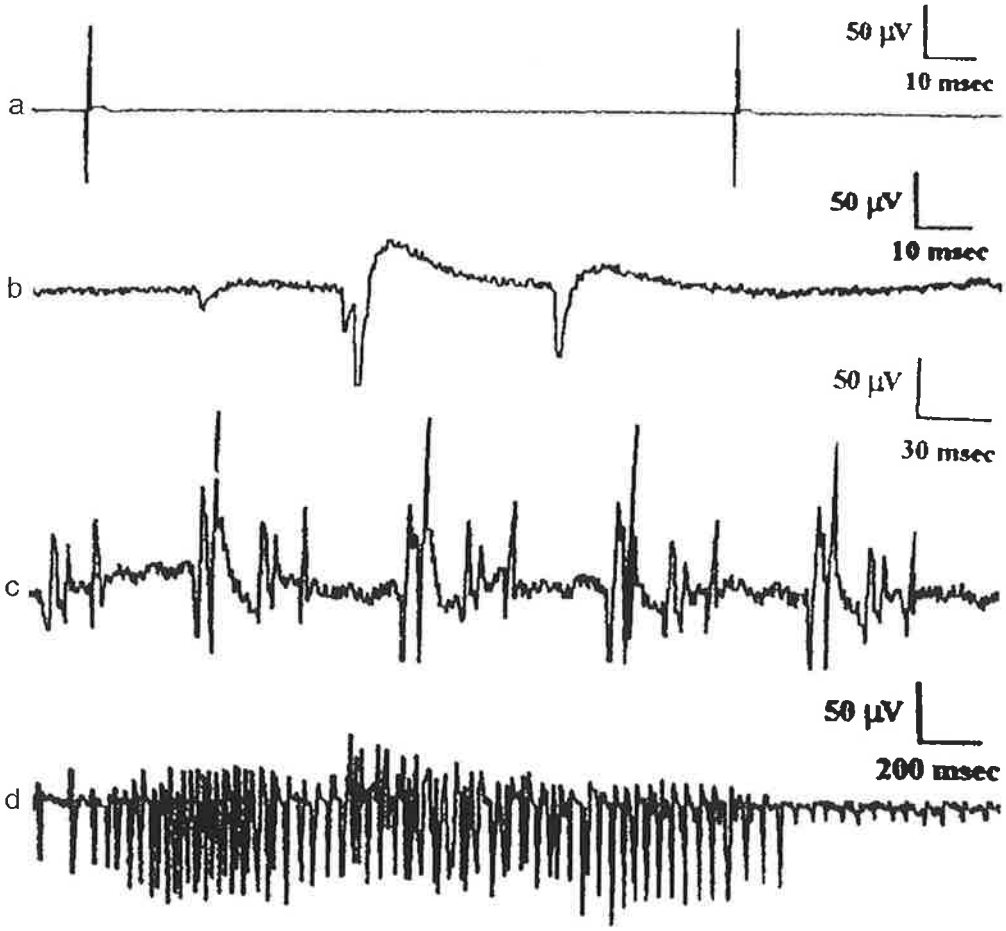

Figura 2.4 – Potenciais anormais de fibras musculares durante atividade espontânea: (a) fibrilações, (b) ondas positivas, (c) descargas repetitivas complexas e (d) descargas miotônicas. (adaptado de [3], p. 184, 186, 187)

Além dos potenciais anormais de fibras musculares, existem os potenciais anormais de unidade motora, que compreendem essencialmente as fasciculações, as descargas mioquímicas e as descargas neuromiotônicas [3], que estão apresentadas na figura 2.5. Como esses padrões estão associados a disparos não só de uma única fibra muscular, mas de um conjunto de fibras pertencente a uma unidade motora, em geral é possível que se observe a olho nu alguma forma de contração muscular nesses casos, embora muitas vezes a contração não seja suficiente para causar movimento do membro.

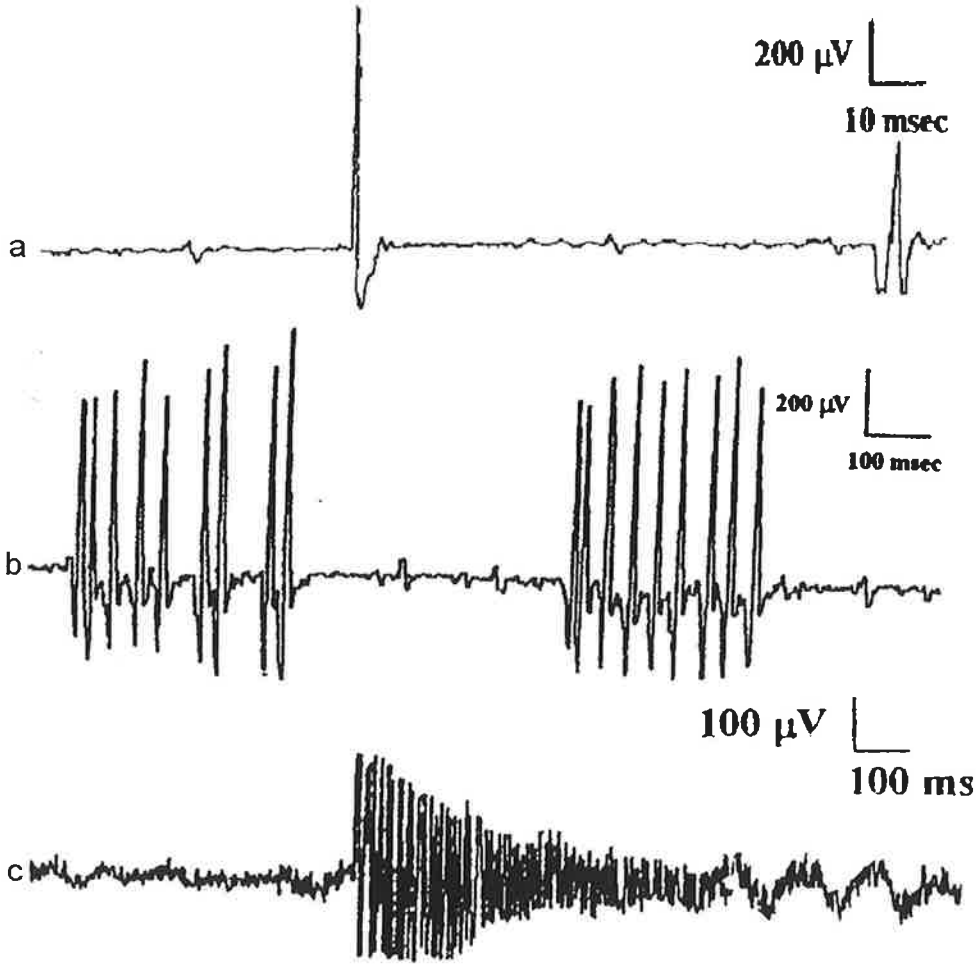

Figura 2.5 – Potenciais anormais de fibras de unidade motora durante atividade espontânea: (a) fasciculações, (b) descargas mioquímicas e (c) descarga neuromiotônica. (adaptado de [3], p. 187-189)

2.2.3. Potenciais de ação de unidade motora

Quando uma contração fraca é realizada, observam-se potenciais de ação de unidade motora (MUAPs, do inglês *motor unit action potential*) isolados no sinal de EMG. A duração, a amplitude e o número de fases de um MUAP dependem do músculo e da idade do paciente sendo examinado [3].

A duração de um MUAP, de um modo geral, aumenta com o número de fibras musculares presentes na unidade motora e também com a idade do indivíduo [3]. Já a amplitude de MUAP não apresenta uma dependência tão grande do número de fibras musculares, pois a amplitude reflete somente as fibras mais próximas ao eletrodo. Os fatores que mais influenciam a amplitude do MUAP captado são a proximidade entre a unidade motora e o eletrodo, o sincronismo entre os disparos das diversas fibras musculares da unidade motora e o número e o diâmetro das fibras musculares [3].

O número de fases de um MUAP depende do sincronismo entre as fibras musculares da unidade motora. Apesar de usualmente apresentarem duas ou três fases, é comum que 5 a 10% dos MUAPs de qualquer músculo sejam polifásicos [3].

Os MUAPs permitem observar algumas das diferenças entre casos típicos de neuropatias e miopatias. Na figura 2.6, estão representadas, de forma esquemática, um par de unidades motoras de um indivíduo normal, de um indivíduo neuropático e de um indivíduo miopático e, na figura 2.7, estão exemplos de sinais captados nesses três indivíduos.

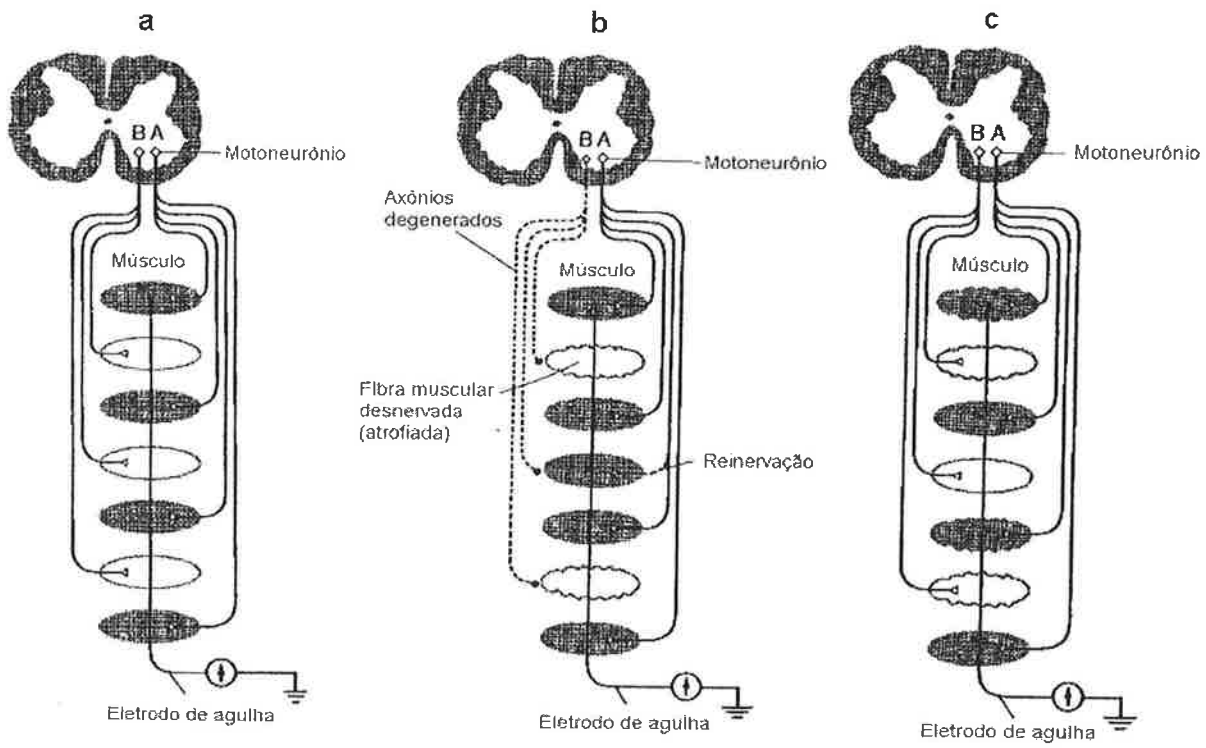

Figura 2.6 – Representação esquemática de um par de unidades motoras de um típico indivíduo (a) normal, (b) neuropático e (c) miopático. (adaptado de [1], p. 246-247)

Figura 2.7 – Sinais de EMG captados durante contração fraca, para um indivíduo (a) normal, (b) neuropático e (c) miopático. (adaptado de [1], p. 246-247)

Em um indivíduo normal, observam-se MUAPs isolados, sendo que cada MUAP é a soma dos potenciais gerados por cada uma das fibras próximas ao eletrodo.

Em um indivíduo neuropático, alguns dos motoneurônios são afetados e se degeneram. Inicialmente, as fibras musculares inervadas por esses motoneurônios são desnervadas. Em seguida, algumas dessas fibras são reinervadas por outro motoneurônio saudável, e as demais se atrofiam. Um sinal captado nessas condições, a uma condição fraca, apresenta MUAPs de amplitudes consideravelmente maiores que aquelas dos MUAPs de indivíduos normais, devido às unidades motoras acrescidas de fibras musculares reinervadas [1].

Em um indivíduo miopático, o número de fibras musculares por unidade motora é menor pois algumas dessas fibras são afetadas pela patologia. Como existem menos fibras por unidade motora, os potenciais registrados possuem amplitudes e durações reduzidas em relação aos sinais de indivíduos normais. Os potenciais muitas vezes assumem formas polifásicas, devido à falta de sincronismo [1].

2.2.4. Padrão de interferência

Quando se aumenta a força de contração, o número de fibras musculares recrutadas aumenta, assim como a taxa de disparo de cada fibra. Desse modo, quando se realizam contrações fortes, observam-se MUAPs sobrepostos no sinal de EMG. Essa sobreposição de MUAPs forma o chamado padrão de interferência [43]. Na maioria dos músculos, a freqüência de disparos observada em um padrão de interferência está em torno de 30 a 50Hz [3]. Em casos patológicos o padrão de

interferência pode sofrer alterações tanto na amplitude como na freqüência de disparo.

Na figura 2.8, estão exemplos de padrões de interferência captados em casos típicos de indivíduos normais, neuropáticos e miopáticos.

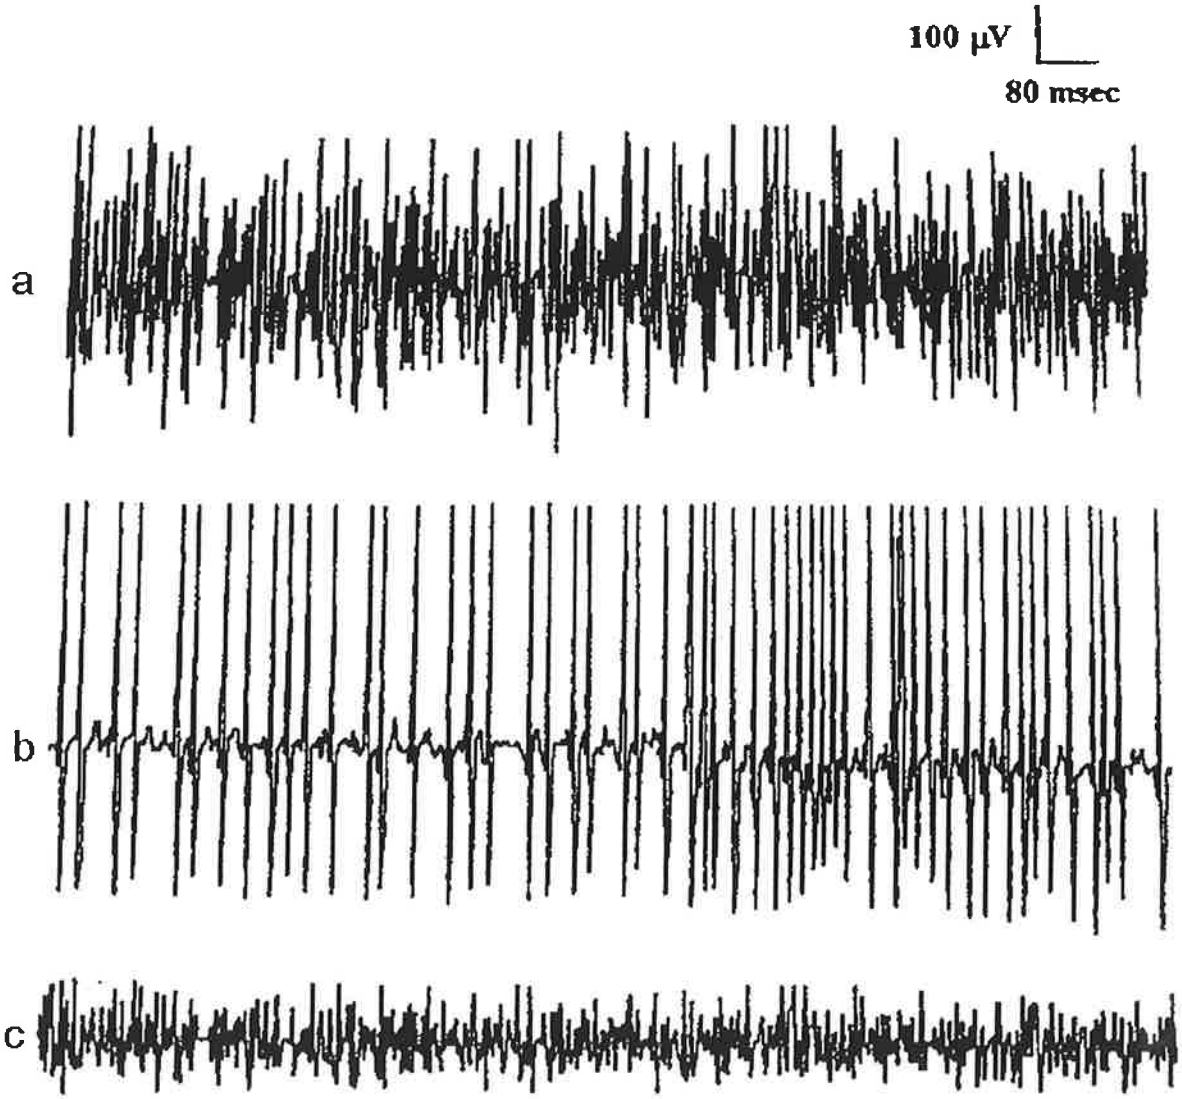

Figura 2.8 - Sinais de EMG captados durante contração forte, para um indivíduo (a) normal, (b) neuropático e (c) miopático. (adaptado de [3], p. 199)

.Observa-se que, em indivíduos normais, o padrão de interferência resultante de uma contração forte torna impossível a distinção de MUAPs isolados.

Em indivíduos neuropáticos, forma-se um sinal mais rarefeito, de modo que é possível a identificação de MUAPs isolados. Isso se deve ao fato de o número de unidades motoras em atividade ser menor do que em um indivíduo normal. Notam-se também potenciais de amplitudes maiores que em um indivíduo normal devido às fibras musculares que são reinervadas pelos motoneurônios não afetados pela patologia [3].

Em indivíduos miopáticos, forma-se um padrão de interferência completo pois o número de unidades motoras se mantém o mesmo, a princípio. Entretanto, o menor número de fibras musculares por unidade motora resulta em amplitudes reduzidas [3].

Nesta seção, foram mostrados casos típicos de neuropatias e miopatias, de fácil identificação. No entanto, como há uma diversidade muito grande de doenças neuromusculares, o diagnóstico preciso se torna uma tarefa muito complexa.

As neuropatias, por exemplo, podem ser divididas em grupos de acordo com a etiologia (causa da patologia), sendo que cada grupo apresenta características típicas. Podem ser citados, dentre esses grupos, as neuropatias nutricionais, causadas por deficiência, em geral, de algum tipo de vitamina B; neuropatias pós-infecciosas ou autoimunes; neuropatias de compressão, causadas quando fibras nervosas são feridas ou o suprimento de sangue ao nervo é obstruído; neuropatias tóxicas, geralmente causadas por chumbo ou arsênico, que impedem a ação de algumas enzimas; neuropatias metabólicas e genéticas, entre outras [46].

As miopatias também podem ser divididas em vários grupos, como miopatias enzimáticas, metabólicas, inflamatórias, induzidas por drogas, entre outras [46].

Essa grande variedade de doenças torna difícil a distinção entre elas e, para a escolha do melhor tratamento, é importante a análise de vários exames complementares.

Neste mestrado, o objetivo é mais modesto. Pretende-se auxiliar o diagnóstico de doenças neuromusculares, separando os sinais de EMG de contrações fortes entre três classes: normais, neuropáticos e miopáticos.

3. Materiais e métodos

Neste capítulo serão apresentadas as descrições dos sinais do banco de dados, dos métodos de estimação dos coeficientes ARMA e dos classificadores (discriminante linear e redes neurais artificiais)

3.1. Obtenção dos sinais

Os sinais de eletromiografia (EMG) utilizados neste trabalho foram obtidos de um banco de dados cedido pelo Professor Donald B. Sanders, do Centro Médico da Universidade de Duke, Estados Unidos. Esses sinais haviam sido captados de indivíduos normais, neuropáticos e miopáticos por meio de eletrodos de agulha e filtrados por um passa-baixas, com freqüência de corte em 10kHz.

No Laboratório de Engenharia Biomédica da Escola Politécnica da Universidade de São Paulo (LEB-EPUSP), em um trabalho anterior de mestrado [19], os sinais haviam sido digitalizados por um conversor A/D de 12 bits, adquiridos à taxa de 25.000 amostras por segundo e salvos em arquivos. Em seguida, havia sido feita uma análise visual para selecionar trechos correspondentes a 50% da máxima contração voluntária. A máxima contração voluntária (MCV) está associada à máxima força que o músculo consegue exercer.

Para cada trecho havia sido selecionado um único intervalo de 800ms de duração. A estacionariedade de cada sinal havia sido confirmada pelo teste de seqüências ("run test") de Wald-Wolfowitz, utilizando-se segmentos de 40ms e nível de significância de 5% [50]. Os sinais selecionados haviam totalizado 171, dentre os

quais, 72 sinais eram provenientes de 6 indivíduos normais, 43 sinais, de 5 indivíduos neuropáticos e 56 sinais, de 6 indivíduos miopáticos.

3.2. Modelagem ARMA

A modelagem paramétrica é uma forma de se representar sinais por meio de um número reduzido de parâmetros que, entretanto, conservam grande parte da informação do sinal original [21].

O modelo auto-regressivo de média móvel (ARMA, do inglês *autoregressive moving average*) é um modelo paramétrico construído admitindo-se que o sinal $x(n)$ a ser modelado é a saída de um sistema causal linear invariante no tempo cuja entrada é o ruído branco $e(n)$ de média nula e variância σ^2 [21]. Os números de coeficientes considerados no sistema fornecem a ordem do modelo. Dessa forma, o modelo de ordem (p,q) é denotado ARMA(p,q) e pode ser descrito pela equação de diferenças [21]

$$x(n) = -\sum_{k=1}^{p} a_k x(n-k) + \sum_{m=1}^{q} b_m e(n-m) + e(n), \qquad (1)$$

que deixa clara a dependência entre a saída atual $x(n)$, as p saídas anteriores $x(n-k)$, a entrada atual $e(n)$ e as q entradas anteriores $e(n-m)$. Os coeficientes a_k, que determinam a relação entre a saída atual e as anteriores, são denominados coeficientes auto-regressivos, enquanto os coeficientes b_m, que estabelecem uma relação entre a entrada e a saída do sistema, constituem os coeficientes de média móvel do modelo ARMA de ordem (p,q). Nesta dissertação, o sinal de saída $x(n)$ é o sinal de EMG a ser classificado.

3.2.1. Método de Gauss-Newton

Neste trabalho, os modelos ARMA para cada um dos 171 trechos de sinal de EMG foram calculados utilizando-se a rotina *armax.m* do Matlab®. Essa rotina se baseia no método de Gauss-Newton [51].

Esse método busca minimizar o erro médio quadrático

$$S[\Theta] = \sum_{n=1}^{N} \left[f[n,\Theta] - x[n] \right]^2 , \tag{2}$$

em que $f(n,\Theta)$ é o estimador de $x(n)$ e Θ é o vetor de coeficientes, descrito por

$$\Theta = \begin{bmatrix} \theta_1 & \theta_2 & \cdots & \theta_{p+q} \end{bmatrix}^T = \begin{bmatrix} a_1 & a_2 & \cdots & a_p & b_1 & b_2 & \cdots & b_q \end{bmatrix}^T . \tag{3}$$

A atualização iterativa do vetor de estimativas $\hat{\Theta}$ é feita segundo a expressão [51]

$$\hat{\Theta}^{(i+1)} = \hat{\Theta}^{(i)} - \mu^{(i)} \cdot \left[R^{(i)} \right]^{-1} \cdot \frac{\partial S(\hat{\Theta}^{(i)})}{\partial \hat{\Theta}} , \tag{4}$$

em que i é o número da iteração, $\mu^{(i)}$ é o tamanho do passo que controla a velocidade de convergência do algoritmo, $\frac{\partial S(\hat{\Theta}^{(i)})}{\partial \hat{\Theta}}$ é o gradiente de S e $R^{(i)}$ representa uma matriz de ponderação.

Em geral, escolhe-se o escalar $\mu^{(i)}$ como sendo igual a 1.

O gradiente de S é dado pelas derivadas parciais de primeira ordem

$$\frac{\partial S(\Theta)}{\partial \Theta} = \begin{bmatrix} \frac{\partial S(\Theta)}{\partial \theta_1} & \frac{\partial S(\Theta)}{\partial \theta_2} & \cdots & \frac{\partial S(\Theta)}{\partial \theta_{p+q}} \end{bmatrix}^T , \tag{5}$$

em que cada uma dessas derivadas pode ser calculada como

$$\frac{\partial S(\Theta)}{\partial \theta_i} = 2 \sum_{n=1}^{N} \left(f(n,\Theta) - x(n) \right) \cdot \frac{\partial f(n,\Theta)}{\partial \theta_i} , \tag{6}$$

a partir da equação 2.

Para realizar o papel de matriz de ponderação $R^{(i)}$, diversas matrizes podem ser escolhidas, sendo que a escolha mais simples é a matriz identidade. Uma outra escolha freqüente é a matriz hessiana de $S(\Theta)$, que é a matriz das derivadas de segunda ordem de $S(\Theta)$ em relação a cada par de coeficientes

$$\frac{\partial^2 S(\Theta)}{\partial \Theta^2} = \begin{bmatrix} \frac{\partial^2 S(\Theta)}{\partial \theta_1^2} & \frac{\partial^2 S(\Theta)}{\partial \theta_1 \partial \theta_2} & \cdots & \frac{\partial^2 S(\Theta)}{\partial \theta_1 \partial \theta_{p+q}} \\ \frac{\partial^2 S(\Theta)}{\partial \theta_2 \partial \theta_1} & \frac{\partial^2 S(\Theta)}{\partial \theta_2^2} & \cdots & \frac{\partial^2 S(\Theta)}{\partial \theta_2 \partial \theta_{p+q}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 S(\Theta)}{\partial \theta_{p+q} \partial \theta_1} & \frac{\partial^2 S(\Theta)}{\partial \theta_{p+q} \partial \theta_2} & \cdots & \frac{\partial^2 S(\Theta)}{\partial \theta_{p+q} \partial \theta_{p+q}} \end{bmatrix}. \tag{7}$$

Quando se escolhe a matriz hessiana, o método é denominado Newton-Raphson [52]. As derivadas de segunda ordem de $S(\Theta)$ podem ser calculadas derivando-se a equação 6. Obtém-se, então

$$\frac{\partial^2 S(\Theta)}{\partial \theta_j \partial \theta_k} = 2\sum_{n=1}^{N} \left\{ \frac{\partial f(n,\Theta)}{\partial \theta_j} \cdot \frac{\partial f(n,\Theta)}{\partial \theta_k} + \left(f(n,\Theta) - x(n) \right) \cdot \frac{\partial^2 f(n,\Theta)}{\partial \theta_j \partial \theta_k} \right\}. \tag{8}$$

Quando as derivadas de segunda ordem de $f(n,\Theta)$ são desprezadas no cálculo da matriz hessiana, o método é denominado método de Gauss-Newton [51].

3.3. Discriminante linear de Fisher

Muitas vezes, desejam-se separar sinais pertencentes a duas ou mais classes. Os sinais são representados por vetores de *m* parâmetros.

Neste trabalho, por exemplo, os sinais de EMG de agulha devem ser separados em três classes: normais, neuropáticos e miopáticos. Cada sinal, captado de um dos pacientes, é representado por um vetor que contém os coeficientes do

modelo ARMA. Esses coeficientes são estimados pelo método de Gauss-Newton, descrito anteriormente.

Dado que a dimensão *m* dos vetores de coeficientes é, em geral, maior que 3, o problema de classificação começa a se tornar complexo, pois esses vetores não podem ser simplesmente representados em um espaço tridimensional e agrupados pela sua proximidade. Além disso, muitas vezes, a relação entre os vetores de uma mesma classe não é trivial, sendo que é difícil se estabelecer um limiar entre duas classes, pela simples análise visual dos vetores.

O Discriminante Linear de Fisher (DLF) [53-54] é um método que foi criado para tentar solucionar esse problema de classificação, para vetores de dimensão *m*. O DLF projeta todos os vetores sobre uma reta, em uma "direção ótima". Dessa forma, cada um dos vetores de dimensão *m* é transformado em um vetor de dimensão menor, ou em um escalar. A direção ótima é aquela que faz com que vetores de uma mesma classe sejam projetados o mais próximo possível um do outro enquanto que vetores de classes diferentes sejam projetados o mais distante possível um do outro. No caso de haver várias classes para se fazer a separação, pode ser necessário escolher mais de uma direção ótima.

Estando os vetores projetados nessas direções ótimas, o problema de classificação se resume a determinar em qual classe o vetor foi projetado.

A classe pode ser escolhida a partir de uma comparação com um valor de limiar, ou então, a partir das distâncias à projeção dos centros das classes.

A seguir, será detalhado o procedimento para aplicação do DLF, mostrando-se, primeiramente, o caso da separação entre duas classes, representadas por 1 e 2, por causa de sua maior simplicidade. Em seguida, será feita uma generalização para três ou mais classes. O primeiro passo é encontrar a direção ótima para se projetar

os vetores. Esse passo é chamado de *treinamento*. Para isso, são considerados n_1 vetores, x_{11}, x_{12}, ..., x_{1n_1}, pertencentes à classe 1, e n_2 vetores, x_{21}, x_{22}, ..., x_{2n_2} da classe 2. Esses vetores, chamados vetores de treinamento, como se pode perceber, já possuem sua classe conhecida previamente, e são usados para treinar, ou seja, calibrar o discriminante. Quanto mais vetores forem utilizados no processo de treinamento, melhor deverá ser o resultado final da classificação, visto que cada classe é, assim, melhor caracterizada [53].

3.3.1. Discriminante linear de Fisher para duas classes

O processo é iniciado estimando-se, a partir dos vetores acima selecionados, o vetor médio u_k da classe k, pela equação [54]

$$u_k = \frac{1}{n_k} \sum_{i=1}^{n_k} x_{ki} \ , \tag{9}$$

em que x_{ki} são os vetores da classe k e n_k é o número de vetores da classe k. A matriz de covariância da classe k é dada por [54]

$$S_k = \frac{1}{n_k - 1} \sum_{i=1}^{n_k} (x_{ki} - u_k)(x_{ki} - u_k)^T \ . \tag{10}$$

Em seguida, calcula-se o vetor v que dá a direção ótima [54]

$$v = \left(\frac{(n_1 - 1)S_1 + (n_2 - 1)S_2}{n_1 + n_2 - 2} \right)^{-1} \cdot (u_1 - u_2) \, . \tag{11}$$

A partir do vetor v, calcula-se o limiar que separa as duas classes e que é fornecido pela fórmula [54]

$$y_L = \frac{2}{n_1 + n_2} \cdot \frac{n_1 \sqrt{v^T S_1 v} \ \ v^T u_2 + n_2 \sqrt{v^T S_2 v} \ \ v^T u_1}{\sqrt{v^T S_1 v} + \sqrt{v^T S_2 v}} \, . \tag{12}$$

O limiar pode ser visto como uma média ponderada das projeções dos vetores médios de treinamento u_1 e u_2.

Estabelecido o limiar, a etapa de treinamento está concluída e passa-se, então, para a etapa de classificação. Nessa segunda etapa, vetores de origem desconhecida são projetados sobre a direção ótima e comparados com o limiar para se descobrir a que classe pertencem. Para isso, toma-se um vetor x que se deseja classificar, e, a partir dele, é calculado o escalar y, pelo produto [54]

$$y = v^T x \,. \tag{13}$$

Atribui-se o vetor x à classe 1 caso o valor de y obtido seja maior que y_L, e à classe 2, caso contrário.

O processo descrito acima permite, então, a classificação de vetores entre duas dadas classes. Na subseção a seguir, será feita a generalização do processo para c classes: 1, 2, ..., c.

3.3.2. Discriminante linear de Fisher para três ou mais classes

Para cada classe, são estimados os vetores médios, pela equação 9, além de ser calculada a média u de todos os vetores de treinamento de forma análoga [54]

$$u = \frac{\sum_{k=1}^{c} \sum_{i=1}^{n_k} x_{ki}}{\sum_{k=1}^{c} n_k} \,. \tag{14}$$

Em seguida, são calculadas duas matrizes de somas de quadrados e produtos (SQP), cujas fórmulas estão explicitadas abaixo: [54]

$$W = \sum_{k=1}^{3} \sum_{i=1}^{n_k} (x_{ki} - u_k)(x_{ki} - u_k)^T \tag{15}$$

e

$$B = \sum_{k=1}^{3} n_k (u_k - u)(u_k - u)^T . \tag{16}$$

Pode-se demonstrar que, neste caso, o autovetor relativo ao maior autovalor da matriz $W^{-1}B$ é a direção ótima. Em geral, é interessante obter mais de uma direção, para melhorar a precisão da classificação. Nesse caso, tomam-se θ autovetores, e_1, e_2, ..., e_θ relativos aos θ maiores autovalores da referida matriz. Observe que sempre se deve ter $\theta<c$.

Pelo fato de haver várias direções ótimas, calcula-se um vetor y_k para cada classe k, por meio da expressão [54]

$$y_k = [e_1^T u_k \quad \cdots \quad e_r^T u_k]^T , \tag{17}$$

que é análoga à utilizada no caso de duas classes. Para o vetor x a ser classificado, calcula-se [54]

$$y = [e_1^T x \quad \cdots \quad e_r^T x]^T . \tag{18}$$

Em seguida, calcula-se a distância euclidiana entre os vetores de classe y_k e o vetor y, dada por [54]

$$d(y_k, y) = \sqrt{(y_k - y)^T (y_k - y)} , \tag{19}$$

para cada uma das classes, ou seja, k=1, 2, ..., c. Conclui-se que x pertence à classe k, para a qual se obtém a menor distância euclidiana entre y_k e y.

3.4. Máquinas de vetor de suporte

As máquinas de vetor de suporte (SVMs) são redes neurais artificiais que possuem seus neurônios organizados em camadas, e a informação sempre trafega em um único sentido [32].

As redes neurais artificiais são ferramentas matemáticas compostas por unidades simples de processamento (neurônios) fortemente interconectadas e que operam em paralelo. Essas redes têm a capacidade de armazenar conhecimento adquirido experimentalmente e utilizá-lo quando necessário [32].

Existem diversas arquiteturas de redes, que diferem entre si na função de transferência dos neurônios, no modo como são feitas as interconexões e em várias outras características. Alguns exemplos que podem ser citados são o perceptron multicamada, as redes com função de base radial, os mapas auto-organizáveis e as SVMs [32].

Neste mestrado, foram utilizadas SVMs com a finalidade de classificar padrões, de forma análoga ao DLF. Devido à sua estrutura mais complexa, as redes neurais artificiais de um modo geral são capazes de lidar com problemas que envolvem não linearidades, diferentemente do discriminante descrito anteriormente [32]. Essa característica leva a melhores desempenhos que o DLF na classificação diagnóstica de doenças neuromusculares [11,18].

Nesta seção, a teoria sobre SVM está dividida em três partes, para facilitar sua exposição. Primeiramente, é apresentado o conceito de hiperplano ótimo de separação entre classes, de base para a construção de uma SVM, no contexto de padrões linearmente separáveis. Em seguida, o conceito é generalizado para o caso

de padrões não-separáveis. Finalmente, é descrita a construção de SVMs para a tarefa de reconhecimento de padrões, que deverá ser realizada neste mestrado.

3.4.1. Hiperplano ótimo de separação para padrões linearmente separáveis

Inicialmente, define-se um conjunto de N vetores x_i (i = 1, ..., N) que consistem em amostras de treinamento. Cada vetor de dados x_i está associado a uma resposta desejada d_i, que assume os valores +1 ou -1, dependendo da classe à qual a respectiva amostra pertence. Um hiperplano capaz de separar essas duas classes pode ser descrito pela equação [32]

$$w^T x + b = 0, \tag{23}$$

em que w é um vetor de pesos ajustáveis e b é um viés. A partir desse plano, pode-se escrever as regras

$$\begin{array}{ll} w^T x_i + b \geq 0, & d_i = +1 \\ w^T x_i + b < 0, & d_i = -1 \end{array}, \tag{24}$$

em que d_i é a saída desejada associada ao vetor de entrada x_i.

Em seguida, define-se a margem de separação ρ como sendo a distância calculada entre o hiperplano definido pela equação 23 e o vetor de dados x_i mais próximo [32]. O hiperplano que maximiza o valor da margem de separação ρ é chamado de "hiperplano ótimo". Sendo w_o e b_o os valores ótimos do vetor de pesos e do viés definidos acima respectivamente, o objetivo de uma SVM é calcular essas variáveis, de modo a se encontrar o hiperplano ótimo de separação. Os vetores x_i que se encontram mais próximos do hiperplano são chamados de vetores de suporte.

Para isso, define-se a função discriminante

$$g(x) = w_o^T x + b_o \,, \tag{25}$$

que fornece uma medida da distância algébrica de um vetor qualquer *x* até o hiperplano ótimo [32]. Mais precisamente, pode-se demonstrar que a distância algébrica entre um vetor *x* e o hiperplano ótimo pode ser calculada como

$$r = \frac{g(x)}{\|w_o\|} \,, \tag{26}$$

em que $\|w_o\|$ é a norma do vetor de pesos w_o.

Quando se calcula a função discriminante da equação 25 para um vetor de suporte, obtém-se, por definição, um valor unitário. O sinal pode ser positivo ou negativo, dependendo de em qual lado do hiperplano o vetor se encontra.

Portanto, para um vetor de suporte, a margem de separação vale

$$\rho = |r| = \frac{1}{\|w_o\|} \,. \tag{27}$$

Da equação 27, conclui-se que, para que a margem de separação ρ seja maximizada, ou seja, para que se obtenha o hiperplano ótimo, deve-se minimizar a norma euclidiana do vetor de pesos *w*.

Desse fato, pode-se formular a minimização da função de custo

$$\Phi(w) = \frac{1}{2} w^T w \,. \tag{28}$$

Para se atender às regras estabelecidas nas restrições 24, o problema de otimização é descrito da seguinte forma [32]: desejam-se encontrar os valores do vetor de pesos *w* e do viés *b* de modo que a inequação

$$d_i \cdot (w^T x_i + b) \geq 1 \,, \tag{29}$$

seja obedecida para todas as amostras de treinamento, ou seja, $i = 1, 2, ..., N$.

Esse problema de otimização pode ser resolvido utilizando-se o método dos *multiplicadores de Lagrange*. Verifica-se que os valores ótimos w_o e b_o podem ser calculados por [32]

$$\begin{cases} w_o = \sum_{i=1}^{N} \alpha_{o,i} d_i x_i \\ b_o = 1 - w_o^T x^{(s)} \end{cases}, \tag{30}$$

em que $x^{(s)}$ é um vetor de suporte do lado positivo do hiperplano ótimo e $\alpha_{o,i}$ são os valores ótimos dos multiplicadores de Lagrange que maximizam a função objetivo

$$Q(\alpha) = \sum_{i=1}^{N} \alpha_i - \frac{1}{2} \sum_{i=1}^{N} \sum_{j=1}^{N} \alpha_i \alpha_j d_i d_j x_i^T x_j , \tag{31}$$

sujeita às restrições

$$\sum_{i=1}^{N} \alpha_i d_i = 0 , \tag{32}$$

em que $\alpha_i \geq 0$, para $i = 1, 2, ..., N$. Dessa forma, todos os parâmetros podem ser calculados a partir somente das amostras de treinamento x_i e das respostas desejadas d_i.

3.4.2. Hiperplano ótimo de separação para padrões não-separáveis

Existem situações em que os dados não obedecem todos à inequação 29. Podem-se destacar dois casos. No primeiro caso, o dado que não obedece à condição da inequação 29 está localizado dentro da região de separação, mas do lado certo da superfície de decisão, de modo que a classificação é realizada corretamente. No segundo caso, o dado se encontra do lado errado da superfície de decisão, portanto, sua classificação é incorreta.

Em ambos os casos, pode-se modificar a inequação 29 incluindo-se um conjunto de variáveis escalares não-negativas ξ_i, i = 1, 2, ..., N. Então, a condição imposta pela inequação 29 é reescrita como [32]

$$d_i \cdot (w^T x_i + b) \geq 1 - \xi_i . \tag{33}$$

A função de custo definida pela equação 28 também é alterada, resultando em

$$\Phi(w) = \frac{1}{2} w^T w + C \sum_{i=1}^{N} \xi_i , \tag{34}$$

em que o parâmetro C, que é selecionado pelo usuário, controla o conflito entre a complexidade da SVM e o número de pontos não-separáveis [32].

Os valores ótimos w_o e b_o são calculados de forma semelhante ao caso linearmente separável, porém, deve-se fazer uma alteração nas restrições impostas na equação 32, para o cálculo dos multiplicadores de Lagrange:

$$\sum_{i=1}^{N} \alpha_i d_i = 0 , \tag{35}$$

em que $0 \leq \alpha_i \leq C$, para $i = 1, 2, ..., N$.

Portanto, para o caso de padrões não-separáveis, o problema a ser resolvido é muito parecido com o caso de padrões linearmente separáveis, do ponto de vista computacional. A única, mas importante, diferença é a restrição imposta à equação 35, ou seja, $0 \leq \alpha_i \leq C$, que é mais forte que a restrição $\alpha_i \geq 0$ imposta à equação 32.

3.4.3. Construção de SVMs para reconhecimento de padrões

O funcionamento de uma SVM se baseia, essencialmente, em um par de processos consecutivos.

O primeiro consiste no mapeamento não-linear dos vetores de entrada em um espaço de alta dimensionalidade. Esse espaço, conhecido como *espaço de características* fica oculto da entrada e da saída da rede e tem como objetivo tornar os dados de entrada linearmente separáveis. O teorema de Cover [32] sobre separabilidade de padrões diz que um conjunto de padrões não-linearmente separáveis pode ser mapeado em um novo espaço multidimensional no qual esses padrões sejam linearmente separáveis com alta probabilidade. No entanto, o teorema não discute como a operação deve ser feita de forma ótima.

Por isso, surge a necessidade do segundo processo, que consiste na construção do hiperplano ótimo discutido anteriormente. Neste caso, os vetores a serem separados são os vetores de entrada originais mapeados no espaço de características que, por sua vez, são linearmente separáveis, segundo o teorema de Cover.

O primeiro processo, ou seja, o mapeamento dos dados de entrada, é realizado por um conjunto de funções não-lineares $\varphi_j(x)$, para j = 1, 2, ..., m_1. Essas funções devem ser definidas *a priori*, como será descrito mais adiante. O número m_1 de funções é a dimensão do espaço de características. Define-se, então, o hiperplano de separação pela equação [32]

$$\sum_{j=1}^{m_1} w_j \varphi_j(x) + b = 0 , \qquad (36)$$

em que w_j são os pesos que conectam o espaço de características ao espaço de saída e b é um viés. A equação 36 pode ser reescrita de forma mais compacta como

$$\sum_{j=0}^{m_1} w_j \varphi_j(x) = 0 , \qquad (37)$$

fazendo-se $\varphi_0(x) = 1$, para todo x, e $w_0 = b$. Agrupando-se as variáveis w_j em um vetor w de dimensão m_1+1 e, analogamente, agrupando-se as funções $\varphi_j(x)$ em outro vetor $\varphi(x)$, também de dimensão m_1+1, chega-se a

$$w^T \varphi(x) = 0, \tag{38}$$

que é a equação 37 reescrita na forma de um produto vetorial.

De forma análoga ao que foi desenvolvido nas subseções anteriores, pode-se concluir que o vetor ótimo de pesos w_o pode ser calculado segundo a equação

$$w_o = \sum_{i=1}^{N} \alpha_{o,i} d_i \varphi(x_i), \tag{39}$$

em que $\alpha_{o,i}$ são os valores ótimos dos multiplicadores de Lagrange, d_i são as respostas desejadas para cada um dos vetores de entrada x_i e $\varphi(x_i)$ é a função definida anteriormente responsável pelo mapeamento dos vetores de entrada para o espaço de características. A equação 39 é equivalente ao par de equações 30, já que o primeiro componente de w_o é igual ao viés b_o.

Os multiplicadores de Lagrange $\alpha_{o,i}$ são calculados minimizando-se a função objetivo

$$Q(\alpha) = \sum_{i=1}^{N} \alpha_i - \frac{1}{2} \sum_{i=1}^{N} \sum_{j=1}^{N} \alpha_i \alpha_j d_i d_j \varphi^T(x_i) \varphi(x_j), \tag{40}$$

sujeita às restrições impostas pela equação 35. Dentre os multiplicadores de Lagrange $\alpha_{o,i}$, aqueles que possuírem valor não-nulo definem quais dos vetores de treinamento x_i serão os vetores de suporte.

Finalmente, define-se o *núcleo de produto interno* como sendo o produto de funções [21]

$$K(x_i, x_j) = \varphi^T(x_i) \varphi(x_j), \tag{41}$$

que permite reformular a equação 40 como

$$Q(\alpha) = \sum_{i=1}^{N} \alpha_i - \frac{1}{2} \sum_{i=1}^{N} \sum_{j=1}^{N} \alpha_i \alpha_j d_i d_j K(x_i, x_j). \tag{42}$$

Os núcleos de produto interno devem ser escolhidos de forma a satisfazer o teorema de Mercer [21], portanto, há alguns grupos de funções que são comumente utilizados com esse fim, pois se sabe que obedecem ao teorema. Uma escolha freqüente [8,15,16] são os núcleos polinomiais, definidos como

$$K(x_i, x_j) = (x_i^T x_j + 1)^p, \tag{41}$$

em que a potência p é definida *a priori* pelo usuário. Neste mestrado, utilizou-se um núcleo polinomial [8] de ordem 2.

A função discriminante, originalmente apresentada na equação 25 pode, agora, ser escrita da seguinte forma

$$g(x) = \sum_{i=1}^{N_S} \alpha_{o,i} d_i K(x_i, x) + b_o, \tag{42}$$

em que N_S é o número de vetores de suporte, $\alpha_{o,i}$ são os valores ótimos dos multiplicadores de Lagrange, d_i são as respostas desejadas equivalentes a cada vetor de treinamento x_i, b_o é o viés, x é o vetor que se deseja classificar e $K(x_i,x)$ é o núcleo de produto interno, definido na equação 40.

Finalmente, a figura 3.1 mostra de forma esquemática a estrutura de uma SVM. A primeira camada, denominada camada de entrada, representa os atributos de entrada da rede, $x(l)$, $l = 1, 2, ..., m_0$, ou seja, os elementos do vetor $x = [x(1)\ x(2)\ ...\ x(m_0)]$ que, neste trabalho, seriam os coeficientes do modelo ARMA.

A segunda camada, denominada camada oculta, possui m_1 neurônios. Um neurônio é um operador matemático que, neste caso, calcula o núcleo de produto interno entre o vetor de entrada x e um dos m_1 vetores de suporte x_i.

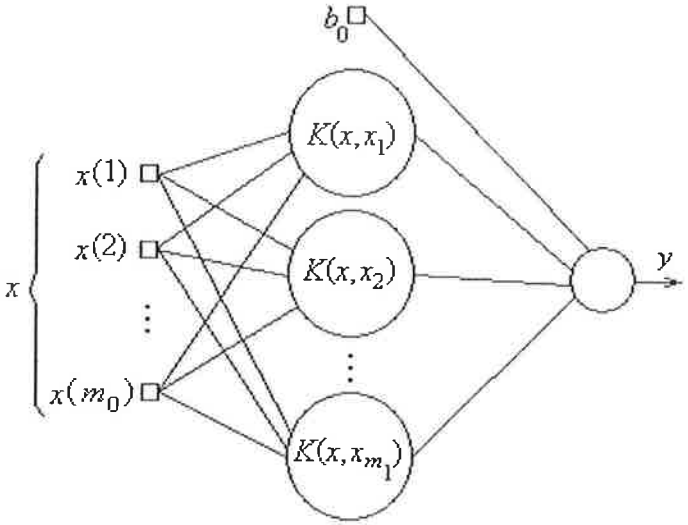

Figura 3.1 – Estrutura de uma SVM.

Na última camada, então, as saídas dos neurônios da segunda camada são ponderadas e somadas, junto ao viés b_0, resultando na saída $g(x)$, definida pela equação 42.

3.5. Estratégia de classificação

Para cada um dos 171 sinais de EMG utilizados nesta dissertação foram calculados os coeficientes dos modelos ARMA(p,q) com $1 \leq (p + q) \leq 55$, resultando num total de 1595 modelos. Para cada modelo, os sinais, representados pelos coeficientes ARMA foram classificados utilizando-se as duas ferramentas de classificação descritas nas duas seções anteriores.

Para ambos os métodos, a classificação dos sinais de EMG foi feita em duas etapas, com separação prévia dos sinais normais, ou seja, em uma primeira etapa, separaram-se os sinais normais dos patológicos (grupo que engloba os sinais

neuropáticos e miopáticos). Em uma segunda etapa, os sinais classificados como patológicos foram separados entre neuropáticos e miopáticos.

Na primeira etapa de classificação, foram utilizados 18 sinais provenientes de dois indivíduos normais e 36 sinais provenientes de quatro indivíduos patológicos (18 sinais de dois indivíduos neuropáticos e 18 sinais de dois indivíduos miopáticos) para o conjunto de teste. Os demais 117 sinais do banco de dados, provenientes de quatro indivíduos normais, três indivíduos neuropáticos e quatro indivíduos miopáticos, foram utilizados para treinamento.

Na segunda etapa, o treinamento foi feito com os mesmos sinais provenientes de indivíduos neuropáticos e miopáticos utilizados na primeira etapa, e foram utilizados para teste todos os sinais que tinham sido classificados como patológicos na primeira etapa.

4. Resultados

Para cada modelo ARMA(p,q), com $1 \leq (p + q) \leq 55$, foi feita a classificação dos 54 sinais de EMG do conjunto de teste, confirme descrito no final do capítulo anterior, utilizando-se o discriminante linear de Fisher (DLF) e a máquina de vetor de suporte (SVM), ambos implementados em ambiente Matlab® por rotinas escritas durante este mestrado.

4.1. Primeira etapa de classificação

Na figura 4.1, estão as taxas de acerto (porcentagem de sinais corretamente classificados) obtidas ao final da primeira etapa de classificação com o DLF. Além das taxas calculadas para os 54 sinais, também estão as taxas parciais somente para sinais normais, patológicos, neuropáticos e miopáticos. O número de coeficientes auto-regressivos p está representado no eixo das ordenadas, e o número de coeficientes de média móvel q está representado no eixo das abscissas. Taxas de acerto mais elevadas são representadas por tons mais avermelhados, enquanto as taxas mais baixas são representadas por tons de azul, como indica a barra vertical na figura.

A figura 4.1.a com as taxas de acerto da primeira etapa mostra que os melhores resultados nessa etapa são obtidos para modelos do tipo ARMA(p,q) com $0 \leq p \leq 2$ (próximos ao eixo das abscissas) e do tipo ARMA(p,0) (no eixo das ordenadas).

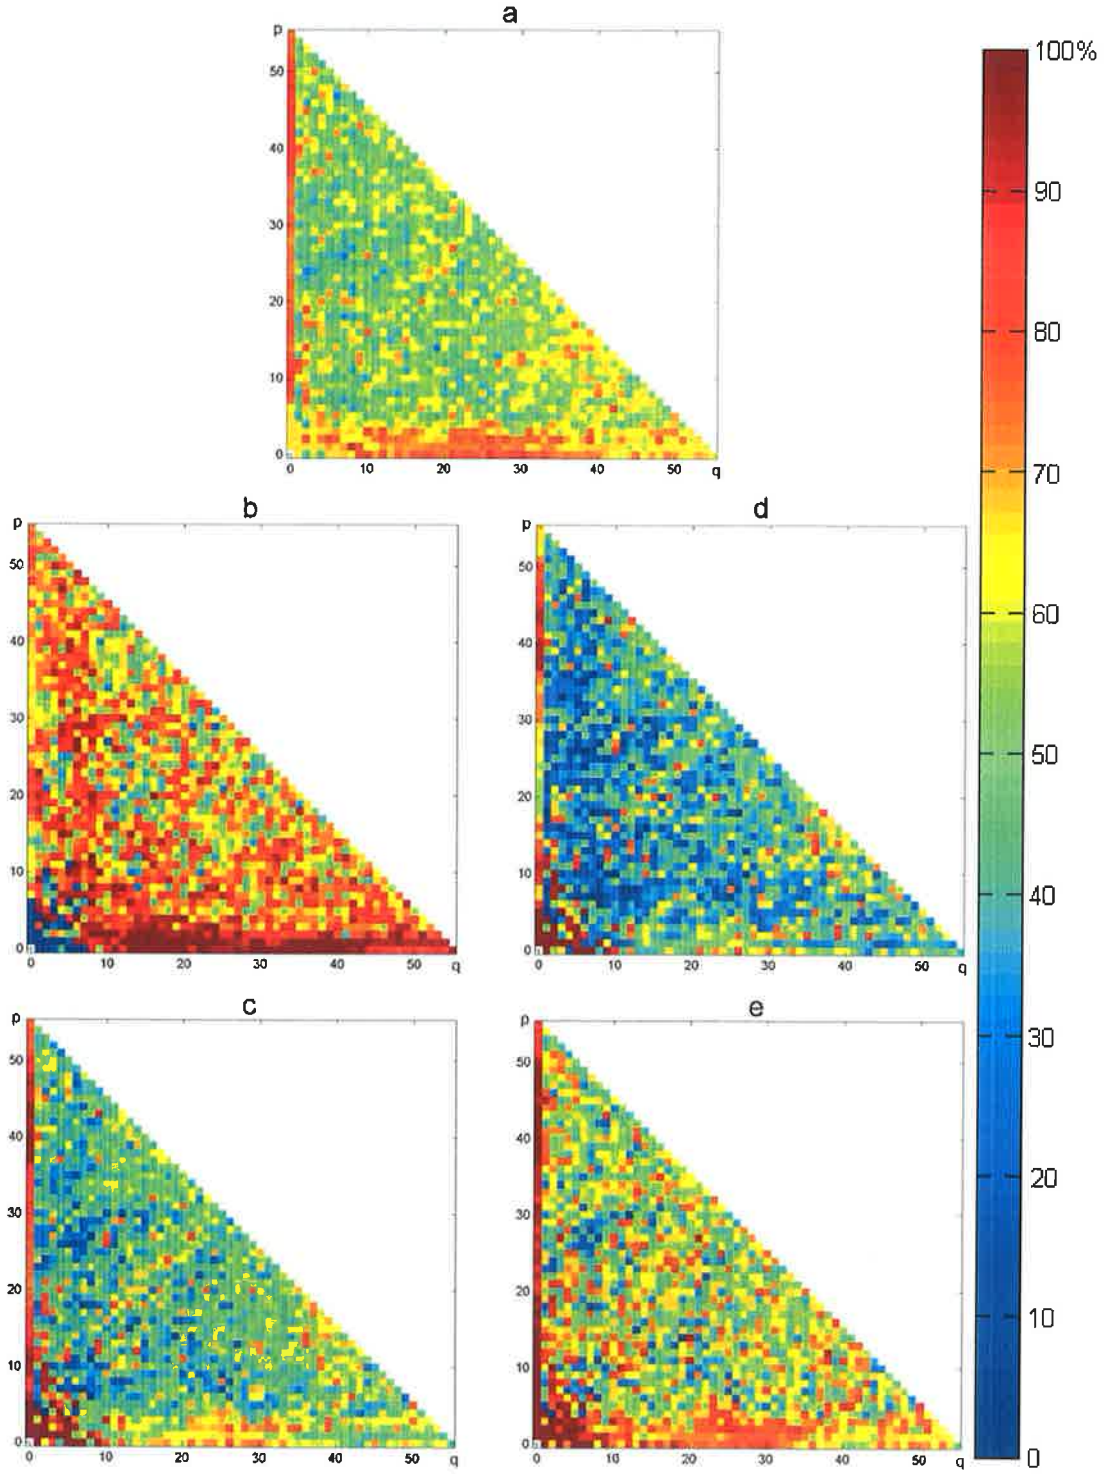

Figura 4.1 – Taxas de acerto na primeira etapa de classificação com o DLF para (a) todos sinais, (b) sinais normais, (c) sinais patológicos, (d) sinais neuropáticos e (e) sinais miopáticos, utilizando-se modelos ARMA (p,q) com $1 \leq (p + q) \leq 55$.

Comparando-se as figuras 4.1.b e 4.1.c, observa-se que, para a maior parte dos modelos, as taxas de acerto são maiores para os indivíduos normais do que para os patológicos. Essa característica torna-se mais acentuada para a maior parte dos modelos ARMA(p,q) com $0 \leq p \leq 2$ (próximos ao eixo das abscissas). A taxa de acerto média (calculada para os 1595 modelos analisados) é de 70,1% para os sinais normais, enquanto é de somente 50,8% para os sinais patológicos.

No entanto, para vários modelos ARMA(p,0) (no eixo das ordenadas), observa-se que a taxa de acerto para sinais patológicos supera a taxa de normais. Além disso, para vários modelos com até 5 coeficientes (próximos da origem), isto é, ARMA(p,q) com $1 \leq (p + q) \leq 5$, todos os sinais são classificados como patológicos.

Além disso, observa-se nas figuras 4.1.d e 4.1.e que as taxas de acerto, em geral, são maiores para os sinais miopáticos do que para os sinais neuropáticos. A taxa média calculada sobre todos os modelos é 59,6% para os sinais miopáticos, e apenas 42,0% para os sinais neuropáticos.

Na figura 4.2, estão as taxas de acerto obtidas na primeira etapa de classificação utilizando-se a SVM. A figura 4.2.a, que contém os resultados com todos os 54 sinais de teste da primeira etapa, foi obtida pela SVM e indica que os melhores resultados são associados aos modelos ARMA(p,q) com $1 \leq p \leq 3$ (próximos ao eixo das abscissas) e também nos modelos ARMA(p,q) com $0 \leq q \leq 1$ (próximos ao eixo das ordenadas). Comparando-se com a figura 4.1.a, verifica-se que o valor médio da taxa de acerto global calculada sobre os 1595 modelos é de 60,9% para a SVM e de 57,2% para o DLF.

Observando-se as figuras 4.2.b e 4.2.c, notam-se taxas de acerto mais elevadas, em média, para os sinais normais (74,4%) do que para os patológicos (54,0%).

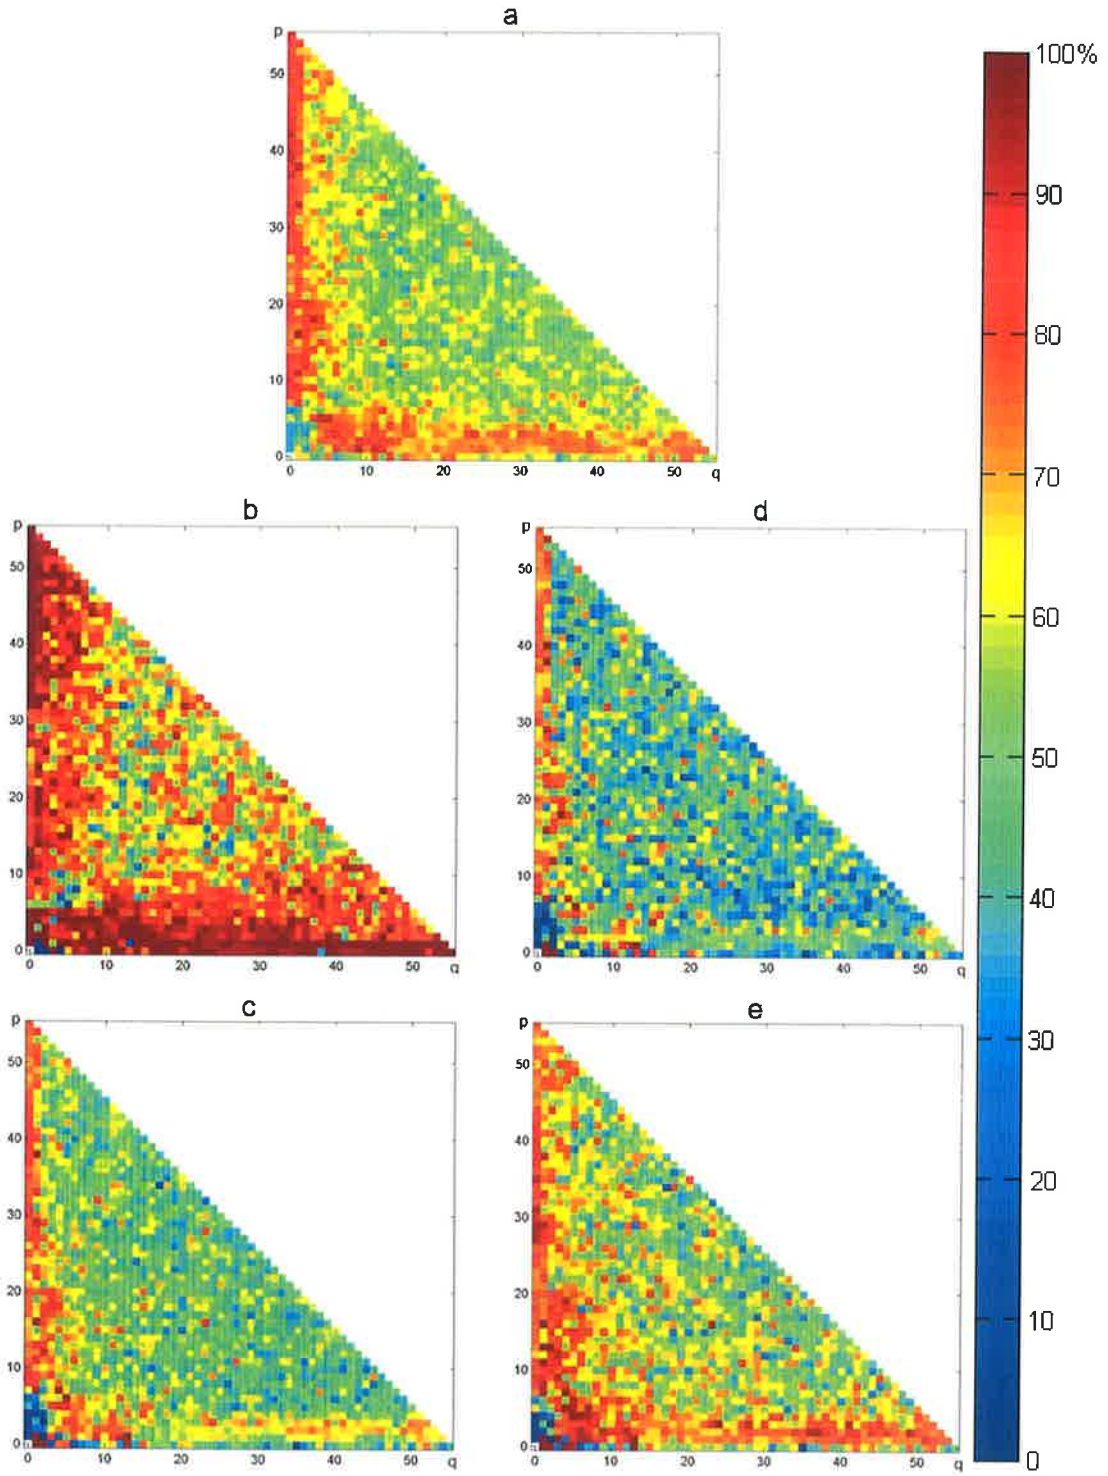

Figura 4.2 – Taxas de acerto na primeira etapa de classificação com a SVM para (a) todos sinais, (b) sinais normais, (c) sinais patológicos, (d) sinais neuropáticos e (e) sinais miopáticos, utilizando-se modelos ARMA (p,q) com $1 \leq (p + q) \leq 55$.

Para sinais normais, as taxas mais elevadas estão na faixa de modelos ARMA(p,q) com $0 \leq p \leq 2$ (próximos ao eixo das abscissas), semelhantemente aos resultados com o DLF. No entanto, há também uma faixa de modelos com $0 \leq q \leq 1$ (próximos ao eixo das ordenadas), em que as taxas de acerto para sinais normais também são mais elevadas do que para os sinais patológicos, o que não acontecia na classificação usando o DLF.

Quanto aos modelos ARMA(p,q) com $1 \leq (p + q) \leq 5$ (próximos à origem), também existem casos em que todos os sinais são classificados como patológicos, como acontecia com o DLF. No entanto, há também alguns casos em que todos os sinais são classificados como normais.

Nota-se, também, que os sinais neuropáticos também levam a taxas de acerto menores que os miopáticos, como acontecia com o DLF. Em comparação aos resultados obtidos com o DLF, as taxas médias calculadas com a SVM são maiores: 47,0% para os sinais neuropáticos e 61,2% para os sinais miopáticos.

4.2. Segunda etapa de classificação

A figura 4.3 apresenta as taxas de acerto obtidas na segunda etapa de classificação com o DLF. Neste caso, calculou-se a taxa de acerto como a relação entre o número de sinais corretamente classificados na segunda etapa e o número de sinais patológicos corretamente classificados na primeira etapa.

É possível observar que as taxas de acerto são, de um modo geral, maiores para os sinais miopáticos do que para os sinais neuropáticos. O valor médio da taxa de acerto para os sinais miopáticos foi 66,6% e para os sinais neuropáticos foi 56,1%.

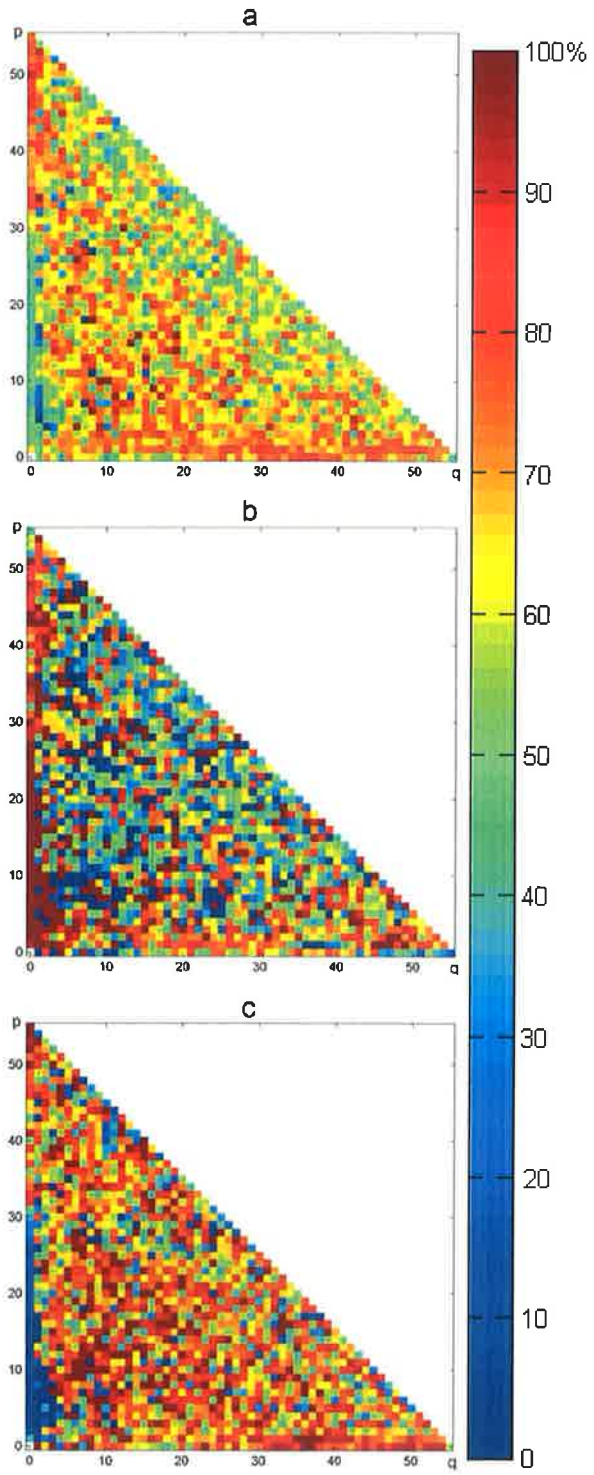

Figura 4.3 – Taxas de acerto na segunda etapa de classificação com o DLF para (a) todos sinais, (b) sinais neuropáticos e (c) sinais miopáticos, utilizando-se modelos ARMA (p,q) com $1 \leq (p + q) \leq 55$.

Comparando as figuras 4.3.b e 4.3.c, também se pode observar que, para modelos ARMA(p,0) com $2 \leq p \leq 26$ (próximos ao eixo das ordenadas), todos os sinais patológicos foram classificados como neuropáticos. O mesmo acontece para outros modelos de poucos coeficientes (próximos à origem).

Ao contrário do que acontecia na primeira etapa, na segunda etapa não se observam agrupamentos de modelos que resultem sempre em altas taxas de acerto global.

Na figura 4.4, estão as taxas de acerto encontradas na segunda etapa de classificação utilizando a SVM. Primeiramente, nota-se que, ao contrário do DLF, a SVM fornece taxas de acerto menores para os sinais miopáticos (valor médio de 64,0%) do que para os neuropáticos (valor médio de 65,9%).

O valor médio das taxas de acerto globais na segunda etapa com a SVM (64,7%) foi levemente superior ao valor médio das taxas obtidas com o DLF (63,4%). Além disso, ao contrário do que acontecia com o DLF, é possível encontrar agrupamentos de altas taxas de acerto quando se utiliza a SVM. Dois grupos perceptíveis são os modelos ARMA(p,q) com $30 \leq p \leq 54$ e $0 \leq q \leq 1$ (ordenadas altas) e os modelos ARMA(0,q) com $15 \leq q \leq 53$ (abscissas altas).

4.3. Resultados finais da classificação

Na figura 4.5 encontram-se as taxas de acerto finais da classificação feita com o DLF. As taxas para os sinais normais foram omitidas na figura pois os valores são os mesmos obtidos na primeira etapa (figura 4.1.b).

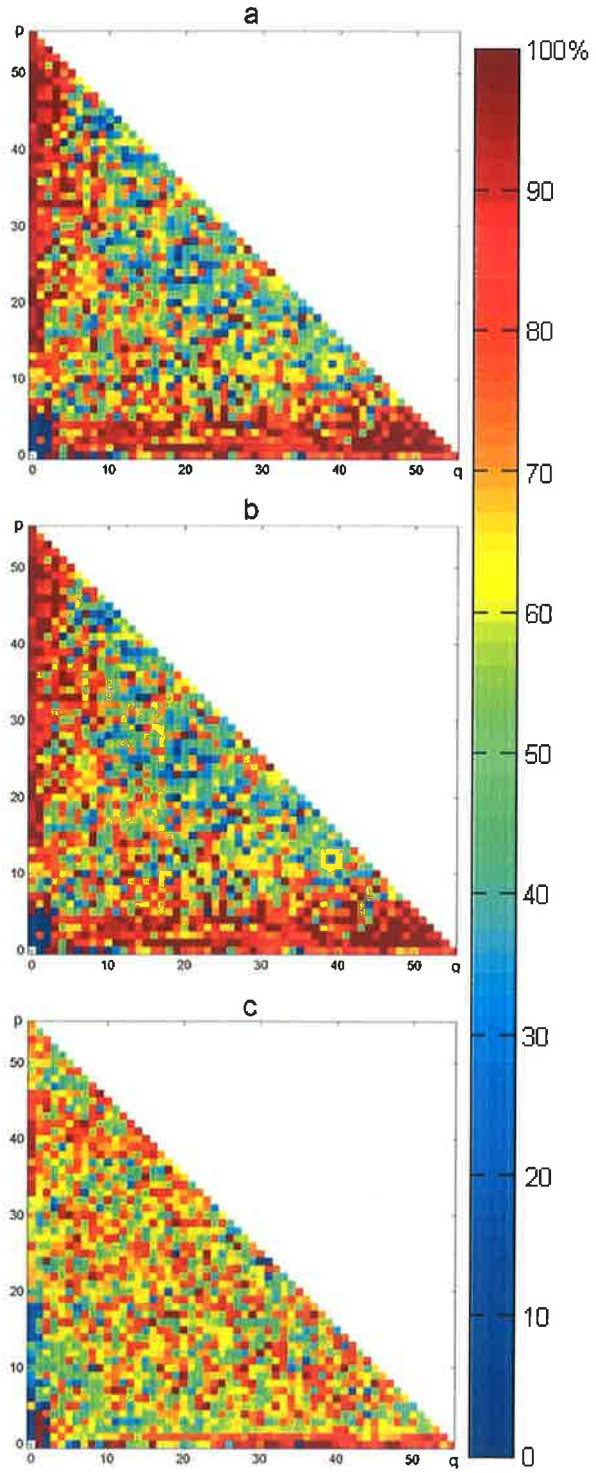

Figura 4.4 – Taxas de acerto na segunda etapa de classificação com a SVM para (a) todos sinais, (b) sinais neuropáticos e (c) sinais miopáticos, utilizando-se modelos ARMA (p,q) com $1 \leq (p + q) \leq 55$.

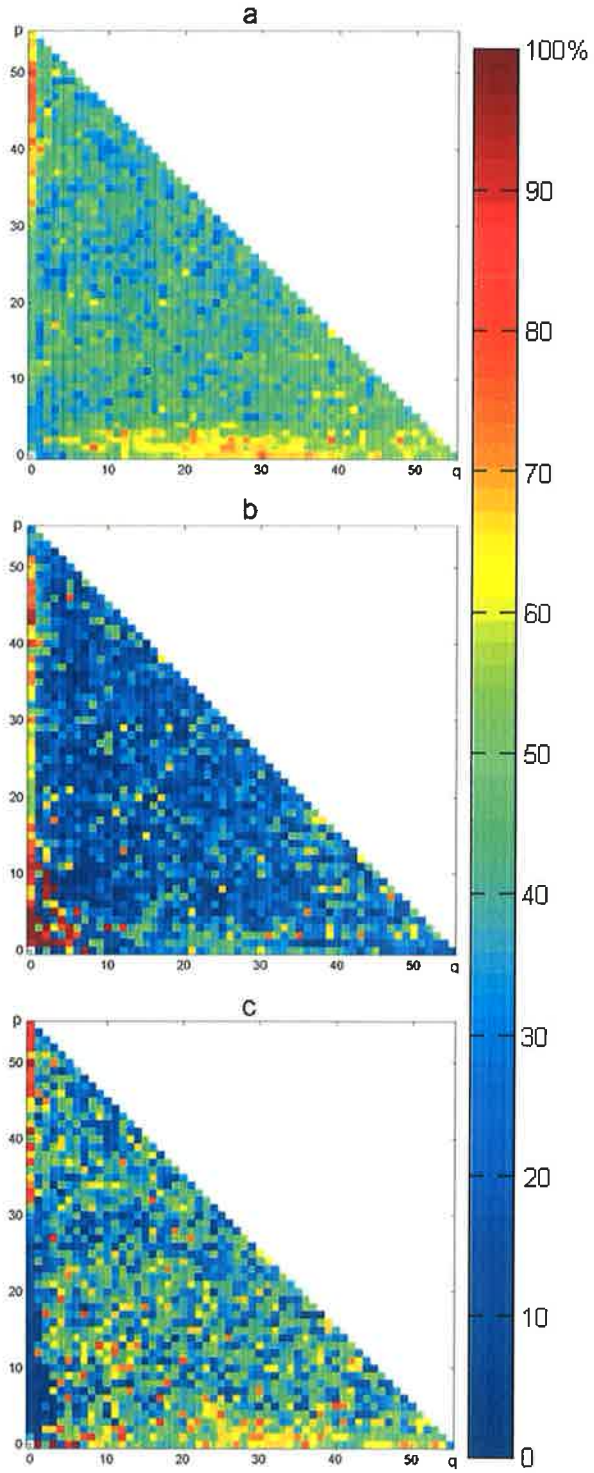

Figura 4.5 – Taxas de acerto finais de classificação com o DLF para (a) todos sinais, (b) sinais neuropáticos e (c) sinais miopáticos, utilizando-se modelos ARMA (p,q) com $1 \leq (p + q) \leq 55$.

As taxas de acerto globais obtidas ao final da classificação utilizando o DLF possuem valor médio de 44,8% e o valor máximo de 79,6%, obtido para os modelos ARMA(48,0) e ARMA(50,0). Taxas acima de 70% podem ser observadas em alguns modelos ARMA(p,q) com $0 \leq p \leq 2$ e $20 \leq q \leq 40$ (abscissas altas) e para vários modelos ARMA(p,0) com $41 \leq p \leq 51$ (ordenadas altas).

Novamente as taxas de acerto obtidas para os sinais neuropáticos são menores que para os miopáticos. O valor médio das taxas de acerto foi 25,2% para os sinais neuropáticos e 39,2% para os sinais miopáticos. Para esses dois tipos de sinais, as taxas de acerto mais altas foram obtidas, em geral, para os modelos ARMA(p,0) com $33 \leq p \leq 51$ (ordenadas altas).

Os resultados finais obtidos com a SVM estão apresentados na figura 4.6. As taxas globais obtidas ao final da classificação possuem valor médio de 48,3% e o valor máximo de 88,9%, encontrado para o modelo ARMA(39,0). Além disso, taxas de acerto acima de 70% são obtidas para todos os modelos ARMA(p,0) com $32 \leq p \leq 54$ (ordenadas altas) e diversos modelos do tipo ARMA(p,1) com $33 \leq p \leq 52$ (ordenadas altas). Também são observadas taxas de acerto em torno de 70 % para modelos do tipo ARMA(1,q) para $9 \leq q \leq 42$ (abscissas).

Mais uma vez é possível observar que as menores taxas de acerto são obtidas para os sinais neuropáticos (31,5%), apesar de que as taxas obtidas para os sinais miopáticos também não sejam muito elevadas (39,1%).

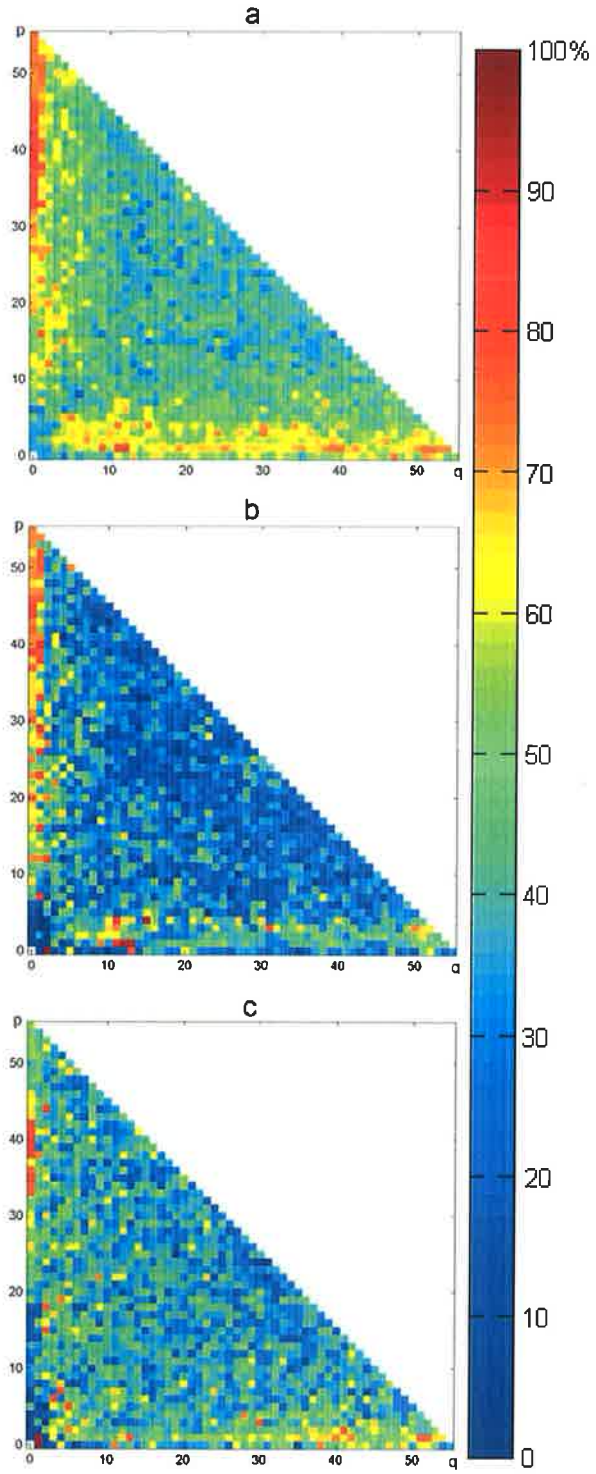

Figura 4.6 – Taxas de acerto finais de classificação com a SVM para (a) todos sinais, (b) sinais neuropáticos e (c) sinais miopáticos, utilizando-se modelos ARMA (p,q) com $1 \leq (p + q) \leq 55$.

4.3.1. Modelos auto-regressivos

Dados os resultados apresentados acima, decidiu-se detalhar o resultado da classificação para alguns modelos específicos cujas taxas de acerto de classificação foram altas. Na figura 4.7, está detalhada a classificação de cada um dos 54 sinais do grupo de teste para os modelos auto-regressivos ARMA(p,0) com $1 \leq p \leq 55$ (eixo das ordenadas), utilizando-se o DLF e a SVM. Cada linha representa um sinal, sendo que os sinais de 1 a 18 pertencem a indivíduos normais, os sinais de 19 a 36 pertencem a indivíduos neuropáticos e os sinais de 37 a 54 pertencem a indivíduos miopáticos. Os sinais classificados como normais foram representados pela cor branca, aqueles classificados como neuropáticos, pela cor azul, e aqueles classificados como miopáticos, pela cor vermelha.

Quando se utilizam modelos ARMA(p,0), com $p < 6$, quase todos sinais são classificados como neuropáticos pelo DLF (figura 4.7.a), enquanto a SVM (figura 4.7.b) os classifica como normais.

Para $p < 30$, o DLF classifica quase todos os sinais miopáticos como sendo neuropáticos. Além disso, os sinais normais classificados erroneamente como patológicos também são classificados como neuropáticos, na maioria dos casos. A SVM é capaz de classificar corretamente os sinais miopáticos a partir de ordens mais baixas, a partir de $p = 19$.

Para $p > 31$, a SVM classifica corretamente todos os 18 sinais normais. Também é possível observar que, em geral, o número de sinais classificados como normais pela SVM é maior que o número de sinais assim classificados pelo DLF.

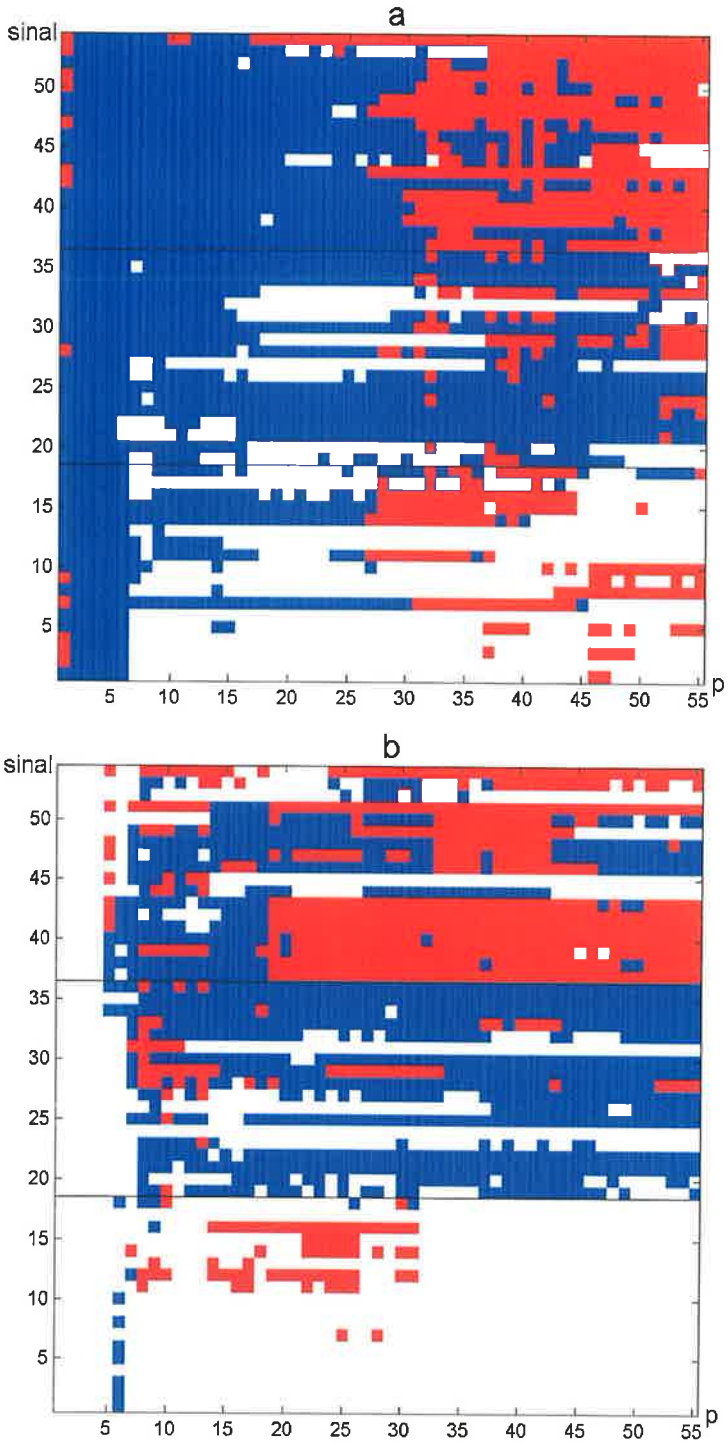

Figura 4.7 – Sinais normais (1 a 18), neuropáticos (19 a 36) e miopáticos (37 a 54) classificados como normais (branco), neuropáticos (azul) e miopáticos (vermelho), para modelos ARMA(p,0), utilizando (a) o DLF e (b) a SVM.

Nota-se, além disso, que sinais que são quase sempre classificados incorretamente por um dos classificadores não são, necessariamente, classificados incorretamente pelo outro, por exemplo, o sinal de número 24. Ele é proveniente de um indivíduo neuropático e é sempre classificado como normal pela SVM. No entanto, é classificado corretamente pelo DLF em 88,9% dos casos.

4.3.2. Modelos de média móvel

Na figura 4.8, quando se observam os resultados para os modelos de média móvel ARMA(0,q), $1 \leq q \leq 55$ (eixo das abscissas), nota-se que a classificação fornecida por modelos adjacentes tem um comportamento mais aleatório do que nos modelos auto-regressivos. O número de sinais normais classificados corretamente pelo DLF é quase sempre elevado. Entretanto, o número total de sinais classificados como normais pela SVM supera o número de sinais assim classificados pelo DLF.

4.3.3. Modelos auto-regressivos de média móvel próximos ao eixo das ordenadas

Na figura 4.9 também foi representada a classificação individual de cada um dos 54 sinais do grupo de teste utilizando-se o DLF e a SVM. Para estes gráficos, foram utilizados os modelos ARMA(p,1), com $0 \leq p \leq 54$. Observa-se que a classificação de um dado sinal para valores consecutivos de p se altera com muito mais freqüência do que para os modelos auto-regressivos, mostrados na figura 4.7.

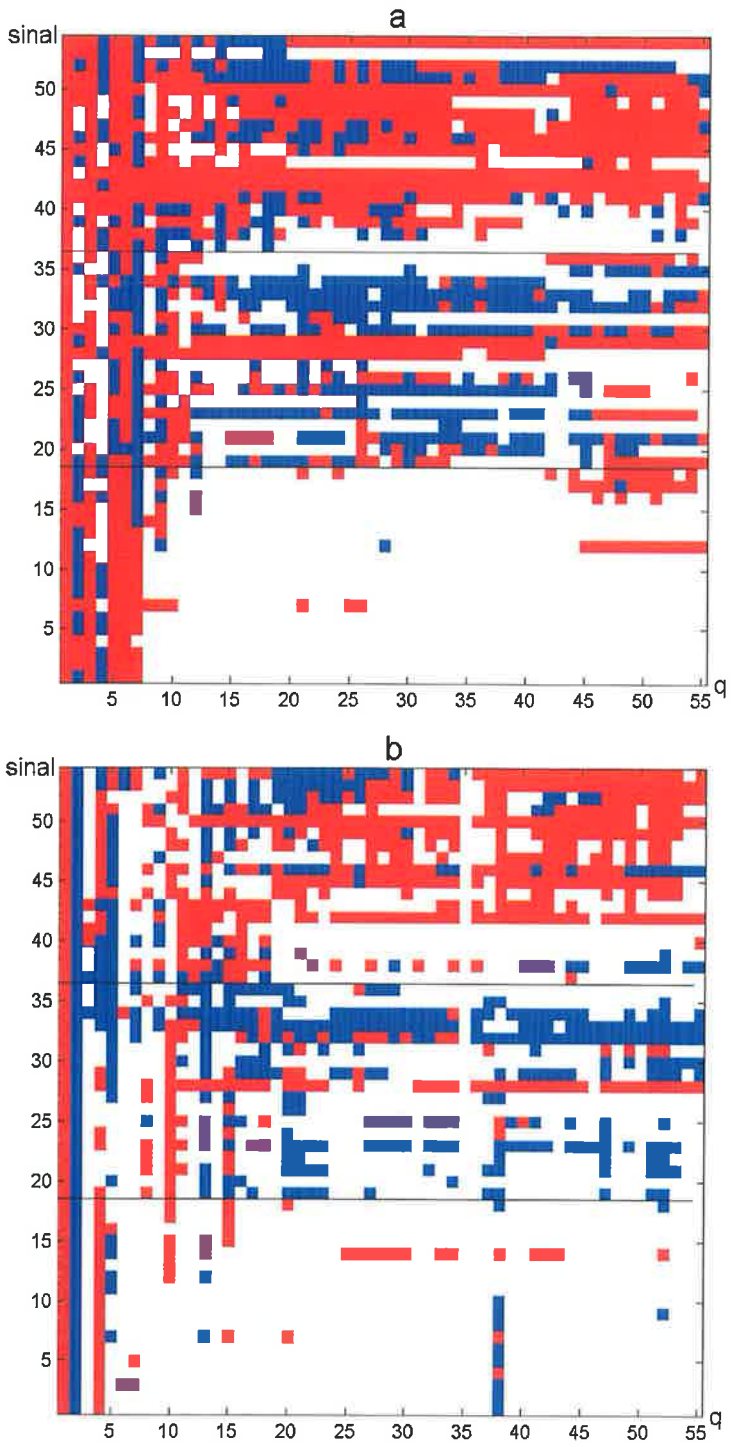

Figura 4.8 – Sinais normais (1 a 18), neuropáticos (19 a 36) e miopáticos (37 a 54) classificados como normais (branco), neuropáticos (azul) e miopáticos (vermelho), para modelos ARMA(0,q), utilizando (a) o DLF e (b) a SVM.

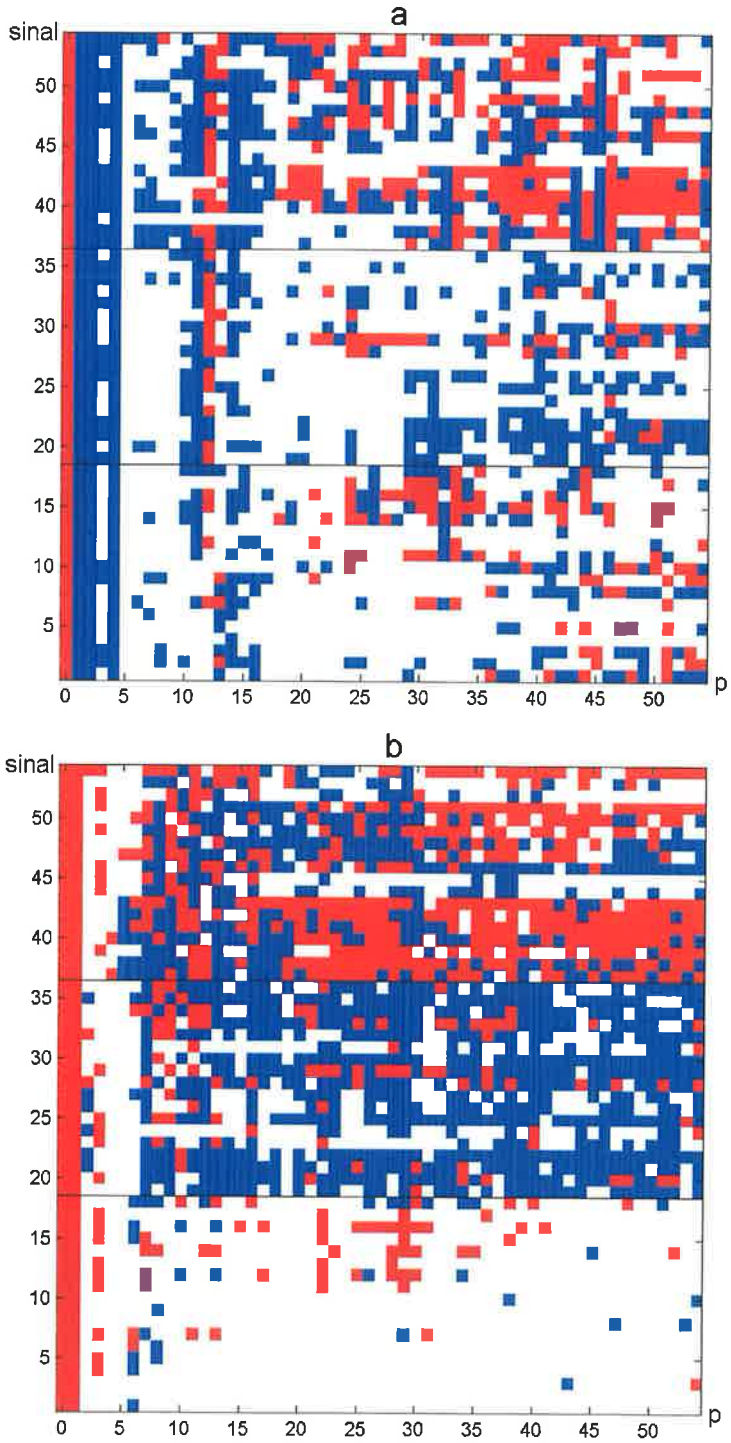

Figura 4.9 – Sinais normais (1 a 18), neuropáticos (19 a 36) e miopáticos (37 a 54) classificados como normais (branco), neuropáticos (azul) e miopáticos (vermelho), para modelos ARMA(p,1), utilizando (a) o DLF e (b) a SVM.

Modelos com um número muito pequeno de coeficientes levam, em geral, os classificadores a atribuir erroneamente quase todos os sinais a uma mesma classe. Nota-se, também, que, ao se passar dos modelos ARMA(p,0) para os modelos ARMA(p,1), o número de sinais patológicos classificados como normais aumenta, principalmente para o DLF.

A figura 4.10, mostra o resultado da classificação feita para cada um dos 54 sinais, utilizando-se o DLF e a SVM, e modelos ARMA(p,2), com $0 \leq p \leq 53$. Esses modelos fornecem, tanto com o DLF como com a SVM, resultados com uma aparência aleatória, de forma que a classificação da maioria dos sinais muda entre dois modelos com valores consecutivos de p.

4.3.4. Modelos auto-regressivos de média móvel próximos ao eixo das abscissas

Já os modelos ARMA(1,q), com $0 \leq q \leq 54$, ilustrados na figura 4.11, levam a uma classificação mais constante, de forma que valores de q consecutivos, em geral, fazem com que a classificação da maior parte dos sinais se mantenha inalterada.

A figura 4.12, finalmente, mostra os resultados para os modelos ARMA(2,q), com $0 \leq q \leq 53$. Apesar de esses modelos apresentarem taxas aparentemente aleatórias como os modelos da figura 4.10, existem vários sinais cuja classificação se mantém constante mesmo para grandes variações de q, principalmente quando se usa a SVM.

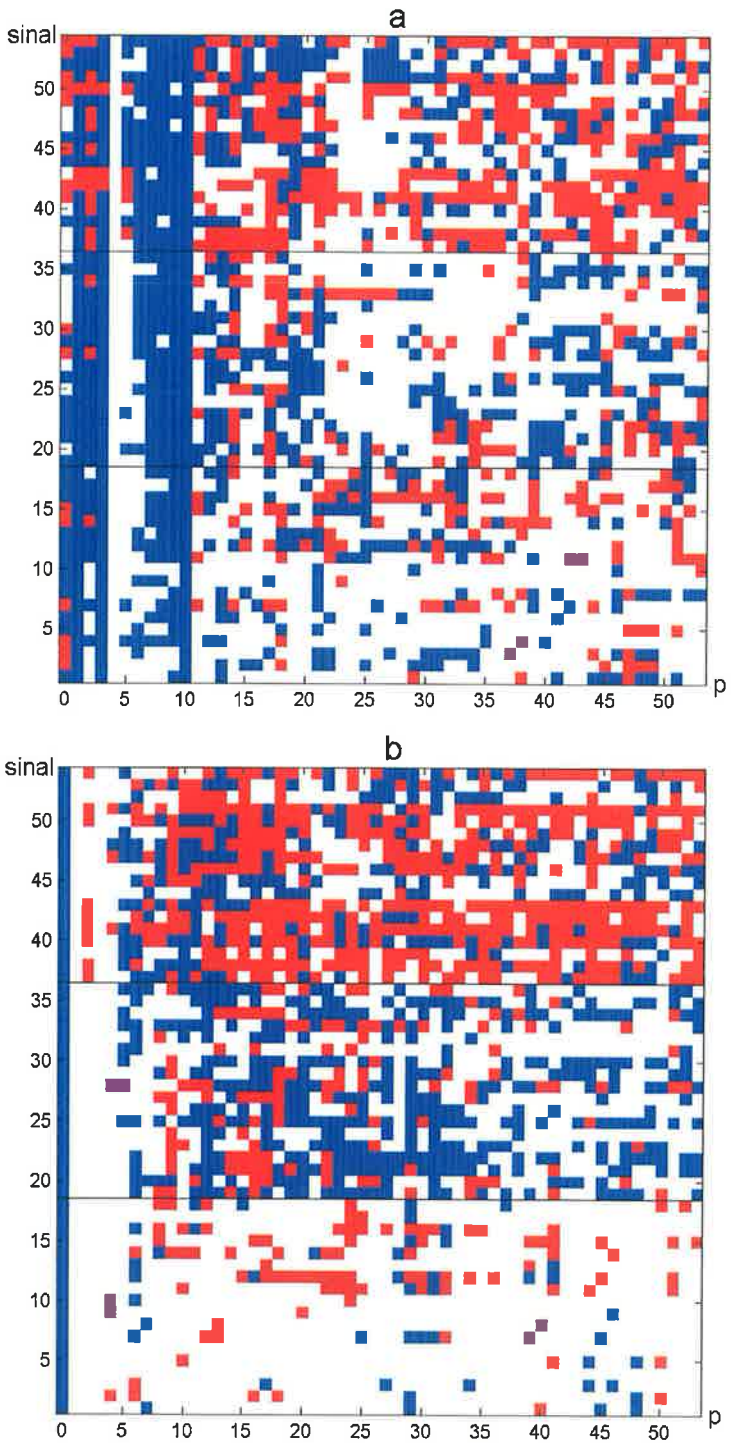

Figura 4.10 – Sinais normais (1 a 18), neuropáticos (19 a 36) e miopáticos (37 a 54) classificados como normais (branco), neuropáticos (azul) e miopáticos (vermelho), para modelos ARMA(p,2), utilizando (a) o DLF e (b) a SVM.

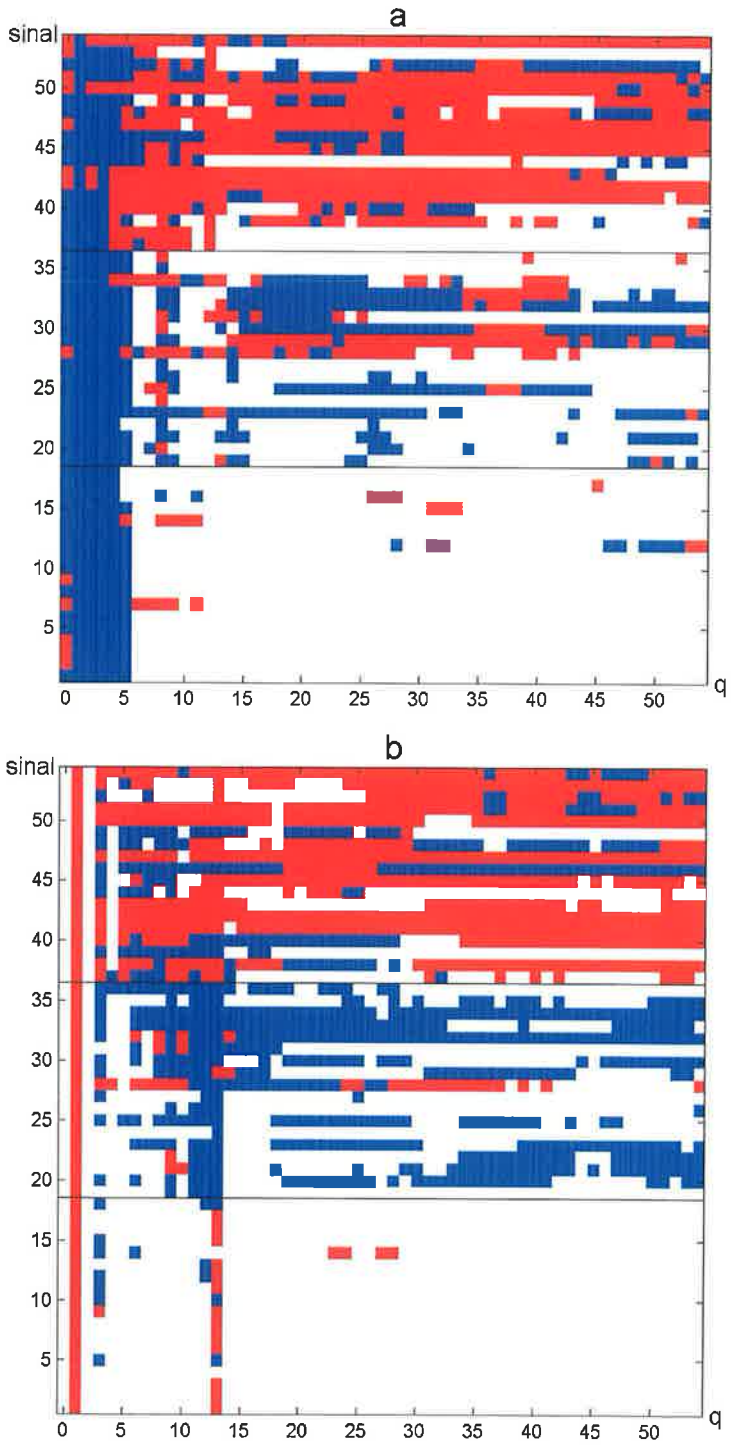

Figura 4.11 – Sinais normais (1 a 18), neuropáticos (19 a 36) e miopáticos (37 a 54) classificados como normais (branco), neuropáticos (azul) e miopáticos (vermelho), para modelos ARMA(1,*q*), utilizando (a) o DLF e (b) a SVM.

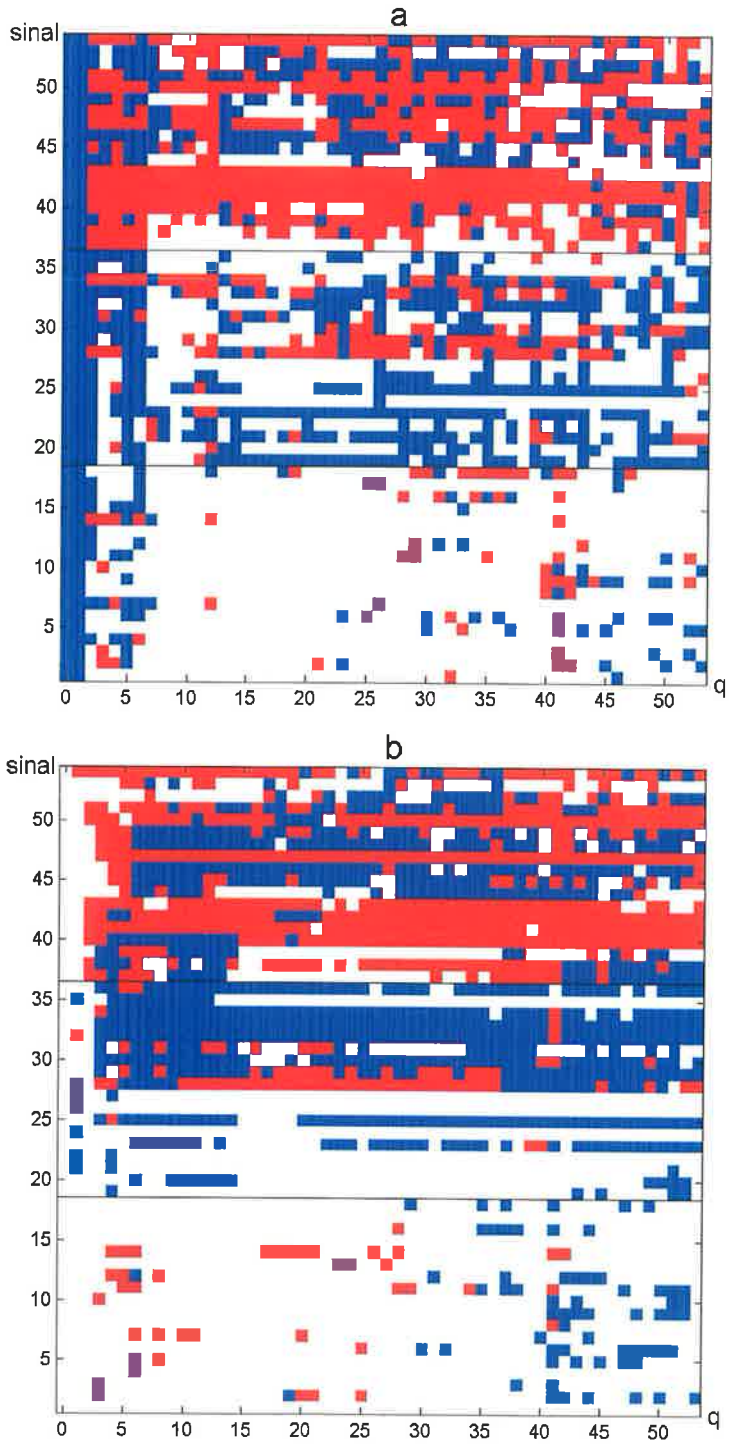

Figura 4.12 – Sinais normais (1 a 18), neuropáticos (19 a 36) e miopáticos (37 a 54) classificados como normais (branco), neuropáticos (azul) e miopáticos (vermelho), para modelos ARMA(2,*q*), utilizando (a) o DLF e (b) a SVM.

5. Análise e conclusão

Os resultados apresentados no capítulo anterior podem, em primeiro lugar, ser comparados com outros trabalhos da literatura que tenham investigado a classificação diagnóstica de sinais de eletromiografia (EMG), representados por modelos auto-regressivos (AR).

Pattichis e Elia [6], utilizaram modelos AR de ordem 12 para representar sinais eletromiográficos de agulha. Os sinais utilizados por Pattichis e Elia possuíam somente 25,6ms de duração, diferentemente dos sinais de 800ms utilizados neste mestrado. Em seu trabalho, a separação entre sinais normais, miopáticos e neuropáticos foi feita utilizando-se três arquiteturas de redes neurais artificiais: mapa auto-organizável, rede de função de base radial e perceptron multicamada treinado por retropropagação de erro. A maior taxa de acerto, 56,2%, foi obtida utilizando-se o perceptron. Neste mestrado, utilizando o modelo auto-regressivo ARMA(12,0), obteve-se a taxa de acerto de 50,0% com o discriminante linear de Fisher (DLF) e de 64,8% com a máquina de vetor de suporte (SVM), resultados comparáveis com os obtidos pelos autores.

Abou-Chadi e colaboradores [11] utilizaram 20 coeficientes AR para fazer a classificação entre indivíduos normais e miopáticos. Neste caso, os sinais de EMG foram captados com eletrodos de superfície, e utilizaram-se trechos com 500ms de duração. O uso de várias arquiteturas de redes neurais artificiais levaram a taxas de acerto de até 90,0% (com o perceptron e a rede probabilística) e o uso do tradicional DLF levou à taxa de acerto de 60,0%. Para poder comparar esses resultados com os obtidos neste mestrado, foi feito um

treinamento apenas com sujeitos normais e miopáticos, descartando-se os neuropáticos. Para o modelo auto-regressivo ARMA(20,0), obteve-se a taxa de acerto de 77,8% com o DLF e 69,4% com a SVM. Os resultados são superiores ao obtido pelos autores com o DLF, mas inferiores ao obtido com o perceptron.

Inbar e Noujaim [10] também utilizaram 20 coeficientes AR para representar sinais de EMG de superfície, com 800ms de duração. Ao fazerem a classificação de indivíduos normais e patológicos por meio do DLF, obtiveram uma taxa de acerto de 87,5%. Neste mestrado, na primeira etapa de classificação (separação entre sinais normais e patológicos), obteve-se uma taxa de acerto de 75,9% com o DLF e 81,5% com a SVM, utilizando-se o modelo auto-regressivo ARMA(20,0). Esses resultados estão próximos aos apresentados pelos autores.

Na classificação entre indivíduos neuropáticos e miopáticos, Inbar e Noujaim [10] obtiveram uma taxa de acerto de 75,0% com o modelo AR(20). Neste mestrado, um novo treinamento foi efetuado entre os sinais neuropáticos e miopáticos para que os resultados pudessem ser comparados. Chegou-se a uma taxa de acerto de 52,8% com o DLF e de 66,7% com a SVM, sempre utilizando-se o modelo ARMA(20,0). O resultado obtido neste caso foi sensivelmente inferior ao obtido pelos autores.

Güler e Koçer [17], finalmente, utilizaram modelos AR de ordem 50 e fizeram a separação entre indivíduos normais, neuropáticos e miopáticos, usando SVMs. Obteve-se a taxa de acerto de 94,4%. Neste mestrado, o uso do modelo ARMA(50,0) resultou na taxa de acerto de 79,6% com o DLF e de 70,4% com a SVM. Os valores foram, novamente, inferiores aos apresentados pelos autores.

As diferenças entre os resultados obtidos neste mestrado e os encontrados por Abou-Chadi [11], Inbar [10] e Güler [17] podem ser justificados pelo fato de

que esses autores utilizaram sinais de EMG de superfície, cujas características são muito diferentes dos sinais de agulha utilizados neste trabalho. Além disso, os bancos de sinais de EMG utilizados nos diversos trabalhos foram obtidos a partir de indivíduos diferentes, conseqüentemente, seria previsível que os resultados da classificação variassem bastante de um trabalho para outro.

Após a análise dos resultados obtidos neste mestrado para modelos AR, decidiu-se comparar também o desempenho da classificação utilizando modelos ARMA(p,q), com mesmo número de coeficientes que os modelos AR. Dessa forma, é possível observar se há melhoras perceptíveis na substituição de modelos AR por modelos ARMA.

Na tabela 5.1 estão apresentadas as taxas de acerto na classificação de sinais normais, neuropáticos e miopáticos utilizando-se modelos ARMA(p,12-p) com $0 \leq p \leq 12$. Esses resultados poderiam ser comparados com os resultados obtidos por Pattichis e Elia [6], que utilizaram um modelo AR com 12 coeficientes.

Observa-se que as taxas, em média, são inferiores àquelas obtidas com o modelo auto-regressivo ARMA(12,0). Entretanto, com a SVM, é possível, a partir do modelo ARMA(1,11), alcançar uma taxa de acerto de 81,5%, sensivelmente superior à taxa de 64,8% obtida com o modelo AR. Esse resultado mostra que um modelo ARMA com o mesmo número de coeficientes que o AR elevou consideravelmente o desempenho da classificação. Além disso, comparando-se a SVM com o DLF, observaram-se taxas maiores para a SVM em dez dentre os treze modelos avaliados.

Tabela 5.1: Taxas de acerto obtidas na classificação de sinais normais, neuropáticos e miopáticos, para cada um dos modelos ARMA(p,12-p), utilizando-se o DLF e a SVM.

Modelo	DLF	SVM
ARMA(0,12)	61,1%	50,0%
ARMA(1,11)	46,3%	81,5%
ARMA(2,10)	59,3%	64,8%
ARMA(3,9)	59,3%	55,6%
ARMA(4,8)	50,0%	63,0%
ARMA(5,7)	44,4%	51,9%
ARMA(6,6)	35,2%	42,6%
ARMA(7,5)	42,6%	35,2%
ARMA(8,4)	51,9%	53,7%
ARMA(9,3)	35,2%	59,3%
ARMA(10,2)	33,3%	46,3%
ARMA(11,1)	53,7%	66,7%
ARMA(12,0)	50,0%	64,8%
máximo	**61,1%**	**81,5%**
mínimo	**33,3%**	**35,2%**
média	**47,9%**	**56,6%**
desvio padrão	**9,1%**	**12,0%**

Para uma comparação com os resultados obtidos por Abou-Chadi e colaboradores [11], o treinamento com sinais normais e miopáticos foi repetido para modelos ARMA(p,20-p), com 20 coeficientes, para $0 \leq p \leq 20$. A classificação dos sinais de teste normais e miopáticos resultou nas taxas de acerto apresentadas na tabela 5.2.

Observa-se que, quando a classificação é feita por meio da SVM, a taxa média de acerto para os 21 modelos testados (70,8%) foi muito próxima à taxa obtida para o modelo auto-regressivo ARMA(20,0), de 69,4%. Além disso, nota-se que, para muitos modelos ARMA de 20 coeficientes, as taxas de acerto são sensivelmente superiores às obtidas com o modelo AR. Para o modelo ARMA(18,2), por exemplo, obteve-se uma taxa de acerto de 86,1% com a SVM.

Tabela 5.2: Taxas de acerto obtidas para cada um dos modelos ARMA(p,20-p), na separação entre sinais normais e miopáticos, utilizando-se o DLF e a SVM.

Modelo	DLF	SVM
ARMA(0,20)	61,1%	72,2%
ARMA(1,19)	63,9%	77,8%
ARMA(2,18)	63,9%	80,6%
ARMA(3,17)	61,1%	75,0%
ARMA(4,16)	83,3%	75,0%
ARMA(5,15)	58,3%	63,9%
ARMA(6,14)	61,1%	52,8%
ARMA(7,13)	72,2%	77,8%
ARMA(8,12)	63,9%	69,4%
ARMA(9,11)	80,6%	63,8%
ARMA(10,10)	72,2%	66,7%
ARMA(11,9)	58,3%	69,4%
ARMA(12,8)	77,8%	66,7%
ARMA(13,7)	72,2%	72,2%
ARMA(14,6)	72,2%	55,6%
ARMA(15,5)	75,0%	69,4%
ARMA(16,4)	77,8%	75,0%
ARMA(17,3)	83,3%	77,8%
ARMA(18,2)	61,1%	86,1%
ARMA(19,1)	58,3%	69,4%
ARMA(20,0)	77,8%	69,4%
máximo	**83,3%**	**86,1%**
mínimo	**58,3%**	**52,8%**
média	**69,3%**	**70,8%**
desvio padrão	**8,7%**	**7,8%**

Modelos ARMA(p,20-p), com 20 coeficientes, para $0 \leq p \leq 20$ também foram utilizados para comparações com o trabalho de Inbar e Noujaim [10]. Os resultados obtidos na separação entre sinais normais e patológicos, durante a primeira etapa de classificação, estão apresentados na tabela 5.3. Os resultados obtidos na separação entre sinais neuropáticos e miopáticos, após treinamento específico dos classificadores, estão apresentados na tabela 5.4.

Tabela 5.3: Taxas de acerto obtidas para cada um dos modelos ARMA(p,20-p), na separação entre sinais normais e patológicos, utilizando-se o DLF e a SVM.

Modelo	DLF	SVM
ARMA(0,20)	72,2%	74,1%
ARMA(1,19)	74,1%	75,9%
ARMA(2,18)	63,0%	66,7%
ARMA(3,17)	70,4%	63,0%
ARMA(4,16)	57,4%	72,2%
ARMA(5,15)	53,7%	77,8%
ARMA(6,14)	44,4%	64,8%
ARMA(7,13)	61,1%	64,8%
ARMA(8,12)	42,6%	64,8%
ARMA(9,11)	57,4%	51,9%
ARMA(10,10)	35,2%	68,5%
ARMA(11,9)	57,4%	66,7%
ARMA(12,8)	48,1%	61,1%
ARMA(13,7)	50,0%	64,8%
ARMA(14,6)	68,5%	72,2%
ARMA(15,5)	51,9%	72,2%
ARMA(16,4)	68,5%	57,4%
ARMA(17,3)	75,9%	77,8%
ARMA(18,2)	68,5%	81,5%
ARMA(19,1)	57,4%	66,7%
ARMA(20,0)	75,9%	81,5%
máximo	**75,9%**	**81,5%**
mínimo	**35,2%**	**51,9%**
média	**59,7%**	**68,9%**
desvio padrão	**11,7%**	**7,7%**

Em primeiro lugar, comparando-se sinais normais e partológicos ,observa-se que as taxas médias de acerto para todos os modelos ARMA considerados é menor ou igual à obtida com o modelo AR.

Entretanto, o valor médio para os modelos ARMA é maior que o valor obtido com o modelo AR, na separação entre sinais neuropáticos e miopáticos. Neste caso, observa-se que as taxas de acerto obtidas para modelos ARMA superam em muitas vezes aquelas obtidas para o modelo AR, como tanto com o DLF quanto com a SVM. O modelo ARMA(1,19) é um bom exemplo: as taxas de acerto foram 77,8% e 86,1%, para o DLF e para a SVM, respectivamente. Essas taxas são

perceptivelmente mais elevadas que respectivas taxas de 52,8% e 66,7%, obtidas a partir do modelo auto-regressivo ARMA(20,0).

Tabela 5.4: Taxas de acerto obtidas para cada um dos modelos ARMA(p,20-p), na separação entre sinais neuropáticos e miopáticos, utilizando-se o DLF e a SVM.

Modelo	DLF	SVM
ARMA(0,20)	72,2%	63,9%
ARMA(1,19)	77,8%	86,1%
ARMA(2,18)	75,0%	58,3%
ARMA(3,17)	75,0%	61,1%
ARMA(4,16)	69,4%	75,0%
ARMA(5,15)	75,0%	69,4%
ARMA(6,14)	66,7%	72,2%
ARMA(7,13)	66,7%	75,0%
ARMA(8,12)	63,9%	47,2%
ARMA(9,11)	83,3%	58,3%
ARMA(10,10)	83,3%	72,2%
ARMA(11,9)	55,6%	63,9%
ARMA(12,8)	72,2%	75,0%
ARMA(13,7)	66,7%	69,4%
ARMA(14,6)	66,7%	72,2%
ARMA(15,5)	77,8%	69,4%
ARMA(16,4)	72,2%	61,1%
ARMA(17,3)	72,2%	61,1%
ARMA(18,2)	52,8%	69,4%
ARMA(19,1)	66,7%	69,4%
ARMA(20,0)	52,8%	66,7%
máximo	**83,3%**	**86,1%**
mínimo	**52,8%**	**47,2%**
média	**69,7%**	**67,5%**
desvio padrão	**8,6%**	**8,2%**

Finalmente, foram separadas na tabela 5.5 as taxas de acerto obtidas na classificação de sinais normais, neuropáticos e miopáticos a partir de modelos ARMA(p,50-p), com 50 coeficientes, para que se pudessem comparar os resultados com os obtidos por Güler e Koçer [17].

Tabela 5.5: Taxas de acerto obtidas para cada um dos modelos ARMA(p,50-p), na separação entre sinais normais, neuropáticos e miopáticos, utilizando-se o DLF e a SVM.

Modelo	DLF	SVM
ARMA(0,50)	57,4%	48,1%
ARMA(1,49)	59,3%	64,8%
ARMA(2,48)	72,2%	57,4%
ARMA(3,47)	50,0%	63,0%
ARMA(4,46)	51,9%	53,7%
ARMA(5,45)	40,7%	44,4%
ARMA(6,44)	51,9%	51,9%
ARMA(7,43)	50,0%	50,0%
ARMA(8,42)	44,4%	48,1%
ARMA(9,41)	50,0%	40,7%
ARMA(10,40)	42,6%	42,6%
ARMA(11,39)	33,3%	48,1%
ARMA(12,38)	44,4%	42,6%
ARMA(13,37)	59,3%	33,3%
ARMA(14,36)	51,9%	33,3%
ARMA(15,35)	50,0%	38,9%
ARMA(16,34)	40,7%	42,6%
ARMA(17,33)	42,6%	42,6%
ARMA(18,32)	51,9%	40,7%
ARMA(19,31)	40,7%	40,7%
ARMA(20,30)	35,2%	48,1%
ARMA(21,29)	33,3%	44,4%
ARMA(22,28)	35,2%	37,0%
ARMA(23,27)	38,9%	33,3%
ARMA(24,26)	33,3%	42,6%
ARMA(25,25)	37,0%	42,6%
ARMA(26,24)	33,3%	46,3%
ARMA(27,23)	37,0%	38,9%
ARMA(28,22)	44,4%	37,0%
ARMA(29,21)	27,8%	46,3%
ARMA(30,20)	38,9%	31,5%
ARMA(31,19)	44,4%	40,7%
ARMA(32,18)	42,6%	42,6%
ARMA(33,17)	51,9%	48,1%
ARMA(34,16)	48,1%	42,6%
ARMA(35,15)	44,4%	44,4%
ARMA(36,14)	29,6%	40,7%
ARMA(37,13)	31,5%	38,9%
ARMA(38,12)	33,3%	48,1%
ARMA(39,11)	37,0%	42,6%
ARMA(40,10)	29,6%	42,6%
ARMA(41,9)	31,5%	46,3%
ARMA(42,8)	33,3%	44,4%
ARMA(43,7)	46,3%	40,7%
ARMA(44,6)	37,0%	48,1%
ARMA(45,5)	46,3%	40,7%
ARMA(46,4)	48,1%	46,3%
ARMA(47,3)	31,5%	53,7%
ARMA(48,2)	38,9%	44,4%
ARMA(49,1)	44,4%	74,1%
ARMA(50,0)	79,6%	70,4%
máximo	**79,6%**	**74,1%**
mínimo	**27,8%**	**31,5%**
média	**43,3%**	**45,4%**
desvio padrão	**10,5%**	**8,6%**

Neste caso, observa-se que as taxas obtidas com modelos ARMA são, em média, bastante inferiores àquelas obtidas com o modelo AR. Somente o modelo ARMA(49,1) resulta em uma taxa de acerto melhor que o modelo ARMA(50,0), quando utilizada a SVM. Portanto, não é vantajoso o uso de modelos ARMA(p,50-p) em comparação ao AR(50).

No entanto, é importante frisar que as comparações realizadas com os resultados da literatura sugerem que o uso de modelos ARMA de ordem pequena (12 ou 20) traz vantagens em relação ao uso de modelos AR. A seguir, os resultados obtidos neste trabalho, e detalhados no capítulo anterior, serão comparados entre si, de forma a analisar a viabilidade do uso de modelos ARMA no lugar dos modelos AR, com a finalidade de auxiliar a classificação diagnóstica de sinais de EMG.

Os resultados apresentados no capítulo anterior mostraram, em primeiro lugar, que, para modelos ARMA(p,q) com um número muito reduzido de coeficientes, ou seja, $(p + q) \leq 5$, as taxas de acerto são muito baixas, tanto para o DLF quanto para a SVM. Observando-se as figuras de 4.7 a 4.12, compreende-se que esse valor é devido ao classificador fornecer uma resposta enviesada, de forma que praticamente todos os sinais sejam colocados na mesma classe. Quando se utiliza o modelo ARMA(1,1), por exemplo, a SVM classifica todos os 54 sinais como neuropáticos enquanto o DLF os classifica como miopáticos. Conclui-se, desses resultados, que um número muito baixo de coeficientes ARMA é insuficiente para representar as diferenças entre os vários tipos de sinal.

Em segundo lugar, observam-se taxas de acerto elevadas para modelos ARMA(0,q), principalmente com o DLF. Contudo, quando se observa a figura 4.8, nota-se que a classificação de muitos dos sinais parece aleatória, variando muito para valores consecutivos de q. O sinal de número 40, por exemplo, foi classificado como

neuropático, normal e miopático, variando-se q de 51 a 53. Portanto, pode-se dizer que os modelos de média móvel ARMA(0,q) não seriam os mais adequados para a classificação diagnóstica de sinais de EMG. Esse comportamento aleatório também é bastante observado nos modelos ARMA(p,1), ARMA(p,2) e ARMA(2,q). Dentre os modelos com altas taxas de acerto de classificação, apenas os ARMA(p,0) e os ARMA(1,q) não apresentaram esse comportamento.

Para ambos os classificadores, as maiores taxas de acerto foram obtidas utilizando-se modelos auto-regressivos ARMA(p,0). Valores acima de 70% foram conseguidos com o DLF para vários modelos com $41 \leq p \leq 51$ e, com a SVM, para todos os modelos com $32 \leq p \leq 54$, sendo que muitos desses modelos levaram a taxas de acerto superiores a 80%.

As taxas de acerto mostradas nas figuras 4.5 e 4.6, aliadas aos resultados detalhados na figura 4.7, sugerem o uso de SVM em vez do DLF e modelos auto-regressivos ARMA(p,0) com $38 \leq p \leq 46$ pois, além de as taxas de acerto estarem quase sempre acima de 80%, a classificação da maioria dos sinais se mantém constante para variações moderadas de p.

Entretanto, há um outro grupo de modelos cujos resultados da classificação se destacam: os modelos ARMA(1,q). Quando se classificam os sinais de EMG utilizando SVM e modelos ARMA(1,q), obtêm-se taxas de acerto acima de 70% para diversos valores de q. Para $q = 11$ e $q = 12$, são observadas as maiores taxas de acerto, iguais a 81,5%. Este resultado é importante porque, quando se utilizam modelos AR, taxas de acerto acima de 80% só foram obtidas pela SVM quando se utilizam mais de 32 coeficientes. Os modelos ARMA(1,11) e ARMA(1,12), que possuem somente 12 e 13 coeficientes, respectivamente, possibilitaram a obtenção de taxas de acerto acima de 80%. Desse resultado, conclui-se que existem modelos ARMA que são capazes de

representar sinais de EMG com um número menor de coeficientes que os modelos AR, mantendo bons resultados na sua classificação.

Além disso, quando se observam as tabelas de 5.1 a 5.4, que comparavam modelos com número pequeno de coeficientes (até 20), observa-se que, em três das quatro tabelas, os modelos ARMA(1,q) produziram taxas de acerto superiores aos modelos auto-regressivos ARMA(p,0). Essa é outra evidência de que modelos do tipo ARMA(1,q) são mais eficazes na representação de sinais de EMG que os modelos auto-regressivos quando se utiliza um número pequeno de coeficientes.

Todos os resultados e conclusões apresentados nesta dissertação foram feitas com base em experimentos realizados com sinais de EMG de agulha, com duração de 800ms, e amostrados à taxa de 25000 amostras por segundo. Dado que muitos pesquisadores têm trabalhado com sinais de EMG de superfície [10-11,16-17] com a finalidade de classificação diagnóstica, poderiam ser sugeridos para o futuro trabalhos que apliquem a metodologia utilizada neste mestrado em sinais de EMG de superfície, apesar de esse não ser o tipo de sinal tradicionalmente utilizado em clínica [43].

Além disso, dado que a ordem ótima de um modelo AR para representar um dado sinal depende do seu número de amostras, também poderiam ser propostas pesquisas envolvendo um estudo da variação das taxas de acerto com a taxa de amostragem dos sinais ou com a duração dos mesmos.

Outra possibilidade de trabalho futuro poderia ser uma comparação entre o desempenho da SVM e o do perceptron multicamada, uma arquitetura de rede neural mais tradicional que a SVM, amplamente explorada na literatura [6,11-12,16-18].

Finalmente, o uso conjunto de parâmetros no domínio do tempo como número de cruzamentos de zero e reversões também poderia ser investigado, assim como

sua influência no desempenho da classificação, visto que a literatura registra bons resultados utilizando-se esses parâmetros [6,14-15].

Este mestrado permitiu concluir que o uso de SVMs e modelagem ARMA é válido junto a sinais de EMG, no diagnóstico de doenças neuromusculares. O desempenho da SVM, neste caso, é sensivelmente superior ao do tradicional DLF, visto que taxas de acerto acima de 80% só foram obtidas com a SVM. Além disso, verificou-se que modelos ARMA(1,q) com poucos coeficientes (12 ou 13) resultam em um desempenho de classificação que só é obtido por modelos AR que contenham mais de 32 coeficientes. Esse fato torna os modelos ARMA uma opção vantajosa para a representação de sinais de EMG, visto que necessitam de um número de coeficientes bem menor que um modelo auto-regressivo, tradicionalmente utilizado com essa finalidade.

Referências

[1] ROWLAND, L. P., "Diseases of the motor unit" In: KANDEL, E. R., SCHWARTZ, J. H., JESSEL, T. M., *Principles of Neuroscience*, 3.ed. East Norwalk: Appleton & Lange, 1991.

[2] CHRISTODOULOU, C. I., PATTICHIS, C. S., "Unsupervised pattern recognition for the classification of EMG signals", *IEEE Transactions on Biomedical Engineering*, 46(2):169-178, 1999.

[3] PRESTON, D. C., SHAPIRO, B. E., *Electromyography and Neuromuscular Disorders: Clinical-Electrophysiologic Corelations*, Boston: Butterworth-Heinemann, 1998.

[4] MERLETTI, R., PARKER, P. A., *Electromyography: Physiology, Engineering, and Noninvasive Applications*, Hoboken, New Jersey: John Wiley & Sons, 2004.

[5] OH, S. J., *Clinical Electromyography: Nerve Conduction Studies*, 2.ed. Baltimore: Williams & Wilkins, 1993.

[6] PATTICHIS, C. S., ELIA, A. G., "Autoregressive and cepstral analyses of motor unit action potentials", *Medical Engineering and Physics* 21(6-7):405-419, 1999.

[7] SUBASI, A., YILMAZ, M., OZCALIK, H. R., "Classification of EMG signals using neural network", *Journal of Neuroscience Methods* 156(1-2):360-367, 2006.

[8] XIE, H., WANG, Z., HUANG, H., QING, C., "Support vector machine in computer aided clinical electromyography", *Proceedings of the Second International Conference on Machine Learning and Cybernetics*, Xi'an, 2003.

[9] AVELINO, V. F., "Sistema de detecção e classificação para eletromiografia clínica". Dissertação de mestrado, São Paulo: Escola Politécnica da Universidade de São Paulo, 1992.

[10] INBAR, G. F., NOUJAIM, A. E., "On surface EMG spectral characterization and its application to diagnostic classification", *IEEE Transactions on Biomedical Engineering* 31(9):597-604, 1984.

[11] ABOU-CHADI, F. E., NASHAR, A., SAAD, M., "Automatic analysis and classification of surface electromyography", *Frontiers of Medical and Biological Engineering* 11(1):13-29, 2001.

[12] ABEL, E. W., ZACHARIA, P. C., FORSTER, A., FARROW, T. L., "Neural network analysis of the EMG interference pattern", *Medical Engineering and Physics*, 18(1):12-17, 1996.

[13] BARRIOS JR, R., "Sistema de tempo real para análise temporal do padrão de interferência eletromiográfico". Dissertação de mestrado, São Paulo: Escola Politécnica da Universidade de São Paulo, 1991.

[14] BERZUINI, C., MARANZANA-FIGINI, M., BERNARDINELLI, L., "Effective use of EMG parameters in the assessment of neuromuscular diseases", *International Journal of Bio-Medical Computing*, 13: 481-499, 1982.

[15] BERZUINI, C., MARANZANA-FIGINI, M., BERNARDINELLI, L., "Evaluation of the effectiveness of EMG parameters in the study of neurogenic diseases – a statistical approach using clinical and simulated data", *IEEE Transactions on Biomedical Engineering*, 32(1):15-27, 1985.

[16] GÜLER, N. F., KOÇER, S., "Classification of EMG signals using PCA and FFT", *Journal of Medical Systems*, 29(3):241-250, 2005.

[17] GÜLER, N. F., KOÇER, S., "Use of support vector machines and neural network in diagnosis of neuromuscular disorders", *Journal of Medical Systems*, 29(3):271-284, 2005.

[18] PIRES, P. H., "Classificação diagnóstica de sinais eletromiográficos por redes neurais artificiais". Dissertação de mestrado, São Paulo: Escola Politécnica da Universidade de São Paulo, 2005.

[19] IKE, I. K., "Modelagem auto-regressiva e memórias associativas na classificação de sinais eletromiográficos de agulha". Dissertação de mestrado, São Paulo: Escola Politécnica da Universidade de São Paulo, 2001.

[20] ITIKI, C., "Processamento de EMG por modelagem auto-regressiva: aspectos metodológicos". Dissertação de mestrado, São Paulo: Escola Politécnica da Universidade de São Paulo, 1991.

[21] MARPLE, S. L., JR., *Digital Spectral Analysis*, Englewood Cliffs: Prentice-Hall, 1987.

[22] GRUNENFELDER, R., COSMAS, J. P., MANTHORPE, S., ODINMA-OKAFOR, A., "Characterization of video codecs as autoregressive moving average process and related queueing system performance", *IEEE Journal on Selected Areas in Communications*, 9(3):284-293, 1991.

[23] TRENBERTH, K. E., HOAR, T. J., "The 1990-1995 El Nino southern oscillation event: longest on record", *Geophysical Research Letters*, 23(1):57-60, 1996.

[24] LÖFGREN, N., LINDECRANTZ, K., FLISBERG, A., BÅGENHOLM, R., KJELLER, I., THORDSTEI, N., "Spectral distance for ARMA models appalied to electroencepholagram for early detection of hypoxia", *Journal of Neural Engineering*, 3:227-234, 2006.

[25] SUBASI, A., "Application of classical and model-based spectar methods to describe the state of alertness in EEG", *Journal of Medical Systems*, 29(5):473-486, 2005.

[26] JACOBS, M. H., RAO, S. S., JOSÉ, G. V., "Parametric modeling of somatosensory evoked potentials", *IEEE Transactions on Biomedical Engineering*, 36(3):392-403, 1989.

[27] SAWAGUCHI, K., OGAWA, T., "Component wave analysis of flash visual evoked potentials in preterm infants", *Electroencephalography*, 108:62-72, 1998.

[28] LIN, Z., MARIS, J. HERMANS, L., VANDEWALLE, J., CHEN, J. D. Z., "Classification of normal and abnormal electrograstrograms using multilayer feedforward neural networks", *Medical and Biological Engineering and Computing*, 35:199-206, 1997.

[29] BARRETTO, M. Y., KOHN, A. F., ITIKI, C., "Modelagem auto-regressiva e discriminante linear de Fisher na classificação de sinais eletromiográficos de agulha", *Proceedings of the International Federation for Medical and Biological Engineering,* 5(1):939-942, 2004.

[30] BOSER, B., GUYTON, I., VAPNIK, V. N. "A training algorithm for optimal margin classifiers", *Fifth Annual Workshop on Computational Learning Theory*, San Mateo: Morgan Kaufmann, p. 144-152, 1992.

[31] CORTES, C., VAPNIK, V. N., "Support vector networks", *Machine Learning*, 20:273-297, 1995.

[32] HAYKIN, S., *Neural Networks: A Comprehensive Foundation*, 2.ed. Upper Saddle River, New Jersey: Prentice-Hall, 1999.

[33] ZHANG, T., OLES, F. J., "Text categorization based on regularized linear classification methods", *Information Retrieval*, 4:5-31, 2001.

[34] HAO, P. Y., CHIANG, J. H., TU, Y. K., "Hierarchically SVM classification based on support vector clustering method and its application to document categorization", *Expert Systems with Applications*, 33:627-635, 2007.

[35] WANG, Y., CHUA, C. S., HO, Y. K., "Facial feature detection and face recognition from 2D and 3D images", *Pattern Recognition Letters*, 23:1191-1202, 2002.

[36] KADOURY, S., LEVINE, M. D., "Face detection in gray scale images using locally linear embeddings", *Computer Vision and Image Undesrtanding*, 105:1-20, 2007.

[37] CAMASTRA, F., "A SVM-based cursive character recognizer", *Pattern Recognition*, 40:3721-3727, 2007.

[38] DING, C. H. Q., DUBCHAK, I., "Multi-class protein fold recognition using support vector machines and neural networks", *Bioinformatics*, 17(4):349-358, 2001.

[39] ONG, S. A. K., LIN, H. H., CHEN, Y. Z., LI, Z. R., CAO, Z., "Efficacy of different protein descriptions in predicting protein functional families", *BMC Bioinformatics*, 8:300, 2007.

[40] BAI, O., LIN, P., VORBACH, S., LI, J., FURLANI, S., HALLETT, M., "Exploration of computational methods for classification of movement intention during human voluntary movement from single trial EEG", *Clinical Neurophysiology*, 2007, no prelo.

[41] LIAO, X., YAO, D., LI, C., "Transductive SVM for reducing the training effort in BCI", *Journal of Neural Engineering*, 4:246-254, 2007.

[42] METHA, S. S., LINGAYAT, N. S., "Combined entropy based method for detection of QRS complexes in 12-lead electrocardiogram using SVM", *Computers in Biology and Medicine*, 2007, no prelo.

[43] LENMAN, J. A. R., RITCHIE, A. E. Clinical Electromyography. 4.ed. Edinburgh: Churchill Livingstone, 1987.

[44] AMINOFF, M. J. Electrodiagnosis in Clinical Neurology. 3.ed. New York: Churchill Livingstone, 1992.

[45] DUMITRU, D. Electrodiagnostic Medicine. Philadelphia: Hanley & Belfus, 1995.

[46] SCHEINBERG, P. An Introduction to Diagnosis and Management of Common Neurologic Disorders. 3.ed. New York: Raven Press, 1986.

[47] BROOKE, M. H. A Clinician's View of Neuromuscular Diseases. 2.ed. Baltimore: Williams & Wilkins, 1986.

[48] PERRY, J. Gait Analysis: Normal and Pathological Function. New York: McGraw Hill, 1992.

[49] DELISA, J. A., GANS, M. B. Rehabilitation Medicine: Principles and Practice. 2.ed. Philadelphia: Lippincott, 1993.

[50] BENDAT, J. S., PIERSOL, A. G. Random Data: Analysis and Measurement Procedures, 2.ed. New York: John Wiley & Sons, 1986.

[51] LJUNG, L., System Identification: Theory for the User, Englewood Cliffs: Prentice-Hall, 1987.

[52] KAGIWADA, H., KALABA, R., RASAKHOO, N., SPINGARN, K., Numerical Derivatives and Nonlinear Analysis, New York: Plenum Press, 1986.

[53] NADLER, M., SMITH, E. P., Pattern Recognition Engineering, New York: Wiley, 1993.

[54] KOHN, A. F., Reconhecimento de Padrões. Uma Abordagem Estatística, São Paulo: PEE/EPUSP, 1998.

[55] NGUYEN, D., WIDROW, B., "Improving the learning speed of 2-layer neural network by choosing initial values of the adaptive weights", IEEE First International Joint Conference on Neural Networks, 3:21-26, 1990.