

CECÍLIA ROMARO

Varição da Ordem Ótima do Modelo Autorregressivo com a Força de Contração
Muscular e a Duração do Eletromiograma

São Paulo

2015

CECÍLIA ROMARO

Varição da Ordem Ótima do Modelo Autorregressivo com a Força de Contração Muscular e a Duração do Eletromiograma

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

São Paulo

2015

CECÍLIA ROMARO

Varição da Ordem Ótima do Modelo Autorregressivo com a Força de Contração Muscular e a Duração do Eletromiograma

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Engenharia Biomédica.

Orientadora: Profa. Dra. Cinthia Itiki.

São Paulo

2015

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 29 de abril de 2015

Assinatura do autor: _____

Assinatura do orientador: _____

Catálogo-na-publicação

Romaro, Cecília

Varição da ordem ótima do modelo autorregressivo com a força de contração muscular e a duração do eletromiograma / C. Romaro -- versão corr. - São Paulo, 2015.

83 p.

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

1.Eletromiografia 2.Bioengenharia I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Telecomunicações e Controle II.t.

*Dedico este trabalho ao mundo, em especial,
a todos os estudantes que, de alguma forma,
desejam um mundo melhor.*

AGRADECIMENTOS

Agradeço à minha professora e orientadora Cinthia Itiki, pessoa que mais contribuiu, tanto profissionalmente quanto pessoalmente, para a conclusão deste trabalho. Sou muito grata por toda a paciência e impaciência que teve comigo, por todos os “puxões de orelha”, conversas e orientações, além de estar sempre atenta aos prazos (mais do que eu) e me lembrar deles. Obrigada professora.

Também agradeço ao Prof. Dr. Sanders (Duke University) pelo banco de dados, ao CNPq por um ano de apoio. E a Deus, é claro.

“Begin at the beginning (...) and go on till you come to the end: then stop.”

Lewis Carrol.

RESUMO

Os sinais de eletromiografia de agulha podem ser modelados por um sistema linear invariante no tempo (SLIT). A pergunta é: Quantos coeficientes são necessários para tal? O presente mestrado estuda, para sinais de eletromiografia de agulha gravados sob as mesmas condições experimentais, como varia o número ótimo de coeficientes autorregressivos com o comprimento das épocas e com a força de contração muscular concomitantemente. O estudo foi realizado tendo como base sinais de 10%, 25%, 50% e 80% da máxima contração voluntária (MCV) e tendo épocas de 500ms, 250ms, 100ms, 50ms e 25ms de seis indivíduos normais. Desta forma, uma função densidade de probabilidade é sugerida para a ordem do modelo autorregressivo que melhor descreva o sinal de eletromiografia obtido a uma “força de contração” específica e que tenha uma “duração de época” definida.

Palavras-chave: Sistema linear invariante no tempo (SLIT). Eletromiografia de agulha. Modelo autorregressivo. Contração muscular.

ABSTRACT

Needle electromyography signals (EMG) can be modeled by a linear time-invariant system (LTI). The posed question is "How many coefficients are needed for an adequate modeling?" This Master's dissertation studies how the optimal number of autoregressive coefficients changes concomitantly with the epoch length and the muscle contraction force for needle electromyography signals recorded under the same experimental conditions. The study was conducted on signals from six normal individuals at 10%, 25%, 50% and 80% of the maximum voluntary contraction and epoch lengths of 500ms, 250ms, 100ms, 50ms and 25ms. Thus, a probability density function is suggested for the autoregressive model order that best describes the electromyographic signal obtained at a specific "contraction force" and has a defined "epoch length".

Keywords: Linear time-invariant system. Needle electromyography. Autoregressive model. Muscle contraction.

LISTA DE FIGURAS

- Figura 1** – Sinal captado na Eletromiografia pelo acionamento de uma unidade motora: somatória de sinais gerados pela despolarização da membrana e contração das fibras musculares inervadas por aquele motoneurônio. Fonte: Adaptado de Luca, 1979 e Cunha, 2002.22
- Figura 2** – Sinais típicos de eletromiografia para músculo em repouso, contração fraca e contração forte, provenientes de indivíduo normal.23
- Figura 3** – Divisão do quinto sinal do indivíduo 6, obtido a 80%MCV. Um sinal de 500ms (A) dá origem a (B) duas épocas de 250ms (roxo), (C) cinco épocas de 100ms (rosa), (D) dez épocas de 50ms (vermelho) e (E) vinte épocas de 25ms (laranja).25
- Figura 4** – Numeração dos sistemas lineares invariantes no tempo (SLIT), de acordo com a porcentagem da máxima contração voluntária e a duração da época. No presente trabalho, os sistemas foram considerados do tipo autorregressivo.27
- Figura 5** – Sistema autorregressivo com ruído branco desconhecido $e(t)$ na entrada e sinal de eletromiografia $y(t)$ na saída. Imagem cedida por C. Itiki (2012).27
- Figura 6** – Critério de otimização para uma época de 500ms e 50% da máxima contração voluntária. A ordenação selecionada que minimiza o critério MDL foi 11. Imagem cedida por C. Itiki (2012).29
- Figura 7** – Ordens selecionadas pelo critério MDL para o quinto sinal do indivíduo 6, obtido a 80%MCV e dividido em épocas. As ordens selecionadas para as épocas estão fornecidas nas cores laranja (25ms), vermelho (50ms), rosa (100ms), roxo (250ms) e azul marinho (500ms) e correspondem respectivamente às ordens dos sistemas lineares invariantes no tempo de número 16, 17, 18, 19 e 20 ilustrados na Figura 4.30
- Figura 8** – Histograma de duração da época por ordem ótima do indivíduo 5, para uma força de contração fixa em 80%.31

Figura 9 – Histograma de força de contração por ordem ótima do indivíduo 5, para uma duração de época fixa em 100ms.....	32
Figura 10 – Densidade de probabilidade χ^2 para três a seis graus de liberdade.....	35
Figura 11 – Distribuição das ordens ótimas por indivíduo e força de contração mantendo época fixa em 25ms.....	43
Figura 12 – Distribuição das ordens ótimas por indivíduo e força de contração mantendo época fixa em 50ms.....	44
Figura 13 – Distribuição das ordens ótimas por indivíduo e força de contração mantendo época fixa em 100ms.....	45
Figura 14 – Distribuição das ordens ótimas por indivíduo e força de contração mantendo época fixa em 250ms.....	46
Figura 15 – Distribuição das ordens ótimas por indivíduo e força de contração mantendo época fixa em 500ms.....	47
Figura 16 – Distribuição percentual das ordens ótimas por duração de época e força de contração. Resultados para (a) 10%MCV, (b) 25%MCV, (c) 50%MCV e (d) 80%MCV. Cada linha representa os resultados para um comprimento de época. O degradê de azul a bordô indicam uma concentração crescente de coeficientes chegando a 40%.	49
Figura 17 – Histogramas normalizados da ordem ótima.	51
Figura 18 – Ajuste da função densidade de probabilidade Gaussiana.....	55
Figura 19 – Ajuste da função densidade de probabilidade LogNormal.	56
Figura 20 – Ajuste da função densidade de probabilidade Weibull	57
Figura 21 – Ajuste da função densidade de probabilidade Poisson	58
Figura 22 – Ajuste da função densidade de probabilidade Gama	59
Figura 23 – Distribuição das fibras musculares de unidades motoras do músculo gastrocnêmio: a) em indivíduos normais, as fibras musculares de dois tipos são distribuídas de forma aleatória; enquanto que b) em indivíduos neuropáticos, as fibras musculares de mesmo tipo se agrupam, pois as fibras reinervadas assumem as mesmas características das demais fibras da unidade motora. Fonte: Adaptado de Kandel (2003, p. 698).....	80

Figura 24 – Sinais típicos de eletromiografia para músculo em repouso, contração fraca e contração forte, provenientes de indivíduos a) normal; b) neuropático e c) miopático.....82

LISTA DE TABELAS

Tabela 1 – Ordens do modelo autorregressivo utilizadas na literatura.	17
Tabela 2 – Teste de Friedman para épocas de 25 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 140 repetições.	52
Tabela 3 – Teste de Friedman para épocas de 50 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 70 repetições.	52
Tabela 4 – Teste de Friedman para épocas de 100 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 35 repetições.	53
Tabela 5 – Teste de Friedman para épocas de 250 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 14 repetições.	53
Tabela 6 – Teste de Friedman para épocas de 500 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 7 repetições.	53
Tabela 7 – Erro quadrático para distribuição Gaussiana.	60
Tabela 8 – Erro quadrático para distribuição LogNormal.	60
Tabela 9 – Erro quadrático para distribuição Gama.	61
Tabela 10 – Erro quadrático para distribuição Poisson.	61
Tabela 11 – Erro quadrático para distribuição Weibull.	61
Tabela 12 – Distribuição que apresentou o maior erro quadrático para cada SLIT. .	62
Tabela 13 – Maior erro quadrático dentre as distribuições de Poisson e Gaussiana.	63
Tabela 14 – Maior erro quadrático dentre as distribuições de Poisson e Weibull.	63

LISTA DE ABREVIATURAS E SIGLAS

AR	Autorregressivo
EMG	Eletromiografia
MCV	Máxima Contração Voluntária
PAUM	Potencial de Ação de Unidade Motora
PA	Potencial de Ação
SLIT	Sistema Linear Invariante no Tempo
SNC	Sistema Nervoso Central

SUMÁRIO

1. INTRODUÇÃO	15
1.1. REVISÃO BIBLIOGRÁFICA	15
1.2. OBJETIVO	18
1.3. PORQUE USAR UM SISTEMA AUTORREGRESSIVO	18
1.4. EXEMPLOS DE APLICABILIDADE	19
1.5. ORGANIZAÇÃO DA DISSERTAÇÃO	20
2. ELETROMIOGRAFIA	21
2.1. UNIDADE MOTORA	21
2.2. SINAL MIOELÉTRICO	22
2.3. ELETROMIOGRAFIA CLÍNICA	23
3. METODOLOGIA	24
3.1. BANCO DE DADOS	24
3.1.1 <i>Banco de sinais de eletromiografia</i>	24
3.1.2 <i>Banco de épocas de eletromiografia</i>	25
3.1.3 <i>Banco de sistemas autorregressivos</i>	26
3.1.4 <i>Banco de ordens ótimas</i>	28
3.2. HISTOGRAMA DE ORDENS	31
3.3. ANÁLISE ESTATÍSTICA	33
3.4. AJUSTE DE FUNÇÕES DENSIDADE DE PROBABILIDADE	36
3.4.1 <i>Normalização dos histogramas</i>	36
3.4.2 <i>Função densidade de probabilidade</i>	36
3.5. CÁLCULO DO ERRO QUADRÁTICO	38
4. RESULTADOS	40
4.1. ORDEM ÓTIMA	40
4.1.1 <i>Resultados individuais</i>	40
4.1.2 <i>Resultados globais</i>	48
4.2. HISTOGRAMAS DE ORDENS	50
4.2.1 <i>Resultados globais por duração</i>	50
4.2.2 <i>Resultados globais por força</i>	51

4.3	ANÁLISE ESTATÍSTICA	52
4.4	AJUSTE DE FUNÇÕES DENSIDADE DE PROBABILIDADE	54
4.5	ERRO QUADRÁTICO	60
4.5.1	<i>Melhores ajustes: LogNormal e Gama</i>	61
4.5.2	<i>Piores ajustes: Gaussiana, Poisson e Weibull</i>	62
4.5.3	<i>Pior e melhor ajuste: Gaussiana e LogNormal</i>	64
5.	DISCUSSÃO	65
5.1	ORDEM ÓTIMA, FORÇA DE CONTRAÇÃO E DURAÇÃO DA ÉPOCA	65
5.1.1	<i>Efeito da duração da época na ordem</i>	65
5.1.2	<i>Efeito da força de contração na ordem</i>	66
5.2	DISTRIBUIÇÕES E ERRO QUADRÁTICO	67
5.2.1	<i>Melhores Ajustes: LogNormal e Gama</i>	67
5.2.2	<i>Piores ajustes: Gaussiana, Poisson e Weibull</i>	68
5.2.3	<i>Pior e Melhor Ajuste: Gaussiana e LogNormal</i>	69
6.	TRABALHOS FUTUROS E CONCLUSÃO	70
6.1	TRABALHOS FUTUROS	70
6.1.1	<i>Outras distribuições</i>	70
6.1.2	<i>Casos patológicos</i>	70
6.2	CONCLUSÃO	73
	REFERÊNCIAS	74
	APÊNDICE	78
	APÊNDICE A –DOENÇAS NEUROMUSCULARES	79
A.1	<i>Miopatia e Neuropatia</i>	79
A.2	<i>Crítérios clínicos e dosagem de enzimas para o diagnóstico</i>	81
A.3	<i>Eletromiografia para o diagnóstico</i>	81
	APÊNDICE B – FATORAÇÃO QR	83

1. INTRODUÇÃO

1.1. Revisão Bibliográfica

Sinais de eletromiografia (EMG) podem ser usados para classificar movimentos. Huang e colaboradores (2012), por exemplo, classificaram trechos de 256ms de duração de sinais de EMG de superfície por uma rede neural de três camadas. Utilizando coeficientes do modelo autorregressivo (AR) combinado com informações do domínio do tempo como o valor médio do sinal, obtiveram mais de 95% de taxa de acerto na classificação do movimento da mão direita entre oito classes de movimentos (flexão do punho, extensão do punho, etc.) em dez indivíduos. (Huang et al., 2012)

Zhang e colegas (2010) utilizam modelo AR variante no tempo para análise de fadiga muscular durante contrações musculares isométricas e também discute a ineficiência de métodos convencionais quando se usam curtos trechos de sinal eletromiografia de superfície. (Zhang et al., 2010)

Levando em consideração que o movimento muscular acarreta um deslocamento do eletrodo, atrapalhando, assim, o reconhecimento de padrões nos sinais de EMG de superfície, Young e colaboradores (2012) estudaram como reduzir a influência desse deslocamento e tornar mais robusto os sistemas de reconhecimento de padrões. Concluíram que adotar medidas como posicionar os eletrodos longitudinalmente ou perpendicularmente ao sentido das fibras musculares, atentar-se à quantidade de eletrodos necessária (de quatro a seis canais) e a distância ótima entre eletrodos (4cm), além de utilizar o processamento AR ao invés do domínio no tempo melhoram o desempenho do reconhecimento de padrões e reduzem o erro de classificação. (Young et al., 2012)

Inbar e Noujaim (1984) estudaram a possibilidade de substituir o exame de eletromiografia de agulha por eletromiografia de superfície para alguns casos. Utilizando sinais correspondentes a 50%MCV e 500ms de duração, concluíram que a ordem adequada do modelo AR seria de vinte coeficientes. A partir deste ponto, utilizando 10 sinais por indivíduo desenvolveram um método para classificar entre

normais ou anormais, estando nesta última classe tanto indivíduos miopáticos como neuropáticos, O método indicou um falso negativo apenas para o caso limítrofe presente em um dos três indivíduos anormais, dentre um total de oito indivíduos previamente diagnosticados com o auxílio de exames de eletromiografia de agulha, ou seja, obteve-se 87,5% de taxa de acerto. Inbar e Noujaim concluíram que, embora um aperfeiçoamento e mais testes sejam necessários, esta aplicação é interessante para casos especiais nos quais a eletromiografia de agulha é inviabilizada. (Inbar e Noujaim, 1984)

Em 1982, Berzuini e colaboradores realizaram uma revisão dos possíveis processamentos do sinal de EMG de agulha com a finalidade de conseguir classificá-los entre normais, miopáticos ou com disfunções neurológicas. Concluiu-se que as análises no domínio do tempo são mais eficientes que as análises no domínio da frequência e, no entanto, a combinação dos dois seria o caminho para melhorar os meios de classificação. (Berzuini et al., 1982)

Pattichis e Elia (1999) comparam o desempenho de quatro análises para classificar indivíduos em normais, miopáticos e neuropático a partir do potencial de ação de unidade motora presentes nos sinais de EMG de agulha. As análises foram classificadas de acordo com a performance das redes neurais, isto é, maior taxa de acerto, na seguinte ordem: parâmetros do domínio do tempo, coeficientes cepstrais, parâmetros espectrais do modelo AR e por fim, e pior desempenho, os coeficientes AR. Utilizando um método automático de reconhecimento de potencial de ação de unidade motora (PAUM) nas épocas de 25,6 ms de duração, as análises de coeficientes cepstrais e coeficientes AR foram baseadas em 12 coeficientes. Pattichis e Elia concluíram, similarmente a Berzuini e colaboradores, que a utilização dos parâmetros do domínio do tempo e da frequência, combinados entre si, seria o caminho para auxiliar o diagnóstico de doenças neuromusculares como a miopatologia. (Pattichis e Elia, 1999)

A tabela 1 resume as ordens encontradas na literatura, conforme a aplicação específica, a duração e o número de amostras dos sinais de EMG. A grande gama de ordem usada (2 a 50), assim como a de duração da época (25,6 ms a 5.000 ms), à primeira vista, indicaria a necessidade de ordens ótimas diferentes para aplicações diferentes; no entanto, intrinsecamente esta variedade pode indicar a inconsciência da ordem ideal. Vista por outro ângulo, cada trabalho escolheu a ordem ótima

isoladamente e esta escolha pode ter interferido no melhor ou pior resultado da pesquisa.

Tabela 1 – Ordens do modelo autorregressivo utilizadas na literatura.

Aplicação	Ordem	Duração (ms)	Número de amostras
Reconhecimento de movimentos (J. Chiang et al., 2007; Latwesern e Patterson, 1994)	4	50 – 300	30 – 300
Controle de próteses (Chiou et al., 2004; Chen et al., 2009)	4 – 6	3000 – 5000	5000 – 6000
Fadiga muscular (Clancy et al., 2005; Karlsson e Yu, 2000; Paiss e Inbar, 1987)	2 – 30	500 – 512	256 – 2048
Diagnóstico de doenças neuromusculares (Inbar e Noujaim, 1984; Pattichis e Elia, 1999; Güler e Koçer, 2005)	10 – 50	25,6 – 4000	256 – 20000

Inbar e Noujaim (1987), utilizando eletromiografia de superfície, obtiveram taxas de acerto significativamente maiores que Pattichis e Elia (1999), mesmo tendo estes utilizado o método clínico atual: eletromiografia de agulha. Surge então uma indagação. Será que o número de coeficientes, força ou duração da época influenciaram a diferença entre estes resultados?

Os trabalhos de Itiki (2002), Shirota e Itiki (2002), Itiki (2012), Vicente e Itiki (2014) estudaram a influência da duração da época e do critério de otimização na escolha da ordem ótima do modelo AR para eletromiogramas normais, miopáticos e neuropáticos. Porém, nenhum trabalho anterior estudou como varia o número ótimo de coeficientes AR com o comprimento das épocas e com a força de contração muscular concomitantemente, para sinais de EMG de agulha gravados sob as mesmas condições experimentais (Romaro e Itiki, 2014).

1.2. Objetivo

O objetivo deste trabalho é estudar como varia o número ótimo de coeficientes AR com o comprimento das épocas e com a força de contração muscular concomitantemente, para sinais de EMG de agulha gravados sob as mesmas condições experimentais. Desta forma, uma função densidade de probabilidade é sugerida para a ordem do modelo AR que melhor descreva o sinal de EMG obtido a uma “força de contração” específica e que tenha uma “duração da época” definida.

1.3. Porque Usar um Sistema Autorregressivo

Há modelos que representam a resposta mecânica do músculo como, por exemplo, os modelos que representam suas propriedades viscoelásticas (Hill, 1953).

Há também modelos que representam a geração de sinais elétricos. A modelagem de sinais de eletromiografia pode se basear fortemente na Neurofisiologia, incluindo equações que descrevam a geração (Hodgkin e Huxley, 1952) e propagação de potenciais de ação nos neurônios e fibras musculares (Merletti et al., 1999). Também pode considerar o número e o tipo de neurônios e fibras musculares, além das conexões sinápticas entre eles (Vieira e Kohn, 2007).

No entanto, nesta dissertação, adotou-se a abordagem de caixa preta. Os sinais de eletromiografia são representados como saídas de sistemas lineares invariantes no tempo (SLIT), em particular, sistemas AR. Não há uma associação direta entre os elementos anatômico-fisiológicos do músculo e os sistemas AR. Porém, o uso da modelagem AR do sinal de EMG é mais do que justificado pela literatura, conforme indicado na Tabela 1. Além disso, o uso de sistemas AR para o diagnóstico de doenças neuromusculares se provou mais eficiente do que os demais sistemas lineares, sejam eles de média móvel ou autorregressivos de média móvel (Barretto, 2007).

1.4. Exemplos de Aplicabilidade

O estudo de como varia a ordem ótima do modelo AR necessário para modelar sinais EMG já é uma aplicação academicamente interessante por si só, uma vez que estuda intrinsecamente como a complexidade do sinal, e de sua representação, varia com o comprimento de época e a força aplicada. Na prática, este estudo pode ser usado como ferramentas didáticas e diagnósticas.

Em aplicações diagnósticas, os indivíduos normais têm uma quantidade de unidades motoras, e cada unidade motora comanda um número de fibras musculares. Indivíduos com miopatia, por exemplo, apresentam o mesmo número de unidades motoras, mas cada unidade motora comanda um número reduzido de fibras musculares. Em contra partida, indivíduos com neuropatia apresentam um número menor de unidades motoras, mas, para compensar, cada unidade comanda um número maior de fibras musculares (Kandel, 2003). Claramente a modelagem destes três sistemas é diferente. O estudo foi realizado apenas para indivíduos normais, logo o mesmo padrão encontrado para estes indivíduos não deve necessariamente se repetir em indivíduos com patologia como miopatia ou neuropatia. Ou seja, a extensão deste estudo para indivíduos com miopatia (Vicente e Itiki, 2014) ou neuropatia deve ser realizada, porque pode revelar resultados passíveis de auxiliar diagnósticos médicos.

Do ponto de vista didático, atualmente os médicos são treinados a interpretar e reconhecer visual e auditivamente sinais normais e patológicos. O exame de eletromiografia utiliza eletrodos de agulha que são invasivos, implicam na possibilidade de infecção além de causar dor ou desconforto, já que o exame exige a contração muscular com eletrodos inseridos no músculo. Tendo estes fatores em mente percebe-se que o registro dos sinais de EMG de agulha é difícil de ser obtido de voluntários sem doenças neuromusculares. E paralelamente a isto, no caso do nosso país, a restrição à remuneração apresenta a impossibilidade de se incentivar o aumento do número de voluntários. A captação de sinais de EMG de indivíduos normais demandaria a total abnegação dos voluntários, tanto em termos de tolerância à dor física quanto de disponibilidade de tempo. Nesse contexto, a utilização de sinais de EMG gerados por simuladores computacionais se torna

extremamente atraente para fins didáticos, pois permite gerar sinais com características normais para servirem de ilustração nas aulas.

1.5. Organização da Dissertação

O capítulo 2 faz uma rápida revisão da parte biológica para explicar o que é um eletromiograma.

A metodologia, apresentada no capítulo 3, descreve nas subseções a parte teórica e cronológica desde o banco de dados até o cálculo do erro. Explica a escolha dos tamanhos dos trechos, a análise estatística necessária, criação dos SLIT e ajuste de diferentes distribuições aos histogramas normalizados.

Os resultados, expostos no capítulo 4, são apresentados e comparados tanto por indivíduo como por grupo de mesma força de contração ou época com o auxílio de diferentes recursos de apresentação visual como tabelas e histogramas em escala de cores. Os resultados e tendências observadas ganham supostas explicações no capítulo 5.

Os trabalhos futuros aparecem tanto dos resultados não esperados como da continuação do trabalho para comprovar a teoria levantada. Estas linhas sugeridas e a conclusão da dissertação são apresentadas no capítulo 6.

2. ELETROMIOGRAFIA

2.1. Unidade Motora

A unidade motora é constituída por um neurônio motor e as fibras musculares que ele inerva (Bear, 2008)

Uma única unidade motora pode ser encarregada de ativar mais de mil fibras ou apenas meia dúzia delas, dependendo da funcionalidade daquela unidade. Quando encarregada de executar movimentos finos, isto é, de alta precisão, como o movimento ocular ou dedos da mão - cada unidade motora comanda poucas fibras musculares. Nestes movimentos um motoneurônio pode inervar apenas três fibras, por exemplo. Em contrapartida, quando a força é exigida, centenas ou milhares de fibras respondem a uma única unidade motora. Uma unidade motora dos músculos antigravitacionais da perna, por exemplo, ativa em média mais de 1.000 fibras e uma unidade do sistema digestivo comanda duas mil fibras. (Kandel, 2003, Bear, 2008).

Quanto maior é a força do movimento muscular, mais ramificados são os axônios dos neurônios motores para atingir mais fibras neuromusculares que por consequência apresenta menor precisão. Quanto menos ramificados são os axônios dos neurônios motores, menos fibras musculares ele atinge e mais específico fica o movimento; no entanto, com menor intensidade.

De forma geral, um músculo contém unidades motoras que inervam números diferentes de fibras. Para contrair este músculo, o recrutamento é ordenado, isto é: primeiramente são acionadas as unidades menores, que comandam um pequeno número de fibras; gradativamente são acionadas unidades maiores, conforme uma maior força é solicitada. Esta é a segunda maneira pela qual o sistema nervoso central (SNC) gradua a contração muscular e explica por que é possível ter um controle fino do movimento para cargas leves, e este controle é perdido para cargas maiores. Em outras palavras, existe uma relação inversamente proporcional entre a precisão e a força do movimento muscular. (Bear, 2008)

A primeira forma pela qual o SNC controla a contração muscular é pela frequência de disparo dos motoneurônios. Uma alta taxa de acionamento causa uma somação temporal, retifica a contração resultando numa força maior. (Bear, 2008)

2.2. Sinal Mioelétrico

O sinal mioelétrico ou eletromiografia é o sinal da somatória das unidades motoras acionadas, de acordo com a Figura 1. A amplitude do sinal mioelétrico está diretamente relacionada com a força exercida, tendo como base sinais de um mesmo paciente. A frequência entre os impulsos e a força apresentam outra relação interessante: quanto maior é a frequência, maior é a força. A fadiga muscular acarreta na diminuição forçada a frequência dos pulsos. Fadigados, os músculos passam a não responder à força exigida, fato evidenciado na diminuição da frequência. (Kandel, 2003)

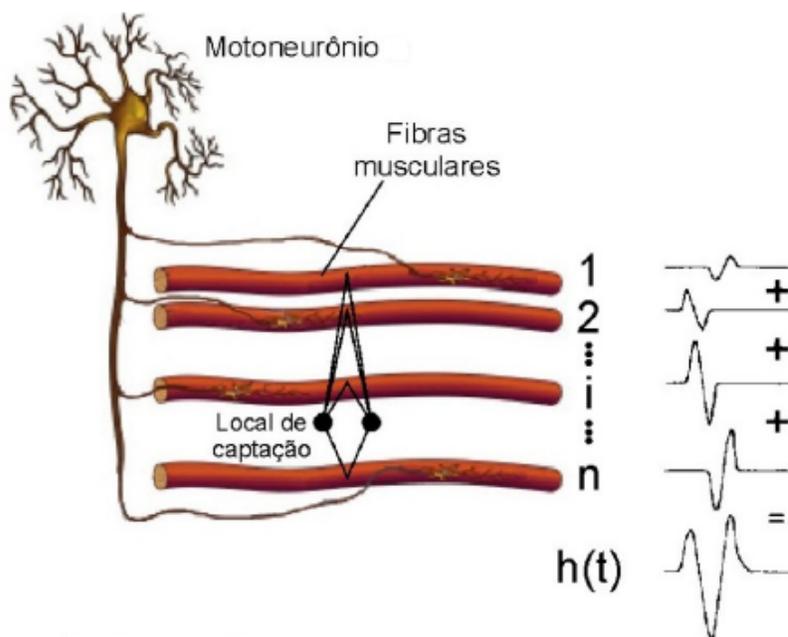


Figura 1 – Sinal captado na Eletromiografia pelo acionamento de uma unidade motora: somatória de sinais gerados pela despolarização da membrana e contração das fibras musculares inervadas por aquele motoneurônio. Fonte: Adaptado de Luca, 1979 e Cunha, 2002.

2.3. Eletromiografia Clínica

A eletromiografia de agulha é um recurso laboratorial utilizado para diagnóstico entre miopatia e neuropatia. Ela consiste em inserir uma fina agulha no interior do músculo para assim registrar as atividades das unidades motoras que têm suas fibras musculares próximas à agulha.

Em uma unidade motora sem anomalia espera-se não haver atividade muscular registrada no repouso. A amplitude do potencial gerado por esta unidade motora depende do número de fibras musculares que ela engloba. Quanto maior a força exercida pelo paciente, mais intenso será o padrão de interferência registrado e maior será o número e a frequência de unidades motoras recrutadas. No entanto, a amplitude do sinal de eletromiografia pouco se altera (Figura 2).

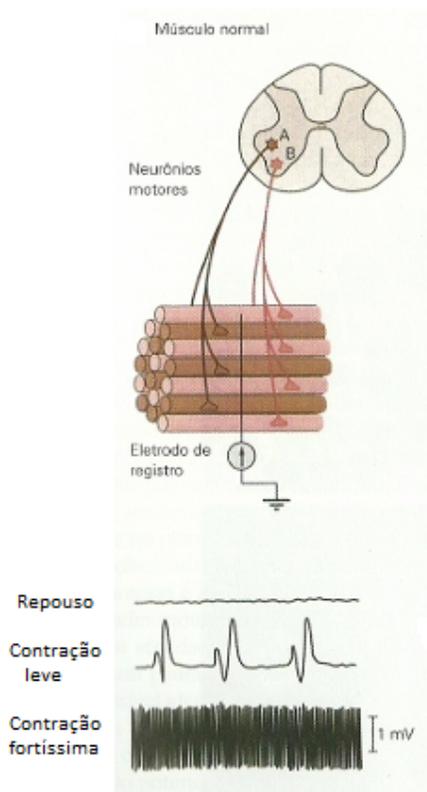


Figura 2 – Sinais típicos de eletromiografia para músculo em repouso, contração fraca e contração forte, provenientes de indivíduo normal.
Fonte: Kandel (2003, p.697)

3. METODOLOGIA

3.1. Banco de Dados

3.1.1 Banco de sinais de eletromiografia

A captação dos eletromiogramas foi realizada pela equipe do Prof. Donald Sanders, da *Duke University*, Estados Unidos da América e de acordo com os princípios da Declaração de Helsinque. Seis sujeitos normais realizaram as contrações isométrica em patamares isotônicos equivalentes a 10%, 25%, 50% e 80% da máxima contração voluntária (MCV). Os sinais de EMG do músculo braquial foram captados por meio de eletrodos de agulha concêntricos. Os eletrodos foram posicionados em 10 locais diferentes de captação para cada indivíduo, no entanto apenas 7 destes sinais foram utilizados neste trabalho, não sendo possível identificá-los. Os sinais de EMG foram pré-condicionados por um eletromiógrafo: amplificados de 100 a 1.000 vezes e filtrados por um passa-baixas com frequência de corte de 10kHz. Na sequência, foram codificados por um PMC-2 e gravados em uma fita de vídeo para transporte.

A aquisição dos eletromiogramas foi realizada no Laboratório de Engenharia Biomédica da Escola Politécnica da Universidade de São Paulo (LEB-EPUSP), por Ike (2001). O banco de sinais captados na *Duke University* foi, então, cedido para o LEB, onde foi decodificado. Os sinais decodificados foram digitalizados por um conversor analógico-digital de 12 bits à taxa de amostragem de 25kHz. A conversão foi realizada pelos software AqDados versão 4.17 e placa CAD 12/36, ambos da Lynx Tecnologia Eletrônica Ltda. A conversão dos arquivos (inicialmente em complemento de 2 e formato compatível com AqDados) para o formato ASCII, compatíveis com MATLAB foi realizada pelo programa cnvasc.exe desenvolvido anteriormente no próprio LEB e usado no mestrado de Ike (2001)

3.1.2 Banco de épocas de eletromiografia

A seleção dos sinais de 500ms e trechos usados nesta dissertação de mestrado foi realizada no LEB-EPUSP por Itiki (2012). Dos arquivos digitalizados, dentre os sinais de 500 ms, do início de cada patamar de força de contração muscular (10%, 25%, 50% e 80% da MCV), os classificados como estacionários na média e variância, segundo o teste de sequências (*run test*) de Wald e Wolfowitz (1948), foram selecionados.

Cada um desses sinais selecionados de 500ms foi então dividido em dois trechos de 250ms, cinco trechos de 100ms, dez trechos de 50ms e vinte trechos de 25ms de duração, conforme ilustrado na Figura 3. A faixa de durações de 25ms a 500ms foi escolhida para englobar os valores usuais de duração mencionados na literatura (Inbar e Noujaim, 1984; Pattichis e Elia, 1999; Itiki, 2012).

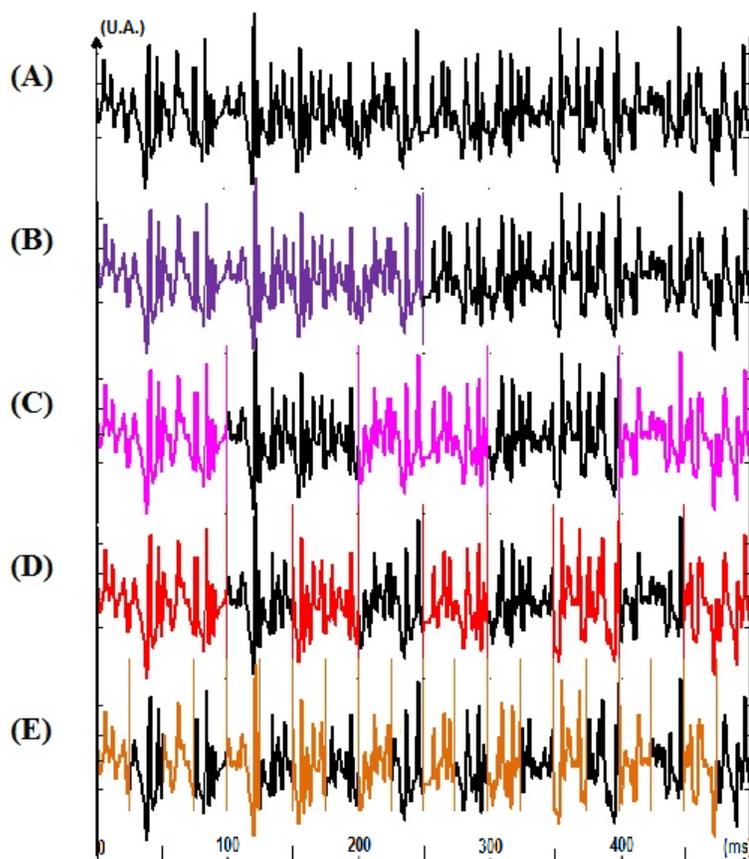


Figura 3 – Divisão do quinto sinal do indivíduo 6, obtido a 80%MCV. Um sinal de 500ms (A) dá origem a (B) duas épocas de 250ms (roxo), (C) cinco épocas de 100ms (rosa), (D) dez épocas de 50ms (vermelho) e (E) vinte épocas de 25ms (laranja).

Como resultado, obtiveram-se para cada sujeito 28, 56, 140, 280 e 560 trechos de 500ms, 250ms, 100ms, 50ms e 25ms de duração, igualmente distribuídos entre as quatro forças de contração muscular. Considerando-se os seis sujeitos, tem-se 168, 336, 840, 1680 e 3360 trechos de 500ms, 250ms, 100ms, 50ms e 25ms de duração respectivamente, totalizando 6384 épocas igualmente distribuídos entre as quatro forças de contração muscular e usadas nesta dissertação de mestrado.

Para evitar dubiedade na compreensão desta dissertação, a partir deste ponto serão usados os termos “trecho” ou “época” para o trecho do sinal de EMG, correspondente à saída de um SLIT. Além disso, será usado o termo “duração da época” para os valores de 500ms, 250ms, 100ms, 50ms ou 25ms associados ao conjunto de trechos com essas durações. Eventualmente, o termo “sinal” poderá ser usado para um trecho de 500ms de duração.

3.1.3 Banco de sistemas autorregressivos

O cálculo dos parâmetros dos sistemas AR foi realizado no LEB-EPUSP (Itiki, 2012). Os trechos de EMG foram então agrupados da seguinte forma: cada par “duração da época” versus “porcentagem da MCV” foi considerado um tipo de SLIT. Relembrando que cada sujeito forneceu épocas de cinco durações diferentes e quatro porcentagens da máxima contração voluntária, têm-se vinte SLIT. Os sistemas numerados de 1 a 5 corresponderam a 10% MCV, os de número 6 a 10 foram associados a 25% MCV, aqueles de 11 a 15 foram atribuídos a 50% MCV e os de 16 a 20 descreveram as épocas de 80% MCV. Para cada força de contração muscular, o número maior do sistema correspondeu à duração maior da época, conforme ilustrado na Figura 4.

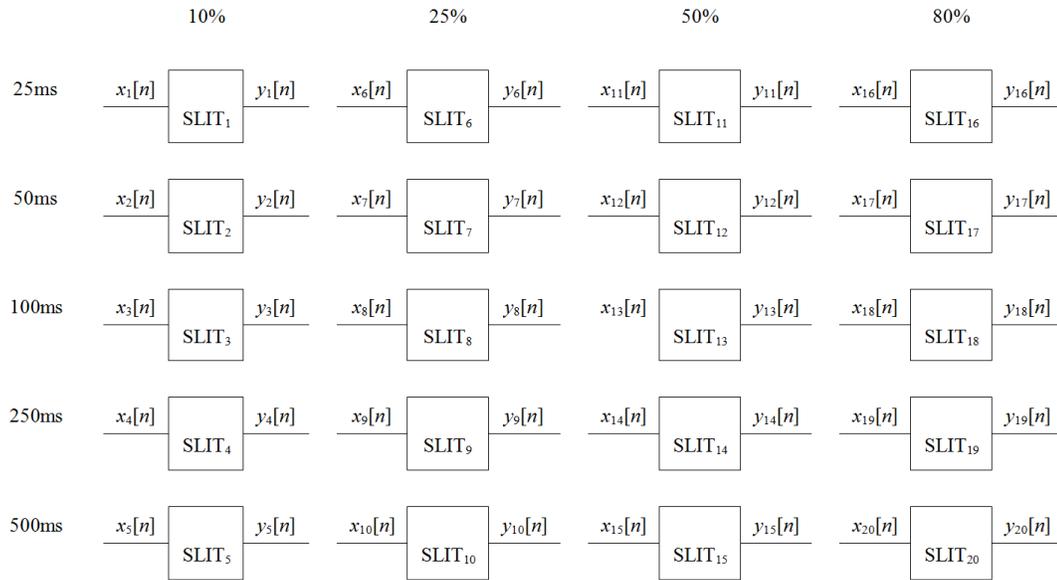


Figura 4 – Numeração dos sistemas lineares invariantes no tempo (SLIT), de acordo com a porcentagem da máxima contração voluntária e a duração da época. No presente trabalho, os sistemas foram considerados do tipo autorregressivo.

Cada época foi modelada como a saída $y(t)$ de um sistema AR (Kay, 1987), segundo a equação

$$y(t) = -a_1 y(t-1) - a_2 y(t-2) \dots - a_n y(t-n) + e(t) \quad (1)$$

em que $e(t)$ é o ruído branco na entrada do sistema, $y(t)$ é o trecho de EMG na saída do sistema, t é o número da amostra, n é a ordem do modelo e a_k são os coeficientes do sistema, para $k = 1, 2, \dots, n$. A Figura 5 ilustra o sistema AR descrito pela equação (1).

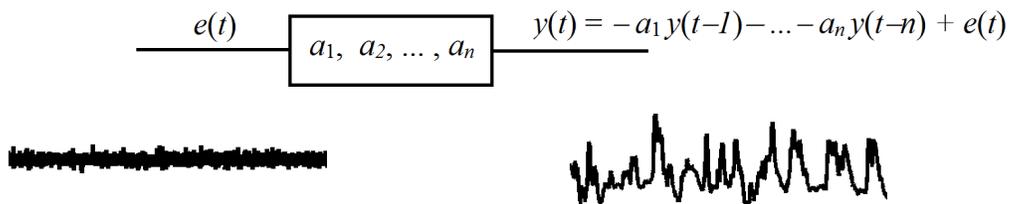


Figura 5 – Sistema autorregressivo com ruído branco desconhecido $e(t)$ na entrada e sinal de eletromiografia $y(t)$ na saída. Imagem cedida por C. Itiki (2012).

Os coeficientes do modelo e a variância do sinal de entrada foram calculados pela função *arx.m* do Matlab. O algoritmo utilizado no cálculo é descrito no apêndice.

3.1.4 Banco de ordens ótimas

O critério utilizado neste trabalho foi o de comprimento mínimo de descrição (MDL, do inglês *Minimum Description Length*) que consiste de uma função que pondera o comprimento N da época multiplicado pelo logaritmo da variância σ_n^2 e a ordem n do modelo multiplicada pelo logaritmo do comprimento N , de acordo com a relação de Rissanen (1983):

$$MDL(n) = N \times \ln[\sigma_n^2] + n \times \ln[N]. \quad (2)$$

As épocas têm comprimentos N fixos e iguais a 625, 1250, 2500, 6250 e 12500 amostras para as respectivas durações de 25ms, 50ms, 100ms, 250ms e 500ms. A ideia deste critério é ponderar a ordem do modelo e a variância ao número de amostras, não permitindo assim ordens demasiadamente elevadas para épocas pequenas.

Para cada trecho de EMG colocado como saída dos SLIT obteve-se uma ordem ótima n , que minimizou o critério de escolha da ordem. Embora cada trecho de EMG gere quantidades diferentes de coeficientes ($a_0, a_1, a_2, \dots, a_n$), o número ótimo de coeficientes para um dado trecho é único: $n+1$. Além disso, a ordem n é única para cada trecho. Portanto, o número de ordens ótimas obtidos equivale, assim, ao número de trechos de EMG.

A Figura 6 ilustra os valores do critérios MDL para uma época de 500ms e força de 50% MCV. Nessa figura, o critério MDL forneceu uma estimativa da ordem ótima igual a 11.

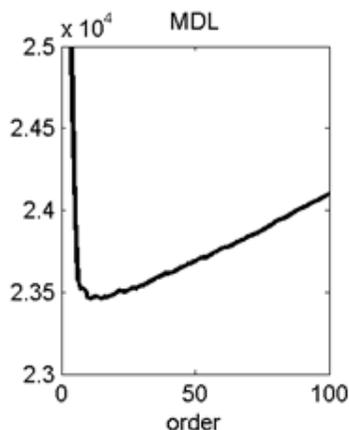


Figura 6 – Critério de otimização para uma época de 500ms e 50% da máxima contração voluntária. A orden selecionada que minimiza o critério MDL foi 11. Imagem cedida por C. Itiki (2012).

De acordo com a literatura (Itiki, 2012), para sinais de EMG de agulha, o critério de informação AIC (Akaike, 1974) superestima a ordem ótima, requerendo uma carga maior de processamento de dados; enquanto o critério MDL e o critério de informação BIC (Akaike, 1978) apresentam resultados próximos entre si sugerindo ordens ótimas bem inferiores ao AIC. O critério MDL de seleção de ordem foi escolhido para este mestrado porque, embora apresente resultados próximos aos do critério de BIC, ele fornece valores de estimativas de ordem sempre intermediários aos fornecidos por AIC e BIC.

A Figura 7 apresenta o quinto sinal do indivíduo 6 para força de 80% MCV. As ordens selecionadas pelo critério MDL variaram de 4 (quatro) a 13 (treze) neste exemplo, para as épocas de 25ms a 500ms. Para facilitar a visualização, as ordens ótimas para as épocas com 25ms estão representadas pela cor laranja, as ordens ótimas para as épocas de 50ms estão representadas pela cor vermelha, 100ms pela cor rosa, 250ms pela cor roxa e 500ms pela cor azul marinho. Visualmente percebe-se que quanto maior a duração da época maior é a ordem ótima. Ou seja, a ordem ótima tende a diminuir com a diminuição da época.

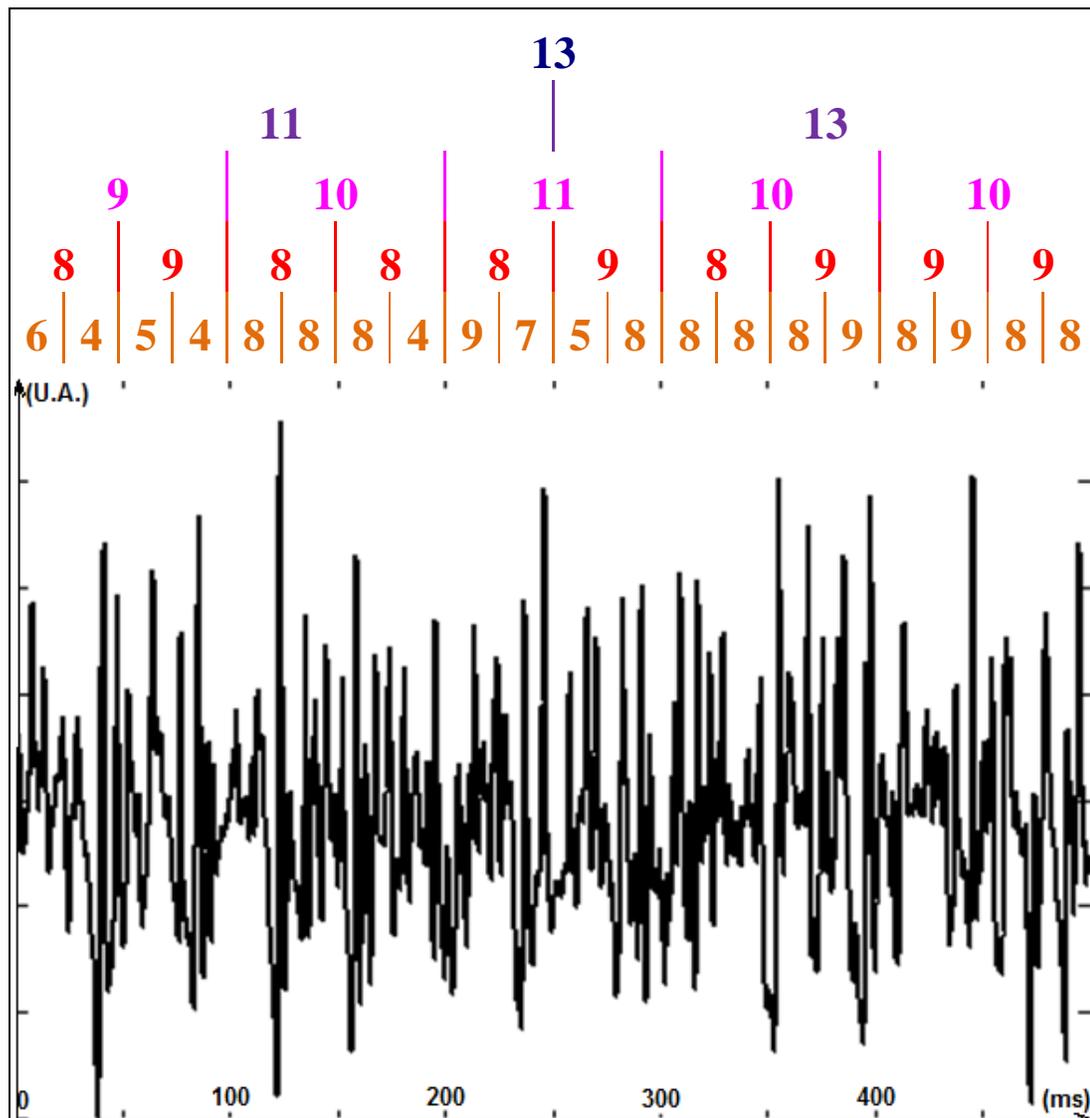


Figura 7 – Ordens selecionadas pelo critério MDL para o quinto sinal do indivíduo 6, obtido a 80% MCV e dividido em épocas. As ordens selecionadas para as épocas estão fornecidas nas cores laranja (25ms), vermelho (50ms), rosa (100ms), roxo (250ms) e azul marinho (500ms) e correspondem respectivamente às ordens dos sistemas lineares invariantes no tempo de número 16, 17, 18, 19 e 20 ilustrados na Figura 4.

3.2. Histograma de Ordens

Neste mestrado, foram usadas as ordens ótimas fornecidas pelo banco de dados descrito anteriormente.

As ordens foram divididas pela força de contração e duração de época para cada indivíduo. Em seguida foram construídos histogramas de distribuição das ordens.

Na Figura 8, no histograma de duração da época por ordem ótima para uma força de contração fixa em 80% de MCV do indivíduo 5 tem-se no eixo X a ordem do modelo e no eixo Y a quantidade de trechos para cada duração de época. Note que a 'mesma' diferença de distribuição observada na Figura 7 aparece visualmente. Isto é, a distribuição tende a se concentrar em ordens menores para durações de época menores.

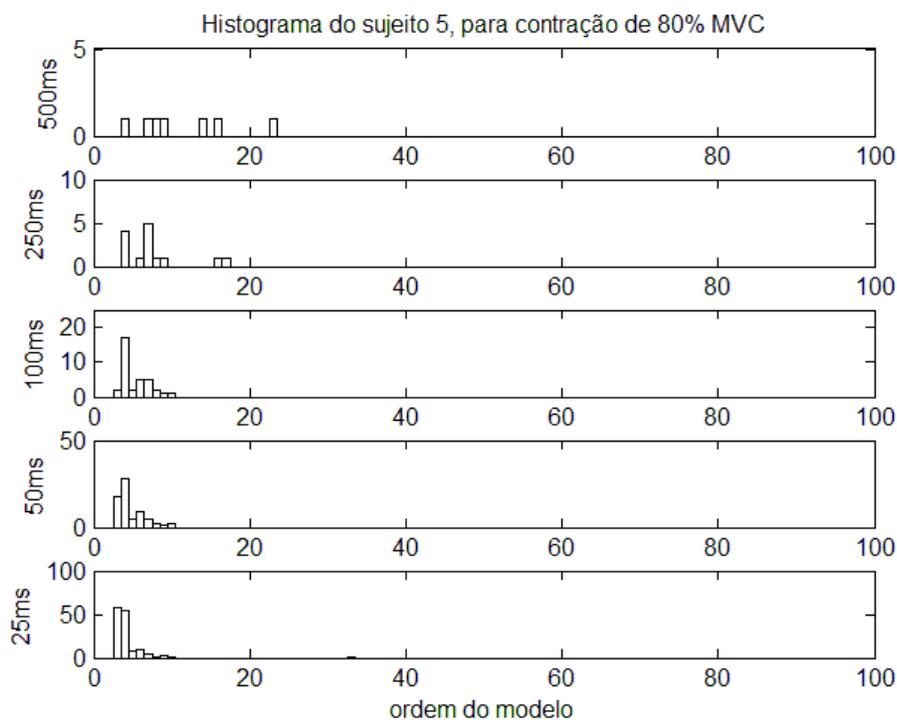


Figura 8 – Histograma de duração da época por ordem ótima do indivíduo 5, para uma força de contração fixa em 80%.

Já na Figura 9, nos histogramas de força de contração por ordem ótima, para uma duração de época fixa em 100ms, tem-se no eixo X a ordem do modelo e no eixo Y a quantidade de trechos para cada força de contração 10%, 25%, 50% e 80%. Nota-se que visualmente a distribuição tende a se deslocar para ordens menores com o aumento da força de contração.

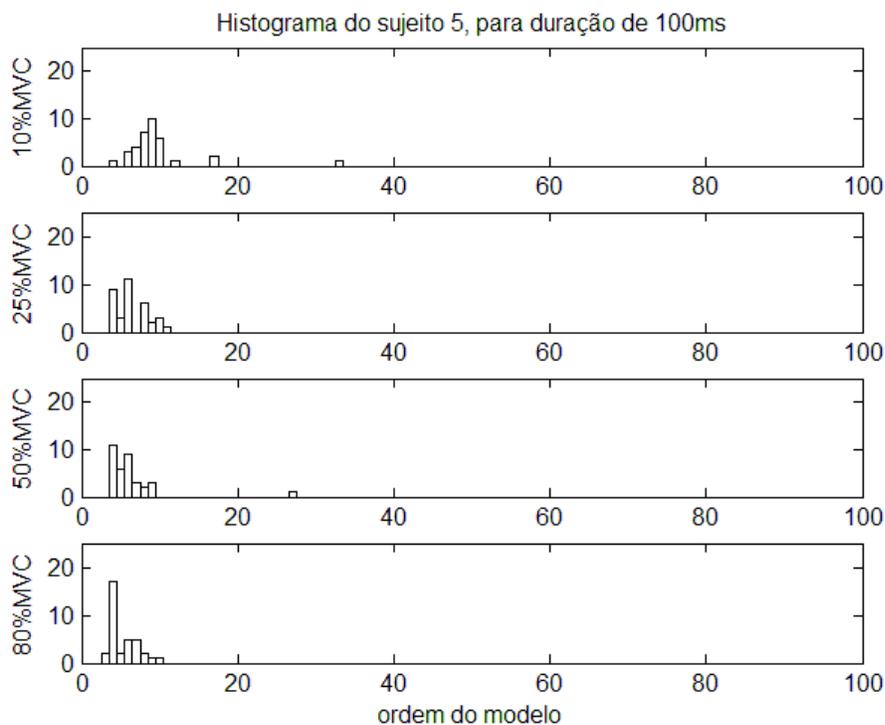


Figura 9 – Histograma de força de contração por ordem ótima do indivíduo 5, para uma duração de época fixa em 100ms.

Os mesmos padrões de deslocamento da distribuição aparecem de forma significativa, mesmo visualmente, para a grande maioria dos sinais. No entanto, para comprovar esta observação e retirar dúvidas sobre sinais com o deslocamento não tão nítidos, uma análise estatística se fez necessária.

3.3. Análise Estatística

Inicialmente, a “contração” (porcentagem da MCV) foi usada como fator para a análise estatística. As ordens ótimas indicadas pelo critério MDL foram fornecidas ao teste estatístico para se verificar a hipótese de que a contração induziria diferenças significativas na distribuição ($p \leq 0,05$). Como o número de épocas para 500ms era muito reduzido e não havia garantias de que a distribuição das ordens ótimas fosse Gaussiana (conforme claramente demonstrado pelas Figuras 8 e 9), usou-se um teste estatístico não paramétrico.

Em projetos em que se quer isolar os fatores responsáveis pela variação da variável em estudo, a ferramenta estatística mais utilizada é a análise de variância. No entanto, quando os dados não são suficientemente numerosos ou quando a suposição de que os dados sejam provenientes de uma distribuição Gaussiana não é justificável, torna-se necessário arranjar um método alternativo. Uma possível solução é classificar cada conjunto de valores em ordem crescente e numerá-los de 1 até o número total de classes. A utilização dessas classificações, em vez dos valores originais, garante que o teste não dependa da distribuição da variável original.

O procedimento, denominado método das classificações (*rank*s), foi proposto por Friedman (1947). O teste de Friedman supõe um modelo da forma $x_{ijk} = \mu + \alpha_i + \beta_j + \varepsilon_{ijk}$, em que μ é um parâmetro geral de localização, α_i representa o efeito da coluna, β_j representa o efeito da linha e ε_{ijk} representa o erro. O valor de p fornecido pelo teste de Friedman é o valor da probabilidade de a hipótese nula ($\alpha=0$) ser válida. O procedimento envolve as seguintes etapas.

Primeiramente os dados são classificados em cada linha de uma tabela de duas vias.

Em segundo lugar, o valor médio \bar{x}_j das classificações é calculado para cada classe (coluna) j . Sabe-se que a distribuição amostral das classificações deveria ser uniforme com média $\mu = (c + 1) / 2$ e variância $\sigma^2 = (c^2 - 1) / (12r)$, em que c é o número de classes (colunas) e r é o número de classificações (linhas).

Em seguida, o teste verifica se as diferentes colunas da tabela de classificação poderiam ser provenientes de um mesmo universo normal e homogêneo, cujos valores verdadeiros da média e desvio padrão são conhecidos. Esse teste é feito por uma estatística calculada a partir dos valores médios \bar{x}_j das classificações da coluna. O valor da estatística é dado por:

$$\chi_r^2 = \frac{c-1}{c \sigma^2} \sum_{j=1}^c (\bar{x}_j - \mu)^2. \quad (3)$$

Uma forma equivalente de representá-la é:

$$\chi_r^2 = \frac{12}{r c (c+1)} \sum_{j=1}^c \left(\sum_{i=1}^r x_{ij} \right)^2 - 3 r (c+1). \quad (4)$$

Essa estatística tende à conhecida distribuição χ^2 com $(c-1)$ graus de liberdade, quando as classificações são, de fato, aleatórias.

A comparação da estatística χ_r^2 com valores tabelados permite a determinação da probabilidade p . Caso $p \geq p_{\text{crítico}}$ pode-se considerar que o fator não influencia a variável em estudo. Porém, valores de p menores que $p_{\text{crítico}}$ indicam que há uma diferença estatisticamente significativa provocada pela variação do fator. Normalmente, escolhe-se $p_{\text{crítico}}$ igual a 0,05 ou 0,01.

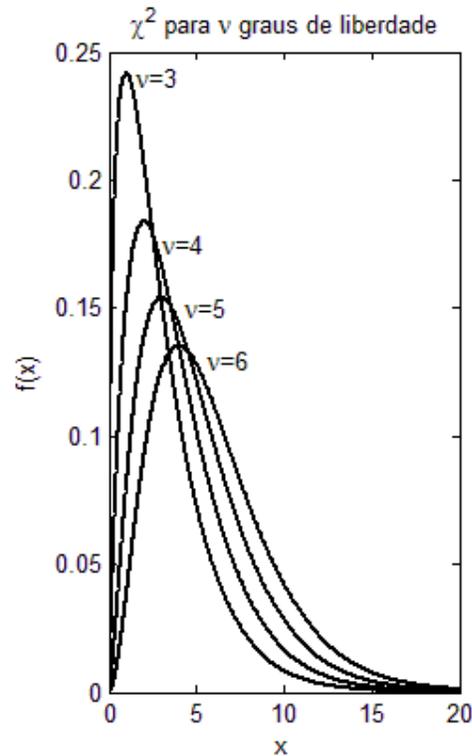


Figura 10 – Densidade de probabilidade χ^2 para três a seis graus de liberdade.

Para auxiliar o teste de Friedman, são construídas tabelas de análise compostas por linhas e colunas.

A primeira coluna dessas tabelas indica a fonte da variabilidade. A segunda mostra a soma dos quadrados (SS, do inglês *Sum of Squares*), a terceira mostra os graus de liberdade (df, do inglês *degrees of freedom*) e a quarta mostra a média dos quadrados (MS, do inglês *Mean of Squares*). Por fim, a quinta coluna mostra o valor da estatística χ_r^2 de Friedman e a sexta coluna mostra o valor da probabilidade p .

A segunda linha das tabelas indica a variabilidade causada por efeitos das colunas, no caso, das forças de contração muscular. A terceira linha mostra a variabilidade devida à interação entre linhas e colunas. E a quarta linha mostra a variabilidade restante, que não pode ser explicada por nenhuma fonte sistemática.

Neste mestrado, usou-se a função nativa do MatLab, *friedman.m*, para aplicar o teste de Friedman.

3.4. Ajuste de Funções Densidade de Probabilidade

3.4.1 Normalização dos histogramas

Um histograma de ordem ótima foi gerado para cada SLIT, isto é, para cada par %MCV e duração de época tiveram seus coeficientes de ordem ótima representados por um histograma. Como o número de trechos disponíveis, e assim de ordens ótimas, eram diferentes para duração de época diferentes, os histogramas tiveram que ser normalizados.

A normalização foi feita dividindo-se o eixo y (quantidade de trechos) pelo número total de trechos que aquele SLIT (par %MCV e “duração de época”) apresentava (Ver fórmula 17).

3.4.2 Função densidade de probabilidade

As funções Gaussiana, LogNormal, Weibull, Poisson e Gama foram ajustadas ao histograma normalizado de ordens ótimas e apresentadas neste trabalho.

A função densidade de probabilidade para a distribuição Gaussiana (também conhecida como Normal) é dada por:

$$y = f(x | \mu, \sigma) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad (5)$$

em que μ é a média e σ é o desvio padrão. A distribuição Gaussiana ajustada foi a que apresentou a estimativa do parâmetro μ igual a média amostral e a estimativa do parâmetro σ , igual ao desvio padrão viciado do respectivo histograma normalizado.

A função densidade de probabilidade para a distribuição LogNormal é dada por:

$$y = f(x | \mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}} \quad (6)$$

em que μ é a média e σ é o desvio padrão da distribuição Gaussiana da função $\log(X)$. A distribuição LogNormal escolhida foi a que apresentou a estimativa do parâmetro μ igual à média amostral e a estimativa do parâmetro σ igual ao desvio padrão do conjunto de logaritmos das respectivas ordens ótimas.

A função densidade de probabilidade para a distribuição de Weibull é dada por:

$$y = f(x | a, b) = ba^{-b} x^{b-1} e^{-\left(\frac{x}{a}\right)^b} \quad (7)$$

em que a é o parâmetro escalar, b é o parâmetro de forma e x é positivo.

A função densidade de probabilidade para a distribuição de Poisson é dada por:

$$y = f(x | \lambda) = \frac{\lambda^x}{x!} e^{-\lambda} \quad (8)$$

em que λ é a média e a variância da distribuição para x positivo. A estimativa do parâmetro λ é calculada pela média amostral.

A distribuição de Poisson está relacionada com a distribuição exponencial da seguinte forma: se o número de eventos segue a distribuição de Poisson, então o intervalo entre a ocorrência dos eventos segue uma distribuição exponencial. Para λ tendendo a infinito, a distribuição de Poisson se aproxima da distribuição Gaussiana para o caso específico de média $\mu = \lambda$ e variância $\sigma^2 = \lambda$.

A função densidade de probabilidade para a distribuição Gama é dada por:

$$y = f(x | a, b) = \frac{1}{b^a \Gamma(a)} x^{a-1} e^{-\frac{x}{b}} \quad (9)$$

em que a é o parâmetro de forma, b é o parâmetro de escala e $\Gamma(a)$ é calculada por:

$$\Gamma(a) = \int_0^{\infty} e^{-t} t^{a-1} dt \quad (10)$$

O ajuste das distribuições Gama e Weibull foi obtido por máxima verossimilhança (*maximum likelihood estimate*).

As diversas funções densidade de probabilidade foram ajustadas para cada histograma normalizado das ordens ótimas dos modelos AR. Os ajustes foram obtidos pelas funções nativas do Matlab: `normfit.m`, `lognfit.m`, `poissfit.m`, `wblfit.m` e `gamfit.m`. Em seguida cada função densidade de probabilidade foi comparada com o histograma normalizado. Novamente rotinas nativas do Matlab para obtenção das funções densidade de probabilidade (`normpdf.m`, `lognpdf.m`, `poisspdf.m`, `wblpdf.m` e `gampdf.m`) e do histograma (`hist.m`) foram utilizadas. A distribuição escolhida foi a que apresentou o menor erro quadrático quando comparada com o histograma normalizado. Os histogramas e as funções ajustadas estão apresentados no capítulo de Resultados.

3.5. Cálculo do Erro Quadrático

As distribuições contínuas tiveram sua função densidade de probabilidade discretizadas da seguinte forma:

$$P(X = n) = \int_{n-0.5}^{n+0.5} f(x) dx, \quad (11)$$

para os valores inteiros de n . Isto é, a função densidade de probabilidade foi integrada nos intervalos $(n - 0.5, n + 0.5]$ para fornecer o valor da probabilidade em n inteiro.

O erro quadrático foi então calculado da seguinte forma:

$$E_T = \sqrt{\sum_{N_1}^{N_2} (P(X = n) - H_T(n))^2}, \quad (12)$$

em que H_T é o histograma normalizado:

$$H_T(n) = \begin{cases} \frac{H(n)}{\sum_{n=1}^{100} H(n)}, & 1 \leq n \leq 100; \\ 0 & , \text{ caso contrário.} \end{cases} \quad (13)$$

O histograma normalizado contém valores não-nulos apenas no intervalo 1 a 100. Neste mestrado, o truncamento no cálculo do erro quadrático foi em $N_1=1$ e $N_2=100$, mesmo intervalo do histograma normalizado. Esse truncamento despreza as probabilidades não-nulas para valores negativos da ordem n . Dentre as funções densidade de probabilidade usadas neste mestrado, a única que apresenta probabilidade não-nula para ordens negativas é a Gaussiana, pelo fato de ser simétrica. O truncamento também despreza as probabilidades para ordens acima de 100 para todas as funções densidade de probabilidade. Idealmente, N_1 tenderia a $-\infty$ e N_2 tenderia a $+\infty$.

4. RESULTADOS

4.1. Ordem Ótima

As ordens ótimas são apresentadas de duas formas: para cada indivíduo e para o conjunto global de todos os indivíduos.

4.1.1 Resultados individuais

Todas as ordens ótimas obtidas por indivíduo deste trabalho estão apresentadas nas cinco figuras seguintes (Figuras de 11 a 15). Cada figura apresenta os resultados para um comprimento de época. Cada linha apresenta a quantidade de coeficientes de um indivíduo para uma dada força de contração e época. No eixo x estão as ordens ótimas e no eixo Y tem-se o número do indivíduo (1 ao 6) e suas respectivas forças de contração.

Por exemplo, na Figura 11, as quatro primeiras linhas correspondem às ordens ótimas do indivíduo 1. A primeira linha corresponde às ordens ótimas obtidas para 10% MCV e épocas de 25ms de duração deste indivíduo. Note que há vinte ordens ótimas iguais a 3; trinta e oito iguais a 4; onze iguais a 5; trinta e três iguais a 6; quatorze iguais a 7; quatro iguais a 8 e assim por diante, totalizando 140 trechos ou ordens ótimas. Ainda na Figura 11, a segunda linha corresponde às ordens ótimas obtidas para o mesmo indivíduo mantendo-se o mesmo comprimento de época de 25ms de duração, mas aumentando a força aplicada para 25% MCV.

Na Figura 12 estão apresentadas as ordens ótimas obtidas para as épocas iguais a 50ms. O mesmo padrão de apresentação da Figura 11 se repete nesta figura: primeira linha, ordens ótimas para indivíduo 1 com 10% da MCV; segunda linha, indivíduo 1 para 25% da MCV. Cada quatro linhas apresentam os resultados para um indivíduo. Assim da 21^a até a 24^a linha apresentam-se as ordens ótimas para o indivíduo 6 com 10% até 80% da MCV.

As figuras podem ser visualizadas como histogramas das ordens ótimas, nos quais o gradiente de cor vai da branca (nenhum coeficiente) à vermelha (a maior concentração de coeficientes), passando pela amarela. A apresentação dos dados foi truncada em 40 apenas para facilitar visualização das tabelas, as ordens ótimas foram obtidas dentro do intervalo de 1 a 100 e as ordens maiores que 40 estão apresentadas na última coluna das tabelas com a notação ">40".

Retornando à Figura 11, pode-se então visualizar a maior concentração de coeficientes: igual a 82, correspondente a épocas de 25ms no indivíduo 4 com 50%MCV e ordem ótima 4. A maior concentração de coeficientes para épocas de 50ms: 50, assim como para a de 25ms, como pode ser observado na Figura 12, também pertence ao indivíduo 4 com 50%MVC e ordem ótima 4.

Na Figura 13 estão apresentados os resultados para épocas iguais a 100ms, seguindo a mesma lógica de apresentação das figuras anteriores. Nota-se o 'pico' de concentração de coeficientes para 100ms: vinte e dois trechos estão na ordem ótima 7, para a 10% da MCV do indivíduo 6. O segundo 'pico': 21, está em uma ordem ótima menor: igual a 4, para uma força de contração maior: 50%MCV e pertence ao indivíduo 4.

Na Figura 14, para épocas iguais a 250ms, as máximas concentrações de ordens ótimas (oito trechos a 10% MCV) estão nas ordens 15 e 10 para os indivíduos 1 e 5 respectivamente. O segundo maior acúmulo de ordem ótima (seis trechos a 50%MCV) está nas ordens 8 e 4 dos indivíduos 2 e 4 respectivamente. Comparando com as máximas concentrações de ordens tem-se que o segundo maior acúmulo de ordem ótima está em uma força de contração maior (50%MCV) e em ordens menores (8 e 4). Note que este é a mesma comparação apresentada no parágrafo anterior, ordem menor com força maior.

A Figura 15 apresenta as ordens ótimas para os sinais de 500ms separadas por indivíduo e força de contração como descrito anteriormente. As máximas concentrações (cinco trechos) estão na ordem 15 sendo elas correspondentes a 10%MCV para o indivíduo 1 e 25%MCV para o indivíduo 2.

Para as 5 figuras apresentadas, as máximas concentrações correspondem a mais de 57% dos coeficientes daquele indivíduo no respectivo SLIT. São elas: 82 de 140 para 25ms, 50 de 70 para 50ms, 22 de 35 para 100ms, 8 de 14 para 250ms e 5

de 7 para 500ms. As máximas concentrações se localizam em ordens crescentes conforme se aumenta a duração da época: ordem 4 para épocas de 25ms e 50ms, ordem 7 para época de 100ms, ordens 10 e 15 para 250ms e ordem 15 para 500ms.

Nenhum trecho apresentou ordem ótima igual a um, conclusão obtida observando a primeira linha das quatro figuras (Figuras 11 a 15). Comparando a segunda coluna das figuras têm-se menos de 0,5% das épocas de 25ms e 50ms apresentaram ordem ótima igual a dois, enquanto as três épocas maiores (100, 250 e 500ms) não tiveram nenhuma ordem ótima igual a 2. Proporcionalmente aos números de coeficientes, 15% dos trechos de 25ms e 5,8% dos trechos de 50ms apresentam ordem ótima igual a 3 enquanto menos de 1% dos coeficientes dos trechos de 100ms e nenhum dos trechos de 250 e 500ms apresentam ordem ótima menor ou igual a 3. Comparando a ordem 4 tem-se 29,3%; 25,5%; 17,7%; 7,4% e 3,6% dos trechos de 25ms, 50ms, 100ms, 250ms e 500ms respectivamente. Mais de 44% das épocas de 25ms tem ordem ótima inferior a 5 contra menos de 4% dos sinais de 500ms. Pode-se observar que quanto menor o comprimento da época maior a porcentagem de trechos que apresentam ordem ótima inferior a 5.

De forma geral, ao se comparar as cinco figuras observa-se visualmente que as ordens tendem a se espalharem e deslocarem para ordens maiores com o aumento da duração da época.

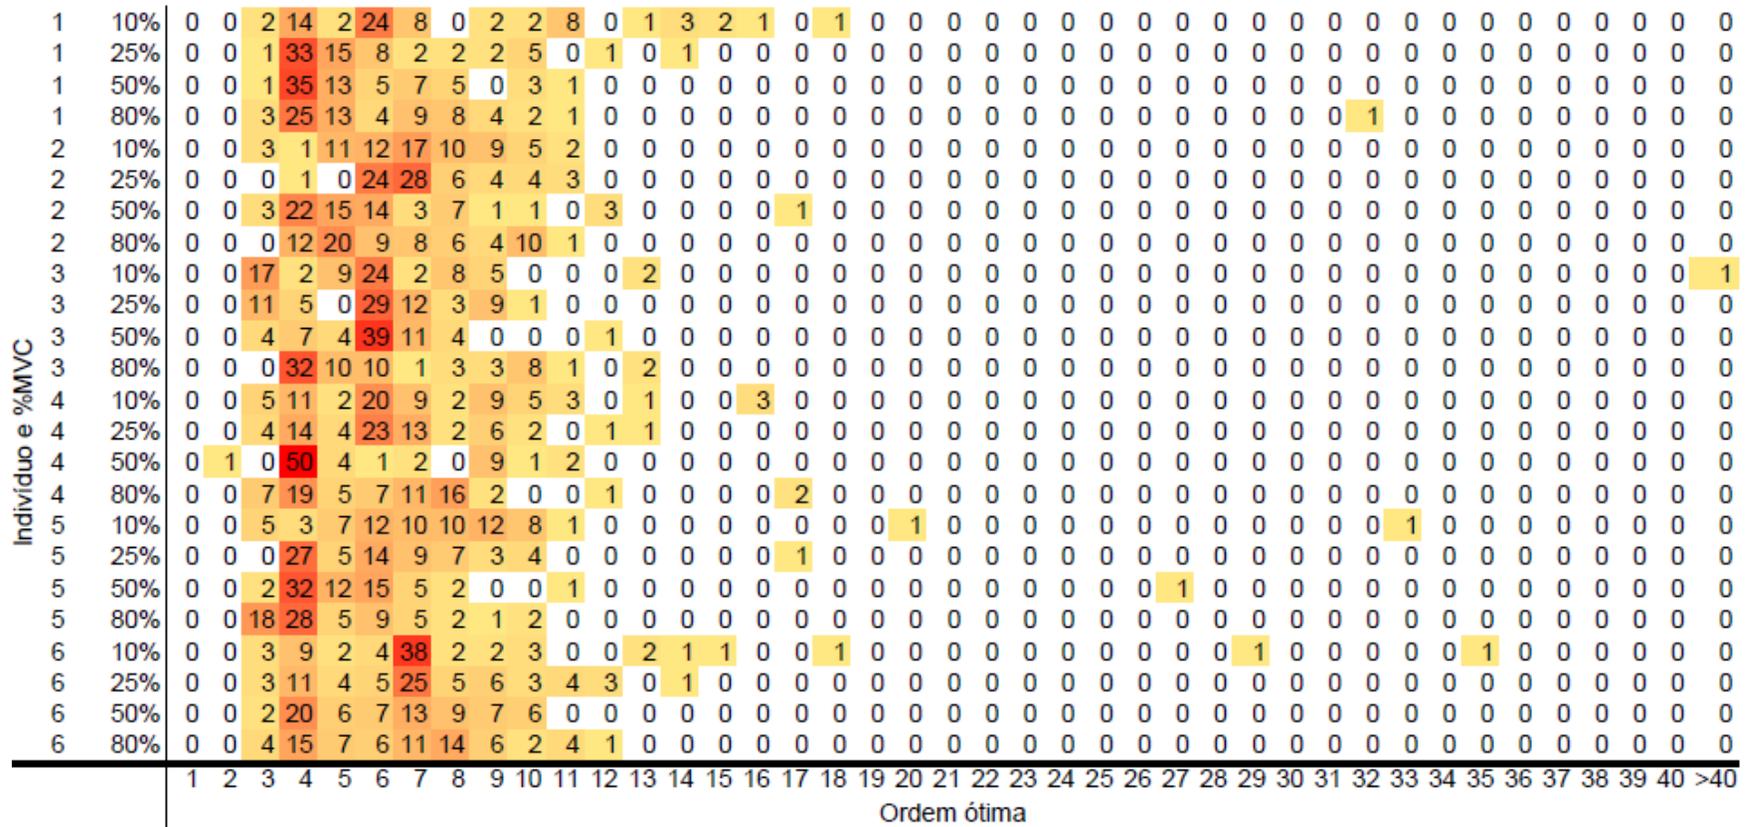


Figura 12 – Distribuição das ordens ótimas por indivíduo e força de contração mantendo época fixa em 50ms.

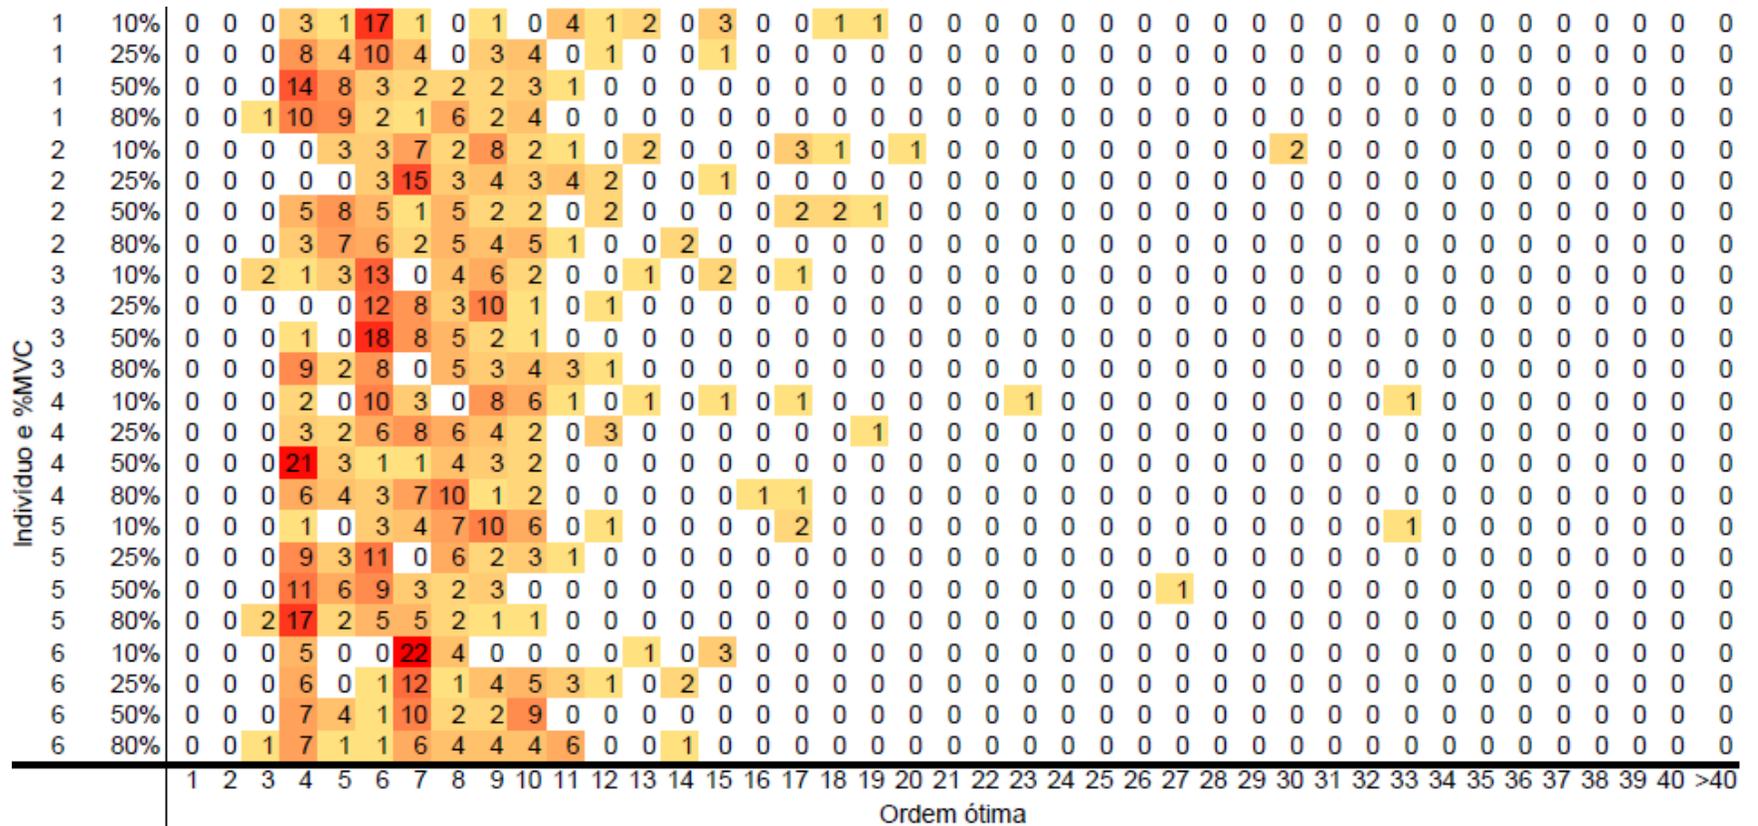


Figura 13 – Distribuição das ordens ótimas por indivíduo e força de contração mantendo época fixa em 100ms.

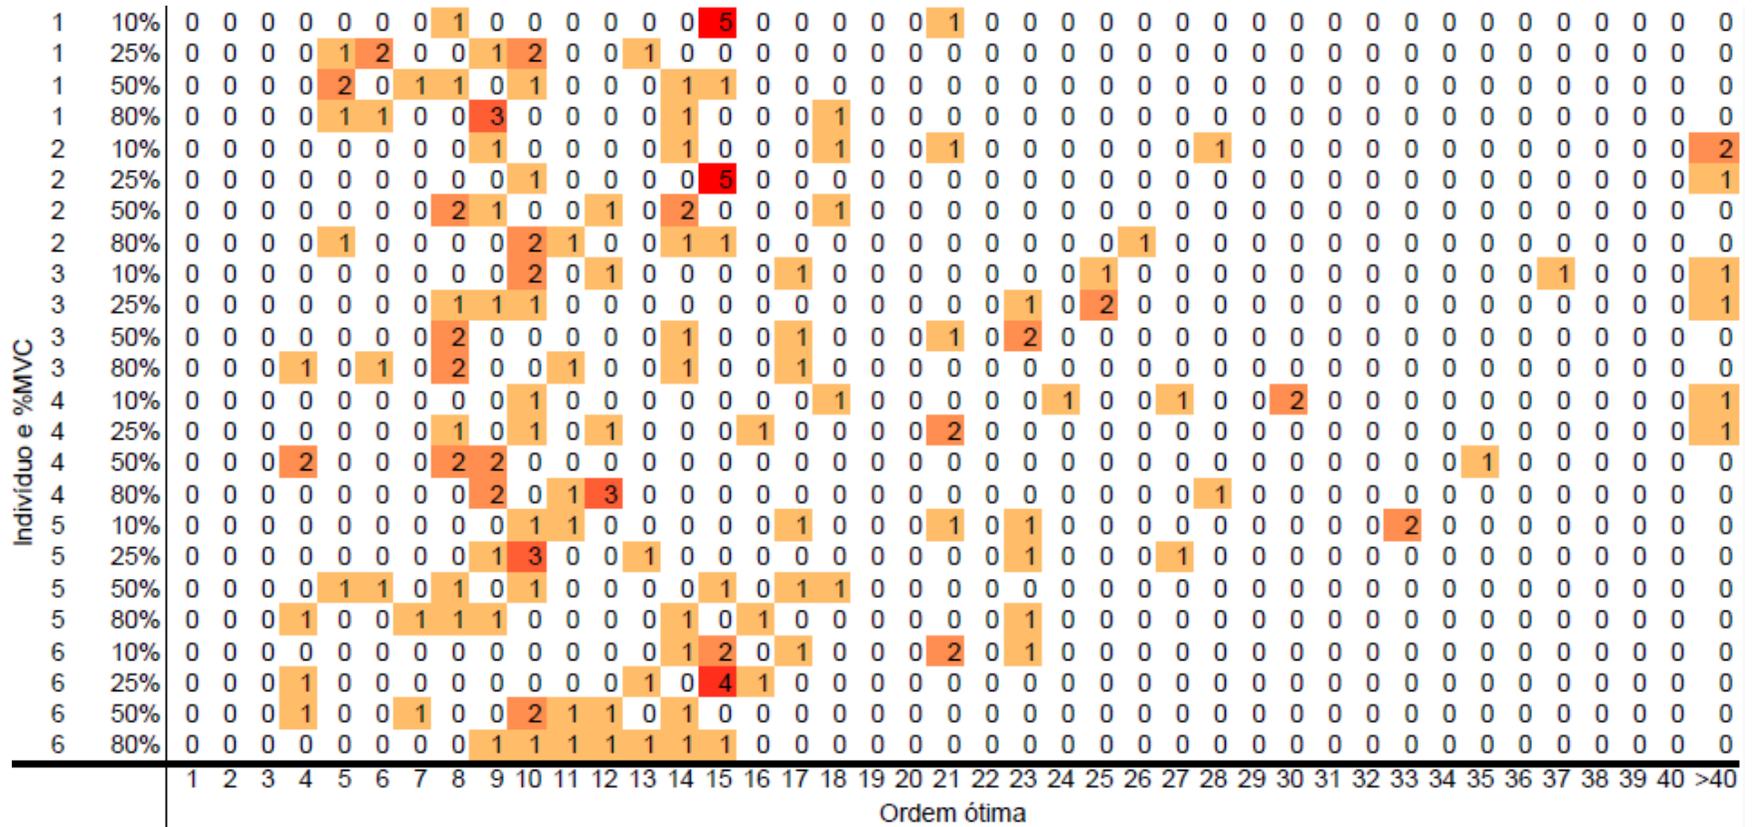


Figura 15 – Distribuição das ordens ótimas por indivíduo e força de contração mantendo época fixa em 500ms.

4.1.2 Resultados globais

A Figura 16 apresenta as porcentagens das ordens ótimas de todos os indivíduos, agrupadas por duração de época e força de contração. Dessa forma, não se faz distinção das ordens entre os indivíduos. O degradê vai de azul a bordô. Azul representa baixa concentração de coeficientes enquanto bordô indica altas concentrações de coeficientes chegando a representar 40% da concentração total de coeficientes para o respectivo SLIT, isto é, conjunto de sinais com um mesmo comprimento de época e porcentagem da máxima contração voluntária.

Ao contrário dos resultados individuais que foram agrupados pela duração de época para cada figura, os resultados globais estão agrupados pela força. A Figura 16.a apresenta as ordens para 10% MCV para as diferentes épocas. Na primeira linha estão as ordens correspondentes aos trechos de 25ms; na segunda linha, as ordens dos trechos de 50ms; a terceira, 100ms; a quarta, 250ms e a quinta, dos sinais de 500ms. Comparando a quinta com a primeira linha da Figura 16.a, observa-se que as ordens ótimas tendem a se concentrar e se deslocar para valores menores com a redução da duração da época.

A Figura 16.b apresenta as ordens para 25% MCV. As Figuras 16.c e 16.d apresentam as ordens ótimas para 50% MCV e 80% MCV respectivamente. A mesma lógica de apresentação da Figura 16.a está presente nessas figuras. Embora mais sutil, a mesma concentração e redução dos valores das ordens pode ser observado ao se diminuir a duração da época, ao se comparar as linhas de cada subfigura.

Comparando as distribuições de 500ms das Figuras 16.a, 16.b, 16.c e 16.d, observa-se que as ordens tendem a se concentrar em valores menores, com o aumento da força de contração. A mesma tendência pode ser observada, embora menos acentuada, para as demais durações, ou seja, concentração em ordens menores com o aumento da força de contração.

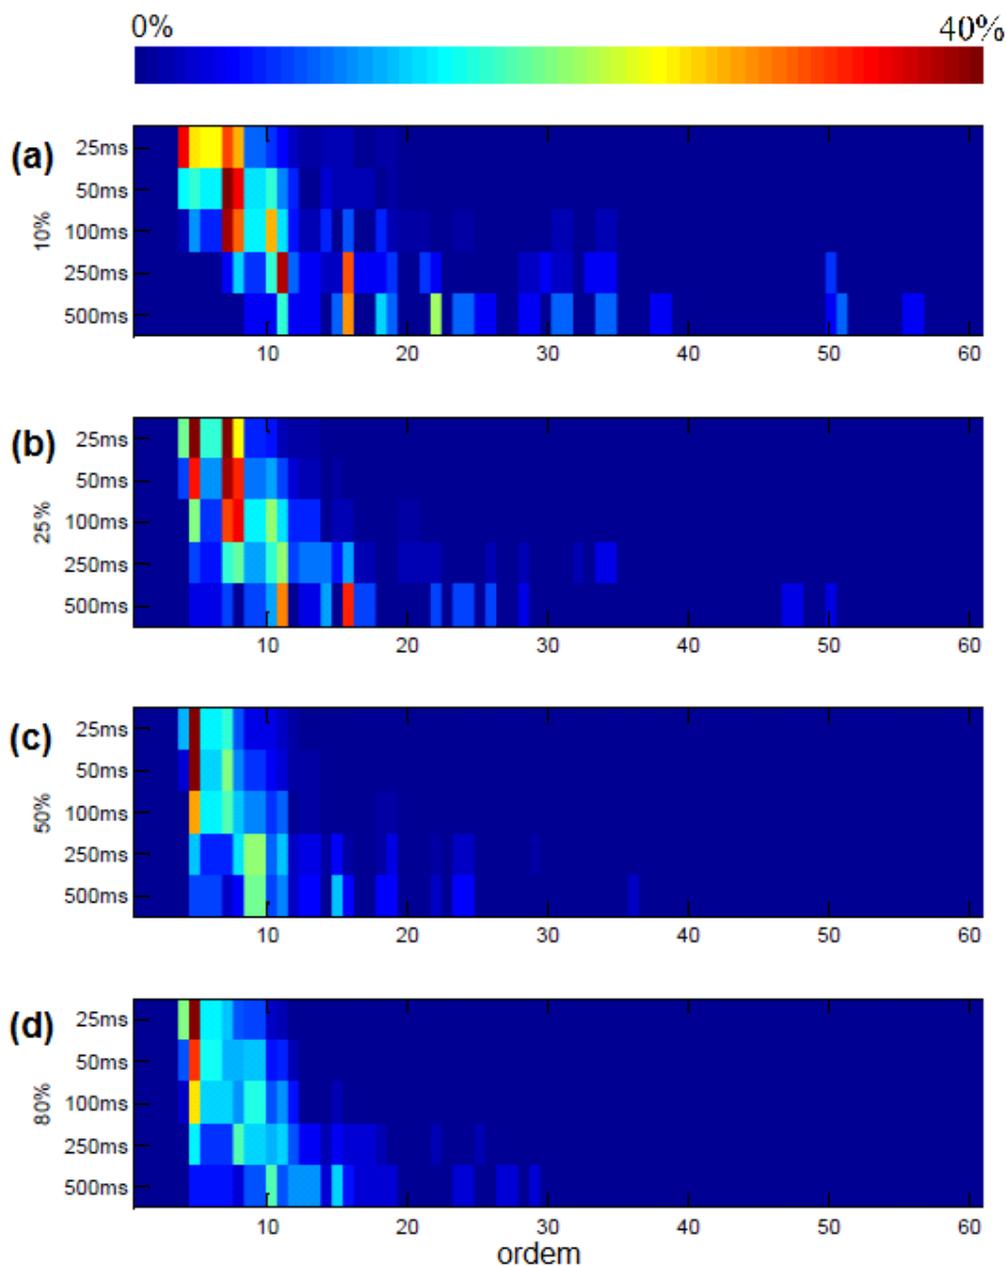


Figura 16 – Distribuição percentual das ordens ótimas por duração de época e força de contração. Resultados para (a) 10%MCV, (b) 25%MCV, (c) 50%MCV e (d) 80%MCV. Cada linha representa os resultados para um comprimento de época. O degradê de azul a bordô indica uma concentração crescente de coeficientes chegando a 40%.

4.2 Histogramas de Ordens

A Figura 17 apresenta os histogramas das ordens ótimas dos vinte SLIT. Na primeira linha de histogramas estão os resultados para épocas de 25ms de duração e diferentes contrações; na segunda linha estão os resultados para 50ms; na terceira, quarta e quinta estão os resultados para 100ms, 250ms e 500ms respectivamente. Na primeira coluna de histogramas estão os resultados para força de contração igual a 10%MCV; na segunda, terceira e quarta colunas estão os resultados para 25%, 50% e 80% da máxima contração voluntária. Desta forma, o histograma 17.A corresponde às ordens de época com 25ms e força equivalente a 10%MCV; o histograma 17.B, primeira linha e segunda coluna, corresponde as ordens de épocas com 25ms e força equivalente a 25%MCV; o histograma 17.E corresponde às ordens de épocas iguais a 50ms e força iguais a 10%MCV. O histograma 17.O corresponde aos resultados das épocas iguais a 250ms e 50%MCV.

O histograma 17.D apresenta-se assimétrico com menos de 0,5% de suas ordens ótimas inferiores a 2, 20% das ordens iguais a 3 e seu pico de quase 40% igual a 4. O declínio é menos abrupto tendo ordens superiores a 40. Esta assimetria, caracterizada por uma elevação abrupta e queda suave pode ser observada visualmente, embora não tão marcada, nos demais histogramas para durações de até 100ms.

4.2.1 Resultados globais por duração

O histograma 17.A tem seu pico máximo na ordem 4. Mantendo-se a força de contração em 10% MCV e aumentando-se a duração da época, verifica-se que os histogramas 17.E, 17.I 17.M e 17.Q têm seus picos nas ordens 7, 7, 11 e 16. Ou seja, comparando entre si os histogramas pertencentes a uma mesma coluna (força de contração), há uma tendência de deslocamento do pico do histograma ao longo do eixo x para ordens maiores com o aumento da duração da época.

4.2.2 Resultados globais por força

Os histogramas 17.E e 17.I correspondem a 10% MCV e têm seus picos na ordem 7. Para a força de 80% MCV, os histogramas 17.H e 17.L têm seus picos na ordem 5. Portanto, mantendo-se as durações de épocas constantes, os picos dos histogramas normalizados se deslocam para ordens menores com o aumento da força de contração. A mesma tendência pode ser observada para duração de 50ms, ou seja, pela comparação dos histogramas 17.Q, 17.R, 17.S e 17.T.

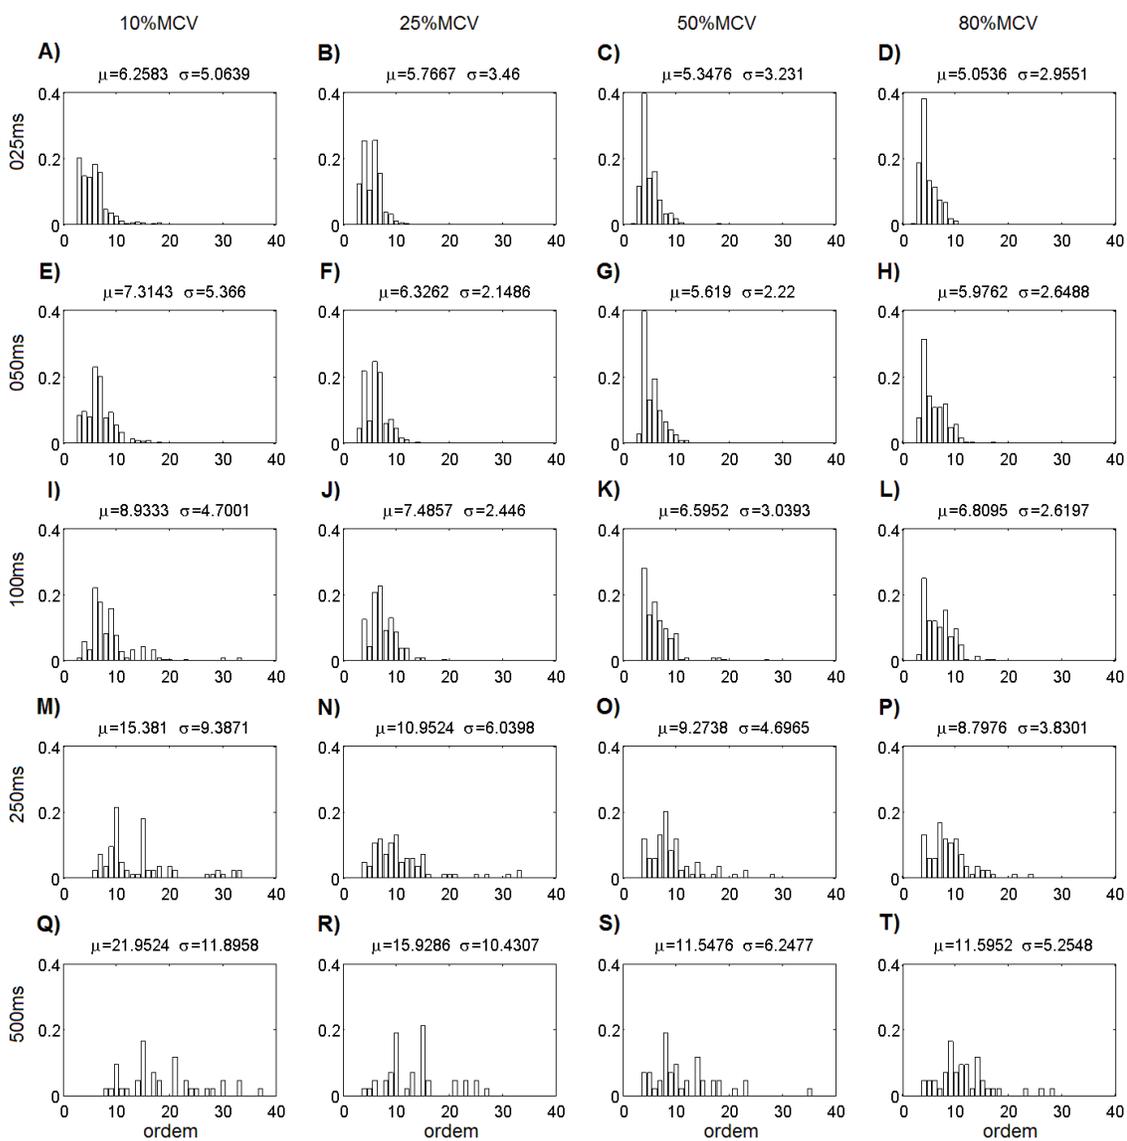


Figura 17 – Histogramas normalizados da ordem ótima.

4.3 Análise Estatística

Na seção anterior, observou-se que visualmente parece haver diferenças decorrente das alterações nas forças de contração e durações de época. Para comprovar esta suposição, uma análise estatística se faz necessária.

A literatura já registrou que há influência da duração da época nos histogramas de ordem ótima (Itiki, 2002). Portanto, esta dissertação se restringirá a confirmar a existência de diferenças estatisticamente significativas causadas pela alteração da força de contração muscular.

As Tabelas 2 a 6, já explicadas na seção 3.3 desta dissertação, foram geradas pela rotina *friedman.m* nativa do MatLab e apresentam os resultados do teste de Friedman para durações de 25ms a 500ms.

Tabela 2 – Teste de Friedman para épocas de 25 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 140 repetições.

Fonte	SS	df	MS	χ^2	P
Colunas	2,1642E6	3	721409,9	87,07	9,34109E-19
Interação	3,6204E6	15	241359,8		
Erro	77,5859E6	3336	23257,2		
Total	83,3705E6	3359			

Tabela 3 – Teste de Friedman para épocas de 50 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 70 repetições.

Fonte	SS	df	MS	χ^2	P
Colunas	488973,6	3	162991,2	78,17	7,58644E-17
Interação	464564,2	15	30970,9		
Erro	9518093,7	1656	5747,6		
Total	10471631,5	1679			

Tabela 4 – Teste de Friedman para épocas de 100 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 35 repetições.

Fonte	SS	df	MS	χ^2	P
Colunas	94933,5	3	31644,5	59,82	6,4105E-13
Interação	69247,7	16	4616,5		
Erro	1159281,8	816	1420,7		
Total	1323463,0	839			

Tabela 5 – Teste de Friedman para épocas de 250 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 14 repetições.

Fonte	SS	df	MS	χ^2	P
Colunas	15665,7	3	5221,91	59,79	6,50667E-13
Interação	3254,8	15	216,99		
Erro	67538,5	312	216,47		
Total	86459,0	335			

Tabela 6 – Teste de Friedman para épocas de 500 ms. O fator contração foi testado, após a remoção da influência dos sujeitos, para 7 repetições.

Fonte	SS	df	MS	χ^2	P
Colunas	2976,7	3	992,234	44,56	1,14883e-9
Interação	699,3	15	46,620		
Erro	7146,5	144	49,628		
Total	10822,5	167			

Os valores obtidos da probabilidade P foram de $9,3 \times 10^{-19}$; $7,6 \times 10^{-17}$; $6,4 \times 10^{-13}$; $6,5 \times 10^{-13}$ e $1,1 \times 10^{-9}$ respectivamente para as épocas de durações de 25ms, 50ms, 100ms, 250ms e 500ms. Com base nesses valores, rejeita-se a hipótese de igualdade das distribuições. Portanto, há diferenças significativas entre as distribuições, resultantes da variação da força de contração muscular e, assim, é pertinente ajustar uma função densidade de probabilidade para cada par de força de contração e duração de época (correspondente a um dos vinte SLIT).

4.4 Ajuste de Funções Densidade de Probabilidade

A função densidade de probabilidade Gaussiana foi ajustada aos histogramas normalizados de acordo com a força de contração e a duração de época, conforme ilustrado na Figura 18. As curvas em vermelho, sobrepostas aos histogramas normalizados, representam as densidades de probabilidade que melhor se ajustaram aos histogramas. A distribuição dos histogramas por força de contração (linhas) para duração fixa e por duração de época (colunas) para contração fixa segue a mesma apresentação da Figura 17.

A Figura 19 ilustra o ajuste da função densidade de probabilidade LogNormal. As Figuras 18.A, 18.B, 18.C, 18.D, 19.A, 19.B, 19.C e 19.D ilustram, para o comprimento de época igual a 25ms e diferentes contrações voluntárias, o ajuste da melhor densidade de probabilidade encontrado para as distribuições Gaussiana e LogNormal, respectivamente. Visualmente é possível inferir que a distribuição LogNormal modela melhor os histogramas do que a Gaussiana.

As Figuras 18.D, 18.H, 18.L, 18.P, 18.T, 19.D, 19.H, 19.L, 19.P e 19.T ilustram o ajuste da melhor densidade de probabilidade encontrado para a força de contração igual a 80%MCV e diferentes comprimento de época. Os mesmos elementos discutidos no parágrafo anterior podem ser observados.

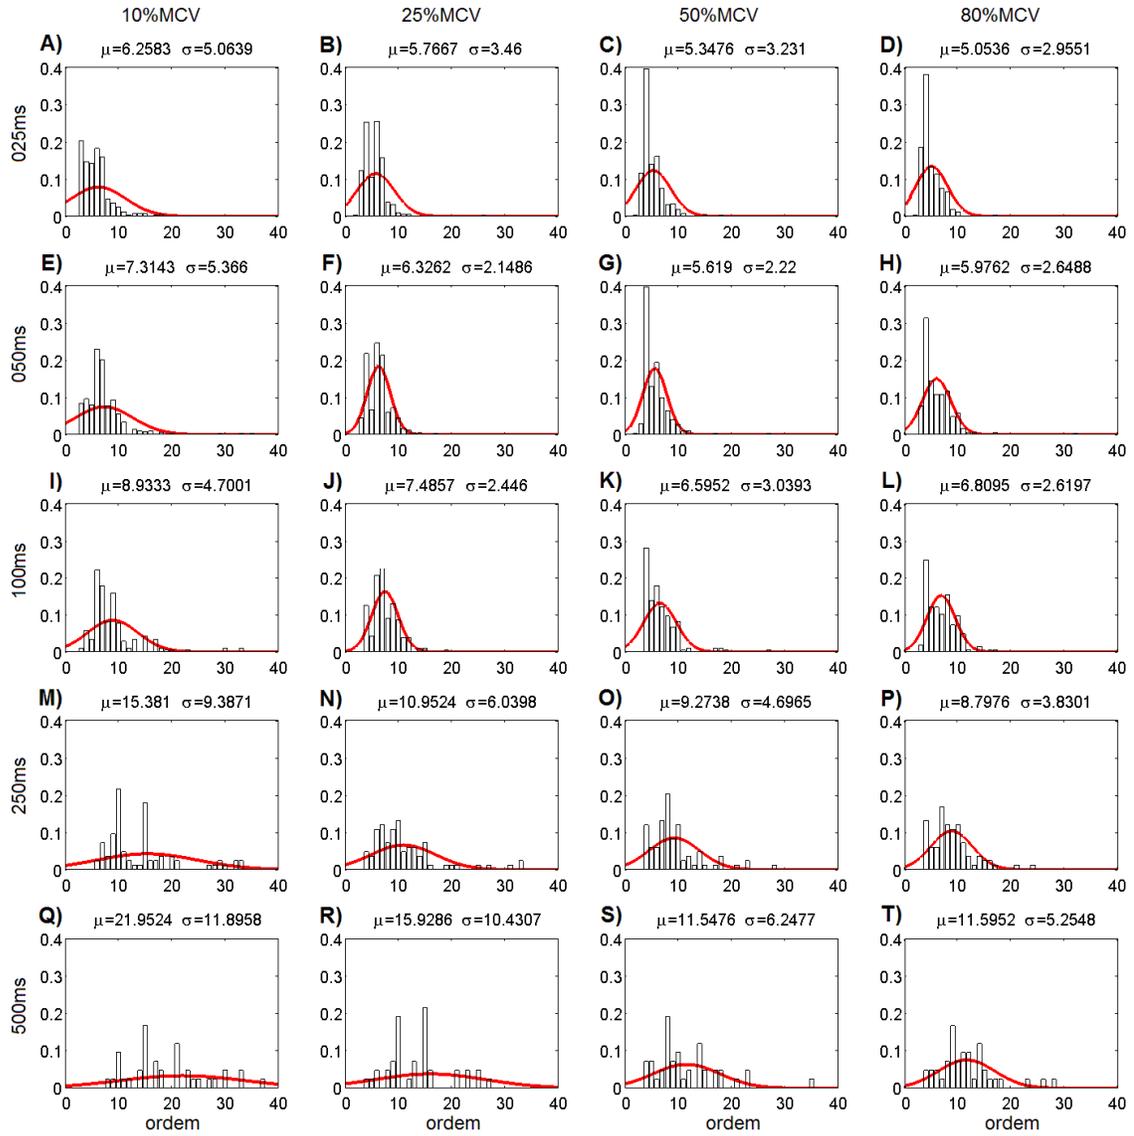


Figura 18 – Ajuste da função densidade de probabilidade Gaussiana.

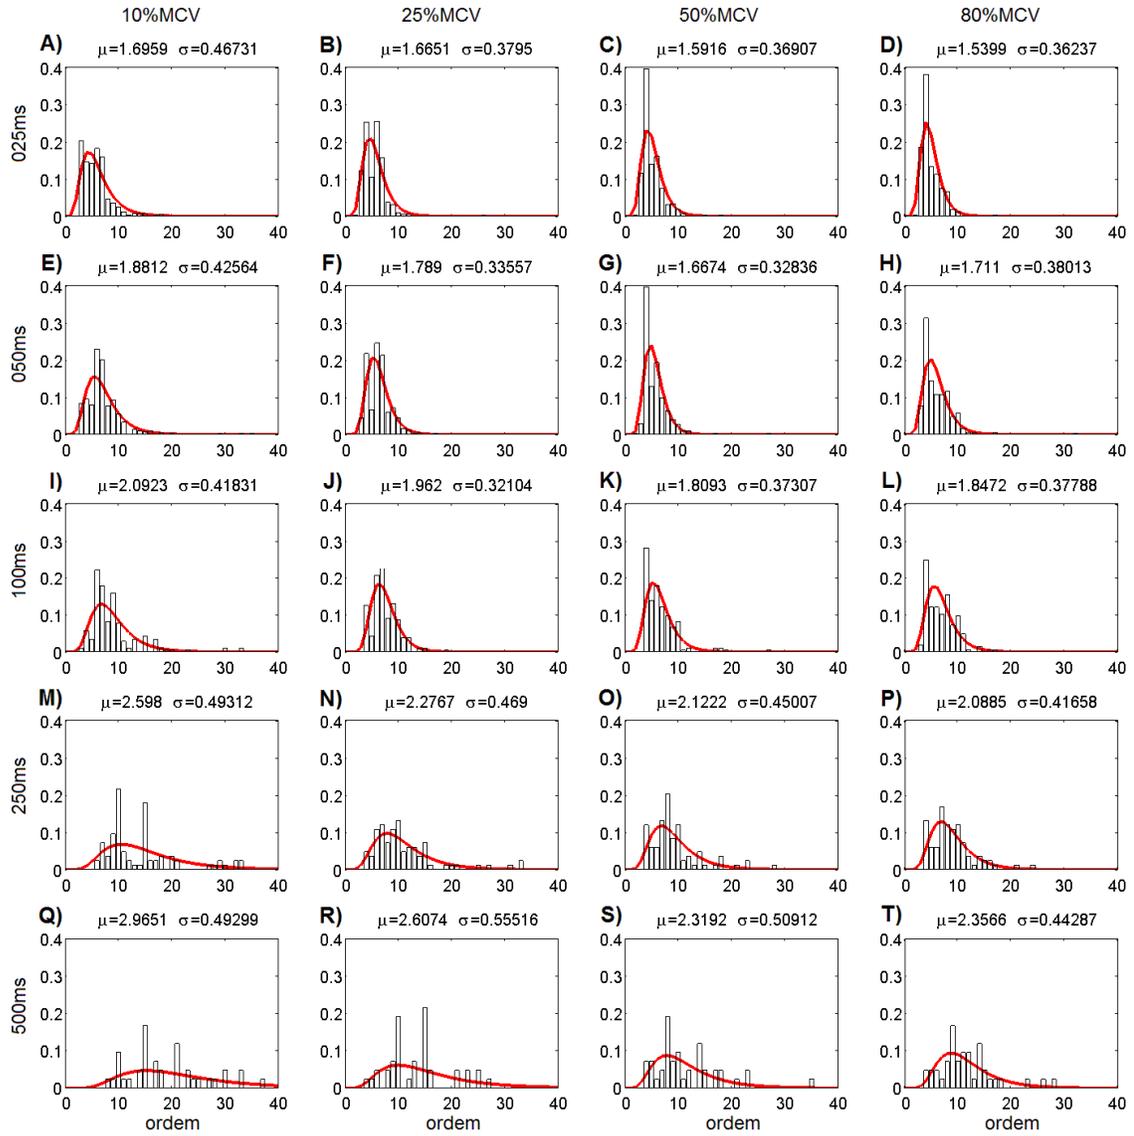


Figura 19 – Ajuste da função densidade de probabilidade LogNormal.

As Figuras 20, 21 e 22 ilustram os ajustes das funções densidade de probabilidade Weibull, Poisson e Gama respectivamente.

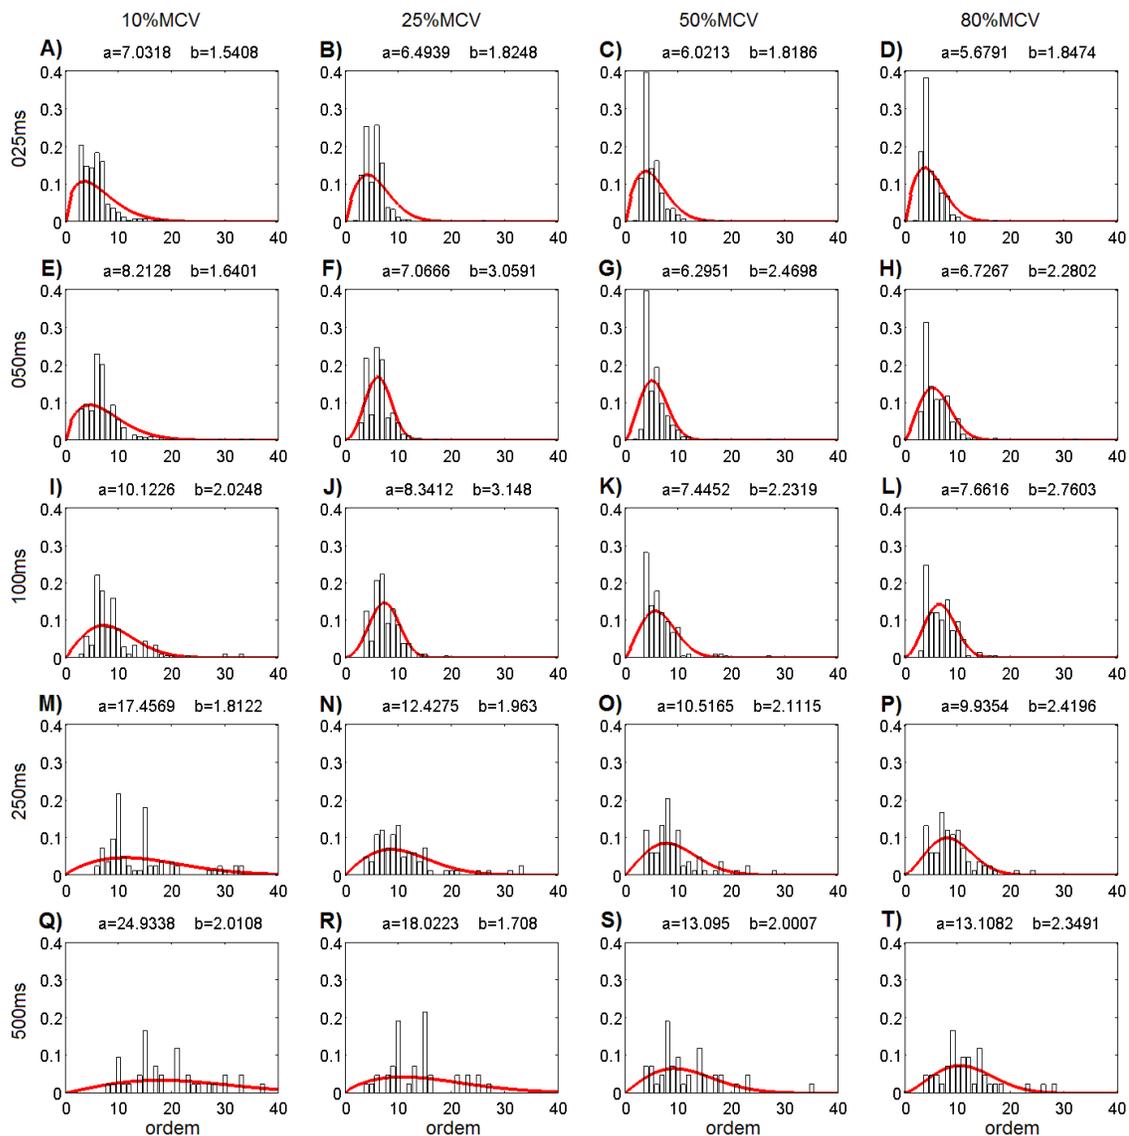


Figura 20 – Ajuste da função densidade de probabilidade Weibull

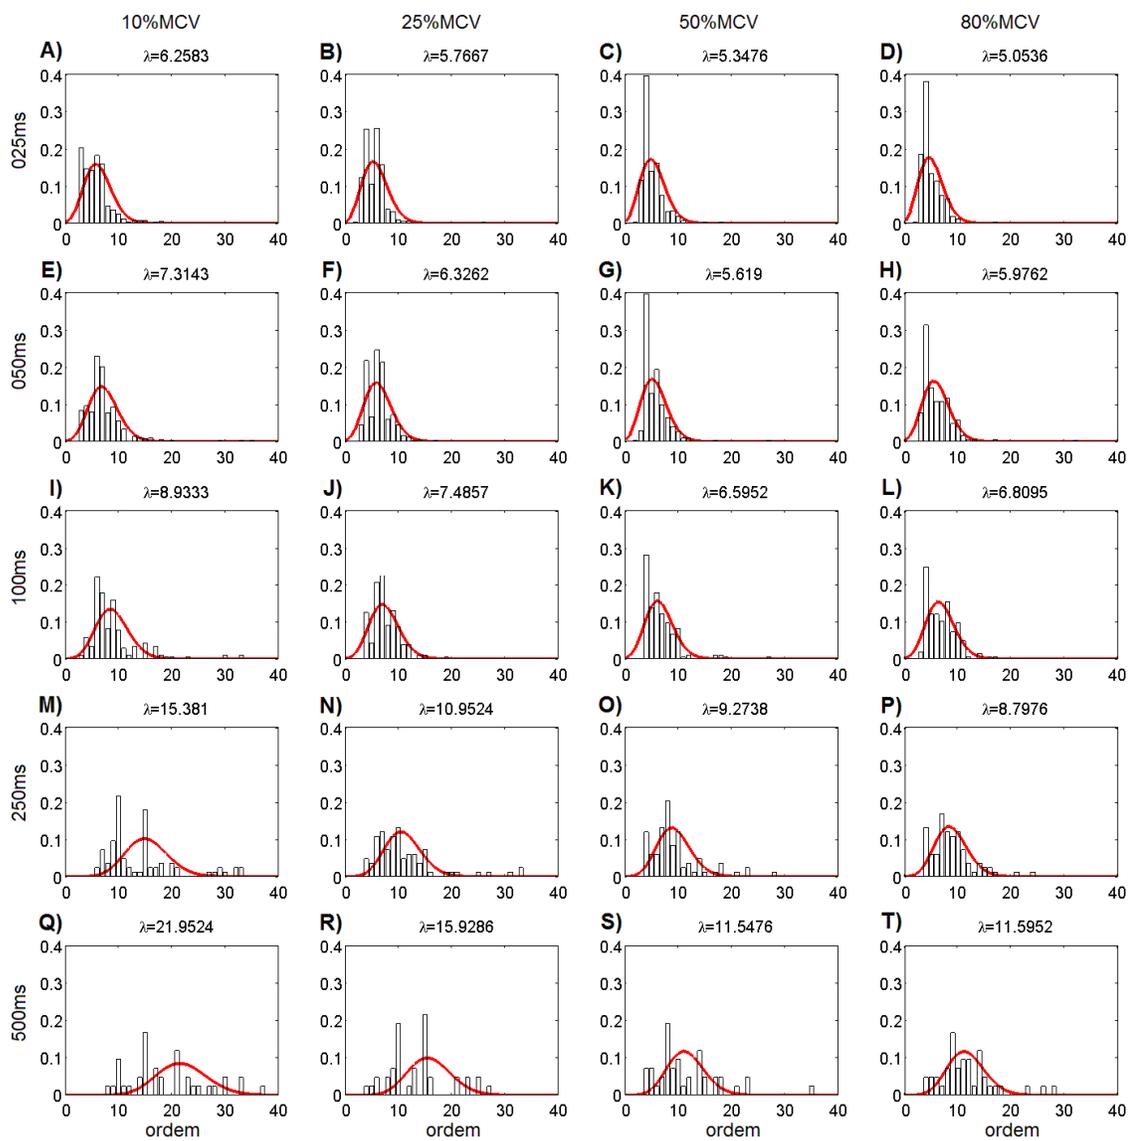


Figura 21 – Ajuste da função densidade de probabilidade Poisson

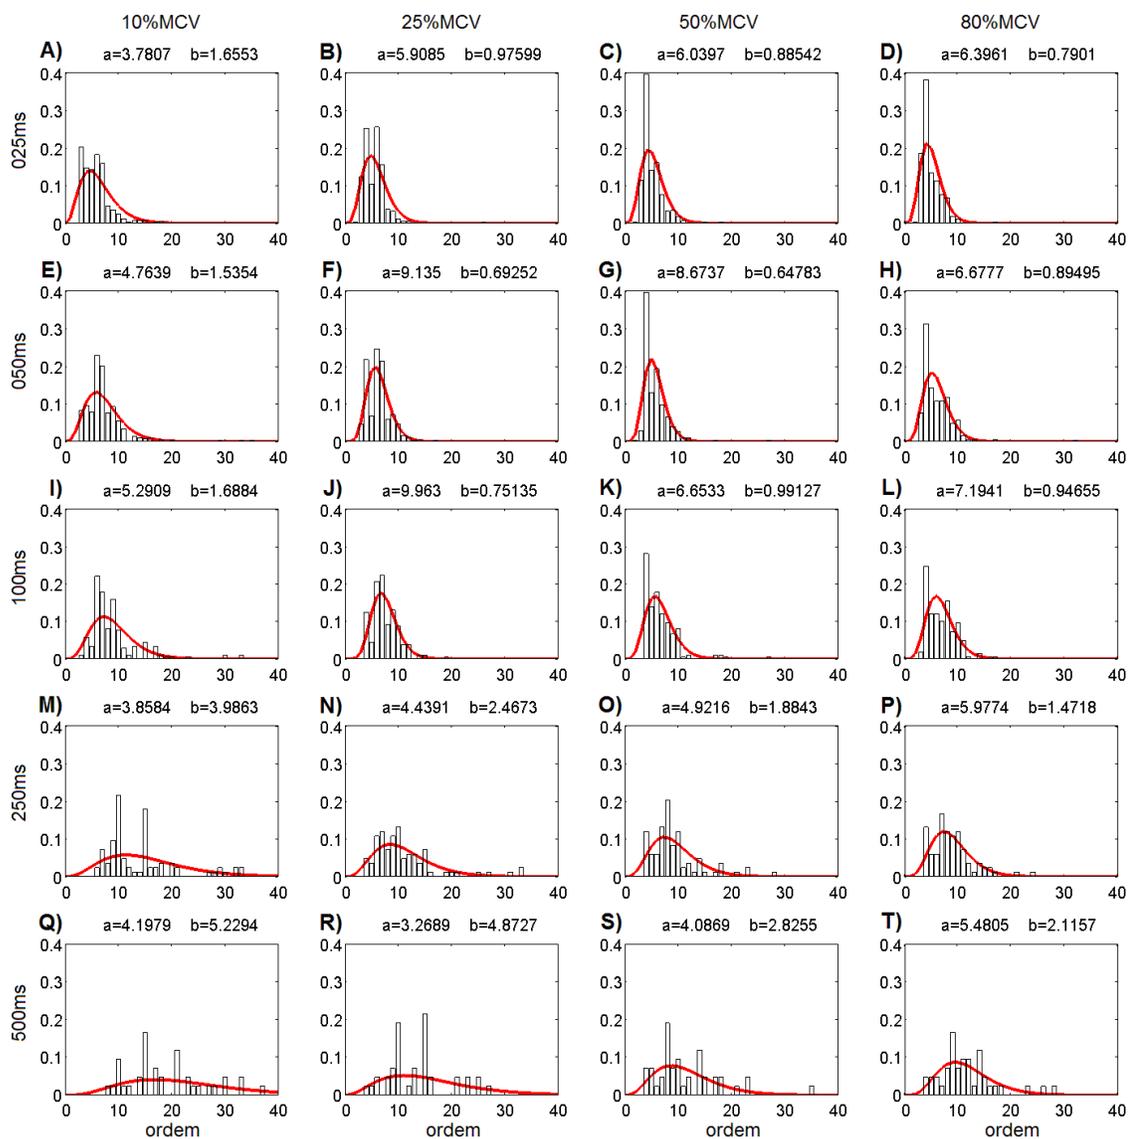


Figura 22 – Ajuste da função densidade de probabilidade Gama

Nas Figuras 19J, 19L, 22J e 22L estão apresentados os ajustes de LogNormal e de Gama para época igual a 100ms e contrações voluntárias iguais a 25% e 80% da MCV. Embora visualmente muito parecidas, para épocas de 100ms, a Gama apresentou-se melhor para modelar 25% da MCV enquanto LogNormal apresentou-se mais eficiente para modelar 80% da MCV. Esse fato pode ser confirmado pelo erro quadrático, apresentado na próxima seção.

4.5 Erro Quadrático

As Tabelas 7 a 11 mostram o erro quadrático de cada SLIT obtido para as distribuições Gaussiana, LogNormal, Gama, de Poisson e de Weibull respectivamente. Para facilitar a observação e comparação dos resultados, os erros foram classificados por cores do **magenta**, para o menor erro dentre as 5 distribuições, ao **roxo**, para o maior erro, passando por **laranja**, **verde** e **azul**.

Tabela 7 – Erro quadrático para distribuição Gaussiana.

contração duração	10% MCV	25% MCV	50% MCV	80% MCV
025ms	0,0600	0,0613	0,0968	0,0839
050ms	0,0529	0,0326	0,0793	0,0466
100ms	0,0502	0,0229	0,0498	0,0342
250ms	0,0683	0,0230	0,0368	0,0195
500ms	0,0497	0,0762	0,0402	0,0226

Tabela 8 – Erro quadrático para distribuição LogNormal.

contração duração	10% MCV	25% MCV	50% MCV	80% MCV
025ms	0,0157	0,0252	0,0367	0,0276
050ms	0,0191	0,0320	0,0521	0,0279
100ms	0,0259	0,0194	0,0287	0,0285
250ms	0,0528	0,0096	0,0236	0,0154
500ms	0,0430	0,0653	0,0326	0,0197

Tabela 9 – Erro quadrático para distribuição Gama.

contração duração	10% MCV	25% MCV	50% MCV	80% MCV
025ms	0,0228	0,0287	0,0509	0,0402
050ms	0,0221	0,0303	0,0594	0,0326
100ms	0,0320	0,0190	0,0333	0,0293
250ms	0,0571	0,0121	0,0254	0,0145
500ms	0,0444	0,0674	0,0335	0,0187

Tabela 10 – Erro quadrático para distribuição Poisson.

contração duração	10% MCV	25% MCV	50% MCV	80% MCV
025ms	0,0255	0,0332	0,0646	0,0565
050ms	0,0199	0,0342	0,0741	0,0389
100ms	0,0369	0,0227	0,0395	0,0309
250ms	0,0810	0,0219	0,0296	0,0166
500ms	0,0691	0,0889	0,0527	0,0211

Tabela 11 – Erro quadrático para distribuição Weibull.

contração duração	10% MCV	25% MCV	50% MCV	80% MCV
025ms	0,0449	0,0578	0,0893	0,0779
050ms	0,0445	0,0334	0,0796	0,0424
100ms	0,0452	0,0241	0,0473	0,0309
250ms	0,0627	0,0186	0,0325	0,0180
500ms	0,0469	0,0713	0,0363	0,0216

4.5.1 Melhores ajustes: LogNormal e Gama

As distribuições Gama e LogNormal foram as que apresentaram os menores erros quadráticos, isto é, as melhores distribuições, segundo as Tabelas 8 e 9, tendo ora a Gama resultado no menor erro quadrático, ora a LogNormal. A Gama apresentou-se melhor para modelar épocas de 50ms e 100ms na contração de 25%

MCV e para épocas de 250ms e 500ms na contração de 80%MCV. Em todos os demais casos, a LogNormal apresentou-se mais eficiente. Vale observar que quando a LogNormal não apresentou o menor erro quadrático (cor magenta), resultou no segundo menor erro (cor laranja), conclusão visualizada pela tabela 8.

4.5.2 Piores ajustes: Gaussiana, Poisson e Weibull

Na tabela 12 estão as piores distribuições: as que apresentaram o maior erro quadrático. A distribuição Gaussiana apresentou-se com o maior erro quadrático para 13 (treze) dos 20 (vinte) SLIT. A distribuição de Poisson apresentou-se com o maior erro quadrático para 5 (cinco) dos 7 SLIT restantes e Weibull para os outros 2. As distribuições LogNormal e Gama não apresentaram o maior erro quadrático, nem o segundo maior erro, para nenhum dos SLIT.

A distribuição Gaussiana apresentou-se como uma das duas piores distribuições entre as cinco apresentadas para 19 (dezenove) dos 20 SLIT, conclusão observada pela quase totalidade da tabela 7 em azul e roxo.

Tabela 12 – Distribuição que apresentou o maior erro quadrático para cada SLIT.

contração duração	10% MCV	25% MCV	50% MCV	80% MCV
025ms	Gaussiana	Gaussiana	Gaussiana	Gaussiana
050ms	Gaussiana	Poisson	Weibull	Gaussiana
100ms	Gaussiana	Weibull	Gaussiana	Gaussiana
250ms	Poisson	Gaussiana	Gaussiana	Gaussiana
500ms	Poisson	Poisson	Poisson	Gaussiana

4.5.2.1 Gaussiana e Poisson

Comparando-se apenas as distribuições Gaussiana e Poisson, obtém-se a tabela 13, que é uma forma de rerepresentar parte dos resultados contidos nas tabelas Tabelas 7 e 10. Observa-se que Poisson se mostra pior conforme a ordem

ótima aumenta, isto é, para os SLITs referentes às contrações fracas e épocas maiores. Assim, uma conclusão secundária que pode ser observada para os piores ajustes é que a distribuição de Poisson piora sua eficiência para representar contrações musculares mais fracas e épocas maiores, correspondentes às células do canto inferior esquerdo (cor roxa) da Tabela 13.

Tabela 13 – Maior erro quadrático dentre as distribuições de Poisson e Gaussiana.

contração duração	10% MCV	25% MCV	50% MCV	80% MCV
025ms	Gaussiana	Gaussiana	Gaussiana	Gaussiana
050ms	Gaussiana	Poisson	Gaussiana	Gaussiana
100ms	Gaussiana	Gaussiana	Gaussiana	Gaussiana
250ms	Poisson	Gaussiana	Gaussiana	Gaussiana
500ms	Poisson	Poisson	Poisson	Gaussiana

4.5.2.2 Poisson e Weibull

Comparando o desempenho das distribuições Weibull e Poisson, temos que Poisson se mostra pior conforme a ordem ótima aumenta, isto é, para os SLITs de contrações fracas e épocas maiores. A Tabela 14, para facilitar a comparação sugerida, é uma forma de rerepresentar parte dos resultados contidos nas tabelas Tabelas 10 e 11.

Tabela 14 – Maior erro quadrático dentre as distribuições de Poisson e Weibull.

contração duração	10% MCV	25% MCV	50% MCV	80% MCV
025ms	Weibull	Weibull	Weibull	Weibull
050ms	Weibull	Poisson	Weibull	Weibull
100ms	Weibull	Weibull	Weibull	Weibull
250ms	Poisson	Poisson	Weibull	Weibull
500ms	Poisson	Poisson	Poisson	Weibull

Comparando as Figuras 20 e 21, em especial a 20E com 21E e 20I com a 21I, percebe-se uma significativa inserção de erro na distribuição de Weibull decorrente de uma distribuição não nula para as primeiras ordens em contraste com a Poisson. É interessante resaltar, também, que uma função com parâmetros de forma e escala, como Weibull, apresentou um rendimento inferior ao da distribuição 'rígida' como Poisson em várias combinações de duração de época e força de contração.

4.5.3 Pior e melhor ajuste: Gaussiana e LogNormal

Comparando o desempenho das distribuições Gaussiana (tabela 7) e LogNormal (tabela 8), percebe-se que ajustar o logaritmo da ordem do sistema AR parece mais adequado do que ajustar a ordem em si. Enquanto a LogNormal manteve-se sempre como uma das duas melhores distribuições para se ajustar ao histograma das ordens ótimas, a Gaussiana apresentou um dos dois maiores erros quadráticos para 19 dos 20 SLIT deste trabalho. Apesar de ser uma distribuição clássica da Estatística, a distribuição Gaussiana foi a que apresentou, de forma geral, os piores ajustes, de acordo com os erros quadráticos.

5. DISCUSSÃO

5.1 Ordem Ótima, Força de Contração e Duração da Época

5.1.1 Efeito da duração da época na ordem

O aumento da ordem ótima com o aumento da duração da época pode ser atribuído a dois fatores, sendo eles:

- o aumento do número de PAUMs com o aumento da época;
- o algoritmo de escolha de critério de comprimento mínimo de descrição.

O critério MDL se baseia em um algoritmo que pondera o comprimento da época e a ordem do modelo da seguinte forma: quanto maior for a época maior será o peso (M) dado à variância σ_n^2 do que o peso ($\log[M]$) dado à ordem autorregressiva n , já que $MDL(n) = N \times \ln[\sigma_n^2] + \ln[N] \times n$. Portanto, existe um ajuste entre o número de amostras e a confiabilidade da variância, em outras palavras, para épocas menores o algoritmo abre mão da fiabilidade da variância aumentando a margem de erro aceitável para com esta em troca de ordens menores. O critério MDL não permite, assim, ordens demasiadamente elevadas para épocas demasiadamente pequenas.

Além da relação de Rissanen, o número de PAUMs presentes na época faz com que o número ótimo de coeficientes aumente. O sinal de EMG de indivíduos normais pode ser considerado não periódico, o que equivale a um sinal com período infinito. No entanto, considerando uma mesma taxa de amostragem, o aumento da duração de um trecho resultaria no aumento do número de PAUMs presentes nesse trecho. Se o potencial de uma mesma unidade motora aparecesse no início e no final do trecho, o segundo PAUM poderia ser modelado identicamente ao primeiro, ou seja $y(t) = a_M y(t-M)$, em que $a_M = 1$. O índice M do coeficiente a_M indicaria o intervalo de tempo (em número de amostras) entre o início do primeiro e do segundo PAUM. Portanto, para épocas mais longas, uma quantidade maior ou igual de

coeficientes seria necessária. Não se pode afirmar que seria uma relação estritamente crescente, mas necessariamente seria crescente, isto é, maior ou igual.

5.1.2 Efeito da força de contração na ordem

Uma forma de interpretar a diminuição da ordem ótima com o aumento da contração muscular está no padrão de interferência dos potenciais de ação de unidade motora (PAUMs) e na representação AR de um pulso.

Relembrando que a ativação repetida do motoneurônio resulta em um trem de PAUMs, típico de contrações musculares fracas. Quando mais de uma unidade motora é ativada, os trens de PAUMs podem sobrepor-se e interferir um no outro, resultando no padrão de interferência, característico de contrações musculares médias e fortes. Portanto, o sinal de EMG pode consistir de um trem de PAUMs ou de um padrão de interferência, dependendo da força de contração muscular.

Supondo que a representação de um PAUM se aproxima matematicamente de um pulso. Lembrando que um pulso é representado por um modelo AR com infinitos coeficientes a_k e uma harmônica é representada com apenas um par de coeficientes a_1 e a_2 , tem-se que com o aumento da contração voluntária o sinal passe de sequência de PAUMs para um padrão de interferência cada vez mais forte (antes da fadiga muscular) e desta forma o número ótimo de coeficientes a_k diminua de infinito para um número finito cada vez mais próximo de 2.

Obviamente um sinal de EMG nunca se aproximaria de uma única harmônica, mas sem dúvida pode ser representado por somatórias de harmônicas e devido ao padrão de interferência para contrações mais fortes, a representação se afasta de um pulso. Ou seja, contrações fortes apresentam padrão de interferência acentuado, sendo necessárias algumas harmônicas para representá-lo. Em contrapartida, contrações leves apresentam menor padrão de interferência, sua representação se aproxima de pulsos sendo necessárias mais harmônicas para representá-lo.

Outra possível justificativa para a redução da ordem com o aumento da força de contração está associada ao espectro. Os trechos de maior força de contração podem apresentar fadiga muscular, o que se manifestaria pelo deslocamento do

espectro para frequências mais baixas. Os componentes de alta frequência, portanto, diminuem de valor e contribuem pouco para o espectro. Consequentemente, não são necessários pólos nas altas frequências. Com isso, a ordem do modelo AR diminui.

Independentemente da explicação dada, a diminuição da ordem ótima com o aumento da força de contração indica que os modelos AR são mais apropriados para descrever padrões de interferência do que trens de PAUMs.

Esta pode ser a razão da baixa taxa de Pattichis e Elia (1999), questionamento levantado na Introdução desta dissertação. Pense que o aparecimento de PAUM em sinal de EMG, representa baixa força de contração, ausência de padrão de interferência e, portanto, não está dentro da condição ideal para a modelagem AR, diferentemente de Inbar e Noujaim (1987) que utilizaram 50% MCV. Uma outra explicação para este resultado pode ser o tamanho da época utilizada. Pattichis e Elia (1999) utilizaram a menor época da literatura, a qual poderia não ser suficiente para aplicação de modelo AR.

Vale ressaltar que independente de ser um trem de PAUMs ou um padrão de interferência, o sinal de EMG foi representado por modelos AR cuja ordem é melhor descrita pela distribuição LogNormal (78% dos casos), que representa o logaritmo da ordem por uma distribuição Gaussiana. E os outros 22% dos SLIT são melhor descritos pela distribuição Gama, conforme a discussão a seguir.

5.2 Distribuições e Erro Quadrático

5.2.1. Melhores Ajustes: LogNormal e Gama

Comparando as Figuras 19 e 22, em especial as Figuras 19F, 19J, 22F e 22J, observa-se que a LogNormal e Gama são visualmente muito parecidas. Esta intrigante semelhança não poderia passar despercebida. Conhecer as propriedades e utilização da distribuição Gama revela um resultado interessante para este trabalho:

A distribuição Gama é uma distribuição da família Personiana de distribuições, que é muito utilizada para modelar o logaritmo da variável. Desta forma fica compreensível porque a distribuição Gama compete em desempenho com a LogNormal, logaritmo da distribuição Gaussiana, neste trabalho. Tem-se, assim, reforçada a suposição de que distribuições que modelem o logaritmo da variável sejam apropriadas para modelar o número ótimo de coeficientes AR de sinais de EMG de agulha para indivíduos saudáveis.

5.2.2 Piores ajustes: Gaussiana, Poisson e Weibull

5.2.2.1 Gaussiana e Poisson

A distribuição Gaussiana, historicamente, teve seu primeiro uso como uma aproximação da distribuição binomial para o caso contínuo. Poisson pode ser visto como o caso limite da distribuição binomial quando $N \rightarrow \infty$, $p \rightarrow 0$ e $N \times p = \lambda$. Assim, para λ grande, a distribuição de Poisson se aproxima da distribuição Gaussiana para o caso específico de média $\mu = \lambda$ e variância $\sigma^2 = \lambda$. Oras, neste caso a distribuição Gaussiana é mais eficiente, uma vez que engloba o caso específico de média μ e variância σ^2 iguais a λ , o que explicaria porque Poisson perde eficiência para Gaussiana com o aumento da ordem ótima. Uma outra forma de interpretar a perda de eficiência da Poisson seria a conclusão de que a variância σ^2 do sinal é grande e não aumenta proporcionalmente com a média μ do sinal, como se esperaria para uma distribuição de Poisson.

5.2.2.2 Poisson e Weibull

A distribuição de Weibull, implementada neste trabalho, foi a distribuição clássica, com parâmetros de forma e escala, no entanto, fixa no eixo x. Esta pode ser a causa de uma função com parâmetros de forma e escala ter apresentado um

rendimento inferior ao da distribuição 'rígida' como Poisson, principalmente para as forças de contração mais altas e as durações de época mais curtas da Tabela 13.

5.2.3 Pior e Melhor Ajuste: Gaussiana e LogNormal

As Figuras 18 e 19, além das Tabelas 7 e 8, revelaram que definitivamente a distribuição LogNormal modela melhor os histogramas do que a Gaussiana. A razão para este desempenho pode estar no fato de que a distribuição Gaussiana é simétrica enquanto a LogNormal é assimétrica e capaz de melhor representar a elevação abrupta da concentração de coeficientes para ordens baixas e uma suave queda de concentração para ordens maiores, característica dos histogramas normalizados de ordens ótimas.

A distribuição Gaussiana foi mantida nesta dissertação para apresentar que, se por um lado, a ordem dos modelos não segue uma distribuição normal, por outro, o logaritmo da ordem segue.

6. TRABALHOS FUTUROS E CONCLUSÃO

6.1 Trabalhos Futuros

6.1.1 Outras distribuições

A distribuição de Weibull, diferentemente da forma tradicional que foi implementada neste trabalho, pode ter sua função densidade de probabilidade dependente de três parâmetros como mostrada a seguir:

$$y = f(x | a, b, c) = ba^{-b} (x - c)^{b-1} e^{-\left(\frac{x-c}{a}\right)^b}, \quad (14)$$

em que a é o parâmetro escalar, b é o parâmetro de forma e c é o parâmetro de localização da distribuição. O parâmetro c é a origem da distribuição, isto é, x só está definido para $x > c$. Este terceiro parâmetro, c , é responsável por “deslizar” a distribuição ao longo do eixo x . Provavelmente a inclusão do terceiro parâmetro, o deslocamento, permitirá que a distribuição de Weibull forneça resultados melhores do que uma distribuição rígida (com apenas um parâmetro) como a Poisson. Sugere-se então, em trabalhos futuros, a implementação da distribuição de Weibull com três parâmetros.

6.1.2. Casos patológicos

Tendo em mente as aplicações sugeridas: simulador computacional e auxiliar diagnósticos, destacar atributos desta modelagem do sinal eletromiográfico que possibilitem distinguir sinais normais de patológicos se faz necessário.

Partindo do modelo biológico de que cada indivíduo tem uma quantidade X de neurônios motores, cada neurônio motor comanda Y fibras musculares, e da modelagem deste trabalho que concluiu que a ordem ótima do modelo AR aumenta

com o aumento da época e diminui com o aumento da força de contração - sendo que a distribuição de ordem ótima, para todos os SLIT estudados neste trabalho, é melhor caracterizada por distribuições que modelem o logaritmo da ordem ótima -, pode-se inferir que: indivíduos miopáticos apresentem ordens ótimas ligeiramente maiores, porém ainda descritas pelas mesmas funções densidade de probabilidade que os indivíduos normais; enquanto indivíduos neuropáticos apresentem ordens acentuadamente maiores sem garantia de serem caracterizadas por distribuições logarítmicas. Estas suposições estão explicadas abaixo.

Como já mencionado, indivíduos com miopatia têm a quantidade de neurônios motores X idêntica a de um indivíduo normal. Desta forma, a diferença fundamental está na quantidade de fibras Y comandadas por cada neurônio. Há visualmente o mesmo padrão de interferência presente nos sinais de indivíduos normais. A maior diferença estaria na amplitude do sinal; no entanto, a amplitude do sinal depende da máxima força que o indivíduo pode exercer: MCV. Enquanto um indivíduo aplica 50kgf, outro aplica 30kgf, ou seja, já é variável entre indivíduos normais.

Uma outra forma de avaliar a situação seria se atentar à quantidade de fibras ativadas, uma vez que as unidades motoras em indivíduos miopáticos são ativadas com a mesma frequência que em indivíduos normais. Didaticamente suponha que cada neurônio motor de um indivíduo normal ative 20 fibras, enquanto que um indivíduo miopático ative 14, tendo 6 fibras atrofiadas. Suponha ainda que para realizar 50% da MCV, eles comandem 10 neurônios motores: o indivíduo normal ativaria 200 fibras enquanto o portador de miopatia ativaria 140. Esta diferença poderia ser interpretada pela modelagem como a aplicação de uma força menor, resultando em um número ligeiramente maior de coeficientes para descrever o SLIT, mas a distribuição de coeficientes manter-se-ia logaritmicamente distribuída e a ordem ótima do modelo se manteria diretamente proporcional ao comprimento da época.

Estudos iniciais paralelos a esta dissertação apresentam resultados que caminham para comprovar esta teoria. Segundo Vicente e Itiki (2014), a média da ordem ótima de coeficientes de indivíduos miopáticos tende a ser ligeiramente maior que a de indivíduos normais para uma contração equivalente a 50% da MCV, sendo a distribuição de coeficientes melhor descrita por função densidade de probabilidade que modele o logaritmo da ordem ótima. A distribuição LogNormal foi a que melhor

descreveu a distribuição das ordens ótimas entre as três distribuições testadas (Gaussiana, LogNormal e Weibull) e a média da ordem ótima tendeu a aumentar como o aumento da época, reforçando as suposições do parágrafo anterior.

Relembrando a modelagem biológica do sistema neuromuscular de portadores de neuropatia: Há perda de neurônios, fibras musculares ficam sem receber estímulos atrofiando-se ou são reenergizadas por outros neurônios. Temos assim um número maior Y de fibras comandadas por cada neurônio motor, entretanto, o número total de neurônios X é reduzido, reduzindo assim o número total de fibras que podem ser ativadas. É importante ressaltar também que as unidades motoras não são ativadas em indivíduos neuropáticos com a mesma frequência que em indivíduos normais (X diferente, ver Figura 24) e o sinal de EMG apresenta um padrão de interferência rarefeito e PAUMs gigantes.

Supondo novamente de forma didática que para realizar 50% da máxima contração voluntária um indivíduo ative 7 motoneurônios (a mesma redução de 30% aplicada na suposição anterior), no entanto cada motoneurônio ative 23 fibras, tem-se 161 fibras que resultaria em um leve aumento no número ótimo de coeficientes seguindo o raciocínio anterior.

Todavia, tendo em mente que a representação matemática de um pulso exige infinitos coeficientes e o sinal de EMG de indivíduos neuropáticos é caracterizado pela quase ausência do padrão de interferência e a presença de PAUMs gigantes, pode-se inferir que: a ordem ótima de coeficientes necessária para modelar um sinal neuropático será significativamente maior que a ordem necessária para indivíduos normais e miopáticos. Assim, diante do discutido, somado à menor frequência de ativação de unidades motoras, a distribuição logarítmica não está mais assegurada.

6.2. Conclusão

A ordem ótima do modelo AR de sinais de EMG de agulha de indivíduos normais tende a diminuir com o aumento da força de contração voluntária e aumentar com a duração da época.

As distribuições que modelam o logaritmo da ordem e, assim, possuem flexibilidade para transladar no eixo "x" apresentam as funções densidade de probabilidade mais apropriadas para representar o número ótimo de coeficientes AR estudados neste trabalho.

O mesmo estudo pode ser realizado para sinais eletromiográficos característicos de patologias como miopatia e neuropatia, confirmando ou negando as projeções sugeridas por este trabalho.

REFERÊNCIAS

- Akaike, H. "A new look at the statistical model identification," *IEEE Transactions on Automatic Control*, vol. AC-19, no. 6, p. 716–723, 1974.
- Akaike, H. "A Bayesian analysis of the minimum AIC procedure," *Annals of the Institute of Statistical Mathematics*, vol. 30, part A, p. 9–14, 1978.
- Bear, M.; Connors, B. W.; Paradiso, M. A. "Neurociência Desvendando o sistema nervosa", 3° ed. Porto Alegre, Artmed, 2008.
- Berzuini, C.; Maranzana-Figini, M.; Bernardinelli, L.; "Effective use of EMG parameters in the assessment of neuromuscular diseases," *International Journal of Bio-Medical Computing*, vol. 13, p. 481–499, 1985.
- Chen, X.; Zhu, X.; Zhang, D. "Use of the discriminant Fourier-derived cepstrum with feature-level post-processing for surface electromyographic signal classification," *Physiol. Meas.*, vol. 30, no. 12, p. 1399–1413, 2009.
- Chiang, J.; Wang, Z.; McKeown, M.J. "Hidden Markov multivariate autoregressive (HMM-mAR) modeling framework for surface electromyography (sEMG) data," *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, 2007, p. 4826–4829, 2007.
- Chiou, Y.H. et al. "The comparison of electromyographic pattern classifications with active and passive electrodes," *Med. Eng. Phys.*, vol. 26, no. 7, p. 605–610, 2004.
- Clancy, E. A.; Farina, D.; Merletti, R. "Cross-comparison of time- and frequency-domain methods for monitoring the myoelectric signal during a cyclic, force-varying, fatiguing hand-grip task," *J. Electromyogr. Kinesiol.*, vol. 15, no. 3, p. 256–265, 2005.
- Cunha, F. L. "Mão de São Carlos, uma prótese multifunção para membros superiores: um estudo dos mecanismos, atuadores e sensores". Tese doutorado. São Carlos, 2002.
- Friedman, M. The use of ranks to avoid the assumption of normality implicit in the analysis of variance. *Journal of the American Statistical Association*, vol. 32, n. 200, p. 675-701, dez 1937

Güler, N. F., Koçer, D. "Use of support vector machines and neural network in diagnosis of neuromuscular disorders," *J. Med. Syst.*, vol. 29, no. 3, p. 271–284, 2005.

Hill, A. V. "The mechanics of active muscle", *Proc R Soc Lond B Biol Sci*, vol. 141, no. 902, p. 104-17, mar 1953.

Hodgkin, A. L.; Huxley, A. F. "A quantitative description of membrane current and its application to conduction and excitation in nerve," *J Physiol*, vol. 117, no. 4, p. 500-544, ago 1952.

Huang, H.; Xie, H. B.; Guo, J. Y.; Chen, H. J. "Ant colony optimization-based feature selection method for surface electromyography signals classification," *Computers in Biology and Medicine*, vol. 42, no. 1, p. 30-38, jan 2012.

Ike, I. K., "Modelagem Auto-Regressiva e memórias associativas na classificação de sinais de eletromiográficos de agulha", Dissertação de mestrado, São Paulo, 2001.

Inbar, G. F.; Noujaim, A. E. "On surface EMG spectral characterization and its application to diagnostic classification," *IEEE Transactions on Biomedical Engineering*, vol. 31, no. 9, p. 597–694, 1984.

Itiki, C. "Comparação entre critérios de seleção da ordem de modelos auto-regressivos para sinais eletromiográficos de agulha". In: XVIII Congresso Brasileiro de Engenharia Biomédica, 2002, São José dos Campos. *Anais de Trabalhos Completos do XVIII Congresso Brasileiro de Engenharia Biomédica*. São José dos Campos: UNIVAP, 2002. v. 5. p. 347-351.

Itiki, C. "Epoch length and autoregressive-order selection for electromyography signals," *Proceedings of the 34th Annual International Conference of the IEEE-EMBS*, San Diego, USA, 28 Aug.-1 Sept., p. 3476–3479, 2012.

Kandel, E. R.; Schwartz, J. H.; Jessell, T. M. "Princípios da Neurociência", Manole, 4° ed. Barueri, 2003.

Karlsson, S.; Yu, J. "Estimation of surface electromyogram spectral alteration using reduced-order autoregressive model," *Med. Biol. Eng. Comput.*, vol. 38, no. 5, p. 520–527, 2000.

Kay, S. M. *Modern Spectral Estimation: Theory and Application*, Englewood Cliffs: Prentice- Hall, 1987, p. 234–237.

Latwesen, A.; Patterson, P. E. "Identification of lower arm motions using the EMG signals of shoulder muscles," *Med. Eng. Phys.*, vol. 16, no. 2, p. 113–121, 1994.

Ljung, L. *System Identification Theory for the User*, 2nd ed. Upper Saddle River, NJ: PTR Prentice Hall, 1999, ch.10.

Luca, C. J. D., "Physiology and Mathematics of Myoelectric Signals", *IEEE Transactions on Biomedical Engineering*, vol. BME-26, no. 6, p. 313-325, 1979.

Merletti, R.; Conte, L. L.; Avignone, E.; Guglielminotti, P. "Modeling of surface myoelectric signals – part I: model implementation", *IEEE Transactions on Biomedical Engineering*, vol. 46, no. 7, p. 810–820, julho 1999

Mesin, L.; Farina, D. "An analytical model for surface EMG generation in volume conductors with smooth conductivity variations", *IEEE Transactions on Biomedical Engineering*, vol. 53, no. 5, p. 773–779, maio 2006

Paiss, O.; Inbar, G. F. "Autoregressive modeling of surface EMG and its spectrum with application to fatigue," *IEEE Trans. Biomed. Eng.*, vol. 34, no. 10, p.761–770, 1987.

Pattichis, C. S.; Elia, A. G.; "Autoregressive and cepstral analyses of motor unit action potentials," *Medical Engineering and Physics*, vol. 21, n. 6–7, p. 405–419, 1999.

Rissanen, J. "A universal prior for the integers and estimation by minimum description length," *The Annals of Statistics*, vol. 11, p. 417–431, 1983.

Romaro, C.; Itiki, C. "Variação da ordem autorregressiva com a força de contração muscular e duração do eletromiograma", In: XXIV Congresso Brasileiro de Engenharia Biomédica, 2014, Uberlândia. *Anais do XXIV Congresso Brasileiro de Engenharia Biomédica*, 2014, v.1, p. 365-368.

Shirota, C.; Itiki, C. "Estudo da ordem de modelos auto-regressivos para sinais eletromiográficos normais, miopáticos e neuropáticos", In: XVIII Congresso Brasileiro de Engenharia Biomédica, 2002, São José dos Campos. *Anais de Trabalhos Completos do XVIII Congresso Brasileiro de Engenharia Biomédica*. São José dos Campos: UNIVAP, 2002. v. 5. p. 352-354.

Vicente, J. G.; Itiki, C. "Optimal autoregressive orders for myopathic electromyograms" *Proceedings of the 36th Annual International Conference of the IEEE-EMBS*, Chicago, USA, p. 114-117, 2014.

Vieira, M. F.; Kohn, A.F. "Compartmental models of mammalian motoneurons of types S, FR and FF and their computer simulation", *Comput Biol Med.* , vol. 37, no. 6, p. 842-860, jun 2007.

Wald, A.; Wolfowitz, J. "Optimum character of the sequential probability ratio test," *Annals of Mathematical Statistics*, vol. 19, no. 3, p. 326–339, 1948.

Young, A. J.; Hargrove, L. J.; Kuiken, T. A. "Improving myoelectric pattern recognition robustness to electrode shift by changing interelectrode distance and electrode configuration," *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 3, p. 645-52, Mar 2012.

Zhang, Z. G.; Zhang, Z. G.; Liu, H. T.; Chan, S. C.; Luk, K. D.; Hu Y. "Time-dependent power spectral density estimation of surface electromyography during isometric muscle contraction: methods and comparisons," *Journal of Electromyography and Kinesiology*, vol. 20, no. 1, p. 89-101, Feb 2010.

APÊNDICE

APÊNDICE A –Doenças neuromusculares

Embora este trabalho modele sinais de EMG de indivíduos normais, isto é, saudáveis, entender como as patologias afetam o sistema neuromuscular é fundamental para a compreensão da conclusão deste trabalho.

Uma patologia na unidade motora pode atingir o corpo celular do motoneurônio, o axônio do neurônio motor ou as fibras musculares. Geralmente atinge apenas um dos três, sendo classificada como miopatia quando atinge as fibras musculares e neuropatias nos outros dois casos. Independentemente da estrutura afetada, a doença neuromuscular culmina com fraqueza progressiva e eventualmente a atrofia dos músculos (Kandel, 2003).

A.1 Miopatia e Neuropatia

Em indivíduos normais, uma unidade motora comanda um determinado número de fibras musculares e estas estão intercaladas com fibras comandadas por outras unidades motoras formando, assim, um padrão aleatório.

Em um indivíduo com neuropatia, o axônio ou o corpo celular dos neurônios são comprometidos. O axônio deixa de comandar a fibra muscular inervada por ele e esta passa a ficar 'disponível'. Como a neuropatia atinge muitos neurônios e assim seus axônios, muitas unidades motoras deixam de funcionar. Em contrapartida, os neurônios saudáveis 'percebem' a existência de fibras musculares 'disponíveis' próximas a suas fibras. Eles criam, então, ramificações de seus axônios para reinervar as fibras antes desenergizadas das unidades motoras anômalas. O indivíduo com neuropatia tem, portanto, um menor número de unidades motoras; mas cada uma delas é mais forte que a unidade de um indivíduo saudável, pois recruta mais fibras musculares. Como nem todas as fibras desenergizadas são reinervadas, há atrofia das fibras que não foram reinervadas e perda de força muscular. (Kandel, 2003) A Figura 23 ilustra a alteração histoquímica do tecido muscular, resultante do processo de reinervação.

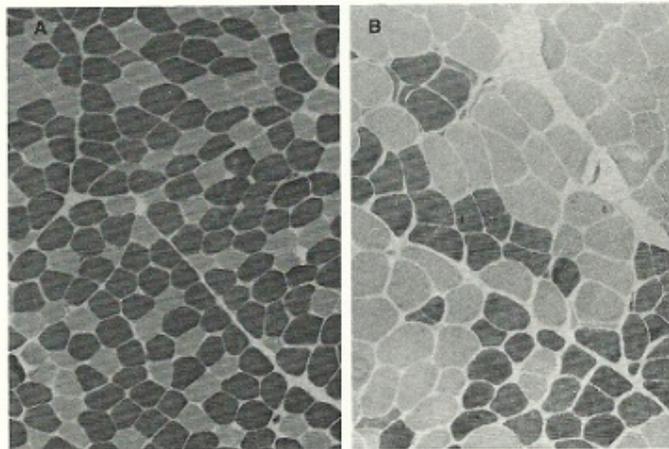


Figura 23 – Distribuição das fibras musculares de unidades motoras do músculo gastrocnêmio: a) em indivíduos normais, as fibras musculares de dois tipos são distribuídas de forma aleatória; enquanto que b) em indivíduos neuropáticos, as fibras musculares de mesmo tipo se agrupam, pois as fibras reinervadas assumem as mesmas características das demais fibras da unidade motora. Fonte: Adaptado de Kandel (2003, p. 698)

Em um indivíduo com miopatia, as fibras musculares são patológicas e não os neurônios. Desta forma, na miopatia não há perda das funções sensoriais, como ocorre na neuropatia quando os axônios motores e sensoriais são afetados. As fibras patológicas estão distribuídas em um padrão aleatório no músculo atingindo muitas unidades motoras, mas sem deteriorá-las por completo. Consequentemente, um indivíduo com miopatia tem o mesmo número de unidades motoras de um indivíduo sadio, no entanto cada uma delas é levemente mais fraca, pois comanda um menor número de fibras musculares. (Kandel, 2003)

A.2 Critérios clínicos e dosagem de enzimas para o diagnóstico

A caracterização e a distinção entre miopatia e neuropatia são realizadas com base em critérios laboratoriais e clínicos.

A dosagem sérica de enzimas (creatinocinase, transaminase glutâmico oxalacética e desidrogenase láctica) é um indicador de miopatia, pois tem uma elevação mais acentuada nesta que na neuropatia (Kandel, 2003). Porém, a dosagem das atividades enzimáticas não é um item suficiente para o diagnóstico.

Geralmente a fraqueza distal caracteriza doenças neurogênicas, enquanto a fraqueza proximal caracteriza doenças miopáticas; no entanto existem muitas exceções, não sendo este um sintoma determinante. (Kandel, 2003)

A presença de fasciculação (contração sincronizada e involuntária de todas as fibras de uma unidade motora, que resulta em um tremor visível a olho nu) é suficiente para se diagnosticar uma neuropatia. No entanto, sua ausência não permite excluir a hipótese de neuropatia, pois raramente aparecem em neuropatias periféricas. (Kandel, 2003)

A.3 Eletromiografia para o diagnóstico

Pacientes com neuropatias apresentam um menor número de unidades motoras, mas cada unidade motora engloba um maior número de fibras musculares. Desta forma, apresentará PAUMs maiores ao de um indivíduo normal. No entanto, o padrão de interferência será rarefeito, ou seja, será possível distinguir os PAUM, pois não haverá sobreposição, conforme ilustrado na Figura 24.b. (Kandel, 2003)

Por outro lado, pacientes com miopatias têm um menor número de fibras musculares comandadas por neurônios. Assim este paciente apresenta o mesmo número de unidades motoras de um indivíduo sadio, mas cada unidade motora engloba um número menor de fibras musculares. Desta forma, a amplitude do potencial de ação do indivíduo com miopatia será reduzida em relação àquela de um

indivíduo normal. No entanto, os dois apresentarão um padrão de interferência completo, ou seja, não rarefeito, conforme a Figura 24.c. (Kandel, 2003)

Em ambos os casos patológicos há fibrilação (atividade elétrica espontânea de fibras musculares, mesmo quando todas as unidades motoras estiverem em repouso). A fibrilação é decorrente da descarga de uma única fibra muscular, não é visível a olho nu, aparecendo assim apenas na EMG. (Kandel, 2003)

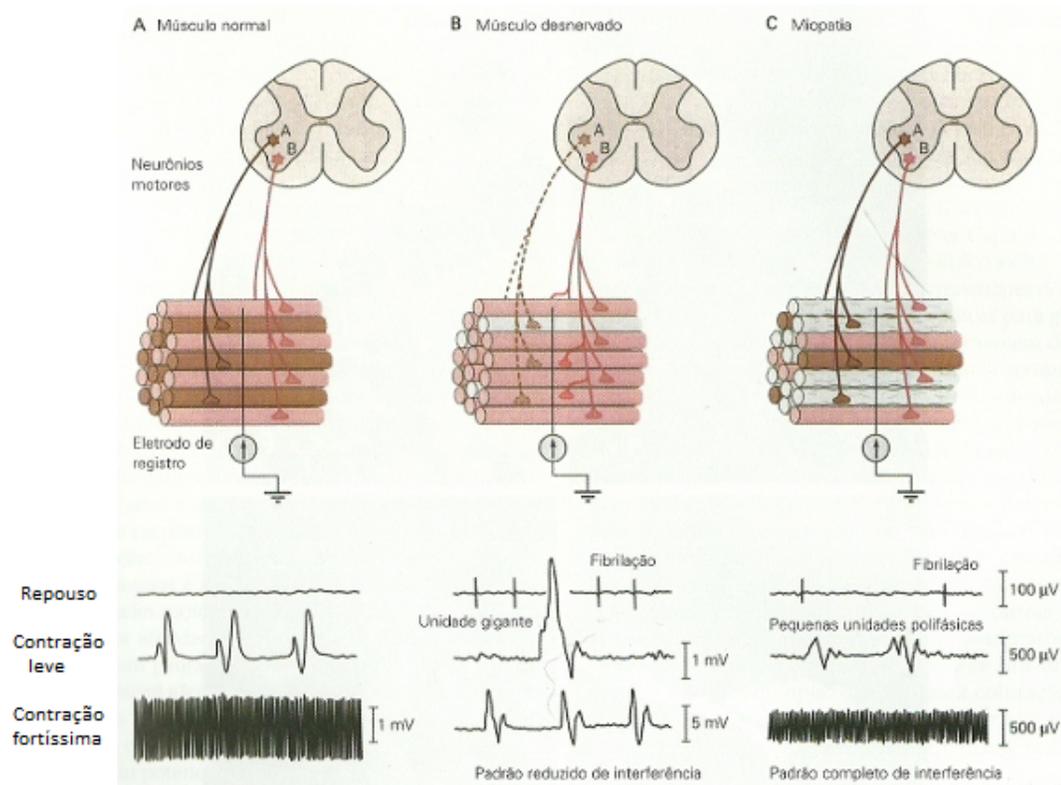


Figura 24 – Sinais típicos de eletromiografia para músculo em repouso, contração fraca e contração forte, provenientes de indivíduos a) normal; b) neuropático e c) miopático. Fonte: Kandel (2003, p.697)

APÊNDICE B – Fatoração QR

O método de estimação dos coeficientes e da variância foi a minimização do erro quadrático pela fatoração QR (Ljung, 1999), descrito a seguir.

Para uma época de N amostras, o erro poderia ser representado por

$$\mathbf{e}_N = \mathbf{y}_N - \Phi \boldsymbol{\theta}_n, \quad (15)$$

em que $\mathbf{y}_N^T = [y(1) \ y(2) \ \dots \ y(N)]$ contém as amostras da época, $\mathbf{e}_N^T = [e(1) \ e(2) \ \dots \ e(N)]$ é o vetor de erro, $\boldsymbol{\theta}_n^T = [a_1 \ a_2 \ \dots \ a_n]$ contém os coeficientes autorregressivos, $\Phi^T = [\varphi^T(1) \ \varphi^T(2) \ \dots \ \varphi^T(N)]$ é a matriz de amostras passadas da época e $-\varphi^T(t) = [y(t-1) \ y(t-2) \ \dots \ y(t-n)]$ são as épocas deslocadas, para $t=1, 2, \dots, N$.

A minimização do erro quadrático, descrito na equação 16, resulta na estimativa $\hat{\boldsymbol{\theta}}_n$

$$V_N(\boldsymbol{\theta}_n, \mathbf{y}_N) = (\mathbf{y}_N - \Phi \boldsymbol{\theta}_n)^T (\mathbf{y}_N - \Phi \boldsymbol{\theta}_n). \quad (16)$$

A fatoração QR (Ljung, 1999) é uma forma de minimizar o erro quadrático. A matriz ortonormal \mathbf{Q} de dimensão N por N e a matriz triangular superior \mathbf{R} de dimensão N por $(n+1)$ descrevem a relação

$$[\Phi \ \mathbf{y}_N] = \mathbf{Q} \mathbf{R} \quad (17)$$

em que $\mathbf{Q}^T \mathbf{Q} = \mathbf{I}$ e $\mathbf{R} = \begin{bmatrix} \mathbf{R}_1 & 0 & \mathbf{0}_{n \times p} \\ \mathbf{r}_2 & r_3 & \mathbf{0}_{1 \times p} \end{bmatrix}^T$, para uma matriz quadrada \mathbf{R}_1 de dimensão n por n , um vetor linha \mathbf{r}_2 de comprimento n e um escalar r_3 . A matriz e o vetor nulos inserem zeros para que a matriz \mathbf{R} totalize $(n+1)$ linhas e $(n+1)$ colunas. (Itiki, 2012)