

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

KARINA DE OLIVEIRA ALVES DE MOURA

**MODELO ADAPTATIVO BASEADO EM SENSOR VIRTUAL
PARA ELETROMIOGRAFIA DE SUPERFÍCIE COM
SISTEMA DE CLASSIFICAÇÃO TOLERANTE A FALHAS**

Porto Alegre

2018

KARINA DE OLIVEIRA ALVES DE MOURA

**MODELO ADAPTATIVO BASEADO EM SENSOR VIRTUAL
PARA ELETROMIOGRAFIA DE SUPERFÍCIE COM
SISTEMA DE CLASSIFICAÇÃO TOLERANTE A FALHAS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, da Universidade Federal do Rio Grande do Sul, como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.

Área de concentração: Controle e Automação - Instrumentação.

ORIENTADOR: Prof. Dr. Alexandre Balbinot

Porto Alegre

2018

KARINA DE OLIVEIRA ALVES DE MOURA

**MODELO ADAPTATIVO BASEADO EM SENSOR VIRTUAL
PARA ELETROMIOGRAFIA DE SUPERFÍCIE COM
SISTEMA DE CLASSIFICAÇÃO TOLERANTE A FALHAS**

Esta tese foi julgada adequada para a
obtenção do título de Doutor em Engenharia
Elétrica e aprovada em sua forma final pelo
Orientador e pela Banca Examinadora.

Orientador: _____

Prof. Dr. Alexandre Balbinot, UFRGS

Doutor pela UFRGS – Porto Alegre, Brasil

Banca Examinadora:

Prof. Dr. Jurandir Nadal, Programa de Engenharia Biomédica - UFRJ

Doutor pela Universidade Federal do Rio de Janeiro – Rio de Janeiro, Brasil

Prof. Dr. Milton Antônio Zaro, PPGIE - UFRGS

Doutor pela Universidade Federal do Rio Grande do Sul – Porto Alegre, Brasil

Prof. Dr. Herbert Martins Gomes, PROMEC - UFRGS

Doutor pela Universidade Federal do Rio Grande do Sul – Porto Alegre, Brasil

Prof. Dr. Jeferson Vieira Flores, PPGEE - UFRGS

Doutor pela Universidade Federal do Rio Grande do Sul – Porto Alegre, Brasil

Prof. Dr. Valner João Brusamarello, PPGEE - UFRGS

Doutor pela Universidade Federal de Santa Catarina – Florianópolis, Brasil

Coordenador do PPGEE: _____

Prof. Dr. João Manoel Gomes da Silva Jr.

Porto Alegre, Setembro de 2018.

"We've all got both light and dark inside us.
What matters is the part we choose to act on.
That's who we really are."

— J.K. Rowling

À minha mãe, que sempre me apoia e incentiva em todas as minhas empreitadas.

Ao meu pai, por todo amor e tempo que me dedica.

Ao meu marido e filho, pelo tempo cedido para esta formação.

AGRADECIMENTOS

Gostaria de agradecer as todas as pessoas que contribuíram de uma forma ou outra na elaboração deste trabalho. Entretanto, gostaria de agradecer em especial a certas pessoas que foram fundamentais para que obtivesse sucesso neste desafio.

Eu agradeço aos meus pais, Ana Marisa de Oliveira Alves e Antonio da Silva Alves, que sempre apoiaram meu estudo, me mostraram os caminhos que eu poderia seguir, em momentos de cansaço, me motivavam e tentavam me ajudar.

Agradeço ao meu marido, Felipe Bittencourt de Moura, que sem dúvida me apoiou em todos os momentos, entendeu toda a pressão que sentia com a pós-graduação.

Gostaria de agradecer em especial ao meu orientador Alexandre Balbinot, que sempre acreditou em mim e continuamente me incentivou para terminar este projeto.

Ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, pela oportunidade de realização de trabalhos em minha área de pesquisa.

Aos colegas do PPGEE pelo seu auxílio e incentivo nas tarefas desenvolvidas durante o curso deste trabalho, em especial Gabriela Favieiro e Vinicius Cene.

Ao CNPq pela provisão da bolsa de doutorado.

RESUMO

Apenas alguns sistemas de controle protético na literatura científica são baseados em algoritmos de reconhecimento de padrões, os quais são adaptados às mudanças que ocorrem no sinal mioelétrico ao longo do tempo, e, frequentemente, tais sistemas não são naturais e intuitivos. As mudanças no sinal mioelétrico são alguns dos vários desafios para as próteses mioelétricas serem amplamente utilizadas. O conceito do sensor virtual, que tem como objetivo fundamental estimar medidas indisponíveis por trás de outras medidas disponíveis, vem sendo utilizado em outras áreas de pesquisa. O sensor virtual aplicado à eletromiografia de superfície (sEMG) pode ajudar a minimizar esses problemas, tipicamente relacionados à degradação do sinal mioelétrico, os quais geralmente provocam uma diminuição na taxa de acerto da classificação dos movimentos por sistemas de inteligência computacional. A principal contribuição deste trabalho é o desenvolvimento de um sistema de classificação de movimentos tolerante a falhas, o qual utiliza o conceito de sensores virtuais para reduzir o impacto de degradação de sinais de sEMG. A segunda contribuição é um modelo do sinal de sEMG dinâmico e adaptativo para o sensor virtual, o qual produz um modelo de saída de sinal independente da aquisição física do sinal de interesse. A modelagem do sinal de sEMG é projetada de forma a combinar os conceitos de multicanais e sua correlação cruzada, além de utilizar um sistema de ajuste dos coeficientes de correlação, a fim de substituir os canais de sinais degradados. Dois modelos são avaliados e detalhados: *Time-Varying Autoregressive Moving Average* (TVARMA) e o *Time-Varying Kalman Filter* (TVK). A terceira contribuição é a combinação de uma análise e detecção da contaminação do sinal realizada por um sensor de detecção tolerante a falhas (*Sensor Fault-Tolerant Detector – SFTD*). Os resultados da classificação dos movimentos foram apresentados comparando as técnicas usuais de classificação com o método da substituição do sinal degradado e um processo de retreinamento do classificador simplificado. Os resultados foram avaliados para cinco tipos de ruído em 16 estudos de caso da degradação dos canais de sEMG. O sistema adaptativo proposto sem o uso de técnicas de retreinamento do classificador recuperou a taxa de acerto média de classificação em até 46% para os ruídos de deslocamento de eletrodos e de saturação. Devido às limitações do sistema proposto quanto aos ruídos de artefato de movimento, de interferência de linha de energia e ECG, o sistema apresentado pode ser utilizado como uma técnica complementar com outras técnicas de classificação para aumentar o impacto clínico da prótese mioelétrica. Entretanto, o sistema ainda requer uma análise quanto a diferentes níveis de SNR antes de uma otimização do algoritmo. Além disso, o modelo TVARMA do sensor virtual obteve uma taxa de acerto média superior em comparação ao modelo TVK na maioria das situações avaliadas neste trabalho.

Palavras-chave: processamento de sinais mioelétricos, Máquina de Vetores de Suporte (SVM), sensor virtual, sistema adaptativo tolerante a falhas.

ABSTRACT

Nowadays, only a few prosthetic control systems in the scientific literature are founded on pattern recognition algorithms adapted to changes that occur in the myoelectric signal over time and, frequently, such systems are not natural and intuitive. These are some of the several challenges for myoelectric prostheses for everyday use. The concept of the virtual sensor, which has as its fundamental objective to estimate unavailable measures based on other available measures, is already being used in other fields of research. The virtual sensor technique applied to surface electromyography (sEMG) can help to mitigate these problems, typically related to the degradation of the myoelectric signal that usually leads to a decrease in the classification accuracy of the movements characterized by intelligent computational systems. Therefore, the main contribution of this work is the Fault-Tolerant Classification System, that was developed using the concept of virtual sensors to reduce the degradation impact of sEMG signals. The second contribution is a dynamic and adaptive virtual sensor model, which produces a signal output model independent of the physical acquisition of the interest signal. The sEMG signal modeling was designed to combine multichannel concepts and their cross-correlation, in addition to the use of the correlation coefficient adjustment system to replace degraded signal channels. Two models were evaluated and detailed: Time-Varying Autoregressive Moving Average (TVARMA) and Time-Varying Kalman Filter (TVK). The third contribution is the analysis and detection of signal contamination by a Sensor Fault-Tolerant Detector (SFTD). The classification results of the movements were compared to the traditional classification techniques, the classification with the degraded signal replacement method and a simplified re-training process of the classifier. The results were evaluated for five noise types in 16 case studies of the sEMG channels degradation. The adaptive system proposed, without the classifier re-training techniques, was able to recover 46% of the mean classification accuracy for the electrodes displacement and saturation noise. Moreover, the proposed system can be used as a complementary technique with other classification techniques to increase the clinical impact of the myoelectric prosthesis since there are still limitations in the proposed method regarding the movement artifact noise, power line, and ECG interference. However, the system still requires an analysis of different SNR levels before the algorithm optimization. Also, the TVARMA model of the virtual sensor obtained a higher classification accuracy compared to the TVK model in most of the evaluated situations.

Keywords: myoelectric signal processing, Support Vector Machine (SVM), virtual sensor, adaptive fault tolerant system.

SUMÁRIO

1	INTRODUÇÃO	18
2	PRINCÍPIOS BÁSICOS SOBRE ELETROMIOGRAFIA	23
2.1	SINAL MIOELÉTRICO	23
2.2	PROCESSO DE CONTRAÇÃO MUSCULAR	24
2.3	MÚSCULOS ESQUELÉTICOS	25
2.4	SINAL MIOELÉTRICO DE SUPERFÍCIE	27
2.5	AQUISIÇÃO DE SINAIS MIOELÉTRICOS	28
2.6	EXTRAÇÃO DE CARACTERÍSTICAS	29
3	PROCESSAMENTO DE SINAIS DE SEMG	31
3.1	PROCEDIMENTOS DE SEGMENTAÇÃO	31
3.1.1	Procedimento de Segmentação por <i>Timestamp</i>	32
3.1.2	Procedimento de Segmentação Inteligente	33
3.2	MÉTODOS PROEMINENTES DE CLASSIFICAÇÃO EM SINAIS DE SEMG	34
3.2.1	Lógica <i>Fuzzy</i>	35
3.2.2	<i>Linear Discriminant Analysis</i> (LDA)	37
3.2.3	Redes Neurais Artificiais (RNA)	40
3.2.4	Máquinas de Vetores de Suporte (SVM)	42
3.3	INSTRUMENTAÇÃO INTELIGENTE	52
3.3.1	Técnicas Inteligentes Utilizadas em EMG	54
3.3.1.1	<i>Principle Component Analysis</i> (PCA)	59
3.3.1.2	Sistemas Multiusuários	60
3.3.2	Sensores Virtuais	63
3.3.2.1	<i>Time-Varying Autoregressive Moving Average</i> (TVARMA)	63
3.3.2.2	Filtro de Kalman	66
4	SISTEMA DE CLASSIFICAÇÃO TOLERANTE A FALHAS	70
4.1	AQUISIÇÃO DA BASE DE SINAIS DE SEMG	72
4.2	PRÉ-PROCESSAMENTO	78
4.3	MÉTODO EMPREGADO DE SEGMENTAÇÃO	81
4.4	CONTAMINAÇÃO DE SINAIS DE SEMG	83
4.5	SENSOR DE DETECÇÃO TOLERANTE A FALHAS	87
4.6	EXTRAÇÃO DE CARACTERÍSTICAS	90
4.7	SENSOR VIRTUAL	91
4.2.1	Modelo <i>Time-Varying Autoregressive Moving Average</i> (TVARMA)	97
4.2.2	Modelo <i>Time-Varying Kalman Filter</i> (TVK)	100
4.8	ETAPA DE CLASSIFICAÇÃO	101
4.9	PROJETO DE EXPERIMENTOS	109
5	RESULTADOS E DISCUSSÃO	112
5.1	Resultados e Análise Estatística do SFTD	112
5.2	Sistema Adaptativo com Sensor Virtual	122
5.3	Discussão em Relação a Outros Estudos Semelhantes	147
6	CONSIDERAÇÕES FINAIS	150
	REFERÊNCIAS BIBLIOGRÁFICAS	152
	APÊNDICE A - RESULTADOS COMPLEMENTARES	171
	APÊNDICE B – PROJETOS DE EXPERIMENTOS	172

LISTA DE FIGURAS

Figura 1	Fases do potencial de ação.....	25
Figura 2	Principais músculos superficiais do braço e antebraço sEMG.	27
Figura 3	Segmentação de sEMG por janelas de tempo incluindo segmentos sobrepostos ou não sobrepostos.....	29
Figura 4	Hiperplano ótimo separando dados de margens rígidas.	43
Figura 5	Hiperplano ótimo separando dados de margens suaves.	44
Figura 6	Diagrama de blocos da metodologia experimental.....	72
Figura 7	Grupos de movimentos analisados.	74
Figura 8	Fluxo da aquisição de dados de sinais de sEMG.....	76
Figura 9	Posicionamentos dos 12 eletrodos: a) Posicionamento em um modelo de braço, b) Posicionamento em um voluntário das bases de dados NinaPro e c) Posicionamento em um voluntário da base de dados do Laboratório IEE.....	77
Figura 10	Etapas de pré-processamento: a) Sinal filtrado com ajuste de <i>offset</i> ; b) Sinal retificado e c) Sinal normalizado.	80
Figura 11	Exemplo de segmentação por <i>timestamp</i>	81
Figura 12	Fluxograma da contaminação artificial do sinal.	84
Figura 13	A comparação de cada inserção de contaminante no sinal de sEMG.....	86
Figura 14	Fluxograma da a) formação do SFTD e do b) funcionamento em conjunto com o sensor virtual.....	88
Figura 15	Fluxograma de funcionamento simplificado do sensor virtual.....	92
Figura 16	Lógica de operação do SFTD com o sensor virtual.....	93
Figura 17	Fluxograma Modelo TVK.	101
Figura 18	Descrição da configuração de classificação do SVM.....	102
Figura 19	Exemplos de restrição dos multiplicadores de Lagrange no SMO.....	105
Figura 20	Algoritmo SMO resumido.	105
Figura 21	Fluxograma de decisão para multiclases.	106
Figura 22	Exemplo da matriz de confusão.....	109
Figura 23	Dispersão da taxa de acerto média da detecção de contaminantes pelo SFTD para todos os sujeitos.	114
Figura 24	Dispersão da taxa de acerto média da detecção de contaminantes pelo SFTD para (a) base NinaPro de amputados, (b) base NinaPro de não amputados e (c) base do IEE.	115
Figura 25	Gráfico de validação do Projeto de Experimentos para taxa de detecção do SFTD quanto aos fatores de variação da base de dados, estudos de contaminação e tipos de ruídos: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	118
Figura 26	Curva da Potência Estatística do projeto de experimentos para a taxa de detecção do SFTD.....	119
Figura 27	Taxa de detecção do SFTD na interação de estudos de caso de degradação de canais e tipos de ruídos para todos os sujeitos.....	120
Figura 28	Taxa de detecção do SFTD na interação de estudos de caso de degradação de canais e tipos de ruídos para: a) Bases de dados do NinaPro não anputados; b) Base de dados do NinaPro amputados e c) Base de dados do IEE.....	121
Figura 29	Comparação da taxa de acerto para cada configuração de classificação e para cada tipo de ruído com a classificação de sinal íntegro de sEMG.	125

Figura 30	Comparação do desvio padrão para cada configuração de classificação e para cada tipo de ruído com a classificação de sinal íntegro de sEMG.	127
Figura 31	Taxas de acerto média e as taxas de erros entre movimentos das configurações de classificação para os 18 movimentos da base de dados do NinaPro de não amputados.	128
Figura 32	Taxas de acerto média e as taxas de erros entre movimentos das configurações de classificação para os 18 movimentos da base de dados do NinaPro de Amputados.	130
Figura 33	Taxas de acerto média e as taxas de erros entre movimentos das configurações de classificação para os 18 movimentos da base de dados do IEE.	131
Figura 34	Análise da contaminação do sinal por Artefatos de Movimento entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.	134
Figura 35	Análise da contaminação do sinal por Deslocamento de Eletrodos entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.	134
Figura 36	Análise da contaminação do sinal por Saturação entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.	135
Figura 37	Análise da contaminação do sinal por Interferência de Linha de Energia entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.	136
Figura 38	Análise da contaminação do sinal por Interferência de ECG entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.	137
Figura 39	Comparação da característica RMS dos modelos do sensor virtual.	146
Figura 40	Taxa de detecção do SFTD na interação de base de dados e tipos de ruídos.	171
Figura 41	Taxa de detecção do SFTD na interação de base de dados e estudos de caso de degradação.	171
Figura 42	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos, tipos de ruídos e configuração de classificação: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	172
Figura 43	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos, tipos de ruídos e configuração de classificação.	172
Figura 44	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	173
Figura 45	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento.	173
Figura 46	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor	

	ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	174
Figura 47	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento.....	174
Figura 48	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.....	175
Figura 49	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento.	175
Figura 50	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	176
Figura 51	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos.	176
Figura 52	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	177
Figura 53	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos.	177
Figura 54	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.....	178
Figura 55	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos.	178
Figura 56	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.....	179

Figura 57	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação.	179
Figura 58	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	180
Figura 59	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação.	180
Figura 60	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	181
Figura 61	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação.	181
Figura 62	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	182
Figura 63	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia.	182
Figura 64	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	183
Figura 65	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia.	183
Figura 66	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	184
Figura 67	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia.	184

Figura 68	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	185
Figura 69	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG.	185
Figura 70	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	186
Figura 71	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG.	186
Figura 72	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	187
Figura 73	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG.....	187
Figura 74	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o sistema adaptativo com os modelos do sensor virtual substituindo o sinal contaminado: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	188
Figura 75	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o sistema adaptativo com os modelos do sensor virtual substituindo o sinal contaminado.	188
Figura 76	Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o retreinamento do classificador com os modelos do sensor virtual substituindo o sinal contaminado: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.	189
Figura 77	Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o retreinamento do classificador com os modelos do sensor virtual substituindo o sinal contaminado.	189

LISTA DE TABELAS

Tabela 1	Principais músculos superficiais do braço, antebraço e suas funções	26
Tabela 2	Representação matemática de extração de algumas das características de sEMG utilizadas	30
Tabela 3	Comparação entre artigos de classificação utilizando métodos com Lógica <i>Fuzzy</i>	36
Tabela 4	Comparação entre artigos de classificação utilizando métodos com LDA	39
Tabela 5	Comparação entre artigos de classificação utilizando métodos com RNA	41
Tabela 6	Comparação entre artigos de classificação utilizando métodos com SVM Linear	48
Tabela 7	Comparação entre artigos de classificação utilizando métodos com SVM não linear e combinada com outras técnicas	50
Tabela 8	Resumo das bases de dados NinaPro	73
Tabela 9	Descrição dos movimentos selecionados para o estudo	74
Tabela 10	Características clínicas dos sujeitos amputados	75
Tabela 11	Canais contaminados em dezesseis casos para cada tipo de contaminante	87
Tabela 12	Taxa de reconhecimento de contaminantes em pesquisa preliminar	90
Tabela 13	Taxa acerto no reconhecimento de cada contaminante	112
Tabela 14	Cálculo do Projeto de Experimentos da análise da taxa de detecção do SFTD para variação da base de dados, estudos de contaminação e tipos de ruídos	116
Tabela 15	Comparação de alguns trabalhos com a base de dados do NinaPro	124
Tabela 16	Resultado da taxa média de Falsos Positivos para os canais que não receberam contaminação artificial.....	171
Tabela 17	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos, tipos de ruídos e configuração de classificação	172
Tabela 18	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento	173
Tabela 19	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento	174
Tabela 20	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento	175
Tabela 21	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos.....	176
Tabela 22	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos	177
Tabela 23	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos.....	178
Tabela 24	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação	179

Tabela 25	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação.....	180
Tabela 26	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação	181
Tabela 27	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia	182
Tabela 28	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia.....	183
Tabela 29	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia...	184
Tabela 30	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG.....	185
Tabela 31	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG..	186
Tabela 32	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG	187
Tabela 33	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o sistema adaptativo com os modelos do sensor virtual substituindo o sinal contaminado.....	188
Tabela 34	Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o retreinamento do classificador com os modelos do sensor virtual substituindo o sinal contaminado	189

LISTA DE ABREVIATURAS

ACO: *Ant Colony Optimization*

ACO-mRMR: *Minimum Redundancy Maximum Relevance Criterion ACO*

AR: *Autoregressive*

ARIMA: *Autoregressive Integrated Moving Average*

ARMA: *Autoregressive Moving Average*

AR-RMS: *AR model coefficients and room mean square value*

BCO: *Bee Colony Optimization*

BEP: *Beginning Extraction Point*

CCA: *Canonical Correlation Analysis*

CDA: *Canonical Discriminant Analysis*

CNN: *Convolutional Neural Network*

CSP: *Common Spatial Pattern*

CV: *Cross Validation*

DWT: *Discrete Wavelet Transform*

ECG: Eletrocardiograma

EEP: *Ending Extraction Point*

EMG: Eletromiografia

FD: *Fractal Dimension*

FDH: *Fractal Dimension Higuchi*

FMD: Frequência Mediana

FMN: Frequência Média

FP: Função de Pertinência

GA: Algoritmo Genético

HMM: Modelos Ocultos de Markov

ICA: *Independent Components Analysis*

IEE: Instrumentação Eletro-Eletrônica

K-NN: *K-Nearest Neighbour*

KURT: Curtose

LDA: *Linear Discriminant Analysis*

LF: Lógica Fuzzy

MAV: Média de Valor Absoluto

MCC: *Multichannel Cross-Correlation*
MFL: *Maximum Fractal Length*
MPF: *Mean Peak Frequency*
MUAP: *Motor Unit Action Potential*
NinaPro: *Non-Invasive Adaptive Prosthetics*
NPE: *Neighbourhood Preserving Embedding*
NWFE: *Non-Parametric Weighted Feature Extraction*
OLDA: *Orthogonal Linear Discriminant Analysis*
P&WND: *Peak information and Non-Equidistant Window Function Method*
PCA: *Principal Component Analysis*
PSO: *Particle Swarm Optimization*
PWR: *Power*
RBF: *Gaussiano de Função Base Radial*
RMS: *Root Mean Square*
RNA: *Redes Neurais Artificiais*
sEMG: *Eletromiografia de Superfície*
SFTD: *Sensor Fault-Tolerant Detector*
SFTM: *Módulo Tolerante às Falhas dos Sensores*
SKW: *Skewness (Obliquidade)*
SNC: *Sistema Nervoso Central*
SNP: *Sistema Nervoso Periférico*
SNR: *Relação Sinal Ruído*
SVM Linear: *SVM com função kernel linear*
SVM Polinomial: *SVM com função kernel polinomial*
SVM RBF: *SVM com função kernel RBF*
SVM: *Máquinas de Vetores de Suporte*
TDAR: *Time Domain features combined with Autoregressive model Coefficients*
TMR: *Targeted Muscle Reinnervation*
TSR: *Targeted Sensory Reinnervation*
TVAR: *Time-Varying Autoregressive*
TVARMA: *Time-Varying Autoregressive Moving Average*
TVK: *Time-Varying Kalman filter*
UFRGS: *Universidade Federal do Rio Grande do Sul*
VAR: *Variância*

WL: *Waveform Length*

WT: *Transformada Wavelet*

1 INTRODUÇÃO

O objetivo em diversas pesquisas de reabilitação motora é a recuperação de alguma parte da funcionalidade perdida, como exemplo, a reabilitação após a amputação de uma mão ou braço. A aplicação de sinais de Eletromiografia de Superfície (sEMG) para o controle de próteses tem sido estudada nas últimas décadas para oferecer uma interface capaz de executar diferentes comandos ou movimentos de interesse (ATZORI; MULLER; BAECHLER, 2013; BALBINOT; FAVIEIRO, 2013; CHIANG; WANG; MCKEOWN, 2008; DEIJS *et al.*, 2016; REKHI *et al.*, 2009; RIILLO *et al.*, 2014; XIE *et al.*, 2015). O desenvolvimento tecnológico na área de engenharia de reabilitação motora com a intenção de replicar os movimentos do segmento mão-braço tem como objetivo melhorar continuamente a qualidade de vida dessas pessoas, tornando-as menos dependentes e auxiliando na sua integração de forma mais produtiva à sociedade (ATZORI *et al.*, 2012a).

Os recentes avanços no processamento do sinal de eletromiografia e nos procedimentos cirúrgicos inovadores, como a reinervação muscular orientada (*Targeted Muscle Reinnervation* - TMR) e a reinervação sensorial direcionada (*Targeted Sensory Reinnervation* - TSR), são os principais responsáveis pelos avanços na engenharia de reabilitação motora devido a amputação de membros superiores e inferiores (ENGDAHL *et al.*, 2015; JIANG *et al.*, 2012; LI; SCHULTZ; KUIKEN, 2010; SENSINGER; LOCK; KUIKEN, 2009). No entanto, ainda existem diversos desafios consideráveis de ordem tecnológica para efetivamente propor uma solução ideal e benéfica para a população em geral de amputados (JIANG *et al.*, 2012).

A classificação usando sinais mioelétricos é baseada na busca de diferentes e repetitivos padrões das distintas ativações musculares. Por exemplo, um classificador de sinais mioelétricos específico para cada usuário possibilita o reconhecimento das sutilezas de cada movimento realizado por uma pessoa em um determinado período. Entretanto, normalmente o classificador não se adapta às mudanças nos padrões ocorridas nos sinais mioelétricos das pessoas ao longo do tempo. Essas alterações ao longo do tempo podem ser causadas, por exemplo, por alterações da condutibilidade dos eletrodos, por causa da transpiração ou umidade ambiente, fadiga muscular, atrofia ou hipertrofia, deslocamento do eletrodo na pele, mudanças na execução de movimentos por parte do usuário, assim como, na intensidade da força aplicada (SENSINGER; LOCK; KUIKEN, 2009).

A maioria dos sistemas de controle mioelétricos propostos na literatura científica não se adaptam às mudanças citadas anteriormente e muitas vezes não são sistemas naturais e intuitivos ao usuário, pois o sujeito deve aprender a associar movimentos dos músculos com os

movimentos da prótese através de longos períodos de treinamento (ATZORI; MULLER; BAECHLER, 2013). Além disso, a dificuldade de adaptação no controle de próteses mioelétricas dos membros superiores é um dos motivos para ainda terem impacto clínico e comercial relativamente limitados (DEIJS *et al.*, 2016; ENGDAHL *et al.*, 2015; JIANG *et al.*, 2012).

O desenvolvimento de uma prótese similar ao braço humano, além das dificuldades citadas anteriormente, ainda apresenta diversos outros problemas de ordem tecnológica, como por exemplo, a distinção dos diferentes graus de liberdade dos movimentos do braço e do punho pela prótese, assim como a diferença na caracterização para a execução dos movimentos simples, com apenas um grau de liberdade, em relação aos movimentos compostos, com mais de um grau de liberdade (KHUSHABA *et al.*, 2016). Mesmo com tantos desafios, estudos de pesquisadores como (ATZORI; MULLER; BAECHLER, 2013; CENE; FAVIEIRO; BALBINOT, 2015; RIILLO *et al.*, 2014) certificaram a capacidade de amputados na geração de determinados sinais mioelétricos padronizados durante a intenção da realização de um movimento específico. Portanto, as aplicações dos conceitos da área de instrumentação biomédica e de processamento de sinais biomédicos prometem vislumbrar resultados robustos, os quais determinariam cada movimento executado através da caracterização do sinal mioelétrico.

Os resultados obtidos até o presente momento, tanto na literatura em geral, quanto pela equipe do Laboratório de Instrumentação Eletro-Eletrônica (IEE) da UFRGS, ainda possuem uma significativa quantidade de questões em aberto, as quais requerem investigação científica e tecnológica de outros métodos para o desenvolvimento de sistemas adaptativos e intuitivos. Deste modo, o processamento adaptativo do sinal de sEMG para controle mioelétrico de próteses com o reconhecimento de movimentos do segmento mão-braço de maneira mais natural e intuitiva possível é uma necessidade iminente para o desenvolvimento nessa área de pesquisa (JIANG *et al.*, 2012).

Sensores virtuais são uma ferramenta emergente e inteligente que tem sido usada com sucesso em outros campos, como por exemplo (PONSART; THEILLIOL; AUBRUN, 2010; SÁNCHEZ-MOLINA *et al.*, 2015). Normalmente, eles são usados para substituir sensores físicos (LIU; INOUE; SHIBATA, 2010; PLOENNIGS *et al.*, 2011). Além disso, eles podem ser usados como parte de metodologias de detecção de falhas, onde sua saída é comparada ao sensor correspondente (NAZARI *et al.*, 2013). Sensores virtuais têm como objetivo estimar medidas indisponíveis usando um modelo do sinal de interesse através da correlação deste sinal com outras variáveis disponíveis (BHUYAN, 2013). Portanto, é possível que a utilização dos

conceitos de sensores virtuais de instrumentação inteligente proporcione um processamento adaptativo do sinal de sEMG e contribua para reduzir o impacto de problemas relatados de transpiração ou umidade ambiente, deslocamento de eletrodos na pele e a perda do contato do eletrodo-pele, os quais geram degradação nos sinais de sEMG ou até mesmo a perda total do sinal mioelétrico.

O funcionamento das próteses mioelétricas de forma estável e constante, sem necessidade de contínuas intervenções de ajustes, calibrações e contínuos treinamentos de utilização, pode efetivamente proporcionar a solução ideal e benéfica para os amputados. Um sistema de caracterização de movimentos que possibilite esta estabilidade de funcionamento poderia aumentar o impacto clínico e comercial das próteses mioelétricas.

Deste modo, em função das colocações anteriores, o presente trabalho tem como principal contribuição o estudo e o desenvolvimento de um sistema de classificação de movimentos tolerante a falhas, o qual utiliza o conceito de sensores virtuais para reduzir o impacto de degradação de sinais de sEMG. A degradação do sinal é avaliada a partir dos cinco contaminantes mais comuns em sinais de sEMG (FRASER *et al.*, 2014; MCCOOL *et al.*, 2014; ZHANG; HUANG, 2015): artefatos de movimento, saturação, deslocamentos de eletrodos, interferência de linha de energia e interferência do ECG.

Este sistema inteligente e adaptativo mantém o funcionamento do classificador sem qualquer retreinamento ou calibração, proporcionando um sistema mais intuitivo e natural, sem demasiadas intervenções de ajustes durante o dia. A manutenção do funcionamento do sistema na falta ou na falha da leitura de um eletrodo, sem nenhum retreinamento ou calibração do classificador, tem por consequência o aumento das taxas de acerto na caracterização dos movimentos executados pelos voluntários após a contaminação do sinal.

A segunda contribuição deste sistema proposto é um modelo de sinal de sEMG dinâmico e adaptativo para o sensor virtual, o qual produz um modelo de saída de sinal independente da aquisição física do sinal de interesse. A modelagem do sinal de sEMG é projetada de forma a combinar os conceitos de multicanais e sua correlação cruzada, a fim de substituir os canais de sinais degradados. Essa abordagem apresentada no presente trabalho é referida como correlação cruzada multicanal. Dois tipos de modelagem de sinais de sEMG são avaliados e detalhados: *Time-Varying Autoregressive Moving Average (TVARMA)* e o *Time-Varying Kalman Filter (TVK)*. Os modelos TVARMA foram utilizados para melhorar os modelos de sinal não estacionários (CHEE-MING TING *et al.*, 2011) e o filtro de Kalman tem sido amplamente utilizado em outros campos (CHEE-MING TING *et al.*, 2011; KAUTZ; ESKOFIER, 2015), onde é considerado uma ferramenta de processamento de sinais extremamente eficiente e

flexível, e também é empregado em outras aplicações de sensores virtuais (TABBACHE *et al.*, 2013).

A terceira contribuição é a combinação de uma análise e detecção da contaminação do sinal realizada por um sensor de detecção tolerante a falhas (*Sensor Fault-Tolerant Detector – SFTD*). Diversos estudos demonstraram o interesse em identificar distúrbios no sinal de sEMG, os quais são responsáveis por reduzir a taxa de acerto média da classificação dos movimentos (FRASER *et al.*, 2014; MCCOOL *et al.*, 2014; ZHANG; HUANG, 2015). O SFTD realiza a análise de qualidade para sinais de sEMG usando um algoritmo de Máquina de Vetores de Suporte (*Support Vector Machine, SVM*) de duas classes, onde o treinamento ocorre com sinais selecionados das bases de dados e sua contaminação simulada por artefatos de movimento, saturação do sinal de sEMG, deslocamentos de eletrodos, interferência de linha de energia e interferência no sinal de sEMG pelo sinal de Eletrocardiograma (ECG). Dezesesseis casos de diferentes combinações de canais com inserção de contaminação foram realizados para cada tipo de contaminante.

O algoritmo de classificação utilizado para o reconhecimento dos movimentos dos voluntários foi a SVM não linear com segmentação por janelas deslizantes. A análise deste sistema inteligente e adaptativo é realizada pela caracterização de dezessete movimentos do braço humano e a identificação do braço em repouso de determinados sinais mioelétricos captados por doze eletrodos de superfície. Parte da base de dados do projeto NinaPro (*Non-Invasive Adaptive Prosthetics*) e uma base adquirida no IEE são utilizadas para a caracterização dos movimentos de sujeitos amputados e não amputados.

Este trabalho é apresentado através da divisão dos assuntos em capítulos. No Capítulo 2, são apresentados conceitos básicos de eletromiografia necessários para compreensão do sinal adquirido e, em conjunto, os procedimentos de extração de características. Uma revisão bibliográfica de conceitos teóricos utilizados para a realização deste trabalho e a análise de trabalhos de pesquisa relacionados a mesma área de atuação são apresentados no Capítulo 3.

No Capítulo 4, é apresentado o detalhamento da principal contribuição deste trabalho, o sistema inteligente tolerante a falhas em conjunto com a segunda e terceira contribuição, modelo de sensor virtual e o SFTD respectivamente. Os detalhes da metodologia proposta são descritos abrangendo toda a sua concepção em conjunto com os resultados obtidos em trabalhos preliminares publicados em congresso e revista. Em complemento, também são detalhados os projetos de experimentos realizados para avaliar a contribuição do sistema proposto para a caracterização de movimentos do segmento mão-braço através de sinais de sEMG.

Vários testes são apresentados no Capítulo 5 de resultados. Através das discussões, é apresentado a eficiência do sistema em identificar as contaminações do sinal, proporcionando a redução dos erros de caracterização do movimento decorridos da contaminação. Além disso, é realizado a comparação dos resultados gerados neste trabalho com os resultados obtidos por outros pesquisadores na área e de trabalhos anteriores do grupo de pesquisa do Laboratório IEE. Por fim, as conclusões e considerações finais são apresentadas no Capítulo 6.

2 PRINCÍPIOS BÁSICOS SOBRE ELETROMIOGRAFIA

Por definição, a eletromiografia (EMG) é o registo da atividade elétrica do músculo durante um determinado movimento (PEZARAT-CORREIA; MIL-HOMENS, 2004). A EMG compõe a detecção, análise e interpretação de sinais mioelétricos. O sinal mioelétrico é consequência das correntes elétricas geradas pela troca de íons através das membranas das células musculares (HAHNE *et al.*, 2014). O objetivo deste capítulo é apresentar alguns conceitos básicos da área, facilitando a contextualização deste trabalho no amplo referencial teórico existente. Este assunto pode ser consultado, se for de interesse, na seguinte lista de referências bibliográficas (DE LUCA, 2006a; GUYTON, 2006; TORTORA; DERRICKSON, 2012a, 2012b), assim como nos diversos trabalhos realizados no Laboratório IEE.

2.1 SINAL MIOELÉTRICO

O sinal mioelétrico é proveniente de uma MUAP (*Motor Unit Action Potential*) (HUDGINS; PARKER; SCOTT, 1993; JIANG *et al.*, 2012). Um potencial de ação é enviado por um neurônio motor através de um estímulo elétrico que percorre as fibras musculares, formando um campo eletromagnético nas suas proximidades. A soma algébrica dos potenciais de ação das várias fibras musculares de uma unidade motora é chamada potencial de ação da unidade motora ou MUAP (GUYTON, 2006; TORTORA; DERRICKSON, 2012b). Portanto, é possível determinar o sinal mioelétrico como o sinal de controle do corpo humano para informar a intenção do usuário de contrair um determinado músculo.

A aquisição do sinal mioelétrico pode ser realizada de forma invasiva e não invasiva (DE LUCA, 2002). A forma de aquisição invasiva utiliza eletrodos invasivos ou eletrodos intramusculares, compostos geralmente de fios finos ou agulhas inseridas no músculo de interesse. Estas permitem a obtenção de sinais de áreas específicas ao local onde foram inseridas no músculo, logo, há baixa probabilidade de interferências geradas por outros músculos. As desvantagens são devido ao desconforto e a dor da inserção, câimbras e a dificuldade na repetição de experimentos (BASMAJIAN; DE LUCA, 1985; DE LUCA, 2006b).

Os eletrodos não invasivos ou eletrodos de superfície são simples, higiênicos e de uso prático para os usuários (ENGLEHART *et al.*, 1999). Entretanto, estes eletrodos captam apenas sinais dos músculos superficiais à pele, podendo também ocorrer interferência de outros músculos. Esta interferência pode ser agravada, se a posição do eletrodo não for mantida fixa sobre a pele. Além disso, as preparações da pele, como a remoção de pêlos e suor, são necessárias para obter uma melhor qualidade do sinal (DE LUCA, 2002).

Existem ainda procedimentos cirúrgicos, que tem como objetivo melhorar a aquisição de sinais mioelétricos. Os procedimentos cirúrgicos nos amputados transradiais, como a TMR e a TSR, comentados na introdução, podem proporcionar um controle mais robusto das próteses, aumentando a qualidade do sinal de sEMG, a informação obtida através dos sinais e o *feedback* ao usuário (JIANG *et al.*, 2012; LI; SCHULTZ; KUIKEN, 2010). A TMR é a reinervação de um músculo alvo através da transferência seletiva de nervos residuais aos músculos perto do membro amputado, criando deste modo, locais de sinal adicionais que podem ser usados para controlar uma prótese (KUIKEN, 2009; TUCKER *et al.*, 2015). A TSR permite que receptores sensoriais na pele, perto ou sobre o local selecionado, retransmitam a informação sensorial como se fossem os receptores no membro amputado (JIANG *et al.*, 2012). Os amputados transradiais que estão dispostos a aceitar os riscos da cirurgia, poderiam obter uma prótese mais funcional (ENGD AHL *et al.*, 2015).

2.2 PROCESSO DE CONTRAÇÃO MUSCULAR

O sistema nervoso é dividido em duas subcategorias principais: o sistema nervoso central (SNC) e o sistema nervoso periférico (SNP). O SNP inclui todo o tecido nervoso fora o SNC, o qual abrange o encéfalo e a medula espinhal (TORTORA; DERRICKSON, 2012b).

O SNP pode ser subdividido em sistema nervoso somático, sistema nervoso autônomo e sistema nervoso entérico. A parte de interesse, neste trabalho, são os neurônios motores do sistema nervoso somático, que conduzem os impulsos do SNC para os músculos esqueléticos, estimulando as fibras musculares esqueléticas para a contração (GUYTON, 2006; TORTORA; DERRICKSON, 2012b). O processo de contração muscular abrange as seguintes etapas: condução do impulso nervoso pelo neurônio motor, transmissão sináptica, potenciais de ação do músculo que somados representam o sinal mioelétrico, contração das fibras musculares e o movimento muscular. Uma fibra muscular contrai-se em resposta a um ou mais potenciais de ação (TORTORA; DERRICKSON, 2012b).

Potenciais de ação musculares aparecem na junção neuromuscular ou sinapse, que é a região onde a comunicação ocorre entre um neurônio e uma fibra esquelética muscular (TORTORA; DERRICKSON, 2012b). Um potencial de ação é um sinal elétrico que se propaga pela superfície da membrana dos neurônios, o qual inicia e transita a partir do movimento dos íons (como Sódio, Potássio e Cálcio) entre o fluido intersticial e o interior de um neurônio por canais de íons específicos na sua membrana plasmática (TORTORA; DERRICKSON, 2012b).

Um único impulso nervoso em um neurônio motor estimula um único potencial de ação muscular em todas as fibras musculares com as quais ele faz sinapse. Como as células não se

tocam fisicamente, a primeira célula comunica-se com a segunda através da liberação de mensageiros químicos chamados neurotransmissores (TORTORA; DERRICKSON, 2012b). A membrana que delimita o neurônio possui uma diferença de potencial elétrico entre o interior e exterior da célula mesmo em repouso. Quando certo potencial é alcançado, um potencial de ação é gerado e percorre todo axônio até a extremidade, junção neuromuscular, onde promove a liberação de neurotransmissores, o que possibilita que o impulso gerado seja propagado até a região sináptica (BLANCHARD, 2005; DE LUCA, 1979).

O potencial de ação, apresentado na Figura 1, pode ser dividido em três fases principais segundo (GUYTON; HALL, 2010; TORTORA; DERRICKSON, 2012b): fase de repouso, fase de despolarização e fase de repolarização. Antes do início do potencial de ação, está “negativamente polarizado” (fase de repouso). Após o estímulo, a membrana passa a ficar mais permeável aos íons de Sódio, permitindo a difusão maior de íons para o interior do axônio, e aumentando o potencial para um valor positivo (fase de despolarização). Após milésimos de segundos, os canais de Sódio começam a ficar menos permeáveis e os canais de Potássio passam a ficar mais permeáveis que o normal, ocorrendo uma rápida difusão de íons de Potássio para o exterior e restabelecendo o potencial de repouso negativo da membrana (fase de repolarização).

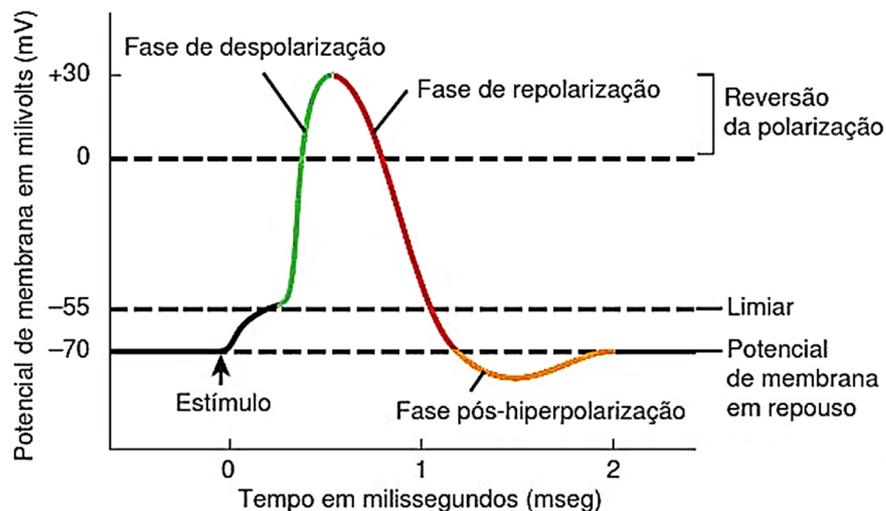


Figura 1 Fases do potencial de ação.

Fonte: (TORTORA; DERRICKSON, 2012b).

2.3 MÚSCULOS ESQUELÉTICOS

Uma unidade motora consiste em um neurônio motor e todas as fibras musculares que ele estimula, e que, portanto, se contraem juntas. Os músculos envolvidos em um movimento fazem parte de várias pequenas unidades motoras (TORTORA; DERRICKSON, 2012a). O

músculo esquelético é um órgão separado, formado por um aglomerado de fascículos musculares, os quais são compostos por centenas a milhares de fibras musculares (BELTRAMINI, 1999; TORTORA; DERRICKSON, 2012a). Cada fibra muscular é formada por unidades menores chamadas respectivamente de: miofibrilas, núcleo celular e retículo sarcoplasmático. Estas estruturas são envoltas por uma membrana chamada de sarcolema (BELTRAMINI, 1999).

Os músculos do braço e antebraço são projetados para atender às diversas necessidades do corpo ao realizar movimentos complexos do cotidiano (TORTORA; DERRICKSON, 2012a). A Tabela 1 apresenta os principais músculos do segmento mão-braço e os respectivos movimentos nos quais eles estão envolvidos. A Figura 2 mostra a musculatura do braço e antebraço humano em vista anterior superficial e posterior superficial dos músculos envolvidos nestes movimentos.

Tabela 1 Principais músculos superficiais do braço, antebraço e suas funções

MÚSCULO	MOVIMENTO
Bíceps braquial	Flexiona e supina o antebraço Flexiona o braço
Braquial	Flexiona o antebraço
Braquiorradial	Flexiona o antebraço
Tríceps braquial	Estende o antebraço e o braço
Supinador	Supina o antebraço (girar a palma da mão para frente)
Pronador redondo	Prona o antebraço (girar a palma da mão para trás)
Flexor radial do carpo	Flexiona e aduz a mão
Flexor ulnar do carpo	Flexiona fracamente a mão
Palmar longo	Flexiona a mão Flexiona as falanges do segundo ao quinto dedo
Flexor superficial dos dedos	Flexiona a mão Flexiona as falanges de cada dedo
Flexor profundo dos dedos	Flexiona as falanges do segundo ao quinto dedo
Extensor radial do carpo	Estende e abduz a mão
Extensor ulnar do carpo	Estende e abduz a mão
Extensor dos dedos	Estende a mão Estende as falanges do segundo ao quinto dedo

Fonte: Adaptado (TORTORA; DERRICKSON, 2012a).

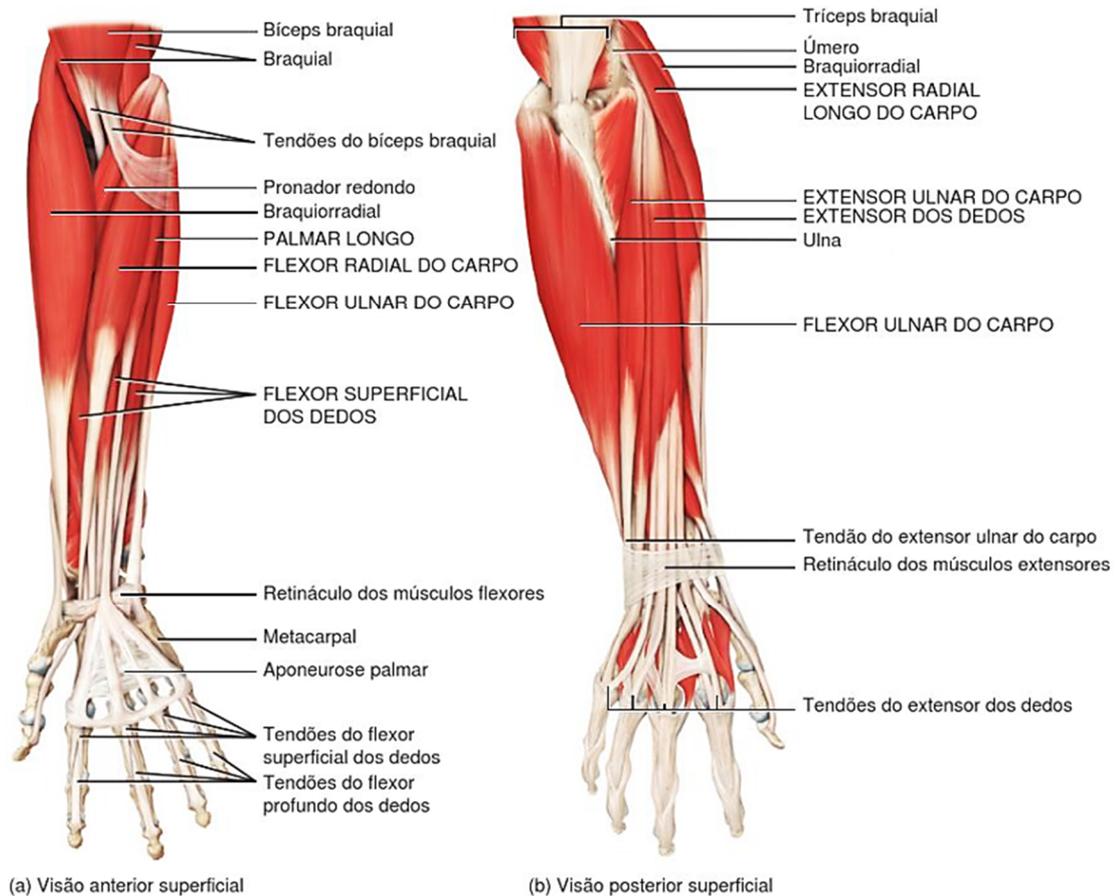


Figura 2 Principais músculos superficiais do braço e antebraço sEMG.

Fonte: Adaptado (TORTORA; DERRICKSON, 2012a).

2.4 SINAL MIOELÉTRICO DE SUPERFÍCIE

As atividades bioelétricas no interior do músculo são observadas com auxílio de eletrodos de EMG. Os eletrodos de superfície, selecionados para o estudo deste trabalho, proporcionam uma técnica não invasiva para medição e detecção dos sinais de sEMG (DE LUCA, 2002), por isto, eles vêm sendo usados, amplamente, nos sistemas de reabilitação para as próteses mioelétricas (LIN; KULIC, 2014; XING *et al.*, 2014). Os eletrodos são tipicamente usados individualmente ou em pares, referidos respectivamente como configuração monopolar e bipolar (DE LUCA, 2006b).

Na configuração monopolar, o sinal é obtido através da diferença entre potenciais em dois pontos, sendo um deles o referencial. A configuração bipolar, por sua vez, utiliza três eletrodos, obtendo dois sinais em relação a um mesmo ponto de referência, que são posteriormente subtraídos. O eletrodo de referência (por vezes chamado o eletrodo de terra) é necessário para proporcionar uma referência comum para a configuração bipolar, que usa entrada diferencial, a fim de eliminar o sinal de ruído proveniente de fontes de linha de energia.

Este sinal de ruído e outros semelhantes, os quais podem ser qualquer sinal que é "comum" a ambos os locais de detecção, vai ser removido e a diferença de sinal nos dois locais será amplificada. Assim, sinais de ruído de linhas elétricas são removidos e os sinais de sEMG são amplificados (DE LUCA, 2002).

2.5 AQUISIÇÃO DE SINAIS MIOELÉTRICOS

O equipamento de aquisição dos sinais mioelétricos é chamado de eletromiógrafo e o registro de eletromiograma. Normalmente, músculos relaxados produzem pouquíssima atividade elétrica; uma contração pequena produz pouca atividade elétrica, contrações cada vez mais fortes produzem atividades elétricas cada vez maiores (TORTORA; DERRICKSON, 2012b).

A morfologia e a amplitude do sinal mioelétrico são dependentes das propriedades elétricas e do posicionamento dos eletrodos, e do músculo onde a diferença de potencial é medida (DE LUCA, 2006a). Segundo os trabalhos de (DE LUCA, 1997; ISON; ARTEMIADIS, 2014), há alguns cuidados que contribuem para uma melhor aquisição do sinal mioelétrico: a escolha de eletrodos de tamanho adequado para ter uma melhor fixação em relação ao músculo de interesse e diminuir o ruído causado por músculos adjacentes, fixar os eletrodos em áreas que não obstruam a movimentação e visão do usuário, e que possuam boa referência anatômica (fácil localização).

As amplitudes máximas encontradas nas aquisições de sinais mioelétricos são próximas a 5 mV na maioria das aplicações (JIANG *et al.*, 2012; LI; SCHULTZ; KUIKEN, 2010) e tipicamente apresentam uma faixa entre 1 e 10 mV. A maior parte da energia do sinal mioelétrico se localiza na faixa de 50-150 Hz (DE LUCA, 2002). Este sinal é afetado pelas propriedades anatômicas e fisiológicas do músculo, pelo controle do sistema nervoso, assim como, pela instrumentação utilizada para detectá-lo (HAHNE *et al.*, 2014).

Embora o sinal obtido com eletrodos de superfície detecte apenas os sinais dos músculos próximos à pele, há diversos estudos, os quais demonstram que amputados são aptos a gerar repetidamente determinados sinais mioelétricos padronizados diante da intenção de realizar um determinado movimento (ATZORI; MULLER; BAECHLER, 2013; RIILLO *et al.*, 2014; WINKLER; BALBINOT, 2012).

2.6 EXTRAÇÃO DE CARACTERÍSTICAS

A etapa de extração de características consiste em extrair características do sinal mioelétrico que os descrevam de forma a reduzir a quantidade de dados a serem manipulados e aumentar a quantidade e qualidade da informação do sinal. Essas características tipicamente são utilizadas como entrada para os métodos de aprendizado de máquina. A extração de características pode ser realizada nos domínios do tempo ou da frequência (WANG *et al.*, 2009). A extração de características ocorre normalmente através de dois tipos de segmentação: por janelas sobrepostas ou não sobrepostas. A Figura 3 apresenta graficamente como a ocorre a segmentação em k segmentos. As representações matemáticas de algumas das características utilizadas estão descritas na Tabela 2.

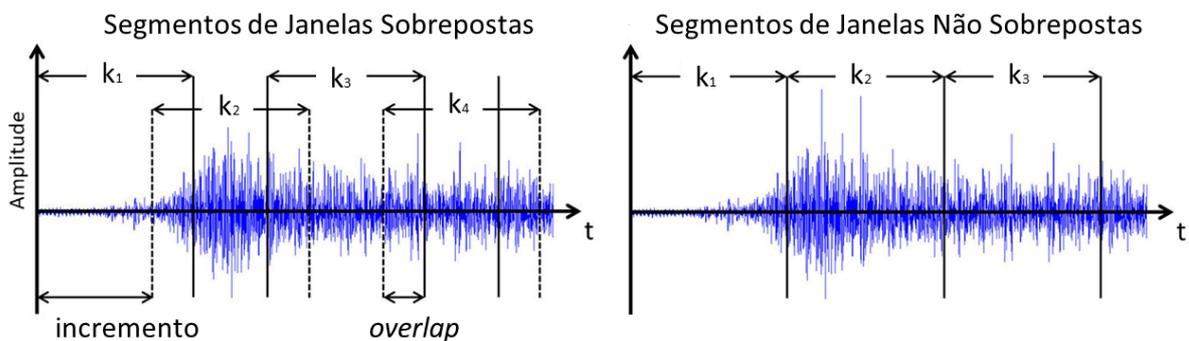


Figura 3 Segmentação de sEMG por janelas de tempo incluindo segmentos sobrepostos ou não sobrepostos.

Fonte: Adaptado de (ORTIZ-CATALAN; BRÅNEMARK; HÅKANSSON, 2013).

As características mais populares no reconhecimento de padrões de sinais de sEMG são características no domínio do tempo, porque são fáceis e rápidas de calcular, uma vez que não requerem uma transformação de domínio (RECHY-RAMIREZ; HU, 2011). Tipicamente são calculadas com base na amplitude do sinal e os valores resultantes podem oferecer uma medida da amplitude do sinal, frequência e duração dentro de parâmetros limitados (OSKOEI; HU, 2006).

As características de domínio frequência são baseadas em sinais estimados de densidade de espectro de potência e são calculadas por métodos paramétricos. No entanto, essas características, em comparação com as características no domínio do tempo, exigem mais tempo para o correspondente cálculo (RECHY-RAMIREZ; HU, 2015).

Tabela 2 Representação matemática de extração de algumas das características de sEMG utilizadas

Característica Extraída	Definição matemática	Referência
Mean Absolute Value (MAV)	$MAV_k = \frac{1}{N} \sum_{i=1}^N x_i $ (1)	(PHINYOMARK <i>et al.</i> , 2012)
Root Mean Square (RMS)	$RMS_k = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$ (2)	(CHOWDHURY <i>et al.</i> , 2013)
Waveform Length (WL)	$WL_k = \sum_{i=1}^{N-1} x_{i+1} - x_i $ (3)	(PHINYOMARK <i>et al.</i> , 2012)
Power (PWR)	$PWR_k = \frac{\sum_{i=1}^N x_i ^2}{N}$ (4)	(NILSSON; HÅKANSSON; ORTIZ-CATALAN, 2017)
Maximum Fractal Length (MFL)	$MFL_k = \log_{10} \left(\sqrt{\sum_{i=1}^{N-1} (x_i - x_{i+1})^2} \right)$ (5)	(PHINYOMARK <i>et al.</i> , 2012)
Frequência Mediana (FMD)	$\sum_{j=1}^{FMD} PSD_j = \sum_{j=FMD}^M PSD_j = \frac{1}{2} \sum_{j=1}^M PSD_j$ (6)	(HAKONEN; PIITULAINEN; VISALA, 2015; RECHY-RAMIREZ; HU, 2015)
Obliquidade (Skewness) (SKW)	$SKW_k = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left(\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \right)^3}$ (7)	(RECHY-RAMIREZ; HU, 2015)
Mean Peak Frequency (MPF)	$peaks_{sort} = sort(PSD_j)$ (8)	(ORTIZ-CATALAN; BRÅNEMARK; HÅKANSSON, 2013)
	$MPF_k = \frac{\sum_{i=1}^3 peaks_{sort_i}}{3}$ (9)	

Legenda: onde x_i são os valores amostrados na janela k , k é o índice de janelas deslizantes, N é o tamanho da janela, M é o comprimento da densidade do espectro de potência e PSD_j é a linha j da densidade do espectro de potência ($PSD_j = \left| \sum_{i=0}^{N-1} x_i e^{-\frac{j2\pi ki}{N}} \right|^2$).

3 PROCESSAMENTO DE SINAIS DE sEMG

O processamento dos sinais de sEMG abrange diversas etapas, incluindo técnicas inteligentes para aprimorar os resultados de classificação de movimentos de interesse. Assim, este capítulo foi dividido em três sessões: procedimentos de segmentação; métodos de classificação e instrumentação inteligente. Cada seção, apresenta a definição do seu tópico e detalhamento de algumas técnicas utilizadas no decorrer da elaboração deste trabalho, além de artigos selecionados e considerados mais relevantes na área deste estudo a partir de 2011.

3.1 PROCEDIMENTOS DE SEGMENTAÇÃO

Segmentar um sinal é subdividir as amostras deste sinal em regiões de interesse ou em alguns casos ocorre a decomposição do sinal. Atualmente, a segmentação dos sinais de sEMG podem ser agrupadas em quatro diferentes abordagens: baseada em um estímulo visual (com referência temporal do vídeo - *timestamp*), baseado em características do sinal de sEMG, com base em outros sinais complementares (SEDLÁK *et al.*, 2013) e em outros métodos complementares, como por exemplo, a adição de técnicas, os quais modificam a segmentação para uma forma mais inteligente (AZAMI *et al.*, 2015; KAUR *et al.*, 2015; KAUR; ARORA; JAIN, 2009; MAZURKIEWICZ, 2007).

Segmentação baseada em características do sinal de sEMG é o processo mais comumente utilizado, também conhecido por segmentação que identifica os picos das MUAPs (BALBINOT; JÚNIOR; FAVIEIRO, 2013; FAVIEIRO; BALBINOT, 2011; SEDLÁK *et al.*, 2013). Um *threshold*, ou um valor de limiar, é definido por um percentual de um valor máximo de um sinal considerado de referência do usuário. Através deste valor de limiar da amplitude do sinal de sEMG, o segmento inicia quando o nível de sinal ultrapassa o valor de limiar de uma janela de comprimento fixo, e termina quando retorna ao valor de limiar ou com base em um valor de comprimento do segmento pré-determinado. Deste modo, o segmento irá conter um pico de sinal no centro do segmento. As amostras na janela são consideradas como possíveis MUAPs (MAZURKIEWICZ, 2007). Por exemplo, o estudo de (FAVIEIRO; BALBINOT, 2011) obteve taxas de acerto média de 93,3% para 5 movimentos executados por 3 sujeitos, utilizando este procedimento de segmentação.

Outros sinais complementares podem ser gravados simultaneamente de forma padronizada, usando, por exemplo, sensores inerciais (acelerômetros ou giroscópios) ou dinamômetros. A gravação de um sinal complementar pode tornar o processo de medição mais complexo. O método de detecção de ciclo de movimento é escolhido de acordo com o tipo de

sinal complementar (SEDLÁK *et al.*, 2013). A gravação de um sinal complementar ou adicional aumenta o custo de um sistema de medida e principalmente acarreta em mais elementos chaves para o monitoramento e o controle de próteses do segmento mão-braço. Seria importante avaliar o custo benefício do uso de sensores complementares e principalmente a usabilidade deste tipo de sistema.

Outro método utilizado em processamentos *on-line* para a segmentação do sinal de sEMG, que não é propriamente um procedimento de segmentação, é *overlapped window* com uso de *sliding windows* ou janelas deslizantes (CELADON *et al.*, 2016; ENGLEHART; HUDGINS, 2003; FARRELL, 2011; HAKONEN; PIITULAINEN; VISALA, 2015; MALANDA *et al.*, 2016; NAZMI *et al.*, 2016; RECHY-RAMIREZ; HU, 2015). Basicamente, é definido um tamanho de janela fixo a ser utilizado e um delimitador de deslizamento, cujas características do sinal são extraídas desta janela fixa que desliza pelo sinal de sEMG, por isso *sliding window*, obtendo, em cada deslizamento, as características de interesse.

No estudo de (MALANDA *et al.*, 2016), foi apresentada uma abordagem complementar à segmentação. Esta abordagem considerou que uma forma comum, entre a existência de vários potenciais de ação dentro de um conjunto de MUAPs com formatos semelhantes em um determinado intervalo de tempo, tem mais probabilidade de ter origem fisiológica do que as interferências de ruído ou contaminação que tipicamente apresentam um comportamento aleatório. Assim, estes potenciais de ação que compartilham uma forma comum foram usados para construir o formato da forma de onda representativa ao longo deste intervalo. Desta forma o algoritmo apresentado de janela deslizante com média seletiva selecionou e calculou a média aritmética dos potenciais semelhantes dentro da janela deslizante. Quando o algoritmo de seleção e cálculo da média é concluído para uma janela, ocorre o deslizamento ao longo da janela avaliada utilizando um delimitador, a partir do qual as variáveis de entrada são reiniciadas.

3.1.1 Procedimento de Segmentação por *Timestamp*

A segmentação por *timestamp* pode ser realizada, por exemplo, com base na temporização de um vídeo de simulação dos movimentos de interesse, ou pela gravação em formato de vídeo da execução dos movimentos a serem replicados por um voluntário ou por interesse de um dado estudo. A gravação de vídeo da execução pode ser obtida conjuntamente com a aquisição do sinal de sEMG, com o objetivo de determinar os tempos de cada movimento (SEDLÁK *et al.*, 2013). Segundo o trabalho de (SEDLÁK *et al.*, 2013), a segmentação por *timestamp* obteve valores de duração dos ciclos do movimento aproximadamente igual em

comparação com o procedimento de segmentação baseada em características do sinal de sEMG, porém com um desvio padrão inferior.

Portanto, o *timestamp* com base no vídeo de simulação da aquisição dos movimentos é definido em função da duração dos movimentos dos vídeos utilizados nos ensaios e do programa de aquisição. Através do *timestamp*, é criada uma curva de segmentação, a qual separa os períodos de movimentos dos intervalos de repouso (ATZORI *et al.*, 2015).

3.1.2 Procedimento de Segmentação Inteligente

Entre as técnicas de segmentação inteligente pode-se citar a identificação de MUAPs pelo *Beginning Extraction Point* (BEP) e *Ending Extraction Point* (EEP), onde o sinal de sEMG é filtrado por um filtro passa-alta a 250 Hz e os BEPS e EEP são identificados por deslizamento de uma janela de extração de comprimento de 3 ms e altura de ± 40 mV. O BEP é o primeiro ponto que satisfaz o critério de pesquisa para a forma de onda do sinal de sEMG, onde o sinal para à esquerda de BEP permanece dentro de ± 40 mV para 3 ms. O EEP é o ponto para a direita da forma de onda do sinal de sEMG. O sinal a direita do EEP permanece dentro do intervalo de ± 40 mV para 3 ms. Estes pontos de extração são mapeados no sinal original, identificando a localização das MUAPs (PATTICHIS; SCHIZAS; MIDDLETON, 1995).

A *Wavelet Transform* (WT) é uma transformação temporal do sinal original em uma base espaço *wavelet*. A representação *wavelet* de tempo e frequência é executada por filtragem do sinal de sEMG repetidamente com um par de filtros que divide o domínio de frequência no meio. A *Discrete Wavelet Transform* (DWT) é a outra técnica de segmentação inteligente utilizada. As funções de tempo e frequência são obtidas por filtragem repetida do sinal pelo par de filtros. Em ambos os casos, realiza-se a segmentação através da decomposição do sinal para um sinal de aproximação e um sinal de detalhe. O sinal de aproximação é posteriormente dividido em novos sinais de aproximação e de detalhe. Este processo é realizado de forma recorrente, produzindo um conjunto de sinais de diferentes níveis de aproximação em detalhe (escalas) e uma aproximação grosseira final do sinal (KAUR *et al.*, 2015; PATTICHIS; PATTICHIS, 1999). Em (KAUR; ARORA; JAIN, 2009), foi realizada uma comparação entre três técnicas, onde a taxa de acerto da técnica utilizada para extrair picos de MUAPs foi de 95,0%, enquanto para a técnica de BEP e EEP foi de 75,4% e para a técnica DWT, de 66,6%.

No artigo de (AZAMI *et al.*, 2015) foi proposto um novo método de segmentação inteligente para sinais de sEMG, o qual baseia-se na *Fractal Dimension* (FD) e quatro algoritmos evolucionários, *Particle Swarm Optimization* (PSO), novo PSO, *PSO With Mutation*, e *Bee Colony Optimization* (BCO). Utilizando a DWT para decompor o sinal em

séries temporais com diferentes faixas de frequência, a FD foi calculada para duas janelas deslizantes. No mesmo estudo, os quatro algoritmos evolucionários foram utilizados para aumentar a correta definição dos limites da ativação do sinal do método de segmentação e selecionar os parâmetros aceitáveis da FD.

Em outra abordagem (LIN; KULIC, 2014), utilizaram um processo de identificação e de reconhecimento em duas fases: uma com base nas características de velocidade e outra através da modelagem estocástica de cada movimento a ser identificado. Na primeira fase, os segmentos de movimentos foram identificados com base na sequência de característica de velocidade, tais como os picos de velocidade e *zero crossing*. Na segunda fase, os modelos ocultos de Markov foram usados para identificar com precisão as posições dos segmentos dos movimentos. Segundo os autores, esta proposta foi capaz de realizar segmentação *on-line*, permitindo *feedback* interativo em aplicações de reabilitação. Este estudo foi avaliado com 20 indivíduos saudáveis e quatro indivíduos em fisioterapia, os quais executaram, no ensaio, movimentos de reabilitação motora. Apresentaram uma taxa de acerto de segmentação de 87% para modelos específicos para cada usuário e 79% a 83% com modelos independentes do usuário.

Os pesquisadores (WILSON; VAIDYANATHAN, 2017) apresentaram um algoritmo unificado de detecção e segmentação dos movimentos, baseado no monitoramento da potência do sinal de Mecanomiografia, a qual registra as vibrações ou sons produzidos pelo músculo esquelético ao se contrair. Os resultados do reconhecimento de sete gestos de mão apresentaram uma taxa de acerto de classificação de 83,5% para cinco sujeitos saudáveis e um amputado transradial. Em um teste com processamento *on-line*, os subconjuntos de dois e cinco gestos apresentaram taxas de acerto médias de 93,3% e 62,2%, respectivamente.

3.2 MÉTODOS PROEMINENTES DE CLASSIFICAÇÃO EM SINAIS DE SEMG

As técnicas de computação inteligente são basicamente algoritmos de aprendizagem de máquina. Atualmente, existem diversos tipos de classificadores e métodos de aprendizado de máquina que são utilizados para a classificação de sinais de sEMG. Apresentam destaque os algoritmos de Análise Discriminante Linear (*Linear Discriminant Analysis - LDA*) (AL-TIMEMY *et al.*, 2016; DING *et al.*, 2017; GENG; ZHOU; LI, 2012; KRASOULIS *et al.*, 2017; KRASOULIS; NAZARPOUR; VIJAYAKUMAR, 2017; RIILLO *et al.*, 2014), de Redes Neurais Artificiais (RNAs) (BALBINOT; JÚNIOR; FAVIEIRO, 2013; KARABULUT *et al.*, 2017; RIILLO *et al.*, 2014), de Lógica Fuzzy (LF) (BALBINOT; FAVIEIRO, 2013; CAESARENDRA; TJAHHOWIDODO; PAMUNGKAS, 2017; KHEZRI; JAHED, 2011) e de

Máquinas de Vetores de Suporte (*Support Vector Machine* - SVM) (ALKAN; GÜNAY, 2012; HUANG *et al.*, 2017; MOURA; FAVIEIRO; BALBINOT, 2016; NILSSON; HÅKANSSON; ORTIZ-CATALAN, 2017; RIILLO *et al.*, 2014; ROSSI *et al.*, 2015). Existem também diversos outros métodos utilizados para a classificação de sinais de sEMG. Entretanto, os quatro métodos relatados anteriormente são empregados em maior número de pesquisas na área desde 2013.

Nas subseções a seguir, são apresentados e discutidos alguns artigos dos principais métodos usados na classificação de sinais de sEMG: LF, RNA, LDA e SVM. O método de classificação SVM é mais detalhado e discutido, uma vez que foi utilizado nesta tese.

3.2.1 Lógica *Fuzzy*

Método proposto inicialmente por (ZADEH, 1965), a lógica *fuzzy* introduziu a ideia de infinitos graus de incerteza que podem existir entre a certeza do sim e do não. Um conjunto *fuzzy* é um conjunto onde a transição entre pertencer ou não a um conjunto é gradual. A transição suave é caracterizada por sua Função de Pertinência (FP), a qual é uma curva que define como um ponto do espaço de entradas mapeado em um grau de pertinência entre 0 e 1 (ZADEH; YAGER, 1992). A estrutura convencional de um sistema de Lógica *Fuzzy* é composto por quatro componentes: *fuzzifier*, a base de regras *fuzzy*, o motor de inferência e o *defuzzifier* (CHAUVET *et al.*, 2003).

Nos estudos de (BALBINOT; FAVIEIRO, 2013; WINKLER; BALBINOT, 2012) (BALBINOT & FAVIEIRO, 2013; FAVIEIRO, 2012), foram apresentados alguns métodos baseados em Sistemas Neuro-*Fuzzy* para utilização de controle de próteses mioelétricas. O método de computação Neuro-*Fuzzy* permite construir um sistema mais robusto de decisão inteligente, combinando as vantagens de uma rede neural artificial com a modelagem difusa do conhecimento impreciso e qualitativo (BALBINOT; FAVIEIRO, 2013).

Em (ABE, 2010), livro sobre SVM para reconhecimento de padrões, o autor concluiu que o desempenho dos classificadores *fuzzy* foi comparável, mas na maioria dos casos inferior, ao método SVM principalmente quando havia um pequeno número de dados de cada classe. Neste livro, o autor também sugeriu que para melhorar o desempenho de classificação SVM não linear pode-se utilizar uma combinação com Lógica *Fuzzy*, chamando de *Fuzzy Support Vector Machine*.

Um estudo com 30 voluntários, utilizando oito pares de eletrodos em configuração bipolar para classificação de sete movimentos distintos atingiu uma taxa de acerto média de 86,0% (BALBINOT; FAVIEIRO, 2013). Foi a menor taxa de acerto apresentada, comparando

com outros estudos relacionados na Tabela 3. Entretanto, os autores (BALBINOT; FAVIEIRO, 2013) utilizaram 30 voluntários, enquanto nos outros estudos utilizaram menos de 10 voluntários. A Tabela 3 ilustra a dificuldade na comparação entre os diversos trabalhos desta linha de pesquisa, onde cada autor realizou a aquisição dos sinais de sEMG com distintas características, como por exemplo, número de eletrodos, posicionamento dos mesmos, características extraídas e movimentos analisados.

Tabela 3 Comparação entre artigos de classificação utilizando métodos com Lógica Fuzzy

Autor	(XIE <i>et al.</i> , 2015)	(CAESA-RENDRA; PAMUNGKAS, 2017)	(KHEZRI; JAHED, 2011)	(HE <i>et al.</i> , 2015)	(BALBINOT; FAVIEIRO, 2013)
Método de Classificação Utilizado	<i>Fuzzy-Logic (fuzzy support vector machine - FSVM)</i>	<i>Fuzzy-Logic (adaptive neuro-fuzzy inference system (ANFIS))</i>	<i>Fuzzy-Logic (adaptive neuro-fuzzy inference system (ANFIS))</i>	<i>Fuzzy-Logic (adaptive neuro-fuzzy inference system (ANFIS))</i>	<i>Fuzzy-Logic (adaptive neuro-fuzzy inference system (ANFIS))</i>
Processo de Segmentação	Janela deslizante (tamanho 256 ms, delimitador 192 ms)	<i>timestamp</i>	Janelas fixas de 50 ms	<i>threshold</i>	<i>threshold</i>
Características	<i>autoregressive model coefficients and the root mean square value (AR-RMS)</i>	16 características com redução usando o PCA	MAV, <i>slope sign changes</i> , AR <i>coefficients</i> , <i>zero crossing</i>	RMS	RMS
Número de Eletrodos	4	1	2	3	8
Movimentos Avaliados	6 Movimentos (posição de aperto, mão aberta, flexão do punho, extensão do punho, desvio ulnar e desvio radial do punho)	7 Movimentos (posição de escrita, aperto, pinça, indicativa, sobre o mouse, mão aberta e mão fechada)	6 Movimentos (abertura da mão, fechamento da mão, pitada, flexão do polegar, flexão radial do punho e extensão radial do punho)	5 Movimentos (fechamento da mão, flexão do punho, extensão do punho, flexão do antebraço e rotação)	7 Movimentos (fechamento da mão, flexão do punho, extensão do punho, flexão do antebraço, rotação do antebraço, adução da mão e abdução da mão)
Número de Voluntários	7 Não amputados e 2 Amputados	5 Não amputados	4 Não amputados	3 Não amputados	30 Não amputados
Taxa de acerto média (%)	93,2 ± 7,0%	91,43%	92,0%	93,2 ± 6,1%	86,0%

Os autores (XIE *et al.*, 2015) utilizaram a fusão de dois métodos, a Lógica *Fuzzy* e a SVM. Nos ensaios, foram utilizados quatro pares de eletrodos em configuração diferencial para a classificação de seis movimentos distintos para duas características diferentes AR com RMS (AR-RMS) e *Wavelet Transform* (WT). Encontraram uma taxa de acerto média de $93,2 \pm 7,0\%$ com a característica AR-RMS e de $92,8 \pm 4,0\%$ com a característica WL.

O estudo de (CAESARENDRA; TIAHJOWIDODO; PAMUNGKAS, 2017) apresentou um comparativo entre SVM e *Adaptive Neuro-fuzzy Inference System* (ANFIS) para sinais de sEMG. Dezesesseis características foram utilizadas (*integrated* EMG, MAV, *modified* MAV 1, *modified* MAV 2, *simple square integral*, VAR, RMS, WL, *difference absolute standard deviation value*, quatro *autoregressive coefficients*, *Hjorth activity*, *Hjorth mobility* e *Hjorth complexity*), reduzidos em três novos conjuntos de características usando a análise de componentes principais (PCA). Este novo conjunto de dados foi dividido em dois para treinamento e teste. A taxa de acerto da classificação dos movimentos com ANFIS foi de 91,43%, superior da classificação SVM, de 82,86%.

3.2.2 *Linear Discriminant Analysis* (LDA)

A LDA é um método tradicional de classificação (TANG *et al.*, 2012), pois é simples de implementar e rápida para treinar. Trabalhos anteriores tem mostrado uso da LDA em que não compromete a taxa de acerto da classificação e é visto como apropriado para aplicações em tempo real (CARRINO *et al.*, 2012; ENGLEHART; HUDGINS, 2003). Entretanto, o desempenho dos classificadores de LDA na identificação de movimentos ainda é limitado para longos tempos de controle de próteses multifuncionais, devido às alterações dos sinais de sEMG ao longo do tempo (HAOSHI ZHANG *et al.*, 2013).

O classificador LDA é baseado na regra de classificação de Bayes. A resposta do classificador é dada em probabilidade, porém não pode ser medida diretamente, mas pode ser derivada das estimativas das probabilidades e da distribuição de classe de acordo com a Equação de Bayes. Na implementação, as funções de probabilidade para todas as classes assumem uma distribuição gaussiana multivariada, onde durante o treinamento são definidos os parâmetros da função. Se estes são fixos, o classificador de LDA é dito estático. Assim, o classificador pode ter dificuldade de manter a taxa de acerto da classificação em longos períodos. Por este motivo, há estudos que propõem métodos adaptativos de LDA (HAOSHI ZHANG *et al.*, 2013; ZHANG *et al.*, 2014).

Antes da aplicação *on-line*, conjuntos de dados provenientes de treinamento são usados para treinar o classificador LDA. Os mesmos dados também são utilizados para avaliar os

conjuntos de características e a matriz de covariância, permitindo que o classificador calcule a função discriminante de separação do espaço em subespaços distintos, de forma a maximizar a distância entre as duas classes e minimizar a variação entre as classes (CARRINO *et al.*, 2012).

No estudo de (TANG *et al.*, 2012) na classificação de movimentos da mão, utilizaram seis pares de eletrodos posicionados de forma ajustável na parte posterior do antebraço. Com um conjunto de seis classificadores LDA em cascata para a identificação de 11 movimentos distintos e um sistema de redução de dimensionalidade da característica extraída com *Karhunen-Loeve transform*, a taxa de acerto média obtida no teste com seis sujeitos foi de 94,8%.

Em (RIILLO *et al.*, 2014), os autores também utilizaram seis eletrodos como os autores de (TANG *et al.*, 2012), porém o modelo apresentado foi desenvolvido para a caracterização de cinco movimentos e um número maior de voluntários. Neste trabalho, encontraram uma taxa de acerto média de $86,9 \pm 6,8\%$ com o uso da metodologia *Principal Component Analysis* (PCA) para identificar a melhor estratégia de classificação e os parâmetros de ajuste relacionados com a análise de combinações de sete características. Já no estudo de (GENG; ZHOU; LI, 2012), para voluntários amputados, foram utilizados oito pares de eletrodos de sEMG em conjunto com acelerômetros, adquirindo os sinais simultaneamente de ambos os braços dos voluntários, o braço não amputado e o braço amputado. Os voluntários realizaram seis movimentos em cinco posicionamentos diferentes do braço. A taxa de acerto média obtida neste estudo foi de $92,7 \pm 2,3\%$.

Em (AL-TIMEMY *et al.*, 2016), foi realizada uma abordagem com relação a presença de níveis variáveis de força em amputados transradiais utilizando a LDA, pois as variações de força podem ter um impacto substancial na eficiência do controle das próteses. Na mesma pesquisa, também foi apresentado um novo conjunto de características, definidas por um algoritmo de extração de características, chamado de *Time-Dependent Power Spectrum Descriptors*. O desempenho foi testado envolvendo dados de nove amputados transradiais utilizando oito eletrodos, realizando seis movimentos, os quais foram realizados em três níveis de força para cada um. Os movimentos analisados foram flexão do polegar, flexão do indicador, pinçamento, posição de escrita ou aperto de tripé, punho fechado e aperto esférico. A taxa de acerto média de classificação ao testar, com força considerada baixa no estudo, foi de 93%, enquanto, para as forças média e alta, foi de 90,3% e 82%, respectivamente.

A Tabela 4 apresenta a comparação dos artigos de classificação de movimentos do segmento mão-braço utilizando classificadores baseados em LDA. Novamente, a diversidade

na escolha de características do sinal de sEMG, número de eletrodos e movimentos avaliados dificulta a comparação dos estudos, porém pode ser observado uma tendência, onde ocorre um menor desempenho do classificador quando avaliado para uma grande variedade de movimentos e voluntários.

Tabela 4 Comparação entre artigos de classificação utilizando métodos com LDA

Autor	(GENG; ZHOU; LI, 2012)	(RIILLO <i>et al.</i> , 2014)	(ATZORI <i>et al.</i> , 2015)	(TANG <i>et al.</i> , 2012)	(AL-TIMEMY <i>et al.</i> , 2016)	(DING <i>et al.</i> , 2017)
Método de Classificação Utilizado	LDA	LDA	LDA	LDA	LDA	Híbrido (SVM e LDA)
Processo de Segmentação	Janela deslizante (tamanho 150 ms, delimitador 50 ms)	Janela deslizante (tamanho 300 ms, delimitador 75 ms)	Janela deslizante (tamanho 400 ms, delimitador 10 ms)	Janela fixa de 500 ms	Janela deslizante (tamanho 150 ms, delimitador 50 ms)	Janela deslizante (tamanho 250 ms, delimitador 100 ms)
Características	MAV, zero crossings, WL, slope sign changes	média, RMS, Willison amplitude, Slope sign change, Simple square integral, VAR, WL	MAV, VAR, WL, histogram, marginal Discrete Wavelet Transform (mDWT) separadamente	Energy ratio feature	Time-Dependent Power Spectrum Descriptors	7 caract., incluindo MAV e coeficientes cepstrais de ordem 6
Número de Eletrodos	8	6	12	6	8	4
Movimentos avaliados	6 Mov. (flexão do punho, extensão do punho, supinação do punho, pronação do punho, abrir a mão e fechar a mão)	5 Mov. (repouso, fechar a mão em punho, pitada, mão aberta e esticada, apontando)	50 Mov.	11 Mov. (movimentos de dedos em 9 posições diferentes, mão fechada, mão segundo uma bola)	6 Mov. (flexão do polegar, flexão do indicador, pinçamento, posição de escrita ou aperto de tripé, punho fechado e aperto esférico)	5 Mov. (agarrar, abrir mão e apertar o dedo indicador, médio e anelar)
Número de Voluntários	5 Amputados	40 Não amputados e 1 Amputado	40 Não amputados e 11 Amputados	6 Não amputados	9 Amputados	3 Não amputados
Taxa de acerto média (%)	92,7 ± 2,3%	86,9 ± 6,8%	Aproximadamente 65%	94,8%	93% para baixa força	92,4±3,3%

Um exemplo do uso de classificador LDA para uma grande quantidade de movimentos pode ser observado em (ATZORI *et al.*, 2015), onde foram utilizados 12 pares de eletrodos de superfície em configuração bipolar e extraído quatro características separadamente. Este estudo, utiliza a base de dados disponível publicamente do Projeto NinaPro (ATZORI *et al.*, 2015), tendo obtido uma taxa de acerto média de aproximadamente 65% para 50 movimentos de mão e punho.

Os pesquisadores de (DING *et al.*, 2017) apresentaram uma metodologia híbrida com dois classificadores, combinando SVM de uma classe com LDA de várias classes. O SVM realizou o reconhecimento de classes conhecidas ou rejeição de classes *outlier* ou discrepantes. Enquanto, o LDA de multiclases foi usado para classificar os movimentos. Cinco movimentos foram avaliados: agarrar, abrir mão e apertar o dedo indicador, médio e anelar. A taxa de acerto média de reconhecimento foi de $92,4 \pm 3,3$ para três sujeitos não amputados, utilizando quatro eletrodos com janelamento deslizante de 250 ms com incremento de 100 ms.

3.2.3 Redes Neurais Artificiais (RNA)

A RNA é um dos métodos de classificação clássicos, baseado em modelos de inteligência computacional capazes de aprender e reconhecer padrões. Uma RNA possui três tipos de camadas: camada de entrada, camada oculta e camada de saída. O número de camadas ocultas de uma rede neural é um valor selecionável e a utilização destas permite a construção de uma rede mais complexa. No entanto, a quantidade de camadas ocultas utilizada, normalmente, é definida através de testes, nos quais são utilizadas quantidades diferentes de camadas ocultas e de neurônios, analisando os resultados (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

O modelo de RNA considerado com melhor desempenho no reconhecimento de padrões é a rede neural *feed forward*. Para muitas aplicações, o modelo pode ser significativamente mais compacto, podendo realizar a classificação mais rapidamente que uma SVM tendo o mesmo desempenho de generalização (BISHOP, 2013; HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

O trabalho de (RIILLO *et al.*, 2014), além de realizar uma análise com LDA, o estudo também avaliou com os métodos de classificação RNA e SVM para os mesmos movimentos com a mesma quantidade de eletrodos. Quando a comparação ocorre com a utilização das mesmas configurações de ensaio, como posicionamento de eletrodos, tempo de amostragem, posicionamento do braço na execução, e avaliação para mesma base de voluntários, ou seja, com exatamente os mesmos dados de ensaio, é realmente possível comparar adequadamente os métodos de classificação, como no caso deste estudo. Os autores encontraram uma taxa de

acerto média com RNA de $89,3 \pm 6,1\%$, sendo esta a taxa de acerto com maior média e com menor desvio padrão que o classificador LDA também utilizado neste estudo. Ainda neste artigo, foi utilizada a metodologia de *Common Spatial Pattern* (CSP) para identificar a melhor estratégia de classificação e os parâmetros de ajuste relacionados, a qual passou a taxa de acerto média de $88,8 \pm 6,5\%$ com o uso da metodologia PCA em conjunto com o classificador RNA para o resultado anteriormente relatado de $89,3 \pm 6,1\%$.

Do ano de 2010 até o momento, a RNA tem sido mais utilizada em conjunto com outras técnicas (HE *et al.*, 2015; KHEZRI; JAHED, 2011; SUBASI, 2012). Porém, outros estudos também relacionados na Tabela 5 de (BALBINOT; JÚNIOR; FAVIEIRO, 2013) e (HASAN *et al.*, 2014), utilizaram classificação apenas por RNA e obtiveram taxa de acertos médias de 78,0% e 74,2%, respectivamente, para apenas dois voluntários, utilizando apenas uma característica extraída do sinal de sEMG.

Para a comparação dos estudos relacionados com classificação RNA, foi elaborada a Tabela 5. Porém, é importante observar que comparando estes estudos de RNA com os anteriores de outros métodos, nenhum destes atingiu taxas de acerto média superior a 90,0%.

Tabela 5 Comparação entre artigos de classificação utilizando métodos com RNA

Autor	(RIILLO <i>et al.</i> , 2014)	(BALBINOT; JÚNIOR; FAVIEIRO, 2013)	(HASAN <i>et al.</i> , 2014)
Método de Classificação Utilizado	RNA	RNA	RNA
Processo de Segmentação	Janela deslizante (tamanho 300 ms, delimitador 75 ms)	<i>threshold</i>	10 partes iguais
Características	média, RMS, <i>Willison amplitude</i> , <i>Slope sign change</i> , <i>Simple square integral</i> , VAR, WL	RMS	<i>average pixel difference values</i>
Número de Eletrodos	6	8	3
Movimentos Analisados	5 Movimentos (repouso, fechar a mão em punho, pitada, mão aberta e esticada, apontando)	5 Movimentos (contração da mão, extensão do punho, flexão do punho, flexão do antebraço e do antebraço rotação)	4 Movimentos (pedir a conta, polegar para baixo, dedos cruzados e <i>hang loose</i>)
Número de Voluntários	40 Não amputados e 1 Amputado	2 Não amputados	2 Não amputados
Taxa de acerto média (%)	$89,3 \pm 6,1\%$	78,0%	74,2%

Os autores de (KARABULUT *et al.*, 2017) apresentaram uma abordagem baseada em RNA para estimativa de forças aplicadas externamente com movimentos de contração muscular isométrica e isotônica, e contrações anisotônicas e anisométricas. As características do sinal de sEMG utilizadas são *Integrated EMG* (IEMG), RMS e WL, porém cada característica foi avaliada separadamente. O processo de classificação foi aplicado para seis sujeitos não amputados a partir de quatro eletrodos, posicionados sobre os músculos bíceps braquial, tríceps braquial, peitoral maior e trapézio. A segmentação utilizada pelos autores foi janelas deslizantes de 500 ms com incremento de 50 ms. Esta pesquisa não foi comparada com as demais, uma vez que o objetivo era a detecção de força, não a caracterização do movimento.

3.2.4 Máquinas de Vetores de Suporte (SVM)

A Máquina de Vetores de Suporte (SVM) é uma técnica de aprendizagem supervisionada, que se estabeleceu embasada na Teoria de Aprendizado Estatístico proposta por Vapnik e Chervonenkis (VAPNIK; CHERVONENKIS, 2013). Apresentou um grande desenvolvimento na última década, com a introdução do classificador com margem suave (CORTES; VAPNIK, 1995). Além disso, é empregada com destaque na classificação de padrões e regressão linear, tendo sua ênfase na capacidade de generalização e na pequena complexidade computacional. A capacidade da técnica é medida por sua eficiência na classificação de dados que não pertençam ao conjunto utilizado em seu treinamento (KECMAN, 2001; LI *et al.*, 2008). A SVM também tem a vantagem de necessitar de um menor número de parâmetros para o modelo de classificação de forma que não requer extensão prévia de informação (SEBALD; BUCKLEW, 2000).

Os métodos de SVMs lineares são eficazes na classificação de conjuntos de dados linearmente separáveis ou que apresentem uma separação aproximadamente linear dos dados. As SVM lineares com dados linearmente separáveis também são designadas por margens rígidas, no qual as restrições garantem que não haja pontos entre as margens de separação das classes, como por exemplo, o esboço gráfico na Figura 4. No caso, o conjunto de treinamento é linearmente separável por um hiperplano (ou a superfície de decisão) que diferencia as duas classes 1 e 2 (positiva e negativa, respectivamente). Pretende-se encontrar qual o melhor hiperplano que separa linearmente as duas classes, denominado por hiperplano ótimo, através da maximização da margem de separação entre as classes (BURGES, 1998; CORTES; VAPNIK, 1995).

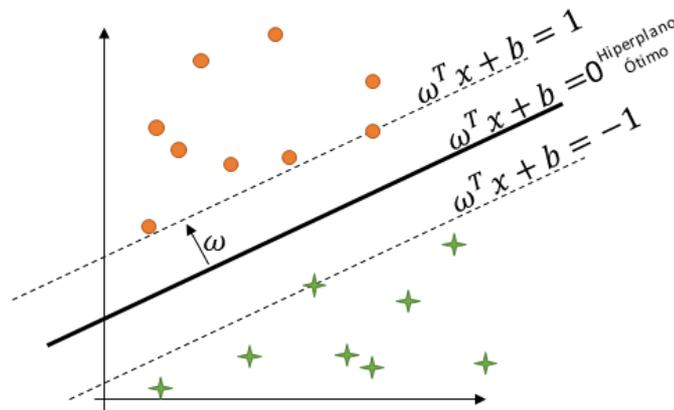


Figura 4 Hiperplano ótimo separando dados de margens rígidas.

Fonte: Adaptado de (HAYKIN, 2001).

Entretanto, há muitos casos em que não é possível dividir linearmente os dados. Nestes casos, é indicado a utilização de SVMs não lineares. A função *kernel* (núcleo de produto interno) é uma técnica matemática que permite a utilização de SVM para separar as amostras pertencentes às diferentes classes, sem que estas sejam linearmente separáveis em sua dimensão original. Muitas funções de mapeamento por *kernel* podem ser usadas, como polinomial, sigmóide e função de base radial (HAYKIN, 2001).

O uso de funções *kernel* das SVMs não lineares permite a construção de hiperplanos em um espaço de alta dimensão de forma tratável do ponto de vista computacional (BURGES, 1998). As características da SVM, tanto linear como não linear, são úteis para a classificação de padrões de sinal de sEMG, onde as características tendem a mudar com o tempo, bem como, permitem, em tempo-real, a classificação de movimentos (GUO *et al.*, 2015a; REKHI *et al.*, 2009; RIILLO *et al.*, 2014).

A restrição da separação completa das classes pelo uso da SVM de margens rígidas limita bastante sua aplicação, visto que a maioria dos problemas experimentais tende a violá-la. A violação pode ocorrer devido à falta de quantidade de informações nos dados de treinamento, superposição inerente entre as classes ou por ruído presente nos dados (LÓPEZ *et al.*, 2013). Como comentado anteriormente, foram desenvolvidas as SVMs de margem suave ou de margem flexível para resolver estes casos (CORTES; VAPNIK, 1995). Como exemplo, a Figura 5 introduz o conceito das variáveis de folga ($\varepsilon_i \geq 0$) associadas a cada um dos i -ésimos padrões de treinamento para aumentar a abrangência da sua aplicabilidade (SCHOLKOPF; SMOLA, 2001). Assim, modifica-se o modelo proposto de forma que ele aceite que alguns pontos do conjunto de treinamento sejam mal classificados, ou permite-se que existam pontos no “lado errado” do hiperplano.

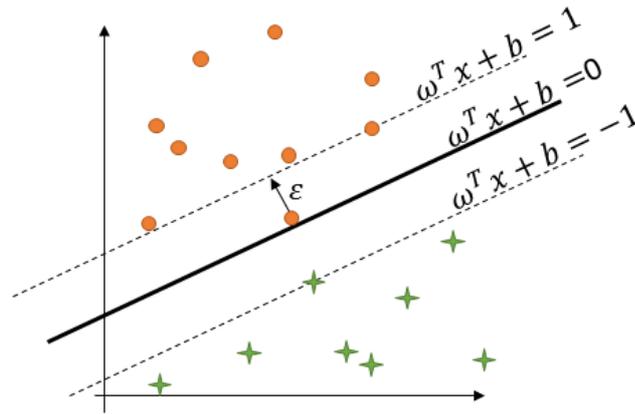


Figura 5 Hiperplano ótimo separando dados de margens suaves.

Fonte: Adaptado de (HAYKIN, 2001).

A SVM considera a formação de dados de entrada como um espaço de características N -dimensional. Em seguida, um $(N - 1)$ hiperplano dimensional separa o espaço em duas partes: os N dados de entrada de treinamento de x_i ($i=1,2, \dots, N$) são definidos como $y_i=1$ para a classe 1 e como $y_i=-1$ para a classe 2. Por exemplo, se utilizados dados linearmente separáveis, pode ser determinado um hiperplano $f(x) = 0$ que separa as classes (ALKAN; GÜNAY, 2012; QIAN *et al.*, 2010; WANG *et al.*, 2009), representado por:

$$f(x) = \omega^T x + b \quad (10)$$

$$f(x) = \sum_{i=1}^N \omega^T x_i + b = 0 \quad (11)$$

onde, $f(x)$ é a função de decisão, ω é um vetor N -dimensional e b é um escalar. O hiperplano determina a separação das classes conforme a Equação (12):

$$y_i(\omega^T x_i + b) - 1 \geq 0 \rightarrow \begin{cases} f(x_i) = \omega^T x_i + b \geq 1 & y_i = +1 \text{ (pertence a classe)} \\ f(x_i) = \omega^T x_i + b \leq -1 & y_i = -1 \text{ (não pertence)} \end{cases} \quad (12)$$

O hiperplano que define o limite máximo é chamado de um hiperplano ótimo ou ideal. Para isso, minimiza-se a solução do hiperplano definida na Equação (13):

$$\mathcal{J}(\omega, \varepsilon) = 1/2 (\omega^T \cdot \omega) + C \left(\sum_{i=1}^N \varepsilon_i \right) \quad (13)$$

onde, ε_i é a variável independente de folga, e C é um parâmetro constante, denominado parâmetro de regularização, que pondera os erros de treinamento (ABE, 2010; WANG *et al.*, 2009).

A Equação (13) depende de:

$$\begin{aligned} y_i(\omega^T x_i + b) &\geq 1 - \varepsilon_i \\ \varepsilon_i &\geq 0 \end{aligned} \quad (14)$$

Este cálculo pode ser simplificado através da utilização do método de multiplicadores de Lagrange, que transforma o problema primal em um problema dual, de solução mais simples. A função Lagrangiana é definida na Equação (15):

$$\mathcal{L}(\omega, b, \varepsilon, \alpha, v) = \mathcal{J}(\omega, \varepsilon) - \sum_{i=1}^N \alpha_i (y_i(\omega^T x_i + b) - 1 + \varepsilon_i) - \sum_{i=1}^N v_i \varepsilon_i \quad (15)$$

onde, os multiplicadores de Lagrange são $\alpha_i \geq 0$ e $v_i \geq 0$ ($i = 1, 2, \dots, N$) (SUYKENS, 2001). A solução é caracterizada por:

$$\max_{\alpha, v} \min_{\omega, b, \varepsilon} \mathcal{L}(\omega, b, \varepsilon, \alpha, v) \quad (16)$$

e obtêm-se:

$$\frac{\partial \mathcal{L}}{\partial \omega} = 0 \rightarrow \omega = \sum_{i=1}^N \alpha_i y_i x_i \quad (17)$$

$$\frac{\partial \mathcal{L}}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad (18)$$

$$\frac{\partial \mathcal{L}}{\partial \varepsilon_i} = 0 \rightarrow 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, N \quad (19)$$

Ao substituir ω na Lagrangeana, o resultado obtido é o problema dual representado pela Equação (20):

$$\max_{\alpha} V(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j \cdot K(x_i, x_j) \quad (20)$$

Considerando:

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (21)$$

$$0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, N \quad (22)$$

A função $K(x_i, x_j)$ é uma função *kernel* que retorna o produto das características. As funções *kernel* mais utilizadas em sEMG são (RECHY-RAMIREZ; HU, 2015; SEBALD; BUCKLEW, 2000; SUYKENS, 2001; WANG *et al.*, 2009):

Linear:

$$K(x_i, x_j) = x_i^T x_j \quad (23)$$

Polinomial:

$$K(x_i, x_j) = (x_i^T x_j + 1)^d \quad (24)$$

Gaussiana de Função Base Radial (RBF):

$$K(x_i, x_j) = \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (25)$$

onde, d é a ordem do polinômio e σ é o desvio padrão do *kernel* RBF. Para definir classificadores SVM, é necessário selecionar uma função *kernel*. No espaço dual o classificador SVM torna-se:

$$y(x) = \text{sign} \left[\sum_{i,j=1}^N \alpha_i y_i \cdot K(x_i, x_j) + b \right] \quad (26)$$

A SVM é utilizada diretamente somente para casos que possuam apenas duas classes a classificar (classificador binário ou booleano). Há várias abordagens recomendadas para separar os vetores de suporte de características em casos onde há mais de duas classes (multiclasses). As mais populares, na área, são: “um contra todos” (*one-versus-all*) e, “um contra um” (*one-versus-one*) (BISHOP, 2013; GIJSBERTS; CAPUTO, 2013; LORENA; DE CARVALHO, 2007; NAIK; KUMAR; JAYADEVA, 2010).

O método amplamente utilizado é o “um contra todos”, pois necessita menor capacidade computacional. O classificador SVM de multiclasses utilizando “um contra todos” distingue uma classe e todas as outras são mescladas. Assim, para cada classe é construído um classificador, ou seja, se existirem N classes são construídos N classificadores. Entretanto, a saída do modelo não apresenta uma probabilidade de acerto para cada classe, as únicas saídas possíveis são $+1$ ou -1 , ocorrendo à possibilidade de mais de um dos N classificadores responderem positivamente para uma determinada classe (BISHOP, 2013).

A *Cross Validation* (CV) é outra técnica geralmente utilizada em conjunto com os métodos de classificação. Partindo da necessidade de separar o conjunto de dados adquiridos de sinais de sEMG disponível em dois grupos, treinamento e teste, a CV determina o *k-fold* (k conjuntos), sendo determinados por k subconjuntos de igual tamanho. Estes subconjuntos são separados de forma aleatória em dados de treinamento e de teste para uma proporção p . A CV de *leave-p-out* forma c subconjuntos diferentes de treinamento e teste dos mesmos dados originais adquiridos para o modelo de classificação desejado, definido pela Equação (27). Assim, a taxa de acerto resultante do modelo proposto é calculada pela média das taxas de acerto de todas as combinações possíveis da proporção p para k números de *k-fold* (LÓPEZ *et al.*, 2013; XING *et al.*, 2014), sendo representado por:

$$c = C(k, p, k) = \frac{k!}{(p \cdot k)! (k - p \cdot k)!} \quad (27)$$

$$0 < p < 1$$

O estudo de (GUO *et al.*, 2015a) buscou a comparação de oito combinações de quatro características extraídas (RMS, *Detrended Fluctuation Analysis*, *Weight Peaks*, e *Muscular Model*) com dois tipos de classificadores (RNA e SVM). Apenas sete voluntários participaram do experimento e foram utilizados seis pares de eletrodos, para obter uma taxa de acerto média de 88,7% durante o treinamento com RNA e uma taxa de acerto média de 85,9% durante a experiência *on-line* com SVM. Ainda comparando as duas técnicas no mesmo estudo, o classificador SVM levou menos tempo que o classificador por RNA durante o processo de treinamento, entretanto necessitava de mais tempo de processamento no funcionamento *on-line*.

Em (ALKAN; GÜNAY, 2012), foram registrados sinais de sEMG gerados pelos músculos bíceps e tríceps para quatro movimentos diferentes. Como entradas do classificador foram extraídos de cada canal a característica MAV para dois tipos de classificadores, análise discriminante e SVM. A análise discriminante obteve taxas de acerto na classificação de 96,0% a 98,0%, enquanto o classificador utilizando SVM alcançou uma taxa de acerto média de 99,0% com a taxa de erro de classificação de 1,0%. É importante ressaltar que neste estudo apenas um voluntário não amputado realizou os movimentos analisados.

A Tabela 6 apresenta a comparação de alguns artigos relacionados anteriormente baseados na classificação de movimentos com SVM de função *kernel* Linear (SVM Linear). Observa-se novamente, a variedade de características distintas em cada estudo.

Tabela 6 Comparação entre artigos de classificação utilizando métodos com SVM Linear

Autor	(GUO <i>et al.</i> , 2015a)	(ALKAN; GÜNAY, 2012)	(ATZORI <i>et al.</i> , 2015)	(ATZORI <i>et al.</i> , 2014)	(MOURA; FAVIEIRO; BALBINOT, 2016)
Método de Classificação Utilizado	SVM Linear	SVM Linear	SVM Linear	SVM Linear	SVM Linear
Processo de Segmentação	Janela deslizando (tamanho 100 amostras, delimitador 25 amostras)	Janelas fixas de 32 amostras	Janela deslizando (tamanho 400 ms, delimitador 10 ms)	<i>timestamp</i>	<i>timestamp</i>
Características	RMS, <i>Detrended Fluctuation Analysis</i> , <i>Weight Peaks</i> , <i>Muscular Model</i>	MAV	MAV, VAR, WL, <i>histogram</i> , mDWT separadamente	RMS, <i>the time domain statistics described by Hudgins</i> , <i>Histogram</i> , <i>marginal Discrete Wavelet Transform</i>	RMS
Número de Eletrodos	6	2	12	12	12
Movimentos Analisados	8 Movimentos (flexão e extensão do cotovelo, pronação do antebraço e supinação, flexão do punho e extensão, abdução e adução de pulso)	4 Movimentos (flexão e extensão do cotovelo, pronação do antebraço e supinação)	50 Movimentos	50 Movimentos	17 Movimentos
Número de Voluntários	7 Não amputados	1 Não amputado	40 Não amputados e 11 Amputados	11 Amputados	5 Não Amputados
Taxa de acerto média (%)	85,9%	99,0 ± 1,0%	Aproximadamente 62,0%	46,3%	83,7%

Nos estudos de (ATZORI *et al.*, 2014, 2015), o objetivo foi caracterizar o banco de dados do projeto NinaPro para permitir que grupos de pesquisa em todo o mundo desenvolvam projetos de reconhecimento de movimento para próteses avançadas do segmento mão-braço em uma base de dados de referência comum. Além de descrever o protocolo de aquisição, características gerais dos conjuntos de dados e os procedimentos de processamento em detalhe, apresentaram resultados da classificação de referência usando uma variedade de classificadores e características extraídas.

Os autores do estudo de (ATZORI *et al.*, 2015) utilizaram seis características extraídas de 12 canais para 40 voluntários não amputados e 11 voluntários amputados. Neste estudo, obtiveram aproximadamente 62,0% de taxa de acerto média utilizando a SVM Linear e aproximadamente 75,0% utilizando SVM não linear com RBF (SVM RBF). Entretanto, no estudo de (ATZORI *et al.*, 2014), foi obtido 46,3% de taxa de acerto média para 11 amputados, utilizando apenas 3 características extraídas dos mesmos 12 canais do estudo anterior.

Em (DE PAULI NILSON; BALBINOT, 2014), foi desenvolvido um sistema com sinais de sEMG e SVM Linear para a caracterização de movimentos específicos de braço humano, utilizando as características RMS, desvio padrão, VAR, média, KURT, SKW extraídos de oito canais para entrada do classificador. A taxa de acerto média obtida foi de 76,7% para um voluntário. Na dissertação de mestrado de (NILSON, 2014), foi utilizado as mesmas características extraídas, porém para três voluntários, os nove movimentos distintos atingiram uma taxa de acerto média de 83,2% para dois canais, e de 91,3% para oito canais.

No estudo de (MOURA; FAVIEIRO; BALBINOT, 2016), uma pesquisa preliminar deste trabalho, foi apresentado a comparação da taxa de acerto de classificação obtida por SVM utilizando os *kernels* linear, polinomial e RBF. A taxa de acerto na classificação de 17 movimentos, usando a característica RMS de 12 canais de sEMG, foi de 83,7% para SVM linear, de 80,8% para SVM polinomial e de 85,1% para SVM RBF. O classificador SVM RBF apresentou o melhor desempenho e com menor dispersão da taxa de acerto média de classificação dos movimentos para diferentes sujeitos. A análise estatística dos resultados experimentais apresentou que a variação dos sujeitos, da função *kernel* do classificador SVM e dos movimentos efetuados afetaram significativamente a taxa de acerto média obtida. A interação entre os fatores de variação do sujeito e do movimento demonstrou que cada sujeito tem características únicas de sinal de sEMG, as quais proporcionam diferenças significativas na taxa de acerto de cada movimento.

No estudo de (RIILLO *et al.*, 2014), como comentado anteriormente, além dos autores analisarem a classificação dos movimentos com LDA e RNA, também classificaram os dados com uma SVM não linear de função *kernel* RBF. Com a mesma quantidade de canais, os autores buscaram as melhores características entre as sete características extraídas para os mesmos cinco movimentos. A melhor taxa de acerto média obtida com SVM RBF foi de $86,7 \pm 7,7\%$, inferior à melhor taxa de acerto de $89,3 \pm 6,1\%$ com RNA, utilizando a metodologia de PCA para identificar a melhor estratégia de classificação e os parâmetros de ajuste relacionados. Na Tabela 7, é possível observar a comparação dos artigos selecionados de classificação com SVM não linear.

Tabela 7 Comparação entre artigos de classificação utilizando métodos com SVM não linear e combinada com outras técnicas

Autor	(RIILLO <i>et al.</i> , 2014)	(ATZORI <i>et al.</i> , 2015)	(ROSSI <i>et al.</i> , 2015)	(XING <i>et al.</i> , 2014)	(LIU, 2015)	(HUANG <i>et al.</i> , 2016)
Método de Classificação Utilizado	SVM RBF	SVM RBF	Modelo Oculto de Markov e SVM RBF	SVM Linear com <i>non-parametric weighted feature extraction</i> (NWFE)	<i>Adaptative SVM</i>	SVM RBF
Processo de Segmentação	Janela deslizante (tamanho 300 ms, delimitador 75 ms)	Janela deslizante (tamanho 400 ms, delimitador 10 ms)	Modelo Oculto de Markov	Janela deslizante (tamanho 256 ms, delimitador 128 ms)	Janela deslizante (tamanho 256 ms, delimitador 128 ms)	Janela deslizante (tamanho 250 ms, <i>overlap</i> 25 ms)
Características	média, RMS, <i>Willison amplitude, Slope sign change, Simple square integral, VAR, WL</i>	MAV, VAR, WL, <i>histogram, mDWT</i> separadamente	Dado no domínio tempo	NWFE	Combinação de AR e <i>time domain</i> (TDAR)	MAV, ZC, <i>slope sign change</i> (SSC) e WL
Número de Eletrodos	6	12	4	4	8	16
Movimentos Analisados	5 Mov. (repouso, fechar a mão em punho, pitada, mão aberta e esticada, apontando)	50 Mov.	6 Mov. (mão fechada, mão aberta, pitada de 2 dedos, pitada de 3 dedos, apontando e posição de repouso)	7 Mov. (repouso, extensão do punho, flexão do punho, desvio ulnar, desvio radial, mão fechada e mão aberta)	7 Mov. (mão aberta, mão fechada, supinação, pronação, flexão do punho, extensão do punho e repouso)	13 Mov.
Número de Voluntários	40 Não amputados e 1 Amputado	40 Não amputados e 11 Amputados	9 Não amputados	1 Intacta	15 Não amputados	5 Não amputados e 3 Amputados
Taxa de acerto média (%)	86,7 ± 7,7%	Aproximadamente 75%	91,8%	98,3%	92,0 ± 4,1%	85,2 %

Em (ROSSI *et al.*, 2015), os autores propuseram, no lugar de uma abordagem convencional para melhorar o desempenho da classificação, a qual se baseia nos ajustes de parâmetros ou técnicas de extração de características, uma abordagem complementar com base

na combinação de dois classificadores heterogêneos, SVM e os Modelos Ocultos de Markov. Neste estudo, concluíram que, independentemente do desempenho inicial da SVM, a abordagem combinada proporciona um aumento na taxa de acerto do reconhecimento dos movimentos. Apenas com SVM, a taxa de acerto média foi de 84,0%, porém, com a adição do Modelo Oculto de Markov, a taxa de acerto média geral relatada foi de 91,8%.

O estudo de (XING *et al.*, 2014) apresentou uma abordagem de reconhecimento de padrões em tempo real para o controle de próteses multifuncionais de mãos mioelétricas, onde utilizaram uma técnica de seleção de características. O algoritmo de classificação SVM utilizou as características selecionadas reduzidas por *Non-Parametric Weighted Feature Extraction* (NWFE) para a classificação de sete movimentos. A técnica de seleção de características foi utilizada para a redução da quantidade de características analisadas pelo classificador. Assim, as características reduzidas, ou não essenciais, foram descartadas diretamente para minimizar o custo computacional durante a classificação. O estudo atingiu a taxa de acerto de 98,3% para o teste com apenas um voluntário.

Também são encontradas abordagens adaptativas utilizando SVM, como por exemplo, o estudo de (LIU, 2015), onde foi proposto um sistema de reconhecimento adaptativo com treinamento do classificador *on-line* dos dados de teste sem supervisão, proporcionando um mecanismo de autocorreção para suprimir erros de classificação. Com dados de 15 indivíduos não amputados, o classificador SVM adaptativo sem supervisão superou o classificador SVM convencional também realizado no estudo, atingindo $92,0 \pm 4,1\%$ no método adaptativo em comparação a $84,0 \pm 8,2\%$ no método convencional.

Na pesquisa de (HUANG *et al.*, 2016), forem avaliados quatro características de sEMG no domínio do tempo, de forma independente e combinadas, para oito sujeitos durante 13 movimentos dos dedos. Os resultados de dois classificadores, SVM RBF e LDA, foram analisados. O posicionamento dos eletrodos, nesta pesquisa, foram 12 eletrodos nos músculos flexores superficiais na parte interna do antebraço e quatro eletrodos foram colocados nos músculos extensores superficiais no lado dorsal do antebraço. Os movimentos realizados foram a flexão do polegar, flexão do dedo indicador, flexão do dedo médio, flexão do dedo anelar, flexão do dedo mínimo, oposição do polegar, extensão do polegar, extensão do dedo indicador, extensão do dedo médio, extensão do dedo anelar, extensão do dedo mínimo e abdução do polegar. A melhor taxa de acerto média utilizando a SVM foi de 85,2% com a estrutura de *one-versus-all* e a técnica de voto majoritário, enquanto o LDA obteve 81,5% nas mesmas condições.

3.3 INSTRUMENTAÇÃO INTELIGENTE

As aplicações de instrumentação têm crescido rapidamente, requerendo sistemas de medição de complexidade média a alta. Durante a última década, foram exigidas novas tecnologias de sistemas de sensores ou de condicionamento de sinal, as quais focam em medições de parâmetros mais especializados no processo. Há ocasiões, na atualidade, em que o sensor, além de medir um parâmetro do processo, também tem que tomar decisões adicionais e executar muitas outras operações não convencionais, como validação, compensação e classificação. Essa nova categoria de sensores recebeu a marca de inteligente e foi a partir dela que se incorporou inteligência a todos os sistemas de instrumentação (BHUYAN, 2013).

Normalmente, os classificadores de sinais mioelétricos não se adaptam às mudanças dos padrões dos sujeitos ao longo do tempo. Entre estas alterações podem ser citadas: condutibilidade dos eletrodos, fadiga muscular, deslocamento do eletrodo na pele, entre outros fatores (LIU, 2015; SENSINGER; LOCK; KUIKEN, 2009; ZHANG; HUANG, 2015). O desenvolvimento de sistemas adaptativos a essas mudanças no sinal de sEMG é necessário para obter próteses mioelétricas de controle mais intuitivo e natural, mas a maioria dos desenvolvimentos recentes não estão adaptados a essas mudanças (ATZORI; MÜLLER, 2015; BLANA *et al.*, 2016; FRASER *et al.*, 2014; JIANG; LORRAIN; FARINA, 2014; LIU, 2015; SENSINGER; LOCK; KUIKEN, 2009; SPANIAS; PERREAULT; HARGROVE, 2016; ZHANG; HUANG, 2015).

Várias soluções foram desenvolvidas para reduzir a interferência nos sinais mioelétricos adquiridos (CHOWDHURY *et al.*, 2013; FAVIEIRO; CENE; BALBINOT, 2016; FRASER *et al.*, 2011; MASTINU *et al.*, 2018; SOEDIRDJO; ULLAH; MERLETTI, 2015; TOMASINI *et al.*, 2016; ZHANG; HUANG; YANG, 2013; ZHANG *et al.*, 2017b). Estes exemplos, relataram que persistem interferências residuais nos sinais de sEMG. Os estudos de (CHOWDHURY *et al.*, 2013; FRASER *et al.*, 2011; SOEDIRDJO; ULLAH; MERLETTI, 2015; TOMASINI *et al.*, 2016) relataram soluções únicas para determinadas interferências, entre as quais relataram que a utilização de filtros podem afetar negativamente o reconhecimento de padrão utilizando características de frequência na detecção de fadiga. Todavia, os estudos de (FAVIEIRO; CENE; BALBINOT, 2016; LIU *et al.*, 2016; ZHANG; HUANG; YANG, 2013; ZHANG *et al.*, 2017a, 2017b) procuraram soluções mais completas para os diferentes ruídos. Entretanto, também relataram a persistência de algumas interferências, como por exemplo, artefatos de movimentos (ZHANG; HUANG; YANG, 2013).

De forma geral, um sistema inteligente deve ser capaz de aprender em função do seu meio ambiente ou do usuário. Portanto, deve ser capaz de dar informações confiáveis em condições de mudança (BHUYAN, 2013). Desta forma, utilizando estes conceitos de instrumentação inteligente para o reconhecimento de movimentos de sinais de sEMG para próteses mioelétricas na interferência de ruído ou na aquisição degradada de algum sinal, o sistema deve identificar e corrigir ou desconsiderar o sinal em questão. O objetivo desta correção ou descarte deve ser de forma a preservar ou melhorar a eficiência na execução dos movimentos de uma prótese. Portanto, a utilização dos conceitos de instrumentação inteligente previamente à classificação pode contribuir para reduzir o impacto dos problemas relatados, como alterações devido à transpiração ou umidade ambiente, deslocamento do eletrodo na pele ou a perda de contato eletrodo-pele. Além disso, pode contribuir garantindo o funcionamento do classificador desenvolvido na falta ou falha da leitura de um eletrodo de superfície de sinal mioelétrico, mantendo a taxa de acerto média dos voluntários, ou pelo menos, na manutenção do funcionamento do sistema.

Segundo (BHUYAN, 2013), os sensores inteligentes são umas das técnicas utilizadas de instrumentação inteligente. Eles podem ser classificados por meio de duas abordagens: pela função que desempenham ou pela técnica a qual foram concebidos. Sensores virtuais são uma das classificações com relação à técnica. Estes tipos de sensores podem ser imprescindíveis para o monitoramento do comportamento e do desempenho de um sistema. Por exemplo, quando uma medida se torna indisponível ou quando ocorre uma falha de aquisição, o desempenho do sistema pode ser comprometido. O sensor virtual tem como objetivo estimar as medidas indisponíveis usando um modelo do sistema ou uma parte dele para correlacionar a medida de interesse com outras variáveis.

Os sensores virtuais são uma ferramenta emergente e inteligente que foi usada com sucesso em outras áreas (FAGIANO; NOVARA, 2013; PLOENNIGS *et al.*, 2011; PONSART; THEILLIOL; AUBRUN, 2010; SÁNCHEZ-MOLINA *et al.*, 2015). Normalmente, estes sensores são usados para substituir sensores físicos (IBARGÜENGOYTIA *et al.*, 2013; LIU; INOUE; SHIBATA, 2010; PLOENNIGS *et al.*, 2011). Todavia, também podem ser usados como parte de metodologias de detecção de falhas, onde sua saída é comparada ao sensor correspondente (HO; SATZGER; DE CASTRO, 2017; NAZARI *et al.*, 2013; PONSART; THEILLIOL; AUBRUN, 2010; TABBACHE *et al.*, 2013; YETENDJE *et al.*, 2011) para atuar corretivamente. O conceito de sensores virtuais também está presente em estudos no contexto de sensores vestíveis (LIU; INOUE; SHIBATA, 2010; RAVEENDRANATHAN *et al.*, 2012) e em outros envolvendo sinais fisiológicos (CREMA *et al.*, 2017).

A pesquisa de artigos tanto em revistas, como em congressos, permitiu identificar pesquisadores com interesse em desenvolver técnicas inteligentes para a classificação de sinais de sEMG (CENE; FAVIEIRO; BALBINOT, 2015; DING *et al.*, 2017; DU *et al.*, 2017; ERTUĞRUL; KAYA; TEKIN, 2016; LIU, 2015; NILSSON; HÅKANSSON; ORTIZ-CATALAN, 2017; ZHANG; HUANG, 2015). Entre os desafios na área de reabilitação, também se encontra o desenvolvimento de interfaces mioelétricas adaptáveis ao usuário, por isso estudos de sistemas com abordagens adaptativas de modelo de reconhecimento dos movimentos começaram a surgir nesta área (KHUSHABA, 2014; MATSUBARA; MORIMOTO, 2013; PARK; LEE, 2016; TOMMASI *et al.*, 2013). Os benefícios são a capacidade do paciente adaptar-se rapidamente à prótese, se sentir confortável e ser capaz de usar com mais naturalidade em atividades diárias (TOMMASI *et al.*, 2013). Então, neste capítulo, também foi abordado interfaces adaptativas independentes do usuário ou parcialmente independentes, também conhecida como interfaces multiusuários.

3.3.1 Técnicas Inteligentes Utilizadas em EMG

As duas técnicas de segmentação inteligentes relacionadas anteriormente (AZAMI *et al.*, 2015; LIN; KULIC, 2014), propõem métodos de decomposição do sinal adicionando algoritmos para otimização da segmentação. Em (AZAMI *et al.*, 2015), o sinal foi decomposto com DWT, foi extraído a FD das janelas e, para melhorar o procedimento de segmentação e comparar os resultados obtidos, foi utilizado quatro algoritmos evolucionários: PSO, novo PSO, PSO *With Mutation*, e BCO. Já em (LIN; KULIC, 2014), foram extraídos dos segmentos características de velocidade, tais como picos de velocidade e *zero crossing*, e foram identificadas as posições de movimentos dos segmentos com os Modelos Ocultos de Markov (HMM). Há outro estudo que também utiliza HMM na segmentação (PARK *et al.*, 2015) com uma abordagem de modelo semioculto.

Há ainda outro estudo relevante de segmentação relacionando sinais de sEMG de membros inferiores, onde foi apresentado um novo método de segmentação, chamado no estudo de *Peak information and Non-Equidistant Window Function Method* (P&WND) (SHI; LIU; WANG, 2013). Basicamente, o P&WND foi realizado em quatro passos: a remoção de segmentos do sinal onde a derivada for negativa, a obtenção do ponto de referência através de um pico do sinal, a determinação do tamanho da janela e a extração de características desta. A taxa de acerto média do método utilizado para comparação, utilizando *threshold* para a definição do segmento, foi de aproximadamente 88,8%, enquanto que a taxa de acerto média do método de segmentação de P&WND atingiu 100%.

Há também combinações de técnicas na classificação, algumas das quais foram citadas anteriormente (DING *et al.*, 2017; ROSSI *et al.*, 2015; XIE *et al.*, 2015). Relembrando especialmente (ROSSI *et al.*, 2015), onde foi realizada a combinação de dois classificadores, o SVM e o HMM, a qual aumentou a taxa de acerto média de 84,0% com SVM, para 91,8% com a adição de HMM. Entretanto, não ocorreu à fusão entre as técnicas no estudo, cada gesto foi considerado um processo dinâmico e suas fases distintas foram identificadas usando HMM. Assim, o classificador HMM foi usado para discernir entre quatro fases (repouso, transientes iniciais, gesto e transitórios finais). A saída do HMM foi então usada na entrada do classificador SVM durante as fases de repouso e de movimento. Durante as fases transientes, não foi ativado o classificador SVM.

A proposta de (ROSSI *et al.*, 2015) é similar à apresentada em (DING *et al.*, 2017), os quais também utilizaram uma metodologia híbrida com dois classificadores. A combinação de uma SVM, que realiza o reconhecimento de classes conhecidas ou rejeição de classes discrepantes, com um LDA para classificação dos movimentos. Além disso, o conjunto foi avaliado quanto a uma atualização incremental no reconhecimento dos movimentos de maneira *on-line* usando os dados de movimentos discrepantes encontrados. O algoritmo híbrido proposto foi capaz de rejeitar os movimentos discrepantes e obter uma taxa de acerto média 23% maior que um classificador RNA.

O estudo de (XING *et al.*, 2014), citado anteriormente, não foi o único que aborda um sistema de otimização focado na seleção de características para um classificador SVM, há também estudos utilizando o PSO (HUANG; DUN, 2008; LIN *et al.*, 2008; SUBASI, 2013; SUDHEER *et al.*, 2014), o *Canonical Discriminant Analysis* (CDA) (FUTAMATA; NAGATA; MAGATANI, 2012), o Algoritmo Genético (GA) (KANITZ *et al.*, 2011), e outro com a combinação de PSO e GA (ALOMARI; LIU, 2015).

Em (ALOMARI; LIU, 2015), foi proposto um sistema de reconhecimento de padrão híbrido inteligente para classificar oito movimentos da mão, utilizando GA e PSO combinados com SVM, chamado de GAPSO-SVM. O sistema híbrido selecionou os parâmetros ideais de função de base radial (SVM RBF) com o PSO e escolheu o nível de decomposição ideal de uma função *wavelet* com o GA. Neste estudo, a característica de energia dos coeficientes *wavelet* foi extraída a partir de sinais de sEMG adquiridos dos músculos do antebraço. Além disso, buscando a redução do grau de dimensionalidade do vetor de características, foi investigado o desempenho de diferentes algoritmos, *Neighbourhood Preserving Embedding* (NPE), *Principal Component Analysis* (PCA), *Independent Components Analysis* (ICA) e *Orthogonal Linear Discriminant Analysis* (OLDA). O resultado do estudo relatou que o modelo híbrido

apresentado atingiu maior taxa de acerto em comparação com outros três classificadores: SVM, *fuzzy least squares SVM* e *K-nearest neighbour* (K-NN). A taxa de acerto com maior média alcançada foi de 98,7%, empregando o classificador GAPSO-SVM com PCA.

Além da abordagem adaptativa relacionada anteriormente (LIU, 2015), a qual utilizou um classificador SVM adaptativo com treinamento do classificador *on-line* com os dados de teste sem supervisão, proporcionando um mecanismo de autocorreção para suprimir erros de classificação, são encontradas outras abordagens adaptativas. Como por exemplo, as propostas com o objetivo de reduzir algumas perturbações que contaminam o sinal de sEMG por eletrodos soltos e/ou mau contato (CENE; FAVIEIRO; BALBINOT, 2015; ZHANG; HUANG, 2015).

Em (ZHANG; HUANG, 2015), foi apresentado um algoritmo de LDA capaz de descartar dados fornecidos com as seguintes interferências: artefatos de contato, contatos soltos e ruído *baseline*. No estudo, foi proposto um módulo tolerante às falhas dos sensores (SFTM) através da utilização da informação redundante em vários sinais de sEMG para próteses controladas de EMG. Este trabalho buscou reduzir o tempo necessário para a classificação de movimento. Além disso, foi relatado que não houve necessidade de nenhum conhecimento prévio do tipo de distúrbio na estruturação do detector de falha do sensor. O SFTM consiste de múltiplos detectores de falha do sensor, um sistema para combinar características em um vetor e um mecanismo de auto recuperação. Este mecanismo pode identificar anomalia no sinal de sEMG e remover as gravações dos ruídos da entrada do classificador, e assim recuperar o desempenho, fazendo um retreinamento do classificador. A avaliação experimental com cinco indivíduos não amputados e um sujeito amputado melhorou significativamente a taxa de acerto média de classificação em comparação com a interface sem a SFTM quando diferentes tipos de distúrbios foram introduzidos.

Os detectores de falha de sensores, ainda no estudo de (ZHANG; HUANG, 2015), acompanham de perto as características de sinais individuais de sEMG para detectar vários distúrbios, usando um método de detecção *outlier* com base na análise Distância de Mahalanobis (MAHALANOBIS, 1936). Este método de detecção foi construído a partir dos dados de treinamento, não precisou de conhecimento prévio de dados considerados normais e de tipos de interferências, além disso, foi considerado pelos autores computacionalmente eficiente para aplicação em tempo real.

Os autores de (CENE; FAVIEIRO; BALBINOT, 2015), buscando melhorar a taxa de acerto média durante a ocorrência de distúrbios, desenvolveram um sistema automático e auto-adaptativo para estabelecer um monitoramento contínuo de sinal de sEMG. Através da busca constante de eletrodos ideais, sinalizando os eletrodos que não atendessem os *thresholds* de

contaminação, para adequar os dados de entrada de um classificador RNA e determinar nove movimentos do braço, o sistema apresentado atingiu a taxa de acerto média de classificação de $83,9 \pm 5,7\%$ para o método de seleção de entrada adaptativa, em comparação com $72,0 \pm 7,1\%$ de um sistema não-adaptativo.

Ainda no estudo de (CENE; FAVIEIRO; BALBINOT, 2015), a identificação de eletrodos soltos foi realizada através da identificação deste ruído ao longo do tempo pelo monitoramento do valor de RMS do sinal de sEMG quando superior ao valor esperado. Todavia, a identificação de eletrodos mal-colocados, o qual é ocasionado pelo deslocamento da região ventre muscular, foi realizada com base em um limite estabelecido de valor RMS durante um momento de relaxamento muscular em comparação com o valor de RMS das últimas cinco contrações musculares conhecidas. A seleção adaptável de entradas ficou constantemente verificando as entradas. Quando detectou uma alteração, a rede neural retreinou, utilizando um conjunto diferente de entradas, com base na análise dos canais, garantindo que o classificador RNA mantivesse apenas dados considerados importantes para o reconhecimento de movimento. Ou seja, o sistema proposto também foi capaz de re-considerar os canais, que foram considerados contaminados anteriormente, para a entrada do classificador.

O artigo de (HUANG *et al.*, 2012) apresentou um novo método de seleção de recurso de *Ant Colony Optimization* (ACO) para classificar os sinais de sEMG de movimentos da mão, o qual fez um esquema de seleção de características com base no ACO através de um *Minimum Redundancy Maximum Relevance Criterion* (ACO-mRMR). Os experimentos foram realizados com 10 indivíduos para oito movimentos dos membros superiores. Dois conjuntos de características (*Time Domain Features Combined With Autoregressive Model Coefficients* (TDAR) e *Wavelet Transform* (WT)) foram extraídos dos sinais de sEMG. As taxas de acerto média de classificação com a utilização do ACO com TDAR e com WT foram de $95,4 \pm 2,2\%$ e $96,0 \pm 3,3\%$, respectivamente. Para comparação, foi utilizado a técnica PCA nos mesmos conjuntos de dados, as taxas de acerto média de classificação com TDAR e com WT foram de $91,5 \pm 4,9\%$ e $89,8 \pm 4,4\%$, respectivamente.

Pesquisas mais recentes também procuram apresentar soluções de sistemas robustos de classificação (NILSSON; HÅKANSSON; ORTIZ-CATALAN, 2017; VIDOVIC *et al.*, 2016). Os pesquisadores (NILSSON; HÅKANSSON; ORTIZ-CATALAN, 2017) apresentaram algoritmos de estimação de complexidade de classificação (CCEAs), os quais tem como objetivo melhorar a seleção de características, prever o desempenho do reconhecimento de padrões e informar sobre a aquisição de sinal considerado degradado. As características utilizadas para realizar a previsão do reconhecimento de padrões e informar sobre a degradação

nos mesmos baseiam-se na Distância de Mahalanobis, Distância de Bhattacharyya, Distância de Hellinger, Divergência de Kullback-Leibler e uma versão modificada da Distância de Mahalanobis.

Em um detalhamento da pesquisa de (NILSSON; HÅKANSSON; ORTIZ-CATALAN, 2017), três classificadores foram comparados quanto à taxa de acerto da classificação: LDA, RNA e SVM. A avaliação da performance quanto à taxa de acerto média obtida com o CCEAs foi realizada com duas bases de dados distintas. A primeira com 20 sujeitos, quatro eletrodos, e 11 movimentos analisados (mão aberta e fechada, flexão e extensão do punho, pronação e supinação, aperto lateral, aperto fino, concordar ou polegar para cima, ponteiro ou extensão do índice e repouso). A segunda base de dados possui 17 sujeitos, oito eletrodos e 27 movimentos (mão aberta e fechada, flexão e extensão do punho, pronação e supinação, e todas as combinações possíveis destes 6 movimentos). A segmentação utilizada foi janelas deslizantes de 200 ms com incremento de 50 ms. As características extraídas foram MAV, desvio padrão, VAR, WL, RMS, *zero-crossing*, *slope sign changes*, PWR, *difference absolute mean*, *max fractal length*, *fractal dimension Higuchi*, *fractal dimension*, *cardinality*, *rough entropy*, *frequency WL*, *mean frequency* e *median frequency*. O algoritmo utilizando SVM obteve melhor resultado de taxa de acerto média utilizando a distância modificada de Mahalanobis de 83% para a primeira base e 94% para segunda base. O algoritmo com LDA também atingiu o melhor resultado utilizando a distância modificada de Mahalanobis de 93% e 92% com cada base respectivamente. Por sua vez, o algoritmo com RNA alcançou 96% e 98% para cada base respectivamente, utilizando a Distância de Bhattacharyya.

Em (VIDOVIC *et al.*, 2016), é apresentado um método de adaptação supervisionado com classificador LDA, baseado na adaptação do treinamento do classificador a partir de conjuntos de calibração diferentes. Esta calibração incorpora aspectos relevantes do sinal e requer um minuto de gravação dos dados. A avaliação desta metodologia supervisionada ocorreu para sete sujeitos não amputados e dois sujeitos amputados, através da aquisição de oito canais de sEMG equidistantes ao redor do antebraço dos sujeitos. A segmentação ocorreu por janelas deslizantes de 250 ms com sobreposição de 50 ms, extraindo a característica de *logarithm of the signal variance*. Foram analisados diversos aspectos quanto a repetibilidade do experimento em classificações *off-line* e quanto a classificação *on-line*. Na análise de dados *off-line*, a taxa média de classificação permaneceu acima de 92% em cinco dias, enquanto diminuiu para 75% sem o processo de adaptação. Na análise *on-line*, o desempenho aumentou em 25% em comparação com um teste sem adaptação.

A maioria dos sistemas com métodos de recuperação da classificação elencados anteriormente necessitam de retreinamento do classificador (CENE; FAVIEIRO; BALBINOT, 2015; HUANG *et al.*, 2010; ZHANG; HUANG, 2015). O princípio destes sistemas é a identificação do sinal contaminado e a correspondente ação para correção de diferentes maneiras (CENE; FAVIEIRO; BALBINOT, 2015; FRASER *et al.*, 2014; MCCOOL *et al.*, 2014; ZHANG; HUANG, 2015).

O estudo de (FRASER *et al.*, 2014) analisou a inserção e a detecção de contaminação por sinais com uma SVM de uma classe, a qual foi empregada com sucesso para detectar uma variedade de contaminação em sinais de sEMG com diferentes níveis de SNR. No respectivo trabalho, a SVM foi treinada apenas com sinais não degradados, chamados de sinais íntegros ou não contaminados, e testada com sinais artificialmente contaminados. A análise dos resultados apresentou que uma SVM de uma classe pode ser empregada com sucesso para detectar uma variedade de contaminantes em sinais de sEMG.

Há também os estudos de (FRASER *et al.*, 2014; MCCOOL *et al.*, 2014) que identificaram especificamente qual contaminante está presente no sinal, porém apresentaram apenas a detecção, sem ação corretiva para a classificação após a ocorrência da degradação do sinal. Como exemplo, o sistema de análise da qualidade do sinal em conjunto com o retreinamento do classificador, o qual remove o canal contaminado, apresentado por (ZHANG; HUANG, 2015).

O estudo de (ZHANG; HUANG, 2015) possui uma abordagem de simulação de contaminação, testando para contaminantes de artefatos de contato, deslocamento de eletrodos e ruído de linha para diferentes níveis de SNR. Os autores na pesquisa se concentraram principalmente na redução do tempo de retreinamento do classificador após a detecção do seu módulo sensor de detecção. O pior caso de contaminação com três canais apresentou uma diminuição na taxa de acerto média na classificação de até 15%.

3.3.1.1 *Principal Component Analysis (PCA)*

A análise de componentes principais (*Principal Component Analysis - PCA*) é um método normalmente utilizado para reduzir a complexidade e as dimensões dos vetores de características (ISAKOVIC; MILJKOVIC; POPOVIC, 2014; MIRANDA DE SÁ *et al.*, 2015; SRINIVASA *et al.*, 2013; TSAI; LUH; LIN, 2015). Assim, a PCA tem sido extensivamente utilizada para traduzir os dados originais dos sinais de sEMG em componentes MUAP de baixa dimensão com um nível reduzido de redundância (NAIK *et al.*, 2016). A PCA é uma abordagem não paramétrica simples, mas eficiente em fornecer uma descrição estatística de um dado

complexo, revelando as estruturas ocultas e suprimindo o ruído. Normalmente, é escolhida devido a sua simplicidade conceitual e capacidade de ser facilmente implementada (MIRANDA DE SÁ *et al.*, 2015; NAIK *et al.*, 2016).

A PCA é uma transformação linear ortogonal é aplicada a dados multivariados projetando-os em um novo conjunto de variáveis denominadas de componentes principais (PCs). Os PCs podem ser considerados como um conjunto de direções espaciais, nas quais os dados são projetados para garantir a máxima variação. Os autovetores da matriz de dispersão são os PCs, que são ortogonais. Os PCs são classificados em ordem decrescente, de acordo com seus autovalores. O autovalor representa o relacionamento mais significativo entre as dimensões dos dados originais, de acordo com a variância destes. Assim, os PCs são não correlacionados e ordenados para que os primeiros retenham a maior parte da variação presente das variáveis originais. Em geral, os dados originais podem ser bem representados com apenas alguns dos primeiros PCs (ISAKOVIC; MILJKOVIC; POPOVIC, 2014; NAIK *et al.*, 2016; TSAI; LUH; LIN, 2015).

No artigo de (ISAKOVIC; MILJKOVIC; POPOVIC, 2014), foram utilizados os dados do primeiro banco de dados da base NinaPro, abordando o uso da PCA para extrair características do sinal de sEMG. A proposta é baseada na existência de uma variabilidade significativa na variância representada por cada PC entre diferentes movimentos e sujeitos. Em (GOKGOZ; SUBASI, 2014), uma abordagem diferente também é apresentada para aumentar a taxa de acerto média de classificação, onde a PCA é utilizada para a redução de ruído antes da classificação do sinal de sEMG. O método foi testado em conjunto com os classificadores k-NN, RNA e SVM, e atingiu no máximo 92,55% de taxa de acerto na classificação com o método de redução de ruído e o classificador SVM, em comparação com 57% apenas com o classificador SVM. Portanto, PCA é uma técnica versátil para diversas aplicações, incluindo a redução de redundâncias nos dados de entrada de classificadores.

3.3.1.2 Sistemas Multiusuários

Sistemas multiusuários, também conhecidos como sistemas com interface independente do usuário, são sistemas onde um novo usuário não necessita realizar o procedimento de treinamento do sistema para a sua utilização (GUO *et al.*, 2015b; KHUSHABA, 2014; MATSUBARA; MORIMOTO, 2013; TOMMASI *et al.*, 2013). Sistemas com este tipo de abordagem surgiram devido aos principais fatores que inibem a aplicação de próteses mioelétricas, como a variação do posicionamento dos eletrodos a cada uso, a variação de como

o usuário executa o mesmo movimento, os longos procedimentos de posicionamento dos eletrodos, assim como os treinamentos intensivos para a utilização de uma prótese mioelétrica, entre outros fatores (DEIJS *et al.*, 2016; ENGDahl *et al.*, 2015; JIANG *et al.*, 2012). É também evidenciado que há diferenças nos sinais de sEMG também entre os movimentos dos dois braços de um mesmo usuário. No entanto, existem estudos que buscaram utilizar a associação de características de sinais de sEMG para o membro amputado a partir de movimentos executados pelo membro intacto (KHUSHABA, 2014; NIELSEN *et al.*, 2011; SEBELIUS *et al.*, 2006).

Como exemplo, no estudo de (GUO *et al.*, 2015c), os autores apresentaram uma braçadeira *wireless* com oito canais de captura de sinais de sEMG. Neste trabalho utilizaram um classificador LDA com a finalidade de desenvolver uma interface mioelétrica multiusuário, capaz de ser utilizada sem treinamento por novos usuários. A estratégia adotada foi classificar os movimentos de um grupo de usuários com propriedades fisiológicas similares, e então, testar sem qualquer calibração adicional com um novo usuário que é fisiologicamente similar ao grupo de treinamento. O estudo baseou-se no pressuposto de que os sinais de sEMG de diferentes sujeitos apresentam características semelhantes, desde que pertençam a um grupo com propriedades fisiológicas ou características antropométricas semelhantes. Os sinais de sEMG foram segmentados em janelas de 300 ms com sobreposição de 200 ms. O método obteve 84,9% de taxa de acerto média na classificação com a característica TDAR para sete movimentos de sete sujeitos não amputados.

No estudo de (TOMMASI *et al.*, 2013), foi proposto um método de aprendizagem adaptativa com base em um classificador SVM com função *kernel* Gaussiana. A adaptação baseou-se na adição de um fator de ponderação para avaliar a verdadeira importância de cada fonte de dado com relação ao movimento alvo. A resposta do método para este fator foi avaliada empiricamente. Os autores utilizaram dois bancos de dados no estudo, um com sinais de sEMG e sinais de força obtidos de 10 indivíduos não amputados e outro com os dados da base 2 do NinaPro de 27 indivíduos não amputados, durante a execução de 52 movimentos da mão. A taxa de acerto média no estudo foi menor que 65%.

Em (MATSUBARA; MORIMOTO, 2013), foi proposto uma abordagem chamada de modelagem bilinear de sinais de sEMG, a qual é composta de dois fatores lineares: um fator dependente do usuário (chamado de estilo) e um fator dependente do movimento (chamado de conteúdo). Após decompor o sinal nestes dois fatores, os fatores dependentes do movimento foram utilizados como características independentes do usuário. Neste estudo, utilizaram quatro canais de sEMG posicionados no antebraço para identificar cinco movimentos da mão e 11

voluntários não amputados do sexo masculino participaram dos ensaios. Nos testes, após o método extrair as características independentes de novos usuários e classificá-las, estas foram adicionadas ao modelo de classificação. Para efeito de comparação neste estudo, foram considerados mais dois métodos de referência chamados no estudo de SVM simples, onde não há nenhum tipo de retreino da SVM, e da SVM adaptada, onde foram adquiridos os dados do usuário de teste de um movimento específico para adicionar nos dados de treinamento da SVM. A segmentação de janelas deslizantes foi utilizada, com o tamanho da janela de 128 amostras e deslocamento de 25 amostras. Para cada janela de cada canal foi extraída a característica RMS. A taxa de acerto média da SVM normalmente utilizada foi de 54%, com a SVM adaptada resultou em 58%, e com o modelo Bilinear foi aproximadamente 73%. No entanto, as dimensões das variáveis estilo e conteúdo foram experimentalmente selecionadas em diversas tentativas empíricas.

Em outro estudo de (KHUSHABA, 2014), foi realizada uma abordagem com *Canonical Correlation Analysis* (CCA), onde foi adotado um modelo para toda a população, formado a partir de todos os indivíduos de treinamento. A CCA utilizou duas abordagens de um mesmo conjunto de dados, dois conjuntos de características extraídos dos sinais de sEMG das duas mãos dos usuários. Entretanto, para novos usuários, foi necessária a calibração do sistema antes que a interface fosse usada. O processo de calibração gerou um novo conjunto de características que foram adicionadas ao modelo. O método proposto foi validado em um conjunto de oito indivíduos não amputados, durante 10 movimentos bilaterais com quatro eletrodos em cada antebraço. Utilizando um classificador SVM com a adição do modelo CCA, as duas melhores taxas de acerto médias foram de $88,8 \pm 7,3\%$ treinando e testando com a mão direita e de $88,3 \pm 6,7\%$ treinando com as duas mãos e testando com a direita.

Em (PARK; LEE, 2016), foi proposto um método de classificação com base em *Convolutional Neural Network* (CNN) para seis movimentos de mão de 27 indivíduos não amputados da base 2 do NinaPro utilizando uma técnica de aprendizagem profunda de características dos sinais de sEMG. A aprendizagem profunda de características foi descrita como uma técnica para aprender a transformação dos dados de entrada para representar de forma mais efetiva a entrada dos métodos de classificação. Para comparação foi utilizado um classificador SVM com função *kernel* RBF. Foram utilizadas duas abordagens para a validação: sem adaptação, onde o classificador treinado foi aplicado ao novo usuário, e com adaptação, onde ocorre a reciclagem do classificador utilizando alguns dados do novo usuário. O método proposto no estudo com adaptação obteve a melhor taxa de acerto média de 90,0%, e sem

adaptação de 60,0%. O classificador SVM com adaptação obteve a segunda melhor taxa de acerto média de 80,0% e sem adaptação de aproximadamente 45,0%.

3.3.2 Sensores Virtuais

O desempenho do sensor virtual depende da seleção adequada do modelo para a correta representação do sinal do sensor de interesse (BHUYAN, 2013), no caso deste trabalho, o sinal de sEMG. O sinal de sEMG é uma série temporal estocástica baseada nas propriedades fisiológicas dos músculos e na forma de contração muscular (ZIVANOVIC, 2014). O mesmo comportamento estocástico que fornece o sinal de sEMG dificulta sua estimação. Modelos *Time-Varying Autoregressive Moving Average* (TVARMA) têm sido utilizados para melhorar modelos de sinais não estacionários, onde os parâmetros autorregressivos variam instantaneamente com o tempo (CHEE-MING TING *et al.*, 2011), podendo ser usado para monitorar rapidamente as variáveis no tempo (ZOU; CHON, 2004). Em paralelo, o modelo de filtro de Kalman tem sido amplamente utilizado em outras áreas do conhecimento (CHEE-MING TING *et al.*, 2011; CHO; GAO; MOAN, 2018; HALIM; CHENG; SU, 2011; KAUTZ; ESKOFIER, 2015; LEBREUX; DÉSILETS; LACROIX, 2012; VAN DE WALLE; NAETS; DESMET, 2018), onde é considerado uma ferramenta de processamento de sinal extremamente eficiente e flexível, e também é empregado em outras aplicações de sensores virtuais (TABBACHE *et al.*, 2013). Assim, tanto um modelo TVARMA como um modelo de filtro de Kalman podem ser adequados para a utilização em sensores virtuais na área de biosinais.

3.3.2.1 *Time-Varying Autoregressive Moving Average* (TVARMA)

Processos aleatórios não estacionários proporcionam um enquadramento matemático apropriado para sinais provenientes da fala, de áudio, processamento de imagem, engenharia biomédica, monitoramento de máquinas, e muitas outras áreas de aplicação (JACHAN *et al.*, 2007). Os sinais de EEG e de EMG são tipicamente usados para detectar e classificar diferentes informações de interesse para diversas aplicações. Processos autorregressivos têm sido usados na modelagem de diferentes sinais biológicos, a maior parte das abordagens analisa características neurológicas ou musculares. As excitações são eventos de curta duração no domínio do tempo, mas também exibem flutuações entre bandas de potência ao longo do espectro de frequência. Modelos *Time-Varying Autoregressive* (TVAR) oferecem uma solução promissora para identificar estas flutuações (CHAPARRO-VARGAS *et al.*, 2015).

O modelo *Autoregressive* (AR) em séries de tempo tem sido usado em estudos de sinais de sEMG, a fim de desenvolver uma técnica de estimação de sinais intramuscular de EMG, através de sinais de superfície, para eliminar a interferência dos músculos adjacentes (REAZ; HUSSAIN; MOHD-YASIN, 2006). Em (GRAUPE; CLINE, 1975), foi empregado pela primeira vez o modelo *Autoregressive Moving Average* (ARMA) para representar sinais de EMG. Os resultados empíricos mostraram que o sinal de sEMG pode ser considerado estacionário ao longo de curtos intervalos de tempo (DE LUCA, 2006b; REAZ; HUSSAIN; MOHD-YASIN, 2006). Em (KHEZRI; JAHED, 2011), afirmaram que a utilização do modelo AR do sinal apresenta várias vantagens, pois os coeficientes AR não se modificam severamente com as mudanças de posição do eletrodo de superfície.

Nos anos seguintes, foram testados outros modelos AR, como *Autoregressive Integrated Moving Average* (ARIMA) e TVARMA (REAZ; HUSSAIN; MOHD-YASIN, 2006). Os autores de (BERNOTAS *et al.*, 1986) empregaram um modelo similar a TVARMA para a modelagem de sinais de sEMG, chamado *Discrete-Time Deterministic Autoregressive Moving Average*. Em 1992, (KIRYU; SAITOH; ISHIOKA, 1992) consideraram que o custo computacional do modelo ARIMA era alto, e a determinação da ordem do modelo complexa e, por vezes, difícil. Em (DVOŘÁK; HOLDEN, 1991), foi estabelecido que *Autoregressive* (AR), ARMA e filtro de Kalman são os métodos paramétricos mais usados na análise do sinal de EEG (RECHY-RAMIREZ; HU, 2011).

O modelo ARMA é geralmente classificado em três etapas. A primeira, identificação do modelo, tem como objetivo determinar as ordens do modelo ARMA. A segunda, a estimativa do modelo, foi concebida para estimar os coeficientes ARMA. A última fase é de verificação, diagnóstico, para examinar o ajuste do modelo estimado (CHOI, 1992). O modelo ARMA pode melhorar o modelo AR porque utiliza menos parâmetros para o modelo e tem sido usado em situações em que o sinal é corrompido por ruído branco (BEGG; LAI; PALANISWAMI, 2008).

Os modelos AR e ARMA são capazes de representar adequadamente vários tipos de sinais naturais, como a fala e sinais de EEG. Para melhorar modelos de sinais não estacionários, modelos TVAR e TVARMA têm sido utilizados, onde os parâmetros AR variam com o tempo (CHEE-MING TING *et al.*, 2011). No estudo de (ZOU; CHON, 2004), os autores ressaltaram as vantagens da utilização de uma abordagem como a do modelo TVARMA, o qual oferece maior resolução no espectro de tempo-frequência do que as outras abordagens, e pode ser usado para monitorar rapidamente as variáveis no tempo.

Os modelos TVARMA generalizam os bem sucedidos modelos invariantes no tempo ARMA para processos não estacionários (JACHAN *et al.*, 2007). O modelo TVARMA (P, Q)

do sinal no instante n do tempo é representado pela seguinte Equação (28) (ZOU; CHON, 2004):

$$y(n) = \sum_{i=1}^P a(i, n)y(n-i) + \sum_{j=0}^Q b(j, n)u(n-j) + e(n) \quad (28)$$

onde $a(i, n)$ e $b(j, n)$ são coeficientes *time-varying* AR e *moving average* (MA), respectivamente, a serem determinados. Assim, usam-se parâmetros diferentes de a e de b a cada amostra de tempo n . Os índices P e Q são as máximas ordens dos modelos AR e MA, respectivamente. O termo $e(n)$ é o erro de predição ou erro de observação e $y(n)$ é o dado observado do sinal na amostra n do tempo. A $u(n)$ sendo uma entrada exógena, torna o sistema mais suscetível a resposta aos distúrbios iniciais do processo.

Os modelos TVAR e TVMA são casos especiais do TVARMA, quando $Q = 0$ e $P = 0$, respectivamente (CHEE-MING TING *et al.*, 2011). Pode-se utilizar a seguinte notação:

$$\theta_n = (a(1, n) \dots a(P, n), b(1, n) \dots b(Q, n))^T \quad (29)$$

$$\varphi_n = (y(n-1) \dots y(n-P), u(n-1) \dots u(n-Q))^T \quad (30)$$

Sendo assim, o modelo TVARMA pode ser escrito como na Equação (31):

$$y(n) = \varphi_n^T \theta_n + e(n) \quad (31)$$

Assim, fica fácil visualizar um modelo de observação linear com o vetor de regressão e o erro de observação (TARVAINEN *et al.*, 2004). Para definição das variáveis do modelo, é possível impor uma função de base $f(n, m)$ de ordem finita para as funções de parâmetros $a(i, n)$ e $b(j, n)$ (JACHAN *et al.*, 2007; ZOU; CHON, 2004):

$$a(i, n) = \sum_{m=0}^V \alpha(i, m)f(n, m) \quad (32)$$

$$b(j, n) = \sum_{m=0}^V \beta(j, m)f(n, m) \quad (33)$$

$$n = 0, 1, 2, \dots, N-1 \quad (34)$$

onde $f(n, m)$ com $m = 0, 1, 2, \dots, V$ é a função de base que necessita ser selecionada adequadamente ao modelo. As funções de parâmetros $\alpha(i, m)$ e $\beta(j, m)$ representam a

expansão dos parâmetros com V , sendo este o máximo número de sequências de base (ZOU; CHON, 2004).

No estudo de (CHAPARRO-VARGAS *et al.*, 2015), uma abordagem computacional foi realizada para detectar de forma espontânea o despertar do sono com sinais de sEMG da contração da mandíbula e da *tibialis* com quatro canais de EEG. A extração de características foi realizada pelo método TVARMA e com filtragem de partículas recursivas. Um sistema *fuzzy* foi usado para a classificação. O modelo TVARMA utilizado foi capaz de lidar com mudanças abruptas e sutis dos biosinais de entrada. Para determinar os coeficientes do modelo, foi desenvolvido um filtro de partículas recursivas. As ordens ideais de P e de Q encontradas no estudo foram 8 e 2, respectivamente.

Em (CHAPARRO-VARGAS *et al.*, 2014), foi abordado a detecção e caracterização dos períodos iniciais do sono. O processamento de gravação de polissonografia envolveu também a extração de características com o método TVARMA e a filtragem de partículas recursivas. O conjunto de recursos envolveu o cálculo de bandas de sinais de EEG, a amplitude média do eletro-oculograma e sinais de sEMG. Foi utilizado um classificador para detectar o despertar e as fases do sono. O desempenho no melhor caso foi de 93,1% de taxa de acerto e erro de 6,8%. A taxa de acerto média obtida foi de $75,82 \pm 14,49$ % com erro de $24,17 \pm 14,49$ %.

Em uma abordagem utilizando modelo AR para o controle de uma prótese de mão de controle dos cinco dedos por sinais de sEMG (ZHAO *et al.*, 2006), foi apresentado um classificador que combina uma rede neural com o modelo AR e WT para discriminar os padrões de sEMG. O classificador identificou com êxito os movimentos de flexão e de extensão do polegar, do dedo indicador e do dedo médio, medindo com três eletrodos posicionados no *flexor digitorum profundus*, *flexor pollicis longus* e *extensor digitorum*. Os autores concluíram, através dos resultados experimentais para um sujeito não amputado, que o classificador tem um grande potencial de aplicação devido à rapidez de processamento na aprendizagem do modelo e devido a sua alta taxa de acerto. O modelo AR apresentou melhor capacidade de reconhecimento dos movimentos com taxa de acerto média de 85,0% em comparação com a Transformada *Wavelet*.

3.3.2.2 Filtro de Kalman

O filtro de Kalman é conhecido por ser um estimador ótimo para sistemas lineares, sendo considerado um modelo promissor no sensoriamento virtual com uma expressiva abrangência na utilização (FAGIANO; NOVARA, 2013; TABBACHE *et al.*, 2013;

TORRENT-FONTBONA, 2018; VAN DE WALLE; NAETS; DESMET, 2018). O filtro de Kalman é um estimador recursivo usado para inferir parâmetros de interesse a partir de observações indiretas, imprecisas e incertas. Basicamente, a predição é baseada em dois passos, onde o primeiro prevê o estado de um passo à frente $x(n + 1)$ (o valor dos parâmetros de interesse) e o segundo atualiza a previsão dada uma nova observação do estado $y(n)$ (novas medições dos parâmetros) (TORRENT-FONTBONA, 2018), conforme expresso na Equação (35) e Equação (36):

$$x(n) = Ax(n - 1) + Bu(n - 1) + w(n - 1) \quad (35)$$

$$y(n) = Cx(n) + v(n) \quad (36)$$

onde, $u(n)$ é a entrada do sistema, $w(n)$ é o ruído branco do processo, $v(n)$ é o ruído branco de observação, a matriz A é referente ao modelo de transição de estado, a matriz B é referente ao modelo de entrada de controle e a matriz C é referente ao modelo de observação.

Os ruídos aleatórios $w(n)$ e $v(n)$ representam os ruídos de processo e de observação respectivamente. Assume-se que são independentes entre si e com distribuição de probabilidade normal, onde:

$$w(n) \sim N(0, Q) \quad (37)$$

$$v(n) \sim N(0, R) \quad (38)$$

onde, Q é a covariância do ruído do processo e R é a covariância do ruído de observação.

O filtro de Kalman é um estimador recursivo e é mais frequentemente conceituado através de duas fases distintas: predição e correção. O equacionamento da fase de predição pode ser representado por:

$$\hat{x}^-(n) = A\hat{x}(n - 1) + Bu(n - 1) \quad (39)$$

$$P^-(n) = AP(n - 1)A^T + Q \quad (40)$$

onde, $\hat{x}^-(n)$ é a estimativa atualizada prevista (*a priori*), $\hat{x}(n - 1)$ é a estimativa atualizada da amostra de tempo $n - 1$ e $P^-(n)$ é a covariância de erro prevista (*a priori*).

O equacionamento da fase de correção pode ser representado por:

$$M(n) = \frac{P^-(n)C^T}{CP^-(n)C^T + R} \quad (41)$$

$$\hat{x}(n) = \hat{x}^-(n) + M(n)[y(n) - C\hat{x}^-(n)] \quad (42)$$

$$P(n) = [I - M(n)C]P^-(n) \quad (43)$$

Além disso, para determinar as covariâncias, são utilizadas as seguintes equações:

$$Q = E(w(n)w(n)^T) \quad (44)$$

$$R = E(v(n)v(n)^T) \quad (45)$$

Em (VAN DE WALLE; NAETS; DESMET, 2018), foi apresentada uma metodologia de microfone virtual, empregando uma metodologia com filtro de Kalman para um modelo vibro-acústico. O objetivo deste estudo era obter medições virtuais para um campo sonoro completo em uma região de interesse a partir de um pequeno número de medições de microfone. O modelo de filtro de Kalman estimou o estado completo de um campo, proporcionando medições virtuais em qualquer ponto desejado deste. A validação das estimativas virtuais foi quantificada usando a dispersão do erro. Os autores concluíram que a dispersão do erro diminuiu aproximadamente 92 % usando apenas a medição de um microfone, permitindo estimar o campo de som completo do modelo vibro-acústico.

Em um outro estudo, foi apresentado por (TABBACHE *et al.*, 2013) um método para aumentar a confiabilidade do controle de falhas da motorização de um veículo elétrico em relação às falhas do sensor de velocidade. Neste trabalho, foi avaliado a utilização em conjunto de dois sensores virtuais utilizando filtro de Kalman estendido e um observador de Luenberger, com base em um sensor de velocidade. A abordagem apresentada do sensor, utilizando o modelo de Kalman em baixas velocidades e o modelo de Luenberger em altas, foi relatada eficiente no sentido de fornecer uma configuração simples para obter as estimativas de respostas de velocidade e torque nas simulações realizadas.

No estudo de (FAGIANO; NOVARA, 2013), foi apresentado um modelo de estimação e aplicado a um sistema não-linear massa-mola-amortecedor. Uma combinação das técnicas *linear Moving Horizon Estimation* e sensor virtual foram aplicadas através de um algoritmo de filtragem, baseado em filtro de Kalman a partir de dados medidos e sem utilizar um modelo do sistema avaliado. Os resultados foram demonstrados por simulações corrompendo os dados em um número finito com ruído com uma SNR de 10% na média. Os autores atingiram seus objetivos, considerando que os resultados simulados obtiveram mínimo erro de estimativa no pior caso avaliado.

Há também abordagens, onde se busca a estimativa de medidas com as informações fornecidas pelo sistema, como no estudo de (TORRENT-FONTBONA, 2018). Nesta pesquisa, uma nova metodologia baseada no filtro de Kalman, para ajustar automaticamente a insulina

basal para *diabetes mellitus* tipo 1, foi apresentada. Mesmo com a complexidade do metabolismo da glicose, que geralmente leva a níveis glicêmicos longe do ideal, este artigo apresentou um sistema adaptativo e personalizado de recomendação de insulina, e relatou convergir rapidamente para a dose ideal sem o risco de instabilidade.

4 SISTEMA DE CLASSIFICAÇÃO TOLERANTE A FALHAS

A metodologia implementada do sistema de classificação de movimentos tolerante a falhas tem como base fundamental a utilização de sensores virtuais para substituir sinais de sEMG com contaminantes ou interferências conhecidas pelo sistema. Dois componentes foram essenciais para a execução deste sistema: um modelo de sensor virtual dinâmico e adaptativo e uma análise para detecção da presença de contaminação do sinal.

O sistema experimental completo abrangeu a aquisição de uma base de dados própria do laboratório, sua leitura posterior e a leitura de uma base de dados pública, assim como o pré-processamento dos dados até a classificação dos sinais de sEMG. As etapas da metodologia proposta podem ser divididas nas seguintes sete etapas: carregamento das bases de dados, simulação do sinal contaminado, pré-processamento, análise e detecção tolerante a falhas, sensor virtual, extração de características e classificação. Um fluxograma da metodologia experimental pode ser visualizado na Figura 6. Este fluxograma inicia com a aquisição da base de dados própria do IEE, posteriormente ocorre o carregamento das bases de dados de sinais de sEMG do grupo de pesquisa NinaPro e do Laboratório IEE. Antes da etapa seguinte, onde os dados gravados são pré-processados (filtragem, ajuste de *offset*, retificação e normalização), normalmente utilizada, ocorre a inserção artificial de contaminantes no sinal. Esta etapa prévia de simulação do sinal contaminado insere ao sinal contaminantes modelados em dezesseis estudos de casos de eletrodos contaminados, realizando estes estudos para cada um dos cinco tipos de contaminação avaliados. Os dezesseis estudos de casos avaliaram a degradação individual de cada canal e de subconjuntos de canais.

Os pesquisadores de (ORTIZ-CATALAN *et al.*, 2015; VUJAKLIJA *et al.*, 2017, 2018) relataram diferenças na taxa de acerto da classificação com o processamento com dados pré-gravados e o desempenho de sistemas *on-line*. O processamento de sinal com dados pré-gravados geralmente apresenta uma maior taxa de acerto na classificação dos movimentos. Conseqüentemente, uma premissa das etapas seguintes, quanto a detecção tolerante a falhas, a geração dos modelos de sensores virtuais e a extração de características, foi aproximar estas ao processamento *on-line*, ou seja, processar estes passos de maneira sequencial para cada uma das janelas deslizantes dos doze canais. Entretanto, após viabilizar o modelo do sensor virtual, não é excluída a necessidade de otimização do algoritmo e ajustes para o processamento *on-line* de uma prótese mioelétrica.

Assim, ainda na Figura 6, a simulação de degradação do sinal foi realizada para os cinco contaminantes mais comuns em sinais de sEMG: artefatos de movimento, saturação,

deslocamentos de eletrodos, interferência de linha de energia e interferência de sinal de ECG. Após, tanto para os sinais contaminados como para o sinal íntegro, as características das janelas deslizantes são extraídas. Os sinais contaminados são analisados pelo Sensor Tolerante de Detecção de Falha, o qual é composto por uma SVM de duas classes que classificam as características dos canais como sinal íntegro (adequado para classificação) ou sinal degradado (presença de contaminantes conhecidos). Quando ocorre a detecção de falha ou identificação de contaminação dos canais, o Sensor Virtual realiza os modelos do sinal de sEMG necessários a partir dos dados temporais com degradação da janela segmentada. Dois modelos de sinais de sEMG são realizados, TVARMA e TVK. Após este processo, as características são novamente extraídas e enviadas para a Classificação dos Movimentos. As características extraídas em cada estudo de caso são salvas separadamente para posterior classificação. Estas características foram selecionadas com base nos resultados obtidos em outros estudos (MOURA; FAVIEIRO; BALBINOT, 2016; PHINYOMARK *et al.*, 2013; TOSIN *et al.*, 2017) e são MAV, RMS, WL, *Power* (PWR), *Maximum Fractal Length* (MFL), Frequência Mediana (FMD), *Skewness* (SKW) e *Mean Peak Frequency* (MPF). Além disso, tanto o sinal com degradação como o sinal íntegro são enviados para classificação dos movimentos para fins de comparação com a classificação do sinal com o uso do Sensor Virtual substituindo o sinal com degradação.

A etapa de classificação presente na Figura 6 foi realizada posteriormente com os dados salvos das características dos cinco ruídos para os 16 estudos de caso de degradação. Sete maneiras distintas de classificação dos movimentos foram avaliadas para obter uma comparação adequada entre as opções clássica ou tradicional, com retreinamento e utilizando o sistema proposto, possibilitando avaliar a contribuição deste trabalho. Para finalizar, a etapa de Conjuntos Experimentais tem como objetivo abranger as possíveis variações para movimentos, tipo de ruído de degradação, sujeitos, modelos adaptativos do sensor virtual, estudos de casos de degradação, que podem interferir no resultado da principal contribuição do sistema de classificação proposto. Além da análise estatística dos resultados, possibilitando a avaliação da relevância dos resultados.

Cada um dos procedimentos do fluxograma na Figura 6 foi detalhado nas próximas subseções. Para cada seção, foi descrita a metodologia proposta e resultados parciais obtidos no transcorrer deste trabalho.

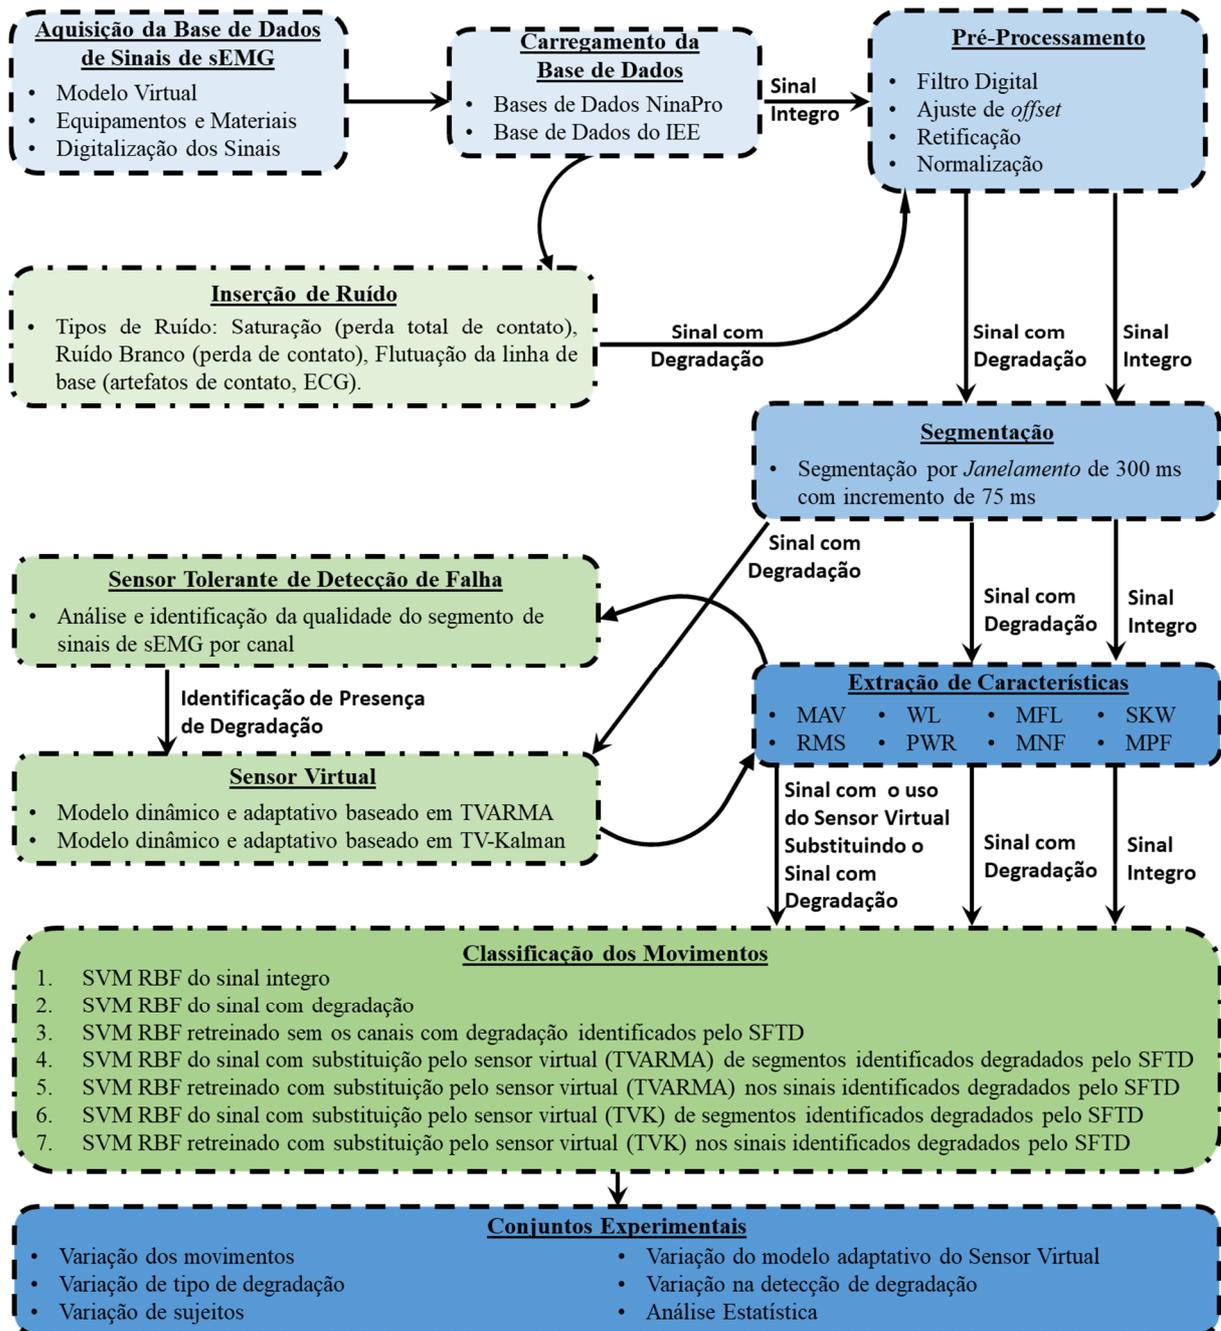


Figura 6 Diagrama de blocos da metodologia experimental.

4.1 AQUISIÇÃO DA BASE DE SINAIS DE SEMG

Uma base de dados com muitos voluntários e que incluísse um número considerável entre eles de amputados raramente é encontrada, conforme demonstrado no capítulo anterior nas diversas pesquisas citadas. Assim, buscou-se a utilização de uma base de dados pública. O projeto NinaPro (*Non-Invasive Adaptive Prosthetics*) disponibiliza publicamente uma base de dados sobre o controle de próteses mioelétricas da mão, com dados adquiridos de sinais de sEMG e outras informações como a cinemática dos movimentos e intensidade de força. Além

de eletrodos de superfície, é utilizada uma luva de aquisição de dados (CyberGlove II), acelerômetros (integrados em cada um dos eletrodos de superfície), e um sensor de força especialmente desenvolvido para o experimento (*Finger-Force Linear Sensor*) (ATZORI *et al.*, 2015). Foram disponibilizadas sete bases de dados até o momento, entre as quais, apenas a base de dados 2, 3 e 7 possuem as mesmas características, movimentos e número de repetições analisados. As bases de dados 4 e 5 utilizam sistemas de aquisição diferentes e a base de dados 6 analisa a repetibilidade durante cinco dias e ainda com movimentos diferentes das outras bases.

A comparação entre as possíveis bases de dados semelhantes pode ser observada na Tabela 8. Foram detalhadas as seguintes características: sujeitos não amputados, sujeitos amputados, número de eletrodos de sEMG utilizados, número total de movimentos analisados, número de repetições de cada movimento e grupo de movimentos realizados.

Tabela 8 Resumo das bases de dados NinaPro

	Bases de Dados NinaPro			
	Base 1	Base 2	Base 3	Base 7
Sujeitos não amputados	27	40	0	20
Sujeitos com amputação transradial	0	0	11	2
Número de eletrodos de sEMG	10	12	12	12
Número total de movimentos analisados	53	50	50	41
Número de repetições de cada movimento	10	6	6	6
Grupo de movimentos realizados	A, B, C, D	B, C, D, E	B, C, D, E	B, C, D

Legenda: O Grupo A de movimentos corresponde a movimentos básicos dos dedos (flexões e extensões); o Grupo B é relacionado a configurações isométricas e isotônicas (“posturas das mãos”); o Grupo C são os movimentos básicos do punho; o Grupo D são movimentos de agarramento e funcionais; o Grupo E são movimentos de dedos únicos e múltiplos para medição de padrão de força.

Os movimentos selecionados para análise neste trabalho foram os movimentos de mão e pulso dos grupos B e C, totalizando 18 movimentos, apresentados na Figura 7. A seleção de movimentos priorizou obter o maior número de amputados possíveis e utilizar apenas sinais de sEMG, não envolver os movimentos relacionados a análise de força aplicada com a luva ou sensor desenvolvido. A Figura 7 também detalha a nova subdivisão dos movimentos em quatro conjuntos semelhantes entre eles. Os movimentos são: (a) posição de repouso; (b) movimentos da mão; (c) movimentos rotacionais; e (d) movimentos de pulso. A descrição detalhada dos movimentos selecionados encontra-se na Tabela 9, com os movimentos divididos entre repouso, movimentos da mão e movimentos do pulso.

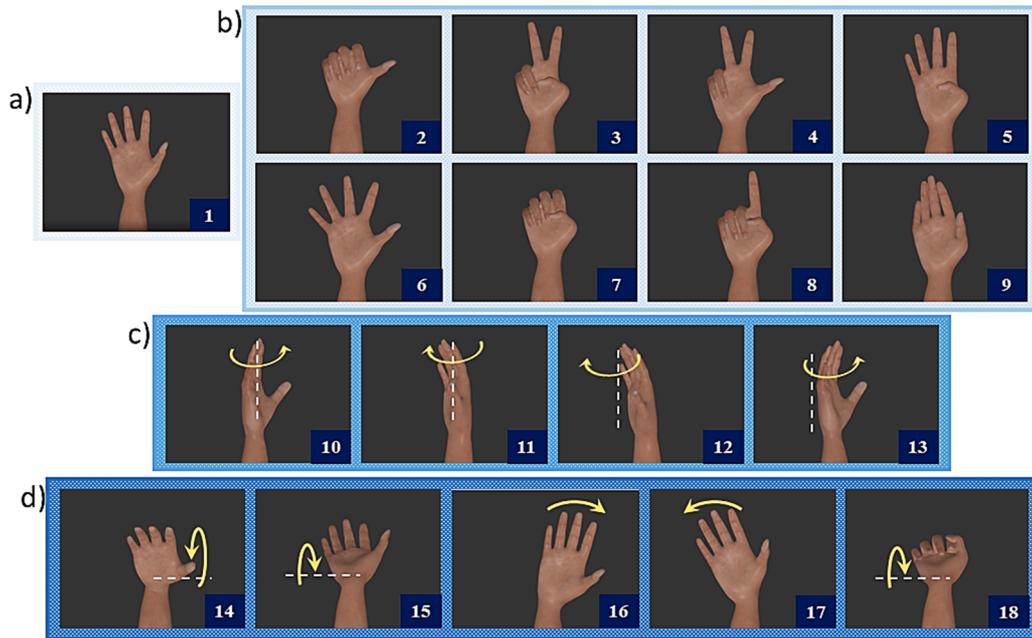


Figura 7 Grupos de movimentos analisados.

Os primeiros 20 sujeitos não amputados (idade entre 26 e 45 anos) da base de dados 2, 11 sujeitos amputados (idade entre 32 e 67 anos) da base de dados 3 e 2 sujeitos amputados (idade 28 e 54 anos) da base de dados 7 do NinaPro foram avaliados neste estudo. A limitação de voluntários é detalhada na seção 4.9 Projeto de Experimentos. As características clínicas dos sujeitos amputados analisados são fornecidas pela base de divulgação do NinaPro e estão listadas na Tabela 10.

Tabela 9 Descrição dos movimentos selecionados para o estudo

Tipo de Movimento	#	Descrição dos Movimentos
Repouso	1	Mão e punho relaxados em repouso
	2	Polegar para cima
Mão	3	Extensão do indicador e do dedo médio enquanto os outros são flexionados
	4	Flexão do dedo anular e mínimo enquanto estende a outros
	5	Flexão do polegar e extensão dos outros
	6	Abdução dos dedos
	7	Fechar a mão
	8	Apontar com o indicador
	9	Adução dos dedos
Rotacionais	10-11	Supinação e pronação de pulso (eixo de rotação através do dedo médio)
	12-13	Supinação e pronação de pulso (eixo de rotação através do dedo mínimo)
Punho	14-15	Flexão e extensão do punho
	16-17	Desvio radial e desvio ulnar do punho
	18	Extensão do punho com a mão fechada

Tabela 10 Características clínicas dos sujeitos amputados

Sujeito	Idade	Lateralidade Dominante	Mão Amputada	Motivo da Amputação	Antebraço Restante (%)	Quant. de Anos de Amputação
1	32	Destro	Direita	Acidente	50	13
2	35	Destro	Esquerda	Acidente	70	6
3	50	Destro	Direita	Acidente	30	5
4	34	Destro	Direita e Esquerda	Acidente	40	1
5	67	Canhoto	Esquerda	Acidente	90	1
6	32	Destro	Esquerda	Acidente	40	13
7	35	Destro	Direita	Acidente	0	7
8	33	Destro	Direita	Acidente	50	5
9	44	Destro	Direita	Acidente	90	14
10	59	Destro	Direita	Acidente	50	2
11	45	Destro	Direita	Câncer	90	5
12	28	Destro	Direita	Acidente	50	6
13	54	Destro	Direita	Câncer	50	18

Fonte: Adaptado de (ATZORI *et al.*, 2014).

Com o objetivo de padronizar a aquisição dos sinais mioelétricos para todos os voluntários, a metodologia de ensaios no Laboratório IEE baseou-se na metodologia definida no Projeto NinaPro com relação aos movimentos, repetições, utilização de estímulo visual, número de eletrodos e posicionamento dos mesmos (ATZORI *et al.*, 2012b). Portanto, cada seção de aquisição de sinais mioelétricos contém 102 movimentos, compostos de seis repetições em série de 17 movimentos distintos, intercalados por momentos de repouso. Todos os movimentos são executados a partir da posição de repouso, e voltam para a posição de repouso após a execução. Os intervalos de repouso minimizam possíveis fadigas dos músculos durante a seção. O movimento é realizado num período de 5 s, intercaladas com pausas de 3 s.

A Figura 8 mostra como é o fluxo da aquisição de sinais de sEMG. A aquisição da base de dados dos sinais de sEMG, tanto na base NinaPro como na desenvolvida no Laboratório IEE, envolve os seguintes itens: o modelo virtual, equipamentos e materiais utilizados, e a digitalização dos sinais de sEMG e o correspondente armazenamento dos dados em arquivos. O processo de aquisição inicia com o modelo virtual, o qual permite ao usuário visualizar e repetir cada movimento exibido na tela, permitindo que todos os voluntários executem os movimentos da melhor maneira possível simultaneamente com o vídeo. O voluntário é instruído a replicar os movimentos utilizando força moderada, porém é importante ressaltar que, até o presente momento, não existe controle do nível de força aplicada pelo voluntário e nenhum sistema de *feedback* para o usuário.

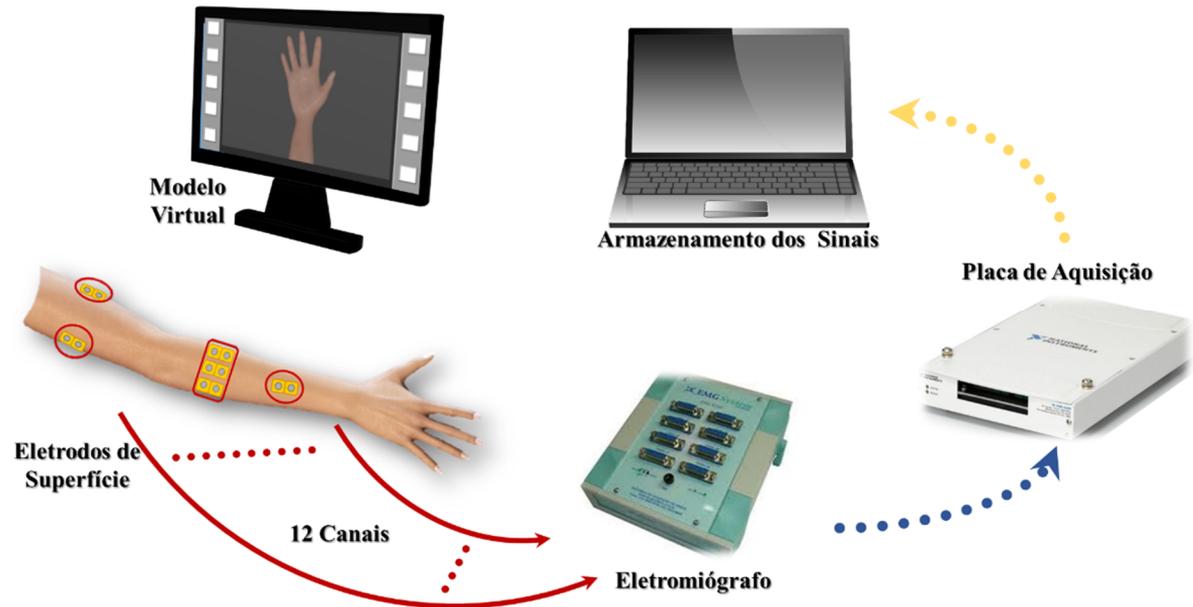


Figura 8 Fluxo da aquisição de dados de sinais de sEMG.

As animações dos 18 movimentos para a aquisição da base do Laboratório IEE foram criadas com auxílio do software *Blender 2.74* e *Makehuman 1.0.2*, depois foram editadas para formarem dois vídeos do modelo virtual, um para o treinamento dos usuários e outro a ser exibido na aquisição dos sinais. São realizadas apenas três repetições de cada movimento no vídeo de treinamento e seis repetições no vídeo para a aquisição. O vídeo de treinamento é utilizado na inicialização do procedimento para conferir os sinais de sEMG, se os eletrodos estão bem posicionados e aderidos a pele. O procedimento de conferência dos canais não impede que problemas, como eletrodos soltos, perda de contato ou uma realização inadequada do movimento ocorram durante os ensaios de aquisição.

O posicionamento dos eletrodos é o mais semelhante possível em todas as bases de dados, conforme detalhado na Figura 9 (a), exceto em dois amputados (6 e 7), nos quais não foi possível colocar dois pares de eletrodos (eletrodos do flexor e extensor dos dedos), devido a pequena porcentagem restante do antebraço. Ao total, são 12 pares de eletrodos divididos em oito pares de eletrodos uniformemente espaçados logo abaixo do cotovelo a uma distância fixa da articulação rádio-humeral, dois pares de eletrodos no flexor e extensor dos dedos e dois pares de eletrodos sobre o ponto de atividade principal do bíceps e do tríceps. O eletrodo de referência, na base do Laboratório IEE, foi colocado na parte central da testa de cada voluntário.

Na base de dados do Laboratório IEE, foram utilizados 12 pares de eletrodos de superfície em configuração diferencial da marca SOLIDOR, modelo MSGST-06. Conforme (GIJSBERTS *et al.*, 2014), as bases do NinaPro utilizaram 12 eletrodos ativos sem fio do sistema DelsysTM TrignoWireless System®, que consiste em uma base e múltiplos eletrodos

sEMG sem fios. As Figura 9 (b) e Figura 9 (c) apresentam o posicionamento dos dois tipos de eletrodos em um voluntário como exemplo.

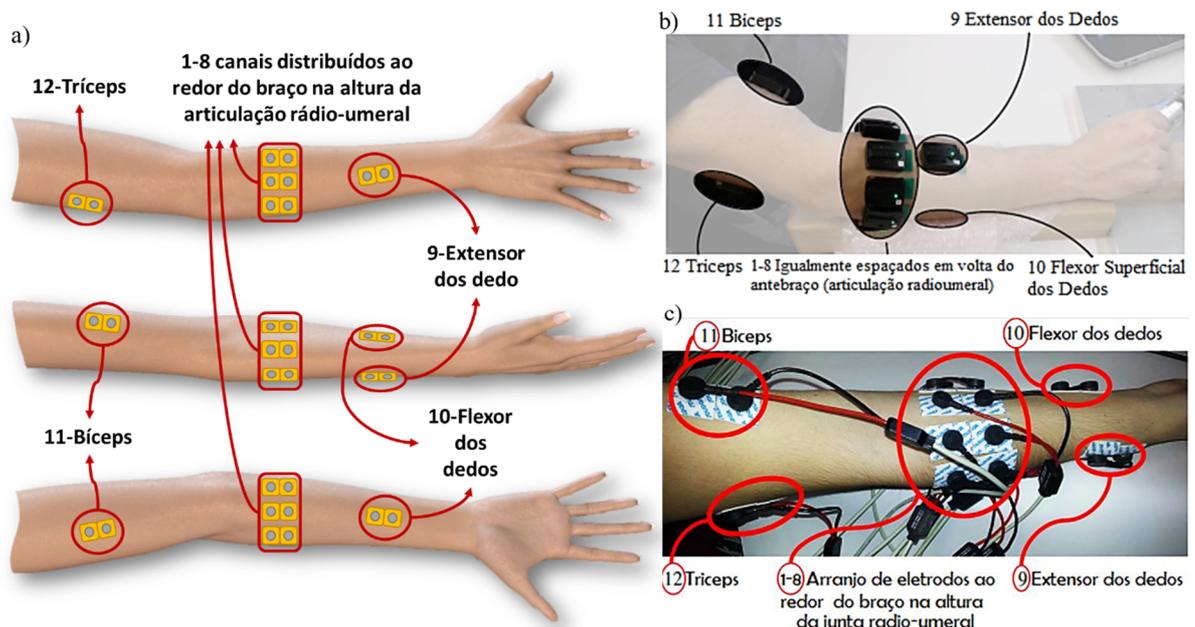


Figura 9 Posicionamentos dos 12 eletrodos: a) Posicionamento em um modelo de braço, b) Posicionamento em um voluntário das bases de dados NinaPro e c) Posicionamento em um voluntário da base de dados do Laboratório IEE.

Fonte: Adaptado de (CENE, 2016; GIJSBERTS *et al.*, 2014).

No Laboratório IEE, foram utilizados dois eletromiógrafos comerciais da EMG System do Brasil, modelo EMG 830 C, cada um com oito canais para a captação dos sinais de sEMG, mas apenas 12 foram utilizados: quatro canais com eletrodos posicionados em músculos específicos e oito canais para os eletrodos aleatoriamente distribuídos ao redor do braço. A frequência de interesse no sinal de sEMG é compreendida entre 20 e 500 Hz com amplitude de 0 a 10mV, por isso os eletromiógrafos comerciais utilizados possuem um filtro passa-banda analógico *Butterworth* de dois pólos, com banda de 20-500 Hz, amplificador com ganho geral de 2000 vezes, eletrodos de superfície com cabos blindados de ganho de 20 vezes e o ruído menor que 3 μ V RMS (EMG SYSTEM DO BRASIL, 2008).

Uma rotina de leitura e exibição dos vídeos de animações foi desenvolvida por um bolsista de Iniciação Científica do Laboratório IEE e aperfeiçoada no trabalho em (TOSIN, 2018) para apresentar de forma amigável ao usuário a sequência de movimentos a imitar, adquirindo os dados de maneira simultânea ao estímulo visual. Esta rotina foi elaborada no software *LabVIEW 2014* e utilizada para a base de dados do Laboratório IEE. Durante a aquisição dos sinais de sEMG, há um operador do sistema visualizando os sinais que estão sendo adquiridos em um computador portátil para analisar a qualidade dos mesmos.

Os sinais adquiridos, no Laboratório IEE, são digitalizados com a placa da *National Instruments*, modelo NI-USB-6289, com frequência de aquisição de 2 kHz, que tem 16 entradas analógicas diferenciais, 18 bits e taxa de amostragem máxima de 625 kHz (NATIONAL INSTRUMENTS, 2014). As bases de dados do NinaPro foram digitalizadas através da plataforma da *National Instruments*, modelo NI-DAQ PCMCIA 6024E, com uma taxa de 2 kHz, 12 bits e com um ruído menor que 750nV RMS (ATZORI *et al.*, 2014). O NinaPro disponibiliza os dados armazenados em um conjunto de arquivos do software *Matlab*, contendo as seguintes informações de interesse: *subject* (número de identificação do voluntário), *exercise* (número de identificação do movimento em cada amostra no tempo), *emg* (matriz de 12 colunas por cada amostra no tempo dos 12 canais de sEMG) e *stimulus* (identificação aproximada do movimento sendo executado em cada amostra no tempo) (ATZORI *et al.*, 2014).

Até o momento, a base de dados do Laboratório IEE possui 20 ensaios de sujeitos entre 20 a 35 anos, os quais foram utilizados para compor a base de dados do Laboratório IEE analisada neste trabalho. Os ensaios estão regulamentados pelo conselho de ética da UFRGS no projeto de código 11253312.8.0000.5347.

4.2 PRÉ-PROCESSAMENTO

Uma vez adquiridos, os sinais são processados pela etapa de pré-processamento, a qual foi desenvolvida através do software Matlab® R2016b (*The MathWorks*, EUA). A etapa tem por objetivo realizar a filtragem, remoção do *offset*, retificação e a normalização do sinal. Para minimizar o nível de ruído medido presente no sinal, como por exemplo, a base do Laboratório IEE tem ruído de aproximadamente de 800µV de amplitude, foi aplicado um filtro digital *Butterworth* passa-banda de ordem 20, sintonizado na faixa de 20 a 500 Hz e possui frequência de amostragem de 2 kS/s.

O sinal adquirido pode apresentar um *offset* (componente DC), deslocando o sinal da sua linha de base. Assim, a remoção do *offset* foi através da subtração do componente DC, calculado da média aritmética do sinal mioelétrico. A retificação de onda completa transforma o sinal de sEMG exclusivamente positivo através do cálculo do módulo do sinal de acordo com a Equação (46):

$$sEMG_{RETIFICADO}(t) = |sEMG(t)| \quad (46)$$

onde, o sinal $sEMG(t)$ é referente aos 12 canais já segmentados e $sEMG_{RETIFICADO}(t)$ é o equivalente do sinal retificado de sEMG.

A normalização do sinal é utilizada para escalonar os dados antes de usar na entrada do classificador, evitando que alguns atributos possuam valores muito altos ou muito discrepantes, que podem influenciar na classificação. Para o escalonamento dos dados é utilizada então, a normalização dos sinais de sEMG por canal, conforme a Equação (47):

$$sEMG_canal_{NORMALIZADO}(t) = \frac{sEMG_{canal_{RETIFICADO}}(t)}{\max(sEMG_{canal_{RETIFICADO}}(t))} \quad (47)$$

onde, $sEMG_canal_{RETIFICADO}(t)$ representa o sinal de sEMG por canal retificado anteriormente e $sEMG_canal_{NORMALIZADO}(t)$ é o respectivo sinal normalizado por canal na seção.

Por exemplo, na Figura 10, são apresentadas algumas etapas do pré-processamento do sinal. O sinal utilizado para exemplificar é referente ao canal posicionado sobre o bíceps durante a realização das seis repetições dos movimentos 2 e 3 do voluntário identificado com o número 68, pertencente a base de dados do IEE.

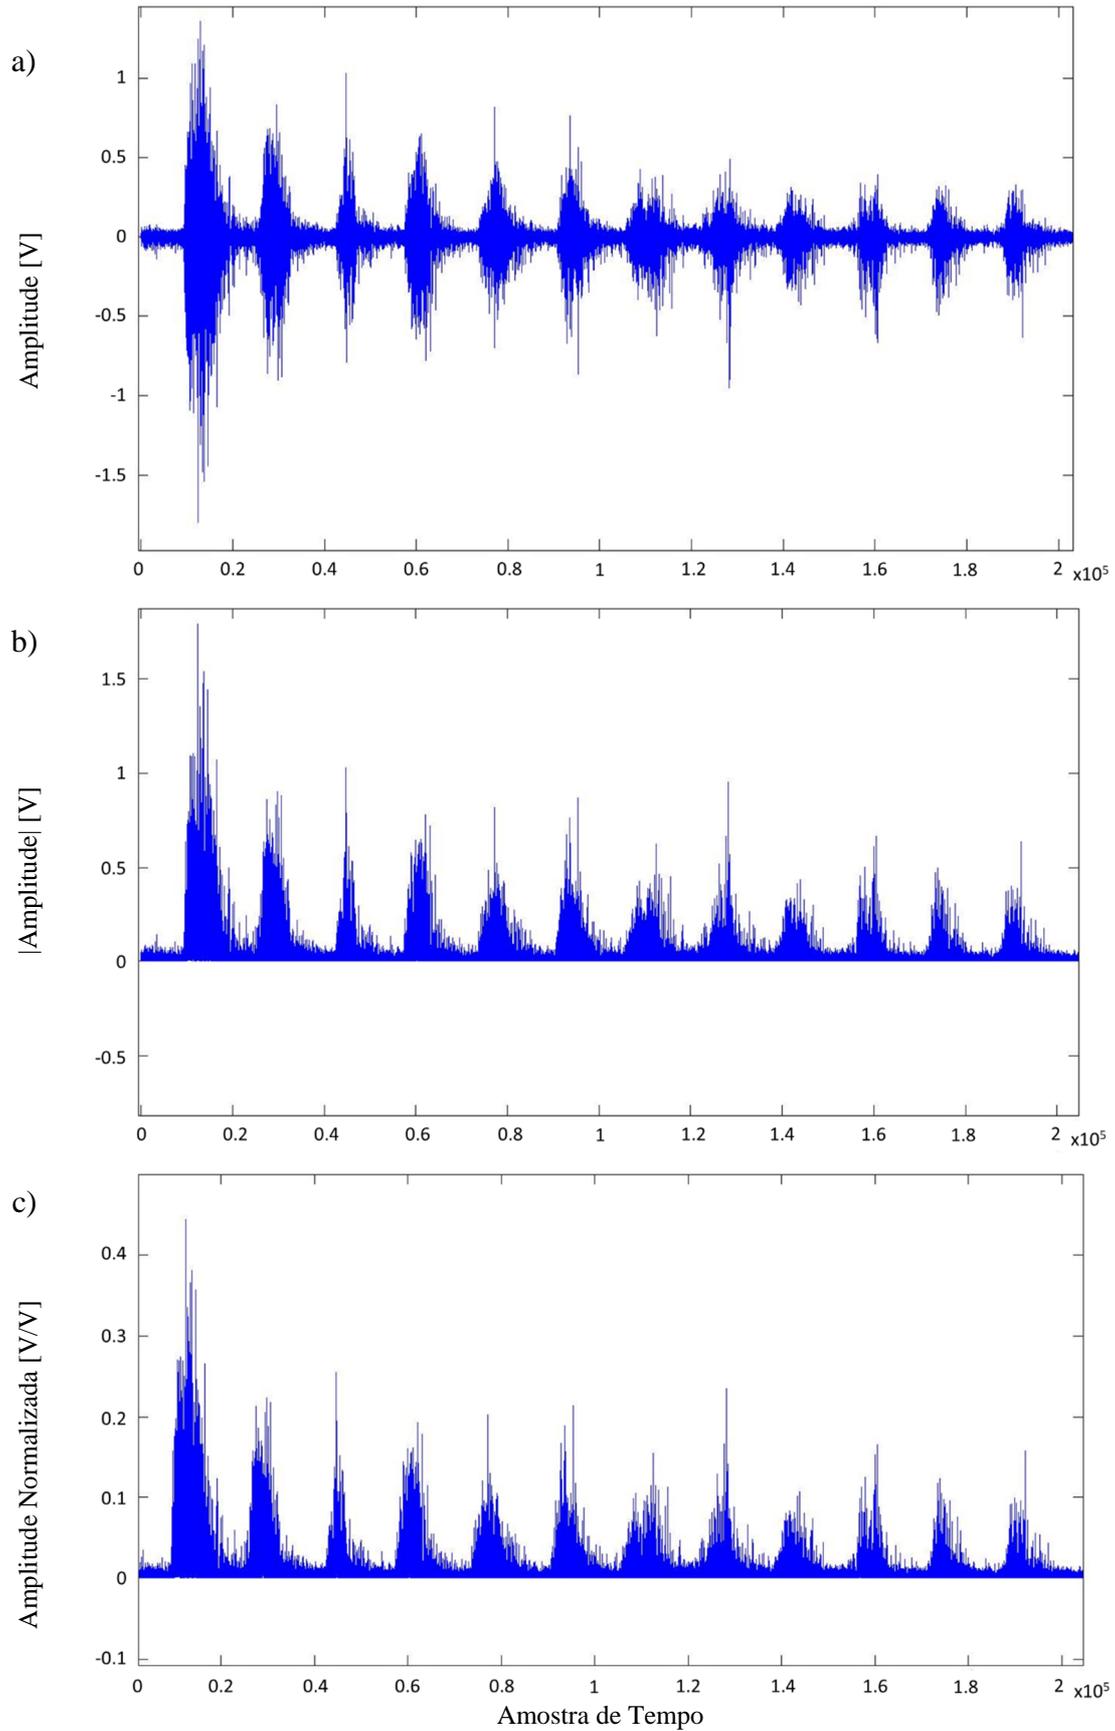


Figura 10 Etapas de pré-processamento: a) Sinal filtrado com ajuste de *offset*; b) Sinal retificado e c) Sinal normalizado.

Legenda: Taxa de aquisição de 2 kHz.

4.3 MÉTODO EMPREGADO DE SEGMENTAÇÃO

No trabalho preliminar de (MOURA; FAVIEIRO; BALBINOT, 2016), o *timestamp* foi definido em função da duração dos movimentos nos vídeos de animações para o estímulo visual. O vídeo de animações tem como finalidade auxiliar o sujeito na replicação do movimento de interesse. Assim, este *timestamp* foi utilizado para a segmentação dos sinais. Esta segmentação separa os períodos de movimentos e os intervalos de repouso durante a realização dos ensaios através dos tempos definidos no *timestamp*, ou seja, a segmentação separa as pausas de repouso de 3 s dos movimentos de duração de 5 s.

Por exemplo, na Figura 11, é apresentado a segmentação do sinal pela linha vermelha do canal referente ao bíceps na realização das seis repetições dos movimentos 2 e 3 do voluntário identificado com o número 68. Para a base de dados do Laboratório IEE, o *timestamp* foi definido apenas com base na temporalização dos vídeos de estímulo. Assim, o movimento é realizado num período de 5 s, com pausas de 3 s entre cada movimento, e não possui nenhum tipo de ajuste fino da localização dos picos dos sinais mioelétricos.

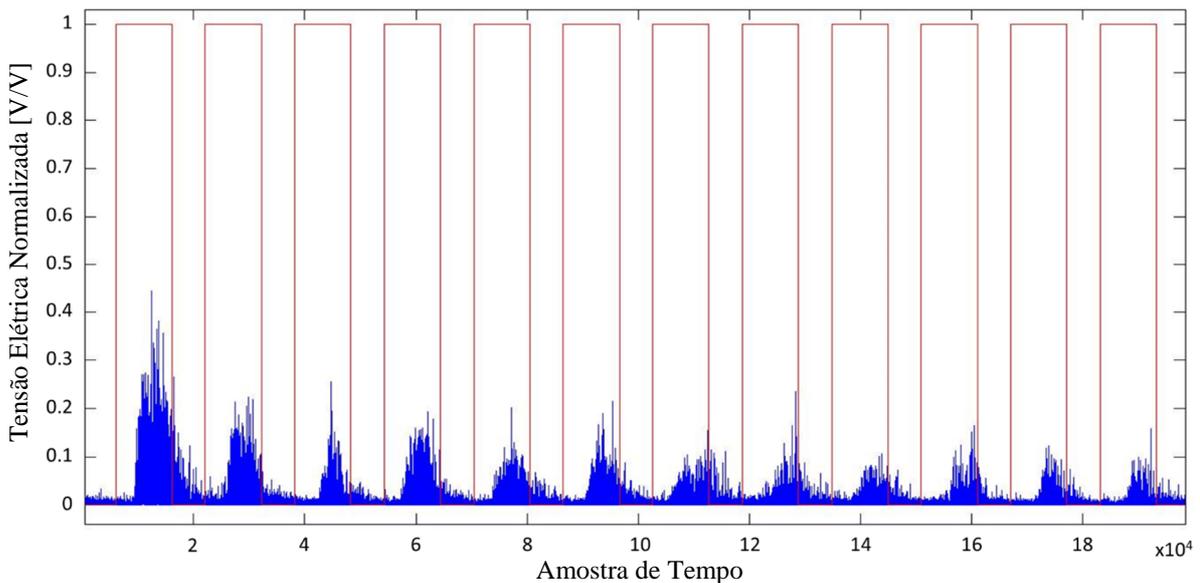


Figura 11 Exemplo de segmentação por *timestamp*.

Legenda: Taxa de aquisição de 2 kHz.

As bases de dados NinaPro fornece o *timestamp* específico de cada usuário. O nome do arquivo é *stimulus*, e, nestes casos, o *timestamp* vem com um tratamento por um algoritmo, chamado de *Generalized Likelihood Ratio*, o qual realinha os limites de cada movimento e ajusta os tempos de início e fim gerados anteriormente pelo *timestamp* dos vídeos de estímulo (ATZORI *et al.*, 2015). Processo semelhante foi realizado com a base de dados do Laboratório IEE, conforme descrito no trabalho de (TOSIN, 2018).

Em aplicações *on-line* com próteses mioelétricas, a classificação é frequentemente baseada nas características extraídas da segmentação por janelas deslizantes (RIILLO *et al.*, 2014). Nesse tipo de segmentação, a janela de análise desliza ao longo de incrementos, adicionando novos dados coletados e descartando os dados mais antigos (FARRELL, 2011). Estudos sugerem que o atraso da resposta da caracterização do movimento deve ser de aproximadamente 100 ms (RIILLO *et al.*, 2014) e o limite superior deve ser de aproximadamente 300 ms (ENGLEHART; HUDGINS, 2003; GIJSBERTS *et al.*, 2014; JIANG; LORRAIN; FARINA, 2014).

Alguns pesquisadores sugerem que as janelas deslizantes podem ter uma duração de até 256 ms, sendo que um registro mais longo que 300 ms pode exceder o atraso da resposta da caracterização do movimento (ENGLEHART; HUDGINS, 2003). Alguns estudos utilizaram janela de comprimento de 256 ms (LIU, 2015; XIE *et al.*, 2015), e de 300ms (DOSEN; SCHAEFFER; FARINA, 2014; GUO *et al.*, 2015c; RIILLO *et al.*, 2014). Ambos os comprimentos são utilizados frequentemente nas pesquisas citadas anteriormente e apresentam taxa de acerto média de classificação acima de 80%. A maior frequência de utilização de tamanhos de incremento apresentado nestas pesquisas foram de acima ou igual a 50% (LIU, 2015; XIE *et al.*, 2015) ou igual a 25% (GUO *et al.*, 2015c; RIILLO *et al.*, 2014) em relação ao tamanho da janela.

O estudo de (GIJSBERTS *et al.*, 2014) analisou a taxa de acerto média da classificação de acordo com a variação do tamanho da janela no banco de dados do NinaPro. O estudo utilizou janelas deslizantes de 100, 200 e 400 ms com um incremento de 10 ms para todas as janelas de análise e obteve a melhor taxa de acerto com um comprimento de janela de 400 ms. No entanto, os autores não analisaram se os efeitos da variação do comprimento da janela e da variação do incremento foram significativos em relação ao sujeito e quanto aos movimentos.

Alguns pesquisadores mostraram que a taxa de acerto da classificação aumenta quando o reconhecimento de padrões é realizado em tamanho de janelas maiores (ATZORI *et al.*, 2015; ENGLEHART; HUDGINS, 2003; FARRELL, 2011; PHINYOMARK *et al.*, 2013). No entanto, isto proporciona um aumento no tempo necessário para coletar e processar um conjunto de dados mais extenso (FARRELL, 2011). Além disso, uma quantidade mais significativa de dados pode resultar no amortecimento de amostras significativamente diferentes dependendo do percentual destas entre as amostras totais da janela, ou seja, pode reduzir as variações das características. É necessário um equilíbrio na escolha do tamanho ideal das janelas deslizantes, as quais dependem do classificador e das características extraídas para obter maiores taxas de acerto na classificação para os mesmos dados, e o atraso da resposta da caracterização. Todavia,

comparar resultados entre estudos com características, segmentos e classificadores diferentes não proporciona a mesma base de comparação para avaliar os resultados. Portanto, este estudo optou por utilizar o tamanho da janela deslizante de 300 ms com o incremento de 75 ms, comprimento mais comum nas recentes pesquisas.

4.4 CONTAMINAÇÃO DE SINAIS DE SEMG

Normalmente, considera-se que a qualidade do sinal de sEMG é adequada para processar e reconhecer os movimentos. A verificação da qualidade do sinal durante a aquisição normalmente é realizada por meio de inspeção visual e pela análise de impedância (NGEO; TAMEI; SHIBATA, 2014; TOWNSEND; GOUBRAN; KNOEFEL, 2012; XU *et al.*, 2013). Entretanto, os sistemas com métodos de recuperação no reconhecimento de movimentos após a ocorrências de alguma degradação do sinal necessitam normalmente do retreinamento do classificador (CENE; FAVIEIRO; BALBINOT, 2015; HUANG *et al.*, 2010; ZHANG; HUANG, 2015). O princípio destes sistemas foi a identificação da presença de sinal contaminado e alguma atuação para corrigir a redução da taxa de acerto ocorrida (CENE; FAVIEIRO; BALBINOT, 2015; FRASER *et al.*, 2014; MCCOOL *et al.*, 2014; ZHANG; HUANG, 2015). Nestas pesquisas, geralmente foi exigido conhecimento dos sinais de sEMG sob diferentes tipos de interferências ou contaminantes (FRASER *et al.*, 2014; MCCOOL *et al.*, 2014).

Alguns estudos procuram reconhecer qual contaminante está presente no sinal (MCCOOL *et al.*, 2014). No entanto, essa informação não é relevante se o foco é encontrar uma solução única para todos os casos de contaminação. O retreinamento do classificador, desconsiderando os canais contaminados, forneceu resultados significativos para manter a taxa de acerto média da classificação. No entanto, os estudos observaram que há um aumento de tempo de processamento para atualizar o classificador sem os canais com contaminação (CENE; FAVIEIRO; BALBINOT, 2015; ZHANG; HUANG, 2015).

Os contaminantes utilizados neste trabalho foram simulados pelo software Matlab® R2016b usando amostras de dados de sinais com contaminação simulados durante uma coleta de dados, forçando a ocorrência de degradação do sinal. Cada modelo de contaminação artificial, exceto pela interferência do sinal de ECG, foi desenvolvido de forma a reproduzir o correspondente sinal contaminado adquirido na coleta. Estes modelos foram realizados com base na análise no domínio do tempo e de frequência do sinal, replicando as características observadas no sinal adquirido com degradação e também considerando como foi realizado em

outros estudos de contaminação do sinal de sEMG (FRASER *et al.*, 2014; MCCOOL *et al.*, 2014).

A contaminação artificial simulada abrange todo o período do canal antes da aplicação da etapa de segmentação da janela, como apresentado graficamente na Figura 12. Após o sinal íntegro ser pré-processado, ocorre a inserção dos contaminantes da adição de cada modelo detalhado a seguir. O sinal com degradação passou por um segundo pré-processamento (Pré-Processamento 2) apenas com relação ao procedimento de retificação. É importante ressaltar que os modelos foram ajustados conforme a aquisição do sinal com contaminação forçada após serem pré-processados com filtro digital, ajuste de *offset* e normalização.

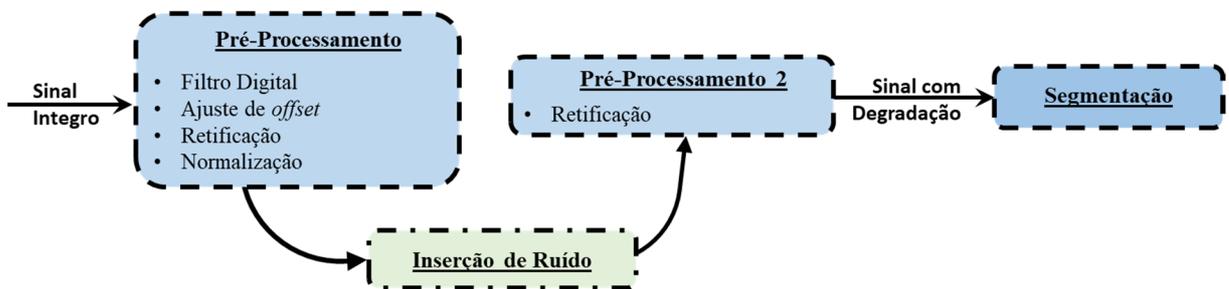


Figura 12 Fluxograma da contaminação artificial do sinal.

Os sinais de artefatos de movimento simulados para contaminar o sinal de sEMG foram modelos estimados baseados nos sinais adquiridos de acordo com os testes descritos em outros estudos (MCCOOL *et al.*, 2014; ZHANG; HUANG, 2015). O modelo de contaminação de artefatos de movimento $y_{MA}(t)$ representado na Equação (48) foi repetido ao longo de cada canal a ser contaminado sem interrupção de tempo entre os modelos:

$$y_{MA}(t) = 1500r \cdot t^2 \cdot e^{-140t} \sin(60.2\pi(t - 20)) \quad (48)$$

onde, o modelo se repete com um número aleatório r de 1 a 10 para cada amostra de tempo t [1,300], com SNR de 6 dB.

O deslocamento de eletrodo artificialmente contaminado foi gerado por *Added White Gaussian Noise* (AWGN) de 15 dB, conforme realizado nos trabalhos de (MCCOOL *et al.*, 2014; ZHANG; HUANG, 2015). O ruído branco gaussiano é um sinal aleatório com densidade espectral de potência constante e intensidade em diferentes frequências. O AWGN foi então adicionado ao sinal de sEMG em todo período do canal, exemplificando a sua definição pela Equação (49):

$$y_{DE}(t) = \sqrt{var} \cdot randn(t), \text{ para } var = 10^{-SNR/10} \quad (49)$$

onde, a variância var é definida através do SNR, no caso de 15 dB, e randn são números aleatórios normalmente distribuídos.

O contaminante de saturação foi implementado pela adição de sete ondas senoidais com uma frequência entre 200 e 240 Hz, conforme analisado na amostra do sinal de sEMG com ruído de saturação e baseado em outro estudo (FRASER *et al.*, 2014). O modelo de contaminação de saturação $y_S(t)$ representado na Equação (50) foi repetido ao longo de cada canal a ser contaminado:

$$y_S(t) = 12,6 \cdot \left(\frac{\sin(203.2\pi t)}{100} + \frac{3 \cdot \sin(210.2\pi t)}{200} + \frac{\sin(213.2\pi t)}{200} + \frac{4 \cdot \sin(220.2\pi t)}{5} + \frac{9 \cdot \sin(226.2\pi t)}{1000} + \frac{3 \cdot \sin(230.2\pi t)}{200} + \frac{4 \cdot \sin(236.2\pi t)}{500} \right) \quad (50)$$

onde, o modelo se repete para cada amostra de tempo t [1,2000], com SNR de 22 dB.

O modelo senoidal, que tem uma frequência de 60 Hz, seus harmônicos e uma amplitude de 0,4 V, foi adicionado aos sinais para simular a interferência da linha de energia. O modelo de contaminação de interferência da linha de energia $y_{IL}(t)$ é representado pela Equação (51):

$$y_{IL}(t) = \frac{1}{225} \cdot \left(\frac{8}{3} \sin(f \cdot 2\pi t) + 4 \sin(2f \cdot 2\pi t) + \frac{4}{3} \sin(3f \cdot 2\pi t) + 2 \sin(4f \cdot 2\pi t) + \sin(5f \cdot 2\pi t) + \frac{4}{3} \sin(6f \cdot 2\pi t) + \frac{4}{5} \sin(7f \cdot 2\pi t) \right) \quad (51)$$

onde, o modelo se repete para cada amostra de tempo t [1,2000] e f é a frequência de 60 Hz, com SNR de 5 dB.

A interferência artificial do ECG ocorreu com o banco de dados de ECG disponível no PhysioBank ATM da Physionet (<http://www.physionet.org>) com a mesma frequência de amostragem do sinal de sEMG. Como relatado anteriormente, a interferência do ECG não ocorre na posição do eletrodo neste trabalho e é por isso que a aquisição de ruído não é demonstrada. Entretanto, a detecção de interferência foi analisada para a aplicação de próteses mioelétricas e a interferência do ECG está presente em casos graves de amputação do membro superior esquerdo, dependendo de onde os eletrodos estão posicionados e se houve reinervação muscular direcionada. O sinal de ECG foi normalizado e adicionado ao sinal de sEMG com amplitude máxima estabelecida em 0,2 para os testes de detecção e SNR de 2 dB.

Na Figura 13, a comparação de cada inserção de contaminante no sinal de sEMG para o sujeito 1 em quatro repetições de movimento 7 pode ser visualizada. A amostra de sinal de sEMG sem contaminação em (a) na Figura 13 é artificialmente contaminada por Artefatos de movimento na primeira coluna em (b), por Saturação na primeira coluna em (c), por

Deslocamentos de eletrodo na primeira coluna em (d), por interferência da linha de energia na primeira coluna em (e) e por interferência do ECG na primeira coluna em (f). A segunda coluna em (b), (c), (d) e (e) são as amostras de sinal de sEMG com a aquisição de ruído.

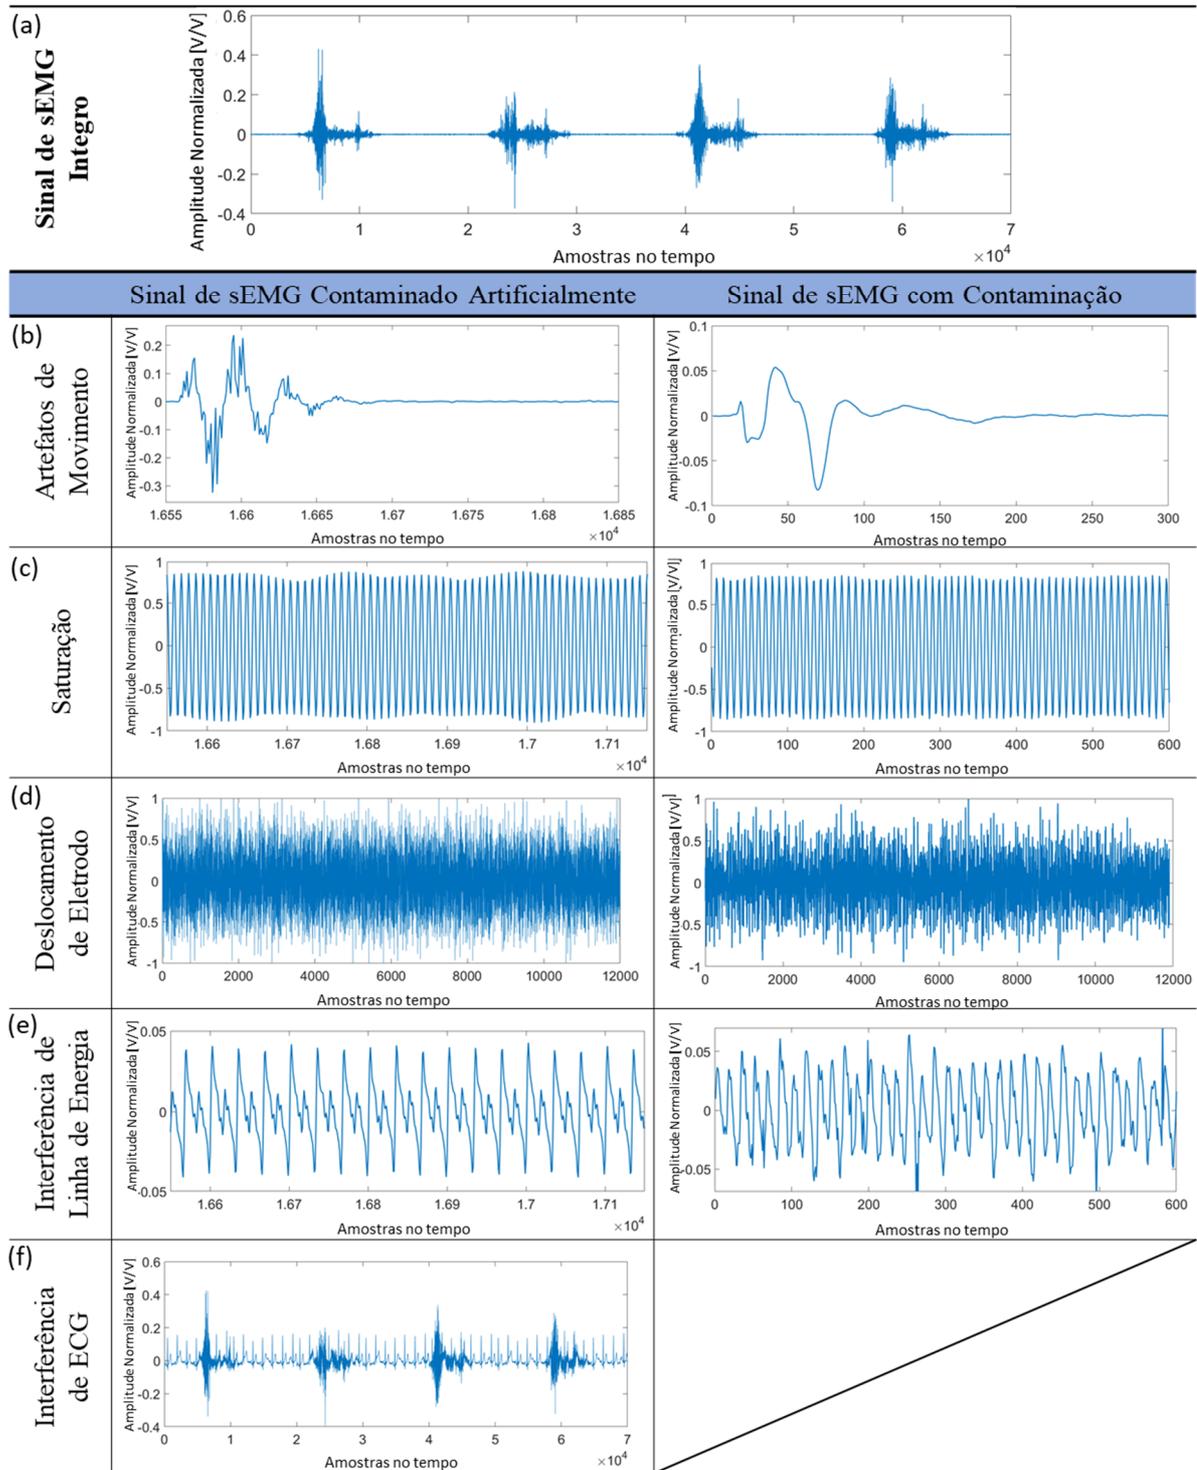


Figura 13 A comparação de cada inserção de contaminante no sinal de sEMG.

Fonte: Adaptado de (DE MOURA; BALBINOT, 2018b).

Diferentes casos de estudo para cada tipo de contaminante foram analisados para verificar a contribuição neste trabalho. São 16 casos de contaminação para cada tipo de contaminante, onde, em cada caso, os contaminantes foram inseridos em um canal ou uma combinação de canais. Os canais que foram contaminados em cada caso estão descritos na Tabela 11. A pesquisa de (CENE; BALBINOT, 2016) relacionou o impacto da combinação de canais na taxa de acerto média da classificação dos dados do NinaPro. Nesta mesma pesquisa, os sinais do bíceps e tríceps apresentaram influência positiva na taxa de acerto do reconhecimento dos movimentos. Com base neste estudo, as combinações de degradação de canais foram selecionadas para avaliar a influência de cada canal separadamente, dos conjuntos de canais por região do braço e por posicionamento dos eletrodos sob músculos específicos. Avaliando o método para as variações ocasionadas por cada canal na taxa de acerto média de classificação, como para o aumento no número de canais degradados, o impacto da falha de leitura por região do antebraço ou até mesmo avaliar o impacto pela degradação dos canais sob músculos específicos. É essencial relatar que este estudo não avaliou o efeito de variação do SNR e não realizou a contaminação do sinal íntegro com o ganho do sinal contaminante de forma aleatória.

Tabela 11 Canais contaminados em dezesseis casos para cada tipo de contaminante

Caso de Estudo	Canais Contaminados	Caso de Estudo (Cont.)	Canais Contaminados (Cont.)
1	O primeiro eletrodo de oito eletrodos uniformemente espaçados	9	O eletrodo sobre o <i>flexor digitorum</i>
2	O segundo eletrodo de oito eletrodos uniformemente espaçados	10	O eletrodo sobre o <i>extensor digitorum</i>
3	O terceiro eletrodo de oito eletrodos uniformemente espaçados	11	O eletrodo sobre o bíceps
4	O quarto eletrodo de oito eletrodos uniformemente espaçados	12	O eletrodo sobre o tríceps
5	O quinto eletrodo de oito eletrodos uniformemente espaçados	13	Os eletrodos sobre o <i>flexor digitorum</i> e o <i>extensor digitorum</i>
6	O sexto eletrodo de oito eletrodos uniformemente espaçados	14	Os eletrodos sobre o bíceps e o tríceps
7	O sétimo eletrodo de oito eletrodos uniformemente espaçados	15	Os eletrodos sobre o <i>flexor digitorum</i> , <i>extensor digitorum</i> , bíceps e tríceps
8	O oitavo eletrodo de oito eletrodos uniformemente espaçados	16	Os eletrodos sobre os oito eletrodos uniformemente espaçados

4.5 SENSOR DE DETECÇÃO TOLERANTE A FALHAS

O Sensor Detector Tolerante a Falhas (SFTD) proposto nesta tese, realiza análise de qualidade para sinais de sEMG usando uma SVM de duas classes, as quais representam a classe

de presença ou a classe de ausência de contaminantes no sinal da sEMG. A estrutura da SVM foi a mesma utilizada na classificação dos movimentos, porém com apenas duas classes e sem a utilização da técnica *k-fold*. O algoritmo da SVM é detalhado na seção 4.8 ETAPA DE CLASSIFICAÇÃO. A SVM utilizada no SFTD também usou a função *kernel* RBF. O valor de C (parâmetro de regularização) da função *kernel* foi ajustado em 70, através de uma busca com C de 1 a 100 da maior taxa de detecção média obtida testando com os próprios dados de treinamento.

A formação do SFTD é representada graficamente na Figura 14 (a) e o seu funcionamento posterior na Figura 14 (b). O treinamento para a formação do SFTD ocorre antecipadamente com sinais de sEMG selecionados de várias amostras de amplitudes diferentes de sinais considerados íntegros (sem contaminantes) e sua contaminação baseada em artefatos de movimento, saturação, deslocamentos de eletrodos, interferência na linha de energia e interferência do ECG. O mesmo SFTD treinado foi então usado para todos os sujeitos analisados. A partir das características extraídas dos sujeitos em cada janela deslizante, o SFTD envia as informações de identificação de presença de contaminantes e os sinais degradados para o sistema de ajustes da entrada do sensor virtual. O sensor virtual retorna os sinais modelados para os canais identificados contaminados. A seguir, os dados íntegros e modelados são enviados novamente para extração de características para a classificação dos movimentos.

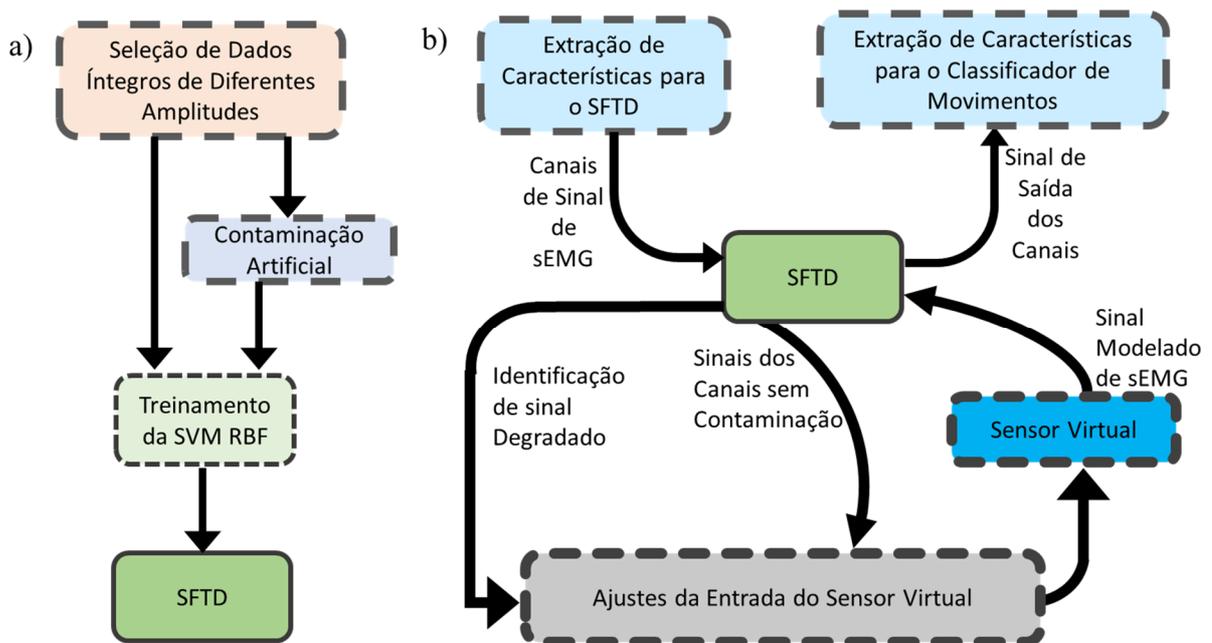


Figura 14 Fluxograma da a) formação do SFTD e do b) funcionamento em conjunto com o sensor virtual.

Os dados do primeiro sujeito dos bancos de dados NinaPro de indivíduos intactos e amputados foram utilizados para o treinamento SFTD. Todos os canais de ambos foram utilizados como padrão para o treinamento de sinais sem a presença de contaminação e os canais 2, 3 e 8 do sujeito 1 intacto foram contaminados artificialmente com os cinco ruídos estudados. O objetivo foi treinar o sensor de detecção para as diferentes variações de amplitude do sinal de sEMG para os diferentes movimentos tanto com padrão de um sujeito intacto como de um sujeito amputado. Além da presença destes contaminantes, o algoritmo faz a identificação em conjunto com os casos de ausência de sinal referentes aos sujeitos amputados 6 e 7 da base de dados do NinaPro.

A detecção das ocorrências de distúrbios no sinal de sEMG pode permitir a aplicação de técnicas para reduzir o impacto na taxa de acerto média da classificação de movimento. A detecção de contaminação pelo SFTD em sinais de sEMG foi baseada nos resultados descritos em (FRASER *et al.*, 2014). Nesta outra pesquisa, eles treinaram o SVM apenas com sinais íntegros e testados com sinais artificialmente contaminados com diferentes níveis de SNR. Seus resultados mostraram que uma SVM de uma classe pode ser empregada com sucesso para detectar uma variedade de contaminantes em sinais de sEMG. Diferentemente, o presente estudo buscou realizar o treinamento do sensor de detecção com sinais com contaminação sem variar o nível de SNR. Assim, este treinamento proporciona uma detecção mais favorável para o reconhecimento de contaminações já reconhecidas e treinadas.

A análise do STFD ocorre para cada janela deslizante dos 12 canais de eletrodos. O método desenvolvido de treinamento não compromete o processamento *on-line*. Após treinado, o SFTD foi desenvolvido para ser aplicado a qualquer sujeito sem nenhum tipo de ajuste ou calibração. No trabalho preliminar de (MOURA; RUSCHEL; BALBINOT, 2018), o SFTD detectou se ocorreu contaminação em mais de 70% do sinal nos últimos 3 s analisados. Esta configuração proporcionou uma limitação de resposta para a ativação do sensor virtual na geração dos modelos de sinais de sEMG, a qual não funcionaria para a presença de ruído com duração menor que 2,1 s.

Ainda no trabalho preliminar de (MOURA; RUSCHEL; BALBINOT, 2018), para cada janela analisada, foram extraídas as seguintes características para o STFD analisar: MAV, RMS, WL, PWR, MFL, FMD, SKW e *Fractal Dimension Higuchi* (FDH). Os resultados obtidos, como pode ser visto na Tabela 12, apresentaram a diferenciação na detecção dependendo do contaminante analisado. A detecção de contaminantes por interferência de ECG e interferência na linha de energia obteve taxas de acerto média no reconhecimento das

interferências significativamente menores que para os demais. Esta análise foi realizada para 10 sujeitos não amputados e 10 sujeitos amputados.

Tabela 12 Taxa de reconhecimento de contaminantes em pesquisa preliminar

Tipo de Contaminante	Taxa de Reconhecimento do SFTD	
	Amputados	Não Amputados
Interferencia de ECG	67,2 ± 25,7%	68,9 ± 25,1%
Interferencia de Linha de Energia	57,5 ± 28,5%	64,9 ± 27,5%
Artefatos de Movimento	96,8 ± 14,6%	99,9 ± 0,2%
Deslocamento de Eletrodos	97,8 ± 14,1%	100,0 ± 0,0%
Saturação	100,0 ± 0,0%	100,0 ± 0,0%

Fonte: Adaptado de (MOURA; RUSCHEL; BALBINOT, 2018).

Devido aos resultados nos estudos anteriores quanto à taxa de reconhecimento dos contaminantes de interferência de ECG e linha de energia, as características extraídas para a entrada do SFTD foram parcialmente atualizadas. Nesta alteração de característica, buscou-se estabelecer mais informações sobre a frequência do sinal de sEMG, trocando uma das características anteriores. Assim, as características selecionadas para extrair do sinal de sEMG de entrada ao SFTD são: MAV, RMS, WL, PWR, MFL, FMD, SKW e *Mean Peak Frequency* (MPF). As definições destas características se encontram descritas na Tabela 2.

Além da alteração das características relatadas, o SFTD foi ajustado para considerar uma janela degradada quando identificasse a ocorrência de contaminação em mais de 50% do sinal nos últimos 3 s analisados. Esta configuração diminui a limitação de resposta de ativação do sensor virtual. A limitação decorre da ausência do acionamento do sensor virtual para a ocorrência da presença de ruído com duração menor que 1,5 s.

4.6 EXTRAÇÃO DE CARACTERÍSTICAS

Primeiramente, foram escolhidas quatro características para serem extraídas dos 12 canais, RMS, curtose, SKW e FMD. A característica RMS foi escolhida por ser amplamente utilizada em diversos estudos na área de eletromiografia (ATZORI *et al.*, 2014; GUO *et al.*, 2015c; RIILLO *et al.*, 2014). As características curtose e SKW foram escolhidas por apresentarem resultados significativos em outros trabalhos de (BÚRIGO, 2014; CENE; FAVIEIRO; BALBINOT, 2015; DE PAULI NILSON; BALBINOT, 2014), assim como, a característica de FMD apresentou recentemente bons resultados no trabalho de (CENE, 2016).

No trabalho preliminar de (MOURA; FAVIEIRO; BALBINOT, 2016), a característica

curtose contribuiu negativamente na taxa de acerto média da classificação dos movimentos para os sujeitos. Assim, passou a não ser mais utilizada. Após observar as características mais utilizadas na literatura científica, as características MAV, RMS, WL, PWR e MFL foram analisadas e os resultados obtidos com esta combinação foram apresentados no trabalho preliminar de (DE MOURA; BALBINOT, 2018b).

A nova seleção de características foi definida buscando melhorar ainda mais a performance de classificação dos movimentos e auxiliar na detecção de padrões de qualidade para o SFTD. Com base nos resultados obtidos no trabalho de (TOSIN, 2018), o qual desenvolveu um algoritmo de seleção de características mais significativas para cada sujeito, foram analisadas diversas características tanto para o uso no SFTD como na classificação de movimentos. Após alterar as características de entrada do SFTD para MAV, RMS, WL, PWR, MFL, FMD, SKW e MPF, conforme relatado na seção anterior, analisou-se por amostragem empírica que duas características agregavam no reconhecimento de padrões de qualidade, porém prejudicavam a taxa média de acerto da classificação de movimentos. Então, estas duas características PWR e MPF não foram consideradas para os dados de entrada do classificador de movimentos.

O formato do arquivo salvo com os dados de características a ser utilizado para a entrada do classificador foi organizado de forma a obter uma matriz de 96 colunas e N amostras no tempo, conjuntos de 12 colunas correspondem às 12 entradas de sinais de sEMG respectivamente para a seguinte sequência de características: MAV, RMS, WL, PWR, MFL, FMD, SKW e MPF. Entretanto, as características no domínio frequência PWR e MPF só proporcionaram vantagens no uso com a SVM do SFTD, contribuindo negativamente na taxa de acerto média para a SVM da classificação dos movimentos. Cada arquivo tem em seu nome a identificação do sujeito, tipo de sinal os quais foram extraídas as características (sinal íntegro, com degradação, ou substituídos pelos modelos do sensor virtual), caso de estudo de forma numérica e a identificação do ruído analisado.

4.7 SENSOR VIRTUAL

O propósito do modelo de sensor virtual foi produzir um modelo de saída de sinal independente da aquisição física do sinal de interesse. O sensor virtual possui a lógica de operação simplificada representada na Figura 15 para cada canal avaliado. Quando a degradação é identificada no segmento do sinal pelo SFTD, o sensor virtual substitui este sinal de sEMG do canal, modelando um sinal de sEMG para substituí-lo. A modelagem do sinal de eletromiografia de superfície foi projetada combinando conceitos de multicanal e sua correlação

cruzada para substituir canais de sinais degradados. Essa abordagem foi chamada de correlação cruzada multicanal (*Multichannel Cross-Correlation - MCC*).

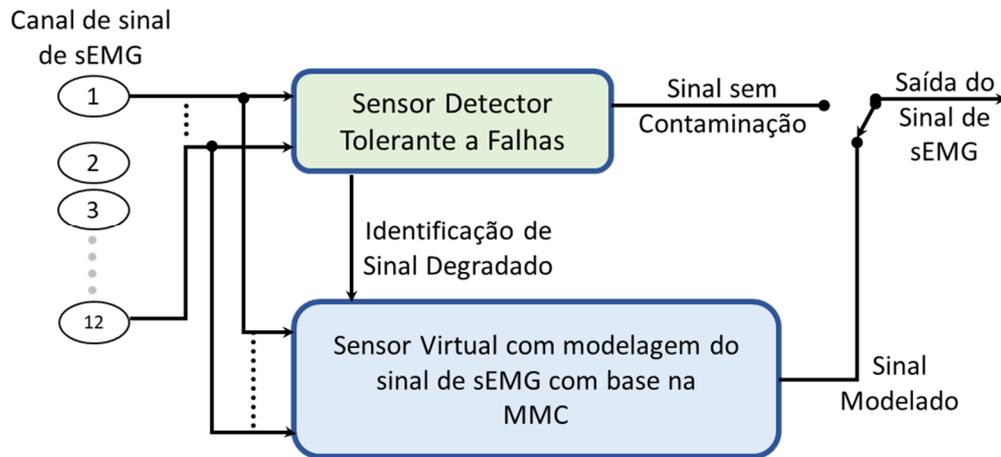


Figura 15 Fluxograma de funcionamento simplificado do sensor virtual.

A ideia inicial deste estudo foi concebida através de estudos de aplicações de análise de coeficientes de correlação cruzada envolvendo investigação do *crossstalk* entre diferentes canais de sEMG (MOGK; KEIR, 2003) e análise do grau de sincronização entre os registros de eletromiografia de superfície para dois músculos (FARINA; MERLETTI; ENOLA, 2004). Assim, assumiu-se a hipótese de que existe algum coeficiente de correlação cruzada entre as fibras musculares ou músculos do mesmo segmento mão-braço na execução do movimento. A lógica completa para a formação da entrada do sensor virtual segue como representado na Figura 16. Após a análise e identificação de contaminantes no sinal de sEMG pelo SFTD, as matrizes MCC no domínio do tempo e do domínio de frequência são ajustadas, desconsiderando primeiramente os canais identificados como degradados. Após o algoritmo baseado nos coeficientes da PCA reduz o número de canais restantes para apenas os mais correlacionados ao canal de interesse em uma nova MCC conjunta no domínio tempo e frequência. Esta MCC conjunta serve como a principal base para a modelagem de sinal de sEMG dos modelos TVARMA e TVK. As definições e detalhes quanto a formação da matriz MCC de entrada do sensor virtual são detalhados a seguir.

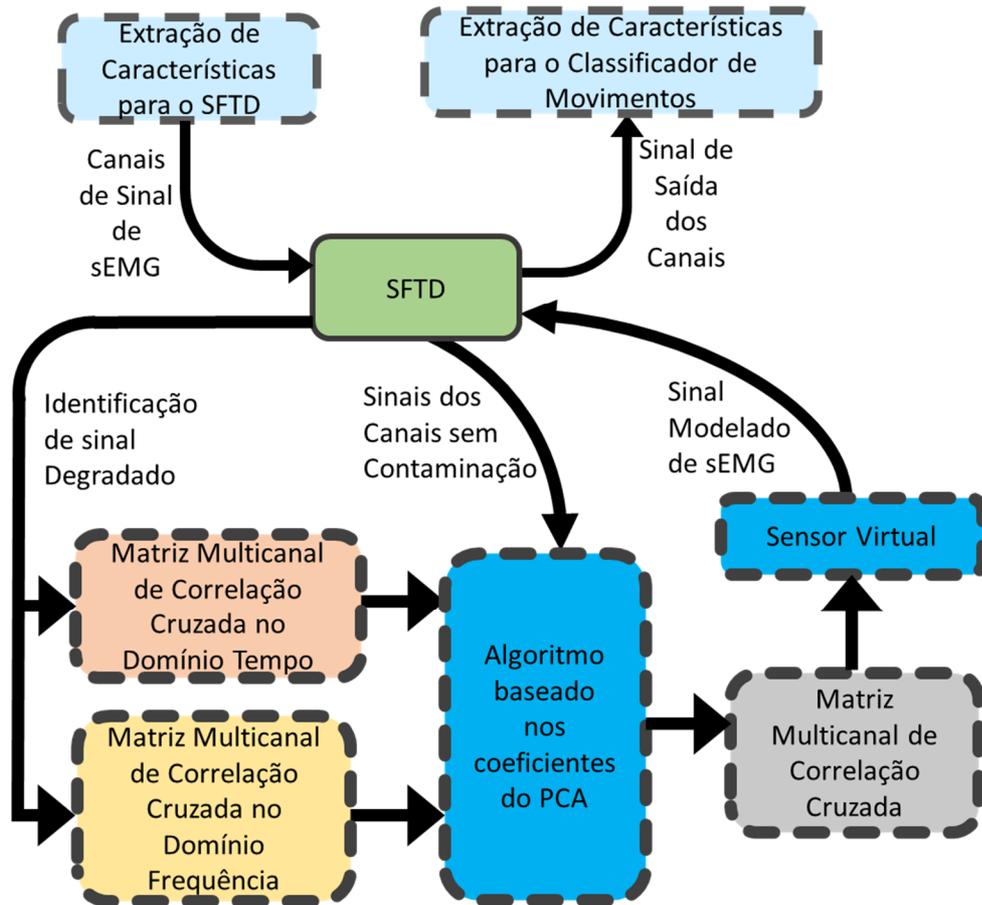


Figura 16 Lógica de operação do SFTD com o sensor virtual.

Em um trabalho preliminar ainda não publicado de (DE MOURA; BALBINOT, 2018a), quatro tipos de modelagem de sinais de sEMG foram avaliados e adaptados com a proposta da correlação cruzada multicanal, porém apenas para o ruído de deslocamento de eletrodos: o sinal com modelagem ARMA, o sinal com modelagem TVARMA com o algoritmo de descida de gradiente usado para estimação de parâmetros, o sinal com modelagem TVARMA com o algoritmo de filtro de Kalman usado para estimação de parâmetros e o sinal com modelagem TVK. O modelo ARMA forneceu a pior taxa de acerto média de classificação, a qual foi explicada pelo fato de conceitualmente o modelo não ser variante no tempo e precisar de mais interações para se ajustar ao sinal da janela deslizante. Os modelos TVARMA, que são variantes no tempo, obtiveram modelos de sinal mais similares com o sinal sem degradação e a sua utilização aumentou a taxa de acerto média de classificação após a degradação do sinal. A diferença com os modelos TVARMA foi o estimador de parâmetros utilizado e o limitador de interações. Ambos poderiam alcançar o melhor modelo, mas o TVARMA com o algoritmo de filtro de Kalman obteve um modelo melhor com um número menor de interações. A modelagem TVK não proporcionou a melhor taxa de acerto média, porém observou-se que faltou ajustes

nas suas matrizes de estados. Assim, os modelos selecionados para este trabalho foram baseados neste estudo preliminar, e buscou-se aprimorar os modelos de TVARMA com o algoritmo de filtro de Kalman usado para estimação de parâmetros e o modelo TVK.

A correlação cruzada (r_{xy}) entre dois canais de sinal de sEMG (x, y) foi normalizada (c_{xy}) para o número de canais (M), que é o mesmo para todos os canais. A nova abordagem chamada correlação cruzada multicanal para utilização no sensor virtual fornece a base da modelagem de sinal dos modelos TVARMA e TVK. A MCC é uma matriz que pode ser obtida através da contribuição percentual (p_{xy}) de cada coeficiente de correlação cruzada entre M canais adquiridos com a Equação (52):

$$p_{xy} = \begin{cases} \frac{c_{xy}}{\sum_{i=1}^M c_{xy,i}}, x \neq y \\ 0, x = y \end{cases} \quad (52)$$

Para 12 canais de sinal de sEMG, x e y variam com o intervalo (1,12) fornecendo uma matriz de correlação cruzada multicanal de ordem 12×12 como pode ser visto na Equação (53):

$$p_{xy} = \begin{bmatrix} 0 & p_{2,1} & p_{3,1} & \cdots & p_{12,1} \\ p_{1,2} & 0 & p_{3,2} & \cdots & p_{12,2} \\ p_{1,3} & p_{2,3} & 0 & \cdots & p_{12,3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ p_{1,12} & p_{2,12} & p_{3,12} & \cdots & 0 \end{bmatrix} \quad (53)$$

Primeiramente, no trabalho preliminar de (DE MOURA; BALBINOT, 2018b), o SFTD enviava a informação da contaminação de canais e a matriz MCC no domínio tempo era ajustada multiplicando por zero os canais contaminados e reajustando os percentuais da matriz. Ainda neste mesmo estudo, observou-se que havia margem para ajustar os modelos do sensor virtual quanto a correlação cruzada dos canais no domínio da frequência. Então, além da matriz MCC para a correlação cruzada no domínio tempo, se adotou o mesmo princípio fazendo a correlação cruzada no domínio frequência. Assim, a MCC passou a ser o somatório normalizado da matriz cruzada multicanal no domínio tempo com a de domínio frequência.

Entretanto, os canais mais correlacionados no domínio tempo não são os mesmos em domínio frequência, assim se implementou um novo algoritmo utilizando PCA para garantir uma priorização entre os canais mais correlacionados não contaminados em cada janela. Assim, com o objetivo de adequar a matriz de correlação cruzada combinada para os domínios de tempo e de frequência, os coeficientes do componente principal da última e da presente janela de

observação de cada uma das oito características primeiramente foram adequados apenas para aos canais não contaminados conforme a Equação (54):

$$coeff(n^\circ \text{ canais}, n^\circ \text{ características}) = \begin{cases} coeff \text{ PCA}, \text{ canal adequado} \\ 0, \text{ canal contaminado} \end{cases} \quad (54)$$

onde, o *coeff* retorna uma matriz 1 x N canais (no caso 12) por 1 x M características (no caso 8).

A matriz *coeff* contém os componentes de variância para todos os canais em relação às características analisadas. Através dos componentes principais, é possível extrair a informação de quais canais não contaminados estão mais correlacionados naquele instante com o canal mais correlacionado não contaminado do histórico da média populacional da base de dados do sujeito analisado. Esta definição de critério foi realizada empiricamente, considerando como mais correlacionados, os canais conforme na Equação (55).

$$\begin{aligned} \text{Se } Maxcoeff > 0 \text{ e } coeff(n, m) > \frac{1}{2} Maxcoeff, \text{ então } cc_i(n, m) &= 1 \\ \text{Se } Maxcoeff < 0 \text{ e } coeff(n, m) < \frac{1}{2} Maxcoeff, \text{ então } cc_i(n, m) &= 1 \end{aligned} \quad (55)$$

onde, o *Maxcoeff* é o coeficiente do canal mais correlacionado da média da população e não se encontra contaminado no instante *i*, *cc_i* é uma matriz com os canais não contaminados mais correlacionados para cada característica *m* no instante *i*, *n* é o canal analisado e *m* é a característica analisada.

Os canais de variância dos componentes principais mais correlacionados entre as cinco características temporais e três características de frequência apresentaram maiores valores verdadeiros quanto a sua posição instantânea para as características no domínio de tempo e frequência, conforme a Equação (56):

$$posTF_i(1:N) = \sum_{m_T=1}^5 cc_i(1:N, m_T) + \sum_{m_F=1}^3 cc_i(1:N, m_F) \quad (56)$$

onde, *posTF_i* é um vetor da posição instantânea *i* para as características de domínio de tempo e frequência com a pontuação de cada canal de relevância entre as oito características, *m_T* é o número de características no domínio de tempo e *m_F* é o número de características no domínio de frequência.

Após as contribuições percentuais dos canais da MCC, para os canais que não atenderem os requisitos conforme apresentados pelas Equações (57), (58) e (59), são zeradas. Como também são zeradas as contribuições dos canais que se detectou contaminação em mais de 50% da janela. Este segundo ajuste da MCC com auxílio dos coeficientes do PCA visa manter sempre no mínimo a correlação de três canais para cada canal ou coluna da matriz, e posteriormente faz o reajuste normalizado da contribuição percentual da representatividade dos canais. Para os casos onde apenas um canal foi considerado contaminado, foi ajustada a MCC para manter apenas os canais mais correlacionados em no mínimo 50% das características, conforme a Equação (57):

$$Se \left(\sum_{n=1}^{12} (posTF_i(n) == 0) \right) < 2 \text{ e } \left(\sum_{n=1}^{12} (posTF_i(n) \geq 4) \right) \geq 3, \quad (57)$$

$$\text{então } MCC(n((posTF_i(n) < 4), 1:12) = 0$$

Para os casos, onde de dois a três canais foram considerados contaminados, foi ajustada a MCC para manter os canais mais correlacionados em no mínimo 25% das características, conforme a Equação (58):

$$Se \left(\sum_{n=1}^{12} (posTF_i(n) == 0) \right) > \frac{2}{4} \text{ e } \left(\sum_{n=1}^{12} (posTF_i(n) \geq 2) \right) \geq 3, \quad (58)$$

$$\text{então } MCC(n((posTF_i(n) < 2), 1:12) = 0$$

Para os casos, onde mais de três canais foram considerados contaminados em no máximo até nove canais, foi ajustada a MCC para manter os canais mais correlacionados em no mínimo 10% das características, conforme a Equação (59):

$$Se \left(\sum_{n=1}^{12} (posTF_i(n) == 0) \right) > \frac{4}{10} \text{ e } \left(\sum_{n=1}^{12} (posTF_i(n) \geq 1) \right) \geq 3, \quad (59)$$

$$\text{então } MCC(n((posTF_i(n) == 0), 1:12) = 0$$

No caso extremo, onde foram considerados que menos de três canais estão não contaminados para a janela analisada, manteve-se a MCC combinada da janela anterior.

4.2.1 Modelo *Time-Varying Autoregressive Moving Average* (TVARMA)

Em (PAISS; INBAR, 1987), os autores haviam definido um modelo AR de sinal EMG. No modelo AR (também chamado modelo de predição linear), cada amostra $y(n)$ do EMG foi descrita como uma combinação linear das amostras anteriores, mais um termo de erro $e(n)$, que é independente de amostras passadas, conforme a Equação (60):

$$y(n) = \sum_{i=1}^P a_i y(n-i) + e(n) \quad (60)$$

onde, a_i é o coeficiente autorregressivo.

Basicamente, outros modelos, de AR e ARMA, têm o mesmo princípio (BAKKOURY; CASTANIE; ROVIRAS, 1996; BARIŞCI, 2008; RASOOL *et al.*, 2014; REAZ; HUSSAIN; MOHD-YASIN, 2006; SCHACK *et al.*, 1995). Modelos TVARMA têm sido utilizados com modelos de sinais não estacionários, onde os parâmetros autorregressivos variam com o tempo (CHEE-MING TING *et al.*, 2011). O modelo de TVARMA do sinal de sEMG proposto para o sensor virtual no tempo n é representado na Equação (61) e foi baseado no modelo de sEMG proposto em (CHEE-MING TING *et al.*, 2011; ZOU; CHON, 2004). O modelo também pode ser chamado por *Autoregressive Moving Average with Exogenous Inputs* (ARMAX). Cada janela de canal de sinal de sEMG do sensor virtual $y_{channel}(n)$ é estabelecido como uma combinação linear das amostras de saída anteriores, mais as amostras de entrada anteriores $u_{channel}(n)$ e um termo de erro de ruído presente $e_{channel}(n)$, que é independente de amostras passadas:

$$y_{channel}(n) = \sum_{i=1}^P a(i, n) \cdot y_{channel}(n-i) + \sum_{j=1}^Q b(j, n) \cdot u_{channel}(n-j) + e_{channel}(n) \quad (61)$$

onde, $a(i, n)$ é o coeficiente autorregressivo (AR) variável no tempo, $b(j, n)$ é o coeficiente de média móvel (MA) variável no tempo e os índices P e Q são as ordens dos modelos AR e MA, respectivamente. O modelo tem as ordens definidas como 4 para P e 2 para Q estabelecidas empiricamente, conforme o tempo necessário para gerar o modelo e a aproximação do modelo com os respectivos sinais originais.

Um exemplo de estimação dos coeficientes TVARMA com filtro de partículas pode ser visto no estudo de (CHEE-MING TING *et al.*, 2011), onde é utilizado um modelo TVARMA para modelar sinais de EEG. Em (BARIŞCI, 2008), foi realizado um estudo de um modelo

adaptativo ARMA para sinal de EMG, onde os coeficientes são estimado pelo algoritmo *Least Mean Square* (LMS).

Entretanto, o princípio básico do funcionamento dos sensores virtuais é estimar medidas indisponíveis com base em um modelo do sistema ou parte dele, a qual pode ser obtida através da correlação da medida de interesse com outras variáveis. As amostras de entrada $u_{channel}(n - j)$ podem ser obtidas através da Equação (62), que usa a respectiva coluna do canal de interesse da matriz MCC combinada e as outras amostras dos outros canais considerados como sinais não contaminados de sEMG. Utilizando a saída dos canais $\vec{y}(n - j)$ para a amostra de tempo $n - j$, os canais com contaminação conhecida são desconsiderados para a estimação de entrada $u_{channel}(n - j)$ a partir do vetor dos coeficientes de correlação, os quais são definidos como zero para estes canais com contaminação na respectiva amostragem de tempo.

$$u_{channel}(n - j) = (\vec{p}_{x,channel})^T \cdot \vec{y}(n - j) \quad (62)$$

onde, $(\vec{p}_{x,channel})^T$ é o vetor de valores das respectivas contribuições percentuais do coeficiente de correlação cruzada entre o canal de interesse e os outros canais.

A Equação (61) também pode ser escrita da seguinte maneira:

$$A(q)y_{channel}(n) = B(q)u_{channel}(n - j) + C(q)e_{channel}(n) \quad (63)$$

onde, $A(q) = 1 + a_1q^{-1} + \dots + a_{na}q^{-na}$, $B(q) = b_1 + b_2q^{-1} + \dots + b_{nb}q^{-nb+1}$, $C(q) = 1 + c_1q^{-1} + \dots + c_{nc}q^{-nc}$, os parâmetros na , nb e nc são as ordens do modelo, j é o atraso e q é o operador de atraso.

Os parâmetros dos polinômios $A(q)$, $B(q)$ e $C(q)$ são estimados por um algoritmo de estimativa recursiva de parâmetros, o qual foi selecionado para o método por algoritmo Kalman Filter, disponível na toolbox do Matlab® R2016b. As seguintes equações resumem o algoritmo de adaptação por Kalman Filter. A forma geral do algoritmo de estimação recursiva é:

$$\hat{\theta}(n) = \hat{\theta}(n - 1) + K(n)(y(n) - \hat{y}(n)) \quad (64)$$

onde, $\hat{\theta}(n)$ é a estimativa do parâmetro no tempo n , $y(n)$ é a saída observada no tempo n , $\hat{y}(n)$ é a previsão de $y(n)$ baseada em observações até o tempo $n - 1$. O ganho, $K(n)$, determina quanto o erro de predição de corrente $y(n) - \hat{y}(n)$ afeta a atualização da estimativa do parâmetro.

O algoritmo de estimação minimiza o termo de erro de predição $y(n) - \hat{y}(n)$. Assim, os polinômios $A(q)$, $B(q)$ e $C(q)$ são estimados separados através de $\hat{\theta}(n)$. O ganho, $K(n)$, é definido por:

$$K(n) = Q(n)\psi(n) \quad (65)$$

onde, $\psi(n)$ representa o gradiente da saída do modelo previsto $\hat{y}(n)$ em relação aos parâmetros θ e $Q(n)$ é calculado usando um Filtro de Kalman, conforme a Equação (66) e (67):

$$Q(n) = \frac{P(n-1)}{R2 + \psi^T(n)P(n-1)\psi(n)} \quad (66)$$

$$P(n) = P(n-1) + R1 - \frac{P(n-1)\psi(n)\psi^T(n)P(n-1)}{R2 + \psi^T(n)P(n-1)\psi(n)} \quad (67)$$

onde, $R2$ é a variância das inovações $e(n)$ na Equação (68), o algoritmo garante que $P(n)$ seja uma matriz positiva definida usando um algoritmo de raiz quadrada, assumindo que os resíduos (diferença entre as saídas estimadas e medidas) são ruído branco, e a variância desses resíduos é 1, e $R1$ é a matriz de covariância das alterações de parâmetros.

A maneira mais simples de visualizar o papel do gradiente $\psi(n)$ dos parâmetros é considerar modelos com uma forma de regressão linear, conforme a Equação (68). Nesta equação, $\psi(n)$ é o vetor de regressão, o qual é calculado com base nos valores anteriores das entradas e saídas medidas.

$$y(n) = \psi^T(n)\theta_0(n) + e(n) \quad (68)$$

onde, $\theta_0(n)$ representa os parâmetros verdadeiros e $e(n)$ é a fonte de ruído, que é assumido como ruído branco. Também se assume que $\theta_0(n)$ é descrito por modelo *random walk*.

Assim, $\theta_0(n)$ pode ser formulado da seguinte maneira:

$$\theta_0(n) = \theta_0(n-1) + w(n) \quad (69)$$

onde, $w(n)$ é o ruído gaussiano branco com a seguinte matriz de covariância, ou matriz de deriva $R1$:

$$R1 = E(w(n)w^T(n)) \quad (70)$$

A saída prevista $\hat{y}(n)$ é dada pela seguinte equação:

$$\hat{y}(n) = \psi^T(n)\hat{\theta}(n-1) \quad (71)$$

Assim, o algoritmo do filtro de Kalman utilizado é inteiramente especificado pela sequência de dados $y(n)$, o gradiente $\psi(n)$, $R1$, $R2$ e as condições iniciais $\theta(n=0)$ (estimativa inicial dos parâmetros) e $P(n=0)$ (matriz de covariância que indica erros de parâmetros).

4.2.2 Modelo *Time-Varying Kalman Filter* (TVK)

O Filtro de Kalman é ideal quando aplicado em sistemas lineares. Para sistemas não lineares, existe a variante de Filtro de Kalman Estendido. O modelo TVK de sinais de sEMG para o sensor virtual linearizado a cada interação transformando-o num sistema linear variante no tempo. Então, o modelo TVK é baseado no estimador de estado de Kalman, o qual recebe um modelo de espaço de estados com entradas conhecidas satisfatórias $u_{channel}(n)$, ruído de processo branco $w(n)$ e ruído de medição branco $v(n)$. A medição do sensor virtual $y_{channel}(n)$ e a equação de estado $x(n)$ podem ser representadas pela Equação (72) e (73):

$$x(n) = Ax(n-1) + Bu_{channel}(n-1) + w(n-1) \quad (72)$$

$$y_{channel}(n) = Cx(n) + v(n) \quad (73)$$

onde, $w(n)$ é o ruído branco do processo, $v(n)$ é o ruído branco de observação, a matriz A é referente ao modelo de transição de estado, a matriz B é referente ao modelo de entrada de controle e a matriz C é referente ao modelo de observação. O $y_{channel}(n)$ e o $u_{channel}(n)$ são referentes conforme relatado para os modelos TVARMA na seção anterior.

Assim, o equacionamento da fase de predição pode ser representado por:

$$\hat{x}^-(n) = A\hat{x}(n-1) + Bu_{channel}(n-1) \quad (74)$$

$$P^-(n) = AP(n-1)A^T + Q \quad (75)$$

onde, $\hat{x}^-(n)$ é a estimativa atualizada prevista (*a priori*), $\hat{x}(n-1)$ é a estimativa atualizada da amostra de tempo $n-1$ e $P^-(n)$ é a covariância de erro prevista (*a priori*).

O equacionamento da fase de correção pode ser representado por:

$$M(n) = \frac{P^-(n)C^T}{CP^-(n)C^T + R} \quad (76)$$

$$\hat{x}(n) = \hat{x}^-(n) + M(n)[y_{channel}(n) - C\hat{x}^-(n)] \quad (77)$$

$$P(n) = [I - M(n)C]P^-(n) \quad (78)$$

As matrizes de estados A, B, C e G representam informações relativas à dinâmica do modelo do sistema analisado, o qual possui um sistema de matriz de ganho para a estimativa de uma previsão de saída com base na entrada especialmente especificado para ser dependente dos outros canais considerados não contaminados. Assim, definiu-se que as matrizes de estado do modelo TVK fossem matrizes de identidade, seguindo um modelo *random walk*. Considerando a condição inicial de $\hat{x}(0)$ e o cálculo de valor de $P(0)$ para $Q=2$, o seguinte fluxograma é apresentado na Figura 17, o qual exemplifica a atualização das estimativas de estado $x(n)$ e as matrizes de covariância de erro $P(n)$ em cada amostra de tempo.

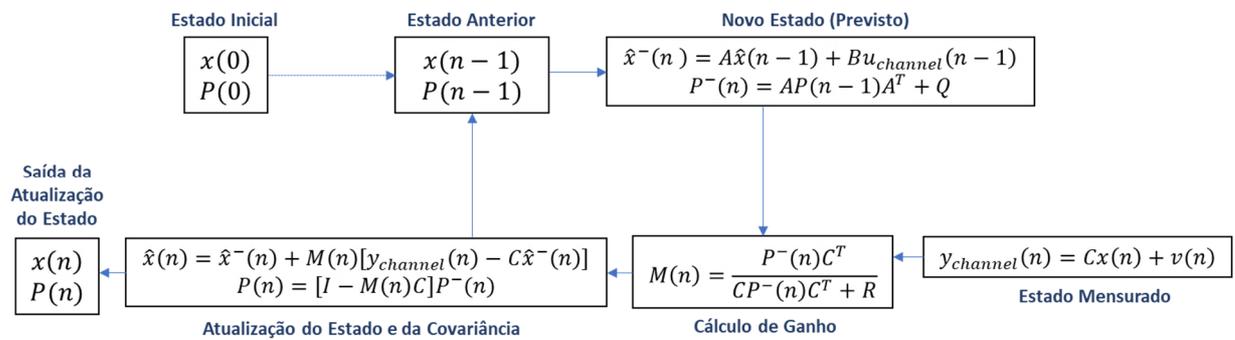


Figura 17 Fluxograma Modelo TVK.

4.8 ETAPA DE CLASSIFICAÇÃO

A etapa de caracterização dos movimentos do segmento mão-braço é realizada através da Máquina de Vetores de Suporte, que é um método amplamente utilizado nesta área. As características do classificador SVM, tanto linear como não linear, são consideradas úteis para a classificação de padrões como os sinais de sEMG, cujas características tendem a mudar com o tempo, bem como permitem em tempo-real a classificação de movimentos (GUO *et al.*, 2015a; REKHI *et al.*, 2009; RIILLO *et al.*, 2014).

Todos os dados salvos de cada sujeito para cada caso, como descrito ao final da subseção 4.6 EXTRAÇÃO DE CARACTERÍSTICAS, têm o mesmo número de amostras temporais. Estas características extraídas foram utilizadas na classificação dos movimentos por um algoritmo de SVM não linear multiclasse em diferentes cenários de análise de casos de classificação, conforme a Figura 18. O procedimento de classificação foi aplicado em sete configurações diferentes. O primeiro caso de análise corresponde à classificação tradicional, em que 50% dos dados do sinal sem degradação ou íntegro foram usados para treinamento e os outros 50% para

o teste. Para os casos 2, 4 e 6, o treinamento do classificador ainda continua usando 50% do sinal íntegro. No entanto, os outros 50% dos dados correspondentes do teste são substituídos pelos sinais com degradação (caso 2), com o sinal do sensor virtual com o modelo TVARMA (caso 4) e com o modelo TVK (caso 6). O caso 3 analisa o retreinamento do classificador sem o canal degradado detectado pelo SFTD. Os últimos casos analisam o retreinamento do classificador a partir do conjunto de dados de sinal íntegro com a substituição dos canais degradados pelo sensor virtual de modelo TVARMA (caso 5) e de modelo TVK (caso 7). Nestes dois últimos casos, o treinamento e o teste foram realizados com a substituição do sinal pelos modelos em todos os pontos detectados pelo SFTD, ou seja, ocorreu o treinamento do classificador com o sinal degradado substituído pelo modelo do sensor virtual.

A classificação SVM não linear com o *kernel* da função de base radial (RBF) foi implementada na classificação dos sinais de sEMG de todos os casos simulados. Os parâmetros das funções do *kernel* foram selecionados por um algoritmo de busca para o melhor resultado para cada sujeito. A técnica de definição de múltiplas classes para o classificador de movimento foi utilizar dezoito classificações binárias de um contra todos. Entretanto, para mais de um caso de classe positiva, o algoritmo seleciona a classe que está mais distante do hiperplano que separa cada classificação binária.

Configuração de classificação SVM	50% de treinamento	50% de teste
1. Sinal Integro (classificação tradicional)	Sinal Integro	Sinal Integro
2. Sinal com Degradação	Sinal Integro	Sinal com Contaminação
3. Retreinamento sem os Canais Contaminados	Após a inserção da degradação e do STFD, o retreinamento e o teste de classificação foram realizados com os sinais íntegros, sem os canais contaminados detectados	
4. Modelo TVARMA	Sinal Integro	Sinal íntegro com a substituição do canal degradado pelo sensor virtual do modelo TVARMA de sinal
5. Retreinamento com Modelo TVARMA	Após a inserção da degradação e do STFD, o retreinamento e teste de classificação foi realizado com o sinal íntegro com a substituição dos canais degradados pelo sensor virtual do modelo TVARMA	
6. Modelo TVK	Sinal Integro	Sinal íntegro com a substituição do canal degradado pelo sensor virtual do modelo TVK de sinal
7. Retreinamento com Modelo TVK	Após a inserção da degradação e do STFD, o retreinamento e teste de classificação foi realizado com o sinal íntegro com a substituição dos canais degradados pelo sensor virtual do modelo TVAK	

Figura 18 Descrição da configuração de classificação do SVM.

A técnica de votação majoritária foi usada como um mecanismo de pós-processamento considerando a classificação das três últimas janelas. Além disso, a técnica complementar de *k-fold* foi aplicada para melhorar o teste de confiabilidade quanto a taxa de acerto com o pequeno

número de amostras nas quais o modelo é treinado e testado. Os testes são realizados em todas as possíveis condições de entrada diferentes, formando 20 combinações ou 20 *k-folds* para as seis repetições de movimento disponíveis. Para cada *k-fold*, três das seis repetições (50% do conjunto de dados) foram selecionadas para o modelo de treinamento e três (50% do conjunto de dados) para o teste.

As sete configurações diferentes incluem a prática de retreinamento do classificador para análise comparativa de desempenho. O retreinamento do classificador sem o canal degradado foi realizado quando 80% das janelas foram consideradas contaminadas pelo SFTD. A classificação com retreinamento utilizando os dois sinais modelados foi feita através da substituição do sinal contaminado pelo sensor virtual no treinamento e teste. Para cada janela deslizante que apresenta 50% de contaminação detectada pelo SFTD nos últimos 3 s, o sensor virtual substituiu o sinal de sEMG pelo sinal modelado. Esse limiar foi estabelecido com base em outro estudo (CENE; FAVIEIRO; BALBINOT, 2015), que introduziu a ideia de temporalidade do contaminante e o retorno à reconsideração do canal contaminado. Cada sujeito foi analisado em relação a diferentes tipos de contaminação em diferentes arranjos de canais, e cada análise resultou em uma matriz de confusão específica de todas as *k* dobras.

No software Matlab® R2016b, o programa que realiza a classificação fez uso da função *fitcsvm* e *predict*. O algoritmo de busca e seleção escolhido dos dois multiplicadores de Lagrange da Equação (26), identificados por α_i e ν_i , para a definição do hiperplano ótimo, foi *Sequential Minimal Optimization* (SMO), também utilizadas nos estudos de (BÚRIGO, 2014; DE PAULI NILSON; BALBINOT, 2014) de classificadores SVM na caracterização de movimentos do segmento mão-braço realizados no Laboratório IEE.

O algoritmo SMO tem sido amplamente utilizado no treinamento de classificadores SVM (KUAN *et al.*, 2012), pois é reconhecido como rápido e fácil para implementar em *software* com SVM (PLATT, 1998). Basicamente, o SMO executa três tarefas por iteração: seleção de um par de coeficientes, otimização do par de coeficientes selecionados e atualização de dados globais. O algoritmo executa um total de *N* iterações até que os coeficientes satisfaçam um conjunto de condições denominadas de Karush-Kuhn-Tucker (KKT) (PLATT, 1998).

As condições KKT de verificação são fundamentais para o algoritmo SMO otimizar a busca dos dois multiplicadores Lagrange (PLATT, 1998). As condições exigem que o produto do multiplicador e sua restrição correspondente desapareçam. Assim, para $1 \leq i \leq N$:

$$\alpha_i (y_i [\omega^T x_i + b] - 1 + \varepsilon_i) = 0 \quad (79)$$

$$v_i \varepsilon_i = 0 \quad (80)$$

As três condições com relação a α_i que devem ser consideradas são:

- $\alpha_i = 0$, assim $v_i = C - \alpha_i = C$ e $\varepsilon_i = 0$, então $y_i[\omega^T x_i + b] - 1 \geq 0$
- $0 < \alpha_i < C$, assim $v_i = C - \alpha_i > 0$ e $\varepsilon_i = 0$, então $y_i[\omega^T x_i + b] - 1 = 0$
- $\alpha_i = C$, assim $v_i = C - \alpha_i = 0$ e $\varepsilon_i \geq 0$, então $y_i[\omega^T x_i + b] - 1 \leq 0$

Podendo formular $y_i[\omega^T x_i + b] - 1$, como na Equação (81):

$$R_i = y_i[\omega^T x_i + b] - y_i^2 = y_i([\omega^T x_i + b] - y_i) = y_i E_i \quad (81)$$

onde, E_i é o erro predito e $y_i^2 = 1$.

As condições KKT agora podem ter uma representação mais simplificada:

$$\begin{aligned} \alpha_i = 0 &\rightarrow R_i \geq 0 \\ 0 < \alpha_i < C &\rightarrow R_i \approx 0 \\ \alpha_i = C &\rightarrow R_i \leq 0 \end{aligned} \quad (82)$$

O SMO inicialmente assume dois multiplicadores de Lagrange α_1 e α_2 , e inicializa-os $\alpha_1 = \alpha_2 = 0$. Considerando a condição da Equação (18), $\sum_{i=1}^N \alpha_i y_i = 0$ para $i = 1, 2, \dots, N$, a condição linear obriga o ajuste para que o outro multiplicador mantenha a validade da restrição, assim:

$$y_1 \alpha_i + y_2 \alpha_j = y_1 \alpha_1 + y_2 \alpha_2 = \text{constante} \quad (83)$$

No espaço formado por (α_1, α_2) e as restrições $0 \leq \alpha_1, \alpha_2 \leq C$, os dois multiplicadores de Lagrange resultantes devem obedecer às restrições do problema original. As desigualdades restringem os multiplicadores em um quadrado e a restrição linear obriga aos multiplicadores a ficarem em uma linha diagonal, conforme Figura 19.

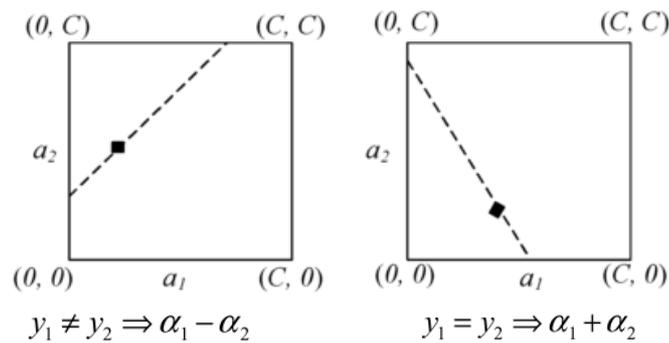


Figura 19 Exemplos de restrição dos multiplicadores de Lagrange no SMO.

Fonte: Adaptado de (KUAN *et al.*, 2012).

O SMO primeiro busca o α_j e determina a reta diagonal em termos de α_j . Após atualizar os dados da globais da SVM, ω , b e E , verifica se α_i e α_j satisfazem as condições KKT. Resumidamente, o algoritmo SMO é apresentado na Figura 20.

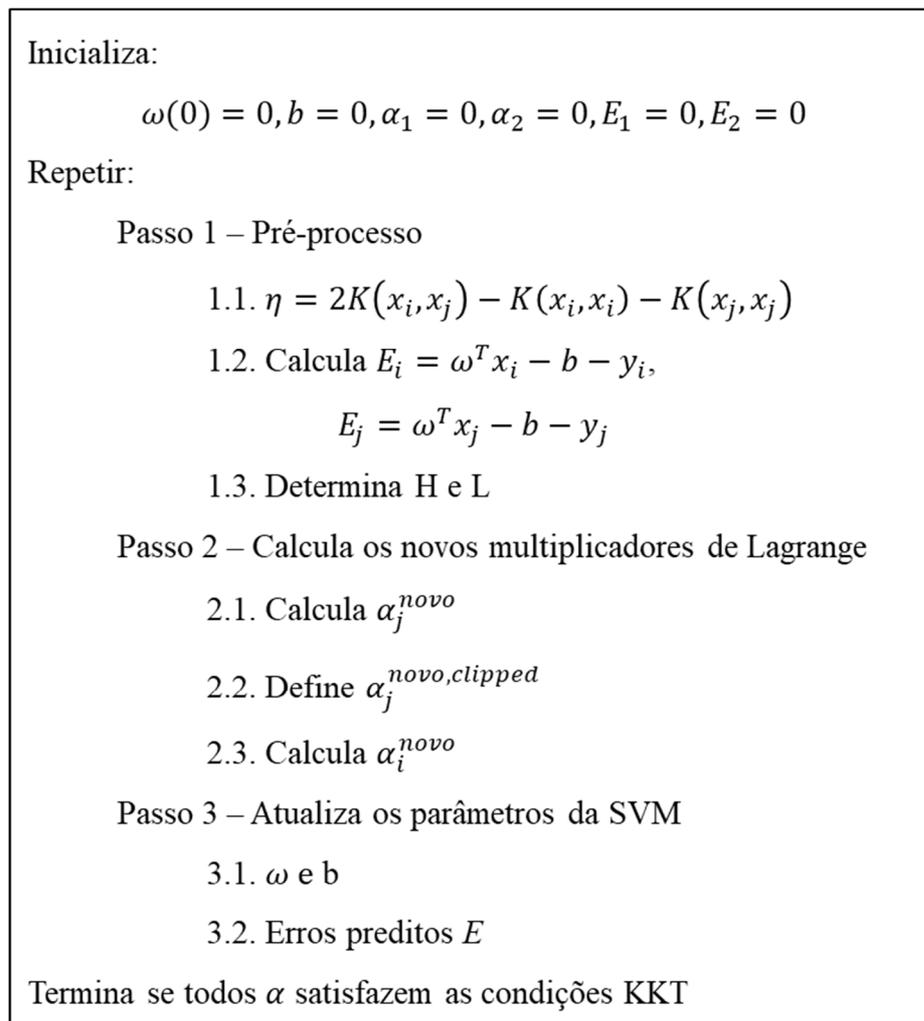


Figura 20 Algoritmo SMO resumido.

O algoritmo de SMO define α_j^{novo} na Equação (84):

$$\alpha_j^{novo} = \alpha_j + \frac{y_j(E_j - E_i)}{\eta} \quad (84)$$

onde, E_i é o erro no i -ésimo exemplo de treinamento, $E_i = \omega^T x_i - b - y_i$, e $\eta = 2K(x_i, x_j) - K(x_i, x_i) - K(x_j, x_j)$.

Se $y_i \neq y_j$, então as seguintes restrições são aplicadas a α_j , $L = \text{máximo}(0, \alpha_j - \alpha_i)$ e $H = \text{mínimo}(0, C - \alpha_j + \alpha_i)$. Se $y_i = y_j$, então as seguintes restrições são aplicadas a α_j , $L = \text{máximo}(0, \alpha_j + \alpha_i - C)$ e $H = \text{mínimo}(0, \alpha_j + \alpha_i)$. Assim, $\alpha_j^{novo,clipped}$ é encontrado pelo *clipping* da extremidade da reta diagonal:

$$\alpha_j^{novo,clipped} = \begin{cases} H & , \text{ se } \alpha_j^{novo} \geq H \\ \alpha_j^{novo} & , \text{ se } \alpha_j^{novo} < H \\ L & , \text{ se } \alpha_j^{novo} \leq L \end{cases} \quad (85)$$

E o valor de α_i^{novo} é definido a partir de α_j^{novo} , conforme a Equação (86):

$$\alpha_i^{novo} = \alpha_i + y_i y_j (\alpha_i - \alpha_j^{novo,clipped}) \quad (86)$$

Entretanto, a saída do modelo não apresenta uma probabilidade de acerto para cada classe, pois a saída é binária. Dessa forma, existe a possibilidade de mais de um dos 18 classificadores responderem positivamente. Assim, em conjunto com a função *predict*, foi calculada a distância do ponto classificado em relação ao hiperplano, considerando-se que, entre as multiclassificadas encontradas positivas, o ponto mais distante do hiperplano da sua classe tem a maior probabilidade de ser o correto. É possível ver este fluxograma de decisão na Figura 21.

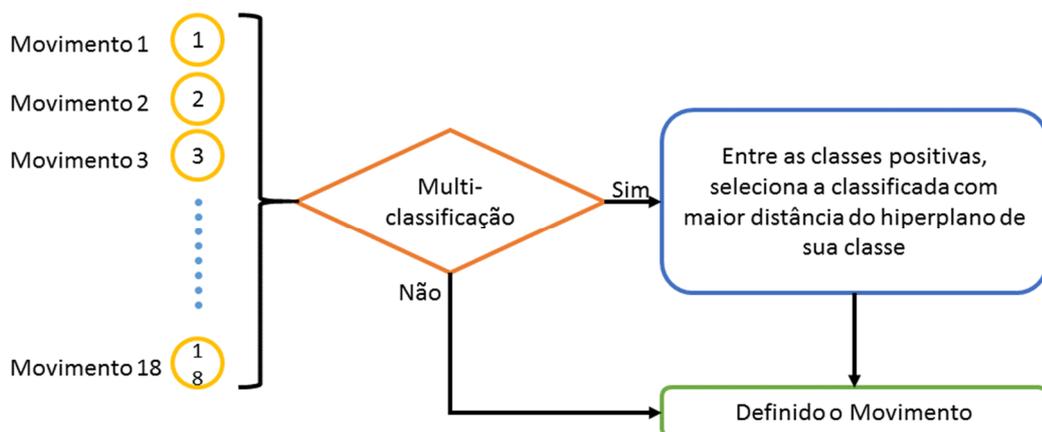


Figura 21 Fluxograma de decisão para multiclassificação.

Assim, o cálculo da distância das características de teste em um determinado instante do tempo é obtido por $fd(x)$ na Equação (87) para cada uma das classes dos movimentos previamente treinadas.

$$fd(x, classe) = \alpha_i y_i \cdot K(x_i, x_j) + b \quad (87)$$

onde, x é o vetor de características de teste, α_i é o vetor de pesos para os vetores de suporte da SVM treinada e y_i é o vetor suporte de observação do treinamento normalizado.

Assim, a definição do movimento no caso de multiclases é dada na Equação (88):

$$classe \text{ do movimento} = \text{máximo}(fd(x, classe)) \quad (88)$$

onde, $classe = 1, 2, \dots, 18$.

Então, em um primeiro momento para a classificação dos movimentos, foi realizada a busca dos melhores parâmetros de entrada da função *kernel* para cada voluntário. Os parâmetros necessários são o valor de C (parâmetro de regularização, que pondera os erros de treinamento) e o valor de σ (desvio padrão do kernel RBF) para a função RBF. Com o auxílio de um algoritmo de busca Uniforme¹, é realizada a busca do melhor valor de C de 1,2, ..., 100 para cada sujeito e a própria função *fitsvm* faz a busca do valor de σ .

Os resultados são salvos em matrizes de confusão e tabelas que serão utilizados no pós-processamento para analisar os resultados. A matriz de confusão, também conhecida como tabela de contingência (ÁLVAREZ-ESTÉVEZ *et al.*, 2013; QIAN *et al.*, 2010; ÜBEYLI, 2010), é desenhada de tal modo que cada linha representa os casos em uma classe real enquanto que as colunas representam os casos em uma classe predita, e os acertos estão localizados na diagonal da matriz. Na Figura 22, é possível visualizar um exemplo da matriz de confusão do sujeito amputado 1 com o sinal íntegro para a classificação tradicional.

No exemplo da matriz de confusão na Figura 22, a taxa de acerto global pode ser vista no canto direito com fundo preto, a taxa de acerto individual de cada movimento pode ser vista na diagonal principal em fundo verde, e os movimentos que foram confundidos possuem fundo vermelho. Também podem ser vistas as seguintes taxas:

- falso positivo (FP - representa as predições positivas que não eram positivas na realidade) em vermelho com fundo azul na linha abaixo;

¹ Método de Busca Uniforme é uma técnica de busca unidimensional, onde os intervalos de busca são decididos antecipadamente. O intervalo inicial $[a, b]$ é sucessivamente subdividido, reduzido em $[a+b/2-\delta; a+b/2+\delta]$ e a função é calculada em cada um dos pontos.

- verdadeiro positivo (VP - representa as predições positivas que eram realmente positivas) em verde com fundo azul na linha abaixo;
- falso negativo (FN - representa as predições negativas que não eram negativas na realidade) em vermelho com fundo azul na coluna da direita;
- verdadeiro negativo (VN - representa as predições negativas que eram realmente negativas) em verde com fundo azul na coluna da direita.

A taxa de acerto global foi calculada segundo a Equação (89):

$$TA = \frac{VP + VN}{N} \quad (89)$$

onde, N indica o número total de casos classificados.

Além da taxa de acerto média de classificação, foi analisado mais três métricas de verificação da eficiência na classificação dos movimentos. As métricas adicionais especificadas estão representadas na Equação (90), (91) e (92) e foram denominadas taxa de erro para com o grupo de repouso $TE_{Repouso}$, com o mesmo grupo de movimentos TE_{IG} , com grupo diferente de movimentos TE_{EG} , conforme subdividido na Figura 7.

$$TE_{Repouso}(mov) = \frac{FN_1}{N} \quad (90)$$

onde, mov é o movimento de interesse que se quer saber a taxa de erro para com o movimento de repouso, FN_1 são as predições falso negativas de repouso e N indica o número total de casos classificados.

$$TE_{IG}(mov) = \frac{\sum_{i=G_1}^{G_n} FN_i}{N} \quad (91)$$

onde, mov é o movimento de interesse que se quer saber a taxa de erro para com o mesmo grupo G de tamanho $i = 1, \dots, n$, FN_i são as predições falso negativas para com os outros movimentos do mesmo grupo e N indica o número total de casos classificados.

$$TE_{EG}(mov) = \frac{\sum_{e=GE_1}^{GE_n} FN_e}{N} \quad (92)$$

onde, mov é o movimento de interesse que se quer saber a taxa de erro para com os grupos externos GE de tamanho $e = 1, \dots, n$, FN_e são as predições falso negativas para com os outros movimentos externos ao grupo e N indica o número total de casos classificados.

Output Class	1	13899 23.9%	86 0.1%	76 0.1%	171 0.3%	495 0.9%	317 0.5%	915 1.6%	428 0.7%	147 0.3%	75 0.1%	76 0.1%	221 0.4%	27 0.0%	426 0.7%	186 0.3%	2 0.0%	106 0.2%	24 0.0%	78.6% 21.4%	
	2	107 0.2%	1463 2.5%	17 0.0%	113 0.2%	0 0.0%	0 0.0%	3 0.0%	0 0.0%	28 0.0%	15 0.0%	0 0.0%	75 0.1%	0 0.0%	80 0.1%	3 0.0%	0 0.0%	4 0.0%	8 0.0%	76.4% 23.6%	
	3	12 0.0%	0 0.0%	889 1.5%	448 0.8%	101 0.2%	0 0.0%	4 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	36 0.1%	13 0.0%	10 0.0%	0 0.0%	0 0.0%	9 0.0%	32 0.1%	57.2% 42.8%
	4	26 0.0%	13 0.0%	323 0.6%	1210 2.1%	88 0.2%	0 0.0%	0 0.0%	13 0.0%	0 0.0%	2 0.0%	0 0.0%	12 0.0%	0 0.0%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	99 0.2%	59 0.1%	65.5% 34.5%
	5	44 0.1%	2 0.0%	36 0.1%	74 0.1%	1011 1.7%	118 0.2%	47 0.1%	28 0.0%	13 0.0%	2 0.0%	25 0.0%	82 0.1%	208 0.4%	32 0.1%	30 0.1%	0 0.0%	52 0.1%	16 0.0%	55.5% 44.5%	
	6	139 0.2%	0 0.0%	4 0.0%	0 0.0%	193 0.3%	2098 3.6%	137 0.2%	45 0.1%	8 0.0%	1 0.0%	11 0.0%	9 0.0%	0 0.0%	26 0.0%	44 0.1%	14 0.0%	11 0.0%	0 0.0%	76.6% 23.4%	
	7	256 0.4%	3 0.0%	20 0.0%	0 0.0%	23 0.0%	63 0.1%	2422 4.2%	23 0.0%	42 0.1%	10 0.0%	0 0.0%	47 0.1%	0 0.0%	50 0.1%	20 0.0%	115 0.2%	14 0.0%	0 0.0%	77.9% 22.1%	
	8	204 0.4%	2 0.0%	119 0.2%	6 0.0%	37 0.1%	137 0.2%	38 0.1%	1873 3.2%	4 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 0.0%	13 0.0%	13 0.0%	14 0.0%	0 0.0%	76.0% 24.0%	
	9	34 0.1%	23 0.0%	16 0.0%	0 0.0%	11 0.0%	21 0.0%	49 0.1%	0 0.0%	1538 2.6%	190 0.3%	25 0.0%	49 0.1%	0 0.0%	22 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	77.8% 22.2%
	10	14 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	0 0.0%	8 0.0%	0 0.0%	352 0.6%	2512 4.3%	12 0.0%	13 0.0%	0 0.0%	68 0.1%	0 0.0%	0 0.0%	2 0.0%	1 0.0%	12 0.0%	83.8% 16.2%
	11	27 0.0%	0 0.0%	0 0.0%	0 0.0%	108 0.2%	19 0.0%	28 0.0%	6 0.0%	64 0.1%	5 0.0%	1803 3.1%	123 0.2%	12 0.0%	75 0.1%	37 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	78.2% 21.8%
	12	85 0.1%	6 0.0%	16 0.0%	12 0.0%	183 0.3%	28 0.0%	46 0.1%	2 0.0%	161 0.3%	104 0.2%	25 0.0%	1878 3.2%	47 0.1%	104 0.2%	79 0.1%	8 0.0%	2 0.0%	9 0.0%	67.2% 32.8%	
	13	42 0.1%	0 0.0%	14 0.0%	2 0.0%	402 0.7%	0 0.0%	0 0.0%	0 0.0%	3 0.0%	0 0.0%	2 0.0%	50 0.1%	1757 3.0%	186 0.3%	3 0.0%	0 0.0%	163 0.3%	55 0.1%	65.6% 34.4%	
	14	126 0.2%	92 0.2%	9 0.0%	2 0.0%	27 0.0%	56 0.1%	249 0.4%	20 0.0%	10 0.0%	24 0.0%	28 0.0%	141 0.2%	75 0.1%	1427 2.5%	442 0.8%	35 0.1%	19 0.0%	2 0.0%	51.3% 48.7%	
	15	33 0.1%	0 0.0%	0 0.0%	0 0.0%	72 0.1%	106 0.2%	34 0.1%	3 0.0%	7 0.0%	0 0.0%	2 0.0%	57 0.1%	14 0.0%	418 0.7%	1054 1.8%	219 0.4%	0 0.0%	0 0.0%	52.2% 47.8%	
	16	26 0.0%	0 0.0%	15 0.0%	0 0.0%	0 0.0%	14 0.0%	0 0.0%	19 0.0%	3 0.0%	0 0.0%	0 0.0%	8 0.0%	4 0.0%	63 0.1%	109 0.2%	1512 2.6%	9 0.0%	0 0.0%	84.8% 15.2%	
	17	96 0.2%	0 0.0%	0 0.0%	105 0.2%	45 0.1%	3 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 0.0%	26 0.0%	64 0.1%	145 0.2%	0 0.0%	0 0.0%	2113 3.6%	478 0.8%	68.3% 31.7%	
	18	30 0.1%	10 0.0%	6 0.0%	77 0.1%	42 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	31 0.1%	33 0.1%	79 0.1%	0 0.0%	0 0.0%	0 0.0%	344 0.6%	1985 3.4%	75.3% 24.7%	
		91.4% 8.6%	86.1% 13.9%	57.0% 43.0%	54.5% 45.5%	35.6% 64.4%	70.4% 29.6%	60.9% 39.1%	76.1% 23.9%	64.6% 35.4%	85.4% 14.6%	87.5% 12.5%	65.7% 34.3%	76.4% 23.6%	45.4% 54.6%	52.2% 47.8%	78.8% 21.3%	71.4% 28.6%	74.1% 25.9%	72.9% 27.1%	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18		
		Target Class																			

Figura 22 Exemplo da matriz de confusão.

4.9 PROJETO DE EXPERIMENTOS

Primeiramente, para a correta interpretação dos resultados, foi necessária uma análise da detecção das janelas contaminadas pelo SFTD com relação à sua taxa de reconhecimento de contaminação. O SFTD pode apresentar uma diferenciação na detecção, dependendo do contaminante analisado, como observado no trabalho preliminar de (MOURA; RUSCHEL; BALBINOT, 2018). Para cada estudo dos 16 casos de contaminação, foi salvo um arquivo Matlab com a saída de classificação do SFTD das janelas deslizantes dos canais. Estas respostas de detecção do SFTD foram comparadas conforme o caso de inserção de contaminantes analisados. Com base nos resultados de percentuais de acerto de detecção do SFTD, foi possível

avaliar a sensibilidade de reconhecimento verdadeiro positivo e quanto ao reconhecimento falso positivo para os contaminantes.

A seguir, foi realizado a análise para definir o desempenho do sistema através das matrizes de confusão com os resultados das variações de modelos de sensor virtual, estudos de casos de contaminação de canais e configuração de classificação por sujeito conforme a metodologia experimental. O desempenho do sistema é analisado separadamente para cada base de dados quanto à variação de sujeitos, modelo do sensor virtual, tipos de ruídos, estudo de casos de contaminação de canais e configuração de classificação. Também é realizada a análise quanto aos erros de classificação entre os grupos de movimentos distintos.

A confiabilidade dos resultados obtidos é realizada por análise estatística. Assim, as variações foram verificadas a partir da análise de validação estatística dos dados obtidos com planejamento experimental baseado na metodologia de Projeto de Experimentos (MONTGOMERY, 2001). Devido ao limitante de até 2.000 variações permitidas pela ferramenta computacional Minitab 17, mais de um modelo fatorial completo foi realizado. Utilizando como variável de resposta a taxa de acerto de classificação de movimentos, os resultados foram avaliados para as seguintes combinações de fatores controláveis, as quais totalizam 18 projetos, sinalizando o número de níveis de cada fator:

- Sujeitos (53), Ruídos (5), Configuração de Classificação (6 – sem a classificação tradicional) - (totalizando 1590 variações);
- Sujeitos de cada Base de dados (20 Intactos NinaPro, 13 Amputados NinaPro e 20 Intactos IEE), Estudos de Contaminação de Canais (16) e Configuração de Classificação (6 – sem a classificação tradicional) - (totalizando 1920 variações) para ruído analisado;
- Sujeitos (53), Estudos de Contaminação de Canais (16), Modelos do Sensor Virtual sem retreinar (2) e retreinando o classificador (2) - (totalizando 1696 variações).

É importante ressaltar que é estimado que todos os dados avaliados seguem as premissas básicas de um Projeto Fatorial Completo e que cada projeto foi examinado quanto a qualidade do modelo. O modelo utilizado segue na Equação (93):

$$y_{ijk} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\alpha\beta\gamma)_{ijk} + \varepsilon_{ijk} \quad (93)$$

onde, y_{ijk} corresponde à resposta de nível i na repetição j , μ corresponde à média geral, α_i corresponde ao efeito de cada nível i e ε_{ij} ao erro do nível i na repetição j . Para maiores detalhes

sobre os procedimentos matemáticos utilizados nos cálculos de Projetos de Experimentos recomenda-se a consulta a (MONTGOMERY, 2001).

Para validar o modelo do Projeto de Experimentos devem ser satisfeitas alguns pressupostos: as observações devem ser adequadamente descritas pelo modelo, os resíduos devem ter distribuição normal e de forma independente, e a variância dos resíduos deve ser constante. Para a avaliação destes pressupostos foram utilizados os gráficos de histograma dos resíduos, a distribuição dos resíduos pelo valor ajustado da resposta e a análise dos resíduos por ordem de observação.

5 RESULTADOS E DISCUSSÃO

Os resultados são apresentados neste capítulo, onde foi avaliada a contribuição do modelo proposto em cada uma das situações propostas na correspondente metodologia. Em um primeiro momento, foi demonstrado a eficiência do sistema em identificar as contaminações do sinal pelo SFTD. Em seguida, foram analisados e discutidos os resultados do sistema tolerante a falhas com a utilização do sensor virtual, o qual proporciona a redução dos erros de caracterização do movimento decorridos após a contaminação. Em conjunto, cada uma das análises foi realizada através da comparação dos resultados gerados neste trabalho com os resultados obtidos por outros pesquisadores na área e de trabalhos anteriores do grupo de pesquisa do Laboratório IEE.

5.1 Resultados e Análise Estatística do SFTD

As respostas do funcionamento do SFTD foram analisadas a partir das matrizes de confusão das análises de degradação realizadas por sujeitos. Através da comparação de cada detecção das janelas deslizantes e o padrão utilizado na degradação do sinal, o qual foi baseado nos estudos de casos de canais contaminados, obteve-se a taxa de acerto e a taxa de resultados falso positivos dos canais. A taxa de falso positivos dos canais são referentes aos que não sofreram degradação e mesmo assim ocorreu detecção de janelas contaminadas. Assim, para cada dos 53 sujeitos avaliados, foram obtidos 80 resultados, as quais são provenientes das possíveis combinações entre cinco ruídos e 16 casos de estudo, sobre a taxa de detecção do SFTD. Os resultados da taxa de detecção pelo SFTD para cada contaminante e base de dados encontram-se na Tabela 13.

Tabela 13 Taxa acerto no reconhecimento de cada contaminante

Tipo de Contaminante	Taxa de Reconhecimento do SFTD		
	NinaPro Amputados	NinaPro Não Amputados	IEE
Interferencia de ECG	82,36 ± 19,40%	89,78 ± 13,84%	96,14 ± 5,67%
Interferencia de Linha de Energia	85,26 ± 18,78%	94,32 ± 11,14%	93,51 ± 15,82%
Artefatos de Movimento	96,42 ± 12,40%	99,91 ± 0,64%	99,14 ± 7,02%
Deslocamento de Eletrodos	99,99 ± 0,02%	100,00 ± 0,00%	99,93 ± 0,31%
Saturação	100,00 ± 0,00%	100,00 ± 0,00%	100,00 ± 0,00%

A Tabela 13 apresenta algumas diferenças obtidas na taxa de detecção pelo SFTD e o seu desvio padrão para cada tipo de contaminante analisado e base de dados. A taxa de acerto média geral de detecção do SFTD foi de $96,18 \pm 10,89\%$, superior a detecção obtida de $85,31 \pm 24,88\%$ no estudo de (MOURA; RUSCHEL; BALBINOT, 2018), mesmo com uma maior variabilidade de sujeitos. A taxa média falso positiva para os canais que não receberam contaminação artificial foi de $4,68 \pm 9,82\%$, uma redução em comparação ao obtido de $8,18 \pm 17,52\%$ no estudo de (MOURA; RUSCHEL; BALBINOT, 2018). Este aumento na taxa de detecção foi proveniente da análise dos resultados obtidos neste estudo preliminar, o qual observou a necessidade da caracterização do sinal através de outra característica de domínio da frequência conforme relatado previamente na correspondente metodologia. A troca da característica FDH pela MPF foi o que possibilitou identificar um maior número de ocorrências de contaminação, principalmente, para os ruídos de interferência de linha de energia e de ECG.

Entretanto, para compreender melhor os correspondentes resultados, foram analisadas as dispersões das taxas de detecção por contaminante, primeiramente, para todos os sujeitos analisados, apresentadas na Figura 23. A Figura 24 apresenta as dispersões separadamente para cada base de dados. Na Figura 24 (a), são apresentados os resultados da dispersão da taxa de acerto na detecção dos contaminantes pelo SFTD para a base do NinaPro de amputados. Na Figura 24 (b), estão representados as taxas de detecção para base do NinaPro de não amputados, e para base de dados do IEE na Figura 24 (c). Nestas figuras, os valores próximos a linha central do *boxplot* são os valores da mediana dos resultados, os valores próximos ao ponto são referentes aos valores médios da taxa de acerto e os símbolos de * indicam os *outliers* ou pontos de valores discrepantes.

A Figura 23 apresenta graficamente uma forma de visualizar a distribuição dos dados médios da taxa de detecção do SFTD, proporcionando uma perspectiva complementar comparativa do resultado para cada tipo de ruído. Analisando esta figura, pode-se concluir que a variabilidade das taxas de detecção para os ruídos de deslocamento de eletrodos e de saturação foram mínimas para todos os sujeitos. A variabilidade das taxas de detecção para o ruído de artefatos de movimento também foi mínima, porém apresentaram muitos casos com taxas discrepantes. Para os casos de interferência de ECG e linha de energia, além de apresentarem maior variabilidade dos dados, também apresentaram diversos valores discrepantes. Para compreender e analisar mais as diferenças de comportamento das interferências, foi necessário investigar mais as variações em cada caso, começando pela variável com relação a base de dados.

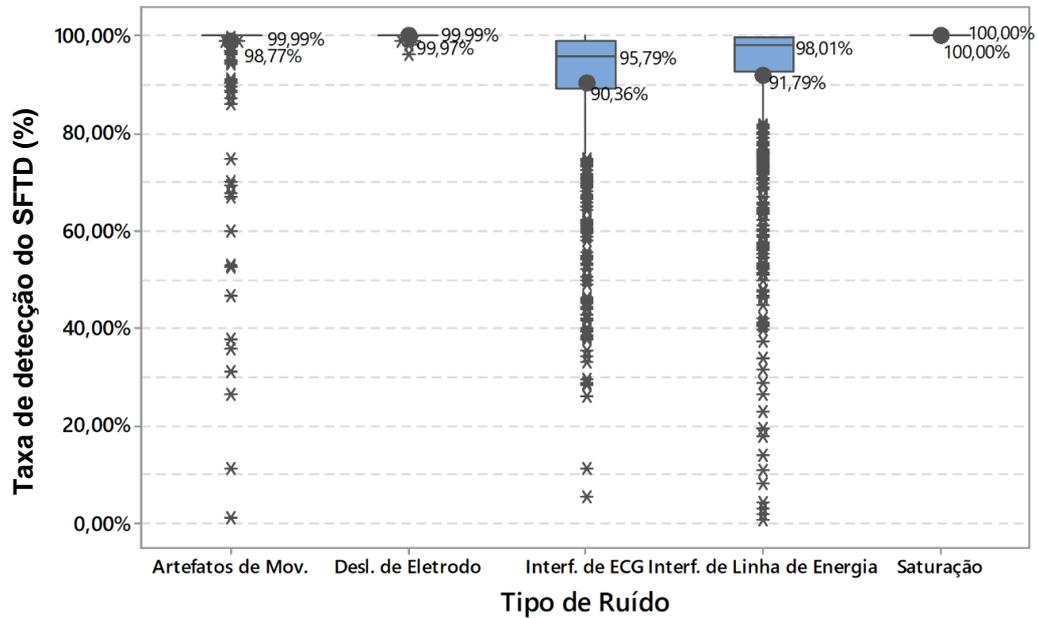


Figura 23 Dispersão da taxa de acerto média da detecção de contaminantes pelo SFTD para todos os sujeitos.

A Figura 24 (a), onde foi apresentada a dispersão para a base de dados do NinaPro de Amputados, comparando com a base de dados do NinaPro Não Amputados na Figura 24 (b) e a base de dados do IEE na Figura 24 (c), apresentou maior variabilidade das taxa de detecção para as interferências de ECG e linha de energia, como também, foi com a base de dados, que ocorreu a maioria dos valores discrepantes para o ruído de artefatos de movimento. Os sujeitos amputados sempre apresentam maior variabilidade nas características, seja para a classificação de movimentos, ou como ocorreu para a detecção de contaminantes no sinal de sEMG. Cada sujeito possui uma ativação muscular única, porém, para os sujeitos amputados, são apresentadas diversas outras dificuldades com relação ao posicionamento cirúrgico dos músculos após a amputação. Assim, os procedimentos de transferência seletiva de nervos residuais aos músculos perto do membro amputado, criando deste modo, locais de sinal adicionais que podem ser usados para controlar uma prótese, auxiliam na redução destas variabilidades de caracterização.

Quanto as dispersões de taxa de acerto na detecção dos ruídos de interferência de linha de energia e ECG pelo SFTD, referente as bases de dados do NinaPro não amputados e do IEE, é possível que os erros tenham ocorrido nos períodos das ativações musculares, sendo as interferências disfarçadas pelos movimentos. As janelas de movimentos representam menos de 60% do total de janelas avaliadas. Portanto, é possível concluir que estes casos podem não reduzir a taxa de classificação dos movimentos e estes erros de detecção ocorreriam para 30% das janelas de movimentos avaliadas.

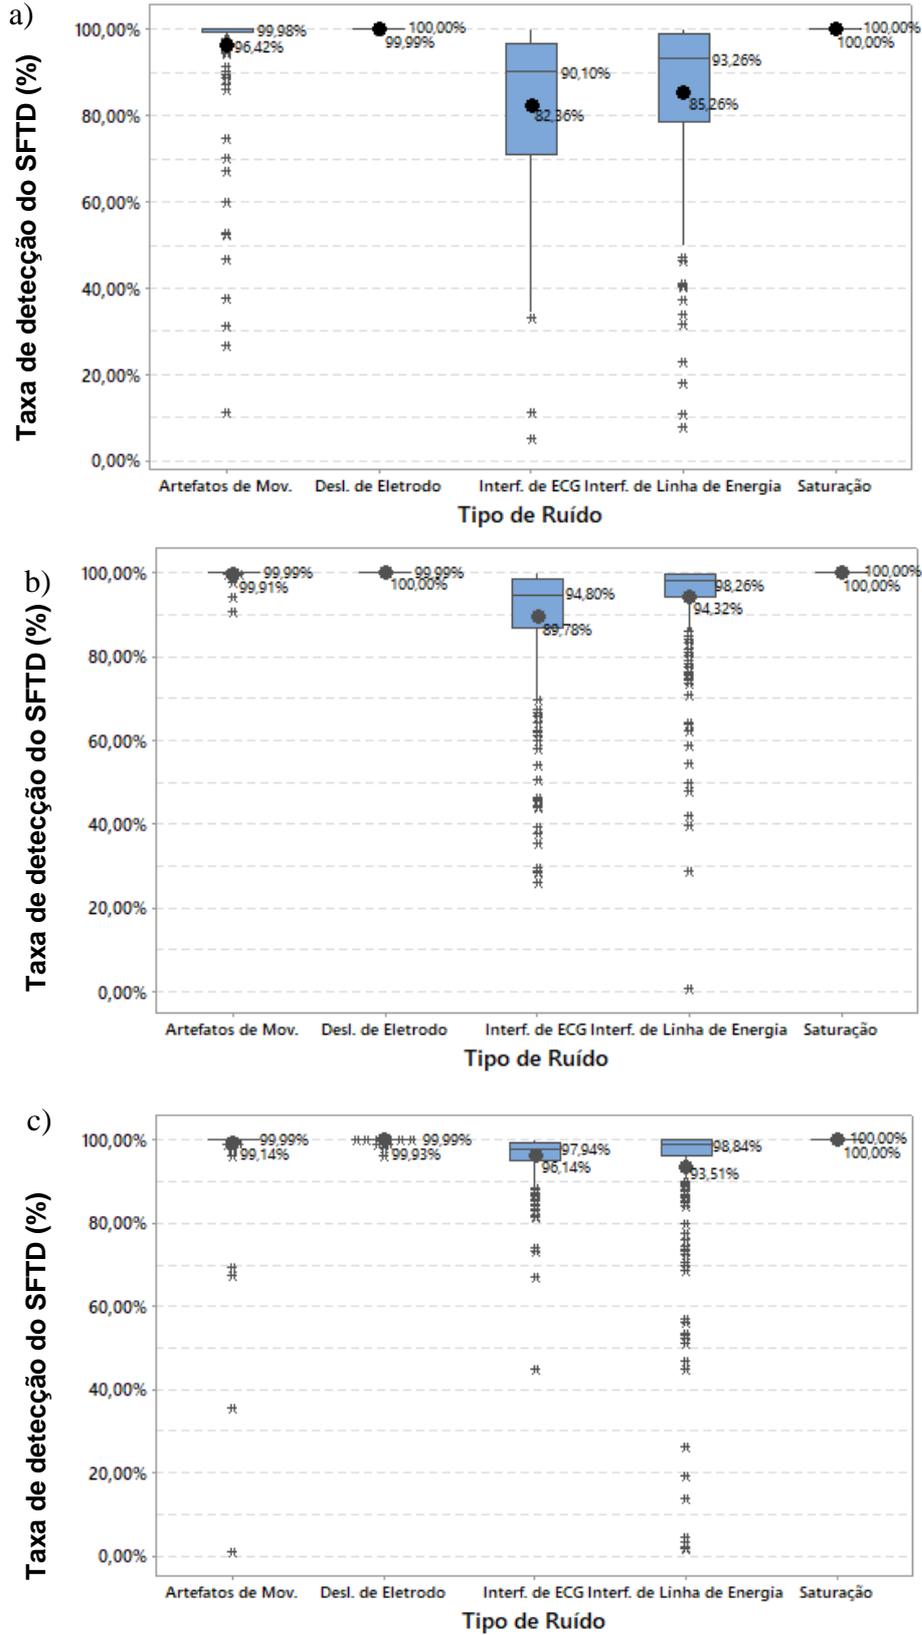


Figura 24 Dispersão da taxa de acerto média da detecção de contaminantes pelo SFTD para (a) base NinaPro de amputados, (b) base NinaPro de não amputados e (c) base do IEE.

Em uma primeira análise, pode-se concluir que o STFD apresenta maior variabilidade na taxa de detecção para os ruídos de artefatos de movimento, interferência de ECG e de linha de energia. Entretanto, para analisar de forma mais aprofundada as correspondentes diferenças foi necessária uma análise estatística com base no Projeto de Experimentos do Tipo Fatorial Completo e sua correspondente comparação múltiplas de médias para a obtenção de mais informações sobre os resultados, tendo como variável de resposta a taxa de detecção do SFTD e como fatores controláveis a variação da base de dados, combinações de estudos de caso de contaminação de canais e tipos de ruídos. Assim, foi possível avaliar a influência de cada fator e suas interações, bem como suas consequências na taxa de detecção da contaminação do sinal.

Na análise estatística, as médias dos resultados são significativamente diferentes se os intervalos forem separados. Se os intervalos se sobrepuserem, eles não serão significativamente diferentes. O cálculo do projeto, na Tabela 14, para o experimento de três fatores mostrou que as principais variações dos fatores quanto as bases de dados, estudos de casos de contaminação de canais e dos tipos de ruídos contaminantes são significativos, ou seja, as variações dos três principais efeitos são diferentes. As interações entre os fatores controláveis também são significativas, devido ao valor P ser pequeno e menor que o teste de valor de F.

Tabela 14 Cálculo do Projeto de Experimentos da análise da taxa de detecção do SFTD para variação da base de dados, estudos de contaminação e tipos de ruídos

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Bases de Dados (Fator A)	1,6377	2	0,81886	96,05	0,0
Estudos de Casos de Contaminação de canais (Fator B)	1,3642	15	0,09094	10,67	0,0
Tipos Ruídos (Fator C)	8,5997	4	2,14993	252,18	0,0
Interação AB	0,4696	30	0,01565	1,84	0,004
Interação AC	2,1238	8	0,26547	31,14	0,0
Interação BC	1,8964	60	0,03161	3,71	0,0
Interação ABC	1,2195	120	0,01016	1,19	0,078
Erro	34,1019	4000	0,00853		
Total	50,2316	4239			

Entretanto, para garantir a análise das diferenças significativas entre os fatores, é necessário que certos pressupostos sobre o modelo do Projeto de Experimentos proposto sejam satisfeitos: as observações sejam adequadamente descritas pelo modelo, os resíduos sejam distribuídos normalmente e de forma independente, e a variância seja constante. Através do

histograma dos resíduos, é possível determinar se os dados são assimétricos ou se contêm *outliers*, que são valores de dados que estão longe de outros valores de dados e podem afetar fortemente seus resultados, prejudicando as conclusões na análise. Na Figura 25 (a), observa-se que há *outliers* e os resíduos possuem distribuição normal simétrica com média aproximadamente em zero. Assim, o tamanho amostral dos dados satisfaz a validação do modelo do Projeto de Experimentos, ou seja, os resultados não são substancialmente afetados pelos desvios da normalidade.

Os resíduos foram analisados para verificação dos pressupostos quanto a distribuídos aleatoriamente destes e se a variância se apresenta constante através da observação da distribuição dos resíduos pelo valor ajustado da resposta (taxa de detecção do SFTD), a qual deve ocorrer aleatoriamente sem nenhum padrão reconhecível e com amplitude constante. Na Figura 25 (b), apresenta-se o comportamento dos resíduos pelo valor ajustado da resposta. Observa-se que a variância é reduzida na faixa positiva, um comportamento esperado, pois não há resultados acima de 100%. Então, a pressuposição da variância ser constante é violada. Entretanto, segundo o autor de (MONTGOMERY, 2001), nestes casos onde a suposição de homogeneidade das variâncias é violada, os resultados do teste F são apenas ligeiramente afetados para modelos de amostras de tamanhos iguais em todos os fatores. Então, conclui-se que sempre será violada esta pressuposição para a variância para amostras com definição de limite máximo e médias próximas a este limite. Além disso, as hipóteses de que para os fatores ou interações, que o valor de $p(0,0)$ é obtido ou que o valor de F seja muito superior ao valor de P, sempre são consideradas significativas. Assim, a interação dos três fatores ($F = 1,19 > P\text{-valor} = 0,078$) sugere não ser significativa e deve ser analisada as interações entre os fatores graficamente. Isso pode ser decorrente das altas taxas de detecção dos ruídos de saturação e deslocamento de eletrodos, as quais possuem mínima dispersão dos dados e desvio padrão aproximadamente 0,0 para as bases de dados.

Por último, foi verificado o pressuposto quanto à análise dos resíduos por ordem de observação. Esta verificação deve apresentar os resíduos de forma independentes um do outro, ou seja, não podem apresentar nenhuma tendência ou padrão quando exibidos em ordem de tempo. A Figura 25 (c) não apresenta nenhuma razão para suspeitar de qualquer violação da correlação entre os dados analisados. É importante notar que as taxas de detecção são avaliadas para cada ruído separadamente, ou seja, as primeiras 848 observações são referentes as detecções obtidas para o ruído de deslocamento de eletrodos, seguido por interferência de linha de energia, saturação, artefatos de movimentos e interferência de ECG.

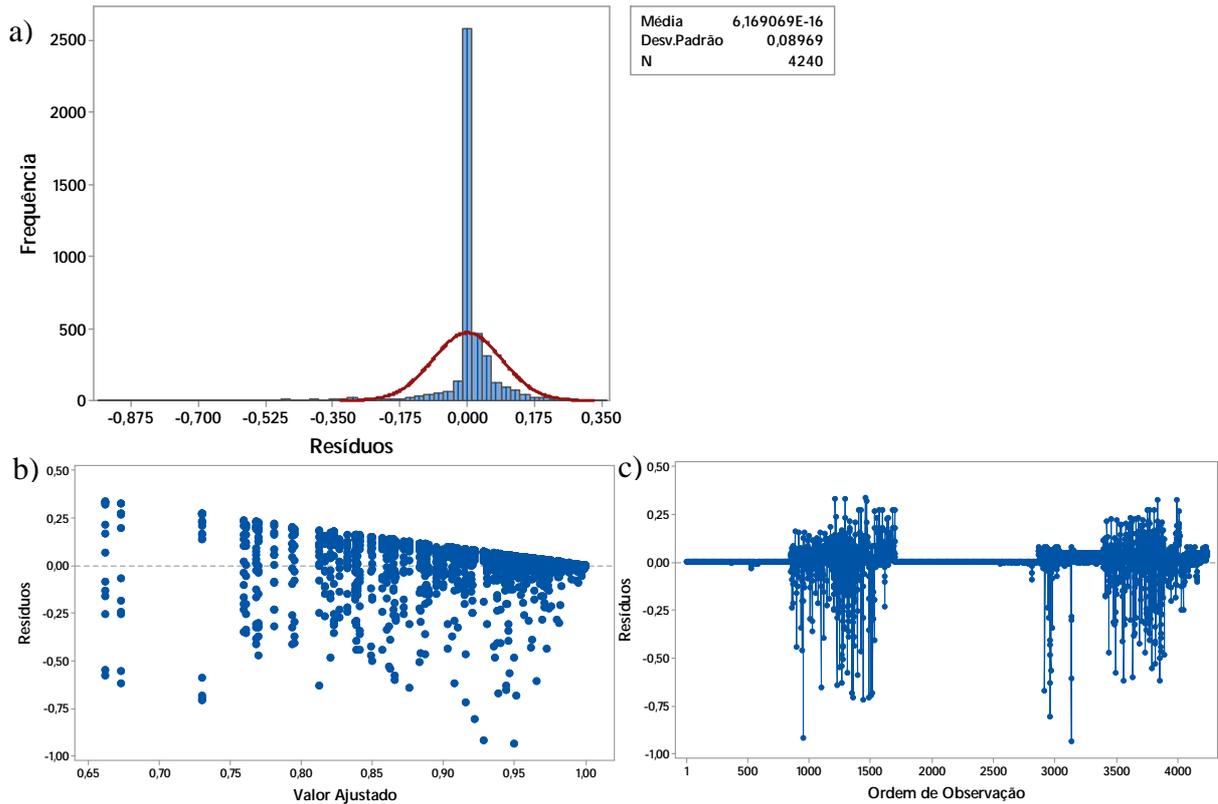


Figura 25 Gráfico de validação do Projeto de Experimentos para taxa de detecção do SFTD quanto aos fatores de variação da base de dados, estudos de contaminação e tipos de ruídos: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

A análise da potência estatística do Projeto de Experimentos pode proporcionar duas determinações sobre este projeto. A primeira resposta obtida com esta análise é a máxima diferença entre as médias de significância das amostras, ou seja, o percentual mínimo das diferenças das taxas de detecção considerado significativamente diferentes. Esta análise da potência estatística também pode proporcionar uma avaliação da probabilidade da rejeição da hipótese contrária à obtida com o projeto de experimentos. Esta análise é afetada pelo tamanho da amostra, valor de potência mínima desejada e o desvio padrão do projeto. O tamanho da amostra e desvio padrão deste projeto são, respectivamente, 13 e 0,092358. Em geral, um valor de potência acima de 0,8 é considerado adequado. Para o valor de 0,8, a máxima diferença detectável de significância das amostras foi de 4,06%, conforme pode ser visualizado na Figura 24. Assim, para variações acima de 4,06%, é possível considerar que as variações entre os fatores controláveis são significativas. Se considerar a potência estatística ideal de 0,95 conforme o intervalo de confiança utilizado no Projeto de Experimentos, a máxima diferença detectável passaria a 4,55%. Ou seja, existe uma certeza de no mínimo 95% das conclusões obtidas pela análise da inferência estatística avaliada pelo Projeto de Experimentos.

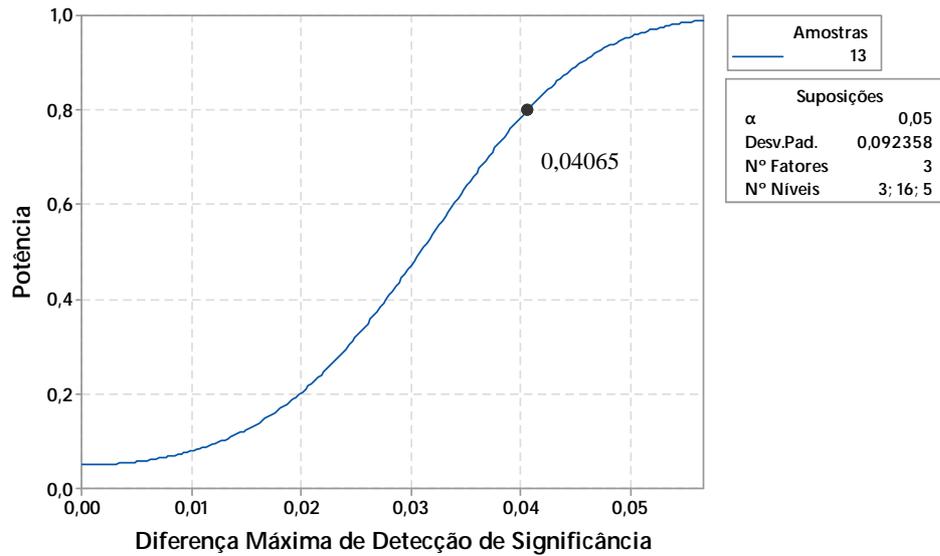


Figura 26 Curva da Potência Estatística do projeto de experimentos para a taxa de detecção do SFTD.

A análise de interações entre os fatores de estudos de casos de degradação de canais e tipos de ruídos apresentaram que as menores taxas de detecção envolvem principalmente a degradação do canal 12 e as taxas médias obtidas para os ruídos de interferências de ECG e linha de energia para todos os sujeitos, como pode ser visto na Figura 27. A redução da taxa de detecção para a degradação do canal 12, que corresponde ao eletrodo posicionado no tríceps, e no caso 14 que corresponde a degradação dos canais 11 e 12 pode ser justificado pelos canais posicionados em músculos com menor representatividade de ativação muscular nesses movimentos apresentando maior dificuldade na detecção.

Os resultados apresentados ainda na Figura 27 sugerem que as diferenças de taxa de detecção entre estes dois fatores são apenas significativas quanto aos casos de degradação dos canais 11, 12, 13, 14, 15 e 16 para os ruídos de interferência de ECG e linha de energia. Logo, para as demais interações, as taxas médias de detecção pelo SFTD foram superiores e com média de 100% para os ruídos de saturação e deslocamento de eletrodos para todos os sujeitos independente do canal degradado. Conseqüentemente, as taxas de detecção obtidas com artefatos de movimento são em média 1,5% inferiores independente do canal degradado. Portanto, a taxa de detecção pelo SFTD abrange quase 100% das janelas independente do canal ou combinações de canais contaminados para os ruídos de saturação, deslocamento de eletrodos e artefatos de movimento em média para todos os sujeitos avaliados.

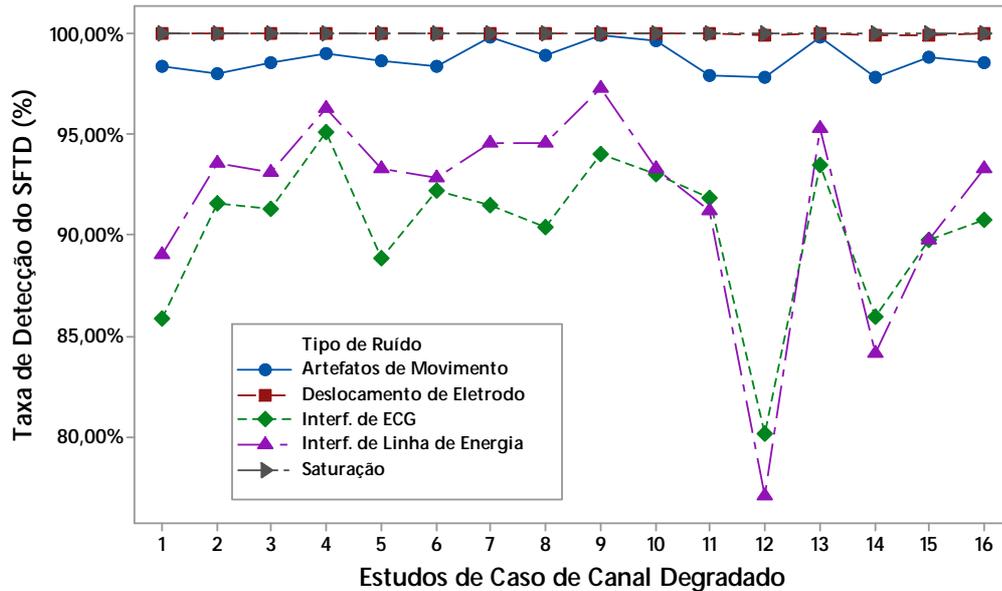


Figura 27 Taxa de detecção do SFTD na interação de estudos de caso de degradação de canais e tipos de ruídos para todos os sujeitos.

Na Figura 28, é apresentado um detalhamento da taxa de detecção do SFTD na interação dos fatores dos estudos de caso de canais degradados e tipos de ruídos para cada base de dados. A taxa de detecção do SFTD na interação de estudos de caso de degradação de canais e tipos de ruídos para bases de dados do NinaPro não amputados é apresentada na Figura 28 (a), a base de dados do NinaPro amputados na Figura 28 (b) e a base de dados do IEE na Figura 28 (c). Assim, foi analisado as interações dos três fatores controláveis: bases de dados, tipos de ruído e estudos de casos de degradação de canais. Observa-se que as interações dos ruídos de artefatos de movimento, Interferência de ECG e linha de energia apresentam taxas de detecção significativamente diferentes para cada base de dados. Existe uma semelhança entre as bases de dados quanto apresentam menores taxas de detecção para os estudos de caso 12 e 14 de degradação de canais para a interferência de linha de energia. Para a interferência de ECG, são obtidas menores taxas de acerto apenas quando avaliadas as bases de dados do NinaPro. Assim, conclui-se que dependendo da base de dados, a taxa de detecção do SFTD para os ruídos de artefatos de movimento, interferência de ECG e linha de energia terá uma diferença significativa. Como também, poderá apresentar diferença significativa dependendo do canal degradado.

Ainda analisando os resultados obtidos para cada base de dados, a detecção do ruído de interferência de linha de energia foi significativamente afetada dependendo do caso de contaminação de canais para todas as bases de dados avaliadas. A taxa de detecção do ruído de interferência de ECG também foi afetada dependendo do caso de contaminação de canais para todas as bases de dados avaliadas, porém com menor variação para base de dados do IEE.

Portanto, é possível que o sistema de aquisição dos sinais de sEMG também seja significativo quando relacionado a detecção do ruído de interferência de ECG.

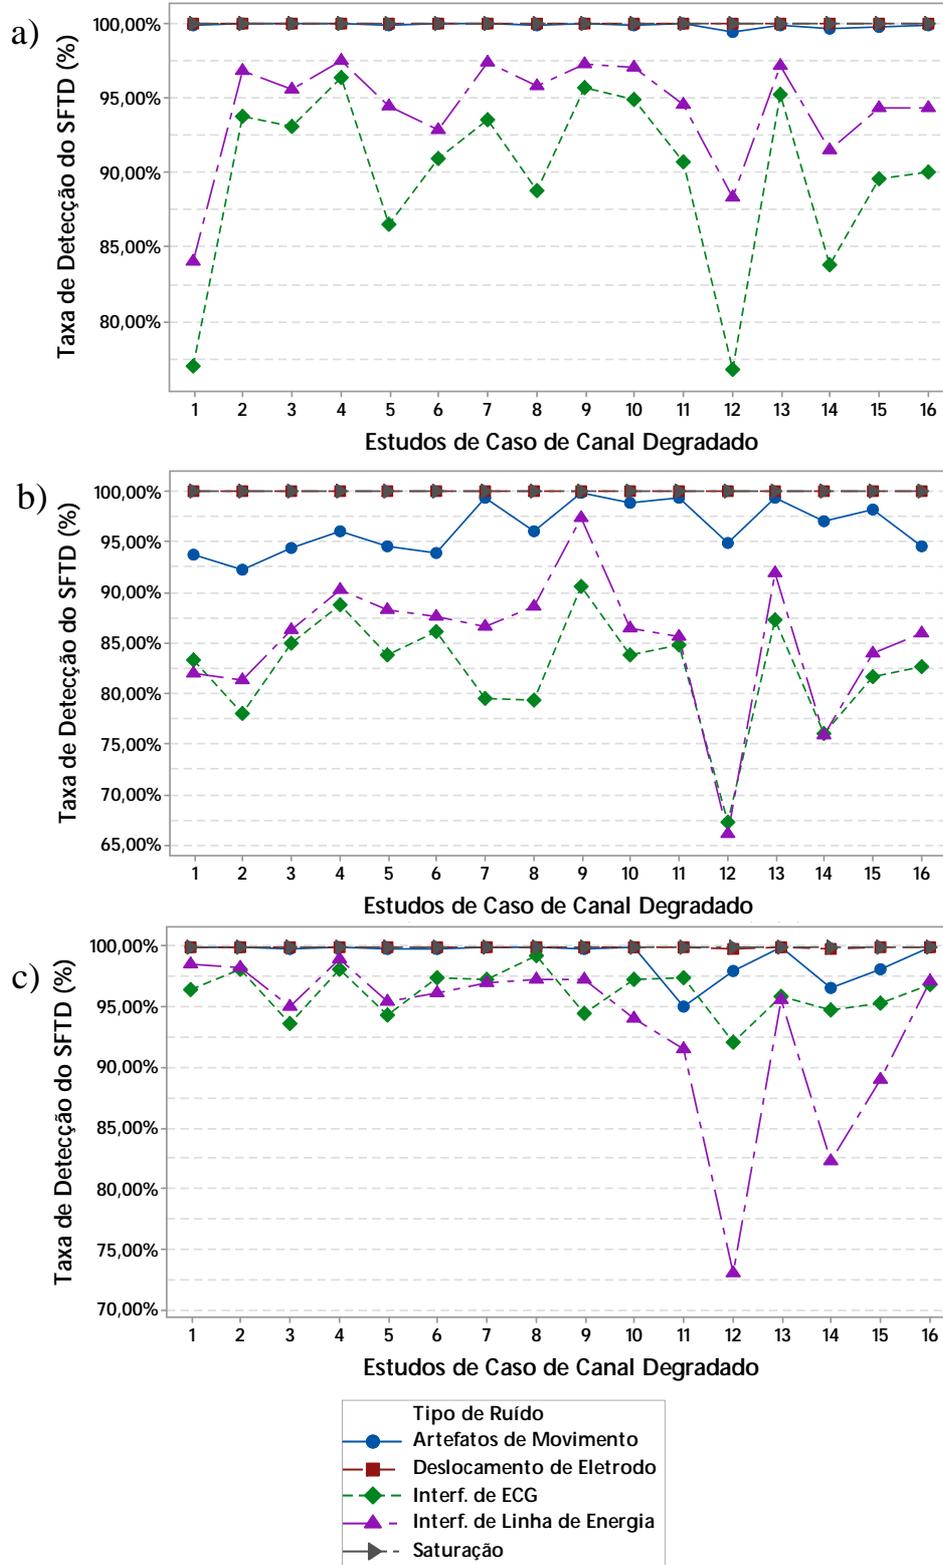


Figura 28 Taxa de detecção do SFTD na interação de estudos de caso de degradação de canais e tipos de ruídos para: a) Bases de dados do NinaPro não anputados; b) Base de dados do NinaPro amputados e c) Base de dados do IEE.

Nas Figura 40 e Figura 41 no Apêndice A - Resultados , está disponível para consulta as demais apresentações gráficas das interações entre os fatores da ANOVA. Todas as apresentações gráficas reforçam que as interações entre os fatores são significativamente diferentes através dos cruzamentos entre os fatores para a taxa de detecção do SFTD. Assim, para cada análise realizada para as três bases de dados, foi obtido uma taxa média de detecção significativamente diferente com uma tendência a reduzir na taxa de detecção para o canal 12 degradado. Todavia, foram obtidas taxas de detecção significativas para testar em conjunto com o sistema adaptativo de classificação de movimentos, utilizando as características MAV, RMS, WL, PWR, MFL, FMD, SKW e MPF.

A alteração da característica MPF proporcionou, através da média dos três maiores picos de frequência do sinal, auxiliar na identificação dos contaminantes de interferência de linha de energia e de ECG em comparação aos resultados preliminares de (MOURA; RUSCHEL; BALBINOT, 2018). Além disso, a alteração na identificação da presença de contaminante em mais de 50% do sinal nos últimos 3 s analisados proporciona um acionamento do sensor virtual para a ocorrência da presença de ruído com duração menor que 1,5 s sem reduzir as taxas de acerto da detecção pelo SFTD. Portanto, indiferente à inserção linear dos contaminantes para a simulação, o método de detecção apresentado pelo SFTD obteve uma solução adequada para identificação de contaminantes no sinal de sEMG com taxas de detecção acima de 80% na média para todos os ruídos. Entretanto, algumas relações de diferentes SNRs podem ainda serem estudas com o objetivo de reduzir a variabilidade de detecção para os ruídos de interferência de linha de energia e de ECG dependendo do canal contaminado e quanto as bases de dados.

5.2 Sistema Adaptativo com Sensor Virtual

A taxa de acerto média de classificação com os sinais íntegros obtidas em outros estudos, que também utilizaram o banco de dados NinaPro, foram de 46,27% a 77,48%, como pode ser visto na Tabela 15. No estudo de (ATZORI *et al.*, 2015), vários classificadores foram comparados quanto a caracterização dos 50 movimentos da base de dados do NinaPro, o classificador SVM RBF atingiu aproximadamente 75 % de taxa de acerto. No estudo de (GIJSBERTS *et al.*, 2014) com apenas sujeitos não amputados, foi obtido uma taxa de acerto média de 77,48%. O estudo de (ZHAI *et al.*, 2016) com sujeitos não amputados obteve 64,71% de taxa de acerto média. No estudo de (ATZORI; COGNOLATO; MÜLLER, 2016), foram obtidas as taxas de acerto de 75% para sujeitos não amputados e de 46,27% para sujeitos amputados com SVM Linear. Outro estudo de (CENE; BALBINOT, 2016) com Regressão

Logística atingiu 61,9% de taxa de acerto para os sujeitos amputados, porém o estudo desconsiderou o sujeito com pior caso de amputação da correspondente base de dados avaliada.

A taxa de acerto média da classificação do sinal íntegro obtido com o classificador SVM RBF desenvolvido neste trabalho foi de $74,62 \pm 13,11\%$ para os 20 sujeitos não amputados e de $55,02 \pm 19,70\%$ para os 13 sujeitos com amputação da base de dados do NinaPro. Para base de dados de 20 sujeitos do IEE, a taxa de acerto média obtida foi de $77,73 \pm 16,67\%$. A validação da classificação de referência para a análise da contribuição do sistema adaptativo proposto foi realizada através da comparação com as configurações de classificação dos estudos relatados na Tabela 15. Estes outros estudos envolvem as bases de dados das bases do NinaPro ou do IEE, porém avaliaram uma maior quantidade de movimentos, de sujeitos, ou ambos. No entanto, como relatado anteriormente, devido aos diferentes movimentos do braço selecionados e diferentes formas de analisar e apresentar os resultados, é essencial uma base de classificação para comparação (VEER, 2015).

Portanto, comparando os resultados de classificação para os sujeitos não amputados da base de dados do NinaPro foi obtido uma taxa de acerto média em até 3 % menor neste trabalho. A máxima diferença foi obtida comparando com o trabalho de (GIJSBERTS *et al.*, 2014), porém, neste trabalho, foram avaliados a metade dos sujeitos e menor número de movimentos, utilizando tamanho de janelas deslizantes em 100 ms menor. Para base de dados de sujeitos amputados, foi obtido uma taxa de acerto média de 9% superior ao artigo (ATZORI; COGNOLATO; MÜLLER, 2016) com segmentação por janelas deslizantes e quase 7% inferior a um artigo (CENE; BALBINOT, 2016) com segmentação por *timestamp*. Entretanto, foram avaliados 2 e 3 sujeitos amputados a mais em comparação a cada artigo respectivamente. A taxa de acerto média com a base do IEE foi 3,5 % maior que o trabalho de (CENE; BALBINOT, 2016), contudo a segmentação por *timestamp* deveria proporcionar maior taxa de acerto, logo a diferença pode estar com relação ao classificador utilizado. Considerando que as pequenas diferenças relatadas são causadas principalmente pela diferença de sujeitos e em segundo pelas características, classificador e segmentação utilizadas, fatores avaliados como significativos na classificação dos movimentos, conclui-se que as taxas de acerto obtidas neste estudo são válidas para comparação e análise do novo método proposto. Porém, é importante ressaltar que, normalmente, os artigos não definem especificamente como são calculadas cada taxa de acerto.

Tabela 15 Comparação de alguns trabalhos com a base de dados do NinaPro

Autor	Classificador Utilizado	Processo de Segmentação	Características	Número de Eletrodos	Movimentos avaliados	Número de Voluntários	Taxa de acerto média (%)
(ATZORI <i>et al.</i> , 2015)	LDA, K-NN, RNA e SVM RBF	Janela deslizante (400ms e delimitador 10 ms)	MAV, VAR, WL, <i>histogram</i> , <i>marginal Discrete Wavelet Transform (mDWT)</i> separadamente	12	50 Mov.	40 Não amputados e 11 Amputados	Aproximadamente 75% para SVM RBF
(GIJSBERTS <i>et al.</i> , 2014)	<i>Kernel Regularized Least Squares</i>	Janela deslizante (400ms e delimitador 10 ms)	RMS, <i>histogram</i> , <i>mDWT</i> e média	12	50 Mov.	40 Não amputados	77,48%
(ZHAI <i>et al.</i> , 2016)	SVM Linear	Janela deslizante (200 ms e 100 ms de incremento)	RMS	12	17 Mov. Sem repouso	40 Não amputados	64.71%
(ATZORI; COGNOLATO; MÜLLER, 2016)	<i>random Forests</i> , SVM Linear, K-NN e LDA.	Janela deslizante (200 ms e 100 ms de incremento)	<i>mDWT</i> , <i>Histogram</i> , WL e RMS	12	50 Mov.	40 Não amputados e 11 Amputados	75,27 ± 7,89% para suj. não amputados com <i>random Forests</i> e 46,27 ± 7,89% para os suj. amputados com SVM.
(CENE; BALBINOT, 2016)	Regressão Logística	<i>timestamp</i>	RMS, VAR e FMD	12	17 Mov. Sem repouso	30 NinaPro Não Amputados e 20 Não Amputados IEE	NinaPro Não Amputados (74,3%), NinaPro Amputados (61,9%) e Não Amputados IEE (74,2%)

A Figura 29 apresenta a taxa de acerto média de classificação para todos os 16 casos de contaminação. Pode-se perceber que cada tipo de contaminação proporciona uma taxa diferente de degradação na classificação (legenda 2) em comparação com a classificação do sinal íntegro (legenda 1). Algumas contaminações afetam mais expressivamente a taxa de acerto que outras, como saturação e deslocamento de eletrodos. Nestes casos de contaminação, a substituição do sinal contaminado pelos sinais modelados com TVARMA (legenda 4) e TVK (legenda 6) recuperou respectivamente por volta de 45% e 30% da taxa de acerto da classificação para sujeitos não amputados e de 30% e 22% para sujeitos amputados. Para contaminação por artefatos de movimento, interferência de ECG e linha de energia, o sinal contaminado substituído pelos modelos de sensor virtual apenas reduziram a taxa de acerto em comparação a classificação com o sinal contaminado. Portanto, manter o sistema de classificação com o sinal contaminado com os ruídos de artefatos de movimento, interferência de ECG e linha de energia obtém maiores taxas de acerto em média para os casos analisados. A relação de características extraídas do sinal foi suficiente para a taxa de acerto do classificador não ser reduzida demasiadamente em ruídos com menor SNR, obtendo em uma taxa média até 22% menor que a classificação original.

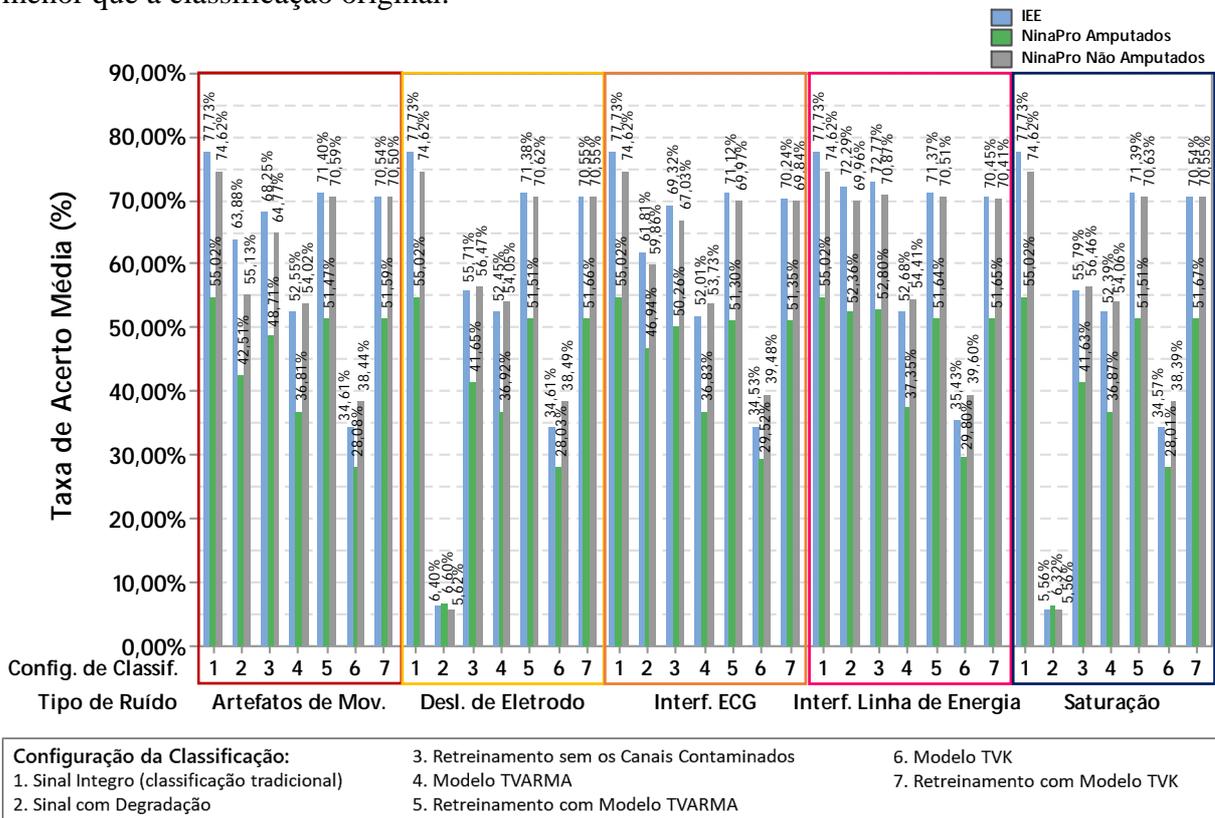


Figura 29 Comparação da taxa de acerto para cada configuração de classificação e para cada tipo de ruído com a classificação de sinal íntegro de sEMG.

Ainda na Figura 29, foi possível observar que os métodos de retreinamento do classificador, utilizando os modelos do sensor virtual (legendas 5 e 7), proporcionaram taxas de acerto média com recuperações em até aproximadamente 5 % abaixo da classificação com sinal íntegro. Entretanto, comparando as configurações com retreinamento do classificador, para a contaminação de interferência de linha de energia, o retreinamento sem os canais contaminados (legenda 3) proporcionou maior taxa de acerto média que o retreinamento com o sinal do sensor virtual. Assim, é possível concluir que a seleção de maior taxa de acerto média na configuração de classificação pode ser significativamente dependente do tipo de degradação. Isso deverá ser analisado estatisticamente. Esta possível dependência para cada tipo de ruído sugere que o sensor de detecção de falha poderia ser alterado para detectar níveis de SNR distintos e acionar uma configuração de classificação conforme cada nível.

A Figura 30 apresenta o desvio padrão para cada configuração de classificação considerando todos os 16 casos de contaminação. Nesta figura, é possível observar que as configurações de classificação com a substituição do sinal contaminado pelo modelado do sensor virtual apresentam um maior desvio padrão de até 37,19% para todos os tipos de ruídos. É importante observar que, nos casos de contaminação por deslocamento de eletrodos e saturação, o desvio padrão da classificação com retreinamento sem o canal contaminado foi maior que as demais configurações. Este desvio padrão sugere que o modelo de classificação com retreinamento sem o canal contaminado desenvolvido neste trabalho, com o objetivo de comparar com sistema adaptativo proposto, pode não ser comparável aos modelos semelhantes apresentados na literatura científica. Nas discussões apresentadas na seção 5.3 Discussão em Relação a Outros Estudos Semelhantes, foi aprofundado um detalhamento das limitações desta metodologia de retreinamento desenvolvida.

Além disso, lembrando que a classificação com a substituição do sinal pelo sensor virtual de modelo TVARMA apresentou uma diferença de até 5% na taxa de acerto média com a configuração de retreinamento sem o canal degradado. Estas duas configurações de classificação apresentaram maiores desvios padrão para os ruídos de saturação e deslocamento de eletrodos, ou seja, a diferença na taxa de acerto de até 5% superior pode não ser significativa para estes casos. Assim, também é importante ressaltar que as classificações com retreinamento com o sinal contaminado substituído pelo sinal do sensor virtual (legendas 5 e 7), obtiveram menores desvios padrões em todas as configurações após a contaminação dos sinais. Isso pode significar que estas configurações de classificação proporcionam taxa de acerto e desvio padrão similares à classificação com o sinal íntegro ao retreinar os classificadores com os modelos do sensor virtual.

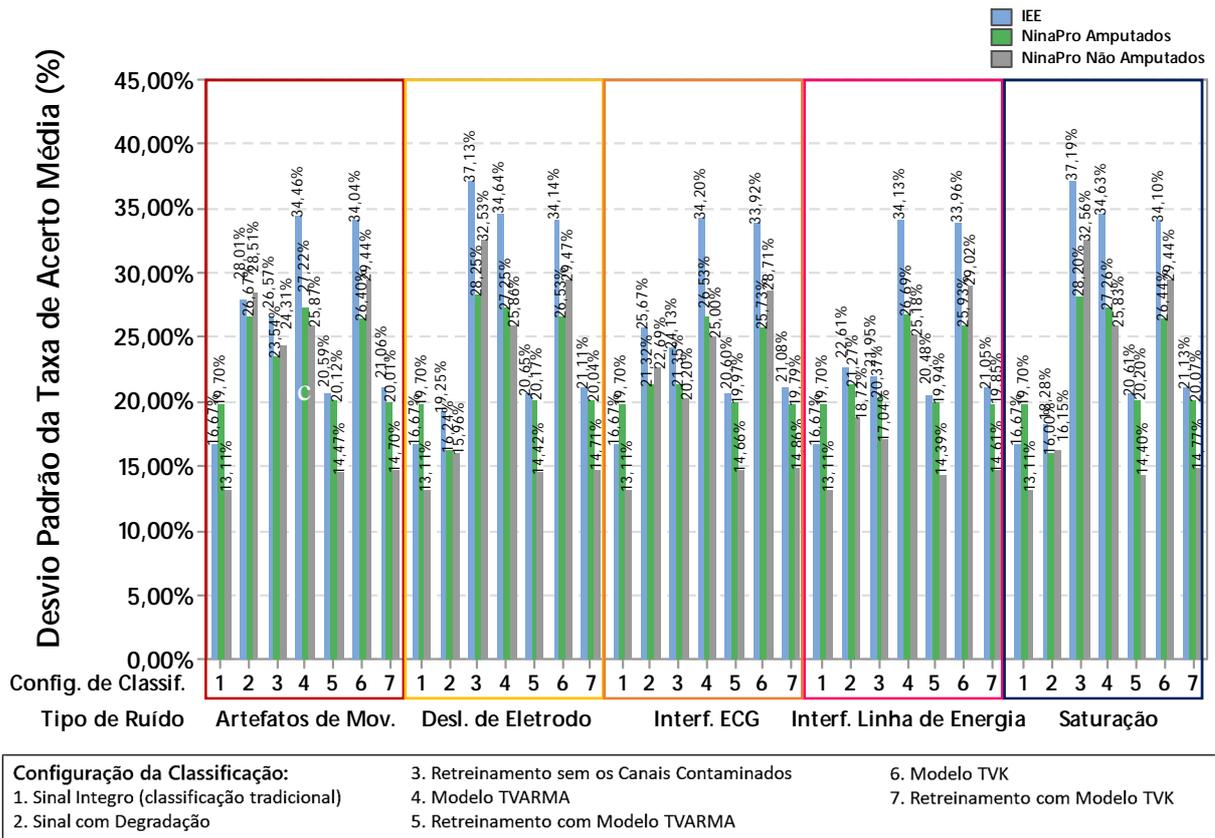


Figura 30 Comparação do desvio padrão para cada configuração de classificação e para cada tipo de ruído com a classificação de sinal íntegro de sEMG.

Além da taxa de acerto média de classificação, os resultados foram analisados para mais três métricas de verificação da eficiência na classificação dos movimentos para cada base de dados. Relembrando as métricas adicionais especificadas anteriormente: taxa de erro para com o grupo de repouso $TE_{Repouso}$ (Equação (71)), com o mesmo grupo de movimentos TE_{IG} (Equação (72)), com grupo diferente de movimentos TE_{EG} (Equação (73)).

As taxas de acerto média e as taxas de erros entre movimentos das configurações de classificação para os 18 movimentos são apresentadas na Figura 31 quanto a base de dados do NinaPro de não amputados, na Figura 32 quanto a base de dados do NinaPro de amputados e na Figura 33 quanto a base de dados do IEE. Na Figura 31 (a), os resultados da taxa de acerto por movimento apresentaram uma sobreposição das configurações de retreinamento entre os modelos de sensor virtual para todos os movimentos e apresentou um cruzamento entre as taxas de acerto obtidas com o sinal degradado e com o sinal substituído pelo modelo TVK. Na Figura 31 (b), foi observado que o movimento de repouso é confundido principalmente com os movimentos 2, 8 e 16 para a base de dados do NinaPro não amputados. Como são movimentos distintos, estes erros podem ser causados pela falta de relaxamento muscular durante o repouso,

ou por erros do sujeito ao replicar o movimento, ou ainda em decorrência do ajuste da segmentação a partir do *timestamp* dos vídeos não abranger a identificação de movimentos executados com mais de 3s após o estímulo visual.

Na Figura 31 (c), é possível visualizar que as taxas de erro entre os movimentos do grupo C e D são maiores com relação ao mesmo grupo de movimentos. Portanto, em um funcionamento *on-line*, este erro de classificação poderia ser corrigido através do *feedback* do movimento. Esta relação de erros no mesmo grupo sugere que o posicionamento dos eletrodos em conjunto das características extraídas do sinal e o modelo do sinal não proporcionam a substituição adequada dos sinais quando contaminados para estes grupos de movimentos. Todavia, remover o canal contaminado e retreinar o classificador na média dos casos de degradação de canais analisados também apresentou maior taxa de erro que a classificação do sinal íntegro nestes movimentos. Assim, pode-se concluir que, para estes movimentos, os sinais de sEMG de cada eletrodo posicionado no braço proporciona uma informação singular, não correlacionada com outros canais, para a identificação destes movimentos pelo classificador SVM.

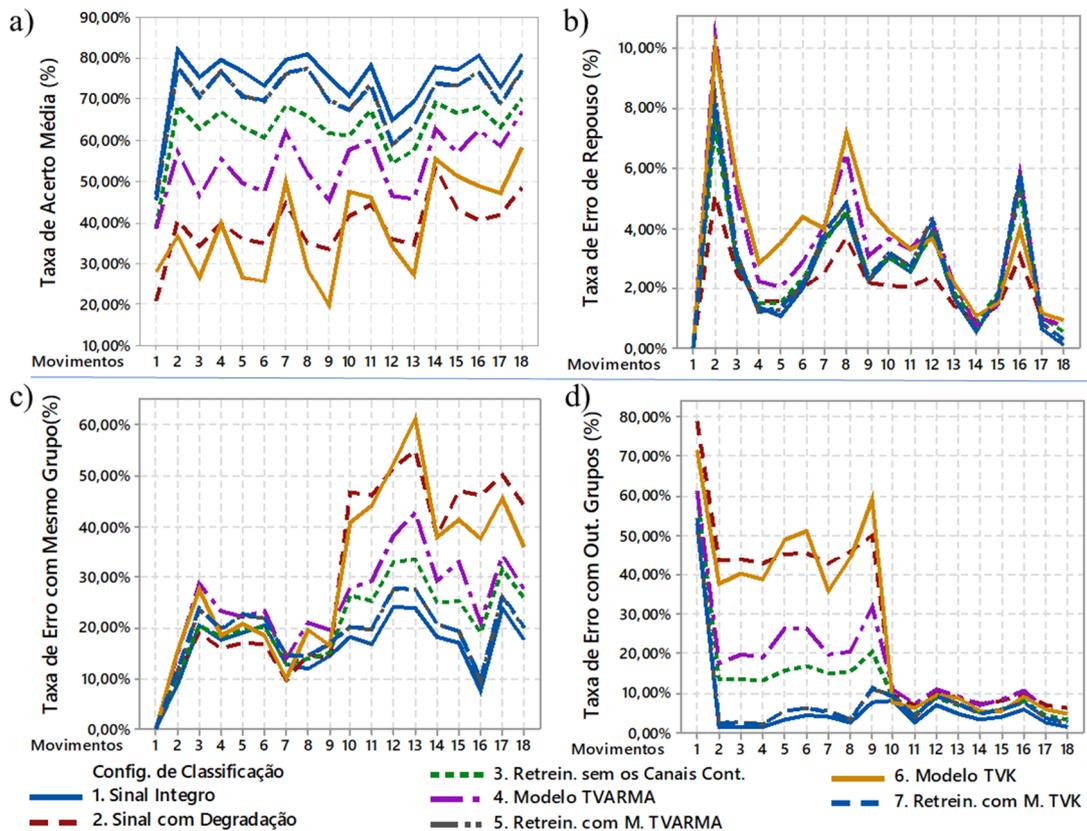


Figura 31 Taxas de acerto média e as taxas de erros entre movimentos das configurações de classificação para os 18 movimentos da base de dados do NinaPro de não amputados.

A Figura 31 (d) mostra que os movimentos do grupo B apresentaram a taxa de erro mais elevada para com os movimentos dos outros grupos. Portanto, isso reforça a conclusão que, também para estes movimentos, os sinais de sEMG de cada eletrodo posicionado no braço proporciona uma informação singular, não correlacionada com outros canais, para a identificação destes movimentos pelo classificador SVM. Neste caso ocorreu um erro de classificação crítico, visto que serão executados movimentos muito diferentes dos desejados através das configurações de classificação após o sinal contaminado na média dos casos analisados. Sendo assim, na média das configurações de classificação após a contaminação do sinal, sempre ocorre a perda de informações singulares que auxiliam na caracterização dos movimentos.

Ainda para a base de dados do NinaPro não amputados e analisando as taxas de erros com relação aos outros grupos de movimentos na Figura 31 (d), foi observado que a classificação com o sinal degradado e a classificação com o sinal contaminado substituído pelo modelo TVK proporcionaram maiores taxas de erro na média para os tipos de ruídos analisados. Este comportamento foi principalmente evidenciado para o grupo B de movimentos. Isso sugere que o modelo TVK não proporcionou um sinal adequado para a caracterização do grupo B de movimentos, já que apresentou piores resultados médios em alguns casos que a classificação com o próprio sinal contaminado. A configuração com retreinamento sem o canal degradado proporciona menor taxa de erro média entre movimentos que a configuração com o sinal contaminado substituído pelo modelo TVARMA, porém esta diferença deve ser avaliada individualmente para cada ruído devido as taxas de acerto médias apresentadas no início desta subseção. As configurações de classificação com o sinal íntegro e com retreinamento com os modelos de sensor virtual apresentaram menores taxas de erro entre os movimentos e com variações de aproximadamente 5% entre elas para cada movimento, podendo novamente concluir que as taxas de acerto e desvios padrão são similares para a classificação com o sinal íntegro e a classificação com retreinamento com os modelos do sensor virtual.

A Figura 32 apresenta algumas variações no comportamento da taxa de acerto média e taxas de erro para a base de dados do NinaPro de Amputados. A principal variação em relação aos sujeitos não amputados foi que a taxa de erro com o movimento de repouso é similar entre todos os movimentos para cada configuração de classificação e praticamente o dobro da taxa de erro máxima do que os sujeitos não amputados, como pode ser visualizado na Figura 32 (b). Este erro similar para todos movimentos é uma característica dos sujeitos não amputados devido a menor representatividade de ativação muscular nos movimentos em relação ao repouso.

Na Figura 32 (d), também foi possível observar a mudança do comportamento da configuração de classificação com a substituição do sinal contaminado pelo modelo TVARMA para o sensor virtual, que apresentou maior taxa de erro entre os movimentos de outros grupos, principalmente no caso do grupo B. Estas diferenciações podem ser justificadas novamente pela menor representatividade de ativação muscular nos canais dos sujeitos amputados, as quais proporcionaram uma menor variação ou singularidade de informação do sinal ao modelo do sensor virtual. Assim, foi apresentada maior dificuldade no reconhecimento dos movimentos em comparação ao repouso e dos movimentos finos dos dedos devido a uma generalização do sinal gerado com o modelo TVARMA.

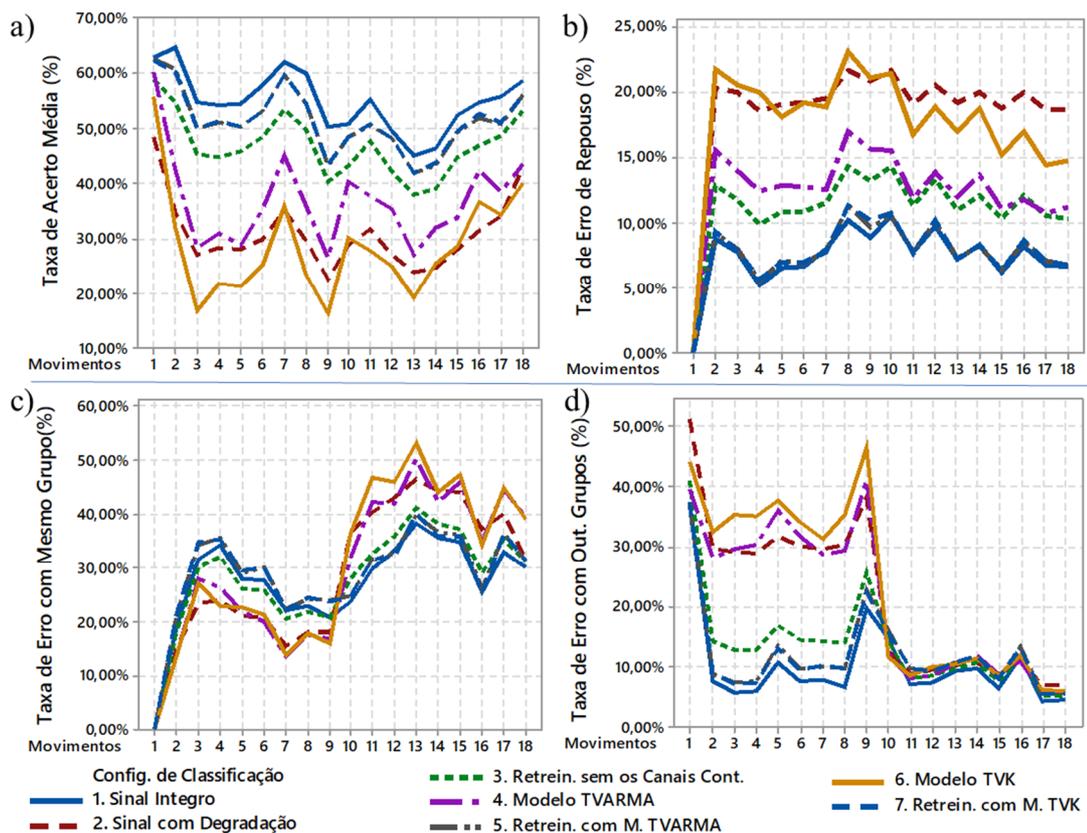


Figura 32 Taxas de acerto média e as taxas de erros entre movimentos das configurações de classificação para os 18 movimentos da base de dados do NinaPro de Amputados.

A Figura 33, referente a base de dados do IEE, apresenta um comportamento similar em relação a taxa de erro com o movimento de repouso dos sujeitos amputados na Figura 33 (b), porém com taxa de erro 5% menor e uma taxa de erro com o repouso em até 10% maior para sujeitos não amputados. Entretanto, a Figura 33 (d) apresenta uma redução no erro do movimento de repouso para com outros movimentos. Esta variação pode estar correlacionada com o método de segmentação por *timestamp* realizado para a base de dados do IEE, a qual de

certa forma pode ter amostras da ativação muscular durante o repouso sinalizadas como pertencentes aos movimentos, principalmente para as regiões de transição.

Outra variação apresentada foi a maior taxa de acerto média para o movimento 14 na Figura 33 (a). É possível que os sujeitos da base de dados do IEE executem o movimento 14 flexionando o pulso para trás de maneira mais extensiva, facilitando a caracterização deste movimento. Ainda sobre a base de dados do IEE, ocorreu uma maior diferença na taxa de erro com outros grupos de movimentos de 10% aproximadamente para a configuração de classificação com a substituição do sinal contaminado pelos modelos do sensor virtual na Figura 33 (d). A classificação com substituição do sinal contaminado pelo sinal modelado com TVK apresentou maiores taxas de erros para o grupo B em no mínimo 10% com relação as outras configurações de classificação. Estes erros só reforçam a conclusão que o modelo TVK não proporcionou um sinal adequado para a caracterização do grupo B de movimentos.

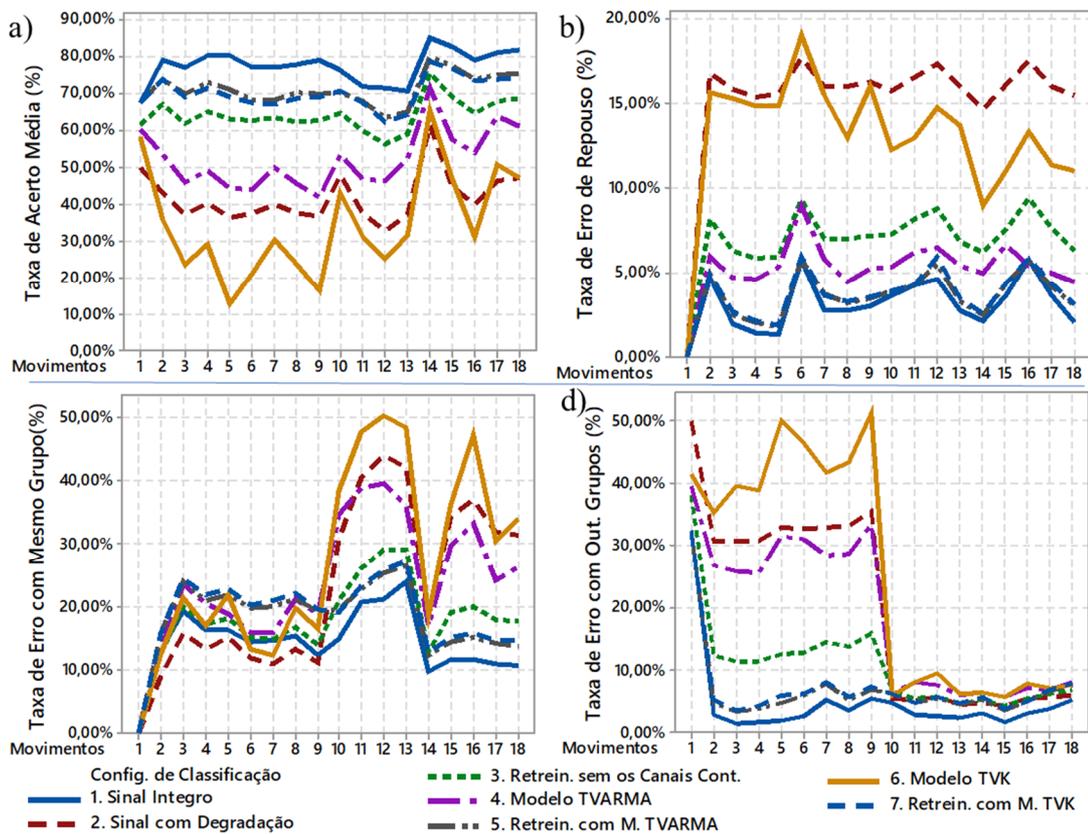


Figura 33 Taxas de acerto média e as taxas de erros entre movimentos das configurações de classificação para os 18 movimentos da base de dados do IEE.

Portanto, em um processamento *on-line* hipotético, seria mais crítico executar um movimento externo ao mesmo grupo de movimento do que confundir entre os movimentos do mesmo grupo. Como foi constatado que a substituição do sinal pelos modelos do sensor virtual aumenta as taxas de erros entre os movimentos de outros grupos, principalmente no caso do

grupo B, esta é uma limitação da geração de um modelo pelo sensor virtual baseada na correlação dos canais. Todavia, as variações dos estudos de caso de degradação de canais auxiliaram na compreensão destas diferenças apresentadas entre as bases de dados considerando a média para os movimentos analisados.

A análise das configurações de classificação para os 16 casos de estudo de contaminação de canais por base de dados e para cada ruído pode ser visualizada nas Figura 34 a Figura 38. Com exceção ao ruído de interferência de linha de energia, os resultados de forma geral apresentaram que o método de retreinamento do classificador sem o canal contaminado não mantém seu desempenho quando mais de um canal é degradado. Estes resultados sugerem que a configuração da classificação com retreinamento do classificador desenvolvidas neste trabalho podem estar simplificadas demasiadamente, já que não é realizado um procedimento de análise contínua para a retirada de um canal contaminado. No caso do retreinamento sem o canal contaminado, este desconsidera, no retreinamento do classificador, o canal com 80% de contaminação na totalidade das janelas. Este tipo de retreinamento nunca poderia ser utilizado em um processamento *on-line*. Assim, para os casos com muitos canais contaminados, a configuração de retirada do canal contaminado para o retreinamento do classificador apresentou não ser adequada a caracterização dos movimentos, ou seja, este algoritmo de retreinamento necessita de uma reformulação para atingir resultados comparáveis aos presentes na literatura científica.

Além disso, mesmo o método de retreinamento do classificador com sinal substituído pelos modelos do sensor virtual apresentando até 20% de variação para o pior caso de degradação (legenda 16) para os sujeitos sem amputação e aproximadamente 10% para os sujeitos com amputação, o retreinamento do classificador com a substituição do sinal contaminado pelo sensor virtual também não seriam uma solução viável para processamento *on-line*. Para a implementação deste, seria necessário armazenar sinais modelados para todos os canais com um determinado número de amostras, ou fazer um procedimento de calibração para aquisição destes modelos, a fim de utilizar estes sinais de sEMG modelados no retreinamento. Portanto, os métodos de classificação de retreinamento proporcionaram taxas de acerto médias de movimento hipotéticas, as quais só seriam obtidas em situações totalmente controladas, e isso deve ser considerado na validação do sistema adaptativo proposto.

O método desenvolvido neste trabalho com a configuração de retreinamento do classificador removendo o canal contaminado foi realizado com menor complexidade do que os desenvolvidos em (CENE; FAVIEIRO; BALBINOT, 2015; ZHANG; HUANG, 2015). Nestes outros trabalhos, foi possível encontrar melhores resultados para uma metodologia de

retreinamento do classificador. Entretanto, o objetivo deste trabalho foi encontrar um método adaptativo de classificação que não necessite de retreinamento, assim os métodos com retreinamento são comparativos para validação dos resultados e suas limitações devem ser consideradas. Para o processamento *on-line*, estes métodos de retreinamento necessitariam muitas alterações no algoritmo para a utilização. O sistema adaptativo de classificação com substituição do sinal contaminado pelo modelo do sensor virtual necessitará de pequenos ajustes e otimização do tempo de processamento para reduzir o *delay* de resposta a execução do movimento.

É importante enfatizar que a taxa de acerto média das configurações de classificação 5 e 7 estão praticamente sobrepostas. Essa sobreposição demonstra que é possível que o modelo escolhido entre TVARMA e TVK para a configuração de classificador com retreinamento do classificador não seja significativo e isso será avaliado ainda nesta subseção. No entanto, o método de retreinamento do classificador com a substituição do sinal degradado pelo sinal do sensor virtual aumentou, aparentemente, a taxa de acerto média na análise de todos os casos contaminados, apresentando destaque quando mais de um canal foi degradado. Sem o retreinamento do classificador, o sistema adaptativo de classificação apresentou taxa de acerto médias maiores para classificação com o sinal degradado apenas para os ruídos de deslocamento de eletrodo e saturação. Estes dois tipos de ruídos possuem maior SNR e maior impacto na taxa de acerto, assim os resultados de classificação com os sinais de sEMG modelados estão correlacionados ao SNR do contaminante.

Em análise quanto o caso do ruído de artefatos de movimento na Figura 34, a classificação com a substituição do sinal contaminado pelo modelo TVARMA do sensor virtual obteve maiores taxas de acerto para alguns estudos de degradação da base de dados do NinaPro não amputados na Figura 34 (a). Isto pode ser indicativo que dependendo da base de dados, foi obtido melhores resultados com o modelo proposto em comparação a classificação com o sinal degradado. Isso indica que existe uma limitação quanto a utilização do sistema proposto para a contaminação por artefatos de movimento, porém para alguns casos ainda pode ser recomendado o seu uso, dependendo do canal degradado e do sujeito analisado. Sendo assim, estas interações ainda devem ser analisadas estatisticamente nesta subseção.

A Figura 35 apresenta os resultados da comparação das configurações de classificação para os 16 casos de estudo de contaminação de canais por base de dados do ruído de deslocamento de eletrodos e a Figura 36 de saturação. Para estes ruídos, as taxas de acerto média da classificação com o sinal contaminado apresentaram no máximo 10% para todos estudos de casos de degradação e bases de dados. Portanto, o sistema de classificação proposto

é indicado para os ruídos com maiores SNRs, que proporcionam uma redução de 90% da taxa de acerto média da classificação tradicional, sendo esta relação ligada principalmente ao nível de contaminação e não ao tipo de ruído analisado. Comparando os efeitos na classificação apenas entre as Figura 34 a Figura 36, também é possível concluir que dependendo do ruído, a taxa de acerto média pode ser afetada significativamente diferente, devendo ser verificada na análise estatística ainda nesta subseção.

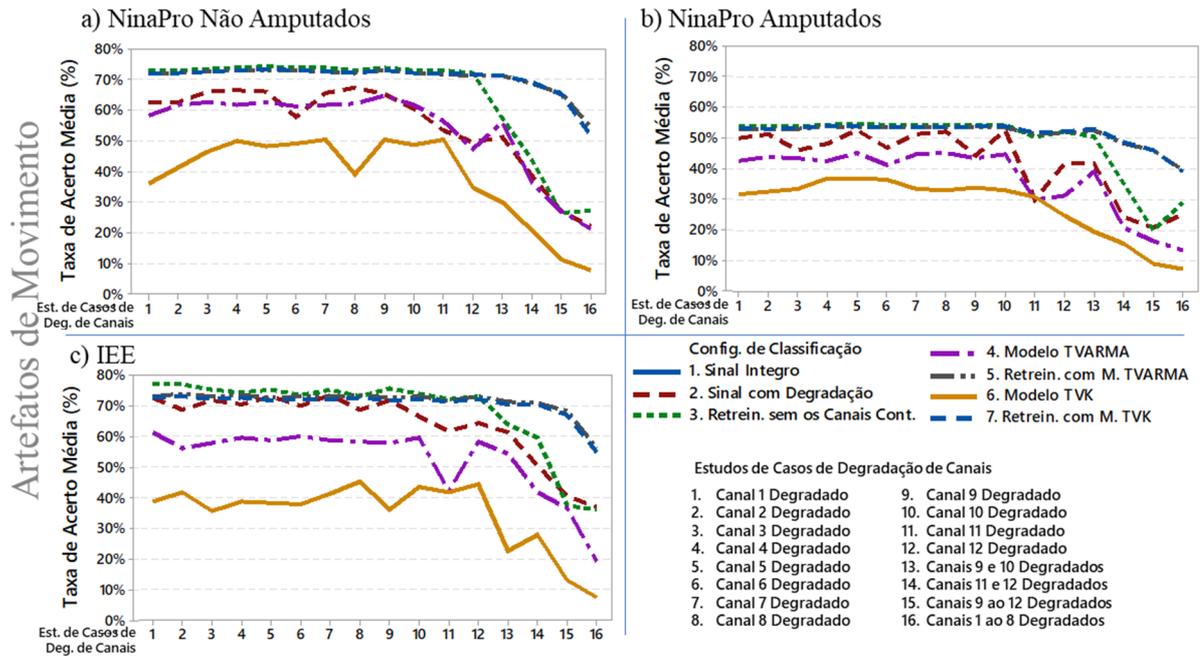


Figura 34 Análise da contaminação do sinal por Artefatos de Movimento entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.

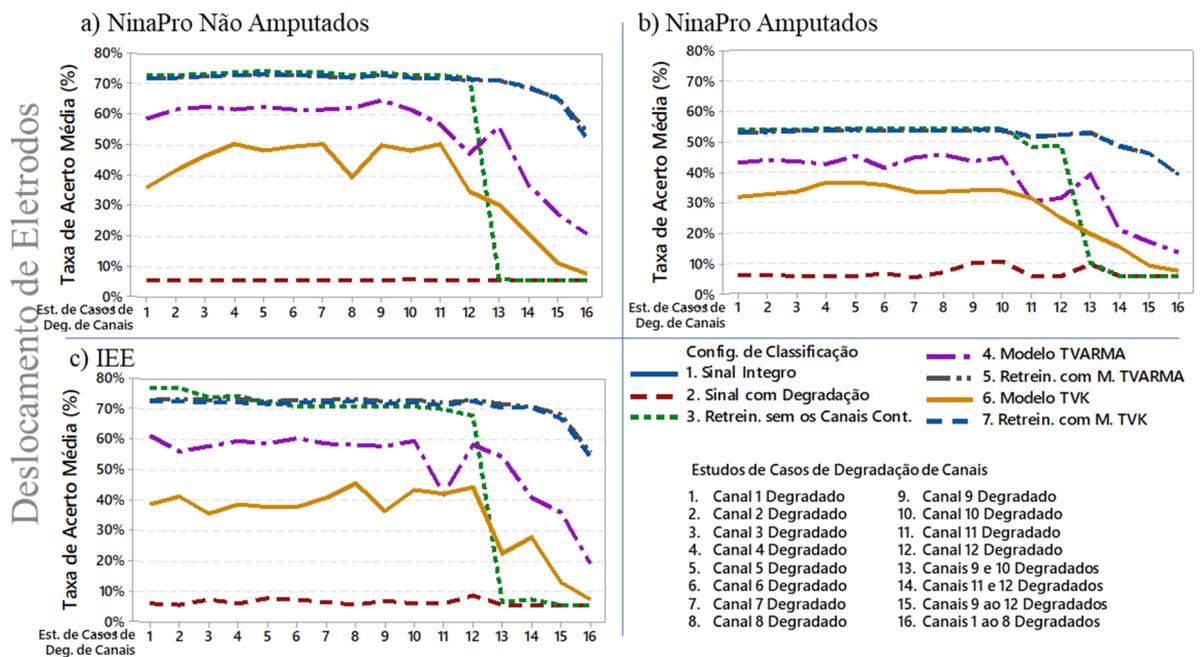


Figura 35 Análise da contaminação do sinal por Deslocamento de Eletrodos entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.

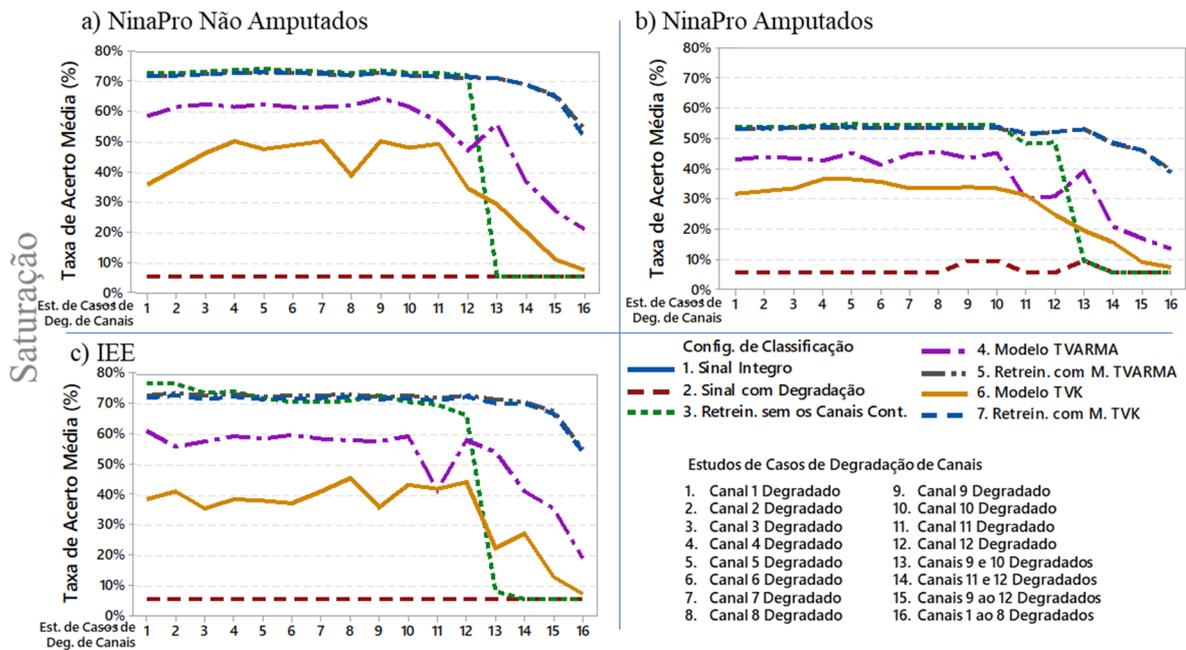


Figura 36 Análise da contaminação do sinal por Saturação entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.

A classificação com o sinal contaminado substituído pelo sinal do sensor virtual para todos os tipos de ruídos analisados apresentou diversas diferenças em comparação aos resultados obtidos na pesquisa preliminar de (DE MOURA; BALBINOT, 2018b). As novas características selecionadas e o ajuste da MCC em domínio tempo e frequência com o algoritmo baseado nos coeficientes PCA propiciaram uma maior taxa de acerto com os modelos TVARMA e TVK. A utilização do modelo TVARMA para o sensor virtual apresentou um aumento por vezes com 20% de diferença na taxa de acerto média obtida, diferenciando ainda mais os dois modelos em comparação ao estudo anterior. A utilização do modelo TVK pelo sensor virtual apresentou um aumento de até 5% para as alterações implantadas. Entretanto, este trabalho utiliza mais sujeitos, não podendo ser comparado diretamente com os resultados preliminares. Mesmo assim, é possível concluir que o sistema de ajuste da MCC proporcionou uma modelagem do sinal de sEMG que aumentou a taxa de acerto média na classificação dos movimentos.

Conforme mencionado na metodologia, foi possível verificar a hipótese de que características no domínio de frequência, as quais proporcionassem uma melhor identificação dos ruídos, em conjunto com o ajuste da matriz MCC em domínio do tempo e da frequência auxiliaram, principalmente, o sistema adaptativo com modelo TVARMA para a gerar um modelo de sEMG com características em um intervalo similar ao sinal íntegro. Esta diferença entre os modelos já estava presente no trabalho preliminar e pode ser justificada pela propriedade dos modelos TVARMA proporcionarem melhor a estimação das flutuações dos

sinais estocásticos, como o sinal de sEMG. O modelo TVK mesmo sendo ajustado para variar no tempo é um sistema linearizado para cada janela analisada.

As novas características também propiciaram uma maior taxa de acerto média na caracterização dos movimentos mesmo contaminados com o ruído de interferência de linha de energia, como pode ser visto na Figura 37. A classificação com o sinal contaminado só não obteve melhor resultado para os casos 11, 12, 13, 14 e 15 da base de dados do NinaPro não amputados (Figura 37. (a)), para o caso 14 da base de dados de amputados (Figura 37. (b)), para os casos 14 e 15 para a base do IEE (Figura 37. (c)). Isso pode estar correlacionado com a troca da característica PWR por FMD e SKW na classificação de movimentos, o que reduziu os erros na caracterização quanto a contaminação por interferência de linha de energia no estudo de (DE MOURA; BALBINOT, 2018b). Portanto, é possível concluir que estas características amenizam a contaminação causada por este tipo de ruído.

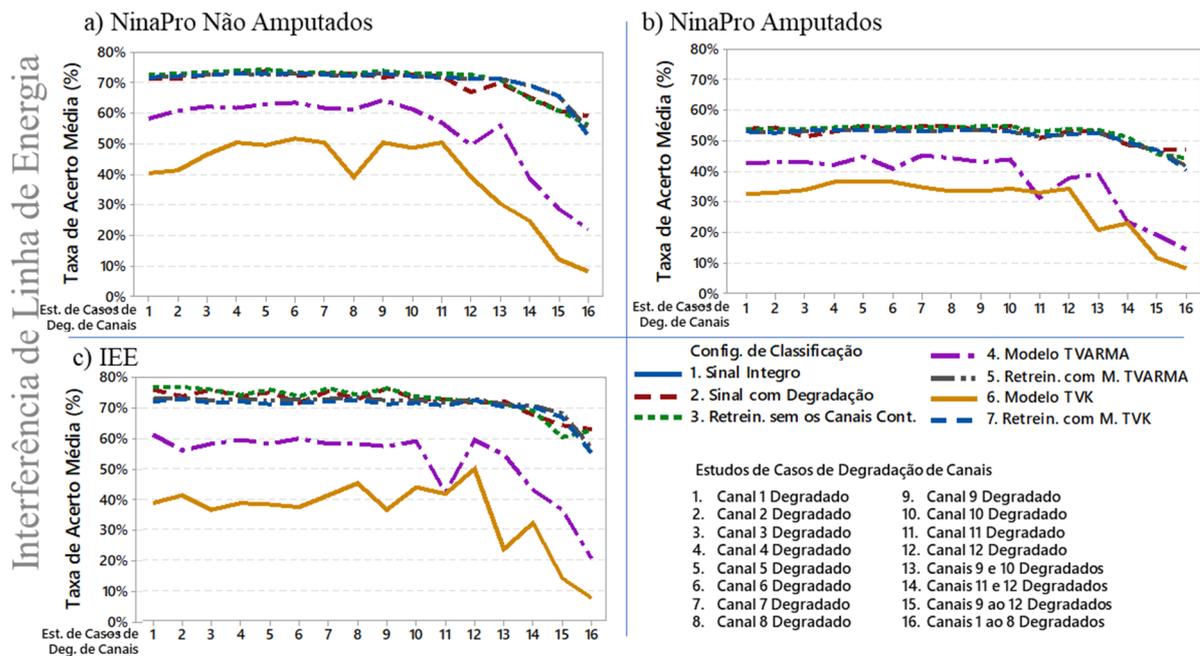


Figura 37 Análise da contaminação do sinal por Interferência de Linha de Energia entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.

Os resultados de classificação para os estudos de casos de degradação de canais com o ruído de interferência de ECG podem ser vistos na Figura 38. As taxas de acerto reduzem com o número de canais degradados para todas as bases de dados e ruídos analisados. O ruído de interferência de ECG foi analisado para compreender melhor os efeitos na taxa de acerto, porém é importante enfatizar que não ocorreriam na posição dos eletrodos deste estudo. O comportamento deste ruído foi similar a interferência de linha de energia com um maior efeito na taxa de acerto para a configuração de classificação com o sinal contaminado. Assim, os

ruídos analisados parecem afetar principalmente devido a amplitude do sinal em comparação a amplitude do ruído, já que, aparentemente, não foi obtido comportamentos únicos da taxa de acerto para cada ruído.

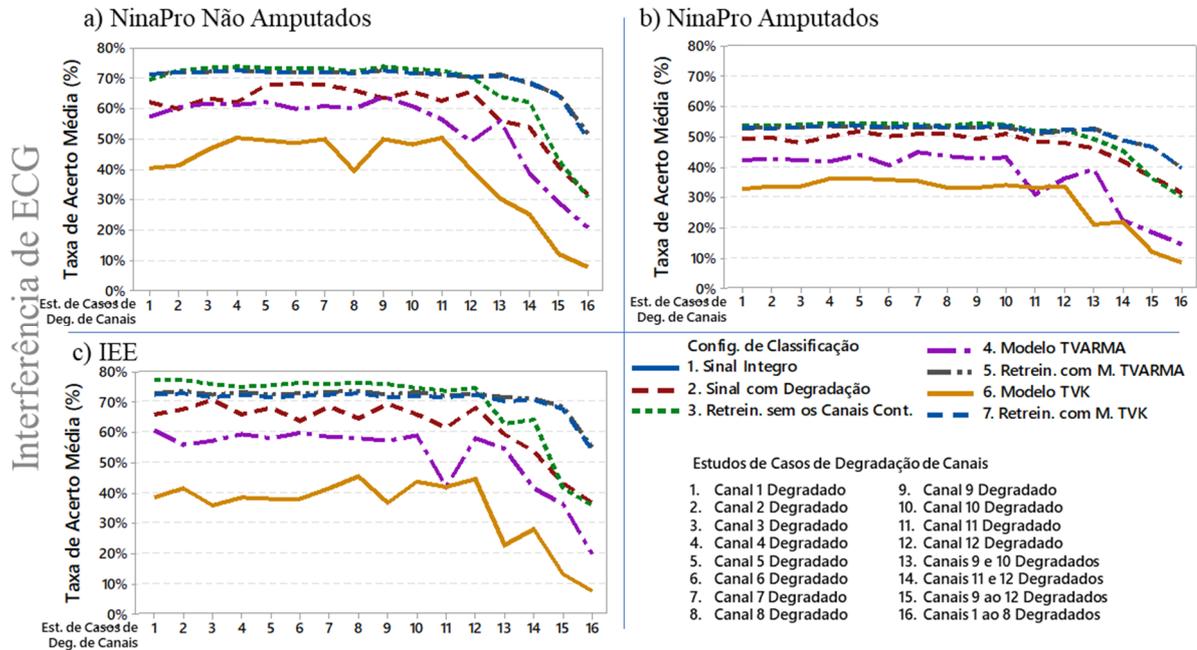


Figura 38 Análise da contaminação do sinal por Interferência de ECG entre as configurações de classificação para os estudos de casos de degradação de canais e bases de dados.

Analisando os resultados em relação as bases de dados, ficou visível a diferença de intervalo de valores da taxa de acerto entre sujeitos não amputados e amputados. Os resultados da taxa de acerto de classificação para os amputados apresentaram um valor médio máximo 20% menor que para sujeitos não amputados. Reforçando como característica dos sujeitos amputados a menor representatividade de ativação muscular em relação ao repouso. Assim, em todas as comparações entre as bases, fica evidente a importância de desenvolver bases de dados de sujeitos amputados para o aperfeiçoamento dos sistemas de caracterização de movimentos.

Dezoito Projetos de Experimentos do Tipo Fatorial Completo com análise da variância dos resultados foram realizados para analisar estatisticamente os resultados do sistema adaptativo de classificação de movimentos. Cada Projeto foi analisado separadamente. Os cálculos dos Projeto de Experimentos da análise da taxa de acerto, juntamente com as validações das pressuposições sobre os dados analisados, foram realizados e analisados conforme descrito no projeto de experimentos dos resultados do SFTD. As tabelas dos cálculos dos Projetos, os gráficos de histograma de resíduos, comportamento dos resíduos pelo valor ajustado da resposta e comportamento dos resíduos por ordem de observação estão disponíveis para consulta no Apêndice B – Projetos de Experimentos. Todos os Projetos apresentaram a

mesma violação quanto a variância dos resíduos serem constantes, um comportamento esperado, pois não há resultados acima de 100% para as amostras de taxa de acerto. A variação da taxa de acerto média de classificação quanto aos fatores controláveis de movimentos e de combinações de características não serão avaliadas estatisticamente neste trabalho. Estes fatores foram analisados anteriormente no trabalho preliminar de (MOURA; FAVIEIRO; BALBINOT, 2016) e influenciam significativamente na taxa de acerto média da classificação. Todos os Projetos utilizaram um intervalo de confiança de 95% para todos os fatores.

O cálculo do Projeto de Experimento que considerou os fatores controláveis os Sujeitos (53), Ruídos (5), Configuração de Classificação (6 – sem a classificação tradicional) pode ser visualizado na Tabela 17 e este projeto foi validado quanto as suposições na Figura 42 e máxima diferença detectável de significância das amostras foi de 1,68% (Figura 43) para a potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos ($F = 3.907,25 > \text{valor } P = 0,0$), dos tipos de ruídos ($F = 7.900,05 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 33.044,89 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, e suas interações também são significativas para a taxa de acerto média da classificação, como verificado anteriormente neste subcapítulo através das figuras com a interação entre estes fatores para cada base de dados. Ou seja, cada configuração de classificação pode proporcionar um melhor resultado dependendo do sujeito e ruído analisado. Portanto, esta análise confirma a hipótese de que o tipo de ruído afeta diferentemente cada sujeito, podendo assim ser adotadas metodologias de classificação não apenas quanto ao sistema adaptativo proposto, como também configurar uma metodologia de classificação para cada tipo de ruído analisado.

Como a taxa de acerto média apresentou ser significativamente afetada pela variação de sujeitos e pela variação de ruídos, foram realizados outros Projetos de Experimentos para compreender melhor as variações em cada base de dados e tipos de ruído. Para cada ruído separadamente, foram analisadas as variações de Estudos de Degradação de Canais (16) e Configuração de Classificação (6 – sem a classificação tradicional) quantos aos Sujeitos de cada Base de dados (20 Intactos NinaPro, 13 Amputados NinaPro e 20 Intactos IEE).

O cálculo do Projeto para o ruído de artefatos de movimento que considerou os fatores controláveis os Sujeitos não Amputados da NinaPro (20), Estudos de Degradação de Canais (16) e Configuração de Classificação (6 – sem a classificação tradicional) pode ser visto na Tabela 18, este projeto foi validado quanto as suposições na Figura 44 e máxima diferença detectável de significância das amostras foi de 2,83% (Figura 45) para a potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de

sujeitos ($F = 157,35 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 789,07 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 2.599,41 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, e suas interações também são significativas para a taxa de acerto média da classificação. Assim, dependendo do sujeito, existe uma configuração de classificação mais adequada para cada estudo de caso de contaminação do sinal por artefatos de movimento. Isso complementa a conclusão quanto à significância de cada tipo de ruído na taxa de acerto. Além de cada ruído afetar diferentemente a configuração de classificação, o ruído de artefatos de movimento afeta diferentemente cada canal contaminado. Portanto, reforça que cada canal possui um sinal com representatividade de ativação muscular em relação ao repouso único, o qual apresentou diferentes variações de classificação a partir das características extraídas quando contaminado.

Continuando com a análise para o ruído de artefatos de movimento, o cálculo do Projeto de Experimentos que considerou os fatores controláveis os Sujeitos Amputados da NinaPro (13), Estudos de Degradação de Canais (16) e Configuração de Classificação (6 – sem a classificação tradicional) foi a apresentado na Tabela 19, este projeto foi validado quanto as pressuposições na Figura 46 e máxima diferença detectável de significância das amostras foi de 2,86% (Figura 47) para a potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos ($F = 1.022,94 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 294,99 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 1.078,23 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, e suas interações também são significativas para a taxa de acerto média da classificação. O cálculo do Projeto de Experimentos que considerou os mesmo fatores controláveis porém utilizando os Sujeitos do IEE (20) pode ser visto na Tabela 20, o projeto em questão foi validado quanto as suposições na Figura 48 e máxima diferença detectável de significância das amostras foi de 2,67% (Figura 49) para a potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos ($F = 2.007,98 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 580,90 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 3.95829 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, e suas interações também são significativas para a taxa de acerto média da classificação.

Logo, é verdadeiro para todos os sujeitos de cada base de dados que existe uma configuração de classificação mais adequada a obter maior taxa de acerto dependendo do caso de contaminação do sinal por artefatos de movimento e que cada sinal apresenta uma representatividade de ativação muscular em relação ao repouso única. Portanto, os cruzamentos

entre as taxas de acerto em ralação as configurações de classificação e os estudos de caso de degradação de canais, na Figura 34, sinalizava que a taxa de acerto é afetada significativamente diferente dependendo da configuração de classificação utilizada para este ruído.

O cálculo do Projeto de Experimentos para o ruído de deslocamento de eletrodos, considerando os fatores controláveis os Sujeitos não Amputados da NinaPro (20), Estudos de Degradação de Canais (16) e Configuração de Classificação (6 – sem a classificação tradicional) pode ser visualizado na Tabela 21, este projeto foi validado quanto as suposições na Figura 50 e máxima diferença detectável de significância das amostras foi de 2,67% (Figura 51) para a potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos ($F = 105,68 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 814,43 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 11.394,80 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos. As interações entre os fatores também são significativas para a taxa de acerto média da classificação. Entretanto, devido a violação da variância ser constante, a interação dos 3 fatores juntos ($F = 1,01 > \text{valor } P = 0,418$) pode não ser significativa. Ou seja, para o ruído de deslocamento de eletrodos, pode existir uma configuração de classificação que proporciona a melhor taxa de acerto para todos os sujeitos analisados. Retornando a Figura 35, é observado que apenas a configuração de classificação, a qual reteinou sem os canais degradados, é que cruza com as outras configurações para mais de um canal degradado. Considerando as limitações que relatadas com estes modelos de treinamento anteriormente, conclui-se que existe sempre uma configuração de classificação mais adequada a todos os sujeitos desta base com o ruído de deslocamento de eletrodos.

Verificando se a afirmação anterior também é válida para as outras duas bases de dados, o cálculo do Projeto de Experimentos considerando os fatores controláveis os Sujeitos Amputados da NinaPro (13), Estudos de Degradação de Canais (16) e Configuração de Classificação (6 – sem a classificação tradicional) disponível na Tabela 22, a validação do projeto quanto as pressuposições na Figura 52 e máxima diferença detectável de significância das amostras foi de 2,74% (Figura 53) para potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos ($F = 719,71 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 313,94 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 3.839,12 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, e todas as interações também são significativas para a taxa de acerto média da classificação. Ou seja, para os sujeitos amputados, a hipótese não é válida,

podendo existir uma configuração de classificação de movimentos que proporciona maior taxa de acerto dependendo do estudo de degradação.

Para o Projeto de Experimentos com mesmos fatores controláveis, porém para os Sujeitos do IEE (20), o cálculo pode ser visto na Tabela 23, o projeto foi validado quanto as suposições na Figura 54 e máxima diferença detectável de significância das amostras foi de 2,67% (Figura 55) para a potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos ($F = 1.447,86 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 660,63 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 11.614,02 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, e todas as interações também são significativas para a taxa de acerto média da classificação. Nos casos dos sujeitos amputados, observou-se que existe uma configuração de classificação de movimentos que proporciona maior taxa de acerto dependendo do estudo de degradação analisado para cada sujeito.

Portanto, existe uma diferença significativa na taxa de acerto dependendo da configuração de classificação utilizada e da combinação de canais degradados. Entretanto, se o algoritmo do retreinamento do classificador sem o canal degradado, o qual fosse desenvolvido conforme os métodos em outros trabalhos da literatura científica, seria possível que a interação entre os fatores de sujeito, configuração de classificação e estudos de casos de degradação não fosse significativa para nenhuma base de dados utilizando o ruído de deslocamento de eletrodos.

Para o ruído de saturação, os cálculos do Projeto de Experimentos que consideraram os fatores controláveis Estudos de Degradação de Canais (16), Configuração de Classificação (6 – sem a classificação tradicional) e os Sujeitos de cada base de dados (não Amputados da NinaPro (20), amputados do NinaPro (13) e do IEE (2)) foram apresentados nas Tabela 24 a Tabela 26, os projetos foram validadas quanto as suposições individualmente nas Figura 56, Figura 58 e Figura 60, e as máximas diferença detectável de significância das amostras foram de 2,67% (Figura 57), 2,74% (Figura 59) e 2,67% (Figura 61), respectivamente, para a potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos não amputados da base de dados do NinaPro ($F = 104,09 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 809,13 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 11.382,25 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, incluindo as interações entre dois fatores. A interação de todos os fatores ($F = 1,00 > \text{valor } P = 0,474$) pode não ser significativa, devido à violação do pressuposto de variância constante dos resíduos. Isso quer dizer que para cada sujeito, é possível obter uma taxa de acerto mais elevada para todos os casos de degradação de canal. Ao observar

a Figura 36 (a), novamente só ocorre o cruzamento da configuração de classificação com retreinamento sem os canais contaminados. Isso reforça a hipótese que existe limitações relacionadas com este modelo de retreinamento na ocorrência de mais de um canal degradado.

A variação de sujeitos amputados da base de dados do NinaPro ($F = 720,61 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 313,29 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 3.913,51 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, todas as suas interações também são significativas para a taxa de acerto média da classificação. O mesmo ocorre para o projeto com a variação de sujeitos da base de dados do IEE ($F = 1.451,30 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 667,35 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 12.143,51 > P\text{-valor} = 0,0$). Voltando a Figura 36, é possível observar que, para cada base de dados do NinaPro amputados (Figura 36 (b)) e do IEE (Figura 36(c)), ocorreu o cruzamento das taxas de acerto para o estudo de caso de degradação no canal 11 para a classificação com os dois modelos de sensor virtual e para a configuração de classificação com retreinamento sem os canais degradados quando mais de um canal foi contaminado.

É importante reforçar que todos os projetos de experimentos são avaliados separadamente, assim, é possível concluir que a taxa de acerto é significativamente diferente entre os sujeitos de cada base de dados separadamente em relação a configuração de classificação em cada estudo de caso de degradação do sinal para o ruído de saturação. Entretanto, deve-se considerar as limitações da configuração de classificação com retreinamento sem os canais degradados, a qual não mantém a taxa de acerto para mais de um canal degradado. Outra consideração, referente à geração dos modelos de sensor virtual através dos canais não contaminados remanescentes, é que ambos modelos proporcionaram taxas de acerto na classificação similares ao reproduzirem o sinal para substituir o sinal contaminado sobre o canal 11, que está posicionado sobre o bíceps. Esta similaridade não está interligada ao modelo, estando provavelmente interligada as características únicas obtidas com a ativação muscular do bíceps, a qual aparentemente não possui uma correlação ideal com os outros canais para a geração do modelo de sensor virtual.

Para o ruído de interferência de linha de energia, os cálculos do Projeto de Experimentos que consideraram os fatores controláveis Estudos de Degradação de Canais (16), Configuração de Classificação (6 – sem a classificação tradicional) e os Sujeitos de cada base de dados (não Amputados da NinaPro (20), amputados do NinaPro (13) e do IEE (2)) podem ser visualizados nas Tabela 27 a Tabela 29. Estes projetos foram validados quanto às suposições individualmente nas Figura 62, Figura 64 e Figura 66, e as máximas diferenças detectáveis de

significância das amostras foram de 2,68% (Figura 63), 2,72% (Figura 65) e 2,48% (Figura 67), respectivamente, para a potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos não amputados da base de dados do NinaPro ($F = 167,91 > P\text{-valor} = 0,0$), dos estudos de caso de degradação de canais ($F = 411,47 > P\text{-valor} = 0,0$) e da configuração de classificação ($F = 3.295,77 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, e suas interações também são significativas para a taxa de acerto média da classificação. A variação de sujeitos amputados da base de dados do NinaPro ($F = 1.202,94 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 129,06 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 1.325,75 > P\text{-valor} = 0,0$) resultou que todos os fatores individualmente e as interações entre cada dois fatores são significativos. A interação dos três fatores juntos ($F = 1,01 > P\text{-valor} = 0,405$) pode não ser significativa para a taxa de acerto média da classificação. Entretanto, ao observar a interação dos fatores na Figura 37 (b), conclui-se que a interação dos três fatores é significativa, devido aos cruzamentos das taxas de acerto para as configurações de classificação dependendo do estudo de caso de degradação de canal.

A variação de sujeitos da base de dados do IEE ($F = 2.314,91 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 320,60 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 5.199,50 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, como também as suas interações, para a taxa de acerto média da classificação. Assim, é possível concluir que a taxa de acerto, para os sujeitos de cada base de dados separadamente, é significativamente afetada em relação das configurações de classificação para cada estudo de caso de degradação do sinal. Ou seja, não existe uma única configuração de classificação que obteve o melhor resultado de taxa de acerto em todos os casos de degradação analisados entre os sujeitos de cada base de dados para o ruído de interferência de linha de energia. Isso reforça a hipótese de que cada canal possui um sinal com representatividade de ativação muscular em relação ao repouso único, o qual apresenta diferentes variações de classificação a partir das características extraídas quando contaminado por este ruído.

Para o ruído de interferência de ECG, os cálculos do Projeto de Experimentos que consideraram os fatores controláveis Estudos de Degradação de Canais (16), Configuração de Classificação (6 – sem a classificação tradicional) e os Sujeitos de cada base de dados (não Amputados da NinaPro (20), amputados do NinaPro (13) e do IEE (2)) podem ser vistos nas Tabela 30 a Tabela 32, estes projetos foram validados quanto às suposições individualmente nas Figura 68, Figura 70 e Figura 72, e as máximas diferenças detectáveis de significância das amostras foram de 2,76% (Figura 69), 2,76% (Figura 71) e 2,62% (Figura 73), respectivamente,

para potência estatística de 0,8, conforme pode ser visualizado no Apêndice B – Projetos de Experimentos. A variação de sujeitos não amputados da base de dados do NinaPro ($F = 134,33 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 632,70 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 2.529,69 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, e suas interações também são significativas para a taxa de acerto média da classificação. Os fatores são individualmente significativos e suas interações a taxa de acerto média da classificação também para a variação de sujeitos da base de dados do IEE ($F = 1.998,08 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 556,04 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 4.124,99 > P\text{-valor} = 0,0$).

No entanto, a variação de sujeitos amputados da base de dados do NinaPro ($F = 1.062,67 > \text{valor } P = 0,0$), dos estudos de caso de degradação de canais ($F = 198,88 > \text{valor } P = 0,0$) e da configuração de classificação ($F = 1.096,92 > P\text{-valor} = 0,0$) resultou que todos os fatores são individualmente significativos, incluindo as interações entre dois fatores. Porém, a interação de todos os fatores juntos ($F = 0,93 > P\text{-valor} = 0,92$) pode não ser significativa para a taxa de acerto média da classificação. Isto pode significar que a taxa de acerto média em relação à configuração de classificação, para cada estudo de caso de degradação pelo ruído de interferência de ECG, poderia ocasionar não ser significativa com um maior número de sujeitos amputados avaliados. Ou seja, poderia ser obtido uma taxa de acerto média melhor para uma configuração de classificação em todas as interações de sujeitos e casos de degradação. Entretanto, é necessário considerar a variação na classificação dos movimentos provavelmente ocasionada por dois sujeitos com um percentual maior de amputação, o que impossibilitou a colocação dos eletrodos 9 e 10 sobre o flexor e extensor dos dedos.

Portanto, analisando a variação de sujeitos separadamente em cada base de dados, concluiu-se que não há uma única configuração de classificação em relação aos estudos de caso de degradação com taxas de acerto média melhor para os estudos de caso de degradação de canais. Assim, baseando-se na hipótese de que cada canal possui um sinal com representatividade de ativação muscular em relação ao repouso único, são obtidas variações significativas na taxa de acerto média de classificação quando o sinal de sEMG é contaminado por ruídos com menor SNR.

O objetivo de aplicar o conceito de sensor virtual foi reduzir a perda de taxa de acerto de classificação na ocorrência de degradação do sinal, projetando através deste um sistema adaptativo que não necessite de nenhuma calibração ou retreinamento do classificador. Então, avaliando em separado os dois modelos do sensor virtual quanto ao desempenho de classificação entre eles, dois Projetos de Experimentos foram calculados. Um dos projetos

verificou as variações dos modelos TVARMA e TVK para o sensor virtual no sistema adaptativo de classificação e o outro projeto a variação destes dois modelos em um sistema com possível retreinamento do classificador.

O cálculo do Projeto de Experimentos que considerou os fatores controláveis Sujeitos (53), Estudos de Contaminação de Canais (16), Configuração de Classificação com a substituição do sinal contaminado pelos Modelos do Sensor Virtual (2) pode ser visualizado na Tabela 33, sendo validado quanto as suposições na Figura 74, e a máxima diferença detectável de significância das amostras foi de 3,09% (Figura 75) para a potência estatística de 0,8. Estas figuras e tabela podem ser consultadas no Apêndice B – Projetos de Experimentos. As variações dos fatores controláveis Sujeitos ($F = 1.878,64 > \text{valor } P = 0,00$), Estudos de Contaminação de Canais ($F = 2.703,47 > \text{valor } P = 0,00$), configuração de classificação com a substituição do sinal contaminado pelos Modelos do Sensor Virtual ($F = 17.652,19 > \text{valor } P = 0,00$) são individualmente significativos, como também as suas interações. Em outras palavras, um modelo de sensor virtual não representou sempre melhor o sinal de sEMG para obter os melhores resultados nas variações dos casos de degradação de canais para todos os sujeitos. Como foi observado nas apresentações gráficas dos resultados de interações destes fatores, existe uma redução na taxa de acerto de classificação quando utilizado o modelo TVARMA para os casos de degradação envolvendo os canais 11 e 12. Portanto, é possível que o modelo TVARMA proporcione melhor taxa de acerto para os demais casos em todos os sujeitos. A similaridade dos modelos do sensor virtual nestes casos de degradação com o canal 11 e 12 é justificada pelas características únicas obtidas com a ativação muscular destes músculos, os quais não possuem uma correlação ideal com os outros canais para a geração do modelo de sensor virtual.

O cálculo do Projeto Experimentos que considerou os fatores controláveis Sujeitos (53), Estudos de Contaminação de Canais (16), Configuração de Classificação com retreinamento do classificador a partir da substituição do sinal contaminado pelos Modelos do Sensor Virtual (2) pode ser visto na Tabela 34, este projeto foi validado quanto às suposições na Figura 76, e a máxima diferença detectável de significância das amostras foi de 1,84% (Figura 77) para potência estatística de 0,8. Estas figuras e tabela podem ser consultadas no Apêndice B – Projetos de Experimentos. O cálculo do projeto apresentou que os fatores controláveis Sujeitos ($F = 4.205,46 > \text{valor } P = 0,00$), Estudos de Contaminação de Canais ($F = 1.189,58 > \text{valor } P = 0,00$), configuração de classificação com retreinamento do classificador a partir da substituição do sinal contaminado pelos Modelos do Sensor Virtual ($F = 27,44 > \text{valor } P = 0,00$) individualmente são significativos, incluindo as interações entre cada dois fatores. Entretanto,

a interação dos três fatores juntos não é significativa ($F = 0,13 < \text{valor } P = 1,00$). Em outras palavras, um modelo sempre tem melhores resultados que o outro para as variações dos casos de contaminação do canal para todos os sujeitos. O modelo que obteve melhor resultado neste caso foi o modelo TVARMA para o sensor virtual. Isso reforça que a propriedade dos modelos TVARMA de proporcionar a melhor estimativa das flutuações dos sinais estocásticos, como o sinal de sEMG, se sobrepõem na geração do modelo de sinal para obter a maior taxa de acerto de classificação em comparação a propriedade de um sistema linearizado variável no tempo do modelo TVK. Um exemplo pontual da resposta dos modelos de sinais de sEMG é mostrado na Figura 39, referente a característica RMS da primeira repetição do movimento 4 do primeiro sujeito amputado da base 3 do NinaPro quando foi avaliado a contaminação por deslocamento de eletrodos no canal 1.

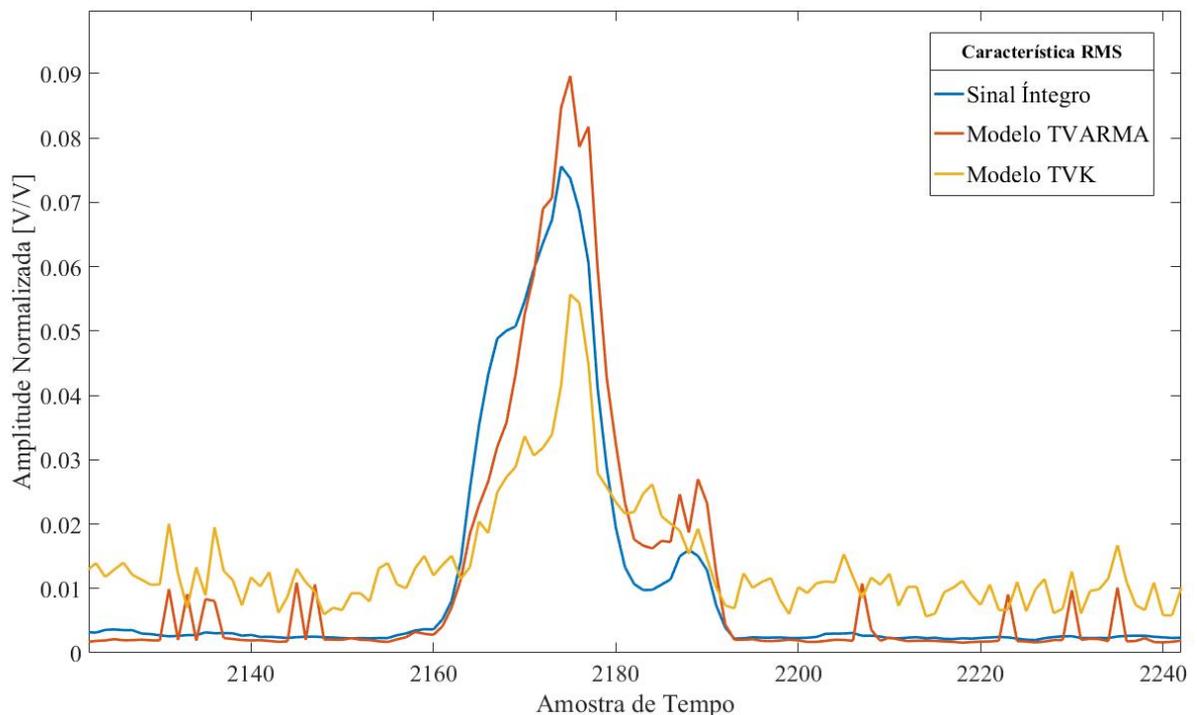


Figura 39 Comparação da característica RMS dos modelos do sensor virtual.

A utilização do modelo de sensor virtual sem a necessidade de retreinamento seria muito mais efetiva em uma aplicação *on-line*. Adicionalmente, o sistema de retreinamento utilizado não poderia ser aplicado nas mesmas condições, pois seria necessário salvar uma base de sinais modelado para cada sEMG a ser utilizada no retreinamento do classificador ou realizar um procedimento de calibração para todos os movimentos de interesse. Logo, o sistema com o retreinamento do classificador com o sinal dos modelos do sensor virtual não é viável em

processamento *on-line*. Assim, apenas proporcionaram uma validação comparativa entre os modelos do sensor virtual proposto.

5.3 Discussão em Relação a Outros Estudos Semelhantes

Analisando a detecção de contaminantes com os outros dois estudos (FRASER *et al.*, 2014; MCCOOL *et al.*, 2014), os quais abordaram a identificação de contaminantes por algoritmos de aprendizagem, o SFTD apresentou desempenho semelhante ao do estudo de (FRASER *et al.*, 2014). Este estudo também utilizou um algoritmo SVM e apresentou uma redução na detecção para os mesmos contaminantes avaliados neste trabalho. Entretanto, diferente do estudo de (FRASER *et al.*, 2014), o qual utilizou um classificador SVM de uma classe para detectar uma variedade de contaminação em sinais de sEMG com diferentes níveis de SNR, o SFTD proposto utilizou duas classes para caracterizar a contaminação no sinal. Além disso, não foi variado os níveis de SNR para cada ruído. Portanto, o SFTD proposto tem maior dependência quanto aos ruídos analisados, podendo não detectar outros contaminantes ou até os mesmos ruídos com diferentes SNR.

Em relação ao estudo de (MCCOOL *et al.*, 2014), que identifica qual ruído está presente no sinal entre os contaminantes, não foi possível fazer comparações como sua taxa de identificação do ruído presente. Considerando que foi verificado que cada ruído afeta diferentemente a taxa de acerto média de classificação devido à representatividade do contaminante à ativação muscular, conclui-se que o SFTD pode ser aperfeiçoado para retornar uma identificação de contaminação em distintos níveis de SNR.

Outros trabalhos relacionados a algoritmos adaptativos de (CENE; FAVIEIRO; BALBINOT, 2015; ZHANG; HUANG, 2015) também foram aplicados a sinais de sEMG e apresentaram resultados relevantes na adaptação do classificador após a identificação de sinais degradados. No entanto, esses estudos utilizam um sistema mais complexo de retreinamento do classificador, removendo os canais de sinais de degradação e mantendo um constante monitoramento sobre os canais, a fim de reconsiderarem estes após não apresentarem contaminação. Ou seja, estes trabalhos apresentaram uma avaliação de retreinamento do classificador com processamento *on-line* dos sinais. Comparando o sistema adaptativo proposto, a vantagem deste é a possibilidade de não retreinar o sistema ao longo do dia e, conseqüentemente, não realizar procedimentos de retreinamento desnecessários. Entretanto, o sistema adaptativo proposto com a utilização do sensor virtual apresentou reduções nas taxas de acerto de classificação, diferentemente para cada ruído analisado.

A implementação de (CENE; FAVIEIRO; BALBINOT, 2015) de uma rede neural auto-adaptativa com auto-treinamento, a qual descartou os canais que apresentaram deslocamento ou mau posicionamento dos eletrodos, foi utilizada de forma a aprimorar a classificação dos sinais de sEMG, os quais foram adquiridos com ruídos. Assim, não realizaram contaminações artificiais, apenas considerando as contaminações obtidas durante a aquisição do sinal. Estas contaminações foram identificadas utilizando o limiar de *threshold* para detecção. No entanto, estes limiares foram ajustados especificamente para a base de dados utilizada e para os comportamentos dos ruídos apresentados. Portanto, este estudo e sistema tiveram como objetivo a possibilidade de detectar contaminantes para melhorar a classificação dos movimentos, porém o trabalho de (CENE; FAVIEIRO; BALBINOT, 2015) requer um conhecimento prévio mais detalhado dos possíveis contaminantes de cada base de dados para definição dos limiares. O uso de limiares dificulta a aplicação destes para outras bases de dados e possíveis contaminantes. Então, a utilização de algoritmos inteligentes da detecção da contaminação do sinal pode ser considerada essencial para o aumento do uso de próteses mioelétricas, facilitando a integração de novos usuários.

O estudo de (ZHANG; HUANG, 2015) apresentou uma abordagem de simulação de contaminação artificial como a implantada neste estudo. No entanto, este outro estudo testou artefatos de contato, deslocamento de eletrodos e ruído *baseline* com diferentes níveis de SNR. Mesmo considerando que este outro se concentrou em reduzir o tempo de retreinamento do classificador após a identificação de contaminação pelo seu módulo sensor de detecção aplicado a outra base de dados, foram realizadas algumas comparações com este trabalho. O número de ocorrências de detecção falso-positivas foi menor em (ZHANG; HUANG, 2015), porém isso pode ser uma característica da base de dados, composta por cinco sujeitos não amputados e um sujeito com amputação. Em uma comparação entre os ruídos utilizados, é possível afirmar que eles obtiveram uma menor taxa de detecção para o ruído de deslocamento de eletrodos. Isso também pode ser decorrente da base de dados utilizada. Entretanto, estes resultados reforçam a importância da detecção de ruídos por algoritmos inteligentes.

Ainda comparando com o trabalho de (ZHANG; HUANG, 2015), a relação da redução na taxa de acerto da classificação após a contaminação de um a três canais foi apresentada e este outro método de retreinamento proporcionou menores efeitos dos contaminantes na redução da taxa de acerto da classificação de movimentos para os sujeitos amputados e não amputados com o aumento de canais degradados. O pior caso com três canais contaminados apresentados, no outro estudo, tem uma redução em até 15%. Através da comparação do método de retreinamento descartando canais contaminados deste trabalho com este outro estudo de

(ZHANG; HUANG, 2015), conclui-se que o outro estudo obteve uma menor redução na taxa de acerto para o mesmo ruído com mais de um canal contaminado. Entretanto, também apresentou uma menor redução na taxa de acerto com os contaminantes avaliados. Assim, o método com retreinamento sem o canal degradado proposto ainda apresenta muitas limitações para a sua aplicação *on-line* como o modelo apresentado por (ZHANG; HUANG, 2015), principalmente, com relação à contaminação de dois ou mais canais.

Considerando que a configuração de classificação com retreinamento sem o canal degradado apresentou resultados similares ao da literatura científica para um canal degradado e apresentou melhores taxas de acerto em comparação ao sistema adaptativo proposto, pode-se afirmar que sistemas com retreinamento do classificador podem atingir maiores taxas de acerto na recuperação da classificação após a contaminação dos sinais. Entretanto, é possível afirmar que este novo sistema adaptativo de classificação tolerante a falhas contribui como uma solução adequada em alguns casos de contaminação, podendo ser utilizado de forma intermediária ao retreinamento do classificador. O método proposto pode ser aplicado aos casos de contaminação com pequenos períodos ou pode ser utilizado enquanto o classificador é retreinado em um segundo plano de processamento, sem a necessidade de descartar dados. É importante ressaltar que o método proposto foi avaliado de forma superior ao encontrado na literatura científica com relação à diversificação de contaminantes e casos de contaminação do canal, utilizando três bases de dados distintas.

6 CONSIDERAÇÕES FINAIS

Neste trabalho, foram apresentadas algumas contribuições, as quais visam manter a taxa de acerto na classificação de movimentos na ocorrência de degradações de sinais conhecidas. A primeira contribuição de um método adaptativo pode contribuir para recuperar em até 46% a taxa de acerto de classificação quando ocorre contaminação do sinal por deslocamento de eletrodos e saturação. Para o ruído de artefatos de movimento, dependendo do canal degradado, foi possível obter maior taxa de acerto com a substituição do sinal pelo modelo TVARMA considerando todos os sujeitos analisados. É importante ressaltar que o método adaptativo obteve estes resultados sem um procedimento de retreinamento ou calibração.

Os resultados experimentais estatísticos determinaram que a variação da configuração de classificação, o tipo de ruído e os estudos de casos de degradação de canais afetam significativamente a taxa de acerto média da classificação. Ou seja, para cada uma das combinações destes fatores, é possível obter diferentes configurações de classificação com maior taxa de acerto média. Para os ruídos de interferência de linha de energia e de ECG, a configuração de classificação com o próprio sinal contaminado obteve maior taxa de acerto que a substituição do sinal pelo sensor virtual, sendo considerado uma das limitações do sistema proposto, porém os métodos com retreinamento do classificador podem recuperar a taxa de acerto perdida com a contaminação.

A segunda contribuição desta tese foi quanto aos modelos de sinais de sEMG, os quais tiveram seus resultados comparados e estatisticamente analisados. Analisando os métodos de classificação com o sensor virtual de modelos TVARMA e TVK, foi apresentado que o uso do modelo TVARMA obteve uma taxa de acerto média superior em comparação ao modelo TVK, porém isso não ocorreu para todos os casos de variação do ruído contaminante, estudos de caso de degradação, ou os dois juntos, para todos os sujeitos analisados. Todavia, a sobreposição entre os modelos pode ser justificada pela propriedade dos modelos TVARMA de proporcionar a estimação das flutuações dos sinais de sEMG para obter maior taxa de acerto de classificação em comparação a propriedade de um sistema linearizado variável no tempo do modelo TVK.

Para finalizar, a terceira contribuição quanto ao SFTD, proporcionou altas taxas de detecção usando como base de treinamento de apenas dois sujeitos, um não amputado e outro amputado, da base do NinaPro e obteve uma ótima generalização para os demais sujeitos analisados. Assim, poderia ser obtida uma taxa de detecção maior, se fosse feito um sistema de calibração para cada usuário. Ainda, devido à singularidade da integridade muscular de cada amputado, a avaliação da aquisição controlada de contaminantes em amputados é necessária

para observar a relação do ruído com o sinal da ativação muscular. No entanto, foi observado que o SFTD poderia fornecer uma diferenciação em níveis de SNR de contaminação para diferentes decisões de configuração de classificação.

A taxa de acerto média da classificação dificilmente pode ser comparada na maioria das pesquisas, pois diferentes movimentos, posicionamento de eletrodos e sujeitos são avaliados. O uso de um banco de dados público, como o NinaPro, permite que a comunidade científica avalie a contribuição dessa inovação. O algoritmo do sistema proposto ainda necessita ser otimizado para ser avaliado em uma aplicação *on-line*. Considerando os resultados analisados neste trabalho, existe a possibilidade de realizar uma integração do sistema adaptativo apresentado com sistemas de retreinamento do classificador, ou de forma a complementar a outras abordagens, como a adaptação do usuário com *feedback on-line* de (HAHNE; MARKOVIC; FARINA, 2017), para manter as taxas de acerto dos movimentos durante a ocorrência de contaminações do sinal de sEMG.

Portanto, o sistema apresentado contribuiu como uma técnica complementar para aumentar o impacto clínico da prótese mioelétrica, ou até mesmo em outras aplicações com os mesmos sinais de comportamento estocástico. Por exemplo, EEG para detecção de convulsões, ECG para detecção de QRS ou classificação de arritmia. No entanto, é imprescindível que ocorra uma integração com outras técnicas de classificação, devido às limitações com os ruídos de artefato de movimento, de interferência de linha de energia e ECG.

A continuidade desta pesquisa pode desenvolver um SFTD para definir uma configuração de classificação, dependendo de níveis de ruídos. Ou seja, detectando não apenas se o sinal de sEMG está contaminado, mas classificando quanto a níveis de SNR. Além disso, poderia ainda ser realizado uma análise sobre o comportamento deste sistema adaptativo com outros tipos de algoritmos de classificação. Todavia, nesta análise de classificadores, também seria importante avaliar as limitações de cada classificador de movimentos quanto aos ruídos analisados.

REFERÊNCIAS BIBLIOGRÁFICAS

ABE, Shigeo. **Support Vector Machines for Pattern Classification**. London: Springer London, 2010. v. 26

AL-TIMEMY, Ali H. et al. Improving the Performance Against Force Variation of EMG Controlled Multifunctional Upper-Limb Prostheses for Transradial Amputees. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 24, n. 6, p. 650–661, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7131549/>>

ALKAN, Ahmet; GÜNAY, Mücahid. Identification of EMG signals using discriminant analysis and SVM classifier. **Expert Systems with Applications**, [s. l.], v. 39, n. 1, p. 44–47, 2012. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0957417411009432>>

ALOMARI, Firas; LIU, Guohai. Novel hybrid soft computing pattern recognition system SVM–GAPSO for classification of eight different hand motions. **Optik - International Journal for Light and Electron Optics**, [s. l.], v. 126, n. 23, p. 4757–4762, 2015.

ÁLVAREZ-ESTÉVEZ, Diego et al. A method for the automatic analysis of the sleep macrostructure in continuum. **Expert Systems with Applications**, [s. l.], v. 40, n. 5, p. 1796–1803, 2013.

ATZORI, Manfredo et al. Experiences in the creation of an electromyography database to help hand amputated persons. **Studies in Health Technology and Informatics**, [s. l.], v. 180, p. 828–832, 2012. a.

ATZORI, Manfredo et al. Building the Ninapro database: A resource for the biorobotics community. In: IEEE RAS AND EMBS INTERNATIONAL CONFERENCE ON BIOMEDICAL ROBOTICS AND BIOMECHATRONICS 2012b, NY. **Anais...** NY: IEEE, 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6290287/>>

ATZORI, Manfredo et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. **Scientific Data**, [s. l.], v. 1, 2014. Disponível em: <<http://www.nature.com/articles/sdata201453>>

ATZORI, Manfredo et al. Characterization of a Benchmark Database for Myoelectric Movement Classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 23, n. 1, p. 73–83, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/6825822/>>

ATZORI, Manfredo; COGNOLATO, Matteo; MÜLLER, Henning. Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands. **Frontiers in Neurobotics**, [s. l.], v. 10, n. SEP, p. 1–10, 2016. Disponível em: <<http://journal.frontiersin.org/Article/10.3389/fnbot.2016.00009/abstract>>

ATZORI, Manfredo; MÜLLER, Henning. Control Capabilities of Myoelectric Robotic Prostheses by Hand Amputees: A Scientific Research and Market Overview. **Frontiers in Systems Neuroscience**, [s. l.], v. 9, n. 162, p. 1–7, 2015. Disponível em: <<http://journal.frontiersin.org/Article/10.3389/fnsys.2015.00162/abstract>>

ATZORI, Manfredo; MULLER, Henning; BAECHLER, Micheal. Recognition of hand movements in a trans-radial amputated subject by sEMG. In: IEEE INTERNATIONAL CONFERENCE ON REHABILITATION ROBOTICS (ICORR) 2013, NY. **Anais...** NY: IEEE, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6650486/>>

AZAMI, Hamed et al. An intelligent approach for variable size segmentation of non-stationary signals. **Journal of Advanced Research**, [s. l.], v. 6, n. 5, p. 687–698, 2015.

BAKKOURY, Jamila; CASTANIE, Francis; ROVIRAS, Daniel. Evolutionary ARMA modelling of time-varying impulse response. In: IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING CONFERENCE PROCEEDINGS, 1996, NY. **Anais...** NY: IEEE, 1996.

BALBINOT, Alexandre; FAVIEIRO, Gabriela. A Neuro-Fuzzy System for Characterization of Arm Movements. **Sensors**, [s. l.], v. 13, n. 2, p. 2613–2630, 2013. Disponível em: <<http://www.mdpi.com/1424-8220/13/2/2613/>>

BALBINOT, Alexandre; JÚNIOR, As; FAVIEIRO, Gabriela Winkler. Decoding Arm Movements by Myoelectric Signal and Artificial Neural Networks. **Intelligent Control and Automation**, [s. l.], n. 4, p. 87–93, 2013. Disponível em: <<http://dx.doi.org/10.4236/ica.2013.41012>>

BARIŞÇI, Necaattin. The adaptive ARMA analysis of EMG signals. **Journal of Medical Systems**, [s. l.], v. 32, n. 1, p. 43–50, 2008. Disponível em: <<http://link.springer.com/10.1007/s10916-007-9106-8>>

BASMAJIAN, J. V.; DE LUCA, C. J. **Muscles alive: Their functions revealed by electromyography**. 5th. ed. Baltimore: Williams & Wilkins, 1985.

BEGG, Rezaul; LAI, Daniel T. H.; PALANISWAMI, Marimuthu. **Computational Intelligence in Biomedical Engineering**. New York: CRC Press, 2008.

BELTRAMINI, L. M. **Elementos de Histologia e Anatomo-fisiologia Humana**. 1. ed. São Carlos, SP: Serviço Gráfico do Instituto de Física de São Carlos - USP, 1999.

BERNOTAS, Leonas A. et al. A Discrete-Time Model of Electrically Stimulated Muscle. **IEEE Transactions on Biomedical Engineering**, NY, v. BME-33, n. 9, p. 829–838, 1986. Disponível em: <<http://ieeexplore.ieee.org/document/4122407/>>

BHUYAN, Manabendra. **Instrumentação Inteligente: Princípios e Aplicações**. Rio de Janeiro: LTC, 2013.

BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. New York: Springer, 2013. v. 53

BLANA, Dimitra et al. Feasibility of using combined EMG and kinematic signals for prosthesis control: A simulation study using a virtual reality environment. **Journal of Electromyography and Kinesiology**, [s. l.], v. 29, p. 21–27, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.jelekin.2015.06.010>>

BLANCHARD, Susan. ANATOMY AND PHYSIOLOGY. In: **Introduction to Biomedical Engineering**. 2. ed. [s.l.] : Elsevier, 2005. p. 73–125.

BURGES, Christopher J. C. A Tutorial on Support Vector Machines for Pattern Recognition. **Data Mining and Knowledge Discovery**, Boston, v. 2, p. 121–167, 1998.

BÚRIGO, Arthur Crippa. **Classificação de Movimentos da Mão Utilizando Eletromiografia de Superfície , Regressão Logística , Redes Neurais , Máquina de Vetores de Suporte e Base de Dados NinaPro**. 2014. Monografia (Bacharel em Engenharia de Computação) - Universidade Federal do Rio Grande do Sul, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2014.

CAESARENDRA, Wahyu; TJAHJOWIDODO, Tegoeh; PAMUNGKAS, Daniel. EMG based classification of hand gestures using PCA and ANFIS. In: INTERNATIONAL CONFERENCE ON ROBOTICS, BIOMIMETICS, AND INTELLIGENT COMPUTATIONAL SYSTEMS (ROBIONETICS), 2017, NY. **Anais...** NY: IEEE, 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8203430/>>

CARRINO, Francesco et al. Gesture Segmentation and Recognition with an EMG-Based Intimate Approach - An Accuracy and Usability Study. In: INTERNATIONAL CONFERENCE ON COMPLEX, INTELLIGENT, AND SOFTWARE INTENSIVE SYSTEMS 2012, NY. **Anais...** NY: IEEE, 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6245626/>>

CELADON, Nicolò et al. Proportional estimation of finger movements from high-density surface electromyography. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 13, n. 1, p. 1–19, 2016.

CENE, V. H.; FAVIEIRO, G.; BALBINOT, A. Upper-limb movement classification based on sEMG signal validation with continuous channel selection. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2015, NY. **Anais...** NY: IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7318405/>>

CENE, VINÍCIUS HORN. **Desenvolvimento de um projeto de experimentos para a caracterização de sinais mioelétricos através do uso de regressão logística**. 2016. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2016.

CENE, Vinícius Horn; BALBINOT, Alexandre. Optimization of Features to Classify Upper - Limb Movements Through sEMG Signal Processing. **Brazilian Journal of Instrumentation and Control**, [s. l.], v. 4, n. 3, p. 14–20, 2016. Disponível em: <<https://periodicos.utfpr.edu.br/bjic/article/view/4878/3218>>

CHAPARRO-VARGAS, Ramiro et al. Sleep onset detection based on Time-Varying Autoregressive models with particle filter estimation. In: IEEE CONFERENCE ON BIOMEDICAL ENGINEERING AND SCIENCES (IECBES), 2014, NY. **Anais...** NY: IEEE, 2014. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7047537>>

CHAPARRO-VARGAS, Ramiro et al. Searching arousals: A fuzzy logic approach. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2015, NY. **Anais...** NY: IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7318962/>>

CHAUVET, Eric et al. Automatic identification of motor unit action potential trains from electromyographic signals using fuzzy techniques. **Medical and Biological Engineering and**

Computing, [s. l.], v. 41, n. 6, p. 646–653, 2003.

CHEE-MING TING et al. Spectral Estimation of Nonstationary EEG Using Particle Filtering With Application to Event-Related Desynchronization (ERD). **IEEE Transactions on Biomedical Engineering**, NY, v. 58, n. 2, p. 321–331, 2011. Disponível em: <<http://ieeexplore.ieee.org/document/5605664/>>

CHIANG, Joyce; WANG, Z. Jane; MCKEOWN, Martin J. A hidden Markov, multivariate autoregressive (HMM-mAR) network framework for analysis of surface EMG (sEMG) data. **IEEE Transactions on Signal Processing**, NY, v. 56, n. 8 II, p. 4069–4081, 2008.

CHO, Seongpil; GAO, Zhen; MOAN, Torgeir. Model-based fault detection, fault isolation and fault-tolerant control of a blade pitch system in floating wind turbines. **Renewable Energy**, [s. l.], v. 120, p. 306–321, 2018. Disponível em: <<https://doi.org/10.1016/j.renene.2017.12.102>>

CHOI, ByoungSeon. **ARMA Model Identification**. NY: Springer, 1992. Disponível em: <<http://link.springer.com/10.1007/978-1-4613-9745-8>>

CHOWDHURY, Rubana H. et al. Surface Electromyography Signal Processing and Classification Techniques. **Sensors**, [s. l.], v. 13, n. 9, p. 12431–12466, 2013. Disponível em: <<http://www.mdpi.com/1424-8220/13/9/12431/>>

CORTES, Corinna; VAPNIK, Vladimir. Support-Vector Networks. **Machine Learning**, [s. l.], v. 20, n. 3, p. 273–297, 1995.

CREMA, Claudio et al. Virtual Respiratory Rate Sensors: An Example of A Smartphone-Based Integrated and Multiparametric mHealth Gateway. **IEEE Transactions on Instrumentation and Measurement**, NY, v. 66, n. 9, p. 2456–2463, 2017.

DE LUCA, Carlo J. Physiology and Mathematics of Myoelectric Signals. **IEEE Transactions on Biomedical Engineering**, NY, v. BME-26, n. 6, p. 313–325, 1979. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4123061>>

DE LUCA, Carlo J. The use of surface electromyography in biomechanics. **Journal of Applied Biomechanics**, [s. l.], v. 13, n. 2, p. 135–163, 1997.

DE LUCA, Carlo J. Surface Electromyography: Detection and Recording. **DelSys Incorporated**, [s. l.], p. 2–10, 2002.

DE LUCA, Carlo J. Decomposition of Surface EMG Signals. **Journal of Neurophysiology**, [s. l.], v. 96, n. 3, p. 1646–1657, 2006. a. Disponível em: <<http://dx.doi.org/10.1152/jn.00009.2006>>

DE LUCA, Carlo J. Electromyography. In: **Encyclopedia of Medical Devices and Instrumentation**. Hoboken, NJ, USA: John Wiley & Sons, 2006. b. p. 98–109.

DE MOURA, Karina; BALBINOT, Alexandre. Classification System Based on Virtual Sensor for Surface Electromyography. **Measurement**, [s. l.], 2018. a.

DE MOURA, Karina; BALBINOT, Alexandre. Virtual Sensor of Surface Electromyography in a New Extensive Fault-Tolerant Classification System. **Sensors**, [s. l.], v. 18, n. 5, p. 1388,

2018. b. Disponível em: <<http://www.mdpi.com/1424-8220/18/5/1388>>

DE PAULI NILSON, Claire; BALBINOT, Alexandre. Acquisition, processing of myoelectrics signals and Support-Vector Machine for movement characterization of hand-arm segment. In: ISSNIP-IEEE BIOSIGNALS AND BIOROBOTICS CONFERENCE: BIOSIGNALS AND ROBOTICS FOR BETTER AND SAFER LIVING (BRC) 2014, NY. **Anais...** NY: IEEE, 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6880961/>>

DEIJS, M. et al. Flexible and static wrist units in upper limb prosthesis users: functionality scores, user satisfaction and compensatory movements. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 13, 2016. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=4791860&tool=pmcentrez&rendertype=abstract>>

DING, Qichuan et al. An incremental EMG classification model to detect and recognize randomly-occurred outlier motion. In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND BIOMIMETICS (ROBIO), 2017, NY. **Anais...** NY: IEEE, 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8324556/>>

DOSEN, Strahinja; SCHAEFFER, Marie-Caroline; FARINA, Dario. Time-division multiplexing for myoelectric closed-loop control using electrotactile feedback. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 11, 2014. Disponível em: <<http://www.jneuroengrehab.com/content/11/1/138>>

DU, Yu et al. Surface EMG-Based Inter-Session Gesture Recognition Enhanced by Deep Domain Adaptation. **Sensors**, [s. l.], v. 17, n. 3, 2017. Disponível em: <<http://www.mdpi.com/1424-8220/17/3/458>>

DVOŘÁK, Ivan; HOLDEN, Arun V. **Mathematical approaches to brain functioning diagnostics**. Manchester: Manchester University Press, 1991.

EMG SYSTEM DO BRASIL. **Características Técnicas do EMG800-C**, 2008.

ENGDAHL, Susannah M. et al. Surveying the interest of individuals with upper limb loss in novel prosthetic control techniques. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 12, 2015. Disponível em: <<http://www.jneuroengrehab.com/content/12/1/53>>

ENGLEHART, K. et al. Classification of the myoelectric signal using time-frequency based representations. **Medical Engineering and Physics**, [s. l.], v. 21, n. 6–7, p. 431–438, 1999.

ENGLEHART, Kevin; HUDGINS, Bernard. A robust, real-time control scheme for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, NY, v. 50, n. 7, p. 848–854, 2003. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/12848352>>. Acesso em: 31 mar. 2015.

ERTUĞRUL, Ömer Faruk; KAYA, Yılmaz; TEKIN, Ramazan. A novel approach for SEMG signal classification with adaptive local binary patterns. **Medical & Biological Engineering & Computing**, [s. l.], v. 54, n. 7, p. 1137–1146, 2016. Disponível em: <<http://link.springer.com/10.1007/s11517-015-1443-z>>

FAGIANO, Lorenzo; NOVARA, Carlo. A combined Moving Horizon and Direct Virtual Sensor approach for constrained nonlinear estimation. **Automatica**, [s. l.], v. 49, n. 1, p. 193–

199, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.automatica.2012.09.009>>

FARINA, Dario; MERLETTI, Roberto;; ENOLA, Roger M. The extraction of neural strategies from the surface EMG. **Journal of Applied Physiology**, [s. l.], v. 96, n. 4, p. 1486–1495, 2004. Disponível em:

<<http://jap.physiology.org/cgi/doi/10.1152/jappphysiol.01070.2003>>

FARRELL, Todd R. Determining delay created by multifunctional prosthesis controllers. **The Journal of Rehabilitation Research and Development**, [s. l.], v. 48, n. 6, 2011. Disponível em: <<http://www.rehab.research.va.gov/jour/11/486/pdf/farrell486.pdf>>

FAVIEIRO, Gabriela; CENE, Vinícius Horn; BALBINOT, Alexandre. Self-adaptive Method for sEMG Movement Classification Based on Continuous Optimal Electrode Assortment. **Brazilian Journal of Instrumentation and Control**, [s. l.], p. 21–26, 2016.

FAVIEIRO, Gabriela Winkler; BALBINOT, Alexandre. Adaptive neuro-fuzzy logic analysis based on myoelectric signals for multifunction prosthesis control. In: PROCEEDINGS OF THE ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, EMBS 2011, **Anais...** [s.l: s.n.]

FRASER, G. D. et al. CleanEMG - Power line interference estimation in sEMG using an adaptive least squares algorithm. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2011, NY. **Anais...** NY: IEEE, 2011. Disponível em:

<<http://ieeexplore.ieee.org/document/6091958/>>

FRASER, Graham D. et al. Automated Biosignal Quality Analysis for Electromyography Using a One-Class Support Vector Machine. **IEEE Transactions on Instrumentation and Measurement**, NY, v. 63, n. 12, p. 2919–2930, 2014. Disponível em:

<<http://ieeexplore.ieee.org/document/6807760/>>

FUTAMATA, Masachika; NAGATA, Kentaro; MAGATANI, Kazushige. The evaluation of the discriminant ability of multiclass SVM in a study of hand motion recognition by using SEMG. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2012, NY. **Anais...** NY: IEEE, 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6347177/>>

GENG, Yanjuan; ZHOU, Ping; LI, Guanglin. Toward attenuating the impact of arm positions on electromyography pattern-recognition based motion classification in transradial amputees. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 9, 2012. Disponível em:

<<http://jneuroengrehab.biomedcentral.com/articles/10.1186/1743-0003-9-74>>

GIJSBERTS, Arjan et al. Movement error rate for evaluation of machine learning methods for sEMG-based hand movement classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 22, n. 4, p. 735–744, 2014.

GIJSBERTS, Arjan; CAPUTO, Barbara. Exploiting accelerometers to improve movement classification for prosthetics. In: IEEE INTERNATIONAL CONFERENCE ON REHABILITATION ROBOTICS (ICORR) 2013, NY. **Anais...** NY: IEEE, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6650476/>>

GOKGOZ, Ercan; SUBASI, Abdulhamit. Effect of multiscale PCA de-noising on EMG signal classification for diagnosis of neuromuscular disorders. **Journal of Medical Systems**, [s. l.], v. 38, n. 4, 2014.

- GRAUPE, D.; CLINE, W. K. Functional separation of EMG signals via ARMA identification methods for prosthesis control purposes. **IEEE Transactions on Systems, Man and Cybernetics**, NY, v. SMC-5, n. 2, p. 252–259, 1975.
- GUO, Shuxiang et al. Comparison of sEMG-Based Feature Extraction and Motion Classification Methods for Upper-Limb Movement. **Sensors**, [s. l.], v. 15, n. 4, p. 9022–9038, 2015. a. Disponível em: <<http://www.mdpi.com/1424-8220/15/4/9022/>>
- GUO, Weichao et al. Towards zero training for myoelectric control based on a wearable wireless sEMG armband. In: IEEE INTERNATIONAL CONFERENCE ON ADVANCED INTELLIGENT MECHATRONICS (AIM), 2015b, NY. **Anais...** NY: IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7222531>>
- GUO, Weichao et al. Towards zero training for myoelectric control based on a wearable wireless sEMG armband. In: IEEE INTERNATIONAL CONFERENCE ON ADVANCED INTELLIGENT MECHATRONICS (AIM), 2015c, NY. **Anais...** NY: IEEE, 2015.
- GUYTON, Arthur C. **Fisiologia Humana**. 11. ed. Rio de Janeiro: Guanabara Koogan, 2006.
- GUYTON, Arthur C.; HALL, John E. **Textbook of Medical Physiology**. 12. ed. [s.l.] : Saunders Elsevier, 2010. v. 53
- HAHNE, J. M. et al. Linear and Nonlinear Regression Techniques for Simultaneous and Proportional Myoelectric Control. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 22, n. 2, p. 269–279, 2014. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6742730>>
- HAKONEN, Maria; PIITULAINEN, Harri; VISALA, Arto. Current state of digital signal processing in myoelectric interfaces and related applications. **Biomedical Signal Processing and Control**, [s. l.], v. 18, p. 334–359, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.bspc.2015.02.009>>
- HALIM, Dunant; CHENG, Li; SU, Zhongqing. Virtual sensors for active noise control in acoustic–structural coupled enclosures using structural sensing: Robust virtual sensor design. **The Journal of the Acoustical Society of America**, [s. l.], v. 129, n. 3, p. 1390–1399, 2011. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/21428503>>
- HAOSHI ZHANG et al. An adaptation strategy of using LDA classifier for EMG pattern recognition. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2013, NY. **Anais...** NY: IEEE, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6610488/>>
- HASAN, Md. Mehedi et al. Human hand gesture detection based on EMG signal using ANN. In: INTERNATIONAL CONFERENCE ON INFORMATICS, ELECTRONICS & VISION (ICIEV) 2014, NY. **Anais...** NY: IEEE, 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6850687/>>
- HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. **The Elements of Statistical Learning**. NY: Springer, 2009. v. 27 Disponível em: <<http://www.springerlink.com/index/D7X7KX6772HQ2135.pdf>>
- HAYKIN, Simon. **Redes Neurais: princípios e prática**. 2. ed. São Paulo: Bookman, 2001.

HE, Jiayuan et al. A comparison of open-loop and closed-loop adaptive calibration for pattern recognition based myoelectric control. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2015, NY. **Anais...** NY: IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7318568/>>

HO, Lok Man; SATZGER, Clemens; DE CASTRO, Ricardo. Fault-tolerant control of an electrohydraulic brake using virtual pressure sensor. In: INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION SCIENCES (ICRAS), 2017, NY. **Anais...** NY: IEEE, 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8071920/>>

HUANG, Cheng-lung; DUN, Jian-fan. A distributed PSO–SVM hybrid system with feature selection and parameter optimization. **Applied Soft Computing**, [s. l.], v. 8, n. 4, p. 1381–1391, 2008. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1568494607001299>>

HUANG, He et al. Design of a robust EMG sensing interface for pattern classification. **Journal of Neural Engineering**, [s. l.], v. 7, n. 5, 2010. Disponível em: <<http://stacks.iop.org/1741-2552/7/i=5/a=056005?key=crossref.3b85a946f7ea5624066a265f6d2f7b5b>>

HUANG, Hu et al. Ant colony optimization-based feature selection method for surface electromyography signals classification. **Computers in Biology and Medicine**, [s. l.], v. 42, n. 1, p. 30–38, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.combiomed.2011.10.004>>

HUANG, Huaiqi et al. EMG pattern recognition using decomposition techniques for constructing multiclass classifiers. In: IEEE INTERNATIONAL CONFERENCE ON BIOMEDICAL ROBOTICS AND BIOMECHATRONICS (BIOROB) 2016, NY. **Anais...** NY: IEEE, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7523810/>>

HUANG, Qi et al. A Novel Unsupervised Adaptive Learning Method for Long-Term Electromyography (EMG) Pattern Recognition. **Sensors**, [s. l.], v. 17, n. 6, 2017. Disponível em: <<http://www.mdpi.com/1424-8220/17/6/1370>>

HUDGINS, Bernard; PARKER, Philip; SCOTT, R. N. A new strategy for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, NY, v. 40, n. 1, p. 82–94, 1993. Disponível em: <<http://ieeexplore.ieee.org/document/204774/>>

IBARGÜENGOYTIA, Pablo H. et al. Viscosity virtual sensor to control combustion in fossil fuel power plants. **Engineering Applications of Artificial Intelligence**, [s. l.], v. 26, n. 9, p. 2153–2163, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.engappai.2013.05.004>>

ISAKOVIC, Milica S.; MILJKOVIC, Nadica; POPOVIC, Mirjana B. Classifying sEMG-based hand movements by means of principal component analysis. In: TELECOMMUNICATIONS FORUM TELFOR (TELFOR) 2014, NY. **Anais...** NY: IEEE, 2014. Disponível em: <<http://ieeexplore.ieee.org/document/7034467/>>

ISON, Mark; ARTEMIADIS, Panagiotis. The role of muscle synergies in myoelectric control: trends and challenges for simultaneous multifunction control. **Journal of Neural Engineering**, [s. l.], v. 11, n. 5, 2014. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/25188509>>

JACHAN, Michael et al. Time-frequency ARMA models and parameter estimators for

underspread nonstationary random processes. **IEEE Transactions on Signal Processing**, NY, v. 55, n. 9, p. 4366–4381, 2007.

JIANG, N. et al. Myoelectric Control of Artificial Limbs: Is There a Need to Change Focus? [In the Spotlight]. **IEEE Signal Processing Magazine**, NY, v. 29, n. 5, p. 150–152, 2012.

JIANG, Ning; LORRAIN, Thomas; FARINA, Dario. A state-based, proportional myoelectric control method: online validation and comparison with the clinical state-of-the-art. **Journal of NeuroEngineering and Rehabilitation**, NY, v. 11, n. 1, 2014. Disponível em: <<http://jneuroengrehab.biomedcentral.com/articles/10.1186/1743-0003-11-110>>

KANITZ, Gunter R. et al. Decoding of individuated finger movements using surface EMG and input optimization applying a genetic algorithm. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY 2011, NY. **Anais...** NY: IEEE, 2011. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/22254630>>

KARABULUT, Derya et al. Comparative evaluation of EMG signal features for myoelectric controlled human arm prosthetics. **Biocybernetics and Biomedical Engineering**, [s. l.], v. 37, n. 2, p. 326–335, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.bbe.2017.03.001>>

KAUR, Ashmeet et al. Segmentation of the EMG Signal and Comparison of the Normal and Diseased EMG signals. **International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE)**, [s. l.], v. 4, n. 11, p. 2767–2772, 2015.

KAUR, Gurmanik; ARORA, As; JAIN, Vk. Comparison of the techniques used for segmentation of EMG signals. In: INTERNATIONAL CONFERENCE ON MATHEMATICAL AND COMPUTATIONAL METHODS IN SCIENCE AND ENGINEERING 2009, **Anais...** [s.l: s.n.] Disponível em: <<http://www.wseas.us/e-library/conferences/2009/baltimore/MACMESE/MACMESE-17.pdf>>

KAUTZ, Thomas; ESKOFIER, Bjoern. A Robust Kalman Framework with Resampling and Optimal Smoothing. **Sensors**, [s. l.], v. 15, n. 3, p. 4975–4995, 2015. Disponível em: <<http://www.mdpi.com/1424-8220/15/3/4975/>>

KECMAN, V. **Learning and Soft Computing: Support Vector Machines, Neural Networks and Fuzzy Logic Models**. USA: MIT PRESS, 2001.

KHEZRI, Mahdi; JAHED, Mehran. A neuro-fuzzy inference system for sEMG-based identification of hand motion commands. **IEEE Transactions on Industrial Electronics**, NY, v. 58, n. 5, p. 1952–1960, 2011.

KHUSHABA, Rami N. Correlation Analysis of Electromyogram Signals for Multiuser Myoelectric Interfaces. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 22, n. 4, p. 745–755, 2014. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6737313>>

KHUSHABA, Rami N. et al. Combined influence of forearm orientation and muscular contraction on EMG pattern recognition. **Expert Systems with Applications**, [s. l.], v. 61, p. 154–161, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2016.05.031>>

KIRYU, T.; SAITOH, Y.; ISHIOKA, K. Investigation on parametric analysis of dynamic

EMG signals by a muscle-structured simulation model. **IEEE Transactions on Biomedical Engineering**, NY, v. 39, n. 3, p. 280–288, 1992. Disponível em:

<<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=125013>>

KRASOULIS, Agamemnon et al. Improved prosthetic hand control with concurrent use of myoelectric and inertial measurements. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 14, n. 1, 2017. Disponível em:

<<http://jneuroengrehab.biomedcentral.com/articles/10.1186/s12984-017-0284-4>>

KRASOULIS, Agamemnon; NAZARPOUR, Kianoush; VIJAYAKUMAR, Sethu. Use of regularized discriminant analysis improves myoelectric hand movement classification. In: INTERNATIONAL IEEE/EMBS CONFERENCE ON NEURAL ENGINEERING (NER) 2017, NY. **Anais...** NY: IEEE, 2017. Disponível em:

<<http://ieeexplore.ieee.org/document/8008373/>>

KUAN, Ta-Wen et al. VLSI Design of an SVM Learning Core on Sequential Minimal Optimization Algorithm. **IEEE Transactions on Very Large Scale Integration (VLSI) Systems**, NY, v. 20, n. 4, p. 673–683, 2012. Disponível em:

<<http://ieeexplore.ieee.org/document/5713858/>>

KUIKEN, Todd A. Targeted Muscle Reinnervation for Real-time Myoelectric Control of Multifunction Artificial Arms. **JAMA**, [s. l.], v. 301, n. 6, p. 619–628, 2009. Disponível em:

<<http://jama.jamanetwork.com/article.aspx?doi=10.1001/jama.2009.116>>

LEBREUX, Marc; DÉSILETS, Martin; LACROIX, Marcel. Prediction of the ledge thickness inside a high-temperature metallurgical reactor using a virtual sensor. **Journal of Physics: Conference Series**, [s. l.], v. 395, n. 8, 2012. Disponível em: <<http://stacks.iop.org/1742-6596/395/i=1/a=012077?key=crossref.7eb69adf676430237db7772cffd8ea4a>>

LI, Guanglin; SCHULTZ, Aimee E.; KUIKEN, Todd A. Quantifying pattern recognition-based myoelectric control of multifunctional transradial prostheses. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 18, n. 2, p. 185–192, 2010.

LI, Yuanqing et al. A self-training semi-supervised SVM algorithm and its application in an EEG-based brain computer interface speller system. **Pattern Recognition Letters**, [s. l.], v. 29, n. 9, p. 1285–1294, 2008.

LIN, Jonathan Feng-Shun; KULIC, Dana. Online Segmentation of Human Motion for Automated Rehabilitation Exercise Analysis. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 22, n. 1, p. 168–180, 2014. Disponível em:

<<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6512570>>

LIN, Shih-Wei et al. Particle swarm optimization for parameter determination and feature selection of support vector machines. **Expert Systems with Applications**, [s. l.], v. 35, n. 4, p. 1817–1824, 2008.

LIU, Jianwei et al. Reduced Daily Recalibration of Myoelectric Prosthesis Classifiers Based on Domain Adaptation. **IEEE journal of biomedical and health informatics**, [s. l.], v. 20, n. 1, p. 166–76, 2016. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/25532196>>

LIU, Jie. Adaptive myoelectric pattern recognition toward improved multifunctional prosthesis control. **Medical Engineering & Physics**, [s. l.], v. 37, n. 4, p. 424–430, 2015.

Disponível em: <<http://dx.doi.org/10.1016/j.medengphy.2015.02.005>>

LIU, Kun; INOUE, Yoshio; SHIBATA, Kyoko. Physical-Sensor and Virtual-Sensor Based Method for Estimation of Lower Limb Gait Posture Using Accelerometers and Gyroscopes. **Journal of Biomechanical Science and Engineering**, [s. l.], v. 5, n. 4, p. 472–483, 2010. Disponível em: <<http://joi.jlc.jst.go.jp/JST.JSTAGE/jbse/5.472?from=CrossRef>>

LÓPEZ, Victoria et al. An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics. **Information Sciences**, [s. l.], v. 250, p. 113–141, 2013. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0020025513005124>>

LORENA, a. C.; DE CARVALHO, a. C. P. L. F. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, [s. l.], v. 14, n. 2, p. 43–67, 2007. Disponível em: <http://seer.ufrgs.br/index.php/rita/article/viewArticle/rita_v14_n2_p43-67>

MAHALANOBIS, P. C. On the generalized distance in statistics. **Proceedings of the National Institute of Sciences of India**, Calcutta, v. 2, n. 1, p. 49–55, 1936.

MALANDA, Armando et al. Sliding window averaging for the extraction of representative waveforms from motor unit action potential trains. **Biomedical Signal Processing and Control**, [s. l.], v. 27, p. 32–43, 2016. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1746809416000045>>

MASTINU, Enzo et al. An Alternative Myoelectric Pattern Recognition Approach for the Control of Hand Prostheses: A Case Study of Use in Daily Life by a Dysmelia Subject. **IEEE Journal of Translational Engineering in Health and Medicine**, NY, v. 6, 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8314725/>>

MATSUBARA, Takamitsu; MORIMOTO, Jun. Bilinear Modeling of EMG Signals to Extract User-Independent Features for Multiuser Myoelectric Interface. **IEEE Transactions on Biomedical Engineering**, NY, v. 60, n. 8, p. 2205–2213, 2013. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6472786>>

MAZURKIEWICZ, Przemyslaw. Automatic Segmentation of EMG Signals Based on Wavelet Representation. In: **Computer Recognition Systems 2**. Berlin, Heidelberg: Springer, 2007. p. 589–595.

MCCOOL, Paul et al. Identification of contaminant type in surface electromyography (EMG) signals. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 22, n. 4, p. 774–783, 2014.

MIRANDA DE SÁ, Antonio Mauricio F. L. et al. A principal component-based algorithm for denoising in single channel data (PCA for denoising in single channel data). **Measurement: Journal of the International Measurement Confederation**, [s. l.], v. 60, p. 121–128, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.measurement.2014.09.079>>

MOGK, Jeremy P. M. M.; KEIR, Peter J. Crosstalk in surface electromyography of the proximal forearm during gripping tasks. **Journal of Electromyography and Kinesiology**, [s. l.], v. 13, n. 1, p. 63–71, 2003. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1050641102000718>>

MONTGOMERY, Douglas C. **Design and Analysis of Experiments**. 5th Edition ed. New York: John Wiley & Sons, INC., 2001.

MOURA, Karina O. A.; FAVIEIRO, Gabriela W.; BALBINOT, Alexandre. Support vectors machine classification of surface electromyography for non-invasive naturally controlled hand prostheses. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2016, NY. **Anais...** NY: IEEE, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7590819/>>

MOURA, Karina O. A.; RUSCHEL, Raphael S.; BALBINOT, Alexandre. Fault-Tolerant Sensor Detection of sEMG signals: Quality Analysis Using a Two-Class Support Vector Machine. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2018, NY. **Anais...** NY: IEEE, 2018.

NAIK, Ganesh R. et al. Principal Component Analysis Applied to Surface Electromyography: A Comprehensive Review. **IEEE Access**, NY, v. 4, p. 4025–4037, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7516567/>>

NAIK, Ganesh R.; KUMAR, Dinesh Kant; JAYADEVA. Twin SVM for gesture classification using the surface electromyogram. **IEEE Transactions on Information Technology in Biomedicine**, NY, v. 14, n. 2, p. 301–308, 2010.

NATIONAL INSTRUMENTS. **Características Técnicas do NI-USB-6289**, 2014.

NAZARI, R. et al. Fault-tolerant control of systems with convex polytopic linear parameter varying model uncertainty using virtual-sensor-based controller reconfiguration. **Annual Reviews in Control**, [s. l.], v. 37, n. 1, p. 146–153, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.arcontrol.2013.04.004>>

NAZMI, Nurhazimah et al. A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions. **Sensors**, [s. l.], v. 16, n. 8, 2016. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/27548165>>

NGEO, Jimson G.; TAMEI, Tomoya; SHIBATA, Tomohiro. Continuous and simultaneous estimation of finger kinematics using inputs from an EMG-to-muscle activation model. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 11, 2014. Disponível em: <<http://jneuroengrehab.biomedcentral.com/articles/10.1186/1743-0003-11-122>>

NIELSEN, Johnny L. G. et al. Simultaneous and proportional force estimation for multifunction myoelectric prostheses using mirrored bilateral training. **IEEE Transactions on Biomedical Engineering**, NY, v. 58, n. 3, p. 681–688, 2011.

NILSON, Clairê D. E. Pauli. **Aquisição, Processamento de Sinais Mioelétricos e Máquinas de Vetores de Suporte para Caracterização de Movimentos do Segmento Mão-Braço**. 2014. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2014.

NILSSON, Niclas; HÅKANSSON, Bo; ORTIZ-CATALAN, Max. Classification complexity in myoelectric pattern recognition. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 14, 2017. Disponível em: <<http://jneuroengrehab.biomedcentral.com/articles/10.1186/s12984-017-0283-5>>

ORTIZ-CATALAN, Max et al. Offline accuracy: A potentially misleading metric in myoelectric pattern recognition for prosthetic control. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2015, NY. **Anais...** NY: IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7318567/>>

ORTIZ-CATALAN, Max; BRÅNEMARK, Rickard; HÅKANSSON, Bo. BioPatRec: A modular research platform for the control of artificial limbs based on pattern recognition algorithms. **Source Code for Biology and Medicine**, [s. l.], v. 8, 2013. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3669028&tool=pmcentrez&rendertype=abstract>>

OSKOEI, Mohammadreza Asghari; HU, Huosheng. GA-based Feature Subset Selection for Myoelectric Classification. In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND BIOMIMETICS, 2006, NY. **Anais...** NY: IEEE, 2006. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4142082>>

PAISS, Omry; INBAR, Gideon F. Autoregressive Modeling of Surface EMG and Its Spectrum with Application to Fatigue. **IEEE Transactions on Biomedical Engineering**, NY, v. BME-34, n. 10, p. 761–770, 1987.

PARK, Ki-hee; LEE, Seong-whan. Movement intention decoding based on deep learning for multiuser myoelectric interfaces. In: INTERNATIONAL WINTER CONFERENCE ON BRAIN-COMPUTER INTERFACE (BCI) 2016, NY. **Anais...** NY: IEEE, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7457459/>>

PARK, Seongsik et al. Dynamic motion phase segmentation using sEMG during countermovement jump based on hidden semi-Markov model. In: INTERNATIONAL CONFERENCE ON UBIQUITOUS ROBOTS AND AMBIENT INTELLIGENCE (URAI) 2015, NY. **Anais...** NY: IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7358869/>>

PATTICHIS, C. S.; PATTICHIS, M. S. Time-scale analysis of motor unit action potentials. **IEEE Transactions on Biomedical Engineering**, NY, v. 46, n. 11, p. 1320–1329, 1999. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0030312521&partnerID=tZOtx3y1>>

PATTICHIS, C. S.; SCHIZAS, C. N.; MIDDLETON, L. T. Neural network models in EMG diagnosis. **IEEE Transactions on Biomedical Engineering**, NY, v. 42, n. 5, p. 486–496, 1995. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=376153>>

PEZARAT-CORREIA, P.; MIL-HOMENS, P. **A Electromiografia no Estudo do Movimento**. 1. ed. Lisboa.

PHINYOMARK, A. et al. Feature Extraction and Reduction of Wavelet Transform Coefficients for EMG Pattern Classification. **Electronics and Electrical Engineering**, [s. l.], v. 122, n. 6, p. 27–32, 2012. Disponível em: <<http://www.eejournal.ktu.lt/index.php/elt/article/view/1816>>

PHINYOMARK, Angkoon et al. EMG feature evaluation for improving myoelectric pattern recognition robustness. **Expert Systems with Applications**, [s. l.], v. 40, n. 12, p. 4832–4840, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2013.02.023>>

PLATT, John C. Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines. **Advances in kernel methods**, [s. l.], p. 1–21, 1998. Disponível em: <http://www.bradblock.com/Sequential_Minimal_Optimization_A_Fast_Algorithm_for_Training_Support_Vector_Machine.pdf>

PLOENNIGS, Joern et al. Virtual sensors for estimation of energy consumption and thermal comfort in buildings with underfloor heating. **Advanced Engineering Informatics**, [s. l.], v. 25, n. 4, p. 688–698, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.aei.2011.07.004>>

PONSART, J. C.; THEILLIOL, D.; AUBRUN, C. Virtual sensors design for active fault tolerant control system applied to a winding machine. **Control Engineering Practice**, [s. l.], v. 18, n. 9, p. 1037–1044, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.conengprac.2010.05.006>>

QIAN, Huimin et al. Recognition of human activities using SVM multi-class classifier. **Pattern Recognition Letters**, [s. l.], v. 31, n. 2, p. 100–111, 2010.

RASOOL, Ghulam et al. Surface myoelectric signal classification using the AR-GARCH model. **Biomedical Signal Processing and Control**, [s. l.], v. 13, n. 1, p. 327–336, 2014.

RAVEENDRANATHAN, Nikhil et al. From Modeling to Implementation of Virtual Sensors in Body Sensor Networks. **IEEE Sensors Journal**, NY, v. 12, n. 3, p. 583–593, 2012. Disponível em: <<http://ieeexplore.ieee.org/document/5721776/>>

REAZ, M. B. I.; HUSSAIN, M. S.; MOHD-YASIN, F. Techniques of EMG signal analysis: detection, processing, classification and applications. **Biological procedures online**, [s. l.], v. 8, n. 1, p. 11–35, 2006.

RECHY-RAMIREZ, Ericka Janet; HU, Huosheng. **Stages for Developing Control Systems using EMG and EEG Signals : A survey**. 2011. Technical Report: CES-513 - University of Essex, United Kingdom, 2011.

RECHY-RAMIREZ, Ericka Janet; HU, Huosheng. Bio-signal based control in assistive robots: a survey. **Digital Communications and Networks**, [s. l.], v. 1, n. 2, p. 85–101, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2352864815000097>>

REKHI, Navleen Singh et al. Multi-Class SVM Classification of Surface EMG Signal for Upper Limb Function. In: INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICAL ENGINEERING 2009, NY. **Anais...** NY: IEEE, 2009. Disponível em: <<http://ieeexplore.ieee.org/document/5163093/>>

RIILLO, F. et al. Optimization of EMG-based hand gesture recognition: Supervised vs. unsupervised data preprocessing on healthy subjects and transradial amputees. **Biomedical Signal Processing and Control**, [s. l.], v. 14, n. 1, p. 117–125, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.bspc.2014.07.007>>

ROSSI, Matteo et al. Hybrid EMG classifier based on HMM and SVM for hand gesture recognition in prosthetics. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY (ICIT), 2015, NY. **Anais...** NY: IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7125342/>>

SÁNCHEZ-MOLINA, J. A. et al. Water content virtual sensor for tomatoes in coconut coir

substrate for irrigation control design. **Agricultural Water Management**, [s. l.], v. 151, p. 114–125, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2014.09.013>>

SCHACK, B. et al. Methods of dynamic spectral analysis by self-exciting autoregressive moving average models and their application to analysing biosignals. **Medical & Biological Engineering & Computing**, [s. l.], v. 33, n. 3, p. 492–498, 1995.

SCHOLKOPF, Bernhard; SMOLA, Alexander J. **Learning With Kernels: Support Vector Machines, Regularization, Optimization, and Beyond**. MA, USA: MIT Press Cambridge, 2001.

SEBALD, D. J.; BUCKLEW, J. a. Support vector machine techniques for nonlinear equalization. **IEEE Transactions on Signal Processing**, NY, v. 48, n. 11, p. 3217–3226, 2000.

SEBELIUS, F. et al. Myoelectric control of a computer animated hand: A new concept based on the combined use of a tree-structured artificial neural network and a data glove. **Journal of Medical Engineering & Technology**, [s. l.], v. 30, n. 1, p. 2–10, 2006. Disponível em: <<http://www.tandfonline.com/doi/full/10.1080/03091900512331332546>>

SEDLÁK, Jan et al. Segmentation of Surface EMG Signals. In: INTERNATIONAL CONFERENCE ON APPLIED ELECTRONICS, 2013, NY. **Anais...** NY: IEEE, 2013.

SENSINGER, Jonathon W.; LOCK, Blair A.; KUIKEN, Todd A. Adaptive pattern recognition of myoelectric signals: Exploration of conceptual framework and practical algorithms. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 17, n. 3, p. 270–278, 2009.

SHI, Lei; LIU, Zhen; WANG, Qiang. A Novel Method of sEMG Signal Segmentation. In: IEEE INTERNATIONAL CONFERENCE ON MOBILE AD-HOC AND SENSOR NETWORKS 2013, NY. **Anais...** NY: IEEE, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6726388/>>

SOEDIRDJO, S. D. H.; ULLAH, K.; MERLETTI, R. Power line interference attenuation in multi-channel sEMG signals: Algorithms and analysis. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2015, NY. **Anais...** NY: IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7319227/>>

SPANIAS, John A.; PERREAULT, Eric J.; HARGROVE, Levi J. Detection of and Compensation for EMG Disturbances for Powered Lower Limb Prosthesis Control. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 24, n. 2, p. 226–234, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7070694/>>

SRINIVASA, Praveen Lakkur et al. Development of two degree of freedom (DoF) bionic hand for below elbow amputee. In: IEEE INTERNATIONAL CONFERENCE ON ELECTRONICS, COMPUTING AND COMMUNICATION TECHNOLOGIES, 2013, NY. **Anais...** NY: IEEE, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6469296/>>

SUBASI, Abdulhamit. Classification of EMG signals using combined features and soft computing techniques. **Applied Soft Computing Journal**, [s. l.], v. 12, n. 8, p. 2188–2198, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.asoc.2012.03.035>>

- SUBASI, Abdulhamit. Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders. **Computers in Biology and Medicine**, [s. l.], v. 43, n. 5, p. 576–586, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.complbiomed.2013.01.020>>
- SUDHEER, Ch et al. A hybrid SVM-PSO model for forecasting monthly streamflow. **Neural Computing and Applications**, [s. l.], v. 24, n. 6, p. 1381–1389, 2014.
- SUYKENS, J. A. K. Nonlinear modelling and support vector machines. In: INSTRUMENTATION AND MEASUREMENT TECHNOLOGY CONFERENCE (IMTC) 2001, **Anais...** : IEEE, 2001. Disponível em: <<http://ieeexplore.ieee.org/document/928828/>>
- TABBACHE, Bekheira et al. Virtual-Sensor-Based Maximum-Likelihood Voting Approach for Fault-Tolerant Control of Electric Vehicle Powertrains. **IEEE Transactions on Vehicular Technology**, NY, v. 62, n. 3, p. 1075–1083, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6362287/>>
- TANG, Xueyan et al. Hand motion classification using a multi-channel surface electromyography sensor. **Sensors**, [s. l.], v. 12, n. 2, p. 1130–1147, 2012.
- TARVAINEN, M. P. et al. Estimation of Nonstationary EEG With Kalman Smoother Approach: An Application to Event-Related Synchronization (ERS). **IEEE Transactions on Biomedical Engineering**, NY, v. 51, n. 3, p. 516–524, 2004. Disponível em: <<http://ieeexplore.ieee.org/document/1268221/>>
- TOMASINI, Marco et al. Power Line Interference Removal for High-Quality Continuous Biosignal Monitoring with Low-Power Wearable Devices. **IEEE Sensors Journal**, NY, v. 16, n. 10, p. 3887–3895, 2016.
- TOMMASI, Tatiana et al. Improving control of dexterous hand prostheses using adaptive learning. **IEEE Transactions on Robotics**, NY, v. 29, n. 1, p. 207–219, 2013.
- TORRENT-FONTBONA, F. Adaptive basal insulin recommender system based on Kalman filter for type 1 diabetes. **Expert Systems with Applications**, [s. l.], v. 101, p. 1–7, 2018. Disponível em: <<https://doi.org/10.1016/j.eswa.2018.02.015>>
- TORTORA, Gerard J.; DERRICKSON, Bryan. Capítulo 8. In: **Corpo humano: fundamentos de anatomia e fisiologia (8a. ed.)**. [s.l: s.n.]. p. 184–236.
- TORTORA, Gerard J.; DERRICKSON, Bryan. Capítulo 9. In: **Corpo humano: fundamentos de anatomia e fisiologia (8a. ed.)**. [s.l: s.n.]. p. 237–254.
- TOSIN, M. C. Mauricio C. et al. SEMG feature selection and classification using SVM-RFE. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBS) 2017, NY. **Anais...** NY: IEEE, 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8036844/>>
- TOSIN, Mauricio C. C. **Aplicação de Algoritmos de Seleção de Características na Classificação de Movimentos do Segmento Mão-Braço Através do Processamento de Sinais de sEMG**. 2018. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2018.
- TOWNSEND, Daphne; GOUBRAN, Rafik; KNOEFEL, Frank. Time domain

characterization of window length and type on moving variance signal features. In: IEEE INTERNATIONAL SYMPOSIUM ON MEDICAL MEASUREMENTS AND APPLICATIONS PROCEEDINGS, 2012, NY. **Anais...** NY: IEEE, 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6226625/>>

TSAI, An-Chih; LUH, Jer-Junn; LIN, Ta-Te. A novel STFT-ranking feature of multi-channel EMG for motion pattern recognition. **Expert Systems with Applications**, [s. l.], v. 42, n. 7, p. 3327–3341, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2014.11.044>>

TUCKER, Michael R. et al. Control strategies for active lower extremity prosthetics and orthotics: a review. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 12, n. 1, 2015. Disponível em: <<http://www.jneuroengrehab.com/content/12/1/1>>

ÜBEYLI, Elif Derya. Least squares support vector machine employing model-based methods coefficients for analysis of EEG signals. **Expert Systems with Applications**, [s. l.], v. 37, n. 1, p. 233–239, 2010.

VAN DE WALLE, A.; NAETS, F.; DESMET, W. Virtual microphone sensing through vibro-acoustic modelling and Kalman filtering. **Mechanical Systems and Signal Processing**, [s. l.], v. 104, p. 120–133, 2018. Disponível em: <<https://doi.org/10.1016/j.ymssp.2017.08.032>>

VAPNIK, Vladimir N.; CHERVONENKIS, Alexey Ya. On the Uniform Convergence of the Frequencies of Occurrence of Events to Their Probabilities. In: SCHÖLKOPF, Bernhard; LUO, Zhiyuan; VOVK, Vladimir (Eds.). **Empirical Inference**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 7–12.

VEER, Karan. A technique for classification and decomposition of muscle signal for control of myoelectric prostheses based on wavelet statistical classifier. **Measurement**, [s. l.], v. 60, p. 283–291, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.measurement.2014.10.023>>

VIDOVIC, Marina M. C. et al. Improving the Robustness of Myoelectric Pattern Recognition for Upper Limb Prostheses by Covariate Shift Adaptation. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 24, n. 9, p. 961–970, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7302056/>>

VUJAKLIJA, Ivan et al. Translating Research on Myoelectric Control into Clinics—Are the Performance Assessment Methods Adequate? **Frontiers in Neurorobotics**, [s. l.], v. 11, n. 7, p. 1–7, 2017. Disponível em: <<http://journal.frontiersin.org/article/10.3389/fnbot.2017.00007/full>>

VUJAKLIJA, Ivan et al. Online mapping of EMG signals into kinematics by autoencoding. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 15, n. 21, p. 1–9, 2018. Disponível em: <<https://jneuroengrehab.biomedcentral.com/articles/10.1186/s12984-018-0363-1>>

WANG, Anna et al. A novel pattern recognition algorithm: Combining ART network with SVM to reconstruct a multi-class classifier. **Computers and Mathematics with Applications**, [s. l.], v. 57, n. 11–12, p. 1908–1914, 2009. Disponível em: <<http://dx.doi.org/10.1016/j.camwa.2008.10.052>>

WILSON, Samuel; VAIDYANATHAN, Ravi. Upper-limb prosthetic control using wearable multichannel mechanomyography. In: IEEE INTERNATIONAL CONFERENCE ON

REHABILITATION ROBOTICS, 2017, NY. **Anais...** NY: IEEE, 2017.

WINKLER, Gabriela; BALBINOT, Alexandre. Proposal of a Neuro Fuzzy System for Myoelectric Signal Analysis from Hand-Arm Segment. In: **Computational Intelligence in Electromyography Analysis**. [s.l.] : InTech, 2012. p. 337–362.

XIE, Hong-Bo et al. A comparative study of surface EMG classification by fuzzy relevance vector machine and fuzzy support vector machine. **Physiological Measurement**, [s. l.], v. 36, n. 2, p. 191–206, 2015. Disponível em: <<http://stacks.iop.org/0967-3334/36/i=2/a=191?key=crossref.03357737514638a8bb1f4e16f90e1912>>

XING, Kexin et al. A real-time EMG pattern recognition method for virtual myoelectric hand control. **Neurocomputing**, [s. l.], v. 136, p. 345–355, 2014. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0925231214000162>>

XU, Qi et al. An adaptive algorithm for the determination of the onset and offset of muscle contraction by EMG signal processing. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, NY, v. 21, n. 1, p. 65–73, 2013.

YETENDJE, A. et al. Invariant-set-based fault tolerant control using virtual sensors. **IET Control Theory and Applications**, [s. l.], v. 5, n. 9, p. 1092–1103, 2011. Disponível em: <<http://digital-library.theiet.org/content/journals/10.1049/iet-cta.2010.0089>>

ZADEH, L. A. Fuzzy sets. **Information and Control**, [s. l.], v. 8, n. 3, p. 338–353, 1965. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S00199586590241X>>

ZADEH, Lotfi A.; YAGER, Ronald R. **An Introduction to Fuzzy Logic Applications in Intelligent Systems**. The Spring ed. Boston, MA: Springer US, 1992. Disponível em: <<http://link.springer.com/10.1007/978-1-4615-3640-6>>

ZHAI, Xiaolong X. L. et al. Short latency hand movement classification based on surface EMG spectrogram with PCA. **38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**, [s. l.], p. 327–330, 2016.

ZHANG, Daohui et al. A comparative study on PCA and LDA based EMG pattern recognition for anthropomorphic robotic hand. In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION (ICRA), 2014, NY. **Anais...** NY: IEEE, 2014. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6907569>>

ZHANG, Xiaorong; HUANG, He. A real-time, practical sensor fault-tolerant module for robust EMG pattern recognition. **Journal of NeuroEngineering and Rehabilitation**, [s. l.], v. 12, n. 18, p. 1–16, 2015. Disponível em: <<http://www.jneuroengrehab.com/content/12/1/18>>

ZHANG, Xiaorong; HUANG, He; YANG, Qing. Real-time implementation of a self-recovery EMG pattern recognition interface for artificial arms. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2013, NY. **Anais...** NY: IEEE, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6610901/>>

ZHANG, Yi et al. Noise-assisted multivariate empirical mode decomposition for multichannel EMG signals. **BioMedical Engineering OnLine**, [s. l.], v. 16, n. 1, p. 107, 2017. a. Disponível em: <<http://biomedical-engineering->

online.biomedcentral.com/articles/10.1186/s12938-017-0397-9>

ZHANG, Yi et al. Performance evaluation of Noise-Assisted Multivariate Empirical Mode Decomposition and its application to multichannel EMG signals. In: **IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC) 2017b**, NY. **Anais...** NY: IEEE, 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8037600/>>

ZHAO, Jingdong et al. EMG Control for a Five-fingered Prosthetic Hand Based on Wavelet Transform and Autoregressive Model. In: **INTERNATIONAL CONFERENCE ON MECHATRONICS AND AUTOMATION**, 2006, NY. **Anais...** NY: IEEE, 2006. Disponível em: <<http://ieeexplore.ieee.org/document/4026238/>>

ZIVANOVIC, Miroslav. Time-Varying Multicomponent Signal Modeling for Analysis of Surface EMG Data. **IEEE Signal Processing Letters**, NY, v. 21, n. 6, p. 692–696, 2014. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=6778792>>

ZOU, Rui; CHON, Ki H. Robust Algorithm for Estimation of Time-Varying Transfer Functions. **IEEE Transactions on Biomedical Engineering**, NY, v. 51, n. 2, p. 219–228, 2004.

APÊNDICE A - RESULTADOS COMPLEMENTARES

Tabela 16 Resultado da taxa média de Falsos Positivos para os canais que não receberam contaminação artificial

Tipo de Contaminante	Taxa de Falso Positivo do SFTD		
	NinaPro Amputados	NinaPro Não Amputados	IEE
Interferencia de ECG	3,86 ± 7,73%	1,63 ± 2,42%	8,29 ± 13,77%
Interferencia de Linha de Energia	3,85 ± 7,71%	1,63 ± 2,42%	8,29 ± 13,77%
Artefatos de Movimento	3,84 ± 7,70%	1,63 ± 2,42%	8,29 ± 13,77%
Deslocamento de Eletrodos	3,74 ± 7,60%	1,63 ± 2,42%	8,29 ± 13,77%
Saturação	3,74 ± 7,60%	1,63 ± 2,42%	8,29 ± 13,77%

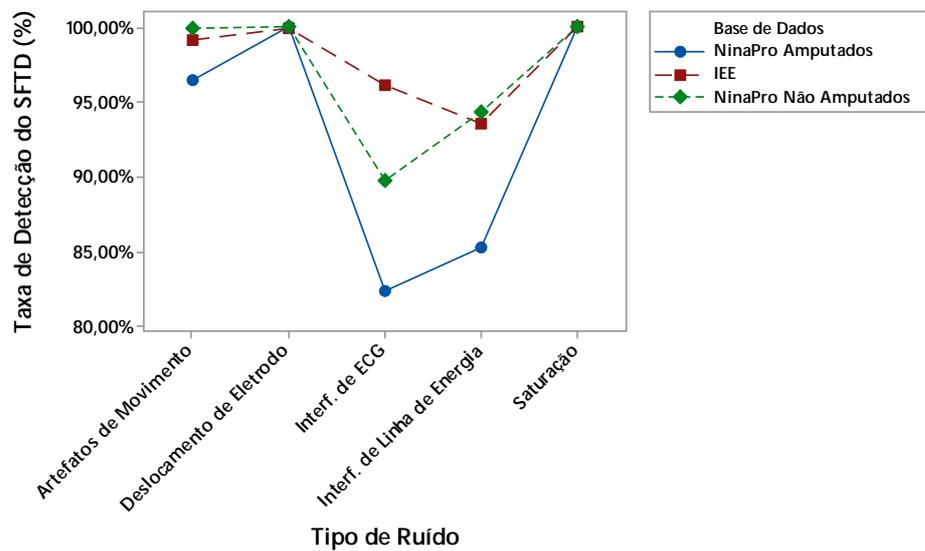


Figura 40 Taxa de detecção do SFTD na interação de base de dados e tipos de ruídos.

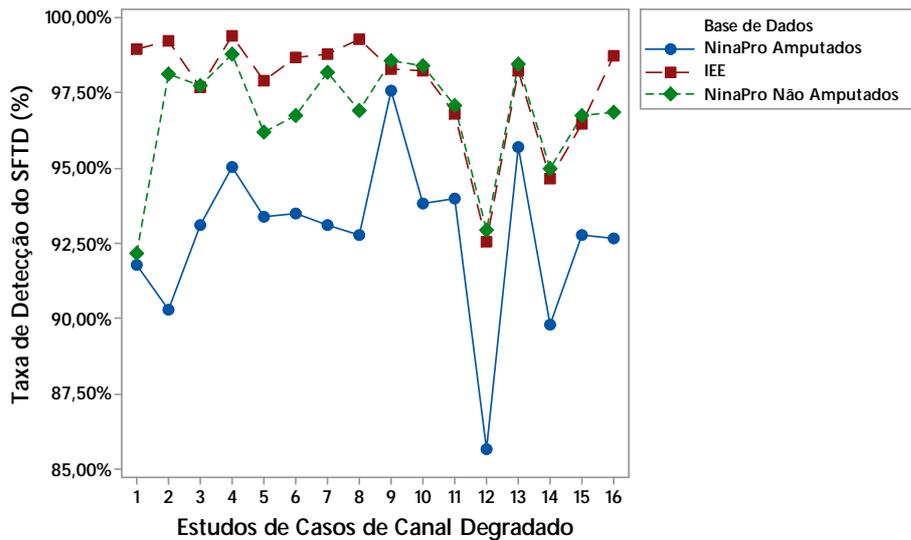


Figura 41 Taxa de detecção do SFTD na interação de base de dados e estudos de caso de degradação.

APÊNDICE B – PROJETOS DE EXPERIMENTOS

Tabela 17 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos, tipos de ruídos e configuração de classificação

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	8823,1	52	169,67	3907,25	0,0
Tipos de Ruído (Fator B)	1372,3	4	343,06	7900,05	0,0
Configuração de Classificação (Fator C)	7175,0	5	1434,99	33044,89	0,0
Interação AB	108,9	208	0,52	12,06	0,0
Interação AC	1316,6	260	5,06	116,61	0,0
Interação BC	4317,3	20	215,86	4970,88	0,0
Interação ABC	390,6	1040	0,38	8,65	0,0
Erro	19816,4	456330	0,04		
Total	43320,0	457919			

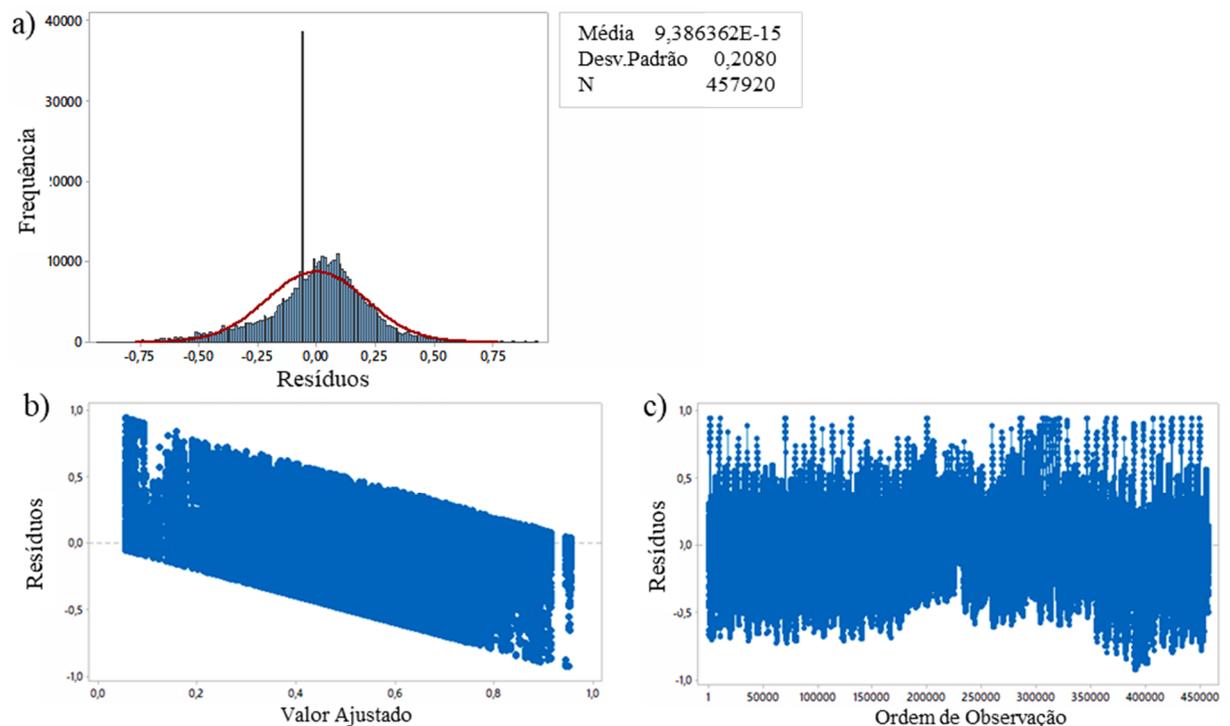


Figura 42 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos, tipos de ruídos e configuração de classificação: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

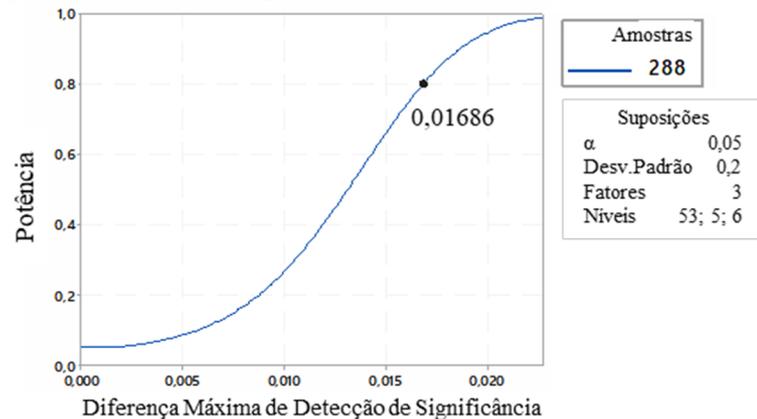


Figura 43 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos, tipos de ruídos e configuração de classificação.

Tabela 18 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	101,03	19	5,3173	157,35	0,0
Estudos de Casos de Degradação (Fator B)	399,98	15	26,6655	789,07	0,0
Configuração de Classificação (Fator C)	439,22	5	87,8433	2599,41	0,0
Interação AB	55,45	285	0,1945	5,76	0,0
Interação AC	59,00	95	0,6211	18,38	0,0
Interação BC	101,44	75	1,3525	40,02	0,0
Interação ABC	117,76	1425	0,0826	2,45	0,0
Erro	1103,02	32640	0,0338		
Total	2376,90	34559			

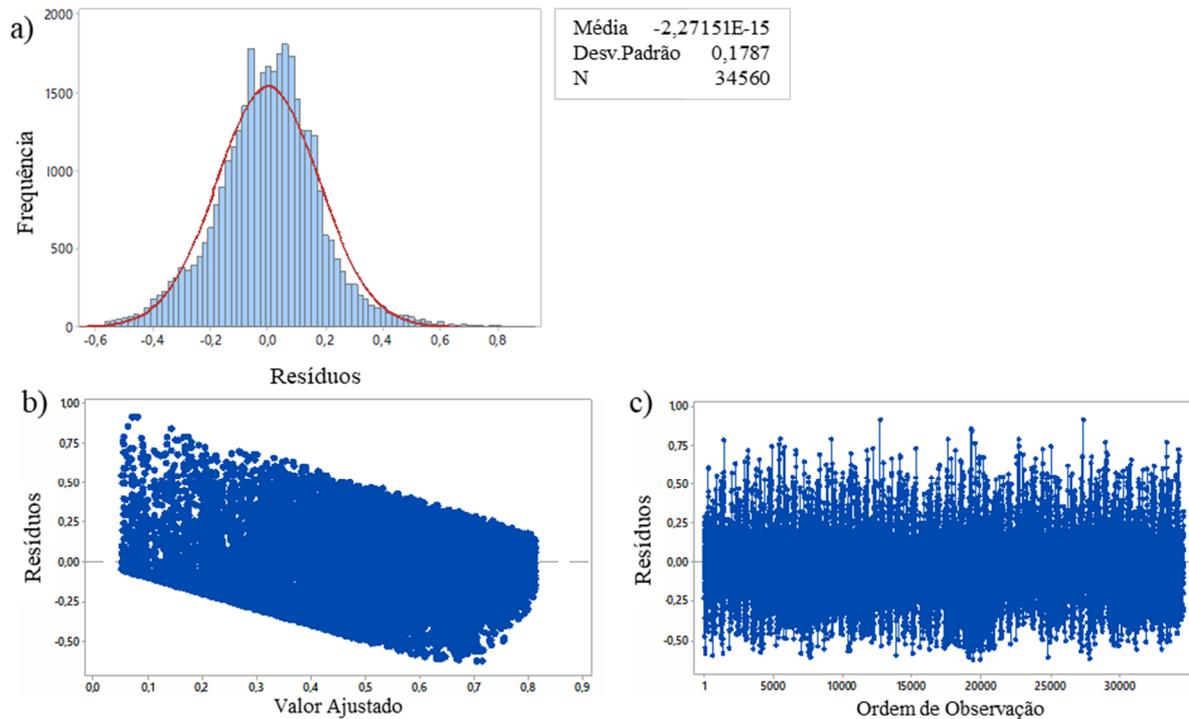


Figura 44 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

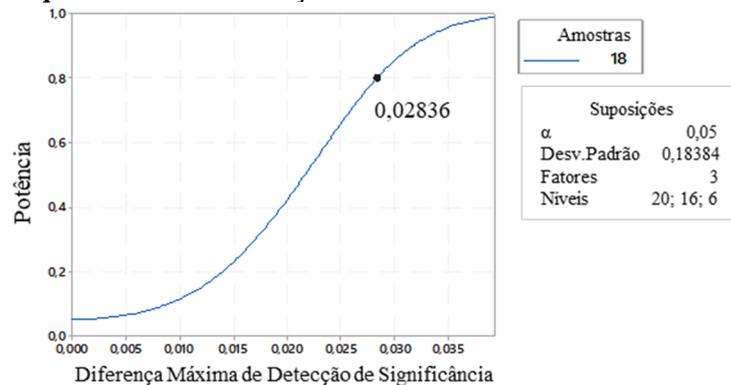


Figura 45 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento.

Tabela 19 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	374,57	12	31,2140	1022,94	0,0
Estudos de Casos de Degradação (Fator B)	135,02	15	9,0013	294,99	0,0
Configuração de Classificação (Fator C)	164,50	5	32,9009	1078,23	0,0
Interação AB	30,93	180	0,1718	5,63	0,0
Interação AC	45,08	60	0,7513	24,62	0,0
Interação BC	33,97	75	0,4530	14,84	0,0
Interação ABC	46,34	900	0,0515	1,69	0,0
Erro	647,38	21216	0,0305		
Total	1477,80	22463			

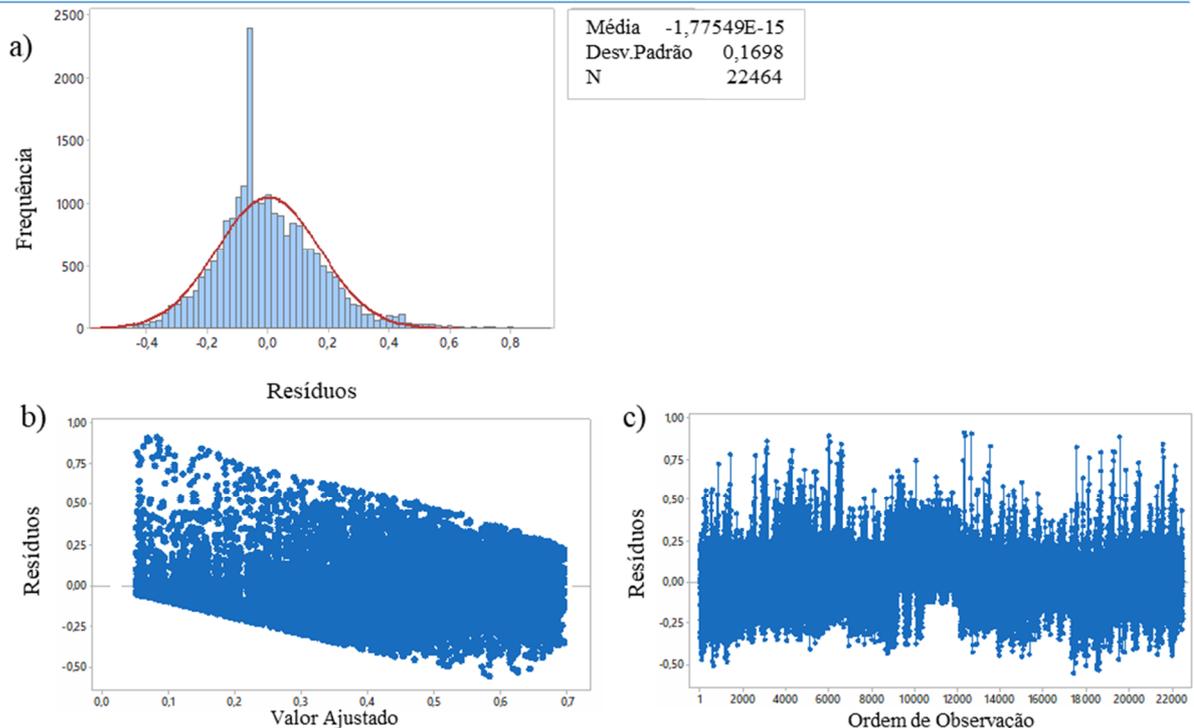


Figura 46 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

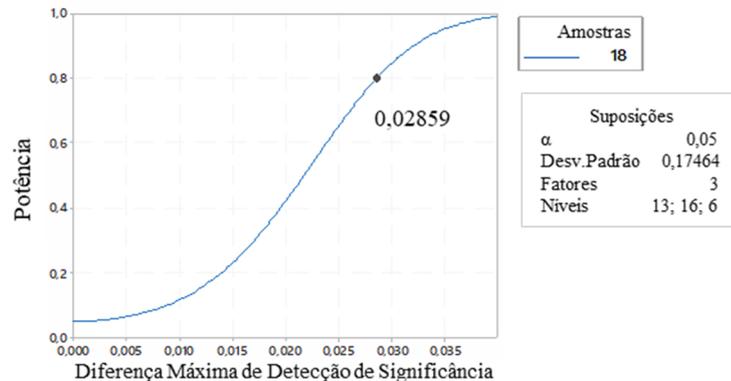


Figura 47 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados da NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento.

Tabela 20 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	1137,26	19	59,856	2007,98	0,0
Estudos de Casos de Degradação (Fator B)	259,74	15	17,316	580,90	0,0
Configuração de Classificação (Fator C)	589,96	5	117,993	3958,29	0,0
Interação AB	50,56	285	0,177	5,95	0,0
Interação AC	121,75	95	1,282	42,99	0,0
Interação BC	67,48	75	0,900	30,18	0,0
Interação ABC	99,29	1425	0,070	2,34	0,0
Erro	972,97	32640	0,030		
Total	3299,01	34559			

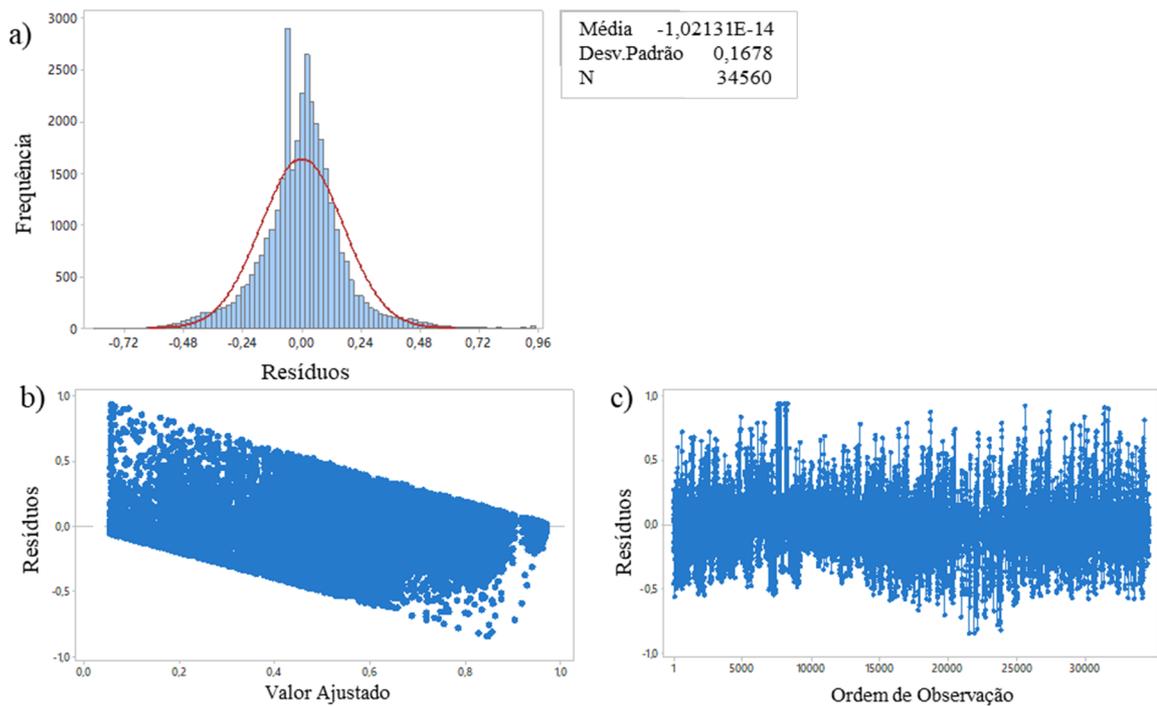


Figura 48 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

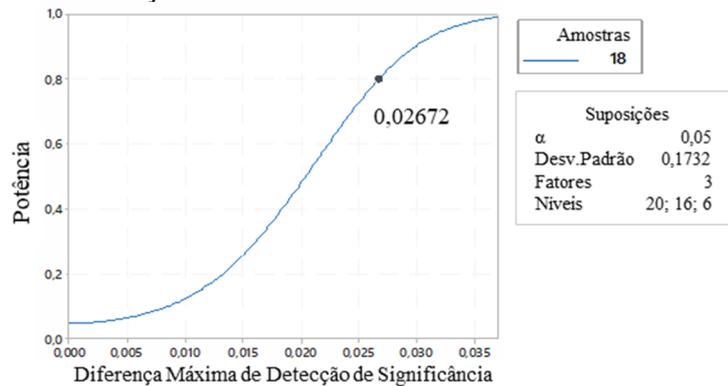


Figura 49 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de artefatos de movimento.

Tabela 21 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	60,99	19	3,210	105,68	0,0
Estudos de Casos de Degradação (Fator B)	371,07	15	24,738	814,43	0,0
Configuração de Classificação (Fator C)	1730,58	5	346,115	11394,80	0,0
Interação AB	14,68	285	0,051	1,70	0,0
Interação AC	41,38	95	0,436	14,34	0,0
Interação BC	362,68	75	4,836	159,20	0,0
Interação ABC	43,61	1425	0,031	1,01	0,418
Erro	991,43	32640	0,030		
Total	3616,42	34559			

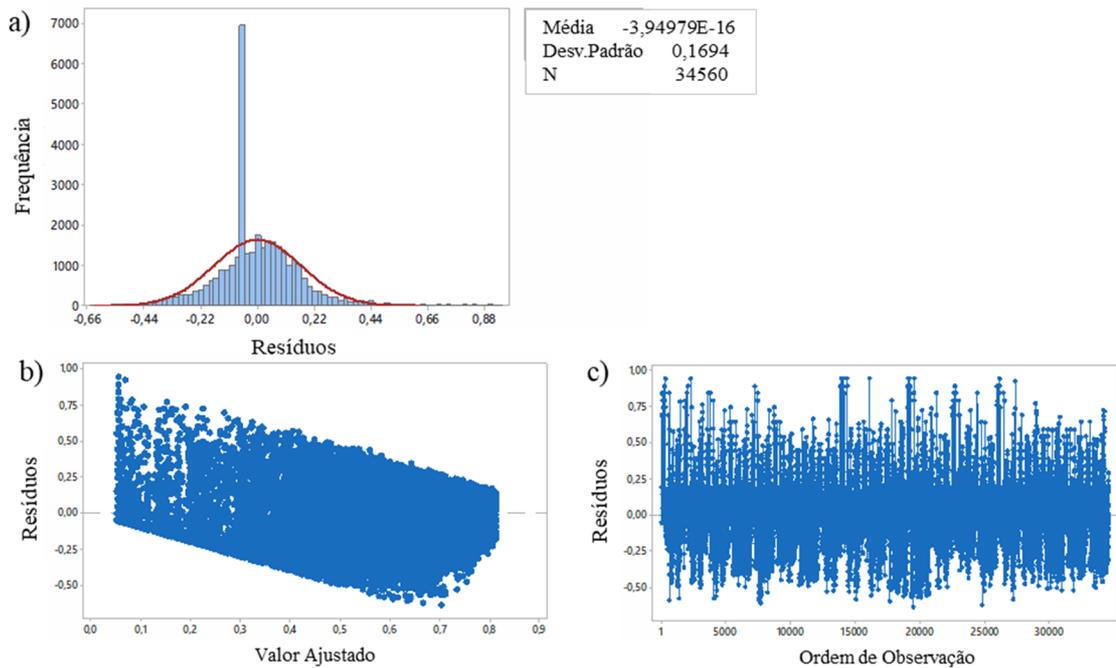


Figura 50 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos: a) Histograma de resíduos; b) Comportamento dos resíduos pelo valor ajustado da resposta; c) Comportamento dos resíduos por ordem de observação.

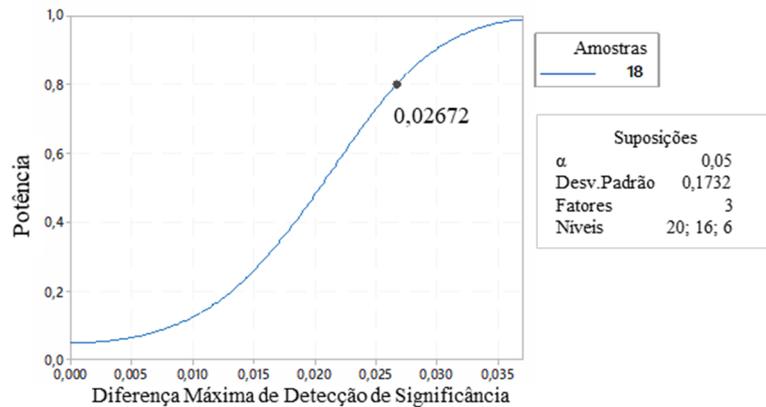


Figura 51 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos.

Tabela 22 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	243,58	12	20,299	719,71	0,0
Estudos de Casos de Degradação (Fator B)	132,82	15	8,854	331,94	0,0
Configuração de Classificação (Fator C)	541,39	5	108,278	3839,12	0,0
Interação AB	24,70	180	0,137	4,86	0,0
Interação AC	86,91	60	1,448	51,36	0,0
Interação BC	109,04	75	1,454	51,55	0,0
Interação ABC	45,88	900	0,051	1,81	0,0
Erro	598,38	21216	0,028		
Total	1782,69	22463			

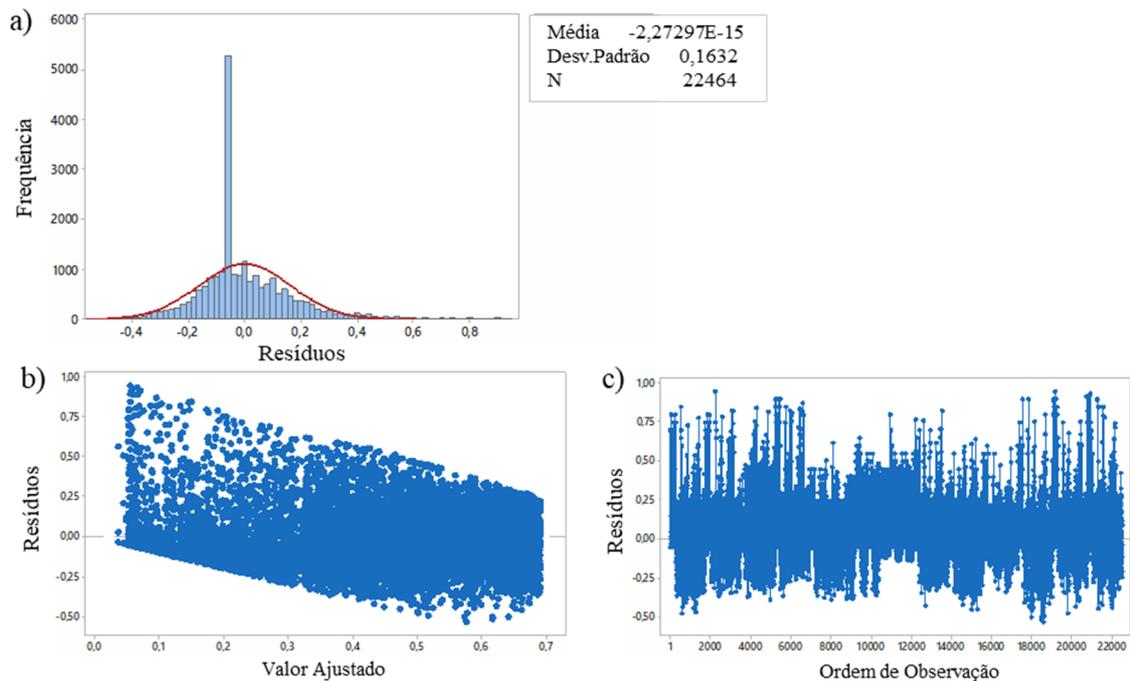


Figura 52 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

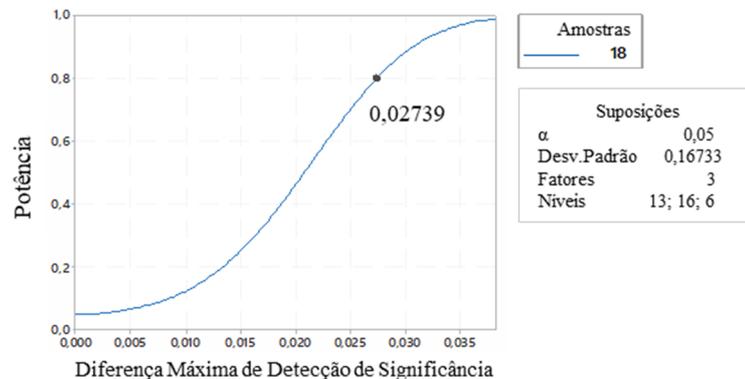


Figura 53 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos.

Tabela 23 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	830,27	19	43,698	1447,86	0,0
Estudos de Casos de Degradação (Fator B)	299,08	15	19,939	660,63	0,0
Configuração de Classificação (Fator C)	1752,63	5	350,525	11614,02	0,0
Interação AB	47,00	285	0,165	5,46	0,0
Interação AC	263,59	95	2,775	91,93	0,0
Interação BC	340,10	75	4,535	150,25	0,0
Interação ABC	106,83	1425	0,075	2,48	0,0
Erro	985,12	32640	0,030		
Total	4624,61	34559			

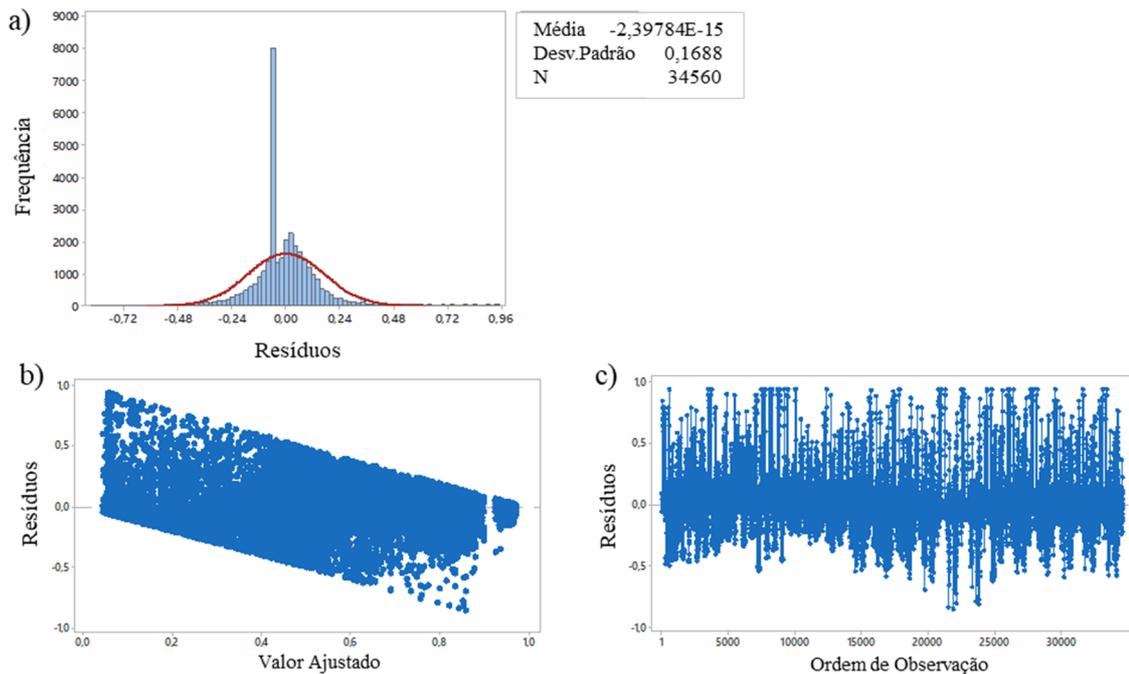


Figura 54 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

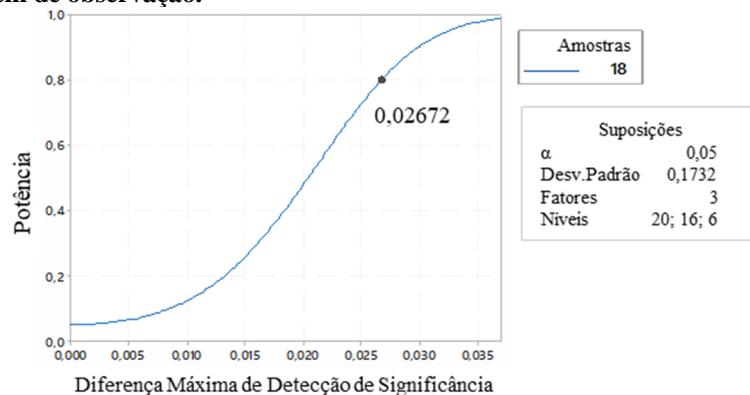


Figura 55 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de deslocamento de eletrodos.

Tabela 24 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	60,31	19	3,174	104,09	0,0
Estudos de Casos de Degradação (Fator B)	370,08	15	24,672	809,13	0,0
Configuração de Classificação (Fator C)	1735,34	5	347,068	11382,25	0,0
Interação AB	14,31	285	0,050	1,65	0,0
Interação AC	41,25	95	0,434	14,24	0,0
Interação BC	364,30	75	4,857	159,30	0,0
Interação ABC	43,54	1425	0,031	1,00	0,474
Erro	995,26	32640	0,030		
Total	3624,38	34559			

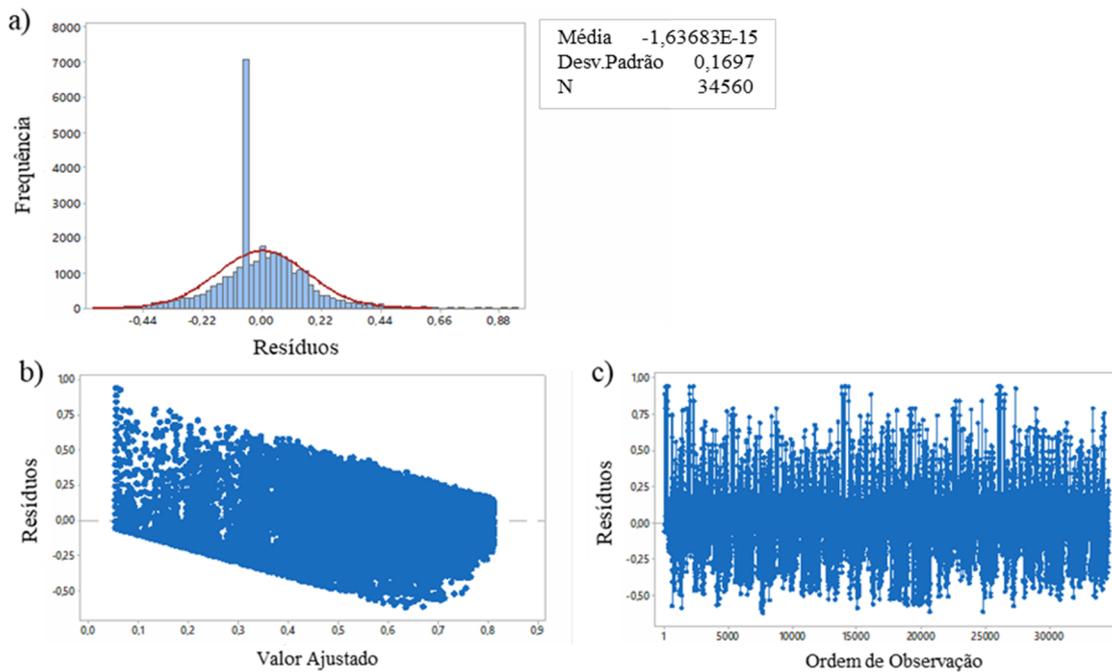


Figura 56 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

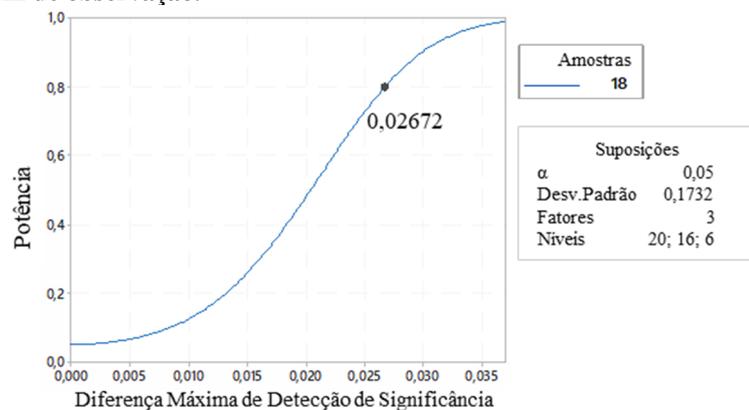


Figura 57 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação.

Tabela 25 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	242,15	12	20,179	720,61	0,0
Estudos de Casos de Degradação (Fator B)	131,60	15	8,773	313,29	0,0
Configuração de Classificação (Fator C)	547,95	5	109,591	3913,51	0,0
Interação AB	24,48	180	0,136	4,86	0,0
Interação AC	87,81	60	1,463	52,26	0,0
Interação BC	110,68	75	0,051	52,70	0,0
Interação ABC	45,82	900	0,028	1,82	0,0
Erro	594,12	21216			
Total	1784,61	22463			

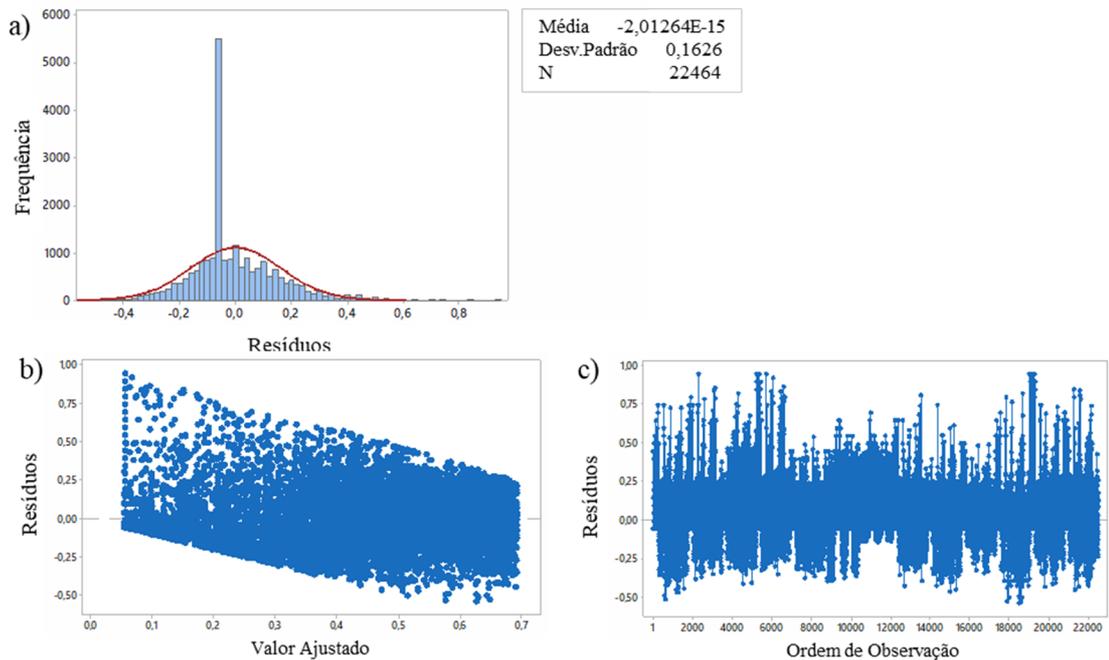


Figura 58 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

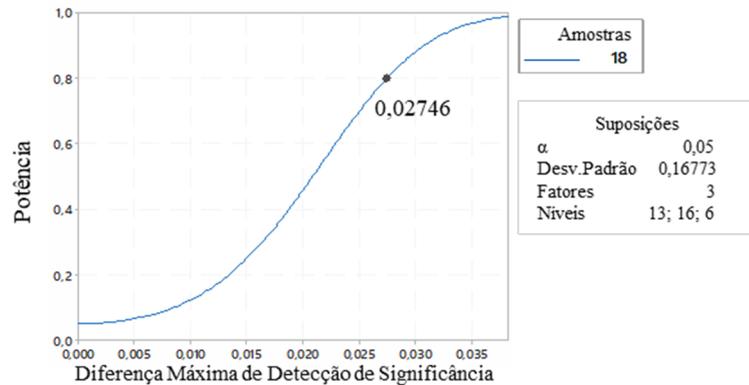


Figura 59 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação.

Tabela 26 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	815,12	19	42,901	1451,30	0,0
Estudos de Casos de Degradação (Fator B)	295,91	15	19,727	667,35	0,0
Configuração de Classificação (Fator C)	1794,84	5	358,968	12143,51	0,0
Interação AB	47,62	285	0,167	5,65	0,0
Interação AC	270,99	95	2,853	96,50	0,0
Interação BC	345,02	75	4,600	155,62	0,0
Interação ABC	111,18	1425	0,078	2,64	0,0
Erro	964,85	32640	0,030		
Total	4645,52	34559			

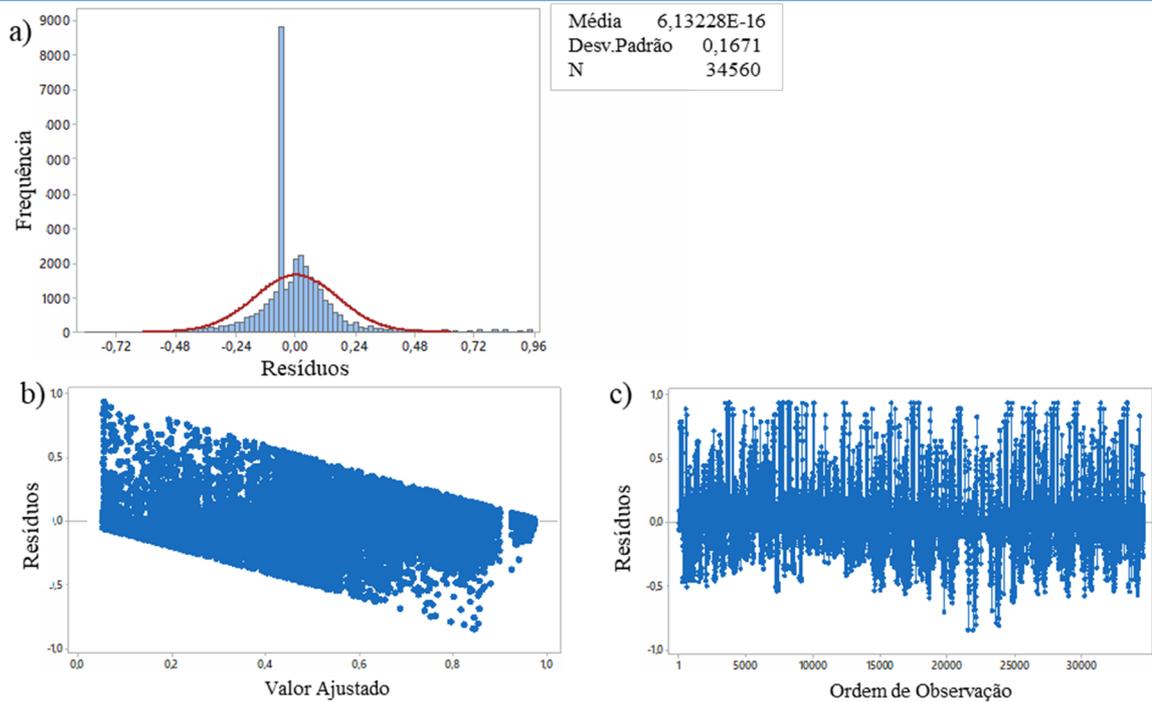


Figura 60 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

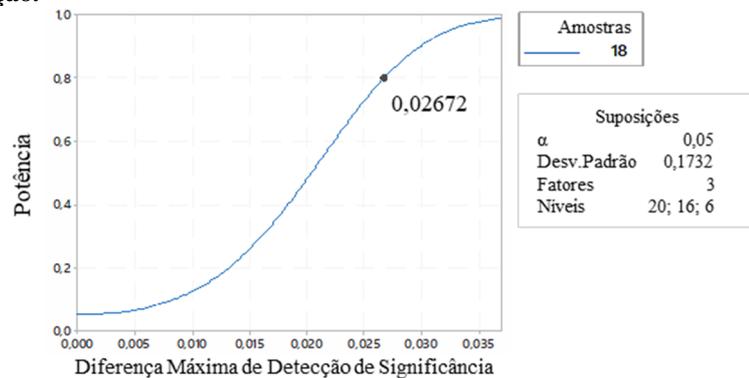


Figura 61 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de saturação.

Tabela 27 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	93,88	19	4,9413	167,91	0,0
Estudos de Casos de Degradação (Fator B)	181,64	15	12,1091	411,47	0,0
Configuração de Classificação (Fator C)	484,95	5	96,9908	3295,77	0,0
Interação AB	45,85	285	0,1609	5,47	0,0
Interação AC	46,65	95	0,4910	16,69	0,0
Interação BC	65,74	75	0,8766	29,79	0,0
Interação ABC	66,97	1425	0,0470	1,60	0,0
Erro	960,56	32640	0,0294		
Total	1946,24	34559			

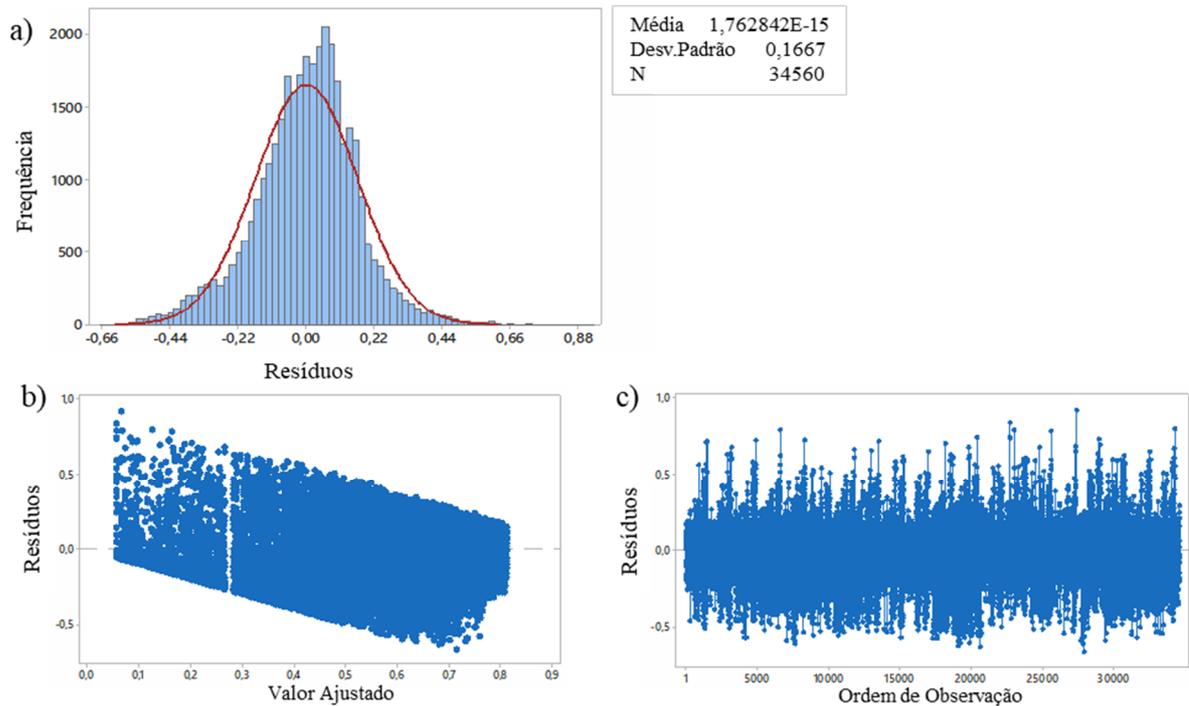


Figura 62 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

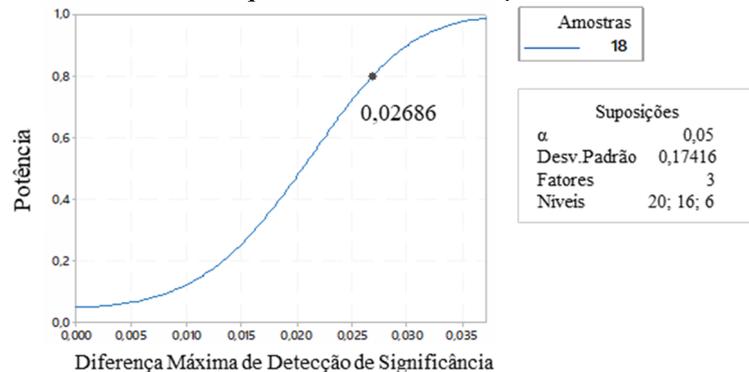


Figura 63 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia.

Tabela 28 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	397,71	12	33,1426	1202,94	0,0
Estudos de Casos de Degradação (Fator B)	53,33	15	3,5557	129,06	0,0
Configuração de Classificação (Fator C)	182,63	5	36,5262	1325,75	0,0
Interação AB	18,89	180	0,1050	3,81	0,0
Interação AC	36,86	60	0,6143	22,30	0,0
Interação BC	22,80	75	0,3040	11,03	0,0
Interação ABC	25,07	900	0,0279	1,01	0,405
Erro	584,53	21216	0,0276		
Total	1321,82	22463			

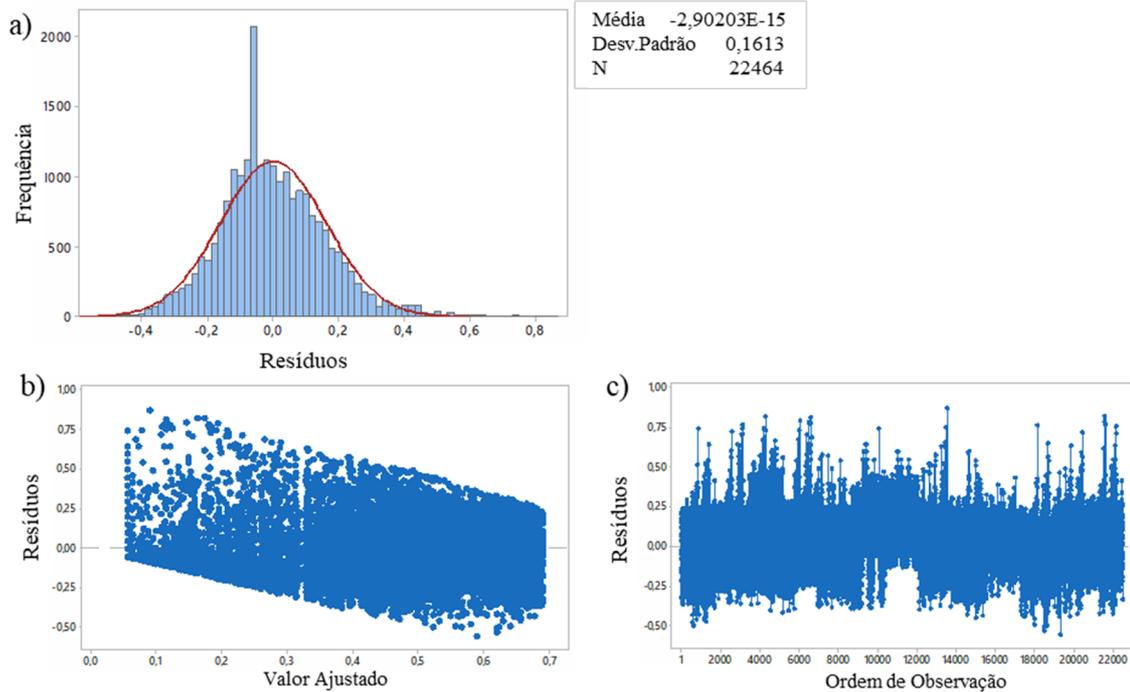


Figura 64 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

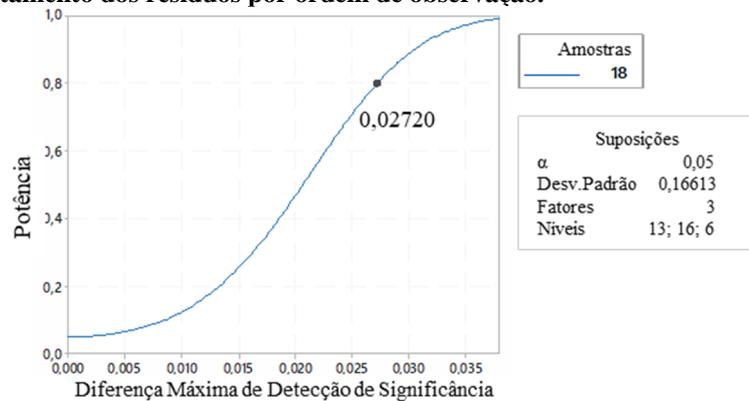


Figura 65 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia.

Tabela 29 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	1142,39	19	60,126	2314,91	0,0
Estudos de Casos de Degradação (Fator B)	124,91	15	8,327	320,60	0,0
Configuração de Classificação (Fator C)	675,24	5	135,048	5199,50	0,0
Interação AB	32,24	285	0,113	4,35	0,0
Interação AC	113,30	95	1,193	45,92	0,0
Interação BC	53,95	75	0,719	27,70	0,0
Interação ABC	89,06	1425	0,062	2,41	0,0
Erro	847,77	32640	0,026		
Total	3078,86	34559			

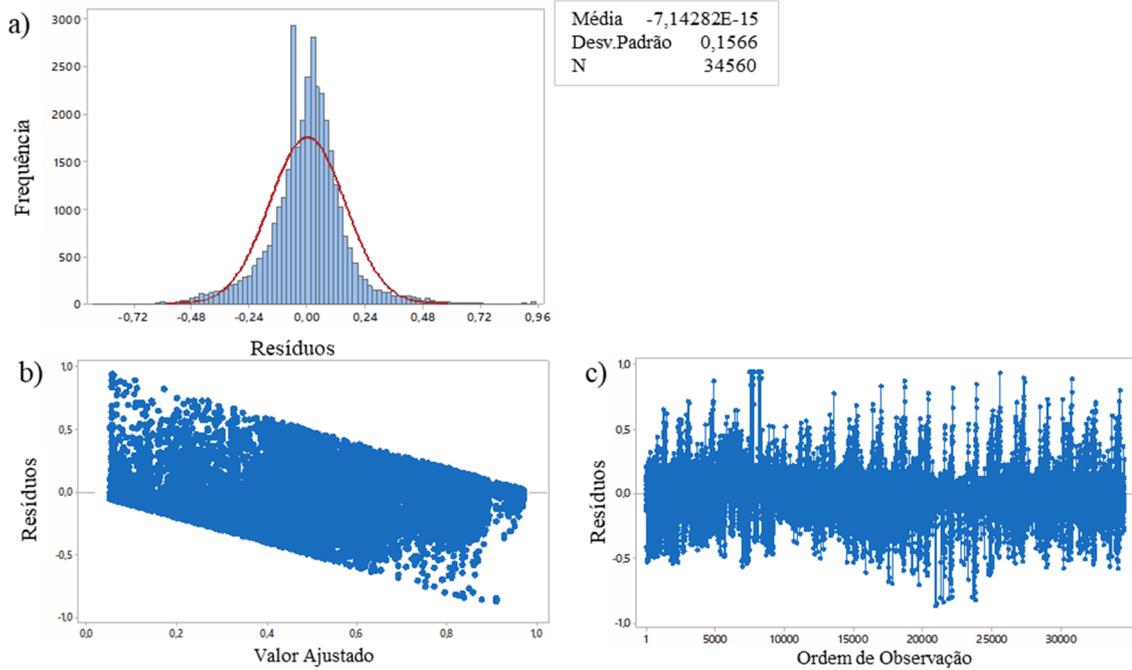


Figura 66 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

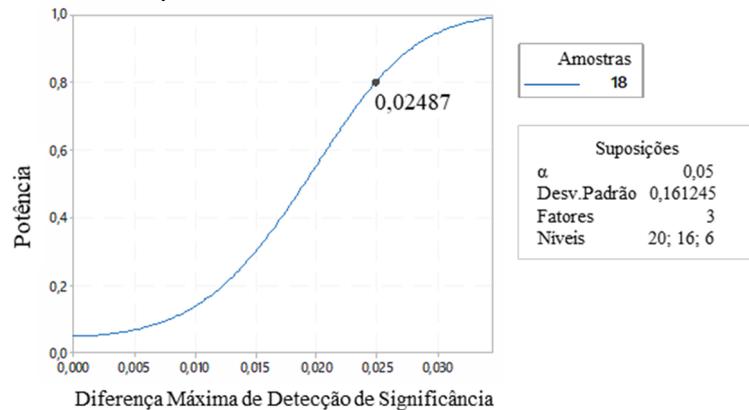


Figura 67 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de linha de energia.

Tabela 30 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	82,05	19	4,3182	134,33	0,0
Estudos de Casos de Degradação (Fator B)	305,10	15	20,3397	632,70	0,0
Configuração de Classificação (Fator C)	406,62	5	81,3233	2529,69	0,0
Interação AB	27,60	285	0,0968	3,01	0,0
Interação AC	43,71	95	0,4601	14,31	0,0
Interação BC	56,48	75	0,7531	23,43	0,0
Interação ABC	53,02	1425	0,0372	1,16	0,0
Erro	1049,30	32640	0,0321		
Total	2023,87	34559			

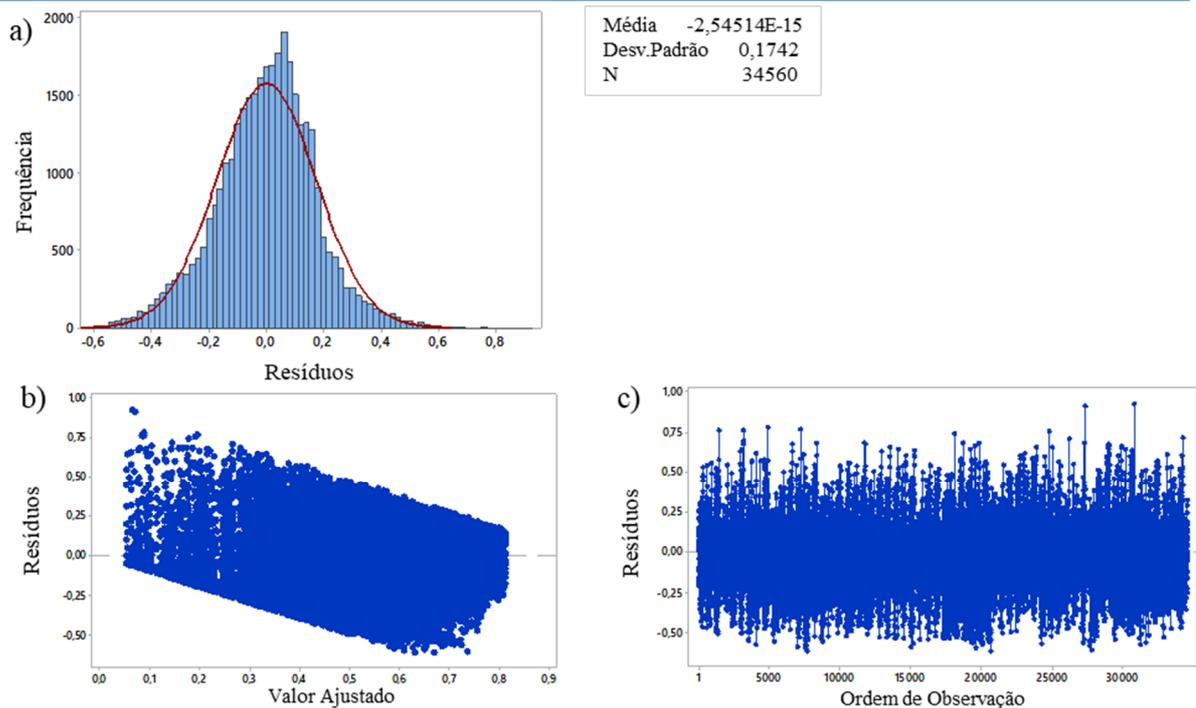


Figura 68 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG: a) Histograma de resíduos; b) Comportamento dos resíduos pelo valor ajustado da resposta; e c) Comportamento dos resíduos por ordem de observação.

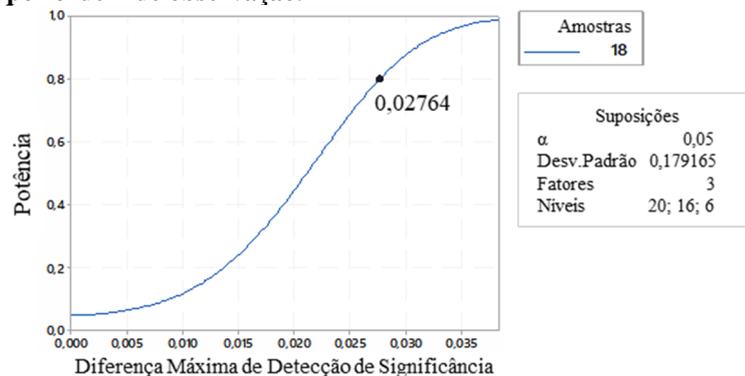


Figura 69 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos não amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG.

Tabela 31 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	361,59	12	30,1322	1062,67	0,0
Estudos de Casos de Degradação (Fator B)	84,59	15	5,6394	198,88	0,0
Configuração de Classificação (Fator C)	155,52	5	31,1034	1096,92	0,0
Interação AB	22,76	180	0,1265	4,46	0,0
Interação AC	36,97	60	0,6161	21,73	0,0
Interação BC	16,53	75	0,2204	7,77	0,0
Interação ABC	23,81	900	0,0265	0,93	0,92
Erro	601,58	21216	0,0284		
Total	1303,56	22463			

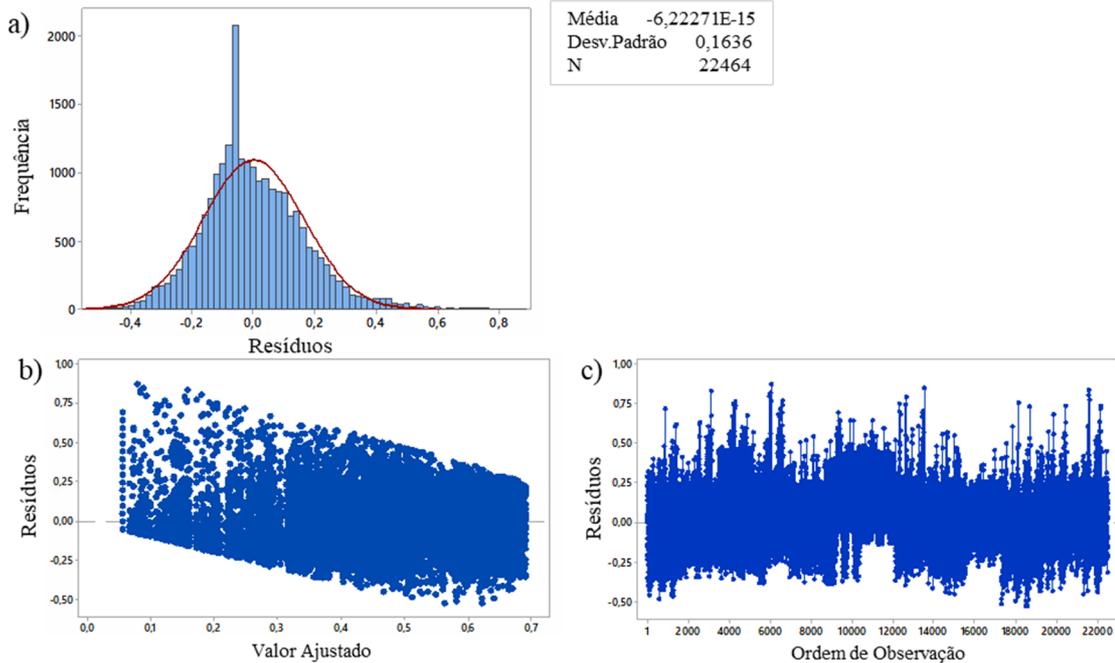


Figura 70 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG: a) Histograma de resíduos; b) Comportamento dos resíduos pelo valor ajustado da resposta; e c) Comportamento dos resíduos por ordem de observação.

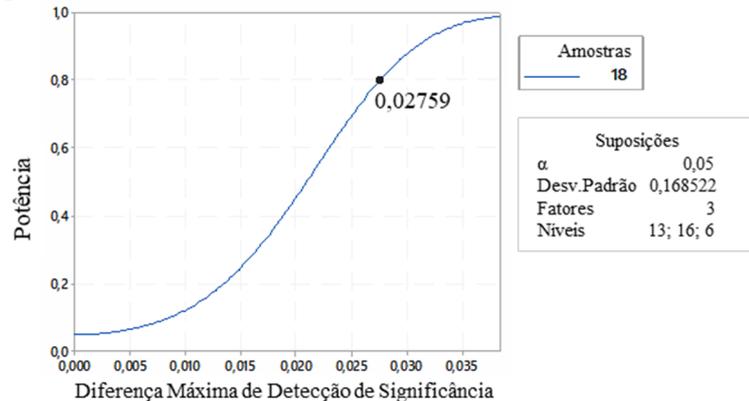


Figura 71 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos amputados do NinaPro, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG.

Tabela 32 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	1092,89	19	57,521	1998,08	0,0
Estudos de Casos de Degradação (Fator B)	240,11	15	16,007	556,04	0,0
Configuração de Classificação (Fator C)	593,75	5	118,750	4124,99	0,0
Interação AB	36,21	285	0,127	4,41	0,0
Interação AC	109,01	95	1,147	39,86	0,0
Interação BC	59,13	75	0,788	27,38	0,0
Interação ABC	74,70	1425	0,052	1,82	0,0
Erro	939,64	32640	0,029		
Total	3145,43	34559			

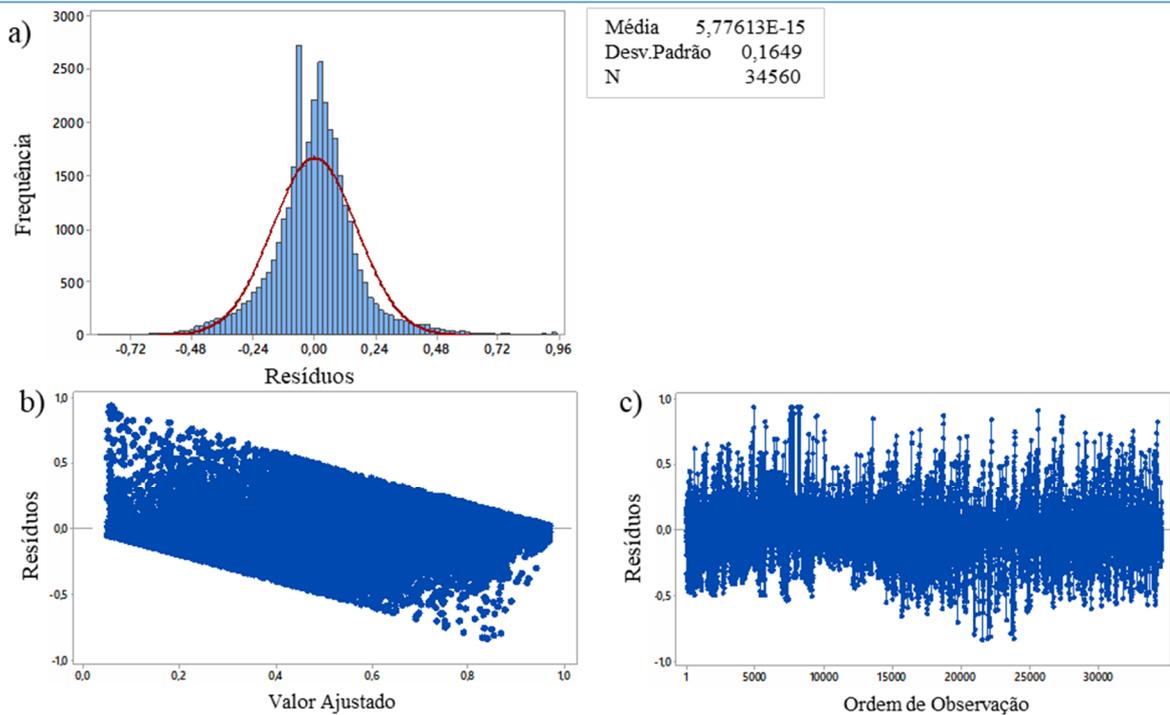


Figura 72 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

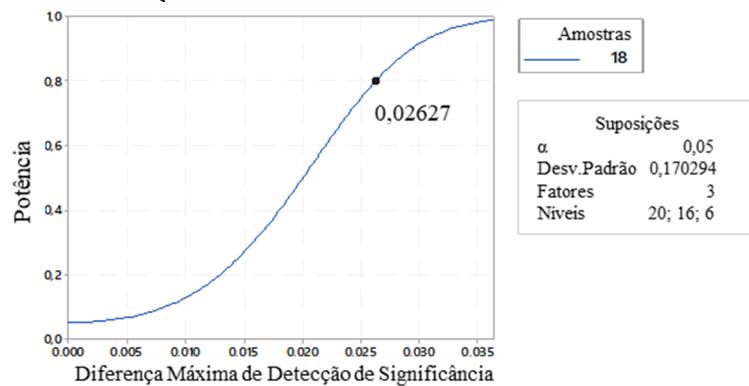


Figura 73 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos do IEE, estudo de casos de degradação de canais e configuração de classificação para o ruído de interferência de ECG.

Tabela 33 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o sistema adaptativo com os modelos do sensor virtual substituindo o sinal contaminado

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	4391,4	52	84,450	1878,64	0,0
Estudos de Casos de Degradação (Fator B)	1822,9	15	121,528	2703,47	0,0
Configuração de Classificação (Fator C)	793,5	1	793,510	17652,19	0,0
Interação AB	662,0	780	0,849	18,88	0,0
Interação AC	241,8	52	4,649	103,43	0,0
Interação BC	86,7	15	5,778	128,54	0,0
Interação ABC	240,5	780	0,308	6,86	0,0
Erro	6785,3	150944	0,045		
Total	15024,0	152639			

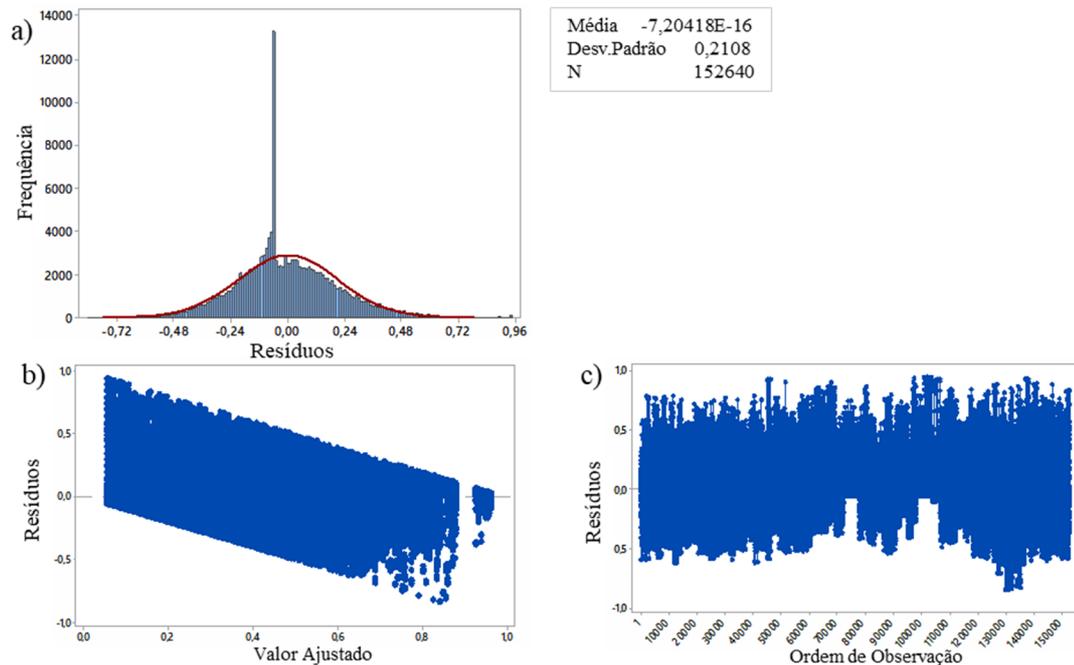


Figura 74 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o sistema adaptativo com os modelos do sensor virtual substituindo o sinal contaminado: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

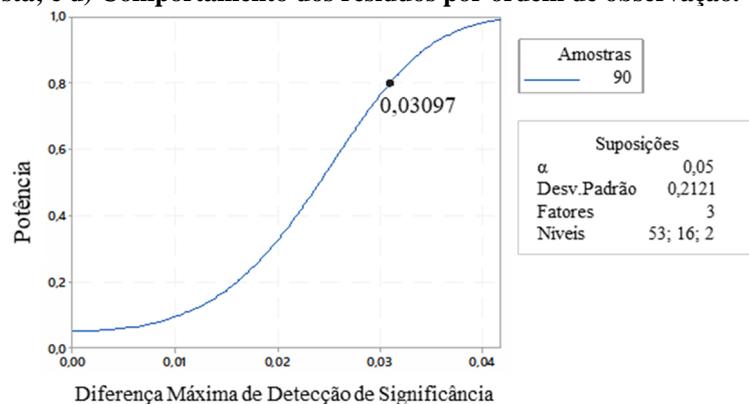


Figura 75 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o sistema adaptativo com os modelos do sensor virtual substituindo o sinal contaminado.

Tabela 34 Cálculo do Projeto de Experimentos da análise da taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o retreinamento do classificador com os modelos do sensor virtual substituindo o sinal contaminado

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	Fator F	P
Sujeitos (Fator A)	3507,64	52	67,4547	4205,46	0,0
Estudos de Casos de Degradação (Fator B)	286,21	15	19,0806	1189,58	0,0
Configuração de Classificação (Fator C)	0,44	1	0,4402	27,44	0,0
Interação AB	43,36	780	0,0556	3,47	0,0
Interação AC	2,30	52	0,0443	2,76	0,0
Interação BC	0,36	15	0,0240	1,50	0,097
Interação ABC	1,60	780	0,0021	0,13	1,000
Erro	2421,11	150944	0,0160		
Total	6263,03	152639			

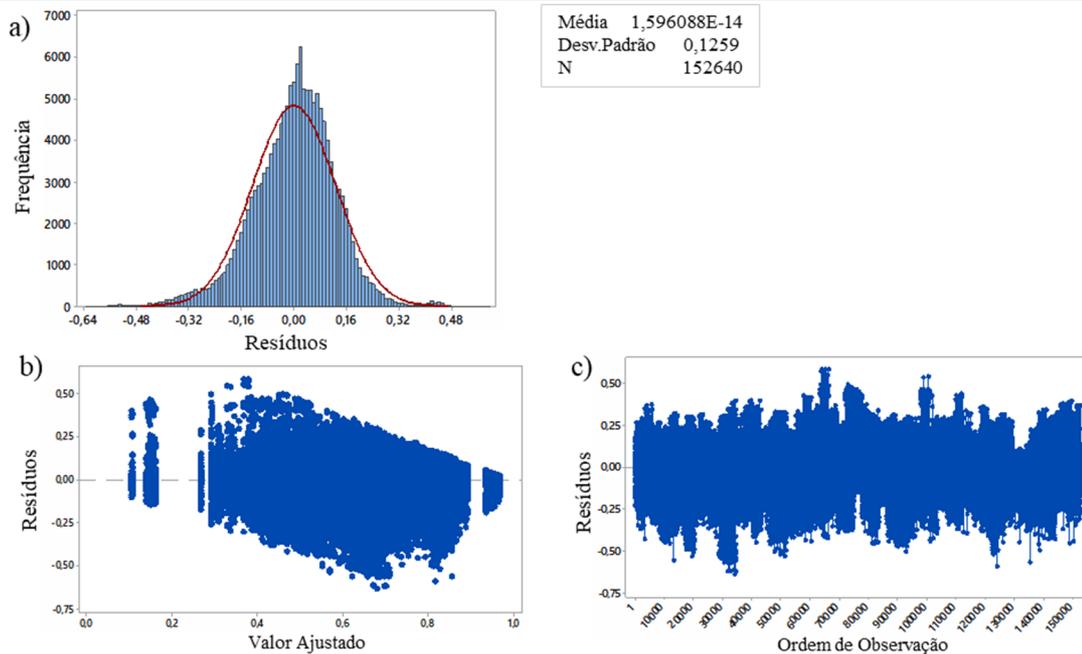


Figura 76 Gráfico de validação do Projeto de Experimentos para taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o retreinamento do classificador com os modelos do sensor virtual substituindo o sinal contaminado: a) Histograma de resíduos; c) Comportamento dos resíduos pelo valor ajustado da resposta; e d) Comportamento dos resíduos por ordem de observação.

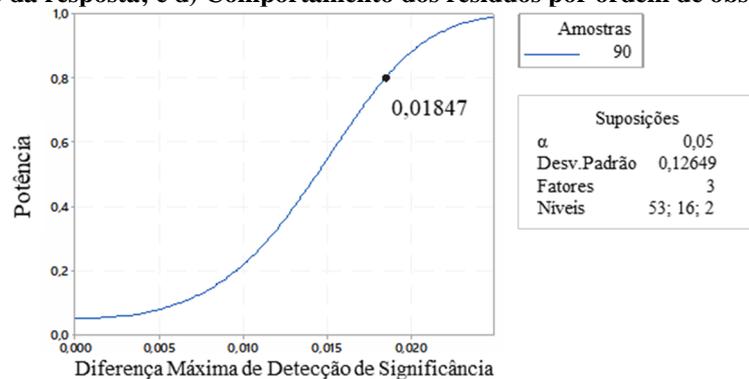


Figura 77 Curva da Potência Estatística do projeto de experimentos para a taxa de acerto média quanto aos fatores de variação sujeitos, estudos de caso de degradação de sinal e configuração de classificação apenas para o retreinamento do classificador com os modelos do sensor virtual substituindo o sinal contaminado.