

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

VINÍCIUS HORN CENE

**MÉTODOS DE CLASSIFICAÇÃO CONFIÁVEL E
RESILIENTE DE MOVIMENTOS DE MEMBROS
SUPERIORES BASEADO EM *EXTREME LEARNING
MACHINES* E SINAIS DE ELETROMIOGRAFIA DE
SUPERFÍCIE**

Porto Alegre

2020

VINÍCIUS HORN CENE

**MÉTODOS DE CLASSIFICAÇÃO CONFIÁVEL E
RESILIENTE DE MOVIMENTOS DE MEMBROS
SUPERIORES BASEADO EM *EXTREME LEARNING
MACHINES* E SINAIS DE ELETROMIOGRAFIA DE
SUPERFÍCIE**

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 Mestre em Engenharia Elétrica.

Área de concentração: Engenharia de Controle e Automação - Instrumentação.

ORIENTADOR: Dr. Alexandre Balbinot

Porto Alegre

2020

VINÍCIUS HORN CENE

**MÉTODOS DE CLASSIFICAÇÃO CONFIÁVEL E
RESILIENTE DE MOVIMENTOS DE MEMBROS
SUPERIORES BASEADO EM *EXTREME LEARNING
MACHINES* E SINAIS DE ELETROMIOGRAFIA DE
SUPERFÍCIE**

Esta Tese de Doutorado 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. Alexandre Rosa Franco, NKI
Doutor pela University of New Mexico – Albuquerque, EUA
Prof. Dr. Altamiro Susin, PPGEE - UFRGS
Doutor pela Institut National Polytechnique de Grenoble – Grenoble, França
Prof. Dr. Fernando Santos Osório, ICMC - USP
Doutor pela Institut National Polytechnique de Grenoble – Grenoble, França
Prof. Dr. Cristiano Bonato Both, PPGCA - UNISINOS
Doutor pela Universidade Federal do Rio Grande do Sul – Porto Alegre, Brasil.
Prof. Dr. Valner 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, Fevereiro de 2020.

DEDICATÓRIA

Aos meus pais, verdadeiros heróis que diligentemente esforçam-se para proporcionar-me uma formação moral e afetiva e por criarem um lar amoroso, em especial a minha mãe, a mulher mais admirável que já conheci na vida. Sinto-me frustrado por não ser capaz de transliterar o tamanho do meu respeito e admiração por estes dois seres incríveis: saibam que tudo que possivelmente realizarei na vida, possuirá a marca de vocês.

Aos meus irmãos, por sempre me oportunizarem respirar, pensar na vida e enxergá-la com a simplicidade e a inocência de uma criança. Quando menor, costumava pensar que “excepcional” uma palavra pejorativa, hoje em dia entendo seu verdadeiro significado.

Aos tantos bons amigos espalhados pelo mundo tentando torna-lo um lugar melhor, continuem o ótimo trabalho. Precisamos cada vez mais de pessoas como vocês.

Aos amigos mais próximos (vocês sabem quem são), verdadeiros irmãos que a vida me deu e que eu não teria como escolher melhor.

A todos que sabem que o extraordinário é algo impossível de ser domado pela tirania da normalidade, em especial, a todos os professores que sempre acreditaram em mim e me apoiaram.

A tantos pesquisadores brilhantes que estabeleceram as bases científicas que possibilitaram as singelas contribuições contidas neste trabalho e a tantos outros que virão e levarão a ciência adiante, consolidando-a como uma ferramenta que possibilite uma vida mais plena a todos os seres.

AGRADECIMENTOS

Ao professor Dr. Alexandre Balbinot pela orientação paciente e de extrema competência, mas acima de tudo pela confiança depositada. Ao PPGEE, pela oportunidade de realização dos trabalhos em minha área de pesquisa bem como a equipe de professores que forneceram muito do subsídio intelectual para a realização deste trabalho e também à CAPES pela bolsa de estudos que tornou este trabalho possível.

Aos colegas do PPGEE e em especial aos colegas e amigos do IEE pelo apoio moral e científico nas diferentes etapas deste projeto e por criarem um ótimo ambiente de trabalho no qual compartilhamos muitos bons momentos durante minha estada no laboratório. Espero que tenha tocado vocês e contribuído para o seu crescimento pessoal e profissional da mesma forma que vocês contribuíram com o meu. Um agradecimento ainda mais especial às colegas Gabriela Favieiro e Karina Alves pelo companheirismo nas disciplinas, trabalhos desenvolvidos e todo o conhecimento e aprendizado compartilhados nesta jornada da Pós-Graduação.

Um agradecimento especial à Sara Borelli, uma das mais gratas surpresas que tive o privilégio de ganhar da vida nos últimos tempos e que foi uma pedra fundamental ao longo deste processo de formação cheio de incertezas e desafios. Não poderia deixar de agradecer também à toda a família de Sara, tanto seus pais Rudimar e Eliana, quanto a sua irmã Camila, por sempre me receberem muito bem no seio da sua família e sempre terem ajudado da melhor forma possível.

In addition, I would like to extend my gratitude to all the brilliant people in Harvard Biodesign Lab that received me for one year as a visiting Ph.D. student and gave me the privilege of sharing uncountable good moments of fun and scientific discoveries. Special thanks to Professor Conor Walsh for leading this group, accepting me and letting me take part in this collection of magnificent human beings who are shaping the future of assistive technology and robotics.

“Per ardua ad astra”.

– Royal Air Force

RESUMO

Apesar de avanços recentes, a classificação confiável de sinais de eletromiografia de superfície (sEMG) permanece uma tarefa árdua sob a perspectiva de Aprendizagem de Máquina. Sinais de sEMG possuem uma sobreposição de classes inerente à sua natureza, o que impede a separação perfeita das amostras e produz ruídos de classificação. Alternativas ao problema geralmente baseiam-se na filtragem do sEMG ou métodos de pós-processamento como o *Major-Voting*, soluções estas que necessariamente geram atrasos na classificação do sinal e frequentemente não geram melhoras substanciais. A abordagem deste trabalho baseia-se no desenvolvimento de métodos confiáveis e resilientes sob a perspectiva de classificação que gerem saídas mais estáveis e consistentes para o classificador baseado em *Extreme Learning Machines* (ELM) utilizado. Para tanto, métodos envolvendo o pré-processamento e pós-processamento, a suavização do *arg max* do classificador, *thresholds* adaptativos e um classificador binário auxiliar foram utilizados. Os sinais classificados derivam de 12 canais de sEMG envolvendo três bases de dados diferentes onde 99 ensaios compostos pela execução de 17 movimentos distintos do segmento mão-braço foram realizados. Nos melhores resultados, os métodos utilizados atingiram taxas de acerto médio global de $66,99 \pm 23,6\%$ para a base de voluntários amputados, $87,10 \pm 5,89\%$ para a base de voluntários não-amputados e taxas superiores a 99% para todas as variações de diferentes ensaios que compõe a base de dados adquirida em laboratório. Já para a taxa de acerto média ponderada por classes, nos melhores resultados foram de $53,36 \pm 18,2\%$ para a base de voluntários amputados, $77,94 \pm 6,22\%$ para a base de voluntários não-amputados e taxas superiores a 91% para os ensaios da base de dados adquirida em laboratório. Ambas as métricas de taxa de acerto consideradas superaram ou equivalem-se a alternativas descritas na literatura, utilizando abordagens que não demandam grandes mudanças estruturais no classificador.

Palavras-chaves: EMG, *Extreme Learning Machines*, Classificação Confiável, Classificação Resiliente, Interação Homem-Máquina.

ABSTRACT

Despite recent advances, reliable classification of surface electromyography (sEMG) signals remains an arduous task from the perspective of Machine Learning. sEMG signals have inherent class overlaps that prevent optimal labeling due to classification noises. Alternatives to classification ripples usually rely on stochastic sEMG filtering or post-processing methods, like Major-Voting, both solutions that insert constraints and additional delays in signal classification and often do not generate substantial improvements. The approach of this paper focuses on the development of reliable and resilient methods used in combination with an Extreme Learning Machines (ELM) classifier to generate more stable and consistent outputs. Methods of pre-processing and post-processing, a smoothed arg max version of the ELM, adaptive thresholds, and an auxiliary binary classifier were used to process signals derived from 12 EMG channels from three different databases. In total, 99 trials were performed, each one containing 17 different upper-limb movements. The proposed methods reached an average overall accuracy rate of $66.99 \pm 23.6\%$ for the amputee individuals' database, $87.10 \pm 5.89\%$ for the non-amputee individuals' database, and rates over 99% for all variations of our own lab-generated database. The average weighted accuracy rates were $53.36 \pm 18.2\%$ for the amputee individuals' database, $77.94 \pm 6.22\%$ for the base of the non-amputee individuals' database, and higher than 91% for the best-case scenario of our own lab-generated database. In both metrics considered, the results outperform, or match alternatives described in the literature using approaches that do not require significant changes in the classifier's architecture.

Keywords: EMG, Extreme Learning Machines, Reliable Classification, Resilient Classification, Human-Machine Interface.

LISTA DE ILUSTRAÇÕES

Figura 1 - Potenciais de ação envolvidos no processo de geração de sinais mioelétricos.	27
Figura 2 - Formação do SME.	28
Figura 3 - Caracterização do sinal proveniente de um canal de eletromiografia: a) amplitude e b) distribuição espectral do sinal para duas repetições de dois movimentos distintos da base IEE.	29
Figura 4 - Principais músculos superficiais do braço e antebraço sEMG.	31
Figura 5 - Arquitetura básica do método ELM utilizada para o reconhecimento de padrões baseada na combinação das diferentes features de entrada.	40
Figura 6 - Diferentes modelos de representação gráfica em função do processamento dos dados de entrada X: a) variáveis consideradas completamente independentes; b) Modelo Markoviano de primeira ordem; c) Modelo Markoviano de segunda ordem e d) <i>Hidden Markov Model</i>	46
Figura 7 - Diagrama de blocos principal do sistema experimental proposto.	67
Figura 8 - Foto Arranjo experimental utilizado na aquisição dos sinais: (1) monitor para a visualização dos movimentos; (2) arranjo dos dois eletromiógrafos utilizados; (3a, 3b e 3c) Cabos do eletromiógrafo: (a) 4 canais para posicionamento específico, (b) 8 canais para posicionamento aleatório e (c) eletrodos de referência; (4) eletrodos de superfície utilizados; (5) placa digitalizadora; (6) borneira e (7) computador utilizado para a aquisição dos sinais rodando LabVIEW® 2009.	69
Figura 9 - Fluxograma da rotina de visualização das animações e aquisição de dados (Fonte: autor).	70
Figura 10 - Posicionamento dos eletrodos no braço de cada voluntário.	72
Figura 11 - Foto da realização de um dos ensaios.	73
Figura 12 - Vídeos representando os movimentos do segmento mão-braço que são repetidos pelos voluntários durante os ensaios.	74
Figura 13 - Exemplo de uma seção de um sinal de sEMG adquirido e do efeito do pré-processamento utilizado no sinal que contém seis repetições de um mesmo movimento. Na figura, 17.a) ilustra o sinal não processado enquanto b) ilustra a mesma seção de sinal após a retificação e c) normalização.	76
Figura 14 - Fluxograma para obtenção e utilização do filtro AVT.	78

Figura 15 - Resultado da aplicação do filtro AVT. Para efeito de comparação são mostrados para um mesmo segmentos de sinal: a) o sinal de sEMG não filtrado; b) o sinal de sEMG filtrado por AVT; c) a <i>feature</i> RMS derivada do sinal de sEMG não filtrada e d) a mesma <i>feature</i> filtrada pelo AVT.	79
Figura 16 - Utilização do DES e do filtro AVT no RELM.	81
Figura 17 – Cálculo do <i>Differential Enhanced Signal</i> (DES) a partir de dois segmentos consecutivos do sinal de sEMG.	82
Figura 18 - Representação dos movimentos fornecida pelas features: a) RMS e b) DES.	83
Figura 19 - Relação entre o nível máximo de <i>arg max</i> encontrado (curva preta) e a classificação realizada (curva vermelha) em relação a referência (curva azul) e o valor médio do <i>arg max</i> (linha em magenta).	84
Figura 20 - Relação entre o nível máximo de <i>arg max</i> encontrado (curva preta) e a classificação realizada (curva vermelha) em relação a referência (curva azul) e o valor médio do <i>arg max</i> (linha em magenta) utilizando: a) somente a <i>feature</i> RMS e b) RMS e o DES.	86
Figura 21 - Diagrama de blocos dos métodos desenvolvidos nesta Tese onde a classificação confiável conta com os métodos HOLD, MV, MKV e DISCARD enquanto a classificação resiliente é composta pelos métodos de <i>arg max</i> suavizado e pelos classificadores binomiais baseados no RELM binário auxiliar e no método do <i>threshold</i> gerado através da métrica de Separação Diferencial Mínima (SDM).	89
Figura 22 - Efeito dos componentes de alta frequência presentes no <i>arg max</i> na classificação (vermelho) em relação ao <i>label</i> ideal (preto). Os valores de <i>arg max</i> para cada uma das classes é representado pelas demais curvas.	89
Figura 23 - Diagrama de blocos geral da classificação por <i>arg max</i> suavizado, onde o processo de suavização é realizado por um filtro AVT como no pré-processamento.	90
Figura 24 - Funcionamento da classificação auxiliar que determinada a utilização da classe repouso na comparação de valores do <i>arg max</i> e nova atribuição de <i>labels</i>	91
Figura 25 - Métricas principais e auxiliares utilizadas na classificação do sinal: a) <i>arg max</i> derivado do RELM padrão; b) <i>arg max</i> suavizado; c) sinal de Separação Diferencial Mínima (SDM) que dá base a classificação resiliente no método do <i>threshold</i> e d) classificação binária auxiliar utilizada para a classificação resiliente no método do classificador binomial.	92

- Figura 26 - Taxas de acerto do ELM padrão para a base NAMP: as figuras a) e c) representam as taxas de acerto global e ponderadas individuais obtidas para cada voluntário, enquanto as figuras b) e d) representam as taxas de acerto ponderadas por classe e médias gerais obtidas, respectivamente. Ambas as métricas são representadas em função da variação do tamanho da janela de segmentação..... 99
- Figura 27 - Taxas de acerto do RELM padrão para a base NAMP: as figuras a) e c) representam as taxas de acerto global e ponderadas individuais obtidas para cada voluntário. As figuras b) e d) representam as taxas de acerto ponderadas por classe e média geral obtidas respectivamente, em função da variação da segmentação. 100
- Figura 28 - Taxas de acerto do classificador para a base AMP de acordo com a segmentação utilizada, onde: a) representa as taxas ponderadas e globais obtidas pelo ELM padrão; b) representa as médias ponderadas e c) as médias globais para toda a base de acordo com a variação da janela de segmentação. Similarmente, d) representa as taxas ponderadas e globais obtidas pelo RELM padrão, e) representa as médias ponderadas e f) as médias globais para toda a base, nas mesmas situações de variação de tamanho de janela de segmentação..... 102
- Figura 29 - Taxas de acerto do ELM para os diferentes exercícios da base IEE, onde a), b) e c) abordam os ensaios sequenciais A e B, que possuem 6 e 10 repetições, respectivamente e d), e) e f) apresentam as taxas obtidas para os ensaios com movimentos aleatórios C e D, que também possuem 6 e 10 repetições, respectivamente. 104
- Figura 30 - Taxas de acerto do RELM para os diferentes exercícios da base IEE, onde a), b) e c) abordam os ensaios sequenciais A e B, que possuem 6 e 10 repetições, respectivamente e d), e) e f) apresentam as taxas obtidas para os ensaios com movimentos aleatórios C e D, que também possuem 6 e 10 repetições, respectivamente. 106
- Figura 31 - Taxas de acerto de treino dos modelos para as variações de tamanho de segmento utilizado em ambas versões do classificador, onde: a) corresponde à base NAMP; b) corresponde à base AMP; c) corresponde ao ENSAIO A da base IEE; d) apresenta os resultados derivados do ENSAIO B da base IEE enquanto e) e f) correspondem aos resultados oriundos do ENSAIO C e ENSAIO D, respectivamente. 109

Figura 32 - Valores médios de <i>threshold</i> \pm desvio padrão por base (zona sombreada) e valores de <i>threshold</i> individuais gerados para as bases: a) AMP e b) NAMP. Já em c) é apresentado o valor médio geral de <i>threshold</i> para ambas as bases.	110
Figura 33 - Taxas de <i>threshold</i> individual por <i>trial</i> e geral para cada ensaio da base IEE, onde: a), b) abordam os ensaios sequenciais A e B, que possuem 6 e 10 repetições, respectivamente e c) e d) tratam dos valores dos <i>threshold</i> derivados dos ensaios de movimentos realizados aleatoriamente também em 6 e 10 repetições, respectivamente. Já e) apresenta a média geral obtida em cada ensaio e a área cinza retangular nos quatro primeiros <i>subplots</i> indica a média e desvio padrão de cada base.	111
Figura 34 - Percentual de dados abaixo do <i>threshold</i> e, portanto, afetados pelos métodos de pós-processamento da versão confiável do RELM. Os resultados foram analisados em suas bases distintas, onde: a) apresenta a porcentagem de dados afetados na base AMP e b) apresenta a porcentagem de dados afetados na base NAMP. Já c) apresenta as médias obtidas em ambas as bases NINAPro.	113
Figura 35 - Taxas de acerto do RELM para os diferentes exercícios da base IEE, onde a), b) e c) abordam os ensaios sequenciais A e B, que possuem 6 e 10 repetições, respectivamente e d), e) e f) apresentam as taxas obtidas para os ensaios com movimentos aleatórios C e D, que também possuem 6 e 10 repetições, respectivamente.	114
Figura 36 - Taxas de acerto global da base NAMP obtidas pelos métodos componentes do modelo de classificação confiável do RELM, onde são apresentadas: a) taxas de acerto individual (voluntário 1 a 20); b) taxas de acerto individual (voluntário 21 a 40) e c) taxas de acerto médio por método utilizado.	115
Figura 37 - Taxas de acerto ponderado da base NAMP obtidas pelos métodos componentes do modelo de classificação confiável do RELM, onde são apresentadas: a) taxas de acerto individual (voluntário 1 a 20); b) taxas de acerto individual (voluntário 21 a 40) e c) taxas de acerto médio por método utilizado.	116
Figura 38 - Efeito da aplicação do MV para amostras abaixo do <i>threshold</i>	117
Figura 39 - Efeito da aplicação do método HOLD para amostras abaixo do <i>threshold</i>	118
Figura 40 - Taxas de acerto global da base AMP para os métodos do RELM confiável para: a) cada voluntário da base e b) a média da base inteira.	120

- Figura 41 - Taxas de acerto ponderado da base AMP para os métodos do RELM confiável para:
a) cada voluntário da base e b) a média da base inteira..... 120
- Figura 42 - Taxas de acerto global para os ensaios da base IEE, sendo a) resultados dos *trials* das bases A e B, b) resultados dos *trials* das bases C e D, c) médias para o ENSAIO A, d) médias para o ENSAIO B, e) médias para o ENSAIO C e f) médias para o ENSAIO D..... 122
- Figura 43 - Taxas de acerto ponderada para os ensaios da base IEE, sendo a) resultados dos *trials* das bases A e B, b) resultados dos *trials* das bases C e D, c) médias para o ENSAIO A, d) médias para o ENSAIO B, e) médias para o ENSAIO C e f) médias para o ENSAIO D..... 123
- Figura 44 - Classificação realizada para o *trial 5* da base IEE, comparando: a) o método HOLD com a classificação do RELM base e b) o método MV com a classificação do RELM base. Para ambos os casos são apresentadas as TAG e TAP do segmento considerado onde as taxas obtidas pelo RELM padrão são TAG = 96,55% e TAP = 93,34%.. 124
- Figura 45 - Comparação da classificação de duas repetições do movimento 14 para utilizando:
a) o classificador padrão ELM e b) o RELM de *arg max* suavizado. 128
- Figura 46 - Métricas principais e auxiliares utilizadas na classificação do sinal: a) *arg max* derivado do RELM padrão; b) *arg max* suavizado; c) sinal de Separação Diferencial Mínima (SDM) que dá base a classificação resiliente no método do *threshold* e d) classificação binária auxiliar utilizada para a classificação resiliente no método do classificador binomial. As quatro métricas são representadas sobre a classificação predita que geram (curva em vermelho) e sobre a classificação ideal pretendida (curva em preto)..... 129
- Figura 47 - Desempenho do classificador binário auxiliar em todas as bases de dados, onde: a) consiste nos resultados obtidos para a base NAMP enquanto b) apresenta os resultados na base AMP, c) apresenta os resultados do ENSAIO A da base IEE enquanto d) apresenta os resultados do ENSAIO B. Os resultados dos ensaios aleatórios são apresentados em d) para o ENSAIO C e f) para o ENSAIO D. 130
- Figura 48 - Comparação dos métodos da versão resiliente do classificador na base NAMP com a TAG representada pelas linhas tracejadas e a TAP pelo gráfico de barras, onde: a) apresenta a TAG e a TAG individualmente para os voluntários 1 ao 20; b) apresenta a TAG e a TAG individualmente para os voluntários 21 ao 40; c) apresenta a média geral obtida para a base e c) apresenta a média ponderada obtida para a base..... 131

- Figura 49 - Comparação dos métodos da versão resiliente do classificador na base AMP com a TAG representada pelas linhas tracejadas e a TAP pelo gráfico de barras, onde: a) apresenta a TAG e a TAG individualmente para todos os voluntários; b) apresenta a média geral obtida para a base e c) apresenta a média ponderada obtida para a base. 133
- Figura 50 - Comparação dos métodos da versão resiliente do classificador na base IEE com a TAG representada pelas linhas tracejadas e a TAP pelo gráfico de barras, onde: a) apresenta a TAG e a TAG individual para cada *trial* realizado nos ensaios sequenciais que de 1 à 12 representam as três repetições de cada um dos quatro voluntários para o ENSAIO A e de 13 à 24 representam as três repetições de cada um dos voluntários para o ENSAIO B, organizadas sequencialmente; b) apresenta a TAG e c) apresenta a TAP do ENSAIO A para todos os métodos enquanto d) apresenta a TAG e e) apresenta a TAP relativa ao ENSAIO B obtida para todos os métodos..... 135
- Figura 51 - Comparação dos métodos da versão resiliente do classificador na base IEE com a TAG representada pelas linhas tracejadas e a TAP pelo gráfico de barras, onde: a) apresenta a TAG e a TAG individual para cada *trial* realizado nos ensaios sequenciais que de 1 à 12 representam as três repetições de cada um dos quatro voluntários para o ENSAIO C e de 13 à 24 representam as três repetições de cada um dos voluntários para o ENSAIO D, organizadas sequencialmente; b) apresenta a TAG e c) apresenta a TAP do ENSAIO C para todos os métodos enquanto d) apresenta a TAG e e) apresenta a TAP relativa ao ENSAIO D obtida para todos os métodos..... 137
- Figura 52 - Incrementos médios de taxa de acerto obtidos através da classificação resiliente e do método DISC, proveniente da versão confiável do classificador. Na figura as taxas são referenciadas ao desempenho do RELM padrão utilizando segmentos de 400+10ms para as bases: a) NAMP, b) AMP e c) IEE..... 140

LISTA DE TABELAS

Tabela 1 - Principais músculos superficiais do braço e antebraço e suas funções.	30
Tabela 2 - Características extraídas para o uso na classificação e caracterização de movimentos.	36
Tabela 3 - Trabalhos relacionados na área de processamento de sinais de sEMG.....	52
Tabela 4 - Trabalhos relacionados ao processamento de sinais de sEMG com base NINAPro.	55
Tabela 5 Trabalhos diversos relacionados a área de processamento de sEMG.....	58
Tabela 6 - Trabalhos relacionados na área de processamento de sEMG utilizando ELM.	61
Tabela 7 - Variação dos ensaios componentes das diferentes bases de dados consideradas nesta Tese.....	75
Tabela 8 - <i>Features</i> extraídas dos sinais de sEMG utilizadas nesta proposta de tese.	80
Tabela 9 - Taxas de acerto global e ponderada médias obtidas por ambos os métodos de classificação para a base IEE considerando os diferentes tempos de segmentação. (Fonte: autor).	107
Tabela 10 - Taxas de acerto global médias obtidas pelos métodos relacionados ao modelo de classificação confiável para as diferentes bases de dados testadas.....	126
Tabela 11 - Taxas de acerto global médias obtidas pelos métodos relacionados ao modelo de classificação confiável para as diferentes bases de dados testadas.....	127
Tabela 12 - Taxas de acerto global médias obtidas pelos métodos relacionados ao modelo de classificação confiável para as diferentes bases de dados testadas.....	139
Tabela 13 - Taxas de acerto global médias obtidas pelos métodos relacionados ao modelo de classificação confiável para as diferentes bases de dados testadas.....	139

LISTA DE ABREVIATURAS

AMP	Amputados
ANN	Artificial Neural Network
ANOVA	Analysis of Variance
AVT	<i>Antonyan Vardan Transform</i>
ARMA	<i>Autoregressive-Moving-Average</i>
AC-PCA	Augmented-Class Principal Component Analysis
BIN	Método do classificador auxiliar binário na classificação resiliente
CSP	Common Spatial Patterns
CNN	Convolutional Neural Network (Rede Neural Convolutacional)
CREn	Cumulative Residual Entropy
DC	<i>Direct Current</i> (Corrente Contínua)
DES	Differential Enhanced Signal
DISC	Método de descarte autônomo de amostras acionado na classificação confiável do sEMG
EM	Expectation-Maximization
EEG	Eletroencefalografia
ELM	<i>Extreme Learning Machines</i>
EMG	Eletromiografia/Sinal Eletromiográfico
FD	Frequency Domain
FFT	Fast Fourier Transform
GMM	Gaussian Mixture Models
GRU	Gated Recurrent Unit
HMM	<i>Hidden Markov Model</i>
HOLD	Método de manter a última classificação confiável do sEMG
IC	Inteligência Computacional
ICA	Independent Component Analysis
IEE	Laboratório de Instrumentação Eletro-Eletrônica
KKT	Karush-Khun-Tucker
kNN	k-Nearest Neighbors
KRLS	Kernel Regularized Least Squares
LR	Logistic Regression
LDA	Linear Discriminant Analysis
LSTM	Long Short-Time Memory
ML	Machine Learning
MV	Método de Major-Voting das 9 últimas amostras acionado na classificação confiável do sEMG

MAV Mean Amplitude Value

MNLR Multiple Nonlinear Regression

NMF Nonnegative Matrix Factorization

mDWT marginal Discrete Wavelet Transform

MUAP Motor Unit Action Potential

MUAPT Motor Unit Action Potential Train

NAMP Não Amputados

NINAPro Non-Invasive Adaptive Hand Prosthetics

OLS Ordinary Least Squares

OFNDA Orthogonal Fuzzy Neighbour Discriminant Analysis

PCA Principal Component Analysis

PSO Particle Swarm Optimization

PPGEE Programa de Pós-Graduação em Engenharia Elétrica

RL Regressão Linear

RLR Regressão Logística Regularizada

RBF *Radial-Basis Function* (Função de Base Radial)

RMS *Root Mean Square* (Raiz Média Quadrada)

RNN Recurrent Neural Networks

RNA Redes Neurais Artificiais

RELM *Regularized Extreme Learning Machines*

RVFL Random Vector Functional-Link

SME Sinal Mioelétrico

SNR Signal-to-Noise Ratio (Relação Sinal-Ruído)

SKW Skewness

SDM Separação Diferencial Mínima

SMT Método do RELM de *arg max* suavizado na classificação resiliente

SSC Slope Sign Change

STD Método de classificação padrão, utilizado como referência na classificação confiável do sEMG

SVD Singular Value Decomposition

SVM Support Vector Machine

SLFN *Single-Layer Feedforward Network*

sEMG Eletromiografia de Superfície

STFT Short-Time Fourier Transform

STTT Short-Time Thompson Transform

TD Time Domain

TH Método do threshold na classificação resiliente

TAG Taxa de Acerto Global
TAP Taxa de Acerto Ponderada
TFD Time-Frequency Domain
TKE Teager-Kaiser Energy
TSD Time-Serial Domain
UFRGS Universidade Federal do Rio Grande do Sul
VAR Variância
VMA Valor Absoluto Médio
WL *Wavelength* (Comprimento de Onda)
ZC *Zero Crossing* (Cruzamentos por Zero)

SUMÁRIO

1	INTRODUÇÃO	21
1.1	JUSTIFICATIVA	22
1.2	OBJETIVOS	23
1.3	CONTRIBUIÇÕES À ÁREA.....	23
2	FUNDAMENTAÇÃO TEÓRICA	26
2.1	PRINCÍPIOS BÁSICOS SOBRE OS SINAIS MIOELÉTRICOS.....	26
2.1.1	Geração do Potencial de Ação e Transmissão do Impulso Nervoso	26
2.1.2	Potencial da Unidade Motora	27
2.2	ELETROMIOGRAFIA DE SUPERFÍCIE E MUSCULATURA DE INTERESSE.....	28
2.2.1	Sinal de Eletromiografia de Superfície	28
2.2.2	Aquisição do sEMG	29
2.2.2.1	Posicionamento dos Eletrodos e Musculatura do Braço.....	29
2.3	PRÉ-PROCESSAMENTO DO SINAL DE ELETROMIOGRAFIA	32
2.3.1	Processo de Filtragem de Sinais de sEMG	32
2.3.2	Antonyan Vardan Transform (AVT) Filter	32
2.3.3	Segmentação dos Sinais de sEMG	33
2.3.4	Extração de Features dos Sinais de sEMG	35
2.3.5	Principal Component Analysis (PCA) e Singular Value Decomposition (SVD)	37
2.3.6	Extreme Learning Machines (ELM)	39
2.3.6.1	Obtenção da matriz pseudoinversa no ELM.....	41
2.3.6.2	Obtenção da matriz pseudoinversa no RELM	43
2.3.7	Modelos Discriminativos e Generativos e Hidden Markov Model (HMM)	44
3	ESTADO DA ARTE	49
3.1	PRÉ-PROCESSAMENTO E EXTRAÇÃO DE <i>FEATURES</i>	49
3.2	CLASSIFICAÇÃO DO SINAL DE ELETROMIOGRAFIA	51
3.2.1	Comparação Entre Trabalhos Utilizando a Base NINAPro	53
3.2.2	Outros Trabalhos Que Utilizam Classificação de Sinais de sEMG	57
3.2.3	Comparação de trabalhos envolvendo ELM	59
3.2.4	Trabalhos Relacionados a Classificação Confiável de Sinais de sEMG	63
4	METODOLOGIA EXPERIMENTAL	67
4.1	AQUISIÇÃO DE DADOS DA BASE DO LABORATÓRIO IEE	69
4.1.1	Eletromiógrafo e Eletrodos	69

4.1.2	Modelo Virtual	70
4.1.3	Procedimentos Para a Realização dos Ensaios de Aquisição de Dados	70
4.2	DESCRIÇÃO DA BASE DE DADOS NINAPRO	73
4.3	MOVIMENTOS REALIZADOS NOS ENSAIOS	73
4.4	PROCESSAMENTO DOS BIOSINAIS	74
4.4.1	Pré-processamento	75
4.4.2	Retificação e normalização do sinal	75
4.4.3	Segmentação por janelas deslizantes	77
4.4.4	Filtro AVT	78
4.4.5	Extração de <i>features</i>	80
4.4.6	<i>Differential Enhanced Signal (DES)</i>	81
4.4.7	Confiabilidade das Classificações	84
4.4.8	Arquiteturas de Classificação Confiável do Sinal de sEMG	85
4.4.9	Arquitetura de Classificação Resiliente do Sinal de sEMG	89
4.4.10	Ajuste dos Classificadores	93
4.4.11	Métricas de Avaliação do Sistema	94
4.4.12	Projetos de Experimento	95
5	RESULTADOS E DISCUSSÕES	98
5.1	COMPARAÇÃO ENTRE ELM, RELM E DIFERENTES TEMPOS DE SEGMENTAÇÃO	98
5.2	AVALIAÇÃO DE MÉTRICAS SECUNDÁRIAS DA CLASSIFICAÇÃO CONFIÁVEL	109
5.3	COMPARAÇÃO DE MODELOS UTILIZADOS NA CLASSIFICAÇÃO CONFIÁVEL.....	114
5.4	COMPARAÇÃO DE MÉTODOS UTILIZADOS NA CLASSIFICAÇÃO RESILIENTE	128
5.5	COMPARAÇÃO COM O ESTADO DA ARTE	141
6	CONCLUSÕES E TRABALHOS FUTUROS	149
	APÊNDICE A - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO	163
	APÊNDICE B - ANAMNESE	165
	APÊNDICE C – ARTIGO SOBRE CARACTERIZAÇÃO DO ELM COMPARADO À REGRESSÃO LOGÍSTICA E AO <i>SUPPORT VECTOR MACHINES</i>	166
	APÊNDICE D – ARTIGO SOBRE OS EFEITOS DE DIFERENTES ESTRATÉGIAS DE PRÉ-PROCESSAMENTOS, VARIAÇÕES DE HIPERPARÂMETROS DO MÉTODO E SOBRE AS VERSÕES CONFIÁVEIS DO ELM EM SUA VERSÃO PADRÃO E EM SUA VERSÃO REGULARIZADA	167

APÊNDICE E – ARTIGO SOBRE A BASE DE DADOS IEE E A UTILIZAÇÃO DAS VERSÕES CONFIÁVEIS DO ELM E RELM PARA O PROCESSAMENTO DAS BASES NINAPRO RELACIONADAS	168
APÊNDICE F – ARTIGO SOBRE O ELM DE <i>ARG MAX</i> SUAVIZADO UTILIZANDO DIFERENTES MÉTODOS DE FILTRAGEM DO SINAL.....	169

1 INTRODUÇÃO

Seja possibilitando diagnósticos mais precisos ou diferentes formas de interação homem-máquina, avanços na área da Instrumentação Biomédica provêm a melhoria da qualidade de vida para integrantes da sociedade como um todo. Por ser uma área multidisciplinar, avanços na área geralmente apoiam-se em desenvolvimentos de áreas correlatas, como Instrumentação Inteligente, Microeletrônica, Medicina, Física, Química e outros campos de estudos constantemente em expansão (BRONZINO & ENDERLE, 2012; ENDERLE, 2006; MACIEJASZ, *et al.*, 2014). A ativação de dispositivos assistivos através de biosinais como a eletromiografia (EMG) e eletroencefalografia (EEG) orientados a interações homem-máquina têm mostrado avanços consistentes em trabalhos recentes (TACCHINO, *et al.*, 2017; MINATTI, *et al.*, 2016; ISON & ARTEMIADIS, 2014; GUIDOTTI D., *et al.*, 2019; MACIEJASZ, *et al.*, 2014; YEPES, *et al.*, 2019). Esta linha de pesquisa da Engenharia Biomédica visa oferecer soluções assistivas às pessoas portadoras de alguma deficiência congênita ou adquirida ao longo da vida e da mesma forma aumentar a capacidade de pessoas saudáveis para a realização de alguma tarefa específica (TANG, *et al.* 2014; VAN ENGELHOVEN, *et al.*, 2018; HUYSAMEN, *et al.*, 2018). Desta forma, buscase outorgar maior independência, e restabelecer parcialmente algumas de suas capacidades perdidas (MACIEJASZ, *et al.*, 2014) assim como evitar possíveis lesões sofridas por trabalhadores expostos a condições não-ergonômicas de trabalho (BALTRUSCH *et al.*, 2018; WESTON *et al.*, 2018). Devido à natureza não-determinística característica destes biosinais, técnicas de Inteligência Computacional (IC) e Instrumentação Inteligente são comumente integradas ao sistema. Através de classificações provenientes dos métodos de IC, torna-se possível a ativação de dispositivos assistivos como exoesqueletos (TANG *et al.*, 2014) ou próteses (GUIDOTTI *et al.*, 2019) que ajudem o sujeito em questão na realização de alguma tarefa ou movimento específico. Desta forma, torna-se possível a reinserção autônoma de portadores de deficiência na sociedade (XIAO *et al.*, 2014; ISON & ARTEMIADIS, 2014; ATZORI *et al.*, 2014; MACIEJASZ, *et al.*, 2014; HE, *et al.*, 2018; YOUNG, *et al.*, 2014) assim como evitar lesões que possam causar problemas crônicos ou interrupção das atividades exercidas em usuários saudáveis (KIM *et al.*, 2018a; HUYSAMEN *et al.*, 2018; KIM *et al.*, 2018b; GOPURA, *et al.*, 2018; VAN ENGELHOVEN, *et al.*, 2018; KIM *et al.*, 2018c).

1.1 JUSTIFICATIVA

Dispositivos assistivos comumente baseiam-se no uso de próteses mecânicas fixas ou capazes de realizar poucos movimentos (ISON & ARTEMIADIS, 2014; HOFMANN, 2016). No entanto, devido a avanços tanto nos equipamentos quanto nos métodos computacionais utilizados, é possível observar um aumento no interesse pela utilização de próteses biomecânicas interfaceadas a biosinais. Este tipo de interface, visa proporcionar uma experiência mais plena e natural aos usuários (MOORE & ZOURIDAKIS, 2004; HOFMANN, 2016; ISON & ARTEMIADIS, 2014; ATZORI *et. al.*, 2014; KRASOULIS *et. al.*, 2017), realimentações hápticas (AZIZIAGHDAM & SAMUR, 2014) ou mesmo o aumento da capacidade humana (ASBECK *et. al.*, 2014; AWAD, *et. al.*, 2017). Evidenciados os potenciais benefícios e a capacidade de controle destas próteses através de biosinais, torna-se de extremo interesse o desenvolvimento de interfaces capazes de interpretar estes estímulos e transformá-los em sinais de ativação que possibilitem o controle adequado de dispositivos de controle natural.

A eficiência dos métodos computacionais neste contexto, é geralmente avaliada em relação às taxas de acerto obtidas na classificação dos sinais. Embora algumas abordagens relatem taxas de acerto acima de 90% contemplando poucos movimentos, modelos formados a partir do sinal de EMG tendem a oferecer problemas como latência de classificação no início e final de cada movimento e confusões entre classes na porção intermediária do sinal, gerando erros. Estes tipos de erros ainda limitam muito as aplicações dos métodos em próteses, que idealmente não devem realizar um movimento errôneo ou imprevisto sob o risco de causar algum dano ao usuário, ao ambiente ao seu redor ou a terceiros. Desta forma, este trabalho é focado no desenvolvimento de soluções que possam maximizar a informação proveniente dos sinais de eletromiografia de superfície (sEMG), tornando-os mais representativos e regulares para a formação de modelos apropriados e confiáveis quanto à sua classificação de saída. Complementarmente, soluções são propostas para mitigar ruídos de classificação e latências do sistema que induzem o classificador à erros. Neste escopo, foram exploradas diferentes arquiteturas de classificação para a identificação mais robusta e confiável dos sinais em questão. Para tanto, ao invés de abordar o problema somente em uma das principais etapas de tratamento do sinal (pré-processamento, classificação e pós-processamento), foram elaborados métodos inéditos em todas estas etapas do processo.

1.2 OBJETIVOS

O objetivo principal deste trabalho consiste no desenvolvimento de um método de Inteligência Computacional que possibilite uma interface humano-computador de forma a reconhecer 18 classes de movimentos de membros-superiores através do processamento do sinal mioelétrico (SME) adquirido do sujeito em questão. Diferentes técnicas de processamento e classificação foram utilizadas com o objetivo de possibilitar uma interface mais robusta em relação aos erros de classificação dos movimentos. Para a caracterização dos movimentos, foi desenvolvido um método de IC baseado na técnica de *Extreme Learning Machines* (ELM), que tem apresentado resultados consistentes em outras áreas de aplicação, mas ainda é pouco utilizada na classificação de biosinais. Através desta técnica, foi gerada uma métrica de confiabilidade da classificação oferecida pelo sistema para o acionamento autônomo de métodos de pós-processamento e o desenvolvimento da versão de *arg max* suavizado do classificador que gera classificações mais estáveis, e por consequência, mais robustas aos erros de classificação. Foi também utilizada uma adaptação de um filtro estocástico e a extração de uma nova *feature*, visando a maximização da representatividade dos sinais particularmente em transições entre movimentos, onde duas estratégias relacionadas ao *arg max* suavizado compõem a versão resiliente do classificador.

Os métodos computacionais empregados foram capazes de classificar os movimentos escolhidos do segmento mão-braço contemplando diversos graus de liberdade com comprovado aumento da confiabilidade das classificações na figura de capacidade de separação entre os diferentes movimentos (classes). Os 17 movimentos escolhidos para o estudo juntamente com o repouso que os intercala constituem as 18 classes de saída do sistema. A figura de mérito principal do método consiste na taxa de acerto na classificação dos movimentos, sendo o método tão eficiente quanto sua taxa de acerto, que é apresentada em sua média global e ponderada, considerando todas as classes.

1.3 CONTRIBUIÇÕES À ÁREA

De forma geral, esta tese baseia-se na utilização de um classificador modular baseado na forma regularizada do ELM (denominada RELM, abreviação de *Regularized Extreme Learning Machine*). Diferentes soluções focando nas etapas de pré-processamento, classificação e pós-

processamento foram utilizadas para a construção de um classificador mais robusto que evite ruídos de classificação e aumente a taxa de acerto em zonas de transição de movimentos, que são, reconhecidamente, as porções do sinal mais desafiadoras do ponto de vista de classificação.

Em relação ao pré-processamento, foi adaptado um filtro estocástico e realizada a extração de uma nova *feature* do sinal desenvolvida com o intuito de maximizar a representatividade do sinal em períodos de transição entre repouso e movimentos. Na etapa de classificação, através da utilização de uma métrica inerente ao classificador, foi desenvolvido o conceito de confiabilidade do sistema, que se relaciona com a probabilidade de ocorrência de cada classe em questão. Tendo sinais de entrada mais representativos, o classificador é capaz de analisar autonomamente a confiabilidade respectiva a cada dado de entrada com base no modelo treinado. Já na etapa de classificação, uma versão de *arg max* suavizado do classificador foi desenvolvida para mitigar ruídos de classificação.

Em relação ao pós-processamento foram testadas diversas alternativas que compõem o modelo de classificação confiável do sinal. Na versão confiável do classificador, todas amostras consideradas não-confiáveis acionam autonomamente diferentes métodos de pós-processamento, envolvendo manter a última classificação confiável, realizar o *major-voting* das nove últimas classificações e o descarte de amostras divergentes ao modelo. Paralelamente a utilização de um *Hidden Markov Model* (HMM), também foi testada visando uma classificação mais robusta em relação a estabilidade da série temporal para evitar ruídos de classificação derivados de oscilação entre classes de movimentos ativos.

Já para os modelos resilientes do classificador, a métrica de confiabilidade foi filtrada e manipulada, gerando um sinal binário que através de *threshold* auxilia na otimização da classificação em momentos de transição do sinal. Paralelamente também foi desenvolvido um classificador binário auxiliar para a geração deste mesmo sinal binomial e auxílio na classificação. Estas últimas abordagens relativas as arquiteturas de classificação resiliente dos sinais oferecem aumentos significativos da taxa de acerto individual de cada movimento mesmo sem o descarte de amostras outrora consideradas não-confiáveis.

Para o desenvolvimento e caracterização das alternativas propostas, os objetivos específicos deste trabalho, onde as contribuições ao estado da arte apresentam-se nos itens de *b* à *f*, foram:

- a) realizar uma comparação inicial entre os métodos baseados em *Single-Layer Feedforward Networks* (SLFN) com outros métodos já bem estabelecidos como SVM e Regressão Logística envolvendo variações de canais e features do sinal de EMG e sua influência da taxa de acerto na abordagem de segmentação por *timestamp*;
- b) avaliar o novo filtro estocástico proposto e a nova *feature* para a representação do sinal e seu impacto na taxa de acerto do método;
- c) avaliar a eficiência da solução baseada na confiabilidade e das diferentes ações tomadas a partir dela na taxa de acerto final, proporcionando inclusive a capacidade do classificador reconhecer e descartar autonomamente amostras pouco representativas;
- d) desenvolver uma estrutura híbrida de Inteligência Computacional, unindo o RELM a um método de *Hidden Markov Model*, em uma tentativa de aumentar a estabilidade das diversas classificações da série temporal e evitar ruídos de classificação;
- e) desenvolver e testar a versão de *arg max* suavizado como alternativa prática a modelos computacionais mais pesados, como o HMM ou de mais alto nível, como o *Major-Voting* para a classificação sequencial mais estável e a mitigação de ruídos de classificação;
- f) desenvolver e testar métricas auxiliares, que nesta Tese são apresentadas na forma da classificação resiliente através dos métodos de *threshold* e do classificador binário auxiliar que permitam uma identificação mais precisa das classes em zonas de transição de movimentos.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 PRINCÍPIOS BÁSICOS SOBRE OS SINAIS MIOELÉTRICOS

Ao final do século XVIII, Luigi Galvani descobria a existência de atividade elétrica em um animal, o que culminou com a criação do campo de estudo da eletrofisiologia (BRONZINO & ENDERLE, 2012). Diversos trabalhos relevantes expandiram a área, como o trabalho de Carlos Mateucci, que em 1838, demonstrou a existência de uma corrente elétrica durante uma contração muscular (MALMIVUO & PLONSEY, 1995) e o francês Dubois-Reymond, que em 1849 demonstrou que esta corrente, denominada de sinal mioelétrico, é o mecanismo de ativação da contração muscular (MEULDERS *et al.*, 2013). No Século XX, Herbert Gasser e Joseph Erlanger continuaram os estudos na área, seus trabalhos, relacionados a morfologia dos sinais, culminaram no surgimento da eletromiografia (EMG), lhes rendendo um Prêmio Nobel de Medicina em 1944 (CRAM, 2003).

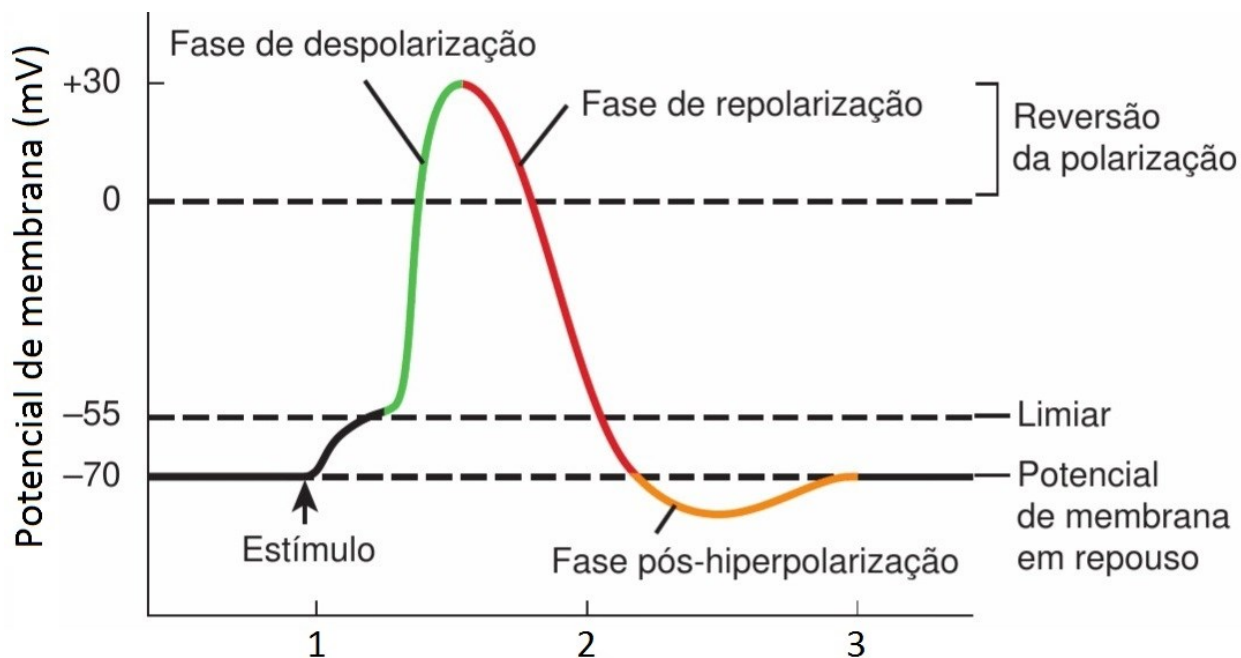
A contração muscular consiste em um ato involuntário quando um potencial de ação é transmitido ao longo de uma fibra nervosa. O potencial de ação é gerado por um neurônio motor, passa pela etapa de transmissão sináptica e os potenciais de ação dos respectivos músculos se somam compondo o sinal mioelétrico. O sinal mioelétrico por sua vez, causa a contração das fibras musculares (BRONZINO & ENDERLE, 2007; GUYTON, 2006).

2.1.1 Geração do Potencial de Ação e Transmissão do Impulso Nervoso

O potencial de ação é gerado pelas variações de cargas elétricas em relação ao potencial da membrana do neurônio motor, que tem como referência (0V), o seu interior (GUYTON, 2006), e varia de acordo com as trocas celulares de íons de sódio (Na^+) e potássio (K^+) que caracterizam três estados principais: **1) Repouso**, onde íons positivos (K^+) saem do interior da fibra muscular deixando proteínas carregadas negativamente que geram um potencial de membrana negativo (por volta de -60mV a -90mV); **2) Despolarização**, onde um fluxo rápido de íons de Na^+ adentra a fibra, tornando o potencial da membrana celular positivo; **3) Repolarização**, onde os íons de Na^+ , que eventualmente difundem-se para o exterior da célula e levam consigo as cargas positivas, deixando o potencial da membrana negativo novamente e tornando-a apta a transmitir um novo impulso nervoso, como ilustrado na Figura 1. A interface entre a fibra muscular esquelética e os terminais do axônio do neurônio motor ocorre na placa motora, onde ao fim da fibra nervosa, a

acetilcolina transmite o impulso nervoso dos neurônios para as células musculares causando um potencial de ação, que se propaga nas duas direções da fibra muscular e provoca a sua contração (GUYTON, 2006; BRONZINO & ENDERLE, 2012).

Figura 1 - Potenciais de ação envolvidos no processo de geração de sinais mioelétricos.



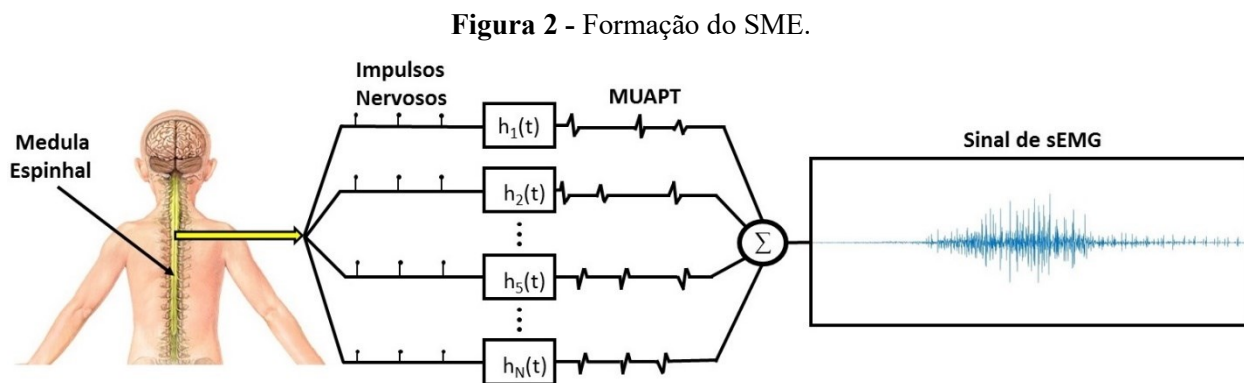
Fonte: Adaptado livremente de (TORTORA, 2007).

2.1.2 Potencial da Unidade Motora

Cada conjunto de fibras musculares inervados somente por uma fibra nervosa motora, compõe a unidade motora. Um músculo geralmente é composto de várias unidades motoras e quantidade fibras proporcionais ao tamanho do músculo (MCLESTER & St. Pierre, 2007), sendo dispersas e intercalando-se com outras fibras de diversas unidades motoras. Assim, no começo de um processo de contração muscular poucas unidades motoras são recrutadas e à medida que o músculo é mais solicitado mais unidades motoras são utilizadas, progressivamente (GUYTON, 2006). A estimulação das fibras musculares tem uma característica não-síncrona, derivada dos diferentes tempos de propagação das ramificações dos axônios no neurônio motor e da natureza aleatória das descargas de acetilcolina (GUYTON, 2006).

A soma algébrica resultante dos diferentes potenciais de ação nas fibras de uma unidade motora é denominada potencial de ação da unidade motora, abreviada em inglês por MUAP (*Motor Unit Action Potential*). Em períodos prolongados, a contração muscular é formada por diversas

sequências de MUAPs, denominadas, em inglês por MUAPT (*Motor Unit Action Potential Train*) (BRONZINO & ENDERLE, 2012; GUYTON, 2006). A Figura 2 apresenta a formação do sinal mioelétrico através da superposição dos MUAPTs provenientes dos potenciais de ação dos neurônios motores.



Fonte: Adaptado livremente de (BASMAJIAN & DE LUCA, 1985).

2.2 ELETROMIOGRAFIA DE SUPERFÍCIE E MUSCULATURA DE INTERESSE

A eletromiografia tem por objetivo, medir a intensidade dos campos eletromagnéticos gerados pela passagem dos potenciais de ação nas fibras musculares de forma a relacioná-los com atividades elétricas musculares. Diversos tipos de eletrodos podem ser utilizados para a detecção destes campos que se tornam interessantes pelo fato da atividade muscular elétrica proporcionar uma alternativa para o controle de próteses e dispositivos assistivos (NAIK & DINESH, 2012; PHINYOMARK *et al.*, 2012; LI *et al.*, 2011; YOUNG *et al.*, 2012).

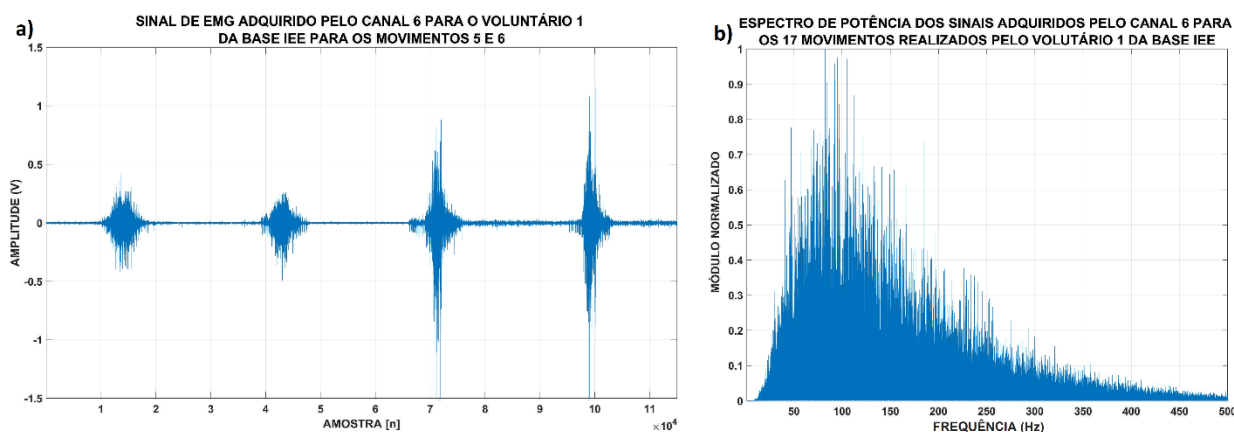
2.2.1 Sinal de Eletromiografia de Superfície

Sinais de sEMG consistem na aquisição não invasiva de sinais elétricos oriundos da musculatura ativada na realização de um movimento. Os sinais de sEMG possuem diversas aplicações em Instrumentação Biomédica, Biomecânica, Medicina, entre outras aplicações (BENEDETTI, 2001; MICERA *et al.*, 2000; LINS *et al.*, 2015; LIU, 2010).

Pelo fato de o sinal ser adquirido na superfície da pele, comumente são captadas influências de outros grupos musculares, o que influencia a leitura do sinal, contribuindo consideravelmente para a sua aleatoriedade (TORTORA, 2007). Naturalmente, o sinal de sEMG possui uma forte natureza estocástica, tendo sua amplitude típica para membros superiores compreendida entre

poucas centenas de microvolts até aproximadamente 10mV e sua faixa de frequência entre 15Hz e 500Hz (ATZORI, 2012). Estes valores variam — entre outros fatores — de acordo com o tipo de músculo analisado, o nível de contração muscular e o posicionamento dos eletrodos (DE LUCA *et al.*, 2010). A Figura 3.a apresenta o sinal obtido na execução de duas repetições de dois movimentos — fechamento da mão (movimento 5) e ação de apontar (movimento 6) — do oitavo canal de EMG adquirido do voluntário 1 da base IEE enquanto a Figura 3.b representa a distribuição espectral normalizada para os 17 movimentos realizados.

Figura 3 - Caracterização do sinal proveniente de um canal de eletromiografia: a) amplitude e b) distribuição espectral do sinal para duas repetições de dois movimentos distintos da base IEE.



Fonte: Elaboração própria.

2.2.2 Aquisição do sEMG

A aquisição dos sinais de sEMG pode ser realizada por diferentes tipos de eletrodos. Normalmente, a morfologia e amplitude do sinal são dependentes das propriedades elétricas e posicionamento dos eletrodos e do músculo onde a diferença de potencial é medida (DE LUCA *et al.*, 2010; ISON & ARTEMIADIS, 2014). Os eletrodos podem ser utilizados em configuração monopolar (par de eletrodos onde um é referência) ou bipolar (trio de eletrodos onde a medida diferencial é realizada entre dois eletrodos com o terceiro servindo como referência). Os eletrodos são divididos basicamente em invasivos e não invasivos, estes últimos também chamados de eletrodos de superfície (BRONZINO & ENDERLE, 2012).

2.2.2.1 Posicionamento dos Eletrodos e Musculatura do Braço

O posicionamento dos eletrodos constitui uma etapa importante na aquisição do sinal de sEMG que naturalmente apresenta amplitudes $< 1\text{mV}$ antes da amplificação. Os eletrodos devem

ser posicionados na parte ventral e ao longo do músculo (DE LUCA, 1997; ISON *et al.*, 2014) onde a maior concentração de unidades motoras gera um maior potencial que é menos afetado pela influência de outros grupos musculares, fenômeno denominado *cross-talk* (BASMAJIAN & DE LUCA, 1985). Há ainda o cuidado posicionar os eletrodos preferivelmente em áreas que não obstruam a movimentação e visão do paciente/voluntário e que possuam boa referência anatômica (fácil localização) para possibilitar a repetição dos ensaios propostos em condições adequadas.

Considerando a variedade de músculos na região de interesse de estudo e os movimentos a serem classificados, é pertinente apresentar a musculatura envolvida em estudos que envolvem sEMG e movimentos de membros superiores. Geralmente é considerada a musculatura da mão, antebraço e braço, representada na Figura 4 em vista anterior superficial e profunda enquanto a Tabela 1 apresenta a relação entre alguns músculos e movimentos comumente executados. Esta Tese apresenta uma revisão sucinta sobre fisiologia e sinais mioelétricos envolvidos neste trabalho. Para informações mais aprofundadas sobre os temas é recomendada a leitura dos seguintes livros:


- BELTRAMINI, L.M. **Elementos de histologia e anátomo-fisiologia humana**. São Carlos: USP, 1997.
- BRONZINO, J. & ENDERLE, J. **Introduction to Biomedical Engineering** 3rd Edition, Burlington, MA, EUA, 2012, Elsevier Inc. (Capítulos 3 e 4);
- GUYTON, A.C. **Fisiologia Humana**. Rio de Janeiro: Guanabara Koogan, 2006 (Unidade II);
- MOORE, J. & ZOURIDAKIS, G., **Biomedical Technology and Devices Handbook**, Boca Raton, FL, EUA, 2004 CRC Press LLC (Capítulo 4);
- TORTORA, G. J. **Corpo Humano: fundamentos de anatomia e fisiologia**, 10 ed. Guanabara Koogan, Rio de Janeiro, 2007 (Capítulo 8).

Tabela 1 - Principais músculos superficiais do braço e antebraço e suas funções.

MÚSCULO	MOVIMENTO
Bíceps braquial	Flexão da mão e supinação do antebraço; flexão do braço.
Braquial	Flexão do antebraço.
Braquiorradial	Flexão do antebraço.
Tríceps braquial	Extensão do antebraço/ braço.
Flexor radial do carpo	Flexão/abdução da mão.
Flexor ulnar do carpo	Flexão/abdução da mão.
Palmar longo	Flexão da mão.
Flexor superficial dos dedos	Flexão das falanges médias de cada dedo.
Extensor radial do carpo	Extensão/abdução a mão.
Extensor ulnar do carpo	Extensão/abdução a mão.
Extensor dos dedos	Extensão das falanges.

Fonte: Adaptado livremente de TORTORA, 2007.

Figura 4 - Principais músculos superficiais do braço e antebraço sEMG.



Fonte: Adaptado livremente de (TORTORA, 2007).

2.3 PRÉ-PROCESSAMENTO DO SINAL DE ELETROMIOGRAFIA

2.3.1 Processo de Filtragem de Sinais de sEMG

Após a digitalização, o sinal de sEMG pode ser condicionado através de funções matemáticas que constituem o pré-processamento do sinal. Na etapa de pré-processamento, estas funções são utilizadas para determinar algumas métricas deste sinal estocástico e torná-lo mais apto à etapa de classificação. Comumente, esta etapa contempla a retificação e a normalização do sinal, além de algoritmos de projeção ou redução de *features* ou canais através, por exemplo, do uso de métodos como *Principal Component Analysis* (PCA) ou o *Independent Component Analysis* (ICA) ou mesmo *thresholds*, além dos próprios métodos de extração de *features* e filtros digitais específicos (CENE *et al.*, 2016b; ISON & ARTEMIADIS, 2014; MICERA *et al.*, 2010; CENE & BALBINOT, 2018a).

Tradicionalmente, a solução mais prática para a filtragem do sinal seria a limitação da banda-passante na etapa de aquisição, entretanto, nos sinais de sEMG o ruído encontra-se também na mesma faixa do sinal de interesse. Logo, reduzir demasiadamente a banda passante, resultaria na perda de sinal útil. Assim, filtros aplicados às etapas de pré-processamento destes sinais geralmente compreendem filtros não convencionais (HOFMANN *et al.*, 2016; HASHIM *et al.*, 2014; ORTOLAN *et al.*, 2003; BOTTER & VIEIRA, 2015; ZHOU *et al.*, 2009; ZIVANOVIC & GONZÁLES-IZAL, 2012; RILLO *et al.*, 2014). Neste trabalho, uma adaptação da Transformada de Antonyan Vardan (*Antonyan Vardan Transform*) (AVT) é utilizada para a filtragem dos dados.

2.3.2 Antonyan Vardan Transform (AVT) Filter

Métodos não-paramétricos para filtragem são comumente utilizados junto a sinais estocásticos. Métodos utilizados neste contexto incluem filtros como Wiener, Kalman e *ARMA* (do inglês, *Autoregressive-Moving-Average*) (EUBANK, 2006). Comparado aos métodos citados, o AVT se destaca por ser formado por um modelo computacional mais simples, sendo bastante útil para a remoção de ruído dentro da banda de interesse de um sinal estocástico. O filtro AVT caracteriza-se como um filtro estatístico, sendo utilizado para suavizar o sinal de sEMG adquirindo, limitando-o a uma faixa de excursão e substituindo *outliers* por valores médios do sinal, removendo assim, muitos componentes de ruído presentes na faixa de interesse remanescentes da etapa nalógica da aquisição do sinal (CENE *et al.*, 2018b).

O AVT tem duas formas básicas de realização, baseado em sua média aritmética e na mediana do segmento de interesse. Independentemente da estratégia utilizada, a métrica escolhida é utilizada como referência para o descarte de dados fora do intervalo admitido. O algoritmo para um filtro AVT básico consiste em:

- 1) definir a porção do sinal (ou segmento) de interesse;
- 2) calcular o valor médio ou mediana do segmento;
- 3) calcular o desvio padrão do segmento;
- 4) descartar os dados que não estejam no intervalo definido (média \pm desvio padrão);
- 5) utilizar os sinais remanescentes como o novo sinal filtrado.

Portanto, o filtro AVT pode ser utilizado como método para descarte de amostras de uma determinada região de interesse. As modificações no algoritmo encontram-se detalhadas no Subcapítulo 4.4.4 da metodologia.

2.3.3 Segmentação dos Sinais de sEMG

A segmentação do sinal de sEMG tem por objetivo separar regiões de ativação muscular representativas para os diferentes movimentos a serem classificados. Existem basicamente dois modos diferentes de segmentar um sinal quanto a sua aquisição para a formação de uma base de dados: A segmentação por *timestamps* do movimento completo e a segmentação por janelamento, que por sua vez, se divide em diversas abordagens em relação ao tamanho e sobreposição das janelas (segmentos de sinal) utilizados.

Comumente a geração das bases de dados de sEMG ocorre com a estimulação visual (ATZORI *et. al.*, 2014; CENE *et. al.* 2019b) ou auditiva (KHUSHABA *et. al.*, 2011) do voluntário, que é instruído a repetir os movimentos (estímulos) que compõe o estudo de interesse. As temporizações indicando em que momento cada movimento deve ser realizado são gravadas e a este vetor de ocorrência temporal é dado o nome de *timestamp*. Assim, sabendo quando cada movimento foi realizado, é atribuído um vetor de rótulo de classes que é utilizado em métodos de aprendizagem supervisionada e que permite a classificação dos sinais de interesse (ATZORI *et. al.*, 2014; CENE *et. al.* 2016b; PHINYOMARK *et. al.*, 2012, CENE *et. al.* 2019b).

Embora o método do *timestamp* ofereça dados mais regulares para o processo de extração de *features*, a correspondente janela do sinal de interesse é formada somente após o movimento ter sido executado, o que impede a aplicação da técnica em tempo real. Já a segmentação por

janelamento é mais utilizada na literatura por sua abordagem proporcionar um cenário de predição mais próximo ao desejado para o controle de uma prótese por sinais mioelétricos (FARRELL, 2011). O método do janelamento pode ser dividido em janelas deslizantes (em inglês, *sliding windows*) com ou sem sobreposição (em inglês, *overlap*), sendo que na literatura há uma variação destas abordagens quanto ao tamanho de janela utilizado e a detecção de início e fim de movimento.

Em relação ao tempo utilizado na abordagem das janelas deslizantes, janelas de 50ms (FARRELL & WIER, 2007), 160ms com 20ms de *overlap* (ZHANG & HUANG, 2015), 250ms (NAIK *et. al.*, 2015) entre outras já foram utilizadas como base para a extração de *features*. Independentemente do tempo escolhido, é importante considerar que o *delay* de resposta do sistema, é sempre, no mínimo, igual ao tempo de armazenamento (“bufferização”) de dados utilizado. Na literatura há trabalhos como o de (FARRELL, 2011), que citam que para o controle natural por parte do usuário, o tempo ótimo do *delay* inserido no sistema não deve ser maior do que 125ms para não prejudicar a usabilidade do dispositivo. Assim, a abordagem *overlaped windows* (janelas sobrepostas) se torna atrativa, pois utiliza uma grande parte da janela anterior e um pequeno incremento, que é o tempo mínimo para a classificação do sinal. Como exemplo de um trabalho com essa abordagem pode-se citar o artigo de (ZHANG & HUANG, 2015).

Em relação à seleção dos tempos iniciais e finais de um segmento de interesse em função da ativação do sinal, a mesma pode ocorrer utilizando-se os *timestamps* previamente definidos em cada base de dados em aplicações *offline* (ANAM & AL-JUMAILY, 2015a) ou através das *features* extraídas de cada segmento em abordagens *online* (BALBINOT & FAVIEIRO, 2013; JIANG *et. al.*, 2014; KWON & KIM, 2011). Geralmente, abordagens *online* baseiam-se em características de amplitude do sinal como *thresholds*, mas atualmente outras abordagens têm sido propostas como a de (LIN & KULIC, 2014) que utilizam Modelos Ocultos de Markov para a segmentação do sinal ou (PARK & CHUNG, 2015), que utilizam modelos Semi-Markovianos. Outro exemplo é o trabalho de (MAZURKIEVICZ, 2007), que utiliza *Wavelets* para a segmentação automática.

É comum encontrar algumas discrepâncias quanto aos momentos exatos da realização dos movimentos mesmo em bases que fornecem os *timestamps* junto aos dados. Esta falha de alinhamento geralmente ocorre por motivos de ordem experimental, como por exemplo, latência do sujeito depois de receber o estímulo até começar a realizar o movimento. Por este motivo,

alguns autores como (ATZORI *et. al.*, 2014), utilizam um processo de *relabelling*, de modo a realinhar da forma mais apropriada possível os rótulos fornecidos com os dados adquiridos.

Por melhor que seja o alinhamento dos rótulos com os movimentos, as porções iniciais e finais do movimento (chamadas de transição entre movimentos) costumam ser as seções mais desafiadoras no processo de classificação (CALVERT & CHAPMAN, 1977; ROSSI *et. al.*, 2015; AL-TIMEMY *et. al.*, 2013; AMSUSS *et. al.*, 2014; HAN & JO, 2014; NAIK *et. al.*, 2016; YANG, 2010). A ativação e desativação progressiva dos MUAPs exigidos por cada movimento tendem a resultar em sinais de baixa amplitude, pouco distintos e sobrepostos entre classes em uma perspectiva de *Machine Learning* (CENE & BALBINOT, 2018a). Nesta parcela do sinal, a extração de *features*, particularmente baseadas em amplitude no domínio tempo, geralmente não são descritivas o suficiente, tendendo a diminuir a eficiência do reconhecimento da ativação dos movimentos (ISON & ARTEMIADIS, 2014). Este tipo de problema é clássico e ainda não resolvido na literatura. Algumas tentativas de mitigar este efeito foram realizadas, muitas delas, simplesmente ignorando o período de transição, como proposto por (ROSSI *et. al.*, 2015; AL-TIMEMY *et. al.*, 2013; NAIK *et. al.*, 2016;). Alternativamente, (HAN & JO, 2014) utilizaram um modelo Bayesiano com uma estratégia de *Latent Neural States* para o processamento do sinal de sEMG, obtendo taxas de acerto *offline* da ordem de 92% para quatro movimentos de mão. Uma abordagem alternativa na extração de *features* baseada na projeção dos dados de sEMG através de SVD foi abordada nesta Tese, e encontra-se detalhada no Subcapítulo 4.4.6 da metodologia.

2.3.4 Extração de *Features* dos Sinais de sEMG

Independentemente do tipo de filtro e classificador utilizados, a extração de *features* configura-se como uma etapa vital no processo de classificação dos movimentos propostos. A extração e seleção de *features* adequadas do sinal destina-se a formar uma base de conhecimento descritiva o suficiente para possibilitar a aplicação pretendida (KUZBORSKI, 2012). No contexto da classificação de sinais de sEMG, o objetivo em relação ao uso das *features* consiste em fornecer parâmetros estatísticos repetitivos e descritivos o suficiente para possibilitar a formação de um modelo de classificação que gere o menor erro possível. A escolha das *features* convenientes é frequentemente mais importante do que o esquema de controle escolhido com relação ao bom desempenho de controle multifuncional (ENGLEHART, 1999; LOCK *et al.*, 2005).

Existem dois domínios básicos para a extração de características: tempo e frequência. Em 1993, (HUDGINS *et al.*, 1993) estabeleceram as bases de um sistema de controle mioelétrico utilizando um conjunto de *features* no domínio do tempo (TD, do inglês *Time Domain*). Desde então diversas técnicas de extração de *features* foram propostas de modo a complementar o seu trabalho incluindo *features* extraídas no domínio da frequência (FD, do inglês *Frequency Domain*), *features* híbridas em tempo e frequência (TFD, do inglês *Time-Frequency Domain*) e *features* envolvendo sequência temporal (TSD, do inglês *Time-Serial Domain*) (ISON & ARTEMIADIS, 2014; MICERA *et al.*, 2010). Algumas das *features* mais utilizadas provenientes destas quatro abordagens distintas são apresentadas na Tabela 2.

Tabela 2 Características extraídas para o uso na classificação e caracterização de movimentos.

DOMÍNIO	FEATURES	VANTAGENS	DESVANTAGENS
TD	Variância (VAR), Valor Médio Absoluto (MAV), Raiz Média Quadrada (RMS), Cruzamentos por Zero (ZC), <i>Slope Sign Change</i> (SSC), Comprimento de Onda (WL), Histograma, <i>Skewness</i> (SKW)	Simplicidade computacional, Proporcionalidade à força e amplitude da contração muscular	Sensibilidade ao ruído, Mudanças transientes do sEMG, Cancelamento de amplitude
FD	Espectro de Potência, Densidade Espectral, Frequência Média, Frequência Mediana	Detecção de fadiga	Complexidade computacional, Baixa resolução temporal, Elevada variância
TFD	Transformada Wavelet, STFT (<i>Short-Time Fourier Transform</i>), mDWT (<i>marginal Discrete Wavelet Transform</i>), STTT (<i>Short-Time Thompson Transform</i>)	Resolução em tempo e frequência, Representação transiente e estática, Distinção de sinais não estacionários	Características abstratas, Saídas com alta dimensionalidade, Muitos parâmetros de controle
TSD	Coefficientes auto-regressivos, Coefficientes Cepstrais	Detecção de fadiga, discernimento dos sinais não estacionários no tempo	Complexidade computacional, Baixa resolução temporal, Elevada variância

Fonte: Adaptado livremente de (ISON *et al.*, 2014; MICERA *et al.*, 2010).

Embora *features* no domínio do tempo sejam úteis para o reconhecimento dos padrões dos sinais de sEMG, elas geralmente são afetadas por características não estacionárias do sinal. Por se basearem basicamente na amplitude do sinal, *features* no TD são especialmente deficientes na transição entre movimentos, sendo estes os trechos do sinal geralmente mais suscetíveis a erros de

classificação (ROSSI *et. al.*, 2015; AL-TIMEMY *et. al.*, 2013). Esta Tese de Doutorado utiliza-se de uma *feature* desenvolvida para o aumento da representatividade do sinal em momentos de transição, quando as *features* mais usuais são flagrantemente ineficientes. A descrição detalhada da técnica denominada *Differential Enhanced Signal* (DES) encontra-se no Subcapítulo 4.4.6 da metodologia.

2.3.5 Principal Component Analysis (PCA) e Singular Value Decomposition (SVD)

O PCA é uma transformada linear amplamente utilizada como método não supervisionado para redução de dimensionalidade de dados, reconhecimento estatístico de padrões e processamento de sinais (HAYKIN, 2008). A utilidade do PCA no processamento de sinais advém da sua capacidade de representar os sinais através de projeções em componentes de máxima variância (componentes principais). No espaço da transformada (valores projetados), o uso destes componentes possibilita a representação aproximada de todo o espaço de dados através dos componentes principais mais descritivos, o que confere ao PCA excelente desempenho na redução de dimensionalidade das amostras, sendo muito utilizado como elemento de pré-processamento em diversas aplicações de *Machine Learning* (HAYKIN, 2008).

No PCA os autovetores ordenados pelos seus respectivos autovalores descrevem os componentes principais (maiores portadores de informação) do sistema. Desta forma, é possível diminuir o número de componentes utilizados para a representação dos dados, perdendo um mínimo de informação (HAYKIN, 2008) ao se eliminar os componentes com os menores autovalores. Esta abordagem configura a utilização do PCA como redutor de dimensionalidade. Apesar da sua eficiência para a representação dos dados, o PCA possui algumas restrições quanto às condições das matrizes representadas (que devem ser similares), isto motiva a utilização de métodos análogos que possuem as mesmas potencialidades do PCA e ao mesmo tempo são mais flexíveis, como o *Singular Value Decomposition* (SVD).

O SVD consiste em uma transformada linear pertencente à família dos “*low-rank approximation methods*” (WANG, 2011; HAYKIN, 2008), O SVD consiste em um método de decomposição de matrizes análogo ao PCA sem as restrições matriciais características, podendo ser utilizado para decompor qualquer matriz retangular, sendo, portanto, mais abrangente. Outra vantagem do SVD é a possibilidade de utilizá-lo em sua chamada “forma econômica” que consiste na remoção de colunas de valor zerado do método original ou da escolha explícita por um número

limitado de componentes, resultando em uma matriz quadrada de menor dimensão, mais facilmente calculável. Segundo (HAYKIN, 2008), este tipo de abordagem fornece um ganho computacional considerável – algo entre $O(W)$ e $O(W^2)$ – e aproxima a matriz original dentro de uma faixa de erros pequena, descrita em função do erro de mínimos quadrados do traço da diferença entre as matrizes (WANG, 2011; HAYKIN, 2008). A decomposição realizada pelo SVD em uma matriz A é descrita pela Equação (1).

$$A = U\Sigma V^T \quad (1)$$

onde $\forall A \in \mathbf{R}$: U e V são denominados vetor singular esquerdo e vetor singular direito, respectivamente. Sendo U e V matrizes ortonormais de números reais, tal que $U^T U = I = V^T V$, ambos formam o espaço da transformada onde os dados são projetados, enquanto a matriz Σ reúne os chamados valores singulares ($\Sigma = \text{diag}[\sigma_1, \sigma_2, \sigma_3 \dots \sigma_n, 0, \dots, 0]$), ordenados por ordem de relevância nesta matriz diagonal. Genericamente, pode-se reescrever a decomposição matricial da Equação (1) em função das suas dimensões de m linhas e n colunas pela Equação (2).

$$A = U_{m,m} \Sigma_{m,n} V_{n,n}^T \quad (2)$$

Considerando que $U^T U = I = V^T V$, as igualdades apresentadas para $A^T A$ e AA^T utilizadas para o cálculo dos vetores singulares da Equação (3) são obtidas. A Equação (4) demonstra como pode ser obtida a matriz diagonal de valores singulares que pode ser utilizada na Equação (5) e na Equação (5) para a definição de dos vetores singulares considerando o sistema apresentado na Equação (3). Os vetores singulares direito e esquerdo para a decomposição da matriz A devem ser depois normalizados para atender a condição de ortonormalidade da técnica. A Equação (7) explicita os componentes de cada matriz e a Equação (8) os descreve em função da variação do índice j para todas as n colunas das matrizes, representando cada componente singular ordenadamente, por ordem de relevância.

$$A^T A = V \Sigma^2 V^T, \text{ assim como: } AA^T = U \Sigma^2 U^T \quad (3)$$

$$\Sigma = \text{det}(A^T A - \sigma I) \quad (4)$$

$$V = A^T A - \sigma I \quad (5)$$

$$AV = U \Sigma \quad (6)$$

$$A[v_1, v_2, \dots, v_n] = [u_1, u_2, \dots, u_m] \begin{bmatrix} \sigma_1 & 0 & 0 \\ 0 & \ddots & 0 \\ \vdots & 0 & \sigma_n \\ 0 & 0 & 0 \end{bmatrix} \quad (7)$$

ou seja:

$$Av_{i,j} = \sigma_i u_j \quad \text{onde: } \begin{cases} i = 1, \dots, m \text{ (para } u) \\ j = 1, \dots, n \text{ (para } u \text{ e } \sigma) \end{cases} \quad (8)$$

onde:

- A é a transformada linear de \mathbf{R}^n para \mathbf{R}^m .
- $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_m$ são bases ortonormais que mapeiam o espaço de saída da transformada \mathbf{R}^m .
- $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n$ são bases ortonormais que mapeiam o espaço de entrada (cada v_j é mapeado em $\sigma_i u_j$) da transformada \mathbf{R}^n .

2.3.6 Extreme Learning Machines (ELM)

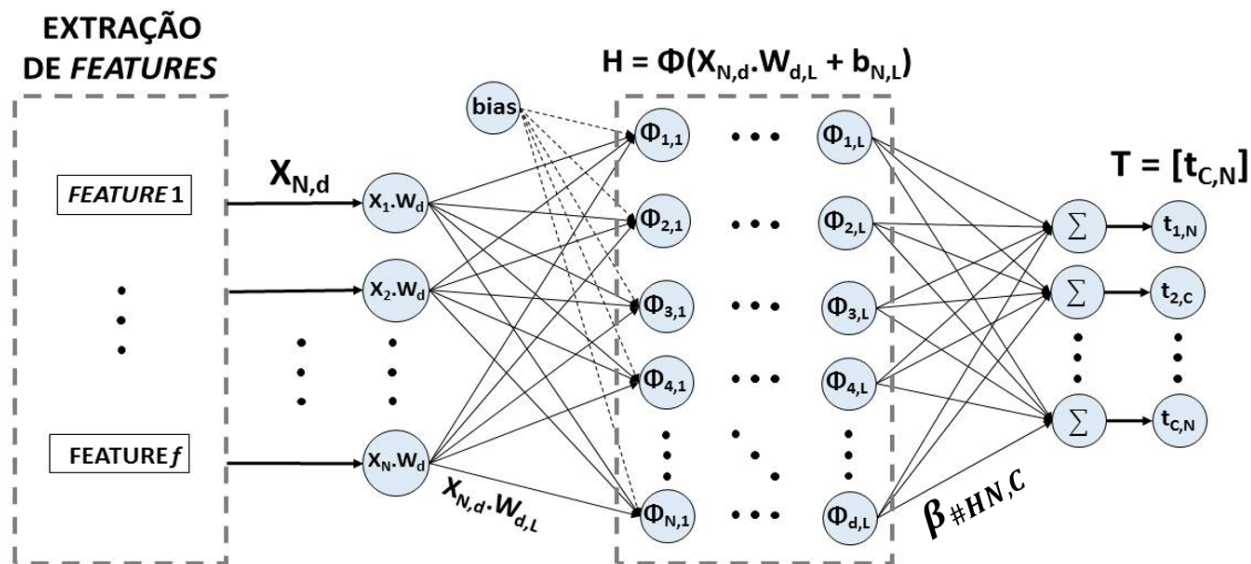
O ELM é um método de aprendizagem supervisionado baseado em Redes Neurais *FeedForward* de Camada Única (SLFN, do inglês *Single Layer FeedForward Neural Networks*) proposto originalmente por Huang *et.al.* em 2006 (HUANG *et al.*, 2006). O ELM garante uma solução ótima do sistema através da determinação analítica de uma matriz pseudoinversa utilizada na geração dos pesos de saída do classificador. O ELM apresenta uma boa generalização com custo computacional muito baixo quando comparado com abordagens baseadas em descidas de gradiente e estruturas *feedforward* iterativas mais tradicionais (HUANG *et. al.*, 2006; MICHE, 2010; LIU *et. al.*, 2015; AKUSOK, 2015; TANG, 2016). A utilização dos pesos aleatórios distribuídos em uma faixa de [-1; 1] na rede resulta em uma maior capacidade de generalização devido à geração de *features* quase ortogonais (pouco correlacionadas) na camada *hidden* e, além disso, tendem a gerar *features* com normas pequenas, o que deixa a rede mais robusta, quanto à interferência de ruído (AKUSOK *et. al.*, 2015).

Devido à sua velocidade computacional quando comparados às Redes Neurais tradicionais, os métodos baseados em ELM se tornaram uma abordagem interessante para o processamento de grandes conjuntos de dados, atraindo a atenção das comunidades de ML e *Big Data* (QIU *et al.*, 2016). O uso de ELM em dados de alta dimensionalidade é abordado na revisão realizada por (LIN *et. al.*, 2015), apresentando aplicações no processamento de imagem/vídeo e variantes do método ELM original, como uma forma regularizada de ELM, também mais detalhada em (AKUSOK, 2015, SCARDAPANE, 2016). Em aplicações baseadas em sEMG, o algoritmo ELM foi usado em combinação com diferentes algoritmos de pré-processamento, como *Wavelets* (ANAM & AL-JUMAILY, 2014), PCA (PARK *et al.*, 2011; LEE *et al.*, 2011; KIM *et al.*, 2013) e métodos de

regressão (ANAM & AL-JUMAILY, 2015a, ANAM & AL-JUMAILY, 2015b), onde também demonstrou um desempenho consistente.

O hiperparâmetro mais importante (e único, na versão padrão do método) do ponto de vista da configuração da topologia do ELM é a escolha do número de neurônios da camada *hidden* ($\#HN$). Por não existirem iterações no método para a geração e otimização dos pesos de saída (obtidos de forma analítica e sem qualquer realimentação), um número muito pequeno de neurônios tende a conduzir o método ao *underfitting*, da mesma forma que o excesso tende levá-lo ao *overfitting*. A utilização da versão regularizada do método, no entanto, tende a impedir ambas as situações, oferecendo mais estabilidade para o classificador. Em função da importância deste parâmetro, além de alguns métodos tradicionais de redução da dimensionalidade, artigos do estado da arte do ELM, eventualmente consideram a utilização de “algoritmos de poda” (*prunning algorithms*), onde o objetivo é encontrar um número ótimo de neurônios da camada oculta (AKUSOK, 2015; MICHE, 2010; MESQUITA, 2015) capaz de realizar uma boa classificação dos dados de entrada. A estrutura básica do método ELM é apresentada na Figura 5.

Figura 5 - Arquitetura básica do método ELM utilizada para o reconhecimento de padrões baseada na combinação das diferentes features de entrada.



Fonte: Elaboração própria.

Na arquitetura apresentada na Figura 5, f features são extraídas dos dados de interesse compondo a matriz de entrada X do classificador. Por sua vez, X é formado pelo arranjo de N amostras a serem treinadas/classificadas e d colunas de tamanho f , que correspondem à quantidade de features extraídas dos dados de entrada. W representa a matriz de pesos formada pelas d colunas

de entrada e L neurônios da camada oculta. \mathbf{H} representa a matriz da camada oculta, que é composta pelo modelo gerado pela função de *kernel* (Φ) utilizada para a projeção da entrada $\mathbf{XW} + \mathbf{b}$ para a saída $\mathbf{T} = \mathbf{H}\boldsymbol{\beta}$, onde $\mathbf{H} = \Phi(\mathbf{XW} + \mathbf{b})$ e cada vetor em \mathbf{H} gera uma saída do modelo representada por $\boldsymbol{\beta}$, como mostra a Equação (9).

$$\mathbf{T}_{C,i} = \sum_{j=1}^L \beta_j \Phi(\mathbf{w}_j \mathbf{x}_i + \mathbf{b}_j) = \mathbf{t}_i + \epsilon \quad (9)$$

Na Equação (9), $\boldsymbol{\beta}$ é o vetor de pesos de saída dos L neurônios *hidden* que dado um vetor de entradas \mathbf{x}_i sujeito aos pesos de entrada \mathbf{w}_i e aos \mathbf{b}_i *bias* associados, gera a saída \mathbf{t}_i e um ruído associado ϵ , que é formado tanto por ruído aleatório quanto pela dependência das variáveis. A matriz \mathbf{T} por sua vez, é a matriz de saída, composta pelos N vetores de amostras constituídos de C classes de elementos que representam o argumento máximo (*arg max*) para cada classe e cada amostra. A matriz \mathbf{T} agrega os valores máximos das saídas que ocorrem sempre na classe que rotula o movimento proposto. Portanto cada amostra N de entrada \mathbf{H} é gerado um vetor de *arg max* em função de cada classe c onde a classe que possui o maior valor de *arg max* (e, conseqüentemente o menor erro médio quadrático) para a amostra, a rotula baseado em uma heurística *One-vs-All*.

2.3.6.1 Obtenção da matriz pseudoinversa no ELM

As variações dos métodos de SLFN entre as formas regularizadas e não regularizadas (padrão) distinguem-se em função do método de obtenção das matrizes pseudoinversas do modelo (AKUSOK *et. al.*, 2015). Genericamente, a geração do modelo para os métodos SLFN pode ser apresentada matricialmente pela Equação (10), onde \mathbf{A} corresponde a matriz de dados de entrada utilizados no treinamento, \mathbf{x} corresponde aos coeficientes do modelo a serem encontrados e \mathbf{Y} corresponde aos rótulos de treinamento que também é saída desejada do sistema.

$$\mathbf{Ax} = \mathbf{Y} \quad (10)$$

Este tipo de sistema pode ser resolvido através da aplicação da inversa de \mathbf{A} (\mathbf{A}^{-1}) em ambos os termos da equação como apresentado na Equação (11). Quando a matriz \mathbf{A} é quadrada, a inversa é garantida ($\det \neq 0$) e a solução para \mathbf{x} é determinada como apresentado na Equação (12).

$$\mathbf{AA}^{-1}\mathbf{x} = \mathbf{A}^{-1}\mathbf{Y} \quad (11)$$

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{Y} \quad (12)$$

Já nos casos subdeterminados (menos linhas que colunas) e sobredeterminados (mais linhas que colunas), a matriz inversa direta pode não existir. Em condições experimentais, a situação típica considerando um treinamento em *batch* é a de matrizes não quadradas, considerando que o

número de amostras geralmente excede muito o número de *features* de entrada do sistema. Neste caso, para a garantia da solução do sistema, usa-se a matriz pseudoinversa, que consiste na exata matriz inversa quando ela existe e em uma aproximação da inversa ideal quando a mesma não é definida (ALBERT, 1972; BEM-ISRAEL, 2002). A pseudoinversa é utilizada como meio de obtenção da matriz inversa para matrizes de entradas retangulares gerais. Como o SVD pode efetuar a decomposição de qualquer matriz em vetores e valores singulares, é utilizado para o cálculo da pseudoinversa do sistema, como descreve a Equação (13). Desta forma, quando a matriz de interesse é não-inversível, a pseudoinversa é capaz de realizar a melhor aproximação numérica possível considerando uma faixa de tolerância para os valores obtidos (14).

$$\mathbf{x} = \mathbf{A}^{\dagger}\mathbf{Y} \quad (13)$$

sujeito a:

$$\begin{cases} \mathbf{A}^{-1}\mathbf{A}\mathbf{x} = \mathbf{I}\mathbf{x} = \mathbf{A}^{-1}\mathbf{Y} \\ \mathbf{A}^{\dagger}\mathbf{A}\mathbf{x} \approx \mathbf{I}\mathbf{x} \approx \mathbf{A}^{\dagger}\mathbf{Y} \end{cases} \quad (14)$$

A matriz pseudoinversa obtida em função do SVD tem o erro quadrático descrito em função do traço da Hessiana entre a matriz original e a matriz projetada em relação à norma de *Frobenius* (ALBERT, 1972; BEN-ISRAEL, 2002). Conforme a Equação (15), a obtenção da pseudoinversa através do SVD se dá de forma análoga à da matriz retangular genérica apresentada na Equação (1), onde, para notações envolvendo ELM, geralmente $\mathbf{A}^{\dagger} = \mathbf{H}^{\dagger}$.

$$\mathbf{A}^{\dagger} = \mathbf{V}\mathbf{\Sigma}^{-1}\mathbf{U}^T \quad (15)$$

Computacionalmente, consideram-se somente os valores singulares da matriz $\mathbf{\Sigma}$ maiores do que uma tolerância pré-determinada. Considerando que os valores singulares são dispostos de forma decrescente na matriz diagonal, isto equivale a estipular o limite do truncamento da matriz de valores singulares, o que funciona analogamente a limitar o número de componentes principais com base em seu autovalor no PCA e que impacta diretamente na velocidade do método utilizado em sua chamada “forma econômica”. Computacionalmente a tolerância é calculada em função da limitação de precisão de ponto flutuante por parte da máquina ou definida em função do método de SVD utilizado para a obtenção da matriz (AKUSOK *et. al.*, 2015). Uma vez reduzida a matriz, os cálculos seguem exatamente os mesmos passos descritos para o SVD com a exceção de que agora, como se deseja aproximar a pseudoinversa (\mathbf{A}^{\dagger}) ao invés de \mathbf{A} , a inversa da matriz $\mathbf{\Sigma}$ é utilizada na equação, que é transposta em relação à Equação (1). Uma vez obtida a pseudoinversa, o modelo de treinamento do sistema é definido como mostra a Equação (12). Abordagens

utilizando o ELM com a pseudoinversa de Moore-Penrose se encontram em trabalhos como os apresentados na Tabela 6, no Subcapítulo 3.2.3.

2.3.6.2 Obtenção da matriz pseudoinversa no RELM

A obtenção da pseudoinversa no RELM ocorre por regularização no qual um método de regressão é utilizado para o *fitting* do modelo (HUANG, 2014). Problemas resolvidos através de regressão podem ser divididos entre *well-posed problems* e *ill-posed problems*. A definição de *well-posed problem* é atribuída a um modelo matemático que: 1) possui uma solução; 2) essa solução é única; 3) essa solução varia continuamente em função das alterações iniciais do problema. Para *well-posed problems*, geralmente é possível utilizar um método de regressão linear conhecido como OLS (*Ordinary Least Squares*). Esta regressão visa diminuir o erro médio de mínimos quadrados levando em conta a matriz de coeficientes encontrada e o rótulo pretendido. Segundo o teorema de Gauss-Markov, o OLS é considerado o melhor estimador linear para *well-posed problems* (PIOTROWSKI & YAMADA, 2008). A regressão OLS para obter um modelo β tendo uma matriz de entrada H e uma saída T é apresentada na Equação (16), onde o sub-índice 2 denota a norma do erro médio quadrático no espaço euclidiano (L_2).

$$\min_{\beta} \|H\beta - T\|_2^2 \quad (16)$$

Entretanto, nos chamados *ill-posed problems*, a solução atingida pelo OLS pode a proporcionar o *overfitting*, ou o *underfitting* do sistema. Como pequenas variações de entrada acabam gerando variações muito bruscas na saída, β acaba sendo muito sensível às entradas e neste caso a solução ótima da regressão não é atingida. Assim, surge a necessidade da utilização de métodos de regressão regularizados, sendo um dos mais populares o *Ridge-Regression* (*Tikhonov Regularization*). Para a solução do sistema, o *Ridge-Regression* utiliza a adição de um termo de regularização C na minimização do erro, como apresentado na Equação (17) (TSENG & LEE, 2015; YANG & DENG, 2012).

$$\min_{\beta} \|H\beta - T\|_2^2 \quad s. t. \quad \|\beta\|_2^2 \leq C^2 \quad (17)$$

onde *s.t.* (do inglês, *subject to*) significa que a otimização de β está sujeita ao valor do termo de regularização C , que é uma variável escolhida no começo de cada processo de regressão, assim como, o multiplicador λ . O termo C restringe o valor a ser obtido pelos coeficientes β , impondo uma restrição para o problema de otimização formulado, que para as condições Karush–Kuhn–Tucker (KKT) e utilizando multiplicadores de Lagrange é dado pela Equação (18).

$$\mathcal{L}(\boldsymbol{\beta}, \lambda) = (\mathbf{H}\boldsymbol{\beta} - \mathbf{T})^2 + \lambda(\boldsymbol{\beta}^2 - C^2) \quad (18)$$

Considerando que a minimização deve ser realizada para os parâmetros de $\boldsymbol{\beta}$ sendo λ e C constantes, é possível reescrever a Equação (19) simplificadamente pela Equação (19).

$$\min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_2^2 \quad (19)$$

Desta forma, o modelo $\boldsymbol{\beta}$ representado na Equação (19) pode ser obtido através da pseudoinversa da matriz de entrada \mathbf{H} , como apresentado na Equação (20) e o erro quadrático a ser minimizado tanto pela pseudoinversa quanto pela *hat-matrix* (matriz de predição $\hat{\boldsymbol{\beta}}$) obtida pela *Ridge-Regression* é apresentado na Equação (21).

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \therefore \boldsymbol{\beta} = \mathbf{H}^\dagger \mathbf{T} \quad (20)$$

$$\|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\|_2^2 = \|\mathbf{H}\mathbf{H}^\dagger \mathbf{T} - \mathbf{T}\|_2^2 = \min_{\boldsymbol{\beta}} \|\mathbf{H}\hat{\boldsymbol{\beta}} - \mathbf{T}\|_2^2 \quad (21)$$

onde \mathbf{H}^\dagger refere-se a matriz pseudoinversa de Moore-Penrose obtida através do cálculo realizado através de decomposição matricial utilizando SVD e $\hat{\boldsymbol{\beta}}$ descreve a matriz de predição obtida através da Regularização de Thikonov (*Ridge-Regression*). Para a versão regularizada do método, o modelo da função custo que define a norma L_2 no espaço euclidiano que descreve o erro médio quadrático do sistema a ser minimizado baseado nas condições KKT é apresentado na Equação (22) (HUANG, 2014). Já a solução do sistema a ser encontrada pela regularização em termos de $\boldsymbol{\beta}$ é obtida na Equação (23), que corresponde a Equação (11) com $C = \lambda$, onde C é o termo de regularização utilizado para o RELM.

$$\min \left[\frac{1}{2} \|\boldsymbol{\beta}\|^2 + C \frac{1}{2} \sum_{i=1}^N \|\boldsymbol{\epsilon}_i\|^2 \right] - \sum_{i=1}^N \sum_{j=1}^m \alpha_{ij} [\mathbf{h}(x_i) \boldsymbol{\beta}_j - \mathbf{t}_{ij} + \boldsymbol{\epsilon}_{ij}] \quad (22)$$

$$\mathbf{H}^\dagger = \mathbf{H}^T (\mathbf{H}^T \mathbf{H} + \frac{1}{C})^{-1} \mathbf{T} \quad (23)$$

2.3.7 Modelos Discriminativos e Generativos e *Hidden Markov Model* (HMM)

Modelos Markovianos compõem uma das alternativas mais amplamente utilizadas para a classificação de dados envolvendo séries temporais e probabilidades conjuntas/condicionais para o tratamento de dependências entre amostras consecutivas (LEVINSON, 1989; ROSSI, *et al.*, 2015). Considerando a Regra da Cadeia para a distribuição condicional de probabilidades, uma série de observações X tem a sua probabilidade descrita pela Equação (24). Da mesma forma, para uma cadeia de Markov de primeira ordem, em que apenas a amostra anterior ($n-1$) é considerada no cálculo da probabilidade condicional, a probabilidade pode ser descrita pela Equação (25), onde

o termo $p(x_n|x_{n-1})$ representa a distribuição condicional de probabilidades até a amostra n (BISHOP, 2006).

$$p(x_1, x_2, \dots, x_n) = \prod_{n=1}^N p(x_n|x_1, x_2, \dots, x_{n-1}) \quad (24)$$

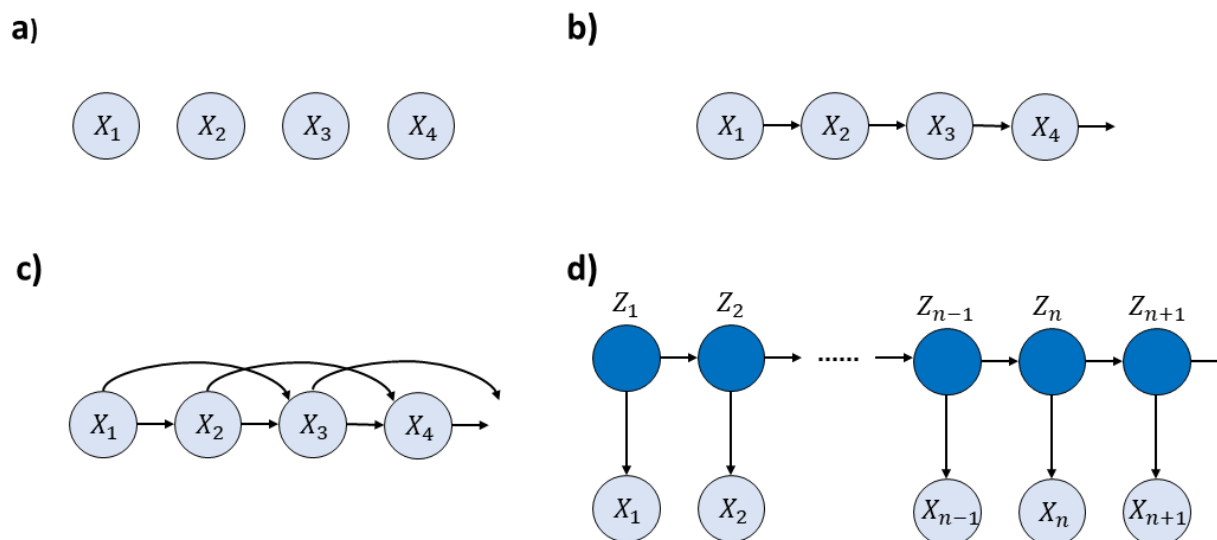
$$p(x_1, x_2, \dots, x_n) = p(x_1) \prod_{n=2}^N p(x_n|x_{n-1}) \quad (25)$$

Para aplicações nas quais a probabilidade condicional dada pela amostra (estado) imediatamente anterior é constante para todo o modelo, onde ela é obtida através de parâmetros que podem ser estimados através do treinamento do sistema, é formado um Modelo Markoviano homogêneo. A ordem (d) do Modelo Markoviano pode ser adaptada para contemplar mais termos anteriores no cálculo da probabilidade condicional, e assim mitigar possíveis efeitos adversos como ruídos nas variáveis que o compõe. Como exemplo, um Modelo Markoviano de segunda ordem pode ser calculado através da Equação (26). Embora a utilização de mais fatores possa agregar mais robustez à formação do modelo, seu uso em excesso implica em um acréscimo exponencial do custo computacional do método, que se torna intratável à medida em que d tende ao infinito (BISHOP, 2006; LEVINSON, 1989).

$$p(x_1, x_2, \dots, x_n) = p(x_1) \dots p(x_d|x_{d-1}) \prod_{n=d+1}^N p(x_n|x_{n-d}, x_{n-1}) \quad (26)$$

Em aplicações práticas, muitas vezes não é possível observar o exato estado pelo qual o modelo transita a cada instante de tempo, mas é possível observar os efeitos destas transições. Os modelos com esta característica são denominados Modelos Ocultos de Markov (HMM, do inglês, *Hidden Markov Model*). Estes modelos, derivados dos Modelos Markovianos tradicionais, são utilizados com o intuito de dar mais robustez ao método (BISHOP, 2006; CHIANG, *et al.*, 2008; LEVINSON, 1989). No HMM, somente as emissões, (nome atribuído ao valor consequente da passagem pelos diferentes estados) são observáveis, sendo o estado em si, uma variável latente (oculta), que pode ser calculada em função das probabilidades de emissão e transição entre as classes (LEVINSON, 1989). A Figura 6 ilustra a diferença entre os diferentes modelos em relação às variáveis de entrada, sendo eles: modelos independentes, modelos com condicionalidade temporal de primeira e segunda ordem e modelos utilizando variáveis auxiliares latentes, respectivamente. Neste último, além da probabilidade de transição entre estados, também é utilizada uma probabilidade de emissões correspondentes aos sub-níveis de cada estado (CHIANG, *et al.*, 2008; LEVINSON, 1989).

Figura 6 - Diferentes modelos de representação gráfica em função do processamento dos dados de entrada X: a) variáveis consideradas completamente independentes; b) Modelo Markoviano de primeira ordem; c) Modelo Markoviano de segunda ordem e d) *Hidden Markov Model*.



Fonte: Elaboração própria.

Em um cenário de reconhecimento de padrões, a principal motivação para a inserção destas variáveis é a geração de um modelo bidimensional que agrega diferentes submodelos com probabilidades individuais para cada classe. Ao fim de uma sequência temporal, os diferentes submodelos podem ser comparados de forma a estabelecer qual possui a máxima probabilidade para a descrição da série em questão (BISHOP, 2006; CHIANG, *et al.*, 2008; LEVINSON, 1989; FENG SHUN LIN & KULIC, 2014). Os componentes de um HMM podem ser descritos por:

- Um conjunto de N estados ocultos, $S = \{s_1, s_2, \dots, s_N\}$;
- Um conjunto de M símbolos discretos observados em cada estado, $V = \{v_1, v_2, \dots, v_M\}$;
- Uma matriz de transição, onde a_{ij} descreve a probabilidade de transição entre os estados vizinhos s_i e s_j , ou seja: $a_{ij} = p(q_t = s_j | q_{t-1} = s_i)$, sendo $1 \leq i, j \leq N$ com q_t representando um estado específico em um momento t ;
- Uma matriz de distribuição de probabilidades, onde $b_j(k)$ é a probabilidade de emissão de v_k em um instante t , ou seja: $b_j(k) = p(o_t = v_k | q_t = s_j)$, sendo $1 \leq i \leq M$; $1 \leq k \leq M$, onde o_t representa uma observação em um momento t ;

- Uma matriz de distribuição inicial de probabilidades de estado $\pi = \{\pi_i\}$ para o modelo proposto onde π descreve a probabilidade de π_i ser o estado inicial, ou seja: $\pi_i = p(q_1 = s_i)$ com $1 \ll N$.

Os HMM apoiam-se em duas premissas básicas em relação à independência das amostras (FENG SHUN LIN & KULIC, 2014; BISHOP 2006; HABERMANN *et al.*, 2016): 1) cada estado do modelo depende única e exclusivamente do estado anterior e 2) cada emissão depende somente do estado atual. Tais premissas permitem a propagação sequencial das relações para amostras contíguas do modelo que é descrito em notação compacta por $\lambda = (A, B, \pi)$ e em sua forma mais elementar segue o seguinte algoritmo:

- 1) Escolher um estado inicial do modelo $q_1 = S_1$ de acordo com a distribuição inicial de probabilidades π ;
- 2) Incrementar t ;
- 3) Escolher a emissão $o_t = v_k$ de acordo com a distribuição de probabilidades descrita pela matriz B para o estado $S_i (b_i(k))$;
- 4) Transitar para o estado $q_{t+1} = S_j$ de acordo com a probabilidade de transição descrita por $A (a_{ij})$;
- 5) Repetir os passos de 2 a 4 enquanto $t < T$.

A correspondência entre as probabilidades de transição de estados e emissão do HMM possuem natureza bidirecional, o que significa que tanto os estados futuros podem ser definidos através das combinações probabilísticas de um modelo, como o modelo pode ser calculado ao se transitar de um estado a outro considerando uma sequência específica. Baseado nestas características, o HMM pode ser utilizado para em três cenários principais (LEVINSON, 1989):

- 1) Avaliação: onde um HMM atribui a probabilidade $P(O|\lambda)$ de ocorrência de uma sequência $O = (o_1, o_2, \dots, o_T)$ dado diferentes modelos (classes) treinados $\lambda = (A, B, \pi)$ e o relaciona à classe que tem a maior probabilidade acumulada para a série finita de estados em questão;
- 2) Decodificação: onde para cada uma das emissões ($O = (o_1, o_2, \dots, o_T)$), é calculado um estado responsável pela geração de cada emissão. Embora nem sempre utilizada, esta técnica é especialmente interessante em algumas aplicações como por exemplo, mapeamento genético (GHAVIDEL *et al.*, 2015; FLAGEL *et al.*, 2019).

- 3) Treinamento/Aprendizado: onde um modelo é treinado de forma a maximizar a probabilidade $P(O|\lambda)$ para diversas classes diferentes. Nesta etapa geralmente são utilizados métodos como *Expectation-Maximization* (EM)/Baum-Welch ou Viterbi (RODRIGUEZ & TORRES, 2003) para o processo também conhecido como inferência.

Considerando a potencialidade do HMM para o tratamento de séries temporais, o método avaliado como alternativa de pós-processamento para mitigar ruídos de classificação do sinal e oferecer saídas mais consistentes. A integração do HMM e dos diferentes métodos de classificação confiável no ELM é especificada no Subcapítulo 4.4.8 deste trabalho.

3 ESTADO DA ARTE

Apesar do sinal de sEMG apresentar faixas de frequência e amplitude conhecidas, o sinal se caracteriza por um comportamento estocástico dependente do movimento realizado, da musculatura e do sujeito em questão (FARINA *et al.*, 2014). Este comportamento não-determinístico do sinal de sEMG originou diversas abordagens focadas tanto no pré-processamento (envolvendo filtragem e extração de *features*) como na classificação do sinal (geralmente métodos de pós-processamento, como o *Major-Voting*). De forma geral, procura-se obter os menores erros de classificação e tempo de processamento possíveis. Os próximos subcapítulos detalham algumas das principais alternativas em relação aos métodos de pré-processamento e classificadores utilizados no processamento de sinais de sEMG.

3.1 PRÉ-PROCESSAMENTO E EXTRAÇÃO DE *FEATURES*

Apesar de filtros de natureza passa-baixas diminuïrem o nível de ruído na medida em que o número de amostras (janela) para o filtro é aumentado, geralmente prejudica-se a resposta dinâmica do sistema, provocando latências que podem inviabilizar a utilização do método. Já filtros mais sofisticados tendem a causar atrasos na resposta do sistema devido à complexidade computacional envolvida. Assim, a escolha do filtro utilizado deve ponderar o nível da relação sinal-ruído (SNR) desejado e a responsividade do sistema (HOFMANN *et.al.*, 2016).

Dentre as várias soluções propostas para a filtragem dos sinais de sEMG na literatura, destaca-se o trabalho de (HOFMANN *et.al.*, 2016), que utilizaram um filtro bayesiano para suavizar o sinal mantendo parte de sua resposta dinâmica a um custo computacional ainda aplicável ao seu sistema *online* proposto. Já (ZHOU *et.al.*, 2009) empregaram um filtro baseado no operador *Teager-Kaiser Energy (TKE)*; sensível a variações de amplitude e frequência para o uso em contrações musculares leves (baixo emprego de força). Outras aplicações de filtros mais sofisticados são encontradas na remoção de artefatos gerados por batimento cardíaco (HASHIM *et.al.*, 2014; ZIVANOVIC & GONZÁLES-IZAL, 2012), ruído de ambiente (ORTOLAN *et.al.*, 2003) e ruído de linha (BOTTER & VIEIRA, 2015). Já RILLO *et. al.*, 2014, exploraram o uso do método de *Common Spatial Patterns (CSP)*, geralmente utilizado no processamento de sinais de EEG, para aumentar a representatividade do sinal, filtro este que demonstram ser tão eficiente quanto a utilização do PCA na taxa de acerto final de seu sistema. Neste trabalho, uma adaptação

da Transformada de Antonyan Vardan (*Antonyan Vardan Transform*) (AVT) é utilizada para a filtragem dos dados.

Em relação a algumas estratégias para a compensação da natureza estocástica do sinal e falta de representatividade gerada por abordagens mais usuais, há alguns trabalhos da literatura que visam mitigar estas influências. (KHUSHABA *et al.*, 2014), utilizaram *features* espectrais do sinal de sEMG para classificar movimentos realizados por 11 voluntários com o braço partindo de cinco posições distintas onde *features* no TD sofreriam variações consideráveis em função dos diferentes recrutamentos musculares envolvidos. Os autores utilizam esta heurística em alternativa ao uso de sensores inerciais, o que é geralmente tido como padrão e demonstram um aumento na taxa de acerto do classificador, que foi capaz de oferecer uma taxa de acerto média de aproximadamente 92% para as oito classes testadas em cinco posições diferentes do braço dos 11 voluntários. Já em (KHUSHABA *et al.*, 2016), os autores utilizam métricas de correlação e de seus denominados *Temporal-Spatial Descriptors* (TSDs) e os comparam com *features* mais usuais no TD baseadas em Wavelet e *features* Auto-Regressivas (AR-RMS), relatando em torno de 95% de taxa de acerto para 11 movimentos de dedos.

Existem ainda trabalhos de ampla revisão sobre o tema como o de (PHINYOMARK A. *et al.*, 2013) que compara 50 *features*, diferentes classificadores e tempos de segmentação e seu efeito nas taxas de acerto obtidas visando a construção de um classificador robusto. Os autores ressaltam as capacidades de *features* no TD, a utilização de *Linear Discriminant Analysis* (LDA) como classificador e uma configuração de 500ms+125ms nas janelas deslizantes para a segmentação do sinal. Esta Tese de Doutorado utiliza-se de uma *feature* desenvolvida para o aumento da representatividade do sinal em momentos de transição, quando as *features* mais usuais são flagrantemente ineficientes. A descrição detalhada da técnica denominada *Differential Enhanced Signal* (DES) encontra-se no Subcapítulo 4.4.6 da metodologia.

No que se refere a métodos não paramétricos para a definição dos dados mais relevantes para a formação do modelo, o PCA é um dos métodos mais amplamente utilizados. Esta abordagem configura a utilização do PCA como redutor de dimensionalidade. No processamento de sEMG, abordagens como estas são encontradas em (GEETHANJAL, 2015), que efetuou descartes de informação pertinente à formação do modelo variando a taxa de acerto obtida e (ZHAI *et al.*, 2016), que apresentaram um aumento significativo na taxa de acerto (de 67,7% para 77,4% na média geral) utilizando espectrograma e PCA para o treinamento e teste do classificador

considerando todas as classes de movimentos abordados. Já (ZHANG *et al.*, 2014) realizaram um estudo envolvendo diversas combinações de *features* e pré-processamento por PCA para a reprodução de seis classes de movimento em uma mão robótica.

Outra aplicação da técnica consiste não em reduzir o número de entradas para a criação do modelo, mas sim transformá-las usando a projeção realizada pelo PCA e utilizar os valores dos dados – de baixa variância – projetados como entrada do classificador. Este processo é geralmente usado entre os blocos de extração de *features* e o classificador, apresentando uma característica de filtro passa-baixas no sistema. Este tipo de abordagem é utilizado em (LIN & KULIC, 2014) como uma proposta *online* automática para a segmentação do sinal de sEMG e em (MIRANDA DE SÁ *et al.*, 2015) que utilizaram o PCA como filtro para remover ruídos como ECG de um único canal de sEMG. O método também é citado neste contexto na revisão abrangente realizada por (ISON & ARTEMIAIDS, 2014).

Embora amplamente utilizado em diversas aplicações de ML pela capacidade de decompor qualquer matriz e extrair semânticas quanto a fatores mais significativos, o SVD é um método relativamente pouco utilizado individualmente no processamento de sinais de sEMG. (MURAKAMI *et al.*, 2007) utilizaram o método para redução de dimensionalidade em função dos valores singulares relacionados às características para ativações de padrões de EEG em atividades humanas. (ZHANG *et al.*, 2002) utilizaram o SVD e transformada *wavelet* para seleção de *features* e classificação de seis classes de movimentos da mão através de um classificador Neuro-Fuzzy enquanto (CAI *et al.*, 1999) utilizaram a mesma heurística, com uma ANN como classificador, destacando o potencial do SVD para este tipo de aplicação.

3.2 CLASSIFICAÇÃO DO SINAL DE ELETROMIOGRAFIA

Atualmente existem diversas técnicas de *Machine Learning* utilizadas para a classificação dos sinais de sEMG. Entre as técnicas mais proeminentes destacam-se o LDA (ATZORI *et al.*, 2014; ZHANG *et al.*, 2014; CHOWDHURY *et al.*, 2013), Redes Neurais Artificiais (CHOWDHURY *et al.*, 2013; FAVIEIRO *et al.*, 2016), Neuro-Fuzzy (BALBINOT & FAVIEIRO, 2013) e SVM (ISON & ARTEMIADIS, 2014; ROSSI *et al.*, 2015). Métodos de ML não supervisionados como *Independent Component Analysis* (ICA) já foram utilizados para identificar diferentes contribuições musculares para a formação do sinal de sEMG (NAIK *et al.*, 2015). Além disso, é comum encontrar a combinação de métodos como *Principal Component*

Analysis (PCA) e outras técnicas de ML como *k-Nearest Neighbors* (k-NN), Redes Neurais (GEETHANJALI *et. al.*, 2015), SVM ou LDA (RIILLO *et. al.*, 2014). Geralmente, esta combinação de técnicas visa reduzir a dimensionalidade dos dados, utilizando apenas os dados mais representativos para a geração de um modelo de classificação (FAVIEIRO *et. al.*, 2016, CENE *et. al.*, 2015). A Tabela 3 mostra resultados obtidos em relação aos métodos mais comuns e temas de interesse deste trabalho na base de periódicos da CAPES.

Tabela 3 - Trabalhos relacionados na área de processamento de sinais de sEMG.

CLASSIFICADOR	TERMO ASSOCIADO			
	EMG	sEMG	sEMG <i>Upper Limb</i>	sEMG <i>Hand</i>
<i>Support Vector Machines</i> (SVM)	4.753	3.577	134	200
<i>Fuzzy</i>	2.265	334	209	277
<i>Artificial Neural Networks</i> (ANN)	12.887	10.023	187	284
<i>Linear Discriminant Analysis</i> (LDA)	2.911	1.134	196	265
<i>Hidden Markov Models</i> (HMM)	691	109	53	101
<i>Gaussian Mixture Models</i> (GMMs)	853	115	59	101
<i>Logistic Regression</i> (LR)	2.504	146	61	98
<i>k-Nearest-Neighbors</i> (k-NN)	239	46	35	38
<i>Extreme Learning Machines</i> (ELM)	733	332	27	43

Fonte: Periódicos CAPES, julho de 2019 com o filtro “publicações em periódicos revisados por pares” ativada.

Métodos baseados em Redes Neurais, que são a abordagem mais popular na área, têm sido atualizados com novas estratégias como *Convolutional Neural Networks* (ZHAI *et. al.*, 2017) e SLFN (ZHANG & SUNGANTHAN, 2016b). A partir dos últimos desenvolvimentos das SLFN, os métodos *Random Vector Functional-Link* (RVFL) e ELM emergiram como principais soluções para processar dados que podem ser tratados na memória, alcançando soluções ótimas a velocidades muito atrativas devido à sua eficiência computacional e sua abordagem não-iterativa para a formação do modelo (ZHANG & SUNGANTHAN, 2016a).

Nesta Tese, os métodos ELM e RELM foram abordados como SLFN com *kernels Radial-Basis Function* (RBF), que obtém o modelo através de uma matriz pseudoinvertida utilizando Moore-Penrose e *Ridge-Regression*, na forma padrão e regularizada dos classificadores, respectivamente.

A comparação inicial de desempenho dos métodos não iterativos utilizados nesta Tese foi realizada frente a dois métodos tradicionais: a Regressão Logística e ao SVM, ambos regularizados. Tendo em vista que estes métodos mais usuais já são amplamente descritos na

literatura, esta Tese foca na descrição dos métodos não iterativos, sendo que o detalhamento matemático dos métodos de SVM e a Regressão Logística Regularizada (RLR) utilizados como comparação inicial da eficiência do ELM descritos no artigo do APÊNDICE C.

3.2.1 Comparação Entre Trabalhos Utilizando a Base NINAPro

Geralmente, as bases de dados de EMG de acesso aberto apresentam limitações quanto ao pequeno número de movimentos realizados, ao pequeno número de sujeitos, à falta de repetições do ensaio e à diferentes variações dos próprios ensaios. Além disso, esses bancos de dados frequentemente usam metodologias experimentais diferentes que inviabilizam a comparação direta entre diferentes trabalhos na área. A base de dados NINAPro (KUZBORSKIJ *et. al.*, 2012; ATZORI, *et. al.*, 2014; ATZORI, *et. al.*, 2015; PALERMO *et. al.*, 2017) foi criada para compensar algumas dessas limitações oferecendo dados adquiridos de uma grande variedade de indivíduos realizando diferentes movimentos de membros superiores e, mais recentemente, incluindo repetições (PALERMO *et. al.*, 2017). Desde sua publicação, a base NINAPro vem sendo utilizada por diversos grupos de pesquisa. A seguir, são detalhados alguns dos trabalhos utilizando a base e o processamento de sinais de sEMG para a classificação de movimentos. Estes trabalhos utilizam-se de quatro porções diferentes da base de dados: DB1, composta por 52 classes de movimentos realizadas por 27 voluntários, DB2 que é uma expansão de DB1, agora com 40 voluntários realizando as mesmas 52 classes de movimentos e alguns padrões de força que também são realizados em DB3, que é composta por sinais adquiridos de 11 voluntários com amputação trans-radial e DB6, que foca em repetições de ensaios em diferentes dias. As seções DB2 (Exercício B) e DB3 da base NINAPro foram contempladas neste trabalho e são detalhadas na Seção 4.2 desta Tese enquanto a Tabela 4 detalha alguns trabalhos pertinentes que utilizaram a base NINAPro.

Em relação a alguns trabalhos publicados com a base, (ATZORI *et. al.*, 2015) e (KUZBORSKIJ *et. al.*, 2012) realizaram uma série de testes com diferentes *features*, classificadores e tempos de segmentação com janelas deslizantes para a seção DB1 da base relatando taxas de acerto de 76% e 75%, respectivamente, em seus melhores cenários. Aspectos mais interessantes do trabalho de (ATZORI *et. al.*, 2015), relatam a mudança significativa (em 63% dos casos) em relação a execução do movimento e aos potenciais elétricos gerados na medida em que os voluntários repetiam os diferentes movimentos. Os autores também consideraram variações quanto ao tempo de segmentação e características antropomórficas dos voluntários como

altura, peso e gênero, notando que de forma geral, sujeitos mais magros e fortes tendem a prover sinais de sEMG mais descritivos para a classificação. (ATZORI *et. al.*, 2015) ainda verificaram a não variação da taxa de acerto em função das *features* escolhidas, mas sim em função dos tempos de segmentação, que refletem mais positivamente nas taxas de acerto do sistema usando a configuração de 400+10ms de janelas deslizantes. Este fator também foi ressaltado por (KUZBORSKIJ *et. al.*, 2012), além do problema da falta de representatividade do sinal em períodos de transição de movimento. Mais especificamente, (ATZORI *et. al.*, 2015), utilizando-se de seis *features* retiradas dos 12 canais de sEMG atingiram taxas de acerto de aproximadamente 62,0% utilizando o SVM linear e aproximadamente 76,0% utilizando SVM não linear com RBF para os voluntários não amputados. Já para os voluntários amputados a taxa de acerto médio caiu para aproximadamente 46,3% utilizando três *features* provenientes dos 12 canais de sEMG utilizados.

Em (ATZORI *et. al.*, 2014), os autores utilizam-se de classificadores baseados em *k*-NN, SVM, *Random Forests* e LDA juntamente a variações de *features* envolvendo TD e TFD e dados de sensores inerciais em sua apresentação da base. A maior taxa de acerto entre as combinações, onde a segmentação por janelas fixas de 200ms foi realizada, foi obtido através de *Random Forests* e todas as *features*, atingindo 75,32% para a DB1 e 75,27% para a DB2 e SVM em conjunto com todas as *features* para a DB3, atingindo 46,27%. (ZHAI *et. al.*, 2016) utilizaram SVM para a classificação de amostras obtidas através do spectrograma do sinal, que tiveram sua dimensionalidade reduzida pela aplicação de PCA. Com esta técnica, obtiveram de 67,61% para a DB1 e 75,74% para a DB2 da base NINAPro. Já em (ZHAI *et. al.*, 2017), estas mesmas *features* foram classificadas através de uma Rede Neural Convolutacional (CNN) e um método adaptativo. Em seus melhores resultados antes da utilização do método adaptativo, os autores atingiram uma taxa de acerto média de 78,7% que relatam aproximar de 80% para as três bases uma vez que sua classificação adaptativa é utilizada.

Em (GIJSBERTS, 2014) foram analisados 40 movimentos do segmento mão-braço, onde a classificação foi realizada a partir de 4 *features* isoladas e suas variações e 3 diferentes *kernels*. Foi ainda explorada e enfatizada a contribuição de dados provenientes dos sensores inerciais, também componentes da base NINAPro. De fato, foi mostrado que a taxa de acerto aumentou em até 9% quando estes dados foram utilizados em conjunto com os dados de sEMG.

Tabela 4 - Trabalhos relacionados ao processamento de sinais de sEMG com base NINAPro.

AUTOR	MÉTODO	SEGMENT.	FEATURES	MOV.	Nº VOLUNT.	ACERTO (%)
ATZORI et al., 2014	LDA, SVM, <i>k</i> -NN e <i>Random Forests</i>	200ms	RMS, Hidgins TD, Histograma, <i>mDWT</i> e Combinação normalizada de todas <i>features</i>	50 Movimentos (DB1, DB2 e DB3 NINAPro)	27 (DB1), 40 (DB2) e 11 (DB3)	75% (DB1), 75% (DB2) e 46% (DB3) para os melhores casos
KUZBORS KIJ et al., 2012	LDA, SVM (<i>kernel</i> linear e RBF), ANN e <i>k</i> -NN	<i>Janelas-deslizantes</i> (100, 200 e 400ms) + 10ms	MAV, VAR, WL, Histograma <i>Cepstral Coefficient</i> , <i>STFT</i> , <i>mDWT</i>	52 Movimentos (DB1 NINAPro)	27 (DB1)	75%
ATZORI et al., 2015	LDA, SVM (<i>kernel</i> linear e RBF), ANN e <i>k</i> -NN	<i>Janelas-deslizantes</i> (100, 200 e 400ms) + 10ms	MAV, VAR, WL, Histograma <i>Cepstral Coefficient</i> , <i>STFT</i> , <i>mDWT</i>	52 Movimentos (DB1 NINAPro)	27 (DB1)	76%
GIJSBERTS et al., 2014	Classificador Multimodal para Dados de EMG e Sensores Inerciais	<i>Overlap-windows</i> (400+10) ms	RMS, Histograma, <i>mDWT</i> , MAV e combinação	40 dos 52 movimentos da DB2	40 (DB2)	77% para os melhores casos
PALERMO et al., 2017	<i>Random Forests</i>	<i>Janelas-deslizantes</i> (200 + 10) ms	MAV e WL	7 Movimentos distintos repetidos 12 vezes	10 (DB6) com sinais adquiridos ao longo de 5 dias	52% (dados adquiridos no mesmo dia) e 25% (dados adquiridos em dias diferentes)
ZHAI et al., 2016	SVM	<i>Janelas-deslizantes</i> (200 + 100) ms	RMS e Spectrogrma + PCA para redução de dimensionalidade	49 Movimentos (DB2 NINAPro)	40 (DB2)	77% para os melhores casos
ZHAI et al., 2017	SVM, CNN e CNN adaptativo	<i>Janelas-deslizantes</i> (200 + 100) ms	RMS e Spectrogrma + PCA para redução de dimensionalidade	50 Movimentos (DB2 NINAPro)	40 (DB2)	77% (padrão) e 78% (adaptativo)
CENE, 2016c	RLR	<i>timestamp</i>	RMS, Variância e Frequência Mediana (Todas as combinações possíveis)	17 Movimentos (Exercício B, DB2)	50: 40 Não-Amputados, 10 Amputados	Médias de 74,2% e 61,9%. Melhores resultados: 95,2% e 87,1%
SAMADANI, 2018	RNN: LSTM e GRU com variações para a obtenção do modelo	Não descrito	Envelope do sinal de sEMG	17 Movimentos + Repouso (Exercício B, DB2)	35 sujeitos (DB2)	86% para o melhor caso
HE, et al., 2018	Classificador híbrido - LSTM + ANN	400 ms	RMS	52 Movimentos (DB1)	27 (DB1)	75% para o melhor caso

*Alguns trabalhos relatam diferente número de movimentos na DB2 (49, 50, 52) em função de considerar ou não a classe repouso, presente em cada subgrupo como um movimento. Fonte: Elaboração própria.

O trabalho de (PALERMO *et al.*, 2017) explora a seção DB6 da base NINAPro, criada recentemente e focada na análise de classificação de sinais adquiridos em dias diferentes que focam em ações de agarrar diferentes objetos. Baseado em (KUZBORSKIJ *et. al.*, 2012), os autores utilizaram as features de *Mean Amplitude Value* e *Wavelength* (WL) para os testes realizados através de *Random Forests*. Em seu melhor resultado, utilizando a combinação de ambas *features*, os autores relatam uma taxa de acerto médio de 52,43% para os dados derivados do mesmo teste de cada usuário e 25,40% ao misturar dados de diferentes ensaios. Esta diminuição na taxa de acerto é esperada, pois, mesmo para a mesma pessoa, as características do sinal sEMG tendem a variar no tempo, alterando a morfologia do sinal e, conseqüentemente as *features* extraídas.

O trabalho de (CENE, 2016c) utilizou a técnica de Regressão Logística Regularizada (RLR) para a classificação *offline* dos 17 movimentos do Exercício B da base NINAPro e uma base de dados própria gerada a partir dos mesmos movimentos. A classificação foi realizada através da variação total de três *features* e 12 canais de sEMG em 11 diferentes combinações. Com esta abordagem, (CENE, 2016c) realizou um Projeto de Experimentos do Tipo Fatorial Completo a fim avaliar quais fatores afetavam significativamente a taxa de acerto considerando as variações de *features* e canais propostas. A taxa média de acerto utilizando todas as combinações foi de 74,2% para os 40 não amputados e de 61,9% para os amputados. Ao utilizar a melhor combinação, a taxa média de acerto atingida foi de 95,2% para os não amputados e de 87,1% para os amputados.

Abordagens modernas baseadas em Recurrent Neural Networks (RNNs) como a Long Short-Term Memory (LSTM) também têm sido utilizadas no processamento dos sinais de sEMG. De forma geral, a hipótese é de que estes classificadores por sua característica natural de seleção de entradas de uma sequência temporal sejam capazes de mitigar erros causados pela característica não-determinística do sinal de sEMG (SAMADANI, 2018). Em seu trabalho, (SAMADANI, 2018) utiliza a arquitetura do LSTM e do *Gated Recurrent Unit* (GRU) conjuntamente a uma versão simplificada do *Attention Mechanism* para a extração de informação do sinal de sEMG e formação de um classificador mais estável. Os testes foram realizados utilizando 18 movimentos referentes ao Exercício B da porção DB2 da base NINAPro e o envelope do sinal de sEMG. De todos os testes realizados, a melhor taxa de acerto é relatada para a versão Bidirecional do LSTM utilizando o *Attention Mechanism* e uma taxa de aprendizado convergindo em diferentes níveis conforme o número de *epochs* utilizado (BILSTM_AT_LR) capaz de fornecer 86% de taxa de acerto na etapa de validação da rede que não teve o tempo de segmentação descrito (possivelmente

timestamp). Já (HE *et al.*, 2018) utilizam um modelo híbrido de LSTM e ANN visando aproveitar-se de características estocásticas (LSTM) e determinísticas (ANN) do sinal de sEMG e através da segmentação de 400 ms e do RMS do sinal, obtiveram uma taxa média de acerto de 75% para os 27 voluntários da DB1.

3.2.2 Outros Trabalhos Que Utilizam Classificação de Sinais de sEMG

Trabalhos que realizam classificação de sinais de sEMG geralmente apresentam diferenças significativas quanto a metodologia aplicada, incluindo aquisição, número e tipo de movimentos, *features* extraídas do sinal e classificadores utilizados. Desta forma, é difícil conduzir uma comparação quantitativa direta adequada entre trabalhos na área. Um resumo de algumas técnicas utilizadas na literatura e suas diversas abordagens é apresentado na Tabela 5. Já a Tabela 6 apresenta soluções propostas utilizando o ELM como classificador enquanto os trabalhos encontrados em relação a confiabilidade da classificação dos dados se sEMG são descritos no Subcapítulo 3.2.4.

Dos trabalhos citados na Tabela 4, (HAN & JO, 2014) utilizaram somente a amplitude média do sinal proveniente de quatro canais de sEMG como *feature* de entrada em um classificador hierárquico bayesiano para a classificação de sete movimentos distintos. Já (JIANG *et al.*, 2014), questionaram a importância efetiva do desempenho do classificador em relação ao aprendizado do usuário na utilização do sistema e apresentaram em seu estudo resultados de classificação *offline* e *online* para três classificadores (Regressão Linear, ANN e *Non-negative Matrix Factorization*). O resultado do estudo comprovou que na classificação *online* os resultados são praticamente equivalentes, mesmo comparando o classificador de pior desempenho com o melhor, o que indicou uma melhora substancial do sistema realimentado. Este é um aspecto que ainda permanece em aberto na literatura, mas tem mostrado um aumento substancial de pesquisas, focando no controle *online* proporcional de interfaces e na capacidade do usuário se adaptar ao sistema.

Já (FAVIEIRO, 2012) realizou a classificação *online* dos sinais por *Neuro-Fuzzy* para a classificação de 11 movimentos distintos do segmento mão-braço, obtendo uma taxa global de acertos de 65%. A principal contribuição de (FAVIEIRO, 2012) se dá na abordagem *online* de movimentos compostos, que lidam com mais de um grau de liberdade e que são mais dificilmente classificados. Em seu trabalho, (NILSON, 2014) classificou 9 dos 11 movimentos utilizados por (FAVIEIRO, 2012) através da extração *offline* de seis *features* obtidas considerando a variação do

uso dos canais de sEMG proposta. Embora o estudo tenha sido realizado com apenas três voluntários, o trabalho possui sete níveis de repetição de testes, o que confere repetitividade à taxa média de acerto de 91,3% encontrada.

Tabela 5 Trabalhos diversos relacionados a área de processamento de sEMG.

AUTOR	MÉTODO	SEGMENT.	FEATURES	MOV.	Nº VOLUNT.	ACERTO (%)
HAN & JO, 2014	Modelo Hierárquico Bayesiano	Janelas-deslizantes (250-50) ms	MAV	8 (Flexão e Extensão do Pulso, Desvio Ulnar e Radial do Punho, Pronação e Supinação do Antebraço, Fechamento e Abertura da Mão)	7	77% - 84%
JIANG <i>et al.</i> , 2014	Nonnegative Matrix Factorization (NMF), Regressão Linear (RL) e ANN (<i>online</i> e <i>offline</i>)	Sinal contínuo	Envelope do sinal de sEMG filtrado e retificado	Flexão, Extensão e Rotação do Pulso	9	Diferentes métricas envolvendo velocidade e eficiência da execução dos movimentos.
FAVIEIRO, 2012	Neuro-Fuzzy	Adaptativo (baseado em <i>threshold</i>)	RMS	11 Movimentos descritos em (FAVIEIRO, 2012)	7	65%
NILSON, 2014	SVM	<i>timestamp</i>	RMS, MAV, VAR, SD, SKW, KURT (algumas combinações)	9 Movimentos de mão e antebraço	3	91,3%
MA <i>et al.</i> , 2015	NMF adaptativo baseado na sinergia do sinal	(200 + 25) ms	MAV, RMS, MSV, WL, ZC, SS, <i>Log detector</i>	9 Movimentos (repouso, abertura e fechamento da mão e três tipos de supinação e pronação do pulso)	10	Em função do r^2: <i>Offline</i> – 80% (RMS) <i>Online</i> – 97%
KRASOULIS <i>et al.</i> , 2017	LDA multimodal (sEMG e Acelerometria)	(256 + 50) ms	EMG: MAV, WL, AR, LogVar Acelerometria: MAV	40 - Exercícios B e C DB2 NINAPro (<i>offline</i>) 5 padrões de pegada (<i>grasp</i>) e um click no teclado no teste <i>online</i>	13	<i>Offline</i>: 82% (não-amputados) 77% (amputados) <i>Online</i>: 90% (não-amputados) 50% (amputados)
KHUSHA BA <i>et al.</i> , 2014	SVM, LDA, <i>k</i> -NN e ELM	(100 + 25) ms	Pacote de <i>features</i> espectrais	8 movimentos partindo de 5 posições diferentes	11	91% para o melhor caso

Fonte: Elaboração própria.

Em seu trabalho, (MA et. al., 2015) apresentam uma alternativa de controle *online* (método adaptativo) e *offline* (método padrão) utilizando um classificador de NMF e a adequação da sua métrica de sinergia muscular derivada de features baseadas em amplitude no TD. Para a classificação de oito movimentos simples e a classe de repouso, utilizando features extraídas através de janelas deslizantes (200 + 25ms) seus melhores foram de 80% para o método padrão e 97% para o método adaptativo (que vale salientar, é amplamente influenciado pela classe de repouso, dominante neste teste).

Outro trabalho que trata de controle *online* foi realizado por (KRASOULIS et al., 2017) que utilizaram sensores inerciais e sEMG para a classificação de quatro tipos de “pegada” (*grasp*) em objetos diferentes e um posterior acionamento da tecla de espaço em um teclado. Os autores ainda realizaram testes offline contemplando 40 movimentos replicando os Exercícios B e C referentes a DB2 da base NINAPro e investigaram a utilização dos sensores inerciais para a reconstrução do “envelope” do sinal de sEMG.

(KHUSHABA et al., 2014), utilizaram um conjunto de *features* espectrais incluindo momentos, fluxo e correlação espectral para a caracterização de oito movimentos de pulso partindo de cinco posições diferentes do braço dos 11 voluntários no espaço. As features propostas apresentam-se como alternativas interessantes ao uso de sensores inerciais, que compensariam as diferentes ativações musculares decorrentes da influência dos diferentes músculos exigidos para manter o braço em posições específicas. A partir desta abordagem, que foi analisada em quatro classificadores diferentes, incluindo o ELM, os autores relatam a obtenção de 91% de taxa de acerto média para as melhores combinações de *features* e classificadores.

3.2.3 Comparação de trabalhos envolvendo ELM

O ELM tem apresentado um volume crescente de publicações inclusive na área de processamento de sinais de sEMG. Alguns dos principais trabalhos envolvendo o ELM para a classificação de movimentos através de sEMG são apresentados na Tabela 6, além do já citado trabalho de (KHUSHABA et al., 2014).

Em seu trabalho, (ANAM & JUMAILY, 2015a) propuseram um modelo híbrido de ELM utilizando *Spectral Regression* que denominaram SRELM e utilizaram para redução de dimensionalidade e obtenção dos pesos de saída do modelo através de uma projeção de features. Os autores ressaltaram ainda as vantagens em relação à separabilidade das classes comparado ao

seu trabalho anterior, descrito em (ANAM & JUMAILY, 2015b), onde utilizaram o *SRDA* e *Particle Swarm Optimization* (PSO) para a otimização dos *kernels* utilizados no ELM (*SRDA-ELM*), onde *kernels* não lineares apresentam maior taxa de acerto. Os autores também utilizam *Major-Voting* (MV) como método de pós-processamento.

Já em (ANAM & JUMAILY, 2017), os autores apresentaram um método para a classificação de movimentos de dedos em 9 sujeitos não amputados e 5 amputados em uma análise *offline*. Ao todo 13 *features* são extraídas de cada um dos 12 canais formados pelos eletrodos posicionados em músculos específicos. A dimensionalidade das *features* é posteriormente reduzida através de métodos como LDA, SRDA e *Orthogonal Fuzzy Neighbour Discriminant Analysis* (OFNDA) e há ainda um pós-processamento realizado por *Major-Voting*. O *kernel* gaussiano usado ofereceu a maior taxa de acerto. Todos os resultados obtidos no trabalho de (ANAM & JUMAILY, 2016) foram atingindo através do descarte de amostras em períodos de transição dos movimentos, que são justamente as porções mais dificilmente classificadas corretamente e que, em um cenário prático, atrasam a ativação da prótese quando descartadas.

Em seu trabalho, (XIAO *et.al.*, 2014), descreveram o uso de um arranjo de oito *Force Sensing Resistors* em um ELM básico. O ELM executou o controle *online* de uma mão robótica para duas e quatro classes de movimentos e repouso, atingindo 98% e 96% de taxa de acerto, respectivamente. Já (LEE *et.al.*, 2011) mostraram em seu artigo o potencial experimental do ELM caracterizado por sua capacidade de generalização utilizando somente 80 neurônios na camada *hidden* e um tempo de treinamento relatado de 50 segundos para o controle de uma mão robótica à distância através de protocolo TCP/IP. O trabalho utiliza oito eletrodos e redução de dimensionalidade através de PCA.

Em seu artigo, (SHI *et.al.*, 2013) apresentaram uma nova *feature* extraída do sinal de sEMG. (SHI *et.al.*, 2013) compararam sua *Cumulative Residual Entropy* (CREn) com três outras *features* baseadas em entropia e também *features* no domínio tempo. Das *features* apresentadas no artigo, a CREn apresentou melhor separação entre classes para diferentes tamanhos de janela de segmentação. (SHI *et.al.*, 2013) ainda relatam as vantagens do ponto de vista complexidade computacional de sua *feature* proposta em relação às demais. Em relação a sua taxa de acerto no reconhecimento dos movimentos realizados, a combinação ELM + CREn demonstra desempenho superior ou igual às outras combinações, variando de ~95% à ~97%, dependendo do tamanho de janela utilizado.

Tabela 6 - Trabalhos relacionados na área de processamento de sEMG utilizando ELM.

AUTOR	MÉTODO	SEGMENT.	FEATURES	MOV.	Nº VOLUNT.	ACERTO (%)
ANAM & AL-JUMAILY, 2015a	(SRELM)	Janela fixa (100ms)	ZC, SSC, Hjorth TD e AR	10 combinações de movimentos de dedos	8	95,6% de melhor resultado para 5 movimentos
ANAM & AL-JUMAILY, 2015b	(SRDA-ELM e <i>Major-Voting</i>)	Janela fixa (100ms)	MAV, ZC, SSC, Hjorth TD e AR	10 combinações de movimentos de dedos	8	90% ~ 94%
ANAM & AL-JUMAILY, 2017	Diversos métodos e <i>Major-Voting</i>	<i>Janelas-deslizantes</i> (200+25) ms	MAV, ZC, SSC, Hjorth TD (HTD), SKW, MAVS (MAV-SKW), RMS e AR	15 combinações de movimentos de dedos	9 não-amputados e 5 amputados	98% para os amputados e 99% para não amputados nos melhores resultados
XIAO <i>et. al.</i> , 2014	ELM	Sinal contínuo	-	2 (binário no protocolo 1; controle de intensidade no 2)	1 voluntário: (2 protocolos)	98% para o (protocolo 1) e 96% para o (protocolo 2)
LEE <i>et. al.</i> , 2011	ELM + AC-PCA (<i>Augment-Class PCA</i>)	Não comentado	RMS	4 movimentos de mão para o acionamento de mão robótica	1	Não quantitativo
SHI <i>et. al.</i> , 2013	ELM LDA SVM	200ms, 250ms, 1s	<i>Cumulative Residual Entropy (CREn), Fuzzy Entropy, Sample Entropy, Approximate Entropy</i>	6 (Abertura e Fechamento da Mão, Flexão e Extensão do Pulso, Desvio Ulnar e Radial do Punho)	10	94% ~ 97% (ELM) 95% ~ 97% (SVM) 93% ~ 94% (LDA)
CAO <i>et. al.</i> , 2015	SVM, ELM, <i>Multiple Nonlinear Regression (MNLR)</i>	Sinal RMS normalizado pelo movimento inteiro (~10s)	RMS + Giroscopia	1 (aperto no dinamômetro)	10	RMSE: SVM (0,8), ELM (1,1), MNLR (3,3) Correlação: SVM (0,99), ELM (0,99), MNLR (0,93)
FREITAS <i>et. al.</i> , 2019	ELM	150 ms	SSC, ZC, WL, HTD, SKW	10 classes de movimentos de dedos	8	85% para o melhor caso
CENE & BALBINOT, 2018b	ELM	(300+15) ms	RMS, VAR, MAV, SD	6 movimentos de dedos + repouso	4	97% para o melhor caso
CENE & BALBINOT, 2019b	ELM, RVFL, SVM, RL	Timestamp & (300+10) ms	Variações de feats. (RMS, VAR, MAV, SD, ZC) e canais	17 (DB2, DB3 NINAPro)	20	DB2: 77,2%, DB3: 55,3%, (Raspberry)
CENE & BALBINOT, 2018a	Reliable-ELM	(200+10) ms	RMS, VAR, MAV, SD, DES	18 (DB2, DB3 NINAPro) e base própria (IEE)	60	DB2: 82%, DB3: 60%, IEE: 99%

Fonte: Elaboração própria.

Já (CAO *et.al.*, 2015) usaram sensores inercias e o valor de RMS extraído de seis canais de sEMG posicionados em músculos específicos para realizar uma estimativa da força aplicada pelos sujeitos em um movimento de “fechamento de mão” em torno de um dinamômetro comercial (WCS-1000, *The Shanghai Wanqing Electron Co., Ltd.*). O dinamômetro comercial foi utilizado como instrumento de referência e as métricas do sistema foram as saídas dos classificadores na estimação de força e a correlação do valor estimado com o fornecido pelo dinamômetro. Os autores comentaram que apesar do SVM ter se mostrado levemente mais preciso, o ELM foi muito mais rápido, justificando o seu uso. As saídas dos métodos encontram-se na Tabela 5 descritas pelo RMSE obtido na estimação de força e na correlação encontrada.

A fim de verificar a praticidade do ELM para controle de dispositivos auxiliares, (FREITAS, *et. al.*, 2019) coletaram dados de oito voluntários que tiveram sinais adquiridos por dois canais sEMG. Destes sinais foram extraídas sete *features* para a classificação realizada em uma plataforma embarcada híbrida capaz de oferecer uma taxa de acerto máxima de 86% considerando a maior taxa de acerto dentre as variações no número de *Hidden Neurons* realizadas.

Ainda com relação a plataformas embarcadas, (CENE *et. al.*, 2018b) apresentam a utilização do ELM em um *Raspberry Pi* para a classificação de seis movimentos distintos de dedos acrescidos de uma classe de repouso. Através de um filtro estocástico simples e da extração de *features* no TD utilizando janelas deslizantes de $(300 + 15)$ ms, foram capazes de provar a viabilidade desta abordagem, obtendo uma taxa de acerto máxima de 97%. Similarmente, CENE & BALBINOT também utilizam as bases NINAPro DB2 e DB3 com um *Raspberry Pi* e em um PC utilizando segmentações por *timestamp* e janelas deslizantes $(300 + 10)$ ms em seu outro artigo mais recente (CENE & BALBINOT, 2019b). Neste artigo ainda realizam uma abrangente revisão sobre os métodos de ELM e *Random Vector Functional-Link* (RVFL) em suas formas padronizadas e regularizadas, comparando o seu desempenho a técnicas mais tradicionais como SVM e Regressão Logística. Adicionalmente, os autores também exploraram diversas combinações de canais e *features*, onde ressaltam a eficiência do ELM por praticidade computacional e taxas de acerto obtidas que foram de 94,4% e 76,3% para as bases DB2 e DB3, respectivamente, utilizando a segmentação por *timestamp* no PC e 77,2% e 55% para as mesmas bases com o *Raspberry Pi* e a segmentação por janelas deslizantes.

Já em (CENE & BALBINOT, 2018a), o conceito da confiabilidade utilizando o ELM é apresentado juntamente a *feature* de *Differential Enhanced Signal* desenvolvida para aumentar a

representatividade do sinal de sEMG em períodos de transição de movimentos, admitidamente os segmentos de sinal mais difíceis de serem classificados. Através da *feature* proposta e de pós-processamentos do sinal envolvendo o descarte autônomo de amostras não representativas, o método foi testado nas bases DB2 (não amputados) e DB3 (amputados) da base NINAPro e também em uma base própria gerada pelos dos autores (base IEE). As taxas de acerto médio para cada uma das bases de dados foram de 82%, 60% e 99% para as bases DB2, DB3 e IEE, respectivamente.

3.2.4 Trabalhos Relacionados a Classificação Confiável de Sinais de sEMG

O modelo de resolução do sistema apoiado pela matriz T como realizado no ELM - como explicado no Subcapítulo 2.3.6 - oferece uma alternativa interessante de modo a possibilitar a avaliação de erro para classe rotulada em cada amostra. Observando o maior valor obtido entre todas as classes – e que rotula a amostra – no vetor de saída, é possível avaliar se ele é suficientemente divergente das demais classes de forma a avaliar a classificação obtida. Por essa lógica, uma classificação desejável acontece quando uma amostra n pertencente à classe genérica C , exerce influência o suficiente no sistema para oferecer um valor de saída muito alto para a posição correta do vetor de saída formado por $T_{C,n}$ em relação às demais amostras. Através deste tipo de abordagem, é possível definir uma métrica de “confiabilidade da classificação”. Apesar desta métrica promissora, este tipo de abordagem ainda é pouco explorado em classificadores para sinais de sEMG. Trabalhos que consideram este tipo de métrica basicamente se resumem aos trabalhos de (SCHEME *et. al.*, 2013), (AMSUSS *et. al.*, 2014), (BETTHAUSER *et. al.*, 2018), (PAN *et. al.*, 2018), (ROBERTSON *et. al.*, 2018a), (ROBERTSON *et. al.*, 2018b).

Em seu trabalho, (SCHEME *et. al.*, 2013) desenvolveram um classificador baseado em LDA que é capaz de “negar movimentos”, quando estes são desenvolvidos com um baixo grau de confiabilidade baseado em *thresholds* individuais para cada classe calculados através da Lei de Fitts. Já (AMSUSS *et. al.*, 2014), utilizaram uma Rede Neural na saída de um LDA e consideraram a separação entre classes de saída e o nível de atividade muscular para inferir a confiabilidade da classificação realizada. Em seu trabalho, (AMSUSS *et. al.*, 2014) testaram uma série de ações a serem tomadas em substituição a uma classificação que não forneça uma separação desejada (definida por *threshold*) entre classes. As ações tomadas pelos autores consistiram em manter a classe anterior, utilizar *Major-Voting* retroativos e diferentes manipulações nos valores de saída e

nos hiperparâmetros do modelo atingindo resultados próximos a 100% para as oito classes de movimentos propostas em seus melhores resultados.

(BETTHAUSER *et. al.*, 2018) utilizam a estrutura do ELM para definir uma métrica de qualidade para as classificações realizadas. Uma vez detectada uma classificação abaixo de um *threshold* previamente definido, uma segunda representação do modelo do sinal baseada em *Sparse Representations* é utilizada para a correção do modelo visando manter a consistência das classificações frente as características não-determinísticas do sinal. Para a classificação de quatro classes de movimento de pulso e repouso, *features* em tempo e frequência e componentes auto regressivos foram extraídos de janelas deslizantes de $(200 + 50)$ ms provenientes de cada um dos oito canais de sEMG utilizados para os 10 voluntários, sendo dois deles, amputados. Os autores comparam seu método frente a outros métodos tipicamente utilizados como LDA, SVM e ANN. Para as tarefas online foram relatadas vantagens quanto a velocidade de realização das tarefas propostas e a taxa de acerto global, aproximadamente 14% maior (85% no total) do que a do LDA. Já nos testes *offline*, para os melhores resultados foram relatados ganhos de aproximadamente 6% em relação a taxa de acerto.

Em (PAN *et. al.*, 2018), quatro canais de sEMG foram utilizados para a extração da MAV através de uma segmentação de $(100 + 20)$ ms acrescido de um filtro e normalização do sinal. Esta *feature* do sinal foi utilizada para verificar a robustez multiusuário do modelo em relação a quatro movimentos envolvendo a flexão e extensão das falanges metacarpianas e pulso de quatro voluntários segurando três níveis de cargas diferentes (0, 1,25 e 2,5 libras). As métricas de avaliação do seu sistema *online* foram derivadas de testes com uma interface visual em *Matlab* controlada por um modelo muscular proposto onde o tempo para completar a tarefa, o número de *overshoots* (extrapolação dos limites do modelo) e a eficiência do controle (caminho) realizado foram considerados. Apesar de não utilizar uma abordagem explícita tradicional de processamento e classificação de dados, mas sim o controle proporcional através do modelo muscular virtual, os autores foram capazes de estabelecer uma interface confiável para os diferentes voluntários e condições analisadas no estudo.

(ROBERTSON *et. al.*, 2018a) realizaram a avaliação de como o descarte de classificações errôneas utilizadas para o controle em tempo real de um sistema de sEMG para o reconhecimento de abertura e fechamento de mão e pronação e supinação de pulso. Sete limiares diferentes foram utilizados conjuntamente a um classificador baseado em SVM para avaliar erros sistêmicos (do

classificador) e três erros específicos relacionados a usuários. Seu estudo concluiu que o aumento do limiar é capaz de reduzir substancialmente a taxa de erros sistêmicos e, em menor proporção, também a taxa de erros de usuários. Os autores, porém, fazem a ressalva de que utilizar fatores excessivamente restritivos causam um nível consideravelmente maior de rejeições (inclusive de controles corretos), que podem prejudicar a controlabilidade do sistema (que não foi avaliada no trabalho). Métricas de usabilidade foram incorporadas no trabalho subsequente dos autores, que em (ROBERTSON *et al.*, 2018b) exploram algumas métricas relacionadas a Lei de Fitts para os 24 usuários de seu sistema. Apesar das métricas de usabilidade apresentarem melhores indicadores quando os limiares de corte de amostras foram mais altos, também foi observada uma maior dificuldade por parte dos usuários. A partir disto, os autores concluem que há uma relação não muito bem definida ainda entre a usabilidade do dispositivo e as taxas de acerto e que isto ocorre não só em sistemas *offline* como também em sistemas *online*. Assim como em seu trabalho anterior, não foram observadas variações significativas nos resultados entre usuários experientes e não-experientes para este tipo de controle. De forma geral, embora alternativas envolvendo métricas de confiabilidade tenham começado a ser divulgadas com mais frequência recentemente, esta abordagem ainda se encontra muito incipiente na literatura, oportunizando a exploração desta métrica juntamente a alternativas mais tradicionais formando soluções bem recebidas na comunidade científica da área.

Em (CENE *et al.*, 2019a), os autores utilizam a denominada versão confiável do seu classificador baseado em ELM para o processamento abrangente de diversos exercícios e bases NINAPro envolvendo diferentes movimentos, números de repetições e voluntários. Adicionalmente os autores apresentam a base IEE, que baseada no Exercício 2 da base NINAPro, junta 17 movimentos distintos do segmento mão-braço. Os autores ainda ponderam sobre a importância da análise utilizando as métricas de taxa de acerto global e ponderada em paralelo buscando anular o *bias* inserido pela classe repouso na taxa de acerto. As taxas de acerto global foram de 99% para a base IEE e 75,1%, 79,77% e 69,83% para as bases DB1, DB2 e DB6 do NINAPro, respectivamente. Como ponto principal do trabalho os autores validam suas técnicas e base de dados realizando testes e atingindo resultados compatíveis ou superiores com o estado da arte.

Já em (CENE *et al.*, 2019c), os autores apresentam a versão de seu classificador ELM de *arg max* suavizado. Nesta técnica, os valores de *arg max* utilizados para a classificação das

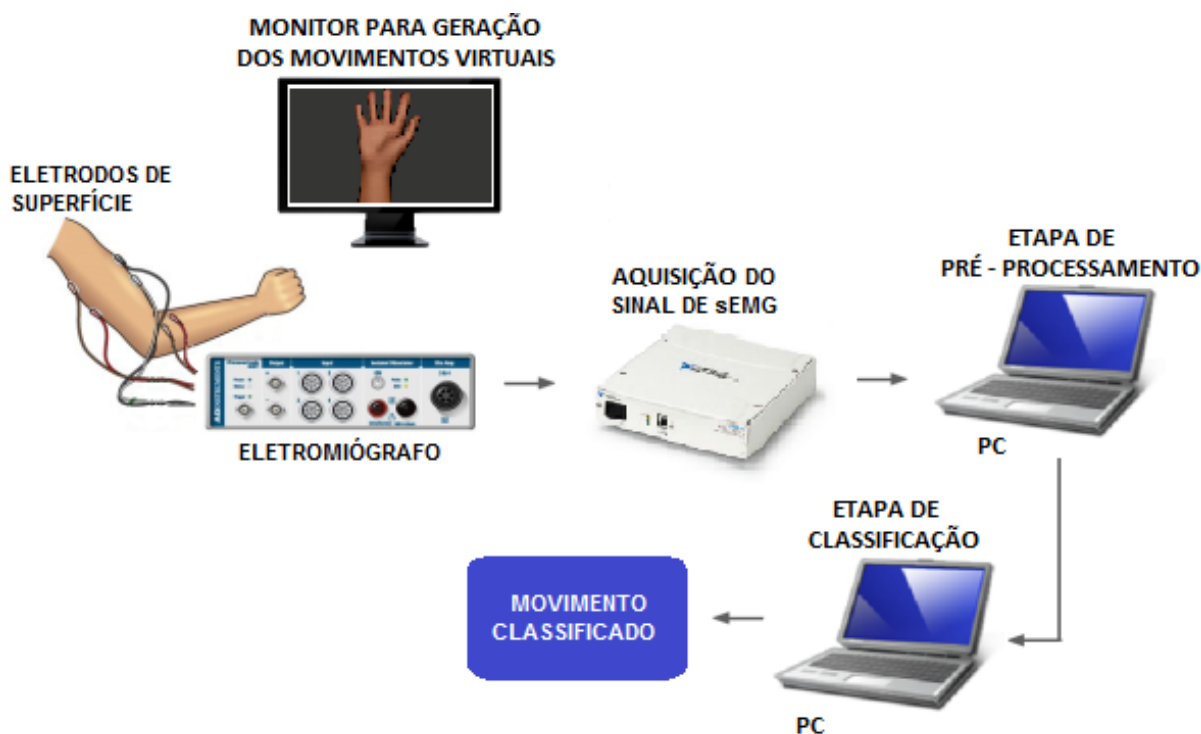
amostras testadas passa por uma etapa de pós-processamento onde é filtrado, eliminando o ruído desta métrica para a classificação. A motivação é a geração de um reconhecimento de padrões mais robusto a ruídos de classificação, que são fortemente característicos do sinal de sEMG. Os filtros utilizados consistem em um filtro AVT e um filtro exponencial simples. O Exercício B da base IEE é utilizado para a validação da técnica, que apresentou taxas de acerto médias global e ponderada de 96,0% e 82% considerando os 12 ensaios que compõe esta seção da base de dados.

Uma vez que os classificadores baseados em ELM apresentaram melhores taxas de acerto para os testes conduzidos (CENE *et al.*, 2019a; CENE & BALBINOT, 2019b), o método foi escolhido como base para os desenvolvimentos realizados nesta Tese. Alguns dos testes preliminares são detalhados nos artigos em APÊNDICE (APÊNDICE C; APÊNDICE D e APÊNDICE E) e em algumas seções dos próximos capítulos, referentes as etapas de Metodologia e Resultados deste trabalho.

4 METODOLOGIA EXPERIMENTAL

A Figura 7 apresenta o arranjo experimental utilizado para a aquisição da base de dados realizada em laboratório, denominada IEE. Esta base de dados é a mesma utilizada em (CENE, 2016c; CENE & BALBINOT, 2018a; CENE *et. al.*, 2018b; CENE *et. al.*, 2019a; CENE *et. al.*, 2019c). Na Figura 7 são expostos os principais blocos do sistema utilizados na aquisição da base e classificação do sinal que são explicados detalhadamente ao longo deste capítulo.

Figura 7 - Diagrama de blocos principal do sistema experimental proposto.



Fonte: Elaboração própria.

A metodologia experimental pode ser dividida em duas abordagens quanto a segmentação dos dados: a) *timestamp*, onde a duração total do movimento realizado foi utilizada como janela para a extração das *features* e que foi utilizado na caracterização inicial do ELM frente a outros classificadores comumente utilizados na área (CENE & BALBINOT, 2019b); e b) janelas deslizantes de três tamanhos diferentes, como explorado no trabalho de (KUZBORSKIJ, et al., 2012). Buscando otimizar o espaço dedicado à discussões científicas mais interessantes e pertinentes, a parte do trabalho referente a segmentação por *timestamp* e seus métodos e resultados é exclusivamente apresentada como material complementar deste texto e encontra-se no APÊNDICE C. Desta forma, as metodologias e resultados apresentados no corpo principal desta

Tese derivam da segmentação por janelas-deslizantes, para as quais, após análise preliminar apresentada no Subcapítulo 5.1, foram escolhidos como parâmetros o tamanho de 400ms e sobreposição de 390ms em função da taxa de acerto oferecida nas versões padrão dos classificadores. É importante ressaltar que o estudo envolveu duas bases de dados. Quando os dados utilizados provêm da base de dados NINAPro (ATZORI, 2012), o sistema se resume as etapas de pré-processamento e de classificação do sinal, tendo em vista que as primeiras etapas já foram realizadas pela equipe que disponibiliza o banco de dados. Para os sinais de sEMG adquiridos no Laboratório IEE, o sistema é implementado em sua plenitude. De forma geral, o sistema para a aquisição de sinais de sEMG é constituído pelos seguintes blocos:


- um monitor posicionado em frente ao sujeito: permitindo que o sujeito acompanhe os movimentos realizados pelo braço virtual (nas etapas de treino e de aquisição de dados) replicando os movimentos mostrados neste monitor;
- dois eletromiógrafos comerciais, formando 12 canais para a captação dos sinais de sEMG através de eletrodos de superfície: 4 canais referentes ao posicionamento de eletrodos em músculos específicos e 8 canais referentes ao posicionamento dos eletrodos aleatoriamente distribuídos ao redor do braço direito de cada sujeito, para a captação do sinal mioelétrico durante a execução dos movimentos;
- uma plataforma dedicada à aquisição e digitalização dos dados, composta por uma placa de aquisição (NI USB-6289) da *National Instruments* conectada a um computador rodando o software *LabVIEW*® com a correspondente configuração dos parâmetros para a aquisição do sinal de sEMG;
- a etapa de pré-processamento: responsável pela filtragem, segmentação e extração das *features* usadas como entradas do classificador;
- a etapa de classificação: onde foram aplicados os algoritmos de Inteligência Computacional para a classificação dos movimentos através da entrada composta pelas *features* do sinal escolhidas para servir de entrada aos métodos.

4.1 AQUISIÇÃO DE DADOS DA BASE DO LABORATÓRIO IEE¹

4.1.1 Eletromiógrafo e Eletrodos

Eletromiógrafo (EMG) é o equipamento que faz uso de eletrodos para captar sinais mioelétricos. O eletromiógrafo utilizado nesse trabalho para a aquisição do sinal mioelétrico foi o 830-C da *EMG System do Brasil*. Neste trabalho, foi realizada a combinação de dois eletromiógrafos comerciais de oito canais conectados em paralelo. Utilizando oito canais do primeiro EMG e quatro canais do segundo EMG, foi possível montar uma plataforma capaz de capturar doze canais de sEMG. A captação do sinal é realizada através de eletrodos bipolares de configuração passiva (SOLIDOR, MSGST-06) e o arranjo experimental utilizado é mostrado na foto da Figura 8.

Figura 8 - Foto Arranjo experimental utilizado na aquisição dos sinais: (1) monitor para a visualização dos movimentos; (2) arranjo dos dois eletromiógrafos utilizados; (3a, 3b e 3c) Cabos do eletromiógrafo: (a) 4 canais para posicionamento específico, (b) 8 canais para posicionamento aleatório e (c) eletrodos de referência; (4) eletrodos de superfície utilizados; (5) placa digitalizadora; (6) borneira e (7) computador utilizado para a aquisição dos sinais rodando LabVIEW[®] 2009.



Fonte: Elaboração própria.

A faixa do sinal de sEMG de interesse é compreendida entre 20 e 450 Hz em frequência e de 0 a 10mV em amplitude. Para realizar um condicionamento analógico e um primeiro tratamento

¹ Atualmente a base de dados IEE está sendo expandida de forma contemplar a participação de mais voluntários. A base em sua forma atual e alguns métodos de processamento, encontram-se disponíveis para download no site do IEE (https://www.ufrgs.br/ieelab/IEE_sEMG_db.php) e já são matéria de um artigo publicado específico apresentado no APÊNDICE C.

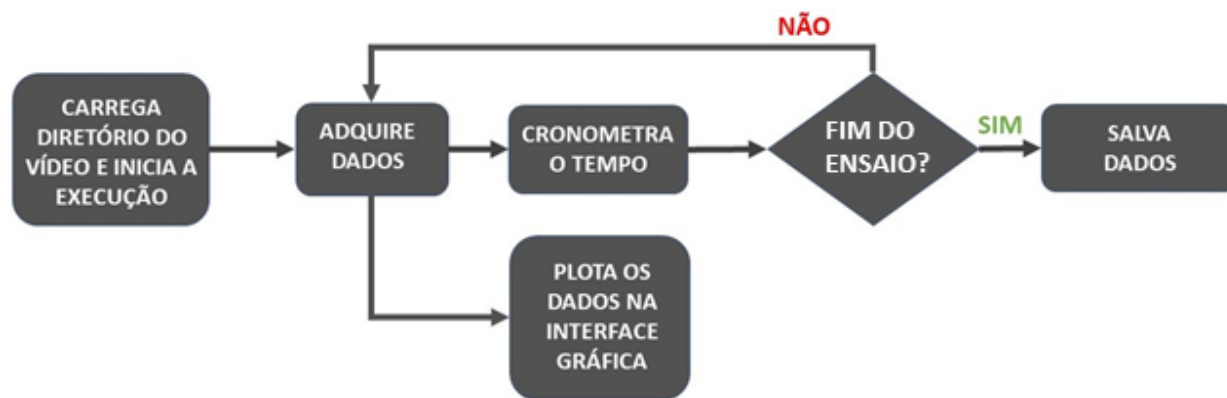
do sinal, os eletromiógrafos comerciais utilizados possuem um filtro passa-banda de quarta ordem com banda passante na frequência de interesse e um ganho combinado total de 2000 vezes.

Para a aquisição e digitalização dos dados foi selecionada uma placa da *National Instruments* NI USB-6289 que possui 32 entradas analógicas e opera com 18 bits de quantização a um limite de 625 kS/s de digitalização. Para o presente trabalho, foi definida a frequência de amostragem de 2 kHz, a fim de manter o mesmo padrão da base NINAPro que também é utilizada neste trabalho. Através destas configurações, foi construída a base IEE.

4.1.2 Modelo Virtual

Para a padronização dos ensaios, foi criado um modelo virtual de cada movimento mostrado a cada voluntário que deve replicá-lo tão natural e similarmente quanto possível. O *timestamp* de cada ensaio é salvo e utilizado posteriormente na rotulação das classes. Para o desenvolvimento do modelo virtual foram utilizados os softwares MakeHuman 1.0.2 e Blender 2.75a, sendo a criação dos movimentos virtuais detalhada no trabalho de (FAVIEIRO, 2012). Para apresentar as animações criadas para o usuário do sistema, a rotina apresentada na Figura 9 foi desenvolvida no LabVIEW® de forma a realizar a leitura dos arquivos de animação gerados no Blender. Ao total, dois vídeos com diferentes números de repetições de movimentos foram gerados assim como um vídeo para cada movimento individual.

Figura 9 - Fluxograma da rotina de visualização das animações e aquisição de dados (Fonte: autor).



Fonte: Elaboração própria.

4.1.3 Procedimentos Para a Realização dos Ensaios de Aquisição de Dados

A primeira etapa ao se realizar ensaios com seres humanos consiste na apresentação e explicação de um Termo de Livre Consentimento que relata o experimento e os potenciais riscos


aos quais os voluntários ficam submetidos caso aceitem participar dos ensaios. O termo de consentimento padrão é ilustrado no APÊNDICE A. A seguir, é realizada uma breve anamnese, para se ter conhecimento de algumas características relevantes de cada voluntário. A anamnese utilizada encontra-se no APÊNDICE B. Este trabalho faz parte do projeto aprovado pelo Comitê de Ética CAAE: 11253312.8.0000.5347.

A metodologia de fixação de eletrodos consiste basicamente em: a) limpar a pele e depilar a região de interesse; b) fixar os eletrodos na parte ventral dos músculos de forma que os cabos não restrinjam os movimentos e não se movimentem, principalmente, próximo aos eletrodos (o que gera ruído). Dos 12 pares de eletrodos utilizados, oito foram posicionados em um arranjo equidistante a 3cm da junta rádio-umeral do voluntário. Os quatro pares de eletrodos restantes, foram posicionados sobre os seguintes músculos específicos: Extensor dos dedos (canal 9); Flexor profundo dos dedos (canal 10); Bíceps (canal 11) e Tríceps (canal 12). A Figura 10 ilustra o posicionamento dos eletrodos.

O processo de aquisição é iniciado a partir do início do vídeo do primeiro movimento, que assim como os subsequentes, é replicado simultaneamente pelo usuário que acompanha os movimentos exibidos no monitor auxiliar específico. É importante ressaltar que neste trabalho não foi realizado o monitoramento da força aplicada pelo voluntário e nem usado qualquer procedimento de realimentação. Para o ENSAIO A, seguiu-se as diretrizes do Exercício B da base NINAPro (ATZORI, 2012), onde cada ensaio consiste em uma sessão de 102 movimentos composta por seis repetições sequenciais dos 17 movimentos diferentes (5s cada) intercalados por períodos de repouso (3s cada). Entretanto, como na base IEE um vídeo auxiliar para preparação de execução de movimento foi utilizado, o tempo de repouso foi de 9s. O mesmo foi realizado para o ENSAIO B onde 10 repetições de cada movimento foram realizadas. Os ENSAIOS C e D variam, além da ordem dos movimentos, o período de repouso, que foi estendido para 11s, sendo acrescido 1s antes e 1s depois de cada chamada do vídeo de preparação. Até o momento da escrita desta Tese, quatro voluntários com características detalhadas na Tabela 7 realizaram três repetições de cada uma das quatro variações de exercício. Consequentemente, um total de 48 ensaios diferentes foram gerados e encontram-se disponíveis para download na página web do Laboratório IEE (https://www.ufrgs.br/ieelab/IEE_sEMG_db.php) juntamente a alguns métodos de pré-processamento. A base se encontra em franca expansão de forma que mais ensaios estão sendo

realizados e em seu estado atual juntamente a alguns métodos, encontra-se publicada no artigo *Open-Access* do APÊNDICE D.


Figura 10 - Posicionamento dos eletrodos no braço de cada voluntário.



Fonte: Elaboração própria.

Embora o ensaio para aquisição de dados dure em média 25 minutos, somando-se os tempos de preparação do voluntário e a montagem do aparato experimental, este tempo aproxima-se em média de uma hora de duração. A Figura 11 ilustra a realização de um dos ensaios.

Figura 11 - Foto da realização de um dos ensaios.



Fonte: Elaboração própria.

4.2 DESCRIÇÃO DA BASE DE DADOS NINAPRO

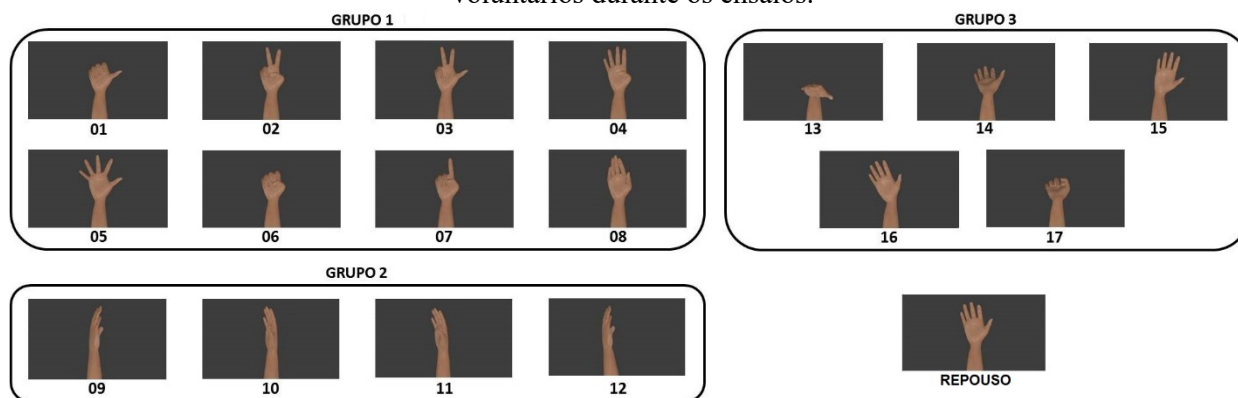
Na base de dados NINAPro, a atividade muscular foi adquirida através de um arranjo de 12 eletrodos de sEMG *wireless* não invasivos. Cada um dos eletrodos é equipado com uma bateria recarregável e possui um alcance de 40m em sua área de cobertura. Os dados foram digitalizados através da plataforma NI-DAQ PCMCIA 6024E da *National Instruments* a uma taxa de 2 kHz e 12 bits, com um ruído relatado de 750nV (ATZORI, 2014). As seções da base NINAPro utilizadas nesta Tese consistem do Exercício B das bases II e III, compostas respectivamente de dados adquiridos de voluntários não-amputados e amputados que realizaram os mesmos movimentos da base IEE detalhados no Subcapítulo 4.3.

4.3 MOVIMENTOS REALIZADOS NOS ENSAIOS

Os movimentos do segmento mão-braço executados durante os ensaios são ilustrados na Figura 12 e dividem-se em três grupos onde: a) o grupo 1 consiste em movimentos de dedos (polegar para cima (1), extensão do dedo médio e indicador com flexão dos outros dedos (2), flexão dos dedos anular e mínimo com extensão dos demais (3), flexão do polegar (4), adução dos dedos (5), fechamento da mão (6), ação de apontar (7) e adução de dedos estendidos (8)); b) o grupo 2 reúne movimentos de torção com diferentes eixos (supinação do pulso com eixo no dedo médio

(9), pronação do pulso com eixo no dedo médio (10), supinação do pulso com eixo no dedo mínimo (11) e pronação do pulso com eixo no dedo mínimo (12)); c) o grupo 3 reúne movimentos de pulso (flexão do pulso (13), extensão do pulso (14), desvio radial do pulso (15), desvio do ulnar do pulso (16) e extensão do pulso com a mão fechada (17)).

Figura 12 - Vídeos representando os movimentos do segmento mão-braço que são repetidos pelos voluntários durante os ensaios.



Fonte: Elaboração própria.

4.4 PROCESSAMENTO DOS BIOSINAIS

É importante ressaltar que as seções que contém o Exercício B da base de dados NINAPro possuem um total de 51 voluntários (40 não amputados e 11 amputados). A classificação dos dados segmentados por *timestamp* constituiu uma prova de conceito preliminar dos métodos de classificação utilizados neste trabalho utilizando 10 voluntários não amputados e 10 amputados do Exercício B das seções DB2 e DB3 da base NINAPRO. Buscando otimizar o espaço dedicado à discussões científicas mais interessantes e pertinentes, a parte do trabalho referente a segmentação por *timestamp* e seus métodos e resultados é exclusivamente apresentada como material complementar deste texto e encontra-se no APÊNDICE C.

Já para a classificação por janelas deslizantes, que constitui uma avaliação mais importante quanto aos desenvolvimentos futuros desta área pelo Grupo de Pesquisadores do Laboratório IEE, dados de todos os voluntários da base NINAPro nas suas seções DB2 e DB3 referentes ao Exercício B foram utilizados, além de 48 ensaios da base IEE em suas quatro variações de exercícios. A Tabela 7 descreve os dados das bases de dados utilizados nesta Tese, incluindo as quatro variações de ensaios para a base IEE, que diferem quanto ao número e ordem das repetições de movimentos realizados. A coluna “Tempo de Estímulo” refere-se aos períodos de movimento

ativo (execução) e repouso (preparação), onde para a base IEE o período de preparação inclui o tempo de visualização do próximo movimento a ser realizado de forma a mitigar erros de execução por parte do voluntário.

Tabela 7 - Variação dos ensaios componentes das diferentes bases de dados consideradas nesta Tese.

BASE	ENSAIO	ORDEM	NÚMERO DE VOLUNT.	NÚMERO DE REPETIÇÕES DE MOVIMENTOS	TEMPO DO ESTÍMULO (s)	
					PREPARO	EXECUÇÃO
Não amputados (NAMP)	B	Sequencial	40	6	3	5
Amputados (AMP)	B	Sequencial	11	6	3	5
IEE (4 Exercícios)	A	Sequencial	4	6	9	5
	B	Sequencial	4	10	9	5
	C	Aleatória	4	6	11	5
	D	Aleatória	4	10	11	5

Fonte: Elaboração própria.

Uma vez adquiridos, os sinais passam pelas etapas de processamento onde são realizadas as diversas operações de pré-processamento, extração de *features* e posteriormente a classificação dos dados. Todos os algoritmos de processamento foram desenvolvidos utilizando o MATLAB 2019a® (MathWorks). Cada um dos blocos principais dos programas desenvolvidos para a realização deste trabalho é detalhado nos próximos subcapítulos.


4.4.1 Pré-processamento

Genericamente, o pré-processamento contempla as etapas de filtragem digital, retificação e normalização de cada canal de sEMG, assim como a extração de *features*, as quais são utilizadas como variáveis de entrada dos classificadores.

4.4.2 Retificação e normalização do sinal

Considerando que a utilização de dados de entrada com uma menor faixa de entrada de excursão age como um filtro passa-baixas digital, favorecendo o desempenho do classificador, o sinal é retificado e normalizado antes que as características sejam extraídas. Os efeitos desta etapa de processamento no sinal são apresentados na Figura 13.

Figura 13 - Exemplo de uma seção de um sinal de sEMG adquirido e do efeito do pré-processamento utilizado no sinal que contém seis repetições de um mesmo movimento. Na figura, 17.a) ilustra o sinal não processado enquanto b) ilustra a mesma seção de sinal após a retificação e c) normalização.



Fonte: Elaboração própria.

A retificação provê a obtenção de um sinal de sEMG exclusivamente positivo, esta operação é facilmente realizável através do cálculo do módulo do sinal como apresentado na Equação (27). Neste trabalho foi utilizada a retificação de onda completa, onde todos valores são representações do módulo do sinal de sEMG, resultando em um sinal mais descritivo ao se considerar a amplitude (ISON & ARTEMIADIS, 2014). Na Equação (27), $sEMG_{CH}(t)$ representa o sinal de sEMG proveniente dos doze canais de entrada enquanto $sEMG_{RET}(t)$ representa o sinal de sEMG equivalente retificado.

$$sEMG_{RET}(t) = |sEMG_{CH}(t)| \quad (27)$$

Em relação à normalização do sinal, em seu estudo (HSU *et al.*, 2003) ressaltaram a importância de escalonar os dados antes de usá-los como entrada de um método de IC. A principal vantagem é evitar atributos que possuam valores muito altos ou muito discrepantes e que influenciem em demasia os coeficientes do classificador. Para o escalonamento dos dados é utilizada então, a normalização dos sinais de sEMG por canal, conforme a Equação (28):

$$sEMG_{CANAL_{NORM}}(t) = \frac{sEMG_{RET}(t)}{\max(|sEMG_{RET}(t)|)} \quad (28)$$

onde $sEMG_{RET}(t)$ representa o sinal de sEMG de entrada retificado por canal e $sEMG_{CANAL_{NORM}}(t)$ representa o respectivo sinal de sEMG normalizado por canal. Como exemplo,

a Figura 13 ilustra: a) o sinal de sEMG de um dos canais adquiridos durante a repetição de um movimento da base IEE; b) a mesma porção do sinal retificado ($sEMG_{RET}$) enquanto c) o correspondente sinal normalizado ($sEMG_{CANAL_NORM}$) do movimento correspondente.

4.4.3 Segmentação por janelas deslizantes

A segmentação por janelas deslizantes é uma estratégia muito comum em processamento de sinais. A técnica consiste em percorrer o sinal de interesse com um tamanho de segmentação pré-definido para o qual novas amostras são inseridas no vetor de segmentação destinado à extração de *features*. Neste trabalho, o filtro AVT para cada janela considerada foi utilizado concomitante a segmentação. A segmentação por *timestamp* costuma fornecer sinais com comportamento muito mais regulares do que a segmentação por janelas deslizantes tendo em vista que enquanto em métodos de *timestamp* geralmente o movimento inteiro é considerado para a classificação enquanto nas janelas deslizantes porções muito menores e muito menos representativas dos sinais são consideradas. Em contrapartida a segmentação por *timestamp* oferece bem menos amostras de entrada aos classificadores, uma vez que cada amostra provém de um movimento distinto inteiro, perfazendo, uma matriz de 102 amostras x o número de *features* extraídas para cada ensaio realizado ao considerar-se a base NINAPro ou o Exercício A da base IEE.

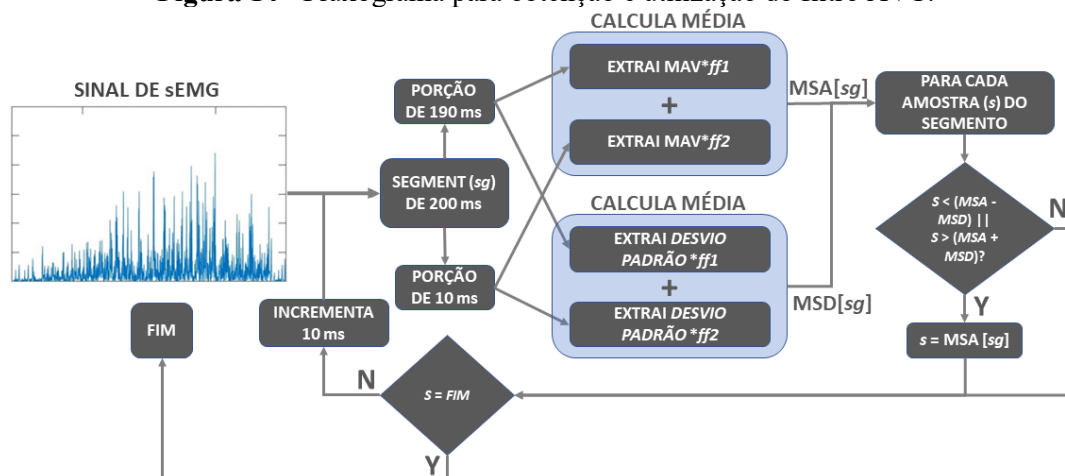
Este cenário muda radicalmente na utilização da técnica de janelas deslizantes, onde, por exemplo, para o Exercício D da base IEE, cada ensaio utilizado neste trabalho, gera uma matriz de mais de 300.000 amostras x o número de *features* extraídas por canal. A dimensionalidade típica deste tipo de ensaio, gera um problema relacionado a representatividade e repetitividade de cada amostra que é dificilmente suficiente para o treinamento ideal de um classificador em função de muitas amostras dispersas entre classes. Considerando este cenário, a aplicação de filtros digitais de pré-processamento para condicionar o sinal dentro de margens mais convenientes ao treino do classificador é bastante útil. Neste trabalho, um modelo modificado do filtro AVT foi utilizado. A utilização e seleção de parâmetros do filtro são detalhadas no próximo subcapítulo. Ainda em relação a segmentação do sinal, testes preliminares envolvendo três segmentações diferentes (200ms, 300ms e 400ms de tamanho e 10ms de incremento) foram realizados. Através destes testes constatou-se um cenário mais favorável à taxa de acerto quando segmentos de 400ms de tamanho e 10ms de incremento foram utilizados. Este resultado confirma as conclusões de (FARRELL &

WIER, 2007; FARRELL, 2011), que relatam a tendência com a qual períodos maiores de segmentação fornecem maiores taxas de acerto. Os resultados correspondentes a estes testes preliminares encontram-se na seção 5.1, no Capítulo de Resultados desta Tese.

4.4.4 Filtro AVT

O filtro AVT utilizado no trabalho foi aplicado no sinal de sEMG retificado. Tendo em vista que a janela deslizante utilizada em cada passo de segmentação já tinha limites e incrementos definidos, optou-se por aproveitar estas mesmas janelas como base de dados para definir os parâmetros de amplitude média (MAV) e desvio padrão (STD) do filtro. Estes valores são atualizados progressivamente à medida que as janelas deslizantes percorrem o sinal, em uma heurística de média móvel. Como detalhado no subcapítulo 3.1 deste trabalho, o filtro AVT original utiliza descarte de dados, excluindo *outliers* e gerando uma base de dados com uma dispersão menor quando comparada aos dados sem descarte para descrever um determinado fenômeno. Na aplicação abordada nesta proposta de tese para a abordagem de janelas deslizantes, o descarte de uma amostra de entrada representa uma latência de 10ms de resposta do sistema (incremento da janela deslizante). Desta forma, para não descartar dados e manter a resposta constante do sistema, o algoritmo original do AVT foi modificado e é utilizado como mostra o fluxograma da Figura 14.

Figura 14 - Fluxograma para obtenção e utilização do filtro AVT.



Fonte: Elaboração própria.

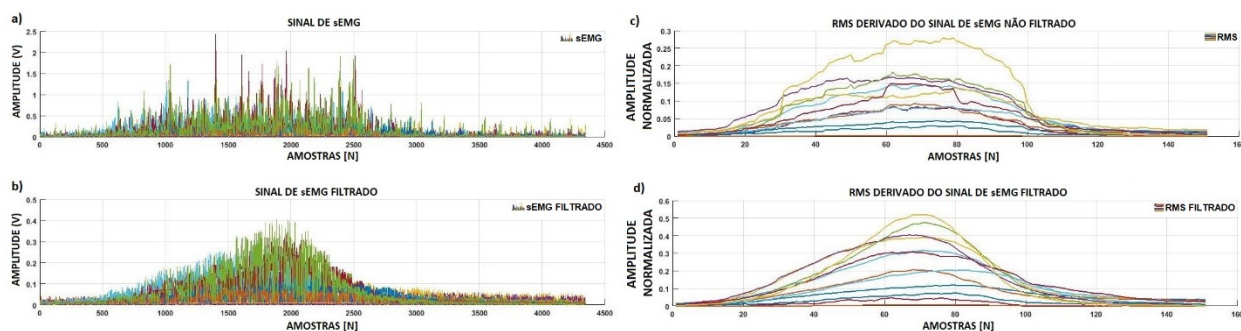
Para aplicação deste filtro, foram criados dois coeficientes para a obtenção da média e do desvio padrão do sinal, como apresentado no sistema de equações apresentado na Equação (29). Esta abordagem foi utilizada pelo fato de que os deslocamentos de 10ms fornecem uma informação

atualizada a cada janela, representando a característica dinâmica do sinal. Desta forma, realizar a média da janela inteira mitigaria esta dinâmica do sistema. Portanto, estes dois coeficientes configuram-se como fator de ordem do filtro de modo que ao atribuir um valor muito alto para a parcela de *overlap* – 390ms prévios do sinal, na configuração 400ms+10ms – elimina-se a dinâmica do sistema, assim como atribuir demasiado valor à parte dinâmica mitiga o efeito de filtragem. Os coeficientes (ff_1 e ff_2) apresentados na Figura 14 foram obtidos empiricamente através de testes preliminares nas bases de dados e foram definidos como 0,8 para a porção de *overlap* do sinal e 0,2 para a porção dinâmica do sinal.

$$\left\{ \begin{array}{l} [\mu_{seg} - \sigma_{seg}] \leq \text{Amplitude da amostra} \leq [\mu_{seg} + \sigma_{seg}] \\ \mu_{seg} = \mu(\text{Overlap} \times 0,8 + \text{Novos dados} \times 0,2) \\ \sigma_{seg} = \sigma(\text{Overlap} \times 0,8 + \text{Novos dados} \times 0,2) \end{array} \right. \quad (29)$$

Desta forma, o filtro AVT utiliza-se da característica estocástica – porém compreendida em uma determinada faixa – do sinal de sEMG para a geração de um sinal mais bem determinado, como mostra a Figura 15. Para efeito de comparação, na Figura 15 são representados: a) o sinal de sEMG referente a execução de um movimento; b) a mesma porção de sinal, filtrado através do método proposto c) valores da *feature* RMS para o sinal de sEMG não filtrado e d) valores da *feature* RMS para o sinal de sEMG filtrado.

Figura 15 - Resultado da aplicação do filtro AVT. Para efeito de comparação são mostrados para um mesmo segmentos de sinal: a) o sinal de sEMG não filtrado; b) o sinal de sEMG filtrado por AVT; c) a *feature* RMS derivada do sinal de sEMG não filtrada e d) a mesma *feature* filtrada pelo AVT.



Fonte: Elaboração própria.

Tanto no sinal de sEMG quanto na *feature* RMS derivados da aplicação do filtro é possível notar o comportamento gaussiano induzido pela aplicação do AVT. Este tipo de comportamento favorece a representatividade na seção intermediária do movimento, o que tende a diminuir os ruídos de classificação nesta seção. Outra característica do AVT é a redução da amplitude do sinal, o que é perceptível ao se comparar os sinais representados na Figura 15.b e Figura 15.a induz uma

atenuação considerável no começo e no final dos movimentos, o que tende a levar o classificador a interpretar uma parte destas seções de cada movimento como repouso. Em uma aplicação prática, esta tendência de classificar parte destes movimentos como repouso tende a introduzir um atraso para o começo do reconhecimento do movimento realizado assim como um retorno prematuro à classe de retorno, próximo do fim da ativação muscular. Tendo em vista que este fenômeno também é característico da utilização de *features* no domínio tempo, nesta Tese foi desenvolvida uma nova *feature* para aumentar a representatividade do sinal em segmentos de transição, esta nova *feature* denominada *Differential Enhanced Signal* (DES), é detalhada no Subcapítulo 4.4.6.

4.4.5 Extração de *features*

Utilizando os vetores que representam as segmentações é possível obter a base de tempo para a extração de *features* do sinal. Para a definição das *features* utilizadas neste trabalho, trabalhos anteriores, como por exemplo, os trabalhos de (CENE, 2016c; CENE & BALBINOT, 2019b) e (PHINYOMARK *et. al.*, 2013; ENGLEHART *et. al.*, 1999) foram considerados. A Tabela 8 detalha as características envolvidas neste trabalho onde k corresponde a k -ésima amostra do i -ésimo segmento de tamanho N e x_{th} corresponde a um *threshold* de interesse do sinal de sEMG.

Tabela 8 - *Features* extraídas dos sinais de sEMG utilizadas nesta proposta de tese.

FEATURE	EQUAÇÃO	DESCRIÇÃO
Root Mean Square (RMS)	$RMS_k = \sqrt{\frac{1}{N} \sum_{k=1}^N x_k^2}$	Valor RMS do i -ésimo segmento de sinal em função das suas k amostras
Variância (VAR)	$VAR_i = \frac{1}{N} \sum_{k=1}^N (x_i(k) - \bar{x}_i)^2$	Valor de variância do i -ésimo segmento de sinal em função das suas k amostras
Valor Absoluto Médio (VMA)	$VAM_i = \frac{1}{N} \sum_{k=1}^N x_i(k) $	Valor absoluto (retificado) médio para o segmento de tamanho N
Desvio Padrão (DP)	$DP_i = \frac{1}{N} \sum_{k=1}^{N-1} x_i(k) - x_i(k+1) $	Valor de desvio padrão do i -ésimo segmento de sinal em função das suas k amostras
Differential Enhanced Signal (DES)	$DES_i = MOVAVG\{PCA(MAV[segmento(i-1)], MAV[segmento(i)])\} $	Valor absoluto médio de amostras sucessivas dos componentes principais da amplitude média

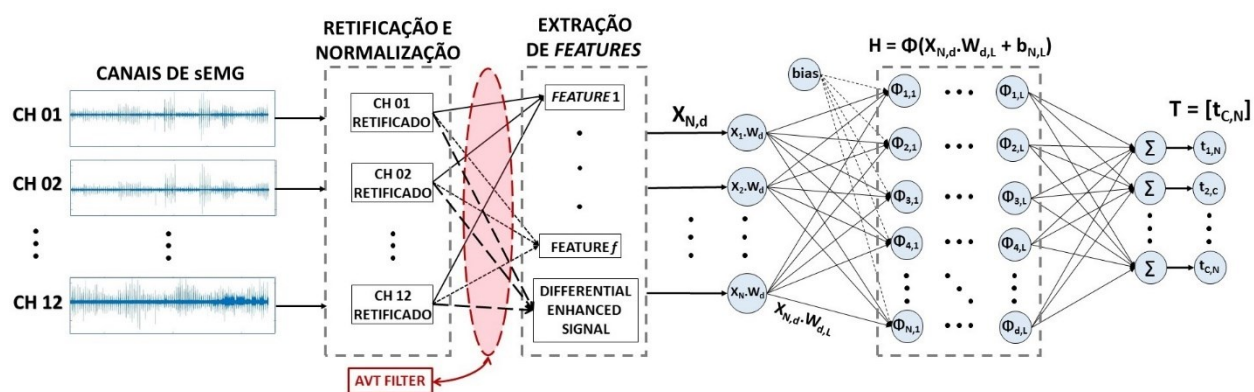
Fonte: Adaptado livremente de (MICERA *et al.*, 2010).

As *features* do domínio tempo apresentadas na Tabela 8 foram escolhidas para classificação do sinal por apresentar boa representatividade da maior parte do sinal em seu domínio. Para representar as ativações em períodos de transições de movimentos nos quais estas *features* são reconhecidamente ineficientes foi utilizada uma nova *feature*, como citado no capítulo anterior. A esta nova *feature*, extraída diretamente do sinal de sEMG retificado e filtrado, foi dado o nome de *Differential Enhanced Signal*.

4.4.6 Differential Enhanced Signal (DES)

Apesar de geralmente fornecer uma representatividade eficiente ao reconhecimento de padrões em períodos intermediários do sinal de sEMG, o RMS, assim como, outras *features* baseadas em amplitude do sinal no domínio tempo, costumam ser descritores pobres em áreas de transições de movimentos. Isto ocorre pela ativação e desativação progressiva dos MUAPs exigidos para a realização de cada movimento que normalmente não fornecem um sinal representativo em amplitude no começo e fim de cada movimento, o que causa muita sobreposição de classes para estes trechos do sinal em uma perspectiva de reconhecimento de padrões. Desta forma, trabalhou-se em torno de outra *feature* capaz de oferecer valores representativos principalmente onde as *features* mais usuais no domínio tempo não os oferecem, nos períodos de transição dos movimentos (CENE & BALBINOT, 2018a). A Figura 16 indica o uso do DES no sistema de classificação por RELM, que agora, também utiliza o filtro AVT em sua entrada.

Figura 16 - Utilização do DES e do filtro AVT no RELM.




Levando em consideração que a *feature* complementar a ser utilizada com a *features* do domínio tempo idealmente deveria contornar o problema oferecido em relação à amplitude do sinal nos segmentos de interesse, optou-se por trabalhar com um método baseado em PCA, realizando

a projeção dos dados em questão. Desta forma, ao invés de utilizar-se de *features* extraídas no tempo, o DES realiza a projeção dos dados através de PCA e obtém 12 coeficientes utilizados para a projeção de cada componente principal (um para cada canal do sEMG).

A principal ideia em relação à *feature* DES é a de que cada novo segmento, que adiciona 10ms (20 amostras do sinal de sEMG) ao vetor de 400ms ao mesmo tempo em que descarta a parcela de 10ms mais antiga, representa uma parcela de 2,5% de novos dados em relação ao vetor de segmentação. Desta forma, é esperado que os componentes principais utilizados para a projeção dos dados se mantenham similares em janelas adjacentes representantes de um mesmo movimento e que os coeficientes dos componentes principais apresentem uma variação pequena para estas mesmas janelas. A Figura 18 descreve o cálculo desta nova *feature*, onde: a) DES representa a característica de saída, b) *MOV AVG* representa um filtro de média móvel que associado à característica fornece um valor com menor dispersão, c) MAV representa a amplitude média de cada segmento retificado de 400ms da amostra atual (i) e anterior ($i-1$) do sinal de sEMG e d) PCA fornece os componentes do espaço projetado para as MAV de cada amostra considerando os 12 canais de sEMG.

Figura 17 – Cálculo do *Differential Enhanced Signal* (DES) a partir de dois segmentos consecutivos do sinal de sEMG.

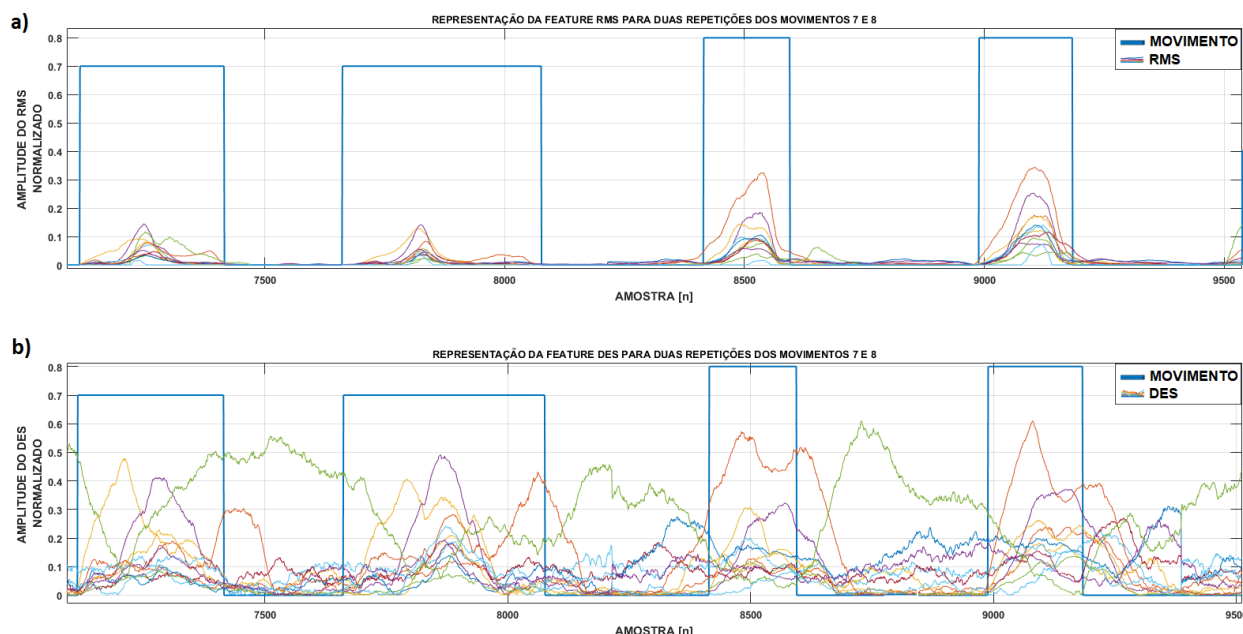


Fonte: Elaboração própria.

Testes preliminares foram realizados para a extração da DES e foi observado que um filtro de média móvel (*MOVAVG*) na saída do sistema é capaz de aumentar a taxa de acerto do classificador significativamente. Após estes testes, 10 amostras foram adotadas como padrão. No entanto, considerando que uma nova amostra resultante do PCA é obtida a cada 10ms do sinal, o acúmulo de 10 amostras para o cálculo provoca o atraso de 100ms de resposta do sistema. Para contornar este problema foi utilizado um filtro de média móvel, que, acumula um *buffer* de nove amostras quando o sistema é inicializado e depois é capaz de fornecer a resposta em uma heurística de janela deslizante, a cada 10ms, evitando a latência do sistema. Desta forma, esta latência de 100ms ocorre uma única vez, quando o sistema é inicializado e o usuário está parado.

A representação de coeficientes obtida pela *feature* DES é particularmente útil para a caracterização e análise dos momentos de transição do sinal de sEMG por apresentar valores bastante distintos para alguns dos coeficientes dos vetores principais. A representação dos movimentos por parte de cada uma das *features* é ilustrado na Figura 18. A critério de comparação, a Figura 18.a ilustra o sinal de RMS obtido enquanto a Figura 18.b ilustra o sinal de DES obtido em função de quatro repetições de movimentos realizados.

Figura 18 - Representação dos movimentos fornecida pelas features: a) RMS e b) DES.



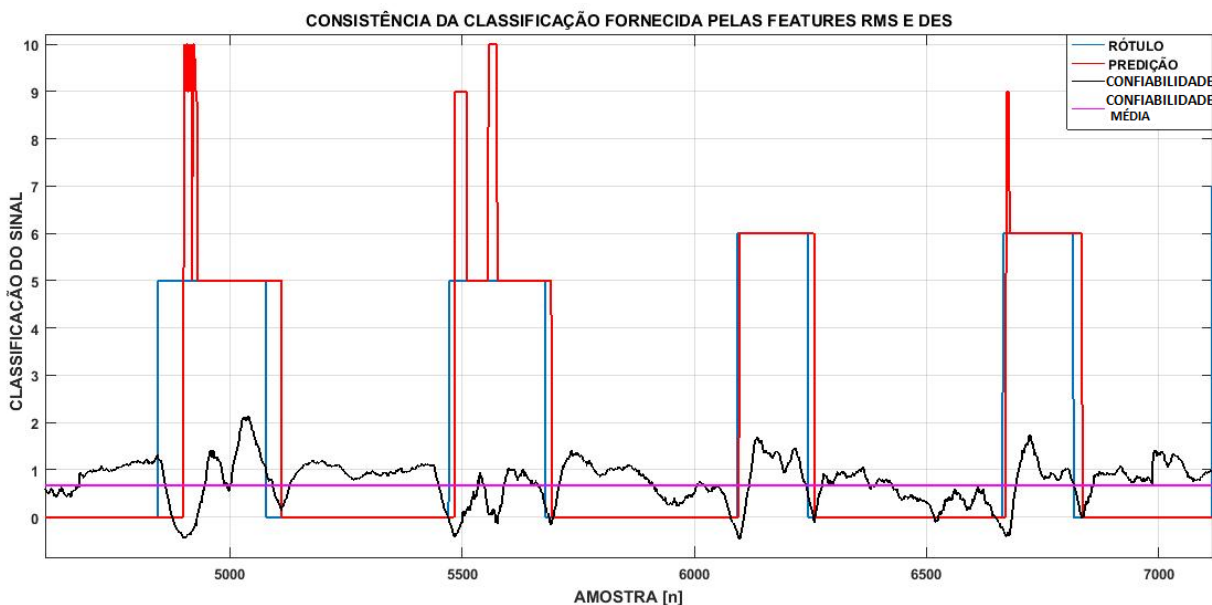
Fonte: Elaboração própria.

Na Figura 18, os retângulos azuis representam os rótulos de movimentos registrados pelo *timestamp* durante o ensaio, que nesta figura foram escalonados por um fator de 10 para a melhor visualização do sinal. Apesar de fornecer um sinal representativo próximo a parte central dos movimentos realizados, a deficiência do RMS para a representação do sinal em momentos de transição particularmente notória para o movimento 7, representado na Figura 18.a. Através dos sinais expostos é esperado que apenas a parte próxima ao centro do rótulo seja classificada adequadamente, sendo que o a parcela restante do sinal se confunde em muito com a classe repouso, apresentando uma ativação baixa em relação a amplitude do sinal. Em contrapartida, a *feature* DES apresenta ativações mais discrepantes, que aumentam o patamar de detecção deste movimento nestas regiões. Assim, a DES fornece que têm padrões de ativação mais distribuídos para as diferentes partes dos movimentos ativos, como apresentado na Figura 18.b.

4.4.7 Confiabilidade das Classificações

No modelo do ELM descrito na Equação (23) e na Figura 19, o vetor de saída $T(\arg \max)$ contém a probabilidade de uma determinada amostra pertencer a cada classe. O rótulo então é atribuído ao maior valor respectivo, que em um cenário ideal é consideravelmente mais alto do que as classes restantes, formando assim uma classificação confiável. Para as amostras que não atingem valores discrepantes o suficiente, ocorre uma queda abrupta do $\arg \max$, onde todas as classes - incluindo a correta - refletem a incapacidade do classificador de fornecer uma saída consistente e muitas vezes, até correta (CENE, *et al.* 2019c). Esta situação é apresentada na Figura 19, onde a baixa representatividade presente em transições dos movimentos e consequente da sobreposição de classes que ocorre principalmente em transições entre repouso e movimentos, leva a uma menor confiabilidade da classificação nesses períodos (CENE, *et al.* 2019a; CENE, *et al.* 2019c; ROSSI, *et al.*, 2015). A mesma situação também pode ocorrer na parte intermediária dos movimentos, o que acaba por provocar ruídos de classificação cada vez que o classificador falha em atingir um valor apropriado de $\arg \max$ e, consequentemente, uma separação de classes adequada.

Figura 19 - Relação entre o nível máximo de $\arg \max$ encontrado (curva preta) e a classificação realizada (curva vermelha) em relação a referência (curva azul) e o valor médio do $\arg \max$ (linha em magenta).



Fonte: Elaboração própria.

Na Figura 19, a curva azul representa o rótulo ideal de cada amostra enquanto a curva vermelha representa a saída predita pelo classificador. Na mesma figura, a curva em magenta

representa o valor médio do *arg max* obtido para todo o teste considerando todas amostras, tanto para o repouso quanto para os movimentos. Ao mesmo tempo, a curva preta representa os valores pontuais de *arg max* para cada amostra classificada onde é possível observar a correlação entre os erros na classificação do sinal e as quedas abruptas no valor do *arg max*. Os efeitos da queda do *arg max* e o ruído na classificação são mais flagrantemente presenciados em períodos ativos de execução de movimentos, isto ocorre pois no repouso, mesmo com um valor mais baixo, a classe é mais facilmente distinguível.

Como meio de mitigar erros de classificação derivados do baixo valor da confiabilidade do sistema dada pelo maior valor de *arg max* para cada amostra, duas alternativas envolvendo: 1) um pacote de técnicas de pós-processamento do sinal, que unido às etapas preliminares de processamento e classificação, forma a versão do ELM Confiável desenvolvido; 2) uma versão do classificador com *arg max* suavizado através do Filtro AVT que também serve de base para dois classificadores auxiliares que juntos compõem os modelos de ELM Resiliente. Ambos os modelos são descritos nos próximos subcapítulos desta Tese.


4.4.8 Arquiteturas de Classificação Confiável do Sinal de sEMG

Na Figura 20, a maior parte das repetições consegue ser classificada razoavelmente perto de suas zonas de início e fim (zonas de transição de movimentos). No entanto, há a ocorrência de confusão entre classes - também chamado de ruído de classificação – mesmo com a utilização da *feature* do DES. O ruído de classificação ocorre tanto na classificação apresentada na Figura 20.a, que é uma classificação realizada somente com a *feature* RMS quanto na Figura 20.b que utiliza RMS e DES como *features* de entrada. Embora o uso do DES aumente a taxa de acerto do classificador para as classes representadas, o ruído de classificação ainda permanece nas zonas de transição de movimentos. Percebe-se então que aumentar o período de reconhecimento do movimento realizado, aumentando o acerto em zonas de transição de movimentos, não necessariamente garante uma classificação do sinal inteiro (embora haja uma tendência neste sentido, considerando que as *features* sejam suficientemente descritivas).

As principais fontes de erros na classificação dos sinais de sEMG advém de dois principais fatores: a) da falta de representatividade das *features* extraídas, principalmente em períodos de transições de movimentos, como explicado no Subcapítulo 4.4.6 e b) do ruído de classificação entre classes que ocorre em função da dificuldade de separação dos dados, gerando sobreposições

indesejadas dos valores de *arg max* do classificador que acabam fornecendo saídas errôneas. A dificuldade de separação entre dados é uma característica marcante do sinal de sEMG proveniente da baixa representatividade de cada amostra obtida a cada 10ms de cada janela de segmentação utilizada, que é ainda mais acentuado nas porções iniciais e finais de cada movimento.

Figura 20 - Relação entre o nível máximo de *arg max* encontrado (curva preta) e a classificação realizada (curva vermelha) em relação a referência (curva azul) e o valor médio do *arg max* (linha em magenta) utilizando: a) somente a *feature* RMS e b) RMS e o DES.



Fonte: Elaboração própria.

Uma forma de atenuar o primeiro problema consiste na utilização de *features* que forneçam informações mais representativas nos períodos de transição, o que já foi realizado com a *feature* DES. Há também trabalhos como (ANAM & AL-JUMAILY, 2017) que descartam estas transições de movimentos, admitindo uma latência considerável no sistema em troca de classificações mais consistentes e sem ruído de classificação, que tendem a aparecer, mais frequentemente, nestas referidas porções do sinal.

Já para contornar o problema de confusão entre classes, existem algumas estratégias clássicas, sendo a mais utilizada o método de votação majoritária. Através da votação majoritária tende-se a manter uma classe de saída baseada em sua ocorrência nas últimas n amostras. Outras soluções mais sofisticadas foram propostas por (SCHEME *et. al.*, 2013) e (AMSUSS *et. al.*, 2014), que avaliaram quando o classificador não tem condições de classificar uma amostra; não fornecendo saída alguma e verificando a eficiência da classificação e a reclassificando através de uma RNA auxiliar, quando necessário. Ambos os métodos utilizaram um critério baseado na saída do classificador para decidir qual ação tomar.

Assim como (AMSUSS *et. al.*, 2014), que utilizaram a *distância de Mahalanobis* derivada do LDA para inferir o quão adequadamente a amostra em questão foi classificada, nesta Tese o valor de *arg max* derivado das classificações que se encontra na matriz T é utilizado como métrica para a verificação de uma classificação adequada (confiável). Esta matriz já é naturalmente utilizada pelo método de ELM para definir qual classe atribui o rótulo à amostra em questão em uma heurística *One-vs-All*. Na abordagem utilizada, o maior valor entre as classes, rotula a amostra. Desta forma, é esperado que uma amostra representativa seja classificada com um valor maior e distinto em relação às outras classes de saída. Da mesma forma, é esperado que o valor geral do *arg max* máximo (confiabilidade representada na Figura 19 e Figura 20) decaia para todas as classes em algumas porções do sinal e gere erros de classificação. À estas classificações de baixa confiabilidade, são adicionados métodos de pós-processamento de forma a corrigir as saídas do classificador, visando oferecer saídas continuamente corretas. O classificador capaz de classificar amostras corretamente de forma contínua para as diferentes classes a serem rotuladas, define um “classificador confiável”.

O referido valor de saída utilizado para a atribuição de classes é representado na Figura 20 pela curva “confiabilidade”, na cor preta. Para efeito de comparação, o parâmetro “confiabilidade média”, representado na cor magenta, refere-se à média encontrada para toda a faixa de classificações de amostras. Nitidamente os valores da confiabilidade do classificador decaem bruscamente quando ocorrem transições entre classes e tendem a se manter em níveis baixos quando ocorrem ruídos de classificação. Baseada nesta resposta do sistema e nos trabalhos de (SCHEME *et. al.*, 2013; AMSUSS *et. al.*, 2014), as alternativas descritas a seguir foram desenvolvidas para proporcionar o aumento da confiabilidade das classificações e o consequente aumento das taxas de acerto do classificador:

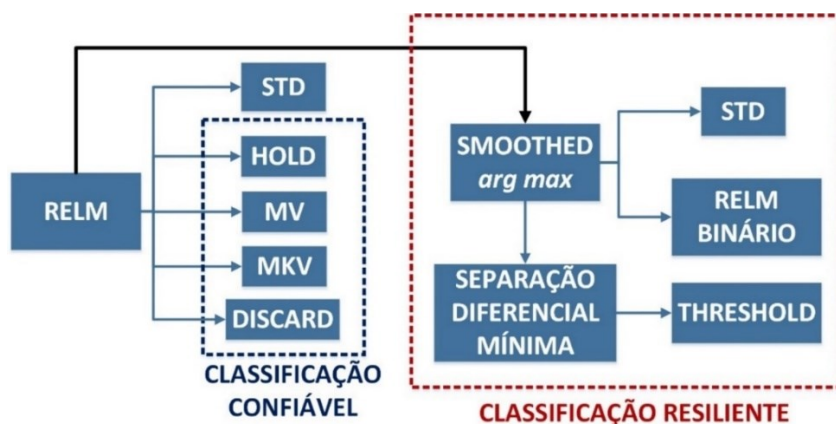
- a primeira consiste em realizar a classificação direta dos dados sem qualquer interferência na classe de saída. Esta abordagem é útil para verificar a taxa de acerto padrão (*baseline*) obtida naturalmente pelo classificador e fornece um patamar de acerto que se deseja melhorar através das demais abordagens adotadas;
- a segunda e a terceira abordagens, utilizam o valor de *threshold* apresentado na Equação (30) para as suas ativações, onde μ_c e σ_c são a média e o desvio padrão da confiabilidade, respectivamente. A segunda abordagem (*HOLD*) – consiste em manter a última classe confiável realizada até que o valor de *threshold* seja alcançado por uma nova classificação, como proposto por (AMSUSS *et. al.*, 2014). Já a terceira abordagem – *Major-Voting (MV)* – atua como um filtro de média móvel do rótulo de saída. Quando a confiabilidade não alcança o nível de *threshold*, a moda das últimas nove classificações realizadas é então atribuída à saída do classificador;

$$threshold_{Ativação} = \mu_c - \sigma_c \quad (30)$$

- a quarta abordagem – Markov (MKV) – baseia-se no trabalho de (HABERMANN, *et al.*, 2016). Da mesma forma, um HMM que mapeia as probabilidades de transição e emissão para cada classe de saída foi utilizado para oferecer uma classificação mais consistente e evitar ruídos no sinal de saída;
- a quinta (*DISC*, do inglês *DISCARD*) e última abordagem, baseia-se em (SCHEME *et. al.*, 2013) e consiste em ignorar a classe de saída quando a confiabilidade da classificação apresenta-se abaixo do *threshold* estabelecido, o que é uma abordagem experimental interessante, tendo em vista que é melhor não acionar algum dispositivo como uma prótese, por exemplo, do que acioná-la erroneamente. O *threshold* é o mesmo utilizado para os métodos de *Major-Voting (MV)* e *HOLD*, como apresentado na Equação (30).

Complementarmente às soluções que perfazem o método do classificador confiável, outras abordagens que compõe a classificação resiliente do classificador também foram exploradas, como apresentado na Figura 21. As soluções relativas ao método do Classificador Resiliente são apresentadas a seguir.

Figura 21 - Diagrama de blocos dos métodos desenvolvidos nesta Tese onde a classificação confiável conta com os métodos HOLD, MV, MKV e DISCARD enquanto a classificação resiliente é composta pelos métodos de *arg max* suavizado e pelos classificadores binomiais baseados no RELM binário auxiliar e no método do *threshold* gerado através da métrica de Separação Diferencial Mínima (SDM).

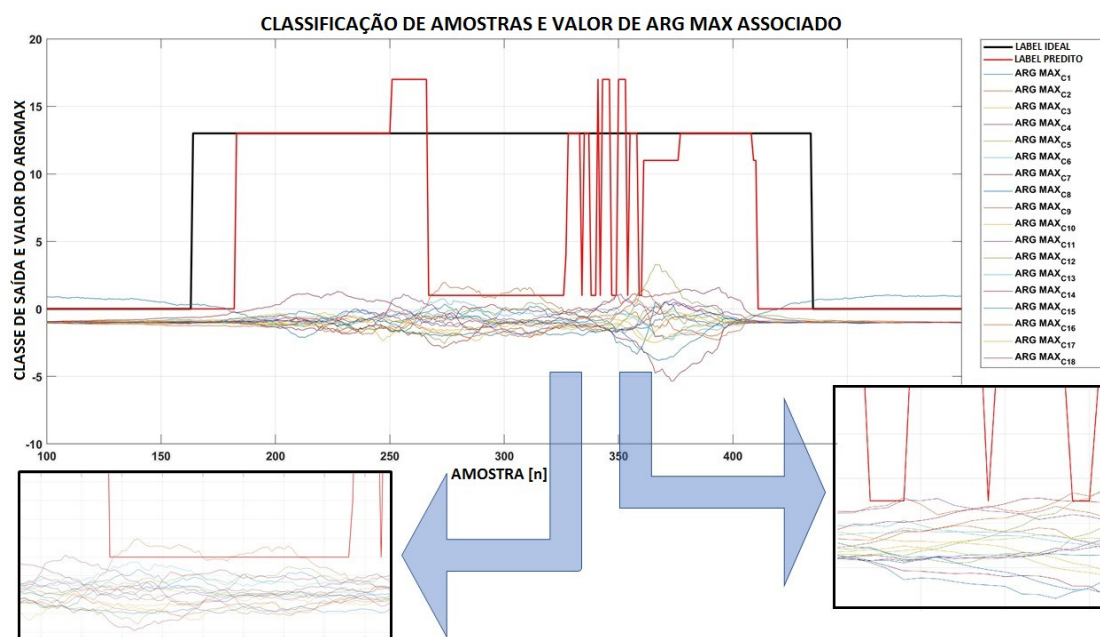


Fonte: Elaboração própria.

4.4.9 Arquitetura de Classificação Resiliente do Sinal de sEMG

A Figura 22 ilustra os valores de *arg max* de todas as classes para o classificador RELM padrão durante a execução de um movimento onde os erros típicos de ruído de classificação em etapas intermediárias do movimento e erros de classificação nas zonas de transição são ilustrados.

Figura 22 - Efeito dos componentes de alta frequência presentes no *arg max* na classificação (vermelho) em relação ao *label* ideal (preto). Os valores de *arg max* para cada uma das classes é representado pelas demais curvas.

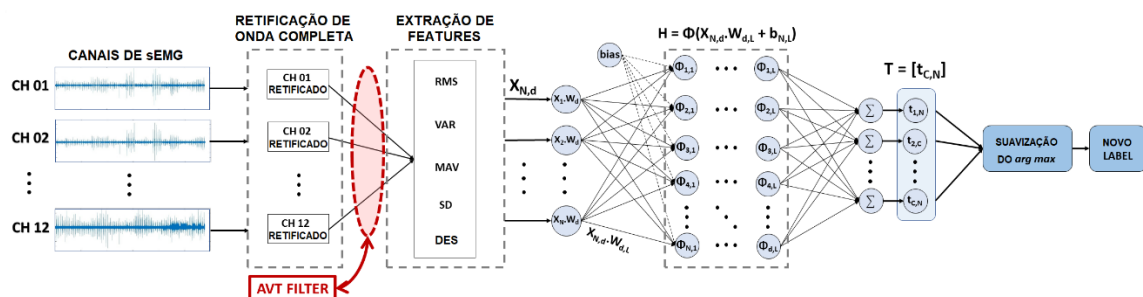


Fonte: Elaboração própria.

Expandindo a análise anterior em relação à métrica de confiabilidade que considera apenas o valor máximo de *arg max* para cada amostra classificada, duas hipóteses principais foram levantadas:

1. Ao considerarmos o ruído de classificação como consequência de componentes de alta frequência presentes no *arg max* do classificador e que durante um movimento específico, o *arg max* predominante será o da classe correta, supõe-se que filtrar esse vetor do *arg max* para cada amostra tende a eliminar a interferência pontual em porções intermediárias do sinal e fornecer uma classificação mais consistente e assertiva. Para mitigar a influência destes sinais ruidosos do *arg max*, o modelo de ELM de *arg max* suavizado foi desenvolvido. Neste modelo, os valores de *arg max* do classificador padrão são filtrados para cada amostra do sistema utilizando o mesmo filtro AVT do pré-processamento do sinal. Logo após este processo, as classes de saída são novamente atribuídas com base no *arg max* filtrado. Desta forma, a influência destrutiva destes componentes de alta frequência é mitigada e é possível obter sinais mais estáveis para todas as classes de saída. A arquitetura geral do ELM de *arg max* suavizado é apresentada na Figura 23.

Figura 23 - Diagrama de blocos geral da classificação por *arg max* suavizado, onde o processo de suavização é realizado por um filtro AVT como no pré-processamento.



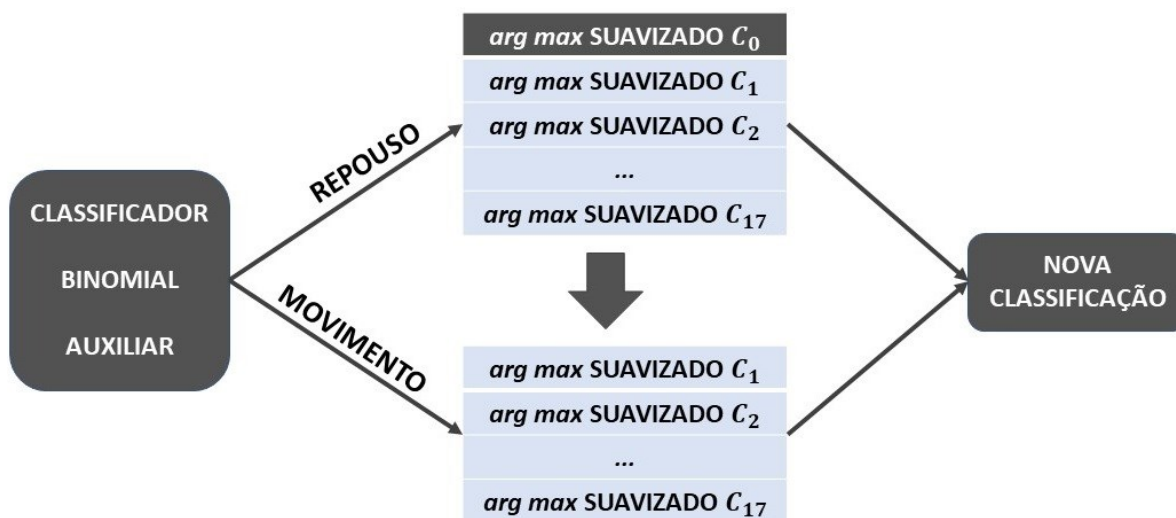
Fonte: Elaboração própria.

2. Em zonas de transição de movimentos, geralmente quando há erro, este erro consiste em classificar a classe repouso ao invés do movimento adequado. Supõe-se então que se uma forma auxiliar for utilizada com sucesso para distinguir mais precisamente os momentos exatos de transição entre repouso e movimentos ativos e vice-versa, uma vez que um movimento é detectado, pode-se excluir a classe de repouso da análise do *arg max*, forçando a amostra a receber um rótulo de movimento ativo, que deve ser a classe correta. Para aumentar a taxa de acerto em zonas de transição de movimentos as versões de

Classificação Resiliente do RELM foram desenvolvidas. As duas heurísticas baseadas no classificador binomial auxiliar e no método do *threshold* são detalhadas a seguir.

Para os modelos de classificação resiliente do sinal, o RELM binário auxiliar faz uso dos mesmos dados de treinamento e teste do RELM principal, com a diferença de que os *labels* são alterados para a classificação binomial. Assim, as classes não consistem em C_0, C_1, \dots, C_{17} e sim em “repouso” e “movimento”. Quando o classificador binomial identifica a saída como repouso, não há interferência na classificação gerada pelo RELM de *arg max* suavizado, porém, quando a classe de movimento é identificada, o *arg max* da classe repouso é ignorado e a classe de saída é definida em função do *arg max* suavizado das classes de movimento C_1, \dots, C_{17} como representado na Figura 24. Esta abordagem oportuniza que classes de movimento sejam classificadas mesmo quando o classificador binário falha em detectar um movimento e força a saída do classificador a reconhecer algum movimento específico caso a saída binária seja “movimento”, anulando os erros gerados com a confusão para a classe repouso em seções de transição de movimentos.

Figura 24 - Funcionamento da classificação auxiliar que determinada a utilização da classe repouso na comparação de valores do *arg max* e nova atribuição de *labels*.



Fonte: Elaboração própria.

Assim como o método do classificador binomial auxiliar, o método do *threshold* também tem por objetivo fornecer um sinal binário que controla o uso ou não do valor de *arg max* correspondente à classe de repouso, como apresentado na Figura 24, onde o método substituiria o bloco “CLASSIFICADOR BINOMIAL AUXILIAR”. A diferença entre os métodos consiste de que a saída binomial baseada em *threshold* é derivada dos valores de *arg max* suavizado obtidos como apresentado na Equação (31), onde a métrica é composta pela normalização da diferença

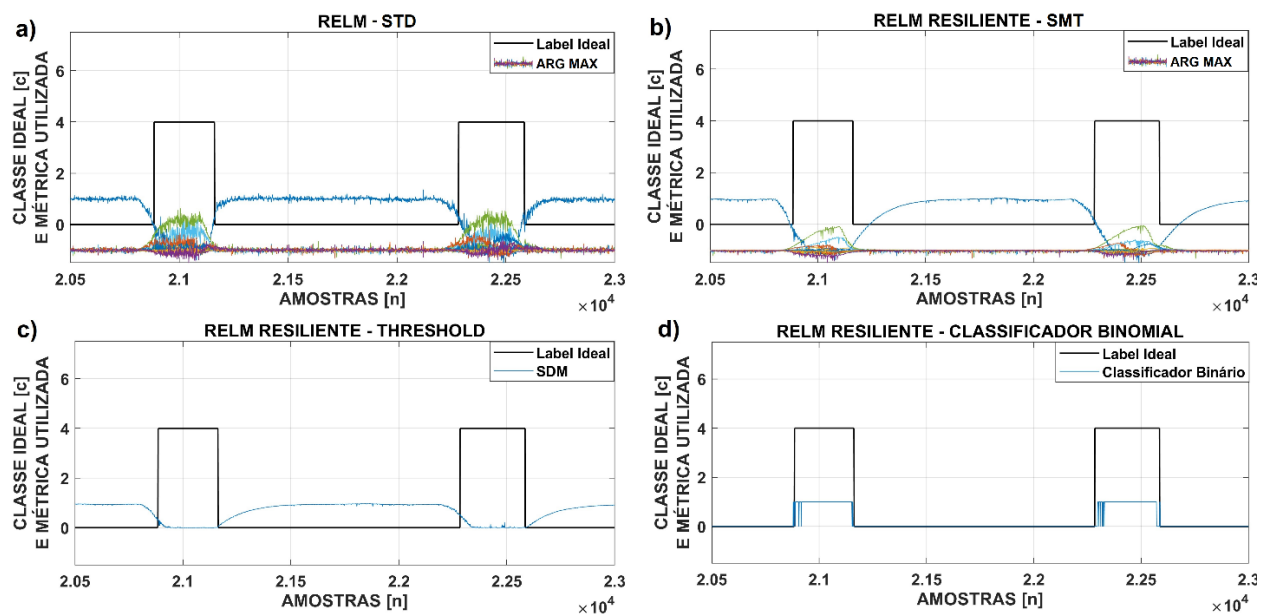
mínima entre o *arg max* do repouso e das demais n classes. Uma vez obtida, esta métrica, na prática, representa a probabilidade da classe repouso estar ocorrendo. Já o *threshold*, é definido pela subtração do desvio padrão (σ_{SDM}) da média (μ_{SDM}) encontrada para cada voluntário e define a ocorrência de um movimento ativo, como apresentado na Equação (32).

$$SDM = NORM(\min|\arg \max_{\text{Repouso}} - \arg \max_{C_2:C_n}|) \quad (31)$$

$$Threshold_{Resiliente} = \mu_{SDM} - \sigma_{SDM} \quad (32)$$

Nesta abordagem, a métrica da confiabilidade utilizada nas versões anteriores dos classificadores é expandida a uma métrica diferencial. Esta métrica baseia-se no fato de a classe de repouso ser mais facilmente classificada em relação às outras por apresentar valores de *arg max* bastante distintos quando ativa. Desta forma, se tem uma separação de classes adequada que decai para as seções dos movimentos, onde geralmente os valores de *arg max* são muito mais próximos, o que é claramente observável, respectivamente, até a amostra 150 (repouso) e da amostra 150 a 400 da Figura 22. Logo, o *threshold* outrora definido pela Equação (30) para ativação dos métodos de classificação confiável é agora definido considerando o valor normalizado da nova abordagem diferencial pela Equação (32). A representação gráfica das três métricas envolvidas na classificação resiliente e o valor de *arg max* do RELM padrão é apresentada na Figura 25.

Figura 25 - Métricas principais e auxiliares utilizadas na classificação do sinal: a) *arg max* derivado do RELM padrão; b) *arg max* suavizado; c) sinal de Separação Diferencial Mínima (SDM) que dá base a classificação resiliente no método do *threshold* e d) classificação binária auxiliar utilizada para a classificação resiliente no método do classificador binomial.



Fonte: Elaboração própria.

4.4.10 Ajuste dos Classificadores

Para a classificação dos sinais, é realizada a leitura de cada matriz de *features* de entrada individualmente para cada sujeito. É importante observar que uma das vantagens do ELM frente a outros métodos de classificação como Regressão Logística, SVM ou outras arquiteturas mais tradicionais envolvendo Redes Neurais é justamente a ausência de hiperparâmetros a serem definidos. Na versão padrão do método o único parâmetro a ser definido é o número de neurônios da camada oculta (*Hidden Neurons*), já na versão regularizada há também a necessidade da definição do parâmetro regularizador.

Como o aumento do número de neurônios na camada oculta não resulta necessariamente em uma taxa de acerto maior, testes preliminares foram realizados para a definição de um valor apropriado do hiperparâmetro. Para a definição do número de neurônios da camada oculta foram realizadas classificações utilizando a faixa de 50 a 2000 neurônios em intervalos de 50 onde foi observado um *overfitting* do modelo a partir de 1200 para a versão regularizada. Este teste, somado aos critérios de informação relatados em (CENE & BALBINOT, 2018a), resultaram na definição de 400 neurônios para a versão padrão do classificador e 1200 para sua versão regularizada. Adicionalmente, o *threshold* de 10^{-9} foi definido para a utilização do modo econômico do SVD utilizado. Em função da taxa de acerto superior apresentada de forma muito consistente em diversos testes preliminares, somente o RELM foi utilizado para os desenvolvimentos das versões confiáveis e resilientes do classificador.

Em sua versão regularizada (RELM), o número de neurônios previamente definido foi mantido enquanto o parâmetro regularizador C foi adicionado, como mostra a Equação (23). Para a seleção do parâmetro de regularização C , foram realizados testes preliminares com o banco de dados envolvendo valores de C dentro de um intervalo de 0,5 a 2,0, sendo que $C = 1,6$ ofereceu os melhores resultados. O intervalo de valores para a atribuição dos pesos aleatórios dos neurônios tanto nos métodos regularizados como nos métodos realizados através de Moore-Penrose se encontra na faixa de $[-1; 1]$. Na versão resiliente do classificador, o classificador binomial auxiliar utilizado também faz uso dos mesmos dados de treino e teste e do mesmo número de neurônios na camada *hidden* e valor de parâmetro regularizador do RELM principal (RELM-STD).

Na abordagem confiável do classificador, os métodos de MV, HOLD e DISCARD são acionados autonomamente em função do *threshold* da Equação (30). Similarmente, na versão resiliente, o método do $threshold_{SDM}$, indica a ativação do método por *threshold*.

Já para a definição dos valores de transição e emissão do HMM foram utilizadas algumas características naturais esperadas do sistema: 1) pela natureza da base de dados, o repouso deve ser mais provável do que qualquer movimento individual tendo em vista que compõe de 40% a 75% dos testes, dependendo da base; 2) não é desejado que sejam permitidas transições entre movimentos. Por exemplo, transitar do movimento 1 ao 2 sem passar pelo repouso antes. Desta forma, somente transições de repouso para algum movimento específico e vice-versa são permitidas, o que é assumido no intuito de mitigar ruídos de classificação durante as classes de movimentos; 3) da mesma forma, considerando a natureza do experimento, é muito mais provável que estando em uma determinada classe, a próxima classificação será a permanência nesta mesma classe ao invés da transição; 4) a emissão parte do princípio de que é muito mais provável que a saída esteja rotulando a classe correta e erros para o repouso são duas vezes mais prováveis do que erros para outra classe de movimentos. Após a definição dos valores iniciais, a função *hmmtrain* do MATLAB 2019a – que utiliza por padrão o algoritmo de *Baum-Welch* para a definição do modelo – foi utilizada para a otimização destes valores submetidos ao limite de 500 iterações ou uma tolerância de erro e 10^{-7} dos coeficientes calculados. Para o treinamento do modelo os *labels* de treino são utilizados, já para o teste a saída do RELM serve de entrada ao HMM, que tem as suas saídas então como *labels* finais do classificador.

4.4.11 Métricas de Avaliação do Sistema

Para a segmentação realizada por janelas deslizantes, o sinal foi dividido nas mesmas proporções (66,6% para treino e 33,3% para teste) para cada voluntário, incluindo os períodos de repouso que intercalam cada movimento. Para as os 17 movimentos do Exercício 2 das bases NINAPro NAMP e AMP (DB2 e DB3) a mesma heurística quanto a divisão dos dados sugerida por (ATZORI *et. al.*, 2014) foi mantida. Esta heurística consiste em utilizar as repetições 1, 3, 4 e 6 de cada movimento para treino e as repetições 2 e 5 para o teste. Esta mesma abordagem também foi utilizada no ENSAIO A da base IEE, que também possui seis repetições de cada movimento. Já nos ENSAIOS B, C e D, as primeiros 66,6% dos dados incluindo os movimentos e seus respectivos repouso foram utilizados para treino e os 33,3% restantes foram utilizados para o teste dos classificadores. As métricas relacionadas à taxa de acerto consistem da razão percentual entre a quantidade de predições acertadas e a quantidade de predições totais realizadas pelo sistema, como apresentado na Equação (33) e na Equação (34). As taxas de acerto são avaliadas tanto em

relação a seu resultado global (Taxa de Acerto global - TAG), que é um percentual bruto de todos os acertos realizados de todas as amostras testadas, quanto em relação ao seu resultado ponderado (Taxa de Acerto Ponderado - TAP), que considera a média de todas as classes individuais obtidas. A TAP é importante para mitigar a influência da classe de repouso, que geralmente é predominante nas bases e é a classe mais facilmente acertada, introduzindo um *bias* positivo nos resultados obtidos. De tal forma, a TAP torna-se uma métrica mais apropriada para a avaliação geral do sistema.

$$\text{Taxa de Acerto Global (TAG)} = \frac{\#Acertos}{\#Total\ de\ dados\ testados} \times 100\% \quad (33)$$

$$\text{Taxa de Acerto Ponderada (TAP)} = \left(\frac{\#Acertos\ Classe\ C_n}{\#Total\ de\ dados\ Classe\ C_n} \right) \times 100\% \quad (34)$$

Além das métricas relacionadas as taxas de acerto, algumas outras métricas secundárias e avaliações preliminares do sistema também foram consideradas, sendo elas:

- A taxa de acerto do ELM e RELM em suas versões básicas considerando 200ms+10ms, 300ms+10ms e 400ms+10ms como tempos de segmentação para as janelas deslizantes;
- A taxa de acerto do treino do RELM base;
- O nível de *threshold* utilizado na classificação confiável;
- A taxa de dados não-confiáveis modificados pelas estruturas de classificação confiável;
- O nível de *threshold* utilizado na classificação resiliente;
- A taxa de acerto do classificador binário auxiliar na classificação resiliente.

4.4.12 Projetos de Experimento

Para a validação estatística dos ensaios, foram realizadas diversas Análises de Variância (ANOVA) do Tipo Fatorial Completo baseados em teste de Tukey ($p = 0,01$) utilizando o Minitab 19. Para apresentar as análises com mais clareza, e pela restrição de software em relação a níveis de interações entre fatores, os testes relativos às taxas de acerto global e ponderada dos métodos desenvolvidos assim como as avaliações preliminares mencionadas no fim do Subcapítulo 4.4.11 são realizadas separadamente por base e variando-se os fatores conforme as características de cada teste, sendo que:

- 1) A comparação ELM x RELM e tempos de segmentação tem como variáveis de resposta (y_1) , (y_2) e (y_3) as taxas de acerto global e ponderada e a taxa de acerto no treinamento dos

classificadores, respectivamente. Os fatores controláveis são as duas (i) variações de método de classificação (α), os três (j) tempos de segmentação diferentes (β) e os k voluntários de cada base (γ). Vale ressaltar que na base AMP $k=11$, na base NAMP $k=40$ e na base IEE, por simplicidade e considerando cada *trial* como um ensaio independente, $k=48$. Na Equação (35) o μ simboliza a taxa de acerto média enquanto ε representa o erro.

$$y_1 = y_2 = y_3 = y_{i,j,k} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + \varepsilon_{ijk} \quad (35)$$

- 2) Para comparação das soluções de pós-processamento da versão confiável do classificador, as variáveis de resposta (y_4) e (y_5) são as taxas de acerto global e ponderada, respectivamente que envolvem diferentes fatores em sua análise. A TAG é uma resposta geral para todo o ensaio já a TAP é uma resposta ponderada que considera as taxas de acerto de todos os movimentos executados. Portanto, para a definição da resposta em relação a TAG nas bases NINAPro é dada pela Equação (36) enquanto a TAP é dada pela Equação (37). Os fatores controláveis envolvidos na definição da TAG para as bases NINAPro são os cinco (i) diferentes métodos componentes da classificação confiável (α) e os j ($j_{AMP}=11$ e $j_{NAMP}=40$) voluntários (β) que compõem ambas as bases. Já para a TAP, em ambas as ANOVAs é acrescido o fator k , que representa a taxa de acerto individual para cada um dos 18 movimentos (γ) realizados durante o teste.

$$y_{4NINAPRO} = y_{i,j} = \mu + \alpha_i + \beta_j + \varepsilon_{ij} \quad (36)$$

$$y_{5NINAPRO} = y_{i,j,k} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + \varepsilon_{ijk} \quad (37)$$

Já as análises envolvendo a base IEE tem como TAG e TAP, respectivamente enquanto variáveis de resposta (y_4) e (y_5) definidas pelos seguintes controláveis: os cinco (i) métodos componentes da classificação confiável (α), os quatro (j) variações de ensaios (β) realizadas pelos quatro (k) voluntários distintos (γ) em suas três (l) repetições (δ) executadas. A ANOVA relativa a TAP da base IEE, é acrescida de um fator (η) relativo aos 18 (m) movimentos distintos executados durante os testes. Os modelos relativos às taxas de resposta são descritos na Equação (38) para a TAG e na Equação (39) para a TAG.

$$y_{4IEE} = y_{i,j,k,l} = \mu + \alpha_i + \beta_j + \gamma_k + \delta_l + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\alpha\delta)_{il} + (\beta\gamma)_{jk} + (\beta\delta)_{jl} + (\gamma\delta)_{kl} + (\alpha\beta\gamma)_{ijk} + (\alpha\beta\delta)_{ijl} + (\beta\gamma\delta)_{jkl} + \varepsilon_{ijk} \quad (38)$$

$$\begin{aligned}
y_{5IEE} = y_{i,j,k,l,m} = & \mu + \alpha_i + \beta_j + \gamma_k + \delta_l + \eta_m + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\alpha\delta)_{il} + (\alpha\eta)_{im} + \\
& (\beta\gamma)_{jk} + (\beta\delta)_{jl} + (\beta\eta)_{jm} + (\gamma\delta)_{kl} + (\alpha\beta\gamma)_{ijk} + (\alpha\beta\delta)_{ijl} + (\alpha\beta\eta)_{ijm} + (\beta\gamma\delta)_{jkl} + \\
& (\beta\gamma\eta)_{jkm} + (\beta\delta\eta)_{jlm} + (\gamma\delta\eta)_{klm} + (\beta\delta\eta)_{jlm} + (\alpha\beta\gamma\delta)_{ijkl} + (\alpha\beta\gamma\eta)_{ijkm} + \\
& (\beta\gamma\delta\eta)_{jklm} + \varepsilon_{ijklm} \quad (39)
\end{aligned}$$

- 3) As análises relativas ao modelo de classificação resiliente segue os mesmos modelos descritos na Equação (38) e na Equação (39), respectivamente, com a diferença de o fator controlável métodos (α) ser composto pelas quatro (i) variações de classificação utilizadas para a validação.

5 RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados e discussões provenientes da metodologia proposta. Buscando oferecer maior espaço aos desenvolvimentos mais recentes desta Tese, resultados preliminares contendo avaliações prévias em relação a comparação de métodos não-iterativos, métodos mais usuais como a Regressão Logística e o SVM, variações de canais e *features* e diferentes filtros utilizados no pré-processamento encontram-se nos APÊNDICES C, e D deste manuscrito. Assim, esta seção é focada nas análises de 1 à 7 apresentadas na última subseção do capítulo anterior, onde a versão padrão (STD) do RELM é a equivalente à apresentada na Figura 16, assim como a sua versão suavizada é apresentada na Figura 23. Ambos os modelos foram utilizados como base para o desenvolvimento das diferentes arquiteturas relativas a versão confiável e a versão resiliente do classificador, ambas apresentadas em diagramas de blocos de alto nível na Figura 21.


5.1 COMPARAÇÃO ENTRE ELM, RELM E DIFERENTES TEMPOS DE SEGMENTAÇÃO

Nesta seção são comparadas as versões básicas do classificador na abordagem de Moore-Penrose (ELM) e *Ridge-Regression* (RELM), sendo a segunda a versão regularizada. Foi analisado também o efeito da segmentação nas taxas de acerto cada base de dados. Os resultados são apresentados na Figura 26 e na Figura 27 para a base NINAPro não-amputados (NAMP) e na Figura 28 para a base NINAPro amputados (AMP). Já a Figura 29 e a Figura 30 apresentam os resultados obtidos pelo ELM e RELM, respectivamente, para os diferentes ensaios da base IEE.

Um dos resultados que se repete em todas as bases e métodos é a diferença entre as taxas de acerto global (TAG) e ponderada (TAP). Essa diferença, frequentemente omitida na literatura, se dá em função de um *bias* de classificação gerado pela “classe repouso”. Na perspectiva de classificação, o repouso é bastante distinto das demais classes, sendo caracterizado pela ausência ou presença quase nula da ativação muscular. Assim, mesmo modelos com taxas de acerto individuais baixas, tendem a classificar o repouso com taxas satisfatórias. Especificamente para a base NAMP, a diferença entre as TAG e TAP é representada na Figura 26.a e na Figura 26.c usando o ELM, enquanto os resultados relacionados ao RELM são apresentados na Figura 27.a e na Figura 27.c. Em ambas as figuras, a TAP é representada pelos gráficos de barra e a TAG pelas linhas², que sempre apresentam um resultado significativamente superior.

² As linhas demonstram a TAG para os diferentes voluntários ou ensaios presentes em cada base.

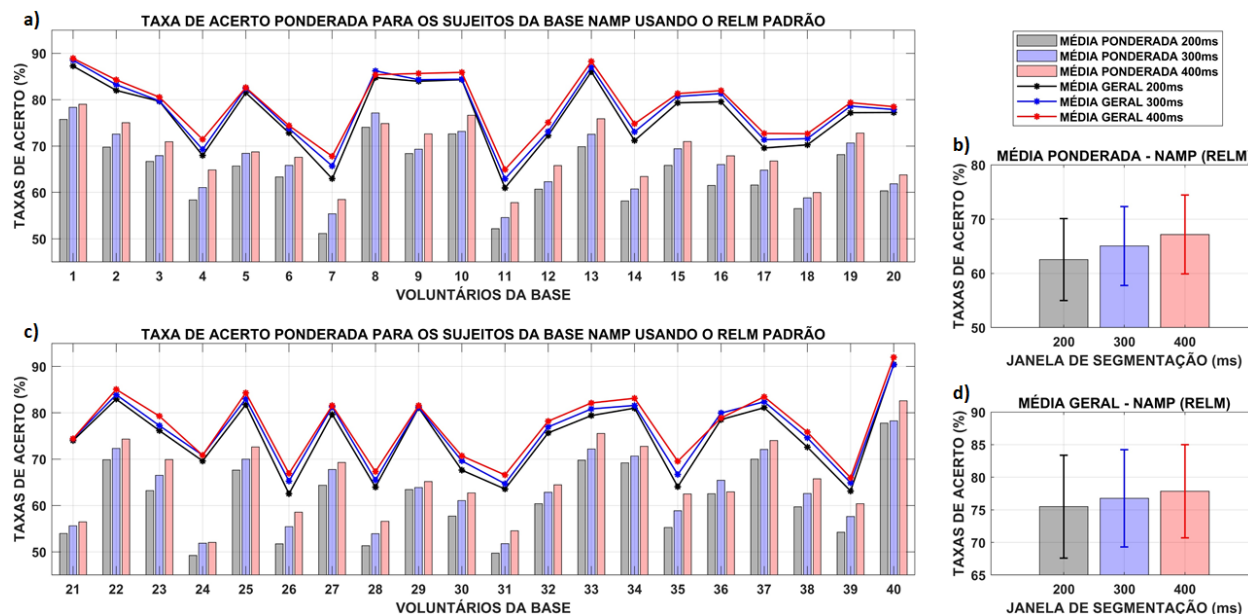
Figura 26 - Taxas de acerto do ELM padrão para a base NAMP: as figuras a) e c) representam as taxas de acerto global e ponderadas individuais obtidas para cada voluntário, enquanto as figuras b) e d) representam as taxas de acerto ponderadas por classe e médias gerais obtidas, respectivamente. Ambas as métricas são representadas em função da variação do tamanho da janela de segmentação.



Fonte: Elaboração própria.

Outro fator marcante nos resultados para todas as bases foi a tendência proporcional das taxas de acerto em relação ao tamanho de janela de segmentação utilizada. Este resultado já era esperado uma vez que alguns artigos na literatura já relatam este efeito (KUZBORSKIJ *et al.*, 2012; FARRELL, 2011). Portanto, na escolha deste parâmetro, uma heurística mais conservadora tende a apostar em janelas mais longas de segmentação e incremento. Entretanto, os tempos de incrementos escolhidos são também responsáveis por parte importante da resposta dinâmica do sistema, definindo o tempo mínimo no qual o classificador poderá oferecer uma resposta. Desta forma, ao mesmo tempo que utilizar um incremento mais longo para as janelas deslizantes tende a proporcionar taxas de acerto mais elevadas (em consequência do uso de amostras mais representativas), também pode impossibilitar uma resposta proprioceptiva adequada para o controle de dispositivos, prejudicando a usabilidade através da inserção de atrasos de resposta. Geralmente a definição destes parâmetros depende da aplicação, porém existem estudos na área (FARRELL, 2011) que indicam que um *delay* de resposta inferior a 125 ms é desejável ao controle natural por parte dos usuários, sem a indução de erros de controlabilidade nas taxas de acerto dos classificadores utilizados.

Figura 27 - Taxas de acerto do RELM padrão para a base NAMP: as figuras a) e c) representam as taxas de acerto global e ponderadas individuais obtidas para cada voluntário. As figuras b) e d) representam as taxas de acerto ponderadas por classe e média geral obtidas respectivamente, em função da variação da segmentação.



Fonte: Elaboração própria.

Ambas as métricas referentes às taxas de acerto apresentam variação, relacionadas não só aos tempos de segmentação, mas também à versão do classificador utilizado. A versão regularizada apresenta resultados mais altos por uma margem que, embora pequena (geralmente em torno de 2,0% para a TAP e 1% para a TAG em cada configuração dos diferentes tempos de segmentação utilizados), ainda é estatisticamente significativa. Pelas taxas médias apresentadas na Figura 26.c e na Figura 26.d e também na Figura 27.c e na Figura 27.d, que ilustram resultados derivados do ELM e RELM, respectivamente, na base NAMP, observa-se uma diferença consistente – $\cong 5,0\%$ em ambos os métodos para a base NAMP e $\cong 4,0\%$ em ambos os métodos para a base AMP – entre a segmentação que utiliza 200ms e a que utiliza 400ms para uma mesma versão do classificador. Este efeito pode ser observado em ambas as bases NINAPro e também nas bases IEE (variações de 3,5% a 5,0%, dependendo do ensaio). Tanto em relação à variação do tempo de segmentação quanto ao método utilizado, o desempenho de ambos os métodos apresenta variações proporcionais bastante similares onde, de forma geral, as menores taxas de acerto ocorrem para o ELM com segmentos de 200ms e as maiores no RELM com segmentos de 400ms. Esses resultados derivam do aumento das taxas de acerto individual de cada classe obtidas com o RELM e as janelas de 400ms, e podem ser apresentados com mais clareza nas TAPs de cada base de dados que não

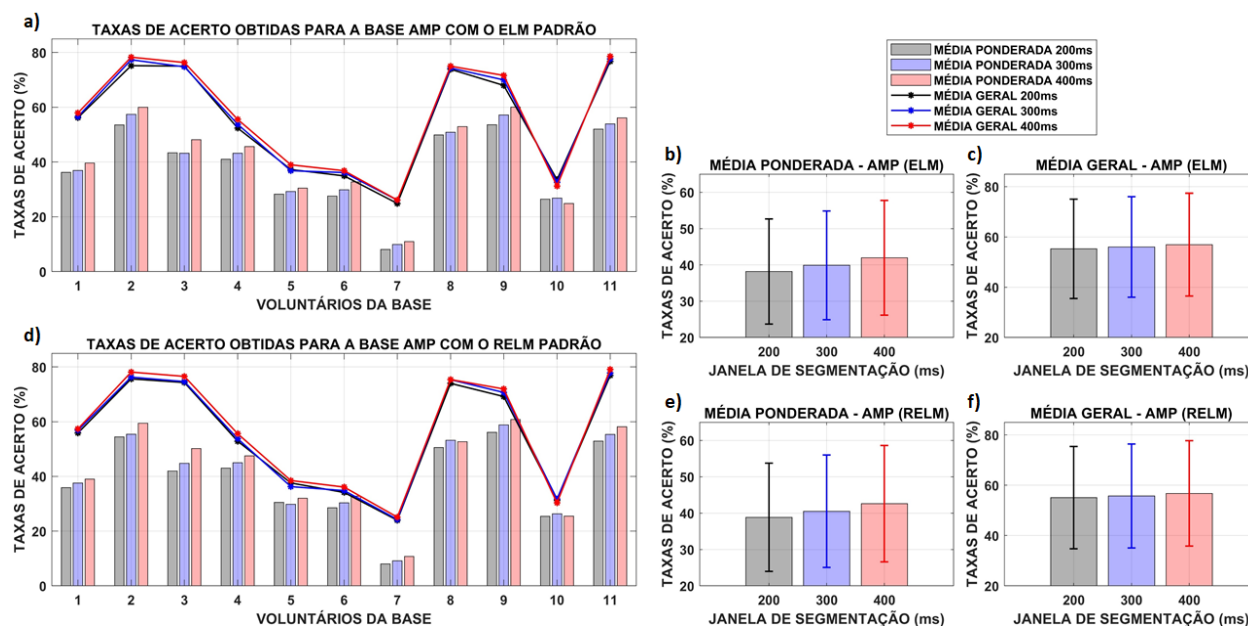
possui a influência da classe repouso mitigando este efeito. O aumento das taxas de acerto nestas condições deve-se à utilização de um classificador regularizado, mais robusto ao *overfitting* e treinado por dados mais representativos. É importante observar que o próprio tamanho de janela utilizado tem um efeito de filtro passa-baixas nas *features* geradas, considerando-se que elas são formadas por um universo de dados maior, capaz de fornecer mais informação a cada segmento utilizado. Para o melhor caso da base NAMP, composto pelo RELM e janelas de 400ms, foi obtida uma TAG de $77,85 \pm 7,14\%$ e uma TAP de $67,17 \pm 6,26\%$. Já o pior resultado ocorre com o ELM e janelas de 200ms, onde a TAG foi de $74,56 \pm 8,05\%$ enquanto a TAP foi de $60,35 \pm 7,35\%$.

Uma análise de variância (ANOVA) foi realizada conforme a Equação (35) para a determinação de fatores influenciadores de ambas as métricas de taxa de acerto. Assim como as outras ANOVAs deste subcapítulo, o nível de significância adotado foi $p < 0,01$. Para ambas métricas de taxa de acerto (TAP e TAG), a análise demonstrou que os três fatores (*método*, *segmentação* e *voluntário*) são significativos tanto quando analisados individualmente quanto em suas interações de segundo grau. Esse resultado indica que a base testada através dos métodos escolhidos apresenta taxas de acerto distintas e estatisticamente significativas, conforme a escolha dos parâmetros de tempo, de segmentação e de método de classificação utilizados. Portanto, em abordagens futuras – e assim foi feito para as abordagens propostas desta Tese – é desejável a utilização da combinação que favoreça a maior taxa de acerto possível, que neste caso, foi o RELM utilizando janelas de 400ms. A significância estatística da variável *voluntário* já era esperada e foi confirmada uma vez que os sinais a serem classificados possuem comportamento estocástico bastante marcante e dependente de cada sujeito, o que afeta diretamente a classificação dos sinais. Já os resultados provenientes da base AMP são apresentados na Figura 28.

Assim como as taxas obtidas na classificação da base NAMP, os resultados apresentados na Figura 28 para a base AMP ilustram a diferença entre as duas métricas de saída em favor da TAG. É interessante observar também a diferença entre os resultados médios obtidos pelas bases NAMP e AMP ($>20,00\%$), que evidenciam a dificuldade de obter modelos suficientemente descritivos para os voluntários amputados em função da representatividade do sinal adquirido. Embora alguns voluntários da base AMP como o 2º, o 9º e o 11º apresentem taxas de acerto globais e ponderadas melhores do que as de alguns voluntários não-amputados, o que ressalta a importância da experiência do usuário para este tipo de interface, como já observado em outros trabalhos relacionados (ATZORI *et al.*, 2014). O voluntário 7 teve o pior resultado dentre todos os

sujeitos testados neste trabalho. A avaliação da TAG ($\cong 26,10\%$) obtida para o 7º voluntário da base AMP em ambas versões do classificador traduz a ineficiência no reconhecimento de padrões obtida, mesmo para a classe de repouso. Este voluntário é especialmente problemático em relação aos sinais adquiridos em função do seu grau transumeral de amputação, o que torna impossível a utilização dos canais 9 e 10 do eletromiógrafo (ATZORI *et al.*, 2014). Os canais 9 e 10 são os responsáveis pela aquisição relacionada à ativação dos músculos extensores e flexores de dedos, respectivamente. Dessa forma, a ausência destes canais prejudica em muito o reconhecimento dos oito primeiros movimentos da base, que são basicamente movimentos de dedos. O mesmo ocorre para o voluntário 6, com a diferença do nível de amputação, já que o sexto voluntário desta base ainda possui 40% do seu antebraço, e por consequência, alguma musculatura residual.

Figura 28 - Taxas de acerto do classificador para a base AMP de acordo com a segmentação utilizada, onde: a) representa as taxas ponderadas e globais obtidas pelo ELM padrão; b) representa as médias ponderadas e c) as médias globais para toda a base de acordo com a variação da janela de segmentação. Similarmente, d) representa as taxas ponderadas e globais obtidas pelo RELM padrão, e) representa as médias ponderadas e f) as médias globais para toda a base, nas mesmas situações de variação de tamanho de janela de segmentação.



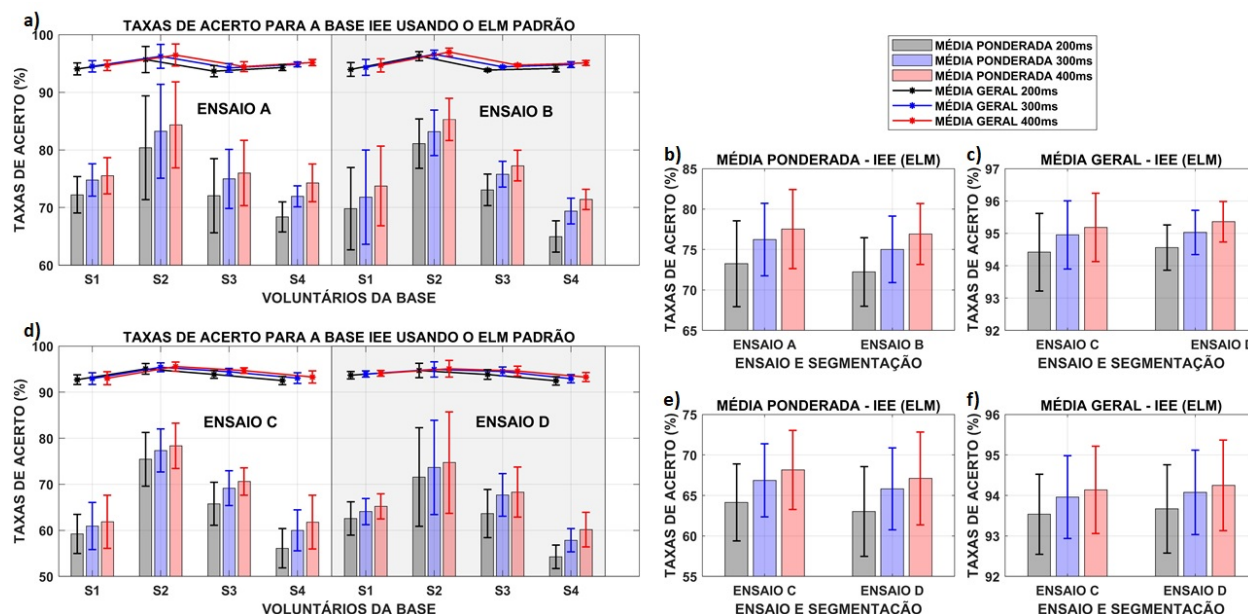
Fonte: Elaboração própria.

A diferença de taxas de acerto oferecida pela variação de métodos de classificação para a base AMP não é tão marcante ($< 1,0\%$) quanto para os voluntários da base NAMP, embora a variação de tamanho das janelas de segmentação ainda provoque diferenças nas taxas de resposta notáveis da Figura 28.a e da Figura 28.d que, embora não sejam tão óbvias quanto as da base

NAMP, ainda demonstram ser estatisticamente significativas. No melhor caso, onde o RELM e janelas de 400ms foram utilizadas, a TAG foi de $56,74 \pm 21,00\%$, enquanto a TAP foi de $42,63 \pm 16,02\%$. Ainda que as taxas sejam consideravelmente menores que as da base NAMP, os resultados apresentam melhoras quando comparados ao trabalho de ATZORI *et. al.*, 2014, que relata 46,27% para a DB3, como apresentado na Tabela 4.

Assim como na base NAMP, foi realizada uma ANOVA ($p < 0,01$), conforme apresentado na Equação (35), para determinar quais fatores controláveis influenciam as duas métricas de taxa de acerto. Para a base AMP, houve uma relevância distinta dos fatores controláveis conforme a métrica de resposta analisada. Para a TAG, a variação do *método* não apresentou significância estatística. Da mesma forma a interação *método* \times *segmentação* também foi estatisticamente insignificante. As outras duas variáveis e interações demonstraram afetar significativamente a variável de resposta tanto isoladamente quanto na sua interação. Esse resultado, de forma geral, traduz a incapacidade de ambos os métodos, independentemente da segmentação adotada, de formar um modelo de classificação adequado. Desta forma, os classificadores tendem a atingir taxas de acerto baixas para cada movimento individual e, quando a TAG é calculada, a classe repouso acaba por mitigar a ineficiência do classificador, gerando uma taxa de acerto global média muito similar para a base independentemente do método e segmentação utilizados, como apresentado na Figura 28.c e na Figura 28.f. Já na TAP, que não sofre o efeito da classe repouso em demasia, todos os fatores demonstraram ser estatisticamente significativos quando testados isoladamente. Ao mesmo tempo, as interações *método* \times *segmentação* e *método* \times *voluntário* não afetaram significativamente essa variável de saída. Esse resultado confirma e generaliza a conclusão obtida na TAG para a base AMP. A insignificância estatística destas duas interações representa a incapacidade dos métodos (mesmo o RELM), de gerar um modelo apropriado e gerar taxas de acerto distintas entre si, o que se repete para voluntários e segmentações distintas. Esse resultado reforça que, embora as estratégias envolvendo classificadores regularizados e diferentes tamanhos de segmentação tenham potencial de impacto significativo nos resultados obtidos, elas ainda serão ineficazes se o sinal a ser classificado carecer de representatividade e repetitividade em suas amostras. Esse resultado demonstra a dificuldade de gerar métodos eficientes para a classificação de sEMG de amputados. A Figura 29 apresenta os resultados obtidos nos diferentes ensaios da base IEE para o ELM enquanto os resultados derivados do RELM são apresentados na Figura 30.

Figura 29 - Taxas de acerto do ELM para os diferentes exercícios da base IEE, onde a), b) e c) abordam os ensaios sequenciais A e B, que possuem 6 e 10 repetições, respectivamente e d), e) e f) apresentam as taxas obtidas para os ensaios com movimentos aleatórios C e D, que também possuem 6 e 10 repetições, respectivamente.



Fonte: Elaboração própria.

Como nas bases NINAPro, as quatro variações de ensaios realizados na base IEE apresentam diferença significativa entre as métricas de TAG e TAP. Ainda em relação aos diferentes ensaios realizados, e considerando ambas as métricas de acerto, é notável a distinção ($\cong 10,00\%$) entre os ensaios sequenciais (A e B) e aleatórios (C e D). Dentro destas categorias é observável também a regularidade dos resultados entre os ensaios sequenciais e em um patamar mais baixo, entre os ensaios aleatórios. Esses resultados indicam claramente que a ordem na qual os movimentos são realizados no teste afetam diretamente os resultados obtidos. Na base IEE é importante levar em consideração a divisão de dados de treinamento e teste realizada. O ENSAIO A seguiu a mesma abordagem dos trabalhos envolvendo a base NINAPro, onde a segunda e a quinta repetição de movimentos são utilizadas para teste do modelo enquanto as demais são utilizadas para o treino. Essa ordem é assumida em trabalhos envolvendo as bases NINAPro AMP e NAMP, possivelmente buscando melhorar a generalização dos modelos, formando um modelo mais balanceado, evitando a demasiada influência de repetições iniciais no treino e finais no teste.

Os resultados obtidos no ENSAIO A servem também como métrica de validação da base IEE em comparação com as bases NINAPro, oferecendo taxas de acerto em ambas as métricas superiores àquelas obtidas nas outras bases. Entretanto, vale ressaltar que a base IEE, por ainda

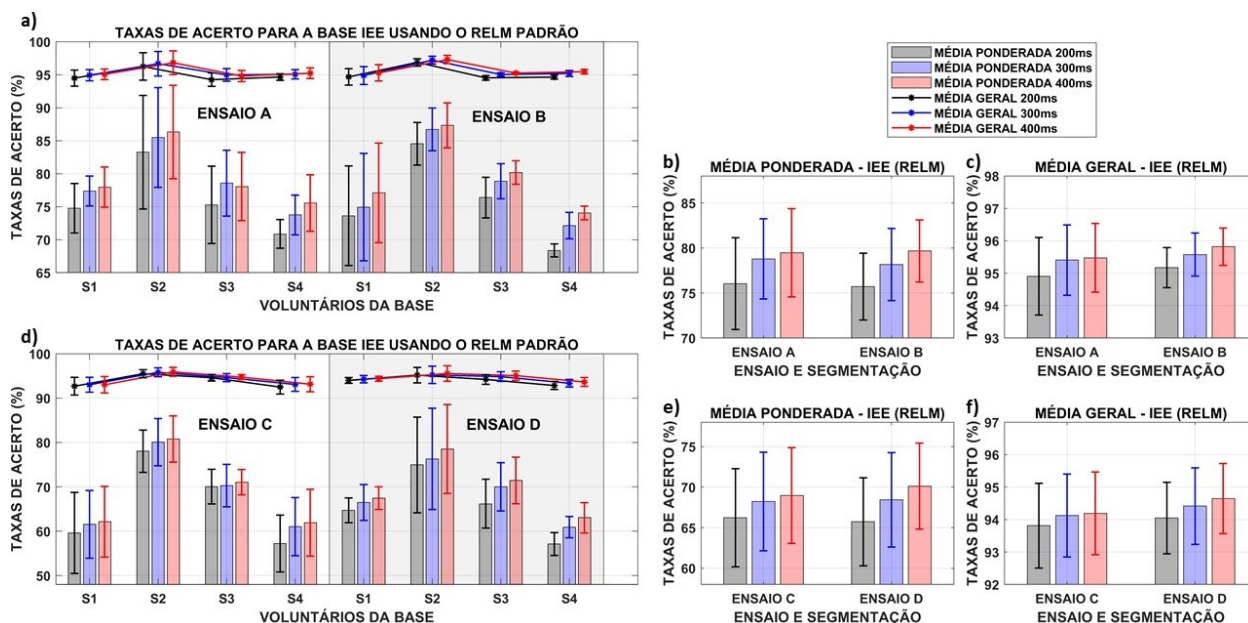
estar em desenvolvimento, possui uma restrição em relação ao número de voluntários quando comparada às bases NINAPro. Nas bases IEE, o resultado é muito influenciado pela classe repouso, que é predominante nas bases em função dos vídeos auxiliares que preparam cada voluntário para a próxima execução de movimento.

Já no ENSAIO B, as seis primeiras repetições foram utilizadas para o treino enquanto as quatro últimas para o teste. Em C e D, manteve-se a proporção de 66% para treino e 33% para teste do modelo, entretanto as repetições de cada movimento foram armazenadas na ordem aleatória na qual ocorreram no teste e depois unidas apropriadamente. A preocupação dos autores das bases NINAPro em utilizar repetições alternadas para evitar algum viés de classificação (ATZORI *et al.*, 2014) parece não se confirmar para os ensaios sequenciais da base IEE, considerando que mesmo com essa heurística utilizada no ENSAIO B, ainda assim, resultados muito próximos aos do ENSAIO A foram obtidos. Vale salientar que no ENSAIO B e no ENSAIO D, quatro repetições de cada movimento são testadas em oposição a duas repetições do ENSAIO A e do ENSAIO C. Portanto, esse resultado indica que os métodos em suas versões básicas apresentam uma taxa de acerto consistente por classes, que tende a se manter – e até aumentar um pouco – mesmo quando mais repetições dos movimentos treinados são testadas. O RELM, que é capaz de generalizar mais o modelo e atingir taxas de acerto maiores para cada classe individual, apresenta uma TAP ligeiramente superior em relação ao ELM para todas as condições testadas.

Embora o mesmo efeito de aumento da taxa de acerto ocorra no ENSAIO D quando comparado ao ENSAIO C, ambos apresentam taxas menores em relação aos ENSAIOS A e B. Estes resultados são consequência da execução aleatória dos movimentos a serem reproduzidos por cada voluntário. De fato, mesmo com a utilização de uma janela auxiliar para mostrar qual seria o próximo movimento a ser realizado, foi percebida uma certa confusão por parte dos voluntários que por vezes começavam o movimento de forma errônea, o confundindo com algum outro da base. Embora não seja possível afirmar que houve algum efeito de aprendizagem na execução dos movimentos por parte dos voluntários, ao menos é coerente que eles executem os movimentos dos ensaios sequenciais com maior regularidade, quando comparados aos ensaios aleatórios. Essa execução mais regular, tende a gerar *features* mais repetitivas e consistentes que favorecem a classificação, explicando as diferenças das TAP entre os diferentes ensaios da base. Ainda em relação aos voluntários (indicados de S1 a S4), é notável que o segundo voluntário da

base (S2) apresenta um desempenho consistentemente superior aos outros, o que possivelmente guarda relação com suas características fisiológicas, como citado por (KUZBORSKIJ *et al.*, 2012).

Figura 30 - Taxas de acerto do RELM para os diferentes exercícios da base IEE, onde a), b) e c) abordam os ensaios sequenciais A e B, que possuem 6 e 10 repetições, respectivamente e d), e) e f) apresentam as taxas obtidas para os ensaios com movimentos aleatórios C e D, que também possuem 6 e 10 repetições, respectivamente.



Fonte: Elaboração própria.

A influência da classe de repouso nas TAGs da base IEE é bastante evidente quando comparada às bases NINAPro e possibilitam taxas superiores a 90% nas variações dos quatro ensaios realizados. Enquanto as bases NAMP e AMP possuem $\cong 40\%$ de dados de repouso, os ensaios IEE A e B possuem $\cong 65\%$ e os ensaios IEE C e D possuem $\cong 70\%$. Esta presença predominante da classe repouso na base IEE deve-se ao tempo adotado para a demonstração na interface gráfica do próximo movimento a ser reproduzido pelo voluntário. Nos ensaios aleatórios foi acrescido ainda 1 segundo adicional ao começo e fim de cada leitura do arquivo de vídeo correspondente ao movimento em questão para evitar *delays* na apresentação ao voluntário. Estes resultados demonstram a importância da utilização da métrica de TAP, que dissolve o *bias* gerado pela classe de repouso, geralmente predominante nos testes e que podem levar a conclusões superficiais e equivocadas. Um exemplo prático deste efeito é a classificação do ENSAIO D da base IEE, que no ELM para 200ms tem uma TAG $\cong 92\%$ enquanto sua TAP é $\cong 65\%$. A Tabela 9 apresenta as taxas de acerto médias obtidas para cada ensaio e cada variação de segmento da base IEE de forma quantitativa para demonstrar a diferença entre as duas métricas de saída do sistema.

Tabela 9 – Taxas de acerto global e ponderada médias, obtidas por ambos os métodos de classificação para a base IEE considerando os diferentes tempos de segmentação. (Fonte: autor).

MÉTODO	ENSAIO	TAP (%)			TAG (%)		
		200ms	300ms	400ms	200ms	300ms	400ms
ELM	A	73,25 ± 5,30	76,23 ± 4,47	77,53 ± 4,89	94,42 ± 1,20	94,95 ± 1,05	95,18 ± 1,05
	B	72,23 ± 4,23	75,02 ± 4,11	76,92 ± 3,76	95,56 ± 0,70	95,03 ± 0,68	95,36 ± 0,62
	C	64,14 ± 4,75	66,86 ± 4,51	68,15 ± 4,87	93,54 ± 0,99	93,96 ± 1,02	94,14 ± 1,08
	D	63,02 ± 5,53	65,82 ± 5,06	67,10 ± 5,73	93,67 ± 1,09	94,07 ± 1,04	94,25 ± 1,12
RELM	A	76,04 ± 5,10	78,79 ± 4,46	79,47 ± 4,90	94,91 ± 1,20	95,41 ± 1,08	95,47 ± 1,06
	B	75,72 ± 3,71	78,16 ± 4,00	79,67 ± 3,44	95,17 ± 0,62	95,58 ± 0,66	95,82 ± 0,58
	C	66,22 ± 6,05	68,24 ± 6,07	68,97 ± 5,90	93,81 ± 1,31	94,13 ± 1,28	94,19 ± 1,27
	D	65,73 ± 5,43	68,42 ± 5,82	70,11 ± 5,30	94,05 ± 1,10	92,42 ± 1,18	94,65 ± 1,80

Para a validação estatística dos resultados da base IEE, uma ANOVA ($p < 0,01$) foi novamente realizada. Como apresentado na Equação (35), os fatores controláveis do modelo foram *método*, *segmentação*, *ensaio*, *voluntário* e *repetição*. Pela natureza diferente da base IEE, que envolve mais fatores em comparação às bases NINAPro, uma análise de fatores isolados e interações em até quatro níveis foi conduzida. Assim como na base NINAPro NAMP, todos os fatores isolados mostraram-se estatisticamente significativos. Na análise de interação de primeiro grau, tanto para a TAP quanto para a TAG, as interações *método* × *repetição* e *segmentação* × *repetição* foram estatisticamente insignificantes, o que é um reflexo do efeito dos fatores *método* e *segmentação*, que dependente de seu arranjo, podem atingir taxas equivalentes em relação às diferentes repetições executadas por cada usuário. Um bom exemplo disso é o fato de ser possível atingir praticamente a mesma taxa de acerto com diferentes arranjos do tempo de segmentação e tipo de método. Por exemplo, na Tabela 9 pode-se observar que para o ENSAIO A é possível atingir praticamente a mesma taxa de acerto em ambas as métricas ao utilizar-se a combinação ELM e 300ms ou RELM e 200ms. De fato, a combinação destes dois fatores se mostra estratégica neste tipo de teste ao passo que afeta ambas as métricas de avaliação em suas variações. Estes resultados indicam a importância da utilização do classificador em sua forma regularizada (RELM), sendo ele capaz de compensar a escolha do tempo de segmentação, que quando utilizado em seu limite superior (400ms) leva às maiores taxas de acerto encontradas nos testes.

Nos demais níveis de interação, para ambas as métricas, todas as interações que envolvem *método* × *repetição* não se apresentaram estatisticamente significativas, o que indica que a

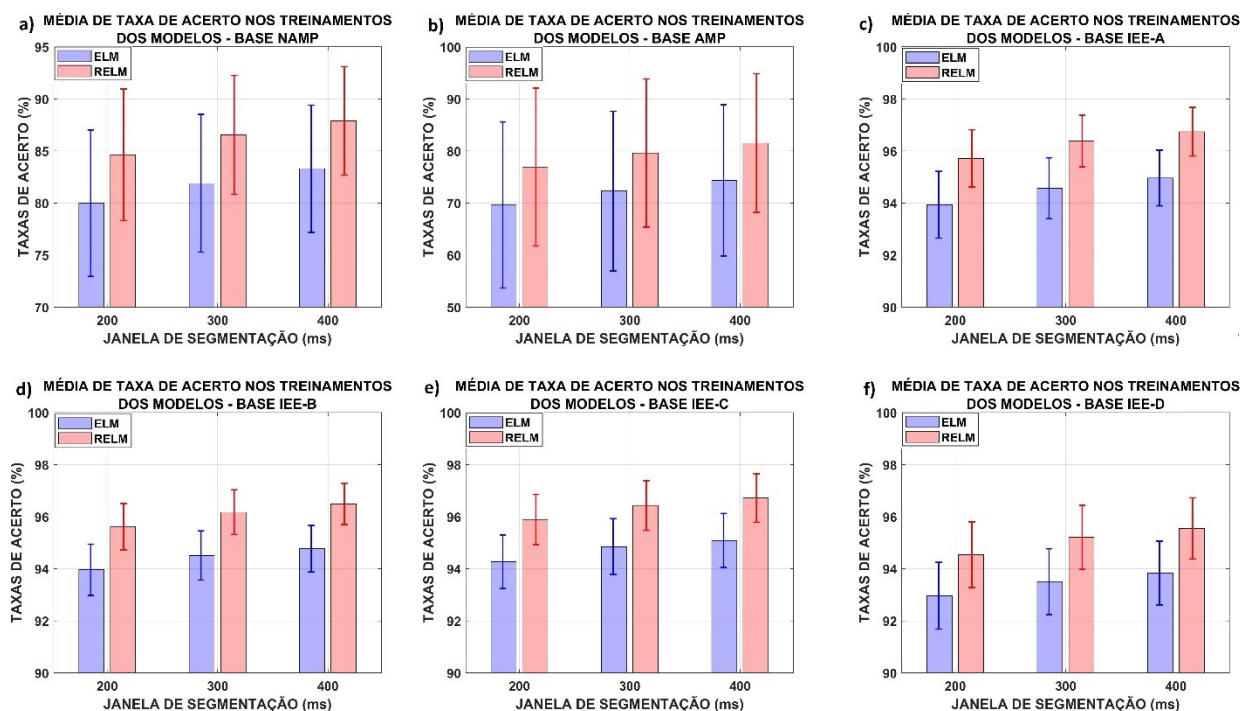
combinação destes fatores pode compensar taxas para um mesmo *ensaio*, *voluntário* ou *repetição*, inclusive algumas delas combinadas, mas não todas ao mesmo tempo. Na interação de segundo nível, para a TAP, as interações *segmentação* \times *ensaio* \times *voluntário* e *segmentação* \times *ensaio* \times *repetição* foram estatisticamente insignificantes. Resultado esse, explicado pelo fato de algumas repetições constituírem *outliers* do modelo, o que demonstra a capacidade da influência do usuário no sistema, independente das estratégias abordadas para o processamento e classificação.

Já para a TAG, ambas interações foram estatisticamente insignificantes assim como a interação *segmentação* \times *voluntário* \times *repetição*. Como já esperado, menos fatores influenciam a TAG, que é menos sensível por sofrer influência da classe repouso. As demais interações de fatores não comentadas demonstraram-se todas significativas na ANOVA realizada.

De forma geral, os resultados (TAG) para estas versões básicas dos classificadores – de $77,85 \pm 7,14\%$ para base NAMP e $56,74 \pm 21,00\%$ para a base AMP – são equivalentes ou superiores em relação aos trabalhos citados na literatura que utilizam as bases NINAPro e encontram-se sintetizados na Tabela 4. Os resultados atingidos provêm da utilização da versão regularizada do classificador (testado para $p < 0,01$), que é capaz de generalizar melhor o modelo de classificação, de combinação da janela de segmentação de $400ms$, e de estratégias de processamento de sinal baseadas no Filtro AVT e na *feature* DES adotada, que conjuntamente, tendem a gerar dados mais representativos melhorando a separação entre classes e por consequência a classificação.

Indiretamente, a separação entre classes pode ser inferida através da taxa de acerto de treinamento do classificador, como apresentado na Figura 31. Em todas as bases houve um melhoramento desta taxa em função da utilização da versão regularizada do classificador e da utilização de segmentos maiores do sinal. Modelos melhor treinados geram classificações mais consistentes e um valor de *arg max* – e por consequência, de confiabilidade – mais alto para cada amostra de saída. Um classificador base mais robusto que tende a oferecer melhores taxas de acerto e o aumento da confiabilidade, mas também tende a reduzir o efeito dos métodos de pós-processamento utilizados na versão confiável do classificador, que são menos acionados devido a maior regularidade do *arg max*. Ainda na Figura 31, é possível observar claramente a vantagem da base IEE frente às outras e também a maior dificuldade de se formar um modelo adequado para a base AMP, o que, inevitavelmente, acaba refletindo destrutivamente na taxa de acerto obtida por esta base.

Figura 31 - Taxas de acerto de treino dos modelos para as variações de tamanho de segmento utilizado em ambas versões do classificador, onde: a) corresponde à base NAMP; b) corresponde à base AMP; c) corresponde ao ENSAIO A da base IEE; d) apresenta os resultados derivados do ENSAIO B da base IEE enquanto e) e f) correspondem aos resultados oriundos do ENSAIO C e ENSAIO D, respectivamente.



Fonte: Elaboração própria.

Além da validação dos métodos de pré-processamento e da base gerada, de forma geral, os resultados obtidos nesta etapa do projeto serviram para guiar a escolha do modelo de classificação e do tempo de segmentação adequados aos desenvolvimentos posteriores envolvendo os métodos de pós-processamento. Baseado nestes resultados, a forma regularizada do método (RELM) e segmentos de 400+10ms foram escolhidos para a realização da forma confiável e da forma resiliente do classificador. Embora taxas satisfatórias já tenham sido alcançadas em função dos métodos de pré-processamento e regularização é esperado que alguns desenvolvimentos desta Tese melhorem estes resultados significativamente em relação ao método base e aos trabalhos apresentados no subcapítulo 3.2.2.

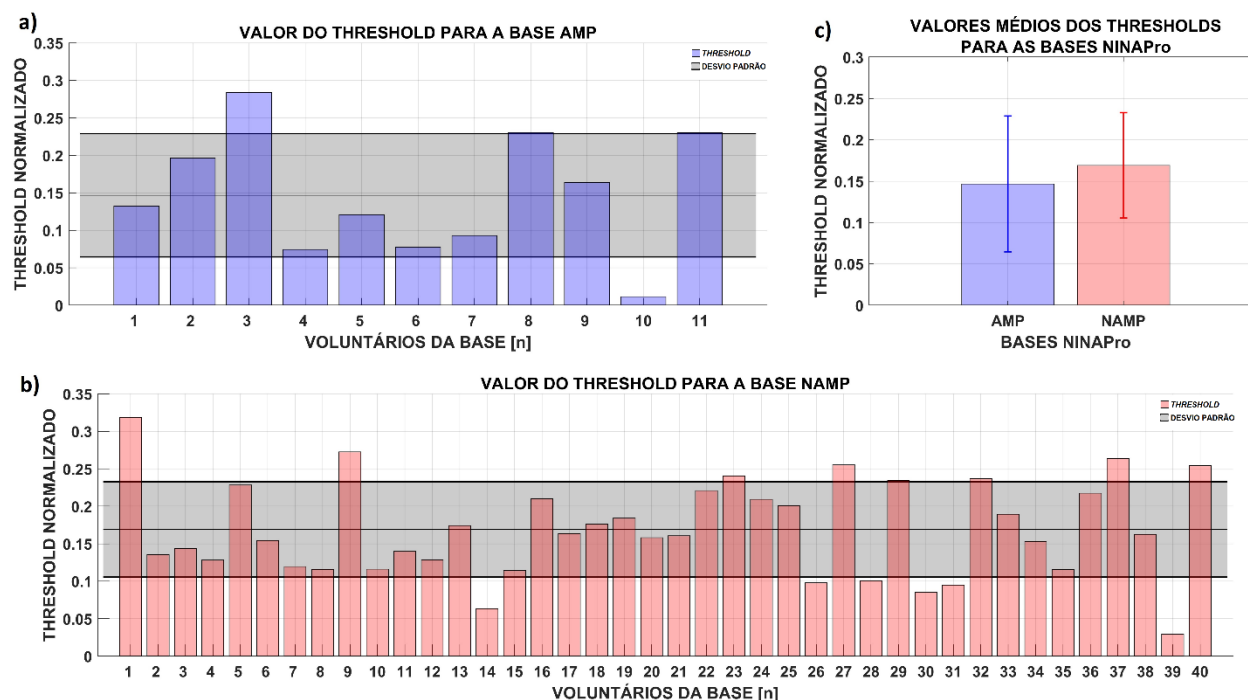
5.2 AVALIAÇÃO DE MÉTRICAS SECUNDÁRIAS DA CLASSIFICAÇÃO CONFIÁVEL

Neste subcapítulo são analisadas as métricas secundárias relacionadas à classificação confiável. Visando apresentar os resultados mais claramente, as análises foram divididas entre as

bases de dados NINAPro e IEE. As métricas consistem no valor de *threshold* para a definição de amostras não-confiáveis e porcentagem de amostras consideradas não-confiáveis em cada ensaio.

Considerando que todos os métodos utilizados na classificação confiável com exceção do MKV são ativados quando a condição de *threshold* apresentada na Equação (30) é satisfeita, torna-se interessante também a avaliação desse parâmetro, que é gerado autonomamente para cada usuário. Desta forma é possível verificar a consistência desta métrica e/ou a existência de algum padrão entre bases/voluntários que permita adaptações futuras para potencializar esta abordagem. A Figura 32 apresenta os valores de *threshold* obtidos para cada “*trial*” (cada coleta de dados realizada) das bases NINAPro enquanto a Figura 33 apresenta os mesmos resultados para os diferentes ensaios da base IEE.

Figura 32 - Valores médios de *threshold* \pm desvio padrão por base (zona sombreada) e valores de *threshold* individuais gerados para as bases: a) AMP e b) NAMP. Já em c) é apresentado o valor médio geral de *threshold* para ambas as bases.

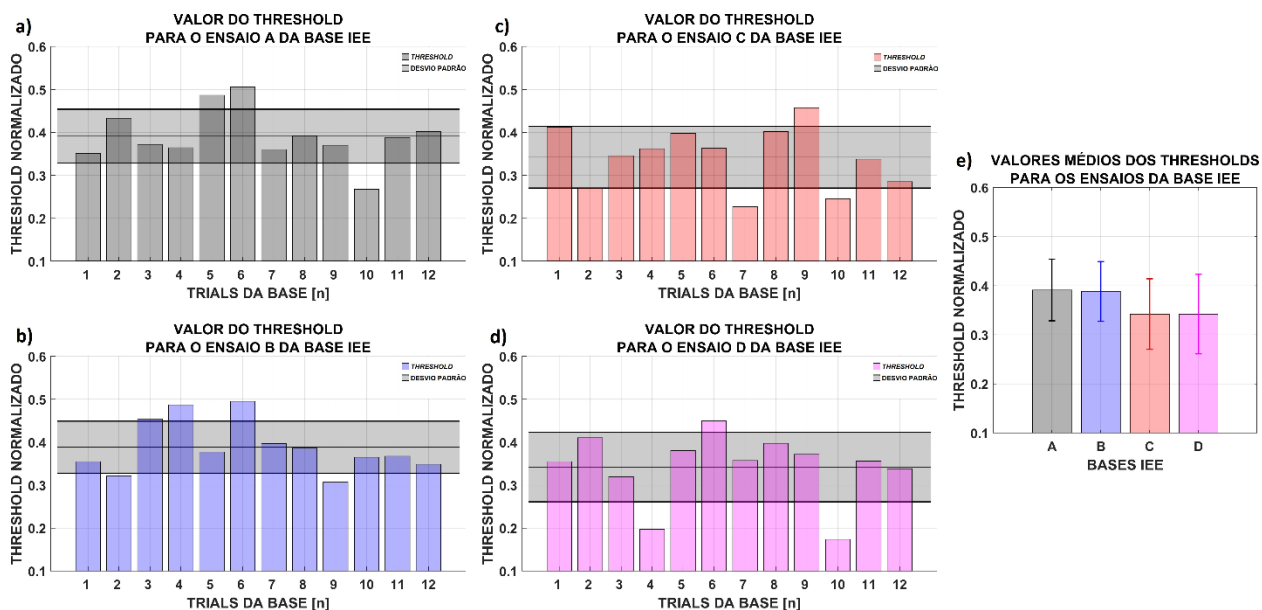


Fonte: Elaboração própria.

Assim como outros parâmetros envolvidos no processamento do sEMG, a métrica de confiabilidade gerada, e por consequência o *threshold* de ativação, também possuem característica estocástica e altamente dependente dos sujeitos em questão. A Figura 32 indica que a métrica da confiabilidade, assim como as taxas de acerto obtidas no subcapítulo anterior variam ainda mais para os voluntários amputados. Este efeito já era esperado, dada a dificuldade usual de se obter um

treinamento adequado do modelo para os sujeitos amputados. Vale lembrar que idealmente, uma amostra com alta confiabilidade seria gerada por ser similar o suficiente a um universo de amostras de uma determinada classe utilizadas no treinamento do classificador. Similaridade esta, dificilmente encontrada nos sinais de sEMG e ainda mais rara em indivíduos com amputação, devido à falta de tônus muscular ou fisioterapia adequada para o fortalecimento da musculatura residual. Desta forma, embora os valores de *threshold* normalizados sejam próximos para os voluntários AMP (0,147) e NAMP (0,169), o desvio padrão da base AMP cobre um range bastante amplo, com valores de limite inferior próximo a 0,06 enquanto que na base NAMP, esse mesmo limite inferior é superior a 0,1.

Figura 33 - Taxas de *threshold* individual por *trial* e geral para cada ensaio da base IEE, onde: a), b) abordam os ensaios sequenciais A e B, que possuem 6 e 10 repetições, respectivamente e c) e d) tratam dos valores dos *threshold* derivados dos ensaios de movimentos realizados aleatoriamente também em 6 e 10 repetições, respectivamente. Já e) apresenta a média geral obtida em cada ensaio e a área cinza retangular nos quatro primeiros *subplots* indica a média e desvio padrão de cada base.



Fonte: Elaboração própria.

Tanto na Figura 32 quanto na Figura 33, a área preenchida em cinza claro delimita a excursão da média \pm desvio padrão onde a média é definida para toda a base considerando cada média individual dos voluntários que compõe a base em questão. Embora obter uma média baixa não necessariamente signifique que o voluntário terá uma taxa de acertos baixa, isso é esperado, tendo em vista que o *threshold* é definido com base na média do teste inteiro que é predominantemente formado pela classe de repouso. Classe essa, que tende a atingir valores muito


próximos ao máximo, considerando que é bastante distinta das outras e geralmente não é afetada por ruídos de classificação. Desta forma, ter um valor muito baixo do *threshold*, como os voluntários 9 da base AMP ou 39 da base NAMP, indica que provavelmente nem mesmo a classe de repouso está sendo classificada com uma separação de classes e confiabilidade apropriadas. De forma complementar, os voluntários AMP 3 e o NAMP 1 ou NAMP 40 possuem taxas de acerto relativamente altas que acompanham o seu *threshold*, também acima da média de cada base. Já os valores de *threshold* relativos aos ensaios da base IEE também sofrem a influência da classe repouso e para todos os ensaios, apresentam no mínimo o dobro (0,342) do valor normalizado encontrado como média nas bases NINAPro. Os resultados derivados da base IEE são apresentados na Figura 33.

Na Figura 33 cada ensaio é composto por 12 *trials*, representando quatro voluntários realizando três repetições cada. Desta forma os *trials* 1-3 consistem nas repetições do voluntário 1, os *trials* 4-6 nas repetições do voluntário 2, assim como 6-9 foram três repetições executadas pelo voluntário 3 e 10-12 pelo voluntário 4. Em função das repetições, é possível conferir na Figura 33, que a característica estocástica marcante do sEMG se estende a esta métrica inclusive em repetições realizadas por um mesmo voluntário. Vale observar também que as bases construídas a partir da execução de movimentos aleatórios apresentam valores médios mais baixos em relação aos ensaios A e B, o que guarda relação com as taxas de acerto também mais baixas obtidas por estas bases. A Figura 34 apresenta a porcentagem de dados modificados ou descartados pelo modelo confiável do classificador nas bases NINAPro enquanto a Figura 35 apresenta a mesma taxa em relação aos diferentes ensaios da base IEE.

Outra métrica secundária bastante importante no conceito deste trabalho é a porcentagem de dados abaixo do *threshold* para cada *trial*. Esta métrica torna-se ainda mais importante em função da utilização do método DISC, de tal forma que é inútil obter uma taxa de acerto muito elevada ao custo de descartar-se juntamente a quase totalidade dos dados. A comparação entre a Figura 32 e a Figura 34 e da Figura 33 com a Figura 35 sugere que principalmente na base AMP, o percentual de dados afetados pelos métodos é proporcional ao valor de *threshold* encontrado, com voluntários que possuem um *threshold* mais alto sofrendo mais atuação dos métodos propostos enquanto o voluntário 10, por exemplo, quase não é afetado. Nas demais bases, embora exista uma tendência neste sentido, muitas vezes voluntários que obtiveram um valor bem abaixo da média da base exibem, ainda assim, percentuais acima da média de dados afetados pela

heurística proposta. Estes resultados demonstram que embora um *threshold* mais alto favoreça a aplicação das técnicas, é necessária uma adequação mínima do classificador em relação aos dados testados para a geração de um valor razoável de confiabilidade mínima. Essa confiabilidade então, dá espaço à excursão do sinal com uma variância que atenda as condições de *threshold* e possibilite a utilização dos métodos. Dessa forma, o método poderia ainda beneficiar-se de uma figura de mérito que descreva a variância de valores entre classes, ou ainda a definição de valores individuais para cada classe, o que tende a permitir o acionamento do método de forma mais seletiva e a mitigação da influência exacerbada da classe repouso no sistema.

Figura 34 - Percentual de dados abaixo do *threshold* e, portanto, afetados pelos métodos de pós-processamento da versão confiável do RELM. Os resultados foram analisados em suas bases distintas, onde: a) apresenta a porcentagem de dados afetados na base AMP e b) apresenta a porcentagem de dados afetados na base NAMP. Já c) apresenta as médias obtidas em ambas as bases NINAPro.




Fonte: Elaboração própria.

Assim como os valores de *threshold* encontrados, até mesmo repetições de um mesmo voluntário caracterizam-se por diferentes percentuais de dados modificados pelos métodos propostos. As bases NINAPro seguiram a tendência do *threshold* obtido onde a base AMP teve uma média de $14,00 \pm 6,16\%$ contra um percentual de $16,68 \pm 3,37\%$ da base NAMP. Já na base IEE, os menores percentuais - por uma margem muito pequena - foram obtidos nos ensaios contendo 10 repetições de movimentos que tiveram médias muito próximas, sendo elas $12,20 \pm 0,92\%$ e $12,10 \pm 1,11\%$ para os ensaios B e D, respectivamente. Já os percentuais médios

dos ensaios contendo 6 repetições de movimentos tiveram valor de $12,32 \pm 1,40\%$ e $12,25 \pm 0,80\%$ para os ensaios A e C, respectivamente. As taxas ligeiramente menores dos ensaios com 10 repetições são consequência, tanto da presença ainda maior da classe repouso onde geralmente não ocorrem modificações na classificação devido a níveis altos de confiabilidade relacionados às classificações, quanto à quantidade de dados de teste, que é aproximadamente o dobro nestas bases. Sabendo o percentual de dados modificados pelo modelo confiável do classificador, é possível analisar mais apropriadamente os efeitos de cada um dos métodos propostos, que têm seus resultados expostos na próxima seção.

Figura 35 - Taxas de acerto do RELM para os diferentes exercícios da base IEE, onde a), b) e c) abordam os ensaios sequenciais A e B, que possuem 6 e 10 repetições, respectivamente e d), e) e f) apresentam as taxas obtidas para os ensaios com movimentos aleatórios C e D, que também possuem 6 e 10 repetições, respectivamente.

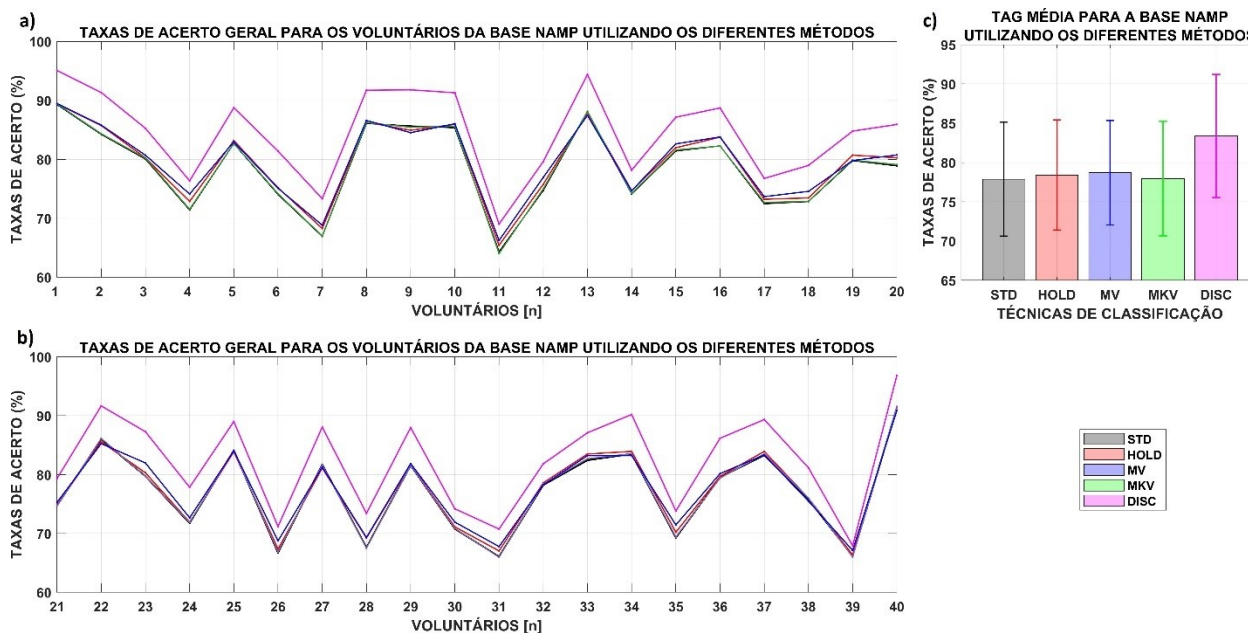


Fonte: Elaboração própria.

5.3 COMPARAÇÃO DE MODELOS UTILIZADOS NA CLASSIFICAÇÃO CONFIÁVEL

Neste subcapítulo são tratados os resultados derivados das diferentes alternativas que compõe a versão confiável do classificador. Idealmente os métodos desenvolvidos devem potencializar a classificação padrão, adicionando uma característica de filtro passa-baixas nos *labels* de saída ou descartando classificações de não-confiáveis. Em relação às taxas alcançadas, a Figura 36 apresenta os resultados da TAG enquanto a Figura 37 apresenta os resultados de TAP, ambos para a base NINAPro NAMP.

Figura 36 - Taxas de acerto global da base NAMP obtidas pelos métodos componentes do modelo de classificação confiável do RELM, onde são apresentadas: a) taxas de acerto individual (voluntário 1 a 20); b) taxas de acerto individual (voluntário 21 a 40) e c) taxas de acerto médio por método utilizado.



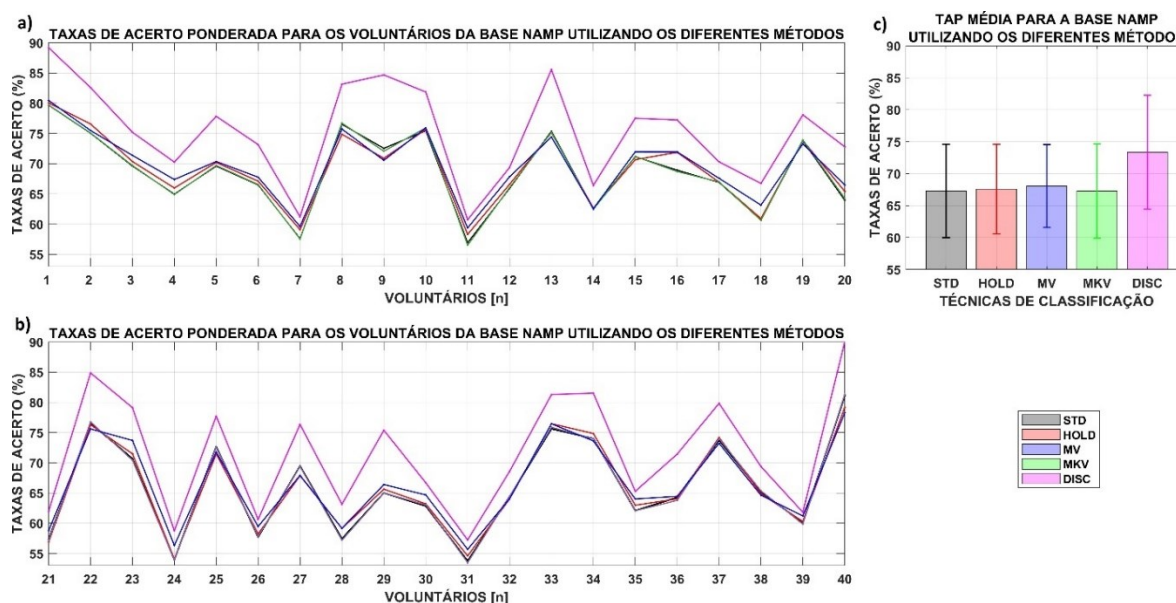
Fonte: Elaboração própria.

Analisando a Figura 36 e a Figura 37, observa-se que o método baseado no Modelo Markoviano (MKV) não mostrou eficiência para melhorar nenhuma das taxas de acerto. De fato, o modelo fica quase sobreposto ao classificador padrão (STD), que corresponde ao RELM com *features* extraídas de janelas de 400ms. Parte da ineficiência do MKV pode ser explicado pelo fato de o classificador original já oferecer uma classificação bastante satisfatória para as bases envolvidas, deixando pouca margem de melhoramento ao MKV. Outra hipótese da ineficiência do MKV baseia-se no fato de que o modelo tende a encontrar dificuldade de generalização para bases que possuem muitas amostras consecutivas de uma mesma classe, o que pode inclusive provocar *overfitting* e saturar o modelo formado. Neste sentido seria interessante testar outros modelos de classificação já conhecidos pela sua capacidade de abstração de características em séries temporais como o *Long Short-Term Memory* (LSTM), que é uma rede neural recorrente que se destaca pelo manejo deste tipo de efeito (MACHADO, CENE & BALBINOT, 2019).

Uma hipótese que se confirmou através da utilização do MKV e um dos motivadores do seu uso foi a mitigação de ruídos de classificação entre movimentos ativos. Este ruído de classificação caracteriza-se pela transição para a classe de um determinado movimento enquanto qualquer outro que não seja o repouso está sendo executado. Neste aspecto o MKV mostrou-se

eficiente. Entretanto, como na abordagem do classificador padrão utilizada (STD) este já era um fenômeno forçosamente raro (uma vez que trocas entre classes constituem uma porção ínfima dos *labels* de saída quando comparados ao total de dados classificados), ele acaba não causando um grande impacto nas taxas de acerto. Muitas vezes, entretanto, foi observado que o MKV substituiu a transição errônea para um outro movimento, pela transição errônea para a classe de repouso, o que de um ponto de vista experimental pode ser menos prejudicial à utilização da interface, mas que ainda pode impedir um controle proprioceptivo apropriado.

Figura 37 - Taxas de acerto ponderado da base NAMP obtidas pelos métodos componentes do modelo de classificação confiável do RELM, onde são apresentadas: a) taxas de acerto individual (voluntário 1 a 20); b) taxas de acerto individual (voluntário 21 a 40) e c) taxas de acerto médio por método utilizado.

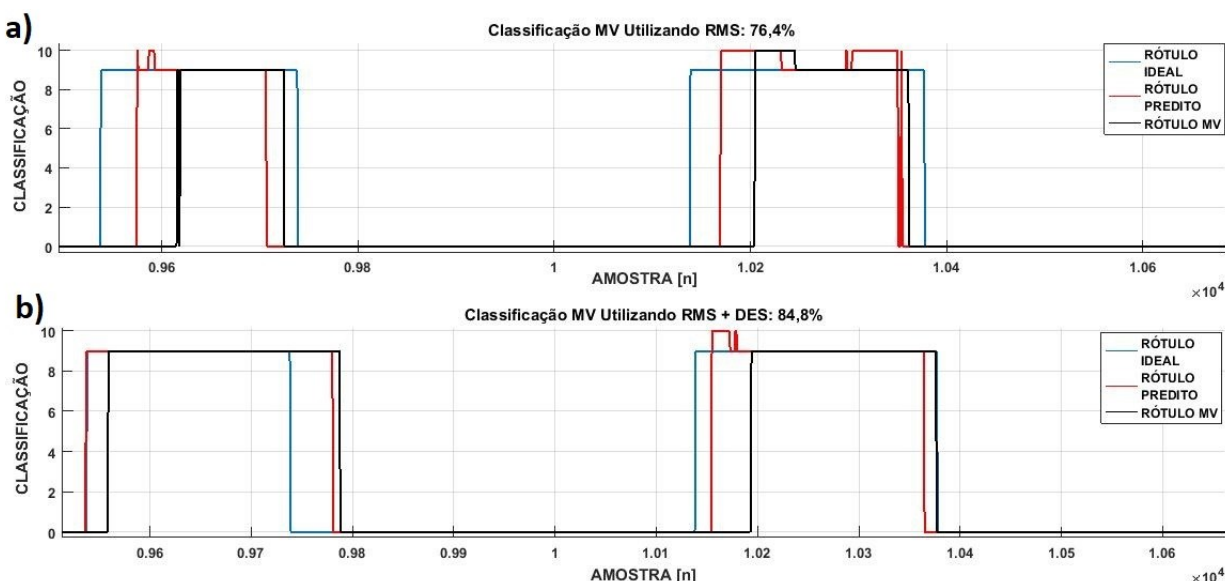


Fonte: Elaboração própria.

Já o MV constitui um método de pós-processamento clássico com comportamento de filtro passa-baixas a nível de tratamento de *labels*. Contrariando alguns resultados obtidos em estudos anteriores (CENE & BALBINOT, 2018a), onde a utilização do MV diminuiu levemente as taxas de acerto se comparado ao classificador padrão, neste trabalho, o MV apresentou a maior taxa de melhora (embora discreta), em relação aos métodos que não envolvem descarte de amostras. No trabalho anterior a menor taxa de acerto obtida com a utilização do MV deu-se em função da classificação predita apresentar latências no começo e final dos movimentos e também ruídos de classificação na parte intermediária do sinal. Nos três casos mencionados geralmente havia a ocorrência de várias amostras consecutivas sendo classificadas erroneamente. Desta forma, no começo do movimento, a utilização do MV costuma atrasar o início da transição do repouso para

algum movimento ativo. Do mesmo modo, ao término do movimento, o MV costumava provocar um atraso para a classificação voltar ao período de repouso, o que tende a aumentar a taxa de erros. Esses experimentos prévios, como apresentados em (CENE & BALBINOT, 2018a), foram realizados com o RELM, janelas deslizantes de $300+15ms$ para a segmentação e cinco amostras foram consideradas para o MV. Além disso, somente uma (RMS) ou duas features (RMS + DES) eram utilizadas por vez na entrada do sistema, o que apesar de gerar taxas de acerto compatíveis com a literatura, deixava o classificador mais instável, como apresentado na Figura 38.

Figura 38 - Efeito da aplicação do MV para amostras abaixo do threshold.




Fonte: Elaboração própria.

Esta carência na representatividade dos sinais foi compensada pela própria versão padrão do classificador, que agora utiliza-se de janelas de $400ms$ e um conjunto mais amplo de *features* para a representação do sinal. Um aspecto que se manteve tanto para testes anteriores como para os resultados mais recentes foi a capacidade do MV apresentar melhores resultados nas porções intermediárias dos movimentos. Mesmo com essa melhora, em testes anteriores o MV não era capaz de compensar o a latência introduzida na resposta do sistema, o que acabava prejudicando mais do que beneficiando a taxa de classificação.

A determinação do efeito de “filtragem de classificação” desempenhada pelo MV pode ser realizada pelo aumento ou diminuição do número de amostras consideradas no método. Este número, quando aumentado, ocasiona um acréscimo considerável no tempo de resposta, que tende a ficar proporcionalmente menos sensível à dinâmica do sistema. Em contrapartida, a escolha de

poucas amostras pode não oferecer o efeito de filtragem desejado ao sinal. A Figura 38 apresenta (na cor preta) a saída gerada pelo MV em comparação à saída de desejada (na cor azul) e à saída predita pelo classificador padrão (na cor vermelha), onde destaca-se o *delay* introduzido pelo método no início dos movimentos. Para as novas configurações de dados de entrada utilizadas neste trabalho, o MV foi capaz de acompanhar de forma mais adequada o *label* fornecido pelo classificador padrão, o que aumentou as taxas de acerto tornando o MV o método de pós-processamento capaz de atingir as maiores taxas médias nesta versão do classificador. Já o efeito do método HOLD na classificação do sinal é apresentado na Figura 39.

Figura 39 - Efeito da aplicação do método HOLD para amostras abaixo do *threshold*.



Fonte: Elaboração própria.


No mesmo trabalho anterior (CENE & BALBINOT, 2018a), a ação de “HOLD” (manter a última classificação confiável até que uma nova ocorra), possibilitou a melhora na taxa de acerto em praticamente todos os ensaios. O resultado do HOLD é explicado por ele oferecer uma resposta mais rápida em relação ao MV, sendo mais sensível às transições abruptas. Este comportamento é particularmente útil nas zonas de transição entre movimentos, onde o HOLD não introduzia tanta latência de resposta quanto o MV. Entretanto o HOLD possui um efeito de filtragem do *label* mais sutil do que o MV, como mostrado na Figura 39. Com as novas configurações de entrada utilizadas, o comportamento do HOLD manteve-se o mesmo, porém o fato da classificação base ser mais consistente e gerar classificações mais confiáveis mitigou consideravelmente o efeito do HOLD, que agora oferece um incremento muito discreto às taxas de acerto base encontradas pelo RELM em sua configuração padrão, como apresentado na Figura 37.

Dentre todos os métodos testados para a classificação confiável dos sinais de sEMG, o método de descarte (DISC), que dota o sistema da capacidade de ignorar classificações de amostras consideradas não representativas ou não confiáveis, oferece o aumento mais substancial em ambas taxas de acerto para todas as bases de dados. O resultado demonstrou a influência destrutiva destas amostras de baixa confiabilidade na classificação dos movimentos realizados. Ainda, o método demonstrou a validade da métrica de saída utilizada sendo que, ao se ignorar as amostras consideradas pouco confiáveis, a taxa de acerto aumenta substancialmente em todas as bases, inclusive chegando perto do máximo possível para a TAG na base IEE. Como apresentado na Figura 37, o efeito do método de descarte (DISC) se faz muito presentemente também na TAP do sistema. Isto é justificado pelas amostras de mais baixa confiabilidade geralmente pertencerem a períodos de movimentos ativos, onde há uma maior sobreposição de classes, tendo em vista que geralmente a classe repouso é bastante distinta das demais e não sofre este efeito. Dessa forma, aumentar as taxas de acerto individuais de cada movimento descartando amostras não confiáveis leva a um aumento substancial na média geral do sistema. Complementarmente, relacionando as taxas de acerto obtidas aos valores de *threshold* e as porcentagem de dados afetados pelas técnicas propostas, é possível estabelecer uma correlação direta e proporcional entre estes fatores para os voluntários 1, 9, 27, 37 e 40, por exemplo, o que ajuda a validar a métrica gerada ao menos no método de seleção autônoma de entradas.

Assim como nas análises prévias, uma ANOVA ($p < 0,01$) para cada base de dados e cada métrica de saída foi realizada para a validação estatística dos resultados apresentados como descrito na Equação (36) para a TAG e na Equação (37) para a TAP, respectivamente. Na análise da TAG, tanto os fatores *método* e *voluntário* mostraram-se significativos em análises considerando e excluindo o método DISC (que é obviamente significativo dadas as suas taxas muito altas). Na análise estatística da TAP, os fatores de *método*, *voluntário* e *movimento* foram considerados significativos quando testados isoladamente e em uma interação pareada considerando o DISC na análise. Ao retirar-se o DISC, o fator *método* mostrou-se não-significativo, o que é explicado pela proximidade dos resultados obtidos e pela melhora bastante modesta das taxas de acerto nas outras abordagens fora a DISC. Este resultado mostra que o classificador suficientemente bem treinado não necessita dos outros métodos para obter o mesmo patamar de TAP para a base NAMP. Entretanto o descarte autônomo e seletivo de amostras não representativas beneficia em muito o classificador, que tiveram sua TAG e TAP para a base NAMP

aumentadas aproximadamente em 5,50% e 6,00%, respectivamente. Já a Figura 40 e a Figura 41 apresentam os resultados da aplicação das técnicas para a base AMP, considerando a TAG e a TAP, respectivamente.


Figura 40 - Taxas de acerto global da base AMP para os métodos do RELM confiável para: a) cada voluntário da base e b) a média da base inteira.



Fonte: Elaboração própria.

Em geral é possível observar os mesmos comportamentos dos métodos em relação a base de dados de voluntários amputados. Bem como para ambas as métricas de taxa de acerto, o classificador padrão (STD) e o MKV possuem desempenho equivalente assim como o HOLD e o MV, embora em um patamar um pouco superior de taxa de acerto. A diferença mais notável é provocada novamente pelo método DISC, que para a maioria dos usuários apresenta uma taxa visualmente maior em ambas as métricas.

Figura 41 - Taxas de acerto ponderado da base AMP para os métodos do RELM confiável para: a) cada voluntário da base e b) a média da base inteira.



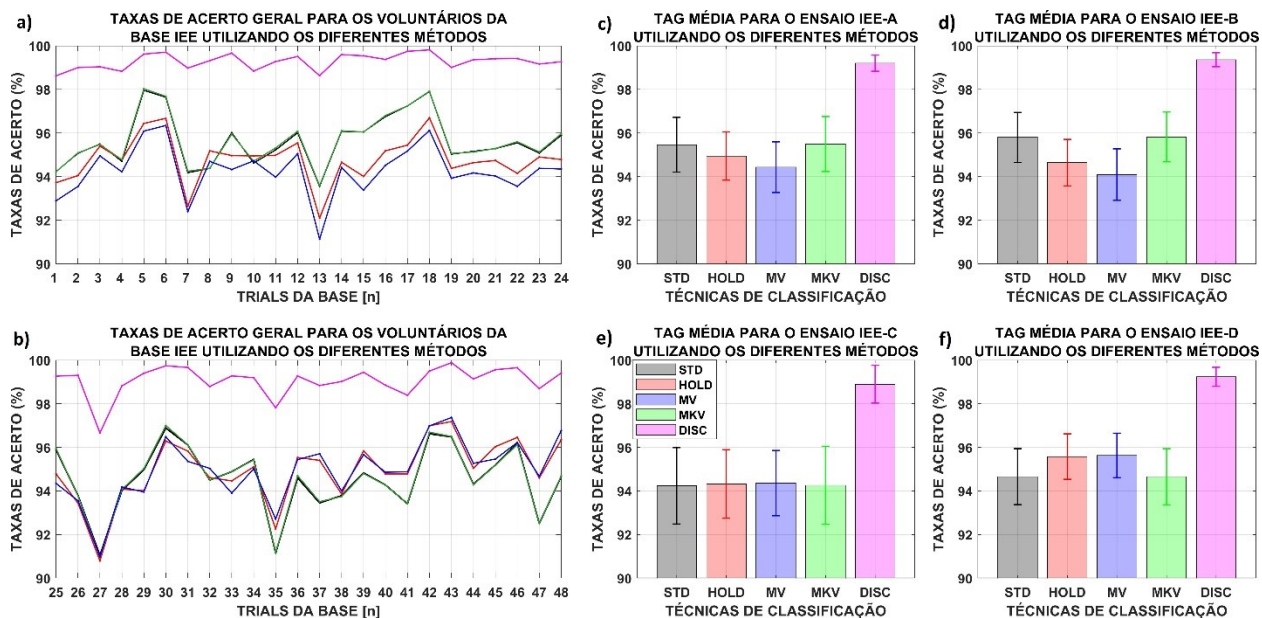
Fonte: Elaboração própria.

Dos resultados obtidos, assim como nos testes preliminares, o voluntário 7 possui a menor taxa de acerto em ambas as métricas de acerto. Igualmente, para os voluntários 6 e 10, os métodos propostos também provocaram resultados insignificantes. Os resultados praticamente idênticos para o voluntário AMP 10 são resultado da porcentagem quase nula de dados modificados para este voluntário específico, que possui o menor dentre todos os valores de *threshold* obtidos neste

estudo. Já os voluntários AMP 2, 3, 8, 9 e 11, que têm os maiores valores de *threshold* obtidos na base e também o maior percentual de dados modificados, apresentam as maiores taxas de acerto em ambas as métricas de resposta. Este resultado, corrobora com o argumento de que embora a confiabilidade seja uma métrica adequada a ser utilizada juntamente à técnicas de processamento, ela depende de um sinal com um mínimo de qualidade e consistência para a formação de um classificador confiável. Os voluntários 6 e 7 também possuem valores reduzidos de *threshold*, o que pode ser explicado pela ausência de canais devido ao seu grau de amputação (como mencionado no Subcapítulo 5.1), o que prejudica em muito a formação de modelos adequados principalmente para o GRUPO 1 e GRUPO 3 de movimentos, que são focadas em movimentos de dedos e pulso. Já os voluntários 1 e 4 apresentaram taxas compatíveis à voluntários amputados, que são geralmente um pouco mais baixas do que as obtidas por voluntários NAMP. Embora exista uma dificuldade muito maior na construção de classificadores confiáveis a partir de dados provenientes de amputados, resultados bastante expressivos foram obtidos para os voluntários 2, 3, 8, 9 e 11, que na TAG apresentam alguns resultados próximos a 90%. Os resultados relativos a TAP da base AMP que segue a mesma tendência da TAG são apresentados na Figura 41.

Os mesmos fatores controláveis e variáveis de resposta do teste para a base NAMP foram utilizados para a validação estatística dos resultados obtidos através de uma ANOVA ($p < 0,01$) conforme apresentado na Equação (36) e na Equação (37). Na análise da TAG, tanto o fator *método* quanto o fator *voluntário* foram considerados significativos em análises incluindo e excluindo o DISC. Já para a TAP, assim como na base NAMP, os fatores *método*, *voluntário* e *movimento* foram considerados. Os fatores foram testados isoladamente e em uma interação pareada e para ambos os casos se mostraram significativos. Mais uma vez, foram retirados os dados oriundos do método DISC e a ANOVA foi repetida. Desta vez, a interação *método* \times *voluntário* mostrou-se não-significativa, demonstrando que as diferenças de TAP obtidas para os diferentes métodos são insignificantes quando os dados provêm de uma mesma fonte (voluntário). Assim como para a base NAMP, este resultado mostra que o classificador suficientemente bem treinado não necessita dos outros métodos para obter o mesmo patamar de TAP. Desta forma, o método de descarte autônomo e seletivo de amostras oferece novamente o maior benefício em relação às taxas de acerto que tem sua TAG e TAP aumentadas aproximadamente em 5,50% e 4,00%, respectivamente. Já os resultados relativos a aplicação das técnicas na base IEE são apresentados em função de TAG na Figura 42 e TAP na Figura 43, respectivamente.

Figura 42 - Taxas de acerto global para os ensaios da base IEE, sendo a) resultados dos *trials* das bases A e B, b) resultados dos *trials* das bases C e D, c) médias para o ENSAIO A, d) médias para o ENSAIO B, e) médias para o ENSAIO C e f) médias para o ENSAIO D.



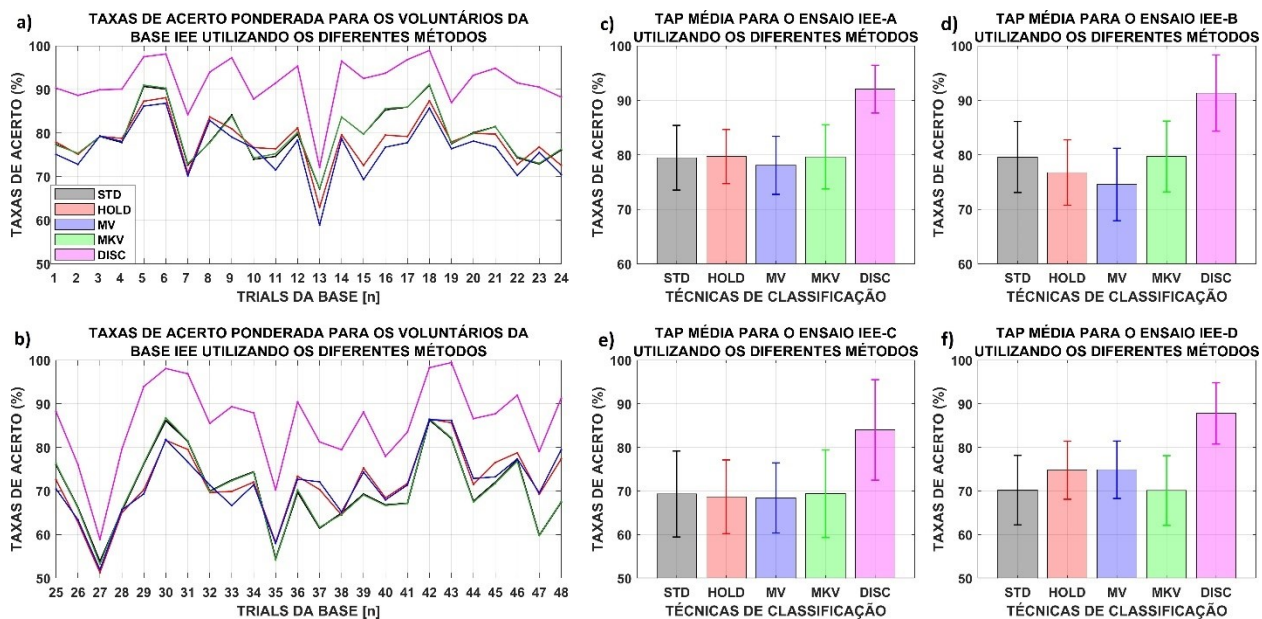
Fonte: Elaboração própria.

Na Figura 42 e na Figura 43, os 48 *trials* correspondem a cada execução de uma das três repetições realizadas por cada um dos quatro voluntários nas quatro variações de ensaios da base IEE. Em ambas as figuras, o ENSAIO A é composto dos *trials* 1-12 enquanto o ENSAIO B é composto dos *trials* de 13-24, já o ENSAIO C engloba os *trials* 25-36 e o ENSAIO D os *trials* de 37-48. Similarmente, os voluntários e repetições estão organizados de maneira incremental, sendo 1-3 as repetições do voluntário 1; 4-6 as repetições do voluntário 2; 7-9 as do voluntário 3; 10-12 as repetições do voluntário 4 e assim, incrementalmente até os *trials* 46-48, que são as três repetições do ENSAIO D realizadas pelo voluntário 4. Nesta seção foi preferido mostrar os resultados para todos os *trials* do que mostrar uma média das três repetições, como apresentado pela Figura 29 e Figura 30, no subcapítulo anterior.

De forma geral, a base IEE apresenta taxas de acerto significativamente mais altas para o ENSAIO A, que é comparável à base NAMP em ambas as métricas da taxa de acerto. Apesar da base IEE ainda ter bem menos sujeitos do que a base NAMP, isto indica que os procedimentos experimentais adotados são coerentes e formam uma base propícia aos testes realizados. Em relação aos métodos testados, as repostas foram distintas conforme cada ensaio realizado e métrica de taxa de acerto considerada sendo uma constante para todos os ensaios a equivalência entre as taxas de acerto do método base e do modelo markoviano (MKV) pelos mesmos motivos

mencionados nas análises das bases NINAPro. Já os métodos HOLD e MV, provocaram variações diferentes nos diferentes ensaios. Sabendo que as TAG sofrem demasiada influência da classe repouso, as análises serão focadas nas TAP obtidas nos diferentes ensaios contidos na base.

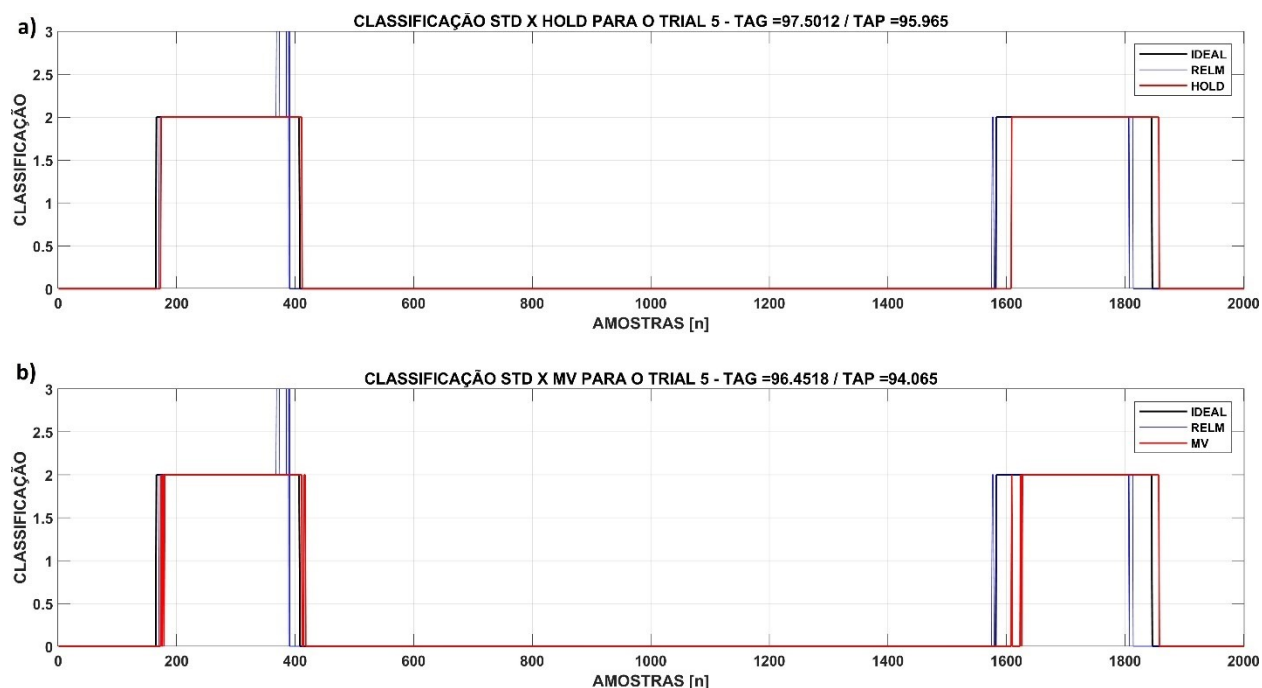
Figura 43 - Taxas de acerto ponderada para os ensaios da base IEE, sendo a) resultados dos *trials* das bases A e B, b) resultados dos *trials* das bases C e D, c) médias para o ENSAIO A, d) médias para o ENSAIO B, e) médias para o ENSAIO C e f) médias para o ENSAIO D.



Fonte: Elaboração própria.

No ENSAIO A, onde os movimentos foram executados de forma sequencial, observa-se que a TAP exibe um comportamento idêntico ao explicado para as taxas da base NAMP que cita os desenvolvimentos realizados em (CENE & BALBINOT, 2018a). Como evidenciado pelas métricas secundárias como a taxa de acerto no treinamento, o nível de *threshold* e o percentual de dados modificados ou pelas próprias taxas de acerto base, as bases IEE são compostas de valores representativos o suficiente para possibilitar classificações mais consistentes mesmo na versão base do classificador, gerando taxas de acerto bastante altas. Desta forma a utilização de métodos como o HOLD e o MV, que mesmo sendo capazes de mitigar alguns dos escassos ruídos de classificação, geraram latências de classificação principalmente no final do movimento. Assim a utilização destes métodos impede uma transição rápida de volta à classe de repouso, induzindo a erros que quando somados, reduzem as taxas de acerto oferecidas por ambos os métodos. A Figura 44 demonstra este efeito de latência de classificação em ambos os métodos.

Figura 44 - Classificação realizada para o *trial 5* da base IEE, comparando: a) o método HOLD com a classificação do RELM base e b) o método MV com a classificação do RELM base. Para ambos os casos são apresentadas as TAG e TAP do segmento considerado onde as taxas obtidas pelo RELM padrão são TAG = 96,55% e TAP = 93,34%.



Fonte: Elaboração própria.

O efeito de latência consequente da utilização dos métodos HOLD e MV tende a sobrepor *labels* em períodos de transição gerando *bias* em relação à classe repouso. Na Figura 44, ambas as saídas do sistema são apresentadas em relação ao STD, que atinge 96,55% na TAG e 93,34% na TAP, respectivamente. A seção de classificação apresentada corresponde ao *trial 5* da base IEE, onde o STD supera os métodos HOLD e MV, e onde o HOLD apresenta taxas ligeiramente superiores por apresentar menos latência de classificação comparado ao MV. O HOLD também oferece mais estabilidade para a classificação e embora também introduza latência, é capaz de eliminar ruídos de classificação, mesmo as que ocorrem para a classe repouso.

De um ponto de vista experimental, os resultados dos métodos HOLD e MV nos ensaios base IEE explicam-se não somente em função da eliminação de *ripples* de classificação e da latência introduzida principalmente ao final de cada movimento, mas também da proporção dos dados de repouso presentes em cada ensaio. No ENSAIO A, que no geral tem sinais mais regulares, o HOLD apresenta uma pequena vantagem pela sua responsividade e capacidade de eliminar ruídos de classificação, o que o MV também faz, mas inserindo mais latência e reduzindo menos o ruído, como apresentado na Figura 44. Já no ENSAIO B, embora os valores de *threshold* obtidos

formem uma média quase igual à do ENSAIO A, a porcentagem de dados modificados por ambos os métodos foi menor. Isso somado a uma maior quantidade de repetições de movimentos, onde cada um dos métodos inseria latências em relação ao retorno ao repouso gerou o pior resultado em relação à classificação padrão dentre os quatro ensaios testados.

Já no ENSAIO C e no ENSAIO D ocorrem menores taxas de acerto individual para cada movimento, que é executado de forma aleatória e menos consistente em relação aos ensaios sequenciais. Assim, os métodos têm mais margem de contribuição na geração de rótulos mais estáveis durante movimentos ativos ao eliminar ruídos de classificação. Outro parâmetro importante a ser considerado é a proporção de amostras da classe de repouso nos ENSAIOS C e D em função dos tempos de chamada dos vídeos aleatórios a serem mostrados para os voluntários, assim como o tempo reservado a execução do próximo movimento a ser realizado. O aumento do número de amostras para a classe repouso diminui proporcionalmente e tende a mitigar o efeito da latência dos métodos HOLD e MV em ambas as métricas da taxa de acerto, considerando que os métodos afetam somente uma parte diminuta da classe repouso, logo após o final de cada movimento. Assim, exclusivamente no ENSAIO D, ambos os métodos conseguem atingir taxas de acerto superiores à versão padrão do RELM em ambas as métricas consideradas.

O método de descarte autônomo de amostras não confiáveis foi o único capaz de demonstrar um desempenho consistente para todos os ensaios da base IEE. De fato, a menor TAG média obtida foi de $98,90 \pm 0,86\%$ para o ENSAIO C. As demais TAG obtidas alcançaram valores de $99,20 \pm 0,37\%$ para o ENSAIO A, $99,36 \pm 0,32\%$ para o ENSAIO B e $99,24 \pm 0,43\%$ para o ENSAIO D, respectivamente. Embora as taxas de acerto geral sejam bastante influenciadas pela classe de repouso (principalmente nas bases IEE onde o repouso no ENSAIO D compõe aproximadamente 70% dos dados), os resultados obtidos para as classes da classe repouso são igualmente altos comparados a outras bases disponíveis, como a NINAPro. Já as TAPs utilizando o método DISC foram obtidas taxas de $92,06 \pm 4,38\%$ para o ENSAIO A, $91,33 \pm 6,99\%$ para o ENSAIO B, $84,02 \pm 11,52\%$ para o ENSAIO C e $87,82 \pm 7,04\%$ para o ENSAIO D.

A validação estatística dos resultados para a base IEE também foi realizada através de uma ANOVA ($p < 0,01$) como apresentado na Equação (38) e na Equação (39) para ambas as taxas de acerto. Os fatores controláveis do modelo foram *método*, *ensaio*, *voluntário*, *repetição* e *movimento* para a TAP; e *método*, *ensaio*, *voluntário* e *repetição* para a TAG. Novamente, considerando a natureza da base IEE que é composta por mais fatores controláveis em comparação

às bases NINAPro, uma análise de fatores isolados e interações em até três níveis foi conduzida. A ANOVA realizada para a TAG conforme o modelo apresentado na Equação (38) demonstra que todos os fatores individuais e em sua interação de primeiro nível são estatisticamente significativos e capazes de alterar a TAG. Já nas interações de segundo nível, as combinações de *método* × *ensaio* × *voluntário*, *método* × *ensaio* × *repetição* e *método* × *voluntário* × *repetição* demonstraram-se não significativas. Esses resultados mostram que apesar dos métodos provocarem mudanças significativas na taxa de acerto global de forma geral para todos os ensaios, repetições e voluntários (interação de segundo nível), para as interações de segundo nível envolvendo os métodos não foi possível obter uma variação de resposta substancial. Esse efeito pode ser explicado pela proximidade natural das taxas TAG com a base IEE. As taxas sofrem bastante influência da classe repouso e, para todas as TAG dos diferentes *trials* obtém taxas acima de 90%. Assim como nas outras bases, devido à diferença substancial oferecida pelo DISC, os resultados relacionados a esta métrica foram retirados do modelo e uma outra ANOVA foi conduzida onde os resultados obtidos não mudaram em termos de fatores controláveis estatisticamente significativos. Para todas as outras interações de fatores não descritas, o método foi estatisticamente significativo. A Tabela 10 apresenta os valores médios encontrados pelos métodos propostos não só para base IEE como também para as bases NINAPro AMP e NAMP.

Tabela 10 – Taxas de acerto global médias obtidas pelos métodos relacionados ao modelo de classificação confiável para as diferentes bases de dados testadas.

BASE		TAG (%)				
		MÉTODO				
		STD	HOLD	MV	MKV	DISC
AMP		56,44 ± 21,30	57,04 ± 21,54	57,35 ± 21,66	56,49 ± 20,95	61,24 ± 24,53
NAMP		77,88 ± 7,25	78,42 ± 7,00	78,70 ± 6,64	77,95 ± 7,29	83,37 ± 7,84
IEE	A	95,46 ± 1,26	94,94 ± 1,11	94,44 ± 1,16	95,50 ± 1,26	99,20 ± 0,37
	B	95,80 ± 1,14	94,64 ± 1,06	94,10 ± 1,18	95,82 ± 1,14	99,36 ± 0,32
	C	94,24 ± 1,75	94,32 ± 1,57	94,36 ± 1,50	94,26 ± 1,78	98,90 ± 0,86
	D	94,66 ± 1,28	95,58 ± 1,04	95,63 ± 1,02	94,66 ± 1,29	99,24 ± 0,43

Fonte: Elaboração própria.

Na validação estatística relativa à TAP, o modelo composto por *método*, *ensaio*, *voluntário*, *repetição* e *movimento* apresentado na Equação (39) dá a oportunidade de ponderar a taxa de acertos individual de cada movimento no modelo. Assim como na análise realizada na TAG, todos os fatores em sua análise individual mostraram-se significativos bem como sua interação de

segundo nível, com exceção de método \times repetição. O que indica que apesar das mudanças substanciais apresentadas na Figura 43, os métodos não são impactantes o suficiente para alterar o efeito na média das repetições realizadas por cada voluntário de forma consistente. Desta forma, novamente observa-se a influência do voluntário nos resultados obtidos, sendo que se os dados utilizados para a criação e teste do modelo não seguirem as condições de representatividade e repetibilidade desejadas, os métodos serão bastante limitados em sua capacidade de aprimorar a classificação. Da mesma forma, a insignificância estatística das interações envolvendo os fatores método e repetição propaga-se pelos demais níveis e mostraram-se estatisticamente não representativas para o terceiro (método \times ensaio \times repetição, método \times voluntário \times repetição e método \times repetição \times movimento) e quarto nível de interações (método \times ensaio \times repetição \times movimento e método \times voluntário \times repetição \times movimento). Todas as outras condições não comentadas de interação de fatores mostraram-se estatisticamente significativas. Assim como nas outras bases, os resultados derivados do método DISC foram descartados e a ANOVA foi recalculada. Os resultados mantiveram-se os mesmos com exceção da interação *ensaio \times voluntário \times repetição \times movimento* que demonstrou ser significativa e das interações de terceiro nível que se demonstraram todas não significativas. Esse resultado é explicado pela subtração do método DISC, capaz de provocar mudanças nas taxas de resposta a nível mais profundo no sistema e que, uma vez removido, reduz em muito as variações das TAP em relação ao quarto nível de interação entre os fatores. A Tabela 11 apresenta os valores médios encontrados pelos métodos propostos não só para base IEE como também para as bases NINAPro AMP e NAMP.

Tabela 11 – Taxas de acerto global médias obtidas pelos métodos relacionados ao modelo de classificação confiável para as diferentes bases de dados testadas.

BASE		TAP (%)				
		MÉTODO				
		STD	HOLD	MV	MKV	DISC
AMP		42,40 \pm 16,30	43,07 \pm 16,88	43,46 \pm 17,27	42,04 \pm 16,14	46,47 \pm 19,31
NAMP		67,28 \pm 7,29	67,57 \pm 7,00	68,06 \pm 6,48	67,28 \pm 7,38	73,37 \pm 8,91
IEE	A	79,47 \pm 5,92	79,68 \pm 4,98	78,07 \pm 5,33	79,63 \pm 5,90	92,06 \pm 4,38
	B	79,60 \pm 6,51	76,76 \pm 6,00	74,57 \pm 6,66	79,70 \pm 6,49	91,33 \pm 6,99
	C	69,32 \pm 9,84	68,68 \pm 8,45	68,43 \pm 8,05	69,37 \pm 10,04	84,02 \pm 11,52
	D	70,19 \pm 7,96	74,78 \pm 6,66	74,88 \pm 6,58	70,12 \pm 8,00	87,82 \pm 7,04

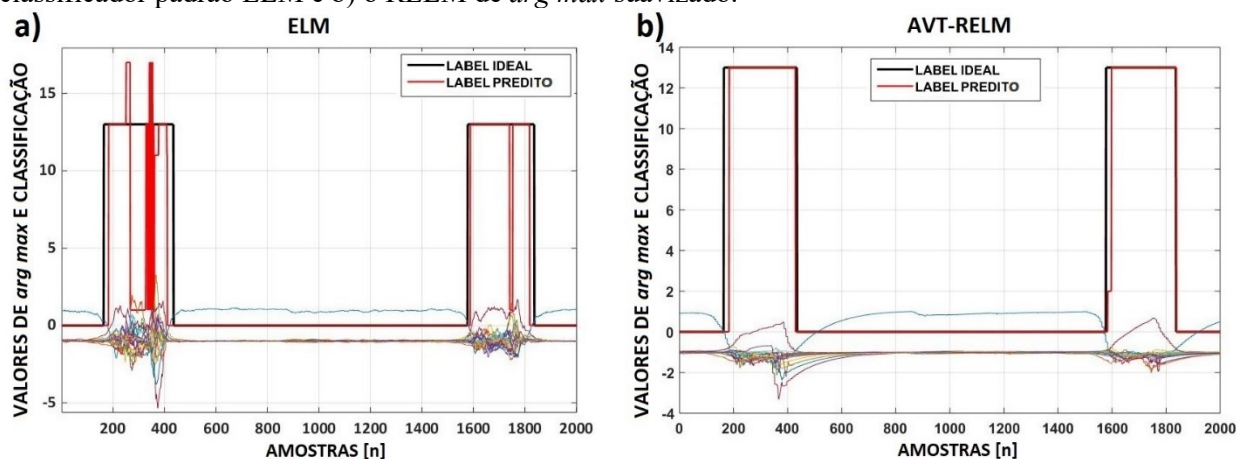
Fonte: Elaboração própria.

5.4 COMPARAÇÃO DOS MÉTODOS UTILIZADOS NA CLASSIFICAÇÃO RESILIENTE

Embora resultados satisfatórios tenham sido obtidos na versão base e confiável do RELM, erros baseados na latência em períodos de transição e ruídos de classificação continuaram a impedir uma classificação ótima dos sinais. Para tanto, foram desenvolvidos os métodos da versão resiliente do classificador composta pelo RELM de *arg max* suavizado, que tende a mitigar ruídos de classificação em partes intermediárias do movimento e pela otimização de reconhecimento entre movimento e repouso. A otimização do reconhecimento em períodos de transição é realizada pelo um RELM binário auxiliar e por um método baseado em *threshold*, onde ambos geram uma saída binária que força o descarte do *arg max* relativo à classe de repouso na atribuição de *labels*.

Métodos de mais alto nível que atuam exclusivamente no *label* de saída do classificador com exceção do DISC tendem a não influenciar significativamente a taxa de acerto do sistema. Assim, a ideia por trás da suavização do *arg max* é oferecer uma solução mais específica e eficiente para a filtragem dos *labels* de saída. Ao invés de atuar somente na saída do classificador (o que é a heurística geralmente adotada em métodos de pós-processamento para a correção de *labels*), a suavização atua no próprio valor de *arg max* interno ao método de classificação responsável por gerar as classes de saída. A Figura 45 apresenta o comparativo de uma classificação utilizando o método ELM em sua forma básica e a classificação por *arg max* suavizado.

Figura 45 - Comparação da classificação de duas repetições do movimento 14 para utilizando: a) o classificador padrão ELM e b) o RELM de *arg max* suavizado.



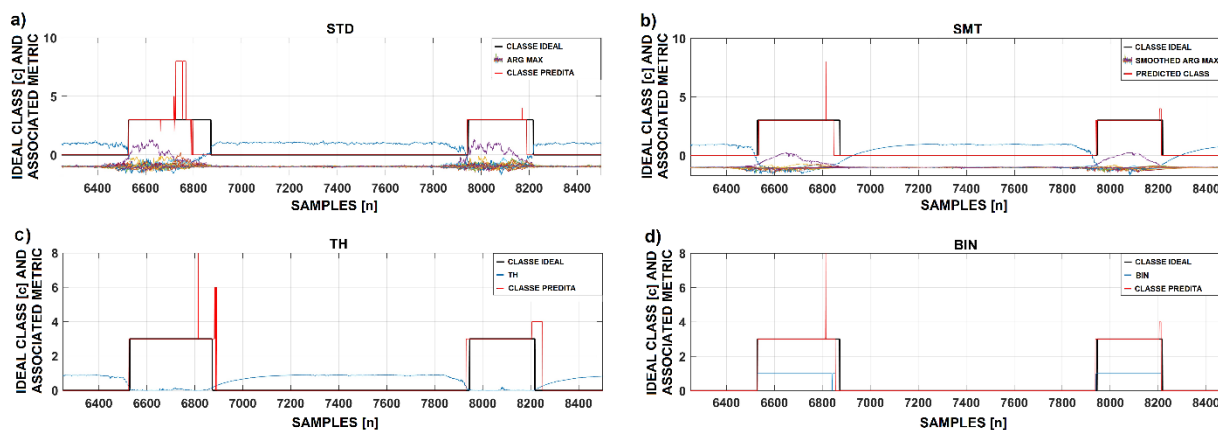
Fonte: Elaboração própria.

Na classificação padrão são nítidas as influências dos ruídos produzidos no *arg max* relacionado, frutos da dificuldade de separação entre as diferentes classes, assim como já apresentado detalhadamente na Figura 22. Estes ruídos e sobreposições indesejadas no *arg max*,

quando propagados à saída, invariavelmente resultam em erros de classificação. Já na Figura 45.b, é possível perceber o efeito da filtragem do sinal, gerando sinais de *arg max* e consequentemente saídas, muito mais consistentes e assertivas.

Os métodos baseados em saída binária (*threshold* e classificador auxiliar), baseiam-se na identificação binária entre repouso e movimentos ativos na tentativa de compensar a latência encontrada pelos métodos de classificação em momentos de transição de movimentos. O método do *threshold* utiliza os valores filtrados do *arg max* que são mais regulares e consistentes e favorecem a separação entre classes, de onde é derivada a métrica de Separação Diferencial Mínima (SDM), definida na Equação (32) e base da definição do *threshold* utilizado. Já o classificador auxiliar utiliza os mesmos dados de treino e teste do classificador base com as saídas mapeadas para uma saída binomial: “repouso” e “movimento”. Como a latência de classificação na transição de movimentos consiste em um *bias* em favor da classe repouso, este métodos são utilizados na esperança de que o segundo valor de *arg max* mais alto pertença à classe correta quando o *arg max* da classe repouso é ignorado. Os efeitos decorrentes das soluções propostas na classificação resiliente são apresentados na Figura 46, que compara os efeitos do *arg max* suavizado, do método do *threshold* e do classificador binário auxiliar com a classificação padrão do RELM e seus efeitos na saída do sistema.

Figura 46 - Métricas principais e auxiliares utilizadas na classificação do sinal: a) *arg max* derivado do RELM padrão; b) *arg max* suavizado; c) sinal de Separação Diferencial Mínima (SDM) que dá base a classificação resiliente no método do *threshold* e d) classificação binária auxiliar utilizada para a classificação resiliente no método do classificador binomial. As quatro métricas são representadas sobre a classificação predita que geram (curva em vermelho) e sobre a classificação ideal pretendida (curva em preto).

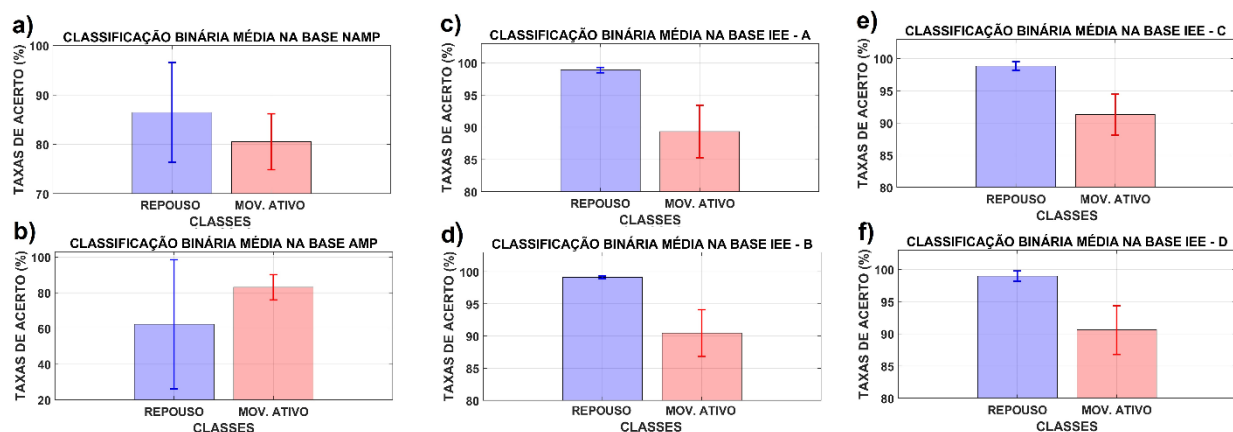


Fonte: Elaboração própria.

Os resultados apresentados na Figura 46 sintetizam os efeitos dos métodos propostos. Como já mencionado, a versão suavizada do classificador tende a eliminar ruídos de classificação na parte intermediária do movimento devido a maior estabilidade gerada para os sinais de *arg max*. Ao mesmo tempo o método do *threshold* aproveita a dificuldade de separação de classes durante movimentos ativos e utilizando a SDM, identifica quando um movimento realmente está sendo realizado e descartando a classe repouso, possibilita a classificação consistente da classe correta.

Embora cubra praticamente toda a seção de movimento ativo, o método de *threshold* tende a introduzir alguma latência depois do movimento realizado consequente do atraso de fase do filtro utilizado para a suavização do *arg max*. Assim, há uma relação direta entre o filtro utilizado e a responsividade do método do *threshold*. Embora esse comportamento gere a diminuição da taxa de acerto na classe repouso, testes experimentais ainda são necessários para averiguar se o método é prejudicial a ponto de afetar a controlabilidade da interface. Adicionalmente, outros filtros podem ser utilizados ao invés do AVT (inclusive filtros de fase nula), o que pode acabar com este revés do método. Já o classificador binário auxiliar não apresenta a latência característica do método do *threshold* mas apresenta ruídos de classificação ocasionais, que obrigatoriamente produzem erro de classificação ao confundirem um movimento ativo com repouso e vice-versa. De forma geral, as duas abordagens parecem atingir seu principal objetivo que é evitar que ocorra latências de classificação no início do movimento ou retorno prematuro à classe de repouso. O desempenho médio do classificador binário auxiliar para as diferentes bases é apresentado na Figura 47.


Figura 47 - Desempenho do classificador binário auxiliar em todas as bases de dados, onde: a) consiste nos resultados obtidos para a base NAMP enquanto b) apresenta os resultados na base AMP, c) apresenta os resultados do ENSAIO A da base IEE enquanto d) apresenta os resultados do ENSAIO B. Os resultados dos ensaios aleatórios são apresentados em d) para o ENSAIO C e f) para o ENSAIO D.



Fonte: Elaboração própria.

Uma das vantagens do classificador binário auxiliar é a possibilidade de conferência mais precisa da atuação do método. Diferente dos modelos referentes à classificação confiável onde era possível monitorar o nível de *threshold* normalizado e a taxa de dados afetados, com o classificador binário auxiliar é possível medir de forma mais clara as porcentagens de dados reconhecidas em cada classe binária para cada base. Tanto as taxas de movimentos modificados e níveis normalizados dos métodos de *threshold* quanto as taxas de acerto do classificador binário não garantem que quando os métodos atuam eles estão induzindo a classificação correta das amostras. Entretanto, no classificador binário dá-se a certeza de que quando um movimento é reconhecido de forma correta, o único erro possível é a classificação errônea para outro movimento ativo, o que, com a utilização da classificação por *arg max* suavizado, tende a ocorrer com menor frequência. Em contrapartida, o classificador binário auxiliar tende a ser mais sensível a ruídos de classificação quando comparado ao *threshold* obtido através da Separação Diferencial Mínima (SDM) que, apesar de gerar uma latência no final de cada movimento, tende a cobrir mais eficientemente a zona de movimentação ativa, muitas vezes eliminando por completo a latência inicial de cada movimento. Os resultados da aplicação dos métodos relativos ao RELM resiliente em comparação ao RELM padrão são apresentados na Figura 48 para a base NAMP.

Figura 48 - Comparação dos métodos da versão resiliente do classificador na base NAMP com a TAG representada pelas linhas tracejadas e a TAP pelo gráfico de barras, onde: a) apresenta a TAG e a TAG individualmente para os voluntários 1 ao 20; b) apresenta a TAG e a TAG individualmente para os voluntários 21 ao 40; c) apresenta a média geral obtida para a base e c) apresenta a média ponderada obtida para a base.



Fonte: Elaboração própria.


De forma a beneficiar a visualização dos dados e simplificar a legenda dos gráficos desta seção, as variações de técnicas foram abreviadas, sendo que o RELM padrão é STD (do inglês, *standard*); o RELM de *arg max* suavizado é SMT (do inglês, *smoothed*); o método baseado em *threshold* é TH e o método baseado na classificação binária auxiliar é denominado BIN. De forma geral é notável a vantagem oferecida pelos métodos resilientes de classificação. De fato, considerando a TAP, os três métodos derivados da classificação resiliente superam a versão padrão do RELM com resultados significativamente mais altos sendo que as únicas equivalências do método padrão com alguma das soluções propostas ocorre para os voluntários 30 e 32, onde o método padrão e o método TH apresentam praticamente a mesma taxa de acerto, o que é representado pelas linhas tracejadas que indicam a TAG. Para os demais voluntários, há uma separação bastante distinta de taxas obtidas tanto na TAG quanto na TAP que deixam nítida a influência dos métodos nos resultados obtidos.

Tanto o método de suavização do *arg max* quanto o método do classificador binário auxiliar são capazes de oferecer aumentos substanciais para a base NAMP de aproximadamente 4,00% e 8,00%, respectivamente para a média da base inteira. Considerando que o RELM de *arg max* suavizado quase não interfere nas classificações de repouso, o efeito na resposta mostra o quanto de espaço ainda havia para melhoramento de movimentos ativos tanto por mitigação de ruídos que geram transições para movimentos errôneos quanto por retornos indesejados à classe de repouso. O método BIN, mesmo sendo mais sensível a ruídos entre movimento e repouso – por não possuir o efeito do filtro AVT – mostra-se como uma alternativa igualmente eficiente para o trato dos dados desta base, e de fato, foi o método que demonstrou a taxa de acerto ponderada mais elevada para as bases NINAPro (AMP e NAMP). No entanto, por ser menos robusto em relação a falsos positivos em períodos de repouso próximos à transição dos movimentos, acumula erros nesta classe, o que prejudica sua TAG.

Já o método TH mostra-se como uma alternativa mais drástica que ao mesmo tempo possui uma cobertura maior dos movimentos ativos, mas induz erro na classe de repouso ao inserir latência para a desativação do movimento (o que por vezes também ocorre no SMT). Vale ressaltar que esta latência é uma consequência direta do filtro utilizado na suavização do *arg max* e que pode ser mitigada com a utilização de outro filtro. Ao mesmo tempo, seria interessante realizar um ensaio experimental para a avaliação do efeito desta latência na controlabilidade de uma interface, e ponderar sobre o custo-benefício deste tipo de abordagem.

Uma ANOVA ($p < 0,01$) foi realizada para a validação estatística dos resultados apresentados como descrito na Equação (37) para a TAG e na Equação (38) para a TAP, respectivamente. Tanto na análise da taxa de acerto geral quanto na taxa ponderada, todos os fatores demonstram-se significativos em sua análise isolada e em suas interações de segundo grau (o que só é possível na TAP). Estes resultados demonstram não só a capacidade dos diferentes métodos de gerar taxas significativamente mais altas de forma geral, mas também proporcionar taxas mais altas para voluntários e movimentos específicos quando comparado ao RELM em sua forma padrão. Já o efeito dos métodos de processamento relacionados à forma resiliente do classificador na base AMP são apresentados na Figura 49.

Figura 49 - Comparação dos métodos da versão resiliente do classificador na base AMP com a TAG representada pelas linhas tracejadas e a TAP pelo gráfico de barras, onde: a) apresenta a TAG e a TAG individualmente para todos os voluntários; b) apresenta a média geral obtida para a base e c) apresenta a média ponderada obtida para a base.



Fonte: Elaboração própria.

Assim como na base NAMP, os métodos relacionados à versão resiliente do classificador apresentam o mesmo comportamento e vantagens consistentes em relação às taxas de acerto. Entretanto é pertinente observar a influência da base de dados no desempenho do sistema como um todo. De forma geral, indivíduos amputados tem uma maior dificuldade em gerar modelos assertivos em função da falta de representatividade dos sinais gerados que frequentemente consistem em sinais de baixa amplitude, dificultando a separação de classes entre movimentos ativos e até mesmo com a classe de repouso. Este efeito pode ser acompanhado na Figura 47.b, na

qual embora o método BIN apresente um desempenho semelhante à classificação de movimentos ativos da base NAMP, apresenta um resultado muito abaixo das demais bases para a classe de repouso. Outro fator interessante é o desvio-padrão muito alto em relação às demais bases que é associado com a taxa de acerto da classe repouso, o que demonstra a variabilidade dos sinais oferecidos na base AMP, que torna a classificação dos sinais de sEMG uma tarefa bastante árdua do ponto de vista de Inteligência Computacional.

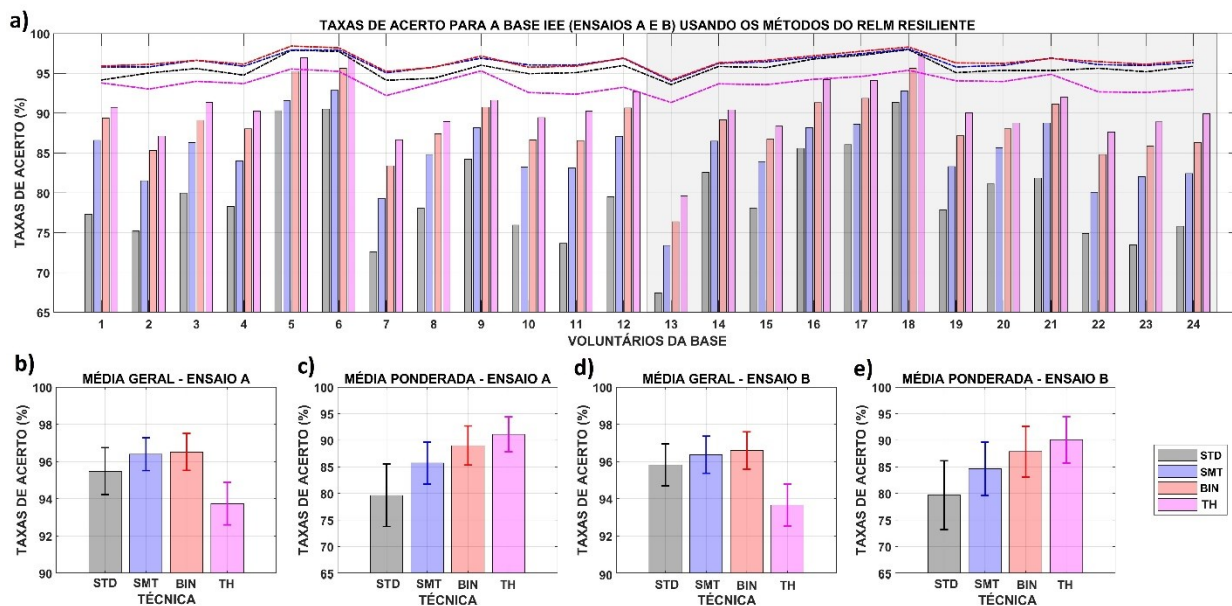
Neste contexto, o método SMT mostra-se interessante novamente a medida em que é capaz de suavizar os ruídos do sinal de *arg max* responsáveis por este erro na classificação, o que tende a aumentar a taxa de acerto individual de cada movimento, sem interferir significativamente na classe de repouso. O reflexo disto é evidenciado pelas altas tanto nas TAG quanto nas TAP em relação ao RELM padrão. O método BIN apresenta o mesmo comportamento, tendo as taxas de acerto ponderadas mais altas uma vez que o classificador binário foi capaz de identificar com razoável precisão as amostras de movimentos ativos da base ($> 80\%$). Uma vez identificado o movimento, o sistema pode então se beneficiar das classificações mais estáveis do SMT, o que impulsionou a TAP que é significativamente superior ao RELM padrão. Em contrapartida, como apresentado na Figura 47.b, o classificador binário auxiliar obteve uma taxa de acerto relativamente baixa e que possui grande variância para a classe repouso da base AMP. Isto tende a causar classificações de falsos positivos e prejudicar a TAG do método. Embora os erros da classe repouso sejam mais comuns nesta base do que nas demais, ao fornecer a sinalização de que o repouso é a classe atual o BIN não força a classificação da saída, ao contrário do que acontece quando um movimento é detectado. Portanto, mesmo com o erro do BIN o classificador ainda pode identificar a classe associada como sendo um movimento ativo e inclusive, acertar exatamente qual.

Já o TH apresenta um padrão muito similar ao da base NAMP e um comportamento quase idêntico ao do SMT, ambos superiores ao STD mas inferiores ao BIN. Uma das principais vantagens destes dois métodos é a robustez ante a sinais modelos treinados com dados pouco representativos. Voluntários que possuem uma separação de classes falha e que geram valores pouco repetitivos e representativos costumam gerar valores de *arg max* com muitas variações e muito ruído, uma vez que as amostras de teste geralmente não possuem uma correlação tão forte com as utilizadas no treino. Nestes modelos, a filtragem do *arg max* potencializa muito a geração de classificações mais consistentes, o que pode ser conferido na Figura 49.a. Nesta figura, para os

voluntários (5, 7 e 10) que tendem a obter classificações no STD com baixas taxas de acerto, o BIN atinge resultados tão ruins quanto, o que é um resultado direto da dificuldade da separação binomial de classes da qual o método depende. Já os métodos focados na filtragem do *arg max* oferecem taxas de acerto $> 5,00\%$ superiores. Portanto, mesmo tendo o BIN como classificador que atinge as maiores médias nas bases NINAPro, tanto o SMT como o TH parecem ser alternativas que proporcionam uma abordagem um pouco mais conservadora, porém robusta.

Assim como na base NAMP, a ANOVA ($p < 0,01$) realizada provou a significância estatística dos fatores em sua análise isolada e em suas interações de primeiro nível, o que só é possível na TAP, como apresentado na Equação (37). Novamente, os resultados demonstram não só a capacidade dos diferentes métodos de gerar taxas significativamente mais altas de forma geral, mas também proporcionar taxas mais altas para voluntários e movimentos específicos quando comparado ao RELM em sua forma padrão. Em relação a base IEE, o efeito dos métodos nas bases de natureza sequencial (ENSAIO A e ENSAIO B) são apresentados na Figura 50.

Figura 50 - Comparação dos métodos da versão resiliente do classificador na base IEE com a TAG representada pelas linhas tracejadas e a TAP pelo gráfico de barras, onde: a) apresenta a TAG e a TAG individual para cada *trial* realizado nos ensaios sequenciais que de 1 à 12 representam as três repetições de cada um dos quatro voluntários para o ENSAIO A e de 13 à 24 representam as três repetições de cada um dos voluntários para o ENSAIO B, organizadas sequencialmente; b) apresenta a TAG e c) apresenta a TAP do ENSAIO A para todos os métodos enquanto d) apresenta a TAG e e) apresenta a TAP relativa ao ENSAIO B obtida para todos os métodos.



Fonte: Elaboração própria.

Nas bases IEE, padrões semelhantes de resposta foram encontrados para os diferentes ensaios, mesmo diante à variação do número ou ordem de repetições utilizadas. Os padrões de resposta consistem basicamente dos efeitos apresentados na Figura 46. Nela é destacada a capacidade do SMT de mitigar ruídos de classificação assim como os métodos BIN e TH que, complementarmente, ainda preenchem quase que por completo as lacunas correspondentes às latências em momentos de transição de movimentos. Nestas transições, geralmente o TH cobre toda região de movimento ativo, ao custo de introduz *delay* ao final de cada movimento em função do atraso de fase gerado pelo AVT.


As médias de ambas as métricas de saída apresentadas na Figura 50 para os ensaios sequenciais e na Figura 51 para os ensaios aleatórios ilustram os efeitos citados. Em relação ao SMT, em ambos os tipos de ensaio o método se beneficia de seu fator filtro e novamente é possível perceber seu potencial particularmente útil em voluntários com menor taxa de acerto (exceto para o *trial* 26, onde nenhum método teve uma boa TAP). De fato, o aumento médio da TAP mais substancial do SMT em relação ao STD foi de aproximadamente 7,00% no ENSAIO D embora já no primeiro *trial* do ENSAIO A uma taxa de aproximadamente de 10% de melhoramento tenha sido obtida.

O método BIN também seguiu consistente com os resultados encontrados nas bases anteriores onde superou as taxas de acerto ponderadas do SMT em ambas bases NINAPro. No entanto, para o ENSAIO A e o ENSAIO B, tanto na TAP quanto na TAG o método do classificador binário superou o RELM de *arg max* suavizado. A justificativa para tanto, conforme apresentado na Figura 31, é que as bases sequenciais IEE geram modelos mais regulares do que as bases NINAPro e desta forma, como apresentado na Figura 47, é possível ter uma taxa de acerto mais alta na distinção entre as classes repouso e movimento. Devido ainda ao modelo bem treinado, mesmo quando o BIN erra uma classificação em favor da classe repouso, o classificador principal baseado em SMT tem uma boa chance de acertar a classificação da amostra. Este tipo de fenômeno já não ocorre com tanta frequência nos ensaios de cunho aleatório – ENSAIO C e ENSAIO D – que, por conterem *trials* com taxas de acerto naturalmente menor na versão padrão do RELM (em torno de 10,00%), dão mais margem a erros. Assim, como nas bases NINAPro, para os ensaios aleatórios da base IEE, o método BIN atinge taxas ponderadas maiores que o SMT mostrando desempenho um pouco inferior quando as TAG são consideradas.

O método do TH mostra sua potencialidade na base IEE onde atinge as melhores taxas ponderadas para a base IEE entre todos os métodos testados que não envolvem descarte de amostras. O TH tende a cobrir a quase totalidade dos movimentos ativos, o que junto às bases IEE que tem modelos mais regulares leva à taxas de acerto em alguns casos, quase perfeitas.

Destaca-se a segunda repetição dos voluntários 1 e 2 no ENSAIO A assim como a segunda repetição do voluntário 2 no ENSAIO B (*trials* 5, 6 e 18, respectivamente). Nessas repetições foram atingidas, respectivamente, $96,97 \pm 4,13\%$, $97,22 \pm 3,63$ e $97,28 \pm 2,59\%$ de taxa de acerto ponderada e ao mesmo tempo $95,55\%$, $95,25\%$ e $95,38\%$ de taxa de acerto global, respectivamente. Este resultado mostra claramente que estas taxas bastante altas foram obtidas ao custo de inserir a latência no fim de cada movimento, inserindo erro na classe de repouso que diminui proporcionalmente nos ensaios mais longos, como os do ENSAIO D da base IEE. A Figura 51 mostra os efeitos dos métodos resilientes aplicados aos ensaios aleatórios (ENSAIO C e ENSAIO D) da base IEE.

Figura 51 - Comparação dos métodos da versão resiliente do classificador na base IEE com a TAG representada pelas linhas tracejadas e a TAP pelo gráfico de barras, onde: a) apresenta a TAG e a TAG individual para cada *trial* realizado nos ensaios sequenciais que de 1 à 12 representam as três repetições de cada um dos quatro voluntários para o ENSAIO C e de 13 à 24 representam as três repetições de cada um dos voluntários para o ENSAIO D, organizadas sequencialmente; b) apresenta a TAG e c) apresenta a TAP do ENSAIO C para todos os métodos enquanto d) apresenta a TAG e e) apresenta a TAP relativa ao ENSAIO D obtida para todos os métodos.



Fonte: Elaboração própria.

Uma ANOVA ($p < 0,01$) foi realizada para ambas as métricas de saída consideradas conforme a Equação (38) para a TAG e a Equação (39) para a TAP, respectivamente. Para a TAG todos os fatores mostraram-se isoladamente significativos, o que é esperado uma vez que tanto os métodos quanto os diferentes ensaios, voluntários e suas repetições geram resultados bastante distintos entre si. A interação de primeiro nível também se mostrou significativa para todos os fatores com exceção da interação *método* \times *repetição*, onde a TAG costuma atingir valores bastante altos ($> 90\%$) e próximos entre si devido ao *bias* da classe de repouso que mitiga a influência dos métodos. Mesmo motivo pelo qual as diferenças nas TAG provenientes das interações de segundo nível envolvendo o método (*método* \times *ensaio* \times *voluntário*, *método* \times *ensaio* \times *repetição* e *método* \times *voluntário* \times *repetição*) são, da mesma forma, estatisticamente insignificantes.

A análise da TAP possibilita análises mais específicas sobre o comportamento do sistema à medida em que considera cada taxa de acerto obtida para cada movimento individual em cada repetição de um ensaio específico realizado por um voluntário. Assim como na TAG tanto os fatores individuais quanto a sua análise de interação em primeiro nível com exceção de *método* \times *repetição* – desta vez por uma margem bem pequena (0,017) – mostraram-se como fatores significativos. Este valor reduzido (contra 0,998 encontrado na TAG) demonstra a potencialidade de avaliação mais fina da TAP, ao considerar médias de todos os movimentos envolvidos ao invés de só considerar a taxa global de cada *trial*.

Já nas interações de segundo nível, como consequência do nível anterior, todas com exceção das três que envolvem interações entre método e repetição (*método* \times *ensaio* \times *repetição*, *método* \times *voluntário* \times *repetição* e *método* \times *repetição* \times *movimento*) foram significativas. Isto mostra a capacidade dos métodos resilientes de oferecer diferentes taxas quando utilizados nos dados de um mesmo voluntário dentro de um ensaio ou mesmo para um mesmo movimento de um mesmo voluntário (o que é claramente demonstrado nas figuras referentes aos resultados obtidos). Entretanto, quando as repetições são consideradas, os métodos apresentam desempenho estatisticamente equivalente. Nas interações de terceiro nível, todos os cruzamentos de fatores envolvendo o método mostraram-se não significativos. A Tabela 12 resume as taxas de acerto globais médias enquanto a Tabela 13 resume as taxas de acerto ponderadas médias dos métodos componentes da versão resiliente do classificador nas bases testadas em comparação com o RELM padrão e o método DISC da versão confiável do classificador.

Tabela 12 – Taxas de acerto globais médias obtidas pelos métodos relacionados ao modelo de classificação confiável para as diferentes bases de dados testadas.

BASE		TAG (%)				
		MÉTODOS				
		STD	SMT	BIN	TH	DISC
AMP		56,44 ± 20,9	61,53 ± 20,8	57,90 ± 24,4	61,49 ± 20,8	66,99 ± 23,57
NAMP		77,88 ± 7,25	81,78 ± 5,44	80,29 ± 6,55	81,73 ± 5,38	87,01 ± 5,89
IEE	A	95,46 ± 1,26	96,40 ± 0,90	96,52 ± 1,00	93,73 ± 1,41	99,43 ± 0,37
	B	95,80 ± 1,13	96,37 ± 1,00	96,59 ± 1,00	93,67 ± 1,12	99,60 ± 0,32
	C	94,26 ± 1,75	95,40 ± 1,74	94,80 ± 1,92	94,18 ± 2,27	99,76 ± 0,37
	D	94,66 ± 1,25	95,92 ± 1,14	95,52 ± 1,48	95,11 ± 1,71	99,90 ± 0,12

Fonte: Elaboração própria.

Em relação aos movimentos, a Figura 52 apresenta os efeitos de incremento de taxa de acerto dos métodos resilientes juntamente ao método DISC, que teve o melhor desempenho na versão confiável do RELM. Os resultados consistem nas taxas médias de cada classificador subtraídas da taxa padrão gerada pelo RELM para as 18 classes de movimentos, de forma a ressaltar as contribuições individuais de cada técnica quando comparada ao classificador padrão.

Tabela 13 – Taxas de acerto ponderas médias obtidas pelos métodos relacionados ao modelo de classificação confiável para as diferentes bases de dados testadas.


BASE		TAP (%)				
		MÉTODOS				
		STD	SMT	BIN	TH	DISC
AMP		42,63 ± 15,9	50,70 ± 19,0	53,36 ± 18,2	50,99 ± 19,1	46,47 ± 19,31
NAMP		67,29 ± 7,46	75,33 ± 6,28	77,94 ± 6,22	75,76 ± 6,45	73,37 ± 8,91
IEE	A	79,63 ± 5,89	85,72 ± 3,93	89,01 ± 3,68	91,11 ± 3,29	92,06 ± 4,38
	B	79,68 ± 6,46	84,63 ± 5,02	87,86 ± 4,77	90,10 ± 4,38	91,33 ± 6,99
	C	69,53 ± 9,69	74,81 ± 9,08	76,00 ± 9,44	77,32 ± 9,83	84,02 ± 11,52
	D	70,22 ± 7,81	76,94 ± 6,66	78,56 ± 6,78	80,73 ± 6,51	87,82 ± 7,04

Fonte: Elaboração própria.

De forma geral, estes resultados replicam, a nível de movimento, os já apresentados nas figuras anteriores. Um fator a ser levado em consideração é a taxa de acerto da separação binomial do BIN, que aparece como um fator crítico e determinante da eficiência da técnica. Nas bases NINAPro onde as taxas da separação binomial não foram tão altas, muito erros ocorrem na classe repouso. Apesar destes erros (10% na base NAMP e 20% na base AMP) o BIN apresenta melhoras

muito consistentes para os demais movimentos da base NINAPro, superando inclusive o DISC, que oferece um resultado inferior ao TH e ao SMT. A vantagem do BIN se deve ao fato de o método tornar-se mais sensível a ocorrência de movimentos, o que por consequência elimina muitos dos erros que antes eram causados pelo *bias* da classe repouso.

Figura 52 - Incrementos médios de taxa de acerto obtidos através da classificação resiliente e do método DISC, proveniente da versão confiável do classificador. Na figura as taxas são referenciadas ao desempenho do RELM padrão utilizando segmentos de 400+10ms para as bases: a) NAMP, b) AMP e c) IEE.



Apesar de sua similaridade com o TH, o SMT destaca-se por seus incrementos próximos a 10% mesmo sem exigir grandes mudanças estruturais no classificador. O TH acompanha o desempenho do SMT nas bases NINAPro mas oferece um leve acréscimo em decorrência da cobertura oferecida pela técnica, que mesmo o SMT não foi capaz de realizar.

Já as bases IEE por serem mais regulares, já apresentavam uma distinção mais favorável em relação a movimentos ativos e repouso e também menos erros de ruídos de classificação. Desta forma, por haver menos margem de atuação, as contribuições do SMT e do BIN tornaram-se mais tímidas, mantendo o TH a sua capacidade de cobrir o movimento inteiro, ao custo de induzir alguns erros no fim do movimento, o que é demonstrado na classe repouso da Figura 52.c. Para a base IEE, o DISC supera os métodos resilientes, ao contrário do que acontece nas bases NINAPro, onde os métodos resilientes atingem maiores taxas mesmo sem realizar descarte de amostra, mesmo as que outrora eram consideradas não-confiáveis.

5.5 COMPARAÇÃO COM O ESTADO DA ARTE

Na comparação com os trabalhos referenciados na Tabela 4 (trabalhos envolvendo bases NINAPro), na Tabela 5 (trabalhos envolvendo processamento de sinais de sEMG de forma geral) e na Tabela 6 (trabalhos envolvendo ELM) devem ser levadas em consideração as estratégias experimentais e de processamento utilizadas para uma comparação mais apropriada entre trabalhos. Para a comparação mais adequada com os trabalhos relacionados que utilizam bases NINAPro, foram escolhidos trabalhos que utilizam a DB2 (NAMP) e a DB3 (AMP), bases que também foram utilizadas neste trabalho. Ao mesmo tempo foram evitados desenvolvimentos envolvendo outras seções da base, divergentes em função dos movimentos e condições experimentais realizados. Portanto, foram escolhidos os trabalhos de (ATZORI *et. al.*, 2014), (GIJSBERTS, *et. al.*, 2014), (ZHAI *et. al.*, 2016), (ZHAI *et. al.*, 2017) e (SAMADANI *et. al.*, 2014). Já em relação aos trabalhos envolvendo ELM foram escolhidos trabalhos que abordem problemas de classificação de sinais de sEMG utilizando heurísticas de janelas deslizantes e alguns modelos híbridos ou dotados de alguma alternativa de reclassificação do sinal. Para tanto foram utilizados os trabalhos de (ANAM & AL-JUMAILY, 2015a), (ANAM & AL-JUMAILY, 2015b), (ANAM & AL-JUMAILY, 2017), (SHI *et. al.*, 2013) e (CENE & BALBINOT, 2019b). Trabalhos envolvendo alternativas de classificações confiáveis e soluções mais complexas são raros na literatura, sendo alguns exemplos encontrados nos trabalhos de (SCHEME *et. al.*, 2013), (AMSUSS *et. al.*, 2014), (BETTHAUSER *et. al.*, 2018), (ROBERTSON *et. al.*, 2018a) e (ROBERTSON *et. al.*, 2018b), comentados a seguir.

Em seu trabalho de apresentação da base NINAPro, (ATZORI *et. al.*, 2014) utiliza vários classificadores consolidados na área como k -NN, SVM, *Random Forests* e LDA juntamente a variações de *features* igualmente conhecidas envolvendo TD e TFD e dados de sensores inerciais. Como a ideia de seu trabalho não é propor métodos de processamento e classificação disruptivos, mas sim apresentar a base em si, não há muita inovação em relação aos métodos realizados. Entretanto este trabalho realiza uma boa variação de técnicas para a caracterização da base e apresenta classificações multimodais ao utilizar os dados de sensores inerciais juntamente ao sEMG. Os autores também estabelecem a taxa de acerto de referência para suas bases de dados, e em seu melhor resultado, utilizando somente sinais de sEMG e um classificador *Random Forests*,

atingem 75,27% de taxa de acerto global para a DB2 (NAMP). Taxa esta, inferior ao RELM em sua versão padrão (STD).

Em seu trabalho, (GIJSBERTS, *et. al.*, 2014) descrevem a aquisição de dados que, junto a outros ensaios posteriores viriam a formar a base NINAPro. Um grande esforço por parte dos autores é despendido na explicação dos dados adquiridos e de como os ensaios foram conduzidos. Adicionalmente também é ressaltada a porção da base relativa a sensores inerciais que dão a oportunidade de explorar modelos multimodais para a classificação dos movimentos. Em relação às técnicas de processamento e classificação utilizadas, 40 movimentos do segmento mão-braço (incluindo os 17 movimentos considerados neste trabalho) foram utilizados sendo a classificação foi realizada a partir de quatro *features* (RMS, histograma, mDWT e MAV), isoladas e em variações contendo interações entre elas. Três diferentes *kernels* foram utilizados juntamente a um classificador de estrutura similar ao SVM denominado *Kernel Regularized Least Squares* (KRLS). Dos *kernels* utilizados, é observada a desvantagem do uso do *kernel* linear em relação a taxa de acerto. Este resultado, assim como outros na área e alguns testes prévios envolvendo variações de *kernel* no ELM guiaram a decisão de utilizar o *kernel* RBF nesta Tese. Em seu trabalho, (GIJSBERTS, *et. al.*, 2014) ainda realizam a análise da classificação multimodal e enfatizam a contribuição dos dados provenientes dos sensores inerciais utilizados. Ao utilizar os dados provenientes dos sensores inerciais para a classificação multimodal os autores relatam um acréscimo na taxa de acerto de aproximadamente 9% quando comparam com a classificação realizada só com o RMS. De fato a taxa relatada tem um aumento de taxa de acerto global de 73,62% para 82,49%, sendo a taxa atingida através do uso do RMS inferior ao RELM em sua versão STD e na classificação multimodal compatível com as versões resilientes e com o método DISC do RELM que atinge esta taxa somente utilizando sinais de sEMG e também janelas de 400+100ms para a segmentação.

(ZHAI *et al.* 2016) atingiram 75,74% da taxa de acerto para a seção DB2 da base NAMP ao utilizarem uma representação em espectrograma, redução de dimensionalidade com PCA e segmentos de 200+100ms. Embora os autores enfatizem que seu método aprimora a representação do sinal em porções de transição de movimento, a utilização de um incremento de 100ms por si já oferece *features* mais representativas em comparação com a 400+10ms utilizada nesta Tese uma vez que a representatividade do sinal geralmente é proporcional ao seu comprimento. No entanto, o RELM padrão foi capaz de atingir $77,88 \pm 7,25\%$ de taxa de acerto global mesmo utilizando um

incremento de dados 10 vezes menor e uma taxa de atualização proporcional de janela de 2,5%. Uma grande desvantagem no uso de maiores incrementos de sinal reside no consequente atraso associado ao buffer de dados. Neste caso específico, os 100 ms de buffer de dados em si atingem o limite da controlabilidade ótima – onde: *delays* <125 são desejáveis e *delays* <100 são ótimos – do sistema proposta por FARRELL (FARRELL & WIER, 2007; FARRELL, 2011) sendo essa a principal motivação para a busca de soluções para melhorar a representatividade de incrementos de sinal mais curtos. Os 10ms de incremento permitem o uso de técnicas de pós-processamento para formar as formas confiáveis e resilientes do classificador e, mesmo assim, não exceder o limite recomendado de 100ms. Além disso, incrementos maiores implicam em menos amostras para classificar, o que pode resultar em menos robustez em relação à consistência da taxa de acerto do classificador.

Já em (ZHAI *et al.* 2017) um classificador baseado em uma Rede Neural Convolutacional (CNN), o espectrograma do sinal sEMG e um método auxiliar foram utilizados com os dados DB2 da base NAMP, atingindo até 80% da taxa de acerto. No entanto, o método explorado em (ZHAI *et al.* 2017) assim como outros métodos baseados na CNN são caracterizados por uma quantidade considerável de processamento. De fato, os autores relatam em seu trabalho que o processamento é realizado usando bibliotecas CUDA específicas para processamento paralelo em GPUs e, mesmo assim, requer aproximadamente 20 segundos para criar um classificador para 10 classes. Além disso, assim como em seu trabalho anterior, o método adaptativo proposto em (ZHAI *et al.* 2017) baseia-se em janelas deslizantes com 200ms de comprimento e 100ms de incremento combinados com um heurística de votação majoritária para a adaptação de uma saída atual. Seus 100ms incremento e seus resultados mais altos relatados com a utilização de 20 amostras implicam que os autores são capazes de alcançar tal precisão somente oferecendo um atraso mínimo de 2 segundos no processamento do sinal, o que não é adequado para o controle natural da interface. Portanto, mesmo o método do RELM padrão oferecendo resultados um pouco inferiores, ainda dá espaço a métodos de pós-processamento capazes de oferecer resultados significativamente superiores, o que de fato ocorre com o DISC e os métodos componentes da versão resiliente do classificador.

Outra abordagem que se utiliza de um classificador mais moderno foi realizada por (SAMADANI, 2018) que em seu trabalho utilizou um classificador LSTM com uma *Gated Recurrent Unit* e uma métrica de “atenção” do classificador (*Attention Mechanism*). Esta métrica

é relacionada com a capacidade de “aprender” do classificador e é usada para a extração de informação do sinal de sEMG e formação de um classificador mais estável. (SAMADANI, 2018) seguiu a hipótese de que este tipo de abordagem é capaz de selecionar entradas de uma sequência temporal que favoreçam mitigar erros causados pela característica não-determinística do sinal de sEMG. Para a obtenção de sinais mais estáveis, o autor utilizou-se do envelope linear dos sinais de sEMG do Exercício B da porção DB2 da base NINAPro. O autor relata a taxa global máxima de saída ao utilizar a versão Bidirecional do LSTM, o *Attention Mechanism* e uma taxa de aprendizagem que varia conforme o número de *epochs* utilizado. O autor relata taxas de acerto em torno de 86%, mas realiza uma divisão incomum para o treinamento do classificador separando 3 repetições de movimento para treino, uma para validação e duas para teste. Os períodos de segmentação ou *features* não foram detalhadas no artigo e nem o tempo de treinamento envolvido no processo, o que, para grandes volumes de dados, geralmente é uma limitação deste tipo de técnica. Apesar da taxa de acerto mencionada ser interessante e superior às apresentadas neste trabalho, detalhes a respeito de possíveis pontos negativos da técnica não são mencionados sendo uma desvantagem óbvia deste tipo de abordagem a necessidade de definição de muitos hiperparâmetros, além do tempo de treinamento. Duas métricas nas quais o RELM leva grande vantagem não somente em relação a técnicas de *Deep Learning*, mas também em relação a classificadores mais tradicionais.

Em relação a trabalhos envolvendo o ELM, ANAM & AL-JUMAILY utilizaram seus modelos de SRELM em (ANAM & AL-JUMAILY, 2015a) e SRDA com ELM e *Major-Voting* em (ANAM & AL-JUMAILY, 2015b). Através destes modelos, utilizaram, respectivamente, cinco e seis *features* de entrada extraídas de janelas fixas de 100ms para a classificação de 10 movimentos de dedos atingindo 95% e 94% em seus melhores resultados relatados médios. Este resultado é compatível com a média de aproximadamente 95% obtida para a base IEE no RELM padrão e inferior aos melhores resultados médios encontrados para o método DISC onde uma taxa de acerto global de $99,36 \pm 0,32\%$ foi encontrada para as 18 classes de movimentos deste trabalho.

Já em seu artigo mais recente, (ANAM & AL-JUMAILY, 2017) realizaram ensaios com 9 voluntários não amputados e 5 voluntários amputados para a formação de uma base de dados própria composta por seis repetições consecutivas de movimentos. Em relação aos movimentos, 14 combinações de movimentos de dedos foram realizadas pelos voluntários não amputados enquanto aos amputados foi pedido que imaginassem e tentassem executar 11 destas diferentes

combinações. Em ambos os casos, os movimentos foram intercalados com a “classe repouso”, que consistia em ficar relaxado sem tentar realizar nenhum movimento. Em ambas as bases, as taxas de acerto médias nos melhores casos atingiram 99%. Entretanto, (ANAM & AL-JUMAILY, 2017) recorreram ao descarte (não informado explicitamente de forma quantitativa) dos dados de transição dos movimentos. O descarte de dados realizado resultou em um número variável de amostras para treino e teste para cada voluntário. Estes números variaram entre $\cong 20,000$ a $\cong 39,000$ para não amputados e $\cong 8,600$ a $\cong 30,000$ para amputados quanto aos dados de treino e $\cong 6,600$ a $\cong 13,000$ para não amputados e $\cong 2,400$ a $\cong 10,000$ para amputados quanto aos dados de teste. Estes valores sugerem que os autores mantiveram somente as amostras mais representativas para a classificação dos dados descartando, em alguns casos, em torno de 70% dos dados de forma a obter taxas de acerto mais elevadas. Nesta Tese, as taxas médias de descarte de dados para todas as bases foi de $13,99 \pm 6,16\%$ para a base AMP, $16,68 \pm 2,37\%$ para a base NAMP e $12,32 \pm 1,40\%$ para o pior caso da base IEE, respectivamente. Ainda em relação as bases testadas, somente o voluntário 3 da base AMP teve uma taxa de descarte superior a 20% (22,08%). Complementarmente, (ANAM & AL-JUMAILY, 2017) utilizaram seis *features* e métodos de pós-processamento como MV para a obtenção de sua taxa de acerto média relatada de 99%. Nesta tese, os resultados de $99,36 \pm 0,32\%$ foram obtidos a partir do *threshold* simples da confiabilidade do sinal, sem a necessidade de métodos de pós-processamentos mais sofisticados e sem a necessidade de “bufferizar” a saída para aplicação de métodos como o *Major-Voting* usado por (ANAM & AL-JUMAILY, 2017). Complementarmente, os métodos desenvolvidos nesta Tese foram validados em 99 *trials* diferentes, envolvendo três bases de dados distintas.

Em seu artigo, (SHI *et. al.*, 2013) utilizaram diferentes comparações de *features* baseadas em entropia na classificação de seis classes distintas de movimentos de punho e mão para propor sua própria *feature*, denominada CREn. Os resultados obtidos variaram de 94% a 97% dependendo do tamanho da janela utilizada (de 200ms a 1s) para a extração da *feature* para os 10 voluntários envolvidos no estudo. Neste estudo, como já relatado anteriormente, utilizando-se a versão padrão do nosso classificador, taxas médias em torno de 95% foram obtidas considerando as variações da base IEE que chegaram a obter em torno de 99% uma vez que alguns métodos de pós-processamento foram aplicados mesmo utilizando-se 400+10ms para a segmentação, o que é uma configuração experimentalmente mais viável do que 1s para o uso da interface.

Ainda com relação ao uso do ELM para classificação de sinais de sEMG, (CENE & BALBINOT, 2019b) apresentam uma comparação entre métodos não-iterativos baseados no ELM básico e regularizado e no *Random Vector Functional-Link* (RVFL) em sua forma básica e regularizada e classificadores mais tradicionais (SVM e Regressão Logística, ambos regularizados). Os autores também efetuam uma vasta comparação entre combinação de canais e *features* derivadas de 10 voluntários AMP e 10 voluntários NAMP da base NINAPro para a determinação do melhor arranjo possível destes fatores em relação a taxa de acerto. A exploração do ELM em uma plataforma portátil baseada em Raspberry Pi também foi utilizada para a classificação dos dados utilizando 300+10ms de segmentação onde o tempo de treinamento do modelo foi em média, 15,47 segundos e o tempo de teste, 10,99ms. Através deste teste os autores demonstraram a viabilidade do uso do ELM em plataformas embarcadas, atingindo taxas de acerto médias de 77,20% para os voluntários NAMP e 55,30% para os voluntários AMP, respectivamente. Taxas estas que são equivalentes às médias encontradas neste trabalho, apesar de (CENE & BALBINOT, 2019b) ter uma população de teste para os voluntários NAMP consideravelmente menor e da população de testes de voluntários AMP desconsiderar o primeiro voluntário da DB3.

Com relação a trabalhos que envolvem métricas mais finas ou alternativas, ou modelos híbridos para a geração da classificação mais consistente dos sinais, a comparação direta muitas vezes é impraticável tendo em vista que os trabalhos são mais focados em classificação online de movimentos e não no uso de bases padrão. Isto implica tanto na utilização de métricas de avaliação diferentes quanto na influência do usuário no sistema, uma vez que ele pode ver os padrões de classificação e se adaptar a eles formando um sistema realimentado. Entretanto a discussão dos modelos teóricos e alternativas ainda é pertinente de forma a fomentar discussões sobre as possíveis vantagens e desvantagens dos modelos propostos frente as técnicas exploradas nesta Tese.

Em seu trabalho, (SCHEME *et. al.*, 2013) utilizam uma abordagem bastante similar ao método DISC utilizado nesta Tese. A técnica de (SCHEME *et. al.*, 2013) consiste em utilizar classificador baseado em LDA e uma métrica de confiabilidade associada que é inerente a classificação baseada em verossimilhança (*likelihood*) realizada pelo classificador. Após a classificação da amostra, um modelo Bayesiano de probabilidade condicional é utilizado para manter ou descartar a classificação realizada, dotando o classificador da capacidade de “negar

movimentos”, quando estes são desenvolvidos com um baixo grau de confiabilidade baseado em *thresholds* individuais para cada classe. Em comparação com a técnica DISC, (SCHEME *et. al.*, 2013) conseguem definir limiares individuais por classes para os seis movimentos testados enquanto o DISC utiliza um *threshold* geral de ativação da técnica para toda a base. Embora não seja possível realizar uma comparação de qual das técnicas envolvendo classificadores diferentes é a mais apropriada, a definição confiável de *thresholds* individuais por classes é certamente desejada. Embora tenham elaborado um método autônomo para a definição do *threshold*, seu ajuste parece não ser ótimo, uma vez que o assunto continua sendo explorado em seus trabalhos continuados descritos em (ROBERTSON *et. al.*, 2018a) e (ROBERTSON *et. al.*, 2018b). Nestes trabalhos os efeitos de diferentes níveis de *threshold* são testados e efeitos como o descarte em demasia de amostras são analisados. Como realizam testes online com voluntários controlando o sistema em tempo real os autores podem avaliar fatores interessantes sob a perspectiva da usabilidade da interface. Em suas conclusões os autores citam o fato de que, como esperado, impor *thresholds* muito permissivos para a ativação dos métodos, resulta em descartes de classificações corretas de dados (descarte em demasia), o que também afeta a controlabilidade do dispositivo. Os autores citam ainda que a despeito da contribuição significativa da estratégia de descarte de amostras não confiáveis nas taxas de acerto, o usuário ainda é o fator preponderante no sucesso das tarefas propostas e que a estratégia de definição ótima dos *thresholds* segue em aberto. Entretanto, a definição de *thresholds* individuais não só possibilita a atuação mais específica na seleção de amostras por classe, como para desenvolvimentos futuros, ao menos em tese, possibilitaria a geração de modelos regenerativos do classificador, capazes de identificar quando uma determinada classe necessitaria ser treinada novamente. Este tipo de abordagem pode ser particularmente útil em aplicações que envolvam, por exemplo, longo tempo de uso de dispositivos. Cenários estes, nos quais os modelos começam a acumular erros devido a mudanças apresentadas pelos sinais de sEMG em função de fatores fisiológicos (como fadiga) ou experimentais (como suor ou descolamento de eletrodos), por exemplo.

Com o intuito de formar um classificador mais robusto a possíveis variações de condições experimentais que prejudiquem a performance do classificador, (BETTHAUSER *et. al.*, 2018) utilizaram a estrutura do ELM para definir uma métrica de qualidade para as classificações realizadas utilizando modelos representação mais genéricos do sinal (*Sparse Representations*). Desta forma os autores tentam formar modelos mais “tolerantes” as variações características do

sEMG, demonstrando vantagens especificamente em relação a variações de resposta em função do posicionamento de membros. Os autores também utilizam *thresholds* para a identificação de classificações não confiáveis onde utilizam modelos auxiliares para a correção. Como esperado em função do uso do ELM frente outras técnicas testadas (incluindo LDA, RNA e SVM) foram relatadas vantagens quanto a velocidade de realização das tarefas propostas e a taxa de acerto global. Esta seria uma técnica diferente mas igualmente interessante para garantir o desempenho da interface em longos períodos de utilização.

Assim como (SCHEME *et. al.*, 2013), o trabalho de (AMSUSS *et. al.*, 2014) utiliza o LDA como classificador principal e uma RNA associada na saída que considera a separação entre classes e o nível de atividade muscular para inferir a confiabilidade da classificação realizada. Em seu trabalho, (AMSUSS *et. al.*, 2014) testaram uma série de ações a serem tomadas em substituição a uma classificação que não forneça uma separação desejada (definida por *threshold*) entre classes. As ações tomadas pelos autores consistiram em manter a classe anterior, o que seria comparável ao método HOLD explorado nesta Tese; utilizar *Major-Voting* retroativos, (como o MV também explorado nesta Tese); diferentes manipulações nos valores de saída e nos hiperparâmetros do modelo e descarte de amostras, atingindo resultados próximos a 100% para as oito classes de movimentos propostas em seus melhores resultados. Ao contrário dos resultados obtidos nesta Tese, os autores relatam aumentos substanciais com as técnicas similares as abordagens HOLD e MV utilizadas, que parecem ter se beneficiado da RNA na saída do classificador principal e das métricas adicionais utilizadas, como a amplitude do sinal de sEMG. Embora nossas soluções envolvendo os métodos HOLD, MV e MKV não tenham demonstrado aumentos significativos nas taxas de acerto, tanto a técnica baseada em descarte de amostras não significativas quanto os métodos do classificador resiliente demonstraram aumentos bastante expressivos das taxas de acerto que superam resultados citados na literatura e beneficiam significativamente o desempenho do classificador.

6 CONCLUSÕES E TRABALHOS FUTUROS

De forma geral esta Tese explorou alguns conceitos similares aos utilizados em trabalhos do estado da arte na classificação de sinais de sEMG e os comparou com as alternativas de cunho pragmático desenvolvidas que levam em conta a aplicação proposta e as limitações ainda em aberto na área. Em relação a escolha do classificador a ser utilizado foram considerados fatores como capacidade de generalização, praticidade e a estratégia computacional utilizada para a formação do modelo. Desta forma, o ELM foi escolhido por ser uma alternativa mais prática e veloz para a formação do modelo devido a quantidade reduzida de hiperparâmetros e a abordagem não-iterativa. Embora o ELM demande um custo alto de memória para a manipulação das matrizes que compõe o método, aplicações em plataformas embarcadas já demonstraram a potencialidade em relação a portabilidade das técnicas, o que é importante do ponto de vista de aplicação. O ELM ainda se apresenta como um classificador bastante versátil, permitindo uma integração muito prática dos métodos de pós-processamento e regularização utilizados neste trabalho. O ELM possui ainda a vantagem de utilizar o *arg max* como parte inerente do seu processo de classificação, o que permitiu o desenvolvimento do ELM de *arg max* suavizado, da métrica de confiabilidade e da Separação Diferencial Mínima, todos utilizados em modelos deste trabalho.

Em relação aos métodos em sua forma mais elementar, a regularização do método de classificação mesmo em sua forma padrão (RELM) possibilitou o alcance de taxas equivalentes ou superiores em relação aos trabalhos da literatura. Já em relação a escolha de hiperparâmetros, a segmentação do sinal ao invés do uso do movimento completo possibilitou uma análise bastante aprofundada que deu espaço a proposição das soluções deste trabalho para a mitigação de erros em períodos de transição e ruídos de classificação.

O estudo do tamanho ideal das janelas deslizantes utilizadas na segmentação e do impacto deste na latência na classificação, levou a uma seleção ótima de parâmetros (janelas de 400ms com incremento de 10ms), que permitem uma utilização adequada das metodologias deste trabalho no reconhecimento em tempo real dos movimentos (permitindo a sua aplicação prática em interfaces). O tempo de segmentação utilizado demonstrou ser um fator significativo nas taxas de acerto alcançadas em função da representatividade dos sinais associada. Embora este fator influencie a taxa de resposta, ainda possui um efeito mais ameno do que o tipo de voluntário testado, onde, de forma geral, os amputados atingem menores taxas de acerto. Entretanto, há exceções para alguns

amputados que já estão acostumados com o uso de próteses de controle mioelétrico capazes de atingir taxas compatíveis aos melhores desempenhos individuais deste trabalho. Esse resultado indica a influência do treino nos resultados e a importância do acompanhamento fisioterápico pós-operatório adequado neste processo.

Em relação aos métodos de pré-processamento, foi adaptado o filtro AVT que se mostrou propício à aplicação e um potencializador da taxa de acerto. O AVT ainda foi utilizado para o desenvolvimento do ELM de *arg max* suavizado, que apesar de basear-se em uma adaptação bastante simples, apresentou um desempenho bastante satisfatório em relação a eliminação de ruídos de classificação. Ainda no pré-processamento, foi criada a feature *Differential Enhanced Signal*, que provou melhorar a representatividade do sinal de sEMG em períodos de transição, fornecendo uma maior taxa de acerto e diminuindo a taxas de descarte de dados e de reclassificação nestas seções do sinal.

Foram propostas abordagens e métodos de classificação confiáveis e resilientes, sendo avaliados de forma extensiva e consistente, onde observou-se aumentos significativos das taxas de acerto. O método DISC foi capaz de realizar o reconhecimento e descarte autônomo das amostras não confiáveis do sistema que frequentemente geram erro no classificador e impedem um controle proprioceptivo adequado para este tipo de interface. Já o SMT é capaz de atingir taxas de acerto intermediárias entre o RELM padrão e o DISC sem realizar o descarte de nenhuma amostra por mitigar ruídos de classificação que tipicamente ocorrem nas zonas intermediárias de movimento ativo. O SMT também possibilitou a geração da métrica de Separação Diferencial Mínima (SDM), utilizada como base do método TH. O método TH assim como o BIN foi utilizado no intuito de aprimorar o reconhecimento das classes de repouso e movimento ativo, favorecendo a taxa de acerto em zonas de transição e mitigando a latência de resposta no início do movimento e retorno prematuro para a classe de repouso no final. De forma geral, o modelo confiável demonstrou sua capacidade de selecionar dados mais propícios ao funcionamento contínuo do sistema, entretanto necessita de sinais minimamente representativos para a distinção entre amostras confiáveis e *outliers* do modelo. Já em sua forma resiliente, o classificador mostrou-se como uma alternativa interessante para bases que possuem mais ruído e não são tão bem comportadas, como as NINAPro (com destaque para a base de amputados).

Em relação a coleta de dados, a base IEE foi montada e publicada e está em constante expansão. Disponibilizando esta base espera-se fomentar a troca de ideias entre os diferentes

grupos de estudo na área que carecem de dados e métodos mais padronizados que possibilitem a discussão científica na área e a comparação mais apropriada de resultados. Ainda em relação a comparação de resultados, a utilização de duas métricas pareadas, uma representando a taxa média global e outra a taxa média ponderada se mostrou bastante útil na avaliação do sistema. Igualmente, a visualização de forma gráfica do *label* ideal e do *label* predito foi muito útil para identificar porções do sinal nas quais havia a ocorrência de erro e propor soluções adequadas.

Em relação aos trabalhos futuros, a base IEE ainda está sendo aumentada na medida em que novos voluntários são recrutados e novos ensaios são realizados, incluindo ensaios com voluntários com deficiências congênitas, algo dificilmente encontrado nas bases públicas disponíveis online. Em relação aos métodos desenvolvidos, embora o desempenho do MKV não tenha sido capaz de melhorar as taxas das bases testadas, devido à natureza sequencial marcante da aplicação, modelos de probabilidade condicional ainda podem ser testados e avaliados em substituição ao MKV. Alguns bons candidatos como o *Conditional Random Fields* ou classificadores bayesianos podem ser considerados para a formação de uma saída mais consistente, assim como métodos mais recentes, como o LSTM. Já a latência apresentada pelo TH pode ser mitigada com a utilização de um filtro alternativo para a suavização do *arg max*. Embora um filtro mais suave ou de menor ordem tenda a diminuir a eficiência do SMT na filtragem de ruídos, a ponderação de filtragem \times *delay* consiste em um teste pertinente na busca pelo equilíbrio ótimo destes dois fatores.

Em relação a métrica de confiabilidade desenvolvida, na medida em que as métricas e o modelo são refinados, é desejável chegar em uma métrica de confiabilidade consistente para a definição de *thresholds* individuais. Estes *thresholds*, possibilitariam uma atuação mais específica no descarte de amostras não representativas e também modelos de classificação regenerativos específicos por classe. Este tipo de abordagem é útil e desejável em aplicações que envolvam longo tempo de uso onde contaminantes e não idealidades impedem a classificação ótima. Embora no modelo atual estas abordagens estejam sendo utilizadas para a classificação de sinais de sEMG onde a separação de classes é uma tarefa bastante árdua, o modelo realizado ainda não foi utilizado para a classificação de outros tipos de dados. Em outras aplicações talvez já seja possível, mesmo com o modelo atual, a distinção da métrica de confiabilidade para diferentes classes, sendo este um teste futuro recomendável pelo seu potencial impacto na área.

REFERÊNCIAS

- AZIZIAGHDAM, M.; SAMUR, E. Providing contact sensory feedback for upper limb robotic prosthesis. *In: IEEE HAPTICS SYMPOSIUM (HAPTICS)*, 3., 2014, Houston. **Proceedings [...]** New York: IEEE, 2014.
- ALBERT, A. **Regression and the Moore-Penrose pseudoinverse**. New York: Academic Press, Inc., 1972.
- AKUSOK, A.; MICHE, Y.; LENDASSE, A. High-performance extreme learning machines: a complete toolbox for big data applications. **IEEE Transactions on Neural Networks**, New York, v. 3, p. 1011-1025, 2015.
- AL-TIMEMY, A. H.; MEMBER, S.; BUGMANN, G.; ESCUDERO, J.; OUTRAM, N. Classification of finger movements for the dexterous hand prosthesis control with surface electromyography. **IEEE Journal of Biomedical and Health Informatics**, New York, v. 17, n. 3, p. 608-618, 2013.
- AMSUSS, S.; GOEBEL, P. M.; JIANG, N. *et al.* Self-correcting pattern recognition system of surface EMG signals for upper limb prosthesis control. **IEEE Transactions on Biomedical Engineering**, New York, v. 61, n. 4, p. 1167-1176, 2014.
- ANAM, K.; AL-JUMAILY, A. Adaptive Wavelet Extreme Learning Machine (AW-ELM) for index finger recognition using two-channel electromyography. *In: CHU, K. H.; LOO, K.; YAP, K.; WONG, K.; TEOH. A. Lecture Notes in Computer Science*, Kuching, Malaysia, Springer, Cham, 2014.
- ANAM, K.; AL-JUMAILY, A. A Robust myoelectric pattern recognition using online sequential extreme learning machine for finger movement classification. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 37., 2015, Milan. **Proceedings [...]** New York: IEEE, 2015a.
- ANAM, K.; AL-JUMAILY, A. A Novel extreme learning machine for dimensionality reduction on finger movement classification using sEMG. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 37., 2015, Milan. **Proceedings [...]** New York: IEEE, 2015b.
- ANAM, K.; AL-JUMAILY, A. Evaluation of extreme learning machine for classification of individual and combined finger movements using electromyography on amputees and non-amputees. **Neural Networks**, [S.l.], v. 85, p. 5168, 2017.
- ASBECK, A. T.; DE ROSSI, S. M.; GALIANA, I.; DING, Y.; WALSH, C. J. Stronger, smarter, softer: next-generation wearable robots. **IEEE Robot. Autom. Mag.**, New York, v. 21, n. 4, p. 22-33, Dec. 2014.
- ATZORI, M. *et al.* Building the NINAPro database: A resource for the biorobotics community. *In: INTERNATIONAL CONFERENCE ON BIOMEDICAL ROBOTICS AND BIOMECHATRONICS (BioRob)*, 4., 2012, Rome. **Proceedings [...]** New York: IEEE, 2012.

ATZORI, M. *et al.* Electromyography data for non-invasive naturally controlled robotic hand prostheses. **Nature Scientific Data**, n. 1, v. 1, p. 1-13, 2014. Disponível em: <http://www.nature.com/articles/sdata201453>. Acesso em: 13 fev. 2015.

ATZORI, M.; GIJSBERTS, A.; KUZBORSKIJ, I. *et al.* Characterization of a benchmark database for myoelectric movement classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. PP, n. 99, p. 1, 2015.

AWAD, L. N. *et al.* A soft robotic exosuit improves walking in patients after stroke. **Science Translational Medicine**, v. 9, n. 400, np, July. 2017.

BALBINOT, A.; FAVIEIRO, G. A neuro-fuzzy system for characterization of arm movements. **Sensors**, Basel, v. 13, n. 2, p. 2613-2630, 2013.

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

BELTRAMINI, L. M. **Elementos de histologia e anátomo-fisiologia humana**. São Carlos: Serviço Gráfico do Instituto de Física de São Carlos - USP, 1997. v. 1.

BEN-ISRAEL, A. The Moore of the Moore-Penrose inverse. **Electronic Journal of Linear Algebra**, [S.l.], v. 9, p. 370-420, 2002.

BENEDETTI, M. G. Muscle activation intervals and EMG envelope in clinical gait analysis. **IEEE Engineering in Medicine and Biology Magazine**, New York, v. 20, n. 6, p. 33-34, Nov. 2001.

BETTHAUSER, J. L. *et al.* Limb position tolerant pattern recognition for myoelectric prosthesis control with adaptive sparse representations from extreme learning. **IEEE Transactions on Biomedical Engineering**, New York, v. 65, n. 4, p. 770-778, 2018.

BOTTER, A.; VIEIRA, T.M filtered virtual reference: a new method for the reduction of power line interference with minimal distortion of monopolar surface EMG. **IEEE Transactions on Biomedical Engineering**, New York, v. 65, n. 4, p. 2638-2647, Nov. 2015.

BRONZINO, J.; ENDERLE, J. **Introduction to Biomedical Engineering**. 3rd. ed. Burlington: Elsevier, 2012.

CAI, L. *et al.* Classifying EMG signals using T-F representation and SVD for artificial limb control. *In: FIRST JOINT BMES/EMBS CONFERENCE*, 21., 1999, Atlanta. **Proceedings [...]** New York: IEEE, Out. 1999.

CALVERT, T. W.; CHAPMAN A. E. The relationship between the surface EMG and force transients in muscle: simulation and experimental studies. **Proceedings of the IEEE**, New York, v. 65, n. 4, p. 682-689, May 1977.

CAO, H.; SUN, S.; ZHANG, K. Modified EMG-based handgrip force prediction using extreme learning machine. **Soft Computing**, Berlin, v. 21, n. 2, p. 491-500, 2015.

CENE, V. H.; FAVIEIRO, G.; BALBINOT A. Upper-limb movement classification based on sEMG signal validation with continuous channel selection. *In: ANNUAL INTERNATIONAL*

CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 37., 2015, Milan. **Proceedings [...]**, New York: IEEE, 2015.

CENE, V. H.; FAVIEIRO, G.; BALBINOT A. Using non-iterative methods and random weight networks to classify upper-limb movements through sEMG signals. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 39., 2017, Jeju. Proceedings [...]* New York: IEEE, 2017a.

CENE, V. H.; FAVIEIRO, G.; NEDEL, L.; BALBINOT A. Reever control: a biosignal controlled interface. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 39., 2017, Jeju. Proceedings [...]* New York: IEEE, 2017b.

CENE, V. H, *et. al.* The use of sEMG signals as a natural control interface. *In: MITCHEL, D. Surface electromyography: fundamentals, computational techniques and clinical applications.* New York: Nova Science Publishers, 2016a.

CENE, V. H.; BALBINOT, A. Avaliação da influência das entradas na classificação de movimentos através de processamento de sinais de sEMG. *In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDIA, 25., 2016, Foz do Iguaçu. Anais [...]* Rio de Janeiro: SBEB, 2016b.

CENE, V. H.; BALBINOT, A. Using the sEMG signal representativity improvement towards upper-limb movement classification reliability. **Biomed. Signal Process. Control**, [S.l.], v. 46, p. 182-191, Sep. 2018a.

CENE, V. *et al.* Open database for accurate upper-limb intent detection using electromyography and reliable extreme learning machines. **SENSORS**, Basel, v. 19, n. 8, p. 1864-1884, 2019a.

CENE, V. H.; BALBINOT, A. Enhancing the classification of hand movements through sEMG signal and non-iterative methods. **Health and Technology**, [S. l.], v. 9, n. 4, p. 561-577, 2019b.

CENE, V. H.; MACHADO, J.; BALBINOT, A. smoothed arg max extreme learning machine: an alternative to avoid classification ripple in sEMG signals. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 41., 2019, Berlin. Proceedings [...]* New York: IEEE, 2019c.

CENE, V. H. **Desenvolvimento de um projeto de experimentos para a caracterização de sinais mioelétricos através do uso de regressão logística.** 2016. 128p. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016c.

CENE, V. H.; SANTOS, R. R. DOS; BALBINOT, A. Using antonyan vardan transform and extreme learning machines for accurate sEMG signal classification. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 40., 2018, Honolulu. Proceedings [...]* New York: IEEE, 2018b.

CHOWDHURY, R. H. *et. al.* Surface electromyography signal processing and classification techniques. **SENSORS**, Basel, v. 13, p. 12431-12466. 2013.

- CRAM, J. R. The history of surface electromyography. **Applied Psychophysiology and Biofeedback**, New York, v. 28, n. 2, Jun. 2003.
- ENDERLE, J. D. Senior design for persons with disabilities. **IEEE Engineering in Medicine and Biology Magazine**, New York, v. 25, n. 3, p. 25-29, 2006.
- ENGLEHART, K. *et al.* classification of myoelectric signal using time-frequency based representations. **Medical Engineering & Physics**, New York, v. 21, n. 6, p. 431-438, 1999.
- EUBANK, R.L. A Kalman filter primer. Boca Raton, Chapman & Hall/CRC, 2006.
- FARINA, D. *et al.* The extraction of neural information from the surface EMG for the control of upper-limb prostheses: emerging avenues and challenges. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 22, n. 4, p. 797-809, July 2014.
- FARRELL T. R. Determining delay created by multifunctional prosthesis controllers. **Journal of Rehabilitation Research & Development**, Washington, DC, v. 48, n. 6, p. 21-37, 2011.
- FARRELL, T. R.; WEIR, R. F. The optimal controller delay for myoelectric prostheses. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 15, n. 1, p. 111-118, Mar 2007.
- FREITAS, R. C.; ALVES, R.; SILVA FILHO, A. G.; SOUZA, R. E.; BEZERRA, B. L. D.; DOS SANTOS, W. P. Electromyography-controlled car: a proof of concept based on surface electromyography, extreme learning machines and low-cost open hardware, **Computers & Electrical Engineering**, [S.l.], v. 73, p. 167-179, Jan. 2019.
- GEETHANJALI, P. Comparative study of PCA in classification of multichannel EMG signals. **Australasian Physical & Engineering Sciences in Medicine**, [S.l.], v. 38, p. 331-343, 2015.
- GIJSBERTS, A. *et al.* The movement error rate for evaluation of machine learning methods for sEMG-based hand movement classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 22, n. 4, p. 735-744, 2014.
- GUIDOTTI D.; LEOFANTE F.; TACHELLA A.; CASTELLINI C. Improving reliability of myocontrol using formal verification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 22, n. 4, p. 564-571, Apr. 2019.
- GUYTON, A. C. **Fisiologia humana**. 11. ed. Rio de Janeiro: Guanabara Koogan, 2006.
- HABERMANN, D. *et al.* Road junction detection from 3D point clouds. *In*: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 1., 2016, Vancouver. **Proceedings [...]** New York: IEEE, Nov. 2016.
- HAN, H.; JO, S. Supervised hierarchical Bayesian model-based electromyographic control and analysis. **IEEE Journal of Biomedical and Health Informatics**, New York, v. 18, n. 4, p. 1214-1224, 2014.
- HASHIM, F.R. *et al.* EMG cancellation from ECG signals using modified NLMS adaptive filters. *In*: IEEE CONFERENCE ON BIOMEDICAL ENGINEERING AND SCIENCES (IECBES), 1., 2015, Kuala Lumpur. **Proceedings [...]** New York: IEEE, Feb. 2015.

- HAYKIN, S. **Neural networks and learning machines**. 3rd ed. New Jersey: Pearson, 2008.
- HE, Y.; FUKUDA, O.; BU, N.; OKUMURA, H.; YAMAGUCHI N. Surface EMG pattern recognition using long short-term memory combined with multilayer perceptron. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 40., 2018, Honolulu. **Proceedings [...]** New York: IEEE, 2018.
- HOFMANN, D.; JIANG, N.; VUJAKLJA, I. Bayesian filtering of surface EMG for accurate simultaneous and proportional prosthetic control. **IEEE Transactions on Biomedical Engineering**, New York, v. 24, n. 12, p. 1333-1341, 2016.
- HUANG, G. An insight into extreme learning machines: random neurons, random features and kernels. **Cognitive Computation**, New York, v. 6, n. 3, p. 376-390, 2014.
- HUDGINS, B.; PARKER, P.; SCOTT, R. A new strategy for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, New York, v. 40, n. 1, p. 82-94, 1993.
- ISON, M.; ARTEMIADIS, P. 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.
- JIANG, N. *et al.* Is accurate mapping of EMG signals on kinematics needed for precise online myoelectric control? **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 22, n. 3, p. 549-558, 2014.
- KRASOULIS, A.; KYRANOU, I.; ERDEN, M. S.; NAZARPOUR, K.; VIJAYAKUMAR, S. Improved prosthetic hand control with concurrent use of myoelectric and inertial measurements. **Journal of Neuroengineering and Rehabilitation**, [S.l.], v. 14, n. 1, p. 71, Dec. 2017.
- KIM, M.; KIM, K. Pilot study on prediction of human hand configuration using transient state of surface-electromyography signals. *In: INTERNATIONAL CONFERENCE ON CONTROL, AUTOMATION AND SYSTEMS (ICCAS)*, 13., 2013, Gwangju. **Proceedings [...]** New York: IEE, Jan. 2013.
- KIM, S. *et al.* Assessing the influence of a passive, upper extremity exoskeletal vest for tasks requiring arm elevation: Part I - “expected” effects on discomfort, shoulder muscle activity, and work task performance. **Applied Ergonomics**, [S.l.], v. 70, p. 315-322, 2018a.
- KIM, S. *et al.* Assessing the influence of a passive, upper extremity exoskeletal vest for tasks requiring arm elevation: Part II - “unexpected” effects on shoulder motion, balance, and spine loading. **Applied Ergonomics**, [S.l.], v. 70, p. 323-330, 2018b.
- KIM, Y.G.; XILOYANNIS, M.; ACCOTO, D.; MASIA, L. Development of a soft exosuit for industrial applications. *In: IEEE INTERNATIONAL CONFERENCE IN BIOMEDICAL ROBOTS AND BIOMECHATRONICS (BIOROB)*, 7., 2018, Enschede. **Proceedings [...]** New York: IEE, Oct. 2018.
- KHUSHABA, R.N. *et al.* Electromyogram (EMG) based fingers movement recognition using neighborhood preserving analysis with QR-decomposition. *In: INTERNATIONAL CONFERENCE ON INTELLIGENT SENSORS, SENSOR NETWORKS AND*

- INFORMATION PROCESSING, 7., 2011, Adelaide. **Proceedings [...]** New York: IEEE, Feb. 2011.
- KHUSHABA, R. N.; TAKRURI, M.; MIRO, J. V.; KODAGODA, S. Towards limb position invariant myoelectric pattern recognition using time-dependent spectral features. **Neural Networks**, [S.l.], v. 55, p. 42-58, July 2014.
- KHUSHABA, R. N.; AL-TIMEMY, A.; AL-ANI, A.; AL-JUMAILY, A. Myoelectric feature extraction using temporal-spatial descriptors for multifunction prosthetic hand control. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 38., 2016, Orlando. **Proceedings [...]** New York: IEEE, 2016.
- KWON, S.; KIM, J. Real-time upper limb motion estimation from surface electromyography and joint angular velocities using an artificial neural network for human-machine cooperation. **IEEE Transactions Information Technology in Biomedicine**, New York, v. 15, n. 4, p. 522-520, 2011.
- KRASOULIS, A.; KYRANOU, I.; ERDEN, M. S.; NAZARPOUR, K.; VIJAYAKUMAR, S. Improved prosthetic hand control with concurrent use of myoelectric and inertial measurements. **Journal of Neuroengineering and Rehabilitation**, [S.l.], v. 14, n. 1, p. 71, Dec. 2017.
- KUZBORSKI, I.; GIJSBERTS, A.; CAPUTO, B. On the challenge of classifying 52 hand movements from surface electromyography. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 34., 2012, San Diego. **Proceedings [...]** New York: IEEE, 2012.
- LEE, W. S.; LIU, B. Learning with positive and unlabeled examples using weighted logistic regression. *In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING (ICML)*, 20., 2003, Washington. **Proceedings [...]** [S.l.: s.n.], 2003.
- LEE, H. *et al.* Online remote control of a robotic hand configurations using sEMG signals on a forearm. *In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND BIOMIMETICS*, 2011, Karon Beach. **Proceedings [...]** New York: IEEE, 2011.
- LEVINSON, S. E. Hidden Markov model speech recognition arrangement. **The Journal of the Acoustical Society of America**, [S. l.], v. 86, n. 6, p. 2478-2478, 1989.
- LIN, J.F.S.; KULIC, D. Online segmentation of human motion for automated rehabilitation exercise analysis. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 22, n. 1, p. 168-180. Jan. 2014
- LIN Z. *et al.* Extreme learning machine on high dimensional and large data applications. **Mathematical Problems in Engineering**, [S.l.], v. 2015, n. 103796, p. 1-13, Mar. 2015.
- LINS, R.G. *et al.* Development and implementation of a natural interface to control an industrial hydraulic robot arm. *In: ANNUAL IEEE INTERNATIONAL SYSTEMS CONFERENCE (SYSCON)*, 9., 2015, Vancouver. **Proceedings [...]** New York: IEEE, 2015.
- LIU, W. Natural user interface-next mainstream product user interface. *In: IEEE INTERNATIONAL CONFERENCE OF COMPUTER-AIDED INDUSTRIAL DESIGN &*

- CONCEPTUAL DESIGN (CAIDCD), 11., 2010, Yiwu. **Proceedings [...]** New York: IEEE, 2010.
- LIU H.; GEGOV A.; STAHL F. Unified framework for construction of rule-based classification systems. *In: PEDRYCZ W.; CHEN S. M. Information granularity, big data, and computational intelligence: studies in big data*, v. 8, [S.l.], 2014.
- LOCK, B.; ENGLEHART, K.; HUDGINS, B. Real-time myoelectric control in a virtual environment to relate usability vs. accuracy. *In: MEC SYMPOSIUM CONFERENCE, 2005*, New Brunswick. **Proceedings [...]** New Brunswick: New Brunswick University, 2005.
- MA, J.; THAKOR, N. V.; MATSUNO, F. Hand and wrist movement control of myoelectric prosthesis based on synergy. **IEEE Transactions on Human-Machine Systems**, New York, v. 45, n. 1, p. 74-83, Feb. 2015.
- MACHADO, J. C.; CENE, V. H.; BALBINOT, A. recurrent neural network as estimator for a virtual sEMG channel. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 41., 2019*, Berlin. **Proceedings [...]** New York: IEEE, 2019.
- MACIEJASZ, P.; ESCHWEILER, J.; GERLACH-HAHN, K.; JANSEN-TROY, A.; LEONHARDT, S. A survey on robotic devices for upper limb rehabilitation. **Journal of Neuro Engineering and Rehabilitation**, [S.l.], v. 11, n. 3. p. 1-29, Jan. 2014.
- MALMIVUO, J.; PLONSEY, R. **Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields**. 1st ed. New York: Oxford University Press, 1995.
- MCLESTER, J.; ST. PIERRE, P. **Applied biomechanics**. 1st ed. Belmont: Wadsworth, 2008.
- MESQUITA, D. P. *et al.* Pruning extreme learning machines using the successive projections algorithm. **IEEE Latin America Transactions**, [S.l.], v. 13, n 12, p. 3974-3979, 2015.
- MEULDERS, A. *et al.* Generalization gradients in cued and contextual pain-related-fear: an experimental study in healthy participants. **Frontiers in Human Neuroscience**, Lausanne, v. 7, p. 345, 2013.
- MICHE, Y. *et al.* OP-ELM: Optimally pruned extreme learning machine, **IEEE Transactions on Neural Networks**, New York, v. 21, n. 1, p. 158-162, Jan. 2010.
- MICERA, S.; SABATINI, A.M.; DARIO, P. On automatic identification of upper-limb movements using small-sized training sets of EMG signals. **Medical Engineering & Physics Journal**, [S.l.], v. 22, n. 8, p. 527-533, Oct. 2000.
- MICERA, S.; CARPANETO, J.; RASPOPOVIC S. Control of hand prosthesis using peripheral information. **IEEE Reviews in Biomedical Engineering**, New York, v. 3, p. 48-68, 2010.
- MIRANDA DE SÁ, A. M. F. L. *et al.* A principal component-based algorithm for denoising in single channel data. **Measurement**, Amsterdam, v. 60, p. 121-128, Jan. 2015.
- MOORE, J.; ZOURIDAKIS, G. **Biomedical technology and devices handbook**. Boca Raton: CRC Press LLC, 2004.

- MURAKAMI, J. *et al.* Detection of the human-activity using the FCM. *In: INTERNATIONAL CONFERENCE ON CONTROL, AUTOMATION AND SYSTEMS, 2017, Seoul. Proceedings [...]* New York: IEEE, 2016.
- NAIK, G.R.; DINESH, K. Identification of hand and finger movements using multi run ICA of surface electromyogram. **Journal of Medical Systems**, [S.l.], v. 36, n. 2, p. 841-851, July 2010.
- NAIK, G.R.; BAKER, K.G.; NGUYEN, H.T. Dependence independence measure for posterior and anterior EMG sensors used in simple and complex finger flexion movements: evaluation using SDICA. **IEEE Journal of Biomedical and Health Informatics**, New York, v. 19, n. 5, p. 1689-1696, Sep. 2015.
- NAIK, G.R. *et al.* Transradial amputee gesture classification using an optimal number of sEMG sensors: an approach using ICA clustering. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 24, n. 8, p. 837-846. Aug. 2016.
- NILSON, C. P. **Aquisição, processamento de sinais mioelétricos e máquina de vetores de suporte para caracterização de movimentos do segmento mão-braço.** 2014. 88p. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul. Escola de Engenharia. Departamento de Engenharia Elétrica, Porto Alegre, 2014.
- ORTOLAN, R. L. *et al.* Evaluation of adaptive/nonadaptive filtering and wavelet transform techniques for noise reduction in EMG mobile acquisition equipment. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 1, n. 1, p. 60-69. May 2003.
- PALERMO, F.; COGNOLATO, M.; GIJSBERTS, A.; MULLER, H.; CAPUTO, B.; ATZORI, M. Repeatability of grasp recognition for robotic hand prosthesis control based on sEMG data. *In: INTERNATIONAL CONFERENCE ON REHABILITATION ROBOTICS (ICORR), 2017, London. Proceedings [...]* New York: IEEE, 2017.
- PARK, S.; CHUNG W. K. Dynamic Motion Phase Segmentation Using Electromyogram. *In: INTERNATIONAL CONFERENCE ON UBIQUITOUS ROBOTICS AND AMBIENT INTELLIGENCE, 12., 2017, Goyang. Proceedings [...]* New York: IEEE, 2015.
- PARK, M. S.; KIM, K.; OH, S. R. A fast classification system for decoding of human hand configurations using multi-channel sEMG signals. *In: IEEE/RSJ INTERNATIONAL CONFERENCE ON INTELLIGENT ROBOTS AND SYSTEMS, 2011, [S.l.]. Proceedings [...]* New York: IEEE, 2015.
- PAN, L.; HARMODY, A.; HUANG, H. A reliable multi-user EMG interface based on a generic-musculoskeletal model against loading weight changes. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 40., 2018, Honolulu. Proceedings [...]* New York: IEEE, 2018.
- PHINYOMARK A.; PHUKPATTARANONT, P.; LIMSAKUL, C. Feature reduction and selection for EMG signal classification. **Expert Systems with Applications**, Elmsford, v. 39, n. 8, p. 7420-7431, June 2012.

- PHINYOMARK A. *et al.* EMG Feature evaluation for improving myoelectric pattern recognition robustness, **Expert Systems Applications**, Elmsford, v. 40, n. 12, p. 4832-4840. Sep. 2013.
- PIOTROWSKI, T.; YAMADA, I. MV-PURE estimator: minimum-variance pseudo-unbiased reduced-rank estimator for linearly constrained ill-conditioned inverse problems. **IEEE Transactions on Signal Processing**, New York, v. 56, n. 8, p. 3408-3423. Aug. 2008.
- QIU, J.; WU, Q.; DING, G.; XU, Y.; FENG, S. A survey of machine learning for big data processing. **EURASIP Journal on Advanced in Signal Processing**, [S.l.], v. 2016, n. 1, p. 67-83, Dec. 2016.
- RAJESH, V.; KUMAR, P.R. Hand gestures recognition based on sEMG signal using wavelet and pattern recognition. **International Journal of Recent Trends in Engineering**, [S.l.], v. 1, n. 4, p. 26-28, May 2009.
- RIILLO, F. *et al.* Evaluating the influence of subject-related variables on EMG-based hand gesture classification. *In: IEEE INTERNATIONAL SYMPOSIUM ON MEDICAL MEASUREMENTS AND APPLICATIONS*, 2014, Lisbon. **Proceedings [...]** New York: IEEE, 2014.
- ROBERTSON, J. W.; ENGLEHART, K. B.; SCHEME, E. J. Rejection of systemic and operator errors in a real-time myoelectric control task. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 40., 2018, Honolulu. **Proceedings [...]** New York: IEEE, 2018a.
- ROBERTSON, J.; SCHEME, E.; ENGLEHART, K. Effects of confidence-based rejection on usability and error in pattern recognition-based myoelectric control. **IEEE Journal of Biomedical and Health Informatics**, New York, v. 4, n. 5, p. 1-7, Oct. 2018b.
- ROSSI, M. *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, Seville. **Proceedings [...]** New York: IEEE, 2015.
- SAMADANI, A. Gated recurrent neural networks for EMG-based hand gesture classification: a comparative study. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 40., 2018, Honolulu. **Proceedings [...]** New York: IEEE, 2018.
- SCARDAPANE, S. *et al.* A semi-supervised random vector functional-link network based on the transductive framework. **Information Sciences**, v. 364-365, p. 156-166, Oct. 2016.
- SCHEME, E. J.; HUDGINS, B. S.; ENGLEHART, K. B. Confidence-based rejection for improved pattern recognition myoelectric control. **IEEE Transactions on Biomedical Engineering**, New York, v. 60, n. 6, p. 1563-1570. Jan. 2013.
- SHI, J. *et al.* sEMG-based hand motion recognition using cumulative residual entropy and extreme learning machine. **Medical & Biological Engineering Computing**, Berlin, v. 51, p. 417-427. Apr. 2013.

- TACCHINO, G. *et al.* EEG analysis during active and assisted repetitive movements: evidence for differences in neural engagement. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 25, n. 6, p. 761-771. June 2017.
- TANG, Z. *et al.* An upper-limb power-assist exoskeleton using proportional myoelectric control. **SENSORS**, Basel, v. 14, n. 4, p. 6677-6694. Apr. 2014.
- TANG, J.; DENG, C.; HUANG, G. Extreme learning machine for multilayer perceptron. **IEEE Transactions on Neural Networks and Learning Systems**, New York, v. 27, n. 4, p. 809-821. Apr. 2016.
- TORTORA, G. J. **Princípios de anatomia humana**. 10. ed. Rio de Janeiro: Guanabara Koogan, 2007.
- TSENG, C. C.; LEE, S. L. Design of graph filter in ill-posed condition using Tikhonov regularization. *In: IEEE INTERNATIONAL CONFERENCE ON CONSUMER ELECTRONICS - TAIWAN (ICCE-TW), 2015, Taiwan. Proceedings [...]* New York: IEE, 2015.
- WANG, J. *Geometric structure of high-dimensional data and dimensionality reduction*. [S.l.]: Springer, 2012.
- XIAO, X.G.; ELNADY, A.M.; MENON. Control an exoskeleton for forearm rotation using FMG. *In: IEEE RAS/EMBS INTERNATIONAL CONFERENCE ON BIOMEDICAL ROBOTICS AND BIOMECHATRONICS, 1., 2014, São Paulo. Proceedings [...]* New York: IEE, 2014.
- YANG, M.; CHOW, S. M. Using state-space model with regime switching to represent the dynamics of facial electromyography (EMG) data. **Psychometrika**, [S.l.], v. 75, p. 744-771. Aug. 2010.
- YANG, X. M.; DENG, Z. L. Logarithmic convergence rates of Tikhonov regularization for nonlinear ill-posed problems. *In: INTERNATIONAL CONFERENCE ON WAVELET ACTIVE MEDIA TECHNOLOGY AND INFORMATION PROCESSING (ICWAMTIP), 2012, Chengdu. Proceedings [...]* New York: IEE, 2012.
- YOUNG A. J.; HARGROVE, L. J.; KUIKEN, T. A. Improving myoelectric pattern recognition robustness to electrode shift by changing interelectrode distance and electrode configuration. **IEEE Transactions on Biomedical Engineering**, New York, v. 59, n. 3, p. 645-652, Mar. 2012.
- ZHAI, X. L. *et al.* Short latency hand movement classification based on surface emg spectrogram with PCA. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 40., 2018, Honolulu. Proceedings [...]* New York: IEEE, 2018.
- ZHAI, X.; JELFS, B.; CHAN, R. H. M.; TIN, C. Self-recalibrating surface EMG pattern recognition for neuroprosthesis control based on convolutional neural network. **Frontiers in Neuroscience**, Lausanne, v. 11, p. 1-11, July 2017.

- ZHANG, X. *et. al.* Wavelet based neuro-fuzzy classification for EMG control. *In: INTERNATIONAL CONFERENCE ON COMMUNICATION CIRCUITS SYSTEMS (ICCCAS)*, 2002, Chengdu. **Proceedings [...]** New York: IEEE, 2002.
- ZHANG, D. *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, Hong Kong. **Proceedings [...]** New York: IEEE, 2014.
- ZHANG, X.; HUANG, H. A Real-time, practical sensor fault-tolerant module for robust EMG pattern recognition. **Journal of Neuroengineering and Rehabilitation**. [S.l.], v.12, n. 1, Feb. 2015.
- ZHANG, L.; SUGANTHAN, P. N. A comprehensive evaluation of random vector functional link networks. **Information Sciences**, [S.l.], v. 367-368, p.1094-1105. Nov. 2016a.
- ZHANG, L.; SUGANTHAN, P. N. A survey of randomized algorithms for training neural networks. **Information Sciences**, [S.l.], v. 364, p. 146-155, Oct. 2016b.
- ZHOU, P. *et. al.* Nonlinear spatial filtering of multichannel surface electromyogram signals during low force contractions. **IEEE Transactions on Biomedical Engineering**, New York, v. 56, n. 7, p. 1871-1879, Mar. 2009.
- ZIVANOVIC, M.; GONZÁLEZ-IZAL, M. Nonstationary harmonic modeling for ECG removal in surface EMG signals. **IEEE Transactions on Biomedical Engineering**, New York, v. 59, n. 6, p. 1633-1640. Mar. 2012.

APÊNDICE A - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Termo de Consentimento Livre Esclarecido

Nome do Projeto: Processamento de Sinais Através de Regressão Logística Para Classificação de Movimentos de Membro Superior.

Pesquisador Responsável: Dr. Alexandre Balbinot.

Pesquisadores/Assistentes/Alunos: Eng. Vinícius Horn Cene e Fernanda Trevisol.

As informações contidas nesta folha, fornecidas por Alexandre Balbinot têm por objetivo firmar acordo escrito com o(a) Voluntário(a) para participação da pesquisa acima referida, autorizando sua participação com pleno conhecimento da natureza dos procedimentos a que ele(a) será submetido(a).

1. Natureza da Pesquisa: Esta pesquisa tem como finalidade o desenvolvimento de uma plataforma de tecnologia assistiva para avaliação de sinais mioelétricos do segmento mão-braço por métodos matemáticos para possibilitar futuramente o controle de dispositivos auxiliares na reabilitação de amputados.
2. Envolvimento na Pesquisa: ao participar dessa pesquisa o senhor(a) estará auxiliando o desenvolvimento das pesquisas na área de instrumentação biomédica. O senhor(a) tem liberdade de se recusar a participar e ainda de recusar a continuar participando em qualquer fase da pesquisa, sem lhe ocasionar qualquer prejuízo. Sempre que quiser poderá pedir mais informações sobre a pesquisa através do telefone dos pesquisadores e do projeto.
3. Protocolo experimental: Inicialmente será realizada uma breve anamnese (entrevista), onde apenas os pesquisadores terão conhecimento dos dados informados. Posteriormente será posicionado no braço e antebraço do Voluntário eletrodos de superfície, um vídeo será rodado informando os movimentos que devem ser realizados. Durante esse procedimento, estaremos adquirindo, através de um eletromiógrafo, os sinais mioelétricos do Voluntário, sendo esse o dado utilizado nesta pesquisa.
4. Riscos e desconfortos: Os procedimentos adotados nesta pesquisa obedecem aos Critérios da Ética em Pesquisa com Seres Humanos conforme Resolução nº.196/96 do Conselho Nacional de Saúde. O procedimento adotado pode causar uma leve fadiga muscular.
5. Confidencialidade: as informações neste estudo são estritamente confidenciais. Os dados do Voluntário serão identificados com um código e não com o nome. Somente os pesquisadores e o orientador desta pesquisa terão conhecimento dos dados.
6. Benefícios: Ao participar desta pesquisa você não terá nenhum benefício direto. Entretanto, esperamos que este estudo contribua com informações e elementos importantes à literatura e

ao desenvolvimento da tecnologia assistiva, onde o pesquisador se compromete a divulgar os resultados obtidos.

7. Garantia de acesso: em qualquer etapa do estudo, você terá acesso aos profissionais responsáveis pela pesquisa para esclarecimento de eventuais dúvidas. O Pesquisador Responsável é o Dr. Eng. Alexandre Balbinot, que pode ser encontrado no endereço Av. Osvaldo Aranha 103 sala 206 D, POA/RS (UFRGS) Telefone 33083326.
8. Despesas e compensações: não há despesas pessoais para o participante em qualquer fase do estudo, incluindo exames e consultas. Também não há compensação financeira relacionada à sua participação. Se existir qualquer despesa adicional, ela será absorvida pelo orçamento da pesquisa.
9. Liberdade de recusar ou retirar consentimento: Você tem a liberdade de retirar seu consentimento a qualquer momento e deixar de participar do estudo sem penalização.
10. Os dados obtidos são de livre uso do grupo de pesquisadores, ou seja, podem ser publicados e utilizados no desenvolvimento de trabalhos científicos. Porém em nenhum momento serão tornados públicos os dados pessoais do Voluntário.

Após estes esclarecimentos, solicitamos o seu consentimento de forma livre para permitir sua participação nesta pesquisa.

Consentimento Livre e Esclarecido

Eu _____ portador do RG _____, de forma livre e esclarecida, manifesto meu consentimento em participar da pesquisa em participar nesse estudo. Ficaram claros para mim quais são os propósitos do estudo, os procedimentos a serem realizados, seus desconfortos e riscos, as garantias de confidencialidade e de esclarecimentos permanentes. Ficou claro também que minha participação é isenta de despesas. Concordo voluntariamente em participar deste estudo e poderei retirar o meu consentimento a qualquer momento, antes ou durante o mesmo, sem penalidades ou prejuízo ou perda de qualquer benefício que eu possa ter adquirido, ou no meu atendimento neste Serviço. Declaro que recebi cópia deste termo de consentimento, e autorizo a realização da pesquisa e a divulgação dos dados obtidos neste estudo.

Local e data _____, ____/____/_____

Assinatura do Participante da Pesquisa

Assinatura do Pesquisador Responável- Dr. Alexandre Balbinot.

Pesquisador Principal: Alexandre Balbinot – Tel:
Demais pesquisadores: Vinícius Horn Cene - Tel:
Maurício Tosin -Tel:

APÊNDICE B - ANAMNESE

Identificação

Nome:**RG:****Idade:** **Idade em que ocorreu a amputação:****Altura:** **Peso:** **Sexo:** **Cor:****Naturalidade:****Profissão :** **Profissão antes da amputação:****Estado Civil:****Escolaridade:**

Contato

Endereço:**Bairro:** **CEP:****Cidade:** **Estado:****Telefone:****e-mail:**

**APÊNDICE C - ARTIGO SOBRE CARACTERIZAÇÃO DO ELM COMPARADO À
REGRESSÃO LOGÍSTICA E AO *SUPPORT VECTOR MACHINES***

Autores: V. Cene, A. Balbinot

Título: *ENHANCING THE CLASSIFICATION OF HAND MOVEMENTS THROUGH SEMG SIGNAL AND NON-ITERATIVE METHODS*

Periódico/Conferência: HEALTH AND TECHNOLOGY

Editora: Springer-Nature.

DOI: 10.1007/s12553-019-00315-6

Ano: 2018.

Disponível em: <https://link.springer.com/article/10.1007/s12553-019-00315-6>

Abstract: In movement classification through surface electromyography signal processing, the classification method must identify the user's intention with satisfactory accuracy to promote an adequate biosignal interface. Traditionally, classical methods such as Support Vector Machines, Artificial Neural Networks, and Logistic Regression have been used to this end. Recently, Non-Iterative Methods based on Artificial Neural Networks have been revisited in the form of Random Vector Functional-Link Networks (RVFL) and its most recent derivation, the so-called Extreme Learning Machines (ELM). In this work, we evaluate the performance and potentialities of RVFL and ELM with Moore-Penrose (RVFL and ELM) and Ridge-Regression (R-ELM and R-RVFL) methods to classify 17 different upper-limb movements through surface electromyography (sEMG) signal processing. 341 different sets of tests involving sEMG channels and features were performed for each one of the 20 subjects (ten amputees and ten non-amputees) from NINAPro database. Overall, the NIM methods presented consistent advantages of accuracy rate and time processing when compared with most traditional classifiers. Once the best setup of inputs was defined, the R-ELM presented the best accuracy rate. While results up to 80% were already reported for NINAPro data using Deep Learning techniques which are blatantly costly on a computational perspective, there is no evaluation performed in embedded platforms using this database. Therefore, we conducted an embedded study case of the ELM method applied to a Raspberry Pi platform using: a) a timestamp segmentation and b) a sliding-window approach to emulate an online application of the technique. The first trial reached an average accuracy rate of 90.9% for the non-amputee and 63.1% for the amputee subjects. The second trial reached 77.2% of average accuracy for the non-amputee and 55.3% for the amputee subjects, pairing the results in literature, even with the limitations of an embedded platform.

**APÊNDICE D - ARTIGO SOBRE OS EFEITOS DE DIFERENTES ESTRATÉGIAS
DE PRÉ-PROCESSAMENTOS, VARIAÇÕES DE HIPERPARÂMETROS DO
MÉTODO E SOBRE AS VERSÕES CONFIÁVEIS DO ELM EM SUA VERSÃO
PADRÃO E EM SUA VERSÃO REGULARIZADA**

Autores: V. Cene, A. Balbinot

Título: *USING THE sEMG SIGNAL REPRESENTATIVITY IMPROVEMENT TOWARDS UPPER-LIMB MOVEMENT CLASSIFICATION RELIABILITY*

Periódico/Conferência: BIOMEDICAL SIGNAL PROCESSING AND CONTROL

Editora: Elsevier.

DOI: 10.1016/j.bspc.2018.07.014

Ano: 2018.

Disponível em: <https://doi.org/10.1016/j.bspc.2018.07.014>

Abstract: Several Machine Learning techniques have been employed to process sEMG signals in order to provide a reliable control biosignal. Although some papers report accuracy rates superior to 90%, there is a lack of more detailed reasoning for reliable systems capable of providing control signals to users that may, for instance, control a prosthetic device. In this paper, we combined two strategies in order to increase the representativity of the sEMG signals: a) the use of a stochastic filter based on Antonyan Vardan Transform (AVT) prior the extraction of the signal features that reduces the stochastic behavior of the sEMG signal; and b) a novel sEMG feature called Differential Enhanced Signal (DES), designed to increase the signal representativity in the sEMG transition sections where features based on time-domain are usually inefficient. Thus, using only RMS and DES features, we were able to mitigate the class overlap in the transition sections and consequentially increase the overall classification accuracy for training and testing of the system. Since a reliable output signal is desired to perform ultimate prosthetic control, a reliability metric was defined and evaluated, and once a non-reliable classification is detected, the system autonomously activates auxiliary methods based on post-processing and data discard to maintain the classification consistency. Three preliminary scenarios involving the AVT filter, a Wavelet filter and the unfiltered signal were compared in terms of accuracy rate to define the most efficient filtering technique. The signal representation using the combination of RMS and DES features was also compared to a set of Time Domain (TD) features to test its enhancement capabilities. The AVT-based filter and the DES feature were able to present higher accuracy rates in both accuracy scenarios tested. Three different databases including 60 subjects among amputees and non-amputees were used to appraise the system, which was able to reach a mean accuracy rate of 99,1% in the best-case scenario..

**APÊNDICE E - ARTIGO SOBRE A BASE DE DADOS IEE E A UTILIZAÇÃO DAS
VERSÕES CONFIÁVEIS DO ELM E RELM PARA O PROCESSAMENTO DAS
BASES NINAPRO RELACIONADAS**

Autores: Vinicius Horn Cene, Mauricio Tosin, Juliano Machado, Alexandre Balbinot

Título: *OPEN DATABASE FOR ACCURATE UPPER-LIMB INTENT DETECTION USING ELECTROMYOGRAPHY AND RELIABLE EXTREME LEARNING MACHINES*

Periódico/Conferência: MDPI SENSORS

Editora: MDPI.

DOI: 10.3390/s19081864

Ano: 2019.

Disponível em: <https://www.mdpi.com/1424-8220/19/8/1864>

Abstract: Surface Electromyography (sEMG) signal processing has a disruptive technology potential to enable a natural human interface with artificial limbs and assistive devices. However, this biosignal real-time control interface still presents several restrictions such as control limitations due to a lack of reliable signal prediction and standards for signal processing among research groups. Our paper aims to present and validate our sEMG database through the signal classification performed by the reliable forms of our Extreme Learning Machines (ELM) classifiers, used to maintain a more consistent signal classification. To perform the signal processing, we explore the use of a stochastic filter based on the Antonyan Vardan Transform (AVT) in combination with two variations of our Reliable classifiers (denoted R-ELM and R-Regularized ELM (RELM), respectively), to derive a reliability metric from the system, which autonomously selects the most reliable samples for the signal classification. To validate and compare our database and classifiers with related papers, we performed the classification of the whole of Databases 1, 2, and 6 (DB1, DB2, and DB6) of the NINAPro database. Our database presented consistent results, while the reliable forms of ELM classifiers matched or outperformed related papers, reaching average accuracies higher than 99% for the IEE database, while average accuracies of 75.1%, 79.77%, and 69.83% were achieved for NINAPro DB1, DB2, and DB6, respectively.

**APÊNDICE F - ARTIGO SOBRE O ELM DE ARG MAX SUAVIZADO
UTILIZANDO DIFERENTES MÉTODOS DE FILTRAGEM DO SINAL**

Autores: Vinicius Horn Cene, Juliano Machado, Alexandre Balbinot

Título: *SMOOTHED ARG MAX EXTREME LEARNING MACHINE - AN ALTERNATIVE TO AVOID CLASSIFICATION RIPPLES IN SEMG SIGNALS*

Periódico/Conferência: 41st ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE EMBS. BERLIN, ALEMANHA, 2019

Editora: IEEE.

DOI: 10.1109/EMBC.2019.8856922

Ano: 2019.

Disponível em: [10.1109/EMBC.2019.8856922](https://doi.org/10.1109/EMBC.2019.8856922)

Abstract: Despite all the recent developments of using the surface electromyography (sEMG) as a control signal, reliable classifications still remain an arduous task due to overlapping classes and classification ripples. In this paper, we present a straightforward approach to avoid classification ripple based on smoothing the *arg max* value of an Extreme Learning Machine (ELM) classifier. We compare the baseline accuracy of the classifier with an *arg max* filtered by a traditional Exponential Smoothing Filter (ESF) and our adaptation of Antonyan Vardan Transform (AVT). The classifiers were evaluated using sEMG data acquired through 12 channels from four subjects performing 17 different movements of forearm and fingers with three repetitions each. In the best scenario, our methods reached results higher than 96% and 82% of overall and weighted accuracy, respectively. Those results match or outperform similar papers of the literature using a simpler model, which may help the application of the techniques on embedded platforms and make the practical use of such devices more feasible.