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

MAURÍCIO CAGLIARI TOSIN

DESENVOLVIMENTO DE METODOLOGIA BASEADA EM APRENDIZADO POR REFORÇO E SISTEMA DE INFERÊNCIA FUZZY PARA IDENTIFICAÇÃO E MINIMIZAÇÃO DE CONTAMINANTES EM SINAIS DE SEMG COM APLICAÇÃO EM IDENTIFICAÇÃO DE MOVIMENTOS DO SEGMENTO MÃO-BRAÇO

MAURÍCIO CAGLIARI TOSIN

DESENVOLVIMENTO DE METODOLOGIA BASEADA EM APRENDIZADO POR REFORÇO E SISTEMA DE INFERÊNCIA FUZZY PARA IDENTIFICAÇÃO E MINIMIZAÇÃO DE CONTAMINANTES EM SINAIS DE SEMG COM APLICAÇÃO EM IDENTIFICAÇÃO DE MOVIMENTOS DO SEGMENTO MÃO-BRAÇO

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

Área de concentração: Eletrônica - Instrumentação e Processamento de Sinais.

ORIENTADOR: Prof. Dr. Alexandre Balbinot

MAURÍCIO CAGLIARI TOSIN

DESENVOLVIMENTO DE METODOLOGIA BASEADA EM APRENDIZADO POR REFORÇO E SISTEMA DE INFERÊNCIA FUZZY PARA IDENTIFICAÇÃO E MINIMIZAÇÃO DE CONTAMINANTES EM SINAIS DE SEMG COM APLICAÇÃO EM IDENTIFICAÇÃO DE MOVIMENTOS DO SEGMENTO MÃO-BRAÇO

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

Porto Alegre, março de 2023.

Orientador:

Prof. Dr. Alexandre Balbinot, UFRGS
Doutor pela UFRGS – Porto Alegre, Brasil
Banca Examinadora:
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. Tiago Oliveira Weber, PPGEE – UFRGS
Doutor pela Universidade de São Paulo - São Paulo, Brasil
Coordenador do PPGEE:
Prof. Dr. Sérgio Luís Haffner

DEDICATÓRIA

À memória de meu pai, Moacir. Humildade, força de vontade, honestidade e perseverança foram as lições que me transmitiste e que nunca esqueci durante esta caminhada. Por tudo isso, o meu muito obrigado.

A minha companheira, Juliana, por sempre estar ao meu lado, me apoiando e me incentivando independentemente do tamanho da dificuldade imposta, por compreender pacientemente os momentos mais estressantes desta jornada, por ser sempre o meu porto seguro e por todo carinho e cuidado que tens comigo. Sou-lhe muito grato por tudo isso.

A minha mãe, Cleide, por sempre acreditar em mim e por me proporcionar todas as condições para eu conquistar meus objetivos.

AGRADECIMENTOS

Ao longo deste percurso, muitas pessoas foram importantes para a elaboração desta tese, auxiliando de forma direta ou indireta, e a quem quero fazer o devido reconhecimento.

Primeiramente, quero agradecer o meu orientador, Prof. Alexandre Balbinot pela sua orientação e conselhos valiosos que foram fundamentais no desenvolvimento deste trabalho.

Aos meus irmãos Roberta, Márcio e Manoela pelo companheirismo e apoio.

Aos professores e colegas do Laboratório do IEE pelo auxílio na execução deste trabalho por meio de ricas discussões e diversas sugestões que foram importantes na resolução de problemas encontrados durante a trajetória. Em especial o Prof. Tiago Weber, Vinícius Cene, Juliano Machado e Guilherme Pedrollo.

Sou grato também ao Fernando Weimer e ao Pedro Mônaco pela valiosa ajuda nas aquisições de dados.

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

Ao CNPq pela provisão da bolsa de doutorado.

RESUMO

A incessante busca por novas tecnologias que proporcionem aumento da qualidade de vida do ser humano tem norteado a pesquisa acadêmica ao longo da história. Isso é observado na evolução dos meios de transporte, dos dispositivos de comunicação e até mesmo de serviços como o bancário. No entanto, para pessoas com deficiência motora, em especial aquelas que sofreram amputação ou não possuem parte do membro superior, a conquista de melhores condições de vida está potencialmente relacionada com liberdade e independência. Visando suprir esta necessidade, muitos pesquisadores têm trabalhado no desenvolvimento de algoritmos preditores de movimento do segmento mão-braço a partir de sinais de eletromiografia para o controle de próteses na expectativa de aumentar o número de graus de liberdade do dispositivo. Contudo, para que se obtenha sistemas eficientes e que tenham elevados índices de assertividade, é imprescindível que o nível de interferência e ruído, os quais inevitavelmente estão presentes nos registros de eletromiografia devido à instrumentação, ambiente, aspectos fisiológicos, dentre outros, seja o menor possível. Neste contexto, alguns trabalhos foram desenvolvidos visando a minimização do efeito de interferências no classificador, contudo todos aqueles abrangidos pela pesquisa realizada demandam um estágio de treinamento off-line, não são adaptáveis às variações do sinal de EMG e/ou dependem do sinal dos outros canais de medição para a minimização do efeito degradador. Diante disso, a presente proposta de tese apresenta uma metodologia baseada em aprendizagem por reforço (Reinforcement Learning) e Sistema de Inferência Fuzzy para detecção, identificação do tipo e atenuação do efeito de contaminantes em registros de eletromiografia, com aplicação em sistemas de reconhecimento de gestos do membro superior. O mesmo está fundamentado em um modelo de agente e ambiente, sendo constituído dos seguintes elementos: ambiente (atividade elétrica muscular), estado (conjunto de 6 características extraídas do sinal de EMG), ações (aplicação de filtros/procedimentos específicos para a redução do impacto de cada interferência) e agente (controlador que fará a identificação do tipo da contaminação e executará a ação adequada). Para cada ação exercida pelo agente será atribuída uma recompensa a qual, por sua vez, é determinada em virtude do impacto da primeira nas características do sinal (estado) por meio de um Sistema de Inferência Fuzzy. O treinamento, realizado através do método Ator-Crítico, consiste na obtenção de uma política de ações que maximize a recompensa percebida a longo prazo. Por meio de um experimento realizado de forma off-line conseguiu-se taxas de acerto de 92,96% na identificação de 4 tipos de contaminantes (interferência por eletrocardiografia (ECG), artefato de movimento, interferência eletromagnética oriunda da rede de energia elétrica e ruído branco gaussiano) e 69,5% quando se considerou também sinal íntegro. Além disso, por meio de um estudo de caso simulando-se o treinamento online do agente evidenciou-se que o modelo de Transfer Learning adotado foi eficaz na dispensa da necessidade do uso de dados adquiridos previamente do usuário além de acelerar o processo de aprendizado. Estas propriedades são fundamentais para a implementação de qualquer sistema de forma online. Logo, verificou-se indícios de que o SIF-ACRL tem, de fato, potencial para ser implementado de forma online.

Palavras-chave: Eletromiografia, identificação de contaminantes, sistema robusto a falhas, treinamento *online*, *Reinforcement Learning*, Sistema de Inferência Fuzzy, classificador de movimentos.

ABSTRACT

The incessant search for new technologies that provide increased quality of life for human beings has guided academic research throughout history. This is observed in the evolution of transports, communication devices and even services such as banking. However, for people with motor disabilities, especially those who have had an amputation or do not have part of the upper limb, achieving better living conditions is potentially related to freedom and independence. To meet this need, many researchers have been working on the development of hand-arm segment movement predictors algorithms from electromyography signals for the control of prostheses in the hope of increasing the device's degrees of freedom. However, to obtain efficient systems that have high levels of assertiveness, it is essential that the interference and noise level, which are inevitably present in the electromyography records due to the instrumentation, environment, physiological aspects, among others, is the lowest possible. In this context, some works were developed aiming at minimizing the effect of interference in the classifier, however, all those covered by the performed research demand an offline training stage, are not adaptable to the EMG signal variations, and/or depend on the signal of others measurement channels to minimize the degrading effect. In view of this, the present thesis proposal presents a methodology based on Reinforcement Learning and Fuzzy Inference System for detection, identification of the type and mitigation of the effect of contaminants in electromyography records, with application in gesture recognition systems of the upper limb. It is based on an agent and environment model, consisting of the following elements: environment (muscle electrical activity), state (set of 6 characteristics extracted from the EMG signal), actions (application of specific filters/procedures to reduce impact of each interference) and agent (controller who will identify the type of contamination and take the appropriate action). For each action performed by the agent, a reward will be attributed which, in turn, is determined by the impact of the actions on the signal features (state) by means of a Fuzzy Inference System. The training, carried out through the Actor-Critic method, consists of obtaining an action policy that maximizes the long term perceived reward. Through an experiment carried out offline, success rates of 92.96% were achieved in the identification of 4 types of contaminants (interference by electrocardiography (ECG), motion artifact, electromagnetic interference from the electricity network and Gaussian white noise) and 69.5% when a clean signal class was added. In addition, a case study simulating the agent's online training showed that the Transfer Learning model adopted was effective in dispensing with the need to use data previously acquired from the user, in addition to accelerating the learning process. These properties are fundamental for the implementation of any system online. Therefore, there were indications that the SIF-ACRL has the potential to be implemented online.

Keywords: Electromyography, contaminants identification, fault-robust system, online training, Reinforcement Learning, Fuzzy Inference System, movement classifier.

LISTA DE FIGURAS

Figura 1 – Potencial elétrico da membrana muscular.	26
Figura 2 – Exemplo de sinal de sEMG.	27
Figura 3 – Esquema do funcionamento de uma rede de aprendizagem por reforço	31
Figura 4 – Diagrama em blocos do algoritmo do ACRL.	35
Figura 5 – Diagrama em blocos típico de um sistema de identificação de movimento a	partir de
EMG.	37
Figura 6 – Mapa de citações entre pesquisadores. Cores indicam número de citações mo	édias por
trabalho	39
Figura 7 – Mapa de cocitações de pesquisadores. Cores representam <i>clusters</i>	40
Figura 8 – Mapa de citações de países. Cores indicam número médio de citações por pul	blicação.
	42
Figura 9 – Mapa de citações por fonte de publicação do trabalho. Cores representam	número
médio de citações	43
Figura 10 – Mapa de coocorrências de palavras-chave utilizadas pelos pesquisadore	s. Cores
indicam clusters.	44
Figura 11 – Configurações isométricas de mão.	58
Figura 12 – Movimentos básicos de pulso.	58
Figura 13 – Procedimento adotado na formação das bases 2 e 3 NinaPro	59
Figura 14 – Procedimento adotado no processo de aquisição de sinal de sEMG	63
Figura 15 – Fluxograma dos algoritmos utilizado durante as aquisições	64
Figura 16 – Posicionamento dos eletrodos no braço e antebraço do participante	64
Figura 17 – Arranjo experimental utilizado nas aquisições na geração da Base de Dados	s do IEE:
(1) corresponde ao monitor onde os movimentos eram mostrac	dos, (2)
eletromiógrafos, (3a-c) cabos do eletromiógrafo, (4) eletrodos de super-	fície, (5)
placa de aquisição, (6) borneira, (7) computador.	65
Figura 18 – Janela do sinal dividida em três partes. t0 indica o tempo de início do mo	vimento
e t1 o de término após a correção realizada pelo algoritmo	66
Figura 19 – Efeito da contaminação com SNR de -10 dB	69
Figura 20 – Representação da área considerada do DEP para o cálculo da Razão Sinal-	Artefato
de Movimento.	71

Figura 21 – Representação da área da DEP considerada no cálculo da característica Relação
Sinal-Ruído
Figura 22 – Implementação do método Ator-Crítico aplicado a identificação de contaminantes
em sinal de sEMG75
Figura 23 – Atribuição de recompensa baseada em SIF
Figura 24 - Impacto da ação relacionada a ECG nas características associadas a todos
contaminantes e sinal íntegro. Os dados são do voluntário #1, canal #1, e a
contaminação está em -30 dB
Figura 25 – Fluxograma da determinação da condição do boxplot alvo
Figura 26 – Funções de entrada e suas respectivas funções de pertinência. Os dados são do
voluntário #1, canal #1, com contaminação em -20, -10 e 0 dB80
Figura 27 – Médias e intervalos de confiança (95% de nível de confidência) associados com
cada parâmetro testado85
Figura 28 – Experimento conduzido para a validação do algoritmo como classificador de
contaminantes86
Figura 29 – Método de Transfer Learning aplicado no experimento conduzido para simular o
treinamento online do agente
Figura 30 – Características extraídas do canal 9 em relação a cada tipo de experimento92
Figura 31 – Características extraídas do canal 10 em relação a cada tipo de experimento92
Figura 32 – Características extraídas do canal 11 em relação a cada tipo de experimento93
Figura 33 – Características extraídas do canal 12 em relação a cada tipo de experimento93
Figura 34 – Taxas de acerto relacionadas a cada classe e SNR. Os pares de gráficos com um
asterisco (*) pertencem a distribuições distintas segundo o teste de Mann-Whitney-
Wilcoxon com nível de confiança de 99%95
Figura 35 – Análise do efeito do voluntário nas taxas de acerto
Figura 36 – Análise do efeito dos canais de medição nas taxas de acerto
Figura 37 – Boxplot da função score associado ao canal 6 do voluntário 8 com SNR de -10dB.
O termo "clean" se refere à classe sinal íntegro
Figura 38 - Experimento conduzido para a validação do algoritmo no estágio de pré-
processamento do sistema de classificação de movimentos
Figura 39 – Resultados de classificação de movimentos para cada base de dados em relação ao
SNR e à quantidade de canais contaminados. Os boxplot com a mesma letra (dentro
de cada base de dados e para cada SNR) pertencem à mesma distribuição segundo
o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%102

Figura 40 – Resultados de classificação de movimentos para cada base de dados em feração ao
canal contaminado. Os boxplot com a mesma letra (dentro de cada base de dados e
associados ao mesmo canal) pertencem à mesma distribuição segundo o teste de
Mann-Whitney-Wilcoxon com nível de confiança de 99%
Figura 41 – Comparação entre os resultados dos diferentes tipos de testes em relação aos obtidos
com sinal íntegro considerando o efeito dos voluntários não amputados 105
Figura 42 – Comparação entre os resultados dos diferentes tipos de testes em relação aos obtidos
com sinal íntegro considerando o efeito dos voluntários amputados105
Figura 43 – Comparação entre os resultados dos diferentes tipos de testes em relação aos obtidos
com sinal íntegro considerando o efeito dos movimentos (Base de Amputados).107
Figura44-Comparaçãoentreosresultadosdosdiferentestiposdetestesemrelaçãoaosobtidos
com sinal íntegro considerando o efeito dos movimentos (Base de Não Amputados).
107
Figura 45 — Correlação entre a taxa de acerto do identificador de contaminantes e o acréscimo
em valor percentual da taxa de acerto do classificador de movimentos (Base 02). A
linha azul indica o índice de assertividade da identificação dos contaminantes e a
vermelha se refere à melhora no reconhecimento dos gestos. O termo "Corr." indica
o índice de correlação de Pearson entre as linhas
Figura 46 – Correlação entre a taxa de acerto do identificador de contaminantes e o acréscimo
em valor percentual da taxa de acerto do classificador de movimentos (Base 03). A
linha azul indica o índice de assertividade da identificação dos contaminantes e a
vermelha se refere à melhora no reconhecimento dos gestos. O termo "Corr." indica
o índice de correlação de Pearson entre as linhas
Figura 47 – Correlação entre a taxa de acerto da identificação de sinal íntegro e o decréscimo
em valor percentual da taxa de acerto do classificador de movimentos. A linha azul
indica o índice de assertividade da identificação da classe sinal íntegro e a vermelha
se refere à piora no reconhecimento dos gestos. O termo "Id. ínt." indica o índice de
assertividade do SIF-ACRL associado a sinal íntegro
Figura 48 – Resultados de classificação de movimentos para cada base de dados em relação ao
SNR e o tipo do teste. Os boxplot com a mesma letra (dentro de cada base de dados
e para cada SNR) pertencem à mesma distribuição segundo o teste de Mann-
Whitney-Wilcoxon com nível de confiança de 99%112
Willting-Wilcoxoff com firver de comfança de 77/0112
Figura 49 – Resultados de classificação de movimentos para cada base de dados em relação ao

	associados ao mesmo canal) pertencem à mesma distribuição segundo o teste de
	Mann-Whitney-Wilcoxon com nível de confiança de 99%
Figura 50	- Evolução do aprendizado do agente ao longo dos episódios de treinamento e seu
	impacto no classificador de movimentos (Base 02)
Figura 51	- Evolução do aprendizado do agente ao longo dos episódios de treinamento e seu
	impacto no classificador de movimentos (Base 03)

LISTA DE TABELAS

Tabela 1 – Contribu	ição dos trabalhos produzidos na área	21
Tabela 2 – Um resur	mo dos trabalhos associados à fase de pré-processamento	47
Tabela 3 – Um resur	mo dos trabalhos associados ao tratamento de contaminantes e	em sEMG.52
Tabela 4 – Definição	o de funções de pertinência de entrada. Na tabela, HOC é o li	mite superior
mais alto	o do boxplot dos outros contaminantes (não o alvo), LTC é o la	imite inferior
do boxp	lot alvo, $1QTC$ é o primeiro quartil da distribuição alvo, $3QTC$	C é o terceiro
quartil n	nais alto dentre os outros contaminantes e FP é Função de Per	tinência79
Tabela 5 – Definiçã	o das funções de pertinência da saída da SIF. O termo "PCE"	' se refere ac
percentu	nal de amostras do contaminante correto da respectiva con	mbinação de
entrada.		81
Tabela 6 – Resultad	dos de classificação do algoritmo proposto para cada base o	de dados. Os
resultade	os com a mesma letra na última coluna pertencem à mesma	distribuição
segundo	o teste de Mann-Whitney-Wilcoxon com nível de confiança	de 99%95
Tabela 7 – Configur	rações de canais contaminados testados	100
Tabela 8 – Resultad	los de classificação de movimentos para cada base de dados. O	Os resultados
com a n	nesma letra (dentro de cada base de dados) na última coluna	pertencem à
mesma	distribuição segundo o teste de Mann-Whitney-Wilcoxon c	om nível de
confianç	ça de 99%	101
Tabela 9 – Resultad	os de classificação de movimentos para cada base de dados. O	Os resultados
com a n	nesma letra (dentro de cada base de dados) na última coluna	pertencem à
mesma	distribuição segundo o teste de Mann-Whitney-Wilcoxon c	om nível de
confianç	ça de 99%	111
Tabela 10 – Resulta	idos de artigos relacionados na área de identificação de conta	minantes. Na
tabela: o	o termo "TxAc" refere-se à taxa de acerto média relatada n	o respectivo
artigo 1	no melhor cenário, SA é saturação do amplificador, (CN é ruído
correlac	ionado, MixA é a composição de mais de um ruído. *Resultad	los expressos
pela med	diana	117
Tabela 11 – Resulta	ados de artigos relacionados na área de classificação de mov	vimentos. Na
tabela: o	o termo "TxAc" refere-se à taxa de acerto média relatada n	o respectivo
artigo n	o melhor cenário, Carac. indica características, TD é domíni	io do tempo,

Mov.	se	refere	a	quan	ıtidade	de	movi	mentos	, SA	é	saturação	do	amplificador.
*Resu	ılta	dos ex	pre	ssos į	pela m	edia	ana	••••••	•••••	••••		•••••	119

LISTA DE ABREVIATURAS

ACRL Actor-Critic Reinforcement Learning

ADANN Adaptive Domain Adversarial Neural Network

ADRC Active Disturbance Rejection Controller

ANOVA Análise das Variâncias

AVC Acidente Vascular Cerebral

CAAE Certificado de Apresentação de Apreciação Ética

CEDE Consensus for Experimental Design in Electromyography

CNN Convolutional Neural Networks

CSSA Comom Spatial-Spectral Analysis

CVM Contração Voluntária Máxima

DC Direct Current

DDPG Deep Deterministic Policy Gradient

DEF Deformação na Densidade Espectral de Potência

DEP Densidade Espectral de Potência

DP Queda do Valor Máximo para o Mínimo da Densidade Espectral de Potência

DQN Deep Q-Network

DTW Dynamic Time Warping

DYNAP Dynamic Neuromorphic Asynchronous Processor

ECG Eletrocardiografia

ELM Extreme Learning Machine

EMBS Engineering in Medicine and Biology Society

EMG Eletromiografia

FMG Force Myography

FPGA Field Programmable Gate Array

GDL Graus de Liberdade

GLR Generalized Likelihood Ratio

HMM Hidden Markov Model

HOG Histogram of Oriented Gradients

IEE Instrumentação Eletro-Eletrônica

IEEE Institute of Electrical and Electronics Engineers

IHM Interface Homem-Máquina

IPL Interpolated Peak Location

kNN *k-Nearest Neighbor*

LDA Linear Discriminat Analysis

LSTM Long Short-Term Memory

MDP Markov Decision Processes

MM Musculoskeletal Model

MOA Artefato de Movimento

MUAP Motor Unit Action Potential

NB Naive Bayes

NinaPro Non-Invasive Adaptive Hand Prosthetics

NMF Non-negative Matrix Factorization

PDI Pattern Distance Index

PID Proporcional Integrador Derivativo

PLI Interferência da Rede Elétrica

QDA Quadratic Discriminant Analysis

RDA Regularized Discriminant Analysis

RELM Regularized Extreme Learning Machine

REQM Raiz do Erro Quadrático Médio

RL Reinforcement Learning

RLR Regularized Logistic Regression

RMS Root Mean Square

RNA Redes Neurais Artificiais

RNR Redes Neurais Recorrentes

rPCA robust Principal Component Analysis

R-RVFL Regularized Random Vector Functional-Link Networks

RSR Relação Sinal-Ruído (Característica extraída do sinal de sEMG)

RVFL Random Vector Functional-Link Networks

sEMG Eletromiografia de superfície

SENIAM Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles

SER Relação Sinal sEMG-ECG

SIF Sistema de Inferência Fuzzy

SMR Sinal-Artefato de Movimento

SNN Spiking Neural Network

SNR Signal-to-Noise Ratio
SOM Self Organizing Map

SPR Relação Sinal-Linha de Energia

SS Spectrum Subtraction

STFT Short-Time Fourier Transform
SVD Singular Value Decomposition

SVM Support Vector Machine

SVM-RFE Support Vector Machine Recursive Feature Elimination

TD-PSD Time-Dependent Power Spectrum Descriptors

TEMPONet Temporal Embedded Muscular Processing Online Network

TF Transformada de Fourier

TVARMA Time-Varying Autoregressive Moving Average

TVK Time-Varying Kalman filter

TW Transformada de Wavelet

UFRGS Universidade Federal do Rio Grande do Sul

WGN Ruído Branco Gaussiano

WPT Wavelet Packet Transform

SUMÁRIO

1	IN	TRODUÇÃO	18
	1.1	JUSTIFICATIVAS	18
	1.2	OBJETIVOS	19
	1.3	CONTRIBUIÇÃO CIENTÍFICA DESTA TESE	21
	1.4	ESTRUTURA DA TESE	22
2	RE	EVISÃO SOBRE ELETROMIOGRAFIA, PROCESSAMENTO DE SINAIS DE SE	MG
Е	FUNI	DAMENTOS DE APRENDIZAGEM POR REFORÇO	24
	2.1	CONCEITOS BÁSICOS SOBRE ELETROMIOGRAFIA	24
	2.2	PRINCÍPIOS SOBRE PROCESSAMENTO DE SINAL DE SEMG	28
	2.3	CONCEITOS BÁSICOS SOBRE APRENDIZAGEM POR REFORÇO	30
3	ES'	TADO DA ARTE	37
	3.1 RECE	ANÁLISE BIBLIOMÉTRICA DOS TRABALHOS PUBLICADOS M ENTES	
	3.2	ANÁLISE DOS TRABALHOS MAIS RECENTES	45
4	ME	ETODOLOGIA EXPERIMENTAL	57
	4.1	DESCRIÇÃO DAS BASES DE DADOS UTILIZADAS	57
		.1 Base de Dados NinaPro	
	4.1	.2 Base de Dados do IEE	
	4.2	DESCRIÇÃO DOS CONTAMINANTES CONSIDERADOS	
	4.3	EXTRAÇÃO DE CARACTERÍSTICAS PARA O TREINO DO FIS-ACRL	
	4.4 APRI	ALGORITMO DO IDENTIFICADOR DE CONTAMINANTES F ENDIZADO POR REFORÇO	POR
	4.4	.1 Determinação das Ações	77
	4.4	.2 Definição da Função de Atribuição de Recompensa	77
	4.4	Definição do Modelo e Parâmetros da Rede Neural do Ator e do Crítico	83
	4.5	TREINAMENTO OFF-LINE DO AGENTE	85
	4.6 TRAN	TREINAMENTO ONLINE DO AGENTE BASEADO NO CONCEITO	
	4.7	PROJETO DE EXPERIMENTOS	88
5	RE	SULTADOS E DISCUSSÕES	90
	5.1	CARACTERIZAÇÃO DA BASE DE DADOS DO IEE	90
	5.2	EXPERIMENTO OFF-LINE	
	5.2		

	5.2	2.2 Classificador de Movimentos	99
	5.3	EXPERIMENTO ONLINE	110
	5.4	TRABALHOS RELACIONADOS	117
6	CC	ONSIDERAÇÕES FINAIS	121
7	AR	RTIGOS PUBLICADOS NA ÁREA	123

1 INTRODUÇÃO

O sinal de eletromiografia (EMG) compreende a manifestação elétrica da ativação neuromuscular associada com uma contração muscular (DE LUCA, 1979). Os primeiros registros de sua aquisição (realizada de modo superficial) datam do Século 19. O responsável pelo experimento foi o fisiologista alemão Emil Heinrich Du Bois-Reymond (PEARCE, 2001). A partir de então, o estudo de eletromiografia tem encontrado aporte em diversas áreas, desde a medicina clínica (BENAZZOUZ; SLIMANE, 2021; PARISI; RAVICHANDRAN, 2020) e esportiva, como por exemplo, na melhora do desempenho de atletas de alto rendimento (FRONSO *et al.*, 2017; JUDGE; MOREAU; BURKE, 2003) até a engenharia biomédica (CENE *et al.*, 2019; SCHWEISFURTH *et al.*, 2020; TRIGILI *et al.*, 2019).

Neste último nicho científico, inúmeras pesquisas têm sido desenvolvidas, principalmente nas últimas décadas, relacionadas à criação de interfaces homem-máquina. Estes trabalhos utilizam o potencial informativo presente no sinal de eletromiografia para a obtenção de padrões que os relacione com a intenção de movimento do usuário. Tipicamente, técnicas de aprendizagem de máquina são aplicadas para a conquista destas associações e consequente geração de um modelo preditor de gestos humanas. Tais algoritmos podem, posteriormente, ser utilizados na concepção de próteses, órteses e exoesqueletos, além de sistemas de teleoperação miocontrolados (BOS *et al.*, 2020; KRASOULIS; VIJAYAKUMAR; NAZARPOUR, 2020; LU *et al.*, 2019; YE *et al.*, 2019).

Contudo, para o desenvolvimento de metodologias de reconhecimento de movimentos eficientes e com alto índice de assertividade, é imprescindível que a máxima informação seja extraída do sinal de EMG. Logo, é de vital importância que o nível de interferência e ruído, os quais inevitavelmente estão presentes nos registros de eletromiografia devido à instrumentação, ambiente, aspectos fisiológicos, dentre outros, seja o menor possível. Diante disso, a presente tese de doutorado visa contribuir para esta linha de estudo com uma técnica para a detecção e minimização do efeito de contaminantes em medições da atividade elétrica muscular com aplicação em sistemas de identificação de intenção de gestos do segmento mão-braço.

1.1 JUSTIFICATIVAS

Historicamente, existe uma busca incessante pelo desenvolvimento de novas tecnologias que facilitem e melhorem o dia-a-dia do ser humano. Isso é observado pela evolução de alguns serviços e dispositivos como o bancário, o telefone, os meios de transporte, dentre outros. Com isso, as pessoas despendem menos tempo realizando tarefas básicas e podem aproveitar mais

momentos dedicados a projetos pessoais e/ou desfrutar da companhia de quem se gosta. O resultado disso é ganho em qualidade de vida.

Contudo, para alguns indivíduos, em especial aqueles que sofreram amputação ou não possuem parte do membro superior, a aquisição de melhores condições de bem-estar se resume a questões bem mais básicas como a execução de tarefas simples do cotidiano. Neste âmbito, a qualidade de vida destas pessoas está potencialmente associada com independência, sendo esta última, por sua vez, diretamente relacionada com o tipo de prótese que faz a substituição do membro faltante. Quanto maior for o número de graus de liberdade do braço artificial maior será a sensação de liberdade do usuário.

Visando o desenvolvimento de tais dispositivos, inúmeros pesquisadores têm dedicado esforços na proposição de algoritmos de reconhecimento de intenções de movimento baseados em eletromiografia para o controle do mecanismo. A saber, o referido sistema pode ser dividido em 6 etapas (Medição/Aquisição do sinal, Pré-processamento, Extração de Características, Seleção de Características, Classificação e Controle do Braço Robótico) sendo que, para cada uma delas, novas e inovadoras abordagens são apresentadas. Em especial, o estágio de pré-processamento preenche uma importante lacuna no processo sendo responsável pela preparação dos dados para a extração de características. Neste contexto, não são poucos os trabalhos publicados com estratégias para detecção, identificação da fonte e atenuação dos efeitos nocivos de contaminantes presentes no sinal de sEMG (Eletromiografia de superfície). Entretanto, todos alcançados pela presente pesquisa demandam uma fase de treinamento *off-line* do modelo preditor o que é indesejável uma vez que, levando-se em conta a também necessária calibração do algoritmo preditor de movimentos, gera incômodo adicional ao usuário podendo levar, inclusive, à rejeição do membro artificial.

Face ao exposto, a presente proposta de tese se justifica na proposição de um método fundamentado em aprendizado por reforço e Sistema de Inferência Fuzzy a qual possibilita a execução do treinamento online e ainda é adaptável às variações do ambiente (sinal de sEMG). De um modo mais geral, a motivação do trabalho reside na necessidade de proporcionar melhores condições de vida às pessoas com deficiência, em especial àquelas que sofreram amputação do membro superior, pelo vislumbre da oferta de próteses com maior número de graus de liberdade.

1.2 OBJETIVOS

O objetivo principal desta tese é o de propor uma alternativa de solução para o problema de contaminações em sinais de sEMG quando aplicados em sistemas de reconhecimento de

movimentos. Identificou-se na literatura lacunas deixadas em aberto pelas propostas atuais para esta etapa do processo. Dentre as quais pode-se citar o fato de que todos eles demandam dados adquiridos previamente do usuário para o treinamento *off-line* do modelo (o que é desagradável do ponto de vista do indivíduo) e da possível necessidade de realização de recalibrações a cada novo uso do dispositivo.

Diante desse cenário, a hipótese de pesquisa a ser verificada neste trabalho é a de que é possível gerar um algoritmo baseado em aprendizado por reforço para identificação e remoção de contaminantes em sinais de sEMG que possa ser treinado de forma online durante o uso do dispositivo (dispensando assim a necessidade de coleta prévia de dados do usuário e tempo gasto no aprendizado *off-line*) e que consiga identificar contaminações mais brandas (sinal com SNR de até 10dB) com resultados semelhantes ou melhores dos que os das propostas já existentes.

Portanto, o objetivo principal deste trabalho mencionado anteriormente se sustenta no desenvolvimento de um sistema de detecção e identificação da fonte e minimização do impacto de contaminantes em sinal de eletromiografia através do conceito de aprendizado por reforço. O uso deste método se fundamenta no seu caráter adaptativo e no fato do agente adquirir aprendizado através da experiência observada pela interação com o ambiente o que possibilita a concepção do treinamento de forma online.

Assim, o sistema foi modelado na forma de um ambiente e um agente. O primeiro é representado pelos dados de eletromiografia adquiridos e o outro corresponde ao controlador que fará a identificação do tipo da interferência e tomará a ação mais adequada. Esta última, por sua vez, consiste na aplicação de um filtro/procedimento para redução do efeito de um contaminante específico. Aqui serão considerados 4 tipos: interferência por sinal de eletrocardiografia, artefato de movimento, interferência da rede de energia elétrica e ruído de linha de base, representado pela adição de ruído branco gaussiano. Os estados são dados por um conjunto de 6 características extraídas do sinal de sEMG: Relação Sinal-Artefato de Movimento (SMR), Queda do Valor Máximo para o Mínimo da Densidade Espectral de Potência (DP), Relação Sinal-Ruído (RSR), Deformação na Densidade Espectral de Potência (DEF), Relação Sinal-Linha de Energia (SPR) e Relação Sinal sEMG-ECG (SER). Para cada ação executada pelo agente o mesmo perceberá uma recompensa a qual é determinada em virtude do impacto da ação nas supracitadas características do sinal. Assim, o objetivo do treinamento é encontrar uma política de ações que maximize o total de recompensa recebida a longo prazo.

Como meta secundária está a formação da versão 02 da Base de Dados do Laboratório de Instrumentação Eletroeletrônica (IEE) da UFRGS (CENE *et al.*, 2019). O objetivo deste novo repositório é a aquisição de sinais sob condições não ideais, reproduzindo possíveis fontes de contaminação que podem ocorrer com o uso pleno do dispositivo mio-controlado.

1.3 CONTRIBUIÇÃO CIENTÍFICA DESTA TESE

De modo a contextualizar a presente pesquisa em relação ao estado da arte, a Tabela 1 expõe as contribuições de alguns dos trabalhos mais relevantes que tratam a questão da identificação de contaminantes em sinais de sEMG.

Tuesta T Common que un mumo production im mom								
Autor	Título	Etapa	Contribuição					
(MACHADO; MACHADO; BALBINOT, 2021)	Deep learning for surface electromyography artifact contamination type detection	Pré- processamento	 Identificador da interferência; Uso de <i>deep learning</i> e dispensa da necessidade de extração de características. 					
(MCCOOL et al., 2014)	Identification of contaminant type in surface electromyography (EMG) signals	Pré- processamento	 Proposição de algoritmo para identificação do tipo de contaminante; Apresentação de características específicas para identificação de contaminação. 					
(IJAZ; CHOI, 2018)	Anomaly Detection of Electromyographic Signals	Pré- processamento	Algoritmo não-supervisionado para detecção e reconhecimento da classe do agente degradador do sinal.					
(FRASER <i>et al.</i> , 2014)	Automated biosignal quality analysis for electromyography using a one-class support vector machine	Pré- processamento	Método para detecção da presença de qualquer fonte de contaminação em sinal de EMG.					

Tabela 1 – Contribuição dos trabalhos produzidos na área.

Segundo a Tabela 1, no trabalho de Machado *et. al* (2021) apresentou-se uma proposta para o estágio de pré-processamento visando tornar o sistema mais robusto à presença de interferências no sinal de eletromiografia. Nele, a pesquisa está centralizada na identificação do tipo da contaminação através de um modelo baseado em um sistema híbrido de uma Rede Neural Recorrente e uma rede neural do tipo *Long Short-Term Memory* (LSTM). O principal ganho deste trabalho foi a dispensa de um estágio de extração de características.

A identificação da fonte da contaminação em sinais de sEMG também foi o tema dos trabalhos de McCool *et. al* (2014) e de Ijaz e Choi (2018). No primeiro propôs-se uma metodologia baseada em SVM para o reconhecimento de 5 diferentes tipos de interferência, a partir da extração de 7 características do sinal de EMG. Ijaz & Choi (2018), por sua vez, apresentou um método de classificação não supervisionado fundamentado em Tranformada de

Wavelet, rPCA (robust Principal Component Analysis) e SOM (Self Organizing Map) objetivando a recognição de 5 fontes de contaminação.

Por fim, a pesquisa de Fraser e equipe (2014) objetivou a criação de um algoritmo de avaliação da qualidade do sinal de sEMG de forma automática. Através do treinamento de um modelo preditor de uma classe por SVM a partir de sinais íntegros de eletromiografia, conseguiu-se detectar 6 diferentes tipos de contaminantes. A abordagem proposta traz como principal inovação a capacidade de detecção de um elevado range de interferências, embora não identifique a fonte das mesmas.

Todas as propostas apresentadas demandam de um estágio de treinamento *off-line* do modelo e, consequentemente, requerem que sejam previamente coletados dados do usuário. Além disso, todos eles utilizaram sinais contaminados artificialmente. Frente ao exposto, as contribuições do presente trabalho podem ser resumidas nos seguintes itens:

- Proposição de uma alternativa para o estágio de pré-processamento que possua potencial para a detecção, identificação e minimização do impacto de contaminantes, que possibilite o treinamento online (dispensa da necessidade de aquisição de dados à priori do usuário);
- Desenvolvimento de um algoritmo que consiga identificar contaminações mais brandas (sinal com SNR de até 10dB) com resultados semelhantes ou melhores dos que os das propostas já existentes;
- 3) Formação de uma base de dados com sinais adquiridos em condições não ideais, reproduzindo possíveis fontes de contaminação que podem ocorrer com o uso pleno do dispositivo mio-controlado.

1.4 ESTRUTURA DA TESE

A tese está estruturada em 7 capítulos. O Capítulo 2 apresenta, de forma resumida, os princípios básicos de eletromiografia, processamento de sinais de sEMG e os principais conceitos do método de aprendizagem por reforço, o qual é o núcleo do algoritmo proposto, de modo a fundamentar e contextualizar o presente trabalho. A revisão do estado da arte está compreendida no Capítulo 3, destacando as produções mais relevantes na área nos últimos 5 anos e realçando os desafios que ainda precisam ser superados.

Já o Capítulo 4 exibe a metodologia experimental desenvolvida, iniciando com a descrição das bases de dados consideradas (a do NinaPro e a adquirida no IEE). Na sequência, expõe-se o modelo utilizado para a geração dos contaminantes utilizados nos testes de validação do algoritmo, seguido da fundamentação e equacionamento das características extraídas do

sinal de sEMG. Após, a metodologia proposta é detalhada através da determinação das ações, do algoritmo da função de recompensa e do modelo e parâmetros das redes neurais do ator e do crítico. Fechando o capítulo, apresenta-se o projeto de experimentos elaborado para a etapa de validação do método.

A validação da base de dados adquirida e os resultados oriundos dos três experimentos realizados de forma *off-line* estão expostos e discutidos no Capítulo 5. Os próximos passos da pesquisa e as considerações finais formam o Capítulo 6. Encerrando a tese, o Capítulo 7 está destinado à descrição dos artigos publicados na área.

2 REVISÃO SOBRE ELETROMIOGRAFIA, PROCESSAMENTO DE SINAIS DE SEMG E FUNDAMENTOS DE APRENDIZAGEM POR REFORÇO

2.1 CONCEITOS BÁSICOS SOBRE ELETROMIOGRAFIA

Eletromiografia (EMG) é o estudo da manifestação elétrica proveniente da ativação neuromuscular na ocorrência da contração de um músculo (DE LUCA, 1979). Apesar do estudo dos músculos ter reconhecida importância ao longo de séculos, a atividade elétrica dos mesmos é alvo de pesquisas apenas em um período recente. A primeira aquisição de sinal de eletromiografia de superfície data de 1849, sendo realizada pelo fisiologista alemão Emil Heinrich Du Bois-Reymond através de um tipo primitivo de galvanômetro (PEARCE, 2001; POZZO; FARINA; MERLETTI, 2004). A ele credita-se a descoberta do potencial de ação, ou seja, a detecção que uma descarga elétrica acompanha a passagem periférica do impulso nervoso (PEARCE, 2001). Por outro lado, no trabalho de ADRIAN & BRONK, (1929), focouse na medição intramuscular do sinal de EMG através de agulhas concêntricas as quais tinham capacidade de realizar a medição dos potenciais de unidades motoras individuais (POZZO; FARINA; MERLETTI, 2004).

Sob o ponto de vista fisiológico, a contração e o relaxamento muscular ocorrem devido à conexão neuromuscular. O início do processo de contração acontece com o estímulo muscular, no qual um sinal elétrico chamado potencial de ação muscular é transmitido às fibras musculares. O emissor deste sinal é o neurônio motor, sendo denominado unidade motora o conjunto formado por ele e todas as fibras musculares a ele conectadas (TORTORA; DERRICKSON, 2012). Um único neurônio motor estimula mais de uma fibra muscular, sendo este número associado, principalmente, ao tipo do movimento. Em músculos associados a movimentos de maior precisão, como por exemplo o de abrir e fechar os olhos, os neurônios motores possuem de 10 a 20 fibras musculares. Em contrapartida, nos músculos responsáveis por movimentos maiores que requerem mais força (por exemplo o bíceps braquial e o gastrocnêmio), um único neurônio motor pode estar associado a uma faixa de 2000 a 3000 fibras musculares (TORTORA; DERRICKSON, 2012).

Os neurônios são estruturados por um corpo celular, dendritos e um axônio. O neurônio motor é classificado em multipolar devido às suas múltiplas extensões celulares, vários dendritos e seu único axônio (TORTORA; DERRICKSON, 2012). O estímulo elétrico recebido pelo neurônio motor origina-se nas ramificações do axônio de outros neurônios, podendo ser excitatórios ou inibitórios. Os pontos de entrada do estímulo no neurônio motor estão nos terminais pré-sinápticos, localizados nas superfícies dos dendritos e corpo celular do mesmo

(HALL; GUYTON, 2011). Após a ocorrência do estímulo, os impulsos nervosos (potenciais de ação) surgem, geralmente na região chamada cone de implantação, a partir do qual são conduzidos ao longo do axônio até os terminais axônicos os quais estão próximos, porém não fisicamente conectados, às fibras musculares. A sinapse entre os terminais axônicos e a placa motora terminal de uma fibra muscular é chamada de junção neuromuscular (TORTORA; DERRICKSON, 2012), e é o meio pelo qual o potencial de ação é transmitido às células musculares induzindo a contração. Diferentemente do que ocorre em sistemas elétricos, a transmissão do impulso nervoso pelo neurônio motor às fibras musculares ocorre através da movimentação de íons e não de elétrons.

O potencial de ação divide-se em duas fases: despolarição e repolarização. Durante a primeira etapa, a membrana parte do repouso (tipicamente apresentando potencial elétrico de -70 mV) para um potencial menos negativo podendo atingir valores positivos. Tipicamente, uma despolarização para um potencial de cerca de -55 mV já caracteriza um impulso (TORTORA; DERRICKSON, 2012). Durante uma contração muscular, o potencial elétrico na região de despolarização pode atingir valores na faixa de 50 a 75 mV (HALL; GUYTON, 2011). Na fase de repolarização o potencial da membrana retorna para o seu valor de repouso (TORTORA; DERRICKSON, 2012). A velocidade na qual o potencial de ação se propaga na membrana muscular está relacionada com o diâmetro e o tipo das fibras musculares, sendo denominada de velocidade de condução (POZZO; FARINA; MERLETTI, 2004). A Figura 1 mostra a atividade elétrica da membrana muscular na ocorrência de um estímulo proveniente do neurônio motor.

A medição da atividade elétrica dos músculos pode ser realizada de modo invasivo ou superficialmente através da pele. No primeiro os eletrodos são inseridos no corpo humano. Neste tipo de medição os eletrodos basicamente consistem em uma agulha com uma cânula em seu interior por onde um ou mais fios isolados fazem a leitura do sinal. A vantagem deste método está no fato dele possibilitar a análise da eletromiografia com maior precisão espacial, limitado de 4 a 5 unidades motoras (POZZO; FARINA; MERLETTI, 2004). Deste modo, o sinal de EMG medido consiste na superposição de potencial de ação da unidade motora (MUAP – *Motor Unit Action Potential*).

Já no modo não invasivo, a medição do sinal de EMG é realizada através de eletrodos fixados na pele. Neste caso, os eletrodos, tipicamente constituídos de prata-cloreto de prata, podem ser colocados diretamente em contato com a pele (medição à seco – *dry electrodes*) ou com uma camada de gel condutivo separando-os da pele (POZZO; FARINA; MERLETTI, 2004). As principais vantagens deste em relação à forma invasiva estão no menor desconforto induzido ao sujeito, nenhum risco de infecção (MERLETTI; DE LUCA, 1989) e na maior

praticidade na alocação dos eletrodos. Além disso, para a medição do sinal de eletromiografia de superfície (sEMG) dispensa-se a presença de um profissional da área da saúde para a colocação dos sensores. Com isso, a sua utilização tem sido amplamente preferida em relação ao método invasivo em aplicações de controle motor e no desenvolvimento de tecnologias de substituição de função, como por exemplo próteses mioelétricas (FARINA; NEGRO, 2012).

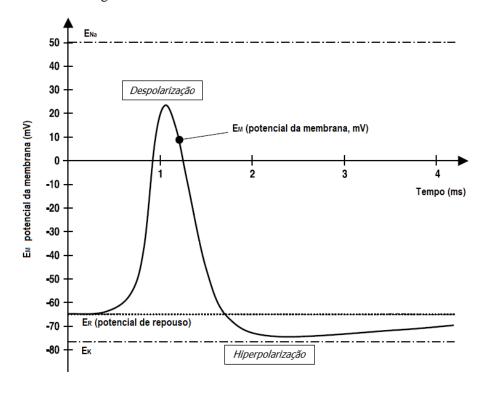


Figura 1 – Potencial elétrico da membrana muscular.

Adaptado de (POZZO; FARINA; MERLETTI, 2004).

O sinal de EMG, medido de forma invasiva ou não, é, portanto, resultado da superposição de vários Potenciais de Ação da Unidade Motora (MUAP). Contudo, na leitura superficial, o eletrodo se encontra distante do músculo, sendo o espaço entre ambos preenchido por tecido biológico. Este último atua como um filtro passa-baixa, atenuando frequências acima de 400 Hz (POZZO; FARINA; MERLETTI, 2004). Com isso, o sinal de sEMG possui componentes entre as frequências de 6 e 500 Hz, sendo a maior parcela da energia compreendida na faixa de 20 e 150 Hz. A amplitude do sinal não processado (à exceção da aplicação de um filtro passabanda) pode excursionar entre ±5000 μV em atletas (KONRAD, 2005).

Como exemplo, a Figura 2 ilustra o sinal de sEMG adquirido de um voluntário saudável sobre a região ventral do músculo *Flexor Digitorum Superficialis*. Este sinal pertence à base de dados NinaPro número 2, voluntário 2 (ATZORI *et al.*, 2014). A atividade elétrica muscular medida da superfície da pele possui forte característica estocástica, podendo ser considerado

um sinal complexo e não estacionário. Tais atributos estão relacionados ao grande número de MUAP's sobrepostas e da natureza irregular da descarga das unidades motoras (ASGHARI OSKOEI; HU, 2007).

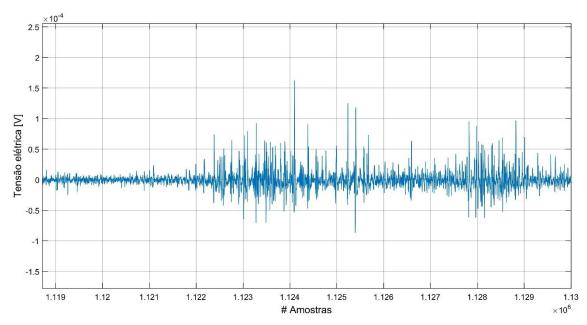


Figura 2 – Exemplo de sinal de sEMG.

Existe uma série de fatores que influenciam a medição de EMG, seja do ponto de vista fisiológico, anatômico e técnico, que fazem com a que a relação entre a amplitude do envelope do sinal (obtido após retificação e filtragem) e a força exercida pela junta ou membro seja apenas qualitativa (DE LUCA, 1997). Ainda segundo de Luca, (1997) os fatores que impactam na aquisição da atividade elétrica muscular podem ser divididos entre extrínsecos e intrínsecos. Os primeiros estão relacionados à estrutura dos eletrodos e à forma em que eles estão dispostos na superfície da pele. Dentre eles pode-se citar a área da superfície de contato do eletrodo com a pele (impacta no número de unidades motoras detectadas), a localização do mesmo em relação ao músculo (caso esteja localizado próximo à borda lateral do músculo o sinal medido sofre maior influência da atividade elétrica de outros grupos musculares, o chamado *crosstalk*), distância entre os eletrodos, além de outros. Já os identificados como fatores intrínsecos compreendem as características fisiológicas, anatômicas e bioquímicas dos músculos. Diferentemente das primeiras, estas não podem ser controladas pelo operador (DE LUCA, 1997).

Contudo, de modo a minimizar os efeitos dos fatores extrínsecos, existe uma série de recomendações que orientam o procedimento para a realização da medição de sEMG. Segundo a SENIAM (Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles – ação

europeia que visa padronizar a medição de sEMG entre laboratórios de pesquisa com foco na caracterização do eletrodo, fixação dos mesmos, processamento e modelamento do sinal de sEMG), é recomendável que o eletrodo tenha no mínimo 10 mm no sentido das fibras musculares e a fixação respeite um distanciamento de 20 mm entre eles (STEGEMAN; HERMENS, 2007). Em relação ao tipo do sensor, recomenda-se o uso de eletrodo com gel condutivo devido a sua maior praticidade de fixação, embora tenha performance semelhante ao seu oposto. Já para o processamento e condicionamento do sinal de sEMG medido, recomenda-se a aplicação de um filtro passa-alta com frequência de corte entre 10 e 20 Hz (para análise de movimentos) e um filtro passa baixa com frequência de corte na faixa dos 500 Hz. O primeiro para atenuação do ruído de baixa frequência, tipicamente associado a artefato de movimento, e o segundo para remoção do ruído intrínseco do sistema de aquisição, que abrange o relacionado com o equipamento e eletrodos (STEGEMAN; HERMENS, 2007).

2.2 PRINCÍPIOS SOBRE PROCESSAMENTO DE SINAL DE SEMG

O sinal não processado de sEMG possui forte natureza estocástica (Figura 2) visto que é constituído da sinergia de vários músculos, sendo, portanto, não muito informativo nesta forma (ANAM et al., 2019; REAZ; HUSSAIN; MOHD-YASIN, 2006). Deste modo, para se extrair informação útil referente à atividade elétrica muscular, é necessária a aplicação de técnicas de processamento que a tornem quantificável e manipulável. Existem diversos métodos de tratamento do sinal de sEMG, sendo os mais comumente utilizados os baseados na exploração das métricas estatísticas do mesmo. Estas dividem-se em características extraídas no domínio do tempo, no domínio da frequência e no domínio do tempo e frequência. A partir destas métricas obtém-se com mais facilidade informações relacionadas às propriedades do músculo, conseguindo-se quantificar o desempenho muscular (MERLETTI; DE LUCA, 1989).

Características extraídas no domínio do tempo são as mais comumente utilizadas no processamento de sEMG, principalmente devido à sua simplicidade computacional em comparação com as suas concorrentes no domínio da frequência e tempo e frequência (ASGHARI OSKOEI; HU, 2007). Elas são obtidas diretamente a partir da análise da amplitude do sinal, não requerendo, portanto, a aplicação de transformações (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012). Considerando que o sinal de sEMG possui média nula, a amplitude do mesmo pode ser caracterizada pelo seu desvio padrão variante no tempo (tendo em vista seu aspecto não estacionário), o qual está relacionado com o número de unidades motoras ativas e a taxa de ativação. Logo, através da verificação da magnitude da série temporal do sinal consegue-se extrair informações acerca da energia, nível da ativação, duração

e força, sendo, com isso, suscetíveis a variações no posicionamento dos eletrodos, espessura do tecido biológico, distribuição das unidades motoras nas fibras musculares, dentre outros (ASGHARI OSKOEI; HU, 2007). A maior desvantagem no uso deste tipo de característica está associada ao fato dela considerar o sinal estacionário. Sabendo-se da natureza não estacionária da atividade elétrica medida de forma não invasiva, seus parâmetros estatísticos variam ao longo do tempo e, consequentemente, as métricas calculadas no domínio temporal também apresentarão alterações (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012).

Segundo PHINYOMARK e colaboradores, (2012) as características extraídas no domínio do tempo podem ser classificadas de acordo com suas propriedades matemáticas. No referido trabalho, analisou-se 26 diferentes métricas as quais foram divididas em 4 grupos: as relacionadas com a energia e complexidade do sinal (Raiz da Média Quadrática, Potência, Comprimento da Forma de Onda, dentre outras), as que trazem informações acerca da frequência do sinal (Número de Cruzamentos por Zero, Número de Alterações da Inclinação do Sinal, dentre outras), as determinadas a partir de modelos preditivos (aqui citam-se Coeficientes Autorregressivos, Coeficientes Cepstral, dentre outros) e, por fim, as obtidas por meio de métodos dependentes no tempo, ou seja, são calculadas através da segmentação temporal das características pertencentes aos 2 primeiros grupos (por exemplo a Inclinação do Valor Absoluto Médio a qual é calculada a partir da diferença entre o Valor Absoluto Médio de dois segmentos temporais consecutivos).

Por outro lado, características extraídas no domínio da frequência requerem maior custo computacional do que as temporais, devido ao fato de exigirem uma etapa extra no seu cálculo que é a transformação de domínio na representação do sinal. Este tipo de métrica traz informações a respeito da taxa de propagação e forma das MUAP's (ISON; ARTEMIADIS, 2014), sendo normalmente aplicadas no estudo de fadiga muscular e análise do recrutamento de unidades motoras (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012). A Densidade Espectral de Potência (DEP) representa parcela importante na análise do sinal de sEMG no domínio da frequência, podendo ser determinado pelo quadrado das componentes obtidas pela aplicação da Transformada de Fourier (TF) dividido pelo comprimento do sinal (ASGHARI OSKOEI; HU, 2007). A DEP é, formalmente, definida pela Transformada de Fourier função autocorrelação do sinal de **sEMG** (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012). O maior ônus deste tipo de atributo está associado à baixa resolução temporal além do seu elevado custo computacional.

Por fim, existem características que são extraídas no domínio da frequência e do tempo simultaneamente. Estas garantem uma boa resolução tanto temporal como espectral. Tais

métricas representam tanto padrões transientes como de estado estacionário de contrações dinâmicas (ISON; ARTEMIADIS, 2014). Tipicamente elas são obtidas a partir da Transformada de Wavelet (TW) e sua generalização, a Transformada de Wavelet em Pacote (*Wavelet Packet Transform* – WPT) e da Transformada de Fourier de Curta Duração (*Short-Time Fourier Transform* - STFT) (ASGHARI OSKOEI; HU, 2007). Sua aplicação é restrita devido ao seu elevado custo computacional, abstração dos atributos e ao fato dela produzir um grande número de coeficientes (ISON; ARTEMIADIS, 2014).

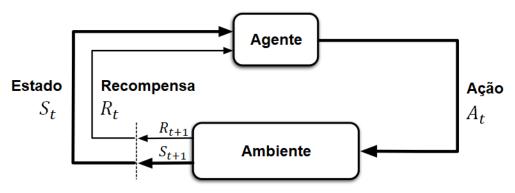
Entretanto, devido ao grande potencial informativo existente nos sinais eletromiografia, seu uso tem se intensificado tanto na medicina (detecção de disfunções neuromotoras e auxílio no tratamento das mesmas, melhora no desempenho de atletas (medicina esportiva), dentre outras) quanto na engenharia biomédica. Neste último, são inúmeras as pesquisas relacionadas com a criação de Interfaces Homem-Máquina (IHM) a partir de EMG, com foco no desenvolvimento de próteses mio-controladas (ATZORI et al., 2012; CENE et al., 2019; KRASOULIS; VIJAYAKUMAR; NAZARPOUR, 2020; MANTILLA-BRITO et al., 2020; SCHWEISFURTH et al., 2020; YAMANOI; OGIRI; KATO, 2020), exoesqueletos (LU et al., 2019; MA et al., 2019; TRIGILI et al., 2019), ambientes de realidade virtual para reabilitação (BOUTERAA; ABDALLAH; ELMOGY, 2019; VAN DIJK et al., 2016; YANG et al., 2017), órteses (BOS et al., 2020), sistemas de tele operação (YE et al., 2019; ZHOU et al., 2019), dentre outros. Todos os nichos de pesquisa supracitados, associados com o desenvolvimento de IHM a partir de eletromiografia, baseiamse no desenvolvimento de um algoritmo preditor de intenção de movimento a partir de padrões do sinal de EMG, normalmente utilizando técnicas de aprendizagem de máquina. No próximo capítulo discutir-se-á a respeito das pesquisas que estão sendo desenvolvidas nesta área (focadas na predição de movimentos do segmento mão-braço) e os desafios e lacunas que ainda precisam ser superados.

2.3 CONCEITOS BÁSICOS SOBRE APRENDIZAGEM POR REFORÇO

Aprendizagem por reforço (*Reinforcement Learning* – RL) é uma forma de aquisição de conhecimento acerca de um determinado sistema através da experiência adquirida de um agente sobre o ambiente no qual está inserido. Diferentemente de outros métodos como os supervisionados e não supervisionados, este está mais focado no aprendizado direcionado a metas por meio da interação (SUTTON; BARTO, 2018). Deste modo, dentre as diversas estratégias para treinamento de modelos preditivos, a realizada por RL é a que mais se aproxima da aprendizagem natural do ser humano e animais em geral.

O conceito de RL baseia-se na interação entre um agente e um ambiente. Esta relação se dá através de ações executadas pelo primeiro e que impactam nas características do segundo. A situação do ambiente em um determinado instante de tempo t é representada por meio de estados. Para cada movimento realizado, o agente passa de um estado S_t para outro S_{t+1} e, como consequência, percebe uma recompensa numérica. O objetivo consiste então na determinação de uma política de ações que maximize o valor recebido a longo prazo pelo executor. Assim, o aprendizado se dá pela experiência adquirida em função das recompensas obtidas pelo agente em decorrência das ações tomadas e da observância do impacto destas no ambiente. A Figura 3 ilustra o princípio de funcionamento de uma rede de RL. Esta forma de representação do sistema através de um agente atuando em um ambiente baseia-se no conceito de Processo de Decisão de Markov (MDP – Markov Decision Processes).

Figura 3 – Esquema do funcionamento de uma rede de aprendizagem por reforço.



Adaptado de (SUTTON; BARTO, 2018).

Além do agente e do ambiente, pode-se identificar mais 4 elementos constituintes de um sistema de aprendizagem por reforço: uma política de ações, um sinal de recompensa, uma função de valor de estado e, opcionalmente, um modelo do ambiente (SUTTON; BARTO, 2018).

ightharpoonup Política de ações: caracteriza o comportamento do agente em um dado instante de tempo. Ela corresponde ao mapeamento das ações a serem tomadas quando o sistema se encontra em um determinado estado. Este elemento é o núcleo do agente uma vez que descreve por si só o seu comportamento. As políticas de ações podem ser desde simples funções determinísticas, inspeção em tabelas de valores de cada estado/ação ou até mesmo estocásticas (SUTTON; BARTO, 2018), dependo do problema abordado. Normalmente é representada pela expressão $\pi(a|s)$ e indica a probabilidade do agente tomar a ação a dado que se encontra no estado s.

- Sinal de recompensa: está diretamente associado ao objetivo do problema de RL, sendo dele a responsabilidade de direcionar o aprendizado do agente através da avaliação das ações executadas por meio da atribuição de um valor numérico (recompensa). Ele consiste na base primária de alteração da política de ações na medida em que pode reduzir a probabilidade do agente repetir uma ação em um dado estado na qual observou-se menor recompensa em um instante de tempo anterior. Geralmente este sinal é caracterizado de forma estocástica em função do estado e das ações tomadas. A maximização do total de recompensa percebida a longo prazo fundamenta a meta global do aprendizado por reforço (SUTTON; BARTO, 2018).
- Função de valor de estado: determina uma estimativa para o total de recompensa recebida pelo agente a longo prazo a partir de um estado específico. O termo "valor de estado" representa a preferência deste levando em consideração os prováveis estados que seguirão e as recompensas neles disponíveis. Deste modo, diferentemente do elemento anterior que avaliava o que era bom em um sentido imediato, este preocupa-se com o retorno esperado do sistema no futuro (SUTTON; BARTO, 2018). Aqui por retorno entende-se o somatório das recompensas percebidas ao longo do tempo pelo agente. A obtenção desta função é de vital importância para o treinamento, visto que um dado estado pode estar associado a uma pequena recompensa e ao mesmo tempo conduzir a uma trajetória que proporcione elevado retorno futuro. O valor estimado para um estado dado que o agente siga uma política de ações π pode ser lido a partir da Equação (1):

$$v_{\pi}(s) = E_{\pi}[G_t|S_t = s] \tag{1}$$

onde E_{π} representa o valor esperado do retorno recebido pelo sistema que se encontra no estado s e segue política π e G_t é o retorno percebido pelo sistema a longo prazo, ou seja, o acúmulo de todas as recompensas recebidas, sendo dado pela Equação (2).

$$G_t = \sum_{k=0}^{\infty} \gamma^k R_{t+k+1} \tag{2}$$

Na Equação (2), γ corresponde a um fator de desconto possuindo valor compreendido dentro do intervalo (0,1]. Sua presença se justifica no impedimento do retorno tender ao infinito nos casos não episódicos, isto é, quando não há um estado terminal (sistemas contínuos).

O valor também pode ser estimado a partir da ação tomada em um certo estado. Neste caso a função é dada pela Equação (3).

$$q_{\pi}(s, a) = E_{\pi}[G_t | S_t = s, A_t = a]$$
(3)

Modelo do ambiente: consiste em algo que simula o comportamento do ambiente, ou seja, dado um estado e a realização de um movimento, o modelo determina a recompensa e o próximo estado. Existem problemas de RL no qual não se possui tal elemento. Nestes casos o treinamento é conduzido através da tentativa e erro por parte do agente (SUTTON; BARTO, 2018).

A base para a obtenção de conhecimento em abordagens fundamentadas em RL está na Equação de Bellman. Por meio dela é possível a determinação da função valor de estado de forma recursiva, o que facilita a aplicação de programação dinâmica, por exemplo, além de outras metodologias computacionais baseadas em *machine learning*. A mesma está descrita na Equação (4), onde expressa-se uma relação entre o retorno esperado para um dado estado *s* e o de seus sucessores (SUTTON; BARTO, 2018).

$$v_{\pi}(s) = \sum_{a} \pi(a|s) \sum_{s',r} p(s',r|s,a) \cdot [r + \gamma v_{\pi}(s')]$$
(4)

Aqui, s' indica o estado subsequente, r a recompensa e p(s',r|s,a) a probabilidade de o sistema ir para s' e receber r sendo que se encontra em s e o agente executou a ação a.

No que concerne ao método de solução aplicado a problemas de aprendizado por reforço, pode-se classificá-lo em tabular ou por aproximação. A primeira se aplica a situações nas quais o número de estados é finito e suficientemente pequeno a ponto de possibilitar que seja representado através de uma matriz ou tabela (SUTTON; BARTO, 2018). Neste caso, o treinamento é realizado através do mapeamento de todos os possíveis estados ou pares de ações/estados para posterior obtenção da estimativa para o retorno esperado de cada um deles. A Equação de Bellman é utilizada para a atualização de tais valores em cada iteração do algoritmo. Deste modo, no limite de tempo tendendo a infinito, cada ponto do mapa converge para a quantia real do total de recompensa alcançada. Assim, consegue-se a solução ótima para o problema, permitindo ao agente a melhor escolha do movimento em cada passo.

Contudo, na maioria das aplicações de interesse o método anterior é impraticável devido ao elevado número de estados, podendo ser, inclusive, infinito. Para tais problemas existem as metodologias de solução por aproximação. A principal divergência de ambas estratégias de aprendizado reside no fato de que nesta não se atinge uma política ótima, diferentemente dos algoritmos tabulares. Nestes casos, as funções de valor de estado e da política de ações podem

ser parametrizadas. Assim, o objetivo se resume na busca pelo conjunto destes parâmetros que maximiza o total de recompensa acumulada (SUTTON; BARTO, 2018).

Neste contexto, o treinamento do agente pode ser realizado de três formas distintas. Uma delas está vinculada à determinação dos parâmetros de uma função valor de estados que guiará a escolha das ações (similar à alternativa tabular). Já uma segunda consiste na obtenção dos fatores de uma política de ações também parametrizada, dispensando-se a atribuição de valores para os estados. Por fim, através da junção das duas abordagens anteriores, existe ainda a possibilidade de se considerar ambas funções parametrizadas (uma para valor de estado e outra para a política de ações). Consequentemente, a meta passa a ser a otimização das duas expressões simultaneamente. Esta última estratégia também é conhecida como Método Ator-Crítico (*Actor-Critic Method*), onde o ator está associado à realização dos movimentos (política de ações parametrizada) cabendo ao crítico a responsabilidade de avaliá-las (função valor de estado).

A escolha dentre as três opções apresentadas para o aprendizado por aproximação depende tipicamente do tipo do problema deparado. Existem situações nas quais a função de estado é mais simples e fácil de se estimar do que a política de ações e vice-versa (SUTTON; BARTO, 2018). Neste último caso cita-se o exemplo da aplicação de RL para a compreensão do jogo de tetris (ŞIMŞEK; ALGORTA; KOTHIYAL, 2016). Em contrapartida, o método Ator-Crítico tende a aprender de forma mais rápida do que quando se considera somente a parametrização da política de ações, uma vez que reduz a variância da estimativa do gradiente (PILARSKI *et al.*, 2011), sendo comumente preferido em aplicações de aprendizado por reforço em controle mioelétrico de membros robóticos (BENBRAHIM; FRANKLIN, 1997; PILARSKI *et al.*, 2011; PILARSKI; DICK; SUTTON, 2013; VASAN; PILARSKI, 2017).

Um modo de se implementar o algoritmo Ator-Crítico é através do método do gradiente. Nele, o aprendizado se dá de modo incremental, onde, a cada iteração, os pesos da política de ações e da função valor de estado são atualizados na direção do gradiente e proporcionalmente ao valor do erro de diferença temporal. Este último é uma medida da diferença entre a estimativa atual do valor do estado S_t e de uma melhor aproximação para a mesma métrica só que considerando a recompensa percebida R_{t+1} e o próximo estado S_{t+1} (SUTTON; BARTO, 2018). O mesmo está representado na Equação (5).

$$\delta_t = R_{t+1} + \gamma \cdot v(S_{t+1}) - v(S_t) \tag{5}$$

Analisando-se a Equação (5), observa-se que a mesma deriva da Equação de Bellman, sendo $v(S_t)$ e $v(S_{t+1})$ estimativas para o retorno esperado no estado S_t e seu subsequente S_{t+1} ,

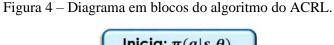
respectivamente. Face ao exposto, a cada etapa do treinamento do agente, os pesos da política de ações e da função valor de estado são corrigidos segundo as equações (6) e (7), nesta ordem:

$$\theta = \theta + \alpha \delta \frac{\nabla_{\theta} \pi(a|s,\theta)}{\pi(a|s,\theta)}$$
 (6)

$$w = w + \alpha \delta \nabla_w v(s, w) \tag{7}$$

onde, $\pi(a|s,\theta)$ é a política de ações parametrizada em θ , ∇_{θ} denota o gradiente calculado em função de θ , v(s,w) é a função valor de estado parametrizada em w, ∇_{w} corresponde ao gradiente tomado em w e α é o fator de aprendizado.

Com base nisso, o algoritmo do ACRL (*Actor-Critic Reinforcement Learning*) pode ser descrito, de forma genérica, pelo diagrama em blocos ilustrado na Figura 4.





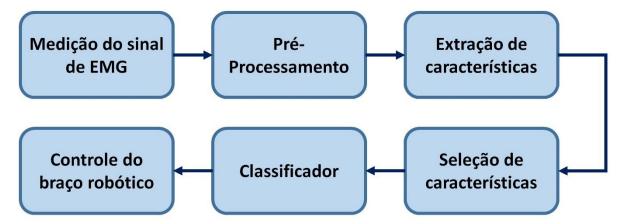
O campo de aplicação de metodologias de RL é amplo, indo desde o aprendizado de jogos como gamão (TESAURO, 1995) e tetris (ŞIMŞEK; ALGORTA; KOTHIYAL, 2016), até em automação predial como no desenvolvimento de sistema de controle de tráfego de elevadores (CRITES; BARTO, 1996). Contudo, no que tange a criação de modelos preditores de movimentos dos membros superiores a partir de eletromiografia o uso de tais técnicas é ainda muito pouco explorado. Os escassos trabalhos encontrados (dentro do alcance da pesquisa realizada) focam em metodologias de controle proporcional das articulações de um braço robótico (PILARSKI *et al.*, 2011; PILARSKI; DICK; SUTTON, 2013; VASAN; PILARSKI, 2017) ou de um exoesqueleto (HAMAYA *et al.*, 2017) e na seleção do melhor conjunto de

características extraídas por uma rede neural convolutiva para a classificação de 6 gestos de mão (SONG *et al.*, 2018). Entretanto, nas supracitadas pesquisas verificou-se a eficácia e aplicabilidade de métodos de RL no desenvolvimento de controladores mioelétricos. Diante disso e da já destacada capacidade de treinamento online do sistema, fundamenta-se a escolha desta abordagem para o algoritmo proposto nesta tese de doutorado.

3 ESTADO DA ARTE

A tarefa de classificação de movimentos do segmento mão-braço pode ser dividida em 6 blocos, como exemplifica o diagrama da Figura 5. Na primeira etapa, o sinal de EMG é adquirido do voluntário através de eletrodos de superfície (método não invasivo) ou por meio de eletrodos inseridos de modo percutâneo (forma invasiva), passando por um devido circuito de condicionamento o qual abrange, no mínimo, um estágio de filtragem para remoção de ruído seguido de uma etapa de amplificação para posterior digitalização. Na sequência, o sinal digitalizado passa por um estágio de pré-processamento no qual filtros adicionais, normalização, retificação, segmentação, dentre outros procedimentos, podem ser aplicados. Depois de pré-processado, características podem ser extraídas (no domínio do tempo, frequência ou do tempo-frequência) de modo a evidenciar as informações úteis presentes no sinal. Após esta fase, o sinal, agora representado pelas métricas calculadas na etapa anterior, é submetido a um refinamento onde as características são filtradas, mantendo-se as que sejam mais relevantes e informativas para a tarefa de classificação e removendo-se as demais. Os atributos remanescentes da etapa de Seleção de Características são, então, utilizados no treinamento de um modelo preditor de movimentos, ou trajetória de movimento, ou força dependendo da aplicação. Por fim, a saída do classificador é usada no controle do braço robótico (prótese, órtese, exoesqueleto, membro virtual) fazendo-o executar o movimento requerido pelo usuário.

Figura 5 – Diagrama em blocos típico de um sistema de identificação de movimento a partir de EMG.



Nos últimos anos, muitas pesquisas foram desenvolvidas nesta área, explorando cada uma das etapas descritas anteriormente e todas com o objetivo em comum de avançar um passo a mais em direção ao desenvolvimento de um sistema robusto de controle mioelétrico de um membro artificial. De modo a contextualizar a tese e apresentar o estado atual da produção

acadêmica inserida neste nicho, as próximas subseções trarão uma descrição dos trabalhos publicados mais recentes. Inicialmente uma análise bibliométrica será apresentada, seguida da descrição dos trabalhos estudados organizados por etapa da tarefa de classificação explorada (segundo a Figura 5).

3.1 ANÁLISE BIBLIOMÉTRICA DOS TRABALHOS PUBLICADOS MAIS RECENTES

Com o intuito de analisar o estado da arte no desenvolvimento de sistemas de classificação de movimentos do segmento mão-braço, uma pesquisa sistemática foi elaborada e aplicada durante o segundo ano de desenvolvimento desta tese. A base de dados considerada foi a Scopus, devido à sua elevada abrangência em artigos científicos e também por ela ser compatível com o software VOSviewer, utilizado na análise bibliométrica. O referido repositório, fundado em 2004 pela Elsevier, indexa citações de publicações científicas (DAVID et al., 2020), cobrindo mais de 5000 editoras e 24600 títulos, dos quais mais de 23500 compreendem *Journals* revisados por pares.

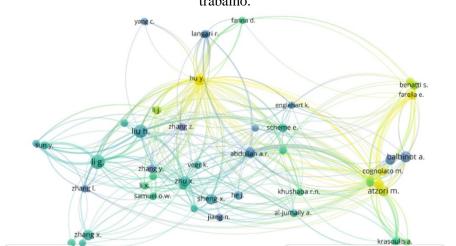
A pesquisa foi limitada pelo período a partir do ano de 2015 com as seguintes palavraschaves e condicionantes: *electromyography* AND ("*movement classification*" OR "*gesture recognition*") AND ("*upper limb*"). Como resultado, 687 trabalhos foram listados. Após, analisou-se o título e o resumo destes, descartando-se aqueles que não se tratavam de sistemas de identificação de movimentos do segmento mão-braço a partir de sinais de EMG, que eram de revisão da literatura, que não estavam em inglês ou espanhol ou português, e que não se obteve acesso. Assim, 426 artigos foram selecionados para leitura completa e análise bibliométrica.

A bibliometria consiste na aplicação de métodos matemáticos e estatísticos a livros e outras formas de produções em meios escritos (ALVARADO, 1984). Por meio dela procura-se obter indicadores da quantidade de conhecimento científico e da tendência de evolução da produção acadêmica dentro de determinada área. Através desta análise consegue-se estimar os autores mais produtivos, os trabalhos/autores/periódicos mais relevantes, os países onde se concentram a maioria dos trabalhos, estabelecer relações entre diferentes autores, dentre outras possibilidades. Com isso, objetiva-se eliminar vieses da pesquisa, apresentando-a dentro de um contexto generalizado.

O software VOSviewer consiste em uma ferramenta para criação de mapas baseado em uma rede de dados. Por meio dele é possível a obtenção de gráficos associados a diferentes tipos de itens, como por exemplo, pesquisadores, periódicos, palavras-chave, países, dentre

outros. Um mapa é, normalmente, constituído de somente um tipo de item. Entre um par de itens pode haver uma conexão denominada de link. Um link pode estar associado à coautoria ou citações simultâneas entre pesquisadores, coocorrência de palavras-chave, para citar alguns exemplos. A cada link é atribuído um indexador de força, representado por um valor numérico positivo. Quanto maior o valor, maior será a força da conexão entre dois itens e maior será a espessura da linha que os une no mapa. Por fim, a cada item presente no gráfico são atribuídos valores de peso e *score*. O primeiro está associado à importância do item (é restrito a valores positivos), estando diretamente relacionado ao tamanho da representação do item no mapa (normalmente esferas). O cálculo do peso pode basear-se no número total de conexões que o item possui, no resultado da soma da força destas, no total de documentos associados a um autor ou país ou periódico, e outros. O *score*, por sua vez, indica alguma propriedade numérica do item (número médio de citações de um autor, por exemplo), sendo representado por uma escala de cores no mapa. Diferentemente do peso, o *score* não precisa necessariamente aparecer na forma de um número positivo.

O número de citações que um pesquisador possui em seus trabalhos publicados é uma importante forma de se mensurar o impacto e a relevância de seus achados. Deste modo, a Figura 6 ilustra o mapa de citações dos autores considerados na supracitada pesquisa. Para melhor visualização, foram incluídos no gráfico somente os pesquisadores que possuem mais de 5 trabalhos publicados dentro da janela considerada na pesquisa. O diâmetro das esferas indica o número total de publicações do respectivo autor (no referido período) e a cor (*score*) representa o número médio de citações por trabalho. As conexões entre pesquisadores representam citações entre eles, independente de quem citou quem, ou seja, não são direcionais.



👠 VOSviewer

Figura 6 – Mapa de citações entre pesquisadores. Cores indicam número de citações médias por trabalho.

Os pesquisadores G. Li e H. Liu destacam-se em relação ao número de trabalhos publicados no período com 21 e 19 respectivamente. Por outro lado, os trabalhos de H. Müller, M. Atzori, M. Cognolato, E. Farella e Y. Hu foram os que receberam o maior número de citações em média por publicação (38, 27,1, 29,8, 31,8, 47,6, na ordem), realçando a relevância de seus achados. A presença dos 3 primeiros autores na lista dos mais citados pode ser explicado pelo fato deles constituírem o projeto NinaPro, o qual compreende uma das maiores bases de dados de sinal de sEMG com algumas de suas expansões publicadas neste período (ATZORI *et al.*, 2015; ATZORI; MULLER, 2015; COGNOLATO *et al.*, 2020; PALERMO *et al.*, 2017), sendo largamente aplicado em pesquisas da área. Já em relação às conexões entre os pesquisadores, destaca-se a força da ligação entre G. Li com Y. Sun e D. Chen, ambas com 24 citações.

A Figura 7 apresenta o mapa de cocitações dentre os autores dos 426 artigos selecionados. Uma cocitação entre dois pesquisadores ocorre quando um terceiro trabalho cita ambos. No gráfico, cada esfera representa um pesquisador, cujo tamanho está associado ao número de citações (em valor absoluto) associado a ele. As conexões, por sua vez, representam ocorrência de cocitação entre 2 pesquisadores, sendo mais espessa quanto maior for o número de incidências (espessura indica força da ligação). Os autores, ainda, são agrupados em *clusters* de acordo com a cor de sua esfera. Aqui, novamente, por questões de clareza na representação só foram selecionados os autores que receberam 45 ou mais citações. A análise de cocitações é importante no sentido de realçar a relação entre os autores e seus respectivos trabalhos.

atzori, m.

gijsberts, a.

castellini, C. babinot, a.

kamavuako, e.n.

lefis b.

kamavuako, e.n.

lefis b.

kamavuako, e.n.

lefis b.

kamavuako, e.n.

liul.

bepini, l.

dieti h., benatti, s. phukpattaranont, p.

cipran, e.

cipr

Figura 7 – Mapa de cocitações de pesquisadores. Cores representam *clusters*.

De acordo com o mapa, destacam-se D. Farina, K. Englehart, B. Hudgins, G. Li, N. Jiang e E. Scheme como principais autores no sentido de interconexão com outros pesquisadores e no número de citações (532, 525, 436, 340, 302 e 295 respectivamente). Dario Farina é um pesquisador influente na área de processamento de sinais de eletromiografia, tendo importantes trabalhos publicados os quais são utilizados como referência em aquisição e tratamento de registros de EMG (FARINA *et al.*, 2014; FARINA; MERLETTI; ENOKA, 2004). Desta forma, pelo fato dos principais trabalhos do referido pesquisador abranger temas genéricos associados a processamento de sinal de EMG, e da destacada relevância de tais trabalhos, justifica-se seu elevado número de citações e a forte incidência de cocitações com os demais autores presentes no mapa, independente do cluster ao qual pertencem. Aqui vale destacar que o mapa é criado a partir das referências dos trabalhos selecionados na pesquisa realizada (limitada aos últimos 5 anos). Logo, não há limitantes de tempo das cocitações ilustradas, sendo esta análise, portanto, uma boa estimativa da importância e relevância geral dos pesquisadores para a produção científica atual na área.

Deste mapa salienta-se ainda o pesquisador A. Phinyomark, cujos trabalhos possuem reconhecida relevância principalmente na análise das características extraídas do sinal de sEMG, das informações associadas a elas e avaliação do impacto no reconhecimento de padrões de movimento (PHINYOMARK *et al.*, 2013; PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012). Por fim, vale realçar ainda a presença dos pesquisadores que constituem o já citado projeto NinaPro: M. Atzori, C. Castellini, A. Gijsberts, B. Caputo e H. Müller. A importância destes está atrelada, principalmente, ao sucesso do supracitado projeto e ao consequente intenso uso das bases de dados disponibilizadas.

Por outro lado, o gráfico de citações entre países (Figura 8) traz a localização das regiões do globo onde estão concentrados os principais grupos de pesquisas na área. A Figura 8 apresenta o número de publicações associado a cada país (diâmetro da esfera), o número médio de citações por trabalho (cor da esfera) e o número de citações entre pares de países (espessura das linhas de conexão). Cada item selecionado para constar no mapa possui no mínimo 5 artigos publicados no período.

A China sobressai-se por ser (com sobras) o maior produtor de trabalhos na área no período com 128, seguido à distância do Reino Unido (56), Itália (40), Estados Unidos (39) e Índia (37). Contudo, a produção recente do Brasil merece destaque com 25 artigos neste intervalo, caracterizando-o como principal país da América Latina neste quesito, ficando à frente, inclusive, de países como Alemanha e Suíça (esfera amarela acima da Itália e ao lado da Alemanha). Este último, por sua vez, salienta-se no número médio de citações por trabalho com

24,12. Não por coincidência esta é a localização principal da equipe do projeto NinaPro. Em relação ao número de ligações com outros países, a China aparece em primeiro com 26 links, seguido da Itália (23), Reino Unido e Suíça (ambos com 20). O fato da China possuir o maior número de conexões se deve, essencialmente, ao elevado índice de publicações. Por outro lado, a presença da Suíça neste grupo explica-se pela média de citações por trabalho.

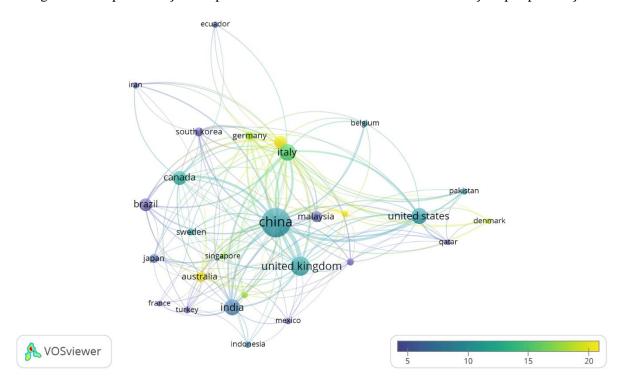


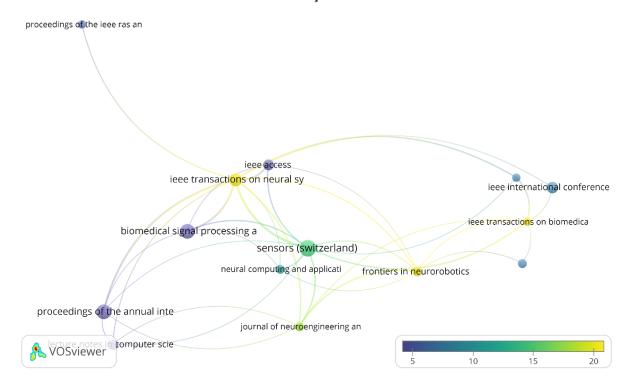
Figura 8 – Mapa de citações de países. Cores indicam número médio de citações por publicação.

Seguindo na mesma linha de análise, a Figura 9 apresenta o mapa de citações por fonte de publicação do trabalho. Aqui, fonte abrange desde *journals* e revistas até anais de eventos científicos. Da mesma forma que nas análises precedentes, na Figura 9 o diâmetro da esfera representa o número total de artigos, cores indicam a média de citações por trabalho e as conexões ilustram ocorrência de citação entre as fontes. Apenas itens com, no mínimo, 6 publicações aparecem no gráfico.

Analisando-se primeiramente os *journals*, o *Sensors* (Suíça) figura como a maior fonte de publicações no período com 24 documentos. Na sequência surgem o *Biomedical Signal Processing and Control* (18), *IEEE Transactions on Neural System and Rehabilitation Engineering* (14) e *IEEE Access* (10). Entretanto, ao levar-se em conta a relevância das publicações, merecem destaque o *IEEE Transactions on Biomedical Circuits and System* com média de 22,83 citações por trabalho, o *Frontiers in Neurorobotics* (21,38) e o *IEEE Transactions on Neural System and Rehabilitation Engineering* (19,64).

No que tange aos eventos científicos, a *International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* e a *International Conference on Rehabilitation Robotics*, também da IEEE, estão associadas aos maiores índices de artigos selecionados pela pesquisa realizada, com, respectivamente, 18 e 11 trabalhos. Em contrapartida, o número médio de citações relacionados a este tipo de fonte varia de 3,39 até 7,91, bem abaixo dos *journals* mencionados anteriormente. Isso se deve ao fato dos trabalhos apresentados em eventos, normalmente, consistirem em resultados preliminares de pesquisas que, embora promissoras, carecem ainda de validação científica mais robusta.

Figura 9 – Mapa de citações por fonte de publicação do trabalho. Cores representam número médio de citações.



Por fim, fechando a análise bibliométrica proposta, apresenta-se o mapa com as coocorrências das palavras-chave dos autores. Na Figura 10, o diâmetro de cada item representa o número de ocorrências, as ligações indicam a aparição simultânea de duas palavras-chave em um mesmo artigo e as cores fazem o agrupamento em *clusters*. Somente palavras que continham 8 ou mais ocorrências compõem o gráfico.

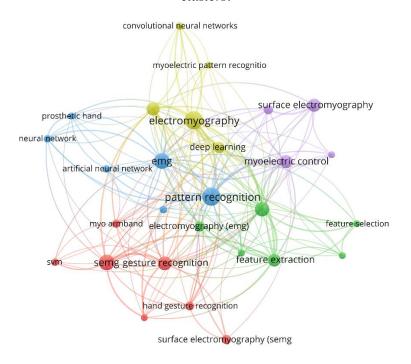
As palavras e termos *electromyography*, *pattern recognition*, *emg* e *semg*, naturalmente, foram as que mais ocorreram, uma vez que apenas a palavra "*pattern*" não havia sido utilizada como elemento chave na pesquisa efetuada. Todavia, ressalta-se o expressivo índice do termo *deep learning*, indicando uma tendência atual do uso de aprendizado profundo no processamento de sinais de EMG. Seguindo essa linha, justifica-se a aparição de *convolutional*

neural networks e sua abreviação *cnn*, o qual constitui um clássico e um dos mais utilizados métodos de aprendizado baseado em *deep learning*.

Outro termo que vale a menção é o *Myo Armband* que consiste em um dispositivo de aquisição de sinal de eletromiografia de superfície que incorpora também um sistema de classificação de movimentos de mão. Criado pela *Thalmic Labs*, ele compreende 8 eletrodos diferenciais do tipo *dry*, além de sensores inerciais como giroscópios, magnetômetros e acelerômetros, todos tri-axial (ZEA; BENALCÁZAR, 2020). O surgimento desta palavrachave no mapa indica uma propensão recente no uso de tal dispositivo para aquisição de sEMG, o que pode ser explicado pela sua portabilidade e seu custo relativamente baixo em comparação com outros sistemas de medição comerciais (PIZZOLATO *et al.*, 2017).

Por fim, destaca-se ainda a ocorrência dos métodos de classificação *support vector machine* e sua abreviação *svm*, e *artificial neural network* juntamente com sua forma reduzida *neural network*. Ambos consistem em algoritmos clássicos de aprendizagem de máquina que são amplamente utilizados no processo de reconhecimento de movimentos do segmento mãobraço a partir de sinais de eletromiografia. De acordo com a Figura 10, os dois seguem sendo tendência, apesar da crescente preferência na utilização de algoritmos baseados em *deep learning*.

Figura 10 – Mapa de coocorrências de palavras-chave utilizadas pelos pesquisadores. Cores indicam *clusters*.



3.2 ANÁLISE DOS TRABALHOS MAIS RECENTES

Como já mencionado neste texto, o sinal de EMG possui informações úteis que podem ser extraídas, através de técnicas de processamento adequadas, e utilizadas para o desenvolvimento de interfaces homem máquina. Contudo, o foco da presente pesquisa fica restrito a trabalhos associados ao desenvolvimento de modelos preditores de movimentos dos membros superiores (mais precisamente do segmento mão-braço) que podem ser aplicados no controle de próteses, órteses, exoesqueletos, em sistemas de realidade virtual, teleoperação, dentre outros. Assim, nesta seção serão descritos os principais trabalhos que estão sendo desenvolvidos na área de desenvolvimento de sistemas de identificação de movimentos do segmento mão-braço baseado no processamento de sinal de eletromiografia, de modo a apresentar o estado atual da pesquisa acadêmica neste ramo. Todavia, serão considerados somente as pesquisas associadas à etapa de pré-processamento e também as que objetivam o tratamento de contaminantes no sinal de sEMG, visto que o presente algoritmo está inserido neste nicho. Para uma análise mais abrangente do estado da arte, sugere-se a leitura do artigo de revisão publicado (TOSIN; MACHADO; BALBINOT, 2022).

Apesar de se conseguir taxas de acerto no reconhecimento de gestos do segmento mãobraço superiores a 90% em ambientes de laboratório, ainda existem muitos desafios a serem superados para que dispositivos mioelétricos tenham o mesmo desempenho em condições ambientais do dia-a-dia. Atualmente, as dificuldades que norteiam a pesquisa em busca de soluções para aumentar a robustez dos sistemas correntes em situações reais podem ser categorizadas em 4 fatores (CAMPBELL; PHINYOMARK; SCHEME, 2020):

- Fator do posicionamento do membro: está associada com a ativação muscular necessária para manter o membro em repouso devido à ação da força gravitacional. Além disso, dependendo da disposição do braço podem ocorrer variações na localização dos eletrodos em relação ao músculo devido ao deslocamento da pele em relação a este. Ambas situações mencionadas se manifestarão no sinal de sEMG como artefatos, causando confusão entre o padrão esperado do sinal (aprendido na etapa de treinamento do classificador) e o observado (CAMPBELL; PHINYOMARK; SCHEME, 2020);
- Fator da intensidade da contração muscular: a intensidade da contração muscular é controlada inconscientemente de acordo com o esforço previsto para a execução de uma ação específica. Já foi verificado em alguns estudos que existe uma relação direta entre a intensidade da contração e a amplitude do sinal de EMG. A alteração

no vigor da ação muscular pode levar inclusive a variações nas características de frequência do sinal (CAMPBELL; PHINYOMARK; SCHEME, 2020);

- Fator do deslocamento de eletrodo: consiste no deslocamento da posição dos eletrodos. Quando isso ocorre, a musculatura subjacente muda em relação a eles. Neste caso, mesmo se as mesmas fibras musculares estão sob a abrangência do eletrodo, com o deslocamento ocorre alteração na impedância do tecido biológico, implicando em mudanças nas propriedades do sinal (CAMPBELL; PHINYOMARK; SCHEME, 2020);
- Fator temporal (entre dias ou durante o mesmo dia): o sinal de EMG é influenciado por diversos mecanismos bioquímicos, fisiológicos ou anatômicos que são variantes no tempo (por exemplo o fluxo sanguíneo). Aqui também podem ser incluídos a variação no posicionamento dos eletrodos devido à remoção recolocação da prótese entre seções, e também as alterações na intensidade da contração entre diferentes usos do dispositivo (CAMPBELL; PHINYOMARK; SCHEME, 2020).

Face ao exposto, ainda não existem, presentemente, dispositivos mioelétricos disponibilizados comercialmente, à exceção de neuropróteses (KACZMAREK; MAŃKOWSKI; TOMCZYŃSKI, 2019). Contudo, as próteses controladas por EMG que obtiveram sucesso no mercado ainda empregam apenas 2 eletrodos bipolares localizados nos músculos extensor e flexor do antebraço (WANG et al., 2019), o que limita o número de movimentos preditos (tipicamente possibilitam controle sequencial de 2 ou menos graus de liberdade (DEWALD et al., 2019)) e, consequentemente, a aplicabilidade do braço artificial. Além disso, estratégias de controle sequencial ainda estão longe de proporcionar movimentos naturais ao usuário, requerendo deste um elevado nível de prática e, consequentemente, de treinamento (ATZORI; MÜLLER, 2015), o que configura um dos maiores empecilhos para a aceitação plena do dispositivo.

Entretanto, inúmeros pesquisadores têm trabalhado arduamente na busca por soluções para a obtenção de um sistema que seja ao mesmo tempo capaz de reconhecer um elevado número de movimentos e que seja robusto em relação aos fatores de variação supracitados. Para tanto, o problema é analisado sob diferentes pontos de vista e para cada etapa do processo novas abordagens são propostas.

Considerando-se a sequência de etapas ilustrada na Figura 5, após a aquisição e condicionamento do sinal de EMG pode ser aplicado ainda um estágio de pré-processamento antes da extração de características. É nesta etapa que o sinal é "preparado" para a sequência do processo através da aplicação de filtros adicionais para a remoção de ruído, análise da presença de contaminantes e minimização do efeito em determinados canais (reconstrução do

sinal, remoção do contaminante, eliminação do canal, dentre outros), segmentação, transformação aplicada ao sinal com o intuito de destacar determinada propriedade, para citar alguns. Assim, sua importância está atrelada à função de garantir um sinal íntegro e possibilitar que a máxima informação seja obtida nas fases subsequentes. Para tanto, inúmeras pesquisas têm sido publicadas nos últimos anos com novas propostas para esta etapa que surgem como alternativas para a melhora da performance dos classificadores (CHEN et al., 2020; HE et al., 2019; MACHADO et al., 2020; SEZGIN, 2019; SHENG et al., 2019; TAM et al., 2020; WAHID; TAFRESHI; LANGARI, 2020; XU et al., 2020; ZHOU et al., 2020). Dentre os ganhos trazidos por esses trabalhos, podemos citar a melhora na qualidade do sinal adquirido, minimização dos efeitos de deslocamento do eletrodo, variação temporal e variação intersujeitos nas características do sinal EMG, para citar alguns, que induzem a um aumento no desempenho do sistema de classificação de movimento.

A Tabela 2 resume os trabalhos supracitados, exceto aqueles relacionados à análise de contaminantes, os quais serão descritos em uma tabela específica.

Tabela 2 – Um resumo dos trabalhos associados à fase de pré-processamento.

Autores	Estratégia	Método	#СН	#Mov.	#V.I.	Classif.	Tx.Ac. [%]	Problema considerado	
(TAM et al., 2020)	Transformação dos dados	Frequency-time- space cross-domain	32	8	1	CNN	98.2	Melhoria da qualidade dos dados.	
(WAHID <i>et al.</i> , 2020)	Segmentação	Multi-Window Majority Voting	8	6	40	RF	80.7	Efeito do tamanho da janela e da sobreposição.	
(XU <i>et al.</i> 2020)	Verificação da posição dos eletrodos	Interpolated Peak Location	8	6	10	ANN	94.7	Deslocamento do eletrodo.	
(ZHOU <i>et al.</i> 2020)	Medida da posição/ direção dos dedos	Hk-medoids clustering	8	10	10	LDA	81.5	Atribuição automática de rótulo de movimento.	
(CHEN <i>et al.</i> 2020a)	Decomposição do sinal sEMG (MUST)	Convoloution kernel compensation	192	11	11	SVM	96.1	Melhoria geral do desempenho do classificador.	
(JIA et al., 2020)	Segmentação	Multi-Window Majority Voting	2	10	8	CNN	99.4	Effect of the window length and overlap size.	
(HE <i>et al.</i> 2019)	Verificação da posição dos eletrodos	Mahalanobis distance (similarity)	6	10	9	MD	95.8	Deslocamento do eletrodo.	
(POWAR; CHEMMANGAT , 2019)	Filtragem digital	Butterworth, Wiener Spectral subtraction	2	8	7	kNN	73.3	Melhoria da qualidade dos dados.	
(SHENG <i>et al.</i> 2019)	Transformação dos dados	Common Spatial- Spectral Analysis	4	13	8	LDA	90.1	Variação temporal.	
(SEZGIN 2019)	Transformação dos dados	Bicoherence Analysis	2	5	42	ELM	97.8	Variação inter-sujeitos.	
(AMEZQUITA -GARCIA et al., 2019)	Transformação dos dados	Scatter Matrix Projection	8	15	8	LDA	93.8	Melhoria da qualidade dos dados.	
(PHUKAN et al., 2019)	Filtragem digital	Transformada de Wavelet	2	10	4	SVM	96.5	Melhoria da qualidade dos dados.	
(TSINGANOS et al., 2019)	Transformação dos dados	Hilbert space-filling curve	10	52	27	CNN	79.1	Melhoria geral do desempenho do classificador.	

Na tabela: "#CH" é o número de canais, o termo "Tx.Ac." refere-se à taxa de acerto média relatada no respectivo artigo no melhor cenário, CNN é *Convolutional Neural Network*, RF é *Random Forest*, ANN é *Artificial Neural Network*, LDA é *Linear Discriminant Analysis*, SVM é *Support Vector Machine*, MD é *Mahalanobis Distance*, kNN é k-*Nearest Neighbor* e MUST é *Motor Unit Spike Train*.

O problema mais frequentemente abordado na fase de pré-processamento é a melhoria da qualidade do sinal. As estratégias vão desde filtros digitais até métodos de transformação de dados. A filtragem digital do sinal de sEMG é uma etapa quase mandatória do processo de classificação de movimentos, sendo empregada na grande maioria dos trabalhos. Contudo, não há definição de qual topologia de filtro é a mais indicada. De modo a contribuir com a clarificação desta questão, Powar e Chemmangat (2019) realizaram um experimento comparando a performance de três topologias de filtros em termos da taxa de acerto da identificação de 8 gestos de mão e pulso por kNN (*k-Nearest Neighbor*): *Butterworth, Spectrum Subtraction* (SS) e *Wiener*. Destes, o primeiro se apresentou marginalmente superior aos demais com taxa de acerto de 73,3%, contra 67,17% (SS) e 65,04% (*Wiener*). Entretanto, SS proporcionou menor custo computacional, ao passo que o *Wiener* foi o responsável por deixar o sinal menos ruidoso dos três, sendo o mais indicado pelos autores para tarefas de detecção de ativação muscular.

Seguindo na mesma linha de filtragem do sinal, Phukan e colaboradores (2019) propuseram metodologia para remoção de ruído de alta frequência baseado na Transformada de *Wavelet*. O algoritmo baseia-se na manutenção dos coeficientes de baixa frequência e aplicação de um filtro nos componentes de alta frequência, no qual zeram-se todos aqueles que forem menor que um determinado valor de limiar. Este último, por sua vez, é determinado a partir das propriedades estatísticas dos próprios coeficientes de alta frequência. Após, aplica-se o procedimento inverso da transformada na representação resultante dos componentes de baixa frequência mais os de alta modificados, para a obtenção do sinal filtrado. Resultados promissores foram alcançados na identificação de 10 movimentos de dedos com apenas dois canais de medição e classificador SVM (*Support Vector Machine*) (taxa de acerto de 96,5%), ratificando o algoritmo proposto como uma boa estratégia para supressão de artefatos indesejados no sinal de sEMG.

Levando-se em conta a questão da variabilidade temporal das características da atividade elétrica muscular medida de forma superficial e também o fator da diferença entre diferentes voluntários, destacam-se os trabalhos realizados por Sheng e colegas (2019) e o de Sezgin (2019). Ambos propuseram técnicas de pré-processamento de modo a minimizar os efeitos variantes do sinal ao longo do tempo e intersujeitos. No primeiro, os autores apresentaram um algoritmo denominado *Comom Spatial-Spectral Analysis* (CSSA) para encontrar o que eles chamaram de "modo comum" no sinal de sEMG. O referido método, o qual baseia-se na aplicação da Transformada de *Wavelet*, parte da premissa de que séries temporais multivariadas (sinal de sEMG com resolução espacial e temporal) podem ser decompostas em uma parcela

estacionária e outra não, a primeira representando o "modo comum" do sinal. Já Sezgin considerou análise bi-espectral, a qual compreende um método estatístico utilizado para encontrar relações não lineares entre os componentes do sinal (SEZGIN, 2019). A partir dela, determina-se a representação da bicoerência do sinal (através da normalização do bi-espectro), a qual, por sua vez, é utilizada na etapa de extração das características.

Ambas propostas de pré-processamento supracitadas apresentaram bons resultados na tarefa de classificação de 13 movimentos com LDA (SHENG *et al.*, 2019) e 5 com ELM (*Extreme Learning Machine*) (SEZGIN, 2019). Contudo, o método CSSA mostrou ser mais eficiente na minimização do fator de variabilidade temporal do sinal, ao passo que o algoritmo baseado na análise da bicoerência obteve taxas de acerto interessantes em um experimento onde o classificador foi treinado com dados adquiridos de múltiplos voluntários.

Por outro lado, o problema associado com o deslocamento dos eletrodos foi o tema das pesquisas de Xu e equipe (2020) e He e colegas (2019). No primeiro, propôs-se uma técnica para identificação de deslocamento angular na posição dos eletrodos dispostos em braçadeiras, o que ocorre tipicamente em dispositivos vestíveis quando os eletrodos se encontram uniformemente espaçados ao longo da circunferência do braço. Para tanto, utilizou-se um algoritmo baseado no que eles denominaram de *Interpolated Peak Location* (IPL), que consiste na verificação da localização do pico de ativação do vetor de sensores para um dado movimento de referência. Este valor é então comparado com o obtido após a recolocação dos eletrodos para a avaliação de possível mudança no posicionamento. Já em (HE *et al.*, 2019), considerou-se, para o mesmo fim, a verificação da similaridade calculada a partir da distância de *Mahalanobis* em relação ao padrão de ativação do conjunto de eletrodos para um determinado movimento de referência. Em ambos métodos é permitido que os eletrodos sejam ajustados antes de reiniciar o uso do sistema. As duas abordagens se apresentam como métodos interessantes de préprocessamento para corrigir um problema que é muito comum neste tipo de procedimento, que é o deslocamento de eletrodo.

Não obstante, além dos problemas supracitados existe a questão da presença de contaminantes no sinal de sEMG. Como já destacado na seção 2.1, existem fatores intrínsecos e extrínsecos do processo de aquisição que influenciam as características do sinal de EMG, se manifestando na forma de contaminantes. De acordo com a literatura, estes podem ser categorizadas em:

Ruído inerente dos equipamentos eletrônicos e à instrumentação: todos dispositivos eletrônicos geram ruído o qual não pode ser eliminado por completo, apenas minimizado através da utilização de componentes de alta qualidade (REAZ; HUSSAIN;

MOHD-YASIN, 2006). Aqui, pode-se citar o ruído térmico presente nos elementos eletrônicos do sistema de amplificação, estando presente na forma de ruído de linha de base (DE LUCA *et al.*, 2010), saturação do amplificador operacional, erro de quantização, contato fraco entre o eletrodo e a pele incluindo o descolamento do mesmo (FRASER *et al.*, 2014), como exemplos;

- Ruído do ambiente: este fator está associado à interferência eletromagnética. O corpo humano está constantemente inundado por radiação eletromagnética, sendo praticamente impossível evitar tal exposição (REAZ; HUSSAIN; MOHD-YASIN, 2006). Neste contexto estão inseridas as contaminações por radiofrequência (RF) e a associada aos cabos de transmissão de energia elétrica (FRASER et al., 2014), se manifestando nas altas frequências (RF) e nas frequências de 50 e 60Hz (no caso da rede elétrica, dependendo da região) e suas harmônicas;
- Artefato de movimento: se manifesta através da deformação da informação, causando irregularidades no sinal medido (REAZ; HUSSAIN; MOHD-YASIN, 2006). Este contaminante pode ocorrer sob 2 circunstâncias: devido ao movimento do cabeamento dos eletrodos e em razão da interface entre o eletrodo e a pele (DE LUCA et al., 2010; IJAZ; CHOI, 2018). Este último, por sua vez, se apresenta, basicamente, em duas situações distintas. Uma delas é devido à movimentação do músculo em relação à pele, causando uma variação na distribuição de carga e, consequentemente, induzindo uma mudança na diferença de potencial da interface eletrodo-pele (DE LUCA et al., 2010; POZZO; FARINA; MERLETTI, 2004). Já a outra aparece quando um impulso de força viaja pelo músculo até a pele provocando um deslocamento na interface sensor-pele (DE LUCA et al., 2010). O artefato de movimento está presente na região de baixas frequências da banda do sinal, com uma faixa espectral que se estende, geralmente, do nível DC até 20 Hz (IJAZ; CHOI, 2018; POZZO; FARINA; MERLETTI, 2004);
- Instabilidade inerente do sinal de EMG: a amplitude do sinal é estocástica por natureza e depende da taxa de ativação das unidades motoras (firing rate) que, tipicamente, está compreendida na faixa de 0 a 20Hz (REAZ; HUSSAIN; MOHDYASIN, 2006). Deste modo, a energia entre as frequências de 10 e 20 Hz contém picos cuja amplitude depende da taxa de ativação das unidades motoras. Tais valores apresentam flutuação principalmente na ocorrência de contrações de pequena magnitude, fazendo com que a energia nesta faixa de baixas frequências seja instável e, consequentemente, não forneça informação confiável acerca da atividade muscular (DE LUCA et al., 2010);

- Atividade e inatividade anômala temporal do músculo: o primeiro ocorre na presença de ação muscular num dado instante de tempo inesperado e o segundo, por outro lado, acontece quando é detectada uma inatividade do músculo em um dado momento em que era esperada uma ação (IJAZ; CHOI, 2018);
- Interferência por outros sinais biológicos indesejados: se encaixam neste fator o cross talk (sinal medido de um músculo inativo e gerado por outro ativo (POZZO; FARINA; MERLETTI, 2004)), interferência por sinal de eletrocardiografia (ECG), dentre outros;
- Ruído relacionado com a interface eletrodo-pele: denominado de ruído eletroquímico, o mesmo, juntamente com o ruído térmico presente nos componentes eletrônicos do sistema de amplificação, formam o ruído de linha de base o qual é detectado sempre que um sensor é conectado à pele (DE LUCA et al., 2010).

A presença de tais fatores no sinal de EMG é indesejada podendo inviabilizar a extração da informação presente no mesmo dependendo do nível da contaminação. Preocupados com isso, muitos pesquisadores têm trabalhado no desenvolvimento de métodos de préprocessamento para detecção, recuperação do sinal de EMG, identificação do tipo de interferência e obtenção de um sistema robusto à presença de contaminantes (DE LUCA et al., 2010; DE MOURA; BALBINOT, 2018; FAVIEIRO; BALBINOT, 2019; FRASER et al., 2012a, 2014; IJAZ; CHOI, 2018; MACHADO et al., 2020; MACHADO; CENE; BALBINOT, 2019; MCCOOL et al., 2014; STACHACZYK; ATASHZAR; FARINA, 2020). A Tabela 3 resume alguns desses trabalhos, onde as abreviaturas significam: "Cont." - Contaminante, "Mov." - Movimentos, "Carac." - características, IM - Identificação de Movimento, IC -Identificação de Contaminantes, DC – Detecção de Contaminantes, "Class.". – classificador, TVARMA - Time-Varying Autoregressive Moving Average, rPCA - robust Principal Component Analysis, SOM - Self-Organizing Map, LSAA - Least Squares Adaptive Algorithm, CMMV - Consecutive Minimum or Maximum Values, SQNR - Signal-to-*Quantization Noise Ratio*, PCC – Pearson Correlation Coefficient, TS – Template Subtraction, ATS - Adaptive Template Subtraction, MBF - Model Based Filtering, WD - Wavelet Denoising, EMD – Empirical Mode Decomposition, MYOPm – Modified Myopulse Percentage rate, IMCRA – Improved Minima Controlled Recursive Averaging, VAE – Variational Autoencoder, AM – Artefato de Movimento, SA – Saturação do Amplificador, AWGN – Additive White Gaussian Noise, PLI - Power Line, RC - Ruídos correlacionados, MixA -Combinação de mais de um contaminante, RQ - Ruído de Quantização, ADC-R - Recorte causado pelo conversor Analógico-Digital.

Tabela 3 – Um resumo dos trabalhos associados ao tratamento de contaminantes em sEMG.

Autores	Etapa	Estratégia	Método	Carac.	Mov.	Tipo cont.	SNR [dB]	Class.	Tx.Ac. [%]	Problema considerado
(DE MOURA; BALBINOT, 2018)	Pré- processamento	Estimação de sensor virtual	TVARMA	5 TD (IM)	17	AM SA AWGN PLI ECG	Não informado	SVM	69.2 (I) 47.5 (A) (IM)	Recuperação do sinal de sEMG.
(MCCOOL et al., 2014)	Pré- processamento	Análise de características do sinal	SVM	3 TD 4 FD (IC)	N/A	AM SA AWGN PLI ECG	-20 a 20	N/A	99.6 a 20.4 (IC)	Identificação do tipo de contaminante.
(IJAZ; CHOI 2018)	Pré- processamento	Clusterização	rPCA-SOM	1 TFD (IC)	N/A	AWGN PLI ECG RC MixA	Não informado	N/A	88.2 (IC)	Detecção da contaminação; Identificação do tipo de contaminante.
(FRASER et al. 2014)	Pré- processamento	Análise de características do sinal	SVM	4 TD 2 FD (DC)	N/A	AM SA PLI ECG RQ ADC-R	-20 a 45	N/A	N/A	Detecção da contaminação.
(FRASER et al., 2011)	Pré- processamento	Estimação do sinal contaminante	LSAA	Não	N/A	PLI	-10 a 40	N/A	N/A	Remoção do contaminante.
(FRASER et al., 2012a)	Pré- processamento	Estimação do sinal contaminante	Filtro média móvel	Não	N/A	ECG	-8 a 8	N/A	N/A	Remoção do contaminante.
(FRASER et al., 2012b)	Pré- processamento	Análise de características do sinal	CMMV (AS) SQNR (QN), PCC (ADC-C)	3 TD (DC)	N/A	SA RQ ADC-R	Não informado	N/A	N/A	Detecção da contaminação.
(MACHADO et al., 2019)	Pré- processamento	Estimação de sensor virtual	RNN-LSTM	1 TD (IM)	17	AS	Não informado	SVM	66.5 (IM)	Recuperação do sinal de sEMG.
(MACHADO et al., 2020)	Pré- processamento	Abordagem de série temporal	RNN-LSTM	Não	N/A	AM AWGN PLI ECG	-20 a 20	N/A	87.8 a 20.0 (IC)	Detecção da contaminação; Identificação do tipo de contaminante.
(DE LUCA et al., 2010)	Pré- processamento	Determinação da frequência de corte	Butterworth HP-filter	Não	N/A	AM	Não informado	N/A	N/A	Remoção do contaminante.
(STACHACZYK et al., 2020)	Pré- processamento	Semelhança espectro-temporal	Adaptive Spatial Filter	Não	4	AWGN PLI	Não informado	LDA	84.5 (IM)	Detecção e minimização do contaminante.
(OO; PHUKPATTA RANONT, 2020)	Pré- processamento	Regressor baseado em ANN	ANN	1 TD	N/A	ECG	-20 a 0	N/A	0.966*	Estimação do SNR do sinal.
(PETERSEN et al., 2020)	Pré- processamento	Várias	TS, ATS, MBF, WD, EMD, HP- Filter	Não	N/A	ECG	-42.6 a 9.7	N/A	N/A	Remoção do contaminante.
(TRIWIYANTO et al., 2018)	Extração de características	Limiares adaptáveis das características	MYOPm	1 TD (IM)	1 GDL	AWGN	0 a 60	Filtro de Kalman	9°**	Melhoria da robustez do sistema à contaminação.
(THONGPANJA et al., 2016)	Pré- processamento	Análise de métricas estatísticas	Kurtosis, Negentropy, L- Kurtosis, Robust Kurtosis	7 TD (DC)	N/A	AM AWGN PLI ECG Spikes	-20 a 20	N/A	N/A	Detecção da contaminação.
(MCCOOL et al., 2015)	Pré- processamento	Subtração espectral	IMCRA-based Spectral Enhancement	5 TD	7	AWGN	-10 a 0	SVM	59.9 a 82.4 (IM)	Melhoria da robustez do sistema à contaminação.
(FRASER et al., 2013)	Pré- processamento	Análise de métricas estatísticas	PCC	Não	N/A	AM PLI ECG	-20 a 30	N/A	N/A	Detecção da contaminação.
(TEH; HARGROVE, 2021)	Extração de características	Projeção do sinal de sEMG	VAE	4 TD (IM)	7	Flatlined signal	Não informado	LDA	>90.0 (IM)	Melhoria da robustez do sistema à contaminação.
(MACHADO et al., 2021)	Pré- processamento	Abordagem de série temporal	RNN-LSTM	Não	N/A	AM AWGN PLI ECG	-40 a 20	RNN- LSTM	20.0 a 99.5 (IC)	Detecção da contaminação; Identificação do tipo de contaminante

Apesar da maioria dos trabalhos listados na Tabela 3 não terem sido realizados visando a tarefa de reconhecimento de movimento, todos se aplicam a ela. Assim, a maioria deles está relacionada à etapa de pré-processamento e propõe métodos para detecção de contaminantes (identifica a interferência, mas não o tipo) ou remoção. As estratégias adotadas para detecção de contaminantes geralmente se baseiam na extração de métricas estatísticas (FRASER *et al.*, 2013; THONGPANJA *et al.*, 2016) e características projetadas artesanalmente do sinal sEMG (FRASER *et al.*, 2012a, 2014). Para remoção de contaminantes, são comumente empregados filtros (DE LUCA *et al.*, 2010; PETERSEN *et al.*, 2020) ou técnicas para estimar os parâmetros da interferência (FRASER *et al.*, 2011, 2012b).

No entanto, apesar da importância da detecção de contaminação para a avaliação da qualidade dos dados, conhecer o tipo de interferência também é desejável para eliminar sua fonte corrigindo o procedimento de aquisição. Dentro deste contexto estão os trabalhos (IJAZ; CHOI, 2018; MACHADO; MACHADO; BALBINOT, 2021; MCCOOL *et al.*, 2014). McCool *et al.* (2014) implementaram um classificador baseado em SVM para reconhecer cinco diferentes fontes de contaminação (ECG, artefato de movimento, saturação do amplificador, interferência de linha de energia e ruído de linha de base, representado por Ruído Gaussiano Branco Aditivo). Através de um experimento com a contaminação do sinal variando de -20 a 20 dB, foram alcançadas taxas de acerto de 100% e 97,79% para -20 e -10 dB. No entanto, à medida em que se diminuiu a intensidade da interferência, se reduziu a performance do algoritmo, registrando um índice de assertividade de apenas 20% a 20 dB.

Em contrapartida, em (IJAZ; CHOI, 2018) apresentou-se um algoritmo não supervisionado para detecção e identificação da classe do agente degradador. O mesmo conta com um estágio de pré-processamento incluindo filtragem por Tranformada de Wavelet e redução de dimensionalidade por rPCA (robust Principal Component Analysis). Assim, os componentes principais são considerados na determinação de um Self Organizing Map (SOM) que faz a clusterização dos dados. A partir da implementação de tal metodologia, conseguiu-se taxas de acerto de 88,2% na separação de 5 diferentes anomalias (ruído de linha de base, ECG, ruído correlacionado, rede elétrica e mistura de diferentes contaminantes) e sinal íntegro. O destaque do método está no fato dele fazer o reconhecimento de modo não supervisionado, todavia, não foi reportado o nível de contaminação aplicado sinteticamente no sinal.

A dispensa de uma etapa de pré-processamento e extração de características foi a inovação trazida por Machado *et al.* (2021). Neste trabalho, a identificação de 4 tipos de contaminantes (rede elétrica, artefato de movimento, ruído branco caracterizando ruído de linha de base e ECG) bem como a ausência destes (sinal íntegro) ficou a cargo de um classificador

fundamentado em Redes Neurais Recorrentes (RNR) e LSTM. Como resultado, atingiu-se 99,5% de índice de assertividade considerando-se dados contaminados com SNR de -30 dB.

Visando a recuperação do sinal contaminado de sEMG, Fraser *et al.* (2011, 2012b) e De Luca e colegas (2010) propuseram estratégias para a remoção de interferência da rede de energia, ECG e ruído de baixa frequência causado por artefato de movimento, respectivamente. Fraser *et al.* apresentaram dois algoritmos para estimar os parâmetros da interferência pela linha de energia e por ECG. No primeiro trabalho de Fraser *et al.* (2011), utilizou-se o *Least Squares Adaptive Algorithm* (LSAA) para estimar a amplitude, fase e frequência de um sinal senoidal sobreposto ao sEMG (interferência de linha de energia). No trabalho mais recente, Fraser *et al.* (2012b) usaram um filtro de média móvel para obter o sinal de ECG sobreposto ao de sEMG. Em ambos os métodos, a estimativa de contaminante obtida foi subtraída do sinal elétrico muscular. O LSAA provou ser eficiente para remover interferência de linha de energia com SNR de 15 dB ou menos. O erro RMS do filtro média-móvel foi comparado com o de um método clássico (medição de um sinal padrão de ECG para posterior uso na remoção da interferência presente no sinal) apresentando superioridade em contaminações mais severas. Demonstrou redução de 15,52% no erro RMS para uma interferência de 2 dB.

Já em (DE LUCA *et al.*, 2010) realizou-se um estudo sobre a melhor escolha para a frequência de corte de um filtro passa-alta na remoção do ruído causado por artefato de movimento. Por meio da execução de alguns testes variando-se a frequência de corte de 1 até 30 Hz de um filtro *Butterworth* com inclinação da zona de transição de 12 dB/oitava, concluiu-se que a determinação do melhor valor depende do tipo de músculo e da análise pretendida. Para o estudo de movimentos isométricos ou gestos comuns e naturais, 20 Hz foi o recomendado. Por outro lado, se o foco for a avaliação de movimentos mais vigorosos como por exemplo os associados a esportes, sugere-se o aumento da frequência para além dos 20 Hz, para maior atenuação da interferência do artefato de movimento, porém ao custo de induzir deformações e atenuação adicional no espectro do sinal de EMG.

No entanto, como alternativa aos algoritmos de pré-processamento para identificação do tipo de contaminante e remoção de interferência, alguns pesquisadores propuseram técnicas para recuperação de sinal EMG (DE MOURA; BALBINOT, 2018; MACHADO; CENE; BALBINOT, 2019) e melhoria da robustez do sistema frente a contaminantes (MCCOOL *et al.*, 2015; TEH; HARGROVE, 2021; TRIWIYANTO *et al.*, 2018). Machado *et al.* (2019) e De Moura e Balbinot (2018) apresentaram estratégias baseadas em sensores virtuais para recuperar as informações de um canal contaminado. De Moura e Balbinot (2018) utilizaram a correlação cruzada entre canais de aquisição (considerando configuração multicanal) para estimar um

modelo para a saída de um eletrodo contaminado. Assim, os dados gerados são independentes do sinal medido fisicamente. Para isso, eles propuseram uma estratégia baseada em *Time-Varying Autoregressive Moving Average* (TVARMA) e outra baseada no filtro *Time-Varying Kalman* (TVK). Para detectar a presença de contaminação no sinal e possibilitar o uso do sensor, foi utilizado um modelo baseado em SVM de uma classe. A avaliação do desempenho do método foi feita reconhecendo 17 movimentos através de 12 canais de sEMG e um classificador SVM. Os contaminantes considerados foram ECG, ruído branco Gaussiano, artefato de movimento, linha de energia e saturação do amplificador. A eficiência do algoritmo foi verificada comparando o desempenho do classificador com e sem contaminação. Aplicando o modelo de sensor virtual desenvolvido a partir do TVARMA, obteve-se uma redução (em média) de apenas 5,6% na precisão do classificador ao teste sem contaminação, superando seu oponente (TVK).

Entretanto, a proposta de Machado e colaboradores (2019) fundamenta-se na estimação do sinal de um canal corrompido a partir de um modelo de regressão obtido dos demais sinais (íntegros). Para a etapa de regressão implementou-se um sistema híbrido abrangendo uma Rede Neural Recorrente e uma rede neural do tipo LSTM. Resultados reportados mostraram um acréscimo de 9 para 66% no índice de assertividade do classificador fazendo-se a reconstrução de um canal contaminado com ruído proveniente da saturação do amplificador em comparação com o uso do sinal corrompido (sem a aplicação do método). Aqui, considerou-se SVM na identificação de 17 movimentos do segmento mão-braço.

Os resultados promissores da estratégia do sensor virtual indicam-no como uma boa opção para recuperação do sinal de sEMG. No entanto, se um grande número de canais estiver contaminado, a reconstrução dos dados será severamente prejudicada. Assim, McCool *et al.* (2015) apresentaram um algoritmo de pré-processamento chamado *Enhanced Minima Controlled Recursive Averaging* (IMCRA) baseado no aprimoramento espectral para atenuar o Ruído Gaussiano Branco no sinal sEMG. O algoritmo calcula o STFT para estimar o ruído presente no sinal recursivamente em cada segmento de tempo/frequência. Após a estimativa do ruído, ele é subtraído do sinal contaminado. Acurácias médias de 59,4 e 82,4 foram alcançadas na classificação de sete movimentos através de dados contaminados com SNR de -10 e 0 dB, respectivamente, demonstrando a eficiência do método.

Portanto, contaminantes no sinal sEMG são um dos fatores que levam ao desempenho reduzido dos sistemas de classificação quando testados fora do laboratório. Consequentemente, para que um dispositivo miocontrolado seja eficaz também em situações não ideais, é essencial que ele inclua o tratamento de contaminantes em seu sistema de controle, seja por um método

específico na etapa de pré-processamento do sinal ou embutido no classificador de movimentos. Esta seção resumiu algumas estratégias promissoras e inovadoras para resolver esse problema. No entanto, a maioria deles não foi considerada no contexto de reconhecimento de movimento, portanto, sua aplicabilidade no cenário de tempo real não é garantida. Assim, ainda há alguns passos a serem dados para melhorar os dispositivos miocontrolados atuais e futuros. Além da questão do tempo real, a variabilidade temporal inerente das propriedades do sinal sEMG e a ocorrência de contaminantes simultâneos também devem ser consideradas nos algoritmos de detecção e remoção de interferências. Finalmente, no que tange à forma como o modelo preditor de contaminantes é concebido, é extremamente desejável que se gaste o menor tempo possível com o treinamento, aquisições pré-uso para formação de base de dados, recalibrações do dispositivo, etc, tendo em vista que é este um dos principais motivos para a rejeição da prótese miocontrolada apontada pelos usuários.

Frente ao exposto, este trabalho visa apresentar soluções para algumas questões remanescentes em torno do tratamento de contaminantes em sEMG, com impacto no desenvolvimento de próteses miocontroladas. Para tanto, propõe-se o uso de metodologia baseada em Aprendizagem por Reforço, para identificação e minimização do efeito destas interferências. Assim, aproveitando as propriedades desta forma de aprendizagem de máquina, o algoritmo apresentado é adaptável a mudanças no ambiente e possibilita a realização do treinamento *online* sem a necessidade de aquisição de dados e calibração *offline*.

4 METODOLOGIA EXPERIMENTAL

Como já realçado nas seções anteriores, o presente trabalho compreende o desenvolvimento de um algoritmo de identificação e minimização dos efeitos de contaminantes em sinais de sEMG em aplicações envolvendo sistemas de classificação de movimentos do segmento mão-braço. Logo, aqui o foco será o estágio de pré-processamento, seguindo o diagrama em blocos representado na Figura 5, sendo o objetivo principal do método o de garantir um sinal íntegro para a etapa de extração de características, possibilitando a maior transferência de informação para o treinamento do modelo preditor de movimentos. Para isso, serão considerados quatro diferentes tipos de contaminação que são comuns no estudo de eletromiografia: presença indesejada de sinal de eletrocardiografia (ECG), artefato de movimento, interferência eletromagnética proveniente da rede elétrica e ruído de linha de base.

Tais fatores serão gerados artificialmente em sinais de sEMG extraídos das Bases 2 e 3 NinaPro e reproduzidos de forma experimental (alguns destes) na base que está sendo formada no Laboratório de Instrumentação Eletroeletrônica (IEE) da UFRGS. Os dados contaminados passarão ainda por um estágio de extração de características antes de serem utilizados no treinamento do agente que realizará a identificação do tipo de degradação e aplicará o filtro adequado para a minimização do mesmo. Visando este objetivo, propôs-se o uso de técnica baseada em aprendizado por reforço e Sistema de Inferência Fuzzy (SIF).

Nas seções subsequentes serão descritas cada etapa da metodologia apresentada com destaque para as bases de dados consideradas na validação do algoritmo bem como a realizada no IEE para fins de reprodução dos fatores geradores de contaminantes, o detalhamento da forma como cada fonte de interferência foi modelado, as características selecionadas para a representação do sinal visando a identificação do contaminante, e, finalmente, o algoritmo proposto fundamentado em RL.

4.1 DESCRIÇÃO DAS BASES DE DADOS UTILIZADAS

4.1.1 Base de Dados NinaPro

O projeto NinaPro corresponde a uma base de dados multimodal publicamente disponível, cujo principal objetivo é o de fornecer suporte para pesquisas na área de desenvolvimento de braços robóticos e próteses controladas por inteligência artificial, além de possibilitar que diferentes metodologias propostas sejam comparadas de forma mais justa (ATZORI *et al.*, 2012). Sendo constituída por dados de eletromiografia, cinemáticos, inerciais,

de rastreamento ocular, clínicas e neurocognitivos adquiridos de voluntários intactos e com amputação, atualmente ela compreende 10 diferentes *datasets*.

As bases 2 (ATZORI *et al.*, 2014) e 3 (ATZORI *et al.*, 2016) foram selecionadas para o desenvolvimento deste trabalho. A primeira é formada 40 sujeitos com os membros superiores íntegros e a última por 11 adultos com amputação transradial. Ambas compreendem sinais de eletromiografia adquiridos durante a execução de 49 movimentos do segmento mão-braço, divididos em 3 exercícios distintos. Aqui considerou-se somente o Exercício B, constituído por 17 movimentos básicos de dedos e pulso mais repouso, os quais estão ilustrados nas Figura 11 e Figura 12. Os referidos gestos foram realizados 6 vezes com duração de 5 segundos alternados por períodos de repouso de aproximadamente 3 segundos.

Figura 11 – Configurações isométricas de mão.



Adaptado de (ATZORI et al., 2014).

Figura 12 – Movimentos básicos de pulso.



Adaptado de (ATZORI et al., 2014).

Para a medição do sinal de sEMG foram usados 12 pares de eletrodos diferenciais ativos wireless do fabricante Delsys, modelo Trigno, a uma taxa de aquisição de 2000 amostras por segundo. Dois deles foram fixados no braço, na região ventral do bíceps e do tríceps. O restante foi alocado no antebraço, sendo 8 deles dispostos de forma equidistante ao longo da circunferência do membro, logo abaixo do cotovelo, e os outros dois pares sobre os músculos *flexor digitorum* e *extensor digitorum*. Os dados obtidos contam com ruído máximo de 750n Vrms.

O protocolo de aquisição seguido no projeto NinaPro consiste, basicamente, na sequência ilustrada na Figura 13. Primeiramente, o movimento a ser executado é mostrado ao sujeito em um monitor. Após, o voluntário, sentado confortavelmente em uma cadeira, replica o gesto apresentado com o membro no qual os eletrodos foram fixados. Estes últimos fazem a medição da atividade elétrica muscular e transmite os sinais a um laptop onde são processados e aplicados no treinamento do classificador de movimentos. Após a determinação do modelo preditor, o mesmo pode ser utilizado para o controle de um braço robótico ou prótese.

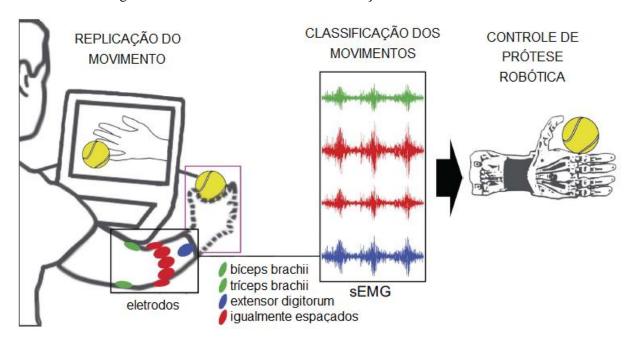


Figura 13 – Procedimento adotado na formação das bases 2 e 3 NinaPro.

Adaptado de (ATZORI et al., 2014).

Para maiores informações acerca do Projeto NinaPro e das referidas bases de dados, sugere-se a leitura dos artigos:

- ATZORI, M. et al. Building the Ninapro database: A resource for the biorobotics community. Proceedings of the IEEE RAS and EMBS International Conference on Biomedical Robotics and Biomechatronics, p. 1258–1265, 2012;
- ATZORI, M. *et al.* Characterization of a Benchmark Database for Myoelectric Movement Classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 23, n. 1, p. 73–83, jan. 2015
- ATZORI, M. et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. **Scientific Data**, 2014;

ATZORI, M. et al. Effect of clinical parameters on the control of myoelectric robotic prosthetic hands. **Journal of Rehabilitation Research and Development**, v. 53, n. 3, p. 345–358, 2016.

4.1.2 Base de Dados do IEE

Visando a criação e disponibilização de uma base de dados de eletromiografia gerada sob condições não ideais, está em andamento o desenvolvimento de um novo repositório de sinais de sEMG adquiridos no laboratório do IEE. O conjunto de movimentos do segmento mão-braço considerados neste recente projeto são os mesmos 17 do Exercício B das bases 2 e 3 NinaPro (Figura 11 e Figura 12) e da primeira versão da base do IEE (CENE *et al.*, 2019).

De acordo com a pesquisa realizada na elaboração desta tese, descrita no Capítulo 3 e detalhada no artigo de revisão (TOSIN; MACHADO; BALBINOT, 2022), todos os trabalhos associados com o tratamento de contaminantes em eletromiografia (alcançados pela referida busca) utilizaram sinais de sEMG contaminados artificialmente para validar seus modelos. Embora esse procedimento seja aceitável na literatura e amplamente utilizado, pode ser um problema quando aplicado a sistemas de classificação de movimento, pois pode não representar fidedignamente a forma como é apresentado na prática durante o uso do dispositivo. Diante desta necessidade de se emular situações reais do uso diário de uma prótese mio-controlada a fim de se verificar potenciais fatores de contaminação e, principalmente, a forma que eles se manifestam no sinal de sEMG, surgiu a ideia da criação desta base de dados.

Deste modo, o novo protocolo de aquisições compreende 4 tipos de experimentos, dos quais 3 simulam potenciais fatores de interferência. O restante foi realizado sob condições ideais. A seguir, estão descritos os agentes causadores de contaminação e a forma como eles foram inseridos no protocolo dos ensaios.

Artefato de movimento: Como já mencionado na seção 3.2, este contaminante pode ocorrer sob 2 circunstâncias: devido ao movimento do cabeamento dos eletrodos e em razão da interface entre o eletrodo e a pele. Aqui emulou-se a segunda situação, ou seja, induziu-se a movimentação do músculo em relação à pele através de impacto mecânico, que é algo na qual a prótese estará constantemente sujeita quando em uso. Assim, o procedimento seguido contou com aquisições realizadas simulando-se deslocamento do eletrodo em relação ao músculo. Para tanto, aplicou-se uma sequência de toques sobre o eletrodo em questão, com intervalos de 1 segundo, enquanto o voluntário executava a série de 17 movimentos. Durante o ensaio, apenas os 4 canais de medição localizados na região ventral de grupos musculares específicos (#9 ao #12 —

Figura 16) foram submetidos à ação contaminante. Deste modo, cada um deles foi alvo de artefato de movimento durante ¼ do ensaio seguindo uma ordenação sorteada antes do início da sessão:

- Eletrodo mal colado: Aqui reproduziu-se uma situação na qual o eletrodo está parcialmente em contato com a pele ou com uma fraca conexão. Numa aplicação prática da prótese, este evento poderia facilmente acontecer devido à presença de suor, sucessivas extensões e compressões da pele, dentre outros. O procedimento utilizado para a sua caracterização durante os ensaios foi a inserção de uma dupla camada de fita adesiva cobrindo uma área de aproximadamente 80% do gel condutor que faz o contato do eletrodo com a pele. Aqui todos os 12 canais de medição foram submetidos ao efeito contaminante;
- Cansaço muscular: Quando um grupo muscular é submetido a esforço excessivo ou prolongado, o sujeito percebe um cansaço que, em situações mais extremas, pode evoluir para um quadro de fadiga muscular. Este último consiste numa condição neuromuscular que resulta na redução da capacidade de produção de força (CIFREK; TONKOVIĆ; MEDVED, 2000). Esta condição pode causar alterações nas características elétricas e mecânicas do músculo como alterações na taxa de disparo dos potenciais de ação e no número das unidades motoras recrutadas, além da redução na força já mencionada (MAKARAM; KARTHICK; SWAMINATHAN, 2021). Aqui, apesar do impacto maior da fadiga nas características do sinal de sEMG, o protocolo consistiu na submissão dos voluntários a uma condição de cansaço muscular apenas, a fim de preservá-los fisicamente. Assim, os sujeitos foram orientados a realizar uma série de exercícios de musculação para cada um dos quatro grupos musculares mais predominantemente acessados durante os ensaios (bíceps, tríceps, flexor digitorum e extensor digitorum). A atividade foi realizada com halteres de 2 a 7kg. O peso foi determinado em função do tipo de exercício e da aptidão física do indivíduo. O treino do bíceps envolveu a flexão e extensão do antebraço contra a gravidade, com o cotovelo apoiado no braço de uma cadeira (durante todos os ensaios o voluntário permanecia sentado). Para o tríceps o exercício era similar (extensão e flexão do antebraço) só com a diferença do braço estar levantado com a mão acima da cabeça e o movimento ser no sentido de arremessar o halter para trás. Por fim, o treino do *flexor digitorum* e do *extensor* digitorum consistiu na flexão e extensão do pulso, respectivamente (reprodução dos movimentos 14 e 13 do protocolo padrão, nesta ordem). A atividade física era realizada até que o voluntário reportasse verbalmente que não conseguia mais prosseguir, ou seja,

era ele quem determinava o fim do exercício. Esse procedimento foi adaptado do utilizado em (MAKARAM; KARTHICK; SWAMINATHAN, 2021). Após o treino exaustivo dos quatro músculos supracitados era dado início à sessão de aquisição.

Por conseguinte, um total de 4 diferentes tipos de ensaios foram conduzidos em um total de 4 voluntários (atualmente). Em todos eles os 17 movimentos foram realizados de modo aleatorizado e com 3 repetições (51 gestos por ensaio).

- Ensaio A: realizado sob condições ideais;
- Ensaio B: realizado sob artefato de movimento induzido nos canais 9 a 12 de modo não simultâneo;
- Ensaio C: realizado com os eletrodos apresentando contato enfraquecido com a pele;
- **Ensaio D:** realizado sob condição de cansaço muscular.

Considerando que cada tipo de ensaio foi realizado 2 vezes pelos voluntários, ao todo cada um deles foi submetido a 8 sessões de aquisição de sEMG.

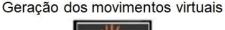
Antes do início do processo experimental, é apresentado e esclarecido a cada participante o Termo de Consentimento Livre e Esclarecido. No corpo do mesmo constam todos os detalhes do experimento a ser realizado, bem como a finalidade e os riscos ao qual o indivíduo estará sendo exposto em caso de consentimento à participação no estudo. Junto ao referido termo, o voluntário é submetido a uma anamnese e incentivado a preencher um formulário contendo informações relevantes para a pesquisa. O protocolo seguido no presente trabalho possui aprovação do Comitê de Ética da UFRGS.

O procedimento adotado na realização dos ensaios pode ser descrito, de forma resumida, pelas seguintes etapas. Primeiramente o movimento é apresentado em um monitor ao participante que, sentado confortavelmente em uma cadeira com encosto para os braços, replica-o após o término da execução do vídeo. Durante este processo, a atividade elétrica muscular do membro utilizado no exercício é medida por 12 pares de eletrodos, alocados no braço e antebraço do voluntário, e transmitida a 2 eletromiógrafos que fazem a filtragem e amplificação do sinal de sEMG. No estágio seguinte os dados são digitalizados e conduzidos a um computador onde são processados e armazenados através do software LabVIEW. A Figura 14 resume esta sequência de passos.

O estímulo visual fornecido aos participantes foi determinado a partir da criação de um modelo virtual da mão humana a qual foi utilizada para formação da animação correspondente a cada um dos 17 movimentos. Para este fim, foram utilizados os softwares MakeHuman 1.0.2

e o Blender 2.74. O desenvolvimento dos vídeos com a simulação de cada um dos gestos fez parte do desenvolvimento da tese de doutorado (MOURA, 2018).

Figura 14 – Procedimento adotado no processo de aquisição de sinal de sEMG.







Adaptado de (TOSIN, 2018).

O gerenciamento do andamento do processo de aquisição foi feito por intermédio do software LabVIEW. O mesmo é responsável por selecionar e reproduzir a animação correspondente ao gesto a ser executado pelo participante em uma determinada sequência (dependente do tipo de ensaio), além de mostrar em tempo real o sinal de sEMG medido e salválo em um arquivo de extensão *lvm*. Em vista disso, duas rotinas distintas foram produzidas em (TOSIN, 2018), uma para as sessões sequencias (Ensaios A e B) e outra para as aleatorizadas (Ensaios C e D). A Figura 15 mostra o fluxograma de ambas.

Os movimentos executados pelo voluntário possuem duração de aproximadamente 5 segundos alternados por períodos de repouso de cerca de 9 segundos. A atividade elétrica muscular é medida por 12 pares de eletrodos bipolares passivos constituídos de Ag/AgCl do fabricante Solidor. A localização destes no membro do sujeito seguem a determinação das Bases 2 e 3 NinaPro e está ilustrada na Figura 16. O sinal de sEMG medido pelos sensores é, então, filtrado e amplificado por dois eletromiógrafos de 8 canais (modelo EMG 830C, produzidos pela EMG System do Brasil) conectados em paralelo. Assim, 8 eletrodos são ligados a um deles e os demais no outro. Para o estágio de digitalização e transferência dos dados ao computador, utilizou-se uma placa da National Instruments NI USB-6289, a qual conta com 32 entradas analógicas e possibilita conversão A/D a uma taxa de até 625 mil amostras por segundo com resolução de 18 bits. Através desta configuração de hardware, a qual está ilustrada na Figura 17, realizou-se a aquisição de sinal de sEMG a uma frequência de 2k Hz.

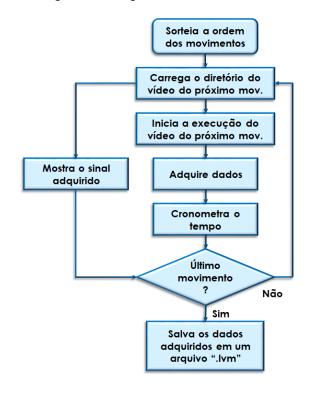
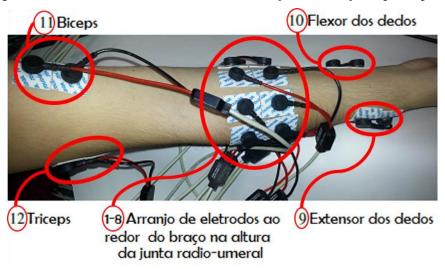


Figura 15 – Fluxograma dos algoritmos utilizado durante as aquisições.

Adaptado de (TOSIN, 2018).

Figura 16 – Posicionamento dos eletrodos no braço e antebraço do participante.



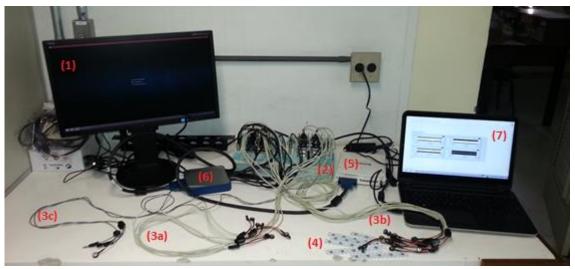
Adaptado de (CENE, 2016).

De modo a minimizar os efeitos indesejados provenientes da interface sensor-pele (ruído eletroquímico, artefato de movimento, dentre outros), principalmente para o Ensaio A, e proporcionar a aquisição de um sinal de maior qualidade, o processo de colagem dos eletrodos seguiu a normativa abaixo (FAVIEIRO, 2012; TOSIN, 2018):

raspagem dos pelos na região de fixação dos sensores;

- limpeza da pele na região de fixação dos eletrodos com a utilização de algodão ou equivalente umedecido com álcool;
- Fixação de dois eletrodos à testa do voluntário (referência dos eletromiógrafos);
- Fixação de um par de eletrodos a uma distância de 3 cm abaixo da linha que separa a face interna do cotovelo e o antebraço, seguindo da colagem de mais 7 pares de eletrodos equidistantes, dispostos ao longo da circunferência do antebraço;
- Fixação de um par de eletrodos na região ventral do músculo *extensor digitorum* do voluntário;
- Fixação, tanto próximo quanto possível, de um par de eletrodos na região ventral do músculo *extensor digitorum* do participante;
- Fixação de um par de eletrodos na região ventral do bíceps do voluntário;
- Fixação de um par de eletrodos na região ventral do tríceps do voluntário;
- conexão dos cabos dos eletromiógrafos aos sensores;
- cobertura de todos os eletrodos com bandagem de velcro a fim de garantir o correto posicionamento e aderência dos eletrodos ao longo do ensaio. Tal procedimento deve ser realizado de modo a não pressionar excessivamente o membro do voluntário, além de não obstruir a circulação sanguínea e evitar sensação de desconforto ao sujeito.

Figura 17 – Arranjo experimental utilizado nas aquisições na geração da Base de Dados do IEE: (1) corresponde ao monitor onde os movimentos eram mostrados, (2) eletromiógrafos, (3a-c) cabos do eletromiógrafo, (4) eletrodos de superfície, (5) placa de aquisição, (6) borneira, (7) computador.



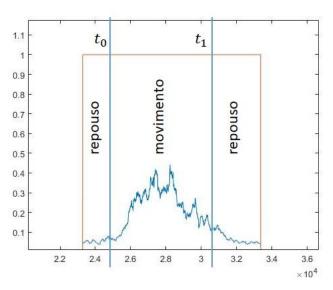
Adaptado de (CENE, 2016).

Após a obtenção dos sinais de sEMG, cada segmento destes precisa ser identificado com um dos movimentos ou repouso para seu posterior uso no treinamento de um modelo preditor. Todavia, imediatamente após a realização do procedimento de aquisição o que se possui são os

tempos de início e término de execução dos vídeos dos gestos mostrados aos voluntários. Contudo, essa informação por si só não é precisa para a caracterização dos períodos exatos em que cada atividade foi feita, tendo em vista que atrasos podem ocorrer devido ao tempo de reação dos participantes.

No entanto, para realizar tal correção na identificação das amostras do sinal, foi desenvolvido em (TOSIN, 2018) um algoritmo baseado na maximização da razão da verossimilhança generalizada (GLR – Generalized Likelihood Ratio) entre o modelo estatístico da atividade elétrica correspondente a repouso e a relacionada a movimento. Diante disso, o sinal de sEMG é, primeiramente, segmentado em janelas limitadas pelos tempos de execução das animações dos gestos. Na sequência, cada um destes segmentos é dividido em três partes (repouso, movimento e repouso), conforme mostra a Figura 18. A partir de então, é realizada a busca pelos instantes t_0 e t_1 que fazem o ajuste mais adequado para esta separação através da maximização da soma das probabilidades de cada amostra fazer parte de um modelo estatístico (determinado por máxima verossimilhança) que melhor representa as parcelas de repouso e movimento. O referido problema de otimização é definido pela Equação (8).

Figura 18 – Janela do sinal dividida em três partes. t_0 indica o tempo de início do movimento e t_1 o de término após a correção realizada pelo algoritmo.



Adaptado de (TOSIN, 2018).

$$\max_{t_0, t_1} \left[\sum_{i=1}^{t_0 - 1} \ln \left(f(y_i | w_0) \right) + \sum_{j=t_0}^{t_1 - 1} \ln \left(f(y_j | w_1) \right) + \sum_{k=t_1}^{T} \ln \left(f(y_k | w_0) \right) \right]$$
(8)

Na Equação (8), $f(y_i|w)$ é a probabilidade da amostra y_j fazer parte de uma distribuição cujos parâmetros estatísticos são dados por w que, por sua vez, são determinados por máxima

verossimilhança considerando-se que as três partes do sinal são caracterizados por uma distribuição Gaussiana.

Para maiores detalhes acerca do desenvolvimento do supracitado algoritmo, sugere-se a consulta à dissertação de mestrado (TOSIN, 2018).

4.2 DESCRIÇÃO DOS CONTAMINANTES CONSIDERADOS

No presente estudo considerou-se o efeito de 4 tipos de contaminantes: artefato de movimento, medição indesejada de sinal de ECG, interferência eletromagnética devido à linha de energia elétrica e ruído de linha de base, representado pela adição de ruído branco gaussiano. Para a criação da representação de tais fatores e acréscimo destes nos sinais de sEMG das bases de dados descritas na seção 4.1.1, utilizou-se o formato adotado no trabalho de doutorado do aluno Juliano Costa Machado (MACHADO, 2019). Assim, o SNR dos dados de eletromiografia estudados (provenientes das Bases NinaPro) foram calculados segundo o CEDE (*Consensus for Experimental Design in Electromyography*) (BESOMI *et al.*, 2019), que o define como a amplitude do sinal de EMG em relação ao ruído medido (MACHADO *et al.*, 2020). Tal procedimento foi adotado de modo a controlar o nível do SNR antes da realização da contaminação. Entretanto, uma vez que os sinais de sEMG constituintes das Bases NinaPro compreendem diversos níveis de contração e repouso e nenhuma informação acerca do CVM (Contração Voluntária Máxima) de cada voluntário, levou-se em conta a potência do período de repouso como medida de referência para a caracterização da potência do sinal de sEMG de cada canal/participante (MACHADO *et al.*, 2020). A mesma é determinada pela Equação (9):

$$P_r = \frac{1}{N} \cdot \sum_{i=1}^{N} x_i^2 \tag{9}$$

onde, P_r é a potência associada ao sinal medido durante o repouso, x_i corresponde a uma amostra do sinal de sEMG e N é o número total de amostras.

Ainda seguindo (MACHADO *et al.*, 2020), aplicou-se um filtro passa-faixa *Butterworth* de 4ª ordem com frequências de corte em 20 e 500 Hz, para a remoção dos ruídos intrínsecos do processo de aquisição dos dados e garantir um sinal íntegro antes da adição da interferência. Após esta etapa, os contaminantes foram inseridos conforme a metodologia a seguir:

Interferência por sinal de ECG

Os dados de eletrocardiografia foram obtidos do banco Physionet (GOLDBERGER *et al.*, 2000), o qual faz parte do *Research Resource for Complex Physiologic Signals*, que, por sua

vez, foi criado pelo Centro Nacional de Recursos de Pesquisa dos Institutos Nacionais de Saúde (*National Center for Research Resources of the National Institutes of Health*) com o objetivo de estimular a pesquisa atual e novas investigações no estudo de sinais cardiovasculares e outros sinais biomédicos complexos. Face ao exposto, segmentos de 10 segundos foram selecionados, aleatoriamente, dos dados de um canal de 17 voluntários. Estes sinais foram, então, submetidos a uma correção de resolução (*upsample*) por interpolação antes de serem adicionados ao sinal de sEMG, uma vez que a taxa de aquisição daquele é menor do que o deste último. Feito isso, o vetor resultante, formado por janelas de 10 segundos de sinal de ECG, é multiplicado por uma constante, de modo que a contaminação atinja o SNR desejado. Com isso, ele é então inserido no sinal de sEMG. Aqui, a potência dos dados de ECG é calculada segundo a Equação (9).

Artefato de movimento

O sinal que caracteriza o artefato de movimento foi obtido experimentalmente e faz parte da metodologia desenvolvida no trabalho de doutorado do aluno Juliano Costa Machado (MACHADO, 2019). O procedimento seguido contou com aquisições realizadas simulando-se deslocamento do eletrodo em relação ao músculo. Para tanto, considerou-se o mesmo arranjo de 12 pares de sensores dispostos nas mesmas localizações dos ensaios realizados na formação da base do IEE e os mesmos hardware e software para o condicionamento, processamento e armazenamento dos dados. O experimento foi conduzido em um voluntário de 37 anos, 80 kg, 1,83 m de altura e consistiu na medição do sinal de sEMG durante uma sequência de 10 toques com intervalos de 1 segundo nos eletrodos, de modo a induzir um deslocamento destes em relação à musculatura. Este procedimento foi realizado de forma individual para cada um dos canais. Um estágio de suavização, através da aplicação de um filtro média móvel com janela de 5,5 ms, foi ainda submetido aos dados. A contaminação se deu, então, pela adição de um vetor constituído por segmentos aleatoriamente selecionados do artefato de movimento gerado de um par de eletrodos específico, ao sinal de sEMG íntegro. A potência dos dados de interferência foi determinada de acordo com a Equação (9) e então multiplicou-se por um fator de modo a atingir o SNR desejado.

Interferência eletromagnética pela linha de energia elétrica

Um sinal senoidal com frequência de 50 Hz e fase determinada de forma randômica, foi inserido nos dados não contaminados de sEMG. A potência da contaminação, neste caso, obteve-se pela Equação (10):

$$P_{le} = \frac{A^2}{2} \tag{10}$$

onde, P_{le} é a potência do sinal de interferência da linha de energia elétrica e A é a amplitude da senoide, sendo determinada de acordo com o SNR requerido para a contaminação.

Ruído branco gaussiano

Caracterizou-se por um vetor de valores aleatórios obtido de uma distribuição normal com média zero e cuja variância foi ajustada em função do SNR desejado. A soma dos referidos valores ao sinal de sEMG íntegro efetivou a contaminação.

A Figura 19 mostra um segmento de 2,5 segundos de sinal de sEMG do canal 1 do primeiro voluntário da Base 02 NinaPro, contaminado com cada uma das 4 fontes de interferência descritas anteriormente.

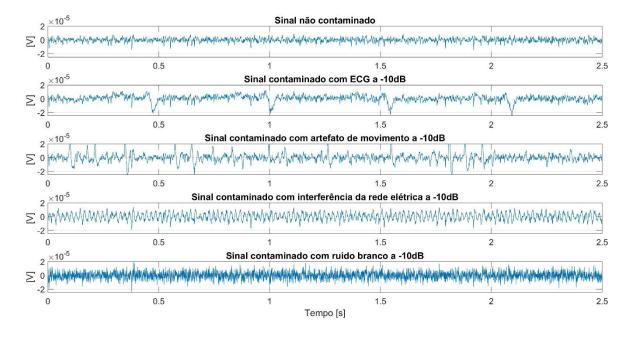


Figura 19 – Efeito da contaminação com SNR de -10 dB.

4.3 EXTRAÇÃO DE CARACTERÍSTICAS PARA O TREINO DO FIS-ACRL

Apesar dos diferentes fatores de contaminação produzirem efeitos distintos no sinal de sEMG, os quais são visíveis na Figura 19, ainda assim é difícil de se obter um classificador que os identifique a partir da análise dos dados não processados. Deste modo, objetivando aumentar a discriminação entre eles, extraiu-se 6 características nos domínios do tempo e da frequência, em janelas de 300 ms, sem sobreposição entre elas. São elas: Relação Sinal-Artefato de Movimento (SMR), Queda do Valor Máximo para o Mínimo da Densidade Espectral de

Potência (DP), Relação Sinal-Ruído de alta frequência (SNRatio), Deformação na Densidade Espectral de Potência (DEF), Relação Sinal-Linha de Energia (SPR) e Relação Sinal sEMG-ECG (SER). Estas características foram propostas em (MCCOOL *et al.*, 2014; SINDERBY; LINDSTROM; GRASSINO, 1995) e são amplamente utilizadas na literatura para identificação de contaminantes (CHANG; PHINYOMARK; SCHEME, 2020; MCCOOL *et al.*, 2014). Destas, a SMR, SER, SPR e SNRatio foram desenvolvidas especificamente para realçar as contaminações consideradas nesta tese (artefato de movimento, ECG, rede de energia e ruído branco gaussiano, respectivamente), o que justifica suas escolhas. As duas restantes (DP e DEF) trazem informações relevantes acerca da Densidade Espectral de Potência do sinal, sendo, portanto, selecionadas para acrescentar poder discriminativo do algoritmo.

Relação Sinal-Artefato de Movimento (SMR)

Como o nome já sugere, esta característica visa potencializar a distinção do contaminante artefato de movimento em relação aos demais, valendo-se do impacto desta na região de baixas frequências do espectro do sinal. Proposta em (SINDERBY; LINDSTROM; GRASSINO, 1995), a mesma fundamenta-se em duas considerações: a primeira de que o artefato de movimento está compreendido tipicamente na faixa de 0-20 Hz, e a segunda refere-se ao fato da DEP de um sinal não corrompido de sEMG possuir formato próximo do linear nesta região do espectro de frequências.

Levando-se isso em conta, tal característica é definida como a soma de todos os componentes da DEP do sinal dividido pelo somatório das densidades de potência das frequências menores de 20 Hz que ultrapassam uma linha reta que une a origem até o ponto da densidade de potência média mais alta (representada pela área em verde na Figura 20). Aqui, a localização do ponto máximo da reta mencionada anteriormente (ponto vermelho na Figura 20) é dada pelo maior valor médio da densidade de potência calculado sobre 13 amostras consecutivas, movendo-se da frequência de 35 Hz até o final do espectro.

Neste contexto, o cálculo da SMR, em decibéis (dB), pode ser executado através da Equação (11):

$$SMR = 10 \cdot \log_{10} \left(\frac{\sum_{i=0}^{i_{m\acute{a}x}} F_i}{\sum_{i=0}^{i_{f=20}} max(0, (F_i - L_i))} \right)$$
 (11)

onde, i é o índice pelo qual a densidade espectral de potência é somada, $i_{m\acute{a}x}$ é o índice correspondente à máxima frequência do espectro, $i_{f=20}$ é o índice relacionado com a frequência

de 20 Hz, F_i é a i-ésima componente da densidade espectral de potência e L_i é o ponto associado à frequência f_i sobre a reta verde tracejada da Figura 20.



Figura 20 – Representação da área considerada do DEP para o cálculo da Razão Sinal-Artefato de Movimento.

Queda do Valor Máximo para o Mínimo da Densidade Espectral de Potência (DP)

Corresponde à razão entre a maior e a menor densidade de potência média calculada sobre 13 amostras consecutivas da DEP, movendo-se da frequência de 35 Hz até o final do espectro (SINDERBY; LINDSTROM; GRASSINO, 1995). O mesmo pode ser determinado pela Equação (12):

$$DP = 10 \cdot \log_{10} \left(\frac{DPM_{m\acute{a}x}}{DPM_{m\acute{a}n}} \right) \tag{12}$$

onde, $DPM_{m\acute{a}x}$ e $DPM_{m\acute{i}n}$ são as densidades de potência média máxima e mínima, respectivamente.

Relação Sinal-Ruído de Alta Frequência (SNRatio)

Neste contexto, ruído consiste em qualquer sinal de origem não definida e que pode ser detectada na região de altas frequências do espectro de potência (SINDERBY; LINDSTROM; GRASSINO, 1995). Esta característica também é resultado do trabalho de Sinderby e colaboradores (1995), e parte da premissa de que o ruído (conforme determinação acima) possui densidade de potência constante ao longo da região de interesse do espectro do sinal e de que

não há atividade nas frequências compreendidas nos 20% superiores do espectro. Assim, a potência dos últimos 20% da faixa de frequências é determinada (área verde da Figura 21) e, então, somada ao longo de todo o espectro (região vermelha da Figura 21) de modo a obter-se uma estimativa para a potência total do ruído.

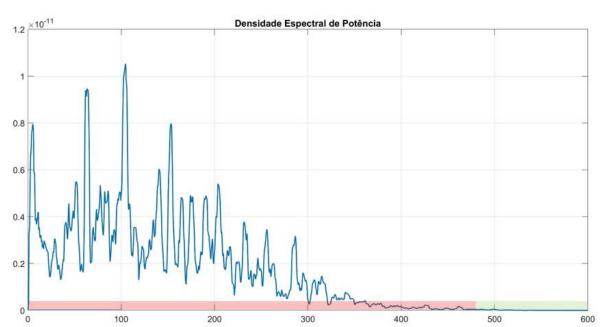


Figura 21 – Representação da área da DEP considerada no cálculo da característica Relação Sinal-Ruído.

Diante disso, a métrica SNRatio pode ser calculada pela razão entre a potência total do sinal dividido pelo valor estimado do ruído. A Equação (13) descreve tal medida em dB.

Frequência [Hz]

$$SNRatio = 10 \cdot \log_{10} \frac{\sum_{i=0}^{i_{m\acute{a}x}} F_i}{5 \cdot \sum_{i=0,8 \cdot i_{m\acute{a}x}}^{i_{m\acute{a}x}} F_i}$$
 (13)

Deformação na Densidade Espectral de Potência (DEF)

Da mesma forma que as anteriores, esta característica também teve origem no estudo de Sinderby e colegas (1995). Ela corresponde ao índice da deformação da DEP, sendo determinada a partir do conceito de momento espectral. O enésimo momento é dado pela Equação (14).

$$M_n = \sum_{i=0}^{i_{m\acute{a}x}} F_i \cdot f_i^{\ n} \tag{14}$$

A partir da definição de momento, a DEF pode ser calculada, em dB, através da Equação (15).

$$DEF = 10 \cdot \log_{10} \frac{\sqrt{M_2/M_0}}{M_1/M_0} \tag{15}$$

Esta característica é sensível a variações na simetria e no valor de pico da densidade espectral de potência, sendo eficaz também na detecção de distúrbios nas regiões de baixa e altas frequências (SINDERBY; LINDSTROM; GRASSINO, 1995).

Relação Sinal-Linha de Energia (SPR)

Desenvolvida em (MCCOOL *et al.*, 2014), a Relação Sinal-Linha de Energia é determinada pela razão entre as potências do sinal de sEMG e a associada com o ruído proveniente da interferência eletromagnética da rede elétrica. Para isso, primeiramente, a amplitude, a fase e a frequência do contaminante são estimadas através do algoritmo proposto em (FRASER *et al.*, 2011). O mesmo consiste em um método iterativo de descida mais íngreme do gradiente do erro médio quadrático entre os sinais da interferência e o de sEMG corrompido pelo ruído. O referido desvio é representado pela Equação (16):

$$E_k = \frac{1}{N} \cdot \sum_{n=0}^{N-1} (x[n] + m[n] - \widehat{m}_k[n])$$
 (16)

onde, x[n] + m[n] corresponde ao sinal de sEMG contaminado, sendo x[n] os dados de eletromiografia íntegros e m[n] o contaminante, k está associado ao número da iteração, N é a quantidade total de amostras e $\widehat{m}_k[n]$ é o valor estimado para a senoide que constitui a interferência da rede elétrica na iteração k, o qual é dado pela Equação (17):

$$\widehat{m}[n] = \widehat{a}\cos(\widehat{\omega} \cdot n) + \widehat{b}\sin(\widehat{\omega} \cdot n) \tag{17}$$

onde, \hat{a} e \hat{b} são as amplitudes das componentes em fase e em quadratura do contaminante senoidal e $\hat{\omega}$ a frequência.

A fundamentação para esta metodologia está na assunção de que o sinal de sEMG (x[n]) é descorrelacionado com o ruído (m[n]) (FRASER *et al.*, 2011). Assim, a minimização da Equação (16) é equivalente à obtenção do mínimo erro quadrático médio entre m[n] e $\widehat{m}_k[n]$. Com isso, $\widehat{m}_k[n]$ convergirá para uma estimativa do sinal da interferência e, consequentemente, E resultará em uma aproximação para o sinal íntegro de sEMG.

A busca pelo menor valor para E_k na Equação (16) é realizada em função da frequência $\widehat{\omega}$, iterativamente. A cada passo do algoritmo, o valor desta é atualizada proporcionalmente ao gradiente de E multiplicado por um fator de aprendizado (μ), conforme mostra a Equação (18):

$$\widehat{\omega}_{k+1} = \widehat{\omega}_k - 0.5 \cdot \mu \cdot \frac{\partial E_k}{\partial \widehat{\omega}_k} \tag{18}$$

Após a obtenção da estimativa para o sinal de interferência ($\widehat{m}[n]$), subtrai-se o mesmo dos dados de eletromiografia contaminados resultando em uma aproximação para o sinal de sEMG íntegro (x[n]). Deste modo, a característica SPR pode ser calculada pela Equação (19):

$$SPR = 10 \cdot \log_{10} \frac{P_{SEMG}}{P_{le}} \tag{19}$$

onde, P_{SEMG} é a potência do sinal de sEMG após a remoção do contaminante (x[n]) e P_{le} é a potência do sinal estimado para a interferência da rede elétrica $(\hat{m}[n])$, a qual é dada, por sua vez, pela Equação (20):

$$P_{le} = \frac{A^2}{2} \tag{20}$$

onde A é a amplitude da senoide caracterizadora da interferência e vale $\sqrt{\hat{a}^2 + \hat{b}^2}$.

Para mais detalhes acerca da implementação da metodologia apresentada acima, sugerese a leitura do trabalho de Fraser e colaboradores (2011).

Relação Sinal de EMG-ECG (SER)

Esta característica foi primeiramente apresentada em (MCCOOL *et al.*, 2014) objetivando realçar a presença de registros de eletrocardiografia em aquisições de eletromiografia, de modo a facilitar sua identificação. Ela consiste na razão entre a potência dos sinais de sEMG e o de ECG responsável pela contaminação. Para a sua contabilização, inicialmente a interferência é estimada através da aplicação de um filtro média-móvel com janela de 20 ms nos dados corrompidos de eletromiografia. Na sequência, o sinal resultante é subtraído do de sEMG a fim de obter-se uma estimativa dos dados íntegros da atividade elétrica muscular. Por fim, o SER pode, então, ser calculado pela Equação (21):

$$SER = 10 \cdot \log_{10} \frac{P_{SEMG}}{P_{ECG}} \tag{21}$$

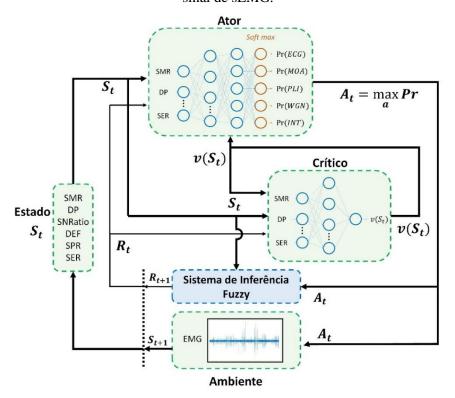
onde, P_{SEMG} e P_{ECG} são as potências dos sinais estimados de sEMG (descontaminado) e de ECG, respectivamente.

4.4 ALGORITMO DO IDENTIFICADOR DE CONTAMINANTES POR APRENDIZADO POR REFORÇO

Como já destacado na Seção 2.3, utilizou-se o método Ator-Crítico para o desenvolvimento do algoritmo identificador de contaminantes através do conceito de aprendizado por reforço. Diante disso, o sistema proposto possui 7 elementos principais: o ambiente, os estados que o caracterizam, o agente, as ações, a função de recompensa, o modelo do ator (política de ações) e do crítico (função valor de estado).

A Figura 22 ilustra o esquemático do sistema de RL adaptado para o problema de identificação de contaminantes. Nela, Pr(ECG), Pr(MOA), Pr(PLI), Pr(WGN) e Pr(INT) indicam a probabilidade do agente selecionar a ação de aplicação do procedimento de minimização do efeito da contaminação por ECG, artefato de movimento, interferência da rede elétrica, ruído branco gaussiano e sinal íntegro¹, nesta ordem, e v(S) consiste na função valor de estado.

Figura 22 – Implementação do método Ator-Crítico aplicado a identificação de contaminantes em sinal de sEMG.



No contexto deste trabalho, o ambiente consiste na atividade elétrica muscular e o agente o controlador que fará a identificação do tipo do contaminante e tomará a ação mais adequada.

¹ Neste texto, serão utilizados os termos sinal íntegro ou "limpo" para caracterizar registros de sEMG não contaminados, como uma tradução da versão em inglês "clean signal" amplamente utilizado e aceito na literatura.

Por conseguinte, os estados são representados pelo conjunto de características apresentadas na Seção 4.3, sendo formados, portanto, por um vetor de 6 valores contínuos. Já as ações correspondem a aplicação de filtros e metodologias para a minimização do efeito dos 4 contaminantes considerados neste estudo (ECG, artefato de movimento, interferência da rede elétrica e ruído branco gaussiano) ou de nenhum deles no caso do sinal não apresentar interferências. Para isso, foi considerado um procedimento específico para cada um dos agentes corruptores. Logo, as ações constituem um grupo discreto de 5 elementos (um para cada classe – os 4 contaminantes mais sinal íntegro). O algoritmo, portanto, classifica se há a presença de contaminantes (identificação de sinal "limpo") e, em caso afirmativo, o tipo da contaminação.

Levando-se em conta a não-linearidade da tarefa e da natureza estocástica dos registros de eletromiografía, optou-se pela adoção de modelos baseados em rede neural tanto para o ator como para o crítico. Ambos recebem na entrada a informação do estado (S_t) e fornecem na saída as probabilidades das ações (ator) e o valor do estado (crítico). Assim, a cada passo de tempo (t), o ator calcula as probabilidades das ações, executando aquela associado ao maior percentual (A_t) , e o crítico determina o valor do estado atual $(v(S_t))$. Em seguida, uma recompensa (R_{t+1}) é atribuída ao agente, com base na ação realizada e no estado atual, por meio de um Sistema de Inferência Fuzzy (SIF) (ilustrado na Figura 23). Na sequência, o ambiente passa para o próximo estado (S_{t+1}) , ou seja, uma nova janela de sEMG. Os parâmetros das redes neurais do ator e do crítico são ajustados iterativamente, visando a máxima recompensa total a longo prazo.

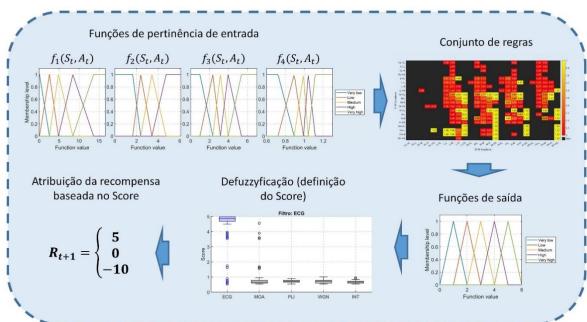


Figura 23 – Atribuição de recompensa baseada em SIF.

4.4.1 Determinação das Ações

Para a minimização dos efeitos da interferência por eletrocardiografia e da rede elétrica, utilizou-se as metodologias apresentadas na Seção 4.3 para a obtenção das características Razão Sinal de EMG-ECG e Relação Sinal-Linha de Energia, respectivamente. Como em ambas situações o procedimento inclui a estimativa para os respectivos sinais de contaminação e a consequente obtenção de uma aproximação para os dados de eletromiografia íntegros (através da subtração daqueles no sinal contaminado), considerou-se estes algoritmos para a minimização do efeito de tais agentes corruptores, constituindo 2 das ações do sistema de RL.

Por outro lado, visando a redução do impacto de artefato de movimento, seguiu-se as ponderações apresentadas em (DE LUCA *et al.*, 2010), já citadas na Seção 3.2. Logo, determinou-se a aplicação de um filtro passa-alta *Butterworth* de 4ª ordem com frequência de corte alocada em 20 Hz.

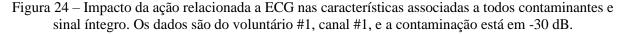
Por fim, para a minimização do ruído branco gaussiano, optou-se pela implementação de um filtro passa-baixa *Butterworth* de 4ª ordem na frequência de 500 Hz. Esta escolha se justifica na característica da influência desta interferência no espectro do sinal. Sabendo-se que ela se apresenta de forma uniforme ao longo da faixa de frequências e que, praticamente, não há atividade muscular a partir de 500 Hz, a aplicação do referido filtro atenua boa parte do ruído sem afetar de modo significativo a banda do sinal de sEMG.

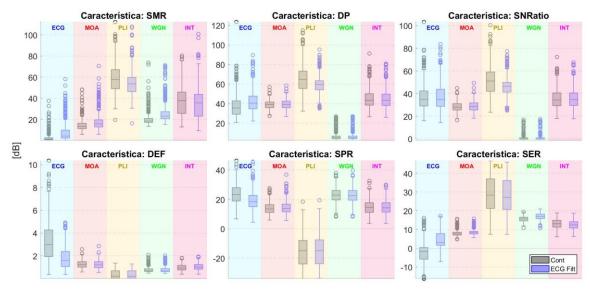
4.4.2 Definição da Função de Atribuição de Recompensa

Esta seção detalha a definição da função de recompensa quando o agente executa a ação de ECG, visando apresentar o procedimento adotado para o seu projeto. As funções de recompensa relacionadas aos demais contaminantes seguem os mesmos princípios do ECG e serão apresentadas apenas em sua forma final.

A atribuição de recompensa é um ponto crítico para o aprendizado do sistema. É de vital importância que o agente perceba um incentivo positivo para cada ação correta (aplicação do filtro/procedimento adequado para atenuar o contaminante que se apresenta no sinal de sEMG) e negativo caso contrário. Face ao exposto, a tarefa consiste em encontrar um padrão nas características que evidencie a escolha certa. No entanto, para determinar uma estratégia para atribuir uma recompensa correta a uma escolha do agente, é importante conhecer o impacto de cada ação e cada contaminante nas características do sinal de sEMG. A Figura 24 mostra o impacto da ação relacionada a ECG nas características extraídas do sinal contaminado com cada fator considerado (ECG, MOA, PLI e WGN) e também do sinal íntegro (INT). Na figura, os

boxplots cinza são as características extraídas dos sinais contaminados e "limpos" (identificados pelas cores de fundo), e os azuis são as características extraídas após a aplicação do filtro de ECG.





De acordo com a Figura 24, nenhuma característica separa completamente o contaminante de ECG, pois os gráficos de caixa associados ao referido contaminante se sobrepõe a pelo menos um outro contaminante. Por conseguinte, um algoritmo baseado em lógica não-booleana tende a ser mais adequado para esta tarefa. Nesse contexto, a estratégia adotada foi a lógica fuzzy, devido à sua capacidade de discretizar cada entrada considerada em diferentes funções de pertinência. Além disso, essa técnica já teve sua eficácia verificada ao lidar com dados sEMG, apresentando resultados interessantes em trabalhos anteriores (BOZHENYUK; BOZHENIUK; KHAMIDULINA, 2015; TAGELDEEN; ELAMVAZUTHI; PERUMAL, 2016). Partindo dessa premissa, projetou-se um Sistema de Inferência Fuzzy (SIF) do tipo Mandani para determinar uma pontuação (*score*) para as ações executadas pelo agente. Em seguida, esta pontuação (definida no intervalo [0, 6]) é utilizada para decidir a recompensa que o agente deve perceber (5, 0 ou -10) (Figura 23).

Ainda considerando a Figura 24, observa-se que a característica SER do contaminante ECG teve um aumento considerável após a filtragem (mais significativa do que para as outras classes). Além disso, as métricas SMR, SNRatio e SPR apresentam valores menores para ECG, WGN e PLI, respectivamente. Portanto, estes quatro recursos foram selecionados para comporem as funções de entrada da SIF, conforme definido pelas equações (22)-(25), onde os subscritos "cont" e "filt" indicam que o recurso é do sinal contaminado e filtrado, nesta ordem.

Assim, SMR e SER irão discriminar o contaminante de ECG, enquanto que SPR e SNRatio irão rejeitar as interferências da linha de energia e Ruído Branco Gaussiano, respectivamente.

$$f_{1ECG} = \frac{1}{SMR_{cont}} \tag{22}$$

$$f_{2ECG} = \frac{1}{SNRatio_{filt}} \tag{23}$$

$$f_{3ECG} = \frac{1}{SPR_{filt}} \tag{24}$$

$$f_{4ECG} = \frac{SER_{filt}}{SER_{cont}} \tag{25}$$

Em seguida, cada entrada é dividida em até cinco regiões de acordo com a condição do boxplot do contaminante alvo em relação aos demais. O alvo aqui são os contaminantes discriminados ou rejeitados nas equações (22)-(25). Os limites de cada região e o número de funções de pertinência associados a cada uma das entradas (descritas para o contaminante ECG na Tabela 4) são determinados com base na condição supracitada a qual é definida através do fluxograma da Figura 25.

Tabela 4 – Definição de funções de pertinência de entrada. Na tabela, HOC é o limite superior mais alto do boxplot dos outros contaminantes (não o alvo), LTC é o limite inferior do boxplot alvo, 1QTC é o primeiro quartil da distribuição alvo, 3QTC é o terceiro quartil mais alto dentre os outros contaminantes e FP é Função de Pertinência.

Condição	# regiões	Limites	#FP	Código linguístico		
#1	3	$L_1 = HOC$ $L_2 = LTC$	2 trapezoidais 1 triangular	"Muito baixo", "Alto", "Muito alto"		
#2	4	$L_1 = LTC$ $L_2 = 3QOC$ $L_3 = HOC$	2 trapezoidais 2 triangulares	"Muito baixo", "Baixo", "Alto", "Muito alto"		
#3	3	$\begin{aligned} L_1 &= LTC \\ L_2 &= HOC \end{aligned}$	2 trapezoidais 1 triangular	"Muito baixo", "Alto", "Muito alto"		
#4	4	$\begin{aligned} L_1 &= LTC \\ L_2 &= 1QTC \\ L_3 &= HOC \end{aligned}$	2 trapezoidais 2 triangulares	"Muito baixo", "Baixo", "Alto", "Muito alto"		
#5 5		$L_1 = LTC$ $L_2 = 1QTC$ $L_3 = 3QOC$ $L_4 = HOC$	2 trapezoidais 3 triangulares	"Muito baixo", "Baixo", "Alto", "Médio", "Muito alto"		

Foi considerado Função de Pertinência (FP) trapezoidal para as funções extremas ("Muito baixo" e "Muito alto") e triangular para as demais, visando a atribuição de uma probabilidade máxima de pertinência no meio de cada região e nas extremidades. Assim, o valor de pico de cada FP triangular é definido como o ponto médio de dois limites subsequentes e os pontos de base coincidentes com o pico de funções adjacentes, de modo a garantir que a soma de todas

elas seja sempre 1. O ponto inicial da região plana das FP's trapezoidais é definido para assegurar que os limites extremos (L_1 e L_n , onde n é o número de regiões menos um) fiquem no ponto médio entre ele e o pico da próxima função triangular. A Figura 26 mostra a discretização fuzzy das funções de entrada f_{1ECG} a f_{4ECG} sobreposta com o boxplot de cada contaminante. A caixa vermelha está associada a um alvo de contaminante rejeitado e a verde a um alvo discriminado (ECG neste caso).

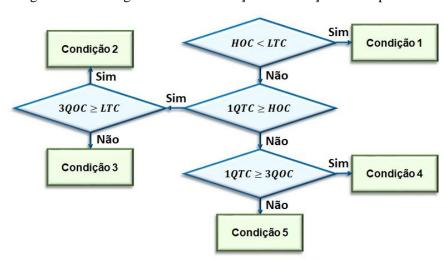
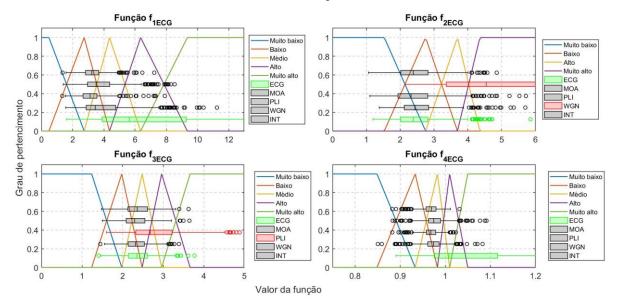


Figura 25 – Fluxograma da determinação da condição do boxplot alvo.

Figura 26 – Funções de entrada e suas respectivas funções de pertinência. Os dados são do voluntário #1, canal #1, com contaminação em -20, -10 e 0 dB.



As regras do SIF são baseadas no operador lógico "E". Primeiramente, foi avaliada a força de cada combinação possível das entradas para reconhecer o contaminante correto. No caso do ECG, existem 500 combinações de entrada (3 entradas com 5 FP e uma com 4). Assim, foi computado o percentual de ocorrência do contaminante correto associado a cada

combinação de entradas. Os resultados relacionados ao contaminante de ECG são mostrados no mapa de calor da Figura 23, onde o eixo y lista as combinações de código linguístico de f_{1ECG} e f_{2ECG} , o eixo x está associado às combinações f_{3ECG} e f_{4ECG} , a cor amarela indica a ocorrência máxima do contaminante correto (100% das amostras), vermelho indica ocorrência mínima (0%) e preto indica ausência de qualquer tipo de contaminante. Não foram consideradas as combinações relacionadas à última condição na definição das regras.

Em seguida, foram definidas cinco diferentes saídas possíveis com base nos valores percentuais do mapa de calor, conforme Tabela 5. Assim, para cada combinação de entrada que possui pelo menos uma amostra de treinamento associada, existe um código linguístico de saída associado. Por exemplo, se a combinação de entrada "Médio", "Baixo", "Baixo" e "Alto" (f_{1ECG} a f_{4ECG}) tiver 70% das amostras de treinamento associadas ao contaminante correto (ECG neste caso), configurará a regra definida na Equação (26).

se
$$(f_{1ECG} = M) \& (f_{2ECG} = B) \& (f_{3ECG} = B) \& (f_{4ECG} = A)$$
, então $Saida = A$ (26)

As funções de pertinência da saída da SIF foram formadas por funções triangulares com pico localizado conforme indicado na Tabela 5 e mostrado na Figura 23. A defuzzificação foi realizada pelo método SoM (*Smallest of Maximum*) que apresentou melhores resultados em testes preliminares. O resultado da etapa de defuzzificação representa o score, que está ilustrado na Figura 23 para a ação do ECG. Observa-se um valor de pontuação predominantemente maior para o contaminante do ECG (boxplot azul) do que para os demais (boxplots cinza), indicando a correta aplicação do filtro.

Tabela 5 – Definição das funções de pertinência da saída da SIF. O termo "PCE" se refere ao percentual de amostras do contaminante correto da respectiva combinação de entrada.

PCE [%]	Saída	Localização do pico da FP
0 ~ 20	"Muito baixo"	1
20 ~ 40	"Baixo"	2
40 ~ 60	"Médio"	3
60 ~ 80	"Alto"	4
80 ~ 100	"Muito alto"	5

Na última etapa, o score é convertido em um valor de recompensa de acordo com a Equação (27), onde o limite superior (*SupLim*) e o inferior (*InfLim*) são definidos através do Algoritmo 1.

$$R_{t+1} = \begin{cases} +5, & para: Score \ge SupLim \\ 0, & para: SupLim > Score \ge InfLim \\ -10, & para: Score < InfLim \end{cases} \tag{27}$$

Algoritmo 1 – Pseudocódigo do algoritmo de determinação dos limites da função de Recompensa.

1:	\mathbf{se} : $LTC > HOC$	
2:	SupLim = LTC	
3:	InfLim = LTC	
4:	senão:	
5:	se: $LTC > 3QOC$	
6:	SupLim = min(HOC, 1QTC)	C)
7:	InfLim = LTC	
8:	senão. se: $HOC > 1QTC$	
9:	se : 3 <i>QOC</i> > 1 <i>QTC</i>	
10:	SupLim = 3QOC	
11:	InfLim = 1QTC	
12:	senão:	
13:	SupLim = 1QTC	
14:	InfLim = 3QOC	
15:	senão:	
16:	SupLim = HOC	
17:	InfLim = 3QOC	
18:	fim	

Foi adotado o mesmo procedimento para o projeto do SIF das ações relacionadas aos contaminantes MOA, PLI e WGN e à classe sinal íntegro (INT). A única diferença são as funções de entrada, que são definidas nas equações (28) a (37). Ressalta-se que para o contaminante WGN, apenas duas funções de entrada foram necessárias.

$$f_{1MOA} = SMR_{filt} - SMR_{cont} (28)$$

$$f_{2MOA} = f_{2PLI} = \frac{1}{SNRatio_{filt}}$$
 (29)

$$f_{3MOA} = \frac{1}{SPR_{filt}} \tag{30}$$

$$f_{4MOA} = abs(SER_{filt} - SER_{cont})$$
 (31)

$$f_{1PLI} = SMR_{cont} (32)$$

$$f_{3PLI} = f_{2WGN} = f_{3INT} = \frac{1}{SPR_{cont}}$$

$$\tag{33}$$

$$f_{4PLI} = SER_{cont} \tag{34}$$

$$f_{1WGN} = f_{2INT} = \frac{1}{SNRatio_{cont}}$$
 (35)

$$f_{1INT} = \frac{1}{SMR_{cont}} \tag{36}$$

$$f_{4INT} = \frac{1}{SER_{cont}} \tag{37}$$

4.4.3 Definição do Modelo e Parâmetros da Rede Neural do Ator e do Crítico

A estrutura do modelo das redes neurais implementadas tanto para o ator como para o crítico estão expostas na Figura 22. Para ambos se considerou uma camada inicial com 6 neurônios (visto que a entrada são os estados, representados por 6 características extraídas do sinal de sEMG) e uma camada oculta com 8 neurônios. Já a saída é constituída por 1 e 5 neurônios para a função de estado e política de ações, respectivamente, uma vez que a primeira computa uma estimativa do retorno esperado para o estado atual e a segunda é responsável pela atribuição de probabilidades para a execução de cada um dos 5 possíveis movimentos do agente. Diante disso, a rede neural do ator conta ainda com uma camada *soft max* na saída (representada em vermelho na Figura 22), a qual calcula as probabilidades associadas a cada uma das ações. A mesma é dada pela função descrita pela Equação (38):

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_i e^{z_i}} \tag{38}$$

onde, z_i corresponde ao valor da saída do neurônio i da última camada da rede.

O treinamento da rede se deu pelo método do gradiente (com otimizador adam), conforme o fluxograma ilustrado na Figura 4 (Capítulo 2.3). Contudo, aqui os parâmetros a serem aprendidos da política de ações e da função valor de estado são os pesos e bias das respectivas redes neurais. O fator de aprendizado (α) das Equações (δ) e (7) e o coeficiente de desconto (γ) da Equação (39) foram ajustados em 0,5 e 0,99, nesta ordem, tanto para o ator quanto para o crítico. Para o cômputo do erro de diferença temporal (δ), considerou-se a estimação do valor de estado a 10 etapas adiante (k_{max}), ou seja, o mesmo é calculado a partir da Equação (39):

$$\delta_t = R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots + \gamma^9 R_{t+10} + \gamma^{10} v(S_{t+10}) - v(S_t)$$
 (39)

Os valores de α , γ e k_{max} , o número de neurônios ocultos do ator e do crítico e o comprimento da janela para extração de características foram definidos em experimentos preliminares por meio de uma metodologia de busca em grade. O algoritmo foi testado com os valores $[0,005,0,01\,0,05,0,1\,0,5\,\mathrm{e}\,1]$ para α , $[0,7,0,8,0,9,0,95,0,97\,\mathrm{e}\,0,99]$ para γ , $[5,10,50\,\mathrm{e}\,100]$ para k_{max} , $[2,4,8,16,32\,\mathrm{e}\,64]$ para os neurônios ocultos e $[100,200,300\,\mathrm{e}\,500\,\mathrm{ms}]$ para o comprimento da janela. Devido ao grande número de experimentos, estes foram conduzidos em um par voluntário/canal selecionado aleatoriamente.

Os resultados obtidos para cada um dos parâmetros acima mencionados estão resumidos na Figura 27. Nos gráficos, os intervalos que não estão superpostos indicam que as médias são potencialmente diferentes com 95% de nível de confidência. Considerando isso, observa-se

que, para todos os valores de γ (gama) testados, não houve diferença significativa nas médias. No entanto, optou-se pelo uso de 0,99 por estar associado à taxa de acerto média marginalmente superior às demais. Em relação ao coeficiente de aprendizado (α), notou-se uma tendência de aumento da taxa de acerto com o acréscimo de tal fator até ele atingir o valor de 0,05. A partir daí os resultados decaíram consideravelmente. Deste modo, ajustou-se este parâmetro em 0,05. Comportamento similar ocorreu para o número de neurônios, número de passos que o agente aguarda (k_{max}) e o tamanho da janela. Assim, manteve-se a mesma lógica e fixou-se tais fatores em 8 neurônios, 10 passos e 300 ms, respectivamente.

Para a geração do modelo do ambiente e do agente bem como o treinamento do sistema, utilizou-se a toolbox *Reinforcement Learning* do software Matlab. Disponibilizada a partir da versão 2019a, a referida biblioteca conta com funções e blocos que permitem o treinamento de redes de RL pelos métodos *Deep Q-Network* (DQN), *Deep Deterministic Policy Gradient* (DDPG) além do Ator-Crítico implementado neste trabalho. Através dele, também é possível a criação de um modelo customizado para o ambiente, no qual funções para a determinação do próximo estado (a partir do estado atual e ação) e para a atribuição da recompensa para cada movimento do agente podem ser desenvolvidas. Neste contexto, a função para determinação do próximo estado é dada pela aquisição da próxima amostra de sinal de sEMG e o método para a determinação da recompensa segue o procedimento descrito na Seção 4.4.2. Com isso, pode-se representar o algoritmo de treinamento do agente de forma resumida pelo pseudocódigo apresentado no Algoritmo 2.

Algoritmo 2 – Treinamento do agente pelo método ACRL proposto.

```
inicializa: \theta, w, \alpha, \gamma, s, k_{max}
1:
         enquanto t \le k_{max} - 1 faça
2:
3:
                           Pr(\mathbf{A}) = \pi(A|s_t, \boldsymbol{\theta_t})
                           a = \max(\Pr(A))
 4:
                           executa a ação (a) e observa r, s_{t+1}
5:
6:
                           R(t) = r
7:
                           S(t) = s_t
                           t = t + 1
8:
9:
         fim
10:
         repita
                            \Pr(\mathbf{A}) = \pi(A|s_t, \boldsymbol{\theta_t})
11:
12:
                           a = \max(\Pr(A))
13:
                           executa a ação (a) e observa r, s_{t+1}
                           \delta_t = \sum_{k=0}^{k_{max}-2} (\gamma^k R(k+1)) + \gamma^{k_{max}-1} r + \gamma^{k_{max}} v(s_t, \boldsymbol{w_t}) - v(S(1), \boldsymbol{w_t})
14:
                           R = [R(2:k_{max} - 1) \ r]
15:
                           S = [S(2:k_{max} - 1) \ s_t]
16:
                           atualiza \mathbf{w}_t, \mathbf{\theta}_t através das equações (6) e (7)
17:
                           t = t + 1
18:
19:
         fim
```

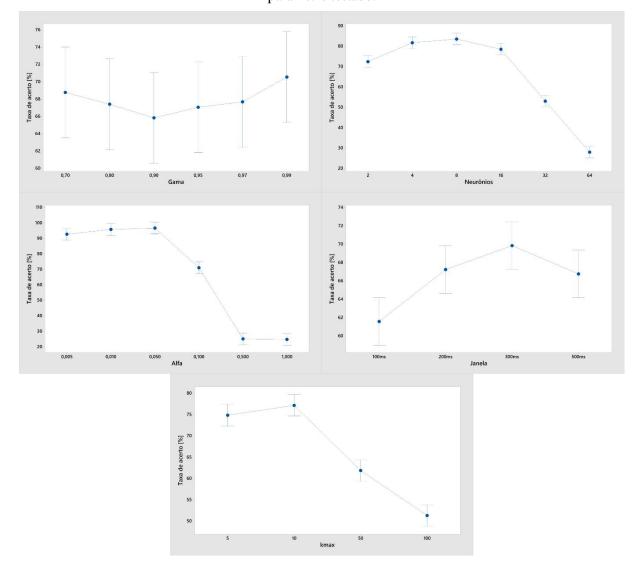


Figura 27 – Médias e intervalos de confiança (95% de nível de confidência) associados com cada parâmetro testado.

4.5 TREINAMENTO OFF-LINE DO AGENTE

Esta seção compreende a descrição do procedimento adotado para o treinamento *off-line* do algoritmo proposto. Para tanto utilizou-se os dados dos 40 voluntários não amputados da Base 02 e de 10 dos 11 sujeitos amputados da Base 03 (ambas pertencentes do projeto Ninapro). O voluntário número 7 desta última não foi utilizado neste e demais experimentos devido a qualidade ruim do sinal, evidenciada pelos resultados apresentados em (ATZORI *et al.*, 2016). Assim, um único resultado neste experimento corresponde ao processamento do sinal de cada par sujeito/canal. Em cada situação, considerou-se apenas os dados associados a movimentos. Os períodos de repouso não foram utilizados, já que também não o foram nos experimentos com classificação de movimentos.

Destes dados, as repetições 1, 3, 4 e 6 foram utilizados para treinar o modelo e as restantes (2 e 5) para testar. Na etapa de contaminação, o sinal sEMG foi dividido em janelas de 2,5 segundos, e em cada uma foi adicionado um tipo de interferência (ECG, MOA, PLI ou WGN) ou deixada intacta (caracterizando a condição sinal íntegro). A sequência das classes foi randomizada. Utilizou-se diferentes níveis de contaminação com SNR de -30 até 10dB com passos de 10dB. O conjunto de treinamento foi submetido a -20, -10 e 0dB enquanto que a base de teste abrangeu toda faixa de intensidades.

Deste modo, todos os procedimentos foram realizados de forma off-line. Como critério de parada do algoritmo, determinou-se o número máximo de episódios igual a 100, onde 1 episódio indica o processamento de todo o conjunto de dados destinado ao aprendizado do sistema. Este parâmetro foi estimado de forma empírica garantindo, com uma margem de segurança, que o treinamento atinja o regime permanente. A Figura 28 ilustra o experimento executado.

Sinal de sEMG Estágio de contaminação Rep. 1, 3, 4 e 6 - Treino C01 PLI WGN MOA WGN ECG PLI C01 2,5 ms 2,5 ms 2,5 ms 2,5 ms 2.5 ms 2,5 ms : C02 WGN MOA WGN INT INT ECG C12 : 2,5 ms 2,5 ms 2,5 ms 2.5 ms 2.5 ms 2.5 ms -20 dB | -10 dB | 0 dB -30 dB | -20 dB | -10 dB | 0 dB | 10 dB C12 Extração de características SMR | DP | SNRatio | DEF | SPR | SER SMR | DP | SNRatio | DEF | SPR | SER SIF-ACRL Treinamento do modelo Teste do modelo

Figura 28 – Experimento conduzido para a validação do algoritmo como classificador de contaminantes.

4.6 TREINAMENTO ONLINE DO AGENTE BASEADO NO CONCEITO DE TRANSFER LEARNING

Como já abordado em outros trechos deste texto (Seção 2.3) uma das principais vantagens da aplicação de métodos baseados em Aprendizado por Reforço é a capacidade do agente

realizar o treinamento de forma online. Esta característica é especialmente importante para o contexto de próteses mio-controladas, pois ela dispensa a aquisição inicial de dados para a execução de um treinamento *off-line* do modelo antes do usuário poder utilizar o dispositivo além da necessidade de recalibrações a cada novo uso. Assim, o indivíduo pode sair operando a prótese e o agente do SIF-ACRL vai ajustando os seus parâmetros ao longo do tempo a partir da experiência adquirida.

Entretanto, para que isso seja, de fato, aplicável na prática dentro do contexto de identificação de contaminantes, é fundamental que o algoritmo consiga aprender sem nenhuma experiência prévia com dados do futuro usuário do sistema e também que esse aprendizado ocorra em um número reduzido de iterações. Trazendo estes dois preceitos para o âmbito do SIF-ACRL, os desafios consistem em determinar os parâmetros do Sistema de Inferência Fuzzy que gerenciará a atribuição de recompensa (sem o acesso aos sinais do voluntário) e propor uma estratégia para acelerar o treinamento do agente.

Assim, de modo a superar os dois desafios supracitados, propôs-se uma abordagem inspirada no conceito de Transfer Learning utilizado em outros trabalhos objetivando agilizar o processo de recalibração do classificador de movimentos (AMERI et al., 2020; KIM; GUAN; LEE, 2020). Deste modo, partindo da premissa de que os contaminantes se manifestam da mesma forma nos dados de sEMG, independentemente do indivíduo, juntou-se os dados de 10 voluntários não amputados e de 3 amputados para o treinamento de um agente padrão para cada uma das bases. Na sequência, os parâmetros das redes do ator e do crítico (θ e w) e o Sistema de Inferência Fuzzy responsável pela atribuição de recompensa, obtidos para estes dados, são utilizados (como uma aproximação inicial no caso de θ e w) no treinamento online de cada um dos demais sujeitos de cada dataset. Resumidamente, os parâmetros do agente padrão são utilizados como um modelo inicial para a execução do treinamento dos modelos associados aos outros voluntários. Assim, para cada canal a ser treinado online (independentemente do indivíduo), os mesmos parâmetros θ e w serão utilizados como ponto de partida e o mesmo SIF será empregado para a atribuição de recompensa (para cada base de dados). A Figura 29 ilustra este procedimento.

A escolha dos 10 e 3 últimos voluntários das bases 02 e 03, respectivamente, não seguiu um critério específico. Apenas procurou-se manter a proporção de aproximadamente ¼ dos dados para a geração do agente padrão de cada *dataset*. Contudo, investigações mais aprofundadas acerca da quantidade e da fonte ideal dos sinais para a formação deste modelo deverão ser conduzidas na sequência do estudo da implementação online do SIF-ACRL.

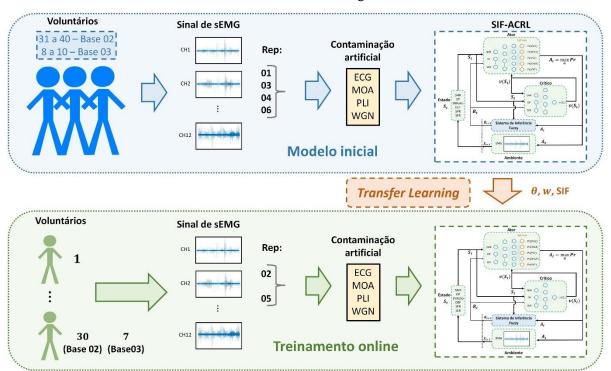


Figura 29 – Método de *Transfer Learning* aplicado no experimento conduzido para simular o treinamento online do agente.

4.7 PROJETO DE EXPERIMENTOS

Tendo em vista que o algoritmo proposto atua tanto na identificação do tipo da contaminação quanto na minimização do efeito destes na classificação de movimentos e o fato do treinamento do modelo poder ser realizado de forma online, foram elaborados 3 projetos de experimentos para validar cada uma destas propriedades. Deste modo, em um deles testou-se a funcionalidade do SIF-ACRL em reconhecer a presença de interferência em registros de sEMG e, em caso afirmativo, a fonte dela. Para tanto, considerou-se a taxa de acerto na classificação dos 4 contaminantes considerados (artefato de movimento, ECG, interferência da rede elétrica e Ruído Branco Gaussiano) mais sinal íntegro como variável de resposta e 5 fatores controláveis (fixos) a citar: voluntário, canal de medição de sEMG, fonte de interferência, nível da contaminação (SNR) e base de dados (Base 02 e 03 Ninapro).

Um segundo experimento foi conduzido para avaliar o impacto do algoritmo proposto na recuperação do sinal contaminado em uma tarefa de classificação de movimentos. A variável de resposta nesse caso foi o índice de assertividade no reconhecimento dos gestos do segmento mão-braço e os fatores controláveis foram a base de dados, sujeito, tipo do sinal considerado (íntegro, contaminado e ambos os tipos com a aplicação do SIF-ACRL), quantidade de canais contaminados (1, 2, 4 e 8), canal, SNR e movimentos.

Por fim, um terceiro teste foi realizado para validar a questão do treinamento online do modelo. Aqui a variável de resposta foi a taxa de acerto do classificador de movimentos e o dataset, o tipo de sinal (íntegro, contaminado não tratado e filtrado pelo método proposto treinado off-line e online), SNR e canal contaminado constituíram as variáveis controladas.

A avaliação da significância do impacto destes parâmetros no índice de assertividade do classificador (contaminantes ou movimentos) foi conduzida pelo método do Teste das Medianas de Mood, onde estima-se a existência ou não de diferença entre as medianas de pelo menos um par de níveis de um referido fator controlável. Logo, ele é aplicável a apenas um fator controlável por vez. A escolha deste método não paramétrico se deu pelo fato dos dados obtidos não seguirem uma curva normal (verificado pelo teste de Ryan-Joiner com 95% de nível de confiança) e não serem homocedásticos (de acordo com o teste de Levene – 95% de nível de confiança). Logo, testes mais potentes como a ANOVA e o teste de Kruskal-Wallis não são os mais adequados.

Na sequência, um teste *post hoc* foi conduzido a fim de se verificar a existência de diferença nas distribuições dos dados de diferentes grupos. O método estatístico utilizado foi o de Mann-Whitney-Wilcoxon (95% de nível de confiança) e a análise foi feita entre pares de distribuições.

5 RESULTADOS E DISCUSSÕES

Este capítulo está estruturado em 4 seções. A primeira apresentará a análise da Base de Dados adquiridas no IEE, onde se verificará a presença ou não de contaminantes em função das não idealidades consideradas nos ensaios (descritas na Seção 4.1.2), a partir do estudo das características extraídas do sinal de sEMG. As duas subsequentes versarão sobre os resultados obtidos em cada um dos experimentos apontados na Seção 4.7. Por fim, um último segmento exporá um resumo dos trabalhos relacionados e se contextualizará os resultados aqui obtidos com aqueles reportados por estas pesquisas.

5.1 CARACTERIZAÇÃO DA BASE DE DADOS DO IEE

Uma vez que o objetivo da criação desta nova versão da Base do IEE é a de caracterizar a forma como os contaminantes podem aparecer nos dados de sEMG durante o uso do dispositivo miocontrolado, extraiu-se um total de 7 características nos sinais adquiridos com cada um dos 4 tipos de ensaios. Seis delas são as mesmas utilizadas na entrada do algoritmo proposto para a identificação dos 4 contaminantes aqui considerados (Relação Sinal-Artefato de Movimento – SMR, Queda do Valor Máximo para o Mínimo da Densidade Espectral de Potência – DP, Relação Sinal-Ruído – SNRatio, Deformação na Densidade Espectral de Potência – DEF, Relação Sinal-Linha de Energia – SPR e Relação Sinal sEMG-ECG – SER). A sétima consiste na métrica apresentada em (MAKARAM; KARTHICK; SWAMINATHAN, 2021) para a caracterização de fadiga muscular, chamada *Symbolic Entropy*. Para o cômputo dessa característica, primeiramente faz-se a representação simbólica binária do sinal de sEMG, através da Equação (40).

$$z(n) = \begin{cases} 1, & para \ y(n) \ge 0 \\ 0, & caso \ contrário \end{cases}$$
 (40)

onde, a função y(n) representa as mudanças de inclinação do sinal de sEMG e é dado pela Equação (41).

$$y(n) = x(n+1) - x(n), \quad n = 1, 2, 3, \dots, N-1$$
 (41)

onde, x(n) representa o sinal de sEMG.

A função binária z(n) passa então por um processo de segmentação em janelas de 3 bits e cada partição é convertida para decimal, formando uma sequência numérica definida no intervalo [0, 7]. A partir dessa nova representação, a referida característica é obtida pelo cálculo da probabilidade de ocorrência de cada símbolo na sequência e, em seguida, pelo cômputo da

entropia de Shannon dessa distribuição (Equação (42)) (MAKARAM; KARTHICK; SWAMINATHAN, 2021).

$$SymEn = -\sum_{i=0}^{7} p(o_i) \cdot \log(p(o_i))$$
(42)

onde, o_i corresponde ao símbolo formado pelo agrupamento de 3 bits e $p(o_i)$ é a probabilidade de ocorrência deste símbolo.

A escolha desta última métrica se justifica na caracterização do efeito do cansaço muscular (objeto de estudo do ensaio Tipo D) no sinal de sEMG e identificar possíveis indícios de fadiga.

As figuras 30 a 33 mostram as distribuições das 7 características extraídas em janelas de 300 ms (sem sobreposição) dos canais 9 ao 12, nesta ordem. Aqui só serão apresentados os dados destes 4 pontos de medição uma vez que estes foram os únicos submetidos a artefato de movimento. Os gráficos de caixa são constituídos pelos sinais de todos os 4 voluntários e pelas 2 repetições realizadas em cada tipo de ensaio. As siglas "CL1", "FD1", "EM1", "MA9", "MA10", "MA11" e "MA12" se referem ao ensaio Tipo A (sob condições ideais), Tipo D (sob condição de cansaço muscular), Tipo C (com eletrodos mal colados), Tipo B (sob artefato de movimento induzido no canal 9), Tipo B (sob artefato de movimento induzido no canal 11) e Tipo B (sob artefato de movimento induzido no canal 12), respectivamente. Os boxplot associados às aquisições com artefato de movimento representam somente o intervalo de tempo no qual a interferência foi induzida no respectivo canal, ou seja, aproximadamente ¼ de todo o ensaio.

Pelos gráficos de caixa, vislumbra-se um claro efeito do eletrodo mal colado (em azul) na característica SPR. Ela apresenta valores predominantemente inferiores para esta métrica em relação aos outros tipos de ensaio, principalmente os canais 9 e 12. Este último também esteve associado aos maiores valores de SNRatio e DP, ainda considerando o experimento Tipo C. Especialmente o comportamento da característica SNRatio pode ser explicado pelo valor extremamente baixo da métrica SPR que, por sua vez, indica uma potência elevada na frequência de 60 Hz. Com isso, a relação entre a potência das componentes de baixas frequências pela de altas tende a ser grande.

Com base nisso, conclui-se que uma má conexão entre eletrodo e pele provoca, predominantemente, o surgimento de ruído de linha de energia no sinal de sEMG. De fato, o enfraquecimento do contato faz com que o eletrodo atue quase como uma antena, potencializando a indução eletromagnética.

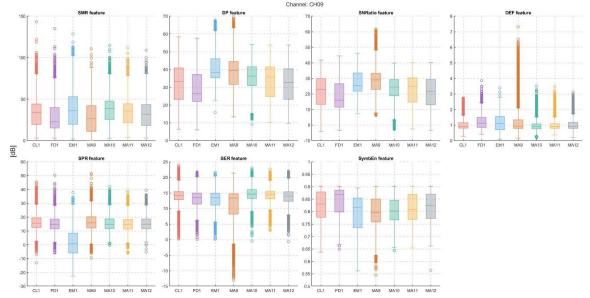
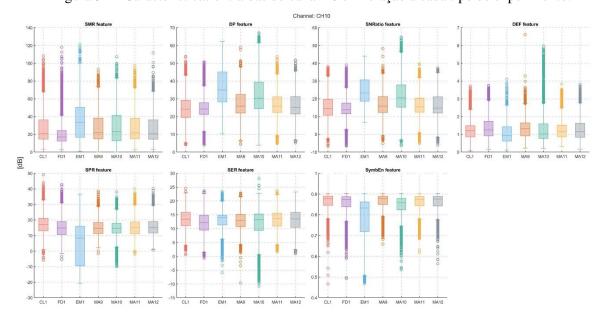


Figura 30 – Características extraídas do canal 9 em relação a cada tipo de experimento.

Figura 31 – Características extraídas do canal 10 em relação a cada tipo de experimento.



Em contrapartida, os ensaios com artefato de movimento (MA9, MA10, MA11 e MA12 nas figuras 30 a 33, respectivamente) apresentaram maior influência nas características SMR e SER, especialmente os canais 9 e 11. Isso já era esperado visto que a primeira foi projetada para a identificação deste contaminante e a segunda para ECG, que também se manifesta em baixas frequências. Estes canais estiveram associados aos menores valores para estas métricas em relação aos demais tipos de ensaio. O fato desta interferência se manifestar de forma distinta nos 4 pontos de medição, mesmo utilizando-se do mesmo procedimento para a geração do impacto mecânico, pode ser explicado pela maior dificuldade no acesso de alguns deles durante

o ensaio. O canal 10 foi o mais difícil de se atingir devido à sua proximidade com a faixa dos 8 pares de eletrodos fixados na circunferência do antebraço.

Além disso, ele localiza-se na parte interna do membro, voltada para o voluntário durante os exercícios, o que exigia um certo contorcionismo do operador gerador do impacto.

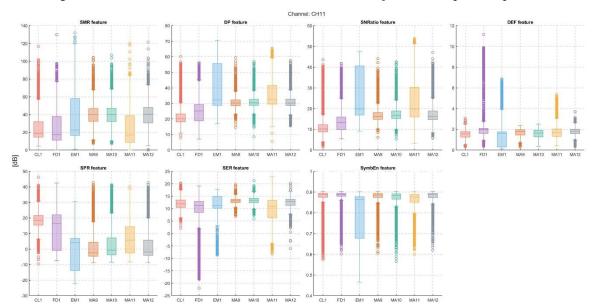
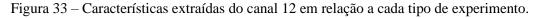
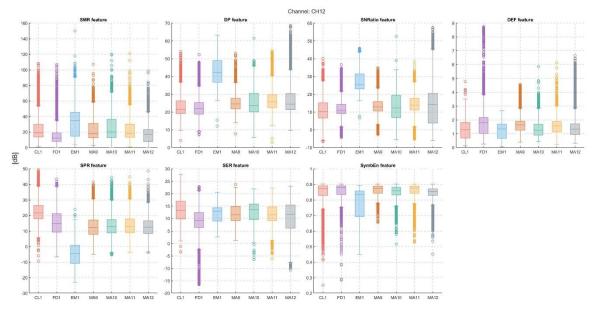


Figura 32 – Características extraídas do canal 11 em relação a cada tipo de experimento.





Por fim, a condição de cansaço muscular (FD1) não apresentou maiores impactos nas características extraídas (em comparação com sinal íntegro), principalmente na *SymEn*. Esta observação indica que, aparentemente, o exercício físico realizado pelo voluntário não foi suficiente para impactar de forma considerável as propriedades do sinal de sEMG. Contudo,

ressalta-se a importância de se verificar a influência desta condição nos resultados de classificação de movimentos, antes de se desconsiderar este possível fator contaminante. Esta análise será conduzida no prosseguimento deste estudo.

Em suma, conseguiu-se reproduzir na prática 2 dos 4 contaminantes considerados neste estudo (PLI e MOA) através da introdução de não idealidades no processo de aquisição de sEMG, simulando-se situações possivelmente encontradas durante o uso contínuo do dispositivo. A interferência por WGN está potencialmente associada com o ruído térmico dos componentes eletrônicos do hardware utilizado no processamento do sinal. Logo, sua reprodução poderia causar danos nos equipamentos do laboratório. Em contrapartida, o impacto de ECG não foi observado em nenhum ensaio realizado com essa configuração de eletrodos. O referido contaminante pode apresentar maiores prejuízos em sistemas que utilizem canais localizados mais próximos ao pulso ou na região do peitoral. Este último caso pode ocorrer em próteses desenvolvidas para pessoas com amputação transumeral que possuem escassa musculatura remanescente no coto. A utilização de grupos musculares como o trapézio e o peitoral maior (por exemplo) podem ser boas alternativas para a caracterização da intenção de movimento do sujeito.

5.2 EXPERIMENTO OFF-LINE

Os experimentos apresentados nesta seção consideram o modelo SIF-ACRL treinado *off-line*, de acordo com o algoritmo apresentado na Seção 4.5.

5.2.1 Identificação de Contaminantes

Nesta seção serão descritos os resultados do experimento projetado para avaliar a propriedade de identificação do tipo da contaminação do algoritmo proposto. A Tabela 6 mostra a mediana e a distância interquartil dos resultados obtidos com cada base. A precisão relatada em cada execução é a média dos contaminantes associado a cada SNR. Estas medidas de tendência central e de dispersão foram consideradas na análise devido à não normalidade dos dados (p-valor < 0,05 verificado pelo teste de Ryan-Joiner).

Verificou-se diferença significativa entre as medianas de acordo com o teste de medianas de Mood com nível de confiança de 99%, apesar da distância de apenas 3% entre elas. Em geral, os resultados obtidos com os dados dos voluntários não amputados foram melhores do que os dos amputados. Contudo, observou-se uma elevada variação intersujeitos em ambas bases com leve superioridade para a 03, o que não surpreende tendo em vista a maior variação nas

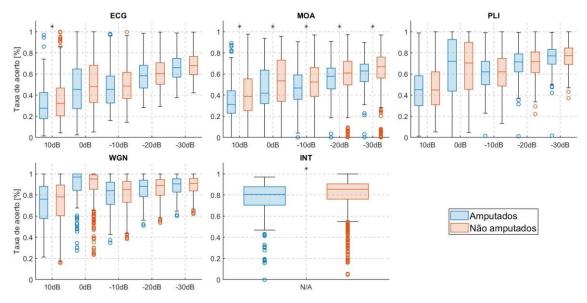
características dos voluntários que compõem essa base como grau da amputação, tempo em que a mesma foi realizada, para citar alguns.

Tabela 6 – Resultados de classificação do algoritmo proposto para cada base de dados. Os resultados com a mesma letra na última coluna pertencem à mesma distribuição segundo o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%.

Base	Mediana [%]	Q3-Q1 [%]	
Amputados	66,5	25,1	A
Não amputados	69,5	23,8	В

Ampliando a análise do ponto de vista do tipo de contaminante e do nível da contaminação, observa-se na Figura 34 que os resultados associados aos sujeitos intactos foram significativamente superiores somente na identificação do contaminante artefato de movimento (para todos SNR's), sinal íntegro e ECG com nível de 10dB. Estes resultados são, de certa forma, surpreendentes visto que os dados de amputados normalmente estão associados aos menores índices de assertividade em trabalhos relacionados como o de Machado et. al (2021). Isso mostra que, apesar de todos os fatores que cercam a aquisição na musculatura residual dos voluntários com o membro subtraído, como a localização do eletrodo na região não ventral, o reconhecimento de possíveis contaminações por ECG, PLI e WGN não são influenciadas de forma significativa.

Figura 34 – Taxas de acerto relacionadas a cada classe e SNR. Os pares de gráficos com um asterisco (*) pertencem a distribuições distintas segundo o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%.



Em geral, os contaminantes ECG e artefato de movimento foram os mais difíceis de identificar para ambas bases. Em contraste, o ruído gaussiano branco aditivo foi associado aos

melhores resultados com medianas variando de 76,1 a 96,9% para os amputados e de 78,23 a 95,2% para a outra base. Na verdade, este é o único contaminante que aparece na região de altas frequências, o que explica o maior índice de discriminação. No entanto, o espectro de ECG e MOA são sobrepostos (ambos aparecem na região de frequências mais baixas). Além disso, a morfologia do sinal de artefato de movimento muitas vezes se confunde com a das ondas P, QRS e T (MCCOOL *et al.*, 2014; THAKOR; ZHU, 1991). Assim, eles são frequentemente classificados erroneamente entre si, explicando as medianas mais baixas observadas para ambos.

O fator SNR afeta naturalmente o desempenho do classificador. Para níveis muito altos, a potência do sEMG é muito maior que a do contaminante, tornando-o praticamente inidentificável. Portanto, o efeito SNR é importante para identificar o limite de aplicabilidade do método. Como já mencionado, em geral ambas bases apresentaram resultados comparáveis, mesmo em níveis de contaminação mais brandos. Isso pode indicar que elas possuem limites de aplicabilidade semelhantes (do ponto de vista da intensidade da interferência).

Um comportamento interessante foi observado nos resultados atingidos com SNR de 0dB. Eles apresentaram medianas superiores àquelas associadas a -10dB no reconhecimento de PLI e MOA (não amputados) e inclusive aos níveis -20 e -30dB na identificação de WGN. Por alguma razão, o algoritmo teve mais facilidade para classificar dados com esta relação sinal-ruído enquanto que, teoricamente, esperava-se que as interferências ficassem mais evidentes para SNR's mais baixos.

O processo de aquisição realizado pelo grupo Ninapro na formação dos bancos de dados utilizados neste estudo, bem como o desempenho do voluntário, também podem influenciar os resultados dos métodos. Por exemplo, um sujeito que realizou movimentos mais bruscos durante as tentativas pode ter introduzido baixos níveis de artefato de movimento no sinal adquirido. Assim, os resultados alcançados com cada base foram analisados sob a ótica dos sujeitos e dos canais.

Dessa forma, do ponto de vista do voluntário, foi observada certa variabilidade nas medianas dos índices de assertividade (Figura 35). O sujeito 20 apresentou o melhor resultado com mediana de 88,5%. Ele foi o único a superar a casa dos 80%. Já dentre os indivíduos com amputação, as maiores taxas de acerto ficaram com o 5 e o 9 com 79,5% cada. Em contrapartida, os voluntários 1 e 13 (não amputados) e os 2, 3 e 7 (amputados) se destacaram por suas medianas mais baixas (60,7,57,1,57,5,57,1 e 56,3%, respectivamente). Assim sendo, observase uma considerável diferença entre os extremos principalmente para os intactos (31,4%), o que indica a presença de alguns aspectos nos sujeitos que favoreceram a identificação dos

contaminantes. Portanto, conclui-se que o voluntário tem grande impacto no desempenho do sistema.

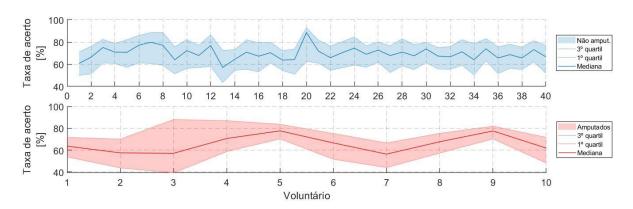


Figura 35 – Análise do efeito do voluntário nas taxas de acerto.

Considerando o impacto do canal, o número 1 esteve associado às menores medianas para ambas bases (Figura 36). Esse canal era proveniente de um conjunto composto por oito pares de eletrodos igualmente espaçados ao redor do antebraço do voluntário. Sua localização, potencialmente, pode ter afetado a qualidade dos dados adquiridos, incluindo contaminantes adicionais. De fato, o nível de ruído destas bases de dados foi avaliado em (CHANG; PHINYOMARK; SCHEME, 2020) sendo considerado um nível aceitável, mas com recomendação de melhoria. No entanto, nenhuma observação foi feita especificamente para o canal 1.

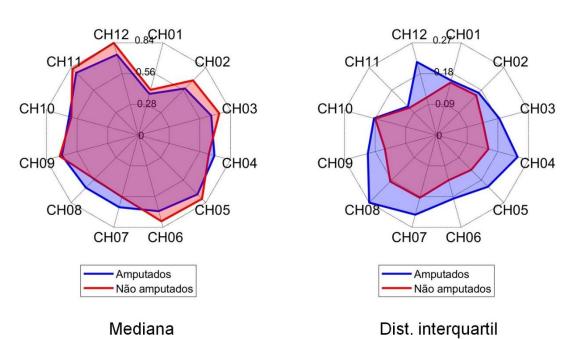
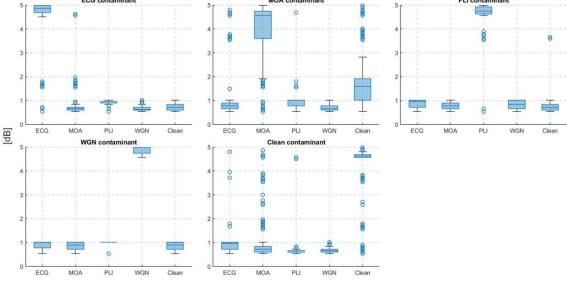


Figura 36 – Análise do efeito dos canais de medição nas taxas de acerto.

Os canais 11 e 12 foram os mais fáceis de identificar o tipo de contaminante tanto em voluntários amputados como nos intactos. Estes foram colocados na região ventral do bíceps e do tríceps. Considerando que os movimentos aqui considerados são movimentos básicos de dedos e punhos, o braço ficou praticamente estático durante o exercício, diminuindo a probabilidade de artefato de movimento, deslocamento/descolamento de eletrodos, entre outros fatores contaminantes, o que pode explicar seus melhores resultados.

Em resumo, os resultados aqui apresentados indicam que o SIF-ACRL é promissor para o problema de identificação do tipo de contaminantes em sEMG. Contudo, as taxas de acerto medianas globais, especialmente a referente à Base 02 (69,5%), ficaram consideravelmente abaixo das já apresentadas para o mesmo método no artigo publicado em (TOSIN; BALBINOT, 2022) onde obteve-se 92,6%. A única diferença no algoritmo foi o acréscimo da classe "sinal íntegro" o que, por si só, não explicaria esta queda considerável na taxa de acerto. Até pelo fato de tal classe ser facilmente identificável pelas características propostas como mostra o boxplot da função score na Figura 37.

Figura 37 — Boxplot da função score associado ao canal 6 do voluntário 8 com SNR de -10dB. O termo "clean" se refere à classe sinal íntegro.



Por outro lado, o protocolo do experimento adotado no artigo considerou todo o intervalo do sinal, inclusive os dados de repouso. Como não há ativação muscular neste período, o contaminante inserido é mais proeminente, facilitando a sua identificação. Levando em conta que cerca de 60% do ensaio é constituído de repouso, atribui-se a este fato a diferença nos resultados aqui expostos dos do experimento anterior. Em todo caso, recomenda-se a leitura do referido artigo para mais detalhes do experimento conduzido e que contribuiu na validação da propriedade de identificar contaminantes do SIF-ACRL.

5.2.2 Classificador de Movimentos

Neste experimento objetivou-se avaliar o efeito do SIF-ACRL inserido em um sistema de classificação de movimentos. Para tanto, testou-se 4 diferentes configurações a fim de verificar duas hipóteses: a de que o algoritmo proposto é capaz de melhorar a taxa de acerto do sistema quando 1 ou mais canais estiverem contaminados; e a de que ele não afeta a performance do classificador quando o sinal não estiver corrompido. Assim, definiu-se os quatro seguintes protocolos:

- 1) Teste com sinal íntegro: aqui o sinal não contaminado é inserido diretamente ao sistema de classificação de movimentos;
- Teste com sinal íntegro incluindo o estágio de pré-processamento proposto: neste teste, os dados não corrompidos são inseridos no SIF-ACRL antes de serem aplicados ao modelo identificador de gestos;
- Teste com sinal contaminado e não filtrado: os dados de um ou mais canais (dependendo do tipo do experimento) são previamente contaminados e inseridos ao classificador;
- 4) Teste com sinal contaminado incluindo o estágio de pré-processamento proposto: aqui o procedimento é similar ao anterior só que com a aplicação do SIF-ACRL.

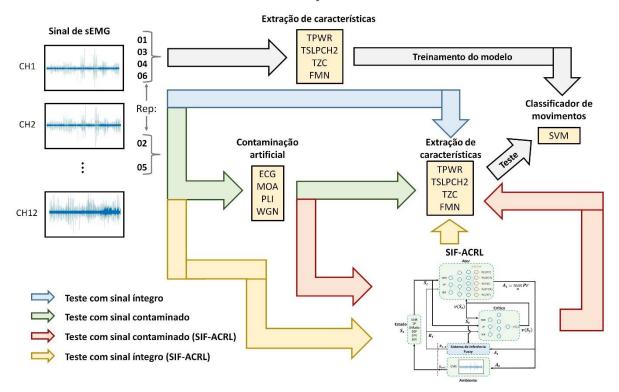
O classificador de movimentos utilizado em todos os protocolos listados anteriormente consiste em um modelo treinado com as repetições 1, 3, 4 e 6 de cada voluntário. Considerouse apenas sinais não contaminados para tanto. Assim, o mesmo modelo foi testado com as repetições remanescentes usando-se ou dados íntegros ou íntegros e filtrados ou contaminados ou corrompidos e filtrados. A Figura 38 ilustra o experimento conduzido.

Support Vector Machine (SVM) foi o método de classificação escolhido para a etapa de reconhecimento de gestos. Ele é uma das técnicas mais poderosas para classificação de dados, sendo amplamente utilizado na identificação de movimentos a partir de sEMG (CHEN et al., 2020; MOURA; FAVIEIRO; BALBINOT, 2016). Quatro características foram extraídas em janelas de 300 ms sem superposição, antes da fase de classificação. São eles: Potência (TPWR), Mudanças de Inclinação do Sinal (TLSPCH2), Número de Cruzamentos por Zero (TZC) e Frequência Média (FMN). Estas métricas foram escolhidas com base nos resultados obtidos no trabalho de mestrado e publicados em (TOSIN; CENE; BALBINOT, 2020).

Todos os experimentos foram conduzidos no software Matlab versão 2020b. A SVM foi implementada através da biblioteca LibSVM (CHANG; LIN, 2011) com kernel linear e fator de penalidade de 0,0001. Este parâmetro foi selecionado após testes preliminares com o fator

de penalidade variando de 0,00001 a 100000 em uma progressão geométrica de razão 10. Os modelos dos agentes da SIF-ACRL associado com cada par canal-voluntário e usados nos testes são aqueles obtidos no Experimento 01 (Seção 5.2).

Figura 38 – Experimento conduzido para a validação do algoritmo no estágio de pré-processamento do sistema de classificação de movimentos.



Os testes com sinal contaminado foram realizados com 16 configurações diferentes, com 1, 2, 4 e 8 canais corrompidos (Tabela 7). Esta escolha foi feita para avaliar o efeito de cada ponto de medição individualmente, do par situado em músculos específicos no braço (C11 e C12) e do antebraço (C9 e C10), dos canais fixados na região ventral muscular (C9 ao C12) e dos canais dispostos aleatoriamente ao longo da circunferência do antebraço (C1 ao C8).

Tabela 7 – Configurações de canais contaminados testados.

C1	C2	C3	C4	C5	C6	C11 e C12	C9, C10, C11 e C12
C7	C8	C9	C10	C11	C12	C9 e C10	C1, C2, C3, C4, C5, C6, C7 e C8

A Tabela 8 resume os resultados alcançados com cada base de dados para todos os diferentes protocolos da Figura 38. Aqui, novamente considerou-se a mediana e a distância interquartil como métricas de tendência central e de dispersão pelos mesmos motivos apresentados na Seção 5.2.1, ou seja, pelo fato dos dados não seguirem uma curva normal (p-valor < 0,05 verificado pelo teste de Ryan-Joiner). Os experimentos com sinais contaminados compreendem todas as configurações de canais testadas (Tabela 7).

Tabela 8 – Resultados de classificação de movimentos para cada base de dados. Os resultados com a mesma letra (dentro de cada base de dados) na última coluna pertencem à mesma distribuição segundo o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%.

AMPU	JTADOS		NÃO AMPUTADOS				
Protocolo	rotocolo Mediana [%]			Protocolo	Mediana [%]	Q3-Q1 [%]	
Sinal íntegro	49,0	14,9	A	Sinal íntegro	62,9	11,0	A
Sinal íntegro (SIF-ACRL)	48,3	16,2	A	Sinal íntegro (SIF-ACRL)	61,5	9,3	A
Sinal cont.	32,4	21,2	В	Sinal cont.	43,3	23,8	В
Sinal cont. (SIF-ACRL)	38,7	17,8	C	Sinal cont. (SIF-ACRL)	51,8	18,1	C

Foi identificada uma diferença significativa entre as medianas de acordo com o teste de medianas de Mood (99% de nível de confiança). De acordo com a Tabela 8, de um modo geral a aplicação do SIF-ACRL não prejudicou de forma significativa a performance do classificador de movimentos, uma vez que ambos resultados (sinal íntegro e sinal íntegro SIF-ACRL) foram verificados pertencentes à mesma distribuição para ambas bases. Contudo, para os dois tipos de voluntários observou-se uma redução na taxa de acerto mediana que, embora pequena (0,7% – Amputados e 1,4% – Não amputados), reforça a premissa de que a filtragem desnecessária do sinal exclui informações que podem ser importantes para o reconhecimento da intenção de movimento, sendo, portanto, não recomendável. Deve-se levar em conta que o algoritmo apresentou um índice de assertividade mediano de 80,6% (Base 03) e 85,6% (Base 02) para a classe sinal íntegro (Seção 5.2.1).

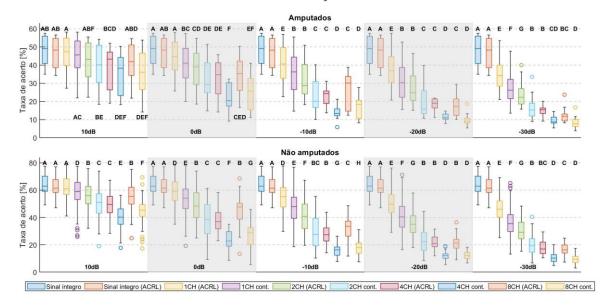
Por outro lado, a aplicação do método de pré-processamento proposto induziu em um acréscimo significativo na taxa de acerto do sinal contaminado (6,3% e 8,5% em valor absoluto para as bases 03 e 02, respectivamente). Em contrapartida, esta melhoria não foi suficiente para igualar o desempenho que o classificador teve com dados não corrompidos. Todavia, convém lembrar que aqui estão sendo considerados situações severas de prejuízo na qualidade do sistema como baixos SNR's (abaixo de 0dB) e também ocorrências de mais de 1 canal contaminado. Nestes casos a restauração total da informação é impraticável.

Em suma, nesta primeira análise dos resultados confirmou-se (de um modo generalizado) as duas hipóteses levantadas no início desta seção, ou seja, a de que o algoritmo proposto é capaz de melhorar a taxa de acerto do sistema quando 1 ou mais canais estiverem contaminados e a de que ele não afeta a performance do classificador quando o sinal não estiver corrompido.

Aprofundando a análise em relação ao número de canais contaminados e à intensidade da contaminação, certificou-se que, para 10dB o SIF-ACRL conseguiu recuperar o desempenho do classificador quando apenas um ponto de medição estava corrompido (Figura 39). Nestas condições houve uma diferença de apenas 1,8% (para ambas bases) entre a taxa de acerto

mediana associada ao processamento de dados íntegros e ao experimento com um canal contaminado submetido ao algoritmo de pré-processamento, não sendo observado diferença estatística entre as distribuições (99% de nível de confiança). Ao analisar apenas do ponto de vista dos sujeitos amputados a 10dB, não se verificou distinção entre as distribuições dos resultados dos sinais "limpos" e de todas configurações de canais contaminados e submetidos ao SIF-ACRL. Esta consideração evidencia a eficácia do método proposto mesmo na presença de um número elevado de dados corrompidos (a 10dB).

Figura 39 – Resultados de classificação de movimentos para cada base de dados em relação ao SNR e à quantidade de canais contaminados. Os boxplot com a mesma letra (dentro de cada base de dados e para cada SNR) pertencem à mesma distribuição segundo o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%.



Para contaminações mais brandas (SNR maiores do que -20dB), notou-se que na configuração de 8 canais contaminados o algoritmo teve um melhor desempenho na recuperação da performance do classificador. Em todos os casos (exceto 10dB - Amputados) a taxa de acerto mediana deste protocolo superou a dos 4 canais filtrados e, inclusive, a condição de apenas 2 pontos de medição contaminados e não tratados. Além disso, apresentou resultados comparáveis com o teste a 2 canais contaminados e pré-processados (SIF-ACRL) para dados da Base 03 (a 10 e -10dB) e da Base 02 (a 10 e 0dB).

Estas observações reforçam a importância de se realizar a aquisição de sEMG com os eletrodos colados na região ventral dos grupos musculares, visto que o efeito da contaminação nos 8 canais fixados de forma aleatória ao longo da circunferência do braço ficou próximo ao dos 4 pares de sensores alocados no bíceps, tríceps, extensor e flexor dos dedos e também, em alguns casos, quando apenas 2 destes estavam corrompidos. Isso pode induzir que a informação

extraída de grupos musculares específicos (C9 a C12), mesmo com a metade do número de canais, igualou a obtida com os demais sensores dispostos de forma randômica.

Por outro lado, para níveis de contaminação mais severas (SNR menores do que -10dB) notou-se uma relação inversa entre a taxa de acerto do classificador e o número de canais contaminados, ou seja, a quantidade de pontos de medição corrompidos se mostrou mais impactante do que a localização dos mesmos. Para estas situações mais extremas a quantidade de informação perdida por sensor (mesmo com a aplicação do algoritmo de pré-processamento) é muito grande, o que torna o impacto da contaminação de um único canal mais relevante. Isso pode explicar o fato dos resultados terem sido piores quando um número maior de pontos de medição foi corrompido com estes SNR's.

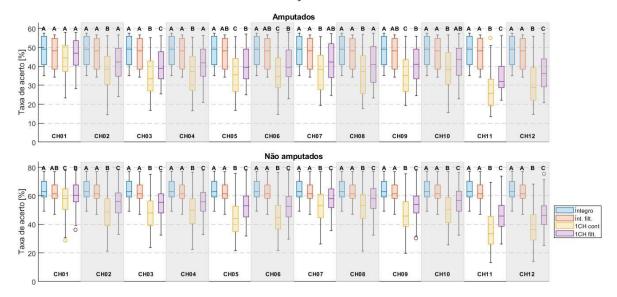
Avaliando a situação do ponto de vista de cada canal de forma individual, observou-se os resultados obtidos com os experimentos a 1 ponto de medição contaminado e comparou-se com àqueles associados aos sinais íntegros (Figura 40). Desta análise, verifica-se que o canal 1 teve o menor impacto (disparadamente) na taxa de acerto do classificador. A diferença entre as medianas alcançadas com sinal íntegro e com o filtrado (aplicação do SIF-ACRL) foi de apenas 2% (Amputados) e 2,5% (Não amputados). Aqui convém destacar que estão sendo considerados todos os níveis de interferência (de 10 a -30dB). Esta evidência pode ser justificada devido a sua localização, potencialmente, poder ter afetado a qualidade dos dados adquiridos, incluindo contaminantes adicionais, o que explicaria também os baixos índices de assertividade de identificação dos contaminantes, conforme já mencionado na Seção 5.2.1. Além disso, este canal está localizado próximo a outros dois pares de eletrodos e não está na região ventral de nenhum músculo específico. Logo, parte da informação captada por ele pode ser redundante àquela trazida pelos pontos de medição adjacentes, fazendo com que não haja uma perda significativa de dados úteis ao classificador.

Por outro lado, este comportamento do canal 1 também poderia estar associado a uma possível maior intensidade da ativação muscular captada por ele em relação aos níveis de tensão registrados durante o período de inatividade do voluntário. Neste caso, como a potência do sinal foi estimada em função dos dados de repouso (Seção 4.2), o canal seria menos suscetível a ruído. Isso também ajudaria a justificar os resultados inferiores do Experimento 01 obtidos para ele. Contudo, ressalta-se a importância de se aprofundar na investigação da condição deste canal para que este comportamento seja devidamente elucidado.

Ainda de acordo com a Figura 40, observa-se que os canais 11 e 12 tiveram um maior impacto na taxa de acerto do classificador para as duas bases. Ambos são os únicos fixados na região do braço do voluntário (bíceps e tríceps). Todavia, eles trazem informações únicas que

não são compensadas por nenhum outro sensor. Mesmo se considerarmos os outros dois pares de eletrodos alocados sobre o flexor e extensor dos dedos (C09 e C10), existem canais dentro dos 8 aleatórios que capturam sinais destes músculos, suprindo assim a sua "ausência". Logo, é perfeitamente compreensível a maior perda de assertividade com a contaminação dos canais 11 e 12.

Figura 40 – Resultados de classificação de movimentos para cada base de dados em relação ao canal contaminado. Os boxplot com a mesma letra (dentro de cada base de dados e associados ao mesmo canal) pertencem à mesma distribuição segundo o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%.



Por fim, constatou-se comportamento similar para os pontos de medição 2 ao 10, ou seja, uma redução na taxa de acerto maior do que a do #1 e menor do que as do #11 e #12. Isso pode ser explicado pela natural correlação existente entre os sinais adquiridos por eles.

As figuras 41 e 42 mostram o efeito dos sujeitos não amputados e amputados, nesta ordem, na performance do classificador. Os resultados com sinal íntegro estão representados somente por uma linha contínua porque só foi executado um teste com cada voluntário. Em relação ao efeito do SIF-ACRL aplicado ao sinal "limpo", observou-se uma tendência de pequena redução na taxa de acerto com a aplicação do método. Os maiores decréscimos estiveram associados com os indivíduos não amputados 30 e 32 (cerca de 4% em valor absoluto) e o amputado 9 (cerca de 3% em valor absoluto).

Todavia, notou-se um acréscimo no índice de assertividade do classificador para os voluntários intactos 10 e 19 com o uso do algoritmo de pré-processamento. Potencialmente, o sistema proposto reduziu o efeito de contaminantes que já se encontravam no sinal, melhorando o desempenho do identificador de movimentos. No entanto, à exceção destes casos peculiares,

os resultados apresentados reforçam a premissa de que o uso indevido de filtragens no sinal pode causar prejuízo no reconhecimento dos gestos.

Figura 41 – Comparação entre os resultados dos diferentes tipos de testes em relação aos obtidos com sinal íntegro considerando o efeito dos voluntários não amputados.

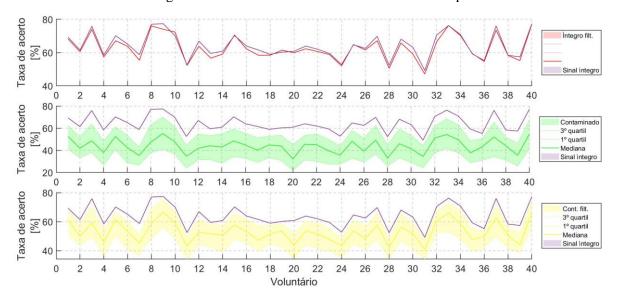
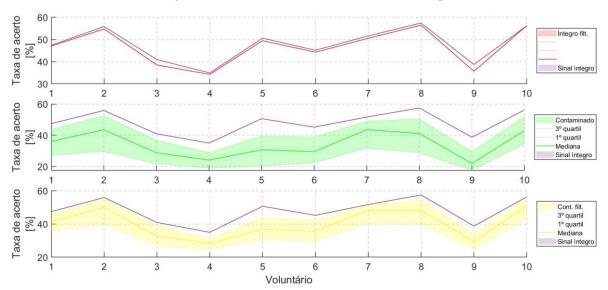


Figura 42 – Comparação entre os resultados dos diferentes tipos de testes em relação aos obtidos com sinal íntegro considerando o efeito dos voluntários amputados.



Em relação ao impacto da contaminação (gráfico do meio), se observou certa variação dentre os voluntários, tanto intactos quanto amputados. Para os primeiros houve uma queda máxima da taxa de acerto mediana de cerca de 30% (#8) e mínima de 12% (#36). Já para os sujeitos com subtração de parte do membro superior a amplitude entre tais valores foi um pouco menor. Constatou-se redução máxima de 20% (#5) e mínima de 8% (#7). Todos eles representados em termos absolutos. Tal comportamento pode ser explicado pelas diferenças intrínsecas dos aspectos fisiológicos dos participantes e pelo seu desempenho durante os

ensaios. Por exemplo, sujeitos associados aos maiores níveis de ativação muscular (que dependem dos fatores citados anteriormente) potencialmente estão menos afetados pela presença dos contaminantes inseridos.

Finalmente, analisando a influência da aplicação do algoritmo proposto, nota-se também distinção entre voluntários, ou seja, para alguns ele é mais eficaz do que para outros. Este resultado já era esperado e está de acordo com aqueles apresentados na Seção 5.2.1 associados à Figura 35, onde concluiu-se que o fator indivíduo era significativo para o índice de assertividade do SIF-ACRL no reconhecimento do tipo de contaminante.

No que tange ao movimento executado pelo participante, observou-se que a aplicação do algoritmo proposto diretamente aos sinais íntegros melhorou a taxa de acerto mediana para os movimentos 3, 9, 11 e 15 para os amputados (Figura 43 – A). De fato, o gesto 9 da Base 03 foi o mais sensível à inserção dos contaminantes (maior redução na taxa de acerto de acordo com a Figura 43 – C) e um dos mais incrementados com o processo de filtragem (um dos maiores aumentos na taxa de acerto em relação ao sinal contaminado, de acordo com a Figura 43 – B). Logo, a minimização de ruídos adicionais presentes no sinal íntegro pelo SIF-ACRL pode estar por trás do comportamento notado na Figura 43 – A para este gesto. Os demais movimentos desta base e todos os associados aos não amputados (Figura 44 – A) apresentaram leve decréscimo ou se mantiveram indiferentes à aplicação do método.

Para a base dos intactos houve uma maior influência da contaminação nos movimentos 1, 4, 5, 7 e 15 e menor para os números 9 ao 14. Em relação ao desempenho do SIF-ACRL na recuperação do sinal, não se constatou nenhuma tendência significativa entre os gestos. Para todos conseguiu-se melhorar o índice de assertividade mediano do classificador além de reduzir a variabilidade dos resultados (menor distância interquartil).

Aqui, diferentemente da análise dos outros fatores, não ocorreu uma concordância entre as bases. Por exemplo, o movimento 9 que foi o mais sofreu com a inclusão das interferências para a Base 03, foi um dos que menos sentiram na Base 02. Isso mostra que a relação sujeito/movimento é impactada de forma diferente pela presença de dados corrompidos.

Até este ponto da análise se certificou que o algoritmo proposto é eficaz na recuperação do sinal contaminado do ponto de vista do desempenho do classificador de movimentos. Contudo, não se pode afirmar que esta melhora na performance teve relação com o fato do filtro mais apropriado ter sido aplicado à interferência correta ou simplesmente ao fato de ter sido aplicado algum método qualquer para supressão de ruídos. Em outras palavras, não se tem informação acerca da importância de se realizar a identificação do tipo da contaminação na

restauração dos dados corrompidos visando a tarefa de se reconhecer gestos do segmento mãobraço.

Figura 43 – Comparação entre os resultados dos diferentes tipos de testes em relação aos obtidos com sinal íntegro considerando o efeito dos movimentos (Base de Amputados).

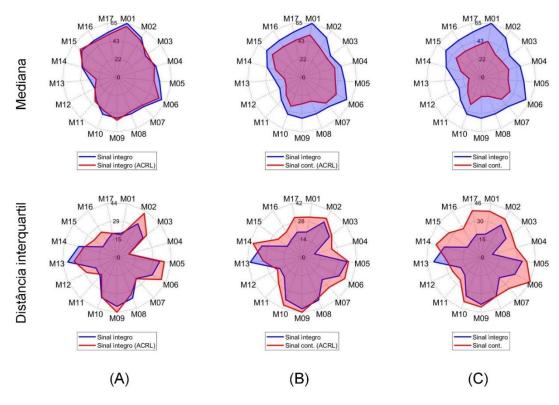
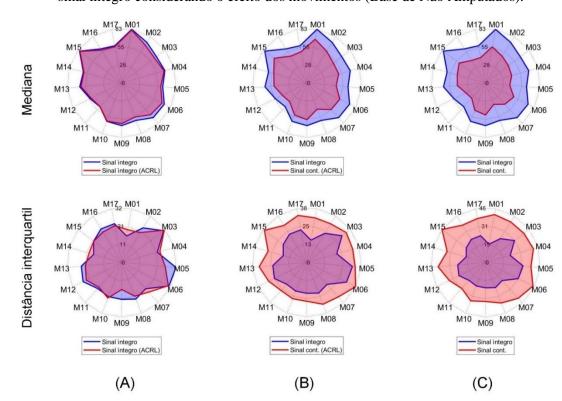


Figura 44 – Comparação entre os resultados dos diferentes tipos de testes em relação aos obtidos com sinal íntegro considerando o efeito dos movimentos (Base de Não Amputados).



Diante disso, avaliou-se a correlação entre o valor médio do percentual da melhora na taxa de acerto do classificador (diferença relativa entre os resultados obtidos com os sinais contaminados não filtrados e aqueles alcançados com o algoritmo proposto — Equação (43)) e o índice de assertividade médio do SIF-ACRL na identificação dos contaminantes em cada par canal/voluntário. Estas duas métricas estão representadas nas figuras 45 e 46 pelas linhas contínuas azul e vermelha (respectivamente) e indicam a tendência de variação em relação aos sujeitos de cada base para cada canal. A correlação entre elas está exposta no título de cada gráfico.

$$Melhora_{\%} = 100 \cdot \frac{TaxaAcertoM\'{e}dia_{SIF-ACRL} - TaxaAcertoM\'{e}dia_{cont}}{TaxaAcertoM\'{e}dia_{cont}} \quad (43)$$

Todos pares voluntário/canal apresentaram correlação positiva, com a maioria deles (75% dos pares) com mais de 50%. Apenas os canais 3, 5 e 12 (Não amputados) e 2, 8 e 11 (Amputados) tiveram índices menores de 50%. Em contrapartida, os pontos de medição 8 (Base 02) e 1, 3, 7 e 10 (Base 03) estiveram associados a valores de correlação acima de 80%. Por conseguinte, pode-se afirmar com mais segurança que a identificação do contaminante correto é importante não só para a correção do sistema (eliminação da causa raiz da interferência), mas também para o aumento na eficácia do processo de filtragem.

Figura 45 – Correlação entre a taxa de acerto do identificador de contaminantes e o acréscimo em valor percentual da taxa de acerto do classificador de movimentos (Base 02). A linha azul indica o índice de assertividade da identificação dos contaminantes e a vermelha se refere à melhora no reconhecimento dos gestos. O termo "Corr." indica o índice de correlação de Pearson entre as linhas.

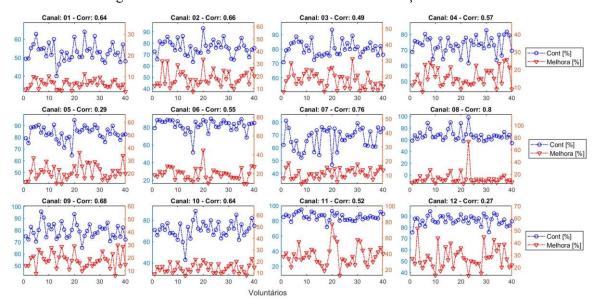
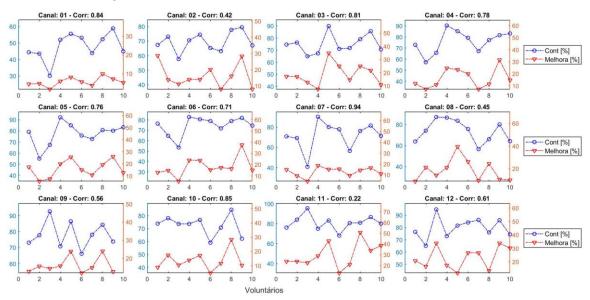


Figura 46 – Correlação entre a taxa de acerto do identificador de contaminantes e o acréscimo em valor percentual da taxa de acerto do classificador de movimentos (Base 03). A linha azul indica o índice de assertividade da identificação dos contaminantes e a vermelha se refere à melhora no reconhecimento dos gestos. O termo "Corr." indica o índice de correlação de Pearson entre as linhas.

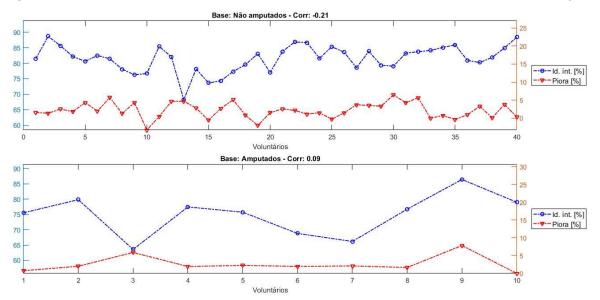


Por fim, objetivando a verificação da relação entre o impacto da aplicação do algoritmo proposto em sinais íntegros e a taxa de acerto do mesmo na identificação desta classe, realizouse análise similar à anterior, ou seja, calculou-se a correlação entre taxa de acerto da identificação de sinal íntegro e o decréscimo em valor percentual da taxa de acerto do classificador de movimentos. Os resultados estão expostos na Figura 47, onde as linhas azuis indicam a tendência de variação entre voluntários da taxa de acerto do SIF-ACRL no reconhecimento de sinal íntegro (cada ponto corresponde à média entre os canais) e as linhas vermelhas mostram a tendência de variação do percentual de decréscimo no índice de assertividade do classificador de movimentos em decorrência da aplicação do algoritmo (cada ponto neste gráfico foi computado segundo a Equação (44)). Cada gráfico está associado a uma das bases de dados.

$$Piora_{\%} = 100 \cdot \frac{TaxaAcerto_{integro} - TaxaAcerto_{SIF-ACRL}}{TaxaAcerto_{integro}}$$
(44)

Observa-se uma leve correlação negativa para a base de intactos e fraca correlação para a de amputados. O índice negativo, embora de apenas 21%, evidencia uma tendência de redução na piora da taxa de acerto do classificador de movimentos em virtude de um aumento no número de amostras de sinal íntegro identificadas corretamente (pelo menos para os indivíduos não amputados). Tal conclusão reforça a premissa de que filtragens desnecessárias podem ser prejudiciais ao desempenho do sistema.

Figura 47 – Correlação entre a taxa de acerto da identificação de sinal íntegro e o decréscimo em valor percentual da taxa de acerto do classificador de movimentos. A linha azul indica o índice de assertividade da identificação da classe sinal íntegro e a vermelha se refere à piora no reconhecimento dos gestos. O termo "Id. ínt." indica o índice de assertividade do SIF-ACRL associado a sinal íntegro.



No entanto, a fraca correlação vislumbrada para a Base 03 pode indicar que os dados deste *dataset* possuem uma quantidade maior de ruído, o que explicaria as situações nas quais observa-se menor impacto do SIF-ACRL nos resultados do sistema quando ele apresenta baixo índice de acerto na identificação do sinal íntegro, e vice-versa. Contudo, esta base, de fato, apresentou maiores índices de interferências do que a Base 02 no estudo realizado em (CHANG; PHINYOMARK; SCHEME, 2020) corroborando, assim, com esta teoria.

Em suma, verificou-se através do Experimento 02 que as duas hipóteses levantadas no início desta Seção (a de que o algoritmo proposto é capaz de melhorar a taxa de acerto do sistema quando 1 ou mais canais estiverem contaminados e a de que ele não afeta a performance do classificador quando o sinal não estiver corrompido) se confirmaram por meio dos resultados alcançados. Além disso, evidenciou-se a importância de se identificar o contaminante correto para o aumento na eficácia do processo de filtragem e o fato de que a aplicação de métodos de remoção de ruído de forma desnecessária pode causar danos ao processo de identificação de movimentos, sendo, portanto, desaconselhável.

5.3 EXPERIMENTO ONLINE

A fim de avaliar o potencial do método proposto de cumprir com os dois requisitos apontados na Seção 4.6 (determinar os parâmetros do Sistema de Inferência Fuzzy que gerenciará a atribuição de recompensa sem o acesso aos sinais do voluntário e propor uma estratégia para acelerar o treinamento do agente) e, consequentemente, estar apto a realizar o

treinamento online, foi projetado um terceiro experimento. Nele, foram utilizados os mesmos dados dos testes anteriores e o protocolo envolvendo o classificador de movimentos foi o mesmo do experimento conduzido na Seção 5.2.2, ou seja, o modelo preditor dos gestos utilizado aqui foi aquele obtido naquela oportunidade. A única diferença está, portanto, na determinação dos parâmetros do SIF-ACRL. Aqui serão considerados somente os dados de teste para o treinamento do agente sendo que, a cada iteração (nova amostra do sinal de sEMG) será verificado se o contaminante correto foi identificado ou não, e a saída (sinal filtrado ou não) será aplicada ao classificador de movimentos. Com isso, ter-se-á o monitoramento da evolução do aprendizado do SIF-ACRL e do impacto dele no reconhecimento dos gestos, simulando assim uma condição de aplicação online. Contudo, ressalta-se que, apesar deste experimento ter sido conduzido para validar a possibilidade de se realizar o treinamento online, todos os processamentos foram feitos de forma *off-line*.

Diante disso, o protocolo deste experimento é similar ao da Figura 38 para o teste com sinal contaminado e filtrado pelo SIF-ACRL, com a única diferença exatamente no bloco do algoritmo de pré-processamento proposto. Aqui, utilizou-se a abordagem inspirada no conceito de *Transfer Learning* apresentada na Seção 4.6 para o treinamento online do agente.

Os resultados alcançados com este experimento serão comparados (em termos da taxa de acerto do classificador de movimentos) com aqueles associados aos do experimento *off-line* (Seção 5.2.2) com sinal íntegro (não filtrado) e contaminado (não filtrado e submetido ao SIF-ACRL obtido de forma *off-line* por meio do experimento apresentado na Seção 5.2.1). Por conseguinte, a Tabela 9 apresenta as medianas e as distâncias interquartil das taxas de acerto de cada um dos testes mencionados anteriormente e o obtido com o deste após 5 episódios de treinamento do agente. Episódio, aqui, se refere ao processamento de todo o conjunto de teste.

Tabela 9 – Resultados de classificação de movimentos para cada base de dados. Os resultados com a mesma letra (dentro de cada base de dados) na última coluna pertencem à mesma distribuição segundo o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%.

AMPUTADOS				NÃO AMPUTADOS				
Protocolo	Mediana [%]	Q3-Q1 [%]		Protocolo	Mediana [%]	Q3-Q1 [%]		
Sinal íntegro	47,4	10,7	A	Sinal íntegro	62,9	9,8	A	
SIF-ACRL (off-line)	40,7	16,0	В	SIF-ACRL (off-line)	54,7	14,8	В	
SIF-ACRL (online)	38,7	13,4	C	SIF-ACRL (online)	53,2	13,3	C	
Sinal contaminado	34,9	17,4	D	Sinal contaminado	47,6	19,7	D	

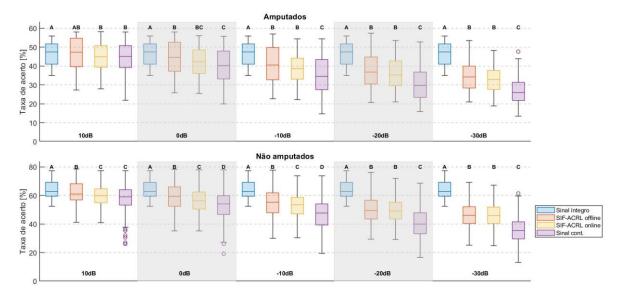
As medianas foram verificadas como significativamente distintas pelo teste de Mood (99% de nível de confiança). Além disso, todos os pares de distribuições também são estatisticamente diferentes pelo teste de Mann-Whitney-Wilcoxon com nível de confidência de

99%. Contudo, apesar disso notou-se uma pequena diferença entre o desempenho do algoritmo proposto treinado de forma online e *off-line* (2,0% - Amputados e 1,5% - Não amputados). Vale ressaltar que essa distância foi menor do que entre o SIF-ACRL (online) e sinal contaminado (3,8% e 5,6% para as bases 03 e 02, nesta ordem). Este resultado evidencia que, com pelo menos 5 episódios de treinamento, o agente foi capaz de quase igualar o desempenho do experimento 02.

Por outro lado, a variabilidade dos resultados associados à versão online do SIF-ACRL foi menor do que a *off-line*, de acordo com as distâncias interquartil registradas para ambas bases. Sinal íntegro obteve menor dispersão das taxas de acerto, enquanto que a sua versão contaminada a maior, tanto para voluntários intactos quanto para amputados.

Expandindo a análise do ponto de vista da intensidade da contaminação, constatou-se que, para os voluntários amputados, em todos SNR's não houve diferença estatística entre as distribuições dos resultados do SIF-ACRL *off-line* e online. Com nível de 10dB, a distância entre a taxa de acerto mediana do sinal íntegro e da versão online do algoritmo foi de 2,5% (em valor absoluto). Por outro lado, este último teve índice de acerto mediano igual ao do sinal contaminado. Todavia, para -20 e -30dB observou-se os melhores desempenhos do algoritmo proposto treinado com *Transfer Learning*, ficando muito próximo do *off-line*.

Figura 48 – Resultados de classificação de movimentos para cada base de dados em relação ao SNR e o tipo do teste. Os boxplot com a mesma letra (dentro de cada base de dados e para cada SNR) pertencem à mesma distribuição segundo o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%.



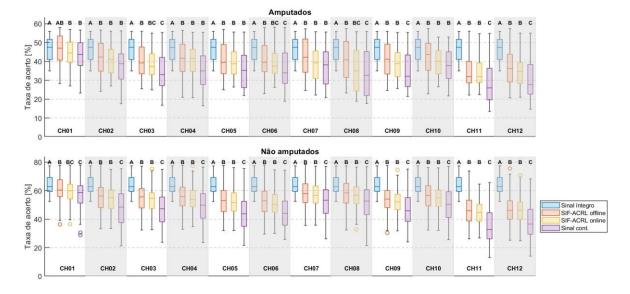
Para os sujeitos intactos, verificou-se comportamento similar. O algoritmo na versão online apresentou desempenho mais próximo ao *off-line* para contaminações mais severas

ficando um pouco mais distante para relações sinal-ruído mais elevados. Para SNR's de -20 e - 30dB os resultados do SIF-ACRL foram praticamente iguais. Essa tendência observada pode ser explicada pelo fato do agente ter mais facilidade em aprender amostras afetadas por interferências mais severas e, potencialmente, levar mais tempo (ou precisar de mais iterações) para adquirir conhecimento suficiente para classificar corretamente dados com contaminações mais brandas.

Contudo, deve-se ressaltar o fato de que para todas intensidades de ruído o SIF-ACRL conseguiu restabelecer de forma parcial o desempenho do classificador de movimentos após 5 episódios de treinamento.

Analisando o efeito do canal, notou-se que em todos eles não houve diferença estatística entre as distribuições dos resultados do algoritmo treinado de forma online e *off-line* (Figura 49). Entretanto, pode-se observar que para alguns pontos de medição a distância entre as taxas de acerto mediana foram bem pequenas, com destaque para os #2, 4, 5 e 11 (Base 03) e #2, 3, 11 e 12 (Base 02). Inclusive para o número 11 dos voluntários com amputação o SIF-ACRL obtido a partir de *Transfer Learning* superou o seu oponente. Em relação aos canais 11 e 12 (especialmente para os intactos), esta averiguação não chega a ser surpreendente, tendo em vista a maior facilidade que o método proposto teve para identificar contaminações nestes sensores (já destacada na Seção 5.2.2). Logo, é natural que o agente necessite de uma menor quantidade de iterações para aprender.

Figura 49 — Resultados de classificação de movimentos para cada base de dados em relação ao canal contaminado. Os boxplot com a mesma letra (dentro de cada base de dados e associados ao mesmo canal) pertencem à mesma distribuição segundo o teste de Mann-Whitney-Wilcoxon com nível de confiança de 99%.



Em contrapartida, os canais 1, 6, 7, 8 e 10 (amputados) e os 1, 4 e 6 (intactos) foram os que necessitavam de mais iterações de treinamento para que a implementação online alcançasse os resultados da forma alternativa. De fato, o ponto de medição 1 se mostrou o mais difícil de se classificar a fonte de interferência (pelas razões já exibidas na Seção 5.2.2), exigindo, desta forma, um tempo maior para o aprendizado pleno. Quanto aos outros sensores destacados, apesar da questão levantada, todos conseguiram uma significativa recuperação da taxa de acerto do classificador de movimentos (em relação àquela atingida com sinal contaminado).

Do ponto de vista da dispersão dos resultados, não se identificou diferença significativa entre as duas versões do SIF-ACRL em todos canais. Assim, a forma do treinamento do agente parece não influenciar a questão da variabilidade dentro de cada canal.

Até este ponto da análise, certificou-se que, com 5 episódios de treinamento, o agente foi capaz de atingir um nível de aprendizado no mínimo comparável com aquele considerado ótimo (obtido no experimento da Seção 5.2.1 e testado com o classificador de movimentos no teste da Seção 5.2.2) em termos do índice de assertividade do reconhecimento de gestos. Contudo, nada se pode afirmar acerca da evolução do desempenho do algoritmo neste período, tanto do ponto de vista da identificação dos contaminantes como dos movimentos.

Diante disso, as figuras 50 e 51 mostram as linhas de tendência do aprendizado do agente (azul) e o impacto dele no classificador de movimentos (vermelha) de cada canal para as bases 02 e 03, nesta ordem. Os gráficos de caixa azuis são formados pelas taxas de acerto do SIF-ACRL em cada episódio de treinamento, e os vermelhos pelos índices de assertividade da SVM também em cada época. Os pontos das linhas de tendência correspondem aos valores medianos dos boxplot.

Para os voluntários intactos (Figura 50) observou-se pequena variação ao longo dos episódios, tanto do ponto de vista dos contaminantes (máximo de 5,2% - canal 12) como dos movimentos (menos de 1% em todos pontos de medição). Já para os amputados (Figura 51), houve uma oscilação mais acentuada dos resultados do identificador de interferências com destaque para os canais 3, 9 e 11 que registraram aumento de 15,2%, 9,1 e 8,3% na taxa de acerto mediana, nesta ordem, entre o primeiro e o quinto episódio. A linha vermelha (gestos) se manteve praticamente constante ao longo das épocas (similar ao da outra base).

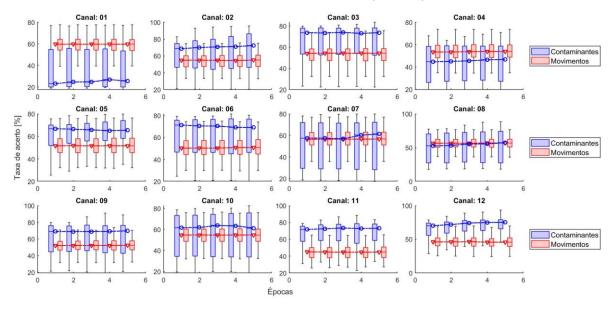
No tocante à propriedade de reconhecimento de fontes de ruído, comparando os resultados das figuras 50 e 51 com o da Figura 35 (Seção 5.2.1)² constatou-se maior diferença

,

² Aqui vale a ressalva de que no experimento da Seção 5.2.1 considerou-se os dados de todos os 40 voluntários da Base 02 e os 10 da 03. No entanto, neste experimento processou-se somente os sinais dos primeiros 30 e 7 voluntários das bases 02 e 03, nesta ordem.

entre as taxas de acerto mediana do SIF-ACRL online (no quinto episódio) e *off-line* nos canais 1, 4, 5, 6, 11 e 12 (intactos) e 5, 6, 7 e 8 (com amputação). As distâncias variaram de 8,5 (canal 12) a 32,6 (canal 7). Destes, destacam-se os pontos de medição 1, 4, 11 e 12 da Base 02 por apresentarem uma tendência de evolução. Provavelmente com mais algumas poucas épocas eles alcançariam o nível ótimo de aprendizado. Além disso, como já mencionado, o canal 1 esteve associado aos sinais mais difíceis de se identificar o contaminante, requerendo, naturalmente, maior tempo para o devido treinamento do modelo. Em contrapartida, os demais pares de sensores experimentaram uma queda no índice de assertividade entre a 1ª e a 5ª época. Nestas situações, o agente estava seguindo por um caminho errado e, por conseguinte, possivelmente demandaria uma maior quantidade de iterações para convergir.

Figura 50 – Evolução do aprendizado do agente ao longo dos episódios de treinamento e seu impacto no classificador de movimentos (Base 02).



No entanto, o canal 9 (não amputados) e os 4, 10 e 12 (amputados) tiveram resultados comparáveis nos testes online aos da versão *off-line*, apresentando uma redução menor do que 3%. Já os pontos de medição 2, 3, 7, 8 e 10 (intactos) e os 3, e 11 (participantes com subtração parcial do membro superior) demostraram uma melhora de desempenho após 5 episódios de treinamento, com destaque para o 2 e o 7 com aumento de 4,5 e 5,4%, respectivamente. Estas constatações são promissoras no sentido de validar a proposta de *Transfer Learning* e respalda a hipótese de que é possível treinar o agente sem o uso de dados previamente adquiridos do indivíduo (uma das condições fundamentais para a aplicabilidade do aprendizado online).

Ainda considerando estes mesmos canais, sobressaem-se os de número 2, 3, 7, 8, 9 e 10 da Base 02 por precisarem de apenas um episódio de treinamento para atingirem um índice de assertividade mediano comparável ao obtido com o experimento da Seção 5.2.1. Todos eles

apresentaram diferenças menores de 3% entre os dois tipos de testes. Isso quer dizer que, para estas situações, o SIF-ACRL levou apenas cerca de 2 minutos e 50 segundos para o ajuste dos parâmetros das redes neurais do ator e do crítico (que é o tempo estimado para a execução de 2 repetições dos 17 movimentos segundo o protocolo utilizado pela equipe do projeto Ninapro). Este fato, por sua vez, contribui na verificação da propriedade do método de *Transfer Learning* proposto de acelerar o treinamento do agente (segunda condição fundamental para a aplicabilidade do aprendizado online), pelo menos para estes canais.

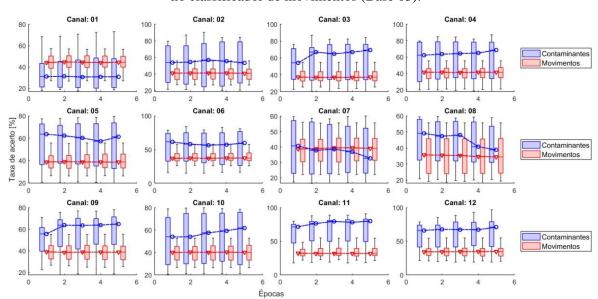


Figura 51 – Evolução do aprendizado do agente ao longo dos episódios de treinamento e seu impacto no classificador de movimentos (Base 03).

Por fim, notou-se ainda que a taxa de acerto do classificador de movimentos se manteve praticamente constante ao longo dos episódios para todos os canais e bases de dados. Isso pode induzir que o desempenho do sistema principal (identificação da intenção de movimento do usuário da prótese) sofreu pouca ou quase nenhuma influência do período de aprendizado do agente. Esta conclusão é respaldada pelas análises anteriores dos resultados expostos nas figuras 48 e 49 e Tabela 9 e é mais um indicativo de que o SIF-ACRL tem potencial para ser aplicado de forma online dentro deste contexto.

Em suma, o experimento apresentado nesta seção foi importante para evidenciar o potencial do método proposto de cumprir com os desafios lançados anteriormente e que eram premissas básicas para a aplicabilidade do aprendizado online (treinamento sem o acesso a dados prévios do voluntário e redução do tempo gasto por ele). Os resultados promissores alcançados respaldam a sequência do estudo neste sentido.

Contudo, vale a ressalva de que ainda devem ser estudados outros fatores que, embora não estejam associados diretamente com a mecânica do algoritmo proposto, também são importantes para a aplicabilidade do sistema de forma online. Aqui pode-se citar o tempo gasto no cômputo das características, a quantidade de memória exigível, dentre outros. Estes tópicos serão aprofundados no prosseguimento deste trabalho.

5.4 TRABALHOS RELACIONADOS

A Tabela 10 mostra os resultados relatados por trabalhos anteriores no reconhecimento do tipo de contaminante em registros de EMG. Aqui as pesquisas foram classificadas de acordo com a estratégia de treinamento do modelo proposto em supervisionado ou não e online ou *off-line*. Deste modo, os resultados associados ao algoritmo proposto foram apresentados tanto na condição online (Seção 5.3) como *off-line* (Seção 5.2.1). Além disso, só foram considerados aqueles associados à Base 02. Vale ressaltar também que os outros trabalhos consideraram o valor médio para relatar os resultados, enquanto o valor mediano foi a melhor opção aqui e no artigo publicado (TOSIN; BALBINOT, 2022), tendo em vista que a média não representa uma tendência central adequada devido à não normalidade dos dados.

Tabela 10 – Resultados de artigos relacionados na área de identificação de contaminantes. Na tabela: o termo "TxAc" refere-se à taxa de acerto média relatada no respectivo artigo no melhor cenário, SA é saturação do amplificador, CN é ruído correlacionado, MixA é a composição de mais de um ruído.

*Resultados expressos pela mediana.

Autores	Estratégia	Método	Tipo de contaminante	SNR [dB]	TxAc (SNR) [%]	
(MACHADO; MACHADO; BALBINOT, 2021)	Supervisionado / off-line	RNN-LSTM	MOA, WGN, PLI, ECG	-40 a 20	87,0 (-40) 99,5 (-20) 45,7 (0) 20,0 (20)	
(MCCOOL et al., 2014)	Supervisionado / off-line	SVM	SA, WGN, PLI, ECG, MOA	-20 a 20	99,6 (-20) 97,8 (-10) 46,7 (0) 23,0 (10) 20,4 (20)	
(IJAZ; CHOI, 2018)	Não supervisionado / off-line	rPCA-SOM	CN, WGN, PLI, ECG, MixA	Não informado	88,2	
(TOSIN; BALBINOT, 2022)	Não supervisionado / off-line	SIF-ACRL	MOA, WGN, PLI, ECG	-30 a 10	98,5* (-30) 97,9* (-20) 94,6* (-10) 85,2* (0) 65,1* (10)	
Este trabalho	Não supervisionado / off-line	SIF-ACRL	MOA, WGN, PLI, ECG	-30 a 10	77,5* (-30) 73,1* (-20) 66,1* (-10) 69,6* (0) 55,6* (10)	
Este trabalho	Não supervisionado / online	SIF-ACRL	MOA, WGN, PLI, ECG	-30 a 10	76,0* (-30) 73,4* (-20) 66,2* (-10) 46,4* (0) 26,7* (10)	

Deve-se levar em conta que as diferenças no número e tipo de interferências analisadas, nível de contaminação, comprimento da janela, entre outros, inviabilizam uma comparação direta entre os algoritmos. No entanto, apesar disso, eles são uma boa referência para o reconhecimento de contaminantes em diferentes SNR's.

Nesse contexto, o algoritmo SIF-ACRL treinado de forma *off-line* parece operar melhor sob contaminações mais brandas, apresentando melhores resultados em 0 e 10dB do que as estratégias supervisionadas (MACHADO; MACHADO; BALBINOT, 2021; MCCOOL *et al.*, 2014). No entanto, vale ressaltar que Machado *et al.* (2021) também classificaram os sinais de repouso, que são, como já mencionado, mais fáceis de se identificar o contaminante, enquanto que aqui utilizou-se somente os dados de movimento da base Ninapro. Isso também ajuda a explicar a diferença entre os índices de assertividade deste trabalho com o do artigo de publicação da SIF-ACRL (lá considerou-se também os dados de repouso).

Ainda levando em conta estas intensidades de contaminação, a versão online do método proposto obteve resultados comparáveis aos das versões supervisionadas e *off-line* (MACHADO; MACHADO; BALBINOT, 2021; MCCOOL *et al.*, 2014), apesar das considerações feitas anteriormente acerca dos sinais processados por Machado *et al.* (2021). Já para contaminações mais severas (SNR menores do que 0dB) o SIF-ACRL sentiu mais o efeito de não considerar os sinais de repouso, apresentando taxas de acerto inferiores aos de seus oponentes. Todavia, ao considerar-se a implementação *off-line* do algoritmo no artigo publicado, os resultados foram comparáveis aos métodos supervisionados para estes SNR's, o que evidencia que o SIF-ACRL funciona bem também em situações mais críticas de ruído.

Ijaz e Choi (2018) relataram índices de acerto interessantes no reconhecimento de cinco classes de interferências por meio de sua metodologia baseada em rPCA-SOM. Esta abordagem foi a mais próxima da apresentada aqui em termos de estratégia de aprendizagem. Entretanto, a ausência de informações sobre o nível de contaminação dificulta uma comparação com o presente trabalho.

Contudo, a fim de contextualizar o desempenho do algoritmo proposto com aqueles já reportados por outras estratégias que visam a minimização da ação de contaminantes em sistemas de classificação de movimentos, reuniu-se na Tabela 11 os resultados dos principais trabalhos da área. Aqui, novamente, os resultados associados ao SIF-ACRL foram apresentados tanto na condição online (Seção 5.3) como *off-line* (Seção 5.2.2). Nesta análise, as mesmas ressalvas feitas anteriormente sobre as diferenças entre as pesquisas devem ser levadas em conta, o que impede uma comparação direta entre os algoritmos. Contudo, apesar disso, eles

são uma boa referência para o impacto de contaminantes em diferentes SNR's na taxa de acerto do classificador de movimentos.

Tabela 11 – Resultados de artigos relacionados na área de classificação de movimentos. Na tabela: o termo "TxAc" refere-se à taxa de acerto média relatada no respectivo artigo no melhor cenário, Carac. indica características, TD é domínio do tempo, Mov. se refere a quantidade de movimentos, SA é saturação do amplificador. *Resultados expressos pela mediana.

Autores	Etapa	Estratégia	Método	Carac.	Mov.	Tipo cont.	SNR [dB]	Class.	TxAc [%]
(MACHADO et al., 2019)	Pré- processamento	Estimação de sensor virtual	RNN-LSTM	1 TD	17	SA	Não informado	SVM	66,5
(STACHACZYK et al., 2020)	Pré- processamento	Semelhança espectro-temporal	Adaptive Spatial Filter	Não	4	AWGN PLI	Não informado	LDA	84,5
(MCCOOL et al., 2015)	Pré- processamento	Subtração espectral	IMCRA-based Spectral Enhancement	5 TD	7	AWGN	-10 a 0	SVM	59,9 a 82,4
(TEH; HARGROVE, 2021)	Extração de características	Projeção do sinal de sEMG	VAE	4 TD	7	Flatlined signal	Não informado	LDA	>90,0
Este trabalho.	Pré- processamento	Identificação do contaminante	SIF-ACRL (off-line)	4 TD	17	MOA, WGN, PLI, ECG	-30 a 10	SVM	46,1* a 61,1*
Este trabalho.	Pré- processamento	Identificação do contaminante	SIF-ACRL (online)	4 TD	17	MOA, WGN, PLI, ECG	-30 a 10	SVM	45,9* a 59,9*

Em suma, os resultados aqui apresentados são promissores e comparáveis com outros estudos. McCool *et al.* (2015) relataram uma precisão de 82,4% na classificação de 7 movimentos com 7 canais de sEMG contaminados com ruído gaussiano branco aditivo a 0dB e filtrados pelo método IMCRA-*based Spectral Enhancement*. Esse resultado foi 9,6% menor que a classificação com sinais limpos, enquanto que o SIF-ACRL apresentou redução de 3,7 e 6,7% para este SNR sob treinamento *off-line* e online, respectivamente. No entanto, deve-se levar em conta que em (MCCOOL *et al.*, 2015) o índice de assertividade do classificador foi maior do que o obtido aqui (92,0 a 62,9%), o que pode ser explicada pela diferença no número de movimentos considerados (7 a 17). Logo, o impacto de ruído no sinal é maior naquele caso do que neste.

Por outro lado, Machado *et al.* (2019) (que utilizaram a mesma base de dados) obteve uma precisão média de 66,1% no reconhecimento de 17 movimentos de 12 canais. No experimento, um canal foi contaminado por saturação e restaurado pela aplicação de um sensor virtual gerado a partir de uma rede LSTM. Este resultado foi 7,9% inferior ao obtido com sinais limpos. No entanto, o SNR não foi informado.

Os melhores resultados estão associados com o trabalho de Teh e Hargrove (2021). Contudo, eles também não informaram a intensidade da contaminação além de considerarem o efeito de somente uma interferência. Neste quesito, o experimento que mais se aproxima do conduzido aqui é o de Stachaczyk *et al.* (2020) onde considerou-se os ruídos da linha de energia

(PLI) e branco Gaussiano aditivo (AWGN). Entretanto, apesar dos promissores resultados reportados, eles também não especificaram o SNR da contaminação o que inviabiliza o estabelecimento de comparações com os apresentados aqui.

Em resumo, a despeito da dificuldade em se estabelecer comparações entre os trabalhos listados na Tabela 11 e respeitando os limites impostos pelas peculiaridades de cada um deles, pode-se afirmar que, ao menos, os resultados aqui apresentados estão coerentes com os observados na literatura.

6 CONSIDERAÇÕES FINAIS

Neste trabalho de doutorado, propôs-se um algoritmo para identificação de contaminantes em sinais de sEMG e minimização do efeito deles em sistemas de identificação de movimentos aplicáveis a dispositivos mio-controlados. Os resultados promissores aqui alcançados, demostraram a capacidade do SIF-ACRL reconhecer até as contaminações mais brandas (SNR maior de 0dB) com taxas de acerto superiores às de outras propostas.

Além disso, os testes simulando o treinamento online do agente evidenciou que o modelo de *Transfer Learning* adotado foi eficaz na dispensa da necessidade do uso de dados adquiridos previamente do usuário além de acelerar o processo de aprendizado. Estas propriedades são fundamentais para a implementação de qualquer sistema de forma online. Logo, comprovou-se que o SIF-ACRL tem, de fato, potencial para ser implementado de forma online. Esta propriedade é a principal contribuição desta tese de doutorado, visto que nenhuma das propostas atuais para este problema possuem esta característica (dentro do alcance da pesquisa realizada). Não obstante, o tempo demandado para a calibração do dispositivo mio-controlado com aquisições de dados e posterior treinamento *off-line* do sistema é extremamente desagradável para os usuários. Logo, a possibilidade de eliminação dessa etapa, pelo menos no tocante ao algoritmo de pré-processamento, já é um ganho considerável.

Contudo, como já destacado na Seção 5.3, vale a ressalva de que ainda devem ser estudados outros fatores que, embora não estejam associados diretamente com a mecânica do algoritmo proposto, também são importantes para a aplicabilidade do sistema de forma online.

Por fim, uma terceira contribuição deste trabalho é a formação da versão 02 da Base do IEE com sinais adquiridos em condições não ideais, reproduzindo possíveis fontes de contaminação que podem ocorrer com o uso pleno do dispositivo mio-controlado. Dentro do alcance da pesquisa conduzida, este é o primeiro repositório proposto com esta finalidade e que consideram os fatores eletrodo mal colado, cansaço muscular e artefato de movimento durante a execução de uma série de movimentos.

Diante disso, este projeto será continuado com os seguintes focos:

- Prosseguimento das aquisições da versão 02 da Base do IEE. Estudar a inclusão de outros fatores contaminantes;
- Prosseguir com a investigação associada à implementação online do algoritmo.
 Avaliar o tempo de processamento do método e complexidade do código propondo estratégias de otimização;

- Investigação dos procedimentos utilizados para remoção dos contaminantes do sinal, visando aumentar o percentual de recuperação da taxa de acerto do classificador de movimentos;
- 4) Avaliar a possibilidade de incluir a informação do tipo de contaminante como entrada no classificador de movimentos.

7 ARTIGOS PUBLICADOS NA ÁREA

Artigo de publicação da Base de Dados do IEE

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.

Artigo referente a aplicação de diferentes estratégias de seleção de características na identificação de movimentos do segmento mão-braço

Autores: Mauricio Tosin, Vinicius Horn Cene, Alexandre Balbinot

Título: STATISTICAL FEATURE AND CHANNEL SELECTION FOR UPPER LIMB

CLASSIFICATION USING SEMG SIGNAL PROCESSING

Periódico/Conferência: RESEARCH ON BIOMEDICAL ENGINEERING

Editora: Springer

DOI: 10.1007/s42600-020-00080-w

Ano: 2020

Abstract: Feature and channel selection stage plays an important role in identifying movement intent through surface electromyography (sEMG), once the best feature or features set and channel ensemble is still an open topic in this research field. In this work, we present three different strategies to feature and channel selection used in movement recognition through sEMG processing. This paper analyzes the feature selection stage, considering the relevance of each feature-channel pair to movement characterization. Three feature selection methods based on support vector machine recursive feature elimination (SVM-RFE), Monte Carlo feature selection, and singular value decomposition (SVD) entropy that are benchmark techniques for DNA microarray data analysis formed a ranking of feature/channel pairs. The ranking, organized according to their importance to movement classification, forms a heuristic for a wrapper method based feature selection algorithm, which uses the regularized extreme learning machine (RELM) classifier for the movement recognition. To test the proposed methods, we used the NINAPro Databases 2 and 3 (40 intact and 10 amputee volunteers, respectively). The results derived from the technique reached average accuracies of 84.9%, 84.0%, and 83.9% for the SVM-RFE, Monte Carlo, and SVD entropy ranking methods, respectively, for database 2. At the same time, the same methods achieved 74.8%, 74.5%, and 74.1% of accuracy for database 3, respectively. In terms of most selected features, zero crossings (TZC), mean frequency (FMN), signal slope changes (TSLPCH2), and power (TPWR) were the most frequently selected. The results obtained showed no statistically significant difference among the three feature selection algorithms implemented regarding the classification accuracy. The introduction of the pre-processing steps in the classification process provided promising classification accuracy levels, outperforming the results presented by related works with the same NINAPro database.

Artigo sobre a aplicação do algoritmo proposto como identificador de contaminantes

Autores: Maurício Tosin, Alexandre Balbinot

Título: *IDENTIFICATION AND REMOVAL OF CONTAMINANTS IN SEMG RECORDINGS*THROUGH A METHODOLOGY BASED ON FUZZY INFERENCE AND ACTOR-CRITIC
REINFORCEMENT LEARNING

Periódico/Conferência: EXPERT SYSTEMS WITH APPLICATIONS

Editora: Elsevier

DOI: 10.1016/j.eswa.2022.117772

Ano: 2022

Abstract: Purpose: Contaminants in surface electromyography (sEMG) recordings might configure an issue if not kept at lower levels since they can impair the extraction of information. In this context, several approaches have been proposed to minimize the effects of specific contaminants. However, knowing the type of interference is important to improve the system efficiency and avoid deformation in the EMG signal by unnecessary filtering. Thereby, this paper proposes a new strategy to recognize and minimize four contaminants commonly found in sEMG recordings (motion artifact, electrocardiography, powerline interference, and additive white Gaussian noise). Methods: An Actor-Critic Reinforcement Learning model with a Fuzzy Inference System (FIS)-based reward function (FIS-ACRL) was designed for contaminant identification and removal. The ACRL model consists of an environment (sEMG), a state (represented by a set of six handcrafted features), a set of actions (four filters/ methodologies to remove each contaminant), and an actor and a critic (formed by two neural networks). A reward is assigned to the agent actions through a FIS, where the inputs are determined according to the impact of the action in the features, and the defuzzified output configures a score that is, in turn, converted to the proper reward. Results: The ACRL model evaluation was through a supervised experiment (the reward assigning was from the correct label), achieving an overall median accuracy of 93.13% at classifying the four contaminants with Signal- to-Noise Ratio (SNR) ranging from -30 to 10 dB in steps of 10 dB. The FIS-ACRL performance assessment was through an unsupervised experiment in the same dataset. It was obtained 92.60% of median accuracy, out-performing three typical clustering algorithms (k-Means, Self-Organizing Map (SOM)-k-Means, and SOM-Ward). Conclusion: The results validate the proposed strategy, showing that it is possible to identify the contaminant type through unsupervised and continuous learning, besides automatically executing the correct procedure to mini- mize it. Moreover, the nature of ACRL theory enables the continuous adaptation of the agent learning over the environment changes.

Artigo de revisão apresentando o estudo do estado da arte realizado neste trabalho de doutorado

Autores: Maurício Tosin, Juliano Machado, Alexandre Balbinot

Título: sEMG-BASED UPPER LIMB MOVEMENT CLASSIFIER: CURRENT SCENARIO

AND UPCOMING CHALLENGES

Periódico/Conferência: JOURNAL OF ARTIFICIAL INTELLIGENCE RESEARCH

Editora: AI Access Foundation

DOI: 10.1613/jair.1.13999

Ano: 2022

Abstract: Despite achieving accuracies higher than 90% on recognizing upper-limb movements through sEMG (surface Electromyography) signal with the state of art classifiers in the laboratory environment, there are still issues to be addressed for a myo-controlled prosthesis achieve similar performance in real environment conditions. Thereby, the main goal of this review is to expose the latest researches in terms of strategies in each block of the system, giving a global view of the current state of academic research. A systematic review was conducted, and the retrieved papers were organized according to the system step related to the proposed method. Then, for each stage of the upper limb motion recognition system, the works were described and compared in terms of strategy, methodology and issue addressed. An additional section was destined for the description of works related to signal contamination that is often neglected in reviews focused on sEMG based motion classifiers. Therefore, this section is the main contribution of this paper. Deep learning methods are a current trend for classification stage, providing strategies based on time-series and transfer learning to address the issues related to limb position, temporal/inter-subject variation, and electrode displacement. Despite the promising strategies presented for contaminant detection, identification, and removal, there are still some factors to be considered, such as the occurrence of simultaneous contaminants. This review exposes the current scenario of the movement classification system, providing valuable information for new researchers and guiding future works towards myocontrolled devices.

Artigo sobre a aplicação do algoritmo proposto na minimização do efeito de contaminantes em sistemas de classificação de movimentos

Autores: Mauricio Tosin, Leia Bagesteiro, Alexandre Balbinot

Título: ACTOR-CRITIC REINFORCEMENT LEARNING BASED ALGORITHM FOR

CONTAMINANT MINIMIZATION IN SEMG MOVEMENT RECOGNITION

Periódico/Conferência: 44th ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE

ENGINEERING IN MEDICINE & BIOLOGY SOCIETY (EMBC)

Editora: IEEE

DOI: 10.1109/EMBC48229.2022.9871412

Ano: 2022

Abstract: This paper aims to present an approach based on Reinforcement Learning (RL) concept to detect contaminants' type and minimize their effect on surface electromyography signal (sEMG) based movement recognition. The referred method was applied in the preprocessing stage of a sEMG based motion classification system using the Ninapro database 2 artificially contaminated with electrocardiography (ECG) interference, motion artifact (MOA), powerline interference (PLI) and additive white Gaussian noise (WGN). Support Vector Machine was the method for movement classification. The results showed an improvement of 8.9%, 16.7%, 15.9%, 16.5%, and 11.9% in the movement recognition accuracy with the application of the pre-processing algorithm to restore, respectively, one, three, six, nine, and 12 contaminated channels.

REFERÊNCIAS BIBLIOGRÁFICAS

ADRIAN, E. D.; BRONK, D. W. The discharge of impulses in motor nerve fibres. **The Journal of Physiology**, v. 67, n. 2, p. 119–151, 1929.

ALVARADO, R. U. A Bibliometria no Brasil. **Ciência da Informação**, v. 13, n. 2, p. 91–105, 1984.

AMERI, A. et al. A Deep Transfer Learning Approach to Reducing the Effect of Electrode Shift in EMG Pattern Recognition-Based Control. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 28, n. 2, p. 370–379, 2020.

AMEZQUITA-GARCIA, J. A. et al. **Hand Movement Detection from Surface Electromyography Signals by Machine Learning Techniques**. VIII Latin American

Conference on Biomedical Engineering. **Anais**...Cancún, México: Springer, 2019

ANAM, K. et al. **Finger Movement Regression with Myoelectric Signal and Deep Neural Network**. 2019 International Conference on Computer Science, Information Technology, and Electrical Engineering (ICOMITEE). **Anais**...Jember, Indonesia: IEEE, out. 2019Disponível em: https://ieeexplore.ieee.org/document/8920934/>

ASGHARI OSKOEI, M.; HU, H. Myoelectric control systems—A survey. **Biomedical Signal Processing and Control**, v. 2, n. 4, p. 275–294, out. 2007.

ATZORI, M. et al. **Building the Ninapro database: A resource for the biorobotics community**. 2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob). **Anais**...Rome, Italy: IEEE, jun. 2012Disponível em: http://ieeexplore.ieee.org/document/6290287/

ATZORI, M. et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. **Scientific data**, v. 1, p. 1–13, 2014.

ATZORI, M. et al. Characterization of a Benchmark Database for Myoelectric Movement Classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 23, n. 1, p. 73–83, jan. 2015.

ATZORI, M. et al. Effect of clinical parameters on the control of myoelectric robotic prosthetic

hands. **Journal of Rehabilitation Research and Development**, v. 53, n. 3, p. 345–358, 2016.

ATZORI, M.; MULLER, H. The Ninapro database: A resource for sEMG naturally controlled robotic hand prosthetics. Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS. Anais...2015

ATZORI, M.; MULLER, H. Control capabilities of myoelectric robotic prostheses by hand amputees: A scientific research and market overview. **Frontiers in Systems Neuroscience**, v. 9, n. Nov, p. 1–7, 2015.

BENAZZOUZ, A.; SLIMANE, Z. E. H. Knee pathology diagnosis based on muscle activation intervals detection and the relationship between knee flexion and surface EMG. **International Journal of Medical Engineering and Informatics**, v. 13, n. 1, p. 14, 2021.

BENBRAHIM, H.; FRANKLIN, J. A. Biped dynamic walking using reinforcement learning. **Robotics and Autonomous Systems**, v. 22, n. 3–4, p. 283–302, dez. 1997.

BESOMI, M. et al. Consensus for Experimental Design in Electromyography (CEDE) project: Electrode selection matrix. **Journal of Electromyography and Kinesiology**, v. 48, n. April, p. 128–144, 2019.

BOS, R. A. et al. A Case Study With Symbihand: An sEMG-Controlled Electrohydraulic Hand Orthosis for Individuals With Duchenne Muscular Dystrophy. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 28, n. 1, p. 258–266, jan. 2020.

BOUTERAA, Y.; ABDALLAH, I. BEN; ELMOGY, A. M. Training of Hand Rehabilitation Using Low Cost Exoskeleton and Vision-Based Game Interface. **Journal of Intelligent & Robotic Systems**, v. 96, n. 1, p. 31–47, 5 out. 2019.

BOZHENYUK, A.; BOZHENIUK, V.; KHAMIDULINA, A. Modeling of a Motion of Hand Prosthesis Based on the Fuzzy Deductive Inference Scheme. 9th International Conference on Application of Information and Communication Technologies (AICT). Anais...2015

CAMPBELL, E.; PHINYOMARK, A.; SCHEME, E. Current Trends and Confounding Factors in Myoelectric Control: Limb Position and Contraction Intensity. **Sensors**, v. 20, n. 6, p. 1–44, 13 mar. 2020.

CENE, V. et al. Open Database for Accurate Upper-Limb Intent Detection Using

Electromyography and Reliable Extreme Learning Machines. **Sensors**, v. 19, n. 8, p. 1864, 18 abr. 2019.

CENE, V. H. Desenvolvimento de um projeto de experimentos para a caracterização de sinais mioelétricos através do uso de regressão logística. [s.l.] UFRGS, 2016.

CHANG, C.-C.; LIN, C.-J. LIBSVM: A Library for Support Vector Machines. **ACM Transactions on Intelligent Systems and Technology (TIST)**, v. 2, n. 3, 2011.

CHANG, J.; PHINYOMARK, A.; SCHEME, E. Assessment of EMG Benchmark Data for Gesture Recognition Using the NinaPro Database. Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS. Anais...Montreal, CA: 2020

CHEN, C. et al. Hand gesture recognition based on motor unit spike trains decoded from high-density electromyography. **Biomedical Signal Processing and Control**, v. 55, p. 1–7, jan. 2020.

CIFREK, M.; TONKOVIĆ, S.; MEDVED, V. Measurement and analysis of surface myoelectric signals during fatigued cyclic dynamic contractions. **Measurement**, v. 27, n. 2, p. 85–92, mar. 2000.

COGNOLATO, M. et al. Gaze, visual, myoelectric, and inertial data of grasps for intelligent prosthetics. **Scientific Data**, v. 7, n. 43, p. 1–15, 2020.

CRITES, R. H.; BARTO, A. G. Improving Elevator Performance Using Reinforcement Learning. **Advances in neural information processing systems**, v. 8, p. 1017–1023, 1996.

DAVID, T. M. et al. Future research tendencies for solar energy management using a bibliometric analysis, 2000–2019. **Heliyon**, v. 6, n. 7, p. e04452, jul. 2020.

DE LUCA, C. J. Physiology and Mathematics of Myoelectric Signals. **IEEE Transactions on Biomedical Engineering**, v. BME-26, n. 6, p. 313–325, jun. 1979.

DE LUCA, C. J. The Use of Surface Electromyography in Biomechanics. **Journal of Applied Biomechanics**, v. 13, n. 2, p. 135–163, 1 maio 1997.

DE LUCA, C. J. et al. Filtering the surface EMG signal: Movement artifact and baseline noise

contamination. **Journal of Biomechanics**, v. 43, n. 8, p. 1573–1579, maio 2010.

DE MOURA, K. DE O. A.; BALBINOT, A. Virtual sensor of surface electromyography in a new extensive fault-tolerant classification system. **Sensors (Switzerland)**, v. 18, n. 5, 2018.

DEWALD, H. A. et al. Stable, three degree-of-freedom myoelectric prosthetic control via chronic bipolar intramuscular electrodes: a case study. **Journal of NeuroEngineering and Rehabilitation**, v. 16, n. 1, p. 1–13, 21 dez. 2019.

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**, v. 22, n. 4, p. 797–809, jul. 2014.

FARINA, D.; MERLETTI, R.; ENOKA, R. M. The extraction of neural strategies from the surface EMG. **Journal of Applied Physiology**, v. 96, n. 4, p. 1486–1495, abr. 2004.

FARINA, D.; NEGRO, F. Accessing the neural drive to muscle and translation to neurorehabilitation technologies. **IEEE Reviews in Biomedical Engineering**, v. 5, p. 3–14, 2012.

FAVIEIRO, G. W. Desenvolvimento De Um Sistema Neuro-Fuzzy Para Análise De Sinais Mioelétricos Do Segmento Mão-Braço. [s.l.] UFRGS, 2012.

FAVIEIRO, G. W.; BALBINOT, A. Paraconsistent Random Forest: An Alternative Approach for Dealing With Uncertain Data. **IEEE Access**, v. 7, p. 147914–147927, 2019.

FRASER, G. D. et al. CleanEMG - Power line interference estimation in sEMG using an adaptive least squares algorithm. 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Anais...Boston, MA, USA: IEEE, ago. 2011Disponível em: http://ieeexplore.ieee.org/document/6091958/>

FRASER, G. D. et al. **Removal of electrocardiogram artifacts in surface electromyography using a moving average method**. 2012 IEEE Symposium on Medical Measurements and Applications, Proceedings. **Anais**...Budapest, Hungary: IEEE, 2012a

FRASER, G. D. et al. **Detection of ADC clipping, quantization noise, and amplifier saturation in surface electromyography**. 2012 IEEE International Symposium on Medical Measurements and Applications Proceedings. **Anais**...Budapest, Hungary: IEEE, maio

2012bDisponível em: http://ieeexplore.ieee.org/document/6226629/

FRASER, G. D. et al. **Biosignal quality analysis of surface EMG using a correlation coefficient test for normality**. MeMeA 2013 - IEEE International Symposium on Medical Measurements and Applications, Proceedings. **Anais**...Gatineau, QC, Canada: 2013

FRASER, G. D. et al. Automated biosignal quality analysis for electromyography using a oneclass support vector machine. **IEEE Transactions on Instrumentation and Measurement**, v. 63, n. 12, p. 2919–2930, 2014.

FRONSO, S. DI et al. Performance Optimization in Sport: A Psychophysiological Approach. **Motriz: Revista de Educação Física**, v. 23, n. 4, p. 1–7, 27 nov. 2017.

GOLDBERGER, A. L. et al. PhysioBank, PhysioToolkit, and PhysioNet. **Circulation**, v. 101, n. 23, 13 jun. 2000.

HALL, J. E.; GUYTON, A. C. **Tratado de Fisiologia Médica**. 12a. ed. ed. Rio de Janeiro: Elsevier Editora Ltda., 2011.

HAMAYA, M. et al. Learning task-parametrized assistive strategies for exoskeleton robots by multi-task reinforcement learning. 2017 IEEE International Conference on Robotics and Automation (ICRA). Anais...Singapore, Singapore: IEEE, maio 2017Disponível em: http://ieeexplore.ieee.org/document/7989695/>

HE, J. et al. A Novel Framework Based on Position Verification for Robust Myoelectric Control Against Sensor Shift. **IEEE Sensors Journal**, v. 19, n. 21, p. 9859–9868, 1 nov. 2019.

IJAZ, A.; CHOI, J. Anomaly Detection of Electromyographic Signals. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 26, n. 4, p. 770–779, 2018.

ISON, M.; ARTEMIADIS, P. The role of muscle synergies in myoelectric control: trends and challenges for simultaneous multifunction control. **Journal of Neural Engineering**, v. 11, n. 5, p. 051001, 2014.

JIA, G. et al. Classification of electromyographic hand gesture signals using machine learning techniques. **Neurocomputing**, v. 401, n. xxxx, p. 236–248, ago. 2020.

JUDGE, L.; MOREAU, C.; BURKE, J. Neural adaptations with sport-specific resistance

training in highly skilled athletes. **Journal of Sports Sciences**, v. 21, n. 5, p. 419–427, jan. 2003.

KACZMAREK, P.; MAŃKOWSKI, T.; TOMCZYŃSKI, J. putEMG—A Surface Electromyography Hand Gesture Recognition Dataset. **Sensors**, v. 19, n. 16, p. 3548, 14 ago. 2019.

KIM, K.-T.; GUAN, C.; LEE, S.-W. A Subject-Transfer Framework Based on Single-Trial EMG Analysis Using Convolutional Neural Networks. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 28, n. 1, p. 94–103, jan. 2020.

KONRAD, P. **ABC** of **EMG** – **A** Practical Introduction to Kinesiological Electromyography. [s.l.] Noraxon INC. USA., 2005.

KRASOULIS, A.; VIJAYAKUMAR, S.; NAZARPOUR, K. Multi-Grip Classification-Based Prosthesis Control with Two EMG-IMU Sensors. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 28, n. 2, p. 508–518, 2020.

LU, Z. et al. Myoelectric Pattern Recognition for Controlling a Robotic Hand: A Feasibility Study in Stroke. **IEEE Transactions on Biomedical Engineering**, v. 66, n. 2, p. 365–372, fev. 2019.

MA, J. et al. Mirror-Training of a Cable- Driven Hand Rehabilitation Robot Based on Surface Electromyography (sEMG). 2019 Tenth International Conference on Intelligent Control and Information Processing (ICICIP). Anais...Marrakesh, Morocco: IEEE, dez. 2019Disponível em: https://ieeexplore.ieee.org/document/9012217/>

MACHADO, J. et al. Recurrent Neural Network for Contaminant Type Detector in Surface Electromyography Signals. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Anais...Montreal, CA: IEEE, jul. 2020Disponível em: https://ieeexplore.ieee.org/document/9175348/>

MACHADO, J. C. Proposta para o uso de redes recorrentes na estimação de um sensor virtual em eletromiografia no contexto de um sistema tolerante a falhas. [s.l.] Universidade Federal do Rio Grande do Sul, 2019.

MACHADO, J. C.; CENE, V. H.; BALBINOT, A. Recurrent Neural Network as Estimator

for a Virtual sEMG Channel. 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). **Anais**...Berlin, Germany: IEEE, jul. 2019Disponível em: https://ieeexplore.ieee.org/document/8857462/>

MACHADO, J.; MACHADO, A.; BALBINOT, A. Deep learning for surface electromyography artifact contamination type detection. **Biomedical Signal Processing and Control**, v. 68, n. August 2020, p. 102752, jul. 2021.

MAKARAM, N.; KARTHICK, P. A.; SWAMINATHAN, R. Analysis of Dynamics of EMG Signal Variations in Fatiguing Contractions of Muscles Using Transition Network Approach. **IEEE Transactions on Instrumentation and Measurement**, v. 70, p. 1–8, 2021.

MANTILLA-BRITO, J. et al. Embedded System for Hand Gesture Recognition Using EMG Signals: Effect of Size in the Analysis Windows. In: NUMMENMAA, J. et al. (Eds.). . Advances and Applications in Computer Science, Electronics and Industrial Engineering. Advances in Intelligent Systems and Computing. Cham: Springer International Publishing, 2020. v. 1078p. 214–225.

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

MCCOOL, P. et al. Improved pattern recognition classification accuracy for surface myoelectric signals using spectral enhancement. **Biomedical Signal Processing and Control**, v. 18, p. 61–68, abr. 2015.

MERLETTI, R.; DE LUCA, C. J. New techniques in surface electromyography. In: Computer Aided EMG and Expert Systems. Amsterdã, Holanda: Elsevier B.V., 1989. p. 115–124.

MOURA, K. DE O. A. DE. Modelo adaptativo baseado em sensor virtual para eletromiografia de superfície com sistema de classificação tolerante a falhas. [s.l.] Universidade Federal do Rio Grande do Sul, 2018.

MOURA, K. O. A.; FAVIEIRO, G. W.; BALBINOT, A. Support vectors machine classification of surface electromyography for non-invasive naturally controlled hand prostheses. **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**, v. 2016- Octob, p. 788–791, 2016.

OO, T.; PHUKPATTARANONT, P. Signal-to-Noise Ratio Estimation in Electromyography Signals Contaminated with Electrocardiography Signals. **Fluctuation and Noise Letters**, v. 19, n. 03, p. 2050027, 17 set. 2020.

PALERMO, F. et al. Repeatability of grasp recognition for robotic hand prosthesis control based on sEMG data. IEEE International Conference on Rehabilitation Robotics.

Anais...London, UK: 2017

PARISI, L.; RAVICHANDRAN, N. Evolutionary Denoising-Based Machine Learning for Detecting Knee Disorders. **Neural Processing Letters**, v. 52, n. 3, p. 2565–2581, 2020.

PEARCE, J. M. S. Emil Heinrich Du Bois-Reymond (1818-96). **Journal of Neurology, Neurosurgery & Psychiatry**, v. 71, n. 5, p. 620-620, 1 nov. 2001.

PETERSEN, E. et al. Removing Cardiac Artifacts From Single-Channel Respiratory Electromyograms. **IEEE Access**, v. 8, p. 30905–30917, 2020.

PHINYOMARK, A. et al. EMG feature evaluation for improving myoelectric pattern recognition robustness. **Expert Systems with Applications**, v. 40, n. 12, p. 4832–4840, 2013.

PHINYOMARK, A.; PHUKPATTARANONT, P.; LIMSAKUL, C. Feature reduction and selection for EMG signal classification. **Expert Systems with Applications**, v. 39, n. 8, p. 7420–7431, 2012.

PHUKAN, N. et al. Finger movements recognition using minimally redundant features of wavelet denoised EMG. **Health and Technology**, v. 9, n. 4, p. 579–593, 17 ago. 2019.

PILARSKI, P. M. et al. **Online human training of a myoelectric prosthesis controller via actor-critic reinforcement learning**. 2011 IEEE International Conference on Rehabilitation Robotics. **Anais**...Zurich, Switzerland: IEEE, jun. 2011Disponível em: http://ieeexplore.ieee.org/document/5975338/>

PILARSKI, P. M.; DICK, T. B.; SUTTON, R. S. Real-time prediction learning for the simultaneous actuation of multiple prosthetic joints. 2013 IEEE 13th International Conference on Rehabilitation Robotics (ICORR). Anais...Seattle, USA: IEEE, jun. 2013Disponível em: http://ieeexplore.ieee.org/document/6650435/>

PIZZOLATO, S. et al. Comparison of six electromyography acquisition setups on hand

movement classification tasks. **PLoS ONE**, v. 12, n. 10, p. 1–17, 2017.

POWAR, O. S.; CHEMMANGAT, K. Comparison of Pre-Processing Filters on the Performance of sEMG based Pattern Recognition. 2019 International Conference on Power Electronics Applications and Technology in Present Energy Scenario (PETPES). Anais...Mangalore, India: IEEE, ago. 2019Disponível em: https://ieeexplore.ieee.org/document/9003771/

POZZO, M.; FARINA, D.; MERLETTI, R. Electromyography: Detection, Processing, and Applications. In: MOORE, J.; ZOURIDAKIS, G. (Eds.). . **Biomedical Technology and Devices Handbook**. New York: CRC Press, 2004. p. 70–135.

REAZ, M. B. I.; HUSSAIN, M. S.; MOHD-YASIN, F. Techniques of EMG signal analysis: detection, processing, classification and applications (Correction). **Biological Procedures Online**, v. 8, n. 1, p. 163–163, 2006.

SCHWEISFURTH, M. A. et al. The Interaction Between Feedback Type and Learning in Routine Grasping With Myoelectric Prostheses. **IEEE Transactions on Haptics**, v. 13, n. 3, p. 645–654, 1 jul. 2020.

SEZGIN, N. A new hand finger movements' classification system based on bicoherence analysis of two-channel surface EMG signals. **Neural Computing and Applications**, v. 31, n. 8, p. 3327–3337, 20 ago. 2019.

SHENG, X. et al. Common spatial-spectral analysis of EMG signals for multiday and multiuser myoelectric interface. **Biomedical Signal Processing and Control**, v. 53, p. 101572, ago. 2019.

ŞIMŞEK, Ö.; ALGORTA, S.; KOTHIYAL, A. Why most decisions are easy in tetris-and perhaps in other sequential decision problems, as well. 33rd International Conference on Machine Learning, ICML 2016. Anais...New York, USA: 2016

SINDERBY, C.; LINDSTROM, L.; GRASSINO, A. E. Automatic assessment of electromyogram quality. **Journal of Applied Physiology**, v. 79, n. 5, p. 1803–1815, 1 nov. 1995.

SONG, C. et al. Deep Reinforcement Learning Apply in Electromyography Data

Classification. 2018 IEEE International Conference on Cyborg and Bionic Systems (CBS).

Anais...Shenzhen, China: IEEE, out. 2018Disponível em:
https://ieeexplore.ieee.org/document/8612213/

STACHACZYK, M.; ATASHZAR, S. F.; FARINA, D. Adaptive Spatial Filtering of High-Density EMG for Reducing the Influence of Noise and Artefacts in Myoelectric Control. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 4320, n. c, p. 1–8, 2020.

STEGEMAN, D.; HERMENS, H. Standards for surface electromyography: The European project Surface EMG for non-invasive assessment of muscles (SENIAM). **Roessingh Research and Development**, v. 1, p. 108–112, 2007.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. 2^a ed. Cambridge, EUA: MIT Press, 2018.

TAGELDEEN, M. K.; ELAMVAZUTHI, I.; PERUMAL, N. Motion control for a multiple input rehabilitation wearable exoskeleton using fuzzy logic and PID. 2016 IEEE 14th International Workshop on Advanced Motion Control (AMC). Anais...IEEE, abr. 2016Disponível em: http://ieeexplore.ieee.org/document/7496395/>

TAM, S. et al. A Fully Embedded Adaptive Real-Time Hand Gesture Classifier Leveraging HD-sEMG and Deep Learning. **IEEE Transactions on Biomedical Circuits and Systems**, v. 14, n. 2, p. 232–243, 2020.

TEH, Y.; HARGROVE, L. J. Using Latent Representations of Muscle Activation Patterns to Mitigate Myoelectric Interface Noise. 10th International IEEE/EMBS Conference on Neural Engineering (NER). Anais...Italy: 2021

TESAURO, G. Temporal difference learning and TD-Gammon. **Communications of the ACM**, v. 38, p. 58–68, 1995.

THAKOR, N. V.; ZHU, Y.-S. Applications of adaptive filtering to ECG analysis: noise cancellation and arrhythmia detection. **IEEE Transactions on Biomedical Engineering**, v. 38, n. 8, p. 785–794, 1991.

THONGPANJA, S. et al. Probability Density Functions of Stationary Surface EMG Signals in

Noisy Environments. **IEEE Transactions on Instrumentation and Measurement**, v. 65, n. 7, p. 1547–1557, jul. 2016.

TORTORA, G. J.; DERRICKSON, B. Corpo humano: fundamentos de anatomia e fisiologia (8a. ed.). 8a. ed. ed. Porto Alegre: Grupo A - Artmed, 2012.

TOSIN, M. C. Aplicação de Algoritmos de Seleção de Características na Classificação de Movimentos do Segmento Mão-Braço Através do Processamento de Sinais de sEMG. [s.l.] Universidade Federal do Rio Grande do Sul, 2018.

TOSIN, M. C.; BALBINOT, A. Identification and removal of contaminants in sEMG recordings through a methodology based on Fuzzy Inference and Actor-Critic Reinforcement learning. **Expert Systems with Applications**, v. 206, p. 117772, nov. 2022.

TOSIN, M. C.; CENE, V. H.; BALBINOT, A. Statistical feature and channel selection for upper limb classification using sEMG signal processing. **Research on Biomedical Engineering**, p. 1–17, 18 ago. 2020.

TOSIN, M. C.; MACHADO, J. C.; BALBINOT, A. sEMG-Based Upper Limb Movement Classifier: Current Scenario and Upcoming Challenges. **Journal of Artificial Intelligence Research**, v. 75, p. 83–127, 19 set. 2022.

TRIGILI, E. et al. Detection of movement onset using EMG signals for upper-limb exoskeletons in reaching tasks. **Journal of NeuroEngineering and Rehabilitation**, v. 16, n. 1, p. 45, 29 dez. 2019.

TRIWIYANTO, - et al. Robust Features for Elbow Joint Angle Estimation Based on Electromyography. **International Journal on Advanced Science, Engineering and Information Technology**, v. 8, n. 5, p. 1956, 13 out. 2018.

TSINGANOS, P. et al. A Hilbert Curve Based Representation of sEMG Signals for Gesture Recognition. 2019 International Conference on Systems, Signals and Image Processing (IWSSIP). Anais...Osijek, Croatia: IEEE, jun. 2019Disponível em: https://ieeexplore.ieee.org/document/8787290/

VAN DIJK, L. et al. Task-Oriented Gaming for Transfer to Prosthesis Use. **IEEE Transactions** on Neural Systems and Rehabilitation Engineering, v. 24, n. 12, p. 1384–1394, dez. 2016.

VASAN, G.; PILARSKI, P. M. Learning from demonstration: Teaching a myoelectric prosthesis with an intact limb via reinforcement learning. 2017 International Conference on Rehabilitation Robotics (ICORR). Anais...London, UK: IEEE, jul. 2017Disponível em: https://ieeexplore.ieee.org/document/8009453/>

WAHID, M. F.; TAFRESHI, R.; LANGARI, R. A Multi-Window Majority Voting Strategy to Improve Hand Gesture Recognition Accuracies Using Electromyography Signal. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 28, n. 2, p. 427–436, 2020.

WANG, Z. et al. Facilitate sEMG-Based Human–Machine Interaction Through Channel Optimization. **International Journal of Humanoid Robotics**, v. 16, n. 04, p. 1–19, 27 ago. 2019.

XU, Z. et al. Advanced hand gesture prediction robust to electrode shift with an arbitrary angle. **Sensors (Switzerland)**, v. 20, n. 4, 2020.

YAMANOI, Y.; OGIRI, Y.; KATO, R. EMG-based posture classification using a convolutional neural network for a myoelectric hand. **Biomedical Signal Processing and Control**, v. 55, p. 1–10, jan. 2020.

YANG, X. et al. **Hand Rehabilitation Using Virtual Reality Electromyography Signals**. 2017 5th International Conference on Enterprise Systems (ES). **Anais**...Beijing, China: IEEE, set. 2017Disponível em: http://ieeexplore.ieee.org/document/8119378/>

YE, Y. et al. **Optimal Feature Selection for EMG-Based Finger Force Estimation Using LightGBM Model**. 2019 28th IEEE International Conference on Robot and Human Interactive Communication (RO-MAN). **Anais**...New Delhi, India: IEEE, out. 2019Disponível em: https://ieeexplore.ieee.org/document/8956453/>

ZEA, J. A.; BENALCÁZAR, M. E. Real-Time Hand Gesture Recognition: A Long Short-Term Memory Approach with Electromyography. In: NUMMENMAA, J. et al. (Eds.). . **Advances and Applications in Computer Science, Electronics and Industrial Engineering**. 1. ed. Cham, Switzerland: Springer International Publishing, 2020. p. 155–167.

ZHOU, T. et al. Adapting Random Forest Classifier Based on Single and Multiple Features for Surface Electromyography Signal Recognition. 2019 12th International Congress on

Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). **Anais**...Suzhou, China: IEEE, out. 2019Disponível em: https://ieeexplore.ieee.org/document/8965719/>

ZHOU, X. et al. A novel muscle-computer interface for hand gesture recognition using depth vision. **Journal of Ambient Intelligence and Humanized Computing**, n. 1, 29 mar. 2020.