

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

JULIANO COSTA MACHADO

**USO DE REDES RECORRENTES PARA IDENTIFICAÇÃO
AUTOMÁTICA DE CONTAMINANTES E PARA A
ESTIMAÇÃO DE UM SENSOR VIRTUAL DE
ELETROMIOGRAFIA NO CONTEXTO DE UM SISTEMA
TOLERANTE A FALHAS**

Porto Alegre

2021

JULIANO COSTA MACHADO

**USO DE REDES RECORRENTES PARA IDENTIFICAÇÃO
AUTOMÁTICA DE CONTAMINANTES E PARA A
ESTIMAÇÃO DE UM SENSOR VIRTUAL DE
ELETROMIOGRAFIA NO CONTEXTO DE UM SISTEMA
TOLERANTE A FALHAS**

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

Área de concentração: Controle e
Automação – Instrumentação.

ORIENTADOR: Dr. Alexandre Balbinot

Porto Alegre

2021

JULIANO COSTA MACHADO

**USO DE REDES RECORRENTES PARA IDENTIFICAÇÃO
AUTOMÁTICA DE CONTAMINANTES E PARA A
ESTIMAÇÃO DE UM SENSOR VIRTUAL DE
ELETROMIOGRAFIA NO CONTEXTO DE UM SISTEMA
TOLERANTE A FALHAS**

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

Orientador: _____

Profa. Dr. Alexandre Balbinot

Doutor pela UFRGS – Porto Alegre, Brasil

Banca Examinadora:

Prof. Dr. Leonardo Abdala Elias, UNICAMP

Doutor pela Universidade de São Paulo, São Paulo, Brasil

Prof. Dr. Alexandre Rosa Franco, NKI Doutor

Doutor pela University of New Mexico, Albuquerque, EUA

Prof. Dr. Altamiro Susin, PPGEE – UFRGS

Doutor pela Institut National Polytechnique de Grenoble, Grenoble, França

Coordenador do PPGEE: _____

Prof. Dr. Sérgio Luís Haffner

Porto Alegre, setembro de 2021.

RESUMO

O desenvolvimento de sistemas inteligentes controlados por eletromiografia que possam se adaptar a possíveis contaminações extrínsecas e intrínsecas, que afetem a taxa de acerto do classificador de movimentos, leva a dispositivos mais robustos e seguros, vistos que evitariam acionamentos indevidos e inesperados. Esse trabalho apresenta uma solução para contaminações por Artefato de Movimento, Ruído de Linha Elétrica, Ruído Branco Aditivo e ECG em 9 diferentes níveis de SNR, de -40dB a 40dB, utilizando Redes Neurais Recorrentes (RNR) com unidades LSTM nas duas etapas deste trabalho. A primeira etapa é o sistema de identificação da contaminação, que traz como inovação a identificação do contaminante diretamente do sinal bruto de sEMG, deixando para a rede a extração das características temporais, onde os resultados apontaram uma taxa de mais de 90% de acerto do tipo de contaminante para SNR = -30dB. A segunda etapa é a geração de um Sensor Virtual a partir de 7 estudos de caso em falhas de eletrodos, que traz como inovação a regressão do sinal retificado e suavizado por um filtro AVT. A geração do sensor virtual é realizada a partir dos canais não contaminados também utilizando uma RNR - LSTM com o objetivo de recuperar a taxa de acerto em 18 classes de um classificador Extreme Learning Machine (ELM), aplicado nas bases NinaPro e IEE. Os resultados indicaram que foi possível recuperar a taxa média de acerto para 2 canais contaminados com ruído branco aditivo em -30dB, de um total de 12 canais, de 7,28% para 68,34% em 4 indivíduos não amputados e de 15,07% para 43,67% em 9 indivíduos amputados.

Palavras-chave: processamento do sinal mioelétrico; redes neurais recorrentes; *long short-term memory* (LSTM); contaminantes; análise qualidade; sensor virtual; sistema robusto a falhas; regressão; *extreme learning machine*.

ABSTRACT

The development of electromyographic controlled systems adaptable to possible extrinsic and intrinsic contaminations, affecting the movement classification hit rate, lead to more robust and secure devices avoiding unexpected situations. This work presents a solution for Movement Artifact, Electrical Noise, White Gaussian Noise and ECG in nine SNR levels, ranging from -40dB to 40dB in 10dB steps, using Recurrent Neural Networks with LSTM units in the two stages of this work. The first stage is an automatic contamination detector, that has the contaminant identification made direct from the raw sEMG signal as a novelty, where the tests point to 90% correct identification for SNR = -30dB. The second stage is the development of a virtual sensor, that generates the corrupted channel using the non-corrupted ones using a RNR-LSTM with the objective to recover the 18 movement class classification hit rate for an Extreme Learning Machine (ELM). The results show that it was possible to recover the classification hit rate for 2 contaminated channels from 7.28% to 63.34% in 4 non-amputee subjects and from 15.07% to 43.67% in 9 amputee subjects.

Keywords: myoelectric signal processing; recurrent neural networks, long short-term memory; contamination; quality analysis; virtual sensor; fault-robust system; regression; extreme learning machines.

LISTA DE FIGURAS

Figura 1 – Diagrama em blocos de um sistema típico para processamento do sinal sEMG....	26
Figura 2 – Exemplo de Rede Neural Recorrente com profundidade de 4 amostras de tempo. (a) rede em topologia compacta e (b) rede em topologia completa.....	34
Figura 3 – Pesos e variáveis resultantes do passo à frente da rede.....	35
Figura 4 – Exemplo gráfico do: (a) desaparecimento do gradiente e (b) divergência do gradiente.	38
Figura 5 – Diagrama em blocos de uma rede com 2 unidades LSTM.	41
Figura 6 – Função perda \mathcal{L} . Seu valor é determinado a partir das somas das perdas parciais $\mathcal{L}(t)$ determinadas a partir da saída verdadeira \mathbf{y}_v e saída prevista \mathbf{y}_p	42
Figura 7 – Representação gráfica da propagação de uma RNN simplificada. $\mathbf{b}(t)$ representa o estado da camada oculta no instante de tempo t	43
Figura 8 – Propagação do gradiente da função perda dentro de uma rede LSTM com 2 unidades.	44
Figura 9 – Diagrama em blocos do sistema proposto para C canais contaminados.....	63
Figura 10 – Movimentos realizados na base de dados NinaPro.....	66
Figura 11 – Posicionamento dos eletrodos no braço de cada voluntário.....	68
Figura 12 – Efeito da contaminação em diferentes níveis de SNR por RBA no sinal de sEMG normalizado.	75
Figura 13 – Efeito dos diferentes contaminantes para SNR = -20dB.....	76
Figura 14 – Efeito dos diferentes contaminantes para SNR = -10dB.....	76
Figura 15 – Diagrama em blocos da classificação de contaminantes para C canais.....	77
Figura 16 – Arquitetura Básica da RNN-LSTM. (a) Rede em topologia compacta; (b) Rede em topologia completa.....	78
Figura 17 – Exemplo de um trecho de sEMG com 450 amostras, particionada em 10 séries de 45 amostras cada.....	83
Figura 18 – Conjunto de dados para treinar os 12 modelos a serem testados.	84
Figura 19 – Arquitetura resumida da rede RNR-LSTM proposta. a) Rede em topologia compacta e b) Rede em topologia completa.	90
Figura 20 – Exemplo de contração e períodos de repouso.....	93
Figura 21 – Trecho de contração dividido em K partes com N amostras cada.....	94
Figura 22 – Gráficos tipo <i>boxplot</i> para o grupo de treinamento A considerando todas as combinações (N , #LSTM). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.	99
Figura 23 – Gráficos tipo <i>boxplot</i> para o grupo de treinamento A considerando todos os modelos para a configuração ($N = 60$, #LSTM = 75). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.....	103
Figura 24 – Taxa de acerto normalizada para Verdadeiro Positivo para (a) RBA, (b) RL, (c) AM e (d) ECG.	106
Figura 25 – Interação entre Épocas e Modelos para o Caso 1.....	113
Figura 26 – Interação entre Épocas e Modelos para o caso 2.....	113
Figura 27 – Interação entre Épocas e Modelos para o caso 6.....	113

Figura 44 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.	135
Figura 45 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.	135
Figura 46 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.	136
Figura 47 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.	136
Figura 48 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.	139
Figura 49 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.	139
Figura 50 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.	140
Figura 51 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.	140
Figura 52 – Médias para NC, CONT e VC, considerando a base DB3, caso 4, RBA em 0dB para cada sujeito.	149
Figura 53 – Gráficos tipo <i>boxplot</i> para o grupo de treinamento B considerando todas as combinações (N , #LSTM). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.	168
Figura 54 – Gráficos tipo <i>boxplot</i> para o grupo de treinamento C considerando todas as combinações (N , #LSTM). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.	169
Figura 55 – Gráficos tipo <i>boxplot</i> para o grupo de treinamento B considerando todos os modelos para a configuração ($N = 60$, #LSTM = 50). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.	170
Figura 56 – Gráficos tipo <i>boxplot</i> para o grupo de treinamento C considerando todos os modelos para a configuração ($N = 60$, #LSTM = 50). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.	171
Figura 57 – Taxa de acerto normalizada para Falso Negativo	172
Figura 58 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.	176
Figura 59 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.	177
Figura 60 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.	177

Figura 77 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.....	188
Figura 78 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.....	188
Figura 79 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.....	189
Figura 80 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.....	189
Figura 81 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.....	190
Figura 82 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.....	190
Figura 83 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.....	191
Figura 84 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.....	191
Figura 85 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.....	192
Figura 86 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.....	192
Figura 87 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.....	193
Figura 88 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.....	193
Figura 89 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.....	194

LISTA DE TABELAS

Tabela 1 – Notação utilizada para os pesos presentes na rede exemplificada na Figura 2.	40
Tabela 2 – Publicações de processamento de sEMG por RNN-LSTM.....	51
Tabela 3 – Publicações de trabalhos sobre análise de qualidade do sinal sEMG.....	56
Tabela 4 – Resumo dos trabalhos de sistemas tolerantes a falha com sEMG.....	62
Tabela 5 – Resumo das bases de dado NinaPro – Exercício B.	66
Tabela 6 – Tipos de exercícios realizados na Base IEE	69
Tabela 7 – Base de dados de sEMG do IEE.	69
Tabela 8 – Parâmetros da RNR-LSTM	79
Tabela 9 – Correlação Média Entre sinal íntegro e contaminado para base NinaPro.	81
Tabela 10 – Correlação Média Entre sinal íntegro e contaminado para base IEE.	81
Tabela 11 – Níveis de SNR para treinamento.	82
Tabela 12 – Casos analisados para seleção dos parâmetros da RNR-LSTM para detecção de contaminantes.	85
Tabela 13 – Arquiteturas testadas para o sensor virtual.	91
Tabela 14 – Média, desvio padrão e intervalo de confiança para as arquiteturas candidatas para o grupo de treinamento A.	101
Tabela 15 – Parâmetros N e $\#LSTM$ do IAC para cada grupo de treinamento.....	101
Tabela 16 – Média, Desvio Padrão e Intervalo de confiança (95%) de Verdadeiro Positivo para os modelos candidatos do grupo de treinamento A.	104
Tabela 17 – Matriz Confusão para os níveis SNR = -40dB, -20dB, 0dB, 20dB, 40dB do grupo de treinamento A.....	108
Tabela 18 – Teste de Tukey considerando os níveis de SNR para cada grupo de treinamento e tipo de contaminante. Níveis com cores iguais na horizontal indica que não são significativamente diferentes.	110
Tabela 19 – Teste de Tukey considerando a média da taxa de acerto nos grupos A e B para cada contaminantes em cada nível de SNR. Intervalos em vermelho indica que são significativamente diferentes e em verde que são iguais.....	110
Tabela 20 – Diferença absoluta, em %, entre VC e CONT para todos casos com 25% de contaminação. Valores positivos indicam ganho de performance. Base DB3.	118
Tabela 21 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 25% de contaminação. Valores positivos indicam ganho de performance. Base IEE.....	123
Tabela 22 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 50% de contaminação. Valores positivos indicam ganho de performance. Base DB3.	128
Tabela 23 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 50% de contaminação. Valores positivos indicam ganho de performance. Base IEE.....	132
Tabela 24 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 100% de contaminação. Valores positivos indicam ganho de performance. Base DB3.	137
Tabela 25 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 100% de contaminação. Valores positivos indicam ganho de performance. Base IEE.....	141
Tabela 26 – Resultado da identificação de contaminantes para o sinal não contaminado, em (%) para canais críticos DB3.	148
Tabela 27 – Resultado da identificação de contaminantes no sinal não contaminado, em (%) para canais críticos IEE.	149

Tabela 28 - Comparativo entre trabalhos semelhantes.....	153
Tabela 29 – Média, Desvio Padrão e Intervalo de confiança (95%) de Verdadeiro Positivo para os modelos candidatos do grupo de treinamento B.	171
Tabela 30 – Média, Desvio Padrão e Intervalo de confiança (95%) de Verdadeiro Positivo para os modelos candidatos do grupo de treinamento C.	172
Tabela 31 – Matriz Confusão para os níveis SNR = -40dB, -20dB, 0dB, 20dB, 40dB do grupo de treinamento B.....	173
Tabela 32 – Matriz Confusão para os níveis SNR = -40dB, -20dB, 0dB, 20dB, 40dB do grupo de treinamento C.....	174
Tabela 33 – Teste Tukey comparando os grupos A e C.....	175
Tabela 34 – Teste Tukey comparando os grupos B e C.....	175
Tabela 35 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 75% de contaminação. Valores positivos indicam ganho de performance. Base DB3.	185
Tabela 36 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 75% de contaminação. Valores positivos indicam ganho de performance. Base IEE.....	195

LISTA DE ABREVIATURAS

ADAM	<i>Adaptative Moment Estimation</i>
AM	Artefato de Movimento
AR	Auto Regressivo
BCI	<i>Brain Machine Interface</i>
BPTT	<i>Backpropagation Through Time</i>
CSP	<i>Common Spatial Pattern</i>
CONT	Contaminado
DE	Deslocamento de Eletrodo
EcOG	Eletrocorticografia
ECG	Eletrocardiograma
EEG	Eletroencefalografia
ELM	<i>Extreme Learning Machine</i>
EMG	Eletromiografia
FD	<i>Frequency Domain</i>
FKD	Filtro de Kalman Descentralizado
FP	Filtro de Partículas
GMM	Gaussian Mixture Model
HMM	Hidden Markov Model
IAC	Identificador Automático de contaminantes
IC	Inteligência Computacional
ICA	<i>Independent Component Analysis</i>

IL	Interferência de Linha de energia
LDA	<i>Linear Discriminant Analysis</i>
LHC	<i>Large Hadron Collider</i>
LSTM	<i>Long Short-Term Memory</i>
KKT	Karush-Kuhn-Tucker
MAE	<i>Mean Absolute Error</i>
MAEP	<i>Mean Absolute Error Percentage</i>
MAV	<i>Mean Absolute Value</i>
MFL	<i>Maximum Fractal Length</i>
MMG	Mecanomiografia
MLPR	<i>Multilayer Perceptron Regression</i>
MSE	<i>Mean Square Error</i>
NARX	<i>Nonlinear Autoregressive Exogenous Model</i>
NB	<i>Naive Bayes</i>
NC	Não Contaminado
NMSE	<i>Normalized Mean Square Error</i>
PCA	<i>Principal Component Analysis</i>
PWR	Potência Média
RBA	Ruído Branco Aditivo
RBF	Função de Base Radial
RELM	<i>Regularized Extreme Learning Machine</i>
RL	Ruído de Linha
RMSE	<i>Root Mean Square Error</i>
RN	<i>Rede Neural Artificial</i>
RNR	Rede Neural Recorrente

RP	Reconhecimento de Padrões
SAT	Saturação
SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
sEM	Eletromiografia de Superfície
SD	<i>Standart Deviation Error</i>
SFTD	<i>Sensor Fault Tolerant Detector</i>
SMO	<i>Sequential Minimal Optimization</i>
SSC	<i>Slope Signal Change</i>
STFT	<i>Short-Time Fourier Transform</i>
STT	<i>Short-Time Thompson Transform</i>
SVM	<i>Support Vector Machines</i>
SV	<i>Support Vectors Regression</i>
TA	Tecnologia Assistiva
TD	<i>Time Domain</i>
TFD	<i>Time Frequency Domain</i>
TVARMA	<i>Time-Varying Autoregressive Moving Average</i>
VC	Sensor Virtual
VMP	<i>Variância Média Ponderada</i>
WL	<i>Waveform Length</i>
ZC	<i>Zero Crossing</i>

SUMÁRIO

1. INTRODUÇÃO	18
1.1. MOTIVAÇÃO	19
1.2. HIPÓTESE	21
1.3. OBJETIVO	22
1.4. CONTRIBUIÇÕES:	22
2. REVISÃO DA LITERATURA	25
2.1. PRINCIPAIS ETAPAS DO PROCESSAMENTO DO SEMG	25
2.2. EXTRAÇÃO E SELEÇÃO DE CARACTERÍSTICAS	27
2.3. PRINCIPAIS CLASSIFICADORES UTILIZADOS NO PROCESSAMENTO DE SEMG	29
2.4. REDES NEURAIS RECORRENTES (RNR).....	32
2.4.1. A UNIDADE LONG SHORT-TERM MEMORY.....	37
2.4.2. TREINAMENTO DA RNR	42
3. ESTADO DA ARTE	45
3.1. USO DE RNR NO PROCESSAMENTO DO SINAL DE SEMG.....	45
3.2. DETECÇÃO DE CONTAMINANTES DO SINAL SEMG.....	50
3.3. SISTEMAS TOLERANTE A FALHAS COM APLICAÇÕES EM SINAIS DE SEMG.....	57
4. METODOLOGIA	63
4.1. BASES DE DADOS DE SEMG	65
4.1.1. BASE DE DADOS NINA PRO.....	65
4.1.2. BASE DE DADOS IEE.....	67
4.2. PRÉ-PROCESSAMENTO	69
4.3. EXTRAÇÃO DE CARACTERÍSTICAS PARA O CLASSIFICADOR DE MOVIMENTOS	71
4.4. CONTAMINANTES ARTIFICIAIS DO SINAL DE SEMG	72
4.5. IDENTIFICADOR AUTOMÁTICO DE CONTAMINANTES (IAC).....	77
4.5.1. CONJUNTO DE TREINAMENTO E CONJUNTO DE TESTE.....	80
4.5.2. SELEÇÃO HIPER PARÂMETROS E MODELO	84
4.5.3. TESTE DO IAC	87
4.6. SENSOR VIRTUAL	88
4.6.1. TREINAMENTO E TESTE.....	92
4.6.2. CLASSIFICAÇÃO CONFIÁVEL E COM TOLERÂNCIA A FALHA	96
5. RESULTADOS E DISCUSSÕES	99
5.1. ANÁLISE DO TAMANHO N DA SEQUÊNCIA E NÚMERO DE NEURÔNIOS LSTM DA CAMADA OCULTA	99
5.2. TESTE DO IAC.....	105
5.3. SELEÇÃO DA ARQUITETURA DO SENSOR VIRTUAL	111
5.4. TESTE IAC E SENSOR VIRTUAL	114
5.4.1. SINAL COM 25% DE CONTAMINAÇÃO PARA BASE DB3	115
5.4.2. SINAL COM 25% DE CONTAMINAÇÃO PARA BASE IEE.	120
5.4.3. SINAL COM 50% DE CONTAMINAÇÃO PARA BASE DB3	124
5.4.4. SINAL COM 50% DE CONTAMINAÇÃO PARA BASE IEE	129
5.4.5. SINAL COM 100% DE CONTAMINAÇÃO PARA BASE DB3	134

5.4.6. SINAL COM 100% DE CONTAMINAÇÃO PARA BASE IEE	138
5.5. DISCUSSÕES E CONSIDERAÇÕES FINAIS	143
6. CONCLUSÕES.....	154
7. PUBLICAÇÕES RELACIONADAS À TESE.....	157
BIBLIOGRAFIA	158
8. APENDICE	168

1. INTRODUÇÃO

A Instrumentação Biomédica busca em suas pesquisas, formas de melhorar a qualidade de vida da sociedade, no desenvolvimento de equipamentos de medição para diagnósticos clínicos e no avanço das Tecnologias Assistivas (TA), que permite o uso da tecnologia para reabilitação e tratamento de pessoas vítimas de doenças degenerativas do sistema nervoso ou muscular, como de pessoas vítimas de traumas com lesões na medula espinhal e amputações de um ou mais membros do corpo.

Diferentes abordagens de reabilitação são estudadas dependendo do tipo de lesão ou doença. Quando existem músculos ou porções de músculos funcionais, como em braços amputados por exemplo, é possível utilizar sinais de eletromiografia de superfície (sEMG) gerados durante a contração voluntária do indivíduo para acionar e controlar dispositivos eletromecânicos, como próteses robóticas (Osborn *et al.*, 2021).

Considerando que se deseja desenvolver dispositivos que se comportem de forma natural, substituindo o membro com as mesmas funcionalidades em todas possíveis condições, pode-se dizer que o estado da arte ainda está longe deste objetivo. Apesar do enorme potencial de reabilitação e mesmo diante de avanços significativos em *hardware* e no processamento de biossinais, cerca de 40% dos usuários de próteses eletromecânicas desistem do seu uso (Biddiss e Chau, 2007; Biddiss, Beaton e Chau, 2007; Osborn *et al.*, 2021; Østlie *et al.*, 2012) por não conseguirem se adaptar devido ao peso da prótese, custos de operação, falta de robustez, ou por não apresentar uma solução melhor que alternativas mais simples (Farrell, 2011; Osborn *et al.*, 2021).

Um problema é que grande parte dos estudos estão limitados a ambientes controlados em laboratórios (Atzori *et al.*, 2014; Cene *et al.*, 2019; Zhang e Huang, 2015) e um dos poucos estudos em ambiente não controlado se focou em atividades domésticas, como jardinagem, preparo de refeições, tocar piano, dentre outras (Osborn *et al.*, 2021). Apesar desses estudos

trazerem valiosas informações, ainda não se sabe o efeito do uso por longas horas, em ambientes eletricamente ruidosos, como industrial, o uso durante a prática de exercícios físicos, dentre diversos outros cenários que podem trazer perturbações ao sinal de sEMG. Os poucos estudos que abordam a robustez de classificadores de movimento (Furukawa *et al.*, 2015; Moura, de e Balbinot, 2018; Samuel *et al.*, 2017; Zhang e Huang, 2015) mostram que há uma degradação considerável no reconhecimento dos movimentos quando o sensor está contaminado por ruídos ou em falha, portanto identificar e mitigar essas falhas pode levar a uma melhora no controle de próteses

1.1.Motivação

Apesar de sistemas baseados em reconhecimento de padrões terem apresentado, em situações específicas, taxas de acerto superiores a 95% (Cene e Balbinot, 2020; Zhang e Huang, 2015), praticamente não existem próteses com múltiplos graus de liberdade controladas por sinais de EMG disponíveis no mercado, sendo a grande maioria restrita a poucos usuários em centros de pesquisas (Osborn *et al.*, 2021). Isso significa que a busca por novos algoritmos de classificação não irá levar, necessariamente, a próteses com controle intuitivo ao usuário.

Como quase todo biossinal, o sinal de sEMG pode sofrer alterações nas suas características pelos mais diversos motivos, tanto de ordem fisiológica, como por fatores externos ao indivíduo (Clancy, Morin e Merletti, 2002; Enderle e Bronzino, 2012). Fatores de ordem fisiológica podem ser devido à fadiga muscular (Navaneethakrishna e Ramakrishnan, 2014) e mudanças na impedância da pele (Sae-lim, Phukpattaranont e Thongpull, 2018) por exemplo, assim como fatores externos podem ser devido à interferência de linha elétrica, saturação do amplificador, deslocamento do eletrodo, rompimento dos cabos ou pelo simples

fato do indivíduo estar em movimento (McCool *et al.*, 2014; Moura, de e Balbinot, 2018; Samuel *et al.*, 2017; Zhang e Huang, 2015).

Uma das descobertas de Osborn *et al.* (2021) foi de que a amplitude do sinal de sEMG fica menor, à medida que o controle da prótese se torna mais natural, deixando sinal mais suscetível a contaminações, pois reduz a relação sinal-ruído (SNR) das contrações e o usuário nem sempre vai ter o conhecimento necessário para conseguir resolver falhas decorrentes da aquisição do sinal sendo, portanto, necessário um sistema autônomo que ou indique o motivo da falha, como um eletrodo descolado, por exemplo, ou que o sistema se adapte à falha.

As abordagens atuais sobre o tema são focadas em diferentes modelos de classificação na memória do sistema (Furukawa *et al.*, 2015), retreinamento do modelo de classificação com dados contidos na memória (Zhang e Huang, 2015) e em sensor virtual (Moura, de e Balbinot, 2018). Em (Furukawa *et al.*, 2015) o sistema proposto estima o torque em uma junta robótica a partir dos sinais de sEMG, onde são analisadas falhas no sEMG como descolamento do eletrodo e desconexão do amplificador, onde são analisados 5 indivíduos não amputados, com 4 canais cada indivíduo.

Já Zhang e Huang (2015), utiliza 3 níveis diferentes de ruído branco, artefato de movimento e eletrodo descolado como contaminantes. O sistema utiliza um classificador de movimentos composto por 6 canais para classificação de 7 tipos de movimento, onde são avaliados 5 indivíduos não amputados e um amputado. Já o trabalho desenvolvido nesta tese foi realizado utilizando 12 canais e 17 tipos de movimentos, além de possuir uma base de dados com 69 indivíduos, sendo 11 amputados.

Portanto, um dos atuais focos da área de controle de próteses deve ser na capacidade adaptativa do sistema, para que seja possível reduzir ou eliminar problemas que serão enfrentados em ambientes não controlados durante o uso corriqueiro de uma prótese e que

impactam diretamente na taxa de acerto dos classificadores (Moura, de e Balbinot, 2018; Zhang e Huang, 2015).

1.2. Hipótese

Existem poucos estudos que avaliam o impacto de contaminantes na classificação de movimentos de posturas de mão, propondo diferentes soluções para mitigar o problema. O estudo de Zhang e Huang (2015) fornece uma solução onde os parâmetros dos canais contaminados são descartados e o trabalho de Moura, de e Balbinot (2018) propôs uma solução baseada em sensor virtual, utilizando *Time-Varying Autoregressive Moving Average* (TVARMA) para estimar as características para classificação do canal corrompido.

Considerando que as séries temporais de sinais de sEMG corrompidos e sEMG íntegro são diferentes (Arvidsson, Grassino e Lindstrom, 1984; McCool *et al.*, 2014; Moura, de e Balbinot, 2018; Sinderby, Lindstrom e Grassino, A. E. E., 1995; Zhang e Huang, 2015) e que existe correlação entre o sinal de sEMG de músculos próximos devido ao *crosstalk* (Farina, Merletti e Enoka, 2004; Mogk e Keir, 2003), a hipótese é de que é possível utilizar Redes Neurais Recorrentes (RNR) em dois diferentes cenários:

- 1) Na identificação de contaminantes presentes no sinal de sEMG em diferentes níveis de SNR;
- 2) Para a regressão do sinal do(s) canal(is) de sEMG onde foi identificada a falha, utilizando como entrada os canais não contaminados.

A hipótese está sustentada no fato da RNR ser uma rede específica para séries temporais (Goodfellow, Bengio e Courville, 2016; Graves, 2012) e que pode ser configurada tanto para saídas simbólicas como contínuas.

1.3. Objetivo

Em função das colocações anteriores, portanto, o objetivo deste trabalho é desenvolver uma plataforma experimental para classificação de movimentos do braço e mãos, capaz de detectar e se adaptar a contaminantes em diferentes níveis de SNR que degradem a taxa de acerto do classificador de movimentos através de um sensor virtual. Tanto a detecção e identificação dos contaminantes como a mitigação serão realizados por Redes Neurais Recorrentes com neurônios do tipo *Long Short-Time Memory* (LSTM) e classificação dos movimentos será realizada com uma *Extreme Learning Machine* (ELM) desenvolvida em pesquisas anteriores do nosso laboratório (Cene *et al.*, 2019; Cene e Balbinot, 2020). O sistema inteligente proposto deve possuir as seguintes características:

- identificar a qualidade do sinal, utilizando como métrica o SNR, dos canais do sinal de sEMG adquiridos utilizando uma RNR-LSTM;
- reconhecer 17 movimentos do braço e mãos mais o período de repouso com tolerância a falha baseada em modelo de sensor virtual utilizando RNR-LSTM em 7 estudos de caso.

Para obter os parâmetros matemáticos dos modelos, a avaliação será *offline* com o uso de bases de dados de movimentos de posturas de mãos, tal como a base pública, chamada *Non-Invasive Adaptive Hand Prosthetics* (NinaPro) (Atzori *et al.*, 2015) e de uma base gerada no laboratório IEE-UFRGS, onde este trabalho foi desenvolvido.

1.4. Contribuições:

Esta tese, de uma forma geral, tem o foco no desenvolvimento de uma solução que não dependa do usuário para identificar e mitigar falhas na operação de um sistema de classificação de movimentos do braço e da mão, identificando o canal em falha e utilizando as

informações disponíveis para estimar o valor do canal de sEMG que não está fisicamente disponível.

Em relação à identificação do contaminante, a maior contribuição desta tese é o desenvolvimento de um sistema que detecta o tipo de contaminante, em 9 níveis de SNR, a partir do sinal bruto em apenas uma etapa, onde as soluções alternativas apresentam conjuntos complexos de características e nem sempre apresentam metodologias para análise em diferentes níveis de SNR (Ijaz e Choi, 2018; McCool *et al.*, 2014).

Também foi realizada uma análise sobre como um classificador de movimentos é impactado com diferentes níveis de SNR de um contaminante, avançando no conhecimento do impacto de possíveis falhas que podem causar em sistemas controlados por sEMG, para diferentes níveis de contaminação.

Do ponto de vista do sensor virtual, a maior contribuição foi definir um método onde se estima o sinal antes da extração de características, melhorando assim a flexibilidade, permitindo o uso em aplicações com diferentes tipos de características. Também se obteve um ganho significativo de desempenho em comparação ao método proposto mais atual (Moura, de e Balbinot, 2018), considerando as mesmas bases de dados e tipos de movimento. Portanto, a partir do exposto anteriormente, as principais contribuições desta tese são:

- desenvolvimento de um identificador de contaminantes baseado no sinal bruto de sEMG e sua inserção em um sistema tolerante a falhas testado em diferentes níveis de SNR;
- avaliação do resultado da classificação de uma *Extreme Learning Machine* (ELM) para diferentes contaminantes, em 9 níveis de SNR;
- avaliação da classificação da ELM com a presença de um sensor virtual substituindo o sinal contaminado, quando identificada a contaminação em 9 níveis de SNR;

- sensor virtual gera o sEMG apenas pré-processado, diferente de outras soluções, que propõe a estimação das características do sinal;
- avaliação de diferentes níveis de contaminação intermitente;
- avaliação de uma abordagem multi-usuário na identificação do contaminante e geração do sensor virtual.

Esta tese está dividida em 6 capítulos principais e um Apêndice. No capítulo 2 é apresentado o referencial teórico do processamento básico de sEMG, dos tipos de classificadores de movimento utilizados, extração de características e sobre Redes Neurais Recorrentes. No capítulo 3 é apresentado o estado da arte em três eixos, no processamento do sinal de sEMG por Redes Neurais Recorrentes, na análise de qualidade do sinal de sEMG e sistemas tolerantes a falha.

Após estabelecidas as fundamentações teóricas, a metodologia é apresentada no capítulo 4, abrangendo as bases de dados, o procedimento de contaminação artificial, o desenvolvimento do identificador de contaminantes, do sensor virtual e da integração entre os dois. No capítulo 5 são apresentados os resultados para seleção de arquitetura dos modelos e dos testes nas bases de dados com as respectivas discussões e comparações com a bibliografia existente, quando possível. Por fim, no capítulo 6 são apresentadas as conclusões obtidas a partir deste trabalho.

2. REVISÃO DA LITERATURA

Nesta seção são apresentados conceitos básicos do processamento do sinal de eletromiografia, principalmente em aplicações que envolvem o segmento mão-braço, foco deste trabalho. Serão apresentadas as principais etapas de processamento, principais características e classificadores utilizados. Dentre os classificadores, é detalhado o funcionamento do *Extreme Learning Machine* regularizado (RELM), classificador de movimentos utilizado nesse trabalho.

Também será apresentado conceitos básicos sobre o funcionamento de Redes Neurais Recorrentes (RNR) e a unidade *Long Short-Term Memory* (LSTM) e suas principais configurações e no capítulo 3 serão analisados os trabalhos mais relevantes da área de eletromiografia utilizando RNR's.

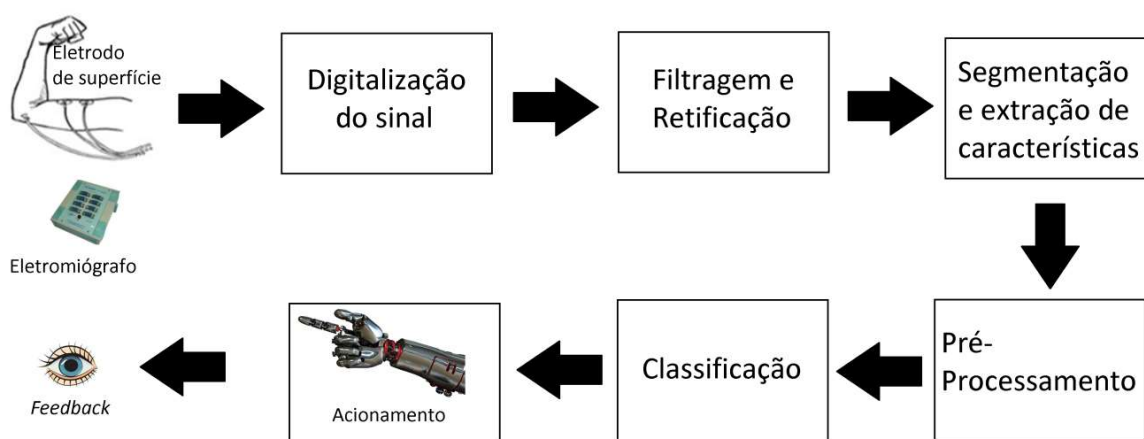
2.1. Principais Etapas do Processamento do sEMG

Nos primeiros trabalhos sobre sEMG, o processamento do sinal era baseado principalmente em avaliação da mudança de amplitude do sinal, para verificar a contração de um músculo (Dorcas, Dunfield e Scott, 1970) para controlar próteses do segmento mão-braço com poucos graus de liberdade, gerando um controle pouco intuitivo, porém ainda utilizado em sistemas comerciais atuais (Jiang e Farina, 2014).

A maior parte das pesquisas na área de eletromiografia para controle de próteses utilizam algoritmos de reconhecimento de padrões (RP) para caracterização dos movimentos devido ao comportamento estocástico do sinal de sEMG, porém, mesmo que se atinjam altas taxas de acerto, ainda há fatores que inibem o uso dessa técnica em equipamentos comercialmente viáveis em grande escala, tais como falta de processamento adaptativo, alterações nos eletrodos durante o uso (Iqbal, Subramaniam e P., 2017; Jiang e Farina, 2014; Sartori *et al.*,

2018). Como exemplo, a Figura 1 apresenta os principais elementos de um sistema típico para o processamento do sinal de sEMG.

Figura 1 – Diagrama em blocos de um sistema típico para processamento do sinal sEMG.



Fonte: Autor

Após a digitalização do sinal, filtragem e retificação o processo de segmentação do sinal de sEMG deve ser realizado de forma que localize corretamente os instantes de ativação muscular, para caracterizar os diferentes tipos de movimentos e o instante de repouso. Um dos métodos mais comuns de segmentação para geração base de dados de sinais de sEMG é o *timestamp*, onde o sinal de sEMG é sincronizado com a realização dos movimento em estudo, gerando um vetor de classes, de acordo com um determinado estímulo visual (Atzori *et al.*, 2015) ou auditivo (Khushaba *et al.*, 2011).

Diferentes abordagens de segmentação já foram realizadas (Englehart, Hudgin e Parker, 2001; Englehart e Hudgins, 2003; Farrell, 2011), onde são analisados tamanhos de janelas, sobreposição, dentre outros atributos. Idealmente, do ponto de vista prático, a melhor janela é a menor possível, porém janelas muito pequenas podem não conter uma quantidade suficiente de amostras para que a característica extraída possua informação discriminatória entre os diferentes estados do sistema.

O uso de janelas maiores possibilita a captura de informações relevantes, levando, normalmente, a uma melhora na taxa de acerto do classificador (Gijsberts *et al.*, 2014), mas janelas muito grandes levam a um *delay* no processamento dos dados, onde, para o controle natural de próteses, o tempo de coleta e processamento dos dados não deveria ser superior a 125ms, sendo 100ms considerado um valor ótimo (Farrell, 2011). Uma das formas de se utilizar as vantagens de pequenas e grandes janelas é utilizar janelas deslizantes com sobreposição, como por exemplo, no trabalho de (Moura, de e Balbinot, 2018) que utiliza janelas deslizantes de 300ms e sobreposição de 75ms e (Zhang e Huang, 2015) que utiliza janelas de 160ms e 20ms de sobreposição.

Nas seções seguintes serão apresentados os outros blocos que compõe a Figura 1 e juntamente serão apresentados os conjuntos de equações para descrever modelos e métodos.

2.2. Extração e Seleção de Características

A classificação do sinal de sEMG é normalmente realizada utilizando características extraídas de cada janela, de forma a aumentar a densidade de informação contida no sinal. A correta escolha dessas características é de fundamental importância para o desempenho do classificador (Hudgins, Parker e Scott, 1993) e é inclusive consenso entre alguns pesquisadores, que a escolha das características tem um papel mais importante que a escolha do classificador onde para um mesmo conjunto de características, o desempenho dos classificadores se mantém praticamente constante, como demonstrou (Hargrove, Englehart e Hudgins, 2007).

As características são comumente extraídas no domínio tempo (*Time Domain* – TD) (Barniv, Aguilar e Hasanbelliu, 2005; Lee e Saridis, 1984; Zardoshti-Kermani *et al.*, 1995), domínio frequência (*Frequency Domain* – FD) (Gu *et al.*, 2018), tempo-frequência (TFD) (Englehart, Hudgin e Parker, 2001) e características espaciais (Stango, Negro e Farina, 2015).

O conjunto de características TD analisadas por (Hudgins, Parker e Scott, 1993) ficaram conhecidas como Hudgins TD *features* e são Valor Absoluto Médio (*Mean Absolute Value – MAV*), inclinação do MAV, Cruzamento por Zero (*Zero Crossing – ZC*), inclinação da troca de sinal (*Slope Signal Change – SSC*) e comprimento de onda (*Waveform Length – WL*) (Iqbal, Subramaniam e P., 2017). Também são utilizadas como características TD, o valor RMS do sinal.

Características comuns no FD são Frequência Média e Frequência Mediana. No domínio TFD, algumas das características mais utilizadas são Transformada *Wavelet*, STFT (*Short-Time Fourier Transform*) e STTT (*Short-Time Thompson Transform*) (Ison e Artemiadis, 2014; Micera, Carpaneto e Raspopovic, 2010). As vantagens do uso das características TD são a simplicidade do cálculo, sem a necessidade de calcular uma nova representação do sinal, e possuem relações diretas entre força e a amplitude da contração muscular, porém apresentam sensibilidade ao ruído e mudanças transientes do sinal de sEMG.

As características FD e TFD tem a capacidade de auxiliar na identificação da fadiga muscular (Shochina *et al.*, 1986; Silva, da *et al.*, 2008), porém, possuem uma complexidade computacional maior que as características TD, baixa resolução temporal e elevada variância, dependendo da forma como é estimada. No caso das TFD, também é gerado um espaço de alta dimensionalidade e possuem diversos parâmetros de controle que devem ser ajustados. Outro modelo utilizado de características são as características baseadas em séries temporais, ou características paramétricas, como Auto Regressive (AR) e Coeficientes Cepstrais (Khan e Jahan, 2018; Koçer e Tümer, 2017) e possuem vantagens e desvantagens semelhantes às FD.

O trabalho de (Hargrove, Englehart e Hudgins, 2007) comparou cinco tipos de classificadores: Percéptons Multi-Camada, Percépton Linear, *Linear Discriminant Anaysis*, *Gaussian Mixture Model* e Cadeias Ocultas de Markov. Para cada classificador, foram testados seis tipos diferentes de características: Transformada de Fourier, Transformada

Wavelet, *Hudgins TD features*, Transformada Wavelet Estacionária, Transformada Wavelet *Packet* e coeficientes AR. As características que apresentaram a melhor taxa de acerto foram os coeficientes AR, sendo que as características TD obtiveram uma taxa de acerto cerca de 4% menor que os coeficientes AR e tem comportamento semelhante às outras características FD e FTD, com a vantagem de ser computacionalmente menos complexa.

A seleção de características é uma etapa que permite a redução da dimensionalidade, selecionando as características que melhor explicam o fenômeno estudado, economizando processamento computacional removendo características redundantes ou sem relação com o fenômeno. O trabalho de (Tosin *et al.*, 2017) utiliza um classificador chamado *Support Vector Recursive Feature Elimination* (SVM-RFE), que foi proposto por (Guyon *et al.*, 2002) para seleção de genes em classificação de câncer. Utilizando correlação para descartar dados redundantes e SVM-RFE para ranquear e determinar recursivamente o conjunto de características que obtêm a melhor taxa de acerto, conseguiram reduzir de 73 para 45 características e aumentar a taxa de acerto de 86,88% para 91,21% em um dos indivíduos avaliados.

Outro método utilizado para redução de dimensionalidade é o *Principal Component Analysis* (PCA), um método não supervisionado, capaz de reconhecer padrões estatísticos do sinal, que projeta o espaço de características em um espaço de máxima variância, demonstrando quais características melhor explicam a variância do sinal, que representam as componentes principais (Haykin, 2008) e é um procedimento aplicado em diversos trabalhos da área de sEMG (Cene e Balbinot, 2018; Geethanjali, 2015; Ison e Artemiadis, 2014).

2.3. Principais Classificadores Utilizados no Processamento de sEMG

Classificação é uma importante etapa do sistema apresentado na Figura 1, onde atualmente são utilizados algoritmos inteligentes, capazes de aprender o comportamento dos

dados através de uma etapa de treinamento. Para a classificação dos sinais de sEMG, as técnicas mais proeminentes são o *Linear Discriminant Analysis* (LDA) (Gijssberts *et al.*, 2014; Waris e Kamavuako, 2018; Zhang e Huang, 2015), Redes Neurais Artificiais (RNA) (Dev e Singh, 2016; Jahani Fariman *et al.*, 2015; Vries, de *et al.*, 2016), Lógica Neuro-Fuzzy (Balbinot e Favieiro, 2013; Zhang *et al.*, 2018), Support Vector Machines (SVM) (Moura, de e Balbinot, 2018; Naik, Kumar e Jayadeva, 2010; Tosin *et al.*, 2017).

Um método de aprendizagem profunda que vem se destacando na área de eletromiografia é o *Extreme Learning Machine* (ELM) (Anam e Al-Jumaily, 2014; Cene *et al.*, 2019; Lee *et al.*, 2011; Park, Kim e Oh, 2011), que é baseado em redes *Single Layer Feed Forward Neural Networks* (SLFN). Uma das vantagens deste método é a sua velocidade de treinamento, pelo fato de abordar o problema através de uma regressão matricial e não por métodos iterativos (Huang, Zhu e Siew, 2006). O uso deste classificador nas mesmas bases de dados utilizadas neste trabalho (Cene, 2020; Cene *et al.*, 2019), realizado pelo grupo de pesquisa onde este trabalho está inserido (Laboratório de Instrumentação Inteligente e Biomédica - antigo IEE), torna a escolha natural para teste e validação do sensor virtual proposto nesta tese. Em função da importância da classificação com base no método ELM, nesta tese, esse método será destacado a seguir.

Para compreender o método de um sistema SFLN padrão com L unidades ocultas, considere um conjunto de N amostras de entrada/saída $(\mathbf{x}_i, \mathbf{y}_i)$, onde $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{if}]^T \in \mathbf{R}^f$ e $\mathbf{y}_i = [y_{i1}, y_{i2}, \dots, y_{iC}]^T \in \mathbf{R}^C$, considerando f características de entrada e C classes de saída. Este conjunto se relaciona de acordo com a Equação ¹(1):

¹ Como forma de padronização para melhor entendimento das equações, deve-se entender letras minúsculas como valores escalares, letras minúsculas em negrito como vetores e letras maiúsculas em negrito como matrizes.

$$\sum_{j=1}^L \beta_j \Phi(w_j x_i + b_j) = y_i, \quad i = 1, \dots, N \quad (1)$$

onde w_j é o j -ésimo peso que conecta a camada de entrada com a camada oculta, $\Phi(\cdot)$ é uma função de ativação e β_j é o j -ésimo peso que conecta a camada oculta para a camada de saída. A classe é dada através função $\text{argmax}(y_i)$. A Equação (1) pode ser reescrita de forma compacta de acordo com as Equações (2) e (3), considerando $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]$.

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{Y} \quad (2)$$

$$\mathbf{H} = \begin{bmatrix} \Phi(\mathbf{w}_1 \mathbf{x}_1 + b_1) & \cdots & \Phi(\mathbf{w}_L \mathbf{x}_1 + b_L) \\ \vdots & \ddots & \vdots \\ \Phi(\mathbf{w}_1 \mathbf{x}_N + b_1) & \cdots & \Phi(\mathbf{w}_L \mathbf{x}_N + b_L) \end{bmatrix} \in \mathbf{R}^{N \times L} \quad (3)$$

O conceito central do ELM é evitar métodos de treinamento iterativos (Huang, Zhu e Siew, 2004), que possuem um alto custo computacional e nem sempre garantem um mínimo global através do método do gradiente. Para isso, considerando os parâmetros da Equação (1), \mathbf{w}_j e \mathbf{b}_j são fixados em valores aleatórios, em geral normalmente distribuídos dentro de um limite e então determina-se a matriz $\boldsymbol{\beta} \in \mathbf{R}^{L \times C}$ através da Equação (4) utilizando o conjunto de treinamento.

$$\boldsymbol{\beta} = \mathbf{H}^\dagger \mathbf{Y} \quad (4)$$

Na Equação (4), \mathbf{H}^\dagger representa a pseudoinversa de \mathbf{H} , visto que usualmente a matriz \mathbf{H} não é quadrada pois, em geral, $N > L$, e não pode ser invertida pelos métodos tradicionais. É necessário então, algum método de decomposição matricial que seja apropriado para matrizes de qualquer dimensão. Para a versão padrão do algoritmo (Huang, Zhu e Siew, 2006) o método utilizado é através da matriz de Moore-Pennrose e outra forma é através da decomposição em valores singulares (*Singular Value Decomposition* – SVD) (Cene *et al.*, 2019; Cene, Machado e Balbinot, 2019; Eckart e Young, 1936; Wang, 2011), onde a pseudoinversa da matriz \mathbf{H} pode ser decomposta na matriz \mathbf{H}^\dagger da seguinte forma:

$$\mathbf{H}^\dagger = \mathbf{V}\mathbf{\Sigma}^{-1}\mathbf{U}^T \quad (5)$$

onde \mathbf{U} e \mathbf{V} são matrizes obtidas através da decomposição em autovetores das matrizes de correlação $\mathbf{H}\mathbf{H}^T$ e $\mathbf{H}^T\mathbf{H}$ respectivamente e com $\mathbf{\Sigma}$ sendo a raiz quadrada da matriz diagonal dos autovalores que satisfaz a decomposição de ambas as matrizes de correlação.

Um dos problemas ocasionados pelos métodos citados anteriormente é a ocorrência de *overfitting* ou *underfitting*. Redes cujas normas dos pesos são muito grandes, são muito sensíveis à pequenas variações na entrada, prejudicando sua capacidade de generalização (Bartlett, 1998; Huang, 2014). Uma forma de evitar *overfitting* ou *underfitting* é utilizando algum tipo de regularizador, como a regularização L2, sujeitando o cálculo da matriz $\boldsymbol{\beta}$ ao problema de otimização apresentado na Equação (6):

$$\min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{Y}\|_2^2, \quad \text{sujeito a:} \quad \|\boldsymbol{\beta}\|_2^2 \leq C^2 \quad (6)$$

onde C é uma constante que limita a norma L2 da matriz $\boldsymbol{\beta}$. Através do método de Karush-Kuhn-Tucker (KKT) e Lagrange é obtida então a expressão para a pseudoinversa \mathbf{H}^\dagger da ELM regularizada (R-ELM) (Cene e Balbinot, 2018; Huang, 2014):

$$\mathbf{H}^\dagger = \mathbf{H}^T \left(\mathbf{H}^T\mathbf{H} + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{Y} \quad (7)$$

2.4. Redes Neurais Recorrentes (RNR)

Conforme será demonstrado na seção 3.1, este é um método que vem se popularizando no processamento de sEMG e será a ferramenta utilizada para a classificação do tipo de contaminante e para a estimativa do sensor virtual, como será descrito na Metodologia. Nesta seção será apresentada uma revisão teórica das Redes Neurais Recorrentes e na seção subsequente o estado da arte no processamento de sEMG com RNR.

Redes Neurais Recorrentes, definidas por (Rumelhart, Hinton e Williams, 1986), são redes neurais especializadas para processamento de séries temporais ou dados sequenciais (Goodfellow, Bengio e Courville, 2016) na forma:

$$\mathbf{X}_{(i)}^{(t)} = [\mathbf{x}_{(i)}^{(0)}, \mathbf{x}_{(i)}^{(1)}, \dots, \mathbf{x}_{(i)}^{(\tau)}] \quad (8)$$

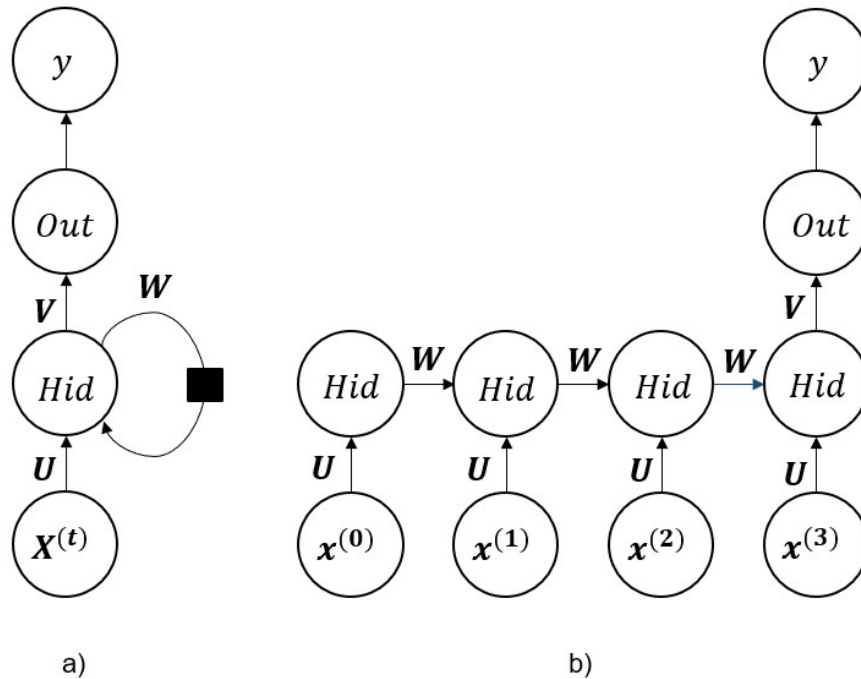
onde (i) representa a dimensão da entrada ou número de características, e (t) representa o instante de tempo da série com tamanho (τ) , sendo $\mathbf{X}_{(i)}^{(t)}$ uma matriz de (τ) colunas e (i) linhas e $\mathbf{x}_{(i)}^{(\tau)}$ o τ -ésimo vetor com (i) linhas.

Esta rede faz parte da família chamadas de *Deep Learning* e o valor do parâmetro (τ) determina a profundidade temporal dela. Na Figura 2 é apresentado um exemplo de rede com profundidade de 4 unidades temporais. A informação é propagada da camada de entrada, representada pela sequência $[\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \dots, \mathbf{x}^{(3)}]$, através dos conjuntos de pesos \mathbf{U} para a camada oculta *Hid*, onde estão localizadas as unidades recorrentes com memória.

A informação armazenada na camada *Hid* é transmitida ao longo do tempo através do conjunto de pesos \mathbf{W} , e após toda sequencia ter sido apresentada, fornece a saída antes da ativação na camada *Out* através dos pesos \mathbf{V} . No caso da Figura 2, a sequência é classificada na camada de ativação y apenas após ter todas amostras apresentadas, numa configuração chamada vários-para-um (*many-to-one*), porém pode classificar a cada passo da série (*many-to-many*), ou até classificar sequências de tamanhos diferentes (Graves, 2012).

Existem aplicações nas mais diversas áreas onde é necessário levar em consideração o contexto temporal da informação, com destaque no processamento da fala (Hanes, Ahalt e Krishnamurthy, 1994; Liu *et al.*, 2016; Pitsilis, Ramampiaro e Langseth, 2018; Thangthai, Milner e Taylor, 2019), reconhecimento de manuscritos (Chherawala, Roy e Cheriet, 2016; Gan, Wang e Lu, 2019; Nguyen *et al.*, 2018; Sueiras *et al.*, 2018) e de predição de funções (LI *et al.*, 2017; Sagheer e Kotb, 2019; Xia e Wang, 2018; Youshen Xia *et al.*, 2005; Zhao *et al.*, 2018).

Figura 2 – Exemplo de Rede Neural Recorrente com profundidade de 4 amostras de tempo. (a) rede em topologia compacta e (b) rede em topologia completa.



Fonte: Autor.

A propagação passo-à-frente da camada de entrada até a camada de saída percorre uma sequência temporal, onde cada passo fica armazenado em uma memória contida na camada *Hid* antes de resultar em uma saída na camada *Out*. A camada *y* aplica uma função de ativação que usualmente pode ser linear, linear retificada (*Rectified Linear Unit* - ReLU), sigmóide, tangente hiperbólica ou *softmax*, sendo as três primeiras geralmente indicadas para funções contínuas e ativações das camadas intermediárias e a última para a última camada em problemas de classificação multi classe onde a classe é dada por *argmax* da camada de saída (Goodfellow, Bengio e Courville, 2016; Graves, 2012). A formulação matemática das funções de ativação é dada pelas Equações (9) a (13). Na Equação (13) é apresentado um exemplo para n classes.

$$\theta_{lin}(x) = a \cdot x \quad (9)$$

$$\theta_{ReLU}(x) = \begin{cases} 0, & \text{para } x < 0 \\ x, & \text{para } x \geq 0 \end{cases} \quad (10)$$

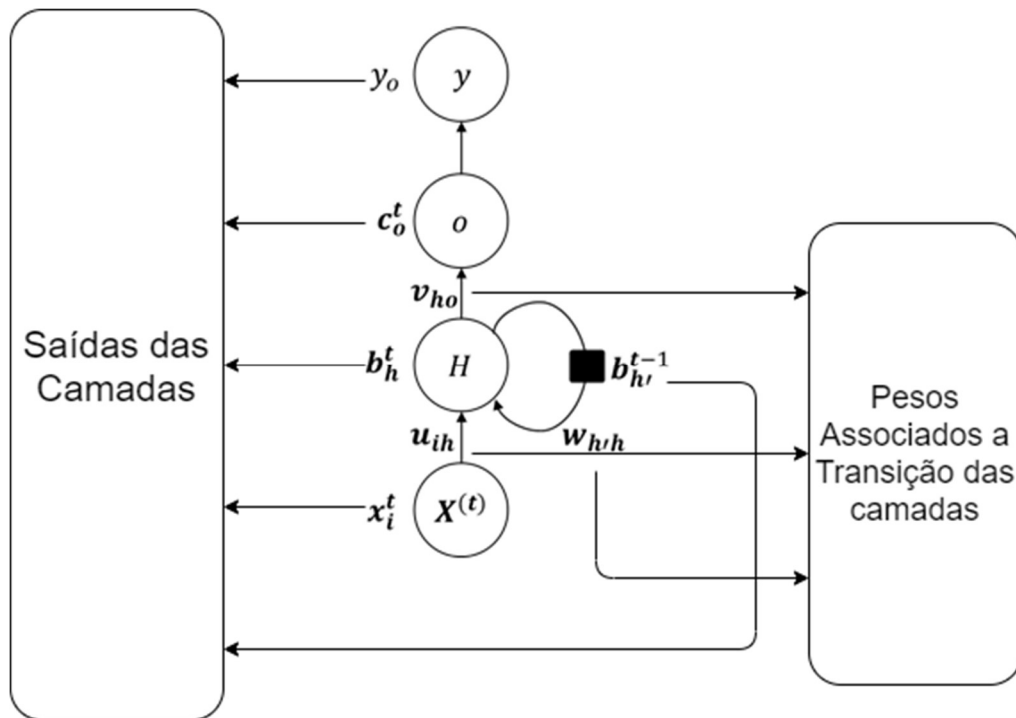
$$\theta_{sig}(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

$$\theta_{\tanh}(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (12)$$

$$x \begin{cases} x_1 \\ x_2 \\ \dots \\ x_n \end{cases} \rightarrow \theta_{\text{softmax}}(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (13)$$

Na Figura 3 são apresentados os pesos e as variáveis geradas pelo passo-a-frente da rede. A camada de entrada $X^{(t)}$ é composta pelos vetores $\mathbf{x}^{(t)}$ conforme Equação (8) sendo x_i^t a i -ésima característica do sinal no instante de tempo t .

Figura 3 – Pesos e variáveis resultantes do passo à frente da rede.



Fonte: Autor

A camada oculta *Hid*, que possui H unidades recorrentes resulta na variável b_h^t que é a h -ésima unidade recorrente no instante de tempo t . A variável b_h^t é resultado da ativação θ_h de a_h^t que é resultado da soma das combinações lineares entre a entrada $\mathbf{X}^{(t)}$ e o conjunto de pesos \mathbf{U} e entre o resultado do instante de tempo anterior $b_{h'}^{t-1}$ e o conjunto de pesos \mathbf{W} . Na Equação (14) pode-se ver os passos para obtenção de b_h^t .

$$a_h^t = \sum_{i=1}^I u_{ih} x_i^t + \sum_{h'=1}^{H'} w_{h'h} b_{h'}^{t-1} \quad (14)$$

$$b_h^t = \theta_h(a_h^t)$$

onde I indica a dimensão ou número de características da entrada e H' o total de conexões recorrentes entre as unidades da camada oculta. O peso $u_{ih} \in \mathbf{U}$ conecta a entrada correspondente à característica i à unidade h da camada oculta e o peso $w_{h'h} \in \mathbf{W}$ conecta a unidade h' à unidade h da camada oculta. A operação é repetida para cada instante de tempo da sequência a ser classificada.

Após a obtenção de b_h^t a informação é propagada da camada oculta *Hid* para camada totalmente conectada *Out* através do conjunto de pesos V . Essa propagação pode ocorrer a cada instante de tempo t ou apenas quando todas as amostras temporais de $\mathbf{X}_{(t)}^{(t)}$ forem apresentadas, como na Figura 2(b). Portanto, uma unidade da saída O após todas as amostras τ serem apresentadas será igual a c_o^τ de acordo com a Equação (15):

$$c_o^\tau = \sum_{o=1}^O v_{ho} b_h^\tau \quad (15)$$

e em seguida a camada y aplica uma função de ativação em c_o^τ , chegando no valor final da saída da rede, para esta unidade, de acordo com a Equação (16).

$$y_o = \theta_y(c_o^\tau) \quad (16)$$

O tamanho da camada de saída O depende da quantidade de variáveis em uma regressão ou das classes em um classificador discreto. Existem outras camadas que podem ser adicionadas nas RNN, como uma camada chamada *Dropout*, que ajuda na generalização da rede.

A camada *Dropout* é uma camada que, em geral, é colocada antes da camada de entrada, mas pode ser colocada antes de camadas ocultas também. Ela possui unidades, cujos pesos são conectados na camada seguinte, que possuem uma probabilidade de não serem treinadas.

Isso permite uma melhor generalização dos dados, segundo resultados experimentais (Srivastava *et al.*, 2014).

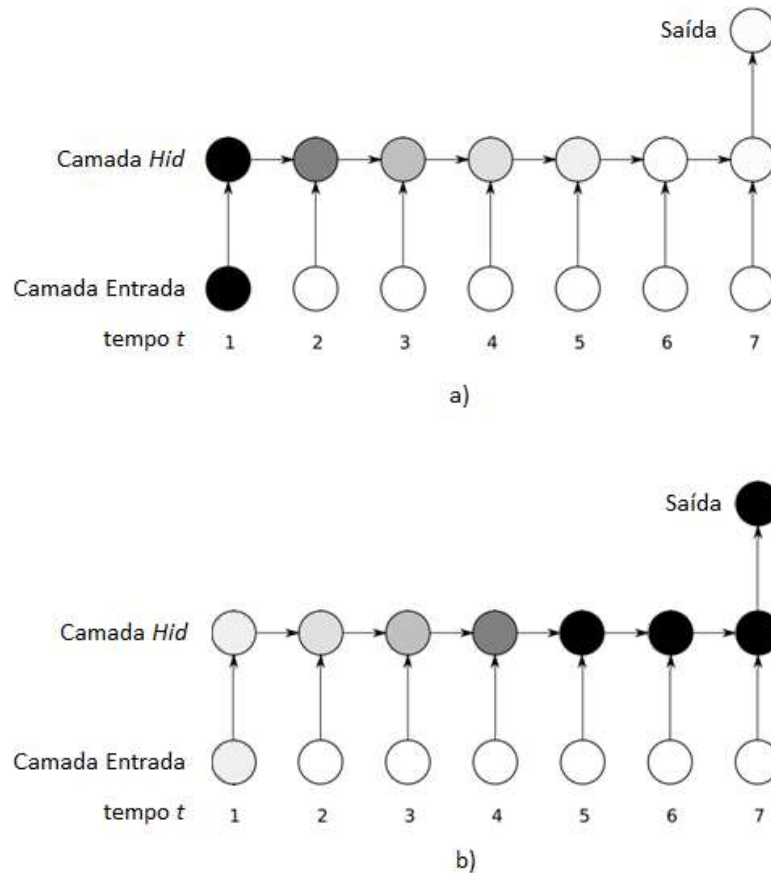
Conforme citado na seção 2.3 a regularização L2 que é aplicada no ELM também pode ser aplicada à RNN-LSTM para evitar *overfitting* e alta variabilidade no conjunto de teste. Quando o conjunto de treinamento é restrito, a tendência é dos pesos se adequarem para esse conjunto, e uma penalidade proporcional à norma L2 do conjunto de pesos é aplicada, afastando o valor dos pesos da tendência.

2.4.1. A unidade Long Short-Term Memory

Uma das maiores limitações das RNN é a dificuldade de armazenamento de informações na camada *Hid* por longos intervalos de tempo (Hochreiter *et al.*, 2001), o que limita o alcance do contexto da informação que consegue ser transmitida até a saída da rede. Na Equação (8) isso representa o impacto que as primeiras amostras causam na saída da rede, até que as τ amostras sejam apresentadas.

O problema se torna significativo na etapa de treinamento do conjunto de pesos W , onde a propagação da informação das primeiras amostras pode não afetar este parâmetro para sequências muito longas em um fenômeno chamado de desaparecimento do gradiente (*gradient vanishing*). Outro problema que também pode ocorrer é a divergência do gradiente (*exploding gradient*), onde a informação das primeiras amostras podem fazer com que os pesos aumentem de forma exponencial (Graves, 2012). Uma representação gráfica dos dois fenômenos descritos anteriormente está apresentada na Figura 4.

Figura 4 – Exemplo gráfico do: (a) desaparecimento do gradiente e (b) divergência do gradiente.



Fonte: Adaptado de (Graves, 2012).

De forma a solucionar este problema, foi proposta uma célula de ativação, da família de células conhecidas como *Gated Recurrent Units* (GRU), que pudesse lidar com estas limitações, chamada de *Long Short-Term Memory* (LSTM) (Hochreiter e Schmidhuber, 1997). A ideia é controlar o fluxo da informação, treinando a rede também para identificar as entradas que são mais ou menos relevantes para a saída. A unidade LSTM possui 3 *gates* de controle do fluxo da informação: *input gate*, *forget gate* – este adicionado posteriormente por (Gers, Schmidhuber e Cummins, 2000) – e *output gate*.

Todos os *gates* funcionam como uma rede a parte a ser treinada, com parâmetros próprios, o que impacta no tempo de treinamento, à medida que se aumenta o número de unidades da camada *Hid*. Um diagrama em blocos do LSTM está representado na Figura 5, onde ele está

inserido em uma rede com 2 unidades na camada *Hid* e com três características na camada de entrada.

A saída de cada *gate* possui uma ativação sigmóide, definida na Equação (11), onde a saída varia entre 0 e 1, assumindo um valor de relevância para aquele dado, onde 0 representaria um dado não relevante e 1 um dado com máxima relevância. A operação passo-a-frente desta rede, se dá da seguinte forma:

1º) O vetor \mathbf{b}_{t-1} representa a saída da camada *Hid* do instante de tempo anterior e se concatena com as três características da entrada (\mathbf{x}_t) no instante de tempo t .

2º) O vetor concatenado passa pelo *forget gate*, onde a ativação sigmóide vai determinar, a relevância do estado de memória anterior (\mathbf{s}_{t-1}) para, posteriormente, atualizar o estado de memória atual (\mathbf{s}_t) e a saída (\mathbf{b}_t).

3º) O *input gate* determina através da função sigmóide a relevância dos dados que vem da Camada de Entrada, onde os dados concatenados no 1º estágio, que passam pelos pesos \mathbf{W} e \mathbf{U} e são ativados por uma função tangente hiperbólica.

4º) O valor do estado anterior e da entrada, modulados pelos *forget gate* e *input gate* respectivamente, são somados para determinar o estado de memória atual (\mathbf{s}_t).

5º) A saída atual da camada *Hid* (\mathbf{b}_t) é determinada pela ativação do resultado do passo 4 por uma função tangente hiperbólica e modulada pelo *output gate* através da função sigmóide.

Considerando que a entrada \mathbf{x}^t possua I características, sendo w_i o peso ligado à i -ésima característica e que na camada oculta (*Hid*) existam H unidades LSTM, sendo w_h o peso ligado a h -ésima unidade e que cada *gate* é considerado uma camada, utilizaremos a notação presente na Tabela 1 para descrever o processamento passo-a-frente da rede e descrito matematicamente pelas equações (17) a (26).

Tabela 1 – Notação utilizada para os pesos presentes na rede exemplificada na Figura 2.

$w_{i\sigma}$	Pesos ligados à σ -enésima saída do <i>input gate</i>
$w_{h\sigma}$	
$w_{i\phi}$	Pesos ligados à ϕ -enésima saída do <i>forget gate</i>
$w_{h\phi}$	
$w_{i\gamma}$	Pesos ligados a γ -enésima saída do <i>output gate</i>
$w_{h\gamma}$	
w_{ic}	Pesos ligados a c -enésima saída da Camada de Entrada
w_{hc}	

- *Input Gate*

$$a_{\sigma}^t = \sum_{i=1}^I w_{i\sigma} x_i^t + \sum_{h=1}^H w_{h\sigma} b_h^{t-1} \quad (17)$$

$$b_{\sigma}^t = \theta_{sig}(a_{\sigma}^t) \quad (18)$$

- *Forget gate*

$$a_{\phi}^t = \sum_{i=1}^I w_{i\phi} x_i^t + \sum_{h=1}^H w_{h\phi} b_h^{t-1} \quad (19)$$

$$b_{\phi}^t = \theta_{sig}(a_{\phi}^t) \quad (20)$$

- *Output gate*

$$a_{\gamma}^t = \sum_{i=1}^I w_{i\gamma} x_i^t + \sum_{h=1}^H w_{h\gamma} b_h^{t-1} \quad (21)$$

$$b_{\gamma}^t = \theta_{sig}(a_{\gamma}^t) \quad (22)$$

- Camada de Entrada

$$a_c^t = \sum_{i=1}^I w_{ic} x_i^t + \sum_{h=1}^H w_{hc} b_h^{t-1} \quad (23)$$

$$b_c^t = \theta_{tanh}(a_c^t) \quad (24)$$

- Estado s_h^t da célula h

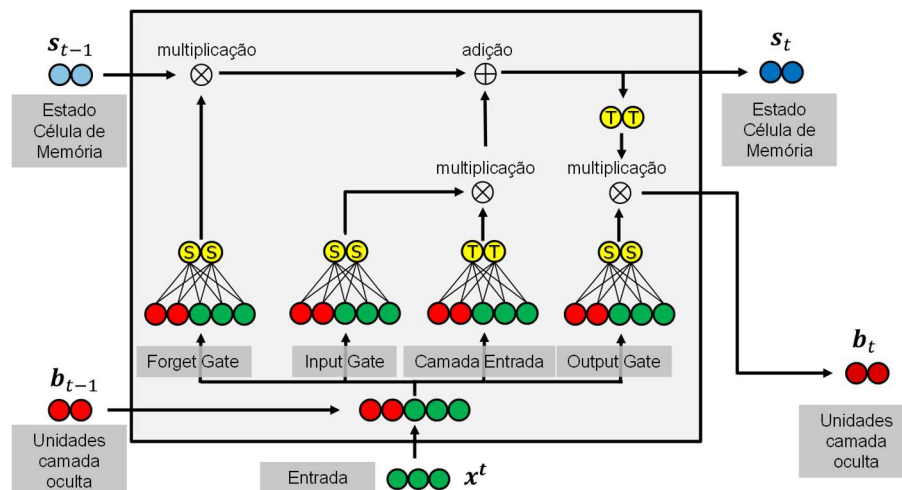
$$s_h^t = s_h^{t-1} \times b_\phi^t + b_\sigma^t \times b_c^t \quad (25)$$

- Saída b_h^t da célula h

$$b_h^t = \theta_{\tanh}(s_h^t) \times b_\gamma^t \quad (26)$$

Um exemplo com duas unidades na camada oculta está representada na Figura 5, onde círculos verdes representam o vetor de entrada (\mathbf{x}^t), com três características, no instante de tempo t que concatenam com o vetor composto com a saída da camada Hid (\mathbf{b}_{t-1}) no instante de tempo anterior, em $(t-1)$. Círculos azuis claros (\mathbf{s}_{t-1}) representam o estado em $(t-1)$ da memória interna do LSTM. Círculos vermelhos e azul escuro representam a saída da camada Hid (\mathbf{b}_t) e o estado da memória (\mathbf{s}_t), respectivamente, em t . Círculos amarelos com S e T no centro representam as saídas com ativações Sigmóide e Tangente Hiperbólica, respectivamente

Figura 5 – Diagrama em blocos de uma rede com 2 unidades LSTM.



Fonte: Autor


Existem algumas variantes da LSTM, onde alguns parâmetros existentes foram simplificados ou novos foram adicionados. O estudo de (Greff *et al.*, 2017) comparou 8

diferentes arquiteturas da LSTM, onde a arquitetura básica, possui um desempenho próximo dos modelos modificados, sendo estável na etapa de treinamento e com um relativo baixo custo computacional, comparada a outras arquiteturas da LSTM, visto que mesmo apresentando desempenho semelhante, possuem mais parâmetros para serem estimados, o que impacta no treinamento e na classificação, ao adicionar operações matemáticas no modelo. O estudo também demonstrou que o *forget gate* e a função de ativação da saída são componentes críticos, sendo que remover qualquer um deles degrada de forma significativa seu desempenho.

2.4.2. Treinamento da RNR

O treinamento é realizado através do método de retro propagação através do tempo, ou *Back Propagation Throught Time* (BPTT), onde o gradiente da função perda \mathcal{L} é propagado da saída até a entrada através das amostras da série a ser classificada. A perda total é igual à soma das perdas parciais, de acordo com a Figura 6, onde é apresentada uma sequência de tamanho 4 e a Equação (27) para uma sequência de tamanho τ .

Figura 6 – Função perda \mathcal{L} . Seu valor é determinado a partir das somas das perdas parciais $\mathcal{L}^{(t)}$ determinadas a partir da saída verdadeira y_v e saída prevista y_p .



Fonte: Autor

$$\mathcal{L} = \sum_{t=0}^{t=\tau} \mathcal{L}^{(t)} \quad (27)$$

A função perda \mathcal{L} é determinada de acordo com a natureza do problema, como a entropia cruzada categórica para classificações discretas multi-classes ou o erro médio quadrático para casos contínuos. A atualização dos pesos é dada pelo gradiente obtido através do BPTT, conforme Figura 7.


De forma simplificada, se derivarmos parcialmente a Equação (27) em relação ao conjunto de pesos recorrente \mathbf{W} obtemos a seguinte equação:

$$\frac{\partial \mathcal{L}}{\partial \mathbf{W}} = \sum_{\tau} \frac{\partial \mathcal{L}^{(t)}}{\partial \mathbf{W}} \quad (28)$$

Para computar o valor de $\frac{\partial \mathcal{L}^{(t)}}{\partial \mathbf{W}}$ é utilizada a regra da cadeia, considerando uma rede simplificada:

$$\frac{\partial \mathcal{L}^{(t)}}{\partial \mathbf{W}} = \frac{\partial \mathcal{L}^{(t)}}{\partial y_p^{(t)}} \frac{\partial y_p^{(t)}}{\partial \mathbf{b}^{(t)}} \frac{\partial \mathbf{b}^{(t)}}{\partial \mathbf{W}} \quad (29)$$

Figura 7 – Representação gráfica da propagação de uma RNN simplificada. $\mathbf{b}^{(t)}$ representa o estado da camada oculta no instante de tempo t .



Fonte: Autor

Porém, de acordo com a Equação (14), o valor de $\mathbf{b}^{(t)}$ depende do valor de $\mathbf{b}^{(t-1)}$, que depende de \mathbf{W} e $\mathbf{b}^{(t-2)}$ e assim em diante, de acordo com a Equação (30).

$$\frac{\partial \mathcal{L}^{(t)}}{\partial \mathbf{W}} = \sum_{k=0}^t \frac{\partial \mathcal{L}^{(t)}}{\partial y_p^{(t)}} \frac{\partial y_p^{(t)}}{\partial \mathbf{b}^{(t)}} \frac{\partial \mathbf{b}^{(t)}}{\partial \mathbf{b}^{(k)}} \frac{\partial \mathbf{b}^{(k)}}{\partial \mathbf{W}} \quad (30)$$

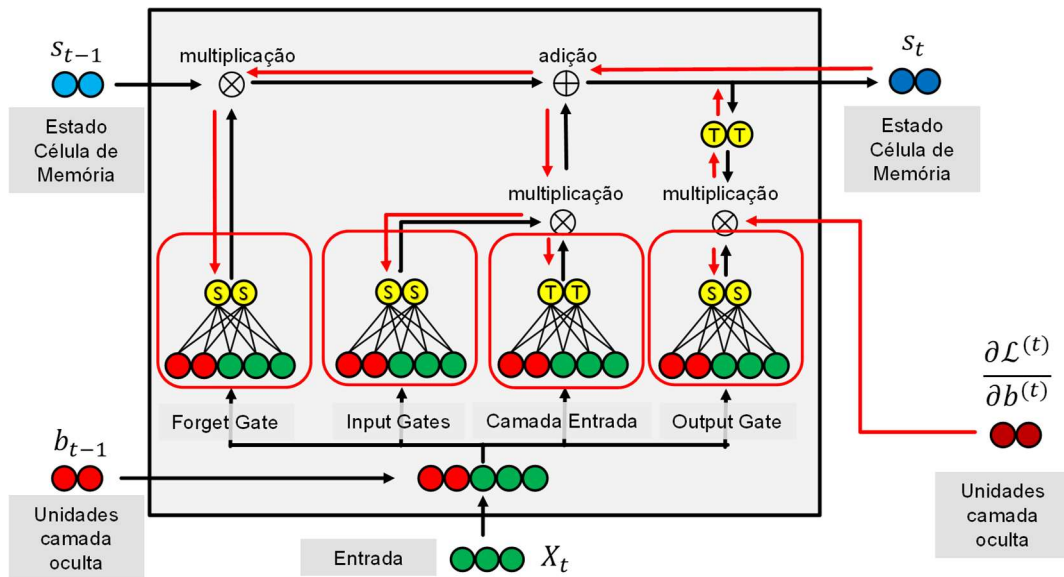
A atualização do conjunto de pesos é então calculada pela Equação (31):

$$\Delta \mathbf{W} = -\alpha \frac{\partial \mathcal{L}}{\partial \mathbf{W}} \quad (31)$$

onde $\alpha \in [0,1]$ é a taxa de aprendizagem.

Para uma rede com unidades LSTM o raciocínio pode ser estendido como demonstrado na Figura 8 onde a propagação do gradiente está representada pelas setas vermelhas.

Figura 8 – Propagação do gradiente da função perda dentro de uma rede LSTM com 2 unidades.



Fonte: Autor

3. ESTADO DA ARTE

3.1. Uso de RNR no processamento do sinal de sEMG

Nesta seção será apresentado o estado da arte em processamento de sEMG com RNN, principalmente com o uso de unidades LSTM. Foram utilizados os termos de busca: ("*surface electromyography*" OR *electromyography* OR *electromyographic* OR "*electromyographic activity*" OR *semg* OR *emg*) AND ("*Recurrent Neural Network*" OR "*Recurrent Network*" OR "*RNN*" OR *lstm* OR "*Long Short-Term Memory*")) nas bases de dados *Scopus*, *Web of Science* e *IEEE* e foram excluídos artigos que tratam da análise de marcha, pois o objetivo da RNN neste caso é capturar o elemento periódico da caminhada, diferente dos objetivos deste trabalho que é realizar classificação e regressão de um sinal não periódico.

Os primeiros trabalhos com processamento de dados de EMG com o uso de RNRs encontrados nas bases de dados *IEEE*, *Web of Science* e *Scopus* foram realizados pelos belgas Chero *et al.* e Cheron & Bourgeois (Cheron *et al.*, 1996; Draye *et al.*, 1997). O trabalho dos belgas tinha por objetivo mapear o comportamento espacial e cinético do membro superior ao desenhar um número 8 utilizando o sinal bruto de sEMG como entrada para uma RNR. Sete canais de sEMG do membro superior e dorso foram monitorados e sincronizados com dados da trajetória espacial adquiridos através de um sistema instrumentado por imagem com o uso de quatro marcadores presos no braço. As coordenadas x e y da trajetória do braço foram preditas com sucesso, utilizando 18 neurônios na camada oculta e 2 na camada de saída, cada um com uma constante temporal, determinada durante o treinamento.

Utilizando a mesma rede, o mesmo grupo belga de pesquisa desenvolveu outro trabalho adicionando a análise postural (Draye, Winters e Cheron, 2002). Dados brutos retificados de oito canais de sEMG foram utilizados como entrada da rede, cuja saída indicava a aceleração angular do quadril, joelho e tornozelo e após uma dupla integração dos dados, era obtida a

posição angular de cada articulação, determinando assim a postura dos indivíduos. Na mesma linha de estudos sobre a cinemática e trajetória do corpo, o estudo de (Cheron *et al.*, 2003) analisa a locomoção humana através da aquisição de 6 sinais de EMG localizados nos membros inferiores.

O primeiro estudo a incorporar amputados para classificar posturas da mão com o uso de redes recorrentes foi de (Bu, Fukuda e Tsuji, 2003), onde cinco voluntários, sendo dois amputados e três com membros íntegros, realizaram seis diferentes movimentos de posturas da mão e punho, enquanto dados de EMG de seis a oito canais eram adquiridos.

Bu, Fukuda e Tsuji utilizaram uma RNR baseada em um Modelo de Mistura Gaussiana (GMM – *Gaussian Mixture Model*) e Modelos Ocultos de Markov (HMM – *Hidden Markov Models*). A HMM neste trabalho foi incluída para caracterizar as relações condicionais dos parâmetros gaussianos da GMM, e assim levar em consideração o contexto passado. A entrada da rede consistia em sinal bruto de 6 canais que eram constantemente classificados. Antes de passar pela rede, a sequência passava por uma transformação não linear e os melhores resultados foram obtidos para sequências 2 a 5 amostras, mostrando uma certa dificuldade da rede em identificar mudança de movimentos dentro de uma sequência. Neste modelo, cada classe possui um conjunto de estados, representados por duas camadas da rede onde ocorre a recorrência (próximo estado depende do estado anterior), cujas entradas são alimentadas por dados de uma etapa anterior que é treinada para aprender densidades de probabilidade condicional dos estados, dada uma classe.

Em (Fukuda, Arita e Tsuji, 2006) foi realizado utilizando o mesmo modelo de rede com o objetivo de reconhecer a trajetória do dedo indicador da mão num espaço de duas dimensões. Foram utilizados sete sujeitos, sendo um deles com amputação abaixo do cotovelo. Foram coletados sinais de sEMG de sete a oito músculos e utilizados segmentos de 20 amostras no tempo do dado bruto para treinamento e 5 amostras para classificação.

Utilizando a recorrência não entre as camadas ocultas, mas da saída da rede diretamente para a entrada foi a configuração utilizada por (Song e Tong, 2005) para estimar o torque realizado pelo cotovelo em um dado movimento. Além da realimentação da saída da rede, a camada de entrada também possuía 3 canais de EMG e outros 3 canais com informações dinâmicas do posicionamento do cotovelo.

Com o objetivo de sintetizar diversos sinais biológicos com o uso de uma RNR-GRU Belo *et al.* (2017) projetaram uma rede com 3 camadas recorrentes e sintetizaram através do método de *autoencoder* o sinal de respiração, ECG, EMG, dentre outros. Como exemplo para a rede, sequências do valor RMS, calculado em uma janela de 70ms, do sinal de sEMG coletado da perna de um indivíduo durante o uso em uma bicicleta ergométrica foi utilizado. A saída da rede era uma camada da função *softmax* de 64 classes, que não é usual para regressão de sinais contínuos, como o de sEMG. Isso foi feito de forma que o sinal gerado pelo *autoencoder* foi sub-quantizado em apenas 64 níveis, cada nível representando uma classe na função *softmax*. Segundo os autores, isto permitia reduzir a complexidade do sinal e melhorar a performance da rede, porém a um custo de uma limitação muito alta ao reduzir a precisão da amplitude para um valor de apenas 6 bits.

Após o estudo de Atzori, Cognolato e Müller (2016) demonstrar a eficiência das Redes Neurais Convolucionais (RNC) em sinais de EMG, o estudo de Xia, Hu e Peng (2018) propôs um método híbrido entre RNC e RNR-LSTM para reconhecimento da trajetória da mão a partir de sinais de EMG de 8 voluntários e utilizando 5 músculos do braço. A rede híbrida proposta consiste em 3 camadas convolutivas, seguidas por 2 camadas recorrentes com o uso do LSTM. A entrada da rede é uma sequência de 20 componentes de frequência extraídos em uma janela deslizante de 50ms com passo de 20ms. Com o modelo híbrido, obtiveram um coeficiente de semelhança de 90,3%, entre a trajetória estimada e a trajetória experimental, e

se mostrou melhor que outros 2 modelos analisados, o *Support Vector Regression* (SVR) e arquiteturas de redes convolutivas tradicionais.

A mesma equipe de pesquisadores chineses realizou outro estudo (Wang *et al.*, 2018), onde aplicou a rede híbrida no *dataset* de domínio público NinaPro (Atzori *et al.*, 2015). Neste estudo, a base de dados NinaPro foi utilizada para gerar uma transferência de aprendizagem para a rede híbrida RNR-RNC. Neste estudo, além do sinal de EMG, são utilizados dados obtidos através de acelerômetros, criando uma fusão de sensores na entrada da rede. Este modelo se mostrou superior na classificação dos movimentos da mão, comparado ao SVM e RNC.

Com o sucesso do uso das RNC para processamento de imagens, os pesquisadores (Hu *et al.*, 2018) propuseram uma rede RNC-RNN com mecanismo de atenção para classificação de movimentos da mão, onde o sinal de sEMG é transformado em uma imagem tipo mapa de calor. O processo de transformação do sinal de sEMG em imagem é realizado no tempo e a imagem também passa por uma transformada de Fourier espacial. Foram abordados dois tipos de base de dados, uma com matrizes de eletrodos de alta densidade e base de dados com eletrodos esparsos, como a NinaPro DB1 com 10 canais. Para o caso de eletrodos esparsos, o conjunto de canais foi replicado e rearranjado de acordo com o algoritmo proposto por (Jiang e Yin, 2015) que permite que todos canais estejam adjacentes uns aos outros. Dessa forma a rede pode utilizar todas as características espaciais entre canais.

As imagens geradas para cada instante de tempo com todos os canais eram as características de entrada da RNC com 2 camadas convolucionais e duas camadas localmente conectadas. Após cada instante de tempo passar por mais duas camadas totalmente conectadas, essas saídas passavam por uma rede LSTM cuja saída *many-to-many* eram as entradas da rede de atenção. A saída da rede de atenção alimentava uma camada totalmente conectada com o número de saídas iguais a quantidade de movimento de cada base de dados

utilizada onde uma função *softmax* determinava a classe final. O mecanismo de atenção na rede não foi capaz de gerar um substancial ganho na classificação dos gestos e a metodologia se mostrou muito mais robusta para classificar base de dados com matrizes de eletrodos.

Em Xu *et al.* (2018) foi descrito um método utilizando RNC, RNN-LSTM e RNC-RNN-LSTM para estimar a força a partir da contração do bíceps utilizando uma matriz de eletrodos com 128 canais. Diversas etapas de pré-processamento são realizadas, incluindo a análise visual para excluir canais com comportamento visivelmente anômalos e o uso de PCA como um filtro espacial. Os 32 canais mais relacionados aos padrões de força são selecionados para o treinamento. Foram utilizadas redes longas com quase 7 mil amostras na configuração *many-to-many*, visto que força é uma variável contínua. Para a rede RNN-LSTM foram utilizadas duas camadas LSTM com 128 unidades cada e uma taxa de *dropout* igual a 0,9. A RNC individualmente teve comportamento inferior a RNN-LSTM e RNC-RNN-LSTM que tiveram comportamento semelhante.

Com o intuito de estimar ângulos do ombro com 3 graus de liberdade e o ângulo do cotovelo com 1 grau de liberdade Chen *et al.* (2019) propuseram uma rede LSTM de três camadas com 20 unidades LSTM em cada e compararam os resultados com uma RNA de três camadas e 20 neurônios em cada camada. Para o estudo foram utilizados 8 canais de sEMG de músculos envolvidos com movimento do braço enquanto a angulação das articulações era medida por vídeo com o uso de marcadores. Quatro características extraídas no tempo (RMS, MAV, WL e VAR) em uma janela de 10ms para um sinal adquirido a uma taxa de 2kHz foram extraídos para a classificação. A raiz do erro médio quadrático foi utilizada como função perda e utilizada, juntamente com o escore R^2 como métricas de desempenho. A RNR-LSTM tinha uma saída *many-to-many* e apresentou desempenho superior a RNA para trechos de 120s de sinal.

Um resumo dos trabalhos apresentados nessa seção está sumarizado na Tabela 2. Avaliando os 11 trabalhos analisados nessa seção, pelo menos 6 utilizam o sinal bruto do sEMG. Essa abordagem é adequada, visto que uma das funções da rede é aprender as características temporais mais relevantes dentro de uma sequência do sinal, tanto em tarefas de regressão como de classificação. Quando as redes são utilizadas em conjunto com Redes Convolutivas, observa-se que há uma certa adaptação, transformando o sinal de sEMG ou suas características tempo-frequência em imagens antes de aplicar as redes. Esse método é custoso computacionalmente e não parece muito adequado para sistemas embarcados, como utilizados em próteses, por exemplo. O uso de redes Convolutivas é mais adequado para eletromiografia de alta densidade, onde um conjunto de eletrodos é representado por uma matriz.

Nenhum estudo é relacionado a análise de qualidade de sEMG e apenas um trabalho aborda regressão do sinal de sEMG (Belo *et al.*, 2017), mas com uma abordagem de saída discreta e não contínua, além de utilizar uma características do sinal sEMG para regressão e não propriamente o sinal bruto.

3.2.Deteção de contaminantes do sinal sEMG

Nesta seção é apresentado o estado da arte na deteção de contaminantes do sinal sEMG. Foi utilizado termo de busca ("*surface electromyography*" OR *electromyography* OR *electromyographic* OR "*electromyographic activity*" OR *semg* OR *emg*) AND (*noise* AND ("*signal quality*" OR "*artifact contamination*" OR *quality*)). Desta busca, os trabalhos foram refinados considerando os seguintes critérios:

- 1) artigos publicados em *journals*;
- 2) trabalhos onde o sinal de sEMG era contaminado e não o contaminante;
- 3) tratavam da deteção e não da mitigação do contaminante.

Tabela 2 – Publicações de processamento de sEMG por RNN-LSTM.

Paper	Tipo de RNR	Arquitetura	Dados Entrada	Objetivo
(Cheron <i>et al.</i> , 1996) (Draye <i>et al.</i> , 1997)	Dinâmica com regularização temporal baseada em equações diferenciais	- <i>Many-to-many</i> - <i>Stateful</i> - 18 neurônios camada oculta - 2 neurônios na camada de saída	- Sinal sEMG bruto	- Regressão da trajetória x-y do braço por sinais de sEMG
(Draye, Winters e Cheron, 2002)	Dinâmica com regularização temporal baseada em equações diferenciais	- <i>Many-to-many</i> - <i>Stateful</i> - Arquitetura modular entre postura e inércia	- Sinal sEMG bruto	- Determinar a postura das articulações do quadril, joelho e tornozelo a partir de sinais de sEMG
(Cheron <i>et al.</i> , 2003)	Dinâmica com regularização temporal baseada em equações diferenciais	- <i>Many-to-many</i> - <i>Stateful</i> - Arquitetura modular entre postura e inércia	- Sinal sEMG bruto	- Comportamento das pernas durante caminhada.
(Bu, Fukuda e Tsuji, 2003)	Baseada em HMM e GMM.	- <i>Many-to-one</i> - 5 camadas	- Trechos do sinal sEMG bruto (1 a 20 amostras) - Estimativa de força (trigger)	- Classificar 6 movimentos das mãos
(Fukuda, Arita e Tsuji, 2006)	Baseada em HMM e GMM.	- <i>Many-to-one</i> - 5 camadas	- Treino com 20 amostras de sinal sEMG bruto - Regressão x-y utilizando 5 amostras de tempo do sinal sEMG bruto	- Coordenadas x-y de um mouse
(Song e Tong, 2005)	Com realimentação saída-entrada	- <i>Many-to-many</i> - <i>Stateful</i> - 3 camadas	- Dados cinéticos, sinal de sEMG bruto e saída realimentada	- Torque do cotovelo
(Belo <i>et al.</i> , 2017)	Com GRU	- <i>Many-to-one</i> - <i>Stateful</i> - 3 camadas	- Valor RMS em uma janela de 70ms foi utilizado para treino - Para sintetização, valores da saída são realimentados na entrada (<i>autencoder</i>)	- Sinal sintético de sEMG, subquantizado para 6 bits.
(Xia e Wang, 2018)	Híbrida com RNC	- <i>Many-to-one</i> - Camadas convolutivas precedendo a RNR	- 20 componentes de frequência extraídos de uma janela de 50ms	- Trajetória da mão
(Wang <i>et al.</i> , 2018)	Híbrida com RNC e fusão utilizando transferência de aprendizagem	- <i>Many-to-one</i> - Camadas convolutivas precedendo a RNR	- 20 componentes de frequência extraídos de uma janela de 50ms - Dados acelerometria	- 17 Movimentos base NinaPro
(Hu <i>et al.</i> , 2018)	Híbrida com RNC e mecanismo de atenção	- <i>Many-to-many</i> - Camadas convolutivas precedendo a RNR - Mecanismo de atenção na saída da RNR	- Canais de eletromiografia transformados em imagem com 20 canais de cor	- 52 movimentos NinaPro DB1 - 50 movimentos NinaPro DB2 - 26 movimentos BioPatRec26MOV - 8 movimentos CapgMyo-DBa - 27 movimentos csl-hdemg
(Chen <i>et al.</i> , 2019)	LSTM com 3 camadas	- <i>Many-to-many</i> - 3 camadas com 20 unidades	- 4 características temporais extraídas em uma janela de 10ms	- 4 medidas de ângulo do ombro e cotovelo

O sinal sEMG, assim como todo bio-sinal, está sujeito a interferências eletromagnéticas geradas pelo corpo, pelos equipamentos utilizados para aquisição e medição ou por outros fatores externos (Clancy, Morin e Merletti, 2002). Existem diversos estudos dedicados à qualidade do sinal sEMG, que abordam diferentes aspectos que podem ser divididos em 4 categorias (Fraser *et al.*, 2014; McCool *et al.*, 2014):

- 1) detecção: determina quando um contaminante está presente no sinal;
- 2) identificação: distingue o tipo de contaminante;
- 3) quantificação: realiza uma métrica para avaliar a severidade da contaminação;
- 4) mitigação: aborda técnicas para atenuar ou remover o contaminante.

Um dos primeiros trabalhos com foco na detecção de contaminantes de EMG, foi proposto por Arvidsson, Grassino e Lindstrom (1984). Nesta pesquisa, sinais de EMG obtidos de forma invasiva do Diafragma, que costumam ser altamente contaminados por ECG e Artefato de Movimento, foram separados visualmente entre contaminados e não contaminados para realizar o treinamento e teste do classificador. Com quatro características, duas em frequência e outras duas no domínio tempo, e com o uso de um classificador quadrático aliado a um *threshold*, cuja saída era binária, indicando apenas se o sinal estava contaminado ou não. As características eram extraídas em janelas de 128ms, 256ms e 512ms, sendo a janela de 512ms a que obteve os melhores resultados com 10% de falsos positivos para contaminação e 2,2% de falso negativo.

O mesmo grupo de pesquisa do trabalho anterior publicou uma continuação do trabalho em (Sinderby, Lindstrom e Grassino, A. E., 1995), onde o músculo do diafragma foi novamente utilizado, além de sinais do diafragma de cães e sinais de EMG sintéticos. Neste estudo foram propostos índices baseados nas características que indicariam contaminação por artefato de movimento ou ECG e a partir de qual valor destes níveis o sinal poderia ser considerado ideal para análises. Foram utilizadas janelas de 512ms, mas poderiam ter até 1s e

a análise foi realizada em torno da frequência central do espectro, que é um parâmetro importante no estudo de fadiga do diafragma.

Em (Fraser *et al.*, 2014), os pesquisadores utilizam um SVM estendido de apenas uma classe (Chang e Lin, 2011) para detectar contaminantes no sinal de sEMG. A técnica encontra um pequeno volume para agrupar os dados dentro do espaço de características, sendo que o conjunto de treinamento possui apenas a classe positiva de sinais não contaminados. No estudo foram avaliadas 31 características diferentes, onde foi encontrado um sub-espaço ótimo de seis, demonstrando que o contaminante modifica as características de forma que o SVM consiga identificar a presença do contaminante. Os contaminantes testados, em diferentes níveis de SNR, foram: interferência da linha de energia, artefato de movimento, interferência por ECG, ruído de quantização, *clipping* e saturação do amplificador. Foi demonstrado que à medida que o SNR do sinal contaminado diminui, o classificador tem maior chance de classificar como contaminado. Para diferentes contaminantes, foram observados diferentes valores de transição do SNR entre o sinal contaminado e não contaminado, sendo -5dB para o ECG e 29 dB para o ruído de quantização.

Como diferentes tipos de contaminantes podem necessitar diferentes ações para sua mitigação, a identificação do tipo de contaminante pode ser essencial. Em McCool *et al.* (2014) com o uso de sEMG coletado experimentalmente e gerado de forma sintética, uma SVM multi-classes *one-vs-one* foi desenvolvido para identificar 5 tipos de contaminantes: Artefato de Movimento, Interferência de Linha Elétrica, ECG, Saturação e Ruído Branco Aditivo. Sete características são extraídas para realizar a classificação, sendo quatro em frequência e três no domínio tempo. O modelo desenvolvido não identifica o sinal não contaminado, sendo necessário um estágio anterior para identificar se o sinal está contaminado ou não.

A metodologia para definir o SNR em McCool *et al.* (2014) é através de frações de 20%, 40% e 60% da Contração Voluntária Máxima (CVM) dos 3 músculos utilizados no estudo, *bíceps brachii*, *quadríceps femoris* e *tiabialis anterior*. Janelas de 1, 2 e 5s foram utilizadas, sendo as janelas de 2 e 5s as que apresentam melhores resultados. O conjunto de treinamento é realizado com todos os níveis de contração e com 3 níveis de SNR: -20dB, -10dB e 0dB.

Os testes conduzidos pelo estudo de McCool *et al.* (2014) demonstraram que para baixos níveis de SNR, -20dB e -10dB, o sistema possui uma taxa de acerto maior que 99% para todos contaminantes reduzindo a medida que o SNR aumenta até 20dB. Os contaminantes que mais se confundiam entre si foram Artefato de Movimento e ECG.

Um sistema tolerante a falhas, que funcionava de forma *online*, foi desenvolvido por Zhang e Huang (2015), onde um sistema de detecção de falhas que utilizava como métrica de similaridade a distância de Mahalanobis, detectava três tipos de contaminantes no sinal de EMG – artefato de contato, contato solto e ruído branco adicionado ao sinal com 3 níveis diferentes de variância – sem a necessidade do conhecimento prévio da perturbação. Foram realizados testes com cinco indivíduos com membros superiores íntegros e um amputado congênito, que realizaram sete diferentes classes de movimento enquanto eram coletados dados de seis músculos do antebraço. O treinamento para a detecção de contaminantes é realizado de forma semelhante à SVM de uma classe, sendo que o sistema baseado em Mahalanobis funciona como um detector de amostras *outliers*. Para os indivíduos não amputados, o estudo obteve mais de 80% de acerto nos contaminantes para contato solto, artefato de contato e ruído branco com máxima variância. À medida que a variância do ruído branco diminui, a taxa de detecção também diminui, fenômeno observado para todos os indivíduos. O sistema obteve taxas de falso positivo abaixo de 3%.

Moura, de e Balbinot, 2018 apresentam uma SVM binária que é responsável por classificar sinais íntegros ou contaminados ao avaliar continuamente 12 canais através de

janelas deslizantes, com dados obtidos através da base NinaPro DB2 e DB3. Cinco diferentes contaminantes são utilizados: artefato de movimento, ruído de linha, ECG, saturação e eletrodo descolado. O trabalho obteve uma taxa de acerto de 85,31% para detecção dos contaminantes e uma taxa de 8,18% de falsos positivos para canais não contaminados artificialmente.

A análise automática da qualidade do sinal de sEMG é uma área ainda pouco explorada (Lovell *et al.*, 2010; McCool *et al.*, 2014) e uma das últimas publicações a respeito (Ijaz e Choi, 2018) trata a respeito de um método de análise de contaminantes por um Mapa Auto Organizável (*Self-Organizing Map* – SOM) aplicado a 4 canais de sEMG das costas e um conjunto de dados sintéticos. Ruído branco, artefato de movimento sintético, ECG, Ruído de linha e uma mistura de ruídos foram analisados. Componentes da transformada *wavlet* selecionada através de PCA foram utilizadas como características de entrada e as métricas utilizadas, precisão e *recall*, sendo a pior performance para o artefato de movimento, que teve falsos negativos superiores a verdadeiros positivos. O estudo não apresente nenhuma análise do nível de contaminação do sinal.

Os trabalhos sobre análise de qualidade do sinal de sEMG estão sumarizados na Tabela 3. O que se observa dos 7 trabalhos encontrados é que os contaminantes mais utilizados são: Artefato de movimento (7), ECG (6), Ruído Branco (6), Ruído de Linha (4), Saturação (3), *A/D Clipping* (1), Erro Quantização (1), Eletrodo Descolado (1).

Algo notável é que apenas os estudos de (Fraser *et al.*, 2014; McCool *et al.*, 2014; Zhang e Huang, 2015) apresentam uma metodologia clara para definição do SNR e realizam testes em diferentes níveis, pois é mais provável que a contaminação ocorra em diferentes níveis, que dependem da proximidade da fonte de contaminação, da qualidade e correto posicionamento dos eletrodos. Além disso, todos detectores necessitam de diferentes características, desde os detectores de *outliers*, considerados sistemas mais simples, até

sistemas mais complexos que utilizam ferramentas de IC. Como visto na seção anterior, as RNR podem realizar tarefas de classificação utilizando o sinal bruto de sEMG, que podem simplificar o processo de identificação de contaminantes.

Tabela 3 – Publicações de trabalhos sobre análise de qualidade do sinal sEMG

Trabalho	Contaminantes	Níveis SNR	Tipo Características	Ferramenta
(Arvidsson, Grassino e Lindstrom, 1984)	ECG, Artefato de movimento, Ruído Branco	Não especificado	2 domínio tempo e 2 domínio frequência em janelas de 512ms	Regressor quadrático
(Sinderby, Lindstrom e Grassino, A. E., 1995)	ECG, Artefato de movimento, Ruído Branco	Não especificado	4 domínio frequência em janelas de até 1s	Índices a partir das características
(Fraser <i>et al.</i> , 2014)	Ruído de Linha, Artefato de movimento, ECG, A/D <i>clipping</i> , erro quantização e saturação	-20dB a 20dB	Coefficientes autorregressivos; Histograma do sEMG; Valor absoluto da média; Frequência Mediana Modificada; Frequência Média Modificada; Histograma Espectral; Inclinação na Variação do Sinal; Amplitude de Willison, <i>Waveform Length</i> ; Cruzamento por zeros	SVM de apenas uma classe determinava apenas se o sinal estava contaminado ou não.
(McCool <i>et al.</i> , 2014)	Artefato de Movimento, Ruído de Linha, ECG, Saturação e Ruído Branco Aditivo	-20dB a 20dB	Razão Sinal-Ruído de Linha; Razão Sinal-Artefato de Movimento; Máximo-para-mínima caída na razão de potência; Deformação da potência Espectral; Razão Sinal-ECG; Coeficiente de correlação para normalidade	SVM <i>one-vs-one</i> para identificar os 5 tipos de contaminantes
(Zhang e Huang, 2015)	Artefato de Movimento; Eletrodo Descolado; Ruído Branco	Especificado para ruído branco em 3 níveis.	Valor Absoluto da Média; Número de cruzamentos por Zero; <i>Waveform Length</i> , Inclinação na variação do sinal	Detector de <i>Outlier</i> baseado na distância de Mahalanobis
(Moura, de e Balbinot, 2018)	Artefato de Movimento; Saturação; Ruído Branco; Ruído de Linha; ECG	Não especificado	Valor Absoluto da Média; RMS; <i>Waveform Length</i> ; <i>Maximum Fractal Length</i> ; Potência	SVM binário
(Ijaz e Choi, 2018)	Ruído Branco; ECG; Ruído de Linha; Artefato de Movimento	Não especificado	Componentes da transformada <i>wavelet</i> selecionados por PCA	Mapa Auto Organizável

3.3. Sistemas Tolerante a Falhas com Aplicações em Sinais de sEMG

Diversas abordagens podem ser adotadas para tornar sistemas de classificação baseados em sinais de sEMG mais robustos, pois existem diferentes causas para a degradação do desempenho dos classificadores (Kyranou, Vijayakumar e Erden, 2018). Uma das causas, conforme visto na seção anterior, é a contaminação ou falha na leitura do sinal de sEMG e será abordada nessa seção os trabalhos mais atuais que tenham dispositivos adaptativos frente a um canal contaminado ou em falha.

Para a seleção dos artigos foram utilizados alguns do mesmo termo de busca da seção anterior, sobre contaminação e que possuíam algum mecanismo de mitigação. Além disso o termo (*"surface electromyography" OR electromyography OR electromyographic OR "electromyographic activity" OR semg OR emg*) AND (*noise AND ("signal quality" OR "artifact contamination" OR quality)*) AND (*robust OR ("fault tolerant")*) foi utilizado para limitar sistemas robustos que possuam falhas por contaminantes. Também foram excluídos trabalhos que tratavam de hardware, como o desenvolvimento de materiais para eletrodos, por exemplo e trabalhos que utilizavam eletrodos de EMG invasivos.

O sistema tolerante a falhas de (Zhang e Huang, 2015), descrito na seção anterior, possui um sistema adaptativo que é composto de um classificador LDA retreinado cada vez que é identificada falha em algum canal. O retreinamento é realizado removendo do vetor de entrada do(s) canal(s) contaminado(s) e removendo os parâmetros relacionados a este(s) canal(s) dentro da matriz do classificador. Foi utilizado um subconjunto das características TD de Hudgins para caracterizar o sinal de sEMG. O método de retreinamento era rápido, para todos os indivíduos e o tempo de processamento ficou abaixo de 5ms, conseguindo recuperar consideravelmente a taxa de acerto, mesmo quando 50% dos canais estavam degradados por algum contaminante, para os indivíduos não amputados. Para o indivíduo amputado, o modelo também conseguiu recuperar a taxa de acerto, porém, à medida que mais

canais falham, pior fica o desempenho do modelo adaptativo, mostrando que as informações obtidas do indivíduo amputado apresentam menor redundância.

Estudos com braços robóticos são fundamentais para área de próteses e reabilitação, e é o foco do trabalho de (López *et al.*, 2009), que propõe um sistema robusto de sEMG com o uso de fusão de sensores virtuais e reais. O trabalho foi realizado com cinco indivíduos não amputados e um indivíduo com amputação acima do cotovelo utilizando dois canais de sEMG localizados no tríceps e bíceps. O sistema de controle proporcional utilizava, utilizando apenas um grau de liberdade de um robô que deveria ser controlado com a ativação de cada músculo individualmente. O sinal de controle era caracterizado pelo valor absoluto da média (MAV), que é corrigido através de dois métodos distintos e envia um sinal de controle proporcional para a junta do robô. Os dois métodos de correção é a Variância Média Ponderada (VMP) e o Filtro de Kalman Descentralizado (FKD) que tiveram resultados comparados. Nesses métodos, os valores obtidos da coleta do sinal de sEMG eram constantemente avaliados para suprimir variações bruscas de amplitude que não sejam características do sinal de eletromiografia e que poderia levar a uma operação não segura de algum dispositivo eletromecânico.

Os dados coletados de sEMG eram fundidos e filtrados para gerar apenas um sinal de controle. Durante os testes, os eletrodos foram descolados do indivíduo diversas vezes, e foram contaminados com ruído branco gaussiano e ruído de linha elétrica. O sistema demonstrou conseguir rejeitar as perturbações, mantendo o sinal de controle adequado, respeitando os limites de atuação do robô. A métrica utilizada para avaliar o erro de controle do sistema foi o Erro Máximo Absoluto Médio e se conclui que o método VMP é melhor para sistemas com apenas sEMG e FKD seria indicado para sistemas onde a natureza dos sensores é diferente.

Também utilizando um braço robótico com um grau de liberdade, no trabalho de (Furukawa *et al.*, 2015) os pesquisadores utilizam sinais de sEMG para estimar o torque do robô onde, paralelamente, era aplicado um monitoramento automático de detecção de falhas baseado em regressão logística, utilizando a correlação entre os canais como entrada do estimador, que possui duas classes, contaminado ou não-contaminado. Para falha dos sensores foram testados dois casos extremos de eletrodo removido da pele ou o cabo ligado ao eletrodo sendo desconectado no amplificador.

O sistema adaptativo consistia em diversos modelos diferentes que eram selecionados de acordo com o(s) eletrodo(s) em falha, ou seja, o sistema era treinado para cada combinação de falha entre eletrodos de forma que o eletrodo degradado não fosse utilizado para determinar a saída do torque. O modelo utilizado para estimativa do torque foi apresentado em (Noda *et al.*, 2013). O estudo foi conduzido com dados de cinco participantes não amputados, utilizando quatro eletrodos, sendo dois localizados no bíceps e dois localizados no tríceps. A métrica utilizada para comparar o sistema íntegro com o sistema adaptado foi o RMSE e os resultados mostraram que o sistema adaptado possui um RMSE menor que o sistema não adaptado em falha.

Um sistema com dados híbridos, utilizando sEMG e mecanomiografia (MMG) foi utilizado no estudo de (Guo *et al.*, 2017). MMG é uma medida do deslocamento físico do músculo durante a contração, que no caso deste trabalho, é realizada a comparação entre dois métodos, utilizando acelerômetros (aMMG) e microfones (mMMG). Foram coletados dados de sete indivíduos não amputados e dois indivíduos com amputação abaixo do cotovelo em quatro canais durante a realização de treze diferentes movimentos da mão. O sistema de detecção de falha é o mesmo proposto por (Zhang e Huang, 2015), descrito na seção anterior utilizando apenas ruído branco como contaminante. Para a classificação dos sinais, foi utilizado o método LDA com quatro características TD e AR de ordem seis. Quando

detectada uma falha em um eletrodo do sEMG (não foi simulada falha nos sensores MMG), o sistema automaticamente retreina o classificador com dados armazenados na memória, para o conjunto menor de canais. O sistema híbrido proposto se mostrou robusto mesmo quando todos os eletrodos de sEMG estão em falha, tanto para indivíduos não amputados, como para os amputados. Estes resultados mostram que é viável o uso de sensores inerciais em fusão com sEMG para classificação de movimentos do segmento mão-braço.

O trabalho mais atual nesta área é de (Moura, de e Balbinot, 2018), já citado na seção anterior no contexto de detecção de contaminantes, que compara duas técnicas diferentes para estimação de um sensor virtual: *Time-Varying Autoregressive Moving Average* (TVARMA) e *Time-Varying Kalman filter* (TVK) utilizando um classificador SVM. O estudo avaliou a base de dados NinaPro (Atzori *et al.*, 2015) para indivíduos não amputados e amputados. Para o modelo TVARMA, era calculada a matriz de correlação entre os canais para ponderar a atuação de cada canal na regressão de um canal, ou seja, quanto mais correlacionados fossem os canais, maior sua influência na estimativa.

O modelo TVK foi construído considerando o problema de regressão como uma estimação de estados de espaço. A predição do valor do sensor em falha é dada por uma equação de estados que utiliza os dados dos canais íntegros, ponderados pela matriz de correlação. Diversas configurações foram testadas com os dois modelos de sensor virtual: classificação com o sinal degradado, retreinamento da rede sem o canal degradado, uso do canal virtual sem retreinamento da rede e retreinamento da rede utilizando dados do sensor virtual, sendo os melhores resultados obtidos para as duas últimas configurações apresentadas.

Uma das possíveis abordagens, como demonstrou (Moura, de e Balbinot, 2018), é o uso de sensores virtuais para aumentar a robustez do sistema baseado em sEMG. Segundo (Bhuyan, 2012), um sensor virtual é uma forma de estimar uma medida inacessível de um

sensor real utilizando um modelo matemático com dados de outras variáveis do sistema que se correlacionem com a medida a ser estimada.

Todos os trabalhos apresentados nessa seção estão sumarizados na Tabela 4. As abordagens são bem diversas, com soluções de mitigação que vão desde filtros adaptativos, retreinamento com dados na memória, modelos já treinados na memória com menor dimensionalidade de entrada e sensor virtual.

Modelos que realizam retreinamento podem causar atrasos consideráveis no processamento dos dados, caso o contaminante tenha característica intermitente. Um sistema que reduz a dimensionalidade está renunciando a informações que podem ser essenciais para a correta operação em casos específicos. A partir deste ponto de vista um sensor virtual necessita apenas de leitura dos dados na memória do sistema e provê uma estimativa da informação perdida.

O modelo desenvolvido por (Moura, Ruschel e Balbinot, 2018) realiza a regressão das características específicas para o classificador de movimentos utilizado no trabalho. Essa solução além de possuir um custo computacional considerável, visto que são 5 características por canal, limita a solução do sensor a este caso específico. Como visto em sessões anteriores, existem soluções com sEMG com a tarefa de regressões utilizando o sinal bruto, o que se aplicado no sensor virtual, permitiria o uso de diferentes características.

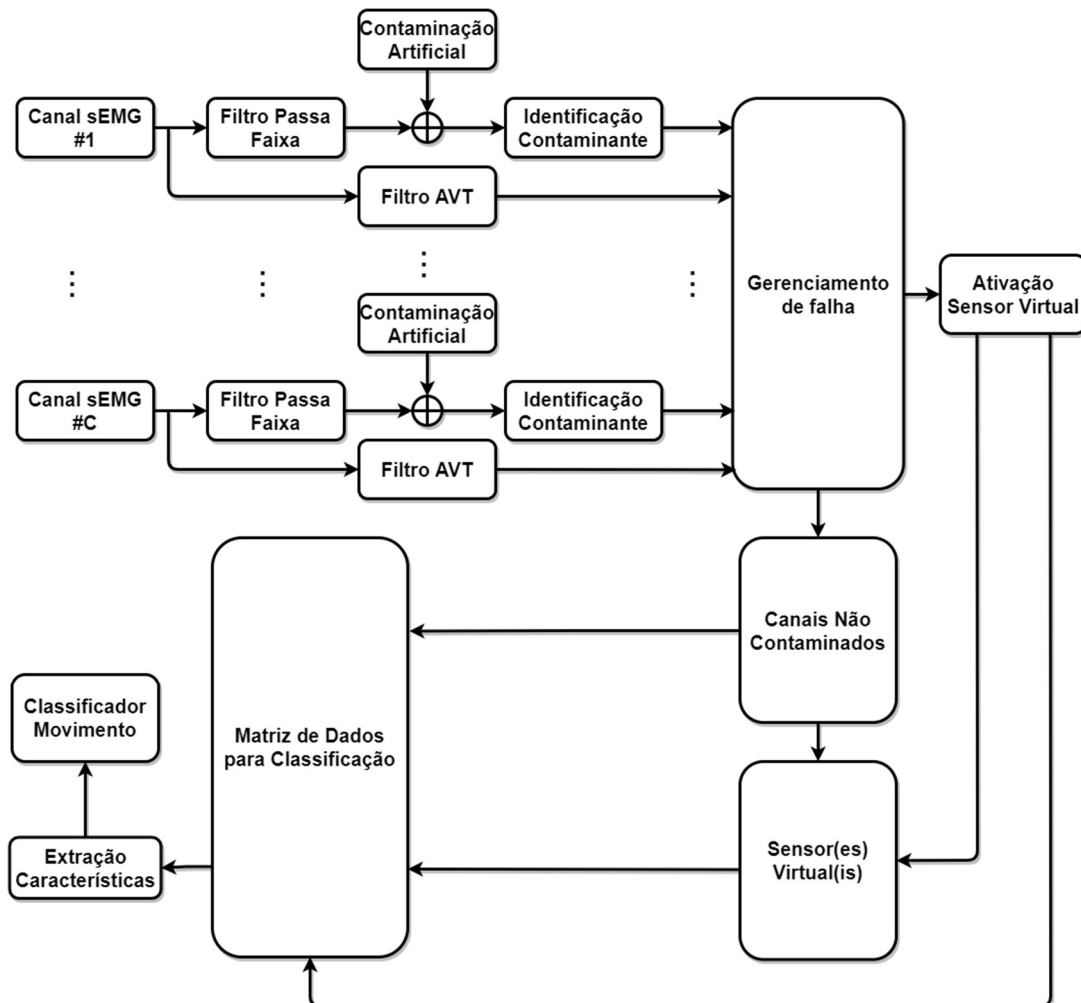
Tabela 4 – Resumo dos trabalhos de sistemas tolerantes a falha com sEMG.

Trabalho	Falhas	Mitigação	Características	Ferramenta
(Zhang e Huang, 2015)	Artefato de Movimento; Eletrodo Descolado; Ruído Branco	Retreinamento do classificador com dados contido na memória; Identificação de falha por distância de Mahalanobis	Valor Absoluto da Média; Número de cruzamentos por Zero; <i>Waveform Length</i> , Inclinação na variação do sinal	Detector de <i>outlier</i> para identificar a falha; LDA para classificar movimentos
(López <i>et al.</i> , 2009)	Eletrodo Desconectado; Ruído Branco; Ruído de linha elétrica	Filtragem adaptativa por Kalman e análise da Variância do Sinal	Valor Absoluto da Média	Controle proporcional; Filtro de Kalman Descentralizado e Média Ponderada da Variância
(Furukawa <i>et al.</i> , 2015)	Eletrodo Desconectado; Eletrodo Desconectado no Amplificador	Diferentes modelos de estimação do torque na memória	Matriz correlação para identificar a falha; sEMG bruto para estimar o torque	Modelo matemático do torque; Regressão logística para identificar falha
(Guo <i>et al.</i> , 2017)	Ruído Branco adicionado ao sEMG	Idem (Zhang e Huang, 2015)	Valor Absoluto da Média; Número de cruzamentos por Zero; <i>Waveform Length</i> , Inclinação na variação do sinal; Seis coeficiente autoregressivos	Idem (Zhang e Huang, 2015)
(Moura, de e Balbinot, 2018)	Contaminação por Artefato de Movimento; Saturação; Ruído Branco; Ruído de Linha; ECG	Sensor Virtual	Valor Absoluto da Média; RMS; <i>Waveform Length</i> ; <i>Maximum Fractal Length</i> ; Potência	TV-ARMA e TVK para sensor virtual; SVM para identificação de falha.

4. METODOLOGIA

A metodologia deste trabalho engloba todas as etapas do sistema de classificação de movimentos tolerante a falhas, utilizando o conceito de sensores virtuais, que se aproveita correlação causada pelo *crossstalk* presente entre canais para gerar uma estimativa do sinal corrompido por contaminantes. Inicialmente são descritas as bases de dados utilizadas, NinaPro e IEE, as etapas de pré-processamento, a contaminação artificial, o desenvolvimento do identificador de contaminante e dos modelos de sensores virtuais, assim como todas as estratégias para seleção dos hiper parâmetros. Um modelo em diagrama em blocos da metodologia proposta é apresentado na Figura 9.

Figura 9 – Diagrama em blocos do sistema proposto para C canais contaminados.



Fonte: Autor

Os principais blocos da Figura 9 para este trabalho são:

- 1) Bloco para contaminação artificial do sinal em diferentes níveis de SNR: nessa etapa são gerados os quatro contaminantes, sendo o ruído de linha e o ruído branco gerados de forma sintética e artefato de movimento e ECG de forma experimental, através de ensaios realizados e banco de dados;
- 2) Bloco para identificar contaminação e qual tipo de contaminante: aqui uma RNR-LSTM para cada canal fica monitorando o sinal que passa apenas por um filtro passa faixa entre 20Hz e 500Hz como pré-processamento. A rede além de indicar a contaminação, também indica qual o tipo de contaminante presente;
- 3) Bloco para o sensor virtual RNR-LSTM de estado retido: uma RNR-LSTM estima na sua saída os canais corrompidos por contaminantes em 7 diferentes estudos de caso, onde as entradas são os canais não contaminados;
- 4) Bloco de Classificador de Movimento, utilizando ELM: o ELM utilizado neste trabalho foi desenvolvido e otimizado em (Cene e Balbinot, 2020) e servirá para realizar a comparação, dentre 18 classes, entre a classificação do sinal contaminado, do sinal não contaminado e do sinal com sensor virtual.

Os canais de sEMG são contaminados artificialmente, adicionando o contaminante ao sinal em 9 diferentes níveis de SNR: -40dB a 40dB em intervalos de 10dB. Os contaminantes avaliados neste trabalho são Artefato de Movimento (AM), sinal de Eletrocardiograma (ECG), Ruído de Linha Elétrica (RL) e Eletrodo Descolado, modelado por Ruído Branco Aditivo (RBA) e que estão presentes em praticamente todos os trabalhos que analisam contaminação de sinais de sEMG, de acordo com a Tabela 3 e que serão detalhados na seção 4.4.

A identificação de contaminação e do tipo de contaminante é realizado a partir do sinal pré-processado, sem extração de características, por uma RNR-LSTM. Ao identificar a

contaminação, o sistema informa o tipo e começa a estimar o(s) canal(is) contaminados a partir de uma RNR-LSTM de estado retido (que mantém a memória por tempo indefinido) utilizando um conjunto de canais íntegros como entrada. A ativação do sensor virtual é realizada simplesmente substituindo os trechos do(s) canal(is) contaminado(s) pelo(s) canal(is) virtual(is) no vetor de entrada do classificador de movimentos onde é identificada a contaminação.

Todos os códigos, com exceção do classificador R-ELM, foram desenvolvidos no *Spyder*[®] *Python 3.7* utilizando *tensorflow-keras 2.1.0*. O R-ELM foi desenvolvido no *Matlab 2018*[®].

4.1. Bases de dados de sEMG

4.1.1. Base de dados NinaPro

A iniciativa NINAPro (ninapro.hevs.ch) inclui diversas bases de dados para estudos de eletromiografia, incluindo sujeitos amputados. São disponibilizadas 9 bases de dados ao total, onde 3 foram consideradas para este trabalho.

As bases foram selecionadas por possuírem distribuição idêntica dos eletrodos nos sujeitos e por já terem sido avaliadas em trabalhos sobre qualidade e robustez (Moura, de e Balbinot, 2018) e também na avaliação do classificador de movimentos (Cene, Machado e Balbinot, 2019)

As bases consideradas foram a DB2 (Atzori *et al.*, 2014) com 40 sujeitos, a DB3 (Atzori *et al.*, 2014, 2016) com 11 sujeitos com amputação transradial, porém dois indivíduos foram excluídos por não possuírem 2 canais, e a DB4 (Pizzolato *et al.*, 2017) com 10 sujeitos. Essas bases de dado são compostas por três tipos de exercícios denominadas como B, C e D. Neste trabalho somente os exercícios B serão utilizados e consistem em 6 repetições sequenciais de 17 movimentos distintos com duração de 5 segundos e 3 segundos de intervalo entre as repetições. Na base DB3, 2 sujeitos são excluídos por não possuírem 2 canais.


Tabela 5 – Resumo das bases de dado NinaPro – Exercício B.

Base de Dados NinaPro			
	Base DB2	Base DB3	Base DB4
Sujeito não amputado	40	0	10
Sujeito amputado trans-radial	0	11 (9)	0
Número de Eletrodos sEMG	12	12 (10)	12
Número de movimento avaliados	17	17	17
Repetições de cada movimento	6	6	6

A atividade muscular foi obtida através de um arranjo de 12 eletrodos de sEMG *wireless* não invasivos. Cada um dos eletrodos é equipado com uma bateria recarregável e possui um alcance de 40m em sua área de cobertura. Os dados foram digitalizados através da plataforma NI-DAQ PCMCIA 6024E da *National Instruments* a uma taxa de 2 kHz e 12 bits, com um ruído de 750nV (Atzori *et al.*, 2014).

Os movimentos do segmento mão braço executados durante os ensaios do exercício B são ilustrados na Figura 10 e dividem-se em três grupos, onde:

Figura 10 – Movimentos realizados na base de dados NinaPro.



Fonte: Adaptado de (Moura, de e Balbinot, 2018).

- 1) o grupo 1 consiste em movimentos de dedos (polegar para cima (1), extensão do dedo médio e indicador com flexão dos outros dedos (2), flexão dos dedos anular e mínimo com extensão dos demais (3), flexão do polegar (4), adução dos dedos (5), fechamento da mão (6), ação de apontar (7) e adução de dedos estendidos (8));
- 2) o grupo 2 reúne movimentos de torção com diferentes eixos (supinação do pulso com eixo no dedo médio (9), pronação do pulso com eixo no dedo médio (10), supinação do pulso com eixo no dedo mínimo (11) e pronação do pulso com eixo no dedo mínimo (12));
- 3) o grupo 3 reúne movimentos de pulso (flexão do pulso (13), extensão do pulso (14), desvio radial do pulso (15), desvio do ulnar do pulso (16) e extensão do pulso com a mão fechada (17)).

4.1.2. Base de dados IEE


A base de dados do IEE (https://www.ufrgs.br/ieelab/IEE_sEMG_db.php) foi adquirida em trabalhos anteriores (Cene *et al.*, 2019) e nesta seção será feita uma descrição dela. Mais detalhes também podem ser obtidos nos trabalhos de (Cene, 2016; Cene e Balbinot, 2018; Cene, Santos e Balbinot, 2018). Importante salientar que esta base ainda está em expansão e sendo utilizada em outra tese em desenvolvimento dentro do IEE.

A aquisição do sinal de sEMG foi adquirida através de um eletromiógrafo comercial, que realizava uma filtragem passa banda de 20Hz a 500Hz e uma amplificação combinada de 2000 vezes. Para digitalização dos dados, foi utilizada uma placa comercial da *National Instruments*® com 18 bits de resolução e taxa de aquisição de 2 kHz por canal, de forma a padronizar com a base de dados NinaPro.

Para a padronização dos ensaios, foi criado um modelo virtual de cada movimento, que é mostrado a cada voluntário do teste que deve replicá-lo, naturalmente e tão bem quanto possível. O *timestamp* utilizado na rotulação das classes do sinal foi retirado com base nos movimentos pré-estabelecidos realizados nestes ensaios.

Dos 12 pares de eletrodos utilizados, oito foram posicionados em um arranjo equidistante na altura da articulação rádio-umeral do voluntário. Os quatro pares de eletrodos restantes, foram posicionados sobre os seguintes músculos específicos: Extensor dos dedos (canal 9); Flexor dos dedos (canal 10); Bíceps (canal 11) e Tríceps (canal 12). A Figura 11 ilustra o posicionamento dos eletrodos.

Figura 11 – Posicionamento dos eletrodos no braço de cada voluntário.



Fonte: Adaptado de (Cene, Santos e Balbinot, 2018)

O processo de aquisição é iniciado a partir do início do vídeo do primeiro movimento, que assim como os subsequentes, é replicado simultaneamente pelo usuário que acompanha os movimentos exibidos no monitor auxiliar específico. É importante ressaltar que neste trabalho não foi realizado o monitoramento da força aplicada pelo voluntário e nem usado qualquer procedimento de realimentação.

A padronização dos ensaios seguiu os mesmos 17 movimentos da base NINAPro (Atzori *et al.*, 2014) porém com variantes chamadas aqui de A, B, C e D, que estão detalhadas na Tabela 6, onde a principal diferença é a presença de movimentos em ordem aleatória.

Tabela 6 – Tipos de exercícios realizados na Base IEE

Tipo Exercício	Repetições	Tipo repetição	Tempo Contração	Tempo Repouso
A	6	Sequencial	5s	7s
B	10	Sequencial	5s	7s
C	6	Aleatória	5s	10s
D	10	Aleatória	5s	10s

A base conta com dados de oito voluntários que realizaram, dois ensaios de cada um dos tipos de exercícios da Tabela 6. Na Tabela 7 mostra-se as características dos voluntários, todos sem amputações.

Tabela 7 – Base de dados de sEMG do IEE.

Sujeito	Mão dominante	Sexo	Idade	Altura (m)	Peso (kg)
1	Direita	Masculino	31	1,87	78
2	Direita	Masculino	26	1,80	70
3	Direita	Feminino	29	1,64	60
4	Direita	Masculino	34	1,82	84
5	Direita	Masculino	23	1,69	60
6	Direita	Masculino	37	1,83	78
7	Direita	Masculino	23	1,69	65
8	Direita	Masculino	24	1,83	95

4.2. Pré-processamento

O pré processamento é realizado de forma diferente para as diferentes etapas do sistema. Para a identificação de contaminantes o sinal é apenas filtrado entre 20Hz e 500Hz e normalizado com o valor máximo e depois segmentado, conforme será detalhado nas próximas sessões.

Para o sensor virtual, é inicialmente realizada uma retificação, para que se trabalhe com sinais sEMG inteiramente positivos e pode ser feita via hardware ou software, utilizando a

Equação (32), onde $sEMG_{RET}(t)$ é o canal retificado e $sEMG_{CH}(t)$ representa os doze canais experimentais de ambas as bases utilizadas no trabalho.

$$sEMG_{RET}(t) = |sEMG_{CH}(t)| \quad (32)$$

Em relação à normalização do sinal, as principais vantagens são evitar *outliers* que influenciem em demasia os coeficientes do classificador, equalizar os canais, de forma que todas as características tenham influência similar no conjunto de dados. Para o escalonamento dos dados é utilizada então, a normalização dos sinais de sEMG por canal, conforme a Equação (33):

$$sEMG_{CANAL_NORM}(t) = \frac{sEMG_{RET}(t)}{\max(|sEMG_{RET}(t)|)} \quad (33)$$

onde $sEMG_{RET}(t)$ representa o sinal de sEMG de entrada retificado por canal e $sEMG_{CANAL_NORM}(t)$ representa o respectivo sinal de sEMG normalizado por canal. Cabe ressaltar aqui que o máximo utilizado para normalização não representa a máxima contração do indivíduo naquele canal, porém como não há essa informação nas bases de dados, se optou por utilizar o valor máximo do músculo durante os ensaios.

Para o sensor virtual, o sinal, além de filtrado é retificado e aplicado um filtro estatístico denominado AVT (*Antonyan Vardan Transform*) cuja operação está apresentada no Pseudo Código 1. O filtro AVT retifica o sinal, ao utilizar o valor da média absoluta (VMA) e desvio padrão para remover *outliers*, em janelas deslizantes de 400ms e com passos de 10ms e então normalizado. Maiores detalhes sobre o AVT podem ser encontrados em (Cene *et al.*, 2019; Cene, Machado e Balbinot, 2019; Cene, Santos e Balbinot, 2018). Como a rede trabalha com estado retido, fazendo previsões amostra a amostra (*many-to-many*) a segmentação do sinal se torna complexa e será detalhada na seção que descreve a etapa de treinamento do sensor virtual.

Pseudo Código 1 – AVT

Para $\alpha_1 = 0,8$ e $\alpha_2 = 0,2$

1 – Enquanto o sinal de sEMG não termina:

1.1 – Ler 400ms do sinal;

1.2 – Separa a janela → trechos de 390 ms + 10 ms;

1.3 – Média Das Médias Ponderada (MMP) =

$$\text{Média}[\text{VMA}(390 \text{ ms}) * ff_1 + \text{VMA}(10 \text{ ms}) * ff_2];$$

1.4 – Média do Desvio Padrão Ponderada (MDPP) =

$$\text{Média}[\sigma(390 \text{ ms}) * ff_1 + \sigma(10 \text{ ms}) * ff_2];$$

1.5 – Para cada amostra da Janela de 400ms:

1.5.1 – if(amplitude da amostra) <= (MMP ± MDPP)
não alterar valor da amostra;
else
Valor da amostra = MMP;

1.6 – Desliza a janela em 10ms;

1.7 – retorna para os passos #1.3;

2 – fim;

Fonte: Adaptado de (Cene e Balbinot, 2018)

4.3. Extração de características para o classificador de movimentos

Como será descrito posteriormente, no processamento da RNN-LSTM tanto na detecção de contaminantes como na regressão do sensor virtual, o sinal de sEMG pré-processado será utilizado como entrada, sem extração de características. Para o ELM serão utilizadas as seguintes características no domínio tempo: RMS, Variância (VAR), Valor Absoluto Médio (VMA), Desvio Padrão (DP) e a *Differential Enhanced Signal* (DES) que é uma característica utilizada para caracterizar melhor o período de transição entre período de repouso e classe de movimento (Cene e Balbinot, 2020). A DES é realizada através de componentes principais (PCA) extraídas de duas janelas de dados suavizadas consecutivas, e as componentes são então filtradas por um filtro de média móvel.

Todas características estão descritas da Equação (34) até a Equação (38), onde x_i é o i -ésimo vetor de canais, na k -ésima janela de tamanho N , representada pela matriz $X_k \in \mathbb{R}^{C \times N}$,

onde C é o número de canais, $\mathbf{y}_\theta(\mathbf{X}_k)$ é o vetor de saída da característica θ na janela k . No caso desse trabalho, $N = 800$ amostras e $C = 12$. Mais detalhes sobre as características podem ser obtidas em (Cene e Balbinot, 2020).

- Valor RMS

$$RMS_k = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (34)$$

- VMA

$$VMA_k = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (35)$$

- VAR

$$VAR_k = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}_i)^2 \quad (36)$$

- DP

$$DP_k = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}_i)^2} \quad (37)$$

- DES

$$DES_k = \left| MOVAVG \left\{ PCA \left(\begin{array}{c} MAV[segmento(i-1)] \\ MAV[segmento(i)] \end{array} \right) \right\} \right| \quad (38)$$

4.4. Contaminantes artificiais do sinal de sEMG

Considerando que os sinais coletados nas 3 bases de dados possuem algum nível de contaminação em baixa e alta frequência, eles são inicialmente filtrados entre 20 e 500Hz com um filtro passa faixa *butterworth* de quarta ordem, normalizado pelo valor máximo absoluto de cada canal. Este procedimento é largamente utilizado em sinais de sEMG sem prejuízo às

informações de interesse contidas no sinal (Luca, De *et al.*, 2010). Este conjunto de dados representa a classe denominada EMG Não Contaminado (NC).

Certamente um filtro passa banda não irá remover toda possível contaminação do sEMG, inclusive contaminações não consideradas nesse trabalho. Considera-se as bases de dados adequadas para definir como não contaminadas baseados em estudos onde elas são utilizadas para classificação de movimentos utilizando o R-ELM (Cene *et al.*, 2019; Cene e Balbinot, 2020), onde as taxas de acerto estão de acordo com a literatura.

A contaminação de um sinal de sEMG pode ocorrer em diferentes níveis de SNR e foi necessário determinar uma metodologia padronizada para a definição do SNR de contaminação. Esta não é uma definição trivial, pois ao trabalhar com 12 eletrodos e 65 indivíduos (50 indivíduos da base NinaPro não amputados, 9 indivíduos da base NinaPro amputados e 8 indivíduos da base IEE).

Dessa forma, é utilizada a potência média de todos os intervalos de repouso para cada canal de cada indivíduo como referência para o SNR da contaminação, calculada de acordo com a Equação (39), cujos resultados são armazenados em uma matriz 12x59.

$$Energia_{repouso} = \frac{1}{N} \sum_1^N x_{repouso}[i]^2 \quad (39)$$

Os contaminantes utilizados neste trabalho estão presentes em diversos trabalhos sobre qualidade do sinal de sEMG e identificação de contaminantes de acordo com a Tabela 3 e são Artefato de Movimento (AM), Eletrocardiograma (ECG), Ruído de Linha (RL) e Ruído Branco Aditivo (RBA) e são descritos a seguir:

- a) **Artefato de Movimento (AM):** as amostras de artefato de movimento foram coletadas de forma experimental em um indivíduo (sexo masculino, 37 anos de idade, 80kg e 1,83m de altura), utilizando a mesma configuração descrita na seção 4.1.2. Sem nenhuma contração, uma sequência de 10 batidas em cada eletrodo com 1s de

intervalo foi realizada para cada canal. Um procedimento similar foi utilizado por (Luca, De *et al.*, 2010). O artefato é selecionado aleatoriamente para cada canal e escalonado para atingir o SNR desejado e adicionado ao sEMG NC;

- b) Artefato de Eletrocardiograma (ECG):** as amostras de ECG utilizadas para contaminação foram obtidas da base de dados pública *Physionet* (Goldberger *et al.*, 2000). Segmentos de 10s foram selecionados aleatoriamente entre 17 indivíduos sem histórico de problemas cardíacos, e um procedimento de *upsampling* foi utilizado para se adequar à taxa de amostragem do sinal de sEMG. Esses segmentos são somados ao sEMG NC e escalonado para atingir o SNR desejado;
- c) Ruído de Linha (RL):** um sinal com a amplitude determinada a partir do valor do SNR desejado e com frequência de 60Hz é adicionada ao sEMG NC;
- d) Ruído Branco Aditivo (RBA):** um vetor com valores aleatórios gerados por uma distribuição normal com média zero é somado ao sinal sEMG NC. A variância é determinada a partir do valor do SNR desejado.

Existem poucos trabalhos que descrevem com exatidão o efeito de todos os contaminantes em aplicações de eletromiografia, pois em geral os ensaios, especificamente os utilizados neste trabalho, são realizados em ambientes controlados. Os autores (Moura, de e Balbinot, 2018) demonstraram como estes artefatos afetaram um classificador SVM para estas mesmas bases de dado em 16 estudos de caso, reduzindo significativamente as classificações dos movimentos, porém nenhuma informação do nível de contaminação é apontada.

No caso da contaminação por ECG, ela pode ser um problema para sistemas com Reinervação Muscular Direcionada (*Targeted Muscle Reinnervated*) afetando principalmente o controle proporcional de próteses (Hargrove *et al.*, 2009).


Em relação aos artefatos de movimentos, existem relatos de que a falta de robustez em algoritmos de classificação de movimentos pode ser causada pela presença deste

contaminante (Luca, De *et al.*, 2010; Roland *et al.*, 2019). Estudos sobre técnicas vibratórias para recuperação de atletas e em medicina de reabilitação demonstraram que a influência de artefatos de movimento podem levar a interpretações errôneas dos dados de eletromiografia (Fratini *et al.*, 2009).

Quanto ao ruído de linha elétrica, diversos algoritmos já foram desenvolvidos para mitigar este contaminante (Malboubi *et al.*, 2010; Soedirdjo, Ullah e Merletti, 2015) em sEMG, enquanto que o ruído branco representa um eletrodo descolado ou desconectado (Furukawa *et al.*, 2015; Gao *et al.*, 2018; Moura, de e Balbinot, 2018), o que certamente afeta a taxa de classificação de qualquer algoritmo baseado em múltiplos canais de sEMG.


Apenas para efeito ilustrativo da metodologia, na Figura 12 é apresentado o efeito da contaminação por RBA para diferentes níveis de SNR em um trecho de 40 segundos do sinal de sEMG normalizado e nas figuras 13 e 14 são apresentados os resultados dos diferentes contaminantes para uma contaminação de -20dB e -10dB respectivamente para um trecho de 5s.

Figura 12 – Efeito da contaminação em diferentes níveis de SNR por RBA no sinal de sEMG normalizado.




Fonte: Autor

Figura 13 – Efeito dos diferentes contaminantes para SNR = -20dB.



Fonte: Autor

Figura 14 – Efeito dos diferentes contaminantes para SNR = -10dB.

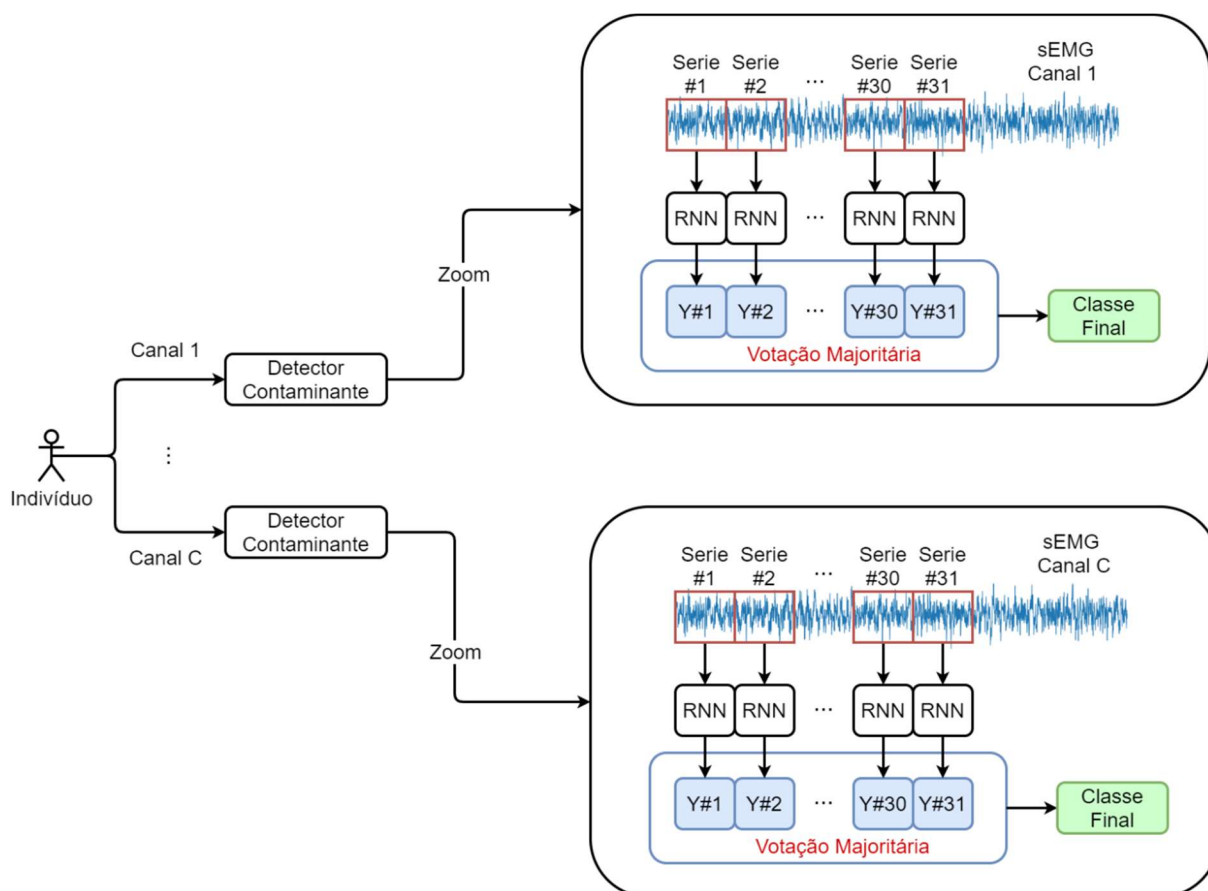


Fonte: Autor

4.5. Identificador Automático de Contaminantes (IAC)

A identificação automática dos contaminantes do sinal de sEMG descritos na seção 4.4 é realizada através de uma RNR – LSTM *many-to-one* em cada canal sem extração de características, realizando a classificação diretamente no sinal bruto para cada canal, de acordo com a Figura 15. Um modelo de RNN-LSTM é utilizado por canal, onde 31 séries consecutivas sem sobreposição são classificadas de forma independente, ou seja, com a camada LSTM tendo sua memória reinicializada a cada classificação de série. O resultado da classificação de cada uma das 31 séries é armazenado em um vetor e realizada uma votação majoritária que determina a classe final que representa o estado do sinal nas últimas $31 \cdot N$ amostras de séries.

Figura 15 – Diagrama em blocos da classificação de contaminantes para C canais.




Fonte: Autor

O tamanho da janela da votação majoritária foi determinada experimentalmente de forma que não ocorresse atraso na transição das classes e mantivesse um valor abaixo das outras soluções propostas para identificação de contaminantes (Ijaz e Choi, 2018; McCool *et al.*, 2014), que variam de 2s a 5s, dependendo da configuração utilizada.

A arquitetura básica da RNR-LSTM proposta é apresentada na Figura 16. A camada de entrada $\mathbf{x}^{(t)} = [x^{(0)}, x^{(1)}, \dots, x^{(N)}]$ é um vetor com dimensão $\mathbb{R}^{1 \times N}$ contendo N amostras de um canal, U é o conjunto de pesos da entrada para a camada oculta H onde ficam as unidades LSTM, W é o conjunto de pesos recorrentes, V é o conjunto de pesos que conecta a camada oculta a camada de *dropout* D , a camada y é a saída da rede e por fim a camada S aplica a função $\text{softmax}(y)$ determinando a classe da série $\mathbf{x}^{(t)}$.

Figura 16 – Arquitetura Básica da RNN-LSTM. (a) Rede em topologia compacta; (b) Rede em topologia completa.



Fonte: Autor

Existem diversos hiper-parâmetros a serem ajustados, tais como camadas LSTM, unidades LSTM, tamanho da série a ser classificada, épocas, taxa de aprendizagem, tamanho do mini-lote, taxa de *dropout*, funções de ativação, dentre outros. Na Tabela 8 estão apresentados os

parâmetros que serão utilizados para determinar o melhor modelo a ser testado em todas as bases de dados.

A função perda \mathcal{L} dada pela Equação (27) é a entropia cruzada categórica, descrita na Equação (40), onde y_k representa a probabilidade da função objetivo para a classe k , ou seja, é igual a 1 para a classe k e 0 para as outras classes enquanto \hat{y}_k representa a probabilidade dada pela função *softmax*, definida na Equação (13). Os valores das atualizações dos pesos dado pela Equação (31) são calculados sobre a média da função perda dentro de cada mini-lote de treinamento.

$$\mathcal{L} = - \sum_{k=1}^K y_k \cdot \log(\hat{y}_k) \quad (40)$$

Tabela 8 – Parâmetros da RNR-LSTM

Taxa de Dropout	0,5
Unidades LSTM	50, 75 e 150
Tamanho da Sequencia (N)	30, 45 e 60
Épocas	5
Tamanho mini lote	128
Características	1

Os valores da Tabela 8 foram obtidos através de estudos preliminares, onde foram testadas redes mais longas com até 500 amostras e se observou que o desempenho era menor que configurações com redes com séries menores que 100 amostras. Além disso, redes longas e com muitas unidades LSTM são limitadas pelo hardware disponível, tendo ocorrido diversos problemas de *overflow* de memória. A taxa de *dropout* foi mantida de acordo com recomendação em (Srivastava *et al.*, 2014), que indica uma taxa entre 0,5 e 0,8 nas unidades da camada oculta. O valor das épocas também foi definido através de estudos preliminares, onde se observou a ocorrência de identificação de contaminação para $\text{SNR} \geq 10\text{dB}$ principalmente o contaminante RBA, o que não é desejável, conforme será esclarecido nas próximas sessões.

Existem diversos algoritmos de otimização na busca de um mínimo da função perda e neste trabalho é utilizado o ADAM (Kingma e Ba, 2015). O algoritmo ADAM (*Adaptive Moment Estimation*) utiliza o conceito de *momentum* do gradiente (Murphy, 2012). Este modelo se adapta bem a sinais estocásticos e/ou esparsos, como é o caso das bases de dados, onde os dados de sEMG são naturalmente estocásticos e são relativamente esparsas, visto que períodos de repouso são muito mais frequentes que as outras classes.

O método do algoritmo ADAM baseia-se em utilizar taxas de aprendizagem adaptativas para o primeiro e o segundo momento do gradiente, utilizando média móvel em ambos os momentos, de acordo com as Equações (41) e (42). e utilizados na atualização dos parâmetros de acordo com a Equação (43):

$$m_l = \beta_1 \cdot m_{l-1} + (1 - \beta_1) \cdot \nabla E[\theta_l] \quad (41)$$

$$v_l = \beta_2 \cdot v_{l-1} + (1 - \beta_2) \cdot (\nabla E[\theta_l])^2 \quad (42)$$

$$\theta_{l+1} = \theta_l - \frac{\alpha \cdot m_l}{\sqrt{v_l} + \varepsilon} \quad (43)$$

onde l representa o número da iteração do mini-lote, m_l representa o primeiro momento do gradiente, v_l representa o segundo momento do gradiente, $\nabla E[\theta_l]$ representa o gradiente do valor esperado da função perda em relação aos parâmetros θ . Os hiperparâmetros α , β_1 , β_2 e ε devem ser determinados pelo usuário. Segundo (Kingma e Ba, 2015), recomenda-se o uso dos seguintes valores $\alpha = 0,001$, $\beta_1 = 0,9$, $\beta_2 = 0,999$ e $\varepsilon = 10^{-8}$, que serão adotados.

4.5.1. Conjunto de treinamento e conjunto de teste

Conforme mencionado na seção 3.2, apenas as pesquisas sobre contaminantes de (Fraser *et al.*, 2014; McCool *et al.*, 2014) apresentavam controle de SNR dos contaminantes e apesar de apresentar um estudo do comportamento de algumas características em relação a mudança do SNR, não demonstrou como essa variação de SNR poderia impactar uma aplicação com

De acordo com a correlação, uma contaminação até -10dB descaracteriza boa parte do sinal e contaminações a partir de 10dB já começam a apresentar correlações muito próximas de 1, acima de 0,90. Apenas para ilustrar, na Figura 12 (pg. 76) também é possível observar que à medida que o SNR aumenta, mais próximo o sinal contaminado fica do sinal original. Esses valores indicam que uma capacidade de identificação até pelo menos -10dB é desejável e partir de 0dB é desejável que o identificador já comece a indicar o sEMG sem contaminação.

Seguindo este raciocínio, serão utilizados três conjuntos de treinamento distintos, de acordo com a Tabela 11, gerando três modelos que serão utilizados para testar o conjunto de dados e a respectiva sensibilidade para identificação de cada um dos contaminantes. Para cada nível de SNR, são extraídos dados de um mesmo canal em três indivíduos da base NinaPro DB2, totalizando 9 indivíduos selecionados aleatoriamente. O fato do grupo C possuir uma diferença de apenas 5dB entre o nível 2 e o nível 3, foi devido à observações preliminares onde utilizar 0dB para o nível 3 acarretava em identificação de RBA para altos níveis de SNR, ou seja, $SNR \geq 0dB$, e de acordo com as Tabelas 9 e 10, seria desejável uma taxa próxima de zero.

Tabela 11 – Níveis de SNR para treinamento.


	Nível SNR 1	Nível SNR 2	Nível SNR 3
Conjunto de Treinamento A	-40dB	-30dB	-20dB
Conjunto de Treinamento B	-30dB	-20dB	-10dB
Conjunto de Treinamento C	-20dB	-10dB	-5dB

O conjunto de teste será composto por dados de todos os canais dos indivíduos das bases NinaPro DB2, excluídos os indivíduos utilizados para treino, NinaPro DB3 e DB4, além da base IEE. Serão avaliadas as taxas de acerto para 9 níveis de SNR de todos os contaminantes, de -40dB a 40dB em intervalos de 10dB, o que resultará em 5 classes distintas: sEMG não contaminado, e sEMG contaminado com RBA, RL, AM e ECG.

A formatação dos dados para o treinamento deve ser realizada de forma a separar os dados do canal selecionado para treinar o modelo em séries temporais, onde cada série vai pertencer a uma classe, dentre as 5 possíveis, que são sEMG, RBA, RL, AM e ECG. Serão testados 3 tamanhos de séries, conforme Tabela 8, que são 30, 45 e 60 amostras, o que representaria 15ms, 22,5ms e 30ms para a frequência de amostragem de 2kHz.

Para o treinamento, um conjunto de 128 séries selecionadas aleatoriamente, onde cada uma pode pertencer a qualquer uma das 5 classes, são caracterizadas como um mini-lote. Uma época de treinamento é realizada quando todos os mini-lotes são apresentados para a rede, para a próxima época as séries são novamente aleatorizadas e apresentadas em mini-lotes, se repetindo o processo até que todas épocas sejam processadas. Para facilitar a compreensão do método proposto, uma amostra de série temporal está representada na Figura 17 onde é apresentado um exemplo de trecho de sEMG com 450 amostras, dividido em 10 séries temporais de 45 amostras cada

Figura 17 – Exemplo de um trecho de sEMG com 450 amostras, particionada em 10 séries de 45 amostras cada.



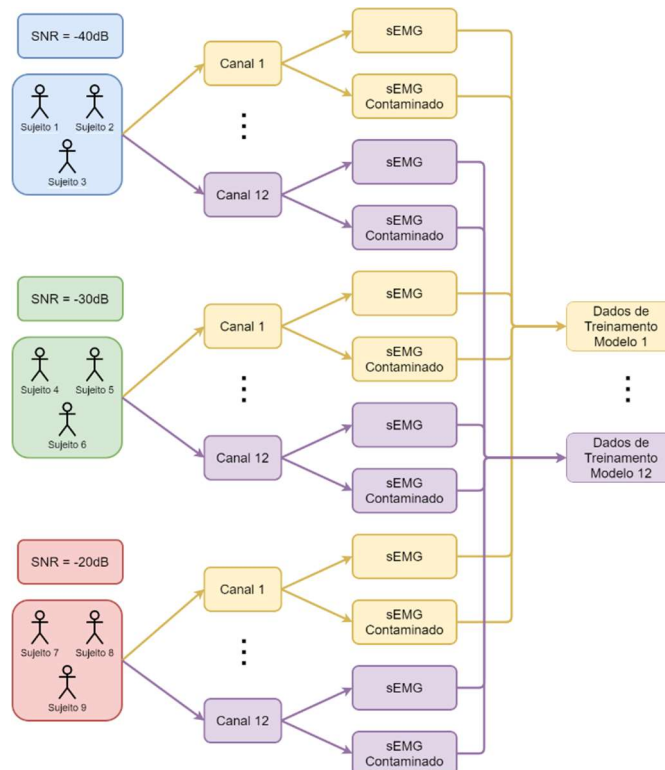
Fonte: Autor.

Para a classificação, um conjunto de 31 séries consecutivas são utilizadas através de votação majoritária para definir a classe final, de acordo com a Figura 15 e lembrando que o estado da camada oculta da RNR é resetado a cada amostra de série, ou seja, classifica as séries de forma independente, mantendo a memória apenas durante a classificação da série.

4.5.2. Seleção hiper parâmetros e modelo

Em testes preliminares, se observou que o tamanho N da sequência e o número de unidades LSTM ($\#LSTM$) na camada oculta (camada H) impactavam a taxa de acerto de forma mais acentuada que os outros parâmetros apresentados na Tabela 8. Para seleção desses hiper parâmetros serão treinados 12 modelos, um para cada canal, utilizando o Conjunto de Treinamento A (Tabela 11), pois representa o pior caso de contaminação possível, facilitando a caracterização de cada contaminante. Na Figura 18 está representado como são gerados os dados para os 12 modelos a serem testados.

Figura 18 – Conjunto de dados para treinar os 12 modelos a serem testados.



Fonte: Autor

Nesse trabalho serão levadas as seguintes considerações para essa seleção: um sinal não contaminado é aquele sinal que não teve nenhuma alteração (sinal bruto) e o sinal contaminado com $SNR \geq 0dB$. Já para poder ser considerado contaminado é necessário possuir um $SNR \leq -10dB$. Essa decisão é fundamentada pelos dados da Tabela 9 e Tabela 10, onde a maioria dos canais já possui correlação acima de 0,8 para $SNR \geq 0dB$. O 0dB é incluído como não contaminado apenas para uma questão de convenção, pois o comportamento esperado desse nível é algo entre contaminado e não contaminado.

Também levando em consideração um contexto de classificação binária, onde o sinal pode estar contaminado ou não, considera-se a classe positiva como contaminada e a classe negativa como não-contaminada. A partir dessas considerações, se delimitam 3 análises fundamentais, que irão guiar o processo de seleção dos parâmetros e teste do IAC e são destacadas no modelo de matriz confusão da Tabela 12:

- 1) taxa de verdadeiro positivo para todos contaminantes com $SNR \leq -10dB$, destacado em vermelho.
- 2) taxa de falso positivo para contaminação com $SNR \geq 0dB$, destacado em amarelo.
- 3) taxa de verdadeiro negativo para o sEMG bruto, ou seja, sem contaminação em nenhum nível, destacado em verde.

Tabela 12 – Casos analisados para seleção dos parâmetros da RNR-LSTM para detecção de contaminantes.

		Predito				
		sEMG	RBA	RL	AM	ECG
Verdadeiro	sEMG	3				
	RBA	2	1			
	RL	2		1		
	AM	2			1	
	ECG	2				1

Essa capacidade do IAC de conseguir distinguir entre contaminação e não contaminação na fronteira (entre -10dB e 0dB) é importante para não acionar mecanismos de mitigação

quando não for necessário. Na grande maioria dos casos (Moura, de e Balbinot, 2018; Zhang e Huang, 2015), considerando o desempenho do sistema, a ação de mitigação não é tão efetiva comparado ao uso do sinal não contaminado, porém mais efetiva que o sinal contaminado.

Portanto a consideração mais importante para se levar em conta nessa análise são as ocorrências de verdadeiro negativo (sinal bruto) e falso negativo para $SNR \geq 0dB$. Nessa condição, falsos negativos são desejáveis, pois conforme afirmado anteriormente, nessa condição já pode-se dizer que o sinal não está mais contaminado.

Para realizar a seleção dos parâmetros dos modelos e a validação dos resultados obtidos com o treinamento do IAC foram utilizados 10 indivíduos da base NinaPro - DB2 (não amputados) e 2 indivíduos da base NinaPro – DB3 (amputados).

Na primeira análise são abordados aspectos da arquitetura do modelo, considerando inicialmente os parâmetros N e $\#LSTM$. Os resultados da validação para seleção dos parâmetros são apresentados para todos os 12 indivíduos, considerando os 12 canais e os 12 modelos treinados (de acordo com a Figura 18) e são realizados para cada um dos grupos de treinamento (A, B e C), descritos na Tabela 11.

As análises serão realizadas inicialmente através de gráficos tipo *boxplot* para cada um dos casos apresentados na Tabela 12 com uma análise de média e intervalo de confiança para todos os casos em que os quartis inferiores das arquiteturas candidatas sejam maiores que 0,8 da taxa de acerto normalizada de cada caso, valor determinado para obter modelos que possuam ao mesmo tempo baixa dispersão e alta mediana, levando a melhores taxas de classificação, com menor erro. Caso nenhuma arquitetura alcance esse indicador de qualidade em alguma das condições analisadas, será selecionado a arquitetura que apresentar o maior limite do quartil inferior dentro daquela condição.

As prioridades para a seleção da arquitetura, após a análise das médias e intervalo de confiança será: 1) melhor desempenho para detecção de FALSO NEGATIVO para $SNR \geq$

0dB (região 2 da Tabela 12), pelos motivos expostos anteriormente; 2) melhor desempenho para verdadeiro negativo (região 3 da Tabela 12); 3) melhor desempenho para verdadeiro positivo (região 1 da Tabela 12); 4) arquiteturas com melhor eficiência computacional (menor sequencia N e $\#LSTM$).

Apesar do IAC ser um identificador de contaminantes, a terceira prioridade na escolha é a taxa de acerto do contaminante porque isso não significa necessariamente que o sinal foi confundido como um sinal não contaminado, mas sim errou o tipo da contaminação. Como no caso da aplicação nesse trabalho, o sensor virtual, o conhecimento do tipo de contaminação não é essencial, se mantém esse aspecto com prioridade mais baixa na escolha da arquitetura e em outras escolhas de projeto do IAC.

O próximo passo é determinar qual canal de sEMG utilizado para treinar o IAC melhor generaliza os resultados, ou seja, que melhor identifique a contaminação em todos os canais dos indivíduos do grupo de teste. Lembrando que são gerados 12 modelos para cada grupo de treinamento, cada um utilizando um dos canais dos indivíduos que compõe o grupo de treinamento, de acordo com a Figura 18. Os modelos gerados para cada grupo de treinamento respeitam os parâmetros determinados na Tabela 15.

É possível se valer das mesmas prioridades utilizadas para seleção da arquitetura, porém, como a busca pelo modelo se torna mais refinada nessa etapa, é utilizado como parâmetro de qualidade modelos cujo quartil inferior esteja acima de 0,9 da taxa de acerto normalizada, valor também determinado empiricamente, que leva a modelos com melhor taxa de acerto e menor variabilidade.

4.5.3. Teste do IAC

Os testes do IAC são realizados utilizando os indivíduos restantes, ou seja, da base NinaPro são utilizados 21 indivíduos da base DB2, 9 da base DB3 (amputados), 10 da base

DB4 e da base IEE são utilizados todos os 8 indivíduos em todas sessões e tipos de exercício. Os resultados do teste irão guiar a escolha do grupo de treinamento que melhor se adapta à aplicação deste trabalho, que é a classificação dos sinais através do ELM.

Inicialmente é realizada uma análise do gráfico Taxa de Acerto x SNR para as regiões 1 e 2 da Tabela 12 comparando os modelos selecionados dos 3 grupos de treinamento. Também são apresentadas as matrizes de confusão para cada grupo de treinamento considerando SNR de -40dB, -20dB, 0dB, 20dB e 40dB.

Uma análise estatística de variâncias (ANOVA) e de médias (Tukey), utilizando o software SAS®, é realizada para verificar a diferença das médias entre cada nível SNR considerando cada tipo de contaminante e grupo, para verificar se as diferenças são significativas dentro dos níveis de SNR, agrupando os níveis 2 a 2. Também é realizada a análise entre cada grupo de treinamento, considerando cada nível SNR e tipo de contaminante, para verificar se existe diferença significativa entre os grupos de treinamento em cada nível SNR. Esses resultados serão utilizados para selecionar o grupo de treinamento utilizado para o teste do sensor virtual.

4.6. Sensor Virtual

A estimação de um sensor virtual pode se assemelhar a um sistema de controle adaptativo, porém há algumas diferenças que devem ser levadas em consideração ao determinar um modelo adaptativo para sensores virtuais (Bhuyan, 2012; Gonzalez *et al.*, 1994):

- 1) um sensor virtual necessita estimar a sua saída continuamente por longos períodos de tempo, enquanto uma planta de controle, usualmente, necessita apenas para curtos períodos. Portanto, modelos matemáticos para séries temporais que possam armazenar o contexto passado podem ser indicados no uso de sensores virtuais;

- 2) sensores virtuais geralmente não necessitam de tantos parâmetros da planta para estimar a saída, apenas de sinais próximos à medida que não está acessível. Do ponto de vista de um sensor virtual aplicado em sinais de sEMG, agrupar conjuntos de músculos próximos para estimação pode resultar em um sinal estimado mais próximo do desejado.

De acordo com a Tabela 4 existe apenas uma solução (Moura, de e Balbinot, 2018) baseada em sensores virtuais para falha em sistemas baseados em sEMG. Nos estudos de caso utilizados foi possível recuperar parte da taxa de classificação perdida com o uso do sensor virtual, mostrando a eficiência da técnica.

Um dos problemas da técnica TVARMA utilizada é a necessidade do constante cálculo da correlação entre os sinais e o uso das 5 características extraídas do sEMG como entrada do modelo, o que pode causar um grande atraso no processamento dos dados, além de limitar a aplicação do sensor a estas características extraídas.

O uso de um canal virtual baseado em RNR-LSTM elimina a necessidade do constante cálculo da correlação, visto que a função de uma ferramenta de aprendizagem de máquina é aprender e generalizar essas relações entre as variáveis. Além disso, o modelo proposto irá regredir o sinal pré-processado do sEMG, ou seja, o sinal filtrado, retificado e filtrado novamente com o filtro AVT. Dessa forma, o modelo pode ser utilizado em diferentes aplicações visto que este pré-processamento é comum na área.


Os canais virtuais que serão gerados nesse estudo são os mesmos dos estudos de caso citados na seção 4.6.2. Para facilitar a leitura da seção, abaixo estão listados novamente os 7 estudos de caso.

- 1) regressão do bloco de 8 eletrodos aleatórios a partir dos canais 9 a 12
- 2) regressão do canal 9 a partir do bloco
- 3) regressão do canal 10 a partir do bloco

- 4) regressão do canal 11 a partir do bloco
- 5) regressão do canal 12 a partir do bloco
- 6) regressão dos canais 9 e 10 a partir do bloco mais canais 11 e 12
- 7) regressão dos canais 11 e 12 a partir do bloco mais canais 9 e 10

A arquitetura da RNR-LSTM deve ser projetada para gerar um *streaming* indefinido de dados, pois não existe nenhuma informação prévia do tempo que irá perdurar a falha do(s) canal(is). É proposta então a RNR-LSTM de estado retido *many-to-many*, pois retém indefinidamente o estado na camada oculta, que permite realizar a regressão de séries de tamanho desconhecido, gerando uma amostra na saída para cada amostra da entrada. Na Figura 19 é apresentada a arquitetura resumida da rede utilizada. A dimensão do vetor de entrada $\mathbf{x}^{(t)}$ e de saída $\mathbf{y}^{(t)}$ vão depender de cada estudo de caso.

Figura 19 – Arquitetura resumida da rede RNR-LSTM proposta. a) Rede em topologia compacta e b) Rede em topologia completa.



Fonte: Autor

São apresentadas 4 arquiteturas distintas, conforme a Tabela 13, com os números de parâmetros para um modelo com 8 entradas e 1 saída, que significa um canal sendo regredido

por 8. A razão para escolher um número limitado de unidades LSTM é dada principalmente pela necessidade de modelos compactos. De acordo com a Tabela 1, a cada unidade LSTM inserida, um novo conjunto de 8 parâmetros é acrescentado, valor que aumenta à medida que aumenta as dimensões de entrada e saída da rede. Para classificação em tempo real o modelo deve ter a capacidade de gerar uma amostra em um tempo menor que o tempo de amostragem dos dados e que ainda possibilite o processamento total dos dados sem atrasos para o usuário, portanto, modelos compactos de rede se mostram mais adequados para futuras aplicações em tempo real.

Tabela 13 – Arquiteturas testadas para o sensor virtual.

Modelo	Camadas LSTM	Unidades Camada #1	Unidades Camada #2	# Parâmetros (8 entradas e 1 saída)
# 1	1	32	-	5.281
# 2	1	64	-	18.753
# 3	2	32	16	8.401
# 4	2	64	32	31.137

Os modelos serão testados a partir do estudo de caso 1 (4 entradas e 8 saídas), caso 2 (8 entradas e 1 saída) e caso 6 (10 entradas e 2 saídas), selecionados de acordo com as configurações de entrada e saída que serão utilizadas em todos os estudos de caso e todos os modelos serão testados para 10, 20 e 30 épocas de treinamento, que foram definidas a partir de testes preliminares. A função de ativação na camada de saída utilizada é a ReLU, apresentada na Equação (10) e por possuir uma saída sempre maior que zero se mostra adequada para um sinal retificado.

A função perda para o treinamento é o Erro Médio Quadrático (EMQ), porém como a variável objetivo final é a classificação de movimentos e repouso, a avaliação dos níveis apresentadas na Tabela 13 serão em relação à taxa de acerto do R-ELM em relação aos movimentos de 10 indivíduos da base NinaPro DB2 que não foram utilizados no treinamento.

Os modelos serão selecionados seguindo como critério principal a arquitetura e em segundo lugar o número de épocas, pois as épocas impactam somente no tempo de treinamento do modelo, enquanto a arquitetura impacta tanto no treinamento quanto na classificação.

Para selecionar o melhor modelo, com as considerações realizadas anteriormente, um projeto experimental é aplicado considerando 2 fatores, Tipo de Modelo e Épocas, com 4 e 3 níveis respectivamente. Para cada combinação serão 10 observações dos indivíduos da base DB2 com os movimentos classificados considerando o pior caso possível, que é 100% de uso do canal virtual. Para avaliar os resultados serão avaliados os efeitos individuais e combinados dos 2 fatores para cada nível. Os modelos que obtiverem prioritariamente nesta ordem: maior taxa de acerto significativa, menor arquitetura e menor quantidade de épocas serão selecionados.


Após selecionado o modelo para cada configuração de entrada e saída, todos estudos de caso são treinados a partir dessas arquiteturas, e é realizado um comparativo entre a taxa de acerto do classificador com todos contaminantes em todos os níveis, com sinal não contaminado e com o sensor virtual. Essa análise é realizada nas bases NinaPro DB3 e IEE, com uma metodologia que será descrita na seção 4.6.2.

4.6.1. Treinamento e Teste

De forma a apresentar dados sequenciais de forma aleatória, inicialmente se tentou apresentar sessões completas aleatorizando os indivíduos, que são 30 indivíduos NinaPro DB2, 10 indivíduos NinaPro DB4 e 4 indivíduos IEE, exercício A sessão 1 apenas, entre as épocas, porém se observou dificuldade em caracterizar as contrações, que pode ser vista na Figura 20. A hipótese é de que como as bases são majoritariamente compostas por períodos de repouso (Cene e Balbinot, 2020), era mais vantajoso para o algoritmo de aprendizagem que

mantivesse os pesos com valores baixos para melhor caracterizar o repouso, pois assim o erro médio também seria menor.

Figura 20 – Exemplo de contração e períodos de repouso



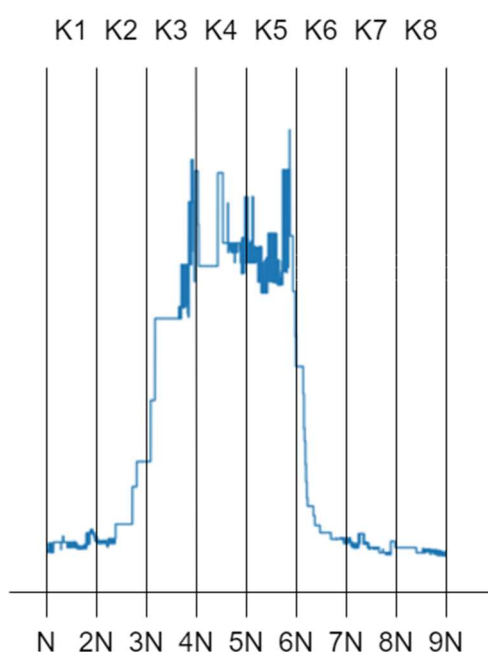
Fonte: Autor

Portanto se notou a importância de caracterizar principalmente as transições de repouso para contração e contração para o repouso, representados pelas linhas verticais na Figura 20. Pode-se notar que o período de repouso parece “invadir” o período de contração, e isso se dá devido a um algoritmo que retrabalha o *timestamp* original analisando todos os canais (Atzori *et al.*, 2015) para sincronizar quando de fato o indivíduo realizou a contração e se realmente manteve a contração por mais ou menos de 5s. Para o treinamento são selecionados os períodos de contração com o tamanho do tempo de repouso antes e depois da contração, definido de forma aleatória.

Cada época do treinamento sequencial da RNR-LSTM de estado retido é realizada com as 6256 amostras de contrações, que são aleatorizadas a cada época. As contrações estão segmentadas em K sequencias de N amostras temporais, conforme Figura 21. Para ficar mais claro, considere que, por exemplo, uma contração qualquer com os 2 períodos de repouso, antes e depois da contração, tenha duração de 10s. Considerando que a taxa de amostragem é de 2 kHz, temos então um total de 20k amostras temporais. Utilizando $N = 100$ amostras, tem-se então $K = \frac{20}{100} = 200$ sequencias de 100 amostras cada.

O mini-lote utilizado é em respeito às K sequencias, que são apresentadas ao modelo na mesma ordem que estão em toda contração, que no caso da Figura 21, seria na ordem $K1, K2, K3 \dots K8$. Portanto se o tamanho do mini-lote for 2, por exemplo, tem-se 4 lotes totais, no caso da Figura 21, onde ao final de cada um dos mini-lotes, o conjunto de pesos é atualizado e após toda contração ter sido apresentada ao modelo, os estados da camada oculta são resetados. O procedimento para resetar o modelo é necessário pois só existe dependência temporal entre as K sequencias de uma mesma contração.

Figura 21 – Trecho de contração dividido em K partes com N amostras cada.



Fonte: Autor

O procedimento para dividir cada contração em K amostras de tamanho N é uma exigência da ferramenta utilizada (*Tensorflow 2.0*) e para este trabalho foi determinado um valor $N = 100$, com mini-lote de 20 amostras, ou seja, tem os pesos atualizados a cada 1s de sinal, suficiente para caracterizar períodos somente de repouso, períodos de transição e períodos somente de contração. O Pseudo Código 2 apresenta todo procedimento de preparação dos dados e treinamento em mini-lotes.

O conjunto de validação será composto dos outros 10 indivíduos da base NinaPro DB2, e o teste de generalização com 9 indivíduos amputados da base NinaPro DB3 e dos 4 indivíduos da base IEE, que são os indivíduos que não foram utilizados na etapa de treinamento.

Pseudo Código 2 – Preparação dos Dados e Treinamento

Preparação dos dados:

1 – Considerar tamanho de mini-lote igual a ML ;

2 – Segmentar todas as C contrações dos 39 indivíduos considerando os períodos de repouso antes e depois da contração;

3 – Dividir cada contração em K séries de N amostras temporais;

Treinamento:

4 – Para E épocas:

4.1 – Aleatoriza lista com C contrações;

4.2 – Para contração c em $C[j]$:

4.3 – Para séries k de tamanho N em $K[i]$ de c :

4.4 – Apresentar ML séries k sequenciais de tamanho N ao modelo;

4.5 – Atualiza os pesos;

4.6 – $i = i + ML$;

4.7 – Retorna para 4.3;

4.8 – $j = j + 1$;

4.9 – Reseta Estados Modelo;

4.10 – Retorna para 4.2

4.10 – $E = E + 1$;

4.11 – Retorna para 4;

5 – Fim de treino;

4.6.2. Classificação Confiável e com tolerância a falha

A classificação do sinal é realizada pelo ELM regularizado de acordo com a Equação (7) com 1200 neurônios na camada oculta e com constante $C = 1,6$. Os dados utilizados para o treino não possuem contaminação artificial e são particionados com 66,6% para treino e 33,3% para testes de cada indivíduo das bases NinaPro DB4 e DB3 e dos 8 indivíduos da base IEE. As características são extraídas em janelas deslizantes de 400ms com incrementos de 10ms.

O classificador possui um pós-processamento da saída que o permite ser mais resiliente e realizar uma classificação confiável. Como grande parte das bases de dados é composto por períodos de repouso, é natural que o classificador crie uma tendência a favor desta classe, visto que é o exemplo mais frequente. Um classificador binário é utilizado inicialmente para determinar período de repouso ou se algum movimento está sendo realizado e após isso é realizado uma suavização da curva de classificação utilizando o mesmo filtro AVT da etapa de pré-processamento do sinal. Esta suavização torna o classificador menos instável, principalmente na região de transição entre repouso e movimento. Mais detalhes podem ser obtidos em (Cene e Balbinot, 2020).

Dada a complexidade da análise das diferentes combinações de contaminações nos canais, o conjunto de 8 eletrodos aleatórios será considerado um bloco único, e serão avaliados os seguintes estudos de caso em que apenas o conjunto de teste terá dados do sensor virtual.

- 1) bloco de canais aleatório contaminado: Regressão a partir dos canais 9 a 12:
- 2) canal 9 contaminado: Regressão a partir do bloco
- 3) canal 10 contaminado: Regressão a partir do bloco
- 4) canal 11 contaminado: Regressão a partir do bloco
- 5) canal 12 contaminado: Regressão a partir do bloco
- 6) canal 9 e 10 contaminados: Regressão a partir do bloco mais canais 11 e 12

7) canal 11 e 12 contaminados: Regressão a partir do bloco mais canais 9 e 10

Essas escolhas são baseadas em proximidade espacial entre os eletrodos, onde o efeito do *crosstalk* sincroniza os registros de eletromiografia para dois ou mais músculos (Farina, Merletti e Enoka, 2004; Mogk e Keir, 2003), ou seja, é mais provável que exista correlação entre músculo próximos do que entre músculos distantes. Existe uma hipótese de uma má performance na regressão se por exemplo tentarmos realizar a regressão do canal 9 posicionado no antebraço utilizando apenas o canal 12, posicionado no tríceps.

Em cada um desses casos será avaliada a taxa de acerto do ELM para os 9 níveis de contaminação de -40dB a 40dB em passos de 10dB. Serão analisadas 4 situações diferentes, considerando o grupo de teste dividido entre amputados (NinaPro-DB3) e não-amputados (IEE) para cada um dos 7 estudos de caso e para cada tipo de contaminante.

- 25% do sinal contaminado;
- 50% do sinal contaminado;
- 75% do sinal contaminado;
- 100% do sinal contaminado;

Para cada nível, em % do sinal contaminado, será utilizada a seguinte metodologia: a cada 10s de sinal, será contaminado um trecho aleatório de 2,5s, 5s, 7,5s e 10s para 25%, 50%, 75% e 100%. Os resultados serão comparados com o sinal íntegro e com o sinal recuperado através do sistema tolerante a falha, constituído do IAC e do sensor virtual para a base de sujeitos amputados e sujeitos não-amputados. A métrica utilizada será a mesma utilizada em (Cene e Balbinot, 2020), a taxa de acerto ponderada pela frequência da classe.

O IAC neste modelo irá operar como um detector binário, entre contaminado e não contaminado, visto que para o sensor virtual não há a necessidade da identificação do contaminante. Como o IAC pode ser utilizado em outros modelos de tolerância a falhas ou até como um indicador para o operador de qual falha está ocorrendo no sistema, se justifica essa

flexibilidade de uso. Nos casos em que mais de um canal está contaminado, são utilizadas duas estratégias para ativação do sensor virtual: quando é o bloco, quando pelo menos 4 ou mais canais indicarem contaminação simultaneamente e para os casos 5 e 6, quando os 2 canais indicarem contaminação simultaneamente.

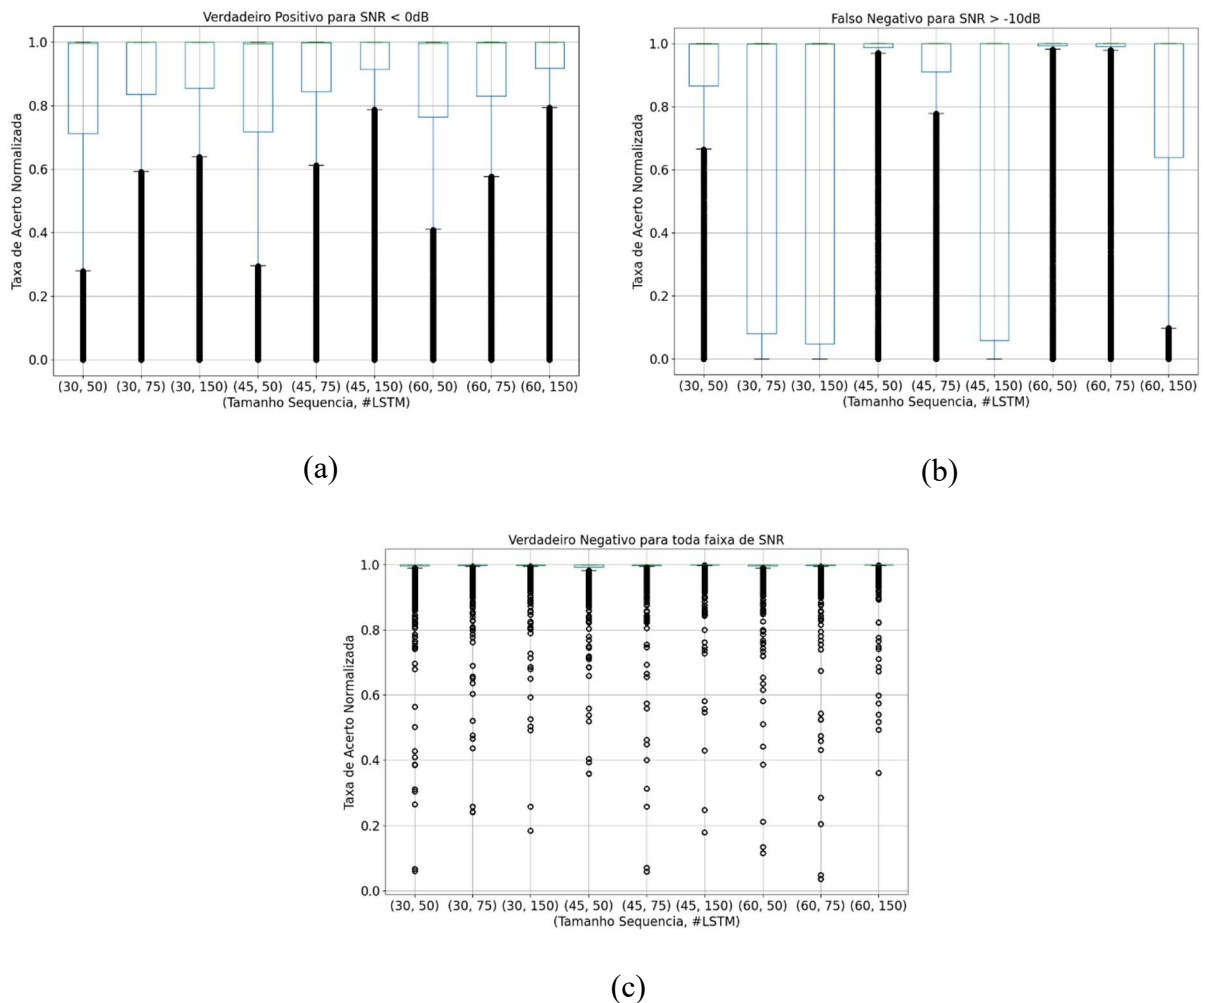
Existem trabalhos que mostram o efeito de sEMG contaminado em classificadores, como no LDA (Zhang e Huang, 2015), SVM (Moura, de e Balbinot, 2018), Regressão Logística (Furukawa *et al.*, 2015), porém nenhum deles apresenta o efeito para diferentes níveis de SNR em todos os contaminantes, sendo essa uma das contribuições originais desse trabalho para a área, além da análise da intermitência do sistema.

5. RESULTADOS E DISCUSSÕES

5.1. Análise do tamanho N da sequência e número de neurônios LSTM da camada oculta

Conforme descrito na seção 4.5.2, inicialmente é realizada a análise das diferentes arquiteturas propostas na Tabela 8. Na Figura 22 são apresentados os *boxplot* para (a) verdadeiro positivo, (b) falso negativo e (c) verdadeiro negativo para o grupo de treinamento A, considerando todas as combinações de N , e #LSTM. Os gráficos para os grupos B e C podem ser visualizadas no Apêndice, nas figuras 56 e 57.

Figura 22 – Gráficos tipo *boxplot* para o grupo de treinamento A considerando todas as combinações (N , #LSTM). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.



Fonte: Autor

Lembrando que para todos os gráficos são desejáveis valores próximos de 1, onde o Verdadeiro Positivo é apresentado para $\text{SNR} \leq -10\text{dB}$ e Falso Negativo para $\text{SNR} \geq 0\text{dB}$, onde a condição Positivo é o sinal contaminado. Para Verdadeiro Negativo a classificação é feita com o sinal bruto, portanto não faz sentido sua análise em diferentes níveis de SNR.

Analisando o grupo A através da Figura 22 (c), na condição Verdadeiro Negativo, observa-se que a identificação do sinal sem nenhum grau de contaminação, ou seja, o sinal bruto, não é um problema para nenhuma configuração de arquitetura dentro do grupo de treinamento A, com todos quartis inferiores acima de 0,8 da taxa de acerto normalizada, que é a métrica de qualidade descrita na seção 4.5.2, mesmo fenômeno observado para os grupos B e C. Agora considerando a Figura 22 (a) e (b), as únicas arquiteturas que se encaixam nos critérios utilizados são ($N = 45$, $\#\text{LSTM} = 75$), e ($N = 60$, $\#\text{LSTM} = 75$). Na Tabela 14 estão apresentadas as médias, desvio padrão e intervalo de confiança para as três arquiteturas candidatas de todos os grupos.

Seguindo os critérios adotados, de acordo com a seção 4.5.2, a arquitetura que prioritariamente apresentar o melhor desempenho médio para Falsos Negativos com $\text{SNR} \geq 0\text{dB}$ é selecionada, portanto, a escolha de arquitetura de projeto para o IAC no grupo de treinamento A é com as seguintes configurações: $N = 60$ e $\#\text{LSTM} = 75$.

Considerando os mesmos critérios para o grupo B, observou-se que apenas a combinação ($N = 60$, $\#\text{LSTM} = 50$) ficou dentro dos critérios estabelecidos, que será então a arquitetura escolhida para o grupo de treinamento B e quanto ao grupo de treinamento C, nenhuma das arquiteturas alcançou o critério de qualidade, portanto, segundo a metodologia aplicada, é utilizada a arquitetura que mais se aproxima dos critérios adotados, que no caso é a combinação ($N = 60$, $\#\text{LSTM} = 50$).

Tabela 14 – Média, desvio padrão e intervalo de confiança para as arquiteturas candidatas para o grupo de treinamento A.

Grupo	Condição	Arquiteturas Candidatas	Média (%)	Intervalo confiança (%)	Desvio Padrão (%)
A	Verdadeiro Positivo	(N = 45, #LSTM = 75)	80,76	[80,13; 80,96]	35,19
		(N = 60, #LSTM = 75)	80,52	[80,11; 80,94]	35,33
	Falso Negativo	(N = 45, #LSTM = 75)	79,00	[78,60; 79,40]	38,33
		(N = 60, #LSTM = 75)	90,49	[90,21; 90,76]	26,46
	Verdadeiro Negativo	(N = 45, #LSTM = 75)	98,92	[98,83; 99,00]	5,46
		(N = 60, #LSTM = 75)	98,97	[98,88; 99,05]	5,45
B	Verdadeiro Positivo	(N = 60, #LSTM = 50)	85,67	[85,31; 86,03]	30,58
	Falso Negativo	(N = 60, #LSTM = 50)	83,32	[82,97; 83,67]	33,36
	Verdadeiro Negativo	(N = 60, #LSTM = 50)	98,00	[97,89; 98,11]	6,81
C	Verdadeiro Positivo	(N = 60, #LSTM = 50)	86,74	[86,39; 87,09]	30,04
	Falso Negativo	(N = 60, #LSTM = 50)	73,61	[73,20; 74,03]	39,70
	Verdadeiro Negativo	(N = 60, #LSTM = 50)	96,44	[96,28; 96,60]	10,23

Na Tabela 15 estão sumarizados os parâmetros N e #LSTM para cada grupo de treinamento usados no IAC:

Tabela 15 – Parâmetros N e #LSTM do IAC para cada grupo de treinamento.

	N	#LSTM
Grupo A	60	75
Grupo B	60	50
Grupo C	60	50

Algo a ser notado é que o aumento de unidades LSTM melhora o desempenho para Verdadeiro Positivo, ou seja, melhora a diferenciação entre os contaminantes, porém causa efeito contrário para Falsos Negativos, ou seja, o classificador fica mais sensível para níveis

altos de SNR, o que não é desejável, o que é notado ao observar que nenhuma arquitetura com 150 unidades LSTM foi selecionada como arquitetura candidata devido esta limitação.

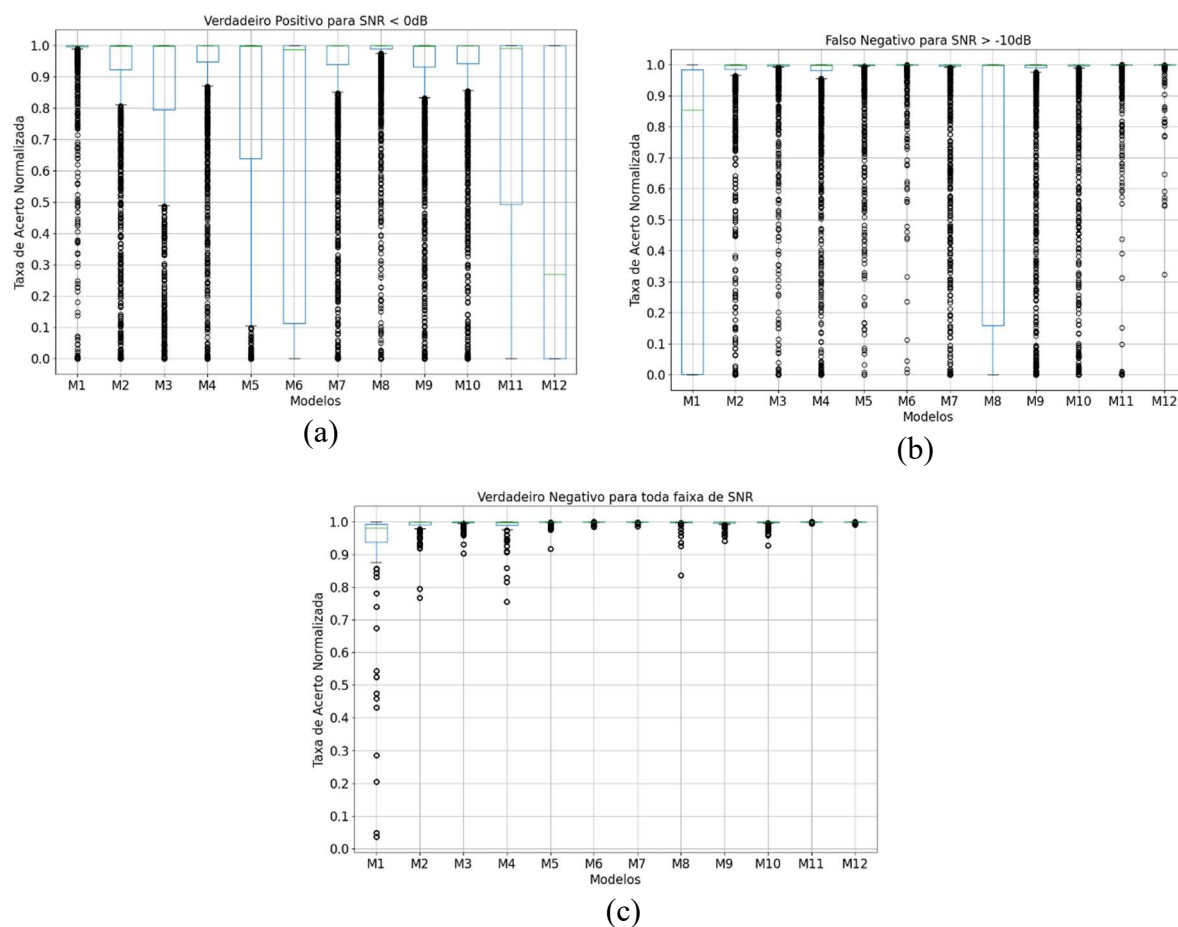
Para o tamanho N , o tamanho 30 não se encaixa como candidata em nenhum dos grupos de treinamento, apresentando principalmente dificuldade em reconhecer Falsos Negativos para SNR alto em todos os grupos de treinamento. Isso forma uma evidência de que séries menores possuem capacidade maior de identificar contaminantes, mesmo para níveis SNR altos. Outra evidência que corrobora a hipótese é de que maior o SNR do grupo de treinamento, mais difícil fica para séries menores “parar” de identificar contaminação, mesmo quando o SNR está alto, conforme observado para as arquiteturas candidatas dos grupos B e C. Essa característica pode ser útil em sistemas que funcionam em 2 etapas, como o sistema proposto em (McCool *et al.*, 2014), onde existe um classificador binário que antecede o identificador de contaminantes, pois não iria depender da RNR-LSTM a sensibilidade entre sinal contaminado e não contaminado, apenas a classificação do tipo de contaminante.

Na Figura 23 são apresentados os gráficos tipo *boxplot* para todos os 12 modelos gerados para o grupo de treinamento A. Os gráficos são apresentados para os mesmos casos destacados na Tabela 12, ou seja, para Verdadeiro Positivo (SNR < 0dB) (a), Falso Negativo (SNR > -10dB) (b) e Verdadeiro Negativo (c). Os gráficos para os grupos de treinamento B e C estão apresentados no Apêndice, na Figura 55 e Figura 56. Os valores do eixo x dos gráficos representam os modelos de cada canal, sendo M1 o modelo do canal 1, M2 o modelo do canal 2 e assim sucessivamente até o modelo M12. Assim como na análise anterior, dos pares (N , #LSTM), são desejáveis valores mais próximos de 1 da taxa de acerto normalizada em todos os gráficos.

Para o grupo de treinamento A, de acordo com a Figura 23 apenas os modelos $M2$, $M4$, $M7$, $M9$ e $M10$ foram selecionados como modelos candidatos, de acordo com os critérios descrito na metodologia (quartil inferior maior que 0,9 em todas as condições). Na Tabela 16

são apresentadas as médias, desvios padrão e intervalos de confiança ao nível de 95% do grupo de treinamento A para os modelos candidatos considerando todas as condições e onde pode-se ver que o modelo *M2* tem o melhor desempenho para Falso Negativo com $\text{SNR} \geq 0\text{dB}$ sendo, portanto, a escolha de modelo para o grupo de treinamento A.

Figura 23 – Gráficos tipo *boxplot* para o grupo de treinamento A considerando todos os modelos para a configuração ($N = 60$, $\#\text{LSTM} = 75$). (a) Verdadeiro Positivo ($\text{SNR} < 0\text{dB}$), (b) Falso Negativo ($\text{SNR} > -10\text{dB}$) e (c) Verdadeiro Negativo.



Fonte: Autor

Utilizando os mesmos critérios para o grupo de treinamento B, os modelos *M1*, *M2*, *M6*, *M7*, *M8*, *M9*, *M11* e *M12* não cumprem o requisito da taxa de acerto normalizada do quartil inferior maior que 0,9. Portanto os modelos candidatos são *M3*, *M4*, *M5*, *M9* e *M10*. Sendo o modelo *M5* selecionado para o grupo de treinamento B.

Tabela 16 – Média, Desvio Padrão e Intervalo de confiança (95%) de Verdadeiro Positivo para os modelos candidatos do grupo de treinamento A.

		Média (%)	Intervalo confiança (%)	Desvio Padrão (%)
Verdadeiro Positivo	M2	84,57	[83,31; 85,84]	31,14
	M4	87,24	[86,11; 88,37]	27,83
	M7	87,58	[86,47; 88,69]	27,34
	M9	89,45	[88,50; 90,39]	23,30
	M10	86,91	[85,75; 88,06]	28,47
Falso Negativo	M2	95,80	[95,25; 96,35]	15,14
	M4	93,27	[92,54; 93,99]	19,98
	M7	88,79	[87,72; 89,85]	29,20
	M9	92,72	[91,93; 93,52]	21,94
	M10	95,34	[94,71; 95,97]	17,25
Verdadeiro Negativo	M2	98,76	[98,60; 98,92]	3,04
	M4	98,63	[98,44; 98,81]	3,46
	M7	99,93	[99,93; 99,94]	1,75
	M9	99,55	[99,50; 99,60]	9,87
	M10	99,61	[99,56; 99,67]	1,01

Também utilizando os mesmos critérios anteriores para o grupo de treinamento C, os modelos candidatos são *M5*, *M6* e *M11*. No caso do grupo de treinamento C, existe uma homogeneidade dos valores, então não se pode afirmar que de fato o modelo *M11* é o melhor modelo por ter a média maior, na realidade tudo indica que não existe uma diferença significativa entre os modelos, porém, como não existe uma diferença de performance entre modelos, pois todos tem a mesma arquitetura, se julga não ser necessário uma análise múltipla de médias. No Apêndice, nas tabelas 29 e 30 são apresentados os valores para os grupos B e C.

Uma observação interessante a ser feita na análise dos canais para escolha do modelo, é que o modelo gerado pelo canal 12, localizado no *triceps*, tem um comportamento relativamente ruim para Verdadeiro Positivo, comparado aos outros modelos. Uma hipótese levantada para esse comportamento é que o *triceps* tem um padrão de contração diferente dos outros canais, que atuam mais nos movimentos de punho, sendo o *triceps* mais ativado em apenas dois exercícios de rotação do antebraço. Essa hipótese também se sustenta pelos

resultados obtidos por (Moura, de e Balbinot, 2018), onde também se observou dificuldade em se caracterizar o sinal de sEMG pelo canal 12 nas mesmas bases de dados.

O fato dos modelos A e B terem sido selecionados dentro do grupo de 8 eletrodos aleatoriamente fixados pode mostrar um poder maior de generalização desses canais para geração dos modelos, considerando que eles estão posicionados de forma muito próxima, podem mostrar uma capacidade maior de generalização, pois agregam informações de um grupo de músculos. Apesar do grupo C ter o canal 11 (*biceps*) como canal selecionado, suas médias têm comportamento muito próximo dos canais 5 e 6, que integram o grupo de eletrodos aleatórios.

Após a seleção dos modelos para cada grupo de treinamento, é realizado um teste, apresentado na seção 5.2, utilizando a base IEE, com 8 indivíduos, consistindo em 4 tipos de exercícios e com 2 sessões cada, o restante da base DB2 (21 indivíduos), a base DB3 (amputados com 9 indivíduos) e a base DB4 (10 indivíduos). Todos os indivíduos possuem 12 canais, com exceção de 2 indivíduos da base de amputados, que não possuem 2 canais cada.

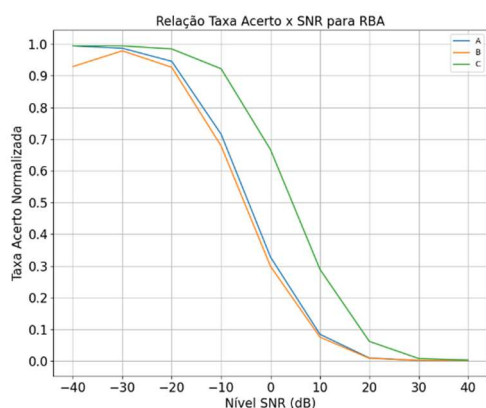
5.2. Teste do IAC

O primeiro resultado do teste apresentado são os gráficos de Taxa de Acerto Normalizada versus SNR para cada um dos grupos de treinamento, cujos resultados são computados de acordo com os Verdadeiros Positivos da Tabela 12. Se optou por não mostrar os resultados por base de dados, pois as bases já foram extensivamente comparadas e demonstraram comportamentos semelhantes (Cene *et al.*, 2019; Cene e Balbinot, 2020), portanto não existe uma diferença significativa na qualidade dos sinais adquiridos.

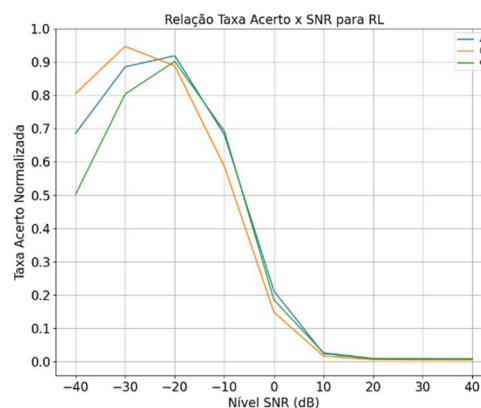
Na Figura 24 observa-se que a variação dos níveis de SNR nos grupos de treinamento parece ter efeito em apenas 2 casos, na Figura 24 (a) e (b). Para a contaminação por RBA o grupo C possui uma sensibilidade maior que A e B, que parecem não ter diferenças

significativas. O fato do próprio sinal de sEMG ter características estocásticas, como o RBA, pode explicar esse aumento de sensibilidade, visto que uma menor amplitude do RBA pode se confundir com o sEMG.

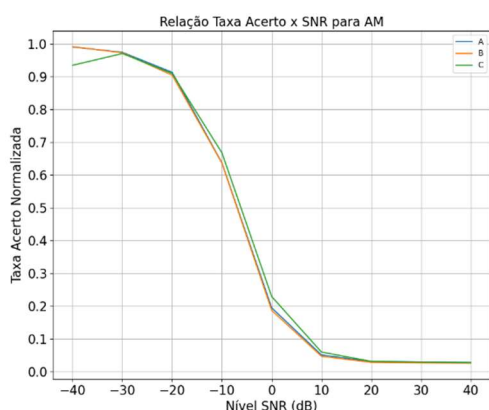
Figura 24 – Taxa de acerto normalizada para Verdadeiro Positivo para (a) RBA, (b) RL, (c) AM e (d) ECG.



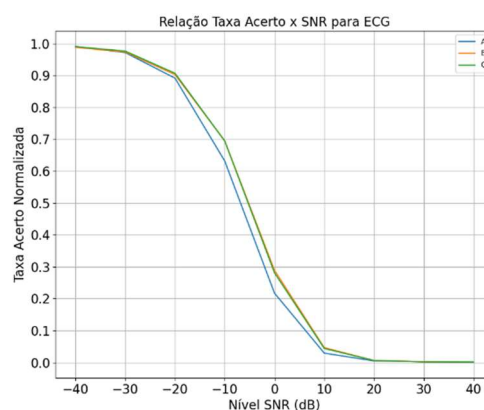
(a)



(b)



(c)



(d)

Fonte: Autor.

Para os demais contaminantes, por possuírem características temporais determinísticas (PLI) ou quasi-determinísticas (ECG e AM) de baixa frequência, se diferem bem ao sEMG quando o SNR é baixo, e quando o SNR é alto, pelas características de baixa frequência, não altera as características temporais do sinal podendo concluir que para esses contaminantes a característica temporal tem uma importância maior que a amplitude para a RNN-LSTM. As

matrizes confusão para os grupos B e C, assim como os gráficos de Falso Negativo estão apresentados no Apêndice, nas tabelas 31 e 32 e na Figura 57.

Para a contaminação com RL, existe uma diferença principalmente nos dois níveis mais altos de contaminação (SNR = -40 e -30 dB), sendo que o RL é mais confundido com o AM nesses casos, de acordo com a Tabela 17, e para o grupo C, também pode ser confundido com RBA. Isso pode ocorrer pelo fato de o grupo C possuir os maiores níveis de SNR (-20, -10 e -5dB), e como demonstrado em (McCool *et al.*, 2014), RBA e AM são confundidos para níveis a partir de 0dB.

Também levando em consideração o fato que o grupo A teve uma taxa de acerto menor para AM e RL que o grupo B, indica que para altos níveis de SNR, AM e RL também se assemelham, pois boa parte da energia do AM está presente entre 1 e 100Hz (Sinderby, Lindstrom e Grassino, A. E., 1995), se sobrepondo ao RL. Para níveis de SNR intermediários a diferenciação é melhor, o que também está de acordo com (McCool *et al.*, 2014).

Sabe-se que ao comparar mesmos modelos com a mesma arquitetura é possível modificar a sensibilidade da identificação de contaminantes (Machado, Machado e Balbinot, 2021) para todos contaminantes, porém o objetivo aqui é determinar o melhor modelo que se encaixa nos critérios determinados a partir das matrizes de correlação das tabelas Tabela 9 e Tabela 10.

Para fundamentar melhor os resultados apresentados na Figura 24 e Tabela 17, foram realizadas 2 análises estatísticas:

- 1) para avaliar se a taxa de acerto média de cada contaminante, considerando cada grupo de treinamento, é significativamente diferente para todos os nove níveis SNR e quais médias são diferentes entre si;
- 2) para avaliar se existe diferença significativa entre os três grupos de treinamento para cada tipo de contaminante, considerando cada nível de SNR.

Tabela 17 – Matriz Confusão para os níveis SNR = -40dB, -20dB, 0dB, 20dB, 40dB do grupo de treinamento A.

		Grupo A					
SNR			Predito				
-40dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,33 ± 9,73	0,02 ± 0,02	0,88 ± 5,58	2,75 ± 8,11	0,03 ± 0,3
		RBA	0,01 ± 0,02	99,42 ± 7,44	0,01 ± 0,02	0,56 ± 7,44	0 ± 0
		RL	0,57 ± 7,46	0,66 ± 7,62	68,57 ± 44,73	30,21 ± 44,21	0 ± 0
		AM	0,64 ± 7,47	0,21 ± 3,90	0,01 ± 0,01	99,12 ± 8,42	0,02 ± 0,11
		ECG	0,69 ± 7,45	0,01 ± 0,27	0 ± 0	0,25 ± 1,02	99,05 ± 7,54
SNR			Predito				
-20dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,33 ± 9,73	0,02 ± 0,02	0,88 ± 5,58	2,75 ± 8,11	0,03 ± 0,3
		RBA	4,87 ± 20,68	94,55 ± 21,86	0,01 ± 0,02	0,29 ± 5,27	0,28 ± 5,27
		RL	6,34 ± 20,17	0,19 ± 3,84	91,83 ± 23,07	1,17 ± 7,94	0,47 ± 5,05
		AM	8,49 ± 21,35	0,10 ± 2,63	0,01 ± 0,02	91,38 ± 21,48	0,02 ± 0,06
		ECG	8,38 ± 19,04	0 ± 0	0 ± 0	2,48 ± 4,45	89,14 ± 19,01
SNR			Predito				
0dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,33 ± 9,73	0,01 ± 0,01	0,88 ± 5,58	2,75 ± 8,11	0,03 ± 0,3
		RBA	66,10 ± 45,04	32,77 ± 45,07	0,02 ± 0,45	0,82 ± 5,73	0,28 ± 5,27
		RL	74,70 ± 36,62	0 ± 0,01	21,18 ± 34,80	3,61 ± 8,91	0,50 ± 3,63
		AM	80,28 ± 31,25	0 ± 0	0,27 ± 2,81	19,43 ± 30,83	0,02 ± 0,23
		ECG	73,18 ± 29,62	0 ± 0	0,30 ± 2,81	4,78 ± 10,65	21,74 ± 25,67
SNR			Predito				
20dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,33 ± 9,73	0 ± 0	0,88 ± 5,58	2,75 ± 8,11	0,03 ± 0,3
		RBA	95,70 ± 13,86	0,96 ± 9,11	0,48 ± 4,11	2,84 ± 9,92	0,03 ± 0,29
		RL	96,40 ± 10,36	0 ± 0	0,8 ± 5,99	2,74 ± 8,24	0,06 ± 0,51
		AM	96,39 ± 10,33	0 ± 0	0,52 ± 4,24	3,02 ± 9,35	0,06 ± 0,60
		ECG	96,10 ± 10,67	0 ± 0	0,52 ± 4,22	2,9 ± 8,65	0,48 ± 4,54
SNR			Predito				
40dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,35 ± 9,73	0 ± 0	0,88 ± 5,58	2,75 ± 8,11	0,03 ± 0,3
		RBA	95,99 ± 12,14	0,17 ± 3,84	0,53 ± 4,25	2,96 ± 9,44	0,34 ± 5,3
		RL	96,56 ± 9,83	0 ± 0	0,67 ± 5,65	2,7 ± 8,03	0,06 ± 0,6
		AM	96,63 ± 9,35	0 ± 0	0,53 ± 4,25	2,78 ± 8,28	0,06 ± 0,8
		ECG	96,58 ± 9,59	0 ± 0	0,54 ± 4,27	2,71 ± 8,08	0,18 ± 2,98

Na análise 1) foi realizada uma análise de variâncias (ANOVA) para cada contaminante em cada grupo de treinamento, totalizando 12 análises. Em todas as análises as médias para cada nível SNR foram consideradas significativas para um $\alpha = 0,05$. Esse resultado é coerente com a Figura 24, pois para todos contaminantes nota-se a diferença das taxas de acerto entre SNR = -40 e 40dB, por exemplo.

Portanto um teste de Tukey, com $\alpha = 0,05$, foi realizado para verificar quais médias eram significativamente diferentes e quais não são, e estão sumarizadas na Tabela 18, onde intervalos com a mesma cor não são significativamente diferentes. O que é notável de se observar é que o nível de 0dB é significativamente diferente dos níveis menores e maiores, o que pode indicar que a partir de 0dB começa a transição entre contaminado e não contaminado, corroborando com as tabelas 9 e 10. Também pode-se observar que a identificação é praticamente a mesma para SNR = -40 e -30dB, com exceção de RBA e RL para o grupo B e RL e AM para o grupo C.

Outro teste que foi realizado, foi comparando os grupos A, B e C para cada nível de SNR e cada contaminante, para ver em quais níveis os grupos são significativamente diferentes considerando cada contaminante. Na Tabela 18 é apresentado o resultado do teste de Tukey, com $\alpha = 0,05$, para os grupos A e B e para as outras comparações, estão disponíveis no Apêndice nas tabelas 33 e 34. As regiões marcadas em vermelho indicam que as médias são significativamente diferentes e em verde, que são significativamente iguais.

Para melhor compreender a Tabela 18, ela pode ser comparada à Figura 24. Para a identificação de RBA, o grupo A tem um melhor desempenho apenas para RBA em -40dB e RL para -10 e 0dB, sendo a diferença maior para -10dB. Para o ECG em todos os níveis que existe diferença, é a favor do grupo B, que poderia ser um problema para o nível de 10dB, pois já é desejável uma baixa taxa de acerto nesse nível, porém a diferença entre os grupos apesar de significativa, é muito pequena.

Tabela 18 – Teste de Tukey considerando os níveis de SNR para cada grupo de treinamento e tipo de contaminante. Níveis com cores iguais na horizontal indica que não são significativamente diferentes.

		Níveis SNR								
		-40	-30	-20	-10	0	10	20	30	40
A	RBA	Blue	Blue	Red	Green	Red	Purple	Orange	Orange	Orange
	RL	Blue	Red	Red	Blue	Green	Red	Red	Red	Red
	AM	Blue	Blue	Red	Green	Red	Purple	Purple	Purple	Purple
	ECG	Blue	Blue	Red	Green	Red	Purple	Purple	Orange	Orange
B	RBA	Blue	Red	Blue	Green	Red	Purple	Orange	Orange	Orange
	RL	Blue	Red	Green	Red	Purple	Orange	Orange	Orange	Orange
	AM	Blue	Blue	Red	Green	Red	Purple	Purple	Purple	Purple
	ECG	Blue	Blue	Red	Green	Red	Purple	Orange	Orange	Orange
C	RBA	Blue	Blue	Blue	Red	Green	Red	Purple	Orange	Orange
	RL	Blue	Red	Green	Red	Purple	Orange	Orange	Orange	Orange
	AM	Blue	Red	Blue	Green	Red	Purple	Purple	Purple	Purple
	ECG	Blue	Blue	Red	Green	Red	Purple	Orange	Orange	Orange

Tabela 19 – Teste de Tukey considerando a média da taxa de acerto nos grupos A e B para cada contaminantes em cada nível de SNR. Intervalos em vermelho indica que são significativamente diferentes e em verde que são iguais.

A e B				
Contaminantes				
SNR (dB)	RBA	RL	AM	ECG
-40	Red	Red	Green	Green
-30	Green	Red	Green	Green
-20	Green	Green	Green	Green
-10	Green	Red	Green	Red
0	Green	Red	Green	Red
10	Green	Green	Green	Red
20	Green	Green	Green	Green
30	Green	Green	Green	Green
40	Green	Green	Green	Green

O grupo C apresentou um comportamento não desejável para RBA, mantendo uma taxa de acerto maior, comparado aos outros grupos, para 0 e 10dB, sendo as médias significativamente diferentes até 20dB entre o grupo C e os grupos A e B. Levando em consideração as observações anteriores, o grupo B é selecionado para o teste com o sensor virtual, pois tem já identifica menos os contaminantes a partir de 10dB, comparado ao grupo

C, e possui uma arquitetura mais compacta que o grupo A, com menos unidades LSTM na camada oculta.

5.3. Seleção da arquitetura do Sensor Virtual

A seleção da arquitetura foi realizada conforme descrito na seção 4.6, onde 100% do sinal dos casos 1, 2 e 6 foram substituídos pelos canais virtuais, estimados por todos modelos e épocas, apresentados na Tabela 13 considerando os 10 indivíduos da base DB2 que não fizeram parte do grupo de treinamento do sensor virtual. Esta metodologia foi implementada, pois com o uso do erro médio quadrático como métrica de treinamento, poderia levar a modelos com um baixo erro, porém com baixa representatividade para o ELM, podendo ajustar o modelo para acertar períodos de repouso, por exemplo, levando a erros para classificação dos movimentos.

Para analisar os resultados e selecionar as arquiteturas, um Projeto de Análise Experimental (DOE – *Design Of Experiments*) foi realizado, considerando Modelos e Épocas os fatores controláveis, com 4 e 3 níveis, respectivamente e após uma análise das médias com um intervalo de confiança de 95%. A prioridade para a seleção do modelo é, conforme descrito na seção 4.6, nesta ordem:

- 1) taxas de acerto mais altas, que devem ser significativamente diferentes;
- 2) arquitetura do Modelo, pois conforme visto na Tabela 13, modelos que apresentam mais unidades LSTM, possuem mais parâmetros, tornando menos eficiente computacionalmente;
- 3) número de épocas, que fica em última prioridade pois só impacta na fase de treinamento.

O resultado do DOE para o caso 1, a combinação dos fatores Modelos e Épocas se mostrou representativo. Porém para este modelo existe um claro problema de representatividade, que já era esperado, visto que é uma tentativa de estimar 8 canais a partir

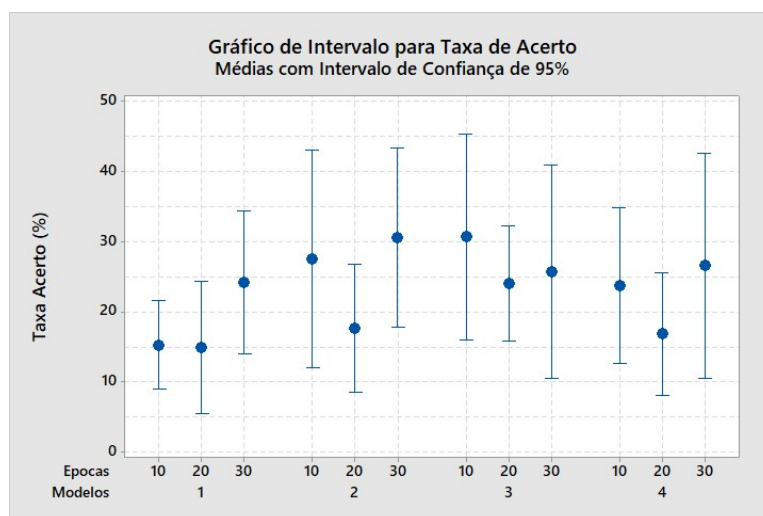
de apenas 4. O objetivo era levar a RNR-LSTM ao limite e analisar seu comportamento, porém os resultados não foram satisfatórios, apresentando médias de acerto na faixa de 30% aproximadamente, de acordo com a Figura 25, onde são apresentadas as médias para os 10 indivíduos em cada condição, com um intervalo de confiança de 95%.

A Figura 25 mostra que o modelo 3 com 10 épocas e o modelo 2 com 30 épocas tem os melhores resultados sendo o modelo 3 selecionado, por possuir a maior taxa de acerto, com o menor número de parâmetros, de acordo com a Tabela 13. A falta de representatividade também é notada em (Moura, de e Balbinot, 2018; Zhang e Huang, 2015), onde a medida que mais canais são contaminados ou degradados, menos eficiente se torna a ferramenta de mitigação.

Para os casos 2 e 6, o efeito combinado entre Modelos e Épocas também se mostrou significativo, para ambos os casos. Na Figura 26 estão apresentadas as médias com os respectivos intervalos com confiança de 95% para o caso 2 e fica claro que o Modelo 1 com 20 épocas é o mais adequado, visto que a taxa de acerto média não é significativamente diferente dos modelos 2 e 4, com 10 épocas ambos e possui uma arquitetura mais compacta. O mesmo comportamento se observa para o caso 6.

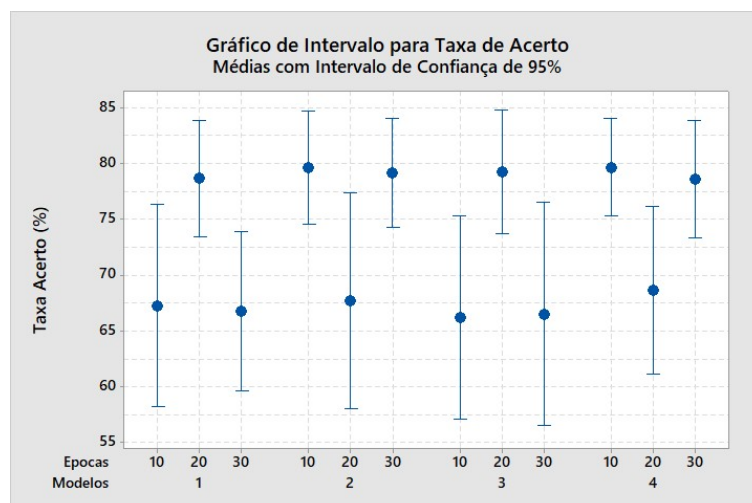
Os dois modelos com mais parâmetros aparentam ter um comportamento anômalo, considerando que tem melhor desempenho em 10 e 30 épocas, perdendo desempenho com 20 épocas. Não é possível afirmar se existe *overfitting* ou *underfitting*, visto que ele só perde desempenho em um valor intermediário de épocas mostrando que o conjunto de treinamento não é suficientemente representativo para esse conjunto de parâmetros, levando a este comportamento inesperado. Para os Modelos 1 e 3 a evidência leva à *underfit* com 10 épocas e *overfit* com 30 épocas, sugerindo que 20 épocas é o valor ideal para o ELM.

Figura 25 – Interação entre Épocas e Modelos para o Caso 1.



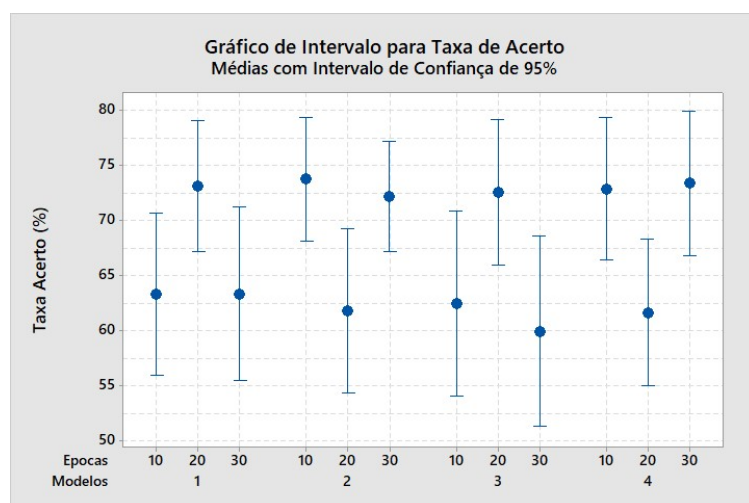
Fonte: Autor

Figura 26 – Interação entre Épocas e Modelos para o caso 2



Fonte: Autor.

Figura 27 – Interação entre Épocas e Modelos para o caso 6.



Fonte: Autor.

5.4. Teste IAC e Sensor Virtual

Nessa seção são apresentados os resultados para o efeito da contaminação no modelo de classificação de movimentos, o RELM, e da atuação do IAC identificando os trechos contaminados e substituindo pelo sensor virtual. O sinal será avaliado considerando 25%, 50% e 100% do sinal contaminado. Também foram realizados testes com 75% de contaminação, cujos resultados estão apresentados no Apêndice, da Figura 69 a 76 e na Tabela 35 para a base NinaPro DB3 e da Figura 86 a 92 e na Tabela 36 para a base IEE.

As análises estão separadas por nível de contaminação, intensidade de contaminação (SNR), contaminantes, base de dados e para cada caso. O objetivo é avaliar onde o IAC associado ao Sensor Virtual, sinal chamado de VC, é efetivo em aumentar a taxa de classificação do sinal contaminado, chamado de CONT e quando ele pode prejudicar o ELM. O sinal não contaminado é denominado NC. Para facilitar a leitura dessa seção, são apresentados novamente os casos considerados:

- 1) regressão do bloco de 8 eletrodos aleatórios a partir dos canais 9 a 12;
- 2) regressão do canal 9 a partir do bloco;
- 3) regressão do canal 10 a partir do bloco;
- 4) regressão do canal 11 a partir do bloco;
- 5) regressão do canal 12 a partir do bloco;
- 6) regressão dos canais 9 e 10 a partir do bloco mais canais 11 e 12;
- 7) regressão dos canais 11 e 12 a partir do bloco mais canais 9 e 10.

Um dos resultados apresentado é a média da taxa de acerto do sinal nas três condições, NC, CONT e VC, de forma gráfica. O outro resultado apresentado é a diferença absoluta entre VC e CONT, sendo que valores positivos representam que VC é maior que CONT e são considerados um efeito positivo do sensor virtual, assim como valores negativos são considerados um efeito negativo. Cabe salientar que as médias apresentadas são para todos os

indivíduos de cada base de teste, pois esse trabalho tem objetivo de apresentar o comportamento por base de dados, porém, sabe-se que existe variabilidade quando analisado sujeito a sujeito, canal a canal e classes de movimento.

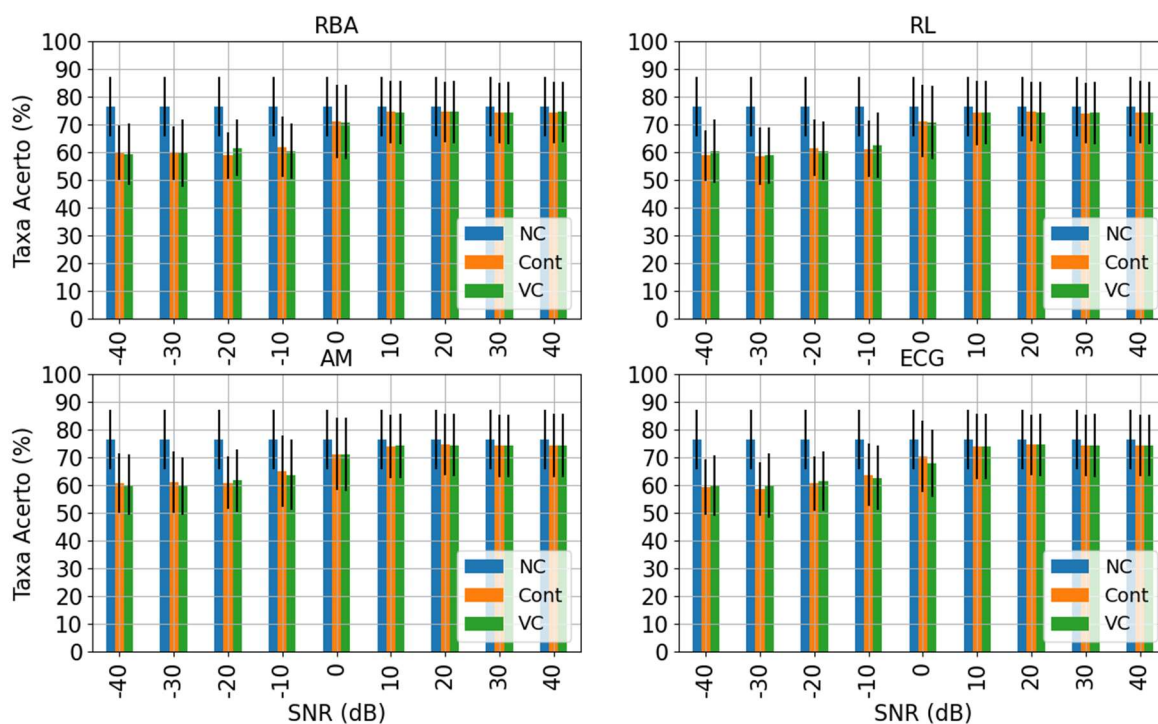
Os resultados são apresentados por nível de contaminação, para cada base de dados em cada um dos casos, onde é feita uma interpretação textual das tabelas e gráficos. As discussões e contextualização desses resultados são realizados na seção 5.5, após a apresentação dos resultados. Devido ao baixo número de amostras e violações do pressuposto de igualdade de variâncias e normalidade da distribuição, se optou por não apresentar uma análise estatística, considerando esses resultados um estudo de caso que não pode ser generalizado para uma população, necessitando mais ensaios, tanto de indivíduos amputados, como não amputados.

5.4.1. Sinal com 25% de contaminação para base DB3

Inicialmente são apresentados os gráficos de efeito para os casos 1, 2, 4 e 6, da Figura 28 a Figura 31, enquanto as figuras para os outros casos estão apresentadas no Apêndice da Figura 58 à 63. Na Tabela 20 são apresentadas todas as diferenças absolutas em % para o sensor virtual e o sinal contaminado, para melhor avaliar as condições em que ele causa um efeito positivo e onde pode causar um efeito negativo.

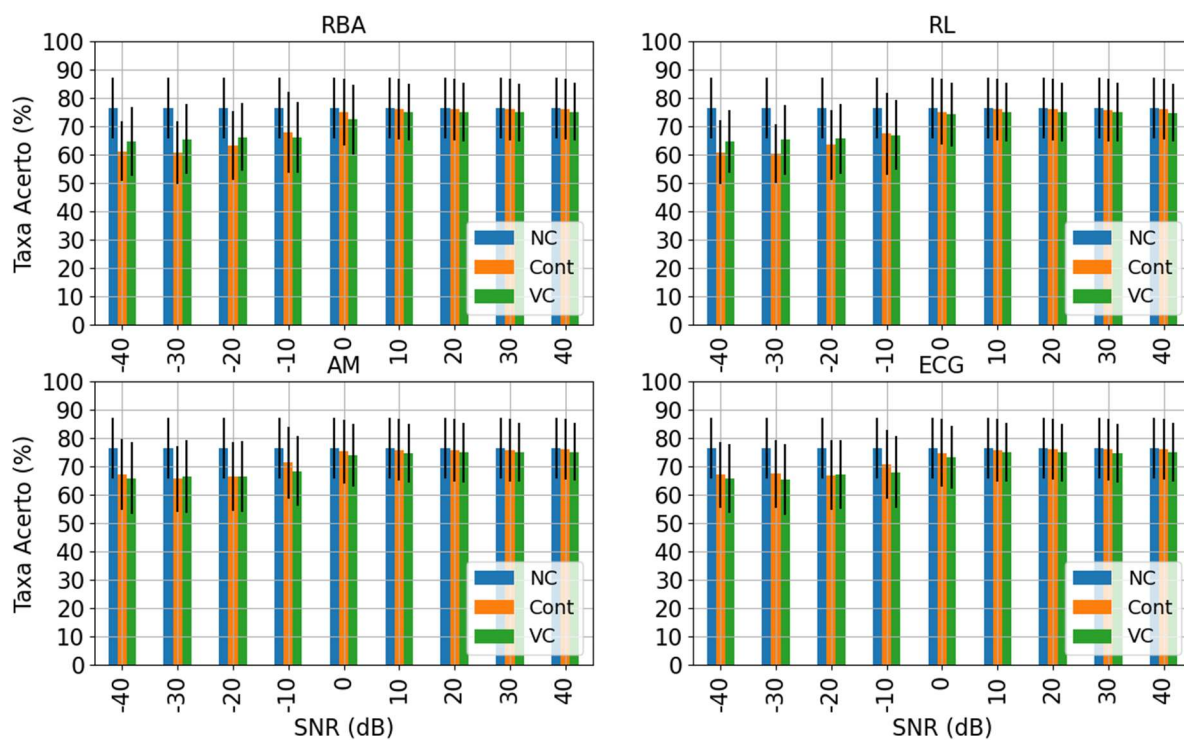
O que se observa para todos os casos é uma redução da taxa de acerto do sinal CONT comparado ao sinal NC para $SNR \leq 0dB$, sendo essa redução mais acentuada para RBA e RL, comparada à AM e ECG. Entre os casos, a maior redução é observada para o caso 1, onde 8 canais são contaminados e para o caso 6, onde os canais 9 e 10 são contaminados, a menor redução é para os casos 4 e 5, que envolvem os canais 11 e 12, respectivamente.

Figura 28 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.



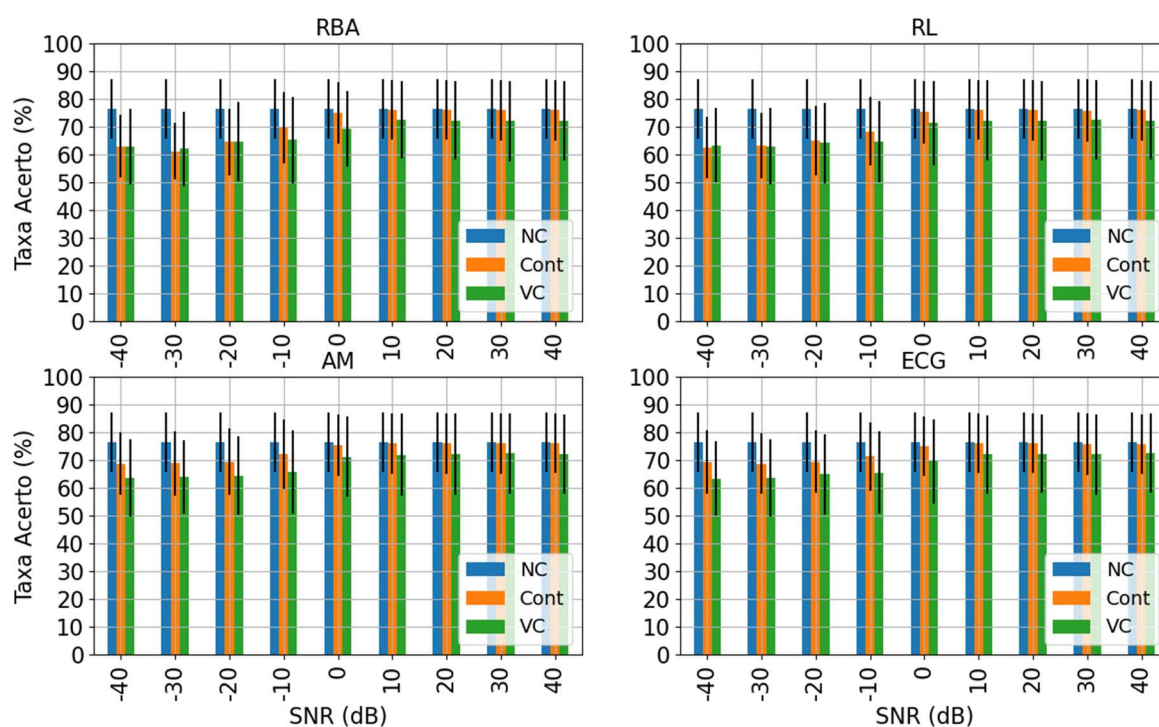
Fonte: Autor.

Figura 29 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.



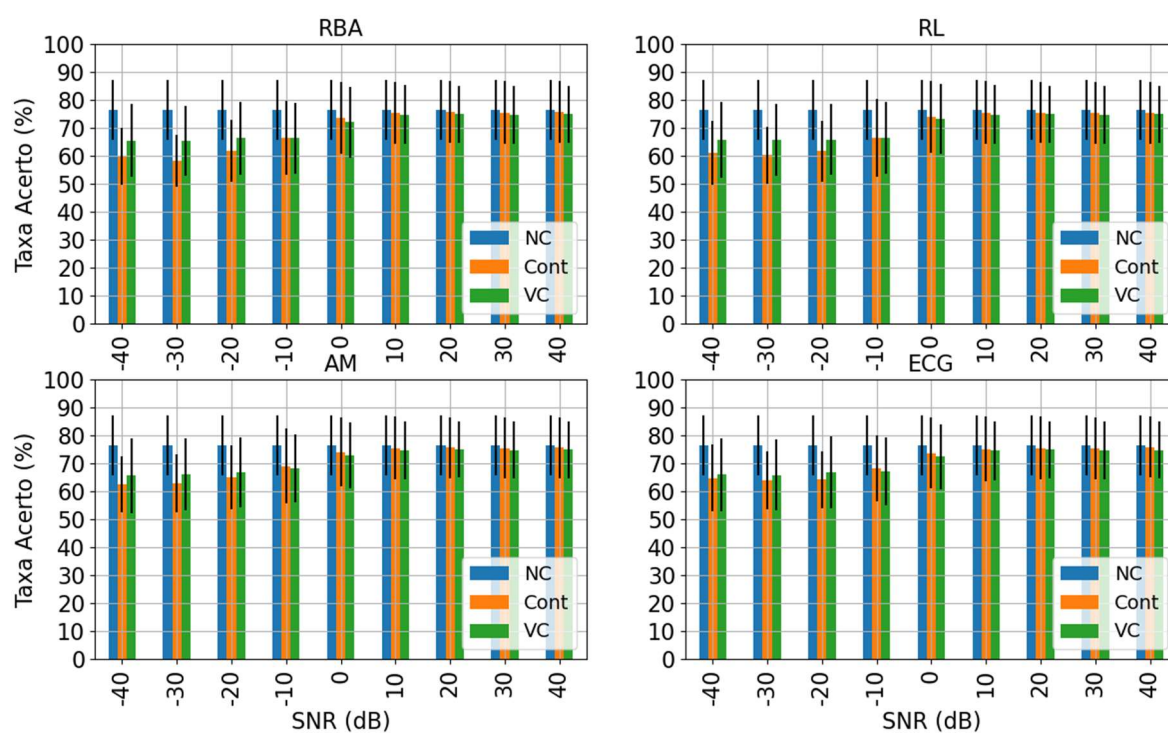
Fonte: Autor.

Figura 30 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.



Fonte: Autor.

Figura 31 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.



Fonte: Autor.

Tabela 20 – Diferença absoluta, em %, entre VC e CONT para todos casos com 25% de contaminação. Valores positivos indicam ganho de performance. Base DB3.

		Níveis SNR (dB)								
		-40	-30	-20	-10	0	10	20	30	40
Caso 1	RBA	-0,48	-0,11	2,63	-1,66	-0,22	-0,29	-0,01	0,05	0,21
	RL	1,47	0,24	-1,02	1,38	-0,47	0,12	-0,26	0,02	-0,18
	AM	-0,43	-1,41	0,88	-1,32	-0,11	0,18	-0,10	0,05	-0,10
	ECG	0,53	1,34	0,86	-0,95	-2,58	-0,08	0,11	0,05	-0,18
Caso 2	RBA	3,40	4,59	2,92	-1,93	-2,75	-0,93	-0,94	-1,08	-0,90
	RL	3,81	4,82	2,21	-0,50	-0,97	-1,03	-0,95	-0,85	-1,24
	AM	-1,13	-0,72	-0,20	-2,86	-1,22	-1,14	-0,82	-0,67	-0,95
	ECG	-1,24	-2,15	0,16	-2,76	-1,73	-0,82	-1,17	-1,24	-0,88
Caso 3	RBA	4,40	4,07	4,34	-2,97	-2,60	-1,48	-1,51	-1,29	-1,32
	RL	5,03	5,83	3,47	-1,01	-2,35	-1,35	-1,35	-1,30	-1,51
	AM	-0,25	-0,12	-0,88	-3,29	-2,18	-1,46	-1,27	-1,56	-1,68
	ECG	-1,14	-1,49	-1,31	-3,47	-2,53	-1,53	-1,32	-1,49	-1,35
Caso 4	RBA	-0,12	0,98	-0,05	-4,47	-5,86	-3,70	-3,77	-3,89	-3,78
	RL	0,90	-0,30	-0,96	-3,72	-4,01	-3,84	-3,83	-3,39	-3,67
	AM	-5,05	-4,84	-4,95	-6,35	-4,26	-4,12	-3,94	-3,50	-3,94
	ECG	-5,92	-5,15	-4,52	-5,81	-5,54	-3,97	-3,85	-3,67	-3,36
Caso 5	RBA	0,04	0,25	-0,85	-3,86	-5,84	-2,02	-2,90	-2,55	-2,35
	RL	0,37	-0,85	-1,32	-2,95	-3,29	-2,80	-2,61	-2,57	-3,21
	AM	-5,13	-4,85	-4,66	-4,24	-3,37	-2,39	-3,26	-2,25	-2,80
	ECG	-4,92	-4,90	-5,16	-4,43	-4,05	-3,50	-2,84	-2,36	-2,30
Caso 6	RBA	5,65	7,11	4,66	-0,17	-1,50	-0,70	-0,96	-0,77	-0,91
	RL	4,68	5,44	4,26	0,03	-0,70	-0,70	-0,63	-0,69	-0,64
	AM	3,01	3,22	1,79	-0,80	-1,06	-0,86	-0,64	-0,78	-0,69
	ECG	1,16	1,96	2,60	-1,01	-1,33	-0,61	-0,56	-0,54	-1,15
Caso 7	RBA	-1,11	-0,05	-3,10	-3,77	-7,51	-4,40	-5,15	-5,22	-5,23
	RL	-0,10	0,18	-1,60	-4,63	-5,62	-4,99	-5,26	-4,89	-5,10
	AM	-5,02	-5,17	-4,33	-7,04	-5,76	-4,69	-5,05	-5,14	-5,49
	ECG	-5,84	-3,82	-5,33	-6,03	-6,28	-5,12	-5,23	-5,41	-5,04

Para o Caso 1, relativo ao bloco de 8 canais, a atuação do sensor virtual não apresentou nenhum padrão, mantendo seu valor próximo de CONT, com efeitos positivos e negativos menores que 3% de acordo com a Figura 28 e Tabela 20 onde se observa o maior ganho de VC para o contaminante RBA em -20dB, e a pior condição para ECG em 0dB.

No caso 2, relativo ao canal 9, o gráfico de efeitos é apresentado na Figura 29, mostrando que o sensor virtual tem um efeito positivo para RBA e RL considerando $SNR \leq -20dB$, e um efeito negativo para esses dois contaminantes, principalmente entre -10dB e 0dB, de acordo

com a Tabela 20. Já para ECG e AM, se observa um efeito negativo do sensor virtual para praticamente todos os níveis de SNR, se acentuando entre -10 e 0dB.

O caso 3, relativo ao canal 10, cujo gráfico de efeitos presente no Apêndice na Figura 58, mostra um efeito positivo do sensor virtual para RBA e RL com $SNR \leq -20dB$ e um efeito negativo principalmente para -10dB e 0dB para estes dois contaminantes, de acordo com a Tabela 20. Para AM e ECG o efeito do sensor virtual é negativo do sensor virtual para todos os níveis SNR.

O caso 4, relativo ao canal 11, apresentado na Figura 30, mostra que o sensor virtual apresenta um efeito positivo para RBA com $SNR = -30dB$ e RL com $SNR = -40dB$ e um efeito negativo para todos outros níveis, inclusive para $SNR \geq 10dB$, mais acentuado entre -10dB e 0dB, de acordo com a Tabela 20.

O caso 5, relativo ao canal 12, cujo gráfico de efeitos se localiza no Apêndice na Figura 59, apresenta efeito positivo apenas em RBA em -40 e -30dB e RL para -40dB, e mantendo um efeito negativo para todas as outras condições, de acordo com a Tabela 20. Esse comportamento se assemelha ao caso 4 e pode ser devido ao fato desses músculos serem menos exigidos, dado os movimentos utilizados, sendo necessário aprofundar mais o comportamento específico desses canais em estudos futuros.

No caso 6, relativo aos canais 9 e 10, o sensor virtual apresenta um efeito positivo para todos contaminantes com $SNR \leq -20dB$, de acordo com a Figura 31 e Tabela 20, sendo esse efeito maior para RBA e RL, comparado à AM e ECG. Para AM e ECG, comparado aos casos 2 e 3, que envolvem os canais 9 e 10 individualmente, o sensor virtual teve um efeito positivo maior, devido à uma maior redução da taxa de acerto do ELM

O caso 7, cujo gráfico está apresentado no Apêndice na Figura 60, relativo aos canais 9 e 10, comparado aos casos 4 e 5, mostra um comportamento semelhante para todos contaminantes, em todos os níveis, sem nenhum efeito positivo do sensor virtual mostrando

que com 25% de contaminação o ELM se comporta de maneira semelhante com os canais individualmente ou simultaneamente contaminados.

5.4.2. Sinal com 25% de contaminação para base Base IEE.

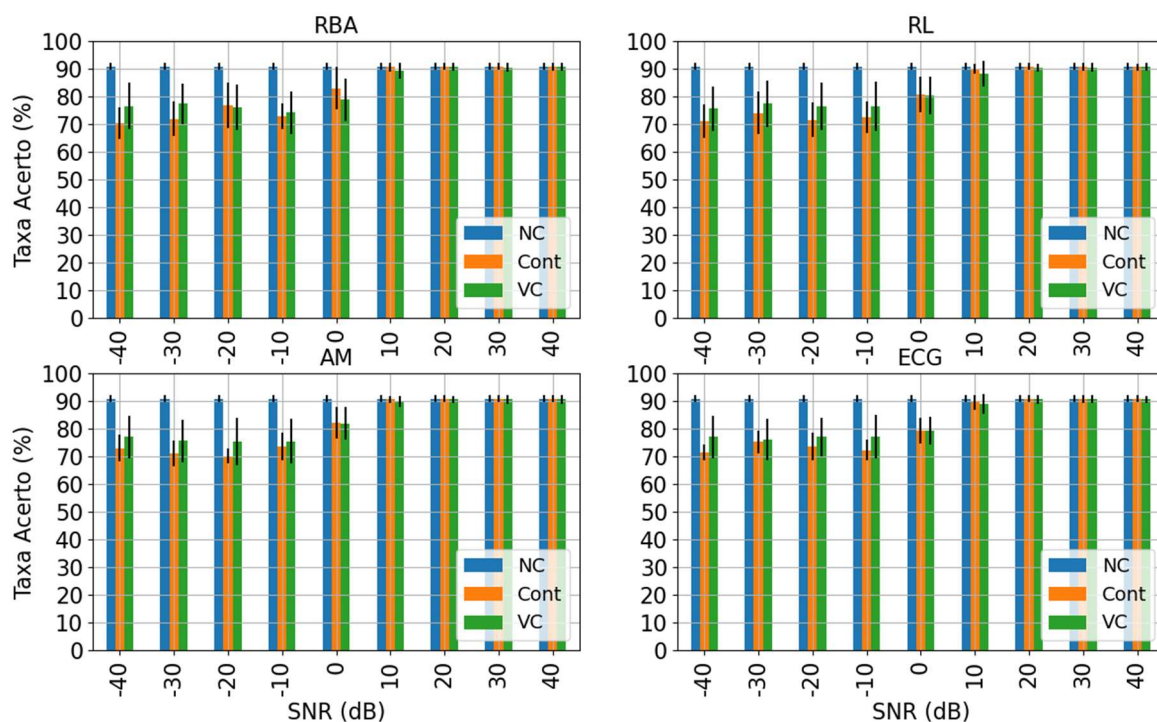
Inicialmente são apresentados os gráficos de efeito para os casos 1, 2, 4 e 6, da Figura 32 a Figura 35, enquanto as figuras para os outros casos estão apresentadas no Apêndice da Figura 74 a Figura 76. Na Tabela 21 são apresentadas todas as diferenças absolutas em % para o sensor virtual e o sinal contaminado, para melhor avaliar as condições onde ele causa um efeito positivo e onde pode causar um efeito negativo.

Para todos os casos se observa uma redução da taxa de acerto do sinal CONT em relação ao sinal NC para todos os casos e contaminantes com $SNR \leq 0dB$, sendo essa redução mais acentuada para RBA e RL. Entre os casos, a maior redução é observada para o caso 1, onde 8 canais são contaminados e para o caso 6, onde os canais 9 e 10 são contaminados, a menor redução é para os casos 4 e 5, que envolvem os canais 11 e 12, respectivamente.

Para o caso 1, relativo ao grupo de 8 canais, de acordo com a Figura 32 e a Tabela 21, É possível observar que o sensor virtual causa um efeito positivo para $SNR \leq -10dB$, considerando todos contaminantes. Para $SNR \geq 0dB$ existe um efeito negativo, sendo ele maior para RBA em 0dB e menor que 2% para toda outras condições.


Para o caso 2, relativo ao canal 9, apresentado na Figura 33, o sensor virtual tem um efeito positivo para todos os contaminantes com $SNR \leq 0dB$, conforme pode ser visto na Tabela 21. Para $SNR \geq 10dB$ o sensor virtual apresenta um efeito negativo, com uma diferença menor que 1% em todas condições.

Figura 32 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 25% do sinal contaminado. Base IEE.



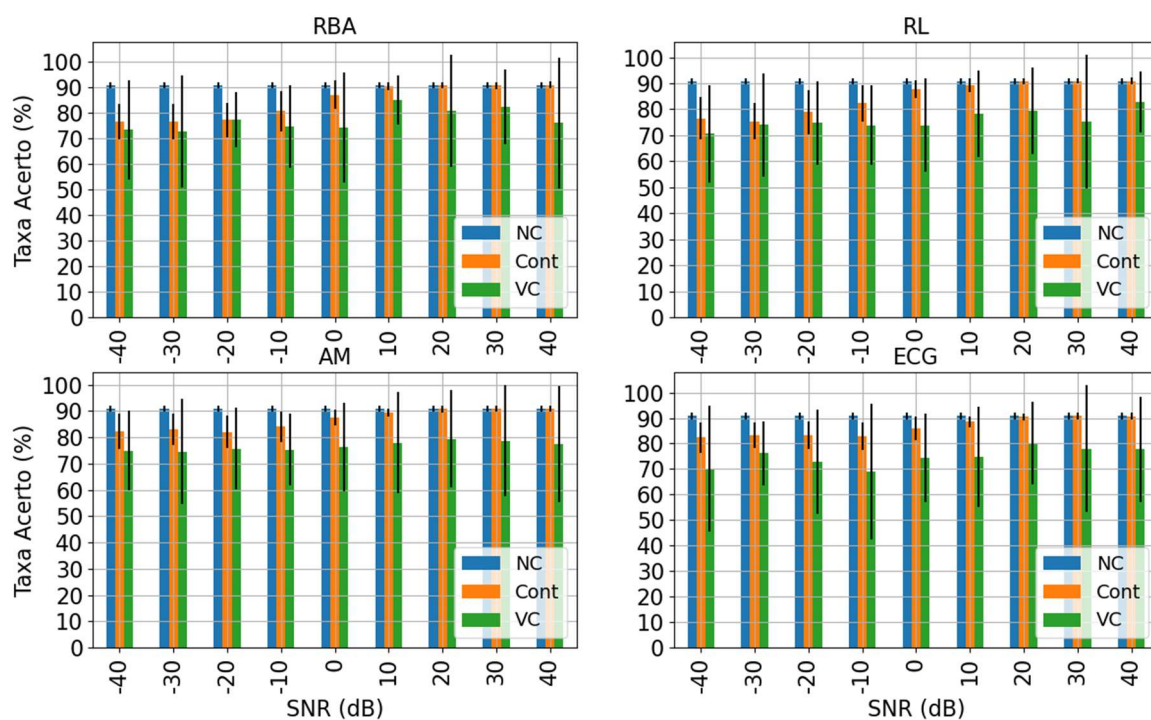
Fonte: Autor.

Figura 33 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 25% do sinal contaminado. Base IEE.



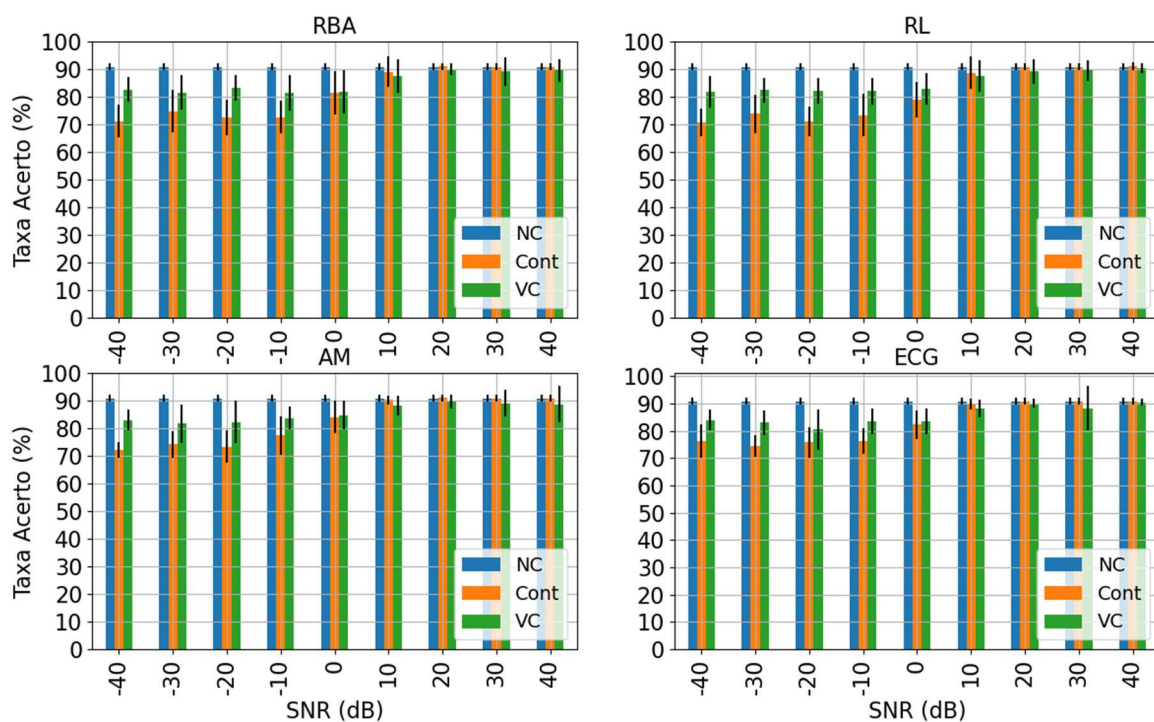
Fonte: Autor.

Figura 34 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 25% do sinal contaminado. Base IEE.



Fonte: Autor

Figura 35 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 25% do sinal contaminado. Base IEE.



Fonte: Autor.

Tabela 21 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 25% de contaminação. Valores positivos indicam ganho de performance. Base IEE.

		Níveis SNR (dB)								
		-40	-30	-20	-10	0	10	20	30	40
Caso 1	RBA	6,16	5,42	-0,81	1,22	-4,23	-1,16	-0,21	-0,34	0,01
	RL	4,53	3,37	4,85	3,91	-0,30	-1,79	-0,39	-0,28	-0,09
	AM	4,02	4,63	5,14	1,98	-0,13	-0,63	-0,27	-0,24	-0,35
	ECG	5,70	0,82	3,52	4,87	-0,12	-0,49	-0,27	-0,08	-0,22
Caso 2	RBA	8,44	10,22	8,18	7,57	0,15	-0,22	-0,22	-0,37	-0,30
	RL	9,02	9,53	6,98	7,68	1,70	-0,39	-0,54	-0,31	-0,34
	AM	4,67	4,02	4,25	2,19	1,63	-0,84	-0,46	-0,21	-0,22
	ECG	3,91	4,68	3,98	2,87	2,70	-0,87	-0,34	-0,35	-0,37
Caso 3	RBA	5,23	11,42	3,55	5,90	-4,90	-1,46	-4,85	-1,40	-3,60
	RL	5,64	7,59	10,36	5,53	-2,14	-7,14	-6,62	-8,42	-6,22
	AM	8,48	4,17	3,43	-3,58	-5,42	-3,30	-5,48	-8,49	-6,52
	ECG	1,42	-0,15	4,24	4,55	-5,91	-2,60	-5,99	-8,37	-6,36
Caso 4	RBA	-3,52	-3,67	-0,13	-6,01	-12,74	-5,57	-10,05	-8,51	-14,93
	RL	-5,92	-1,37	-4,15	-8,37	-13,80	-10,75	-11,11	-15,63	-8,01
	AM	-7,40	-8,43	-6,46	-8,66	-11,27	-11,59	-11,31	-12,22	-13,48
	ECG	-12,04	-7,10	-10,52	-13,91	-11,57	-13,63	-10,27	-12,84	-12,96
Caso 5	RBA	0,92	1,68	-2,65	-4,16	-10,40	-10,08	-5,41	-7,66	-10,16
	RL	1,31	-1,17	-3,23	-7,54	-5,55	-7,15	-8,29	-7,77	-6,62
	AM	-4,53	-4,52	-4,78	-6,69	-4,96	-8,43	-8,00	-8,24	-8,62
	ECG	-5,62	-5,70	-4,61	-0,89	-8,30	-7,84	-7,16	-6,67	-7,20
Caso 6	RBA	11,42	6,81	10,83	8,73	0,23	-1,43	-0,81	-1,63	-1,34
	RL	11,00	8,65	11,12	8,77	3,99	-1,18	-1,60	-1,33	-0,64
	AM	10,82	7,53	8,87	6,24	0,81	-1,87	-1,23	-1,76	-2,11
	ECG	7,71	8,56	4,66	7,20	1,14	-1,62	-0,71	-2,40	-0,45
Caso 7	RBA	-0,39	1,01	3,84	-1,45	-5,56	-2,38	-4,16	-5,04	-4,87
	RL	2,87	1,97	-2,25	-1,25	-8,07	-5,50	-4,72	-4,88	-6,08
	AM	-0,16	0,15	-0,64	-1,22	-7,09	-4,64	-5,43	-6,18	-5,58
	ECG	-1,43	-0,82	0,16	-1,45	-5,34	-6,53	-5,17	-5,14	-4,80

No caso 3, relativo ao canal 10, cujo gráfico está apresentado no Apêndice, na Figura 74, e de acordo com a Tabela 21, observa-se um efeito positivo do sensor virtual para RBA, RL e ECG entre -40dB e 0dB e para AM o efeito positivo é de -40dB a -10dB. Acima de 0dB o que se observa é um efeito negativo do sensor virtual, com uma diferença maior que a observada para os casos 1 e 2. Essa diferença maior ocorre principalmente devido a ocorrência de falsos positivos do IAC, indicando uma contaminação prévia do sinal. Algo que também é observado, é que principalmente para RBA, existe uma interação entre a contaminação prévia

e o contaminante para 10dB e 30dB, deixando o comportamento do sinal mais próximo de sEMG não contaminado.

O caso 4, relativo ao canal 11, conforme pode ser observado na Figura 34 e Tabela 21, possui um efeito negativo do sensor virtual para todos os contaminantes em todos os níveis de SNR. Esse efeito negativo para $SNR \leq 0dB$ é devido a uma má caracterização do sensor virtual para esse canal e para $SNR \geq 0dB$, além do problema de caracterização, existe a ocorrência de falsos positivos do IAC, devido a contaminação prévia do sinal.

O caso 5, relativo ao canal 12, cujo gráfico se encontra no Apêndice, na Figura 75 e que pela Tabela 21, nota-se que existe um efeito negativo do sensor virtual em praticamente todos níveis SNR e contaminantes, com exceção de RBA e RL com $SNR \leq -30dB$. Para esse canal também existe um problema de caracterização e de falsos positivos do IAC.

O caso 6, relativo aos canais 9 e 10, com os resultados apresentados na Figura 35 e que pela Tabela 21 pode-se notar um efeito positivo do sensor virtual com $SNR \leq 0dB$ par todos contaminantes. Acima de 0dB observa-se um efeito negativo, que é menor que o efeito observado individualmente no caso 3, relativos ao canal 10. Isso ocorre porque os 2 canais precisam apresentar contaminação ao mesmo tempo, reduzindo assim a ocorrência de falsos positivos do IAC.

Para o caso 7, cujo gráfico está no Apêndice, na Figura 76, e que de acordo com a Tabela 21, existe um efeito positivo do sensor virtual apenas para alguns poucos casos e sempre abaixo de 4%, mostrando um efeito negativo em praticamente todos os níveis SNR e contaminantes.

5.4.3. Sinal com 50% de contaminação para base DB3

Inicialmente são apresentados os gráficos de efeito para os casos 1, 2, 4 e 6, nas figuras Figura 36 a Figura 39, enquanto as figuras para os outros casos estão apresentadas no

Apêndice da Figura 61 a Figura 63. Na Tabela 22 são apresentadas todas as diferenças absolutas em % para o sensor virtual e o sinal contaminado, para melhor avaliar as condições em que ele causa um efeito positivo e onde pode causar um efeito negativo.

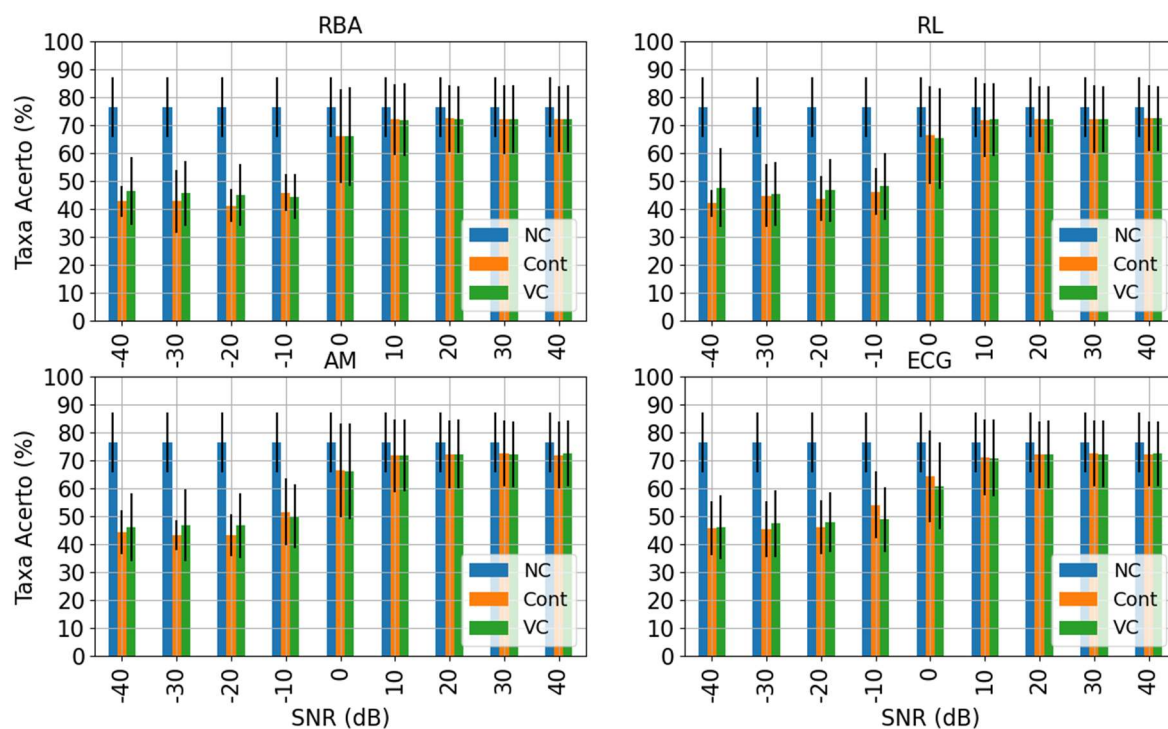
O que se observa para todos os casos é uma redução da taxa de acerto do sinal CONT comparado ao sinal NC para $SNR \leq 0\text{dB}$, sendo essa redução mais acentuada para RBA e RL, comparada à AM e ECG. A redução observada também é maior comparada ao sinal com 25% de contaminação para base DB3. Entre os casos, a maior redução é observada para o caso 1, onde 8 canais são contaminados e para o caso 6, onde os canais 9 e 10 são contaminados, a menor redução é para os casos 4 e 5, que envolvem os canais 11 e 12, respectivamente. Existe também uma redução da taxa de acerto para $SNR \geq 10\text{dB}$ para o caso 1, mostrando que uma contaminação acima deste valor para 8 canais ainda afeta a taxa de acerto.

Para o caso 1, relativo ao grupo de 8 canais, de acordo com a Figura 36 e a Tabela 22 o sensor virtual tem um efeito positivo para todos os contaminantes com $SNR \leq -20\text{dB}$ e um efeito negativo, principalmente entre -10 e 0dB , que é maior para ECG e não chegando a 2% para os outros contaminantes.

O caso 2, relativo ao canal 9 e com os resultados apresentados na Figura 37, o sensor virtual apresenta um efeito positivo para $SNR \leq -20\text{dB}$ para RBA, RL e AM e nenhum efeito positivo para ECG, com exceção de -20dB com um ganho menor que 1%, de acordo com a Tabela 22. O efeito negativo do sensor virtual é maior para SNR entre -10 e 0dB , com exceção de RL.

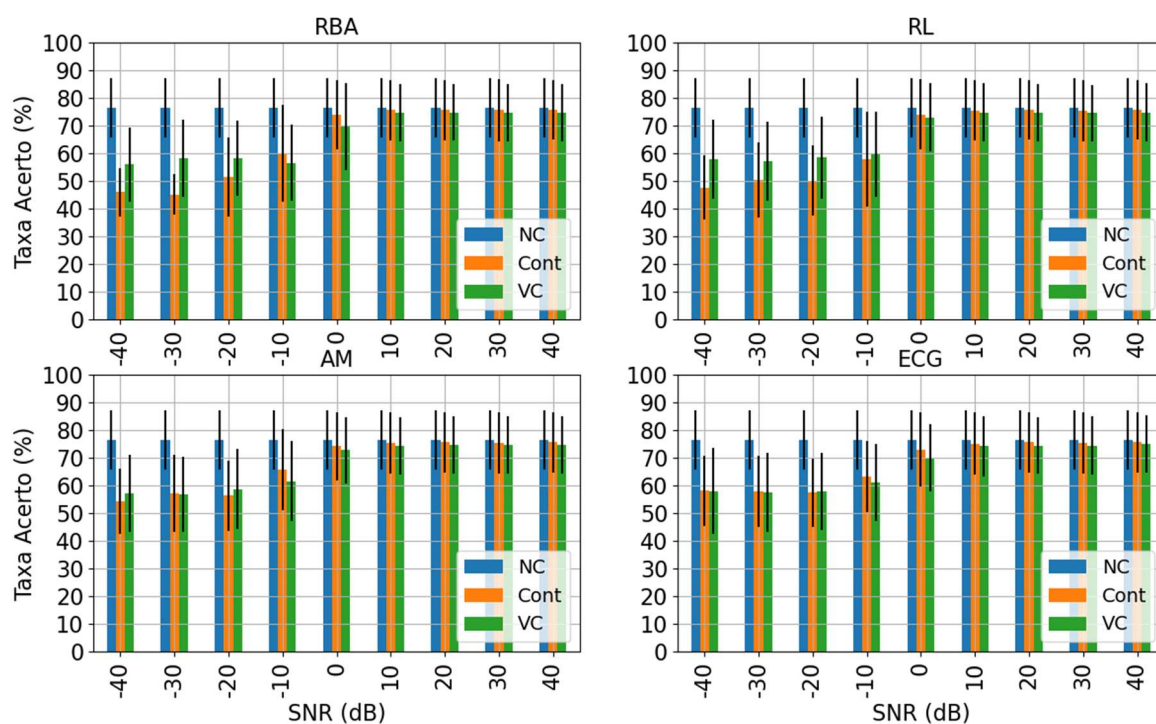
Para o caso 3, relativo ao canal 10, cujo gráfico de efeitos se encontra no Apêndice, na Figura 61, se observa um efeito positivo do sensor virtual para RBA com $SNR \leq -20\text{dB}$ e RL para $SNR \leq -10\text{dB}$ de acordo com a Tabela 22. Para AM apresenta efeito positivo menor que 1,5% em -40dB e -20dB e efeito negativo em todos outros níveis. ECG não apresenta nenhum

Figura 36 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 50% do sinal contaminado. Base DB3.



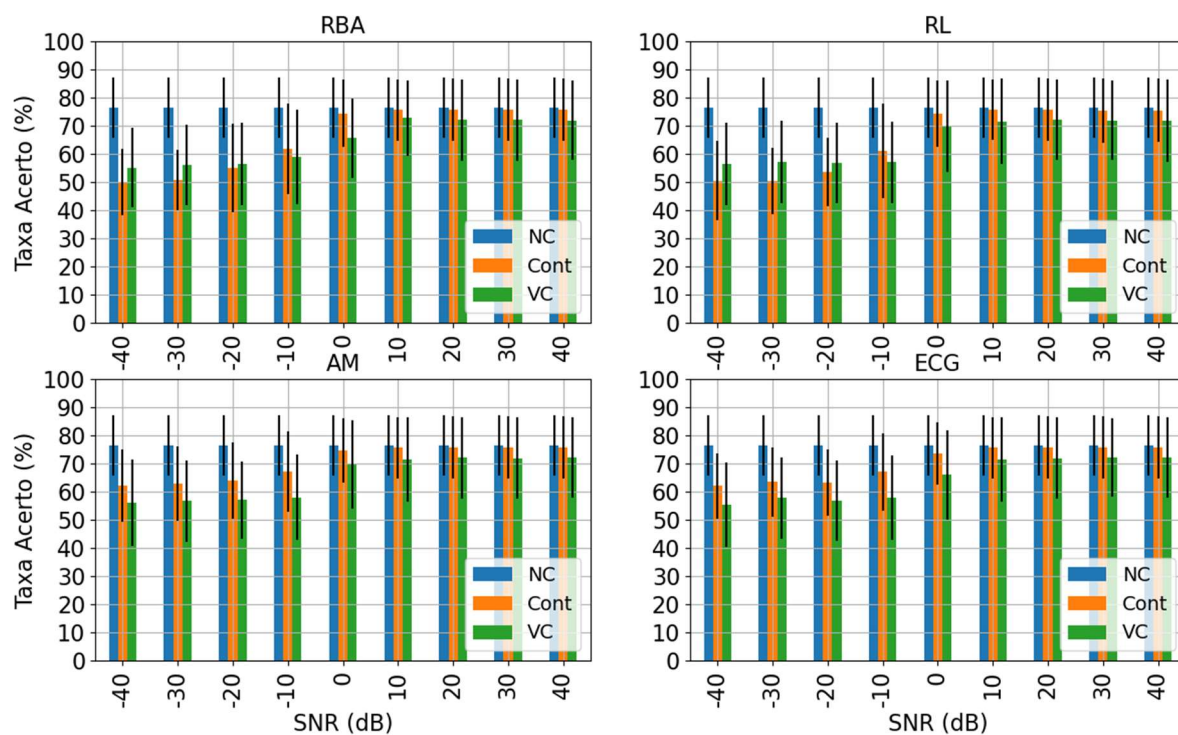
Fonte: Autor.

Figura 37 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 50% do sinal contaminado. Base DB3.



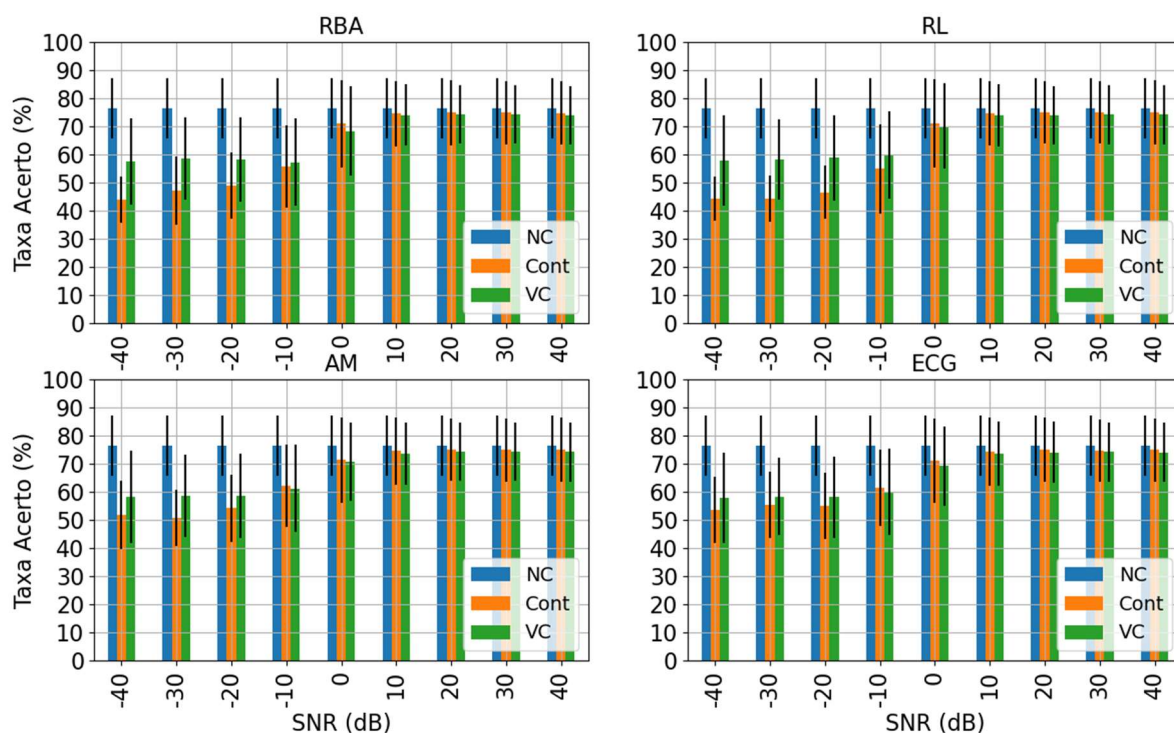
Fonte: Autor.

Figura 38 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 50% do sinal contaminado. Base DB3.



Fonte: Autor.

Figura 39 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 50% do sinal contaminado. Base DB3.



Fonte: Autor.

Tabela 22 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 50% de contaminação. Valores positivos indicam ganho de performance. Base DB3.

		Níveis SNR (dB)								
		-40	-30	-20	-10	0	10	20	30	40
Caso 1	RBA	3,80	2,89	3,71	-1,35	-0,04	-0,10	-0,21	0,30	0,03
	RL	5,52	0,59	2,89	2,04	-1,21	0,31	-0,14	-0,01	-0,03
	AM	1,85	3,66	3,43	-1,55	-0,33	0,08	0,12	-0,15	0,68
	ECG	0,35	1,92	1,85	-5,28	-3,34	-0,22	0,10	-0,24	0,06
Caso 2	RBA	9,94	13,00	6,77	-3,53	-4,27	-0,95	-0,91	-0,87	-1,00
	RL	10,23	6,79	8,24	1,77	-1,02	-0,83	-1,04	-0,84	-0,82
	AM	2,79	-0,34	2,41	-4,20	-1,41	-1,00	-1,08	-0,79	-0,90
	ECG	-0,24	-0,29	0,47	-2,33	-3,05	-1,01	-1,17	-0,95	-0,68
Caso 3	RBA	10,49	8,86	8,34	-2,02	-3,82	-1,31	-1,24	-1,42	-1,48
	RL	11,66	12,44	8,21	2,56	-2,23	-1,39	-1,34	-1,74	-1,16
	AM	1,32	-1,92	0,84	-4,90	-2,27	-1,70	-1,17	-1,35	-1,34
	ECG	-1,99	-1,37	-2,03	-6,25	-3,72	-1,68	-1,47	-1,43	-1,29
Caso 4	RBA	5,18	5,27	1,36	-2,92	-8,91	-2,86	-3,73	-3,69	-3,78
	RL	5,99	6,83	3,09	-4,04	-4,51	-4,22	-3,58	-3,55	-3,75
	AM	-6,12	-6,26	-6,86	-9,29	-5,05	-4,14	-3,53	-3,74	-3,51
	ECG	-6,66	-5,71	-6,58	-9,13	-7,60	-4,13	-3,73	-3,52	-3,52
Caso 5	RBA	6,50	2,65	0,86	-2,94	-8,43	-1,36	-2,75	-2,61	-3,27
	RL	7,39	0,58	0,57	-1,41	-3,42	-3,59	-2,75	-2,84	-2,56
	AM	-4,31	-6,47	-6,59	-6,35	-4,07	-3,11	-2,76	-2,55	-2,62
	ECG	-5,38	-5,48	-6,03	-7,74	-5,53	-3,33	-3,13	-2,03	-2,68
Caso 6	RBA	13,47	11,34	9,30	1,67	-2,56	-0,53	-0,50	-0,82	-0,71
	RL	13,63	13,88	12,29	4,93	-0,94	-0,81	-0,95	-0,73	-0,81
	AM	6,46	7,81	4,23	-0,99	-0,47	-0,76	-0,59	-0,72	-0,85
	ECG	4,47	3,03	3,01	-1,31	-1,81	-0,76	-0,96	-0,60	-0,84
Caso 7	RBA	3,11	5,14	1,89	-1,85	-11,28	-4,00	-4,98	-4,67	-5,43
	RL	7,81	8,28	4,04	-1,22	-4,52	-5,39	-5,02	-4,69	-4,89
	AM	-4,19	-3,56	-4,09	-6,17	-6,58	-5,20	-5,18	-4,93	-4,75
	ECG	-2,02	-3,14	-5,67	-7,23	-7,46	-5,18	-4,82	-4,80	-4,69

efeito positivo e para todos contaminantes o efeito negativo do sensor virtual é maior entre -10 e 0dB.

O caso 4, referente ao canal 11, com os resultados apresentados na Figura 38 apresenta um efeito positivo do sensor virtual apenas para RBA e RL com $SNR \leq -20dB$ e um efeito negativo para todas outras condições, sendo esse efeito maior entre -10dB e 0dB, principalmente para AM e ECG, conforme resultados apresentados na Tabela 22.

O caso 5, referente ao canal 12, cujos resultados estão apresentados no Apêndice, na Figura 62, se observa um comportamento semelhante ao caso 4, com apenas RBA e RL

obtendo um efeito positivo com $SNR \leq -20\text{dB}$, conforme Tabela 22. Essa semelhança com o caso 4 é devido à menor exigência desses dos músculos relacionados a esses canais, para os movimentos considerados, conforme mencionado anteriormente.

O caso 6, referente aos canais 9 e 10, com os resultados apresentados na Figura 39 apresenta um efeito positivo para $SNR \leq -10\text{dB}$ para RBA e RL, apresentando um efeito negativo maior que 1% apenas para RBA em 0dB. Para AM e ECG o efeito positivo se observa para $SNR \leq -20\text{dB}$ e um efeito negativo, menor que 2%, para todas outras condições.

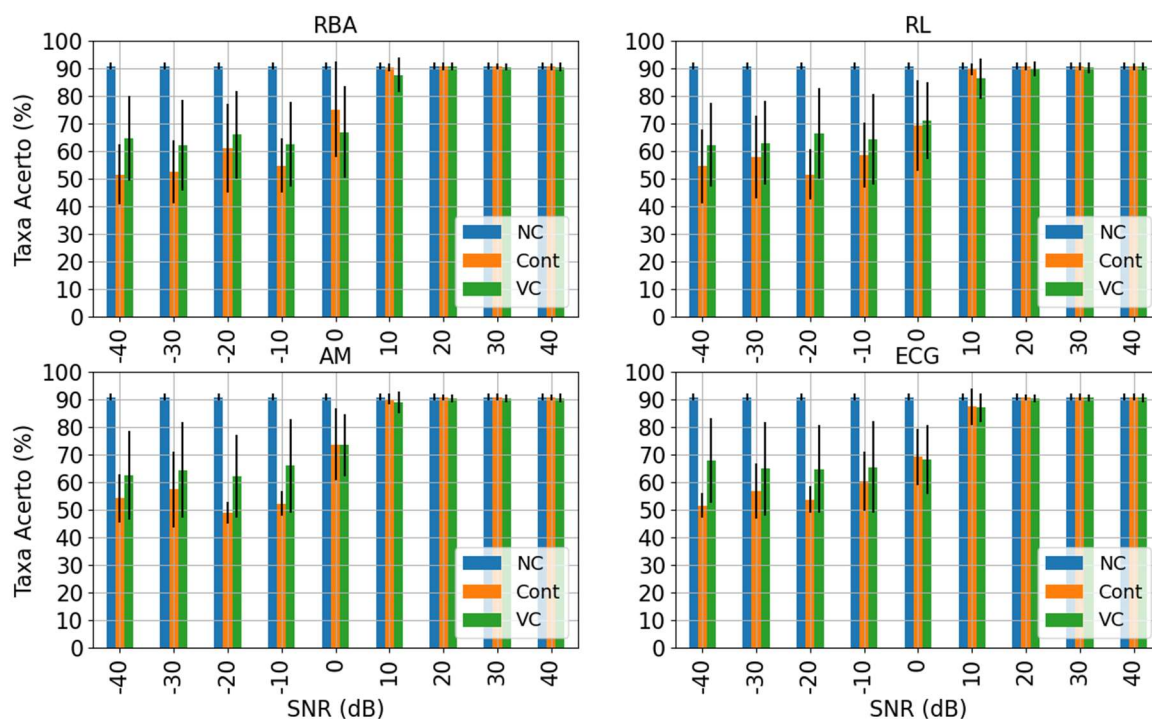
O caso 7, cujos resultados estão apresentados no Apêndice, na Figura 63 e que de acordo com a Tabela 22 apresenta um efeito positivo do sensor virtual apenas para RBA e RL com $SNR \leq -20\text{dB}$ e um efeito negativo para todas outras condições, se acentuando esse efeito entre -10 e 0dB.

5.4.4. Sinal com 50% de contaminação para base IEE

Inicialmente são apresentados os gráficos de efeito para os casos 1, 2, 4 e 6, da Figura 40 à Figura 43 enquanto as figuras para os outros casos estão apresentadas no Apêndice da Figura 77 a Figura 79. Na Tabela 23 são apresentadas todas as diferenças absolutas em % para sensor virtual e para o sinal contaminado, para melhor avaliar as condições em que ele causa um efeito positivo e onde pode causar um efeito negativo.

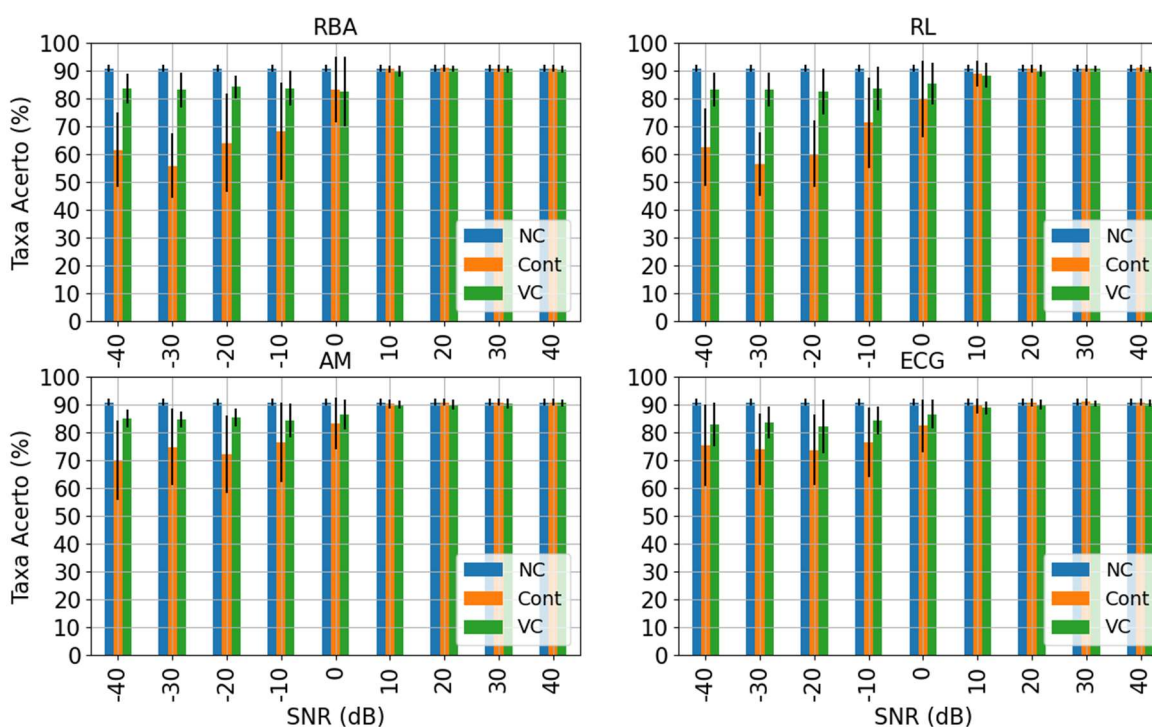
Para todos os casos se observa uma redução da taxa de acerto do sinal CONT em relação ao sinal NC para todos os casos e contaminantes com $SNR \leq 0\text{dB}$, sendo essa redução mais acentuada para RBA e RL. Entre os casos, a maior redução é observada para o caso 1, onde 8 canais são contaminados e para o caso 6, onde os canais 9 e 10 são contaminados, a menor redução é para os casos 4 e 5, que envolvem os canais 11 e 12, respectivamente.

Figura 40 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.



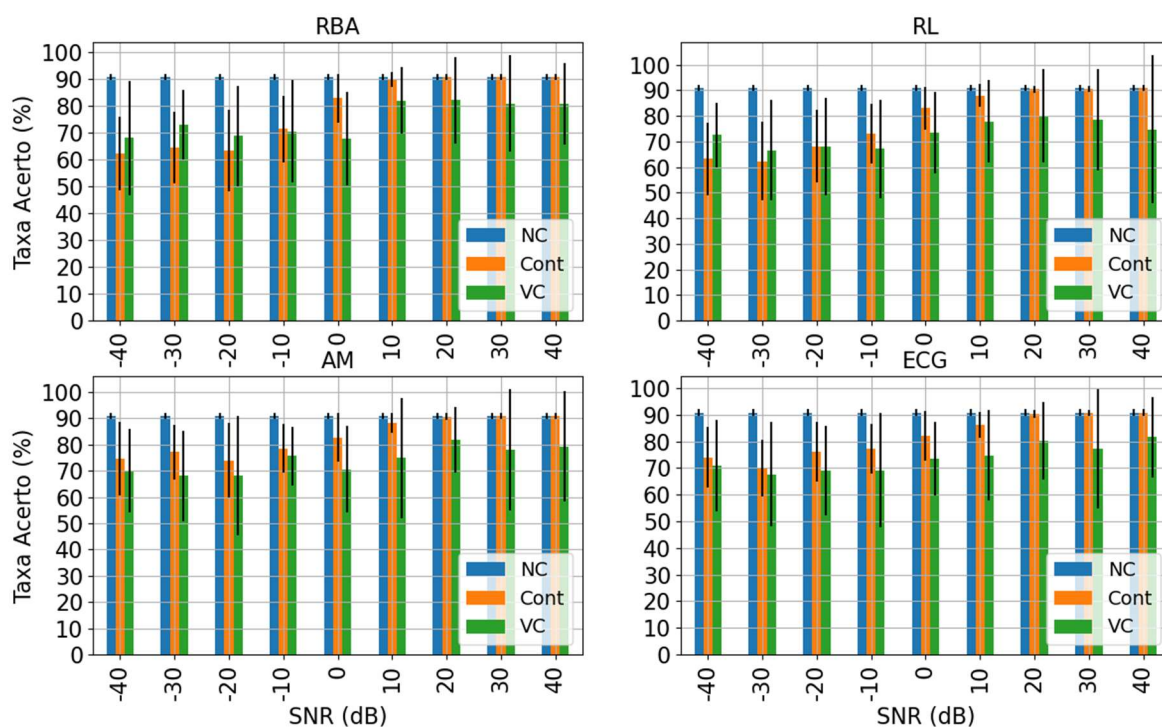
Fonte: Autor

Figura 41 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.



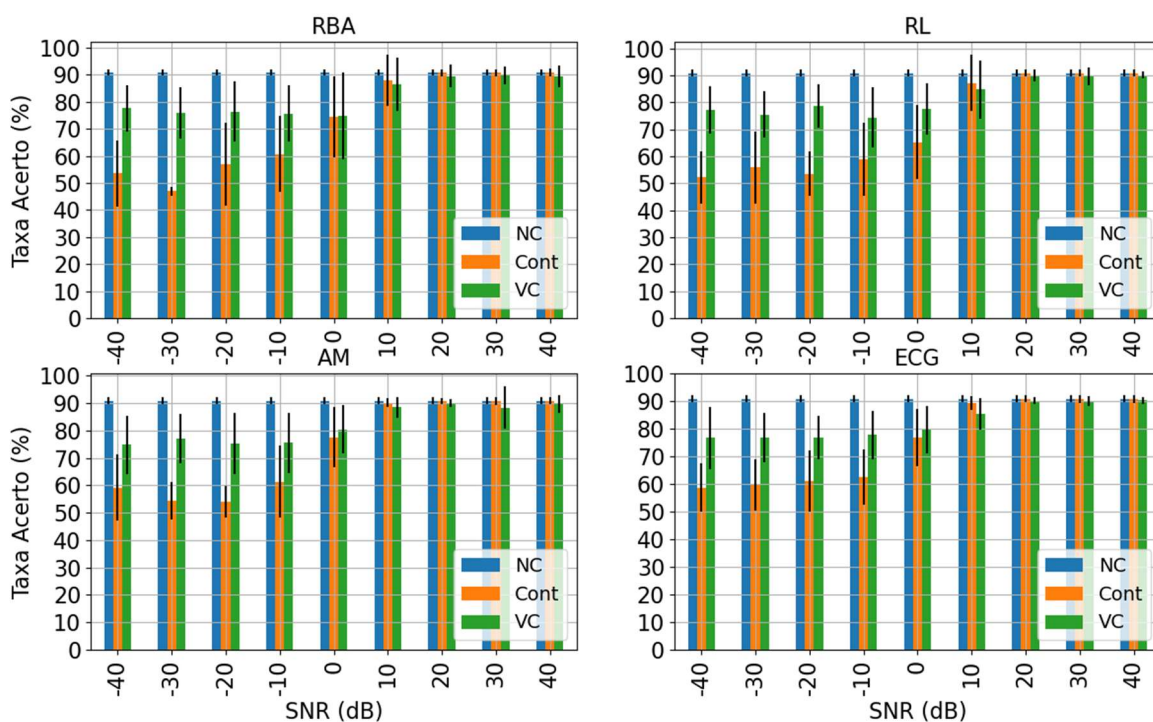
Fonte: Autor.

Figura 42 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.



Fonte: Autor.

Figura 43 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.



Fonte: Autor.

Tabela 23 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 50% de contaminação. Valores positivos indicam ganho de performance. Base IEE.

		Níveis SNR (dB)								
		-40	-30	-20	-10	0	10	20	30	40
Caso 1	RBA	13,19	9,70	4,95	7,85	-8,18	-2,74	-0,08	-0,18	-0,16
	RL	7,53	5,00	14,88	5,81	-1,73	-3,31	-0,92	-0,39	0,07
	AM	8,45	7,01	13,18	13,61	-0,28	-1,18	-0,37	-0,32	-0,15
	ECG	16,37	8,27	11,09	5,02	-0,92	-0,47	-0,35	-0,18	-0,21
Caso 2	RBA	22,08	27,22	20,08	15,56	0,66	-0,74	-0,29	-0,30	-0,41
	RL	20,71	26,87	22,38	12,17	5,46	-0,62	-0,70	0,04	-0,45
	AM	14,89	9,79	13,14	7,80	3,31	-0,33	-0,84	-0,54	-0,20
	ECG	7,62	9,78	8,34	7,65	4,25	-0,71	-0,79	-0,48	-0,28
Caso 3	RBA	12,50	23,21	21,09	10,66	-0,70	-0,57	-5,33	-7,78	-2,79
	RL	21,87	20,34	17,73	17,32	-2,32	-5,32	-5,71	-1,75	-5,82
	AM	13,17	8,19	15,18	3,88	-4,32	-4,03	-7,34	-6,45	-1,72
	ECG	9,63	16,92	11,34	6,69	-10,47	-8,57	-2,21	-5,76	-0,78
Caso 4	RBA	5,75	8,53	5,32	-0,89	-15,21	-7,69	-8,54	-9,96	-10,13
	RL	9,21	4,37	-0,18	-6,06	-9,61	-10,06	-10,39	-12,07	-15,99
	AM	-4,43	-8,99	-5,97	-2,87	-12,06	-13,23	-8,77	-12,71	-11,52
	ECG	-3,07	-2,37	-6,84	-8,22	-8,61	-11,53	-10,15	-13,61	-9,21
Caso 5	RBA	7,71	6,18	1,10	-0,87	-5,43	-2,77	-7,53	-9,94	-7,31
	RL	14,13	9,42	4,76	-1,37	-3,84	-7,31	-5,81	-3,37	-5,51
	AM	-6,63	-1,49	-2,03	-4,11	-7,78	-8,60	-4,59	-6,01	-7,88
	ECG	-2,49	0,86	2,30	1,99	-3,75	-4,31	-8,04	-7,56	-9,60
Caso 6	RBA	24,11	28,87	19,48	15,01	0,41	-1,38	-1,20	-1,11	-1,42
	RL	25,09	19,49	25,18	15,61	12,24	-2,39	-0,85	-1,23	-0,67
	AM	15,58	22,77	21,22	14,16	2,93	-1,70	-0,78	-2,34	-1,20
	ECG	17,97	17,22	15,56	15,21	2,90	-3,96	-0,64	-0,79	-0,42
Caso 7	RBA	9,09	4,55	10,47	9,88	-8,28	-0,46	-1,39	-4,11	-5,11
	RL	9,43	14,83	15,56	5,15	-7,71	-6,09	-5,05	-5,57	-5,87
	AM	4,95	5,77	0,01	1,93	-8,27	-5,52	-4,54	-3,73	-4,40
	ECG	1,77	6,09	1,80	1,00	-5,42	-7,65	-5,27	-3,47	-6,29

Para o caso 1, referente ao bloco de 8 canais, os resultados apresentados na Figura 40 e na Tabela 23 mostram um efeito positivo para todos contaminantes com $SNR \leq -10dB$, mostrando um efeito negativo para todas outras condições, sendo esse efeito maior entre 0 e 10dB e menor que 1% para os outros níveis SNR.

O caso 2, referente ao canal 9, cujos resultados apresentados na Figura 41 e Tabela 23 apresenta um efeito positivo para todos contaminantes com $SNR \leq 0dB$ e um efeito negativo menor que 1% para todas outras condições.

O caso 3, referente ao canal 10, cujos resultados estão apresentados no Apêndice na Figura 77 e na Tabela 23 apresenta um efeito positivo do sensor virtual para todos contaminantes com $SNR \leq -10\text{dB}$ e um efeito negativo para todas outras condições, que é acentuado, comparado ao caso 2, devido à ocorrência de falsos positivos do IAC.

O caso 4, referente ao canal 11, os resultados apresentados na Figura 42 e na Tabela 23 apresentam um efeito positivo do sensor virtual apenas para RBA e RL com $SNR \leq -20\text{dB}$ e um efeito negativo para todas as outras condições. Também se observa uma magnitude maior do efeito negativo como no caso 3, indicando a ocorrência de falsos positivos do IAC devido a contaminação prévia do sinal.

O caso 5, cujos resultados estão apresentados no Apêndice, na Figura 78 e na Tabela 23 mostra que existe um efeito positivo apenas para RBA e RL com $SNR \leq -20\text{dB}$, apresentando um efeito negativo para todas outras condições. Assim como no caso 4, apresenta uma magnitude maior no efeito negativo para $SNR \geq 10\text{dB}$, indicando também a ocorrência de falsos positivos do IAC devido a contaminações prévias.

O caso 6, referente aos canais 9 e 10, os resultados apresentados na Figura 43 e Tabela 23 mostram que existe um efeito positivo do sensor virtual para $SNR \leq 0\text{dB}$ considerando todos contaminantes e um efeito negativo para todas outras condições. O efeito negativo possui uma magnitude menor quando comparado ao caso 3, referente ao canal 10 individualmente, devido ao fato que o IAC precisa identificar a contaminação em ambos os canais simultaneamente para ativar o sensor virtual.

O caso 7, com os resultados apresentados no Apêndice na Figura 79, na Tabela 23, apresenta um efeito positivo para todos contaminantes para $SNR \leq -10\text{dB}$ e apresenta um efeito negativo, com uma maior magnitude em 0dB para todos contaminantes, apresentando também uma diferença para $SNR \geq 10\text{dB}$ que indica a presença de falsos positivos do IAC, também identificado nos casos 4 e 5.

5.4.5. Sinal com 100% de contaminação para base DB3

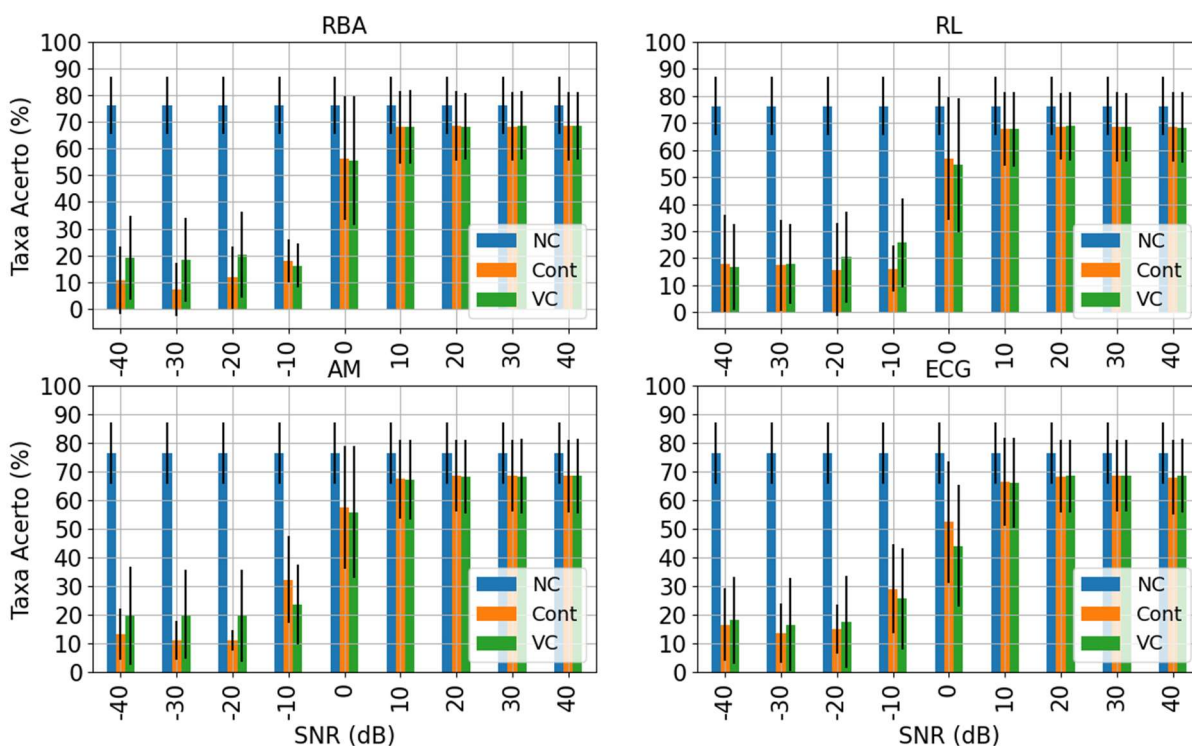
Inicialmente são apresentados os gráficos de efeito para os casos 1, 2, 4 e 6, da Figura 44 à Figura 47, enquanto as figuras para os outros casos estão apresentadas no Apêndice da Figura 64 a Figura 66. Na Tabela 24 são apresentadas todas as diferenças absolutas em % para o sensor virtual e o sinal contaminado, para melhor avaliar as condições em que ele causa um efeito positivo e onde pode causar um efeito negativo.

O que se observa para todos os casos é uma redução da taxa de acerto do sinal CONT comparado ao sinal NC para todos os níveis SNR, tendo maior magnitude para os casos em que mais canais são contaminados, sendo essa redução mais acentuada para RBA e RL, comparada à AM e ECG. A redução observada também é maior comparada ao sinal com 25% e 50% de contaminação para base DB3. Entre os casos, a maior redução é observada para o caso 1, onde 8 canais são contaminados e para o caso 6, onde os canais 9 e 10 são contaminados, a menor redução é para os casos 4 e 5, que envolvem os canais 11 e 12, respectivamente.

O caso 1, referente ao bloco de 8 canais, com os resultados apresentados na Figura 44 e na Tabela 24 apresenta um resultado positivo para RBA, AM e ECG para $SNR \leq -20\text{dB}$ e para RL com SNR entre -30 e -10dB . O efeito negativo do sensor virtual é observado para praticamente todas outras condições, com uma magnitude maior para AM e ECG em -10 e 0dB .

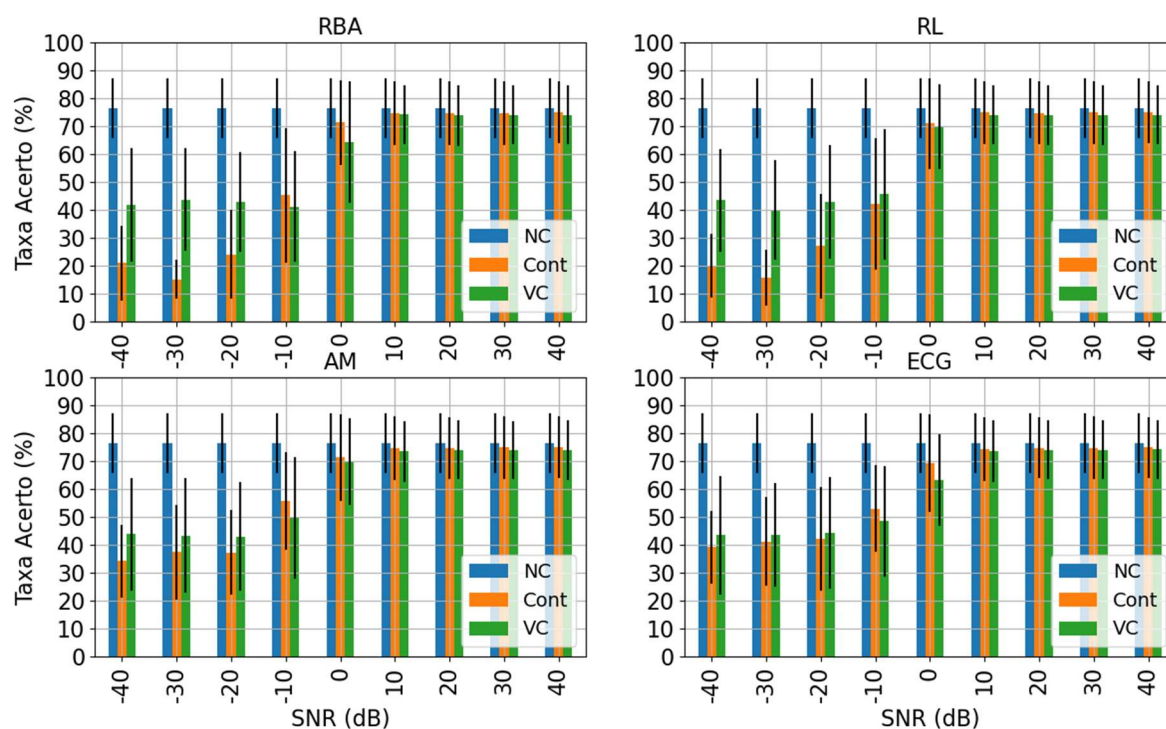
Para o caso 2, referente ao canal 9, de acordo com a Figura 45 e a Tabela 24, se observa um efeito positivo do sensor virtual para $SNR \leq -20\text{dB}$ para todos contaminantes e para RL com $SNR = -10\text{dB}$. O efeito negativo possui uma magnitude maior para SNR entre -10dB e 0dB , principalmente para RBA, AM e ECG e para todas outras condições o efeito negativo é do máximo 1%.

Figura 44 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.



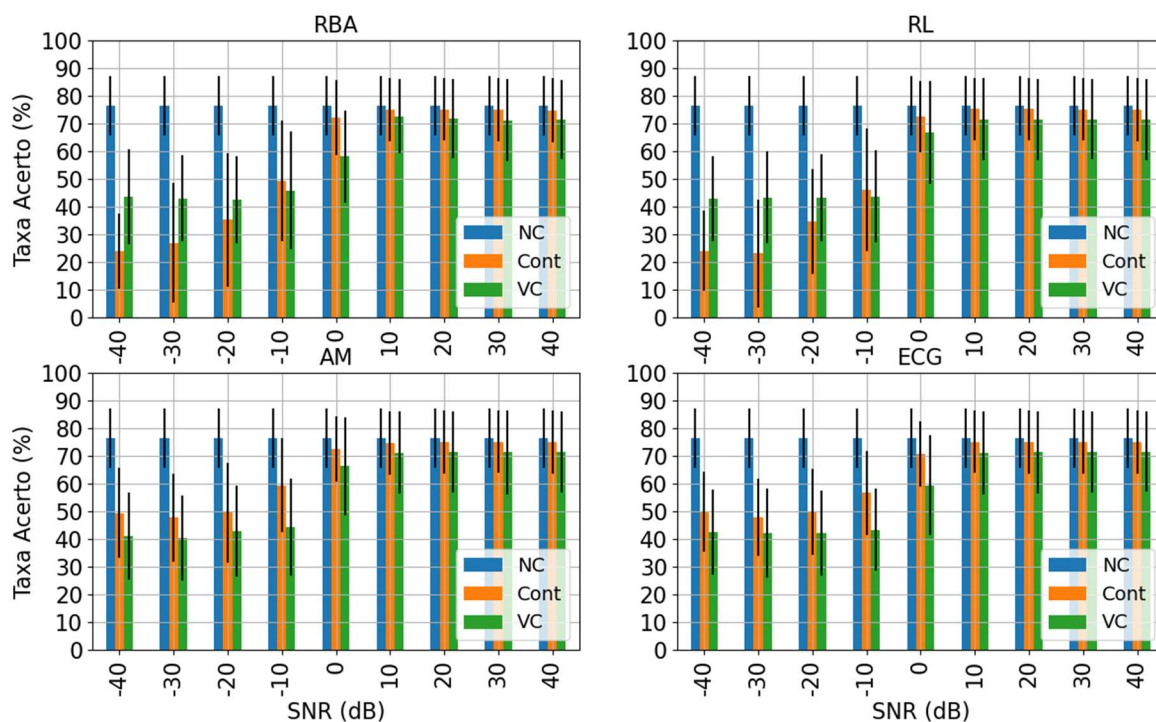
Fonte: Autor.

Figura 45 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.



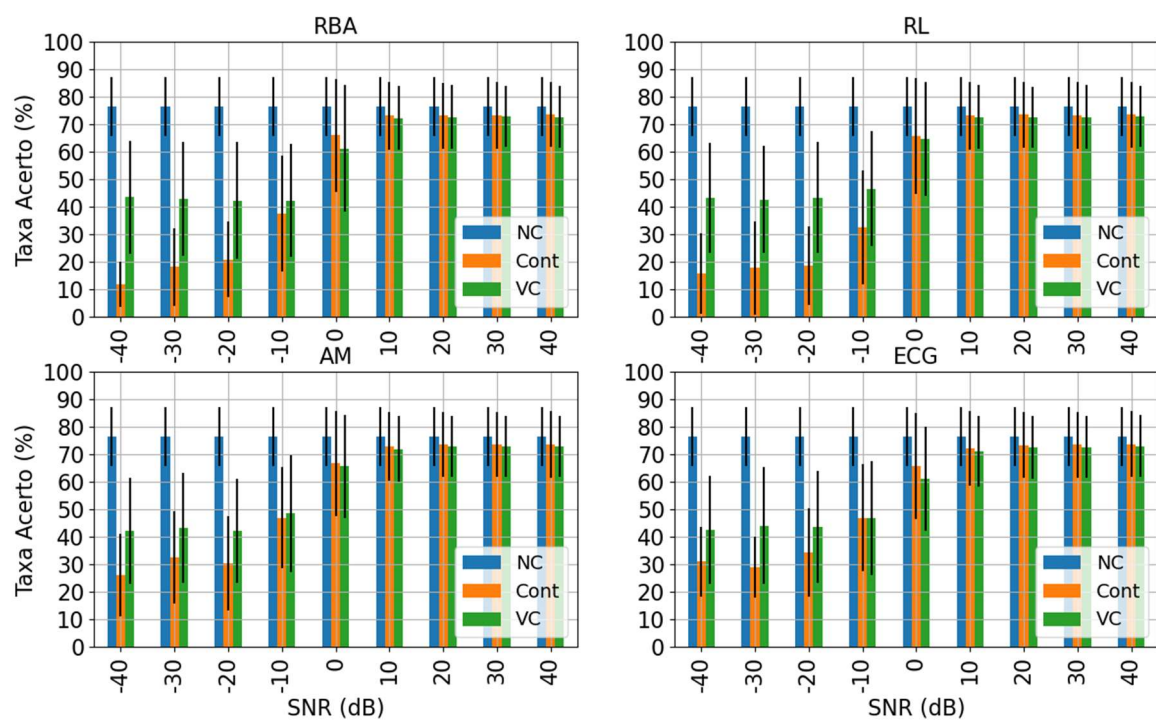
Fonte: Autor.

Figura 46 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.



Fonte: Autor.

Figura 47 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.



Fonte: Autor.

Tabela 24 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 100% de contaminação. Valores positivos indicam ganho de performance. Base DB3.

		Níveis SNR (dB)								
		-40	-30	-20	-10	0	10	20	30	40
Caso 1	RBA	8,34	11,27	8,67	-1,71	-0,94	0,15	-0,24	0,33	0,03
	RL	-1,19	0,64	4,77	9,47	-2,48	-0,08	0,10	-0,04	-0,25
	AM	6,42	9,10	8,56	-8,61	-1,65	-0,31	-0,36	-0,29	0,04
	ECG	1,55	2,83	2,35	-3,48	-8,43	-0,33	0,08	-0,01	0,48
Caso 2	RBA	20,82	28,60	18,92	-4,06	-6,89	-0,55	-0,88	-0,67	-1,00
	RL	23,35	24,29	16,01	3,42	-1,06	-0,95	-0,71	-0,89	-0,91
	AM	9,78	5,93	5,66	-5,97	-1,50	-1,08	-0,64	-0,81	-1,05
	ECG	4,33	2,46	2,11	-4,55	-6,29	-0,86	-0,74	-0,70	-0,79
Caso 3	RBA	30,67	29,00	15,37	-1,95	-6,50	-1,27	-1,41	-1,56	-1,21
	RL	30,56	23,11	15,89	2,88	-3,96	-1,44	-1,45	-1,63	-1,22
	AM	4,22	3,11	2,05	-6,79	-3,81	-1,84	-1,18	-1,31	-1,69
	ECG	0,96	0,27	-2,49	-8,57	-6,37	-2,16	-1,63	-1,49	-1,63
Caso 4	RBA	19,49	16,17	7,21	-3,44	-14,02	-2,33	-3,31	-3,80	-3,27
	RL	18,69	20,28	8,70	-2,30	-5,76	-3,71	-3,76	-3,65	-3,52
	AM	-8,45	-7,36	-6,69	-15,31	-6,24	-3,52	-3,69	-3,86	-3,75
	ECG	-7,24	-5,61	-7,61	-13,39	-11,13	-4,18	-3,71	-3,49	-3,62
Caso 5	RBA	16,27	15,82	16,43	-1,56	-14,59	-0,48	-2,47	-2,77	-2,74
	RL	14,67	8,47	7,97	-2,31	-4,58	-2,97	-2,32	-2,57	-2,83
	AM	-7,67	-9,89	-9,15	-8,07	-6,62	-3,75	-3,16	-2,50	-2,41
	ECG	-10,81	-7,96	-7,29	-9,09	-10,24	-3,93	-2,99	-3,01	-2,58
Caso 6	RBA	31,73	24,75	21,37	4,84	-4,76	-0,84	-0,52	-0,48	-0,85
	RL	27,59	24,95	24,70	13,93	-1,00	-0,61	-0,83	-0,66	-0,53
	AM	16,06	10,71	11,79	1,55	-1,13	-0,82	-0,70	-0,77	-0,74
	ECG	11,52	15,06	9,35	0,03	-4,60	-0,95	-0,85	-0,86	-0,74
Caso 7	RBA	19,57	11,98	10,95	0,31	-12,06	-3,42	-4,39	-4,85	-5,30
	RL	19,10	24,26	13,07	1,47	-5,48	-5,29	-4,80	-4,79	-4,98
	AM	3,68	2,60	-0,18	-7,66	-6,04	-5,74	-5,19	-4,71	-5,15
	ECG	-2,84	-1,51	-1,24	-4,39	-10,21	-5,31	-4,59	-4,83	-5,01

O caso 3, referente ao canal 10, cujo gráfico de resultados está no Apêndice, na Figura 64 e na Tabela 24 apresenta um efeito positivo para RL com $SNR \leq -10dB$, RBA e AM com $SNR \leq -20dB$ e ECG para $SNR \leq -30dB$, sendo o efeito positivo de AM e ECG em menor magnitude em relação à RBA e RL. Para todas outras condições o efeito do sensor virtual é negativo, principalmente entre $-10dB$ e $0dB$.

O caso 4, referente ao canal 11, com resultados apresentado na Figura 46 e na Tabela 24 apresenta um efeito positivo apenas para RBA e RL com $SNR \leq -20dB$ e negativo para todas

outras condições, principalmente para -10dB. As maiores magnitudes de efeito negativo são observadas para AM e ECG.

O caso 5, referente ao canal 12, cujo gráfico está apresentado no Apêndice, na Figura 65 e apresenta efeito positivo apenas para RBA e RL com $SNR \leq -20dB$ e negativo para todas outras condições, principalmente para -10dB, de acordo com a Tabela 24. As maiores magnitudes de efeito negativo são observadas para AM e ECG.

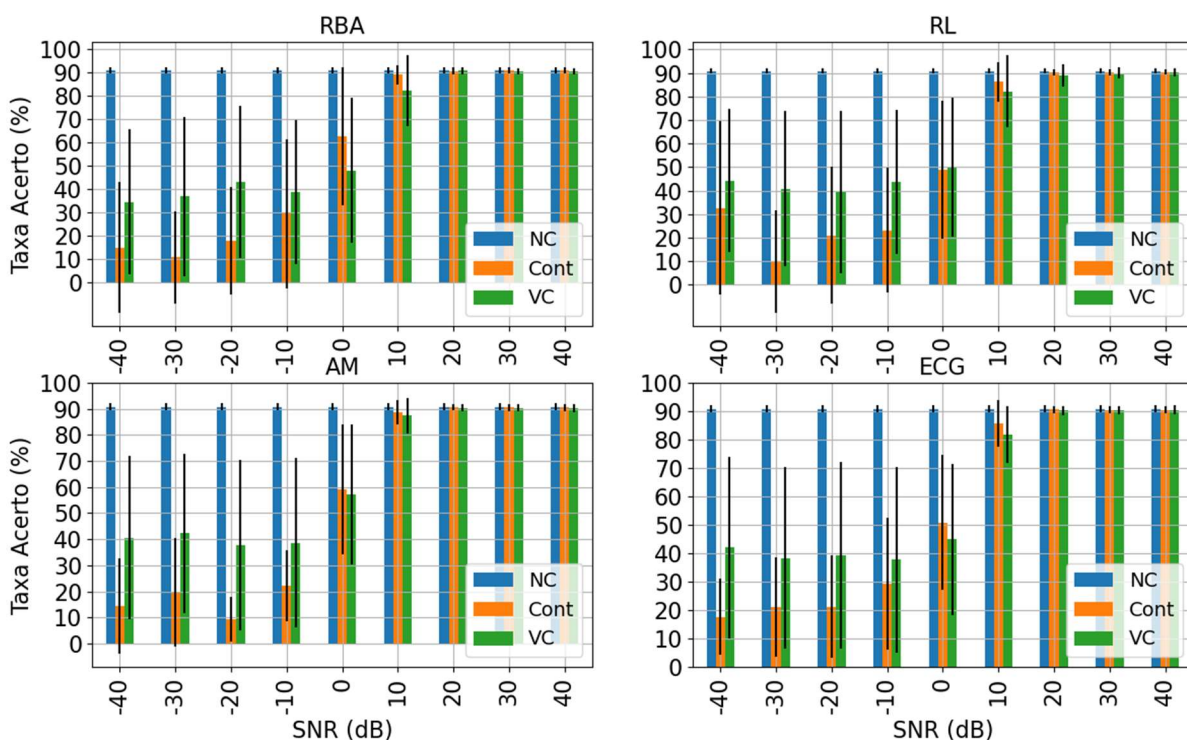
O caso 6, referente aos canais 9 e 10, com os resultados apresentados na Figura 47 apresenta um efeito positivo do sensor virtual para todos contaminantes com $SNR \leq -10dB$, com uma maior magnitude deste efeito para RBA e RL, e um efeito negativo principalmente em 0dB, sendo esse efeito menor que 1% nos outros níveis, de acordo com a Tabela 24.

O caso 7, referente aos canais 11 e 12, cujo gráfico de resultados está no Apêndice, Figura 66 apresenta um efeito positivo do sensor virtual para RBA e RL com $SNR \leq -10dB$ e em menor magnitude para AM com $SNR \leq -30dB$, de acordo com a Tabela 24. Para ECG e todas outras condições dos outros contaminantes é constatado efeito negativo do sensor virtual, com maior magnitude em 0dB.

5.4.6. Sinal com 100% de contaminação para base IEE

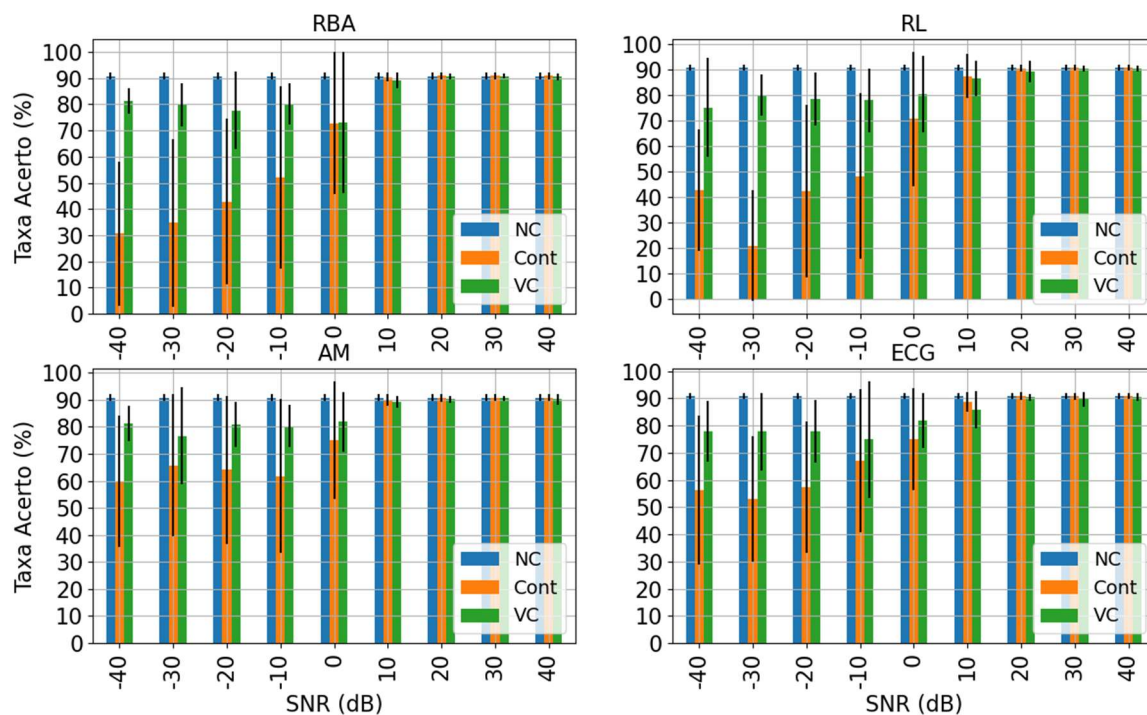
Inicialmente são apresentados os gráficos de efeito para os casos 1, 2, 4 e 6, da Figura 48 à Figura 51, enquanto as figuras para os outros casos estão apresentadas no Apêndice da Figura 80 a Figura 82. Na Tabela 25 são apresentadas todas as diferenças absolutas em % para o sensor virtual e o sinal contaminado, para melhor avaliar as condições em que ele causa um efeito positivo e onde pode causar um efeito negativo.

Figura 48 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.



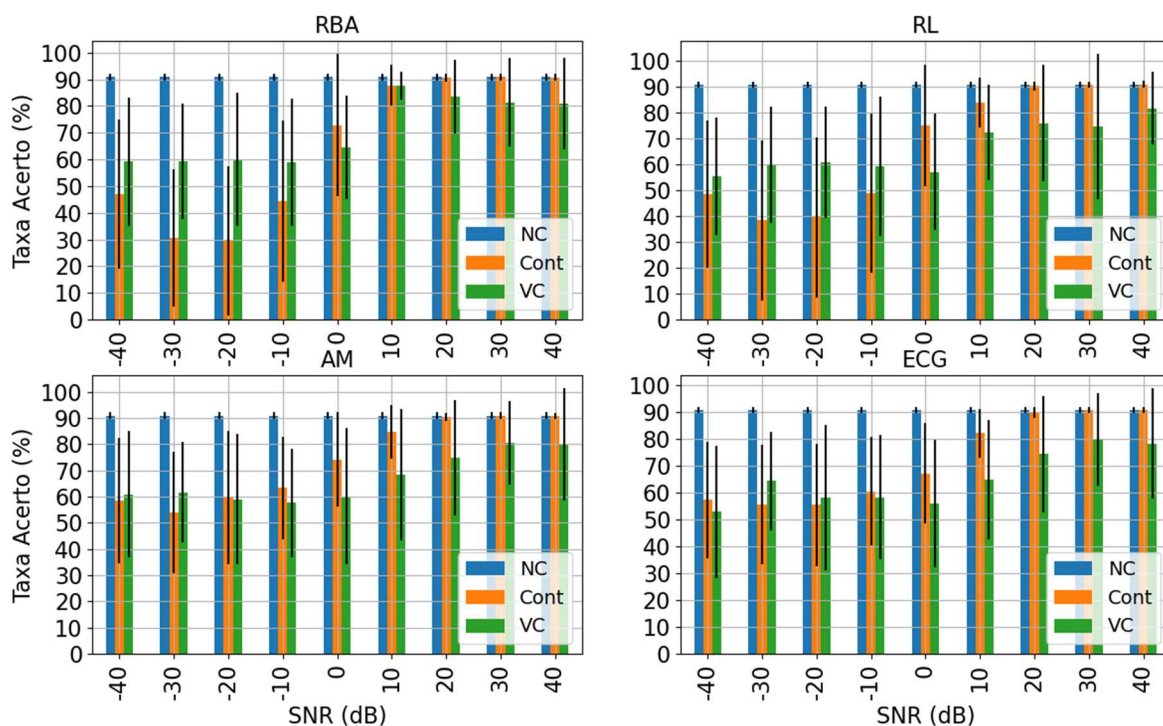
Fonte: Autor.

Figura 49 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.



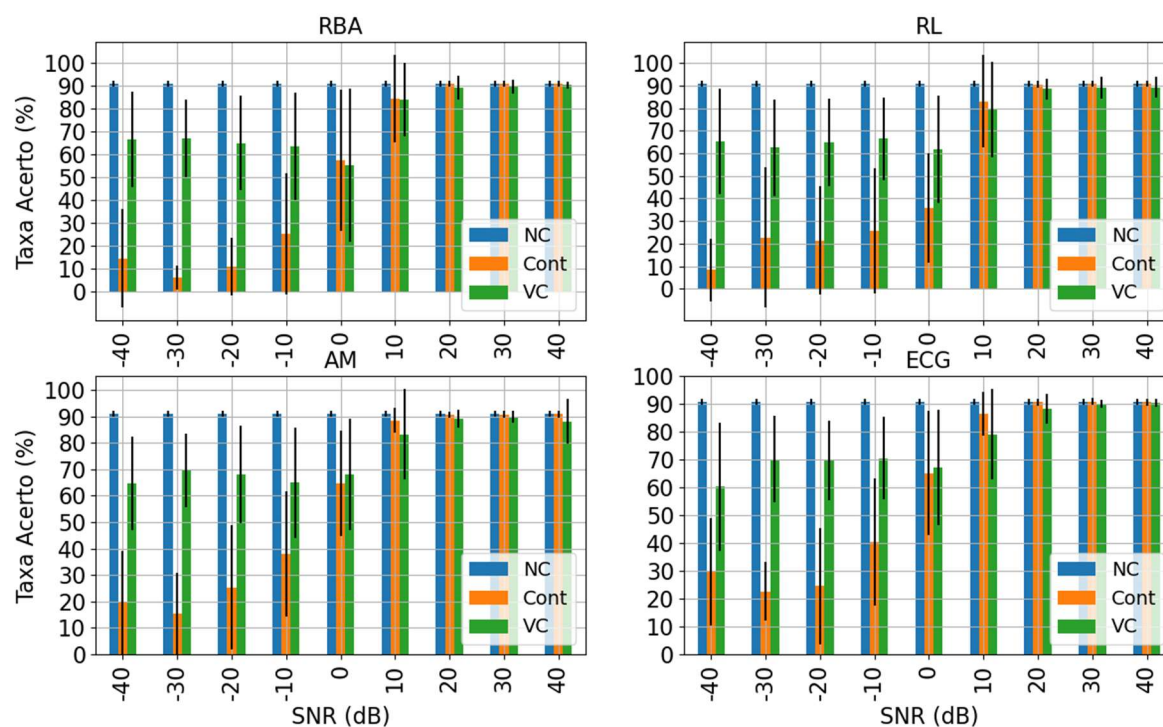
Fonte: Autor.

Figura 50 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.



Fonte: Autor.

Figura 51 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.



Fonte: Autor.

Tabela 25 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 100% de contaminação. Valores positivos indicam ganho de performance. Base IEE.

		Níveis SNR (dB)								
		-40	-30	-20	-10	0	10	20	30	40
Caso 1	RBA	19,68	26,05	25,18	9,29	-14,53	-6,63	0,02	-0,21	-0,25
	RL	11,62	31,06	18,40	20,63	1,19	-3,99	-1,50	-0,40	-0,24
	AM	26,25	22,53	28,16	16,39	-1,85	-1,35	-0,38	-0,11	-0,19
	ECG	24,33	17,12	18,13	8,60	-5,88	-3,94	-0,47	-0,05	-0,12
Caso 2	RBA	50,70	44,98	34,85	27,97	0,28	-1,33	-0,28	-0,12	-0,33
	RL	32,60	59,32	36,36	29,80	9,74	-0,76	-1,34	-0,36	-0,36
	AM	21,37	10,86	16,77	18,52	6,79	-0,78	-0,44	-0,26	-0,61
	ECG	21,60	24,74	20,58	7,91	6,89	-3,00	-0,56	-1,12	-0,41
Caso 3	RBA	49,84	41,69	50,78	35,91	8,37	-0,08	-1,14	-5,70	-3,83
	RL	54,32	49,85	49,00	46,95	9,19	-6,29	-4,95	-5,52	-6,15
	AM	38,89	40,38	34,24	14,35	-9,82	-1,72	-3,45	-1,76	-5,04
	ECG	27,68	23,96	23,62	17,44	-5,01	-8,35	-3,83	-1,22	-1,44
Caso 4	RBA	12,07	28,68	30,80	14,76	-8,22	-0,06	-7,11	-9,39	-9,92
	RL	6,99	21,57	21,31	10,49	-17,98	-11,32	-14,29	-16,07	-9,18
	AM	2,44	7,72	-0,54	-5,59	-14,03	-16,34	-15,49	-10,48	-10,87
	ECG	-4,40	8,70	2,70	-2,32	-11,20	-17,24	-15,57	-10,95	-12,53
Caso 5	RBA	20,18	20,13	29,52	16,05	-3,51	-4,94	-7,86	-5,75	-10,96
	RL	25,50	29,26	24,46	12,09	5,48	-6,49	-8,38	-2,83	-6,53
	AM	-2,70	1,93	4,26	-1,56	-7,83	-4,13	-4,59	-7,90	-10,94
	ECG	5,38	10,04	8,56	-0,74	-1,26	-10,61	-4,72	-5,32	-7,05
Caso 6	RBA	52,23	60,86	54,14	38,41	-2,18	-0,49	-1,76	-1,08	-0,49
	RL	56,81	39,66	43,24	40,64	25,99	-3,91	-2,07	-1,81	-1,63
	AM	44,96	53,91	42,70	26,84	3,52	-5,26	-1,54	-0,94	-2,71
	ECG	30,76	47,56	45,08	30,23	2,07	-7,29	-2,32	-0,63	-0,34
Caso 7	RBA	31,70	25,90	25,44	16,05	-11,70	4,48	1,15	-4,27	-5,48
	RL	34,61	22,76	35,13	16,32	-13,55	1,91	-3,86	-5,92	-4,57
	AM	14,41	18,49	15,21	5,85	-8,17	-0,04	-4,76	-6,37	-4,79
	ECG	6,87	0,88	13,62	10,37	-8,39	-11,38	-4,60	-4,38	-4,90

Para todos os casos se observa uma redução da taxa de acerto do sinal CONT em relação ao sinal NC para todos os casos e contaminantes com $SNR \leq 10dB$, também observada para o caso 7 com $SNR = 20dB$, sendo essa redução mais acentuada para RBA e RL. Entre os casos, a maior redução é observada para o caso 1, onde 8 canais são contaminados e para o caso 6, onde os canais 9 e 10 são contaminados, a menor redução é para os casos 4 e 5, que envolvem os canais 11 e 12, respectivamente.

O caso 1, referente ao bloco de 8 canais, com os resultados apresentados na Figura 48 e Tabela 25 mostram um efeito positivo do sensor virtual para $SNR \leq -10dB$ para todos

contaminantes e um efeito negativo para todas outras condições, sendo a magnitude desse efeito maior para $SNR = 0dB$, principalmente para RBA e ECG.

Para o caso 2, referente ao canal 9, são apresentados os resultados na Figura 49 e na Tabela 25, indicando um efeito positivo para $SNR \leq 0dB$, considerando todos contaminantes. Para $SNR \geq 10dB$ há um efeito negativo que possui magnitude máxima de 3% para ECG em 10dB.

O caso 3, referente ao canal 10, cujo resultados estão apresentados no Apêndice, na Figura 80, indica um efeito positivo para RBA e RL com $SNR \leq 0dB$ e para AM e ECG com $SNR \leq -10dB$, de acordo com a Tabela 25. Para todas outras condições existe um efeito negativo, em uma magnitude maior que o caso 2, indicando haver ocorrência de falsos positivos. Esses falsos positivos são mitigados por RBA em 10 e 20dB, indicando haver uma interação com o contaminante prévio com a contaminação artificial nesses níveis, necessitando mais estudos para compreender melhor essa interação.

O caso 4, referente ao canal 11, tem os resultados apresentados na Figura 50 e que de acordo com a Tabela 25 apresenta um efeito positivo do sensor virtual para RBA e RL com $SNR \leq -10dB$, para AM com $SNR \leq -20dB$ e para ECG com SNR entre $-30dB$ e $-20dB$. Em todas outras condições apresenta um efeito negativo. Este caso apresenta a maior magnitude de efeitos negativos para $SNR \geq 10dB$, indicando contaminação prévia.

O caso 5, referente ao canal 12, cujos resultados estão apresentados no Apêndice, na Figura 81, indica um efeito positivo para RBA com $SNR \leq -10dB$, pra RL com $SNR \leq 0dB$, AM entre -30 e $-20dB$ e ECG para $SNR \leq -20dB$, de acordo com a Tabela 25. Apresenta efeito negativo em todas outras condições, com magnitudes menores apenas que o caso 4, mostrando haver também contaminação prévia do sinal, causando falsos positivos do IAC.

Para o caso 6, referente aos canais 9 e 10, todos contaminantes apresentam efeito positivo para todos contaminantes para $SNR \leq 0dB$, com exceção de RBA que apresenta um efeito

negativo para $SNR = 0dB$, de acordo com a Tabela 25. Em todas outras condições há um efeito negativo do sensor virtual, porém em uma magnitude menor que o caso 3, que envolve o canal 10, devido ao fato de que os dois canais precisam estar contaminados ao mesmo tempo para ativação do sensor virtual.

O caso 7, referente aos canais 11 e 12, cujo gráfico de resultados está apresentado no Apêndice, na Figura 82, apresenta um efeito positivo para todos contaminantes com $SNR \leq -10dB$, e para RBA em 10dB e 20dB e RL para 10dB de acordo com a Tabela 25. Para as outras condições apresenta efeito negativo, mas com uma magnitude menor que o caso 4, que também envolve o canal 11, devido ao fato que ambos os canais precisam apresentar contaminação para ativação do sensor virtual.

5.5. Discussões e considerações finais

Inicialmente considerando a porcentagem de sinal contaminado, pode-se observar pelos resultados que ao aumentar os trechos de contaminação, também se aumenta a degradação da taxa de acerto do ELM para ambas as bases. O ganho do sensor virtual é observado principalmente para os menores níveis de SNR, abaixo de $-10dB$, onde as taxas de acerto são mais reduzidas, devido a uma maior descaracterização do sinal e para SNR maiores que $10dB$ o que se observa são efeitos negativos do sensor virtual devido a ocorrências de falsos negativos.

Considerando a base DB3, dos sujeitos amputados, para o caso 1, as maiores taxas de recuperação são observadas para RBA e RL e AM com 100% do sinal contaminado, com recuperação máxima de 11,27% com RBA em $-30dB$, porém a taxa de acerto do sinal contaminado é menor que 10%, com o sensor virtual recuperando a taxa para um valor abaixo de 20%, situação que se observa para os outros níveis SNR. Para 25% e 50% as taxas de recuperação são ainda menores. Portanto é necessário avaliar se o custo computacional de

realizar essa regressão para todos os contaminantes é interessante para recuperar a taxa de acerto para cerca de 20% no máximo. Falsos positivos do IAC causam um efeito maior entre -10dB e 0dB, mostrando que é necessária uma calibração do IAC, o que já foi demonstrado ser possível em (Machado, Machado e Balbinot, 2021).

Já considerando a base IEE, se observa um melhor desempenho do sensor virtual, comparado à base DB3, recuperando 31,06% pra RL em 30dB com 100% do sinal contaminado, levando a taxa de acerto de 11,51% para cerca de 42,57% e apresentado taxas de recuperação melhor para 25% e 50%, comparado à base DB3. Essa diferença para a base DB3 pode ser explicada principalmente pela representatividade no grupo de treinamento do sensor virtual, que utilizou apenas sujeitos não amputados. Falsos positivos influenciam negativamente mais entre 0dB e 10dB, sendo necessária a calibração do IAC.

O que se observa no caso 2, na base DB3 é que as maiores taxas de recuperação se apresentam para RBA e RL, com 100% do sinal contaminado. Com 25% e 50% do sinal contaminado se observa um máximo de 4,81% de recuperação para RL em -30dB e 13,00% para RBA em -30dB, respectivamente. Existe efeito negativo em praticamente todos os níveis SNR para AM e ECG, tanto para 25% e 50% do sinal contaminado.

Esses resultados, para o caso 2 na base DB3, demonstram ser necessário fazer uma melhor avaliação em estudos futuros para verificar se existe algum real benefício em acionar o sensor virtual para contaminações de até 5s com RBA e RL. Para AM e ECG pode-se concluir, para o grupo de indivíduos testados, que o sensor virtual é inefetivo com 25% e 50% do sinal contaminado.

Para 100% de contaminação, para o maior ganho, com RBA em -30dB o sensor virtual recupera a taxa de acerto de 15,07% para 43,67%, apresentando um comportamento semelhante para RL. Com ECG e AM, apesar de haver um efeito positivo entre -40dB e -20dB, ele é menor, comparado aos ganhos com RBA e RL. Para o caso 2, assim como o caso

1, é necessária uma calibração do IAC, apresentando os efeitos negativos maiores em -10dB e 0dB.

Considerando o caso 2 para a base IEE, o que se observa é um efeito positivo do sensor virtual para 25%, 50% e 100% do sinal contaminado em praticamente todas as condições e quando há um efeito negativo, como por exemplo para ECG em 10dB, é de 3%, efeito esse que ainda pode ser corrigido com a correta calibração do IAC. Para 100% o modelo de sensor virtual recupera uma taxa de acerto de 20,53% com o sinal contaminado, para 79,85% para contaminação por RL em -30dB. Esse desempenho superior ao caso 2 da base DB3 é explicado principalmente pela caracterização mais próxima do sensor original a partir do sensor virtual.

Para o caso 3 para ambas as bases, as mesmas conclusões obtidas com caso 2 podem ser assumidas, tanto para 25%, 50% e 100% do sinal contaminado. O que se observa na base DB3, de diferente entre o caso 2 e 3, é uma melhor caracterização, em termos de magnitude da taxa de acerto, do sensor virtual para o caso 3. Para a base IEE já ocorre o inverso, o caso 2 é mais bem caracterizado pelo sensor virtual. Essa diferença entre amputados e não amputados deve ser mais investigada de forma individual entre os indivíduos amputados, pois existem diferentes níveis de amputação entre os indivíduos, e o canais 9 e 10, relativos aos casos 2 e 3, enquanto para os não amputados é necessário aumentar o número de indivíduos na base de dados para obter conclusões mais generalizadas para a população.

O caso 4 e o caso 5, possuem comportamento similar para base DB3, havendo um efeito positivo apenas em RBA e RL, sendo esse efeito sempre menor que 1% com 25% e menor que 7,5% para 50% do sinal em ambos os casos. Para AM e ECG o efeito é sempre negativo, tanto para 25% quanto para 50% de contaminação. Portanto em trechos com menos de 5s de contaminação é necessário avaliar se os ganhos para RBA e RL compensam o uso do sensor virtual e para AM e ECG não há nenhum efeito positivo no uso. Com 100% de contaminação,

existe um efeito positivo apenas para RBA e RL, para ambos os casos com $SNR \leq -20dB$, de 20,19% no máximo e efeitos negativos para todas outras condições. Portanto, pelo exposto, o uso do sensor virtual nos casos 4 e 5 se justificaria apenas para RBA e RL, em trechos contaminados de 10s ou mais, porém devendo haver uma calibração do IAC, principalmente para 0dB, onde ocorrem os maiores efeitos negativos devido a falsos positivos.

Na base IEE os casos 4 e 5 também apresentam comportamento similar, com um efeito negativo para todas as condições com 25% do sinal contaminado e para 50% apresenta efeito positivo apenas para RBA e RL com $SNR \leq -20dB$. Já para 100% existe um efeito positivo máximo de 30,80% para RBA, 21,57% para RL e para AM e ECG apresenta efeitos positivos menores que 10%. Esse é o caso que apresenta os maiores valores de efeitos negativos com SNR maiores que 10dB, devido principalmente a ocorrência de falsos positivos do IAC. O uso do sensor virtual para RBA e RL em trechos contaminados maiores que 10s pode trazer vantagens ao sistema como um todo, enquanto o uso em AM e ECG pode não ser vantajoso, necessitando mais estudos com um número maior de indivíduos.

Os efeitos positivos nos casos 4 e 5 são menores que os efeitos obtidos pelos casos 2 e 3 e isso ocorre pelo fato de que o ELM é mais afetado nos casos 2 e 3, referentes aos canais 9 e 10, comparado aos casos 4 e 5, referente aos canais 11 e 12. Isso se dá, principalmente pelos movimentos utilizados, que exigem mais dos músculos do antebraço, onde estão localizados os canais 9 e 10, apresentando um sinal mais representativo dos movimentos do ponto de vista do ELM, porém não se pode descartar a diferença fisiológica dos músculos do braço e antebraço. Isso também leva a uma melhor caracterização do sinal pelo sensor virtual. Esse tipo de dificuldade na caracterização dos canais 11 e 12 também foi observado em (Moura, de e Balbinot, 2018).

O caso 6, referente à contaminação simultânea dos canais 9 e 10, possui comportamento semelhante para base DB3 e base IEE, apresentando efeito positivo do sensor virtual para

todos contaminantes para $SNR \leq -10dB$, com 25%, 50% e 100% do sinal contaminado e apresentando efeito negativo, com maior magnitude em 0dB para a base DB3 e 10dB para IEE, devido a ocorrência de falsos positivos do IAC. O efeito positivo é maior, comparado aos casos 2 e 3, principalmente porque a contaminação simultânea afeta mais a saída do ELM, do que com os canais contaminados individualmente. A taxa de acerto do sensor virtual é menor que o caso 3, porém no mesmo patamar que o caso 2 e isso mostra um indício de que a adição dos canais 11 e 12 no treinamento para o caso 6 não melhora a caracterização do sinal, porém é necessário realizar mais estudos, com diferentes tipos de entrada para a RNN-LSTM do sensor virtual para o caso 6. Os efeitos positivos são maiores para a base IEE, devido principalmente a representatividade do grupo de treinamento do sensor virtual.

O caso 7, referente a contaminação simultânea dos canais 11 e 12, não apresenta nenhum efeito positivo para 25% de contaminação para base DB3. Para 50% de contaminação o efeito positivo máximo é de 8,28% em RL e apresenta efeito negativo em todas as condições para AM e ECG, tanto com 25% e 50%. Com 100% de contaminação existe efeito positivo máximo de 24,26% apenas para RBA e RL com $SNR \leq -10dB$ e apresenta também efeito positivo para AM e ECG, porém ele é no máximo de 3,68%. Os maiores efeitos negativos são observados para -10dB e 0dB. Assim como para os casos 4 e 5, referentes aos canais 11 e 12, o uso do sensor virtual nesse caso seria recomendado apenas para RBA e RL, com trechos contaminados maiores que 10s, considerando apenas esse conjunto de indivíduos. Se observou também que a adição dos canais 9 e 10 para estimação do sensor virtual não mostrou nenhum ganho comparado aos casos 4 e 5.

Para a base IEE, o caso 7 com 25% apresenta um efeito positivo máximo de 3,84% para RBA e efeito negativo na maior parte das outras condições. Com 50% de contaminação já existe efeito positivo para todas as condições com $SNR \leq -10dB$, aumentando o efeito positivo para 100% de contaminação. Esse desempenho, melhor em termos de efeitos

positivos, comparado com a base DB3, se deve principalmente pela melhor caracterização do sensor virtual devido a melhor representatividade do grupo de treinamento. Os efeitos negativos se devem à falsos positivos do IAC, indicando uma necessidade de calibração.

Os resultados obtidos para os casos 3 e 4, na base DB3, referente aos canais 11 e 12 apresentaram efeitos negativos que indicavam a ocorrência de falsos positivos, principalmente para o canal 11. O IAC identificou nesses 2 canais uma taxa maior de artefato de movimento no sinal de sEMG não contaminado que nos outros canais, de acordo com a Tabela 26. Uma investigação se essa presença de AM, que ocorre principalmente no *bíceps* e *tríceps*, é pela natureza dos movimentos ou pela fisiologia dos músculos, que são maiores e possuem mais fibras que os músculos utilizados no antebraço.

Tabela 26 – Resultado da identificação de contaminantes para o sinal não contaminado, em (%) para canais críticos DB3.


	sEMG	RBA	RL	AM	ECG
Canal 10	96,87	0	0	3,13	0
Canal 11	89,76	0	0	10,24	0
Canal 12	92,37	0	0	7,63	0

Apesar dos resultados serem apresentados de forma global, é necessário destacar que o comportamento inter-sujeitos pode ter grande variabilidade, principalmente para os sujeitos com amputação, onde os graus de amputação diferem, tempo de amputação, motivo da amputação, experiência prévia com prótese mioelétricas (Atzori *et al.*, 2014). Como exemplo dessa variabilidade, é apresentado na Figura 52 os resultados para cada sujeito, considerando o caso 4 da base DB3 em RBA com 0dB e 100% do sinal contaminado. Para esse caso, efeito negativo de 14,06% é observada, de acordo com a Tabela 24.

Se observa que o problema de calibração do IAC, ou a caracterização do sensor virtual, é falha apenas para os sujeitos 3, 4 e 10, influenciando na redução da taxa de acerto média. Portanto, apesar deste trabalho ter tido uma perspectiva global do problema, é necessário se

aprofundar na questão de cada sujeito, canal e movimentos e para avaliar as características de cada sujeito, seriam necessárias mais horas de aquisição de dados para cada indivíduo.

Figura 52 – Médias para NC, CONT e VC, considerando a base DB3, caso 4, RBA em 0dB para cada sujeito.



Na base IEE também se encontrou efeitos negativos devido a falsos positivos, sendo esse efeito maior nos casos 3 e 4, referentes aos canais 11 e 12. Ao analisar os resultados do IAC no sinal não contaminado, se observou, de acordo com a Tabela 27, que há contaminação por RL e AM nos canais 10, 11 e 12.

Tabela 27 – Resultado da identificação de contaminantes no sinal não contaminado, em (%) para canais críticos IEE.

	sEMG	RBA	RL	AM	ECG
Canal 10	85,19	0	6,56	8,24	0,01
Canal 11	73,16	0,64	12,44	13,63	0,13
Canal 12	62,29	0,98	35,11	0,92	0,71

Ao realizar uma FFT nos sinais, de fato se identificou que principalmente a componente de 60Hz se destacava das demais componentes, mostrando que o falso positivo, na realidade

era a identificação de contaminação ocorrida durante a aquisição do sinal. O fato do canal 11 possuir o maior índice de contaminação por AM está coerente também com os resultados obtidos na base DB3, de acordo com a Tabela 26, indicando que de fato o sinal proveniente do *biceps* gera mais artefato de movimento para os movimentos avaliados, nos dois grupos de indivíduos avaliados.

O fato de o ELM ter um desempenho com classificações acima de 90% para a base IEE, mesmo com uma alta contaminação, principalmente nos canais 11 e 12, é devido ao fato de que tanto o grupo de treinamento como de teste está com contaminação presente, o que leva ao questionamento de como esse classificador iria operar com um grupo de teste sem a presença do contaminante. Isso mostra a importância de se preocupar com a qualidade da aquisição do sinal e se houvesse um sistema de identificação de contaminantes, poderiam ter sido tomadas ações pelo operador para tentar reduzir o nível de contaminação, gerando sinais mais íntegros.

Quanto à calibração do IAC, se observou que é necessário reduzir a taxa de identificação entre -10dB e 0dB para a base DB3 e entre 0dB e 10dB para a base IEE, algo que já foi demonstrado ser possível em (Machado, Machado e Balbinot, 2021). A metodologia de calibração utilizando a correlação dos sinais, apresentadas nas Tabela 9 e Tabela 10 se mostrou apenas em parte eficiente, principalmente para o DB3, onde o IAC já apresenta menos ocorrências de falsos positivos a partir de -10dB, e a partir dos valores de correlação ainda se considerava contaminado. Se observar a Figura 14, é possível ver que para -10dB, o sinal já é visualmente parecido com o sinal sem contaminação.

Ao comparar com outros trabalhos semelhantes, o único que permite uma comparação direta é o trabalho de (Moura, de e Balbinot, 2018), que propõe um sistema de tolerância a falhas através de um sensor virtual, utilizando as mesmas bases de dados, porém existem diferenças na metodologia. A principal é a utilização de diferentes níveis de SNR para as

contaminações e a decisão de não utilizar o a saturação do amplificador como contaminante, pois o problema de saturação ocorre apenas se não for realizada a devida equalização dos ganhos dos canais analógicos. Também utiliza a SVM como classificador de movimentos e para identificar a contaminação, e TVARMA como modelo de sensor virtual.

O estudo de (Moura, de e Balbinot, 2018) apresenta 16 estudos de caso e dentre esses estudos inclui os 7 utilizados neste trabalho. Se considerar os resultados para o pior caso, com 100% do sinal contaminado em -40dB, o modelo proposto com RNN-LSTM apresenta um desempenho superior para todos contaminantes, tanto para amputados como para não amputados, atingindo, portanto, um dos objetivos dessa tese, de desenvolver uma plataforma experimental com sensor virtual que apresentasse um avanço no modelo previamente proposto no referido trabalho e que estimasse o sinal mais próximo do bruto, apenas pré-processado pelo filtro AVT, o que dá mais flexibilidade para aplicação do modelo em outros sistemas de eletromiografia.

A comparação com outros sistemas tolerantes a falhas é complexa, pois a metodologia dos trabalhos são muito diversas, como por exemplo o estudo de (Zhang e Huang, 2015), onde um sistema, que opera *online*, porém mais simplificado consistindo de apenas 6 canais e sete classes de movimentos, onde o sistema consegue recuperar a taxa de acerto do classificador LDA com um método de retreinamento a partir de dados armazenados na memória, utilizando um detector binário de contaminantes, baseado na distância de Mahalanobis para ativação do método de mitigação.

Esse método pode ser muito custoso computacionalmente para contaminantes intermitentes, por exemplo, ou se o sistema possui muitos canais. Além disso, o estudo não especificou níveis diferentes de SNR para todos os contaminantes utilizados, apenas para ruído branco gaussiano, onde 3 constantes são utilizadas para modificar a intensidade deste

contaminante. A base também é reduzida em sujeitos, comparada a este trabalho, com apenas 6 sujeitos, sendo apenas 1 amputado.

Outro trabalho que envolve classificação de movimentos com tolerância a falhas realizado por (Guo *et al.*, 2017), porém a falha, simulada apenas com ruído branco com SNR não informado, é mitigada através de fusão de sensores inerciais que usam o princípio da mecanomiografia em um estudo realizado com apenas 2 indivíduos amputados. A proposta do uso de sensores inerciais fundidos com sEMG pode ser útil na estimação de um modelo de sensor virtual, podendo ser proposta como um estudo futuro.

Em relação à identificação dos contaminantes, se atingiu o objetivo do trabalho nesse aspecto, que era realizar a identificação dos contaminantes sem a necessidade de extrair características, que se difere do trabalho realizado por (McCool *et al.*, 2014), onde 7 características eram extraídas para identificação. A grande vantagem das características extraídas no referido trabalho é que elas se modificam a medida que o SNR se modifica, podendo ser utilizadas para também indicar o nível de contaminação do sinal, mas essa funcionalidade não foi explorada pelos pesquisadores.

Portanto o que se observa, são estudo mais limitados em número de indivíduos, contaminantes e níveis de contaminação, sendo uma das contribuições, a expansão dessas análises, tanto na identificação de contaminantes, como no desenvolvimento de um novo modelo de sensor virtual, de acordo com a Tabela 28.

Em relação aos trabalhos (Guo *et al.*, 2017; Zhang e Huang, 2015), que utilizam o mesmo sistema de detecção de falha, por distância de Mahalanobis, e o de Moura, de e Balbinot (2018), que utiliza SVM, o que se observa inicialmente é a integração entre o sistema de identificação da qualidade com o classificador de movimentos. Ambos os modelos utilizam as mesmas quatro características com uma abordagem interessante do ponto de vista de eficiência, porém não permite a modularidade dos modelos. Se, por exemplo, fosse utilizado

outro modelo na saída, com outros tipos de características de entrada, ou até com diferentes abordagens de saída, como modelos cuja saída são trajetórias, por exemplo, serão necessário cálculos de características diferentes para a identificação de contaminantes e para a saída. A partir deste ponto de vista, o modelo desenvolvido nessa tese permite uma maior flexibilidade, visto que identifica o contaminante diretamente do sEMG bruto.

Tabela 28 - Comparativo entre trabalhos semelhantes.

Trabalho	Canais	Amputados	# Características Identificação Falha	Tipo Saída
(Zhang e Huang, 2015)	6	1*	4	7 (5*) Tipos de movimento membro superior
(López <i>et al.</i> , 2009)	2	1	NA	Sinal Controle PD de uma junta robótica
(Furukawa <i>et al.</i> , 2015)	4	0	sEMG	Torque junta robótica
(Guo <i>et al.</i> , 2017)	4	2	4	13 (11) tipos de movimento
(Moura, de e Balbinot, 2018)	12	11	5	17 Tipos de movimento

Já Furukawa *et al.* (2015) utiliza o dado bruto na forma de covariância e correlação entre os canais em um regressor logístico, de forma a identificar a falha. Porém este método é utilizado em apenas 4 canais (*bíceps braquial cabeça longa*, *bíceps braquial cabeça curta*, *tríceps braquial cabeça longa* e *tríceps braquial cabeça curta*), que são músculos próximos e com *crosstalk* entre eles e não foi testado para mais canais e com maior distância espacial entre eles, como nos músculos do antebraço, por exemplo.

6. CONCLUSÕES

Este trabalho apresentou contribuições para análise da qualidade do sEMG, propondo um identificador de contaminantes utilizando uma RNN-LSTM, onde não é necessária a extração de características, diferente do trabalho proposto por (McCool *et al.*, 2014), onde 7 características são extraídas. O IAC desenvolvido neste trabalho foi utilizado na proposta de tolerância a falhas identificando a contaminação, mas também pode ser utilizado para guiar o operador do aparato experimental na presença de contaminantes, lembrando que o operador nem sempre será um especialista em eletromiografia, podendo ser tanto como usuário comum de uma prótese mioelétrica, como o técnico que opera o sistema. Isso se mostrou importante ao indicar que existia contaminação prévia na base IEE, que poderia ter sido mitigada a partir do momento que fosse indicada a causa.

Outra contribuição foi a caracterização do sensor virtual a partir de um sinal mais próximo do bruto, que se mostrou válida, principalmente para contaminações com $SNR \leq -20dB$ com 100% de contaminação, sendo que para os canais 11 e 12, se demonstrou mais eficiente quando os 2 canais estão em falha, do que apenas os canais de forma individuais. O sistema mostrou uma necessidade de calibração do IAC entre -10dB e 10dB. Outro ponto observado, foi de que a contaminação por RBA e RL é, em geral, mais crítica para o sistema, sendo que a operação com AM e ECG é, em alguns casos, melhor que o uso do sensor virtual, principalmente para a base de amputados.

A abordagem global mostrou que não pode ser aplicada para todos os indivíduos, sendo necessário uma análise mais individualizada, principalmente para o sensor virtual. Porém a metodologia proposta é facilmente adaptável para realizar treinamento e testes individualizados, sendo necessário apenas mais horas de ensaio para um mesmo indivíduo.

Comparado à outro método similar de tolerância a falhas, este estudo evoluiu os resultados obtidos por (Moura, de e Balbinot, 2018), obtendo melhoras significativas para as

taxas de acerto em todos os casos, principalmente com 100% do sinal contaminado, com a vantagem de fazer a estimação de um sinal que é mais próximo do bruto, apenas pré-processado com o filtro AVT, que confere uma maior flexibilidade para utilizar a solução em diferentes aplicações.

Um dos problemas do sensor virtual utilizando a RNN-LSTM é o fato de que cada caso de contaminação precisa de um modelo específico e se fosse utilizar modelos para cada possibilidade de contaminação dos 12 canais, seriam necessários 4095 modelos diferentes, e para se tornar mais viável essa proposta, seria necessário avaliar quais canais impactam mais na taxa de classificação, utilizando métodos como apresentados em (Mendes Junior *et al.*, 2020; Tosin, Cene e Balbinot, 2020), que indicam a relevância de cada canal e característica para a operação do sistema, visando a taxa de acerto. Outro problema que necessita ser avaliado futuramente é o custo computacional da solução tanto do identificador de contaminantes, quanto do sensor virtual, pois RNN's com unidades LSTM possuem, em geral, muitos parâmetros.

Do ponto de vista das hipóteses levantadas por este trabalho, se conclui, que para o grupo de indivíduos avaliados, foi possível identificar a contaminação e o tipo de contaminantes com a RNN-LSTM utilizando o sinal bruto de sEMG e mitigar, em parte, o efeito causado no ELM, principalmente para os menores valores de SNR e com 100% do sinal contaminado, ou seja, para 10s ou mais do sinal contaminado. A mitigação da contaminação de AM e ECG, quando envolvem os canais 11 e 12 para os indivíduos amputados, foram as que obtiveram o pior desempenho, comparado aos outros contaminantes e canais, sendo necessário aprofundar esta questão para verificar se os poucos efeitos positivos indicam a utilização do sensor virtual nesses casos. Portanto a identificação do contaminante, nesses casos, pode ser útil para evitar o acionamento do sensor virtual.

. Para esse trabalho, se identificou, tanto pelos resultados obtidos nas duas bases de dado, como a partir dos movimentos considerados, que quanto mais canais contaminados, maior o impacto na taxa de acerto do classificador e que individualmente os canais 9 e 10 sofrem um impacto maior, pois são mais exigidos nos movimentos considerados, portanto possuem mais informações relevantes sobre o movimento realizado.

Como proposta de trabalho futuro, utilizar os resultados obtidos como uma realimentação para calibração do IAC, para reduzir os efeitos de falso positivo, assim como avaliar se existe vantagem para o sistema mitigar AM e ECG para os canais 11 e 12. Também deve-se adaptar a metodologia para individualizar mais os procedimentos de treinamento e validação dos modelos, aumentar o tamanho da base de dados, trabalho esse que está em andamento para a base IEE, aprofundar a análise do ponto de vista de canais e movimentos assim como estudar formas de implementar um sistema de testes *online*, assim como os contaminantes avaliados necessitam ser validados, sendo uma proposta de trabalho futuro desenvolver uma metodologia que permita avaliar falhas geradas de forma não artificial e *online*, confrontando com as falhas artificiais propostas nesse trabalho.

7. PUBLICAÇÕES RELACIONADAS À TESE

Foram publicados 4 trabalhos, sendo 2 em periódicos internacionais e 2 em congressos IEEE. O primeiro trabalho publicado em periódico está relacionado ao desenvolvimento da base de dados IEE e o segundo diz respeito ao Identificador Automático de Contaminantes. Já está sendo elaborado um terceiro artigo relatando os resultados finais do trabalho. Os trabalhos em congresso dizem respeito aos estudos iniciais realizados para o desenvolvimento do sensor virtual e do identificador automático de contaminantes.

PERIÓDICOS INTERNACIONAIS:

“Open Database for Accurate Upper-Limb Intent Detection Using Electromyography and Reliable Extreme Learning Machines” – Sensors (2019) – Qualis A1 - <https://www.mdpi.com/1424-8220/19/8/1864>

“Deep learning for surface electromyography artifact contamination type detection” – Biomedical Signal Processing And Control (2021) – Qualis A2 – <https://www.sciencedirect.com/science/article/pii/S1746809421003499>

CONGRESSOS INTERNACIONAIS:

“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) - <https://ieeexplore.ieee.org/document/8857462>

“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) - <https://ieeexplore.ieee.org/document/9175348>

BIBLIOGRAFIA

- ANAM, K.; AL-JUMAILY, A. Adaptive Wavelet Extreme Learning Machine (AW-ELM) for Index Finger Recognition Using Two-Channel Electromyography. **In: International Conference on Neural Information Processing, 21st, 2014**. Cham: Springer, 2014. p. 471-478.
- ARVIDSSON, A.; GRASSINO, A.; LINDSTROM, L. Automatic selection of uncontaminated electromyogram as applied to respiratory muscle fatigue. **Journal of Applied Physiology Respiratory Environmental and Exercise Physiology**, v. 56, n. 3, p. 568–575, mar. 1984.
- ATZORI, M. *et al.* Electromyography data for non-invasive naturally-controlled robotic hand prostheses. **Scientific Data**, v. 1, p. 140053, dez. 2014.
- _____. Characterization of a benchmark database for myoelectric movement classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 23, n. 1, p. 73–83, 2015.
- _____. 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.; COGNOLATO, M.; MÜLLER, H. Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands. **Frontiers in neurorobotics**, v. 10, p. 9, 2016.
- BALBINOT, A.; FAVIEIRO, G. A Neuro-Fuzzy System for Characterization of Arm Movements. **Sensors**, v. 13, n. 2, p. 2613–2630, 2013.
- BARNIV, Y.; AGUILAR, M.; HASANBELLIU, E. Using EMG to anticipate head motion for virtual-environment applications. **IEEE Transactions on Biomedical Engineering**, v. 52, n. 6, p. 1078–1093, 2005.
- BARTLETT, P. L. The sample complexity of pattern classification with neural networks: The size of the weights is more important than the size of the network. **IEEE Transactions on Information Theory**, v. 44, n. 2, p. 525–536, 1998.
- BELO, D. *et al.* Biosignals learning and synthesis using deep neural networks. **BioMedical Engineering OnLine**, v. 16, n. 1, p. 115, 2017.
- BHUYAN, M. **Intelligent Instrumentation: Principles And Applications**. Boca Raton: CRC Press, 2012.
- BIDDISS, E. A.; CHAU, T. T. Upper limb prosthesis use and abandonment. **Prosthetics & Orthotics International**, v. 31, n. 3, p. 236–257, 2007.

BIDDISS, E.; BEATON, D.; CHAU, T. Consumer design priorities for upper limb prosthetics. **Disability and Rehabilitation: Assistive Technology**, v. 2, n. 6, p. 346–357, 2007.

BU, N.; FUKUDA, O.; TSUJI, T. EMG-based motion discrimination using a novel recurrent neural network. **Journal of Intelligent Information Systems**, v. 21, n. 2, p. 113–126, 2003.

CENE, V. H. **Desenvolvimento De Um Projeto De Experimentos Para A Caracterização De Sinais Mioelétricos Através Do Uso De Regressão Logística**. [s.l.] Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Sul, 2016.

CENE, V. H., *et al.* Open database for accurate upper-limb intent detection using electromyography and reliable extreme learning machines. **Sensors (Switzerland)**, v. 19, n. 8, p. 1864, 18 abr. 2019.

CENE, V. H. **Métodos de Classificação Confiável e Resiliente de Movimentos de Membros Superiores Baseados em Extreme Learning Machines e Sinais de Eletromiografia de Superfície**. [s.l.] Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, 2020.

CENE, V. H.; BALBINOT, A. Using the sEMG signal representativity improvement towards upper-limb movement classification reliability. **Biomedical Signal Processing and Control**, v. 46, p. 182–191, 1 set. 2018.

_____. Resilient EMG Classification to Enable Reliable Upper-Limb Movement Intent Detection. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, p. 1–1, 21 set. 2020.

CENE, V. H.; MACHADO, J.; BALBINOT, A. Smoothed arg max Extreme Learning Machine: An Alternative to Avoid Classification Ripple in sEMG Signals. In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 41, 2019, Berlin. **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**. Nova York: IEEE, 2019. p. 6603-6606.

CENE, V. H.; SANTOS, R. R. DOS; BALBINOT, A. Using Antonyan Vardan Transform and Extreme Learning Machines for Accurate sEMG Signal Classification. In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 40, 2018, Honolulu. **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**. Nova York: IEEE, 2018. p. 5224-5227.

CHANG, C.-C.; LIN, C.-J. LIBSVM: A library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, n. 3, p. 1–27, 1 abr. 2011.

CHEN, Y. *et al.* A Continuous Estimation Model of Upper Limb Joint Angles by Using Surface Electromyography and Deep Learning Method. **IEEE Access**, v. 7, p. 174940–174950, 2019.

CHERON, G. *et al.* A dynamic neural network identification of electromyography and arm trajectory relationship during complex movements. **IEEE Transactions on Biomedical Engineering**, v. 43, n. 5, p. 552–558, maio 1996.

CHERON, G. *et al.* A dynamic recurrent neural network for multiple muscles electromyographic mapping to elevation angles of the lower limb in human locomotion. **Journal of Neuroscience Methods**, v. 129, n. 2, p. 95–104, out. 2003.

CHHERAWALA, Y.; ROY, P. P.; CHERIET, M. Feature Set Evaluation for Offline Handwriting Recognition Systems: Application to the Recurrent Neural Network Model. **IEEE Transactions on Cybernetics**, v. 46, n. 12, p. 2825–2836, dez. 2016.

CLANCY, E. ; MORIN, E. ; MERLETTI, R. Sampling, noise-reduction and amplitude estimation issues in surface electromyography. **Journal of Electromyography and Kinesiology**, v. 12, n. 1, p. 1–16, 1 fev. 2002.

DEV, R.; SINGH, A. K. Performance analysis of classifiers for EMG signal of different hand movements. **International Journal of Biomedical Engineering and Technology**, v. 22, n. 3, p. 233, 2016.

DORCAS, D. S.; DUNFIELD, V. A.; SCOTT, R. N. Improved myo-electric control system. **Medical & Biological Engineering**, v. 8, n. 4, p. 333–341, jul. 1970.

DRAYE, J. P. *et al.* Improved identification of complex temporal systems with dynamic recurrent neural networks. Application to the identification of electromyography and human arm trajectory relationship. **Journal of Intelligent Systems**, v. 7, n. 1–2, p. 83–102, jan. 1997.

DRAYE, J. P.; WINTERS, J. M.; CHERON, G. Self-selected modular recurrent neural networks with postural and inertial subnetworks applied to complex movements. **Biological Cybernetics**, v. 87, n. 1, p. 27–39, 1 jul. 2002.

ECKART, C.; YOUNG, G. The approximation of one matrix by another of lower rank. **Psychometrika**, v. 1, n. 3, p. 211–218, set. 1936.

ENDERLE, J. D.; BRONZINO, J. D. **Introduction to Biomedical Engineering**. 3rd. ed. Burlington: Elsevier, 2012. v. 1

ENGLEHART, K.; HUDGIN, B.; PARKER, P. A. A wavelet-based continuous classification scheme for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, v. 48, n. 3, p. 302–311, mar. 2001.

ENGLEHART, K.; HUDGINS, B. A robust, real-time control scheme for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, v. 50, n. 7, p. 848–854, jul. 2003.

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

FARRELL, T. R. Determining delay created by multifunctional prosthesis controllers. *Journal of Rehabilitation Research and Development*. **Journal of Rehabilitation Research and Development**, v. 48, n. 6, 2011.

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

- FRATINI, A. *et al.* Relevance of motion artifact in electromyography recordings during vibration treatment. **Journal of Electromyography and Kinesiology**, v. 19, n. 4, p. 710–718, 2009.
- FUKUDA, O.; ARITA, J.; TSUJI, T. An EMG-controlled omnidirectional pointing device. **Systems and Computers in Japan**, v. 37, n. 4, p. 55–63, 2006.
- FURUKAWA, J. *et al.* Fault tolerant approach for biosignal-based robot control. **Advanced Robotics**, v. 29, n. 7, p. 505–514, 2015.
- GAN, J.; WANG, W.; LU, K. A new perspective: Recognizing online handwritten Chinese characters via 1-dimensional CNN. **Information Sciences**, v. 478, p. 375–390, 2019.
- GAO, B. *et al.* Real-Time Evaluation of the Signal Processing of sEMG Used in Limb Exoskeleton Rehabilitation System. **Applied bionics and biomechanics**, v. 2018, p. 1391032, 2018.
- GEETHANJALI, P. Comparative study of PCA in classification of multichannel EMG signals. **Australasian Physical and Engineering Sciences in Medicine**, v. 38, n. 2, p. 331–343, 2015.
- GERS, F. A.; SCHMIDHUBER, J.; CUMMINS, F. Learning to forget: Continual prediction with LSTM. **Neural Computation**, v. 12, n. 10, p. 2451–2471, 2000.
- GIJSBERTS, A. *et al.* Movement error rate for evaluation of machine learning methods for sEMG-based hand movement classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 22, n. 4, p. 735–744, 2014.
- GOLDBERGER, A. *et al.* The MIT-BIH Normal Sinus Rhythm Database - PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. **Circulation** **101**, v. 23, n. June 13, p. 215–220, 2000.
- GONZALEZ, G. D. *et al.* Issues in soft-sensor applications in industrial plants. In: IEEE International Symposium on Industrial Electronics (ISIE'94), 1994, Santiago. **Proceedings of 1994 IEEE International Symposium on Industrial Electronics (ISIE'94)**, New York: IEEE, 2002. p. 380–385, 1994.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge, US: MIT Press, 2016.
- GRAVES, A. **Supervised Sequence Labelling with Recurrent Neural Networks**. 1. ed. [s.l.] Springer, 2012. v. 385
- GREFF, K. *et al.* LSTM: A Search Space Odyssey. **IEEE Transactions on Neural Networks and Learning Systems**, v. 28, n. 10, p. 2222–2232, 2017.
- GU, Y. *et al.* Robust EMG pattern recognition in the presence of confounding factors: features, classifiers and adaptive learning. **Expert Systems with Applications**, v. 96, p. 208–217, 2018.
- GUO, W. *et al.* Mechanomyography Assisted Myoelectric Sensing for Upper-Extremity Prostheses: A Hybrid Approach. **IEEE Sensors Journal**, v. 17, n. 10, p. 3100–3108, 2017.

GUYON, I. *et al.* Gene selection for cancer classification using support vector machines. **Machine Learning**, v. 46, n. 1–3, p. 389–422, 2002.

HANES, M. D.; AHALT, S. C.; KRISHNAMURTHY, A. K. Acoustic-to-phonetic mapping using recurrent neural networks. **IEEE Transactions on Neural Networks**, v. 5, n. 4, p. 659–662, 1994.

HARGROVE, L. *et al.* The effect of ECG interference on pattern-recognition-based myoelectric control for targeted muscle reinnervated patients. **IEEE Transactions on Biomedical Engineering**, v. 56, n. 9, p. 2197–2201, 2009.

HARGROVE, L. J.; ENGLEHART, K.; HUDGINS, B. A Comparison of Surface and Intramuscular Myoelectric Signal Classification. **IEEE Transactions on Biomedical Engineering**, v. 54, n. 5, p. 847–853, 2007.

HAYKIN, S. **Neural Networks and Learning Machines**. 3rd. ed. [s.l.] Pearson Prentice Hall, 2008.

HOCHREITER, S. *et al.* Gradient Flow in Recurrent Nets: the Difficulty of Learning Long-Term Dependencies. *In*: KOLEN, J. F.; KREMER, S. C. (Eds.). . **A Field Guide to Dynamical Recurrent Networks**. [s.l.] Wiley-IEEE Press, 2001. p. 464.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, nov. 1997.

HU, Y. *et al.* A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition. **PLOS ONE**, v. 13, n. 10, p. e0206049, 30 out. 2018.

HUANG, G. BIN. An Insight into Extreme Learning Machines: Random Neurons, Random Features and Kernels. **Cognitive Computation**, v. 6, n. 3, p. 376–390, 3 abr. 2014.

HUANG, G. BIN; ZHU, Q. Y.; SIEW, C. K. Extreme learning machine: A new learning scheme of feedforward neural networks. *In*: International Joint Conference on Neural Networks, 2004, Budapest. **Proceedings of 2004 IEEE International Conference on Neural Networks**. New York: IEEE, v. 2, p. 985–990, 2004.

_____. Extreme learning machine: Theory and applications. **Neurocomputing**, v. 70, n. 1–3, p. 489–501, 2006.

HUDGINS, B.; PARKER, P.; SCOTT, R. N. A New Strategy for Multifunction Myoelectric Control. **IEEE Transactions on Biomedical Engineering**, v. 40, n. 1, p. 82–94, 1993.

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.

IQBAL, N. V.; SUBRAMANIAM, K.; P., S. A. A Review on Upper-Limb Myoelectric Prosthetic Control. **IETE Journal of Research**, v. 64, n. 6, p. 1–13, 2 nov. 2017.

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, 2014.

- JAHANI FARIMAN, H. *et al.* Simple and Computationally Efficient Movement Classification Approach for EMG-controlled Prosthetic Hand: ANFIS vs. Artificial Neural Network. **Intelligent Automation and Soft Computing**, v. 21, n. 4, p. 559–573, 2 out. 2015.
- JIANG, N.; FARINA, D. Myoelectric control of upper limb prosthesis: current status, challenges and recent advances. **Frontiers in Neuroengineering**, v. 7, 2014.
- JIANG, W.; YIN, Z. Human activity recognition using wearable sensors by deep convolutional neural networks. In: ACM international conference on Multimedia, 23. Brisbane. **Proceedings of the 2015 ACM Multimedia Conference**. New York: Association for Computing Machinery, Inc, 2015. p 1307-1310.
- KHAN, M.; JAHAN, M. Classification of myoelectric signal for sub-vocal Hindi phoneme speech recognition. **Journal of Intelligent & Fuzzy Systems**, v. 35, n. 5, p. 5585–5592, 20 nov. 2018.
- KHUSHABA, R. N. *et al.* Electromyogram (EMG) based fingers movement recognition using neighborhood preserving analysis with QR-decomposition. In: International Conference on Intelligent Sensors, Sensor Networks and Information, 7, 2011. Adelaide. **Proceedings of the Seventh International Conference on Intelligent Sensors, Sensor Networks and Information Processing**. New York: IEEE, 2011.
- KINGMA, D. P.; BA, J. L. **Adam: A Method for Stochastic Optimization** International Conference on Learning Representations (ICLR). **Anais...**San Diego: 2015
- KOÇER, S.; TÜMER, A. E. Classifying neuromuscular diseases using artificial neural networks with applied Autoregressive and Cepstral analysis. **Neural Computing and Applications**, v. 28, n. S1, p. 945–952, 10 dez. 2017.
- KYRANOU, I.; VIJAYAKUMAR, S.; ERDEN, M. S. Causes of Performance Degradation in Non-invasive Electromyographic Pattern Recognition in Upper Limb Prostheses. **Frontiers in Neurorobotics**, v. 12, p. 58, 21 set. 2018.
- LEE, H. J. *et al.* Online remote control of a robotic hand configurations using sEMG signals on a forearm. In: IEEE International Conference on Robotics and Biomimetics, 2011, Karon Beach. **Proceedings of the IEEE International Conference on Robotics and Biomimetics**, 2011, New York: IEEE. p. 2243-2244.
- LEE, S.; SARIDIS, G. N. The Control of a Prosthetic Arm by EMG Pattern Recognition. **IEEE Transactions on Automatic Control**, v. 29, n. 4, p. 290–302, dez. 1984.
- LI, X. *et al.* A NOVEL PROPORTIONAL AND SIMULTANEOUS CONTROL METHOD FOR PROSTHETIC HAND. **Journal of Mechanics in Medicine and Biology**, v. 17, n. 08, p. 1750120, dez. 2017.
- LIU, X. *et al.* Two Efficient Lattice Rescoring Methods Using Recurrent Neural Network Language Models. **IEEE/ACM Transactions on Audio, Speech, and Language Processing**, v. 24, n. 8, p. 1438–1449, ago. 2016.
- LÓPEZ, N. M. *et al.* Robust EMG sensing system based on data fusion for myoelectric control of a robotic arm. **BioMedical Engineering OnLine**, v. 8, n. 1, p. 5, 25 fev. 2009.

LOVELL, N. H. *et al.* Biosignal quality detection: An essential feature for unsupervised telehealth applications. In: International Conference on e-health Networking, Applications and Services, 12th, Lyon, 2010. **Proceedings of the 12th IEEE International Conference on e-Health Networking, Applications and Services**. New York: IEEE, 2010.

LUCA, C. J. DE *et al.* Filtering the surface EMG signal: Movement artifact and baseline noise contamination. **Journal of Biomechanics**, v. 43, n. 8, p. 1573–1579, 28 maio 2010.

MACHADO, J.; MACHADO, A.; BALBINOT, A. Deep learning for surface electromyography artifact contamination type detection. **Biomedical Signal Processing and Control**, v. 68, p. 102752, 1 jul. 2021.

MALBOUBI, M. *et al.* Power line noise elimination from EMG signals using adaptive laguerre filter with fuzzy step size. In: Iranian Conference of Biomedical Engineering, 17th, 2010, Isfahan. **Proceedings of the 17th Iranian Conference of Biomedical Engineering**. New York: IEEE, 2010.

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, jul. 2014.

MENDES JUNIOR, J. J. A. *et al.* Feature selection and dimensionality reduction: An extensive comparison in hand gesture classification by sEMG in eight channels armband approach. **Biomedical Signal Processing and Control**, v. 59, p. 101920, 1 maio 2020.

MICERA, S.; CARPANETO, J.; RASPOPOVIC, S. Control of hand prostheses using peripheral information. **IEEE Reviews in Biomedical Engineering**, v. 3, p. 48–68, 2010.

MOGK, J. P. M.; KEIR, P. J. Crosstalk in surface electromyography of the proximal forearm during gripping tasks. **Journal of Electromyography and Kinesiology**, v. 13, n. 1, p. 63–71, 2003.

MOURA, K. DE O. A. DE; BALBINOT, A. Virtual sensor of surface electromyography in a new extensive fault-tolerant classification system. **Sensors (Switzerland)**, v. 18, n. 5, p. 1388, 1 maio 2018.

MOURA, K. O. A.; RUSCHEL, R. S.; BALBINOT, A. Fault-Tolerant Sensor Detection of sEMG signals: Quality Analysis Using a Two-Class Support Vector Machine. In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 40, 2018, Honolulu. **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**. Nova York: IEEE, 2018. p. 5644 - 5647.

MURPHY, K. P. **Machine learning : a probabilistic perspective**. [s.l.] MIT Press, 2012.

NAIK, G. R.; KUMAR, D. K.; JAYADEVA. Twin SVM for gesture classification using the surface electromyogram. In: **IEEE Transactions on Information Technology in Biomedicine**, v. 14, n. 2, p. 301–308, mar. 2010.

NAVANEETHAKRISHNA, M.; RAMAKRISHNAN, S. Multiscale feature based analysis of surface EMG signals under fatigue and non-fatigue conditions. In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 36th, 2014, Chigaco.

Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. New York: IEEE, 2014. p. 4627-4630.

NGUYEN, H. T. *et al.* A database of unconstrained Vietnamese online handwriting and recognition experiments by recurrent neural networks. **Pattern Recognition**, v. 78, p. 291–306, 2018.

NODA, T. *et al.* An electromyogram based force control coordinated in assistive interaction. In: IEEE International Conference on Robotics and Automation, 2013, Karlsruhe. **Proceedings of the 2013 IEEE International Conference on Robotics and Automation.** New York: IEEE. 2013. p. 2657- 2662.

OSBORN, L. E. *et al.* Extended home use of an advanced osseointegrated prosthetic arm improves function, performance, and control efficiency. **Journal of Neural Engineering**, v. 18, n. 2, p. 026020, 2021.

ØSTLIE, K. *et al.* Prosthesis rejection in acquired major upper-limb amputees: A population-based survey. **Disability and Rehabilitation: Assistive Technology**, v. 7, n. 4, p. 294–303, 2012.

PARK, M. S.; KIM, K.; OH, S. R. A fast classification system for decoding of human hand configurations using multi-channel sEMG signals. In: IEEE International Workshop on Intelligent Robots and Systems, 2011, San Francisco. **Proceedings of the 2011 IEEE International Workshop on Intelligent Robots and Systems.** New York: IEEE. 2011. p 4483 - 4487.

PITSILIS, G. K.; RAMAMPIARO, H.; LANGSETH, H. Effective hate-speech detection in Twitter data using recurrent neural networks. **Applied Intelligence**, v. 48, n. 12, p. 4730–4742, 26 dez. 2018.

PIZZOLATO, S. *et al.* Comparison of six electromyography acquisition setups on hand movement classification tasks. **PLoS ONE**, v. 12, n. 10, 2017.

ROLAND, T. *et al.* Ultra-low-power digital filtering for insulated EMG sensing. **Sensors (Switzerland)**, v. 19, n. 4, 2019.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, out. 1986.

SAE-LIM, W.; PHUKPATTARANONT, P.; THONGPULL, K. Effect of Electrode Skin Impedance on Electromyography Signal Quality. In: International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, 15th, 2018, Chiang Rai. **Proceedings of the 15th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology.** New York: IEEE, 2018. p 748 - 751.

SAGHEER, A.; KOTB, M. Time series forecasting of petroleum production using deep LSTM recurrent networks. **Neurocomputing**, v. 323, p. 203–213, jan. 2019.

SAMUEL, O. W. *et al.* Resolving the adverse impact of mobility on myoelectric pattern recognition in upper-limb multifunctional prostheses. **Computers in Biology and Medicine**, v. 90, p. 76–87, 1 nov. 2017.

SARTORI, M. *et al.* Robust simultaneous myoelectric control of multiple degrees of freedom in wrist-hand prostheses by real-time neuromusculoskeletal modeling. **Journal of Neural Engineering**, v. 15, n. 6, p. 066026, 1 dez. 2018.

SHOCHINA, M. *et al.* A study of the application of the Fourier series in the analysis of the electrophysiological pattern of development of muscle fatigue. **Electromyography and clinical neurophysiology**, v. 26, n. 7, p. 513–20, 1986.

SILVA, R. A. DA *et al.* The comparison of wavelet- and Fourier-based electromyographic indices of back muscle fatigue during dynamic contractions: validity and reliability results. **Electromyography and clinical neurophysiology**, v. 48, n. 3–4, p. 147–62, 2008.

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

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

SOEDIRDJO, S. D. H.; ULLAH, K.; MERLETTI, R. **Power line interference attenuation in multi-channel sEMG signals: Algorithms and analysis** Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS. **Anais...**Institute of Electrical and Electronics Engineers Inc., 4 nov. 2015

SONG, R.; TONG, K. Y. Using recurrent artificial neural network model to estimate voluntary elbow torque in dynamic situations. **Medical and Biological Engineering and Computing**, v. 43, n. 4, p. 473–480, ago. 2005.

SRIVASTAVA, N. *et al.* Dropout: A Simple Way to Prevent Neural Networks from Overfitting. **Journal of Machine Learning Research**, v. 15, p. 1929–1958, 2014.

STANGO, A.; NEGRO, F.; FARINA, D. Spatial Correlation of High Density EMG Signals Provides Features Robust to Electrode Number and Shift in Pattern Recognition for Myocontrol. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 23, n. 2, p. 189–198, mar. 2015.

SUEIRAS, J. *et al.* Offline continuous handwriting recognition using sequence to sequence neural networks. **Neurocomputing**, v. 289, p. 119–128, maio 2018.

THANGTHAI, A.; MILNER, B.; TAYLOR, S. Synthesising visual speech using dynamic visemes and deep learning architectures. **Computer Speech & Language**, v. 55, p. 101–119, maio 2019.

TOSIN, M. C. *et al.* sEMG feature selection and classification using SVM-RFE In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 39th, 2017, Jeju. **Proceedings of the 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**. Nova York: IEEE, 2017. p. 390 - 393.

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 2020 36:4, v. 36, n. 4, p. 411–427, 18 ago. 2020.

VRIES, W. H. K. DE *et al.* Can shoulder joint reaction forces be estimated by neural networks? **Journal of Biomechanics**, v. 49, n. 1, p. 73–79, jan. 2016.

WANG, J. **Geometric Structure of High-Dimensional Data and Dimensionality Reduction**. [s.l.] Springer Berlin Heidelberg, 2011.

WANG, W. *et al.* Sensor Fusion for Myoelectric Control Based on Deep Learning With Recurrent Convolutional Neural Networks. **Artificial Organs**, v. 42, n. 9, p. E272–E282, 1 set. 2018.

WARIS, A.; KAMAVUAKO, E. N. Effect of threshold values on the combination of EMG time domain features: Surface versus intramuscular EMG. **Biomedical Signal Processing and Control**, v. 45, p. 267–273, ago. 2018.

XIA, P.; HU, J.; PENG, Y. EMG-Based Estimation of Limb Movement Using Deep Learning With Recurrent Convolutional Neural Networks. **Artificial Organs**, v. 42, n. 5, p. E67–E77, 1 maio 2018.

XIA, Y.; WANG, J. Robust Regression Estimation Based on Low-Dimensional Recurrent Neural Networks. **IEEE Transactions on Neural Networks and Learning Systems**, v. 29, n. 12, p. 5935–5946, dez. 2018.

XU, L. *et al.* Feasibility study of advanced neural networks applied to sEMG-based force estimation. **Sensors (Switzerland)**, v. 18, n. 10, 1 out. 2018.

YOUSHEN XIA *et al.* A new regression estimator with neural network realization. **IEEE Transactions on Signal Processing**, v. 53, n. 2, p. 672–685, fev. 2005.

ZARDOSHTI-KERMANI, M. *et al.* EMG Feature Evaluation for Movement Control of Upper Extremity Prostheses. **IEEE Transactions on Rehabilitation Engineering**, v. 3, n. 4, p. 324–333, 1995.

ZHANG, X.; HUANG, H. A real-time, practical sensor fault-tolerant module for robust EMG pattern recognition. **Journal of NeuroEngineering and Rehabilitation**, v. 12, n. 1, p. 18, 19 fev. 2015.

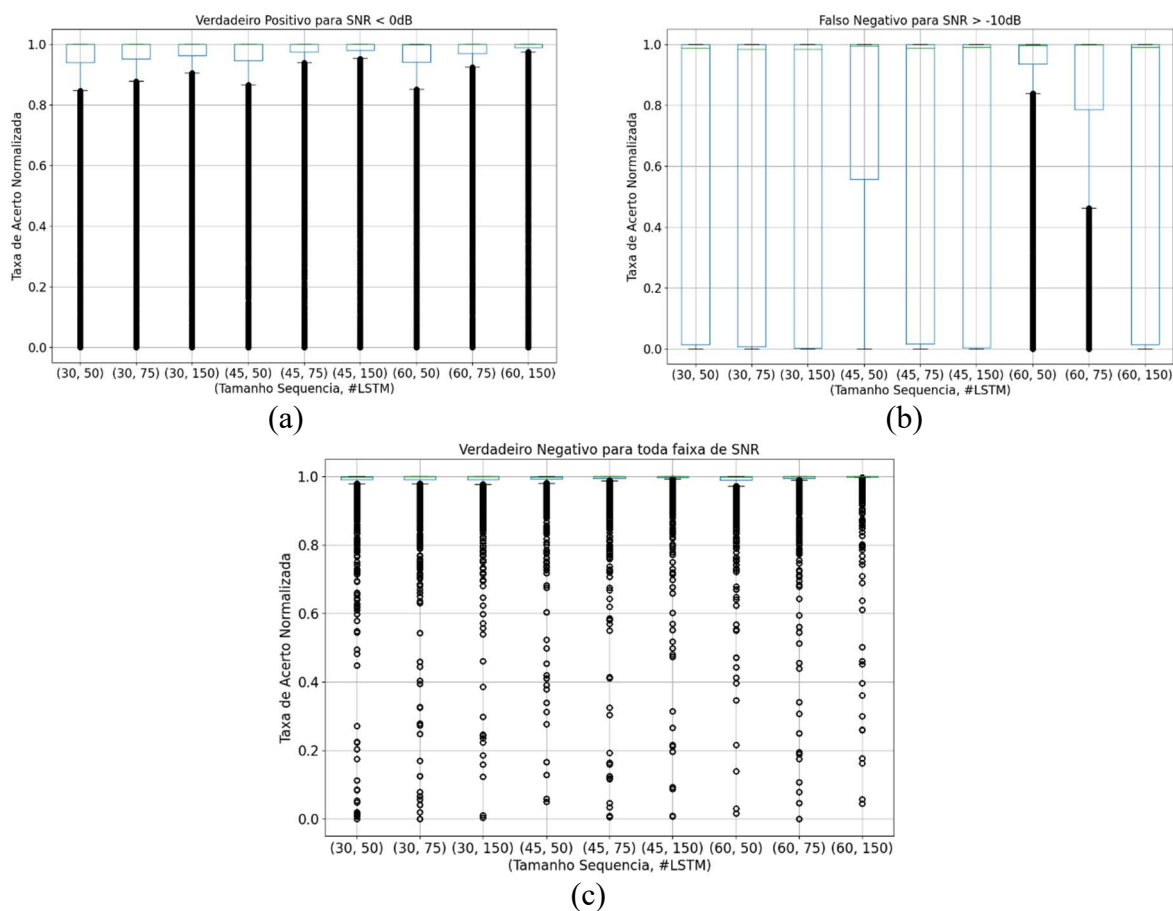
ZHANG, Y. *et al.* Stiffness-gradient-based Grasping Force Control for an Underactuated Prosthetic Hand. **Recent Advances in Electrical & Electronic Engineering (Formerly Recent Patents on Electrical & Electronic Engineering)**, v. 11, n. 4, p. 460–464, 7 nov. 2018.

ZHAO, JIANLONG *et al.* Towards traffic matrix prediction with LSTM recurrent neural networks. **Electronics Letters**, v. 54, n. 9, p. 566–568, 3 maio 2018.

8. APENDICE


GRÁFICOS E TABELAS DO IAC.

Figura 53 – Gráficos tipo *boxplot* para o grupo de treinamento B considerando todas as combinações (N , #LSTM). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.




(c)
Fonte: Autor

Figura 54 – Gráficos tipo *boxplot* para o grupo de treinamento C considerando todas as combinações (N , #LSTM). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.



(a)

(b)



(c)

Fonte: Autor

Figura 55 – Gráficos tipo *boxplot* para o grupo de treinamento B considerando todos os modelos para a configuração ($N = 60$, $\#LSTM = 50$). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.

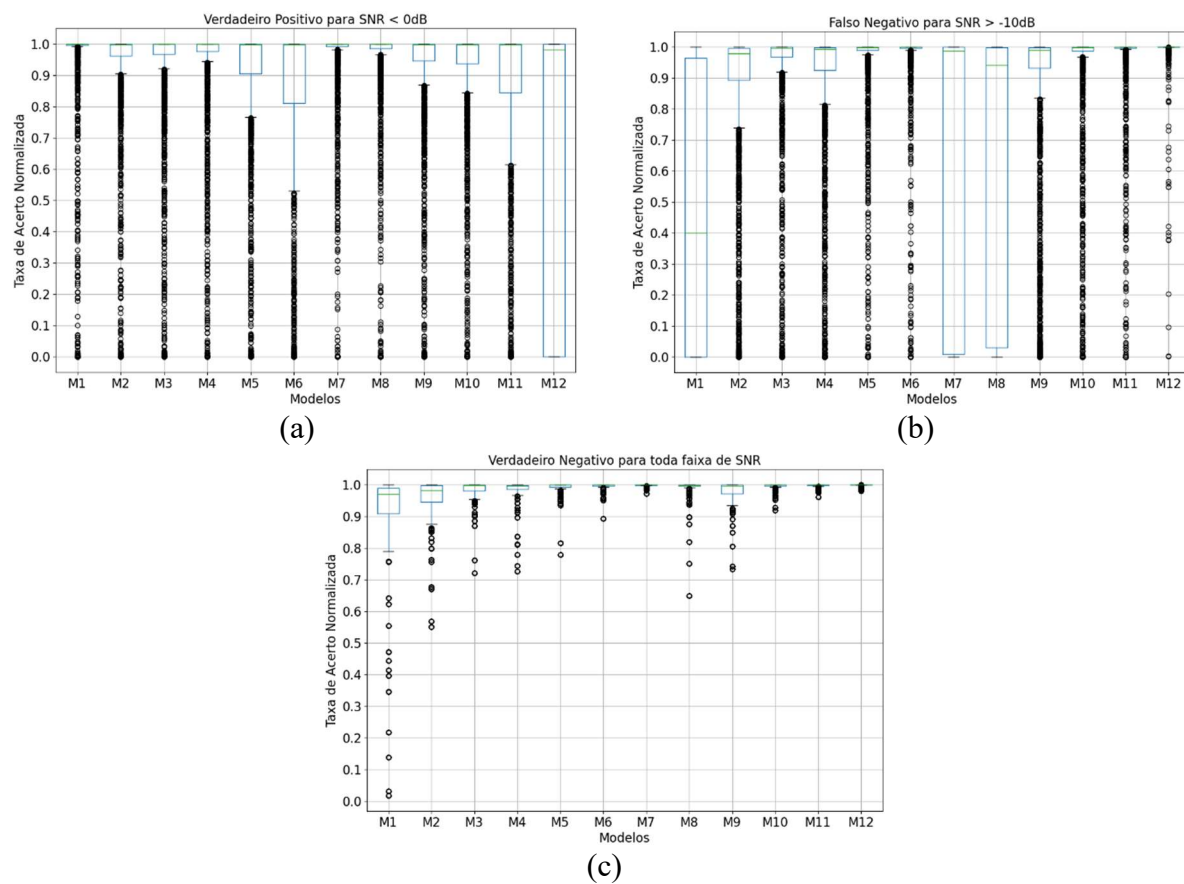
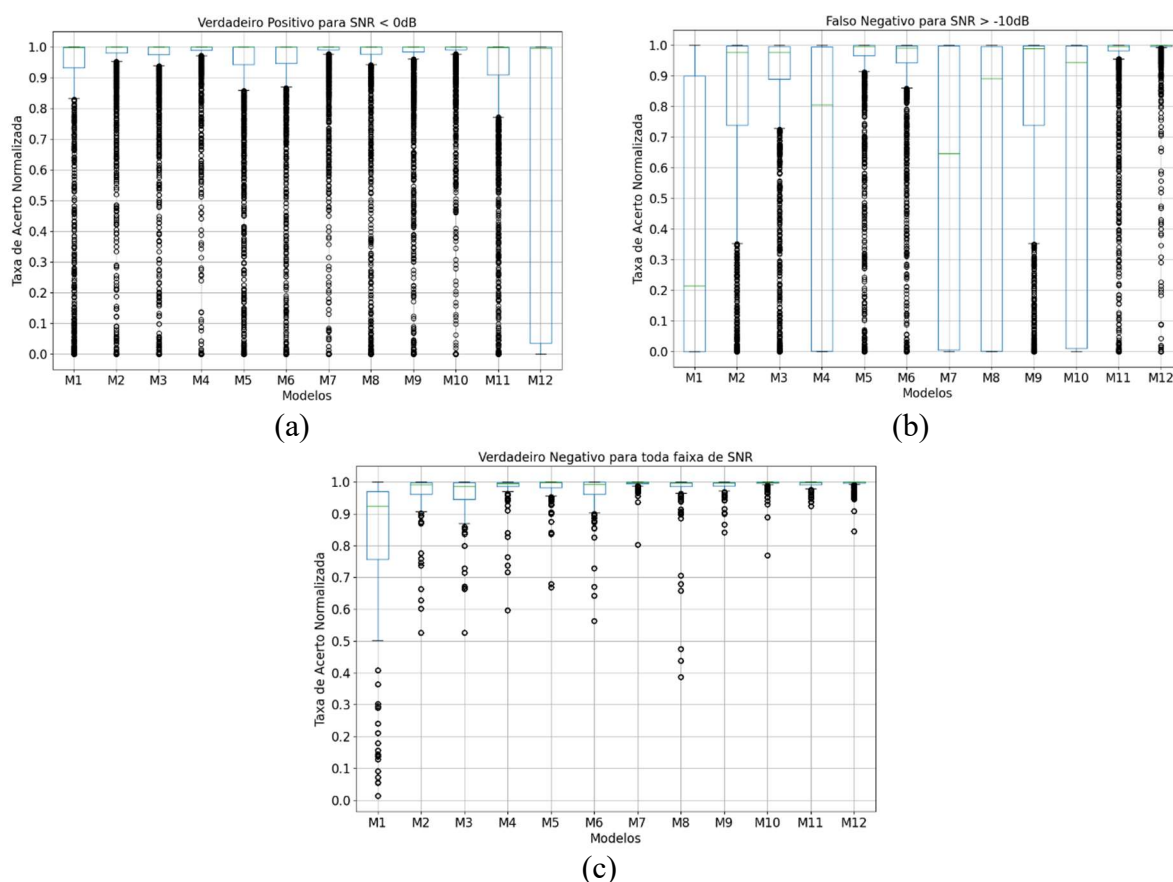


Figura 56 – Gráficos tipo *boxplot* para o grupo de treinamento C considerando todos os modelos para a configuração ($N = 60$, $\#LSTM = 50$). (a) Verdadeiro Positivo (SNR < 0dB), (b) Falso Negativo (SNR > -10dB) e (c) Verdadeiro Negativo.



Fonte: Autor.


Tabela 29 – Média, Desvio Padrão e Intervalo de confiança (95%) de Verdadeiro Positivo para os modelos candidatos do grupo de treinamento B.

Condição	Modelos	Média (%)	Intervalo confiança (%)	Desvio Padrão (%)
Verdadeiro Positivo	M3	88,88	[87,81; 89,95]	26,27
	M4	89,03	[87,96; 90,11]	26,44
	M5	84,12	[82,83; 85,40]	31,59
	M9	88,83	[87,80; 89,86]	25,36
	M10	88,06	[86,98; 89,13]	26,37
Falso Negativo	M3	92,93	[92,21; 93,65]	19,75
	M4	84,07	[82,92; 85,22]	31,66
	M5	95,75	[95,20; 96,30]	15,13
	M9	86,75	[85,76; 87,75]	27,37
	M10	91,51	[90,63; 92,39]	24,13
Verdadeiro Negativo	M3	98,22	[98,01; 98,43]	3,83
	M4	98,12	[97,88; 98,37]	4,52
	M5	99,00	[98,85; 99,14]	2,72
	M9	97,73	[97,50; 97,96]	4,27
	M10	99,52	[99,45; 99,58]	1,21

Tabela 30 – Média, Desvio Padrão e Intervalo de confiança (95%) de Verdadeiro Positivo para os modelos candidatos do grupo de treinamento C.

		Média (%)	Intervalo confiança (%)	Desvio Padrão (%)
Verdadeiro Positivo	M5	86,50	[85,30; 87,68]	29,23
	M6	86,29	[85,08; 87,51]	29,98
	M11	86,21	[85,06; 87,36]	28,28
Falso Negativo	M5	92,52	[91,78; 93,27]	20,44
	M6	91,99	[91,27; 92,70]	19,55
	M11	92,85	[92,07; 93,63]	21,51
Verdadeiro Negativo	M5	97,97	[97,72; 98,23]	4,64
	M6	96,65	[96,30; 97,00]	6,50
	M11	99,21	[99,13; 99,28]	1,32

Figura 57 – Taxa de acerto normalizada para Falso Negativo para (a) RBA, (b) RL, (c) AM e (d) ECG.



Fonte: Autor.

Tabela 31 – Matriz Confusão para os níveis SNR = -40dB, -20dB, 0dB, 20dB, 40dB do grupo de treinamento B.

		Grupo B					
SNR			Predito				
-40dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,87 ± 8,84	0,03 ± 0,51	0,57 ± 4,57	2,52 ± 7,44	0,01 ± 0,15
		RBA	0,01 ± 0,02	92,89 ± 24,53	0,01 ± 0,02	7,09 ± 24,53	0 ± 0
		RL	0,59 ± 7,44	0,17 ± 3,75	80,54 ± 38,86	18,7 ± 38,29	0 ± 0
		AM	0,67 ± 7,49	0,01 ± 0,20	0,01 ± 0,02	99,22 ± 7,52	0,09 ± 0,71
		ECG	0,70 ± 7,45	0 ± 0	0 ± 0	0,5 ± 1,48	98,8 ± 7,56
SNR			Predicted				
-20dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,87 ± 8,84	0,04 ± 0,51	0,57 ± 4,57	2,52 ± 7,44	0,01 ± 0,15
		RBA	6,59 ± 23,84	92,66 ± 25,09	0,01 ± 0,02	0,46 ± 6,51	0,28 ± 5,27
		RL	7,39 ± 20,49	0,01 ± 0,02	88,79 ± 27,34	3,82 ± 16,01	0 ± 0
		AM	9,45 ± 21,79	0 ± 0	0,01 ± 0,02	90,51 ± 21,79	0,03 ± 0,34
		ECG	7,79 ± 17,61	0 ± 0	0 ± 0,07	1,96 ± 3,82	90,24 ± 17,60
SNR			Predicted				
0dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,88 ± 8,84	0,02 ± 0,51	0,57 ± 4,57	2,52 ± 7,44	0,01 ± 0,15
		RBA	69,07 ± 44,16	29,84 ± 44,81	0,02 ± 0,02	0,79 ± 5,78	0,28 ± 5,27
		RL	77,27 ± 34,48	0 ± 0,01	14,83 ± 42,69	7,89 ± 17,23	0 ± 0,04
		AM	81,16 ± 30,50	0 ± 0,03	0,18 ± 0,38	18,65 ± 30,17	0,02 ± 0,10
		ECG	66,6 ± 29,39	0 ± 0,08	0,19 ± 0,63	4,3 ± 9,74	28,91 ± 26,04
SNR			Predicted				
20dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,89 ± 8,84	0,02 ± 0,51	0,57 ± 4,57	2,52 ± 7,44	0,01 ± 0,15
		RBA	96,19 ± 13,28	0,86 ± 8,53	0,32 ± 3,64	2,07 ± 6,39	0,57 ± 7,44
		RL	96,87 ± 9,72	0,02 ± 0,45	0,55 ± 5,36	2,55 ± 7,83	0,01 ± 0,13
		AM	96,87 ± 9,75	0,02 ± 0,46	0,34 ± 3,66	2,77 ± 8,89	0,01 ± 0,16
		ECG	96,37 ± 10,57	0,02 ± 0,59	0,33 ± 3,64	2,67 ± 8,22	0,61 ± 5,08
SNR			Predito				
40dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,89 ± 8,84	0,02 ± 0,51	0,57 ± 4,57	2,52 ± 7,44	0,01 ± 0,15
		RBA	96,19 ± 11,70	0,86 ± 3,88	0,32 ± 3,67	2,07 ± 7,43	0,57 ± 7,44
		RL	96,87 ± 9,19	0,02 ± 0,51	0,55 ± 5,21	2,55 ± 7,49	0,01 ± 0,13
		AM	96,87 ± 8,82	0,02 ± 0,52	0,34 ± 3,66	2,77 ± 7,9	0,01 ± 0,16
		ECG	96,37 ± 9,02	0,02 ± 0,47	0,33 ± 3,67	2,67 ± 7,52	0,61 ± 3,20

Tabela 32 – Matriz Confusão para os níveis SNR = -40dB, -20dB, 0dB, 20dB, 40dB do grupo de treinamento C.

		Grupo C					
SNR			Predito				
-40dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,23 ± 10,09	0,14 ± 3,30	0,95 ± 5,64	2,68 ± 7,69	0 ± 0,06
		RBA	0,01 ± 0,02	99,42 ± 7,44	0,01 ± 0,01	0,28 ± 5,27	0,28 ± 5,27
		RL	0,6 ± 7,45	18,82 ± 37,73	50,24 ± 48,73	30,35 ± 43,71	0 ± 0
		AM	0,67 ± 7,51	4,17 ± 16,45	0,01 ± 0,01	93,53 ± 20,01	1,62 ± 4,40
		ECG	0,69 ± 7,46	0,04 ± 0,85	0 ± 0	0,26 ± 1,05	99,01 ± 7,61
SNR			Predito				
-20dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,23 ± 10,09	0,14 ± 3,30	0,95 ± 5,64	2,68 ± 7,69	0 ± 0,06
		RBA	0,98 ± 9,7	98,44 ± 12,18	0,01 ± 0,02	0,28 ± 5,27	0,28 ± 5,27
		RL	6,8 ± 18,05	0,43 ± 5,81	90,14 ± 23,27	2,63 ± 13,3	0 ± 0
		AM	8,78 ± 20,11	0,17 ± 3,84	0,01 ± 0,02	91,02 ± 20,39	0,01 ± 0,07
		ECG	7,54 ± 17,14	0 ± 0,07	0,01 ± 0,10	1,78 ± 3,57	90,67 ± 17,45
SNR			Predito				
0dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,23 ± 10,09	0,14 ± 3,30	0,95 ± 5,64	2,68 ± 7,69	0 ± 0,06
		RBA	32,06 ± 44,32	66,65 ± 44,77	0,01 ± 7,91	1,28 ± 7,91	0 ± 0,02
		RL	71,28 ± 35,50	0,18 ± 3,84	18,53 ± 19,83	10,00 ± 19,83	0 ± 0
		AM	76,75 ± 31,78	0,01 ± 0,19	0,33 ± 31,25	22,88 ± 31,25	0,02 ± 0,47
		ECG	66,24 ± 29,53	0,05 ± 1,27	0,39 ± 10,81	5,20 ± 10,81	28,12 ± 25,8
SNR			Predito				
20dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,23 ± 10,09	0,14 ± 3,30	0,95 ± 5,64	2,68 ± 7,69	0 ± 0,06
		RBA	89,83 ± 25,92	6,19 ± 21,59	0,55 ± 4,05	3,16 ± 9,39	0,28 ± 5,27
		RL	96,07 ± 11,10	0,12 ± 3,25	0,96 ± 6,39	2,85 ± 8,13	0 ± 0,05
		AM	96,07 ± 11,01	0,12 ± 3,24	0,71 ± 4,99	3,09 ± 9,11	0 ± 0,06
		ECG	95,57 ± 11,64	0,12 ± 3,24	0,71 ± 4,96	2,98 ± 8,37	0,62 ± 5,21
SNR			Predito				
40dB	Verdadeiro	sEMG	RBA	RL	AM	ECG	
		sEMG	96,23 ± 10,09	0,14 ± 3,30	0,95 ± 5,64	2,68 ± 7,69	0 ± 0,06
		RBA	95,71 ± 12,81	0,3 ± 5,06	0,73 ± 5,03	2,7 ± 7,78	0,56 ± 7,44
		RL	96,34 ± 10,52	0,12 ± 3,31	0,85 ± 6,06	2,69 ± 7,75	0 ± 0,07
		AM	96,43 ± 9,94	0,12 ± 3,29	0,73 ± 5,04	2,71 ± 7,78	0 ± 0,07
		ECG	96,33 ± 10,28	0,12 ± 3,32	0,73 ± 5,04	2,71 ± 7,79	0,11 ± 2,69

Tabela 33 – Teste Tukey comparando os grupos A e C.

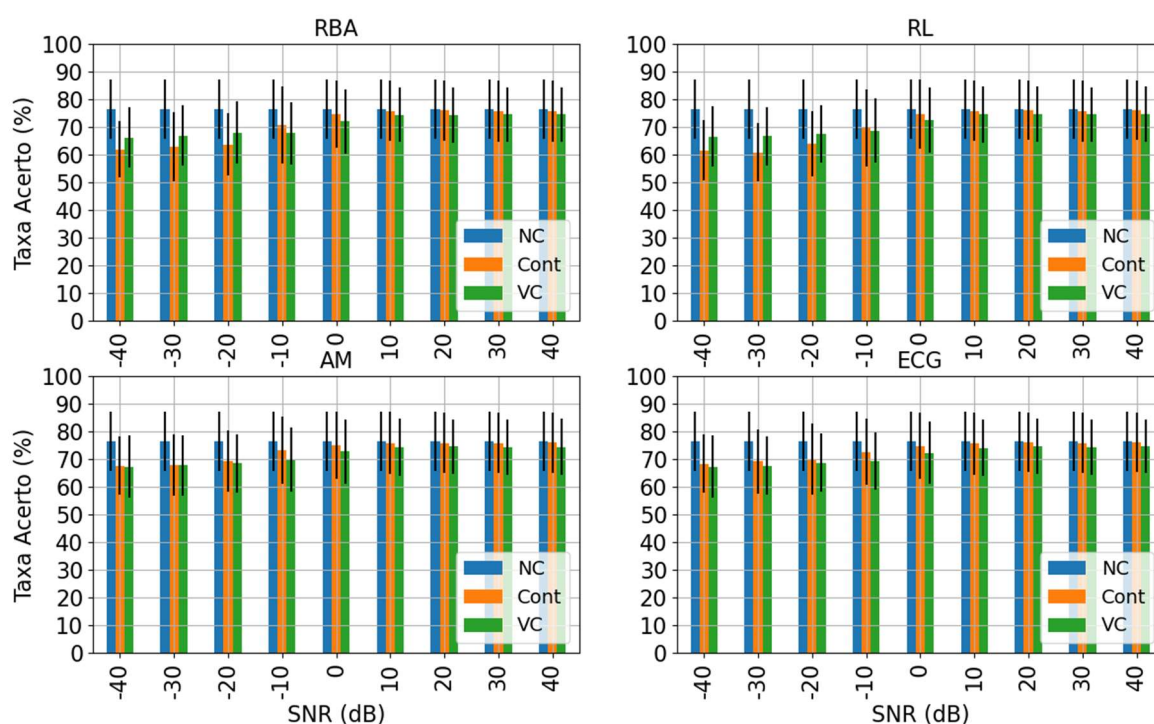
	A e C			
	RBA	RL	AM	ECG
-40				
-30				
-20				
-10				
0				
10				
20				
30				
40				

Tabela 34 – Teste Tukey comparando os grupos B e C.

	B e C			
	RBA	RL	AM	ECG
-40				
-30				
-20				
-10				
0				
10				
20				
30				
40				

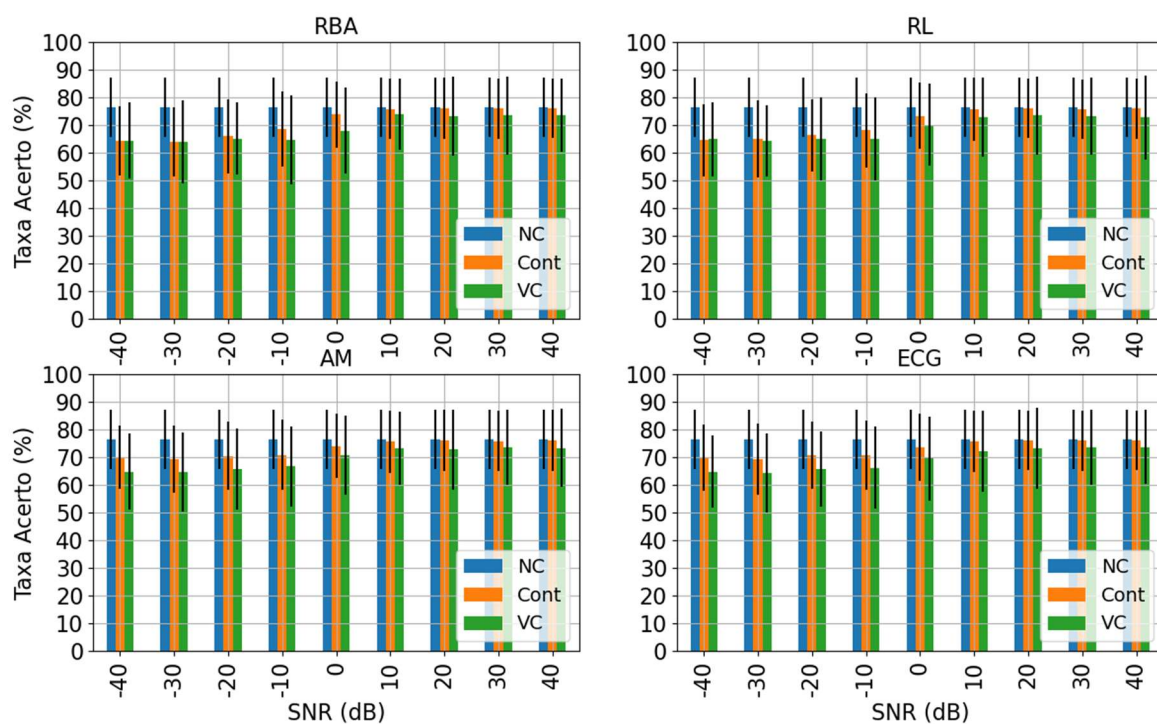
GRÁFICOS E TABELAS DO TESTE DO IAC COM SENSOR VIRTUAL BASE DB3 (AMPUTADOS).

Figura 58 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.



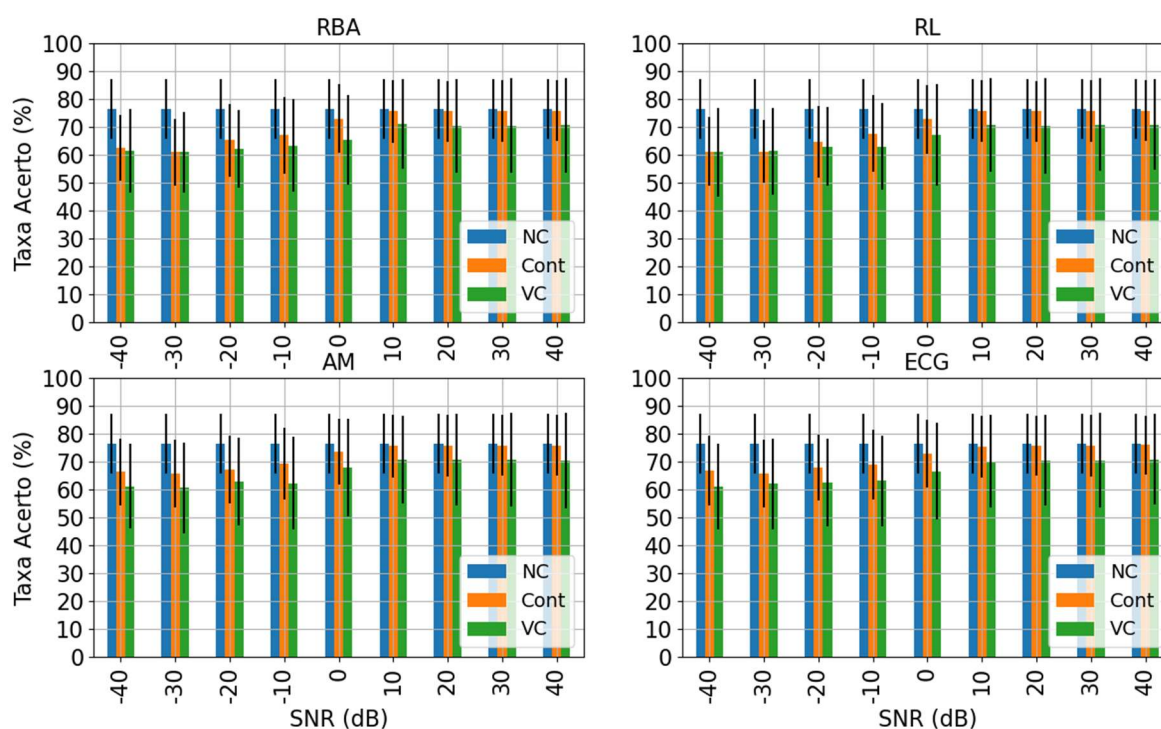
Fonte: Autor.

Figura 59 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.



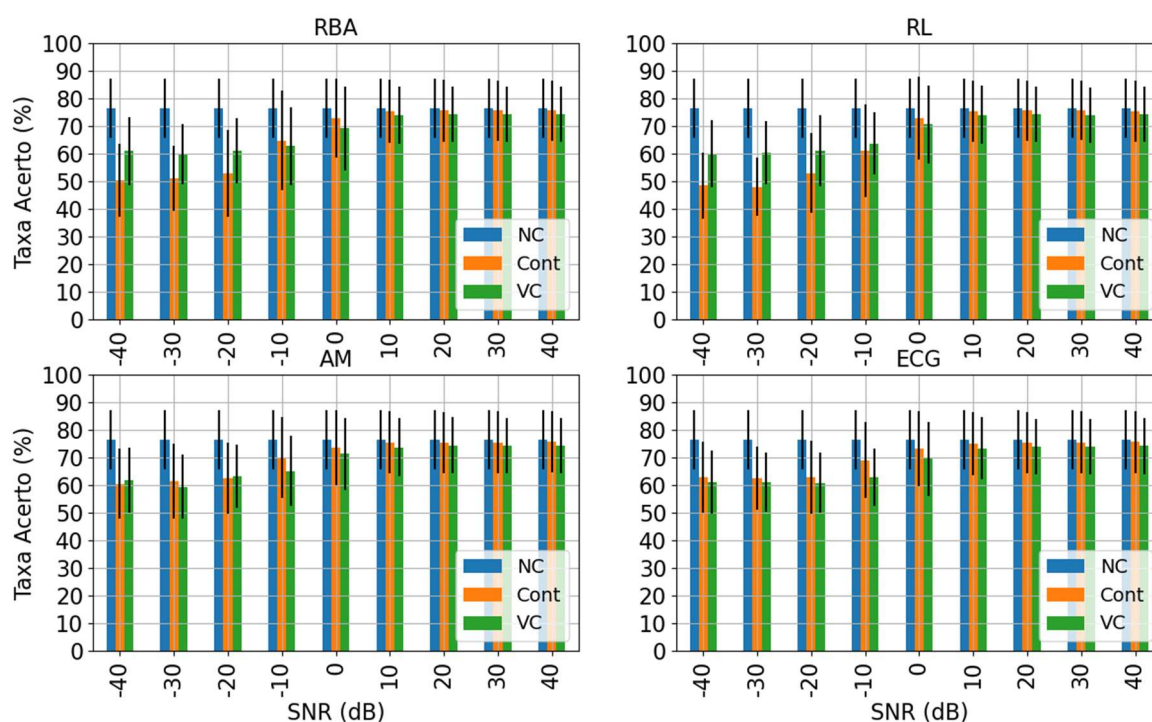
Fonte: Autor.

Figura 60 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 25% do sinal contaminado. Base DB3.



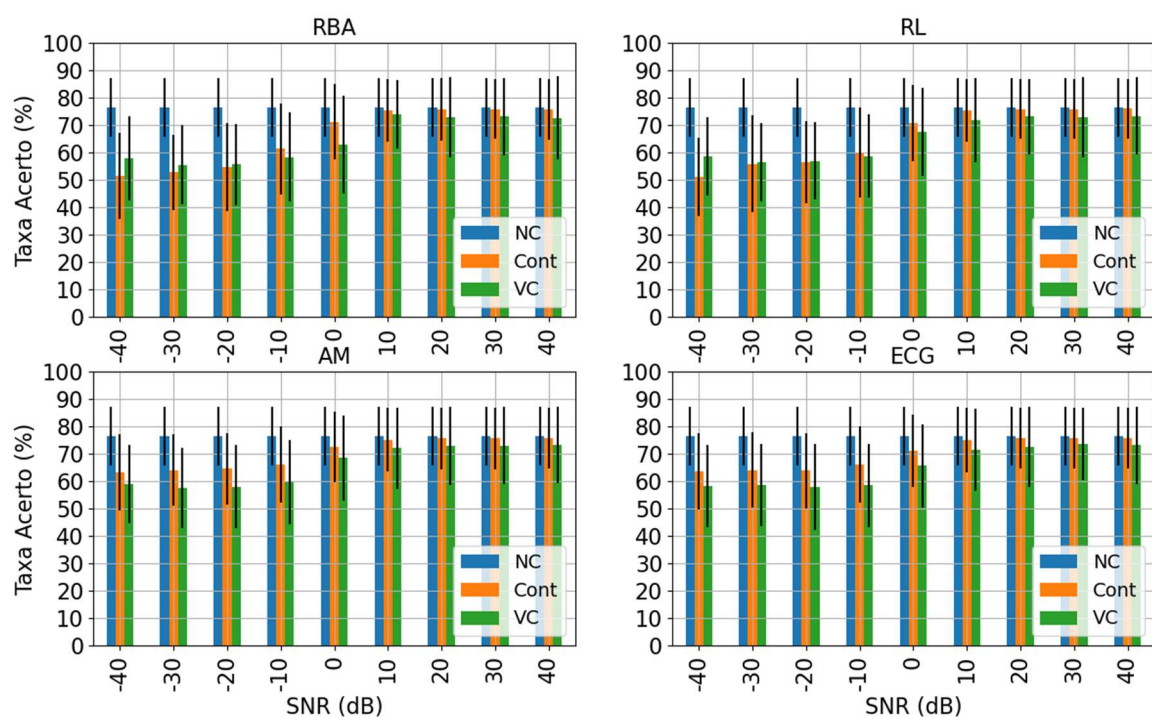
Fonte: Autor.

Figura 61 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 50% do sinal contaminado. Base DB3.



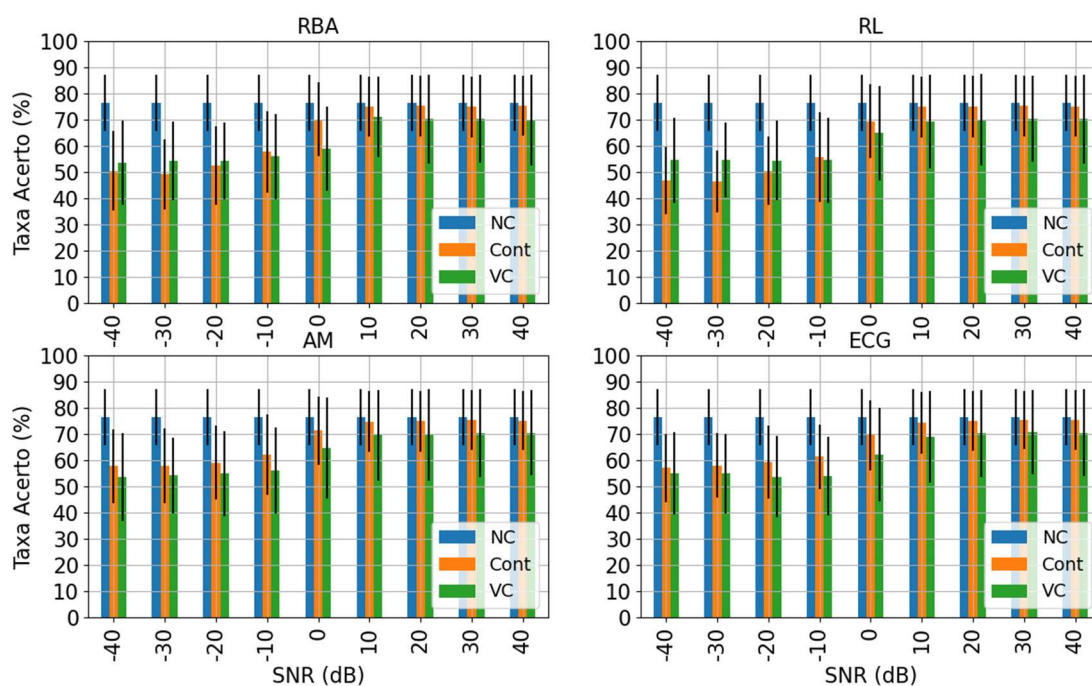
Fonte: Autor.

Figura 62 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 50% do sinal contaminado. Base DB3.



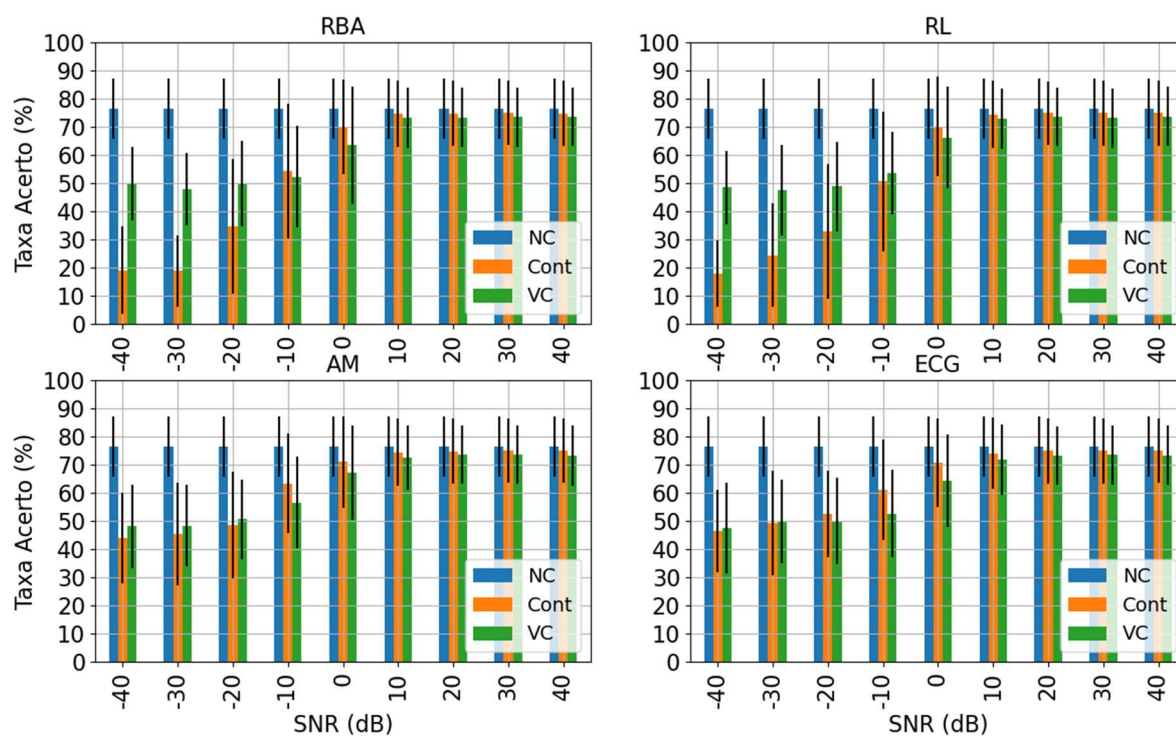
Fonte: Autor.

Figura 63 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 50% do sinal contaminado. Base DB3.



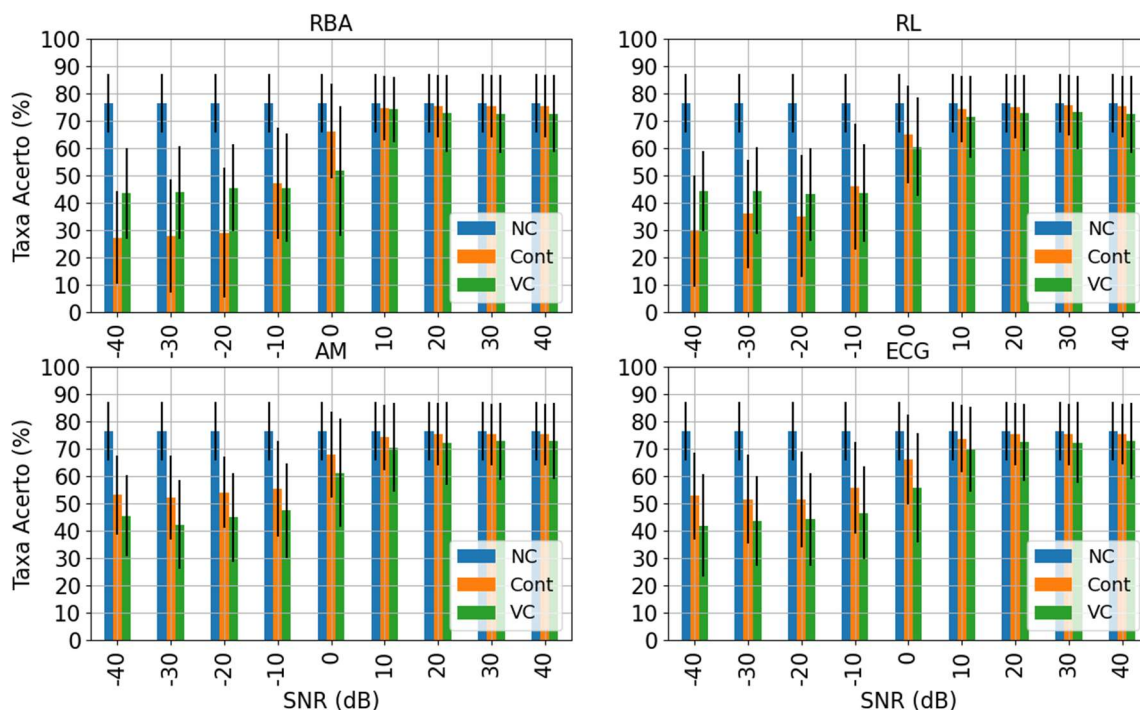
Fonte: Autor.

Figura 64 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.



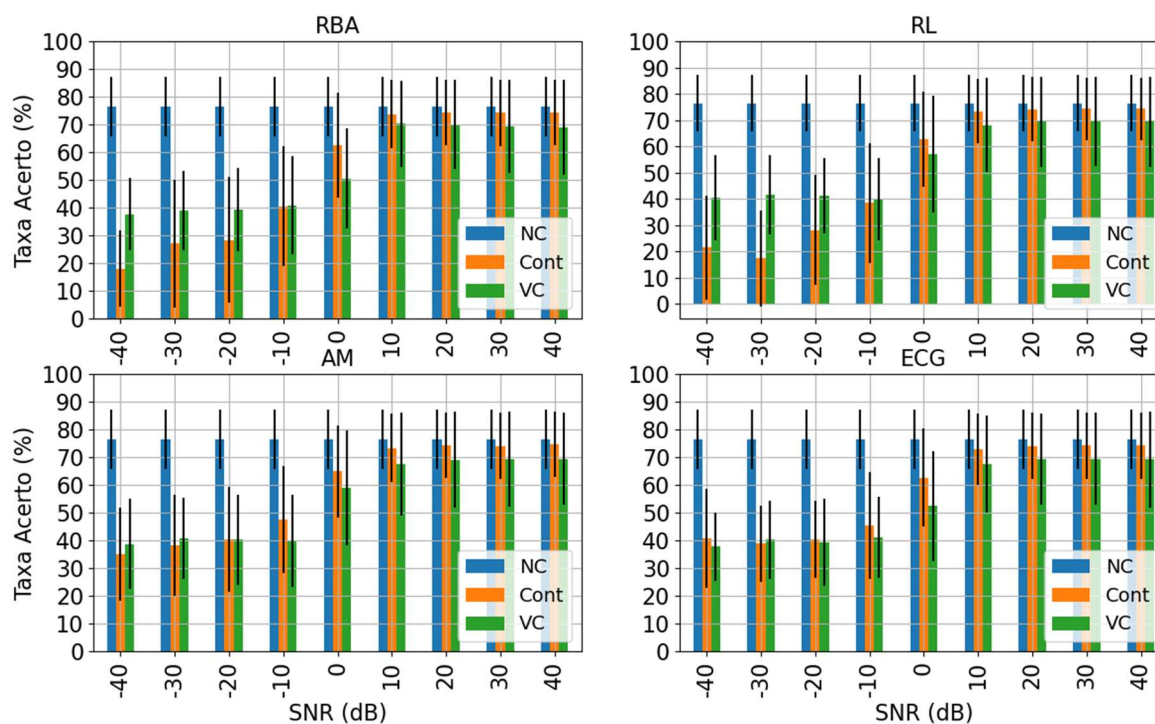
Fonte: Autor.

Figura 65 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.



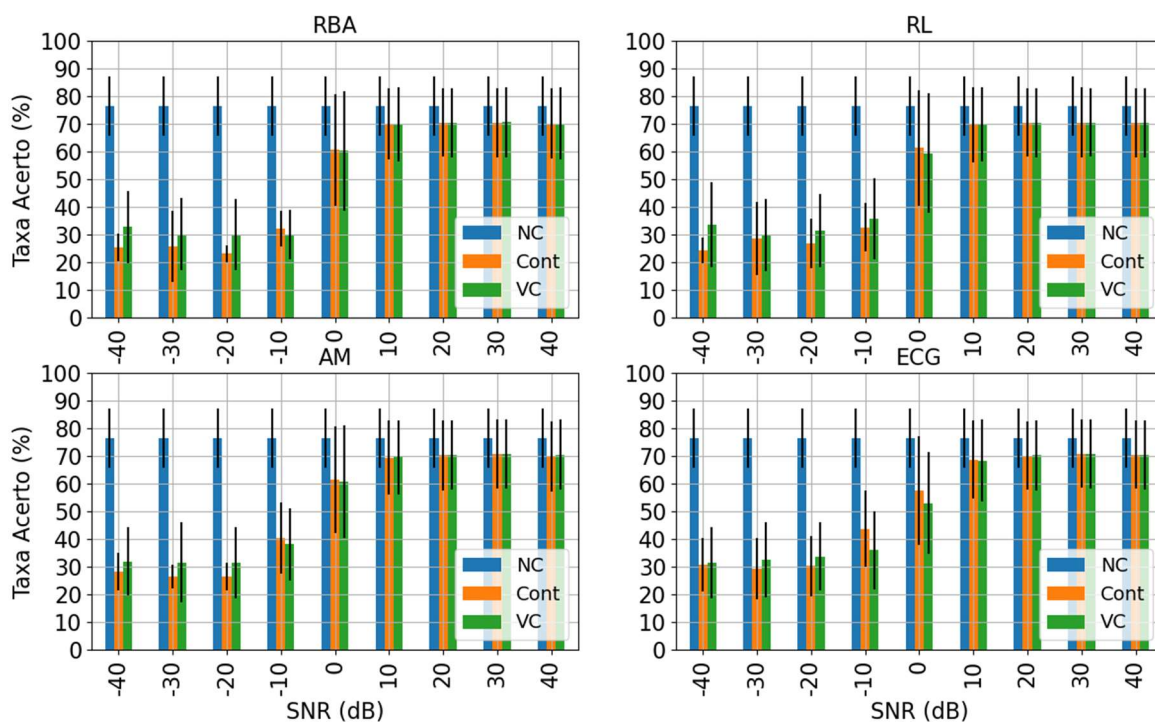
Fonte: Autor.

Figura 66 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 100% do sinal contaminado. Base DB3.



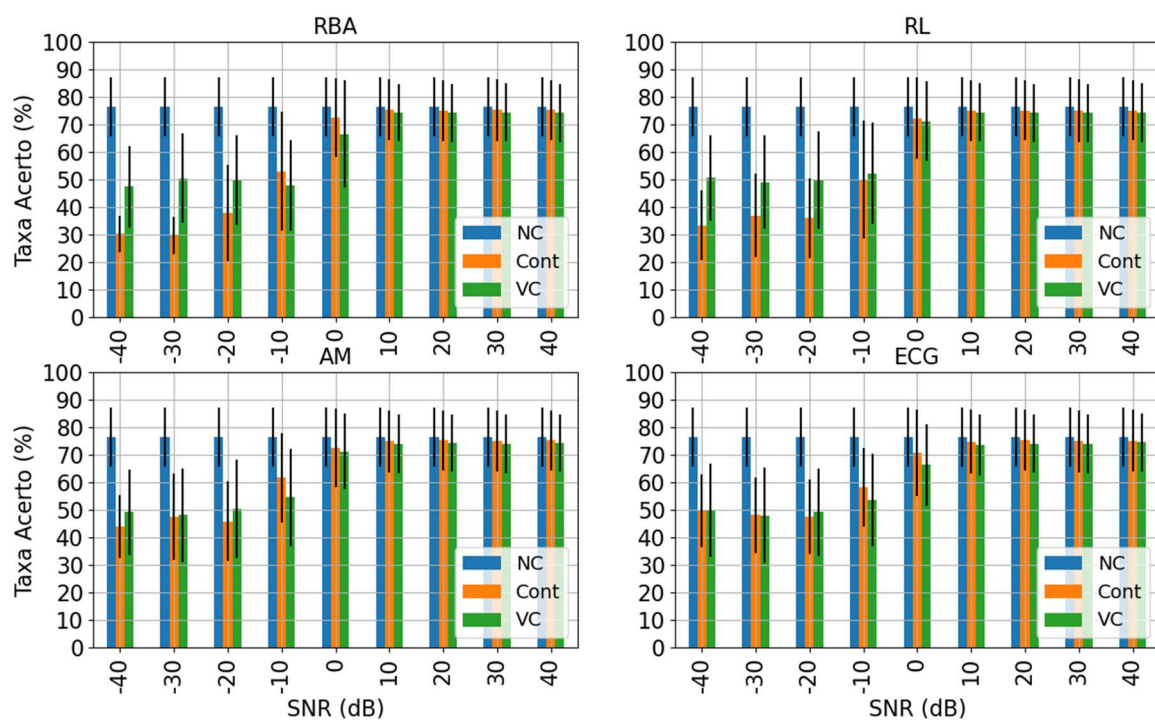
Fonte: Autor.

Figura 67 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 75% do sinal contaminado. Base DB3.



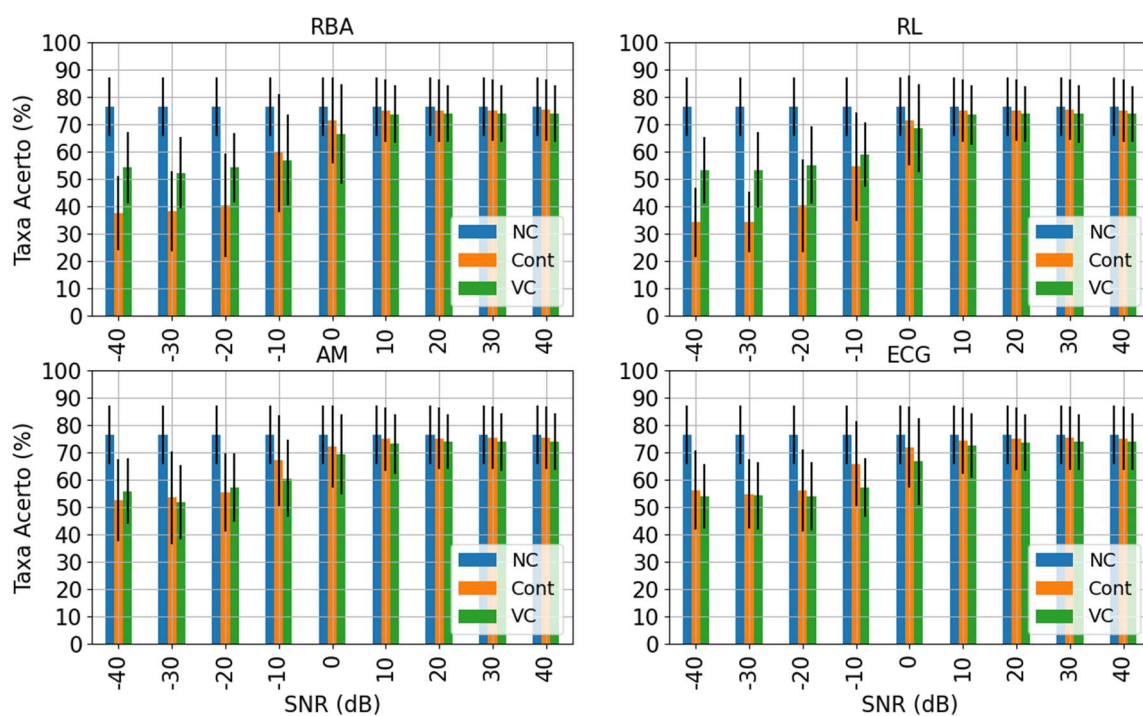
Fonte: Autor.

Figura 68 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 75% do sinal contaminado. Base DB3.



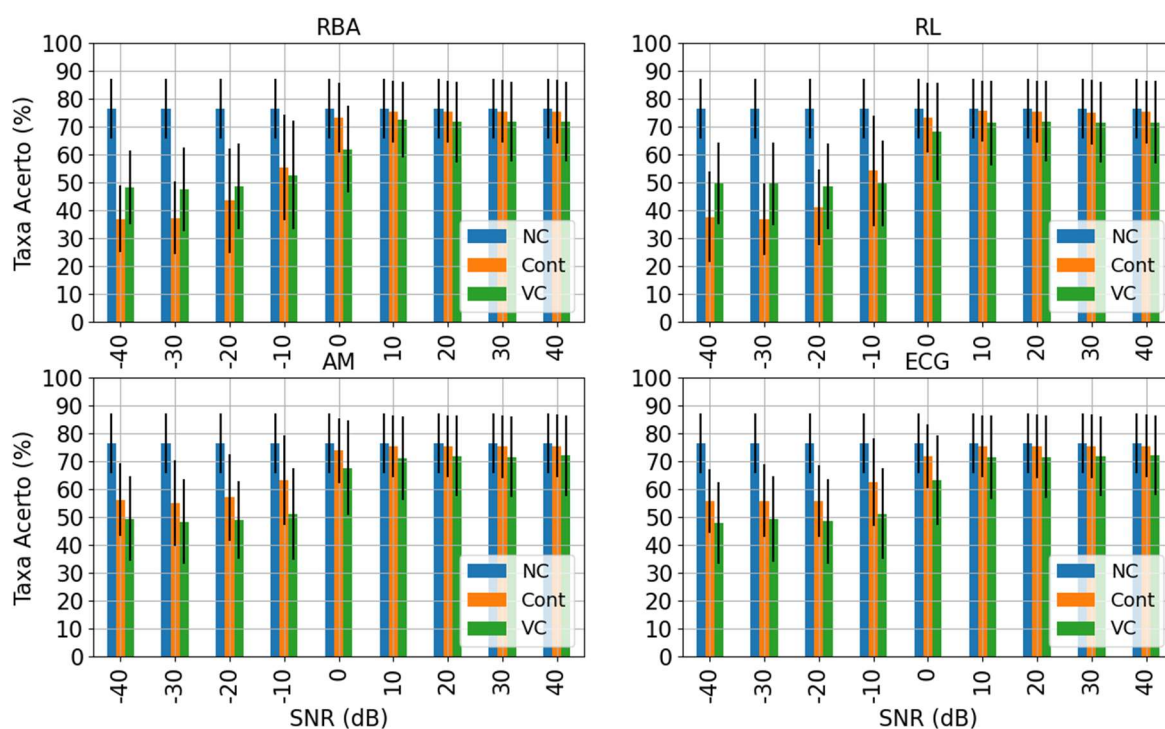
Fonte: Autor.

Figura 69 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 75% do sinal contaminado. Base DB3.



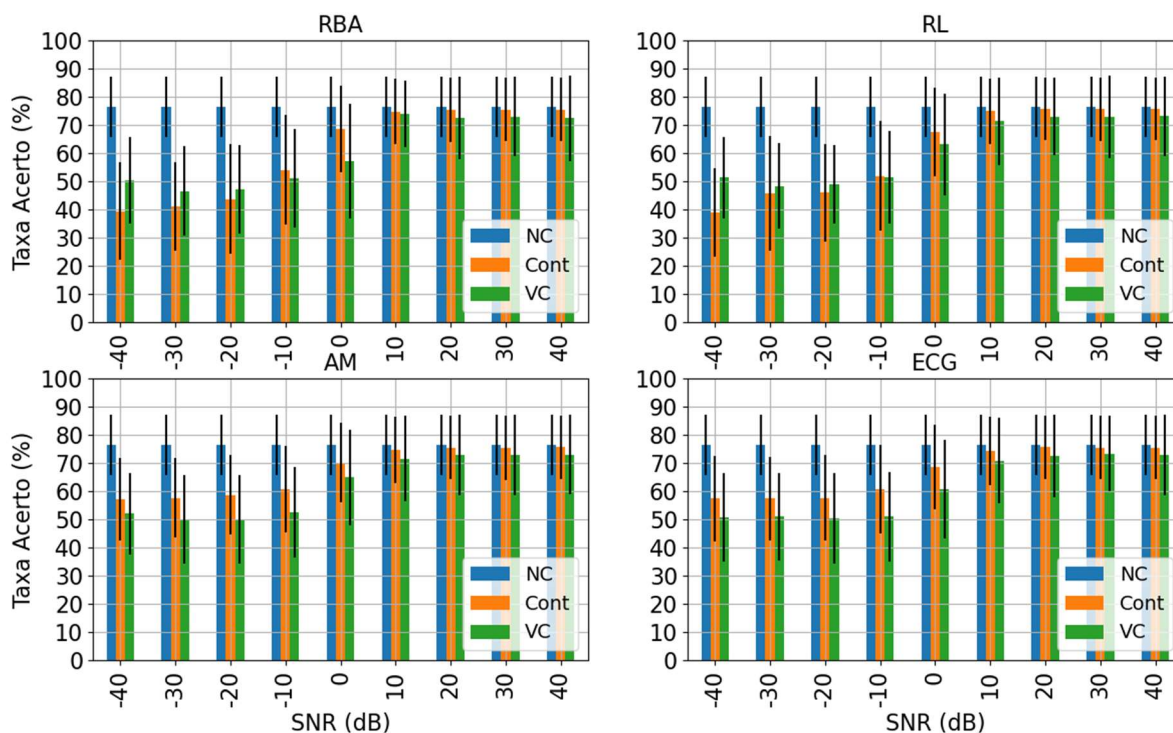
Fonte: Autor.

Figura 70 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 75% do sinal contaminado. Base DB3.



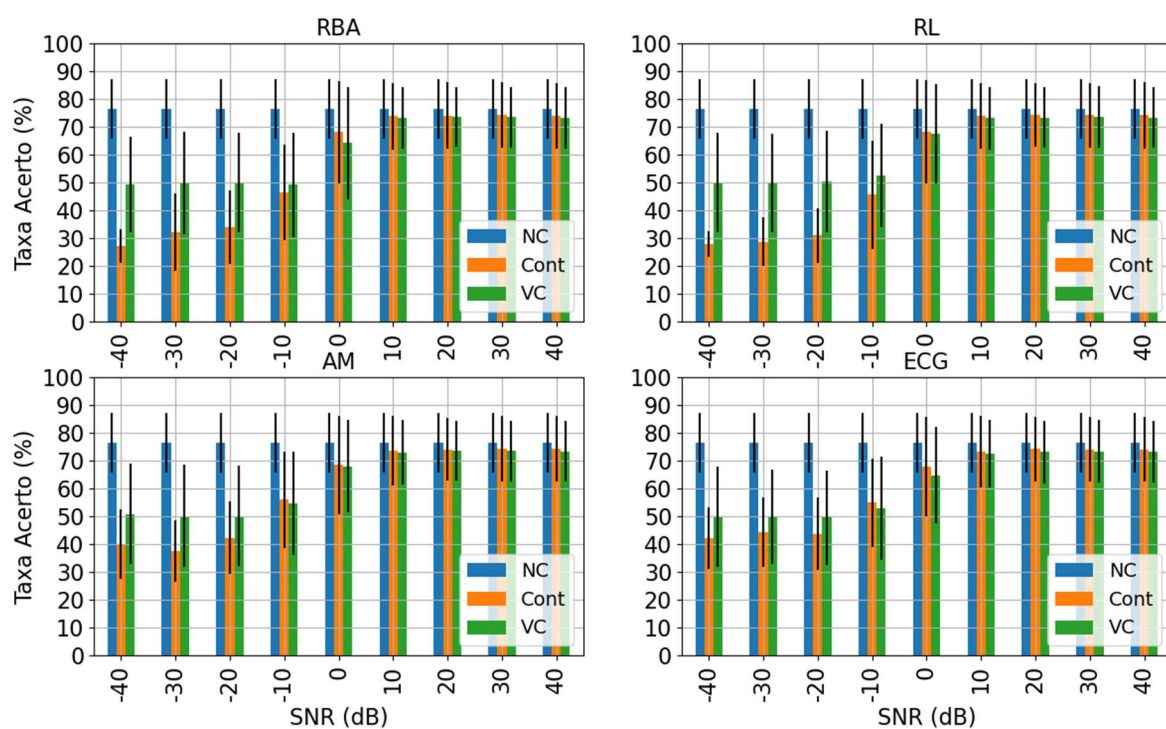
Fonte: Autor.

Figura 71 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 75% do sinal contaminado. Base DB3.



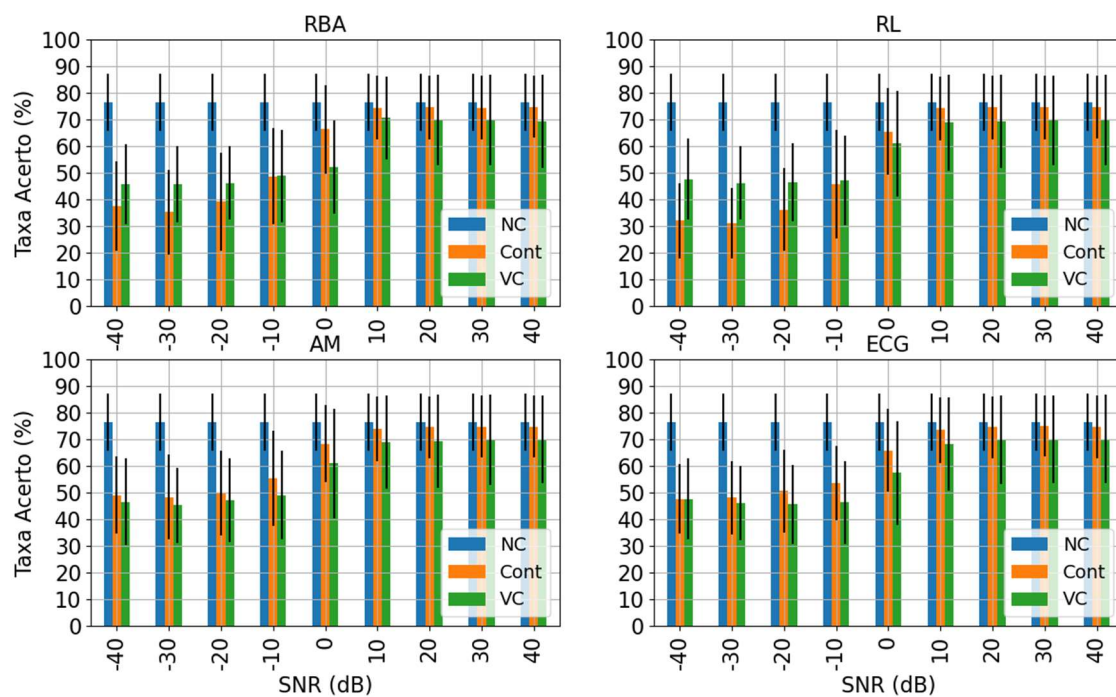
Fonte: Autor.

Figura 72 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 75% do sinal contaminado. Base DB3.



Fonte: Autor.

Figura 73 – Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 75% do sinal contaminado. Base DB3.



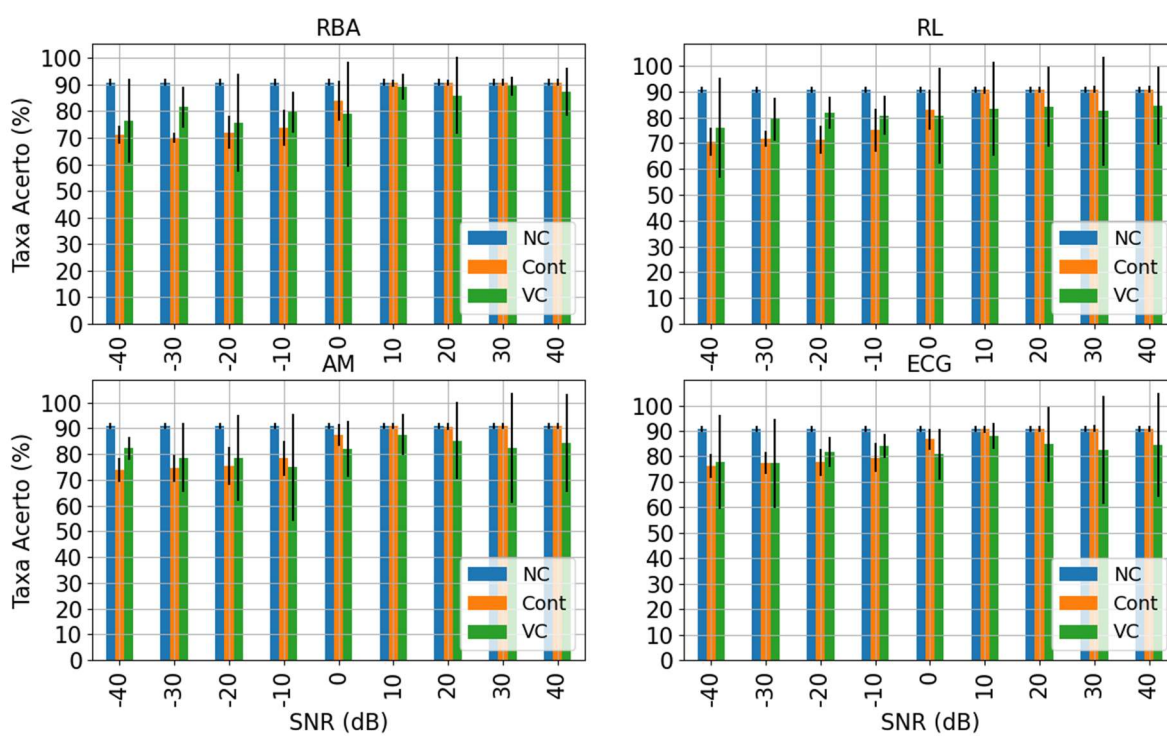
Fonte: Autor.

Tabela 35 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 75% de contaminação. Valores positivos indicam ganho de performance. Base DB3.

		Níveis SNR (dB)								
		-40	-30	-20	-10	0	10	20	30	40
Caso 1	RBA	7,32	4,50	6,97	-2,03	-0,40	-0,29	-0,13	0,30	0,10
	RL	9,13	1,26	4,61	3,15	-1,83	0,17	-0,09	0,03	-0,06
	AM	3,70	5,07	5,03	-2,38	-0,60	0,08	0,23	-0,19	0,58
	ECG	0,68	3,11	3,44	-7,58	-4,57	-0,40	0,07	-0,25	-0,21
Caso 2	RBA	17,13	20,97	11,98	-5,24	-5,79	-0,89	-0,94	-0,87	-1,02
	RL	17,21	12,13	13,93	2,38	-1,12	-0,70	-0,94	-0,87	-0,80
	AM	5,23	0,61	4,51	-7,09	-1,38	-0,96	-0,95	-0,96	-0,97
	ECG	0,17	-0,13	1,57	-4,71	-4,48	-1,14	-1,21	-0,91	-0,66
Caso 3	RBA	16,81	14,15	13,89	-2,57	-4,89	-1,19	-1,18	-1,36	-1,40
	RL	19,08	19,04	14,86	4,25	-2,71	-1,51	-1,33	-1,68	-1,18
	AM	3,20	-1,64	1,58	-6,45	-2,84	-1,74	-1,20	-1,50	-1,45
	ECG	-2,14	-0,68	-1,93	-8,98	-5,20	-1,73	-1,44	-1,43	-1,23
Caso 4	RBA	11,38	10,25	5,08	-2,83	-11,44	-2,87	-3,75	-3,67	-3,63
	RL	12,07	12,69	7,46	-4,58	-5,08	-4,28	-3,47	-3,64	-3,64
	AM	-6,81	-6,71	-7,94	-12,18	-6,14	-4,22	-3,49	-3,64	-3,36
	ECG	-7,76	-6,61	-7,28	-11,37	-8,67	-4,05	-3,87	-3,42	-3,41
Caso 5	RBA	11,07	5,42	3,48	-3,01	-11,54	-0,72	-2,99	-2,54	-3,19
	RL	12,38	2,54	3,00	-0,48	-4,53	-3,54	-2,73	-2,79	-2,53
	AM	-5,20	-7,66	-8,59	-8,48	-5,20	-3,24	-2,61	-2,53	-2,57
	ECG	-6,73	-6,42	-7,39	-9,81	-7,95	-3,56	-3,13	-2,22	-2,69
Caso 6	RBA	22,16	17,69	16,08	2,68	-3,93	-0,56	-0,55	-0,81	-0,63
	RL	22,31	21,11	19,37	7,06	-0,84	-0,81	-0,97	-0,69	-0,80
	AM	10,68	12,56	7,88	-1,36	-0,61	-0,68	-0,50	-0,78	-0,86
	ECG	7,61	5,42	5,75	-2,06	-2,92	-0,73	-1,06	-0,67	-0,79
Caso 7	RBA	8,20	10,48	7,08	0,19	-14,08	-3,87	-4,69	-4,62	-5,41
	RL	15,59	15,12	10,32	1,38	-4,50	-5,38	-5,15	-4,75	-4,91
	AM	-2,49	-3,07	-2,66	-6,30	-7,43	-5,15	-5,12	-4,96	-4,81
	ECG	0,01	-2,12	-5,00	-7,34	-8,39	-5,22	-4,65	-4,89	-4,57


GRÁFICOS E TABELAS DO TESTE DO IAC COM SENSOR VIRTUAL BASE IEE.

Figura 74 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 25% do sinal contaminado. Base IEE.



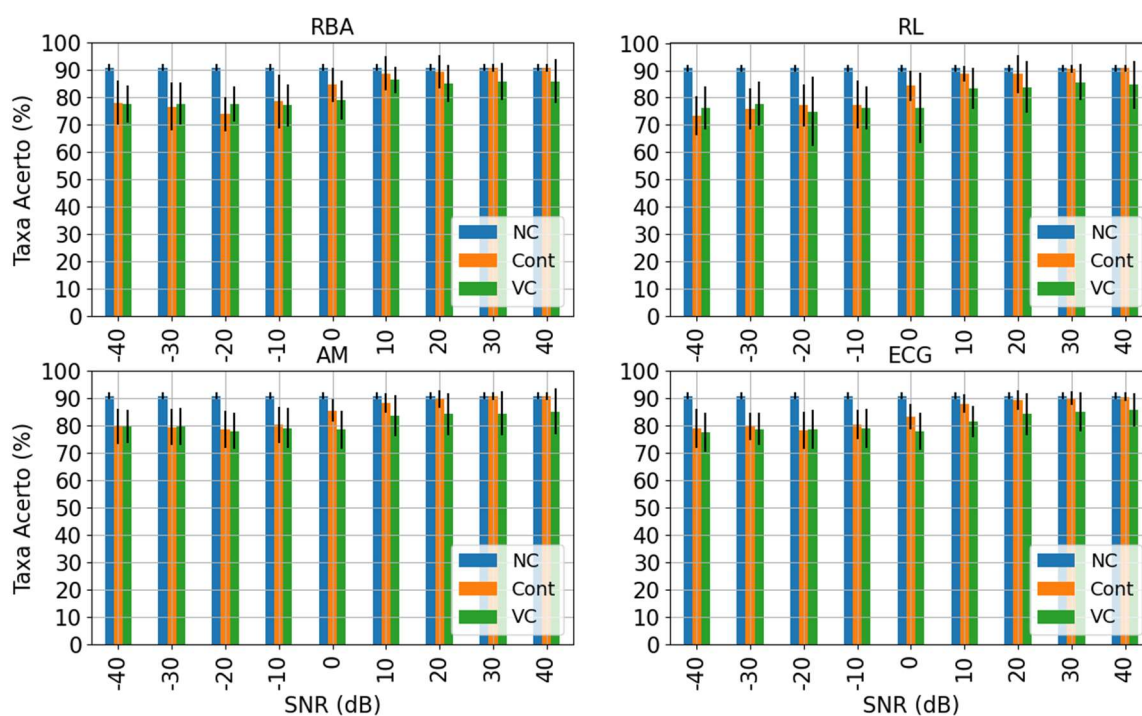
Fonte: Autor.

Figura 75 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 25% do sinal contaminado. Base IEE



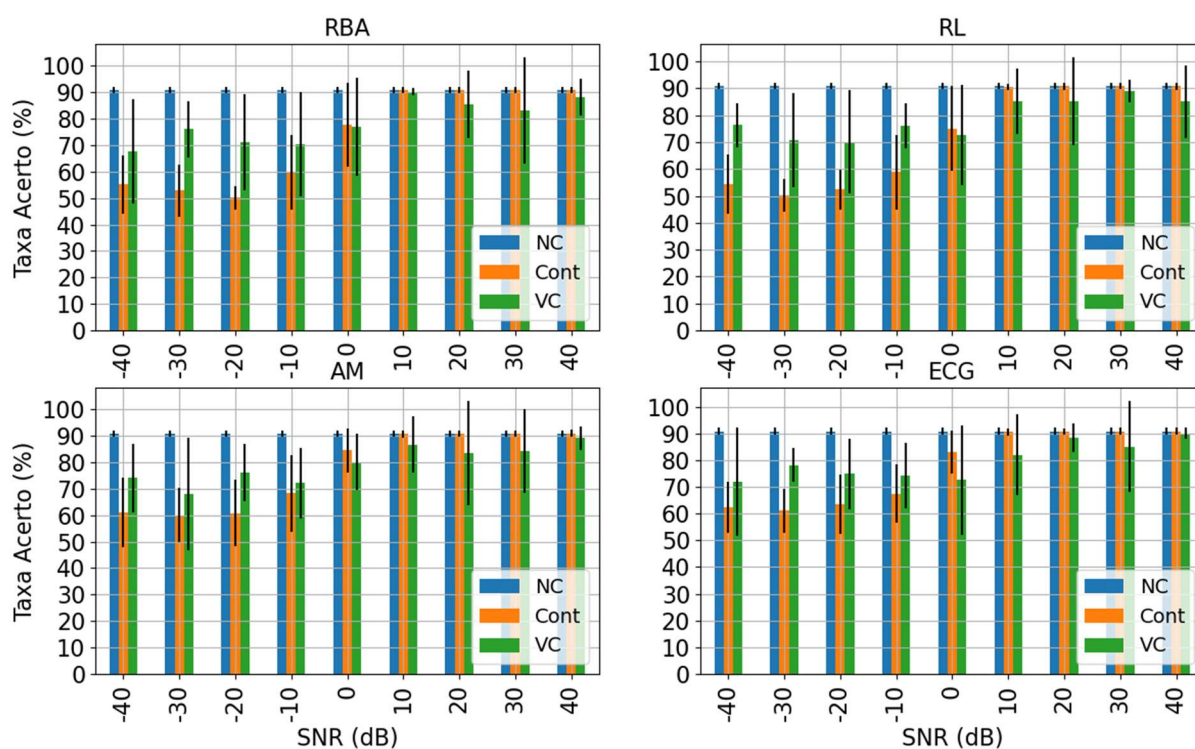
Fonte: Autor.

Figura 76 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 25% do sinal contaminado. Base IEE.



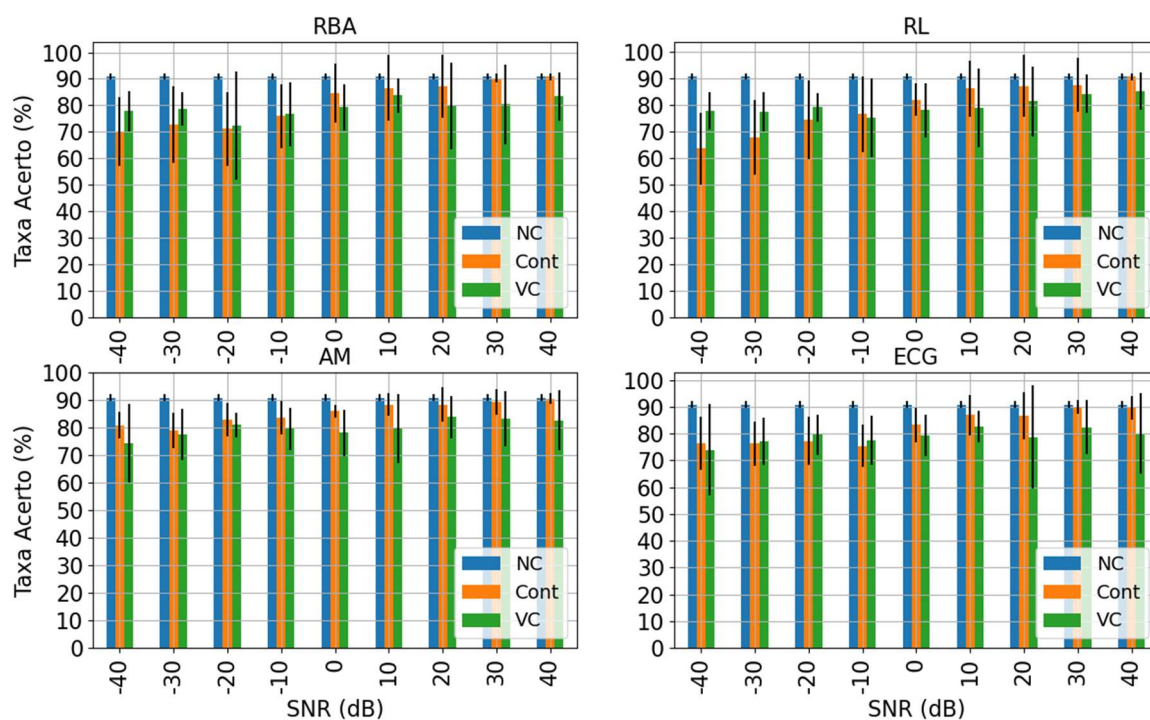
Fonte: Autor.

Figura 77 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.



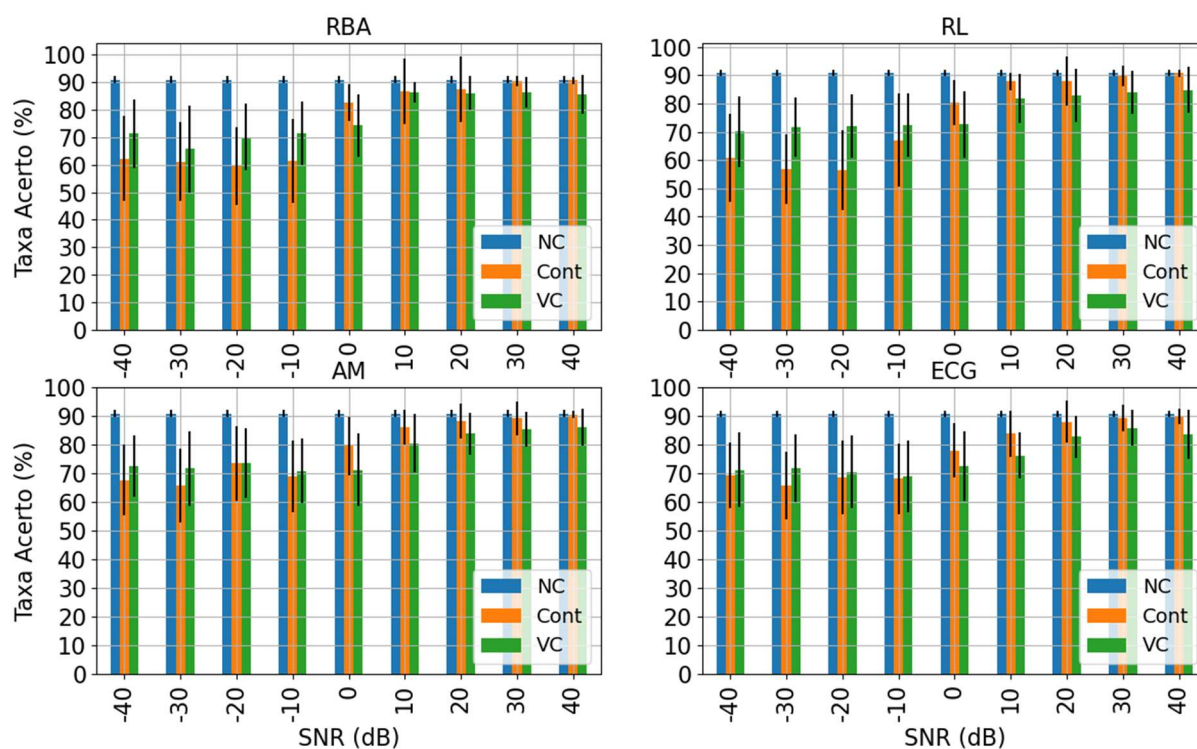
Fonte: Autor.

Figura 78 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.



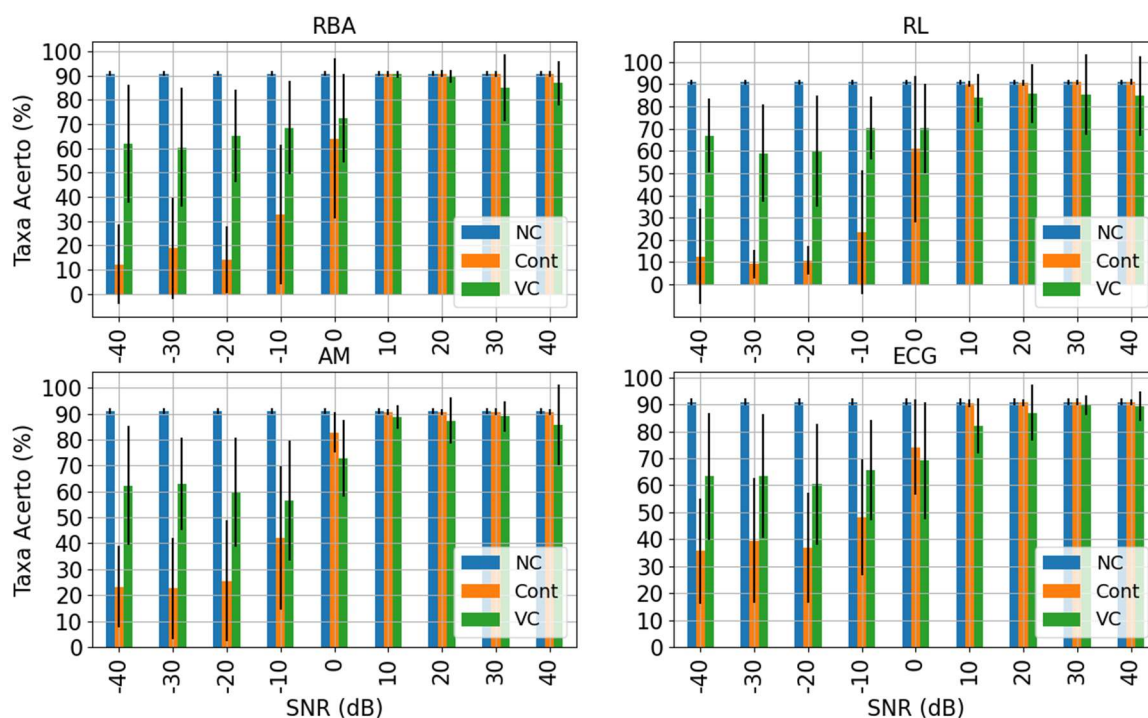
Fonte: Autor.

Figura 79 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 50% do sinal contaminado. Base IEE.



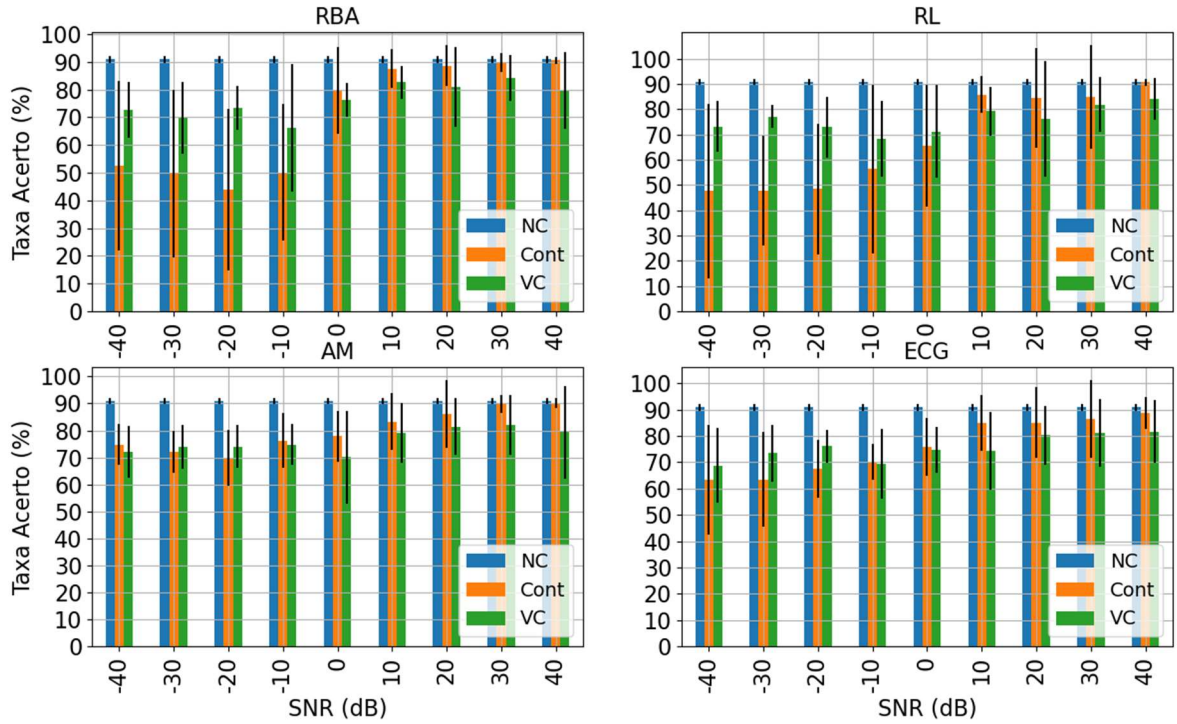
Fonte: Autor.

Figura 80 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.



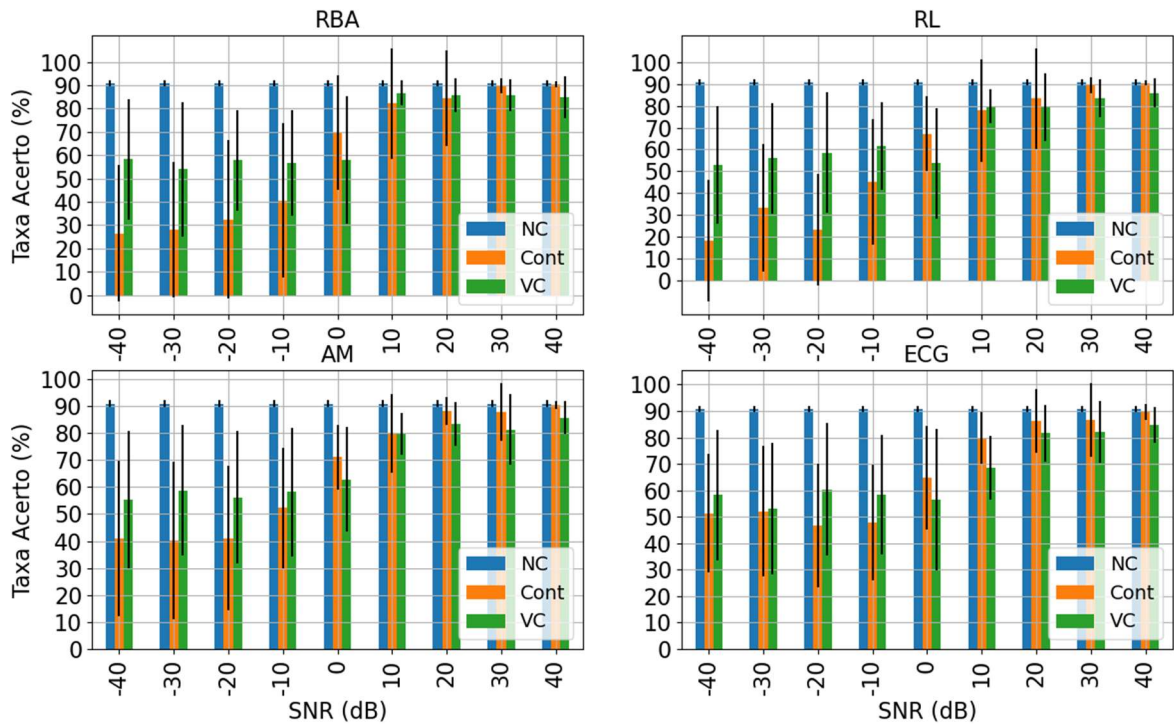
Fonte: Autor.

Figura 81 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.



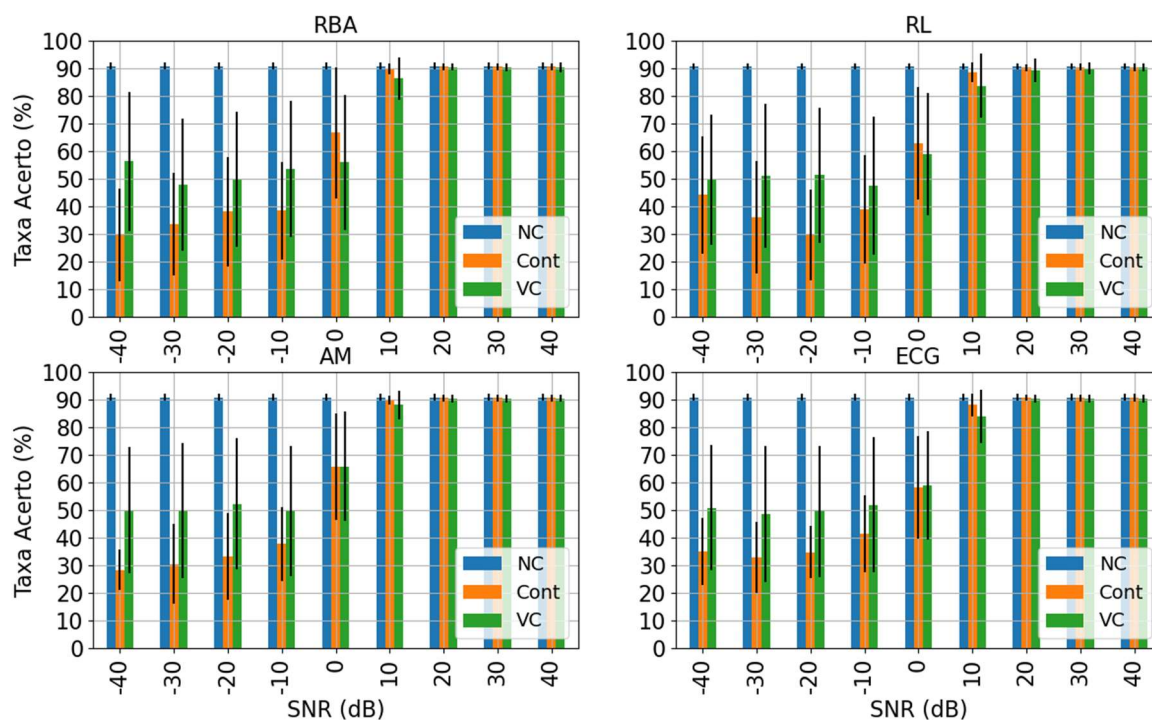
Fonte: Autor.

Figura 82 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 100% do sinal contaminado. Base IEE.



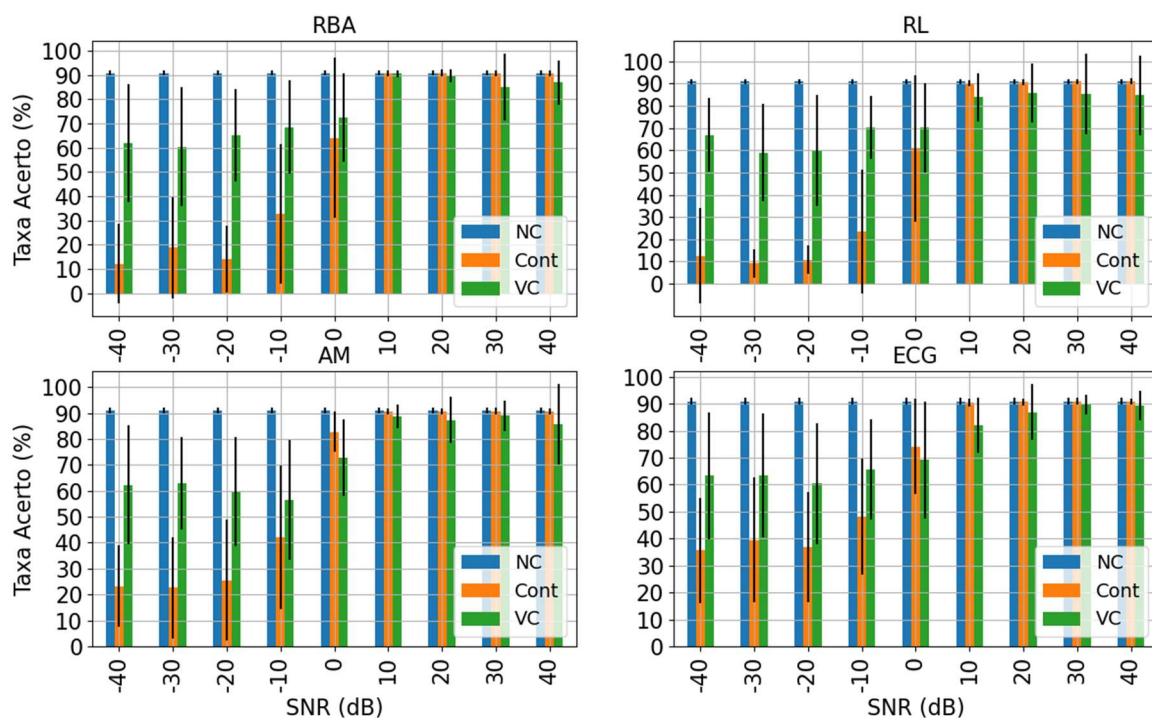
Fonte: Autor.

Figura 83 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 1 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.



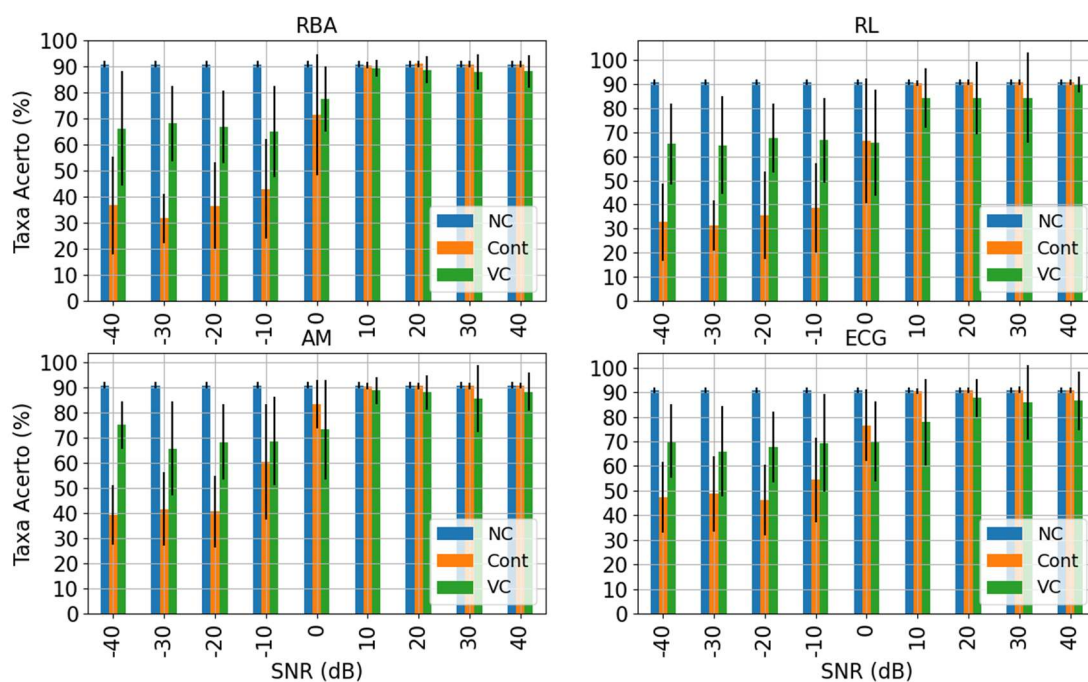
Fonte: Autor.

Figura 84 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 2 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.



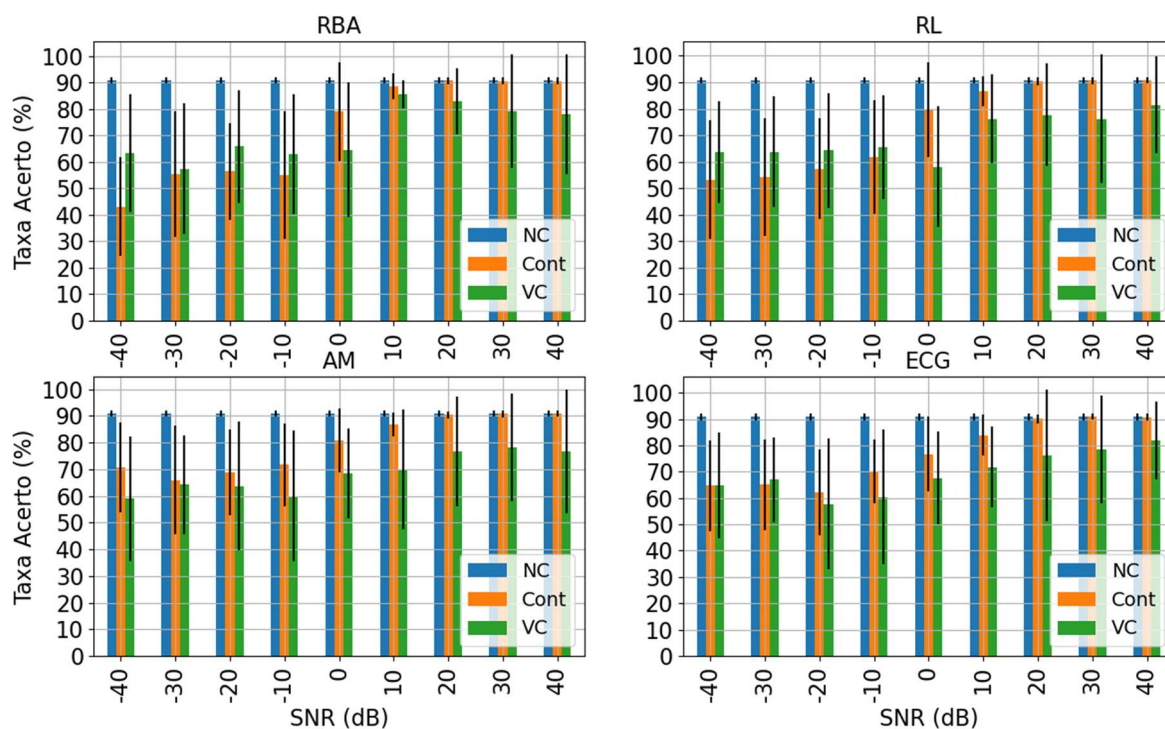
Fonte: Autor.

Figura 85 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 3 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.



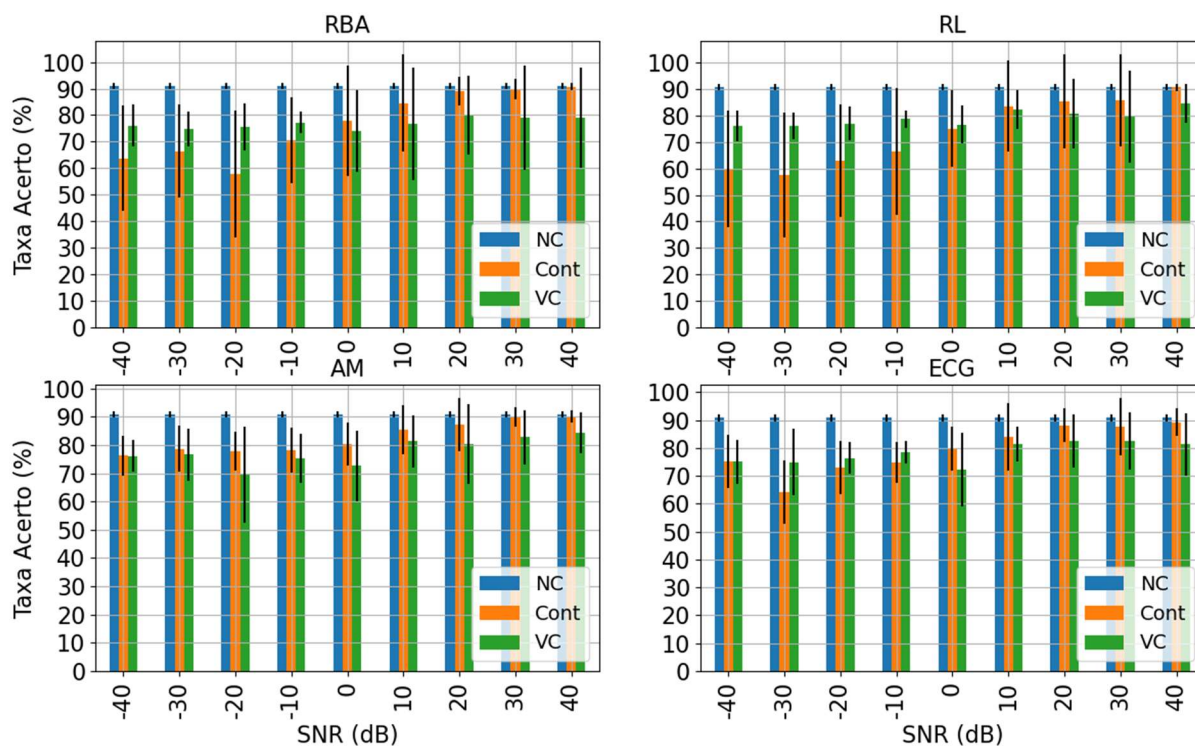
Fonte: Autor.

Figura 86 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 4 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.



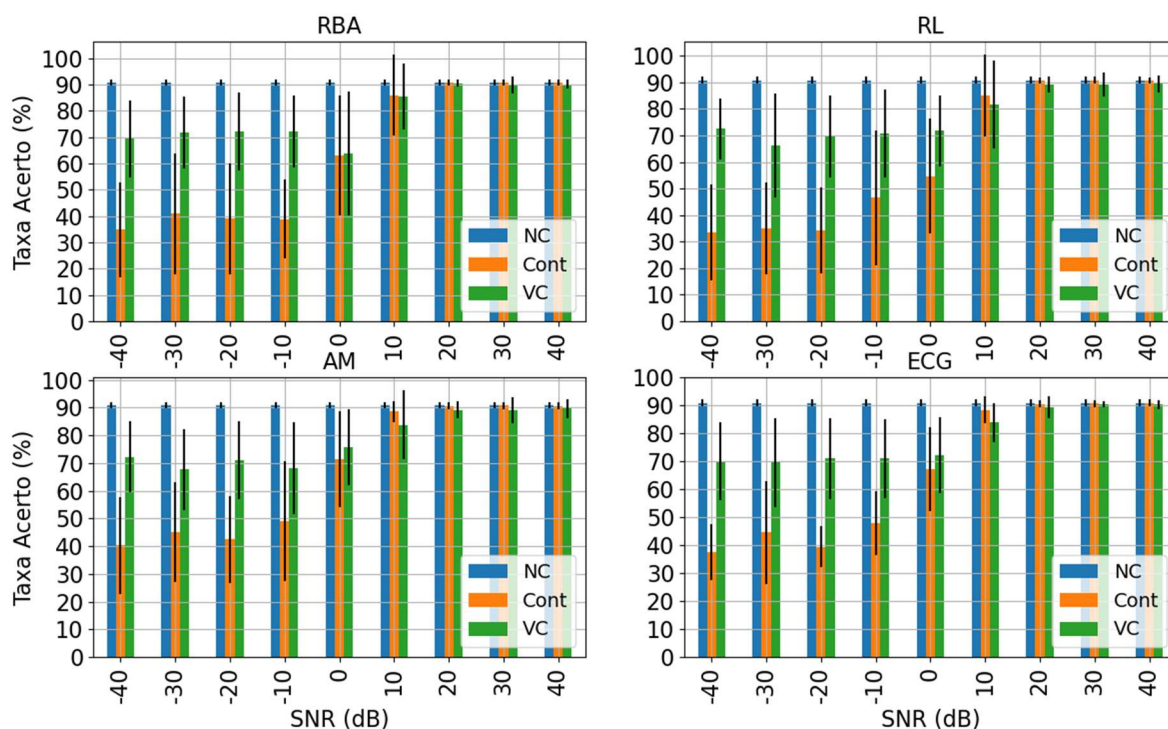
Fonte: Autor.

Figura 87 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 5 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.



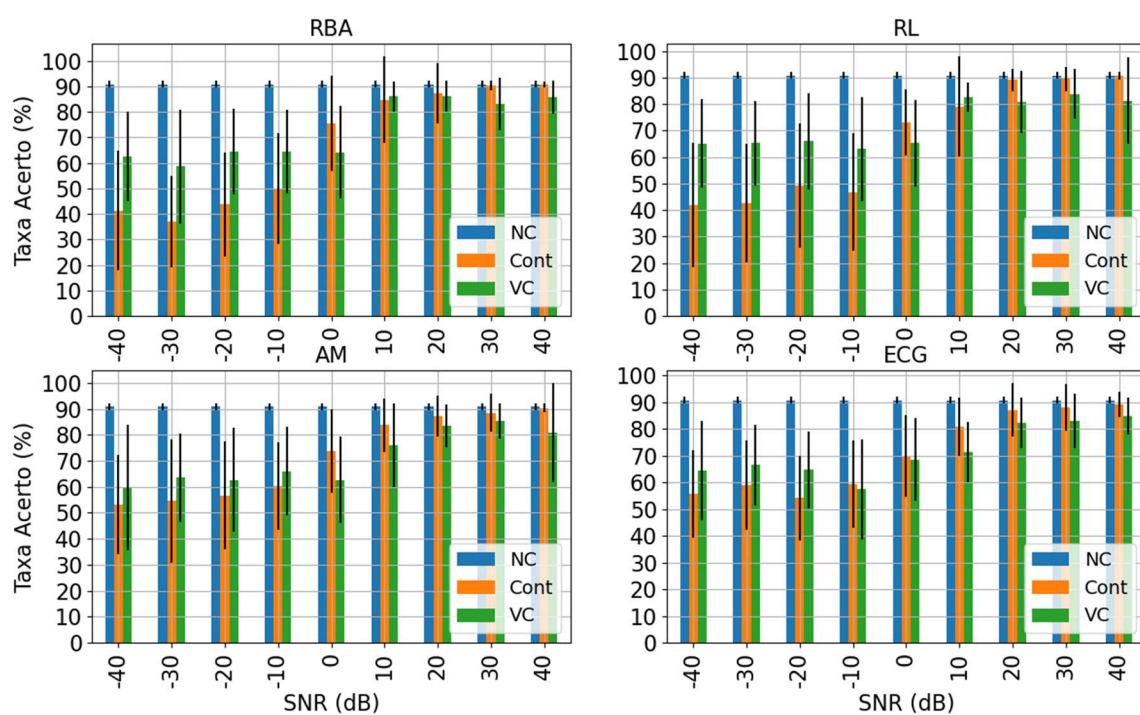
Fonte: Autor.

Figura 88 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 6 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.



Fonte: Autor.

Figura 89 - Efeito do sEMG não contaminado (NC), contaminado (CONT) e do sensor virtual + IAC (VC) para Amputados, no Caso 7 para todos contaminantes e considerando 75% do sinal contaminado. Base IEE.



Fonte: Autor.

Tabela 36 – Diferença absoluta, em %, entre VC e CONT para todos os casos com 75% de contaminação. Valores positivos indicam ganho de performance. Base IEE.

		Níveis SNR (dB)								
		-40	-30	-20	-10	0	10	20	30	40
Caso 1	RBA	29,34	10,97	16,21	19,99	-12,74	-2,73	-0,13	-0,18	-0,21
	RL	8,78	23,81	24,01	15,21	-4,46	-3,77	-0,65	-0,37	-0,04
	AM	25,00	21,28	21,16	17,06	-1,65	-1,34	-0,17	-0,08	-0,07
	ECG	19,21	18,33	16,01	10,21	-3,03	-3,36	-0,20	-0,16	-0,20
Caso 2	RBA	38,87	29,19	32,72	23,74	0,98	-2,59	-4,29	-0,54	-1,13
	RL	33,55	37,95	30,87	18,81	10,92	-1,63	-3,28	-3,64	-3,53
	AM	17,50	20,24	17,49	12,52	4,87	-3,57	-0,71	-2,42	-2,28
	ECG	17,16	20,36	12,01	12,48	5,63	-3,36	-0,62	-0,51	-0,80
Caso 3	RBA	35,32	38,55	31,25	23,00	3,45	-1,43	-2,29	-2,71	-2,35
	RL	37,16	36,92	33,40	28,66	-2,25	-4,82	-5,78	-6,55	-1,19
	AM	36,01	25,39	27,56	9,08	-9,32	-2,01	-2,65	-4,48	-2,23
	ECG	24,08	21,35	22,00	16,62	-6,43	-11,93	-2,83	-4,84	-3,60
Caso 4	RBA	20,70	3,14	6,73	3,20	-14,76	-2,66	-7,00	-10,94	-12,37
	RL	13,68	14,32	6,22	0,54	-23,25	-9,90	-11,30	-12,65	-9,38
	AM	-7,74	-2,32	-3,04	-13,34	-17,02	-14,98	-12,33	-10,78	-13,31
	ECG	1,02	-0,86	-3,38	-10,46	-14,36	-13,66	-12,42	-10,44	-10,54
Caso 5	RBA	18,70	9,67	14,89	8,70	-6,69	-6,81	-10,06	-8,76	-12,30
	RL	17,39	26,05	15,66	11,72	-1,80	-2,93	-4,02	-5,21	-8,19
	AM	2,03	0,32	-2,39	-0,89	-10,11	-3,68	-5,74	-6,59	-3,57
	ECG	0,69	6,86	4,06	2,87	-8,15	-5,86	-6,22	-4,50	-7,86
Caso 6	RBA	32,73	32,51	37,92	35,20	5,52	-1,47	-2,31	-1,22	-3,78
	RL	39,37	32,29	36,99	28,08	19,01	-5,46	-1,47	-1,58	-1,52
	AM	32,09	25,22	31,43	19,05	6,02	-4,55	-1,51	-1,68	-1,50
	ECG	29,81	28,65	31,91	24,31	7,13	-3,33	-2,26	-1,06	-1,15
Caso 7	RBA	21,21	17,41	19,16	9,53	-11,38	0,04	-4,98	-7,17	-6,38
	RL	25,17	20,00	13,35	8,79	-13,13	-0,01	-9,84	-7,53	-11,19
	AM	5,47	3,68	8,74	1,55	-13,05	-9,71	-5,25	-6,48	-11,07
	ECG	7,84	5,36	8,03	-1,97	-7,05	-11,63	-6,86	-6,25	-6,64