

# UMA AVALIAÇÃO DO DESEMPENHO DE UMA REDE NEURAL EXTREME LEARNING MACHINE (ELM) APLICADO A SINAIS DE ELETROMIOGRAFIA DE SUPERFÍCIE (SEMGE)

ALTER D. D. N. SANTOS\*, FRANCISCO D. A. BOLDT\*\*, RICHARD J. M. G. TELLO\*\*

\*PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO (PROPECAUT),  
IFES, SERRA, MANGUINHOS, 29173-087, BRASIL  
E-MAILS: ALTERDIEGU@HOTMAIL.COM

\*\*COORDENADORIA DE AUTOMAÇÃO INDUSTRIAL E INFORMÁTICA,  
IFES, SERRA, MANGUINHOS, 29173-087, BRASIL  
E-MAILS: FRANCISCOA@IFES.EDU.BR, RICHARD@IFES.EDU.BR

**Abstract:** This paper aims to evaluate the classification of hand gestures for the implementation of a robotic prosthesis. The data were generated by capturing Surface Electromyography (sEMG) signs of pre-defined gestures. The features used were: Root Mean Square (RMS), Fourth Order Auto-regressive Coefficients (AR), Integral of Absolute Value (IAV) and Waveform Length (WL). The classification performance were compared by using the techniques of Linear Discriminant Analysis (LDA), Quadratic Discriminant Analysis (QDA), Linear Bayesian Classifier (BC Linear), Quadratic Bayesian Classifier (Quadratic BC), Discriminant Analysis by Mahalanobis Distances and an Single Layer Feedforward Artificial Neural Network "Extreme Learning Machine" (ELM) adapted by Boldt (2017). A comparative analysis was performed identifying the classification by ELM algorithm as the most effective, reaching an average F1-Score of 90,75% and an accuracy of 90,61% after an 8-fold validation.

**Key words:** Pattern Recognition, Surface Electromyography, Gesture Recognition, Root Mean Square, Fourth Order Auto-Regressive Coefficients, Integral of Absolute Value, Waveform Length, Linear Discriminant Analysis, Extreme Learning Machine, Classification.

**Resumo** ↓ Este artigo visa avaliar os resultados da classificação de gestos da mão visando a implementação de uma prótese robótica. Os dados capturados de sinais de Eletromiografia de Superfície (sEMG) gerados a partir de gestos pré-definidos. As características utilizadas para classificação foram: Raiz Média Quadrática (RMS), Coeficientes Auto-regressivos de Quarta Ordem (AR), Integral de Valor Absoluto (IAV) e Comprimento de Forma de Onda (WL). A classificação é testada individualmente pelas técnicas de Análise de Discriminantes Lineares (LDA), Análise de Discriminantes Quadráticos (QDA), classificador Bayesiano Linear (BC Linear), classificador Bayesiano Quadrático (BC Quadrático), Análise de discriminantes por distâncias de Mahalanobis e uma Rede Neural Artificial do tipo "Single Layer Feedforward Network - Extreme Learning Machine" (ELM) adaptada por Boldt (2017). A partir dos resultados obtidos foi realizada uma análise comparativa identificando a classificação por ELM como a mais eficaz atingindo F1-Score médio de 90,75% e uma taxa de acerto de 90,61% em testes realizados a partir da validação 8-fold.

**Palavras-chave** ↓ Reconhecimento de Padrões, Eletromiografia de Superfície, Reconhecimento de gestos, Raiz Média Quadrática, Coeficientes Auto-regressivos de Quarta ordem, Integral de Valor Absoluto, Comprimento de Forma de Onda, Análise de Discriminantes Lineares, Extreme Learning Machine, Classificação.

## 1 Introdução

Diferentes soluções são buscadas para reabilitação de membros amputados, sendo a técnica de reabilitação através de próteses robóticas uma das linhas com maior destaque atualmente conforme o grande número de pesquisas presentes na literatura (AKIRMAK et al., 2017 - ZHANG et Al. 2017 - MATRONE et al., 2012).

No caso das pessoas amputadas, padrões a partir de sinais de Eletromiografia (EMG) provenientes de membros remanescentes ainda podem ser identificados, mesmo após anos, possibilitando a extração desses sinais remanescentes para interpretação, tratamento e posterior controle de uma prótese de mão artificial (FARINA, 2014). O sinal de EMG pode ser obtido através de eletrodos superfície fixados sobre a pele do indivíduo, sendo denominado de EMG de Superfície (sEMG). Este método de aquisição de sinais é amplamente utilizado em pesquisas e implementações de próteses robóticas

devido a sua flexibilidade, facilidade de manuseio e pelo fato de ser um método não invasivo (GEETHANJALI, 2016)

Já existem algumas próteses lançadas no mercado, como por exemplo, a prótese de mão i-LIMB ultra da empresa Touch Bionics, que foi a primeira a oferecer o comando dos 5 dedos de forma independente, outras próteses comerciais conhecidas são a Bebionic3 da empresa RSLSteeper, a Michelangelo da empresa Otto Bock Healthcare Product GmbH e a DEKA arm produzida pela empresa Deka Integrated Solutions Corporation (TELLO, 2013; AKIRMAK et al., 2017).

Apesar de décadas de pesquisas, as próteses de mão baseadas em controle por classificação de sinais sEMG ainda têm muito a evoluir principalmente nos aspectos de custos acessíveis, confiabilidade, robustez e capacidade de movimentos. A aceitação deste tipo de prótese pelo usuário final ainda é pequena, devido necessidade comercial de que estes sistemas também atuem de forma mais natural (intuitividade), possuam maior grau de conforto para o usuário (redução do

peso, quantidade menor de sensores). Os estudos recentes são promissores, porém ainda estão longe de atender as necessidades do uso na prática de um usuário comum. (ATZORI, 2015- FARINA, 2014- GEETHANJALI, 2016)

As técnicas de reconhecimento de gestos a partir de tarefas motoras usando sinais de eletromiografia de superfície (sEMG) podem ser resumidas em um modelo que se inicia com a extração dos bio-sinais, que são pré-processados, segmentados, para que em seguida seja realizada a extração de características desejadas para posterior classificação. Após a classificação, os comandos são enviados ao atuador (WANG, 2017).

Tello et Al.(2013) buscaram comparar resultados dos classificadores, K-vizinhos mais próximos (K-NN), Bayes (BC) Linear e Quadrático, extraíndo as características de RMS, WL e Variância (VAR). Os gestos escolhidos para classificação foram separados em 15 classes divididas em 4 grupos. O classificador Bayesiano Quadrático apresentou a melhor Taxa de acerto chegando a valores acima de 98%.

Já Atzori (2016) obteve diferentes resultados ao classificar 50 movimentos da mão, comparando o desempenho dos classificadores K-Vizinhos mais próximos (K-NN), Máquina de Vetor Suporte (SVM), Random Forests, Análise de Discriminantes Lineares (LDA) e Redes Neurais Convolutivas (CNN), a partir da extração das características de Transformada Discreta Marginal de Wavelet (mWDT), Histograma (HIST), WL, RMS e uma combinação normalizada de todas estas características juntas. Foram utilizadas 3 bases de dados diferentes sendo a primeira referente a 27 indivíduos sem limitações físicas (20 homens, 7 mulheres), a segunda referente a 40 indivíduos sem limitações físicas (28 homens, 12 mulheres) e a terceira base de dados referente a 11 indivíduos com amputação no membro superior (11 homens). A classificação por CNN obteve Taxa de acerto de 66,59±6,40% para o primeiro conjunto de dados, 60,27±7,7% para o segundo conjunto de dados e 38,09±14,29% para o terceiro conjunto de dados, frente a média geral de resultados dos outros classificadores de 62,06±6,07%, 60,28±6,51% e 38,82±11,99% para os conjuntos de dados 1, 2 e 3 respectivamente.

Os resultados apontaram que uma arquitetura básica de Redes Neurais Convolutivas (CNN) apresenta resultados com Taxa de acerto semelhante a média geral dos resultados dos outros classificadores testados, porém nas análises individuais, o classificador Random Forest obteve a melhor Taxa de acerto para os dois primeiros conjuntos de dados (75,32±5,69% e 75,27±7,89% respectivamente), e o classificador SVM obteve o melhor resultado (46,27±7,89%) para o terceiro conjunto de dados.

Jarrasé (2017) obteve resultados com média geral de 70% de sucesso em testes off-line e on-line na classificação de 14 movimentos de mão, punho e cotovelo, utilizando Classificação por LDA a partir da extração das características: Raiz Média Quadrática (RMS), Coeficientes auto-regressivos de quarta

ordem (AR), Amostra de Entropia (SE) e Comprimento de Forma de Onda (WL).

A tabela 1 mostra alguns extratores de características utilizados em pesquisas realizadas entre os anos de 2016 e 2017.

Tabela 1. Extratores de características usados em pesquisas orientadas análise de sEMG durante os anos 2016-2017

DOMÍNIO	CARACTERÍSTICA	SIGLA	REFERÊNCIA
tempo	cruzamento de zeros	zc	raj et al (2016) xiao e menom (2017);
	valor médio absoluto	mav	wang et al.(2017); krasoulis et al (2017)
	raiz média quadrática	rms	pizzolato et al.(2017); jarrasé et al.(2017) ; atzori et al.(2016); xiao e menom (2017)
	comprimento de forma de onda	wl	jarrasé et al.(2017) ; krasoulis et al(2017); xiao e menom (2017)
	integral de emg	iemg	raj et al.(2016)
	variância logarítmica	log var	krasoulis et al (2017)
	histograma de emg	hemg	krasoulis et al (2017); atzori et al. (2016); pizzolato et al.( 2017)
frequência	coeficientes auto-regressivos	ar	wang et al. (2017); jarrasé et al.(2017) ; krasoulis et al (2017); xiao e menom (2017)
frequência-tempo	transformada wavelet discreta	dwt	duan et al.(2016)
	Transformada Marginal Wavelet Discreta	mDWT	Atzori et al. (2016); Pizzolato et Al.( 2017)

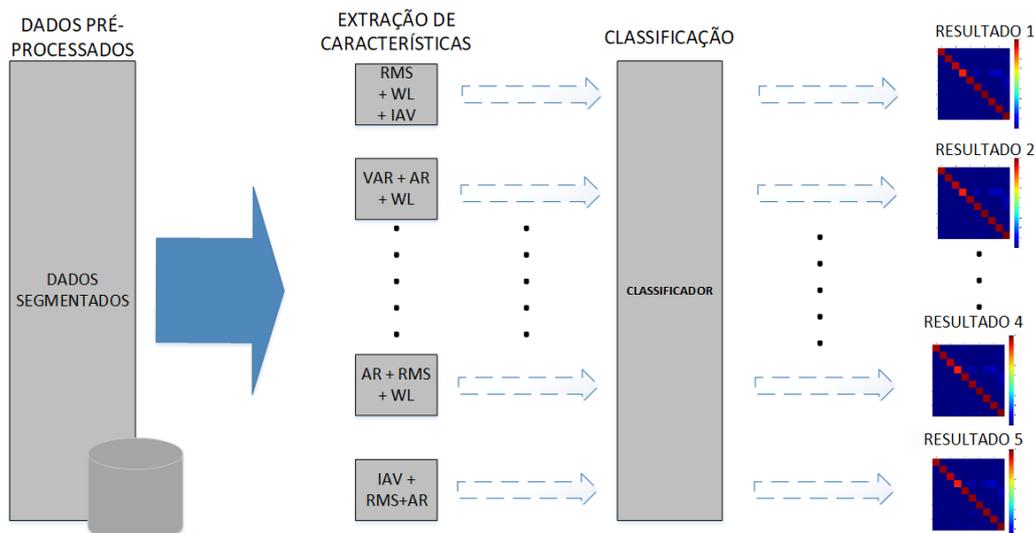


Figura 1. Diagrama de blocos da análise comparativa executada

Além das técnicas demonstradas na tabela 1 existem outras, principalmente no domínio da Frequência e Frequência-Tempo, tais como Transformada Wavelet Packet (WPT), Densidade espectral (DS), Filtragem espacial (FS) (Tello, 2013).

A tabela 2 apresenta alguns classificadores utilizados em pesquisas realizadas durante os anos de 2016 e 2017.

Tabela 2. Classificadores usados em pesquisas orientadas análise de sEMG durante os anos 2016-2017.

CLASSIFICADOR	SIGLA	REFERÊNCIA
Análise Discriminante Linear	LDA	Krasoulis et Al.(2017)
		Atzori et al.(2016) ;
		Wang et al.(2017);
		Jarrassé et al.(2017);
Máquina de Vetor Suporte	SVM	Xiao e Menom (2017)
		Atzori et alt.(2016)
		Pizzolato et Al.(2017);
K- Vizinhos mais Próximos	K-NN	Xiao e Menom (2017)
		Atzori et al.(2016);
Redes Neurais Perceptron Multilayer	MLPNN	Raj et al. (2017)
Random Forest	-	Atzori et Al. (2016);
		Pizzolato et Al.(2017)
Redes Neurais Convolutivas	CNN	Atzori et Al. (2016)
Rede Neural Wavelet	WNN	Duan et Al. (2016)

Existem outras técnicas não citadas como o Classificador por Modelos Ocultos de Markov (HMM), Classificador Bayesiano (BC), Classificador Lógico Difuso (LF), entre outras..

A Extreme Learning Machine (ELM) é uma rede neural feedforward de camada única oculta, com uma função de ativação linear na saída. Nela os pesos entre as entradas e a camada oculta são ajustados aleatoriamente, já os valores dos pesos da camada oculta para camada de saída são deterministicamente calculados, comumente pela multiplicação da pseudoinversa Moore-Penrose dos valores das unidades de camadas ocultas e as classes padrão, o preço por atribuir pesos aleatórios nas conexões entre a entrada e a camada oculta é a necessidade de que haja uma quantidade grande de unidades na camada oculta (BOLDT, 2017). Tapson (2013) sugere que o a quantidade de unidades na camada oculta seja 10 vezes a quantidade de neurônios da entrada, e resume a metodologia em dois passos:

1- Conectar as entradas a uma quantidade muito maior de unidades da camada oculta e escolher os pesos aleatoriamente.

2- Calcular os pesos da conexão entre a camada oculta e os neurônios artificiais da saída através do produto entre a pseudoinversa da camada oculta de ativação e as supostas classes de saída.

A Figura 2 ilustra uma arquitetura da Rede Neural ELM, nela a rede de entrada da camada oculta é :

$$n_i = \sum_{l=1}^d w_{i,l} \cdot x_l + b_i = W_i \cdot X + b_i \quad (1)$$

Onde  $w_{i,l}$  é o peso da conexão entre a l-ésima entrada e a i-ésima unidade da camada oculta, sendo  $b_i$  o bias associado. O resultado da função de ativação  $h_i$  é dado por:

$$h_i = f(n_i) \quad (2)$$

Sendo a função de ativação escolhida para implementação neste trabalho a função sigmoide:

$$f(n) = \frac{1}{(1+\exp(-n))} \quad (3)$$

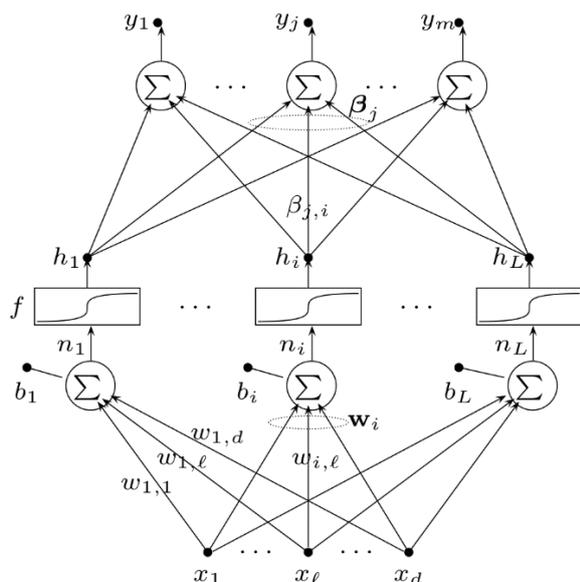


Figura 2. Arquitetura básica da Extreme Learning Machine  
Fonte: Boldt (2017).

A saída  $Y_j$  composta de  $j = 1, \dots, m$  unidades de  $Y_j$  é calculada conforme:

$$Y_j = \sum_{i=1}^L \beta_{j,i} \cdot h_i = \beta_j \cdot H \quad (4)$$

As principais vantagens do ELM são a sua alta capacidade de generalização (fator que aumenta a taxa de acerto do classificador), menor intervenção do programador para cálculo dos pesos e aumento na velocidade de processamento quando comparado a arquiteturas SVM e outras arquiteturas clássicas de Redes Neurais Artificiais (HUANG,2006).

Devido à sua notável eficiência, simplicidade e efetiva capacidade de generalização, o ELM tem sido aplicado em várias áreas, como engenharia biomédica, visão computacional, identificação de sistemas, controle e robótica (HUANG,2015).

A implementação do ELM utilizada neste trabalho é uma variação do classificador implementado por Boldt (2017) baseado em Tapson (2013), onde o número de neurônios da camada oculta foi definido heurísticamente em 10 vezes a quantidade de neurônios da entrada. Boldt (2017) originalmente utiliza este classificador para aplicação relacionada a diagnóstico e detecção de falhas em processos industriais. Este artigo se propõe a testar o classificador proposto em Boldt (2017) na aplicação de reconhecimento de gestos a partir da classificação de sinais sEMG, para verificar sua aplicabilidade e capacidade na classificação de sinais de sEMG.

Neste trabalho, utilizou-se a base de dados fornecida por Chan (2004) para comparar resultados da classificação de gestos da mão (Ver tabela 4), a partir de combinações de quatro diferentes características extraídas do sinal sEMG, sendo eles: Raiz Média Quadrática (RMS) Coeficientes auto-regressivos de quarta ordem (AR), Integral de Valor Absoluto (IAV) e Comprimento de Forma de Onda (WL). Foram utilizados os classificadores Análise de

Discriminantes Lineares (LDA), Análise de Discriminantes Quadráticos (QDA), classificador Bayesiano Linear (BC Linear), classificador Bayesiano Quadrático (BC Quadrático), Análise de discriminantes por distâncias de Mahalanobis e uma Rede Neural Extreme Learning Machine (ELM).

Foi realizado um processo de análise comparativa dos resultados obtidos partir dos diferentes algoritmos gerados das combinações de diferentes extratores de características e classificadores. A partir deste processo comparativo foi possível identificar qual algoritmo apresenta melhor desempenho, qual característica tem maior influência na assertividade geral do classificador e também se o classificador ELM adaptado apresenta resultados semelhantes ou melhores que os outros classificadores mais tradicionais utilizados neste trabalho.

O desempenho médio geral também é apresentado por classes, permitindo identificar qual gesto pode ser reconhecido com maior facilidade pelo algoritmo utilizado.

## 2 Materiais e Métodos

O experimento foi realizado utilizando a ferramenta MATLAB versão 2017a, em um computador equipado com processador Intel Core-i7-4510U CPU @ 2.00Ghz 2.60 Ghz para processamento dos dados.

### 2.1 Dados

Os dados utilizados foram coletados de acordo com Chan (2004) por meio de 8 canais dispostos no antebraço direito de 30 indivíduos, conforme Figura 1. Cada indivíduo participou de 4 sessões, onde em cada sessão foram realizados 6 ensaios. Cada ensaio tinha a duração de 94 segundos, onde durante este período o indivíduo realizou com a mão 7 diferentes gestos de forma aleatória.

Neste trabalho foram utilizados 2 ensaios de 4 indivíduos com membros em perfeito estado.

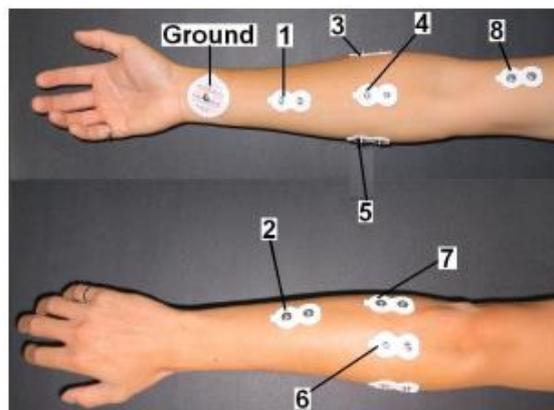


Figura 3. Disposição dos eletrodos (canais, ver Tabela 3) de captação do sEMG. Fonte: Extraído de Chan (2004).

Cada número indicado na foto representa a identificação de canal na aquisição de sinais sEMG correspondente a posição descrita na Tabela 3.

Os dados originais foram obtidos com amostragem de 3 KHz através de placa conversora analógica-digital (National Instruments, PCI-6071E), depois foram reamostrados para a frequência de 1 KHz, processados através do Matlab (CHAN 2007).

Tabela 3. Posicionamento dos sensores (canais)

CANAL	POSIÇÃO (MÚSCULO)
Canal 1	Flexor radial do carpo
Canal 2	Extensor ulnar do carpo
Canal 3	Braquirradial
Canal 4	Entre braquirradial e flexor radial do carpo
Canal 5	Flexor ulnar do carpo
Canal 6	Extensor dos dedos (“ <i>extensor digitorum</i> ”)
Canal 7	Entre extensor ulnar do carpo e flexor ulnar do carpo
Canal 8	Bíceps

A frequência é reamostrada para 1 KHz, pois a faixa de frequência típica do sinal de sEMG é de 50 a 500 Hz. (NAJARIAN, 2012)

Cada gesto foi realizado 4 vezes de forma aleatória durante o ensaio sendo que cada gesto foi mantido um pelo período de 3 segundos. Foram introduzidos um período de descanso de 5 segundos no início e no final de cada ensaio, para evitar perda de dados durante a coleta. A Figura 5 mostra um exemplo temporal do protocolo de ensaio

Os gestos são as classes definidas conforme Tabela 4.

Tabela 4. As Classes avaliadas (gestos)

CLASSE	GESTO
Classe 1	Mão aberta ( <b>C1</b> )
Classe 2	Mão fechada ( <b>C2</b> )
Classe 3	Supinação ( <b>C3</b> )
Classe 4	Pronação ( <b>C4</b> )
Classe 5	Flexão de punho ( <b>C5</b> )
Classe 6	Extensão de punho ( <b>C6</b> )
Classe 7	Descanso ( <b>C7</b> )

As características são extraídas através de amostras do sinal obtidas a partir de janelas de tempo de largura e incremento pré-determinados, conforme exemplo da Figura 4, sendo a largura da janela representada pela letra “L” e o incremento pela sigla “inc”.

se também gera aumento do tempo para decisão do classificador. Eagleheart (2003) recomenda que para sistemas que utilizam sEMG para controle é necessário que cada decisão de classificação do algoritmo seja realizada em um período de tempo inferior a 300 ms, para que não seja percebido pelo usuário. A partir dessa análise, foi estabelecido o tamanho de janela de 256 ms sendo incrementado em 128 ms (“overlap” de 50%) a cada amostra para treinamentos e testes.

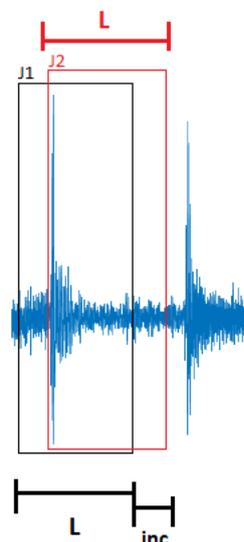


Figura 4. Exemplo de deslizamento de janela

## 2.2 Extração de Características

Para este trabalho foram utilizadas 5 combinações de características para testes conforme tabela 5.

Tabela 5. Combinação de características utilizadas nos testes

COMBINAÇÃO	CARACTERÍSTICAS (FEATURES)
1	RMS+IAV+AR+WL
2	RMS+AR+WL
3	IAV+AR+WL
4	RMS+AR+IAV
5	RMS+IAV+WL

Não foi utilizada nenhuma técnica de redução de dimensionalidade.

## 2.3 Classificação

Os dados foram testados utilizando a validação do tipo “*k-fold*” em 8 partições (8-*fold*).

Foram testados os seguintes classificadores: Análise de Discriminantes Lineares (LDA), Análise de Discriminantes Quadráticos (QDA), classificador Bayesiano Linear (BC Linear), classificador Bayesiano Quadrático (BC Quadrático), Análise de discriminantes por distâncias de Mahalanobis e uma Rede Neural Extreme Learning Machine (ELM) adaptada por Boldt (2017).

A implementação ELM utilizada neste trabalho, se caracteriza por possuir uma quantidade de

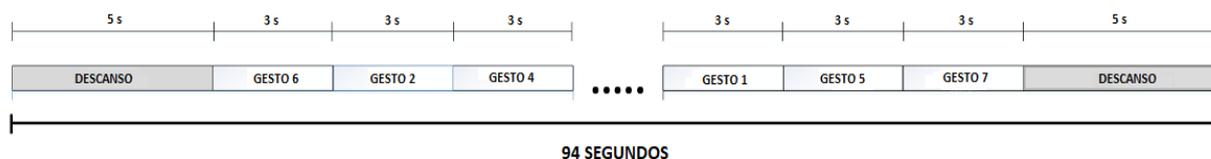


Figura 5. Exemplo sequência temporal de um ensaio de coleta de sinais.

neurônios da camada oculta igual a 10 vezes a quantidade de neurônios de entrada, sendo a função sigmoide escolhida como função de ativação.

Foi utilizado pós-processamentos por “Voto de Maioria” para melhoria do resultado final. Voto de Maioria (do Inglês, *Majority Vote*) consiste em utilizar os resultados anteriores para definir a classe atual (CHAN, 2004). Neste caso utiliza-se 2 resultados anteriores da classificação (com um incremento de 128 ms, isso corresponde aos 256 ms anteriores) para definir o resultado final da classificação

Para cada ensaio de teste de cada indivíduo foi gerada uma Matriz de Confusão como resultado da classificação. Sendo essas realizadas uma a uma para cada variação de combinação apresentada na Tabela 2, aplicada a cada classificador individualmente. Como o algoritmo ELM possui natureza aleatória, seu resultado é consolidado a partir da média 5 testes para cada combinação de feature.

De posse das Matrizes de Confusão, calculou-se o F1-Score e a Taxa de acerto para cada Classe e ao final um valor médio para cada ensaio. Desta forma, foi possível obter resultados por combinações de características utilizadas, por classificadores e por classes, possibilitando identificar quais algoritmos (extrator de característica + classificador) apresentam os melhores e piores resultados e quais combinações e classificadores apresentam maior média de assertividade em relação aos demais aqui comparados.

### 3 Resultados

O desempenho de classificação é estimado com a métrica F1-score e a taxa de acerto.

Nas Figura 6 e 7, é possível identificar o melhor resultado médio (93,17%) por algoritmo que é obtido a partir da técnica ELM adaptada, utilizando se a combinação de características RMS+AR+WL. Também é perceptível o desempenho inferior do classificador Bayesiano Linear em todas as combinações de características utilizadas.

Na Tabela 6 é possível observar que o maior valor médio obtido a partir da combinação de características RMS+AR+WL é ligeiramente superior as outras combinações, com exceção da combinação que utiliza RMS+IAV+WL, sendo esta, a única que não utiliza a característica AR de 4ª Ordem.

A Tabela 7 mostra que o classificador com melhor média de desempenho é o ELM adaptado, sendo que classificador QDA inferior muito próximo. A tabela também confirma o pior resultado médio obtido pelo classificador Bayesiano Linear.

Tabela 6 – Resultados Médios por Combinação de Características

CARACTERÍSTICAS	TAXA DE ACERTO	F1-SCORE
RMS+4-AR+IAV+WL	85,39%	85,51%
RMS+4-AR+IAV	84,15%	84,16%
RMS+4-AR+WL	86,10%	86,26%
RMS+IAV+WL	79,04%	79,37%
4-AR+IAV+WL	85,40%	85,57%

Tabela 7 – Resultados Médios por Classificador

CLASSE	TAXA DE ACERTO	F1-SCORE
CLASSE 1	79,06%	77,62%
CLASSE 2	86,17%	84,49%
CLASSE 3	87,71%	89,44%
CLASSE 4	92,06%	93,27%
CLASSE 5	78,71%	83,94%
CLASSE 6	81,05%	81,43%
CLASSE 7	83,24%	79,02%

Na análise realizada também foi possível identificar os gestos que possuem maior e menor dificuldade de classificação em média. A tabela 8 mostra que a classe com maior média de assertividade, portanto a mais fácil de ser classificada, é a classe 4 que é referente ao gesto de pronatação, em contrapartida o gesto que enfrenta maior dificuldade de reconhecimento é o de mão aberta (Classe 1).

Tabela 8 - Resultado médio de assertividade das Classes

CLASSIFICADOR	TAXA DE ACERTO	F1-SCORE
LDA	82,19%	82,64%
QDA	89,50%	89,46%
BAYES LINEAR	73,41%	73,99%
BAYES QUADRÁTICO	78,89%	79,11%
MAHALANOBIS	89,36%	89,24%
ELM	90,75%	90,61%

O melhor resultado de teste realizado a partir da técnica 8-fold apresentou desempenho de 93,70% de taxa de acerto, e foi obtido a partir da extração das características RMS+AR+WL, pelo classificador

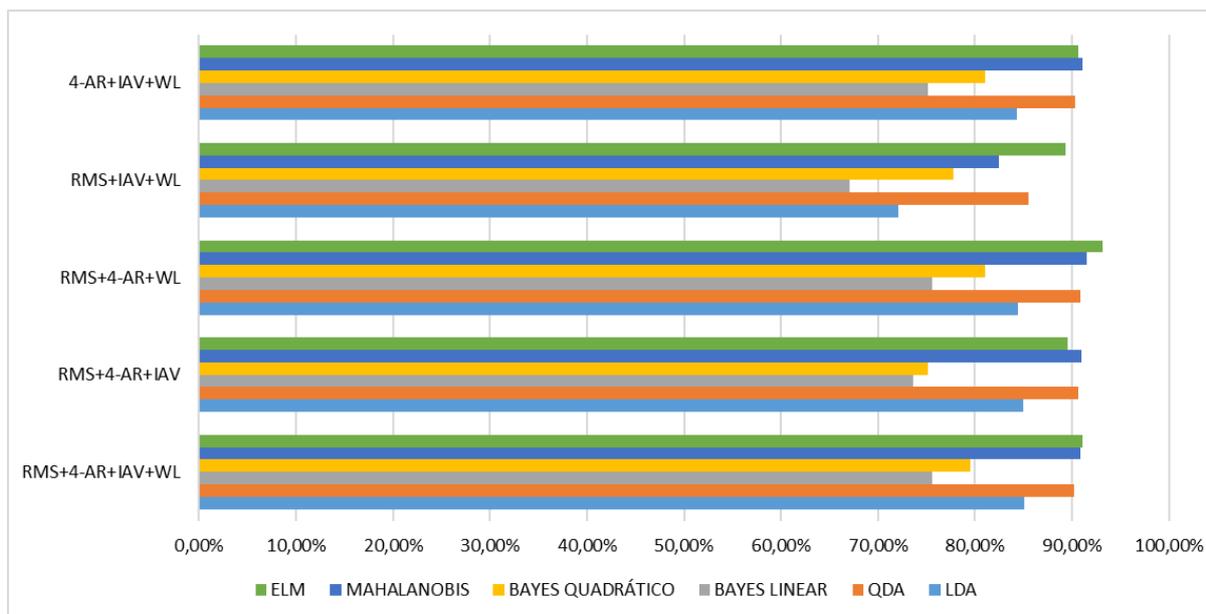


Figura 6. Resultado em F1-Score ELM adaptado. A Figura 8 mostra a matriz de confusão obtida neste ensaio.

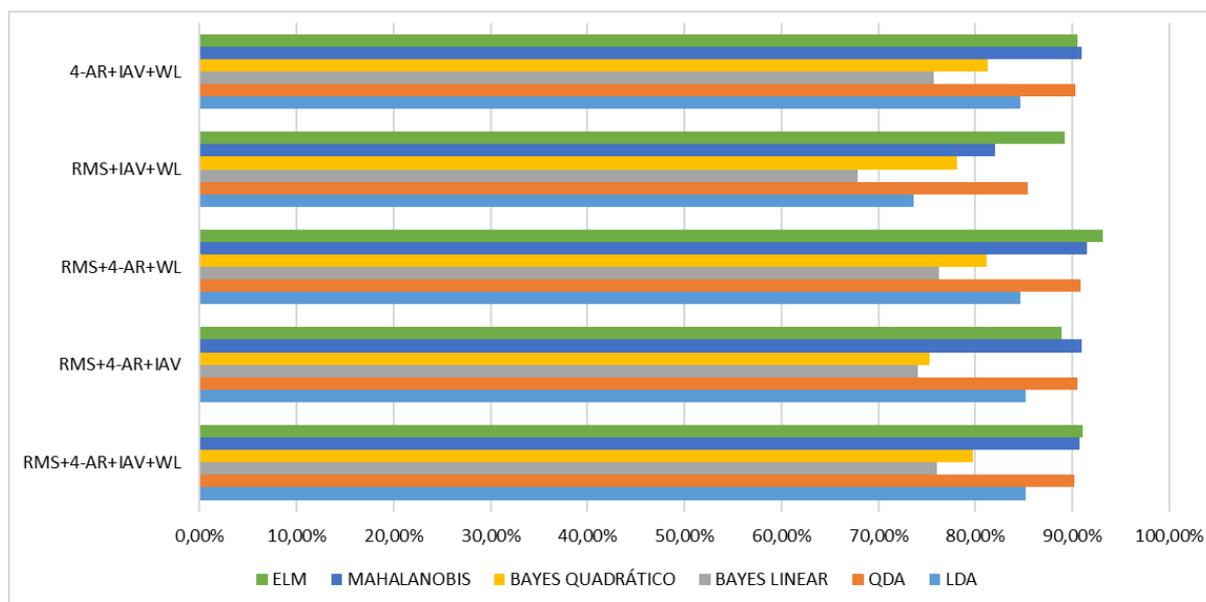


Figura 7. Resultado em Taxa de Acerto

		CLASSE REAL						
		C1	C2	C3	C4	C5	C6	C7
CLASSE PREDITA	C1	88%	0%	1%	1%	1%	3%	1%
	C2	5%	94%	0%	0%	0%	1%	4%
	C3	2%	1%	96%	1%	1%	1%	0%
	C4	0%	0%	1%	97%	1%	0%	0%
	C5	1%	1%	0%	0%	97%	1%	1%
	C6	1%	1%	2%	0%	0%	93%	2%
	C7	3%	2%	1%	1%	1%	2%	91%

Figura 8 - Matriz de Confusão do maior resultado pós validação 8-fold. Indivíduo 3, características extraídas RMS+AR+WL, classificador ELM adaptado (Taxa de acerto =93,70%).

## 4 Conclusão

O impacto da característica AR de 4ª Ordem nos classificadores utilizados foi o mais relevante, uma vez que de acordo com a Tabela 6, há a redução de pelo menos 5 pontos percentuais, quando comparado ao segundo pior resultado de combinação que não utiliza esta característica. Identificou-se que a combinação que apresenta o resultado de maior valor na média geral é a combinação RMS+AR+WL, a qual apresenta maior média.

A partir do protocolo utilizado, conclui-se também que os gestos de Pronação (Classe 4) e Supinação (Classe 3) possuem maior facilidade de reconhecimento, em contrapartida o gesto de mão aberta (Classe 1) é o mais difícil de ser reconhecido pelos classificadores quando analisados os resultados em F1-Score. O resultado se mostra coerente uma vez que muitos gestos são compostos pelo gesto de mão aberta mais uma ação específica, acionando músculos de modo e intensidade semelhantes aos utilizados no gesto de mão aberta, fazendo com que gesto específico de mão aberta sejam mais comumente confundidos com os outros gestos pré-definidos.

Após a análise comparativa dos dados a partir das métricas pré-estabelecidas, demonstra-se que a técnica ELM, adaptada por Boldt (2017), apresenta resultados promissores sendo este o classificador a atingir a melhor média geral em taxa de acerto (90,75%) e F1-Score (90,61%). Confirmando a afirmação de Huang (2015), em relação a capacidade de aplicação deste método na Engenharia Biomédica e também demonstrando o poder de generalização e a eficácia do método ELM quando comparados a outros algoritmos clássicos.

Para trabalhos futuros, sugere-se explorar mais o classificador ELM adaptado por Boldt (2017), buscando combina-lo com outras características não utilizadas neste trabalho. Sugere-se também aumentar o número de indivíduos e classes possíveis do protocolo e analisar qual será a taxa de redução na assertividade média do algoritmo.

### Agradecimentos

Agradeço ao Programa de Pós-Graduação em Engenharia de Controle e Automação (PROPECAUT) do IFES – Campus Serra.

### Referências Bibliográficas

- Akirmak, O. O. et al.; ago. 2017. Design of an Accessible, Powered Myoelectrically Controlled Hand Prosthesis. *Tem Journal*. Izmir, Turquia, p. 479-483.
- Atzori, M; Müller, H.; (2015). Control Capabilities of Myoelectric Robotic Prostheses by Hand Amputees: A Scientific Research and Market Overview. *Frontiers In Systems Neuroscience*, V. 9, pp. 162.
- Atzori, M; Cognolato, M; Muller, H.; set. 2016, Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands. *Frontiers In Neurobotics*. *Front. Neurobot.* 10:9. doi: 10.3389/fnbot.2016.00009 Sierre, p. 1-10.
- Atzori, M et al.; dez, 2014. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific Data*. Sierre, p. 1-13. dez.
- Boldt, F A.; (2017). Classifier ensemble feature selection for automatic fault diagnosis. Doctoral Thesis, Programa de Pós-Graduação em Informática of the Universidade Federal do Espírito Santo, Universidade Federal do Espírito Santo, Vitória, 2013. / Francisco de Assis Boldt.
- Chan, A. D. C.; Goge, A. R.; (2004). Investigating classification parameters for continuous myoelectrically controlled prostheses.
- Chan, A. D. C.; Green, G. C. (2007). myoelectric control development toolbox. 2007. 30th Conference of the Canadian Medical & Biological Engineering Society, Toronto, Canada, M0100,.. Disponível em: <[http://www.sce.carleton.ca/faculty/chan/matlab/myoelectric\\_control\\_development\\_toolbox.pdf](http://www.sce.carleton.ca/faculty/chan/matlab/myoelectric_control_development_toolbox.pdf)>. Acesso em: 10 dez. 2017.
- Duan, F. et al.; mar. 2016. SEMG-Based Identification of Hand Motion Commands Using Wavelet Neural Network Combined With Discrete Wavelet Transform. *Ieee Transactions On Industrial Electronics*. Tianjin, p. 1923-1934.
- Englehart, K.; Hudins, B.; Chan, A. D. C.; (2003). Continuous multifunction myoelectric control using pattern recognition. *Technology and Disability*, 15, p. 95-103.
- Farina, D et al.; fev. 2014. The Extraction of Neural Information from the Surface EMG for the Control of Upper-Limb Prostheses: Emerging Avenues and Challenges. *Ieee Transactions On Neural Systems And Rehabilitation Engineering*. Göttingen, p. 797-809.
- Geethanjali, P.(2016). Myoelectric control of prosthetic hands: state-of-the-art review. *Dove Medical Devices: Evidence and Research*. Tamil Nadu, p. 247-255.
- Huang, G; Huang, G. B.; Song, S.; You, K.; (2015) Trends in extreme learning machines: A review. *Elsevier – Neural Networks* 61, p. 32-48.
- Huang, G.-B.; Zhu, Q.-Y.; Siew, C.-K.; (2006). Extreme learning machine: theory and applications. *Neurocomputing*, Elsevier, v. 70, n. 1, p. 489–501.
- Jarrasé, N et al.; jan. 2017. Classification of Phantom Finger, Hand, Wrist, and Elbow Voluntary Gestures in Transhumeral Amputees With sEMG. *Ieee Transactions On Neural Systems And Rehabilitation Engineering*. Paris, p. 68-77.
- Krasoulis et al.; jul. 2017. Improved prosthetic hand control with concurrent use of myoelectric and

- inertial measurements. *Journal Of Neuro Engineering And Rehabilitation*. Edinburgh, p. 1-14.
- Kumar, D. K.; (2013). Feature Extraction and Classification of sEMG Signals Applied to a Virtual Hand Prosthesis. In: 35th Annual International IEEE EMBS Conference, Osaka (Japan). p. 1911-1914.
- Matrone, G. C. et al.; (2012). Real-time myoelectric control of a multi-fingered hand prosthesis using principal components analysis. *Journal Of Neuroengineering And Rehabilitation*. Pavia, Itália, 9:40.
- Najarian K. e Splinter R.; (2012). *Biomedical Signal and Image Processing 2ed*, CRC Press.
- Pizzolato, S. et al.; out. 2017. Comparison of six electromyography acquisition setups on hand movement classification tasks. *Plos One*. Zurich, p. 1-17.
- Raj, R.; Ramakrishna, R.; Sivanandan, K. S.; out. 2016. A Real Time Surface Electromyography Signal Driven Prosthetic Hand Model Using PID Controlled DC Motor. *Springer - Biomedical Engineering Letters*. Calicut, p. 276-286.
- Scheme, E.; Englehart, K.; (2011). Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use. *Journal of Rehabilitation Research & Development*, V.48, p. 643-660.
- Tapson, J.; Schaik, A. Van.; (2013). Learning the pseudoinverse solution to network weights. *Neural Networks*, Elsevier, v. 45, p. 94-100.
- Tello, R. J. M. G. (2013). Extração de características e classificação de sinais sEMG aplicados a uma prótese de mão virtual. 2013. 115 f. Dissertação (Mestrado) - Curso de Engenharia elétrica, Centro Tecnológico da Universidade Federal do Espírito Santo, Universidade Federal do Espírito Santo, Vitória.
- Tello, R. J. M. G. ; Filho, T. F. B. ; Neto, A F; Arjunan S.P. ; Kumar, D. K.; (2013). Feature Extraction and Classification of sEMG Signals Applied to a Virtual Hand Prosthesis. In: 35th Annual International IEEE EMBS Conference, Osaka (Japan) p. 1911-1914.
- Wang, N.; Lao, K.; Zhang, X.; jan. 2017. Design and Myoelectric Control of an Anthropomorphic Prosthetic Hand. *Journal Of Bionic Engineering*. Guangzhou, p. 47-59.
- Xiao, Z G; Menom, C.; jan. 2017. Performance of Forearm FMG and sEMG for Estimating Elbow, Forearm and Wrist Positions. *Journal Of Bionic Engineering*. British Columbia, p. 284-295.
- Zhang X.; Li X.; Samuel O. W.; Huang Z.; Fang P.; Li G.; (2017). Improving the Robustness of Electromyogram-Pattern Recognition for Prosthetic Control by a Postprocessing Strategy. *Front. Neurobot*. 11:51.