

# Reconhecimento de Gestos de Mão Utilizando Sinais de Eletromiografia de Superfície

Felipe Pinheiro \* Allan Martins \* Alessandra Rodrigues \*\*

\* Programa de Pós-graduação em Engenharia Mecatrônica,  
Universidade Federal do Rio Grande do Norte, RN

\*\* Centro Regional do Nordeste, Instituto Nacional de Pesquisas  
Espaciais, RN

**Abstract:** The control of prostheses, orthoses and other mechanisms based on a specific region's musculature represents the automatic integration between user and application. This work presents three promising feature extraction alternatives, trying to identify different gestures performed with the right hand based on four forearm musculature's electromyography signals.

**Resumo:** O controle de próteses, órteses e outros mecanismos baseando-se em regiões específicas da musculatura representa a integração automática entre aplicação e usuário. Nesse trabalho são apresentadas três alternativas promissoras para extração de características, na intenção de identificar diferentes gestos executados com a mão direita considerando quatro sinais de eletromiografia da musculatura do antebraço.

*Keywords:* Electromyography; features extraction; gesture; systems identification.

*Palavras-chaves:* Eletromiografia; extração de características; gesto; identificação de sistemas.

## 1. INTRODUÇÃO

A eletromiografia (EMG) é um método de registro da resposta elétrica da musculatura ativa e a interpretação desse registro carrega a chave para a integração entre usuário e aplicação. Utilizar os sinais bioelétricos para acionamento e controle de aplicações como *drones*, cadeiras de rodas motorizadas entre outros mecanismos controlados remotamente já é uma realidade ao se coletar esses sinais, enviá-los para uma unidade de processamento e essa unidade comandar o equipamento.

Tratar os sinais de EMG também expande os horizontes da tecnologia assistiva, que visa auxiliar pessoas com limitações físicas em suas atividades laborais ou cotidianas promovendo um aumento da qualidade de vida do indivíduo. Utilizando sinais bioelétricos é possível projetar próteses e órteses controladas por comandos elétricos desencadeados por processos naturais do usuário, tornando o processo de aprendizagem de como utilizá-las mais rápido.

O estudo da atividade muscular através de sua resposta elétrica não é uma novidade, Kazamel and Warren (2017) mostra que em 1929 foram utilizados eletrodos de agulha para aferir sinais de EMG. Atualmente, os trabalhos relacionados ao estudo de EMG utilizam equipamentos comerciais Wang et al. (2017) e Boyali and Hashimoto. (2016). A tecnologia aplicada nessa área de estudo já foi bastante desenvolvida para que a aquisição dos sinais seja feita de forma não invasiva, utilizando eletrodos postos sobre a pele.

Com relação a aquisição dos sinais de EMG do antebraço, foram estudados alguns trabalhos que utilizam dispositivos comerciais com quantidade de sinais diferentes de acordo com cada equipamento. O dispositivo mais comum, utilizado em Boyali and Hashimoto. (2016) e Santhiyarayanan et al. (2015), é uma pulseira posicionada no antebraço próximo ao cotovelo, que apresenta oito sensores de EMG para reconhecer os movimentos da mão. Além dos sensores de EMG o dispositivo utiliza uma unidade adicional de sensores de movimento linear e angular. Esse aparelho apesar de mostrar bons resultados, é mais complexo do que o desejado para esse trabalho além de adicionar um custo indesejado ao projeto. Outro tipo de sensor foi visto em Wang et al. (2017), é um eletrodo bipolar específico para EMG em que o circuito responsável pela aquisição do sinal (amplificador de instrumentação de ganho 10 e CMRR >80dB) é implementado em uma caixa de dimensões 41x20x5mm que é posta sobre a pele para aferir o sinal de EMG da musculatura da região. Entretanto, o fabricante do produto garante que o sensor atinge as especificações somente no caso de todo o equipamento utilizado ser da mesma marca. Dessa forma, esse sensor não foi utilizado. Analisando Winiarski (2015), descobriu-se o CI INA128 desenvolvido pela Texas Instruments que implementa um amplificador de instrumentação utilizando três amplificadores operacionais e um resistor externo para definir seu ganho. Devido a flexibilidade das condições de operação e custo reduzido o INA128 foi escolhido para implementar o circuito de EMG desse trabalho.

Na busca por trabalhos cujos objetivos envolvessem classificação de sinais utilizando técnicas de extração de características, as técnicas que modelam os sinais como processos

\* Pesquisa com apoio financeiro da CAPES.

auto regressivos são bastante utilizadas como alternativa tanto na área de biotecnologia Delis et al. (2009) quanto para outras áreas como comunicações digitais Brahimzadeh et al. (2011). Logo, por ser aplicado com sucesso em diversas áreas para classificar sinais, modelar os sinais de EMG como processos auto regressivos foi uma das técnicas aplicadas nesse trabalho utilizando o método em duas vertentes: estimação em batelada (Estimador de mínimos Quadrados) e recursiva (Estimador de mínimos Quadrados Recursivo).

Analisando trabalhos relacionados à sinais bioelétricos destacou-se também o trabalho Subasi and GURSOY (2010). Nele é feita uma análise da atividade cerebral em que um dos métodos utilizados para a extração de características do sinal é a PCA, do inglês, *Principal Component Analysis*. Essa técnica realiza uma transformação linear para que o conjunto de dados trabalhado se torne linearmente descorrelacionado. Aplicando-a para sinais variantes no tempo, como os de EMG, essa transformação linear deve ser diferente para cada novo conjunto de dados, obedecendo os padrões de cada movimento realizado. Em Subasi and GURSOY (2010), esse método é utilizado para remover características irrelevantes sejam elas redundantes ou que degradem o desempenho do classificador de sinal. Dentre os métodos utilizados, a PCA não obteve o melhor resultado, no entanto, apresentou um bom resultado quanto ao tempo de treinamento, fator desejável para a aplicação.

Diante dos resultados já encontrados na literatura, esse trabalho propôs formar um banco de dados extraído com *hardware* próprio e adaptar as técnicas já conhecidas para a identificação de 4 gestos realizados com a mão direita, analisando comparativamente o desempenho de cada estratégia.

## 2. ANÁLISE DE COMPONENTES PRINCIPAIS

A Análise de Componentes Principais (do inglês, *Principal Component Analysis*, PCA) é uma técnica de análise estatística que por meio de combinações lineares, encontra um novo conjunto de dados linearmente descorrelacionados. Comumente aplicada para a redução de dimensionalidade como em Hild et al. (2006), mas também aplicada como estratégia para extração de características como em Xie et al. (2012).

Essa ferramenta encontra projeções lineares de um conjunto de dados  $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$  ( $\mathbf{x}_i \in \mathbb{R}^n$ ) para que cada variável projetada tenha a variância de sua projeção maximizada. A condição que deve ser cumprida é que a esperança do conjunto de dados seja nula ( $E\{\mathbf{X}\} = 0$ ) e, mantendo a norma finita (2), maximiza-se a variância do dado projetado (1). Deve-se encontrar um novo conjunto de valores projetados  $\mathbf{y}_i = \mathbf{w}^t \mathbf{x}_i$  para que:

$$\mathbf{w} = \operatorname{argmax}_{\|\mathbf{w}\|^2 = 1} \operatorname{Var}\{\mathbf{w}^t \mathbf{X}\} \quad (1)$$

$$\|\mathbf{w}\|^2 = 1 \quad (2)$$

Para fazê-lo, maximiza-se o funcional:

$$\begin{aligned} \varepsilon &= \operatorname{Var}\{\mathbf{w}^t \mathbf{X}\} + \lambda(\|\mathbf{w}\|^2 - 1) \\ \varepsilon &= \frac{1}{N} \sum_{i=1}^N (\mathbf{w}^t \mathbf{x}_i)^2 + \lambda(\|\mathbf{w}\|^2 - 1) \end{aligned} \quad (3)$$

E derivando a equação (3), tem-se:

$$\begin{aligned} \frac{\partial \varepsilon}{\partial \mathbf{w}} &= \frac{2}{N} \sum_{i=1}^N (\mathbf{w}^t \mathbf{x}_i \mathbf{x}_i^t) + 2\lambda \mathbf{w}^t \\ \frac{\partial \varepsilon}{\partial \lambda} &= \|\mathbf{w}\|^2 - 1 \end{aligned} \quad (4)$$

A segunda equação em (4) representa a própria restrição. Igualando a primeira equação à zero, temos que:

$$\mathbf{w}^t \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^t = -\lambda \mathbf{w}^t \quad (5)$$

O somatório apresentado no lado esquerdo da equação (5) representa a matriz de covariância do banco de dados  $\mathbf{X}$  ( $\Sigma_X$ ). Assim, é possível escrever a mesma equação em um formato mais compacto:

$$\mathbf{w}^t \Sigma_X = \lambda \mathbf{w}^t \quad (6)$$

A equação (6) define os autovalores e autovetores da matriz  $\Sigma_X$ . O vetor que maximiza a variância dos dados  $\mathbf{X}$  é o autovetor correspondente ao maior autovalor da matriz de covariância  $\Sigma_X$ .

## 3. ESTIMADOR DE MÍNIMOS QUADRADOS

O Estimador de Mínimos Quadrados (EMQ), como o próprio nome sugere, é utilizado para estimar os melhores parâmetros de uma série temporal de acordo com um conjunto de dados previamente coletados e considerando um modelo auto regressivo de ordem  $n$  arbitrária. Esse modelo pode ser escrito como em (7) ou de maneira mais compacta em (8):

$$y_k = \sum_{i=1}^n -a_i y_{k-i} \quad (7)$$

Em que  $y_k$ , valor no instante  $k$ , é uma combinação do seus valores passados,  $y_{k-i}$ , ponderados por pesos  $a_i$ .

$$y_k = \mathbf{x} \theta \quad (8)$$

Em que  $\mathbf{x}$  é o vetor que representa as realizações anteriores do modelo,  $\mathbf{x} \in \mathbb{R}^{1 \times n}$ , e  $\theta$  é o vetor com os coeficientes do sistema, assim  $\theta \in \mathbb{R}^{n \times 1}$ .

Para estimar os valores dos parâmetros encontrados em  $\theta$  é necessário conhecer  $m$  realizações desse evento, com a limitação que  $m \geq 2n$ , resultando em (9)

$$\mathbf{Y} = \mathbf{X} \theta \quad (9)$$

Em que  $\mathbf{Y}$  representa o vetor com as  $m - n$  realizações mais recentes resultando em  $\mathbf{Y} \in \mathbb{R}^{(m-n) \times 1}$ ,  $\mathbf{X}$  deixa de ser um vetor de regressores e passa a ser uma matriz de dimensão  $\mathbb{R}^{(m-n) \times n}$  e devido a ordem do sistema não mudar com a inclusão de novas observações, o vetor  $\theta$  permanece representando os parâmetros do sistema sendo  $\theta \in \mathbb{R}^{n \times 1}$ .

Para o caso limite, em que  $m = 2n$ , a matriz de regressores torna-se quadrada e a resolução do problema é resumida à inversão da matriz  $\mathbf{X}$  para calcular a estimativa  $\hat{\theta}$  dos parâmetros  $\theta$  do sistema:

$$\hat{\theta} = \mathbf{X}^{-1} \mathbf{Y}$$

Para sistemas sobredeterminados, ou seja, com  $m > 2n$ , a matriz de regressores não é quadrada, logo não inversível, o que torna necessário realizar manipulações algébricas para encontrar uma solução para o sistema:

$$\hat{\theta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (10)$$

A equação (10) utiliza a pseudo-inversa de Moore-Penrose para chegar a uma das infinitas possíveis soluções para o sistema. Entretanto, prova-se que é a solução que melhor aproxima o vetor de parâmetros estimados,  $\hat{\theta}$ , do vetor de parâmetros corretos,  $\theta$ , minimizando a função de custo.

#### 4. EMQ RECURSIVO

O método EMQ formalizado anteriormente mostra a situação em que toda a massa de dados é previamente coletada e seu processamento é realizado em batelada para utilizar a informação encontrada a posteriori Aguirre (2015). Outra situação, comum em casos práticos, acontece quando os dados são disponibilizados sequencialmente e se deseja extrair a informação desses dados a cada nova amostra coletada. Para fazê-lo, utiliza-se a estimação recursiva de parâmetros Aguirre (2015).

Para continuar com a definição matemática do método recursivo, toma-se a equação (11), presente em Aguirre (2015), que considera pesos  $w_i$  para cada amostra para estimar os coeficientes presentes em  $\hat{\theta}$  no instante  $k$ :

$$\begin{aligned} \hat{\theta}_k &= \left[ \sum_{i=1}^k w_i(k) \psi(i-1) \right]^{-1} \sum_{i=1}^k w_i(k) \psi(i-1) y(i) \\ &= \mathbf{P}_k \mathbf{F}_k \end{aligned} \quad (11)$$

A equação (11) é uma maneira de representar a estimativa atual dos coeficientes  $\hat{\theta}_k$ , considerando uma combinação do vetor de regressores (12), o valor atual,  $y(i)$ , e dos pesos,  $w_i(k)$ . Para simplificar a notação de (11) utiliza-se  $\mathbf{P}_k$  e  $\mathbf{F}_k$ .

$$\psi(i) = \begin{bmatrix} y(i-1) \\ y(i-2) \\ \vdots \\ y(i-n) \end{bmatrix} \quad (12)$$

Em se tratando de processamento em batelada, o tamanho do conjunto de dados é fixo. Assim, cada peso é constante e associado à sua respectiva amostra (o peso  $w_{14}$  é associado à décima quarta amostra). No caso recursivo, o valor dos pesos deve variar de acordo com a chegada de novos dados. Portanto, além do índice, será usado o argumento para identificar os pesos, assim,  $w_i(k)$  é o valor do  $i$ -ésimo peso da  $k$ -ésima iteração, considerando  $k \geq i$ .

Dessa forma, a sequência de pesos deve seguir a seguinte restrição:

$$\begin{cases} w_k(k) = 1 \\ w_i(k) = \lambda w_i(k-1), \quad i < k \end{cases} \quad (13)$$

Essa restrição mostra que o maior peso é unitário e corresponde ao último valor recebido. Sempre que um novo dado é recebido os pesos são multiplicados pelo fator de esquecimento  $\lambda$ .

A partir da equação (11) e utilizando a restrição de (13) escreve-se  $\mathbf{P}_k^{-1}$  como:

$$\mathbf{P}_k^{-1} = \lambda \mathbf{P}_{k-1}^{-1} + \psi(k-1) \psi^T(k-1) \quad (14)$$

Equacionando  $\mathbf{F}_k$  de (11) da mesma maneira, tem-se:

$$\mathbf{F}_k = \lambda \mathbf{F}_{k-1} + \psi(k-1) y(k) \quad (15)$$

Reescrevendo (11) a partir de (14) e (15), encontra-se:

$$\hat{\theta}_k = \hat{\theta}_{k-1} + \mathbf{P}_k \psi(k-1) \left[ y(k) - \psi^T(k-1) \hat{\theta}_{k-1} \right] \quad (16)$$

Após a inversão de  $\mathbf{P}_k^{-1}$  presente na (14), conclui-se:

$$\mathbf{P}_k = \frac{1}{\lambda} \left( \mathbf{P}_{k-1} - \frac{\mathbf{P}_{k-1} \psi(k-1) \psi^T(k-1) \mathbf{P}_{k-1}}{\psi^T(k-1) \mathbf{P}_{k-1} \psi(k-1) + \lambda} \right) \quad (17)$$

Na equação (16) o ganho de adaptação do vetor estimado, também chamado de *ganho de Kalman*, é  $\mathbf{K}_k = \mathbf{P}_k \psi(k-1)$  e aplicando (17) nesse ganho, encontra-se:

$$\begin{aligned} \mathbf{K}_k &= \mathbf{P}_k \psi(k-1) \\ &= \frac{\mathbf{P}_{k-1} \psi(k-1)}{\psi^T(k-1) \mathbf{P}_{k-1} \psi(k-1) + \lambda} \end{aligned} \quad (18)$$

Por fim, organiza-se as equações (16), (17) e (18) para encontrar o estimador de mínimos quadrados recursivo com fator de esquecimento  $\lambda$ :

$$\begin{cases} \mathbf{K}_k = \frac{\mathbf{P}_{k-1} \psi_k}{\psi_k^T \mathbf{P}_{k-1} \psi_k + \lambda} \\ \hat{\theta}_k = \hat{\theta}_{k-1} + \mathbf{K}_k \left[ y(k) - \psi_k^T \hat{\theta}_{k-1} \right] \\ \mathbf{P}_k = \frac{1}{\lambda} \left( \mathbf{P}_{k-1} - \frac{\mathbf{P}_{k-1} \psi_k \psi_k^T \mathbf{P}_{k-1}}{\psi_k^T \mathbf{P}_{k-1} \psi_k + \lambda} \right) \end{cases} \quad (19)$$

Em que  $\psi(i-1)$  é representado por  $\psi_k$  descrito por (20).

$$\psi_k = \begin{pmatrix} y_{k-1} \\ y_{k-2} \\ \vdots \\ y_{k-n} \end{pmatrix} \quad (20)$$

Nota-se que apesar de se tratar do instante  $k$ , o vetor  $\psi_k$  apresenta informações a partir do instante  $k-1$ . Isso é importante para que no cálculo de atualização de  $\hat{\theta}_k$ , segunda equação em (19), seja utilizado o erro de estimação uma vez que  $\hat{y}_k = \psi_k^T \theta_k$ .

#### 5. GESTOS

Para assegurar uma boa caracterização do sinal obtido, optou-se por posições marcantes evitando diferenças sutis entre cada repetição. Dessa forma as posições escolhidas foram: punho fechado, mão espalmada, mão flexionada para a esquerda e mão flexionada para a direita, como mostrado na Figura 1.

Vale salientar que somente a mão realizou movimento, não existindo variação de posição do braço e do antebraço. Dessa forma minimiza-se a interferência de sinais de EMG de outros grupos musculares.

Ainda sobre as posições escolhidas é importante lembrar que existe uma quinta posição a ser identificada: mão



Figura 1. Gestos propostos

relaxada ou ausência de movimento. Essa posição deve ser levada em consideração, pois tão importante quanto identificar quando e qual ação está sendo executada é identificar quando nenhuma das posições está sendo praticada. Para facilitar a nomenclatura de cada posição foram atribuídos números para cada posição de acordo com a Tabela 1.

Tabela 1. Definição numérica das posições

Posição executada	Número correspondente
Mão relaxada	0
Mão espalmada	1
Punho fechado	2
Flexionada para esquerda	3
Flexionada para direita	4

## 6. AQUISIÇÃO DE DADOS

Para formar o banco de dados foi necessário estabelecer uma rotina em que os valores obtidos pelo conversor AD foram ajustados de acordo com Equação (21), para que as leituras estivessem em seus valores reais e enviados sequencialmente para o computador mantendo-os em uma mesma linha, a leitura seguinte dos sensores foi posta na linha abaixo e assim por diante. Dessa forma trabalhou-se com os dados com seus valores originais sem adicionar outras dinâmicas provenientes de processos de filtragem.

$$V = \frac{5 L_d}{1023} - 2,5 \quad (21)$$

A Equação (21) converte a leitura digital do conversor AD,  $L_d \in \mathbb{Z} / 0 \leq L_d \leq 1023$ , para o respectivo valor,  $V \in \mathbb{R} / -2,5 \leq V \leq 2,5$ , em Volts do sinal original.

A rotina de aquisição de dados foi implementada em um Arduino atingindo um período de amostragem de  $2,4ms$  e o banco de dados formado obedeceu o formato mostrado na Tabela 2 em que cada coluna da tabela representa a série temporal de cada sensor.

Tabela 2. Estrutura do banco de dados

	Sensor 1	Sensor 2	Sensor 3	Sensor 4
$i = 1$	$V_{11}$	$V_{21}$	$V_{31}$	$V_{41}$
$i = 2$	$V_{12}$	$V_{22}$	$V_{32}$	$V_{42}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$i = n$	$V_{1n}$	$V_{2n}$	$V_{3n}$	$V_{4n}$

Ao final do processo de aquisição de dados, foi formado um banco de dados com 10 arquivos de texto para cada posição ativa. Todos os arquivos se iniciam na posição relaxada, o movimento é executado por aproximadamente 10 segundos e em seguida retorna ao relaxamento.

Em se tratando de séries temporais é possível visualizá-las graficamente como apresentado na Figura 2. Essa imagem apresenta a execução completa do movimento de punho fechado.

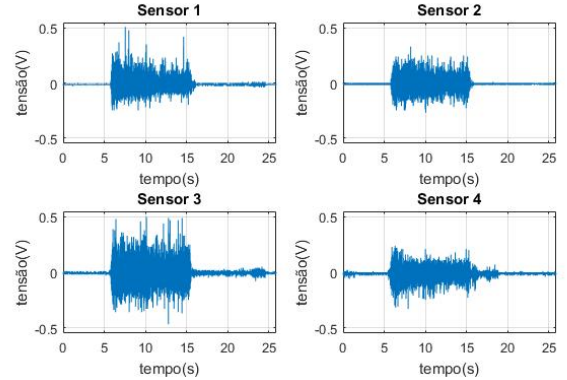


Figura 2. Execução do movimento de mão punho fechado

Ao analisar a Figura 2 percebe-se que existe uma grande diferença entre os momentos de execução de movimentos e os de relaxamento e que uma simples detecção de envoltória seria o suficiente para classificar o estado da musculatura como contraída ou relaxada, mas não seria capaz de distinguir as diferentes possibilidades de movimentos da mão.

## 7. SIMULAÇÃO DAS TÉCNICAS

Para a PCA utilizou-se o vetor  $\mathbf{w}$ , vetor de rotação obtido a partir da matriz de covariância dos dados  $\Sigma_{\mathbf{x}}$ , como parâmetro de comparação para estimação do gesto executado. Para o EMQ e EMQR os sinais foram modelados como processos auto regressivos de quarta ordem, como nos trabalhos que aplicam modelos auto regressivos em sinais de EMG Jiang et al. (2017) e Aishwarya et al. (2013), resultando em quatro vetores  $\hat{\theta}$  com quatro coeficientes cada, esses vetores foram concatenados formando um único vetor  $\hat{\theta}_c \in \mathbb{R}^{16 \times 1}$ , que serviu como parâmetro de comparação.

Todas as técnicas foram submetidas à etapa de treinamento para definir os valores dos parâmetros de referência. O banco de dados foi dividido em duas partes iguais, uma para a etapa de treinamento e a outra para validação dos resultados. A etapa de treinamento foi feita aplicando as técnicas separadamente em cada seção do banco de dados de acordo com movimento executado. Assim, foram extraídos os valores médios para o vetor de coeficientes  $\hat{\theta}_c$  (EMQ e EMQR) e do vetor de rotação  $\mathbf{w}$  (PCA).

A simulação dos métodos foi feita utilizando o software MATLAB de acordo com o diagrama de blocos apresentado na Figura 3. Dessa forma, os dados são apresentados aos métodos de maneira sequencial semelhante à situação real, gerando uma estimação em tempo real.

Ainda sobre a Figura 3, os métodos que necessitam de uma parcela do banco de dados para serem executados (PCA e EMQ) apresentam  $N=100$  para o bloco “N amostras”, enquanto o método EMQR é executado a cada nova amostra, logo  $N=1$ . Dessa forma, percebe-se uma




Figura 3. Diagrama de blocos para simulação

diferença fundamental entre as estimações em batelada e a *on-line*: em batelada os parâmetros são calculados com menos frequência que *on-line*, tornando o algoritmo final computacionalmente mais eficiente.

A fim de analisar o resultado das simulações de maneira quantitativa em erros e acertos, foi necessário adicionar manualmente uma quinta coluna ao banco de dados representando qual posição está sendo executada no instante  $i$ . Assim, o banco de dados ficou estruturado como apresentado na Tabela 3.

Tabela 3. Nova estrutura do banco de dados

	Sensor 1	Sensor 2	Sensor 3	Sensor 4	Posição
$i = 1$	$V_{11}$	$V_{21}$	$V_{31}$	$V_{41}$	$P_1$
$i = 2$	$V_{12}$	$V_{22}$	$V_{32}$	$V_{42}$	$P_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$i = n$	$V_{1n}$	$V_{2n}$	$V_{3n}$	$V_{4n}$	$P_n$

Em que  $P_i \in [0, 1, 2, 3, 4]$  de acordo com as definições da Tabela 1. A quinta coluna adicionada foi importante para definir se a classificação obteve sucesso e assim determinar quais técnicas seriam adequadas para a identificação dos movimentos.

Os resultados das estimações serão apresentados no formato de matrizes de confusão, onde é possível analisar de forma mais detalhada os erros e acertos para cada método em cada posição. A matriz de confusão é uma matriz quadrada em que cada linha representa as instâncias de uma classe prevista, enquanto as colunas representam os casos de uma classe real e é construída com base nos erros e acertos de cada posição. A matriz ideal teria nos seus elementos da diagonal principal o total de vezes que cada posição deveria ter sido estimada e os demais elementos nulos.

### 7.1 PCA

Utilizando o método definido matematicamente em (5) sobre o banco de dados, encontrou-se a matriz de confusão apresentada na Tabela 4 contendo o resultado da simulação da PCA.

Analisando a Tabela 4, percebe-se que aplicar a PCA para estimar a posição da mão atinge bons resultados ao estimar a posição 3, atingindo 96,7% de acerto. Em contrapartida, ao estimar a posição 2 somente 8,9% das estimativas obtiveram sucesso.

Tabela 4. Matriz de confusão para simulação da PCA

	Pos. 0	Pos. 1	Pos. 2	Pos. 3	Pos. 4
Pos. 0	653	30	41	2	12
Pos. 1	47	195	59	0	0
Pos. 2	19	0	19	6	0
Pos. 3	71	22	52	237	38
Pos. 4	88	30	42	0	190
Média	74,37%	70,40%	8,92%	96,73%	79,17%

### 7.2 EMQ

O Estimador de Mínimos Quadrados definido na (10) foi aplicado sobre o banco de dados obtendo os resultados apresentados na matriz de confusão da Tabela 5.

Tabela 5. Matriz de confusão para simulação do EMQ

	Pos. 0	Pos. 1	Pos. 2	Pos. 3	Pos. 4
Pos. 0	841	1	5	4	0
Pos. 1	9	269	27	0	15
Pos. 2	0	3	177	3	0
Pos. 3	18	0	4	238	0
Pos. 4	10	4	0	0	225
Média	95,79%	97,11%	83,10%	97,14%	93,75%

Ao analisar a Tabela 5 percebe-se que para todas as posições o método apresenta maior número de estimações corretas que incorretas, obtendo pior desempenho ao identificar a posição 2 com 83,1% de taxa de acerto e a posição com melhor taxa de acerto foi a posição 1 com 97,11% de identificações bem sucedidas.

### 7.3 EMQR

O método recursivo definido na (19) utilizou o banco de dados de forma sequencial para estimar a posição atual, encontrando os resultados apresentados na matriz de confusão da Tabela 6:

Tabela 6. Matriz de confusão para simulação do EMQR

	Pos. 0	Pos. 1	Pos. 2	Pos. 3	Pos. 4
Pos. 0	840	1	7	3	0
Pos. 1	12	251	34	0	25
Pos. 2	0	6	163	10	1
Pos. 3	19	0	9	232	0
Pos. 4	7	19	0	0	214
Média	95,67%	90,61%	76,52%	94,67%	89,17%

A Tabela 6 mostra que, assim como no método não recursivo, o número de acertos supera o número de erros, atingindo melhor desempenho ao estimar a posição 0 com 95,67% de sucesso nas estimações e no pior dos casos estimou corretamente 76,52% a posição 2.

## 8. CONCLUSÃO

Com a informação do resultado das simulações mostrados nas Tabelas 4, 5 e 6, extraiu-se a média de acertos para cada estratégia como apresentado na Tabela 7.

A Tabela 7 mostra que as técnicas que modelam os sinais como processos auto regressivos têm média de acerto

Tabela 7. Percentual de acerto das simulações

	$\mu$	$\sigma$
PCA	65,99%	33,41
EMQ	93,38%	5,91
EMQR	89,33%	7,66

próximas de 90%, enquanto a PCA pode chegar a ter mais estimações erradas que corretas. O motivo da PCA não obter êxito na identificação das posições pode ser devido ao número reduzido de sensores utilizados, o que torna os sinais previamente descorrelacionados. Outro fator para o insucesso da PCA é que os sinais para a posição relaxada já estão descorrelacionados, pois não há atividade muscular diferenciada para os sensores.

Ainda sobre a Tabela 7, nota-se que o estimador não recursivo apresenta melhor desempenho quando comparado ao estimador recursivo. Isso acontece pois o EMQ utiliza toda a informação presente no banco de dado para encontrar os parâmetros de  $\hat{\theta}$  de acordo com (10), enquanto o método recursivo utiliza apenas as  $n$  amostras mais recentes para atualizar  $\hat{\theta}_k$  de acordo com (19).

#### REFERÊNCIAS

- Aguirre, L. (2015). *Introdução à Identificação de Sistemas*. doi:10.13140/RG.2.1.1616.7925.
- Aishwarya, R., M., P., G., S., and M., A. (2013). Feature extraction for emg based prostheses control. *ICTACT Journal on Soft Computing*, 03, 472–477. doi:10.21917/ijsc.2013.0071.
- Boyalı, A. and Hashimoto., N. (2016). Spectral collaborative representation based classification for handgestures recognition on electromyography signals. *Biomedical Signal Processing And Control*, 24, 11–18.
- Brahimzadeh, A., Azimi, H., and Mirbozorgi, S. (2011). Digital communication signals identification using an efficient recognizer. *Measurement*, 44, 1475–1481.
- Delis, A.L., Carvalho, J.L.A., da Rocha, A.F., Ferreira, R.U., Rodrigues, S.S., and Borges, G.A. (2009). Estimation of the knee joint angle from surface electromyographic signals for active control of leg prostheses. *Physiol Meas*, 30, 931–946.
- Hild, K.E., Erdogmus, D., Torkkola, K., and Principe, J.C. (2006). Feature extraction using information-theoretic learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28, 1385–1392.
- Jiang, X., Merhi, L.K., Xiao, Z., and Menon, C. (2017). Exploration of force myography and surface electromyography in hand gesture classification. *Medical Engineering Physics*, 41, In Press. doi:10.1016/j.medengphy.2017.01.015.
- Kazamel, M. and Warren, P.P. (2017). History of electromyography and nerve conduction studies: A tribute to the founding fathers. *Journal Of Clinical Neuroscience*, 43, 54–60.
- Santhiyarayanan, M., Mulling, T., and Nazir, B. (2015). Controlling a robot using a wearable device (myo). *International Journal of Engineering Development and Research (IJEDR)*, 3.
- Subasi, A. and Gursoy, M. (2010). Eeg signal classification using pca, ica, lda and support vector machines. *Measurement*, 37, 8659–8666.
- Wang, N., K.Lao, and Zhang., X. (2017). Design and myoelectric control of an anthropomorphic prosthetic hand. *Journal Of Bionic*, 14, 47–59.
- Winiarski, D. (2015). The use of emg signal in human-machine interface. *AUTOMATYKA/AUTOMATICS*, 19, 47–61.
- Xie, S., Jin, F., Krishnan, S., and Sattar, F. (2012). Signal feature extraction by multi-scale pca and its application to respiratory sound classification. *Medical Biological Engineering Computing*, 50, 759–768.