

Gizele Ginklings Fróes da Cruz

**CLASSIFICAÇÃO DOS MOVIMENTOS DA MÃO BASEADOS NA AQUISIÇÃO NÃO  
INVASIVA DE SINAIS MIOELÉTRICOS PROVENIENTES DOS MÚSCULOS DO  
ANTEBRAÇO ATRAVÉS DE REDES NEURAIAS ARTIFICIAIS**

Trabalho de Conclusão de Curso submetido ao curso de Engenharia Eletrônica da Universidade Federal de Santa Catarina para a obtenção do Grau de Bacharel em Engenharia Eletrônica.

Orientador: Prof. Jefferson Luiz Brum Marques, PhD.

Florianópolis

2017

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Cruz, Gizele Ginklings Fróes da  
Classificação dos movimentos da mão baseado na  
aquisição não invasiva de sinais mioelétricos  
provenientes dos músculos do antebraço através de  
redes neurais artificiais / Gizele Ginklings Fróes  
da Cruz ; orientador, Jefferson Luiz Brum Marques,  
2017.  
96 p.

Trabalho de Conclusão de Curso (graduação) -  
Universidade Federal de Santa Catarina, Centro  
Tecnológico, Graduação em Engenharia Eletrônica,  
Florianópolis, 2017.

Inclui referências.

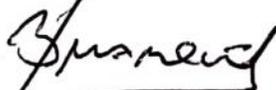
1. Engenharia Eletrônica. 2. Amputação do membro superior. 3. Redes neurais artificiais. 4. Próteses mioelétricas. 5. Matlab. I. Marques, Jefferson Luiz Brum. II. Universidade Federal de Santa Catarina. Graduação em Engenharia Eletrônica. III. Título.

Gizele Ginklings Fróes da Cruz

**CLASSIFICAÇÃO DOS MOVIMENTOS DA MÃO BASEADOS NA AQUISIÇÃO  
NÃO INVASIVA DE SINAIS MIOELÉTRICOS PROVENIENTES DOS  
MÚSCULOS DO ANTEBRAÇO ATRAVÉS DE REDES NEURAIS ARTIFICIAIS**

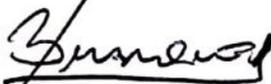
Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do Título de Engenheira Eletrônica e aprovado em sua forma final pelo Departamento de Engenharia Elétrica e Eletrônica da Universidade Federal de Santa Catarina.

Florianópolis, 08 de dezembro de 2017.



Prof. Jefferson Luiz Brum Marques, PhD.  
Coordenador do curso

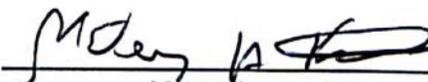
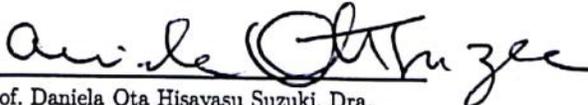
Banca Examinadora:



Prof. Jefferson Luiz Brum Marques, PhD.  
Orientador  
Universidade Federal de Santa Catarina



Prof. Daniela Ota Hisayasu Suzuki, Dra.  
Universidade Federal de Santa Catarina



Mateus Favretto, ME.  
Universidade Federal de Santa Catarina



À minha mãe, por me mostrar que sempre existe um caminho.

À minha irmã, por ser minha melhor amiga.



## AGRADECIMENTOS

Agradeço a minha família, meus pais e irmãos, principalmente a minha mãe, pelo apoio incondicional nessa minha trajetória. À minha irmã Juliana, que além de irmã, é amiga e cúmplice de todas as horas. As minhas tias que eu tanto adoro e ao meu primo Gustavo, que quando eu ainda estava decidindo o que fazer da minha vida, foi quem me deu a ideia de fazer o curso de eletrônica. Ao Jonas pelos docinhos.

Ao meu namorado Giovanni, que torna o meu dia-a-dia muito mais divertido, parceiro de momento bons e descontraídos, e das horas de estudos que foram necessárias ao longo do curso.

Aproveitando para voltar um pouquinho no tempo, para a época que estava estudando para o vestibular, e agradecer a todas as meninas da Livraria Mar e Letras, que me deram muito apoio para o início da minha jornada na graduação, destacando a Paula, por quem tenho muito admiração.

Aos meus amigos da faculdade Isa, Neckel, Jorge, Vini, Erich, Giovanni, Matheus, Raul, Gui, Brida, obrigado por todos esses anos de amizade, estudo e carinho. Em especial a Isa, por nossas longas conversas e o Erich pelo carinho e paciência em me ajudar sempre que precisei.

Aos funcionários e sócios da empresa Medical Harbour e Customize, pela amizade, ensinamento e confiança no meu trabalho. Principalmente ao meu chefe Enrico, me ensinando a ser mais criativa e a Maiara, tornando minhas horas de almoço descontraídas.

Ao meu orientador Jefferson, por toda a dedicação para me ajudar a realizar esse trabalho e apoio para que eu ingressasse na área de engenharia biomédica. Aos membros da minha banca, Suzuki e Mateus, e todos os professores da graduação, que me ajudaram a construir minha formação.

À Universidade Federal de Santa Catarina, pela estrutura, possibilitando o acesso à um excelente curso, e a todos os funcionários que fazem com que a UFSC funcione.

À todos que contribuíram para a minha formação e vida profissional.



"Porque, quando uma mosca bate as asas, uma brisa sopra no mundo;  
quando uma partícula de poeira cai no chão, o planeta fica um pouco mais pesado;  
e quando batemos o pé a terra sai um pouco do seu curso.  
Sempre que rimos, a felicidade espalha-se como as ondas de um lago;  
e sempre que ficamos tristes, ninguém pode estar totalmente feliz."

(JUSTER, Norton, 1999)



## RESUMO

A mão humana é o órgão responsável pela maior parte das atividades do cotidiano, a sua perda pode ser suprida através de técnicas de protetização, visando restaurar, além da estética, a funcionalidade do membro perdido. O objetivo desse trabalho é realizar um estudo voltado para o controle de próteses do membro superior, dessa forma, classificou-se quatro movimentos da mão, provenientes de uma aquisição não invasiva dos sinais mioelétricos dos músculos do antebraço: abrir e fechar de mãos, prensão palmar, referente a ação de segurar um copo, prensão dígito-polegar, referente a ação de segurar um alfinete e o estado de repouso, quando o indivíduo não está executando nenhum movimento. Utilizou-se dois bancos de dados, um de indivíduos normais e outro de indivíduos com amputação transradial do membro superior, para ambos os casos, o banco de dados foi composto de onze indivíduos homens, com cada movimento repetido cinco vezes por cada indivíduo. A classificação dos movimentos foi feita através de redes neurais artificiais, utilizando a *toolbox nntool* do Matlab, os dados passaram por um processamento, foram utilizados os seguintes filtros: DC, *notch* de 60 Hz para remover a interferência da rede, média móvel e passa-baixa de 500 Hz, após as filtrações, diminuiu-se a quantidade de amostras, mudando o sinal de uma frequência de amostragem de 2 KHz para 500 Hz. Os melhores resultados para o banco de dados dos indivíduos normais para o estado de repouso foi com a rede neural NARX com função de ativação linear, com os valores de desempenho de seletividade positiva de 98,04%, seletividade negativa de 55,55%, sensibilidade de 90,90%, especificidade de 86,21% e eficiência de 90,36%. Para o movimento de abrir a mão, foi com a rede neural *feed-forward backpropagation* com função de ativação tangente hiperbólica sigmoide, com os valores de desempenho de seletividade positiva de 51,72%, seletividade negativa de 68,35%, sensibilidade de 54,54%, especificidade de 65,85% e eficiência de 61,32%. Para o movimento de fechar a mão foi com a rede neural *cascade-forward backpropagation* com função de ativação tangente hiperbólica sigmoide, com os valores de desempenho de seletividade positiva de 63,64%, seletividade negativa de 80,88%, sensibilidade de 76,36%, especificidade de 69,62% e eficiência de 72,39%. Para o movimento de prensão palmar foi com a rede neural NARX com função de ativação tangente hiperbólica sigmoide, com os valores de desempenho de seletividade positiva de 85,94%, seletividade negativa de 70,77%, sensibilidade de 83,64%, especificidade de 74,32% e eficiência de 78,30%. Para o movimento de prensão dígito-polegar foi com a rede neural NARX com função de ativação linear, com os valores de desempenho de seletividade positiva de 98,21%, seletividade negativa de 100,00%, sensibilidade de 100,00%, especificidade de 66,67% e eficiência de 98,28%. Apesar de a rede NARX com função de ativação linear trazer bons resultados para os casos de repouso e movimento de pinça, para os demais movimentos essa foi a rede com pior desempenho. Os valores de desempenho para banco de dados dos indivíduos amputados foram inferiores quando comparados com o desempenho dos indivíduos normais. Os melhores resultados para o banco de dados dos indivíduos amputados para o estado de repouso foi com a rede neural *feed-forward backpropagation* com função de ativação tangente hiperbólica sigmoide, com os valores de desempenho de seletividade positiva de 54,30%, seletividade negativa de 63,87%, sensibilidade de 54,80%, especificidade de 59,60% e eficiência de 63,41%. Para o movimento de abrir a mão, foi com a rede neural *feed-forward backpropagation* com função de ativação tangente hiperbólica sigmoide, com os valores de desempenho de seletividade positiva de 30,77%, seletividade negativa de 66,67%, sensibilidade de 50,90%, especificidade de 47,67% e eficiência de 46,15%. Para o movimento de fechar a mão também foi com a rede neural *feed-forward backpropagation* com função de ativação tangente hiperbólica sigmoide, com os valores de desempenho de seletividade positiva de 63,33%, seletividade negativa de 76,39%, sensibilidade de 69,09%, especificidade de 70,45% e eficiência de 71,43%. Para o movimento de prensão palmar foi com a rede neural *feed-forward backpropagation* com função de ativação tangente hiperbólica sigmoide, com os valores de desempenho de seletividade positiva de 16,18%, seletividade negativa de 62,50%, sensibilidade de 40,00%, especificidade de 32,54% e eficiência de 34,30%. Para o movimento de prensão dígito-polegar foi com a rede neural *cascade-forward backpropagation* com função de ativação tangente hiperbólica sigmoide, com os valores de desempenho de seletividade positiva de 20,510%, seletividade negativa de 61,25%, sensibilidade de 43,64%, especificidade de 34,50% e eficiência de 37,06%. A rede que no conjunto dos movimentos

e repouso teve a melhor performance foi a rede *feed-forward backpropagation* com função de ativação tangente hiperbólica sigmoide, tanto para os indivíduos normais como para os indivíduos amputados.

**Palavras-chave:** Amputação do membro superior. Amputação transradial. Sinais mioelétrico. Redes neurais artificiais. Matlab. Próteses mioelétricas. Mão humana.

## ABSTRACT

The human hand is the organ responsible for the majority of day-to-day life activities, and the consequences of its loss can be reduced by using prosthetization techniques that aim to restore aesthetics and functionality of a lost limb. The goal of this thesis is to study ways of controlling upper limb prosthesis. Four hand movements were studied and classified, for which its signals were collected through non-invasive sensors to read myoelectric signal from the patient's forearm: opening and closing of hand, palmar pressure (equivalent to holding a cup), pincer pressure (equivalent to holding a pin) and finally when the hand is at rest. Two sets of data were used, one from individuals that still have a hand and another one with individuals that lost their hand but still had most of its forearm. On both sets, the study was conducted using eleven men, with each movement repeated five times per individual. The classification of the movements was made through artificial neural networks, using the nntool Matlab toolbox. All the signals were preprocessed using the following filters: DC removal, 60Hz notch filter, moving average and a 500Hz low-pass filter, after filtering, the signal was decimated to a sampling frequency of 500Hz. The best achieved results for the normal patients were the detection of state of resting hand using the NARX network with linear activation function, that yielded a positive selectivity of 98,04%, negative selectivity of 55,55%, sensibility of 90,90%, specificity of 86,21% and efficiency of 90,36%. To the hand opening movement, the best network was the feed-forward backpropagation network with the hyperbolic tangent sigmoid activation function, that yielded a positive selectivity of 51,72%, negative selectivity of 68,35%, sensibility of 54,54%, specificity of 65,85% and efficiency of 61,32%. For the hand closing movement, the best network was the cascade-forward backpropagation network with the hyperbolic tangent sigmoid activation function, that yielded a positive selectivity of 63,64%, negative selectivity of 80,88%, sensibility of 76,36%, specificity of 69,62% and efficiency of 72,39%. For the hand pressure movement, the best network was the NARX network with the logarithmic tangent sigmoid activation function, that yielded a positive selectivity of 85,94%, negative selectivity of 70,77%, sensibility of 83,64%, specificity of 74,32% and efficiency of 78,30%. To the pincer movement, the best network was the NARX network with the linear activation function, that yielded a positive selectivity of 98,21%, negative selectivity of 100,00%, sensibility of 100,00%, specificity of 66,67% and efficiency of 98,28%. Although the NARX network with linear activation function provided good results for the cases of rest and pincer movement, for the other movements this was the worst performing network. The performance values for the amputated individuals' database were lower when compared with the performance of normal individuals. The best results for the amputated individual's database was with the feed-forward backpropagation network with hyperbolic tangent sigmoid activation function, that yielded a positive selectivity of 54,30%, negative selectivity of 63,87%, sensibility of 54,80%, specificity of 59,60% and efficiency of 63,41%. To the hand opening movement, the best network was the feed-forward backpropagation network with the hyperbolic tangent sigmoid activation function, that yielded a positive selectivity of 30,77%, negative selectivity of 66,67%, sensibility of 50,90%, specificity of 47,67% and efficiency of 46,15%. The hand closing movement also had the best network as the cascade-forward backpropagation network with the hyperbolic tangent sigmoid activation function, that yielded a positive selectivity of 63,33%, negative selectivity of 76,39%, sensibility of 69,09%, specificity of 70,45% and efficiency of 71,43%. For the hand pressure movement, the best network was the feed-forward backpropagation network with the logarithmic tangent sigmoid activation function, that yielded a positive selectivity of 16,18%, negative selectivity of 62,50%, sensibility of 40,00%, specificity of 32,54% and efficiency of 34,30%. For the digit-thumb grip motion was with the neural network cascade-forward backpropagation with sigmoid hyperbolic tangent activation function, with values of 20.510% positive selectivity, negative selectivity of 61.25%, sensitivity of 43.64%, specificity of 34.50% and efficiency of 37.06%. The network that in the set of movements and rest had the best performance was the feed-forward backpropagation network with sigmoid hyperbolic tangent activation function for both normal individuals and amputated individuals.

**Keywords:** upper limb amputations. Transradial amputations. Myoelectric signals. Artificial neural networks.

Matlab. Myoelectric prosthesis. Human hand.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Ossos da mão, intervalo entre os ossos articulares para aumentar a base didática, vista palmar. . . . .	25
Figura 2 – Nomenclatura dos dedos da mão humana. . . . .	26
Figura 3 – Origem e inserções musculares nos ossos da mão, vista palmar. . . . .	26
Figura 4 – Músculo do antebraço na vista anterior, camada superficial. . . . .	27
Figura 5 – Preensão Bidigitais. Imagem (A) Preensão por oposição terminal, (B) Preensão polpa a polpa, (C) Preensão pulpo-lateral, (D) Preensão interdigital látero-lateral. . . . .	29
Figura 6 – Preensão pluridigitais. Imagem (A) Preensão tridigital, (B) Preensão petradigital, (C) Preensão pentadigital. . . . .	30
Figura 7 – Preensões palmares. Imagem (A) Preensão dígito-palmar, (B) Preensão Tetradigital. . . . .	30
Figura 8 – Preensões centradas. . . . .	30
Figura 9 – Níveis de amputação do membro superior. . . . .	31
Figura 10 – Próteses estética de mão da empresa <i>Touch Bionic</i> do produto <i>livingskin</i> . . . . .	32
Figura 11 – Prótese de mão de controle motriz, com função pinça-gancho da empresa <i>Fillauer</i> . . . . .	32
Figura 12 – Próteses da empresa <i>Steeper</i> , produto <i>bebionic</i> nas cores preta e branca. . . . .	33
Figura 13 – Prótese da empresa <i>Touch Bionic</i> , produto <i>i-limb quantum</i> . . . . .	33
Figura 14 – Modelo proposto por McCulloch e Pitts de uma unidade de processamento. As entradas são multiplicadas por pesos, então são somadas, passam por uma função de ativação, para então apresentar uma resposta de saída. . . . .	35
Figura 15 – Rede de única camada com duas entradas e duas saídas. . . . .	36
Figura 16 – Rede de múltipla camada, nesse caso com uma camada oculta de duas entradas e duas saídas . . . . .	36
Figura 17 – Funções utilizadas como funções de ativação. Em (a) função linear, (b) função tangente hiperbólica sigmoide e (c) função sigmoide logarítmica. Na parte inferior das imagens o nome utilizado para descrevê-las no MATLAB. . . . .	36
Figura 18 – Fluxograma da metodologia empregada no trabalho. . . . .	41
Figura 19 – Posicionamento dos eletrodos para aquisição dos sinais mioelétricos. . . . .	43
Figura 20 – Movimentos escolhidos para a classificação da RNA. Estudos de caso: movimento 1: mão aberta (A); movimento 2: mão fechada (B); movimento 3: pinça-clássica (C); e movimento 4: segurando um copo (D). . . . .	43
Figura 21 – Rede neural <i>Feed-forward Backpropagation</i> com a configuração utilizada nas simulações. . . . .	44
Figura 22 – Rede neural <i>Cascade-forward Backpropagation</i> com a configuração utilizada nas simulações. . . . .	45
Figura 23 – Rede neural NARX com a configuração utilizada durante a simulação. . . . .	45
Figura 24 – Canais de emg (1 ao 6) dos sinais mioelétrico de um dos indivíduos. Cada canal representa os quatro movimentos, cada qual repetido cinco vezes. . . . .	46
Figura 25 – Canais de emg (7 ao 12) dos sinais mioelétrico de um dos indivíduos. Cada canal representa os quatro movimentos, cada qual repetido cinco vezes. . . . .	47
Figura 26 – Primeiro canal de EMG dos sinais mioelétrico de um dos indivíduos, com indicação dos movimentos repetidos cinco vezes. Movimento 1: Abrir a mão. Movimento 2: Fechar a mão. Movimento 3: Preensão palmar. Movimento 4: Preensão dígito-polegar. . . . .	47
Figura 27 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o estado de repouso. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais. . . . .	48
Figura 28 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o primeiro movimento. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais. . . . .	49
Figura 29 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o segundo movimento. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais. . . . .	50

Figura 30 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o terceiro movimento. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais.	51
Figura 31 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o quarto movimento. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais.	52
Figura 32 – Exemplo de funcionamento do <i>Schmitt trigger</i> .	54
Figura 33 – Exemplo de funcionamento do <i>Schmitt trigger</i> .	55
Figura 34 – Em azul, gráfico dos sinais mioelétrico. Em laranja gráfico da saída da rede filtrada. Na ordem dos estudos de caso: repouso, movimento 1 e movimento 2.	56
Figura 35 – Em azul, gráfico dos sinais mioelétrico. Em laranja gráfico da saída da rede filtrada. Na ordem dos estudos de caso: movimento 3 e movimento 4.	57
Figura 36 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: repouso.	57
Figura 37 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: movimento 1.	58
Figura 38 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: movimento 2.	58
Figura 39 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: movimento 3.	59
Figura 40 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: movimento 4.	59

## LISTA DE TABELAS

Tabela 1 – Músculos da mão, localização e função. . . . .	27
Tabela 2 – Músculos do antebraço, localização e função. . . . .	28
Tabela 3 – Características gerais dos bancos de dados 1 e 2 utilizados para o treinamento das RNAs. . . . .	42
Tabela 4 – Banco de dados 2: característica clínica dos indivíduos amputados. . . . .	42
Tabela 5 – Desempenho da rede otimizada com 12 canais, comparou-se amostra por amostra para definir valores de VP, VN, FP e FN. . . . .	54
Tabela 6 – Desempenho da rede otimizada com 12 canais, comparou-se intervalos para definir valores de VP, VN, FP e FN. . . . .	55
Tabela 7 – Desempenho da rede filtrada. . . . .	56
Tabela 8 – Desempenho da rede <i>feed-forward backpropagation</i> com função de ativação TANSIG para o banco de dados de indivíduos normais. . . . .	61
Tabela 9 – Desempenho da rede <i>feed-forward backpropagation</i> com função de ativação PURELIN para o banco de dados de indivíduos normais. . . . .	61
Tabela 10 – Desempenho da rede <i>feed-forward backpropagation</i> com função de ativação LOGSIG para o banco de dados de indivíduos normais. . . . .	62
Tabela 11 – Desempenho da rede <i>cascade-forward backpropagation</i> com função de ativação TANSIG para o banco de dados de indivíduos normais. . . . .	62
Tabela 12 – Desempenho da rede <i>cascade-forward backpropagation</i> com função de ativação PURELIN para o banco de dados de indivíduos normais. . . . .	62
Tabela 13 – Desempenho da rede <i>cascade-forward backpropagation</i> com função de ativação LOGSIG para o banco de dados de indivíduos normais. . . . .	62
Tabela 14 – Desempenho da rede NARX com função de ativação TANSIG para o banco de dados de indivíduos normais. . . . .	63
Tabela 15 – Desempenho da rede NARX com função de ativação PURELIN para o banco de dados de indivíduos normais. . . . .	63
Tabela 16 – Desempenho da rede NARX com função de ativação LOGSIG para o banco de dados de indivíduos normais. . . . .	63
Tabela 17 – Melhor desempenho das redes para o estudo de caso 0: repouso. Considerando o banco de dados dos indivíduos normais. . . . .	64
Tabela 18 – Melhor desempenho das redes para o estudo de caso 1: mão aberta. Considerando o banco de dados dos indivíduos normais. . . . .	65
Tabela 19 – Melhor desempenho das redes para o estudo de caso 2: mão fechada. Considerando o banco de dados dos indivíduos normais. . . . .	65
Tabela 20 – Melhor desempenho das redes para o estudo de caso 3: segurando um copo. Considerando o banco de dados dos indivíduos normais. . . . .	65
Tabela 21 – Melhor desempenho das redes para o estudo de caso 4: pinça clássica. Considerando o banco de dados dos indivíduos normais. . . . .	66
Tabela 22 – Desempenho da rede <i>feed-forward backpropagation</i> com função de ativação TANSIG para o banco de dados de indivíduos amputados. . . . .	66
Tabela 23 – Desempenho da rede <i>cascade-forward backpropagation</i> com função de ativação TANSIG para o banco de dados de indivíduos amputados. . . . .	67
Tabela 24 – Desempenho da rede NARX com função de ativação LOGSIG para o banco de dados de indivíduos amputados. . . . .	67
Tabela 25 – Melhor desempenho das redes para o estudo de caso 0: repouso. Considerando o banco de dados dos indivíduos amputados. . . . .	68

Tabela 26 – Melhor desempenho das redes para o estudo de caso 1: mão aberta. Considerando o banco de dados dos indivíduos amputados. . . . .	68
Tabela 27 – Melhor desempenho das redes para o estudo de caso 2: mão fechada. Considerando o banco de dados dos indivíduos amputados. . . . .	68
Tabela 28 – Melhor desempenho das redes para o estudo de caso 3: segurando um copo. Considerando o banco de dados dos indivíduos amputados. . . . .	68
Tabela 29 – Melhor desempenho das redes para o estudo de caso 4: segurando um alfinete. Considerando o banco de dados dos indivíduos amputados. . . . .	69

## LISTA DE ABREVIATURAS E SIGLAS

CFB	<i>Cascade-forward Backpropagation</i>
DOF	Grau de liberdade, do inglês <i>Degree of freedom</i>
EMG	Eletromiografia
FFB	<i>Feed-forward Backpropagation</i>
FN	Falso Negativo
FP	Falso Positivo
Hz	Hertz
IA	Inteligência artificial
IFD	Interfalangeana distal
IFP	interfalangeana proximal
k	Kilo
LOGSIG	Nomenclatura do MATLAB para função de ativação sigmoide logarítmica
M.	Músculo
m	Mili
MF	Morfologia Flexional
ML	Morfologia Lexical
n	Nano
NARX	Rede autorregressiva não linear com entradas externa
PURELIN	Nomenclatura do MATLAB para função de ativação linear
RMS	Potência eficaz ou potência média quadrática, do inglês <i>Root Mean Square</i>
RNA	Rede neural artificial
RNAs	Redes neurais artificial
sEMG	Densidade na atividade eletromiográfica
SME	Sinal mioelétrico
TANSIG	Nomenclatura do MATLAB para função de ativação tangente hiperbólica sigmoide
V	Volts
VN	Verdadeiro Negativo
VPN	Valor Preditivo Negativo
VPP	Valor Preditivo Positivo
VP	Verdadeiro Positivo



## SUMÁRIO

1	INTRODUÇÃO . . . . .	23
1.1	OBJETIVOS . . . . .	23
1.1.1	Objetivo Geral . . . . .	23
1.1.2	Objetivo Específico . . . . .	23
2	REVISÃO BIBLIOGRÁFICA . . . . .	25
2.1	ANATOMIA . . . . .	25
2.1.1	Mão . . . . .	25
2.1.2	Antebraço . . . . .	27
2.2	FISIOLOGIA E MOVIMENTOS DA MÃO . . . . .	28
2.3	MALFORMAÇÃO CONGÊNITA E AMPUTAÇÃO . . . . .	30
2.3.1	Níveis de amputação . . . . .	31
2.4	PRÓTESES PARA MEMBROS SUPERIORES . . . . .	32
2.4.1	Classificação das próteses referente a energia utilizada . . . . .	32
2.4.2	Estado da arte . . . . .	33
2.5	AQUISIÇÃO DOS SINAIS MIOELÉTRICOS . . . . .	33
2.6	REDES NEURAIS ARTIFICIAIS . . . . .	34
2.6.1	Funções de ativação . . . . .	36
2.7	Estudo de casos . . . . .	37
2.8	CRITÉRIOS PARA AVALIAÇÃO DO DESEMPENHO . . . . .	38
3	METODOLOGIA . . . . .	41
3.1	Visão geral do trabalho . . . . .	41
3.2	Banco de dados . . . . .	42
3.3	Redes neurais artificiais . . . . .	44
4	RESULTADOS E DISCUSSÕES . . . . .	61
4.1	Indivíduos normais . . . . .	61
4.2	Indivíduos amputados . . . . .	66
5	CONSIDERAÇÕES FINAIS . . . . .	71
5.1	Recomendação para trabalhos futuros . . . . .	72
	REFERÊNCIAS . . . . .	73
	APÊNDICES . . . . .	75
	APÊNDICE A – CÓDIGO FEITO NO MATLAB PARA ORGANIZAÇÃO DOS DADOS DOS INDIVÍDUOS . . . . .	77
	APÊNDICE B – CÓDIGO FEITO NO MATLAB PARA CALCULAR O DESEM- PENHO DAS REDES CONSIDERANDO AMOSTRA POR AMOS- TRA . . . . .	83

APÊNDICE C – CÓDIGO FEITO NO MATLAB PARA CALCULAR O DESEMPENHO DAS REDES CONSIDERANDO INTERVALOS DE MOVIMENTOS E REPOUSO . . . . .	89
APÊNDICE D – CÓDIGO FEITO NO MATLAB PARA PROCESSAR OS DADOS	91
APÊNDICE E – CÓDIGO FEITO NO MATLAB PARA PLOTAR OS GRÁFICOS DA REDE FILTRADA . . . . .	95

## 1 INTRODUÇÃO

A mão é responsável pela maior parte das atividades humanas, com funções motoras, táteis e gestuais. A perda desse membro afeta o indivíduo não só pelo aspecto estético como funcional, dificultando a realização das tarefas do dia-a-dia.

A protetização é uma técnica que substitui total ou parcialmente um órgão, tecido ou membro. O objetivo é restaurar a normalidade para o indivíduo que necessita de uma prótese, seja devido à doença congênita ou amputação. A medida que a tecnologia avança, busca-se melhorar as técnicas de confecção de próteses, diminuir a rejeição para com os indivíduos, melhorar o aspecto visual, diminuir o peso, além de melhorar o desempenho e possíveis funções da prótese, tentando ao máximo se assemelhar ao membro perdido do indivíduo.

Para realizar um bom projeto de uma prótese é preciso compreender os aspectos anatômicos e fisiológicos do membro que se deseja substituir, além de todas as partes que estão diretamente ou indiretamente relacionada. O projeto de uma prótese mioelétrica pode ser dividido em várias etapas como: design do produto, mecânica, definindo como os dedos e mão se movimentará, a aquisição dos sinais mioelétrico, processamento do sinal, controle e calibração da prótese, para definir qual deve ser o movimento que a prótese vai responder devido ao movimento que o indivíduo deseja.

O controle e calibração da prótese pode ser feito através de redes neurais artificiais, identificando um padrão de sinal de acordo com cada tipo de movimento, e passando para o atuador o movimento desejado. Assim, neste trabalho pretende-se identificar alguns movimentos registrados através da aquisição de sinais mioelétrico, utilizando processamento de sinal e redes neurais artificiais.

Como movimentos de estudo definiu-se o abrir e fechar de mãos, por serem movimentos básicos para a realização de diversas tarefas e dois movimentos de preensão: representados pela ação de segurar um copo e segurar um alfinete. Além disso fez-se o estudo em um grupo de indivíduos normais e um grupo de indivíduos amputados, buscando compreender as diferenças dos grupos e dificuldades enfrentadas na realização de controle de uma prótese mioelétrica para membro superior.

### 1.1 OBJETIVOS

#### 1.1.1 Objetivo Geral

Estudar a viabilidade da utilização de redes neurais artificiais como controle e treinamento para próteses mioelétrica de membros superiores, através da classificação de quatro movimentos de mão. Fazer uma análise das redes neurais, utilizando métricas de desempenho, afim de definir a melhor rede para cada movimento.

#### 1.1.2 Objetivo Específico

- Obter e organizar uma base de dados de sinais mioelétricos de movimentos da mão e dedos de indivíduos normais e amputados;
- Realizar um processamento nos dados;
- Treinar nove RNA para os indivíduos normais;
- Comparar o desempenho das redes implementadas para os indivíduos normais e utilizar as redes com melhor desempenho para treinar o banco de dados dos indivíduos amputados;
- Comparar o desempenho das redes implementadas para os indivíduos amputados.



## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 ANATOMIA

#### 2.1.1 Mão

A mão humana está localizada na parte mais distal do braço, é formada por 27 ossos, 17 articulações e 19 músculos, isso faz com que ela apresente 23 graus de liberdade (DOF – *degrees of freedom*), sendo cinco movimentos do polegar, quatro para cada dedo e dois para a palma da mão.

Os ossos dão a sustentação e estrutura para o membro (Figura 1). Dos 27 ossos, oito estão localizados na região do Carpo, composto pelos ossos Escafoide, Semilunar, Piramidal, Pisiforme, Trapézio, Trapezoide, Capitato e Hamato. O metacarpo é composto de cinco ossos, um para cada dedo, ligando a região da palma da mão com os dedos. São quatorze ossos de Falange, sendo o polegar composto por duas falanges (distal e proximal) e os demais dedos por três falanges cada um (distal, medial e proximal). Cada dedo recebe um nome específico, são eles: polegar (primeiro dedo), indicador (segundo dedo), médio (terceiro dedo), anular (quarto dedo) e mínimo (quinto dedo), ver figura 2.

Os músculos e articulações moldam os movimentos do membro, a classificação dos músculos é de acordo com sua localização na mão, divididos em: região palmar lateral (Tênar), região palmar medial (Hipotênar) e região palmar média, a Figura 3 mostra os músculos da mão e seus respectivos nomes. A Tabela 1 apresenta os músculos de cada região e uma breve indicação dos movimentos que eles são responsáveis.

Figura 1 – Ossos da mão, intervalo entre os ossos articulares para aumentar a base didática, vista palmar.

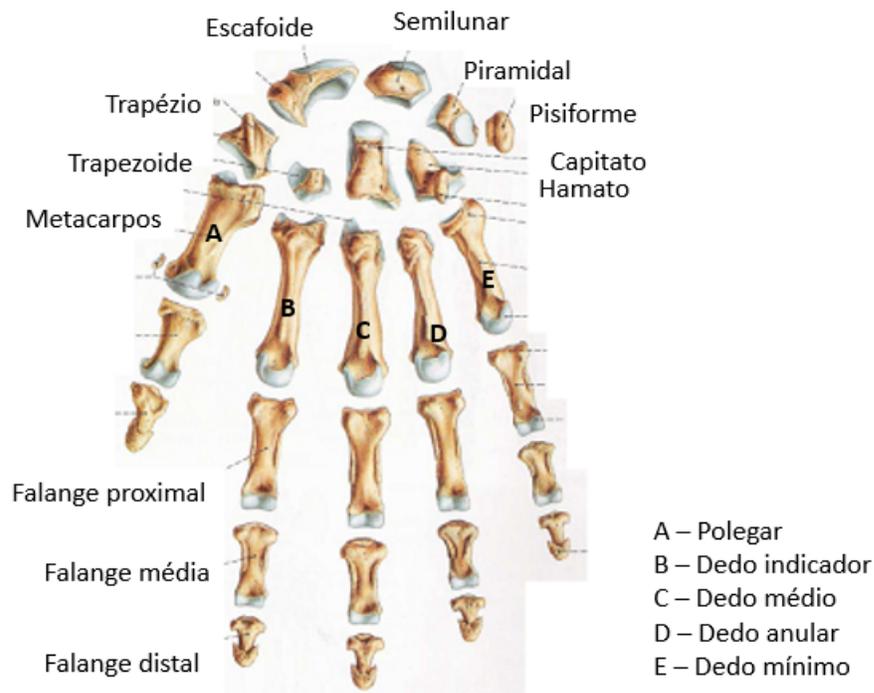
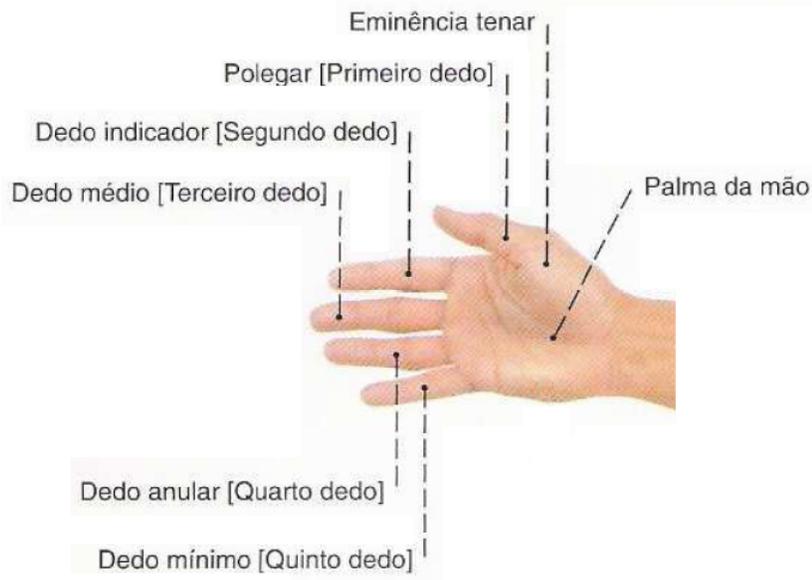
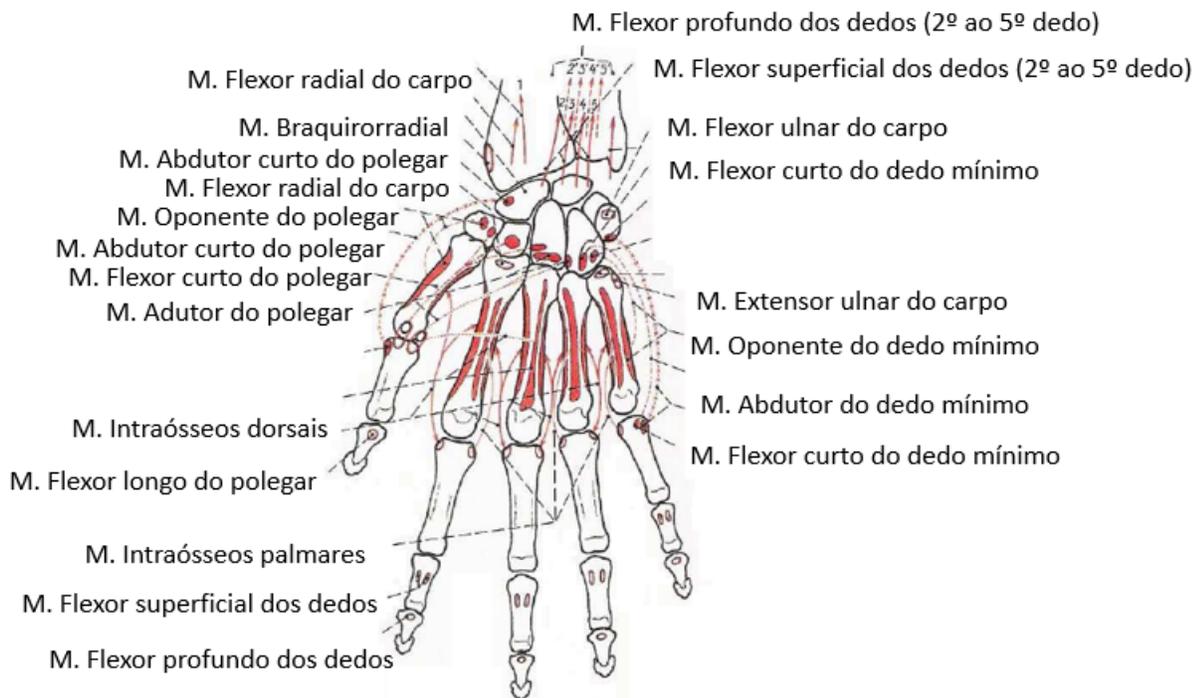


Figura 2 – Nomenclatura dos dedos da mão humana.



Fonte: Adaptado de (SOBOTTA, 2000)

Figura 3 – Origem e inserções musculares nos ossos da mão, vista palmar.



Fonte: Adaptado de (SOBOTTA, 2000)

Tabela 1 – Músculos da mão, localização e função.

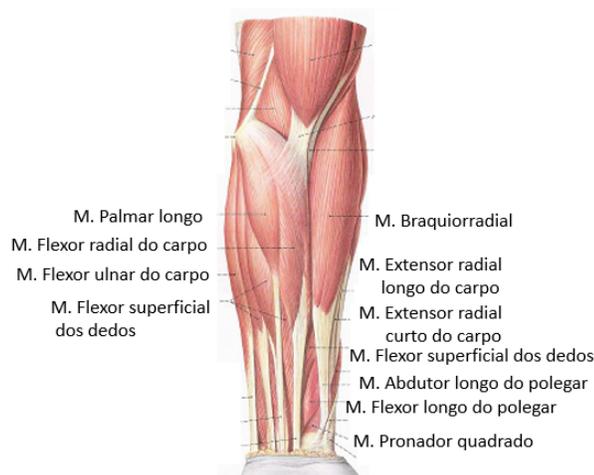
Músculos da mão		
Região	Músculo	Função
Região Palmar Lateral (4 músculos)	M. Abdutor curto do Polegar	Abdução e flexão do polegar
	M. Flexor curto do Polegar	Flexão da MF do polegar
	M. Oponente do Polegar	Oposição do polegar (flexão + adução + pronação)
	M. Abdutor do Polegar	Adução do polegar
Região Palmar Medial (4 músculos)	M. Palmar curto	Pregas transversais na Região Hipotenar
	M. Abdutor do Mínimo	Abdução do dedo mínimo
	M. Flexor Curto do Mínimo	Flexão da MF do dedo mínimo
	M. Oponente do Mínimo	Oposição do dedo mínimo.
Região Palmar Média (11 músculos)	Músculos Lumbricais	Flexão da MF e extensão da IFP e IFD do 2º ao 5º dedos. Propriocepção dos dedos.
	Músculos Interósseos Palmares	Adução dos dedos
	Músculos Interósseos Dorsais	Abdução dos dedos

Fonte: Autoria própria

### 2.1.2 Antebraço

O antebraço é o membro localizado entre a mão e o braço, sua sustentação é devido aos ossos da ulna e rádio e é composto de 20 músculos. Fez-se o estudo do antebraço, pois os seus músculos também são responsáveis por diversos movimentos da mão, e estão ligados aos dedos por tendões. Os músculos são divididos em três grupos de acordo com sua localização, classificados como anterior, posterior e lateral. A Tabela 2 apresenta os músculos de cada região e uma breve indicação dos movimentos que eles são responsáveis. A Figura 4, representa os músculos do antebraço na camada superficial, com a figura na vista anatômica anterior (palma da mão voltada para frente).

Figura 4 – Músculo do antebraço na vista anterior, camada superficial.



Fonte: Adaptado de (SOBOTTA, 2000)

Tabela 2 – Músculos do antebraço, localização e função.

<b>Músculos do antebraço</b>			
<b>Grupo</b>	<b>Camada</b>	<b>Músculo</b>	<b>Função</b>
Anterior	Superficial	M. Pronador Redondo	Flexão e pronação
		M. Flexor Radial do Carpo	Flexão, pronação e abdução da mão
		M. Palmar Longo	Flexão palmar
	Profunda	M. Flexor Superficial dos Dedos	Flexão, abdução e adução dos dedos
		M. Flexor Ulnar do Carpo	Abdução da mão
		Músculos Flexor Profundo dos Dedos	Flexão palmar e adução da mão
		M. Flexor Longo do Polegar	Flexão palmar e adução da mão
	Lateral	M. Pronador Quadrado	Pronação
		M. Braquiorradial	Flexão, pronação e supinação da mão
		M. Extensor Radial Longo do Carpo	Flexão, pronação e supinação da mão
Posterior	Superficial	M. Extensor Radial Curto do Carpo	Flexão e abdução da mão
		M. Extensor dos Dedos	Extensão e dorso flexão dos dedos
		M. Extensor do Dedo Mínimo	Extensão e dorso flexão do dedo mínimo
	Profunda	M. Extensor Ulnar do Carpo	Extensão, dorso flexão e abdução da mão
		M. Supinador	Supinação
		M. Extensor Longo do Polegar	Abdução, adução e extensão do polegar
		M. Extensor do Indicador	Extensão do indicador,
		M. Abdutor Longo do Polegar	Abdução do polegar e da mão
M. Extensor Curto do Polegar	Extensão do polegar e abdução da mão		

Fonte: Autoria própria

## 2.2 FISIOLOGIA E MOVIMENTOS DA MÃO

As funções da mão humana são muito abrangentes, de imediato, pensa-se em toda sua capacidade motora, realizando diversos movimentos complexos, porém, ainda é utilizada para fazer vários gestos, destacando a linguagem de sinais comumente utilizada por deficientes auditivos e mudos, além disso, é o principal membro para o tato, para sentir temperaturas e texturas. Graças ao conhecimento da espessura e das distâncias que lhe proporciona o córtex cerebral, a mão é a educadora da visão, permitindo-lhe controlar e interpretar as informações: sem ela nossa visão do mundo seria plana e sem relevo (KAPANDJI, 1980).

Como o enfoque do trabalho baseia-se na classificação dos movimentos da mão, será abordado os movimentos que a mão desempenha. A mão do homem é um utensílio maravilhoso, capaz de executar inúmeras ações graças à

sua função essencial: a preensão (KAPANDJI, 1980). Segundo Kapandji (1980), os movimentos são classificados em preensões digitais, palmares e centradas e estão listados a seguir:

- **Preensões digitais:** podem ser divididas em preensões bidigitais e pluridigitais
  - Preensões bidigitais: são movimentos de precisão, executadas por dois dedos. É classificada de quatro formas distinta, sendo três delas um movimento de pinça (polegar-dedo):
    - \* Preensão por oposição terminal: O polegar se opõe à outro dedo, por exemplo, para segurar um alfinete (Figura 5 imagem A).
    - \* Preensão polpa a polpa: Parecida com a preensão anterior, só que nesse movimento abrange uma área de contato maior, pois é realizado com a polpa do dedo, por exemplo, segurar um papel (Figura 5 imagem B).
    - \* Preensão pulpo-lateral: O movimento de pinça é feito com o polegar e a lateral de outro dedo, como por exemplo para segurar uma moeda (Figura 5 imagem C).
    - \* Preensão interdigital látero-lateral: O objeto é agarrado por dois dedos, sendo que o polegar não participa da ação, por exemplo, para segurar um cigarro (Figura 5 imagem D).
  - Preensões pluridigitais: São preensões que o polegar se opõe à mais dois dedos (preensão tridigital), à mais três dedos (preensão tetradigital) ou à mais quatro dedos (preensão pentadigital). Nota-se que dependendo do movimento realizado, os dedos vão se posicionando de forma diferente. A Figura 6 apresenta exemplos de preensões pluridigitais.
- **Preensões palmares:** Nesse tipo de preensão, o objeto é agarrado também com a palma da mão, e com isso aumenta a estabilidade e a área da preensão, pode-se ser dividido de acordo com a utilização ou não do polegar. No caso da preensão dígito-palmar (Figura 7 imagem A) opõe a palma da mão aos quatro últimos dedos e na preensão palmar ( Figura 7 imagem B) quando a palma da mão e o polegar se opõe aos quatro últimos dedos.
- **Preensões centradas:** São movimentos simétricos em relação ao eixo longitudinal, com o objetivo de prolongar a mão, exemplo na Figura 8 imagem A e B.

Figura 5 – Preensão Bidigitais. Imagem (A) Preensão por oposição terminal, (B) Preensão polpa a polpa, (C) Preensão pulpo-lateral, (D) Preensão interdigital látero-lateral.

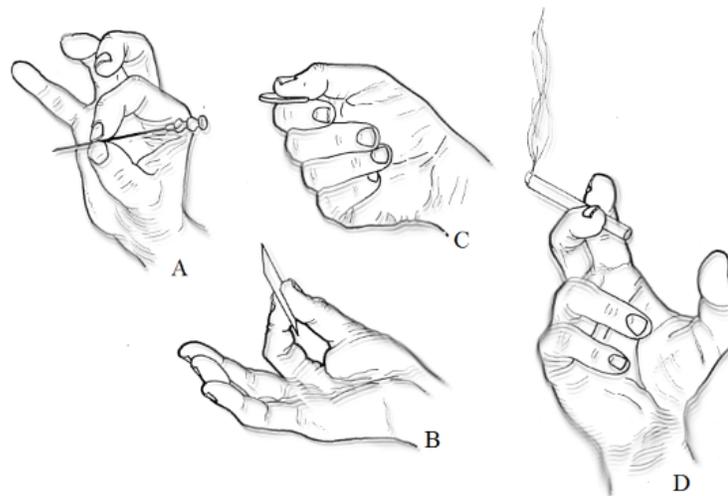
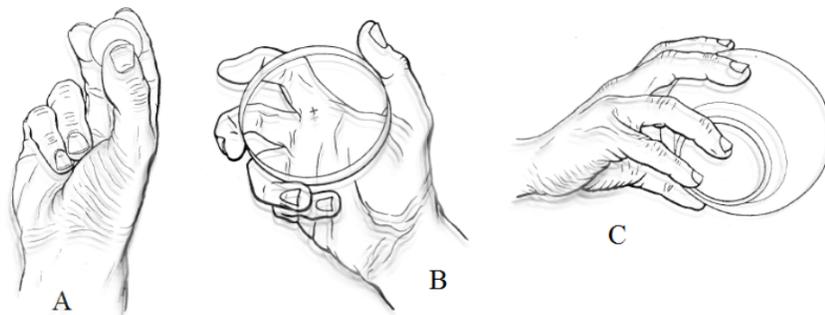
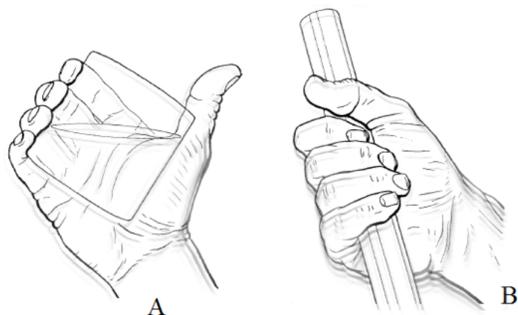


Figura 6 – Preensão pluridigitais. Imagem (A) Preensão tridigital, (B) Preensão petradigital, (C) Preensão pentadigital.



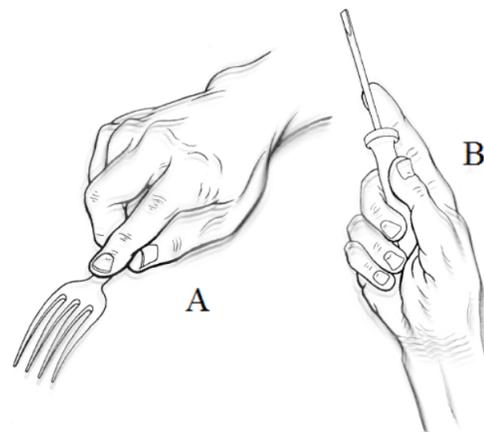
Fonte: Adaptado de (KAPANDJI, 1980)

Figura 7 – Preensões palmares. Imagem (A) Preensão dígito-palmar, (B) Preensão Tetradigital.



Fonte: Adaptado de (KAPANDJI, 1980)

Figura 8 – Preensões centradas.



Fonte: Adaptado de (KAPANDJI, 1980)

Além dos movimentos de preensão estáticas, que não tem a participação da gravidade, também existe os movimentos para executar uma ação, definido como **preensão-ação**, que ocorre ao tocar um instrumento musical, lançar uma bola, etc. Como descrito anteriormente, a mão também é utilizada para a expressão gestual, definido como **percussão**, alguns exemplos são: linguagem de sinal, aperto de mãos, o ato de digitar e modelar uma peça de barro.

### 2.3 MALFORMAÇÃO CONGÊNITA E AMPUTAÇÃO

A perda de um membro pode ocorrer por duas formas distintas: por amputação ou malformação congênita. Amputação é a remoção total ou parcial de um membro devido à um acidente e/ou cirurgia, já malformação congênita é caracterizada por uma deformação estrutural, sendo que o indivíduo pode nascer com essa doença, ou mesmo adquirir nos primeiros meses de vida. Muitas vezes a palavra amputação é usada erroneamente para definir uma deformação congênita e esse termo deve ser evitado para referenciar tais casos (KOTTKE; STILLWELL; LEHMANN, 1984).

Os casos de necessidade de prótese por malformação congênita, precisam ser analisados isoladamente, pois o indivíduo pode apresentar limitação dos sinais mioelétricos, que seriam utilizados para a realização da prótese, ou

mesmo, apresentar vestígio do membro, que pode ser adaptado na confecção da prótese. Logo, estes vestígios não devem ser sacrificados por motivos puramente estéticos (CUNHA, 2002). Além da questão da individualidade de cada malformação congênita, os casos de amputação são superiores quando comparados aos por doenças. Devido à esses motivos, o banco de dados dos indivíduos amputados desse trabalho são referente à indivíduos que sofreram amputação.

Anomalias congênitas afetam entre 1 e 2% dos nascidos vivos, destes, aproximadamente 10% possuem deformidades dos membros superiores (BISNETO, 2012). De acordo com a revista CIPA... (2015), estima-se que amputação por acidente de máquinas entre o ano de 2011 e 2013 foi de 13.724 amputados, uma média de 12 trabalhadores amputados por dia. E, de acordo com os dados extraídos da revista eletrônica saúde e ciência (Reis, Júnior e Campos (2012)), estima-se que ocorre 40.000 amputações por ano, sendo 36,2% vascular, 32,76% acidentes no trânsito (motociclístico, automobilístico e atropelamento), 6,03% acidente com arma branca, 5,19% acidente de trabalho e 19,82% outros (incluindo malformação congênita).

### 2.3.1 Níveis de amputação

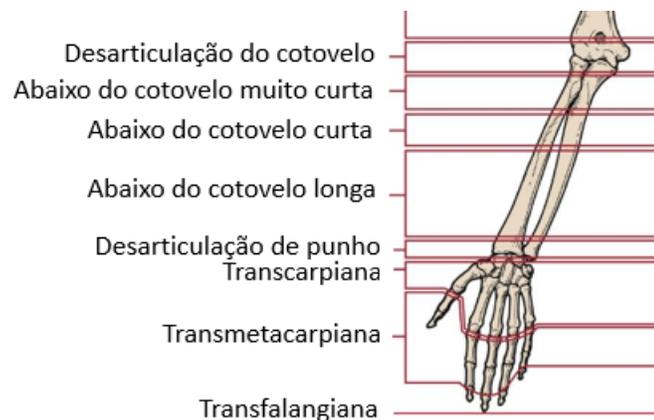
O nível de amputação é classificado de acordo com a localização, sendo que, é preferível que seja feito sempre o mais distal possível, para preservar a maior parte do membro. Quanto mais proximal a amputação, mais difícil a confecção de uma prótese do ponto de vista técnico (BLOHMKE, 1994). Isso ocorre, pois, quanto mais proximal for a amputação, os músculos do antebraço estarão mais preservados e conseqüentemente mais confiável a aquisição dos sinais mioelétricos.

Segundo Carvalho (2003), o membro residual da amputação é denominado coto, que passará a ser considerado um novo membro e será responsável pelo controle da prótese durante o ortostatismo e a deambulação.

Para que isso seja possível, ele deve apresentar algumas características, tais como, nível adequado, coto estável, bom estado da pele, ausência de neuromas e espículas ósseas, presença de um bom coxim com mioplastia e miodese, boa circulação arterial e venosa, boa cicatrização e ausência de edema importante (DEBASTIANI, 2005).

A Figura 9 mostra os diferentes níveis de amputação para o membro superior, e a nomenclatura que cada corte recebe. O banco de dados desse trabalho é formado por indivíduos que sofreram amputação transradial, ou seja, é a secção óssea entre a articulação do cotovelo e do punho, pode ser proximal, média ou distal.

Figura 9 – Níveis de amputação do membro superior.



## 2.4 PRÓTESES PARA MEMBROS SUPERIORES

A protetização é uma técnica antiga, uma vez que a primeira prótese de membros superiores realmente funcional foi desenvolvida por volta de 200 a.C. (CUNHA, 2002). Na busca de melhorar a condição dos que foram mutilados ou apresentavam alguma deficiência, vários médicos e inventores começaram a estudar e desenvolver próteses. Dentre os inventores, destaca-se Leonardo da Vinci e Ambroise Paré, que desenvolveram diversas próteses e instrumentos cirúrgicos, visando manter os aspectos anatômicos e dentro do possível, com as limitações tecnológicas da época, os aspectos funcionais.

### 2.4.1 Classificação das próteses referente a energia utilizada

As próteses podem ser divididas em passivas e ativas. As próteses passivas podem ser estéticas (Figura 10), ou apenas com a finalidade de uma ferramenta, mais comuns antigamente, com instrumentos como gancho, martelo, ou outra ferramenta útil para o usuário. Já as próteses ativas têm como objetivo principal substituir as funções que o membro desempenhava, a classificação de acordo com a energia ocorre por ser proveniente do usuário, externa a ele, ou uma combinação de ambos.

As próteses com força própria em geral são acionadas devido à um movimento do usuário, são controladas por algum esforço do membro que está preservado. Essas próteses são bem mais simples, normalmente apenas com a função de abrir e fechar de mão (Imagem 11). Não possuem características antropomórficas e seu acionamento causa um certo constrangimento ao indivíduo, pois exerce vários movimentos que não são naturais (CUNHA, 2002).

Figura 10 – Próteses estética de mão da empresa *Touch Bionic* do produto *livingskin*.



Fonte: Touchbionics... (2017), disponível em: <<http://www.touchbionics.com/node/2453>>

Figura 11 – Prótese de mão de controle motriz, com função pinça-gancho da empresa *Fillauer*.



Fonte: (FillauerLLC... , 2017), disponível em: <<http://fillauer.com/Upper-Extremity-Prosthetics/index.html>>

Segundo Cunha (2002), as próteses ativas que são mais anatômicas são as elétricas e as pneumáticas, as pneumáticas utilizam ar comprimido ou gás carbônico como fonte de energia, porém como elas são mais pesadas e apresentam mais ruídos não são tão eficientes como as elétricas. As próteses elétricas podem ser acionadas por interruptores ou alimentadas pela própria corrente iônica produzida pela contração e relaxamento dos músculos do indivíduo, denominadas próteses mioelétricas. As próteses mioelétricas trazem maior conforto para o indivíduo, pois devido ao seu meio de energia o funcionamento da prótese ocorre de forma mais natural para o indivíduo, uma vez que ele não precisa ficar acionando ou não interruptores.

Como as próteses mioelétricas conseguem unir funcionalidade e estética, o estudo desse trabalho é referente a próteses mioelétricas, dessa forma, o estudo de controle de prótese para membro superiores é através de banco de dados proveniente da aquisição de sinais mioelétricos dos músculos do antebraço.

### 2.4.2 Estado da arte

As próteses mioelétricas de maior destaque são a *i-Limb* da empresa *Touch Bionics* e a *BeBionic*, originalmente da empresa britânica *RSL Steeper*, e atualmente adquirida pela empresa alemã *Otto Bock*.

A *BeBionic* (Figura 12) imita as funções reais de uma mão humana, apresenta catorze diferentes formas de segurar um objeto e pode suportar até 45 Kg. Cada dedo é composto por motores independentes, aumentando a precisão dos movimentos. Além de trazer para o usuário a possibilidade de pegar objetos variados, apresenta um alto nível de precisão, sendo possível fazer atividades delicadas, como por exemplo, quebrar ovos e escrever. A versão 2.0 apresenta um aumento de bateria, melhorias gerais em velocidade e precisão, além de ser feita em dois tamanhos, médio e grande.

A *i-limb* (Figura 13) também apresenta motores independentes em cada dedo, permitindo variar a força de pressão dedo por dedo. Ao segurar um objeto, a força da prótese aumenta gradativamente. Outra característica marcante é que, de acordo com a intensidade do sinal, os movimentos da prótese tornam-se mais lentos ou rápidos, simulando um movimento real de uma mão humana. Com a prótese vem junto o *software biosimcom* sendo possível cadastrar funções e movimentos personalizados. A linha *i-limb* é composta pelos modelos *i-limb quantum*, *i-limb revolution* e *i-limb ultra*, e são vendidos em diferentes tamanhos.

Figura 12 – Próteses da empresa Steeper, produto bebionic nas cores preta e branca.



Fonte: Bebionic. . . (2017), disponível em: <http://bebionic.com/thehand>

Figura 13 – Prótese da empresa Touch Bionic, produto i-limb quantum.



Fonte: Touchbionics. . . (2017), disponível em: <http://www.touchbionics.com/products/active-prostheses/i-limb-quantum>

## 2.5 AQUISIÇÃO DOS SINAIS MIOELÉTRICOS

Os sinais mioelétricos ocorrem devido a contração e relaxamento muscular, esse movimento dos músculos, faz com que as membranas celulares polarizem e despolarizem. Diz-se que a membrana está despolarizada, quando o acúmulo de íons dentro da membrana é igual ao número de cátions fora, quando ela está em repouso, seu potencial varia entre  $-70\mu V$  a  $-90mV$ . Quando a membrana é excitada (polarização) seu potencial pode chegar a  $100mV$ .

Uma notável característica de todas as células vivas é a diferença de potencial existente entre os fluidos intra e extracelulares. Essa diferença de potencial usualmente varia entre 10 e  $100mV$ , com o interior da célula sendo eletronegativo em relação ao exterior (DELATTRE, 2007).

Como o sinal de polarização e despolarização se propaga pelo corpo, é possível através de meios não invasivos captar esse sinal, dessa forma, utiliza-se um transdutor capaz de transformar essa corrente de íons em uma corrente de elétrons, para então poder alimentar um sistema eletrônico. Os transdutores que transformam a corrente iônica em elétrica são chamados de eletrodos, podendo ser classificados em passivos e ativos, quando utiliza-se eletrodos passivos deve-se considerar a impedância da pele, uma vez que ele se comporta apenas como uma barreira entre o potencial da ação das células musculares e o eletrodo, já na utilização de eletrodos ativos, ele tem um pré-amplificador, que amplifica os sinais mioelétricos. Os eletrodos também podem ser classificados como invasivos ou não invasivos (superfície).

O banco de dados desse trabalho foi feito a partir de uma aquisição com eletrodos passivos não invasivos. Com a utilização destes eletrodos, o SME captado apresenta frequências até cerca de 500 Hz e amplitudes variando entre  $50\mu V$  e  $5mV$  dependendo do músculo analisado e configuração do eletrodo utilizado (ALMEIDA, 1997). Segundo o projeto "Reconhecimento de Sinais – EMG" do Centro Universitário da FEI, Nascimento (2009), a frequência de 10 até 200 Hz é que forma as componentes de maior contribuição de informação do sinal mioelétrico.

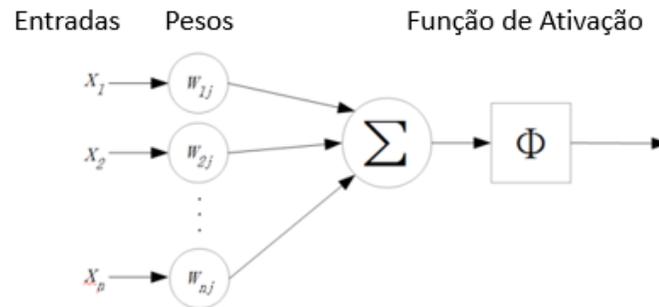
De acordo com o trabalho de Cunha (2002), ele relatou valores empíricos de  $40\mu V$  para o movimento de extensão dos dedos e de  $80\mu V$  para o movimento de flexão dos dedos. Segundo Forti (2005) deve-se atentar ao um bom posicionamento dos eletrodos, uma vez que isso influencia na aquisição dos sinais mioelétricos, os eletrodos posicionados nos ponto distal ou proximal do músculo apresenta um sinal com amplitude superior ao do ponto motor, porém garante maior reprodutividade, uma vez que é mais fácil de localizar o músculo, principalmente com o usos de estímulos elétricos transcutâneo.

## 2.6 REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais (RNAs) é uma das subáreas de atuação do estudo sobre inteligência artificial. O campo da inteligência artificial, ou IA, vai ainda mais além: ele tenta não apenas compreender, mas também construir entidades inteligentes (NORVIG; RUSSELL, 2003). As RNAs são técnicas computacionais construídas com modelos matemáticos, baseados no funcionamento do cérebro humano, mais especificamente, baseado na rede neural, com unidade básica de funcionamento: o neurônio. Uma das definições de inteligência artificial, segundo Charniak e McDermott: "O estudo das faculdades mentais pelo uso de modelos computacionais".

As RNAs são compostas por diversas unidades de processamento (neurônios), sendo que, essas unidades são conectadas por canais de comunicação, cada qual associada a um determinado peso, dessa maneira, as unidades, de forma individual, apresentam um funcionamento simples, e a comunicação entre todas as redes é que fazem com que consigam realizar tarefas inteligentes. As RNAs foram originadas pelo neurofisiologista McCulloch e pelo matemático Pitts na década de 40, eles definiram essa unidade de processamento (Figura 14) como entidades composta por sinais da entrada, cada qual multiplicado por um peso, de acordo com a sua influência na tomada de decisão, então, soma-se todas esses sinais e passam por uma função de ativação, caso o nível de atividade exceder um certo limiar (*threshold*) a unidade produz uma determinada resposta de saída. A função de ativação tipicamente é tanto um limiar rígido, caso em que a unidade é chamada de *perceptron* como uma função logística, caso em que por vezes é utilizado o termo *perceptron sigmoide* (NORVIG; RUSSELL, 2003).

Figura 14 – Modelo proposto por McCulloch e Pitts de uma unidade de processamento. As entradas são multiplicadas por pesos, então são somadas, passam por uma função de ativação, para então apresentar uma resposta de saída.



Fonte: Adaptado de *A Novel Design of a McCulloch-Pitts Neuron in CMOS VLSI*, A... (), disponível em: [http://people.cst.cmich.edu/yelam1k/asee/proceedings/2016/student\\_regular\\_papers/2016\\_ASEE\\_NCS\\_papers28.pdf](http://people.cst.cmich.edu/yelam1k/asee/proceedings/2016/student_regular_papers/2016_ASEE_NCS_papers28.pdf)

Considerando a saída como  $out_j$  e a função de ativação como  $g$ , pode-se descrever matematicamente o comportamento da unidade de processamento de acordo com a fórmula 2.1. Na próxima subsecção será abordado com mais detalhes sobre as funções de ativação.

$$out_j = g\left(\sum_{n=0}^n x_n \cdot w_{n,j}\right) \quad (2.1)$$

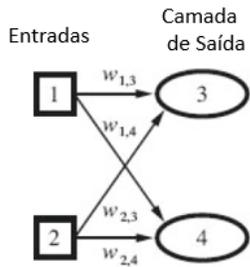
Após definido o comportamento da unidade de processamento, deve-se conectá-los para então forma uma rede neural. As redes neurais podem ser de duas formas: com alimentação para frente ou recorrente.

- **RNAs com alimentação para frente:** As RNAs com alimentação para frente apresentam suas conexões apenas em uma direção, dessa forma, são representadas pela função de sua entrada atual balanceada de acordo com os pesos, não apresentam laços e nem estados intermediários. Essas redes podem ser de apenas uma camada, denominadas rede de camada única ou rede *perceptron*, ou ter várias camadas sequenciais, denominadas de redes de camada múltiplas.

- **Redes de camada única:** Essas redes podem apresentar  $n$  entradas com  $m$  saídas (Figura 15), cada saída representa uma rede separada, que vai aprender a chegar numa determinada resposta quando submetida a um determinado problema, ou seja, a rede terá  $m$  processos independentes. Estudos mostraram que as redes de única camada não são eficientes para solucionar problemas com função que não sejam linearmente separáveis, mas aprendem as funções booleanas básicas E, OR e NOT.
- **Redes de camadas múltiplas:** Devido à dificuldade das redes de única camada de solucionar diversos problemas, foi desenvolvido redes com mais de uma camada (multicamadas). Como as redes de única camada conseguem aprender funções booleanas básicas, as redes de multicamadas conseguem resolver problemas que envolvam a combinação dessas funções, dessa forma é possível obter redes que consigam resolver regressões não lineares.

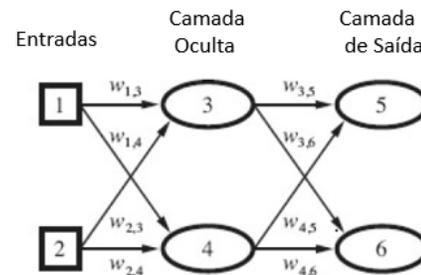
As camadas da rede são divididas em: camada de entrada, com os sinais de entrada, camadas intermediárias ou ocultas, onde é feito o processamento através das conexões ponderadas e camada de saída, com o resultado final da rede.

Figura 15 – Rede de única camada com duas entradas e duas saídas.



Fonte: Adaptado de (NORVIG; RUSSELL, 2003)

Figura 16 – Rede de múltipla camada, nesse caso com uma camada oculta de duas entradas e duas saídas



Fonte: Adaptado de (NORVIG; RUSSELL, 2003)

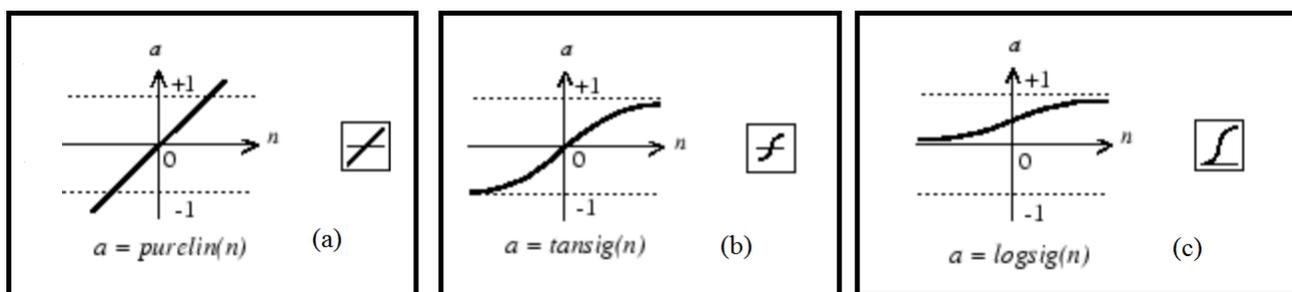
- **RNAs recorrentes:** as redes recorrentes são cíclicas, alimentam suas entradas com saídas, dessa forma apresentam estados intermediários através de memória de curto prazo. Essas redes estão mais próximas do comportamento do cérebro humano e por serem mais complexas, podem apresentar uma saída estável ou não.

### 2.6.1 Funções de ativação

Cada unidade de processamento passa por uma função de ativação, a função é responsável pela resposta na saída da rede, normalmente o valor varia de  $[0,1]$  ou  $[-1, 1]$  de acordo com a função de ativação, sendo que, os valores próximos de 1, indicam que a resposta para o problema está correta, e valores próximos de 0 ou -1 (dependendo da função de ativação), indicam uma resposta incorreta.

Como a plataforma de estudo de redes neurais será o MATLAB, nesse trabalho será estudado três funções de ativação que o programa utiliza: função de ativação linear (Figura 17 (a)), tangente hiperbólica sigmoide (Figura 17 (b)), e sigmoide logarítmica (Figura 17 (c)).

Figura 17 – Funções utilizadas como funções de ativação. Em (a) função linear, (b) função tangente hiperbólica sigmoide e (c) função sigmoide logarítmica. Na parte inferior das imagens o nome utilizado para descrevê-las no MATLAB.



Fonte: Adaptado de MathWorks

- **Função de ativação linear:** função linear, cuja saída varia de  $[-1,1]$ , descrita matematicamente como  $f(n) = n$ , sendo  $n$  um número real. No MATLAB a função é descrita como:  $a = purelin(n)$ .

- **Função de ativação tangente hiperbólica sigmoide:** função não linear, permitindo assim, que a saída também seja não linear, cuja saída varia de  $[-1,1]$ . Descrita matematicamente como  $f(n) = \frac{2}{1+e^{-2n\beta}} - 1$ , sendo  $n$  um número real e  $\beta$  um valor de atenuação da função. No MATLAB a função é descrita como:  $a = \text{tansig}(n)$ , com  $\beta = 1$ .
- **Função de ativação sigmoide logarítmica:** também é uma função não linear, descrita matematicamente como  $f(n) = \frac{1}{1+e^{-n\beta}}$ , sendo  $n$  um número real e  $\beta$  um valor de atenuação da função. No MATLAB a função é descrita como:  $a = \text{logsig}(n)$ , com  $\beta = 1$ . A saída varia de  $[0,1]$ , então é uma função de ativação utilizada em casos em que a saída precisa necessariamente ser um valor positivo.

## 2.7 ESTUDO DE CASOS

Segundo Mattioli et al. (2010), os indivíduos que sofreram amputação da mão apresentam os músculos do antebraço na sua maioria preservado, sendo assim, é possível realizar a aquisição e medições dos sinais de EMG desses músculos. Além disso, os sinais de EMG tem uma característica diferente de acordo com o movimento que está sendo executado, dessa forma, é possível classificar esses movimentos, e uma das aplicação para essa classificação é o controle de próteses. Um método para a classificação desses sinais é com a utilização de redes neurais artificiais.

Uma característica marcante das RNA é sua capacidade de generalização: após uma fase de treinamento, na qual alguns padrões de entrada (juntamente com sua respectiva classificação) são apresentados e processados pela rede, esta pode ser testada com padrões diferentes daqueles utilizados em treinamento, classificando-os adequadamente. (MATTIOLI et al., 2010).

No trabalho, foi classificado quatro movimentos: preensão, flexão do punho, extensão do punho e torção, eles obtiveram como resultado uma eficiência da rede de 95% na classificação, acertando 19 dos 20 padrões analisados para um dos indivíduos (com a utilização de 80 neurônios) e não foram obtidos resultados com eficiência superior a 80% quando utilizou-se 40 neurônios.

Segundo Kawata et al. (2010), existe uma gradescrive a dificuldade de analisar os sinais de EMG em tempo real, pois cada movimento da mão é associado a diversos músculos e os sensores utilizados na aquisição do sinal fazem uma sobreposição de todos os sinais obtidos (na utilização de eletrodos de superfície), dificultando a relação movimento x sinal. Além disso, os sinais de EMG apresentam variações entre diferentes indivíduos, e mesmo em um único indivíduo ocorre variações dos sinais para um mesmo movimento. No estudo, utilizou-se cinco indivíduos e foi classificado seis movimentos: flexão do punho, extensão do punho, agarramento, abertura, supinação do pulso e pronação do pulso, além da condição de repouso. Foi utilizado na primeira camada 360 neurônios, utilizou-se duas camadas intermediárias totalizando 6600 neurônios e a última camada, com um total de seis neurônios, um para cada saída de interesse. A média dos resultados para os cinco indivíduos realizando os seis movimentos foram superiores a 95,0% de eficiência.

O estudo desenvolvido por Godoi, Duque e Díaz (2014), descreve que as redes neurais artificiais tornam a fase de adaptação das pessoas com próteses mais tranquila, uma vez que não terão que aprender o padrão do movimento da prótese, e sim, o contrário, a prótese que se adapta ao usuário. O trabalho modelou cinco movimentos da mão: desvio radial, desvio ulnar, flexão, hiperextensão e fechamento, utilizaram uma rede *feed forward backpropagation* com função de ativação *sigmoid*, a arquitetura da rede foi de três camadas, a primeira com quatro neurônios, sete na camada oculta e na saída de acordo com a quantidade de movimentos de interesse, a taxa de erro para a detecção dos movimentos foi de 17 %.

Na literatura existe uma gama de estudos para o controle de próteses mioelétricas através de redes neurais, Suberbiola et al. (2015) obteve resultados com uma precisão de 91% e tempo de processamento de 100 ms. Geethanjali (2016) fez um estudo comparativo entre diversos métodos para controle de prótese, no caso das redes neurais elas apresentam uma boa performance, porém exigem muito gasto de memória do *hardware* e tempo computacional. Para

Blana et al. (2016) o seu estudo foi utilizando uma plataforma virtual, e obteve um resultado de 78% de eficiência na classificação dos movimentos de flexão e extensão do cotovelo e pronação e supinação do antebraço. Os trabalhos de Ingraham et al. (2015), Favieiro (2009) e Ameri et al. (2014) também trazem estudos na área, consolidando a importância da aplicação das redes neurais como controle de prótese.

## 2.8 CRITÉRIOS PARA AVALIAÇÃO DO DESEMPENHO

As redes neurais artificiais serão utilizadas para classificar os movimentos que o indivíduo está exercendo com a mão, para isso, é preciso verificar se elas estão cumprindo com o objetivo. Para análise do desempenho das redes serão utilizadas avaliações bem definidos e estabelecidos nos processos de validação de ensaios biomédicos: sensibilidade, especificidade e valores preditivos. Foi utilizado como referência para estabelecer esses critérios, os trabalhos de Kawamura (2002), Bianca (2004) e Chagas (2017). Esses critérios são baseados nos seguintes conceitos:

- **Verdadeiro positivo (VP):** Quando, ambos os resultados, o esperado e do teste são positivos. Para esse trabalho, quando o indivíduo fizer um movimento com a mão, e a rede detectar esse movimento.
- **Verdadeiro negativo (VN):** Quando, ambos os resultados, o esperado e do teste são negativos. Para esse trabalho, quando o indivíduo estiver em repouso, e a rede detectar que ele esta em repouso.
- **Falso positivo (FP):** Quando o resultado esperado é negativo, mas o teste apresenta um resultado positivo. Para esse trabalho, quando o indivíduo estiver em repouso e a rede detectar movimento.
- **Falso negativo (FN):** Quando o resultado esperado é positivo, mas o teste apresenta um resultado negativo. Para esse trabalho, quando o indivíduo tiver feito um movimento, mas a rede detectar repouso e/ou outro movimento não desejável.

Utilizando as definições de VP, VN, FP e FN, define-se as métricas de desempenho a seguir:

- **Valor preditivo positivo (VPP):** Total de movimento específico detectado pela rede dividido pela soma do total de movimento específico detectado pela rede com o total de vezes que a rede detectou um movimento que não ocorreu, como descrito na equação 2.2.

$$VPP = 100 \cdot \frac{VP}{VP + FP} \quad (2.2)$$

- **Valor preditivo negativo (VPN):** Total de estado de repouso detectado pela rede dividido pela soma do total de estado de repouso detectado pela rede com o total de vezes que a rede detectou repouso quando ocorreu o movimento de interesse, como descrito na equação 2.3.

$$VPN = 100 \cdot \frac{VN}{VN + FN} \quad (2.3)$$

- **Sensibilidade:** Proporção dos movimentos detectados pela rede por todas as vezes que ocorreu o movimento. Total de movimento específico detectado pela rede dividido pela soma do total de movimento específico detectado pela rede com o total de vezes que a rede detectou repouso quando ocorreu o movimento de interesse, como descrito na equação 2.3, como descrito na equação 2.4.

$$Sensibilidade = 100 \cdot \frac{VP}{VP + FN} \quad (2.4)$$

- **Especificidade:** Proporção de repouso detectado por todas as vezes que ocorreu repouso. Total de estado de repouso detectado pela rede dividido pela soma do total de estado de repouso detectado pela rede com o total de vezes que a rede detectou um movimento que não ocorreu, como descrito na equação 2.5.

$$Especificidade = 100 \cdot \frac{VN}{VN + FP} \quad (2.5)$$

- **Eficiência:** É a porcentagem dos resultados corretamente identificada pela RNA. Soma do total de vezes que a rede acertou (identificou o movimento de interesse e o estado de repouso) dividido pelo total de acertos e erros, como descrito na equação 2.6.

$$Eficiência = 100 \cdot \frac{VP + VN}{(VP + VN + FP + FN)} \quad (2.6)$$



### 3 METODOLOGIA

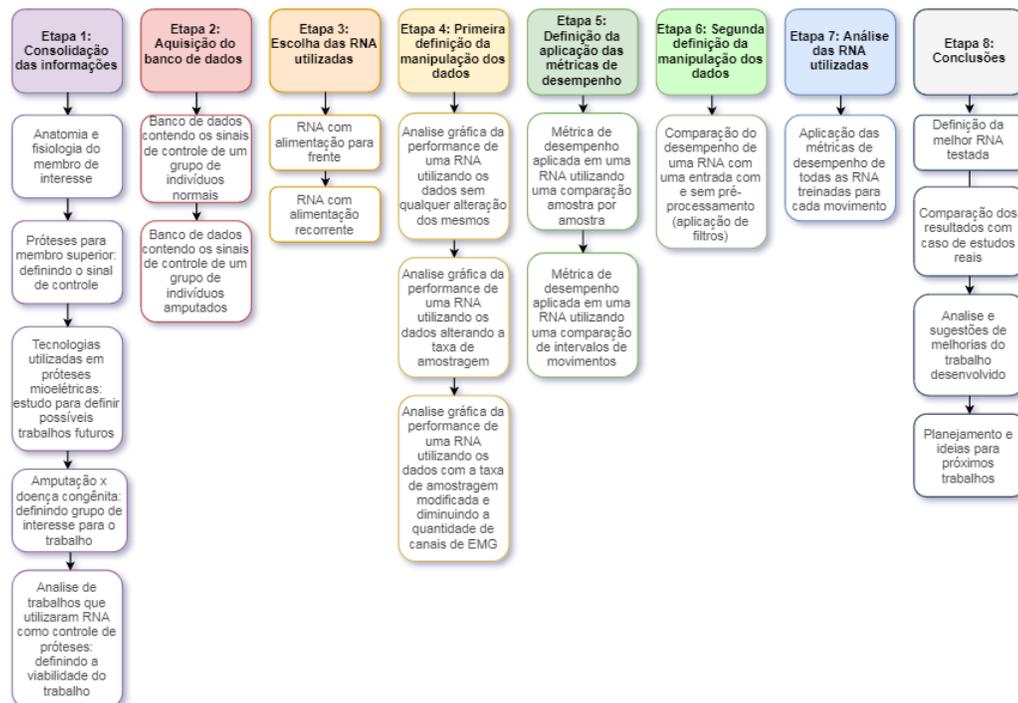
#### 3.1 VISÃO GERAL DO TRABALHO

Ao longo do projeto foram feitas pesquisas em artigos acadêmicos, livros e publicações referentes a próteses mioelétricas, redes neurais, anatomia e fisiologia humana, e demais conteúdos envolvidos para a elaboração desse documento. Para os treinamentos das redes neurais, utilizou-se dois bancos de dados, o primeiro com indivíduos normais e o segundo com indivíduos com amputação transradial, o banco de dados é composto por sinais mioelétricos proveniente de uma aquisição não invasiva utilizando eletrodos localizados na região do antebraço, os sinais representam exercícios padrões de movimentos específicos da mão e dedos que cada indivíduo é submetido a executar.

Os dados foram organizados e processados de acordo com os objetivos do trabalho e escolheu-se a rede neural *Feed-forward Backpropagation* com função de ativação tangente hiperbólica sigmoide e o banco de dados dos indivíduos normais como padrão para realizar alguns testes e determinar como os dados seriam processados pelas demais redes. Após definir esse padrão, os dados dos indivíduos normais foram submetidos à nove redes neurais artificiais. Foi feito um algoritmo para calcular o desempenho das redes, e então para cada movimento de cada rede, foi calculado essas métricas de desempenho. Após concluir o estudo com os dados dos indivíduos normais, escolheu-se as redes que tiveram o melhor desempenho para cada caso de estudo (repouso e quatro movimentos) e então foi feito o mesmo processo utilizando o banco de dados dos indivíduos amputados.

A Figura 18 mostra um fluxograma da metodologia empregado no trabalho, a etapa 1 está descrita no capítulo 2 "Revisão bibliográfica", as etapas 2 até 6 está descrito nesse capítulo, a etapa 7 está descrito no capítulo 4 "Apresentação dos resultados e discussões" e por fim, a etapa 8, está descrito no capítulo 5 "Considerações finais".

Figura 18 – Fluxograma da metodologia empregada no trabalho.



### 3.2 BANCO DE DADOS

Utilizou-se o banco de dados proveniente da Ninaweb, que é uma interface *web* do projeto Ninapro. Para compreender o trabalho desenvolvido foi utilizando as referências: NinaPro... (2017), NinaWeb... (2017), Atzori et al. (2014), Atzori et al. (2012), Gijssberts Arjan (2013) e Atzori et al. (2015)). Esse projeto visa auxiliar pesquisas na área de próteses mioelétricas de mão, fornecendo banco de dados públicos. Os bancos de dados são obtidos através da gravação conjunta de dados multimodais, incluindo a aquisição com eletrodos de superfície, cinemática das mãos e dinâmica das mãos, enquanto os indivíduos realizam um conjunto predefinido de movimentos. Os bancos de dados utilizados para o treinamento das RNAs são listados a seguir e para melhor compreensão podem ser visualizados as Tabelas 3 e 4.

- **Banco de dados 1:** O banco de dados do Ninapro contém dados de 40 indivíduos normais, sendo 28 indivíduos do sexo masculino e 12 do sexo feminino, com 34 destros e 6 canhotos. A idade média do grupo é de 29,9 anos, com desvio padrão de  $\pm 3,9$  anos. Para esse trabalho, foi utilizado 11 indivíduos do sexo masculino, sendo dez destros e um canhoto.
- **Banco de dados 2:** O banco de dados do Ninapro contém dados de 11 indivíduos amputados transradiais, sendo todos do sexo masculino, com 10 destros e 1 canhoto. A idade média do grupo é de 42,36 anos, com desvio padrão de  $\pm 11,96$  anos. Para esse trabalho, foi utilizado todos os 11 indivíduos desse banco de dados.

Tabela 3 – Características gerais dos bancos de dados 1 e 2 utilizados para o treinamento das RNAs.

	Banco de dados 1	Banco de dados 2
Indivíduos normais	11	0
Indivíduos com amputação transradial	0	11
Eletrodos de sEMG	12 Delsys	12 Delsys
Número total de movimentos	4	4
Número de repetição para cada movimento	5	5

Fonte: Autoria própria

Tabela 4 – Banco de dados 2: característica clínica dos indivíduo amputados.

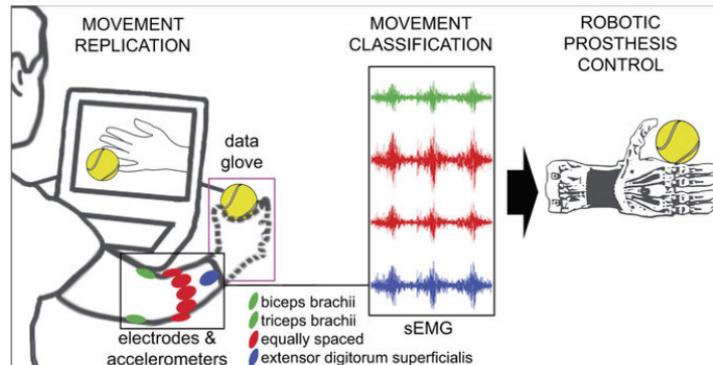
Indivíduo	Mão Amputada	Causa da Amputação	Antebraço restante [%]	Anos desde que sofreu a amputação	Uso de prótese	
1	Destro	Direita	Acidente	50	13	Mioelétrica
2	Destro	Esquerda	Acidente	70	6	Estética
3	Destro	Direita	Acidente	30	5	Mioelétrica
4	Destro	Direita e esquerda	Acidente	40	1	Não
5	Canhoto	Esquerda	Acidente	90	1	Cinemática
6	Destro	Esquerda	Acidente	40	13	Cinemática
7	Destro	Direita	Acidente	0	7	Não
8	Destro	Direita	Acidente	50	5	Mioelétrica
9	Destro	Direita	Acidente	90	14	Mioelétrica
10	Destro	Direita	Acidente	50	2	Mioelétrica
11	Destro	Direita	Câncer	90	5	Mioelétrica

Fonte: Autoria própria

Para esse trabalho, utilizou-se apenas os dados provenientes das atividades musculares, que foi medida utilizando doze eletrodos de sEMG de duplo diferencial *Trigno Wireless (Delsys)*, cada um equipado com uma

bateria recarregável autônoma, como esses eletrodos não são protegidos contra interferência da rede, os sinais foram filtrados após a aquisição. Os sinais de sEMG são amostrados a uma taxa de 2 kHz com um ruído de linha de base inferior a 750 nV RMS. O método de aquisição, foi a combinação de uma abordagem densa, com oito eletrodos igualmente espaçados em torno do antebraço, na altura da articulação radio-humeral e uma estratégia precisa de posicionamento anatômico, com eletrodos colocados no ponto de atividade flexor superficial dos dedos, extensor superficial dos dedos, na região do bíceps braquial e do tríceps braquial (Figura 19).

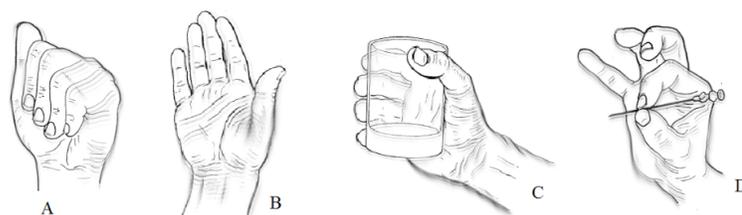
Figura 19 – Posicionamento dos eletrodos para aquisição dos sinais mioelétricos.



Fonte: Atzori et al. (2014)

Para cada indivíduo o projeto Ninapro desenvolveu um arquivo no formato Matlab com diversas variáveis sincronizadas, mas para esse trabalho, foram utilizadas apenas três variáveis: "emg", com os sinais mioelétricos, sendo as colunas de 1 à 8 os sinais provenientes dos eletrodos igualmente espaçados, a coluna 9 corresponde aos sinais proveniente do músculo flexor superficial dos dedos, a coluna 10, corresponde aos sinais do músculo extensor superficial dos dedos, a coluna 11 e 12, incluem os sinais dos músculos bíceps braquial e do tríceps braquial; "stimulus" com informação se o indivíduo está em repouso ou realizando algum movimento específico; "repetition" informando a quantidade de vezes que o indivíduo repetiu cada exercício. Para cada indivíduo, o projeto Ninapro desenvolveu três arquivos com uma série de exercícios, porém, para esse trabalho, foi selecionado quatro movimentos do banco de dados: mão aberta, que é a adução e flexão de todos os dedos da mão (imagem A da Figura 20), mão fechada que é a flexão de todos os dedos da mão (imagem B da Figura 20), preensões digital, com um movimento de pinça dedo-polegar (imagem C da Figura 20) e preensão palmar, com o indivíduo segurando um copo (imagem D da Figura 20).

Figura 20 – Movimentos escolhidos para a classificação da RNA. Estudos de caso: movimento 1: mão aberta (A); movimento 2: mão fechada (B); movimento 3: pinça-clássica (C); e movimento 4: segurando um copo (D).



Fonte: Adaptado de (KAPANDJI, 1980)

### 3.3 REDES NEURAIAS ARTIFICIAIS

Utilizou-se a plataforma *nntool* do Matlab para o processamento das redes neurais artificiais, a plataforma permite importar, criar, e exportar dados, redes neurais e resultados, a plataforma apresenta diversos modelos prontos de RNAs, sendo que, para cada modelo pode-se setar diferentes configurações, como as funções de ativação, números de neurônios nas camadas, quantidade de camadas, algoritmo de treinamento, etc.

Para todas as redes treinadas setou-se a mesma configuração, facilitando assim a análise e comparação de desempenho entre as redes. As redes foram configuradas com três camadas, com uma camada de entrada, com os sinais mioelétricos provenientes dos indivíduos, uma camada oculta, e uma camada de saída, com os resultados finais da rede. A camada de entrada foi definida com 100 neurônios e a camada de saída com cinco.

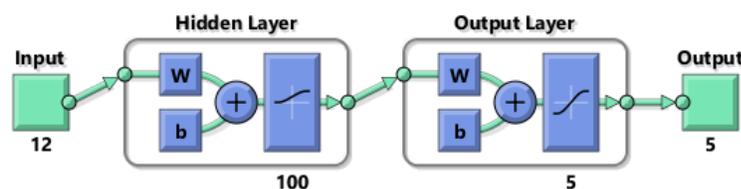
Foi definido para o treinamento das redes, um número máximo de 1000 iterações, um número máximo de 300 falhas (aumento de validação) e um número mínimo de gradiente de  $10^{-20}$ , quando um desses valores for atingido, o treinamento é interrompido. O algoritmo de treinamento para as redes foi o *trainrp* que de acordo com a documentação do Matlab é um dos algoritmos com melhor desempenho para detecção de padrão. Também, na documentação do Matlab, ressaltam que cada vez que uma rede neural é treinada, pode-se obter uma solução diferente, devido a diferentes valores de peso inicial, polarização e diferentes divisões de dados em conjuntos de treinamento, validação e teste, ou seja, treinamentos diferentes da mesma rede neural de um mesmo conjunto de dados pode resultar em saídas diferentes. A *toolbox nntool* do Matlab reserva automaticamente 70% dos dados para o treinamento da rede, 15% para a validação e 15% para o teste.

Utilizou-se três RNA padrões do Matlab, *Feed-forward Backpropagation*, *Cascade-forward Backpropagation* e NARX, para cada rede, testou-se com as funções de ativação tangente hiperbólica sigmoide (no Matlab utiliza-se o termo TANSIG), sigmoide logarítmica (LOGSIG) e função linear (PURELIN), todas já detalhadas na secção de 2.6.2 desse documento. As redes utilizadas são descritas abaixo:

- ***Feed-forward Backpropagation (FFB)***: É uma rede neural com alimentação para frente, dessa forma as conexões entre as unidades não formam um ciclo. Utilizou-se multicamadas para que, a rede possa resolver problemas de regressões não linear. Cada neurônio em uma camada direciona conexão para os neurônios das próximas camadas (Figura 21).

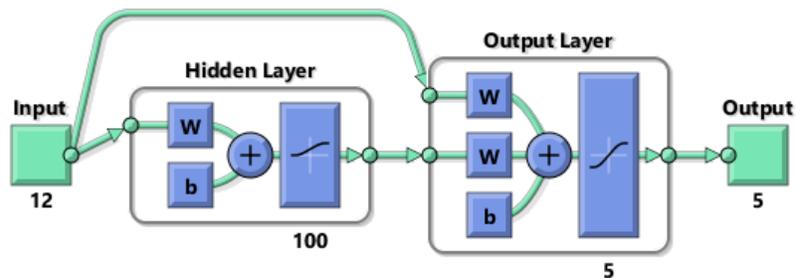
O algoritmo de aprendizagem da rede é do tipo *backpropagation*, os valores de saída são comparados com as respostas corretas e calcula-se uma função de erro com valores predefinidos e esse erro é retornado para a rede, assim, o algoritmo consegue ajustar os pesos das suas conexões até que essa função de erro retorne um valor pequeno, a rede consegue realizar esse processo após um grande ciclo de treinamento. O método de otimização da rede é denominado descida gradiente, para que esse processo de otimização funcione, a função de ativação da rede precisa ser derivável, uma vez que, é feita a derivação da função de erro em relação aos pesos da rede até que, a rede consiga diminuir esse valor.

Figura 21 – Rede neural *Feed-forward Backpropagation* com a configuração utilizada nas simulações.



- **Cascade-forward Backpropagation (CFB):** É uma rede neural similar a *Feed-forward Backpropagation* com o mesmo algoritmo de aprendizado *backpropagation*, a diferença é que todas as camadas além de ter conexões com as camadas anteriores, apresenta uma conexão com a entrada, dessa forma, todas as camadas têm um peso associado aos sinais da entrada (Figura 22).

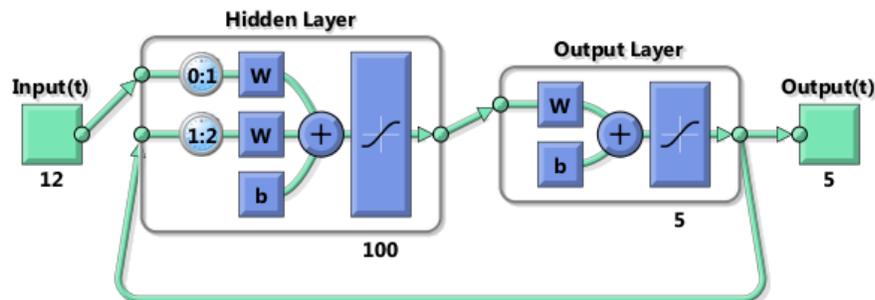
Figura 22 – Rede neural *Cascade-forward Backpropagation* com a configuração utilizada nas simulações.



Fonte: *Toolbox nntool* do Matlab

- **NARX:** A rede autorregressiva não linear com entradas externa (NARX) é uma rede dinâmica recorrente, com conexões de *feedback* que englobam várias camadas da rede (Figura 23).

Figura 23 – Rede neural NARX com a configuração utilizada durante a simulação.



Fonte: *Toolbox nntool* do Matlab

Organizou-se os dados dos indivíduos normais e amputados com os quatro movimentos descritos anteriormente e, para ficarem de acordo com o método de funcionamento da plataforma *nntool*, dessa forma modificou-se as matrizes de emg, *stimulus* e *repetition*, o código referente a essa parte do trabalho encontra-se em apêndice A. Fez-se alguns testes para definir a melhor forma de manipular os dados, todos os testes foram feitos com o banco de dados dos indivíduos normais, com a rede *Feed-forward Backpropagation* e função de ativação tangente hiperbólica sigmoide.

Primeiramente, fez-se uma comparação entre duas redes, uma com os dados sem nenhuma alteração, denominada de "rede original", e outra rede com os dados decimados, para a matriz de sinal de emg, fez-se a média aritmética de quatro em quatro amostra e para a matriz de estímulo, removeu-se três amostras a cada quatro, a matrizes da rede original apresenta 3881436 colunas, dessa forma, as matrizes dos dados decimados apresentam um tamanho de 970359 colunas, ou seja, quatro vezes menor, o objetivo foi verificar se a rede processava melhor com menos informação. Nomeou-se a rede com os dados decimados como "rede otimizada com 12 canais".

Após análise das saídas da rede original e da rede otimizada de 12 canais, notou-se que a rede otimizada de 12 canais obteve uma resposta melhor. Então, fez-se um segundo teste, comparou-se a rede otimizada de 12 canais, com outra rede otimizada, só que, com apenas 7 canais, como no primeiro teste, a rede teve uma resposta melhor quando teve menos informação para processar, o objetivo foi diminuir o número de informações da rede com uma abordagem diferente. Dessa forma, removeu-se os canais 3,5,8,9 e 11, não houve um rigor para definir quais canais seriam excluídos, apenas observou-se graficamente os canais que os padrões dos movimentos não estavam bem definidos. Nomeou-se essa rede como "rede otimizada de 7 canais". A Figura 26 representa o primeiro canal de EMG dos sinais mioelétrico de um dos indivíduos, com indicação dos movimentos repetidos cinco vezes. As Figuras 24 e 25 representam os gráficos de todos os canais dos sinais mioelétricos de apenas um dos indivíduos, com todos os quatro movimentos desejados, e cada movimento repetido cinco vezes, vale ressaltar que as imagens representam apenas um dos indivíduos, mas foi feito uma análise considerando todos os 11 indivíduos que compõe o banco de dados.

Comparou-se a saída da rede otimizada com 12 canais e da rede otimizada com 7 canais, e inferiu-se que a rede com melhor saída foi a rede otimizada com 12 canais.

Para definir qual foi a melhor rede, fez-se uma análise visual, observou-se as saídas de todas as redes (original, otimizada com 12 e 7 canais), para cada caso de estudo (repouso, movimento 1, 2, 3 e 4), de todo o banco de dados. As imagens 27 até 31 representa as saída das redes para cada caso de estudo de apenas um indivíduo, em cada Figura, plotou-se a entrada, na cor azul, dos sinais mioelétricos de um dos indivíduos, com cada movimento repetido cinco vezes e plotou-se a saída de cada rede, para cada caso de estudo na cor laranja. Nas imagens referentes aos movimentos, fez-se um retângulo na cor preta para identificar a região de saída da rede de interesse. Para os gráficos das Figuras 24 até 31, os sinais mioelétricos foram escalonados com um fator de  $10^6$ .

Figura 24 – Canais de emg (1 ao 6) dos sinais mioelétrico de um dos indivíduos. Cada canal representa os quatro movimentos, cada qual repetido cinco vezes.

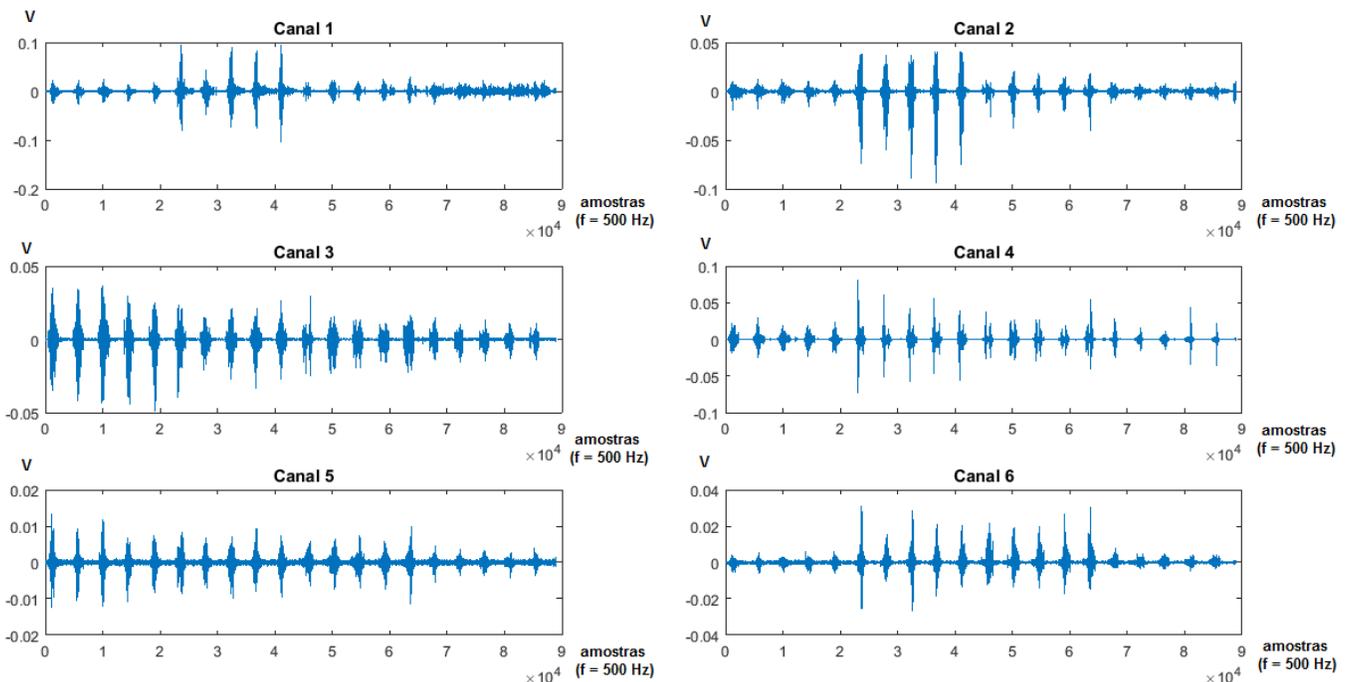
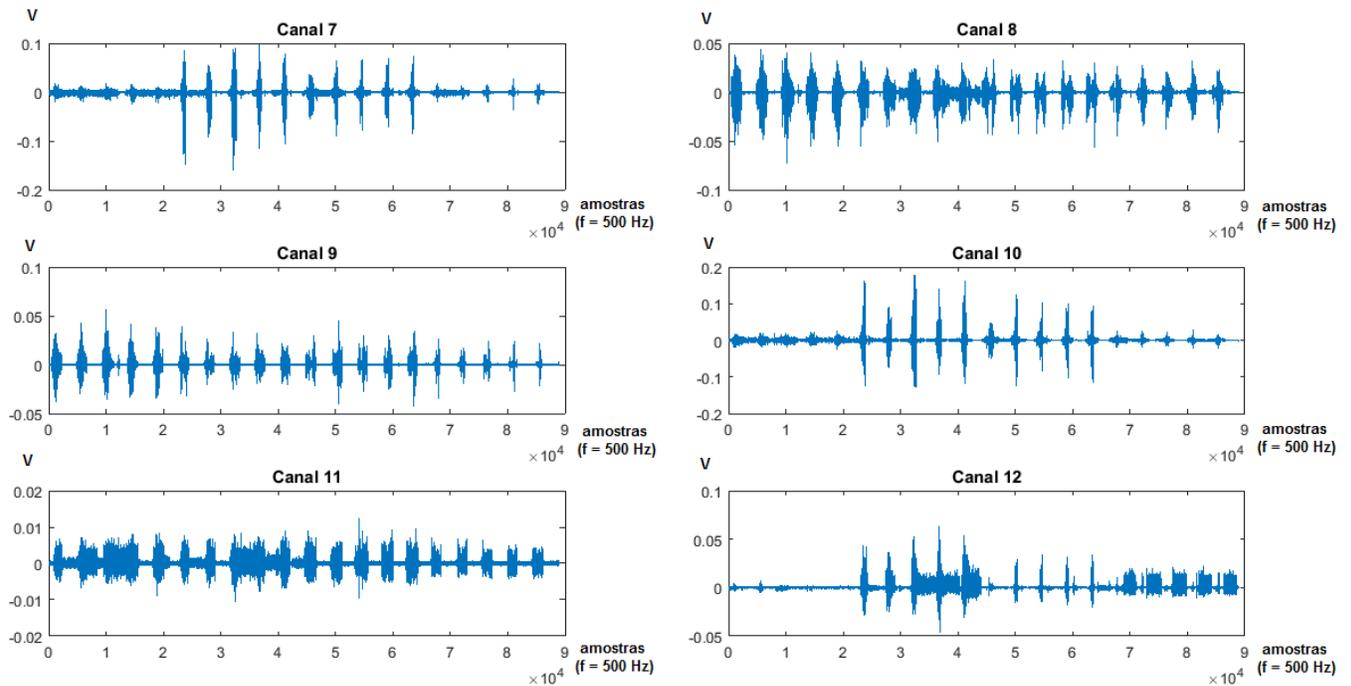
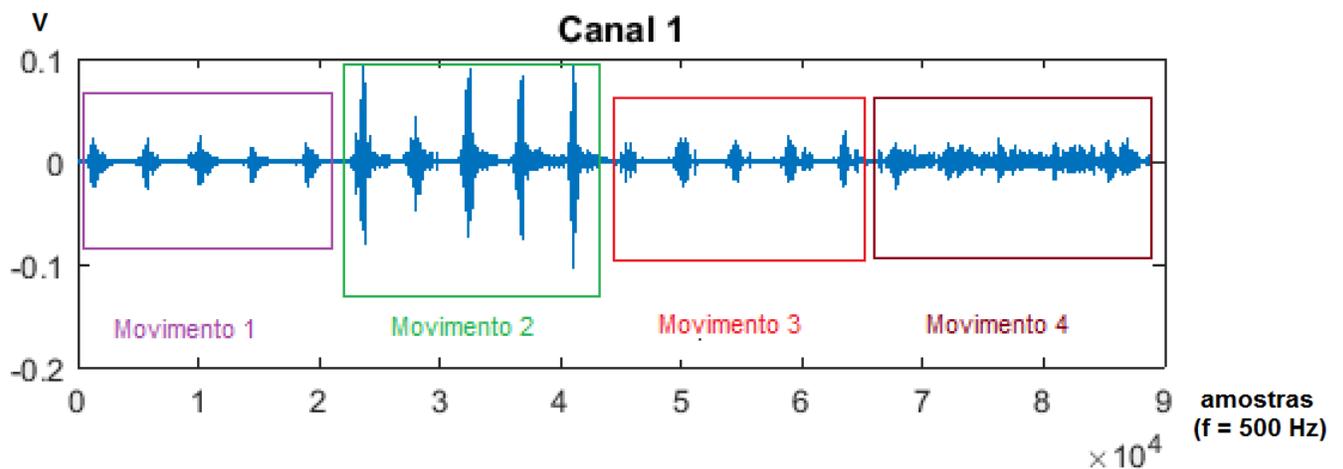


Figura 25 – Canais de emg (7 ao 12) dos sinais mioelétrico de um dos indivíduos. Cada canal representa os quatro movimentos, cada qual repetido cinco vezes.



Fonte: Autoria própria

Figura 26 – Primeiro canal de EMG dos sinais mioelétrico de um dos indivíduos, com indicação dos movimentos repetidos cinco vezes. Movimento 1: Abrir a mão. Movimento 2: Fechar a mão. Movimento 3: Preensão palmar. Movimento 4: Preensão dígito-polegar.



Fonte: Autoria própria

Figura 27 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o estado de repouso. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais.

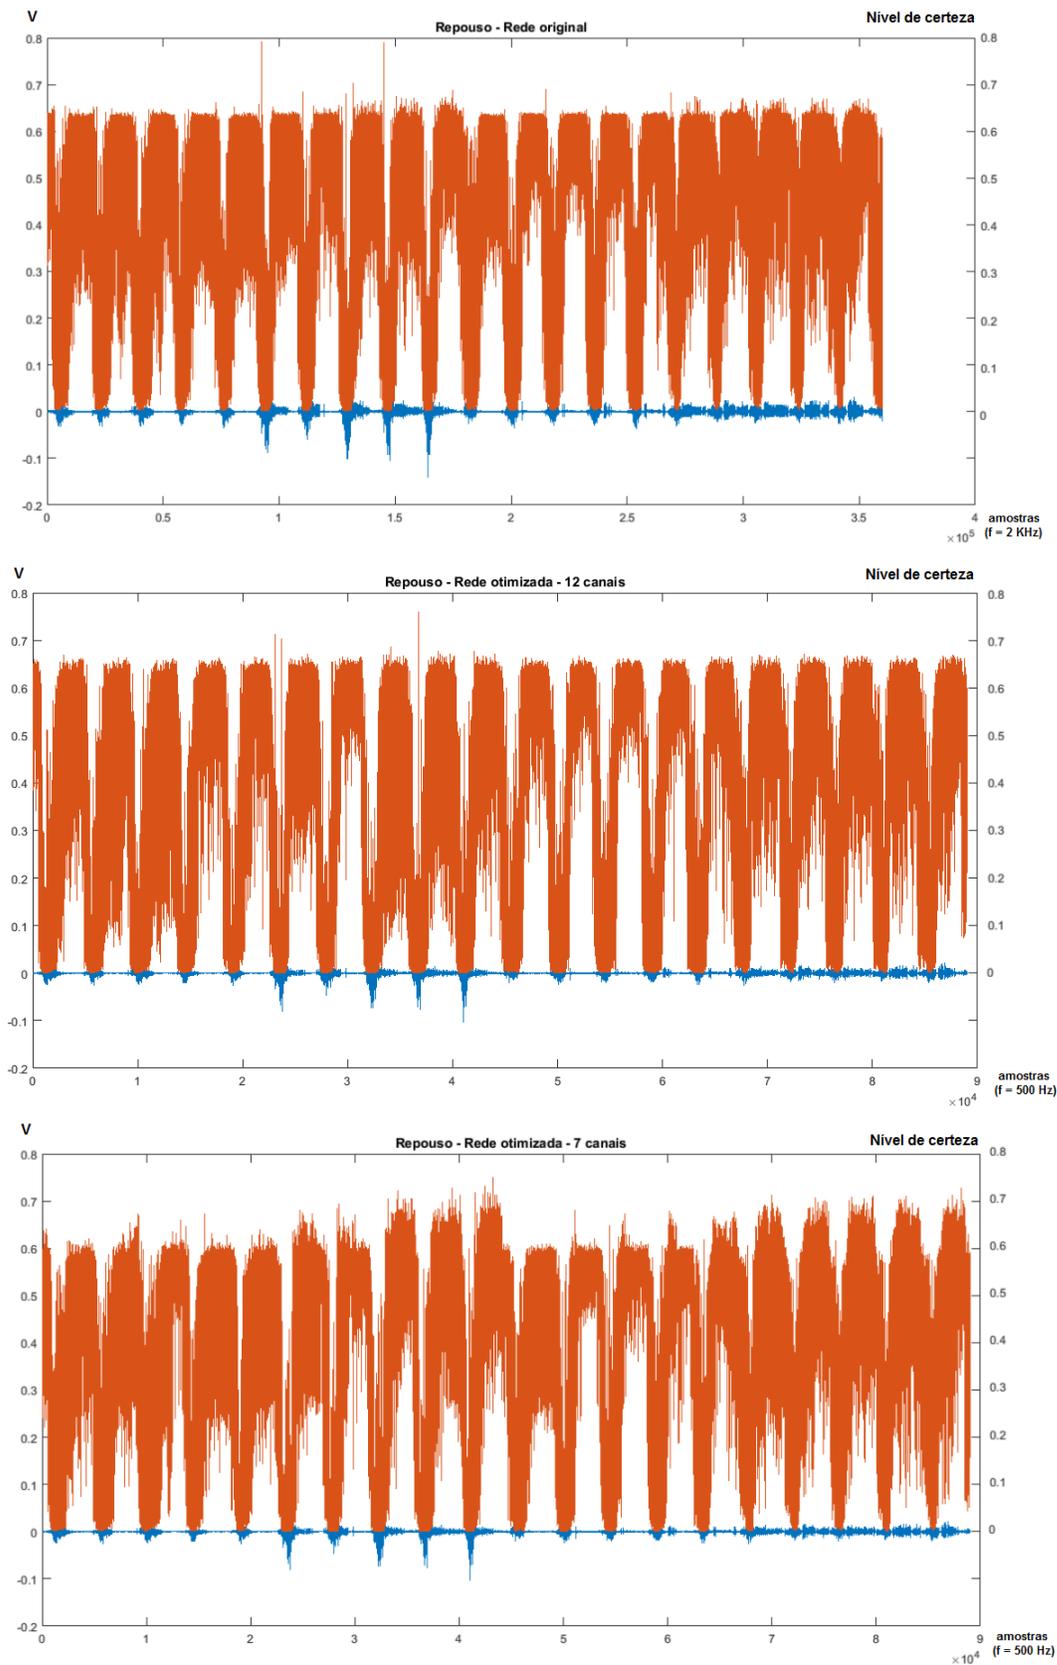


Figura 28 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o primeiro movimento. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais.

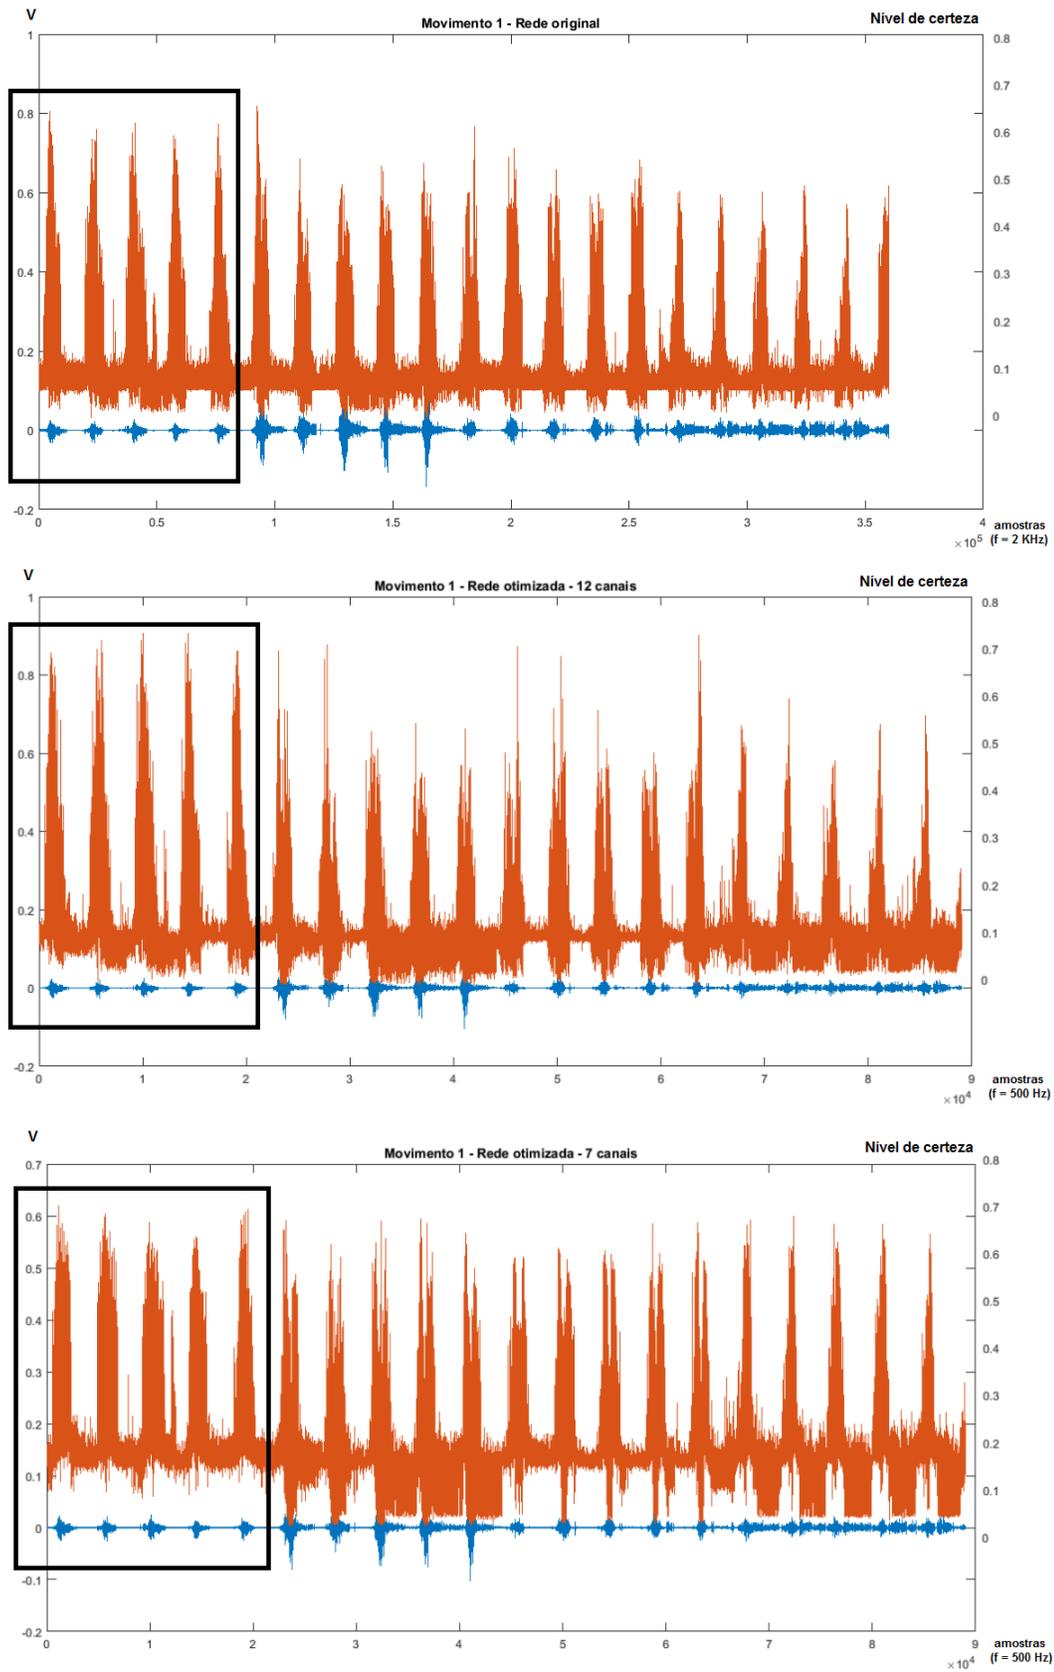


Figura 29 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o segundo movimento. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais.

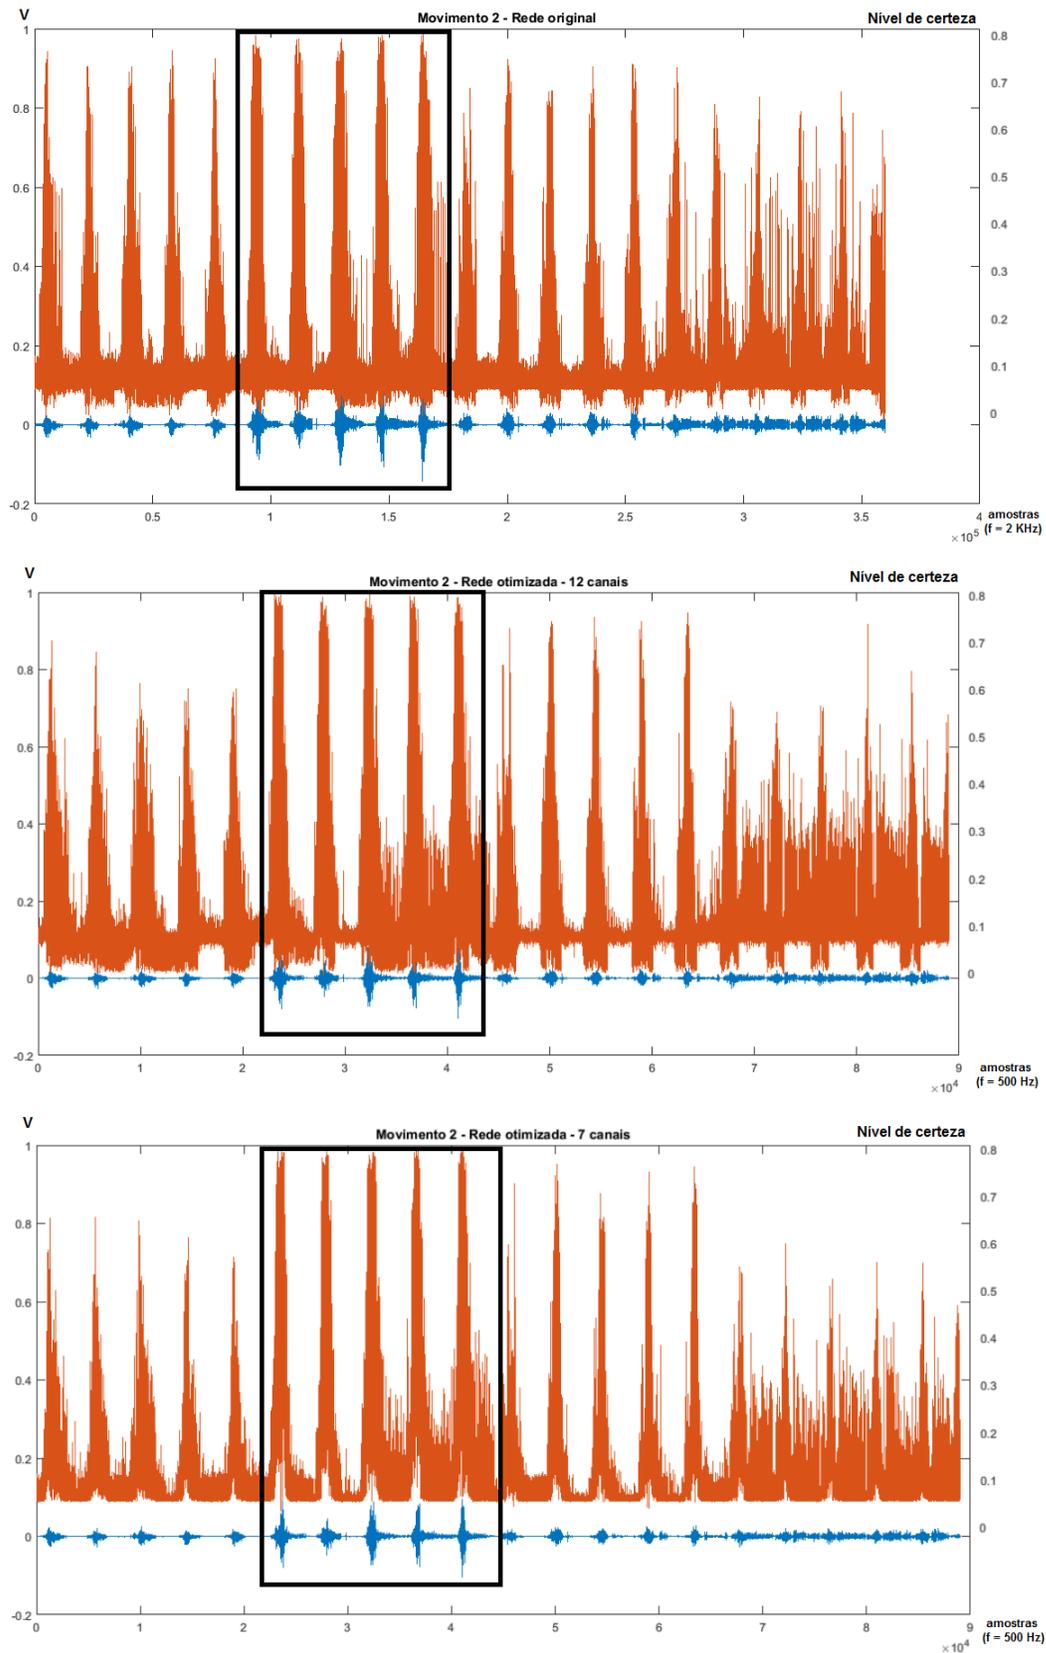


Figura 30 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o terceiro movimento. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais.

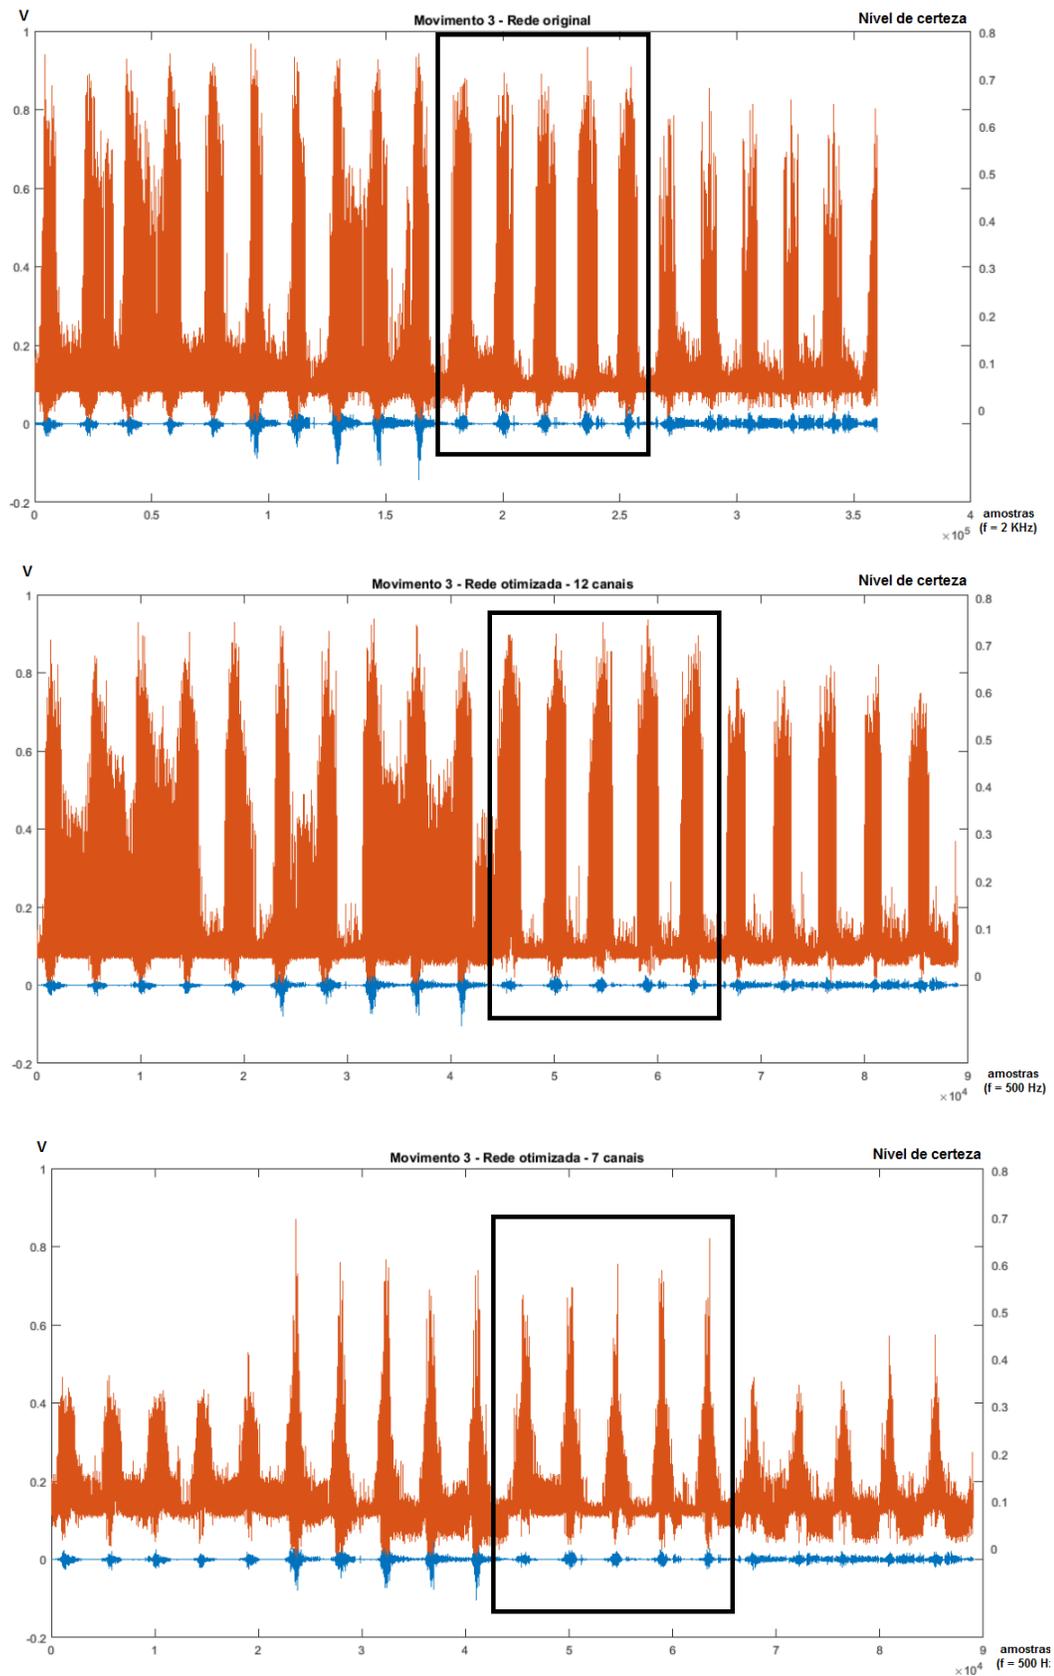
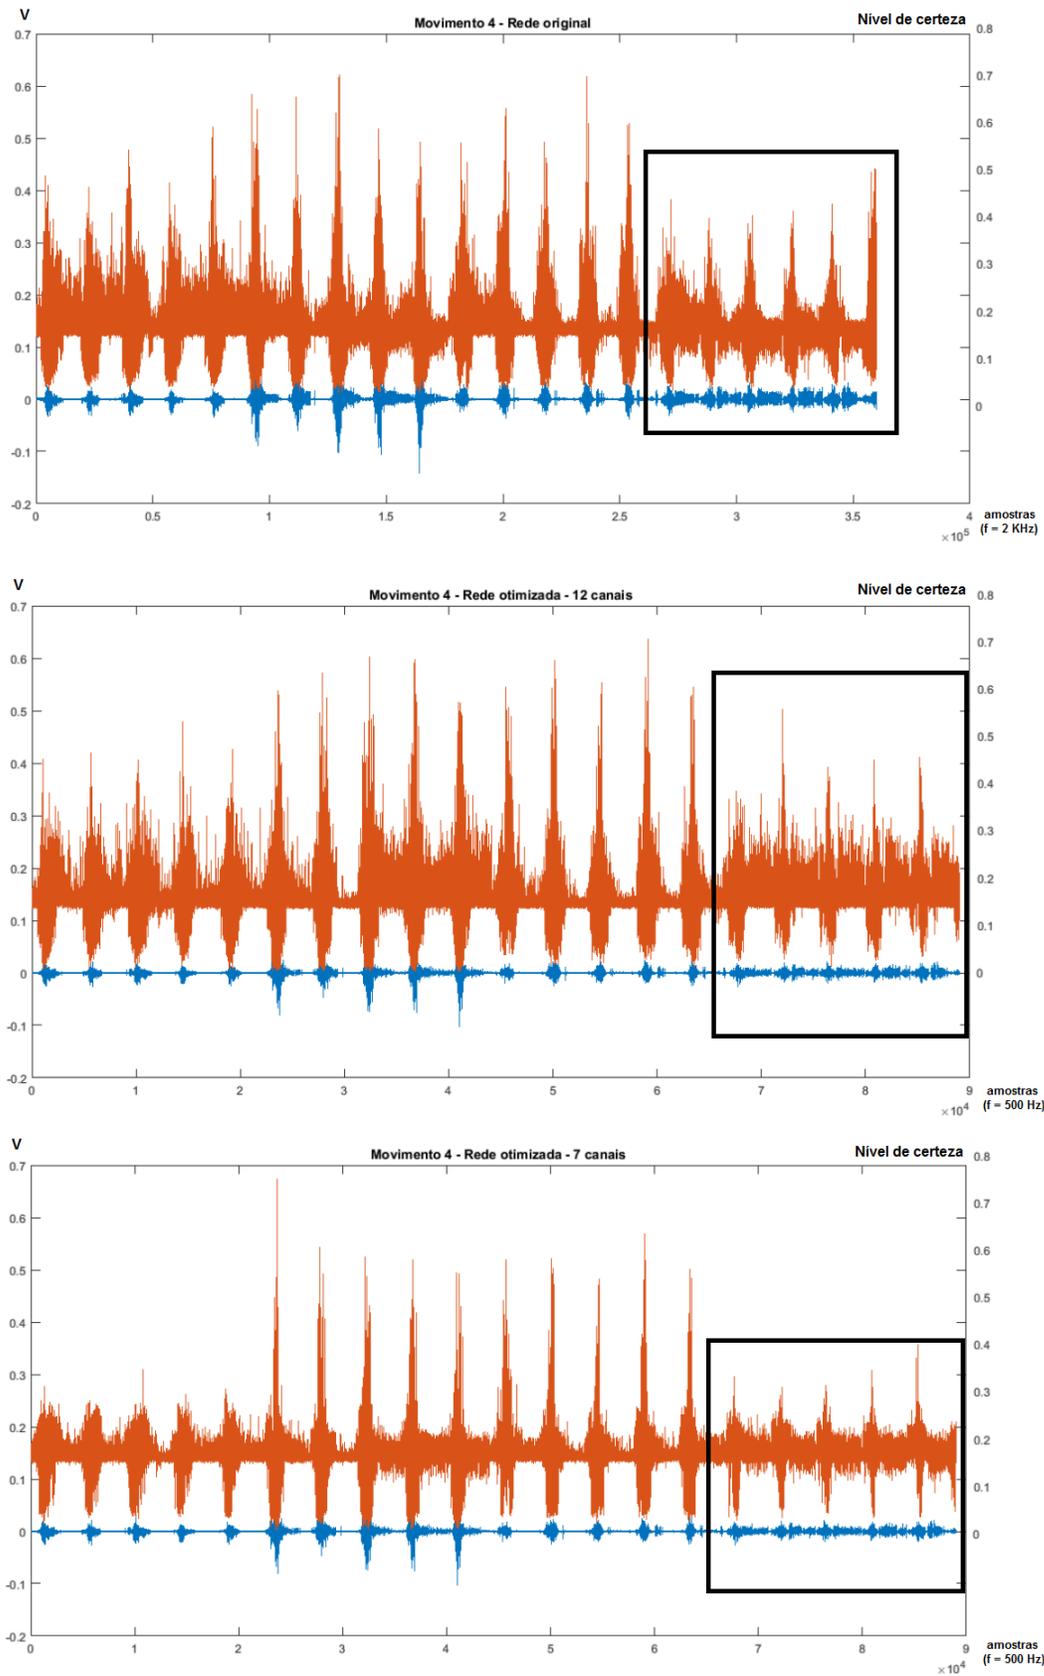


Figura 31 – Em azul, gráfico dos sinais mioelétrico. Em laranja, gráfico da saída das redes para o quarto movimento. Na ordem: rede original, rede otimizada com 12 canais e rede otimizada com 7 canais.



Fonte: Autoria própria

Os resultados das comparações e análise entre as redes está descrito abaixo, deve-se notar que as imagens das saídas das redes são de apenas um dos indivíduos, mas fez-se o estudo dos sinais para cada caso, considerando todos os indivíduos.

- **Para o estado de repouso:** As redes original e otimizada com 12 canais tiveram um resultado similar, e a rede otimizada com 7 canais teve um resultado inferior.
- **Para o movimento 1:** As redes original e otimizada com 12 canais tiveram um bom resultado, porém a rede otimizada foi melhor, novamente a rede otimizada com 7 canais teve um resultado inferior, não conseguiu diferenciar muito bem os movimentos.
- **Para o movimento 2:** As redes otimizada com 12 e 7 canais tiveram um bom resultado, porém a rede com 12 canais teve um resultado melhor, e a rede original teve um resultado inferior.
- **Para o movimento 3:** Todas as redes tiveram um bom resultado, porém as redes otimizada com 7 e 12 canais foram as com melhores saídas.
- **Para o movimento 4:** Nenhuma das redes teve um resultado satisfatório, as redes original e otimizada com 12 canais tiveram um resultado similar e a rede otimizada com 7 canais teve o pior resultado.

Com base nessas observações, a rede otimizada com 12 canais é que ao todo, considerando o repouso e os quatro movimentos, que teve um resultado melhor. Como essa primeira análise foi visual, antes de prosseguir com o treinamento das demais redes, fez-se uma análise de desempenho da rede, para isso, criou-se um código para otimizar os cálculos das métricas de desempenho, o código está no apêndice B. As métricas de desempenho estão descritas na seção 2.7 desse documento, e considerou-se uma comparação de amostra por amostra para determinar os VN, VP, FN e FP.

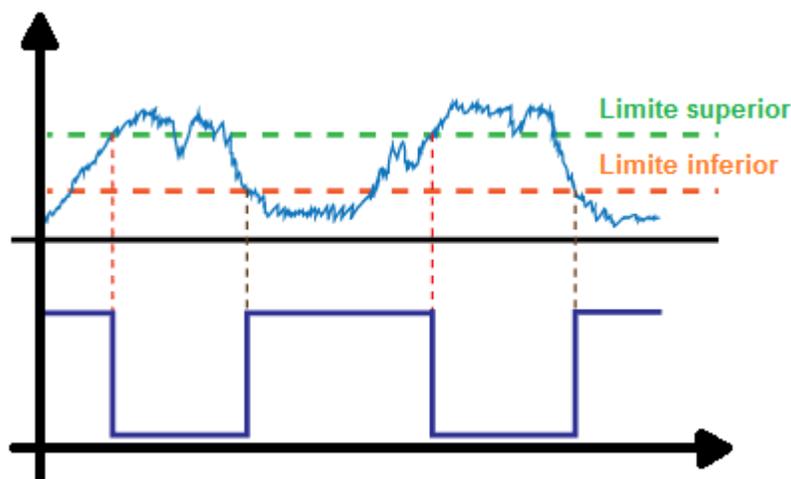
O resultado de desempenho da rede otimizada com 12 canais pode-se ser visto na Tabela 5. A coluna limiar de decisão, refere-se ao valor que foi definido como ideal para identificar um dos casos de estudo. As colunas VPP, VPN, sensibilidade, especificidade e eficiência refere-se a métricas de desempenho já definidas nesse documento. A primeira coluna de cada Tabela, descrita como "estudo de caso" apresenta a seguinte representação:

- **Estudo de caso 0:** Representa o estado de repouso, quando o indivíduo não está fazendo nenhum tipo de movimento.
- **Estudo de caso 1:** Representa o movimento 1, ou seja, a ação de abrir a mão.
- **Estudo de caso 2:** Representa o movimento 2, ou seja, a ação de fechar a mão.
- **Estudo de caso 3:** Representa o movimento 3, ou seja, a ação de prensão palmar referente a ação de segurar um copo.
- **Estudo de caso 4:** Representa o movimento 4, ou seja, a ação prensão dígito-polegar referente a ação de segurar um alfinete.

Nota-se que os valores de VPP, VPN, especificidade e eficiência foram na maior parte maior que 60%. Porém a sensibilidade da rede para todos os casos de estudo foi próxima de zero, isso ocorreu porque, como a comparação de desempenho foi feita amostra por amostra e a rede tem um atraso para identificar os movimentos, esse atraso faz com que o número de falso positivo (FP) seja muito alto, e de verdadeiro positivo (VP) baixo, fazendo com que o valor de sensibilidade seja próximo de zero. Dessa forma, pensou-se em o método de avaliação do desempenho da rede.

Fez-se na saída da rede um *Schmitt trigger* para aumentar o *range* da detecção de movimento. Basicamente, quando a rede chega em um valor igual ou superior ao limiar de decisão específico para cada caso, a saída fica com o 1, e esse valor permanece em 1 até cair para um segundo limiar, ou seja, o sinal de saída da rede é descrita como uma função com vários degraus, a Figura 32 ilustra a aplicação utilizada.

Figura 32 – Exemplo de funcionamento do *Schmitt trigger*.



Fonte: Adaptado de HowToMechatronics... (2017), disponível em:  
<<http://howtomechatronics.com/how-it-works/electrical-engineering/schmitt-trigger/>>

Após a transformação das saídas das redes, decidiu-se não comparar amostra por amostra, fez-se um programa onde compara-se o intervalo de movimento e verifica se foi feito o movimento específico desconsiderando qualquer tipo de atraso, quando feito o movimento, considerou-se todo esse intervalo como um VP, e quando não foi feito o movimento, como um FP. Para os intervalos de repouso fez-se um processo parecido, se durante todo o intervalo de repouso for encontrado qualquer movimento conta-se como um FN, caso contrário como um VN. Agora, a comparação não é mais amostra por amostra e sim, intervalos de movimento e intervalos de repouso. A Tabela 6 mostra o desempenho da mesma rede, agora utilizando esse novo método para cálculo de desempenho. O código referente a essa análise de desempenho encontra-se no apêndice C. Todas as demais tabelas de desempenho nesse trabalho foram feitas dessa forma, caso contrário será especificado no texto.

Tabela 5 – Desempenho da rede otimizada com 12 canais, comparou-se amostra por amostra para definir valores de VP, VN, FP e FN.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,65	63,44	62,60	0,78	99,73	62,60
1	0,78	82,87	84,43	0,14	99,99	84,43
2	0,92	95,19	84,53	0,99	99,99	84,54
3	0,85	90,95	84,45	0,89	99,98	84,46
4	0,50	53,89	84,43	0,44	99,93	84,39

Fonte: Autoria própria

Tabela 6 – Desempenho da rede otimizada com 12 canais, comparou-se intervalos para definir valores de VP, VN, FP e FN.

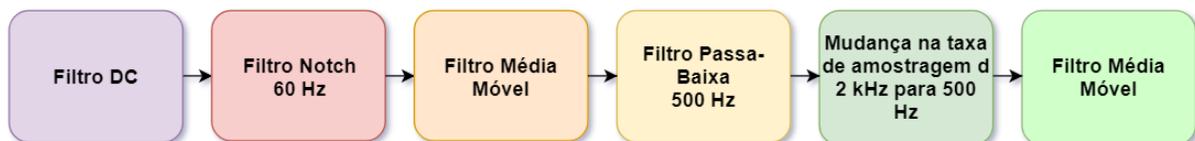
Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,65	33,07	94,02	93,63	34,54	49,71
1	0,78	33,33	61,11	36,36	57,89	50,00
2	0,92	42,86	71,43	60,00	55,55	57,14
3	0,85	29,27	88,71	87,27	32,16	45,57
4	0,50	11,40	62,82	47,27	19,52	24,51

Fonte: Autoria própria

Para a primeira análise de desempenho a sensibilidade da rede foi próxima de zero e para a segunda análise de desempenho da rede, os valores foram mais uniformes, mas não se chegou em um desempenho desejável, dessa forma optou-se por processar os sinais do banco de dados dos indivíduos normais e verificar possíveis melhorias, os códigos referentes à essa etapa, encontra-se em Apêndice D.

O processamento dos dados foi feito com os dados originais, utilizou-se uma função padrão do Matlab para remover a componente DC, depois removeu-se a interferência da rede de 60Hz, utilizou-se a função *abs* para deixar o sinal apenas positivo. Fez-se um filtro de média móvel, removendo dessa forma diversos picos existentes no sinal, após esse filtro, o sinal passou por um filtro passa-baixa de 500 Hz. Depois dessas filtragens, os dados foram decimados, da mesma forma que feito anteriormente, fez-se a média aritmética de quatro em quatro amostras. Após essa etapa, plotou-se o sinal para cada caso de estudo e observou-se que os dados poderiam ser filtrados novamente, a Figura 33 mostra um diagrama de blocos com o procedimento utilizado para processamento dos dados. O sinal passou por um segundo filtro média móvel. Nomeou-se essa rede como "rede filtrada", a Tabela 7 mostra o desempenho para essa rede.

Figura 33 – Exemplo de funcionamento do *Schmitt trigger*.



Fonte: Autoria própria

Como as componentes de maior contribuição do sinal de emg estão na faixa de 20 Hz até 200 Hz, ao decimar as amostras por quatro, faz com que a taxa de amostragem seja de 500 amostras, ainda respeitando o critério de Nyquist de que a taxa de amostragem deve ser de no mínimo duas vezes ao valor da maior frequência de interesse.

Nota-se que o desempenho para a rede filtrada foi superior a rede otimizada com 12 canais, ou seja, o processamento dos dados trouxe melhorias para o sistema, e decidiu-se adotar esse processamento para os dados dos indivíduos normais e amputados, e utilizá-los para o treinamento de todas as redes.

Para a rede filtrada, plotou-se os gráficos da saída e da entrada para também ser feito uma análise gráfica, pode-se visualizar o resultado nas Figuras 34 e 35, os gráficos na cor laranja representa a saída da rede, e os gráficos

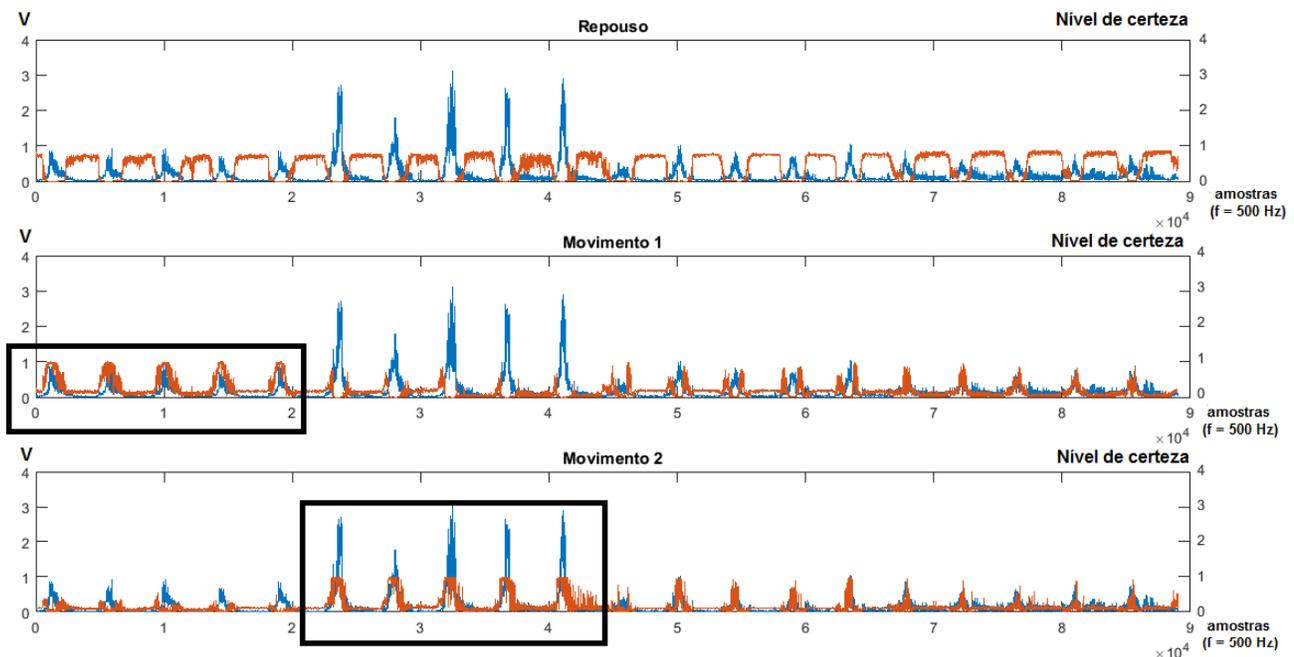
na cor azul, representa a entrada, com os sinais mioelétricos de um dos indivíduos (escalonados por um fator de  $10^7$ ), para os quatro movimentos, cada qual repetido cinco vezes. Demarcou-se com um retângulo preto as regiões de interesse da saída da rede para cada caso de estudo. As Figuras 36 até 40 mostra a demarcação do limiar de decisão para a rede filtrada, e a conversão da saída para um sinal de degraus utilizando o princípio de *Schmitt trigger*. Vale ressaltar que mesmo que por causa das imagens aqui mostradas pareça que um outro limiar de decisão seria uma escolha mais inteligente, para chegar a esses valores foi analisado todo o conjunto de dados, ou seja, os 11 indivíduos, e aqui nesse trabalho, todas as imagens são referentes a de apenas um dos indivíduos.

Tabela 7 – Desempenho da rede filtrada.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,70	46,95	74,74	66,36	57,03	60,43
1	0,88	51,72	68,35	54,54	65,85	61,32
2	0,97	64,52	78,57	72,73	71,43	71,97
3	0,96	57,50	85,94	83,64	61,80	70,14
4	0,50	18,24	61,90	56,36	21,91	30,04

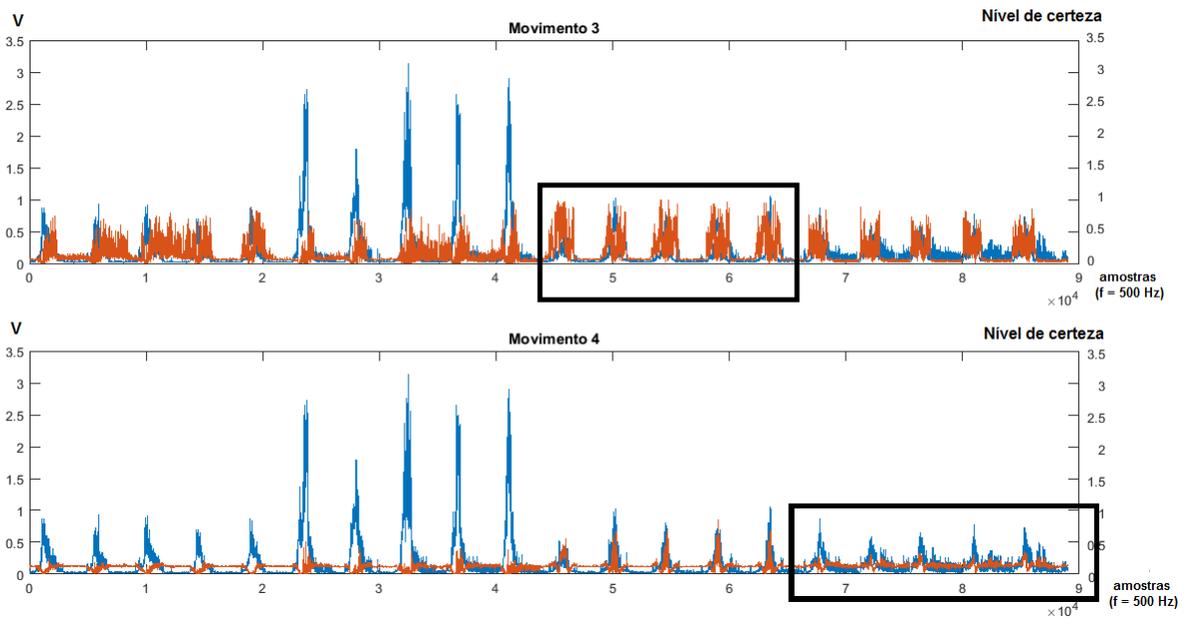
Fonte: Autoria própria

Figura 34 – Em azul, gráfico dos sinais mioelétrico. Em laranja gráfico da saída da rede filtrada. Na ordem dos estudos de caso: repouso, movimento 1 e movimento 2.



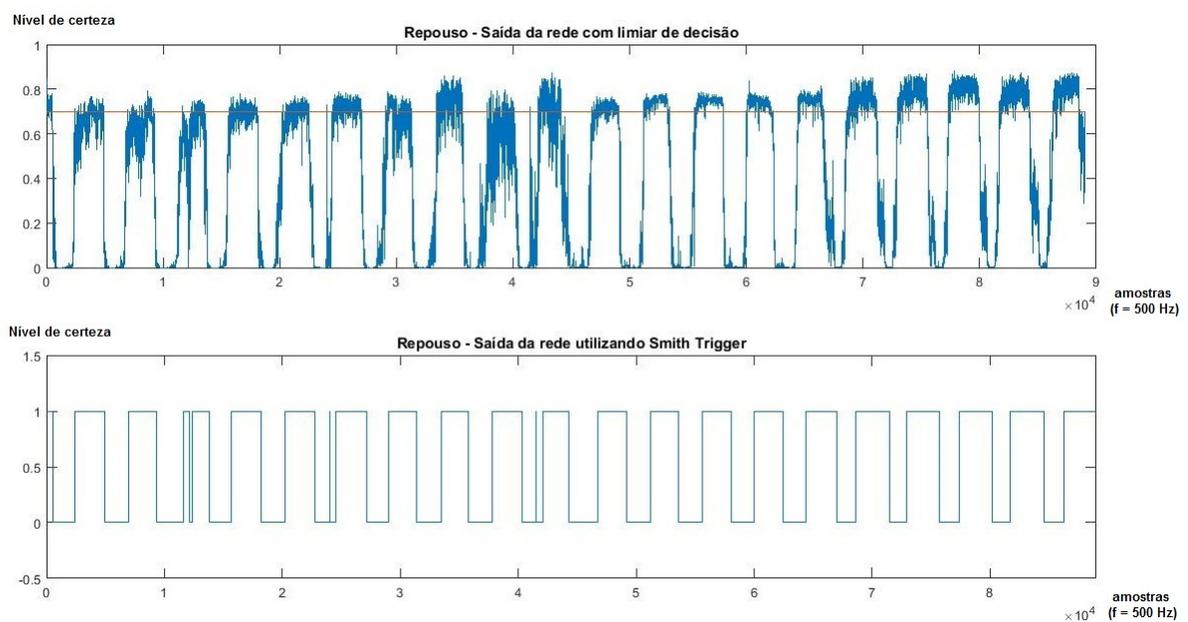
Fonte: Autoria própria

Figura 35 – Em azul, gráfico dos sinais mioelétrico. Em laranja gráfico da saída da rede filtrada. Na ordem dos estudos de caso: movimento 3 e movimento 4.



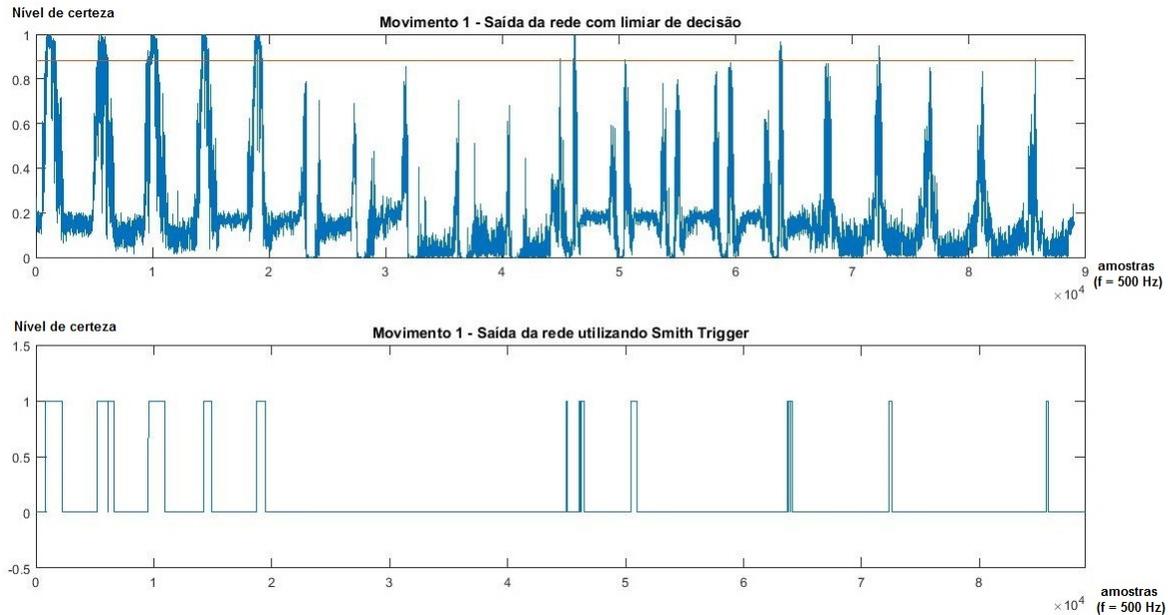
Fonte: Autoria própria

Figura 36 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: repouso.



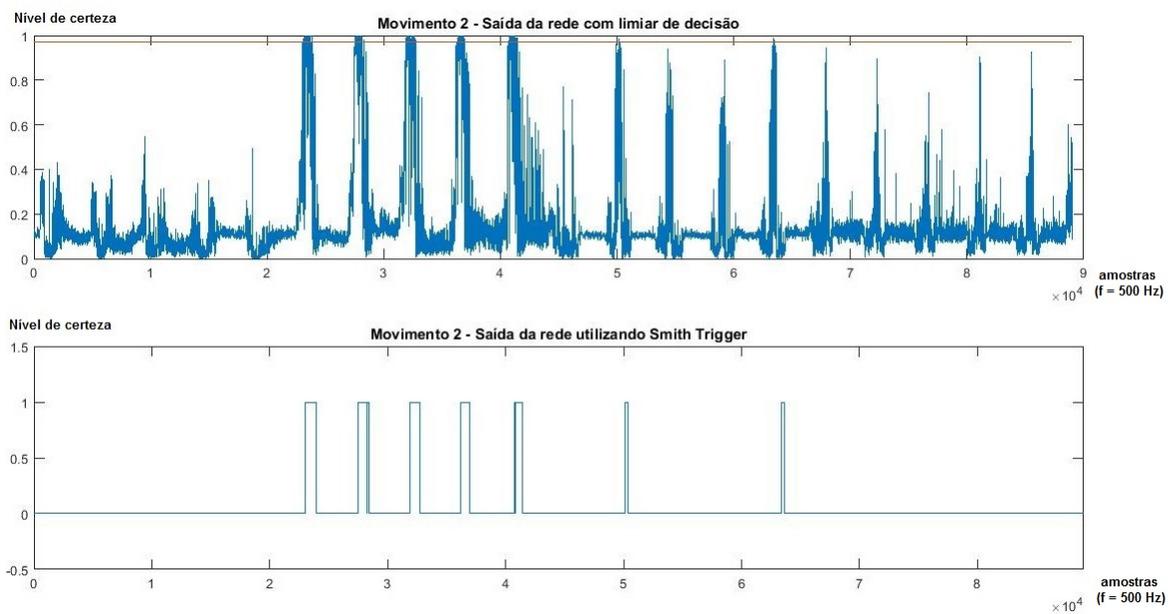
Fonte: Autoria própria

Figura 37 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: movimento 1.



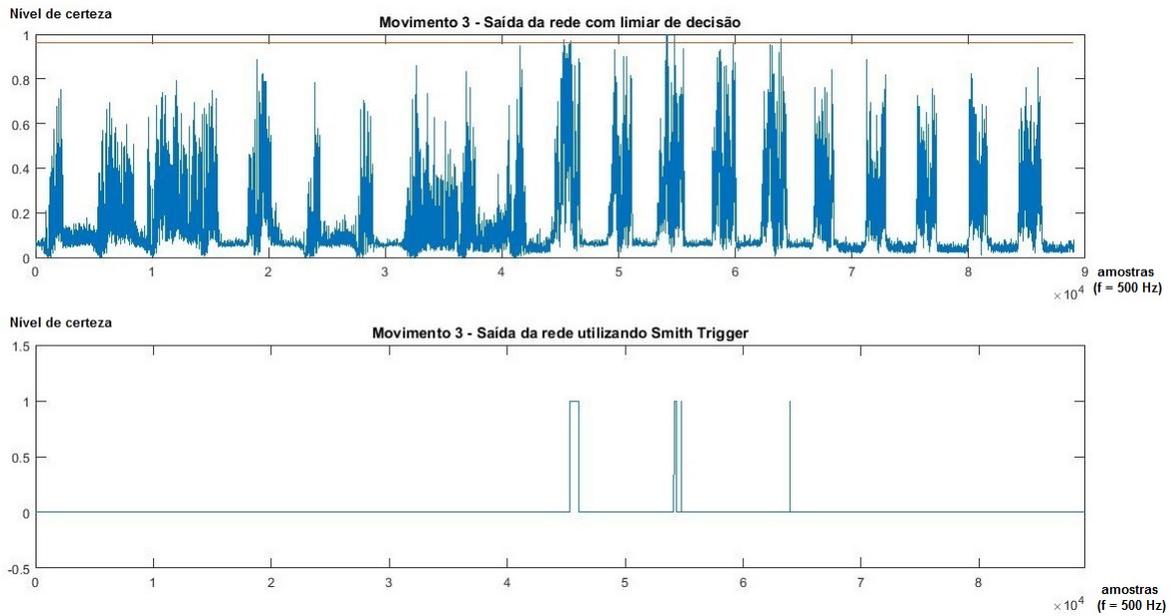
Fonte: Autoria própria

Figura 38 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: movimento 2.



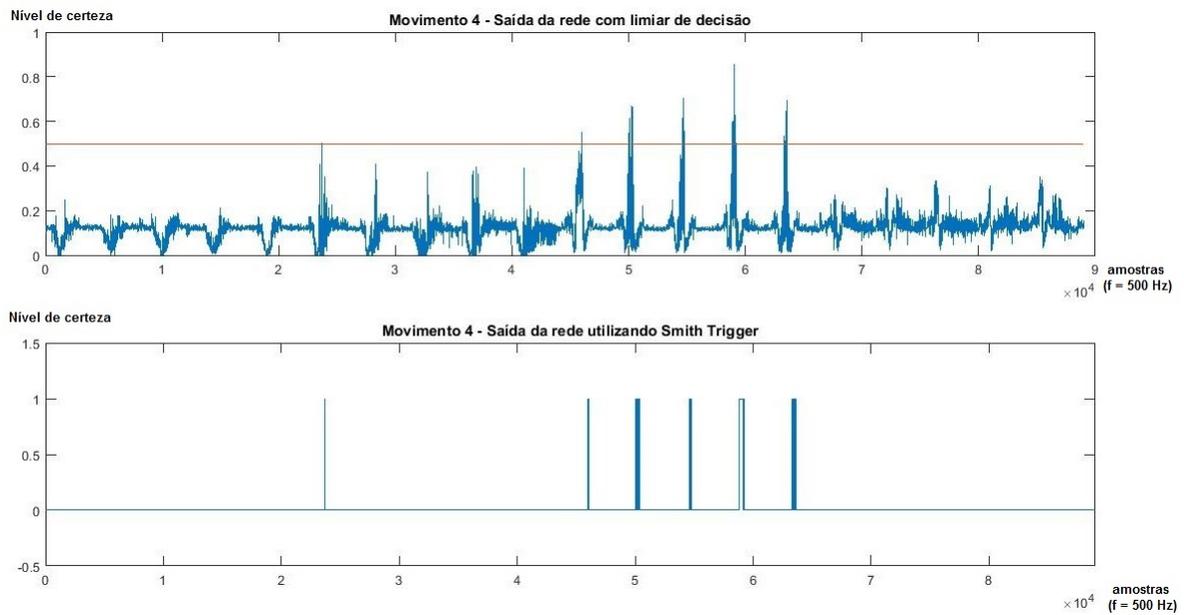
Fonte: Autoria própria

Figura 39 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: movimento 3.



Fonte: Autoria própria

Figura 40 – Saída da rede filtrada. Na primeira imagem a escolha do limiar de decisão, e na segunda imagem a conversão da saída para degraus. Caso de estudo: movimento 4.



Fonte: Autoria própria



## 4 RESULTADOS E DISCUSSÕES

Como descritos na metodologia, todas as redes foram submetidas a mesma configuração, e utilizou-se os dados dos indivíduos normais e amputados processados. Os limiares de decisão foram todos primeiramente definidas visualmente, através da plotagem dos gráficos das saídas das redes, e depois refinados a fim de encontrar a melhor resposta de desempenho para cada caso de estudo de cada rede.

O limiar de decisão define os sinais que serão considerados movimentos, dessa forma, valores menores do limiar de decisão faz com que a sensibilidade do sistema aumente, pois detecta-se mais verdadeiros positivos, e limiar de decisão maiores, aumenta a especificidade do sistema, pois, detecta-se menos falso positivos. Para os casos que o limiar de decisão está mais próximo do valor um, indica que a rede tem mais certeza de que o sinal se refere ao movimento desejado.

### 4.1 INDIVÍDUOS NORMAIS

Observando nas Tabelas 8 até 16, nota-se que para todos os casos, com exceção da rede NARX com função de ativação linear (PURELIN), o movimento com pior desempenho é o movimento 4, e os melhores desempenho são para os movimentos 2 e 3, isso ocorre porque o movimento 4 corresponde ao movimento de pinça, que é um movimento delicado e difícil de detectar, e os movimentos 2 e 3, corresponde respectivamente aos movimentos de fechar a mão e segurar um copo, que são os movimentos que o indivíduo faz maior força, com isso a amplitude do sinal mioelétrico é maior e torna-se movimentos mais fáceis de a rede conseguir perceber um padrão e detectá-los.

Tabela 8 – Desempenho da rede *feed-forward backpropagation* com função de ativação TANSIG para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,70	46,95	74,74	66,36	57,03	60,43
1	0,88	51,72	68,35	54,54	65,85	61,32
2	0,97	64,52	78,57	72,73	71,43	71,97
3	0,96	57,50	85,94	83,64	61,80	70,14
4	0,50	18,24	61,90	56,36	21,91	30,04

Tabela 9 – Desempenho da rede *feed-forward backpropagation* com função de ativação PURELIN para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,64	44,61	76,57	69,55	53,54	59,15
1	0,87	43,93	67,90	52,72	59,78	57,14
2	0,98	52,17	74,32	65,45	62,50	63,63
3	0,99	65,71	85,93	83,63	69,62	75,37
4	0,40	30,14	57,14	40,00	46,32	44,00

Fonte: Autoria própria

Comparando o desempenho das redes *feed-forward-backpropagation*, Tabelas 8, 9 e 10 a rede com função de ativação TANSIG foi a que teve um melhor desempenho para os casos de estudo 0, 1 e 2. Já para o caso de estudo 3, a rede com melhor desempenho foi a com função de ativação PURELIN e depois a LOGSIG, e o caso de estudo 4, teve um resultado ruim em todas as redes, sendo a rede TANSIG com pior resposta.

Tabela 10 – Desempenho da rede *feed-forward backpropagation* com função de ativação LOGSIG para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,60	45,28	74,15	65,45	55,61	59,15
1	0,80	41,46	72,37	61,82	53,40	56,32
2	0,92	50,00	77,47	70,91	58,51	63,09
3	0,99	66,66	83,33	80,00	71,43	75,00
4	0,60	30,38	57,53	43,64	43,30	42,42

Fonte: Autoria própria

Tabela 11 – Desempenho da rede *cascade-forward backpropagation* com função de ativação TANSIG para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,73	47,62	78,57	72,73	55,55	61,69
1	0,80	47,76	70,13	58,18	60,67	59,72
2	0,95	63,64	80,88	76,36	69,62	72,39
3	0,97	57,50	85,94	83,64	61,80	70,14
4	0,65	23,86	60,00	38,18	43,22	41,62

Fonte: Autoria própria

Tabela 12 – Desempenho da rede *cascade-forward backpropagation* com função de ativação PURELIN para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,68	45,27	71,89	60,90	57,59	58,80
1	0,82	38,46	68,75	54,55	53,40	53,80
2	0,90	51,47	73,33	63,64	62,50	62,93
3	0,99	63,01	85,94	83,64	67,07	73,72
4	0,50	22,45	56,58	40,00	36,13	37,36

Tabela 13 – Desempenho da rede *cascade-forward backpropagation* com função de ativação LOGSIG para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,66	43,43	73,74	64,55	54,21	57,85
1	0,85	42,47	69,62	56,36	56,70	56,58
2	0,95	55,07	76,06	69,09	63,53	65,71
3	0,99	63,89	85,94	83,64	67,90	74,26
4	0,60	20,87	58,11	43,64	32,09	35,45

Fonte: Autoria própria

Comparando o desempenho das redes *cascade-forward-backpropagation*, Tabelas 11, 12 e 13 a rede com função de ativação TANSIG foi a que teve um melhor desempenho para os casos de estudo 0, 1 e 2 e 4. Já para o caso de estudo 3, a rede com melhor desempenho foi a com função de ativação LOGSIG e depois a PURELIN.

Todas as redes NARX precisaram ser treinadas diversas vezes para que a saída das redes tivessem uma resposta coerente, nos primeiros treinamentos as saídas das redes não detectaram nenhuma diferença entre os movimentos e o estado de repouso. Após em média cinco treinamentos de cada rede NARX com as diferentes funções de ativação é que foi possível obter uma resposta das redes.

Tabela 14 – Desempenho da rede NARX com função de ativação TANSIG para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,68	46,74	72,28	61,82	58,55	59,76
1	0,85	43,48	68,75	54,55	58,51	57,05
2	0,92	54,93	77,46	70,90	63,22	66,20
3	0,93	64,29	84,62	81,82	68,75	74,07
4	0,60	25,00	57,53	43,64	36,84	39,05

Fonte: Autoria própria

Tabela 15 – Desempenho da rede NARX com função de ativação PURELIN para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,7	98,04	55,55	90,90	86,21	90,36
1	0,02	0,76	59,14	30,90	2,43	3,10
2	0,15	11,63	57,89	27,27	32,54	31,25
3	0,000005	66,66	52,38	10,90	50,00	53,98
4	0,9982	98,21	100,00	100,00	66,67	98,28

Fonte: Autoria própria

Tabela 16 – Desempenho da rede NARX com função de ativação LOGSIG para o banco de dados de indivíduos normais.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,65	81,18	43,90	76,82	50,46	59,30
1	0,80	73,33	41,18	63,64	52,38	56,25
2	0,92	74,32	48,65	65,45	59,14	61,49
3	0,92	85,94	70,77	83,64	74,32	78,30
4	0,50	55,70	30,30	36,36	48,89	44,14

Fonte: Autoria própria

Comparando o desempenho das redes NARX, Tabelas 14, 15 e 16 notou-se que a rede com função de ativação TANSIG foi a que teve um melhor desempenho para os casos de estudo 2, 3 e 4. A rede com função de

ativação PURELIN teve um resultado muito bom para os casos de estudo 0 e 5, com eficiência de 90,36% e 98,28%, respectivamente, mas para os demais casos de estudo, não houve um resultado satisfatório.

As Tabelas 17 até 21 mostra a comparação de desempenho de todas as redes para cada caso de estudo. Utilizou-se como primeiro critério para definir o melhor desempenho a eficiência, e depois, na ordem: sensibilidade, especificidade, VPP, VPN e limiar de decisão. Definiu-se utilizar a melhor rede de cada caso para treinar os dados dos indivíduos amputados, dessa forma:

- **NARX PURELIN:** a rede teve a melhor eficiência para os estudos de caso 0 e 4, com eficiência de 90,36% e 98,28% respectivamente, porém teve o pior desempenho nos demais estudos de caso. Apesar de apresentar bons resultados para dois estudos de caso, e então ser utilizada com o banco de dados dos indivíduos amputados, a rede não foi considerada confiável devido a divergência entre os valores dos diferentes estudos de casos.
- **FFB TANSIG:** a rede com o melhor desempenho para o estudo de caso 1, com 61,32%, ficou em terceiro lugar para o estudo de caso 0, com 60,43% de eficiência, em segundo lugar no estudo de caso 2, com 71,97% de eficiência, em penúltimo lugar no estudo de caso 3, com 70,14% de eficiência e teve o pior desempenho para o estudo de caso 5, com 30,04% de eficiência.
- **CFB TANSIG:** a rede com melhor desempenho para o estudo de caso 2, com 72,39% de eficiência, em segundo lugar para os estudos de caso 0 e 1, com eficiência de 61,69% e 59,72% respectivamente. Em antepenúltimo lugar para o estudo de caso 3, com eficiência de 70,14% e em quinto lugar para o estudo de caso 4, com 41,62% de eficiência.
- **NARX LOGSIG:** a rede teve o melhor desempenho para o estudo de caso 3, com 78,30% de eficiência. Para os estudos de caso 0, 1, 2 e 4 teve uma eficiência de 59,30%, 56,25%, 61,49% e 44,14% respectivamente.

Tabela 17 – Melhor desempenho das redes para o estudo de caso 0: repouso. Considerando o banco de dados dos indivíduos normais.

RNA	Função de Ativação	Limiar de Decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
NARX	PURELIN	0,70	98,04	55,55	90,90	86,21	90,36
CFB	TANSIG	0,73	47,62	78,57	72,73	55,55	61,69
FFB	TANSIG	0,70	46,95	74,74	66,36	57,03	60,43
NARX	TANSIG	0,68	46,74	72,28	61,82	58,55	59,76
NARX	LOGSIG	0,65	81,18	43,90	76,82	50,46	59,30
FFB	PURELIN	0,64	44,61	76,57	69,55	53,54	59,15
FFB	LOGSIG	0,60	45,28	74,15	65,45	55,61	59,15
CFB	PURELIN	0,68	45,27	71,89	60,90	57,59	58,80
CFB	LOGSIG	0,66	43,43	73,74	64,55	54,21	57,85

Fonte: Autoria própria

Tabela 18 – Melhor desempenho das redes para o estudo de caso 1: mão aberta. Considerando o banco de dados dos indivíduos normais.

RNA	Função de Ativação	Limiar de Decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
FFB	TANSIG	0,88	51,72	68,35	54,54	65,85	61,32
CFB	TANSIG	0,80	47,76	70,13	58,18	60,67	59,72
FFB	PURELIN	0,87	43,93	67,90	52,72	59,78	57,14
NARX	TANSIG	0,85	43,48	68,75	54,55	58,51	57,05
CFB	LOGSIG	0,85	42,47	69,62	56,36	56,70	56,58
FFB	LOGSIG	0,80	41,46	72,37	61,82	53,40	56,32
NARX	LOGSIG	0,80	73,33	41,18	63,64	52,38	56,25
CFB	PURELIN	0,82	38,46	68,75	54,55	53,40	53,80
NARX	PURELIN	0,02	0,76	59,14	30,90	2,43	3,10

Fonte: Autoria própria

Tabela 19 – Melhor desempenho das redes para o estudo de caso 2: mão fechada. Considerando o banco de dados dos indivíduos normais.

RNA	Função de Ativação	Limiar de Decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
CFB	TANSIG	0,95	63,64	80,88	76,36	69,62	72,39
FFB	TANSIG	0,97	64,52	78,57	72,73	71,43	71,97
NARX	TANSIG	0,92	54,93	77,46	70,90	63,22	66,20
CFB	LOGSIG	0,95	55,07	76,06	69,09	63,53	65,71
CFB	PURELIN	0,90	51,47	73,33	63,64	62,50	62,93
FFB	PURELIN	0,98	52,17	74,32	65,45	62,50	63,63
FFB	LOGSIG	0,92	50,00	77,47	70,91	58,51	63,09
NARX	LOGSIG	0,92	74,32	48,65	65,45	59,14	61,49
NARX	PURELIN	0,15	11,63	57,89	27,27	32,54	31,25

Fonte: Autoria própria

Tabela 20 – Melhor desempenho das redes para o estudo de caso 3: segurando um copo. Considerando o banco de dados dos indivíduos normais.

RNA	Função de Ativação	Limiar de Decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
NARX	LOGSIG	0,92	85,94	70,77	83,64	74,32	78,30
FFB	PURELIN	0,99	65,71	85,93	83,63	69,62	75,37
FFB	LOGSIG	0,99	66,66	83,33	80,00	71,43	75,00
CFB	LOGSIG	0,99	63,89	85,94	83,64	67,90	74,26
NARX	TANSIG	0,93	64,29	84,62	81,82	68,75	74,07
CFB	PURELIN	0,99	63,01	85,94	83,64	67,07	73,72
CFB	TANSIG	0,97	57,50	85,94	83,64	61,80	70,14
FFB	TANSIG	0,96	57,50	85,94	83,64	61,80	70,14
NARX	PURELIN	0,000005	66,66	52,38	10,90	50,00	53,98

Fonte: Autoria própria

Tabela 21 – Melhor desempenho das redes para o estudo de caso 4: pinça clássica. Considerando o banco de dados dos indivíduos normais.

RNA	Função de Ativação	Limiar de Decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
NARX	PURELIN	0,9982	98,21	100,00	100,00	66,67	98,28
NARX	LOGSIG	0,50	55,70	30,30	36,36	48,89	44,14
FFB	PURELIN	0,40	30,14	57,14	40,00	46,32	44,00
FFB	LOGSIG	0,60	30,38	57,53	43,64	43,30	42,42
CFB	TANSIG	0,65	23,86	60,00	38,18	43,22	41,62
NARX	TANSIG	0,60	25,00	57,53	43,64	36,84	39,05
CFB	PURELIN	0,50	22,45	56,58	40,00	36,13	37,36
CFB	LOGSIG	0,60	20,87	58,11	43,64	32,09	35,45
FFB	TANSIG	0,50	18,24	61,90	56,36	21,91	30,04

Fonte: Autoria própria

## 4.2 INDIVÍDUOS AMPUTADOS

Observando nas Tabelas 22 até 24 nota-se que os valores de desempenho para cada caso de estudo foram inferiores aos valores apresentados para os indivíduos normais. Para todos os casos o movimento com melhor desempenho foi o de fechar a mão, todos os demais movimentos não tiveram uma resposta satisfatória, isso pode ter ocorrido porque o movimento de fechar de mão é um movimento de maior força, ou seja, com valores de sinais mioelétricos mais elevados, além disso, é um movimento bem intuitivo, talvez sendo um dos motivos pelos quais o movimento de segurar um copo não teve uma resposta boa com o banco de dados dos indivíduos amputados.

Para todos os casos de treinamento utilizando o banco de dados de indivíduos amputados foi necessário realizar diversos treinamentos, todos os primeiros treinamentos as redes não conseguiram detectar nenhum movimento. A rede NARX com função de ativação PURELIN não conseguiu ser treinada, mesmo após várias tentativas.

Tabela 22 – Desempenho da rede *feed-forward backpropagation* com função de ativação TANSIG para o banco de dados de indivíduos amputados.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,60	54,30	63,87	54,80	59,60	63,41
1	0,91	30,77	66,67	50,90	47,67	46,15
2	0,94	63,33	76,39	69,09	70,45	71,43
3	0,74	14,09	61,80	38,18	31,93	30,05
4	0,54	9,00	57,95	32,73	23,96	21,89

Fonte: Autoria própria

As Tabelas 25 até 29 mostra a comparação de desempenho de todas as redes para cada caso de estudo considerando o banco de dados de indivíduos amputados. Utilizou-se como primeiro critério para definir o melhor desempenho a eficiência, e depois, na ordem: sensibilidade, especificidade, VPP, VPN e limiar de decisão. Definiu-se utilizar a melhor rede de cada caso para treinar os dados dos indivíduos amputados, dessa forma:

Tabela 23 – Desempenho da rede *cascade-forward backpropagation* com função de ativação TANSIG para o banco de dados de indivíduos amputados.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,60	50,19	66,54	60,27	56,90	58,32
1	0,90	22,50	65,85	49,09	36,73	40,09
2	0,95	62,50	68,75	54,55	75,34	66,41
3	0,72	16,18	62,50	40,00	32,54	34,38
4	0,62	20,51	61,25	43,64	34,50	37,06

Fonte: Autoria própria

Tabela 24 – Desempenho da rede NARX com função de ativação LOGSIG para o banco de dados de indivíduos amputados.

Caso de estudo	Limiar de decisão	VPP (%)	VPN (%)	Sensibilidade (%)	Especificidade (%)	Eficiência (%)
0	0,59	51,08	63,28	53,88	60,63	57,71
1	0,999	16,03	64,29	45,45	29,19	32,92
2	0,84	35,96	69,74	58,18	48,20	51,52
3	0,70	12,42	60,00	34,55	28,72	30,04
4	0,50	5,05	54,17	20,00	20,07	20,06

Fonte: Autoria própria

- **NARX PURELIN:** novamente a rede teve a melhor eficiência para os estudos de caso 0 e 4, ambas com eficiência de 100,00% porém teve o pior desempenho nos demais estudos de caso. Novamente, apesar de apresentar bons resultados para dois estudos de caso, a rede não foi considerada confiável devido a divergência entre os valores dos diferentes estudos de casos.
- **FFB TANSIG:** novamente a rede teve o melhor desempenho para o estudo de caso 1, porém não teve uma resposta com boa eficiência, com o valor de 46,15%. Nesse caso, ficou com o melhor desempenho para o estudo de caso 2, com uma eficiência de 71,43%. A rede, ficou em segundo lugar para os estudos de caso 0 e 3, com eficiência de 63,41% e 30,05% respectivamente.
- **CFB TANSIG:** a rede com melhor desempenho para o estudo de caso 3, porém não teve uma resposta com boa eficiência, com o valor de 34,30%. A rede conseguiu ter resposta satisfatória para os casos 0 e 2, com valores de eficiência de 58,32% e 66,41% respectivamente.
- **NARX LOGSIG:** A rede não se sobressaiu em nenhum estudo de caso. A rede apenas teve uma resposta com eficiência superior a 50% para os estudos de caso 0 e 2.

Tabela 25 – Melhor desempenho das redes para o estudo de caso 0: repouso. Considerando o banco de dados dos indivíduos amputados.

<b>RNA</b>	<b>Função de Ativação</b>	<b>Limiar de Decisão</b>	<b>VPP (%)</b>	<b>VPN (%)</b>	<b>Sensibilidade (%)</b>	<b>Especificidade (%)</b>	<b>Eficiência (%)</b>
FFB	TANSIG	0,60	54,30	63,87	54,80	59,60	63,41
CFB	TANSIG	0,60	50,19	66,54	60,27	56,90	58,32
NARX	LOGSIG	0,59	51,08	63,28	53,88	60,63	57,71

Fonte: Autoria própria

Tabela 26 – Melhor desempenho das redes para o estudo de caso 1: mão aberta. Considerando o banco de dados dos indivíduos amputados.

<b>RNA</b>	<b>Função de Ativação</b>	<b>Limiar de Decisão</b>	<b>VPP (%)</b>	<b>VPN (%)</b>	<b>Sensibilidade (%)</b>	<b>Especificidade (%)</b>	<b>Eficiência (%)</b>
FFB	TANSIG	0,91	30,77	66,67	50,90	47,67	46,15
CFB	TANSIG	0,90	22,50	65,85	49,09	36,73	40,09
NARX	LOGSIG	0,999	16,03	64,29	45,45	29,19	32,92

Fonte: Autoria própria

Tabela 27 – Melhor desempenho das redes para o estudo de caso 2: mão fechada. Considerando o banco de dados dos indivíduos amputados.

<b>RNA</b>	<b>Função de Ativação</b>	<b>Limiar de Decisão</b>	<b>VPP (%)</b>	<b>VPN (%)</b>	<b>Sensibilidade (%)</b>	<b>Especificidade (%)</b>	<b>Eficiência (%)</b>
FFB	TANSIG	0,94	63,33	76,39	69,09	70,45	71,43
CFB	TANSIG	0,95	62,50	68,75	54,55	75,34	66,41
NARX	LOGSIG	0,84	35,96	69,74	58,18	48,20	51,52

Fonte: Autoria própria

Tabela 28 – Melhor desempenho das redes para o estudo de caso 3: segurando um copo. Considerando o banco de dados dos indivíduos amputados.

<b>RNA</b>	<b>Função de Ativação</b>	<b>Limiar de Decisão</b>	<b>VPP (%)</b>	<b>VPN (%)</b>	<b>Sensibilidade (%)</b>	<b>Especificidade (%)</b>	<b>Eficiência (%)</b>
CFB	TANSIG	0,72	16,18	62,50	40,00	32,54	34,30
FFB	TANSIG	0,74	14,09	61,80	38,18	31,93	30,05
NARX	LOGSIG	0,70	12,42	60,00	34,55	28,72	30,00

Fonte: Autoria própria

Tabela 29 – Melhor desempenho das redes para o estudo de caso 4: segurando um alfinete. Considerando o banco de dados dos indivíduos amputados.

<b>RNA</b>	<b>Função de Ativação</b>	<b>Limiar de Decisão</b>	<b>VPP (%)</b>	<b>VPN (%)</b>	<b>Sensibilidade (%)</b>	<b>Especificidade (%)</b>	<b>Eficiência (%)</b>
CFB	TANSIG	0,62	20,51	61,25	43,64	34,50	37,06
FFB	TANSIG	0,54	9,00	57,95	32,73	23,96	21,89
NARX	LOGSIG	0,50	5,05	54,17	20,00	20,07	20,06

Fonte: Autoria própria



## 5 CONSIDERAÇÕES FINAIS

Com a análise dos resultados das redes neurais artificiais utilizando o banco de dados de indivíduos normais notou-se que, não teve uma RNA que conseguiu melhores resultados para todos os movimentos, a rede NARX com função de ativação linear teve o melhor desempenho para o repouso e movimento de preensão dígito-polegar, a rede *feed-forward backpropagation* com função de ativação tangente hiperbólica sigmoide teve o melhor desempenho para o movimento de fechar de mão, a rede com melhor desempenho para o movimento de abrir a mão foi a rede *cascade-forward-backpropagation* com função de ativação tangente hiperbólica sigmoide e a rede que teve o melhor desempenho para o movimento de preensão palmar foi a rede NARX com função de ativação sigmoide logarítmica. Percebe-se que cada rede se adapta melhor a um determinado padrão de exercício e se sobressai em relação as demais redes, apesar disso, a rede que, considerando todos os movimentos e o estado de repouso teve os melhores resultados foi a *feed-forward backpropagation* e a função de ativação que teve os melhores resultados foi a tangente hiperbólica sigmoide.

Para o banco de dados dos indivíduos amputados, a rede *feed-forward backpropagation* com função de ativação tangente hiperbólica sigmoide foi a que obteve o melhor desempenho, e a rede NARX com função de ativação sigmoide logarítmica foi a que teve pior desempenho para todos os movimentos e repouso. Os resultados das RNAs mostraram que o desempenho para os indivíduos normais foi superior ao dos indivíduos amputados, isso ocorreu devido as maiores divergências encontradas no grupo de indivíduos amputados. Alguns fatores que podem levar a esse resultado são: devido à falta de uma parte do membro superior como ocorre perda dos músculos do antebraço, conseqüentemente afeta os valores dos sinais mioelétricos; a irregularidade dos sinais mioelétricos devido à porcentagem do membro que está preservado não ser igual de indivíduo para indivíduo; as idades entre os indivíduos do banco de dados de amputados terem uma diferença média superior ao do banco de dados dos indivíduos normais; em alguns casos, o membro perdido não foi o mesmo do membro mais utilizado pelo indivíduo; a dificuldade individual para realizar um movimento específico devido à sua amputação.

Analisando o resultado que todas as redes tiveram, tanto para os indivíduos normais como para os amputados, de modo geral, o movimento que teve a pior performance foi o de preensão dígito-polegar, acredita-se que isso ocorreu devido ao movimento ser de precisão, e não um movimento de força, dessa forma, os sinais mioelétricos referente ao movimento apresentam uma amplitude menor e conseqüentemente, sendo muito mais ruidoso, dificultando para as RNAs definirem o padrão do movimento. Para os indivíduos normais os movimentos que tiveram as melhores respostas, foram os de preensão palmar e o de fechar a mão, seguindo a mesma lógica, acredita-se que isso tenha ocorrido, por serem movimentos de maior força, dessa forma, os sinais mioelétricos apresentam amplitudes elevadas, facilitando para a rede a detecção do padrão do movimento. Apesar disso, quando se observa os resultados dos indivíduos amputados apenas o movimento de fechar a mão que apresenta um desempenho aceitável, isso pode ter ocorrido, não só pela questão da força do movimento, mas por ser um movimento mais intuitivo para os indivíduos amputados realizarem.

O estudo desenvolvido por Mattioli et al. (2010), descreve um trabalho com algumas abordagens diferentes, fizeram janelamento dos sinais de interesse, e foram extraídas diversas características como média dos valores absolutos, inclinação da média dos valores absolutos, cruzamentos em zero, alterações no sinal da inclinação, comprimento de forma de onda e conteúdo em frequência do sinal. Todos esses parâmetros que foram utilizados para detectar os padrões dos movimentos resultam em uma rede com melhor eficiência, as redes desse trabalho foram apenas treinadas no domínio do tempo.

O trabalho de Kawata et al. (2010), utiliza como RNA a SDNN que é uma rede neural profunda. Redes neural profundas apresentam maior quantidade de neurônio e camadas, dessa forma conseguem resolver problemas mais complexos, resultando numa melhor eficiência do sistema.

O trabalho de Godoi, Duque e Díaz (2014), teve uma resposta satisfatória da rede utilizando a *feed-*

*forward backpropagation* com função de ativação tangente hiperbólica sigmoide e uma quantidade pequena de neurônios. Apesar disso, eles utilizaram um treinamento considerando o domínio do tempo e frequência, e os sinais utilizados foram simulações dos movimentos humanos. Quando se trabalha com movimentos reais, todo o cenário fica mais complexo: dificuldade da aquisição do sinal, processamento, relação sinal-ruído, as diferenças entre os sinais mioelétricos de movimento entre diferentes pessoas, e até diferenças de um mesmo indivíduo, dificultando dessa forma, para o treinamento eficaz de uma rede.

Todos os artigos descrevem a dificuldade em classificar os movimentos da mão utilizando sinais mioelétricos, dessa forma, abordagem mais complexas como por exemplo, as utilizadas nos dois primeiros artigos citados, é necessário para obter uma resposta satisfatória. Além disso, em todos os artigos, a classificação dos movimentos era feita de forma individual, e nesse trabalho, foi utilizado como estudo um grupo de indivíduos. A variação dos movimentos de acordo com cada pessoa prejudica na eficiência da rede, dessa forma, para um bom controle de prótese, o ideal é que a rede aprenda o padrão dos movimentos do indivíduo que vai utilizar a prótese em questão.

Afim de conseguir melhores resultados, pode-se treinar as redes com diferentes abordagens como as realizadas nos artigos citados. Também pode-se realizar um estudo mais abrangente no Matlab, foi utilizado apenas quatro RNAs da toolbox *nntool* e com uma configuração, e nessa toolbox existe 19 RNAs onde para cada uma pode-se configurar diferentes funções, como algoritmos de aprendizado, modificar a quantidade de *layers* e neurônios utilizados, etc. Além disso existe no Matlab diversas toolbox como a *nstart*, *ntstool*, *nprtool*, entre outras. Além disso, pode-se fazer o treinamento das redes utilizando um *dataset* maior.

## 5.1 RECOMENDAÇÃO PARA TRABALHOS FUTUROS

- Estudo para melhorar a performance das redes na classificação dos movimentos da mão, para isso, pode-se realizar um estudo das ferramentas do Matlab, redes neurais profundas, e testar diferentes parâmetros, como discutidos anteriormente;
- Realizar um controle de prótese com maior quantidade de movimentos e customizado para atender as necessidades de um único indivíduo;
- Construir a prótese mioelétrica para membro superior, tanto a parte mecânica, como o *software* referente a aquisição e processamento do sinal mioelétrico;
- Fazer uma plataforma virtual e/ou aplicativo para a calibração e teste do controle da prótese.

## REFERÊNCIAS

- A Novel Design of a McCulloch-Pitts Neuron in CMOS VLSI. Citado na página 35.
- ALEXANDRE, P. *Ikno Legde Assessment of the Amputee*. 2015. Disponível em: <<https://clinicalgate.com/assessment-of-the-amputee/>>. Citado na página 31.
- AMERI, A. et al. Real-time, simultaneous myoelectric control using force and position-based training paradigms. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 61, n. 2, p. 279–287, 2014. Citado na página 38.
- ATZORI, M. et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific data*, Nature Publishing Group, v. 1, p. 140053, 2014. Citado 2 vezes nas páginas 42 e 43.
- ATZORI, M. et al. Building the ninapro database: A resource for the biorobotics community. In: IEEE. *Biomedical Robotics and Biomechanics (BioRob), 2012 4th IEEE RAS & EMBS International Conference on*. [S.l.], 2012. p. 1258–1265. Citado na página 42.
- ATZORI, M. et al. Characterization of a benchmark database for myoelectric movement classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 23, n. 1, p. 73–83, 2015. Citado na página 42.
- Bebionic into the future with Ottobock. 2017. Disponível em: <<http://bebionic.com/>>. Citado na página 33.
- BIANCA. *Clínica Médica Sensibilidade, Especificidade, Valores Preditivos*. 2004. Disponível em: <<http://clinicamedicarquivo.blogspot.com.br/2004/06/sensibilidade-especificidade-valores.html>>. Citado na página 38.
- BISNETO, E. N. F. Deformidades congênitas dos membros superiores. parte i: Falhas de formação. *Rev Bras Ortop*, v. 47, n. 5, p. 545–52, 2012. Citado na página 31.
- BLANA, D. et al. Feasibility of using combined emg and kinematic signals for prosthesis control: a simulation study using a virtual reality environment. *Journal of Electromyography and Kinesiology*, Elsevier, v. 29, p. 21–27, 2016. Citado na página 38.
- BLOHMKE, F. *Compêndio otto bock: Próteses para o membro superior*. Berlin: Schiele & Schön, 1994. Citado na página 31.
- CARVALHO, J. A. *Amputações de membros inferiores: em busca da plena reabilitação*. [S.l.]: Manole, 2003. Citado na página 31.
- CHAGAS, J. E. L. P. Estudo para detecção de crises epilépticas baseada na análise da variabilidade de frequência cardíaca e redes neurais artificiais. 2017. Citado na página 38.
- CIPA Acidentes com máquinas causam 12 amputações por dia no País. 2015. Disponível em: <<http://revistacipa.com.br/acidentes-com-maquinas-causam-12-amputacoes-por-dia-no-pais/>>. Citado na página 31.
- CUNHA, F. L. d. *Mão de São Carlos, uma prótese multifunção para membros superiores: um estudo dos mecanismos, atuadores e sensores*. Tese (Doutorado) — Universidade de São Paulo, 2002. Citado 3 vezes nas páginas 31, 32 e 34.
- DEBASTIANI, J. Avaliação do equilíbrio e funcionalidade em indivíduos com amputação de membro inferior protetizados e reabilitados.[tcc]. *Cascavel: Centro de Ciências Biológicas e da Saúde da Universidade Estadual do Oeste do Paraná*, 2005. Citado na página 31.
- DELATTRE, E. Fundamentos de eletrofisiologia: potenciais de membrana. *Medicina (Ribeirão Preto. Online)*, v. 40, n. 3, p. 378–393, 2007. Citado na página 33.
- FAVIEIRO, G. W. Controle de uma prótese experimental do segmento mão-braço por sinais mioelétricos e redes neurais artificiais. 2009. Citado na página 38.
- FillauerLLC Upper Extremity Prosthetics. 2017. Disponível em: <<http://fillauer.com/Upper-Extremity-Prosthetics/index.html>>. Citado na página 32.
- FORTI, F. Análise do sinal eletromiográfico em diferentes posicionamentos, tipos de eletrodos, ângulos articulares e intensidades de contração. *Piracicaba: UNIMEP*, 2005. Citado na página 34.

- GEETHANJALI, P. A mechatronics platform to study prosthetic hand control using emg signals. *Australasian physical & engineering sciences in medicine*, Springer, v. 39, n. 3, p. 765–771, 2016. Citado na página 37.
- GIJSBERTS ARJAN, A. M. C. C. M. H. C. B. Measuring movement classification performance with the movement error rate. In: IEEE. [S.l.], 2013. Citado na página 42.
- GODOI, T. d. S. M. d.; DUQUE, L. H.; DÍAZ, F. J. d. O. Prótese mioelétrica controlada por redes neurais. 2014. Citado 2 vezes nas páginas 37 e 71.
- HowToMechatronics What is Schmitt Trigger. 2017. Disponível em: <<http://howtomechatronics.com/how-it-works/electrical-engineering/schmitt-trigger/>>. Citado na página 54.
- INGRAHAM, K. A. et al. Nonlinear mappings between discrete and simultaneous motions to decrease training burden of simultaneous pattern recognition myoelectric control. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*. [S.l.], 2015. p. 1675–1678. Citado na página 38.
- KAPANDJI, I. *Fisiologia Articular. Esquemas comentados de mecânica humana. V1 (Membro Superior)*. [S.l.]: Manole, São Paulo, 1980. Citado 4 vezes nas páginas 28, 29, 30 e 43.
- KAWAMURA, T. Interpretação de um teste sob a visão epidemiológica: eficiência de um teste. *Arquivos Brasileiros de Cardiologia*, SciELO Brasil, v. 79, n. 4, p. 437–441, 2002. Citado na página 38.
- KAWATA, H. et al. Practical surface emg pattern classification by using a selective desensitization neural network. In: SPRINGER. *International Conference on Neural Information Processing*. [S.l.], 2010. p. 42–49. Citado 2 vezes nas páginas 37 e 71.
- KOTTKE, J. F.; STILLWELL, G. K.; LEHMANN, J. F. Krusen: tratado de medicina física e reabilitação. In: *Krusen: tratado de medicina física e reabilitação*. [S.l.]: Manole, 1984. Citado na página 30.
- MATTIOLI, F. et al. Utilização de redes neurais para a classificação de sinais emg aplicados no controle de próteses virtuais de mão. *Proceedings of the WRVA*, p. 230–235, 2010. Citado 2 vezes nas páginas 37 e 71.
- NASCIMENTO, T. H. d. Reconhecimento de sinais – emg (plano horizontal sem carga). 2009. Citado na página 34.
- NinaPro Database. 2017. Disponível em: <<http://ninaweb.hevs.ch/>>. Citado na página 42.
- NinaWeb The Ninapro Project database web interface. 2017. Disponível em: <<https://www.idiap.ch//project/ninapro/database>>. Citado na página 42.
- NORVIG, P.; RUSSELL, S. *Inteligência Artificial. São Paulo*. [S.l.]: Campus, 2003. Citado 2 vezes nas páginas 34 e 36.
- REIS, G. dos; JÚNIOR, A. J. C.; CAMPOS, R. da S. Perfil epidemiológico de amputados de membros superiores e inferiores atendidos em um centro de referência. 2012. Citado na página 31.
- SOBOTTA, J. *Atlas de anatomia humana: Cabeça, pescoço e extremidade superior/trad. por Wilma Lins Werneck*. [S.l.]: Guanabara Koogan, 2000. Citado 3 vezes nas páginas 25, 26 e 27.
- SUBERBIOLA, A. et al. Arm orthosis/prosthesis movement control based on surface emg signal extraction. *International journal of neural systems*, World Scientific, v. 25, n. 03, p. 1550009, 2015. Citado na página 37.
- Touchbionics bionics by ossur. 2017. Disponível em: <<http://www.touchbionics.com/>>. Citado 2 vezes nas páginas 32 e 33.

## Apêndices



## APÊNDICE A – CÓDIGO FEITO NO MATLAB PARA ORGANIZAÇÃO DOS DADOS DOS INDIVÍDUOS

%Codigo para separar e organizar o database dos indivíduos  
 %Parte do codigo referente a separação dos movimentos:

%Movimento 5/Ex1:

```
for i = 1: 8000000
    if (stimulus (i,1)==5 & repetition (i,1)==6)
        break
    end
end
for j = 1: 8000000
    if (stimulus(j,1) == 5)
        stm5 = stimulus(j:i-1,1);
        emg5 = emg(j:i-1,:);
        break;
    end
end
```

%Movimento 6/Ex1:

```
for i = 1: 8000000
    if (stimulus (i,1)==6 & repetition (i,1)==6)
        break
    end
end
for j = 1: 8000000
    if (stimulus(j,1) == 6)
        stm6 = stimulus(j:i-1,1);
        emg6 = emg(j:i-1,:);
        break;
    end
end
```

%Movimento 18/Ex2

```
for i = 1: 8000000
    if (stimulusEx2 (i,1)==18 & repetitionEx2 (i,1)==6)
        break
    end
end
for j = 1: 8000000
    if (stimulusEx2(j,1) == 18)
        stm18 = stimulusEx2(j:i-1,1);
        emg18 = emgEx2(j:i-1,:);
        break;
    end
end
```

```

    end
end

%Movimento 26/Ex2:
for i = 1: 8000000
    if (stimulusEx2 (i,1)==26 & repetitionEx2 (i,1)==6)
        break
    end
end
for j = 1: 8000000
    if (stimulusEx2(j,1) == 26)
        stm26 = stimulusEx2(j:i-1,1);
        emg26 = emgEx2(j:i-1,:);
        break;
    end
end

%Concatenando matrizes para formar uma matriz única de estímulo e uma
%matriz única de sinal mioelétrico
emg_indivíduo = vertcat (emg5, emg6, emg18, emg26);
stm = vertcat (stm5, stm6, stm18, stm26);

%Arrumando as informações para as RNA
stimulus_indivíduo = zeros(length(stm),5);
stimulus_indivíduo(stm==0,1) = 1;
stimulus_indivíduo(stm==5,2) = 1;
stimulus_indivíduo(stm==6,3) = 1;
stimulus_indivíduo(stm==18,4) = 1;
stimulus_indivíduo(stm==26,5) = 1;

%Organizando dados de acordo com o indivíduo
dado_stm_indivíduo11 = stm;
dado_stimulus_indivíduo_11 = stimulus_indivíduo.';
dado_emg_indivíduo_11_12_Canais = emg_indivíduo.';
dado_emg_indivíduo_11_08_Canais = dado_emg_indivíduo_11_12_Canais (1:8,:);

%Concatenando matrizes com os dados de todos os indivíduos
database_stm = vertcat(dado_stm_indivíduo01,
dado_stm_indivíduo02, dado_stm_indivíduo03,dado_stm_indivíduo04,
dado_stm_indivíduo05, dado_stm_indivíduo06, dado_stm_indivíduo07,
dado_stm_indivíduo08, dado_stm_indivíduo09, dado_stm_indivíduo10,
dado_stm_indivíduo11);

database_stimulus = horzcat(dado_stimulus_indivíduo_01, dado_stimulus_indivíduo_02,
dado_stimulus_indivíduo_03, dado_stimulus_indivíduo_04, dado_stimulus_indivíduo_05,
dado_stimulus_indivíduo_06, dado_stimulus_indivíduo_07, dado_stimulus_indivíduo_08,
dado_stimulus_indivíduo_09, dado_stimulus_indivíduo_10, dado_stimulus_indivíduo_11);

```

```

database_emg_08Canais = horzcat(dado_emg_indivíduo_01_08_Canais,
dado_emg_indivíduo_02_08_Canais, dado_emg_indivíduo_03_08_Canais,
dado_emg_indivíduo_04_08_Canais, dado_emg_indivíduo_05_08_Canais,
dado_emg_indivíduo_06_08_Canais, dado_emg_indivíduo_07_08_Canais,
dado_emg_indivíduo_08_08_Canais,dado_emg_indivíduo_09_08_Canais,
dado_emg_indivíduo_10_08_Canais, dado_emg_indivíduo_11_08_Canais);

database_emg_12Canais = horzcat(dado_emg_indivíduo_01_12_Canais,
dado_emg_indivíduo_02_12_Canais, dado_emg_indivíduo_03_12_Canais,
dado_emg_indivíduo_04_12_Canais, dado_emg_indivíduo_05_12_Canais,
dado_emg_indivíduo_06_12_Canais, dado_emg_indivíduo_07_12_Canais,
dado_emg_indivíduo_08_12_Canais, dado_emg_indivíduo_09_12_Canais,
dado_emg_indivíduo_10_12_Canais, dado_emg_indivíduo_11_12_Canais);

%Normalizando matrizes de emg e convertendo formato de single para double
database_emg_08Canais_Normalizada = 1000000* double(database_emg_08Canais);
database_emg_12Canais_Normalizada = 1000000* double(database_emg_12Canais);

%Parte do código referente a otimização das matrizes

%Fazendo a média de 4 em 4 amostras do sinal de emg
i = 1;
j = 4;
for p = 1:12
    for k = 1:970359
        database_emg_otimizada12Canais(p,k) =
            mean(database_emg_12Canais_Normalizada(p,i:j));
        i = j+1;
        j = j+4;
    end
    i = 1;
    j = 4;
end

%Pegando 1 a cada 4 amostras do estímulo
database_stimulus_otimizada12Canais = database_stimulus(:,1:4:end);

%Excluindo 5 canais dos dados otimizados de 12 canais
database_stimulus_otimizada7Canais = database_stimulus_otimizada12Canais;
database_stimulus_otimizada7Canais([3 5 8 9 11], :) = [];

%Parte do código referente a plotagem dos gráficos
%Plotando graficos dos 4 movimentos com 5 repetições
figure(1)
subplot(3,2,1); plot (database2_emg_decimate(1,1:360000))
title('Canal 1');

```

```
subplot(3,2,2); plot (database2_emg_decimate(2,1:360000))
title('Canal 2');
subplot(3,2,3); plot (database2_emg_decimate(3,1:360000))
title('Canal 3');
subplot(3,2,4); plot (database2_emg_decimate(4,1:360000))
title('Canal 4');
subplot(3,2,5); plot (database2_emg_decimate(5,1:360000))
title('Canal 5');
subplot(3,2,6); plot (database2_emg_decimate(6,1:360000))
title('Canal 6');
figure(2)
subplot(3,2,1); plot (database2_emg_decimate(7,1:360000))
title('Canal 7');
subplot(3,2,2); plot (database2_emg_decimate(8,1:360000))
title('Canal 8');
subplot(3,2,3); plot (database2_emg_decimate(9,1:360000))
title('Canal 9');
subplot(3,2,4); plot (database2_emg_decimate(10,1:360000))
title('Canal 10');
subplot(3,2,5); plot (database2_emg_decimate(11,1:360000))
title('Canal 11');
subplot(3,2,6); plot (database2_emg_decimate(12,1:360000))
title('Canal 12');

%Plotando os gráficos para comparação de desempenho das rede

%Rede original
figure(1)
plot (database1_emg_Normalizada(1,1:360000))
hold on
plot (FFB1_Normalizada_TANSIG_outputs(1,1:360000))
title('Repouso - Rede original');
figure(2)
plot (database1_emg_Normalizada(1,1:360000))
hold on
plot (FFB1_Normalizada_TANSIG_outputs(2,1:360000))
title('Movimento 1 - Rede original');
figure(3)
plot (database1_emg_Normalizada(1,1:360000))
hold on
plot (FFB1_Normalizada_TANSIG_outputs(3,1:360000))
title('Movimento 2 - Rede original');
figure(4)
plot (database1_emg_Normalizada(1,1:360000))
hold on
plot (FFB1_Normalizada_TANSIG_outputs(4,1:360000))
title('Movimento 3 - Rede original');
```

```
figure(5)
plot (database1_emg_Normalizada(1,1:360000))
hold on
plot (FFB1_Normalizada_TANSIG_outputs(5,1:360000))
title('Movimento 4 - Rede original');

%Rede otimizada - 12 canais
figure(6)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB2_decimate_TANSIG_outputs(1,1:89000))
title('Repouso - Rede otimizada - 12 canais');
figure(7)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB2_decimate_TANSIG_outputs(2,1:89000))
title('Movimento 1 - Rede otimizada - 12 canais');
figure(8)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB2_decimate_TANSIG_outputs(3,1:89000))
title('Movimento 2 - Rede otimizada - 12 canais');
figure(9)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB2_decimate_TANSIG_outputs(4,1:89000))
title('Movimento 3 - Rede otimizada - 12 canais');
figure(10)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB2_decimate_TANSIG_outputs(5,1:89000))
title('Movimento 4 - Rede otimizada - 12 canais');

%Rede otimizada - 7 canais
figure(11)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB4_compactada7canais_TANSING_outputs(1,1:89000))
title('Repouso - Rede otimizada - 7 canais');
figure(12)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB4_compactada7canais_TANSING_outputs(2,1:89000))
title('Movimento 1 - Rede otimizada - 7 canais');
figure(13)
plot (database2_emg_decimate(1,1:89000))
```

```
hold on
plot (FFB4_compactada7canais_TANSING_outputs(3,1:89000))
title('Movimento 2 - Rede otimizada - 7 canais');
figure(14)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB4_compactada7canais_TANSING_outputs(4,1:89000))
title('Movimento 3 - Rede otimizada - 7 canais');
figure(15)
plot (database2_emg_decimate(1,1:89000))
hold on
plot (FFB4_compactada7canais_TANSING_outputs(5,1:89000))
title('Movimento 4 - Rede otimizada - 7 canais');
```

## APÊNDICE B – CÓDIGO FEITO NO MATLAB PARA CALCULAR O DESEMPENHO DAS REDES CONSIDERANDO AMOSTRA POR AMOSTRA

```

%Plotando dos gráficos para definir
%o limiar de decisão para cada movimento das RNA

%Plotagem de todos os dados para cada rede
figure(1)
plot (Adatabase_emg_decimate(1,1:323453))
hold on
plot (CFB_decimate_LOGSIG_outputs(1,1:323453))
title('Repouso');
figure(2)
plot (Adatabase_emg_decimate(1,1:323453))
hold on
plot (CFB_decimate_LOGSIG_outputs(2,1:323453))
title('Movimento 1');
figure(3)
plot (Adatabase_emg_decimate(1,1:323453))
hold on
plot (CFB_decimate_LOGSIG_outputs(3,1:323453))
title('Movimento 2');
figure(4)
plot (Adatabase_emg_decimate(1,1:323453))
hold on
plot (CFB_decimate_LOGSIG_outputs(4,1:323453))
title('Movimento 3');
figure(5)
plot (Adatabase_emg_decimate(1,1:323453))
hold on
plot (CFB_decimate_LOGSIG_outputs(5,1:323453))
title('Movimento 4');
figure(6)
plot (Adatabase_emg_decimate(1,323453:646906))
hold on
plot (CFB_decimate_LOGSIG_outputs(1,323453:646906))
title('Repouso');
figure(7)
plot (Adatabase_emg_decimate(1,323453:646906))
hold on
plot (CFB_decimate_LOGSIG_outputs(2,323453:646906))
title('Movimento 1');
figure(8)
plot (Adatabase_emg_decimate(1,323453:646906))
hold on
plot (CFB_decimate_LOGSIG_outputs(3,323453:646906))

```

```
title('Movimento 2');
figure(9)
plot (Adatabase_emg_decimate(1,323453:646906))
hold on
plot (CFB_decimate_LOGSIG_outputs(4,323453:646906))
title('Movimento 3');
figure(10)
plot (Adatabase_emg_decimate(1,646906:970359))
hold on
plot (CFB_decimate_LOGSIG_outputs(5,646906:970359))
title('Movimento 4');
figure(11)
plot (Adatabase_emg_decimate(1,646906:970359))
hold on
plot (CFB_decimate_LOGSIG_outputs(1,646906:970359))
title('Repouso');
figure(12)
plot (Adatabase_emg_decimate(1,646906:970359))
hold on
plot (CFB_decimate_LOGSIG_outputs(2,646906:970359))
title('Movimento 1');
figure(13)
plot (Adatabase_emg_decimate(1,646906:970359))
hold on
plot (CFB_decimate_LOGSIG_outputs(3,646906:970359))
title('Movimento 2');
figure(14)
plot (Adatabase_emg_decimate(1,646906:970359))
hold on
plot (CFB_decimate_LOGSIG_outputs(4,646906:970359))
title('Movimento 3');
figure(15)
plot (Adatabase_emg_decimate(1,646906:970359))
hold on
plot (CFB_decimate_LOGSIG_outputs(5,646906:970359))
title('Movimento 4');

%Código para avaliar desempenho das RNAs
%Definindo a RNA que será avaliada
rede = CFB_decimate_LOGSIG_outputs;

%Definindo valor de limiar para cada caso (repouso, movimentos 1,2,3 e 4)
limiar_repouso = 0.55;
limiar_mov1 = 0.4;
limiar_mov2 = 0.55;
limiar_mov3 = 0.5;
limiar_mov4 = 0.35;
```

```
%Iniciando variáveis
VP1 = 0; VP2 = 0; VP3 = 0; VP4 = 0; VP5 = 0;
VN1 = 0; VN2 = 0; VN3 = 0; VN4 = 0; VN5 = 0;
FN1 = 0; FN2 = 0; FN3 = 0; FN4 = 0; FN5 = 0;
FP1 = 0; FP2 = 0; FP3 = 0; FP4 = 0; FP5 = 0;

%Definindo os resultados - LINHA 1 - Repouso
for i = 1: 970359
    if (database_stimulus_otimizada12Canais (1,i)==1
        & rede (1,i)>limiar_repouso)
        VP1 = VP1 + 1;
    end
    if (database_stimulus_otimizada12Canais (1,i)==0
        & rede (1,i)<limiar_repouso)
        VN1 = VN1 + 1;
    end
    if (database_stimulus_otimizada12Canais (1,i)==1
        & rede (1,i)<limiar_repouso)
        FN1 = FN1 + 1;
    end
    if (database_stimulus_otimizada12Canais (1,i) ==0
        & rede (1,i)>limiar_repouso)
        FP1 = FP1 + 1;
    end
end

%Definindo os resultados - LINHA 2 - Movimento 1
for i = 1:970359
    if (database_stimulus_otimizada12Canais (2,i)==1
        & rede (2,i)>limiar_mov1)
        VP2 = VP2 + 1;
    end
    if (database_stimulus_otimizada12Canais (2,i)==0
        & rede (2,i)<limiar_mov1)
        VN2 = VN2 + 1;
    end
    if (database_stimulus_otimizada12Canais (2,i)==1
        & rede (2,i)<limiar_mov1)
        FN2 = FN2 + 1;
    end
    if (database_stimulus_otimizada12Canais (2,i) ==0
        & rede (2,i)>limiar_mov1)
        FP2 = FP2 + 1;
    end
end
```

```
%Definindo os resultados - LINHA 3 - Movimento 2
for i = 1:970359
    if (database_stimulus_otimizada12Canais (3,i)==1
        & rede (3,i)>limiar_mov2)
        VP3 = VP3 + 1;
    end
    if (database_stimulus_otimizada12Canais (3,i)==0
        & rede (3,i)<limiar_mov2)
        VN3 = VN3 + 1;
    end
    if (database_stimulus_otimizada12Canais (3,i)==1
        & rede (3,i)<limiar_mov2)
        FN3 = FN3 + 1;
    end
    if (database_stimulus_otimizada12Canais (3,i) ==0
        & rede (3,i)>limiar_mov2)
        FP3 = FP3 + 1;
    end
end
```

```
%Definindo os resultados - LINHA 4 - Movimento 3
for i = 1:970359
    if (database_stimulus_otimizada12Canais (4,i)==1
        & rede (4,i)>limiar_mov3)
        VP4 = VP4 + 1;
    end
    if (database_stimulus_otimizada12Canais (4,i)==0
        & rede (4,i)<limiar_mov3)
        VN4 = VN4 + 1;
    end
    if (database_stimulus_otimizada12Canais (4,i)==1
        & rede (4,i)<limiar_mov3)
        FN4 = FN4 + 1;
    end
    if (database_stimulus_otimizada12Canais (4,i) ==0
        & rede (4,i)>limiar_mov3)
        FP4 = FP4 + 1;
    end
end
```

```
%Definindo os resultados - LINHA 5 - Movimento 4
for i = 1:970359
    if (database_stimulus_otimizada12Canais (5,i)==1
        & rede (5,i)>limiar_mov4)
        VP5 = VP5 + 1;
    end
```

```

if (database_stimulus_otimizada12Canais (5,i)==
0 & rede (5,i)<limiar_mov4)
    VN5 = VN5 + 1;
end
if (database_stimulus_otimizada12Canais (5,i)==1
& rede (5,i)<limiar_mov4)
    FN5 = FN5 + 1;
end
if (database_stimulus_otimizada12Canais (5,i) ==0
& rede (5,i)>limiar_mov4)
    FP5 = FP5 + 1;
end
end

%Desempenho da rede
%Sensibilidade
S1 = 100 * VP1 / (VP1 + FN1);
S2 = 100 * VP2 / (VP2 + FN2);
S3 = 100 * VP3 / (VP3 + FN3);
S4 = 100 * VP4 / (VP4 + FN4);
S5 = 100 * VP5 / (VP5 + FN5);

%Especificidade
E1 = 100 * VN1 / (VN1 + FP1);
E2 = 100 * VN2 / (VN2 + FP2);
E3 = 100 * VN3 / (VN3 + FP3);
E4 = 100 * VN4 / (VN4 + FP4);
E5 = 100 * VN5 / (VN5 + FP5);

%Preditividade
VPP1 = 100 * VP1 / (VP1 + FP1);
VPN1 = 100 * VN1 / (VN1 + FN1);
VPP2 = 100 * VP2 / (VP2 + FP2);
VPN2 = 100 * VN2 / (VN2 + FN2);
VPP3 = 100 * VP3 / (VP3 + FP3);
VPN3 = 100 * VN3 / (VN3 + FN3);
VPP4 = 100 * VP4 / (VP4 + FP4);
VPN4 = 100 * VN4 / (VN4 + FN4);
VPP5 = 100 * VP5 / (VP5 + FP5);
VPN5 = 100 * VN5 / (VN5 + FN5);

%Eficiência
Ef1 = 100 * (VP1 + VN1) / (VP1 + VN1 + FP1 + FN1);
Ef2 = 100 * (VP2 + VN2) / (VP2 + VN2 + FP2 + FN2);
Ef3 = 100 * (VP3 + VN3) / (VP3 + VN3 + FP3 + FN3);
Ef4 = 100 * (VP4 + VN4) / (VP4 + VN4 + FP4 + FN4);
Ef5 = 100 * (VP5 + VN5) / (VP5 + VN5 + FP5 + FN5);

```



**APÊNDICE C – CÓDIGO FEITO NO MATLAB PARA CALCULAR O DESEMPENHO DAS REDES CONSIDERANDO INTERVALOS DE MOVIMENTOS E REPOUSO**

```

%Smith Trigger
ligado = 0;
limiarAlto = 0.50;
limiarBaixo = 0.1;
rede = FFB_decimate_TANSIG_outputs;

for i = 1:970359
    if (ligado==0 & rede(5,i) > limiarAlto)
        ligado = 1;
        FFB_TANSIG_TRIGGER(i) = 1;
    elseif (ligado==1 & rede(5,i) < limiarBaixo)
        ligado = 0;
        FFB_TANSIG_TRIGGER(i) = 0;
    elseif (ligado==0)
        FFB_TANSIG_TRIGGER(i) = 0;
    else (ligado==1)
        FFB_TANSIG_TRIGGER(i) = 1;
    end
end

%Desempenho
subida = 0;
movimento = 0;
errou = 0;
repouso = 0;
VN = 0;
VP = 0;
FN = 0;
FP = 0;

for i = 1:970359
%Detectar movimento
    if (subida ==0 & database_stimulus(5,i)==1)
        subida = 1;
        movimento = 0;
    elseif (subida ==1 & database_stimulus(5,i)==0)
        subida = 0;
        if (movimento ==0)
            FN = FN + 1;
        end
    elseif (subida==1 & FFB_TANSIG_TRIGGER(i)==1)
        if(movimento == 0)
            VP = VP + 1;
        end
    end
end

```

```
        end
        movimento = 1;
    end

    %Detectar repouso
    if (subida==0 & FFB_TANSIG_TRIGGER(i)==1)
        erro = 1;
    elseif (erro==1 & FFB_TANSIG_TRIGGER(i)==0)
        erro = 0;
        FP = FP + 1;
    elseif (subida==0 & FFB_TANSIG_TRIGGER(i)==0)
        repouso = 0;
    elseif (subida==0 & erro ==1)
        repouso = 1;
    elseif (subida==1 & repouso==0)
        VN = VN + 1;
        repouso = 1;
    end
end

%Métricas de desempenho
%Sensibilidade
S1 = 100 * VP / (VP + FN);
%specificidade
E1 = 100 * VN / (VN + FP);
%Preditividade
VPP1 = 100 * VP / (VP + FP);
VPN1 = 100 * VN / (VN + FN);
%Eficiência
Ef1 = 100 * (VP + VN) / (VP + VN + FP + FN);
```

## APÊNDICE D – CÓDIGO FEITO NO MATLAB PARA PROCESSAR OS DADOS

```

%Processamento dos dados

%Removendo componente DC
filtro_dc = dsp.DCBlocker('Algorithm','FIR','Length', 100);

%Separando cada canal e fazendo a matriz transposta
CH1 = database_emg_12Canais_Normalizada(1,:);
CH1 = CH1.>';
CH2 = database_emg_12Canais_Normalizada(2,:);
CH2 = CH2.>';
CH3 = database_emg_12Canais_Normalizada(3,:);
CH3 = CH3.>';
CH4 = database_emg_12Canais_Normalizada(4,:);
CH4 = CH4.>';
CH5 = database_emg_12Canais_Normalizada(5,:);
CH5 = CH5.>';
CH6 = database_emg_12Canais_Normalizada(6,:);
CH6 = CH6.>';
CH7 = database_emg_12Canais_Normalizada(7,:);
CH7 = CH7.>';
CH8 = database_emg_12Canais_Normalizada(8,:);
CH8 = CH8.>';
CH9 = database_emg_12Canais_Normalizada(9,:);
CH9 = CH9.>';
CH10 = database_emg_12Canais_Normalizada(10,:);
CH10 = CH10.>';
CH11 = database_emg_12Canais_Normalizada(11,:);
CH11 = CH11.>';
CH12 = database_emg_12Canais_Normalizada(12,:);
CH12 = CH12.>';

%Aplicando o filtro para cada canal
PA_CH1 = step(filtro_dc,CH1);
PA_CH2 = step(filtro_dc,CH2);
PA_CH3 = step(filtro_dc,CH3);
PA_CH4 = step(filtro_dc,CH4);
PA_CH5 = step(filtro_dc,CH5);
PA_CH6 = step(filtro_dc,CH6);
PA_CH7 = step(filtro_dc,CH7);
PA_CH8 = step(filtro_dc,CH8);
PA_CH9 = step(filtro_dc,CH9);
PA_CH10 = step(filtro_dc,CH10);
PA_CH11 = step(filtro_dc,CH11);
PA_CH12 = step(filtro_dc,CH12);

```

```
%Removendo interferência de 60 Hz
filtro_rede = designfilt ( 'bandstopiir' , 'FilterOrder' , 2, ...
    'HalfPowerFrequency1' , 59, 'HalfPowerFrequency2' , 61, ...
    'DesignMethod' , 'butter' , 'SampleRate' , 2000);

rede_CH1 = filtfilt (filtro_rede, PA_CH1);
rede_CH2 = filtfilt (filtro_rede, PA_CH2);
rede_CH3 = filtfilt (filtro_rede, PA_CH3);
rede_CH4 = filtfilt (filtro_rede, PA_CH4);
rede_CH5 = filtfilt (filtro_rede, PA_CH5);
rede_CH6 = filtfilt (filtro_rede, PA_CH6);
rede_CH7 = filtfilt (filtro_rede, PA_CH7);
rede_CH8 = filtfilt (filtro_rede, PA_CH8);
rede_CH9 = filtfilt (filtro_rede, PA_CH9);
rede_CH10 = filtfilt (filtro_rede, PA_CH10);
rede_CH11 = filtfilt (filtro_rede, PA_CH11);
rede_CH12 = filtfilt (filtro_rede, PA_CH12);

%Deixar o sinal positivo (abs)
abs_CH1 = abs(rede_CH1);
abs_CH2 = abs(rede_CH2);
abs_CH3 = abs(rede_CH3);
abs_CH4 = abs(rede_CH4);
abs_CH5 = abs(rede_CH5);
abs_CH6 = abs(rede_CH6);
abs_CH7 = abs(rede_CH7);
abs_CH8 = abs(rede_CH8);
abs_CH9 = abs(rede_CH9);
abs_CH10 = abs(rede_CH10);
abs_CH11 = abs(rede_CH11);
abs_CH12 = abs(rede_CH12);

% Filtro de média móvel
windowSize = 5;
b = (1/windowSize)*ones(1,windowSize);
a = 1;

MM_CH1 = filter(b,a,abs_CH1);
MM_CH2 = filter(b,a,abs_CH2);
MM_CH3 = filter(b,a,abs_CH3);
MM_CH4 = filter(b,a,abs_CH4);
MM_CH5 = filter(b,a,abs_CH5);
MM_CH6 = filter(b,a,abs_CH6);
MM_CH7 = filter(b,a,abs_CH7);
MM_CH8 = filter(b,a,abs_CH8);
MM_CH9 = filter(b,a,abs_CH9);
```

```
MM_CH10 = filter(b,a,abs_CH10);
MM_CH11 = filter(b,a,abs_CH11);
MM_CH12 = filter(b,a,abs_CH12);

%Filtro passa-baixa de 500Hz
Fs = 2000; % Frequência de amostragem
fc = 500; % Frequência de corte
Wn = (2/Fs)*fc;
filtro_PB = fir1(20,Wn,'low',kaiser(21,3));

PB_CH1 = filter(filtro_PB, 1, MM_CH1);
PB_CH2 = filter(filtro_PB, 1, MM_CH2);
PB_CH3 = filter(filtro_PB, 1, MM_CH3);
PB_CH4 = filter(filtro_PB, 1, MM_CH4);
PB_CH5 = filter(filtro_PB, 1, MM_CH5);
PB_CH6 = filter(filtro_PB, 1, MM_CH6);
PB_CH7 = filter(filtro_PB, 1, MM_CH7);
PB_CH8 = filter(filtro_PB, 1, MM_CH8);
PB_CH9 = filter(filtro_PB, 1, MM_CH9);
PB_CH10 = filter(filtro_PB, 1, MM_CH10);
PB_CH11 = filter(filtro_PB, 1, MM_CH11);
PB_CH12 = filter(filtro_PB, 1, MM_CH12);

%Fazendo as matriz transposta de cada canal
PB_CH1 = PB_CH1.';
PB_CH2 = PB_CH2.';
PB_CH3 = PB_CH3.';
PB_CH4 = PB_CH4.';
PB_CH5 = PB_CH5.';
PB_CH6 = PB_CH6.';
PB_CH7 = PB_CH7.';
PB_CH8 = PB_CH8.';
PB_CH9 = PB_CH9.';
PB_CH10 = PB_CH10.';
PB_CH11 = PB_CH11.';
PB_CH12 = PB_CH12.';

database_emg_filtradoABS = vertcat (PB_CH1, PB_CH2, PB_CH3, PB_CH4,
PB_CH5, PB_CH6, PB_CH7, PB_CH8, PB_CH9, PB_CH10, PB_CH11, PB_CH12);

%Decimar os dados
%Fazendo a média de 4 em 4 amostras do sinal de emg
i = 1;
j = 4;
for p = 1:12
    for k = 1:970359
        database_emg_decimate_filtradoABS(p,k) =
```

```
        mean(database_emg_filtradoABS(p,i:j));
        i = j+1;
        j = j+4;
    end
    i = 1;
    j = 4;
end

%Pegando 1 a cada 4 amostras do estímulo
database_stimulus_decimate = database_stimulus(:,1:4:end);
database_stimulus_filtrado = database_stimulus_decimate(:,1:970359);

%Depois de decimar, filtro MM e PB
CH1 = database_emg_decimate_filtradoABS(1,:);
CH2 = database_emg_decimate_filtradoABS(2,:);
CH3 = database_emg_decimate_filtradoABS(3,:);
CH4 = database_emg_decimate_filtradoABS(4,:);
CH5 = database_emg_decimate_filtradoABS(5,:);
CH6 = database_emg_decimate_filtradoABS(6,:);
CH7 = database_emg_decimate_filtradoABS(7,:);
CH8 = database_emg_decimate_filtradoABS(8,:);
CH9 = database_emg_decimate_filtradoABS(9,:);
CH10 = database_emg_decimate_filtradoABS(10,:);
CH11 = database_emg_decimate_filtradoABS(11,:);
CH12 = database_emg_decimate_filtradoABS(12,:);

% Filtro de média móvel
windowSize = 5;
b = (1/windowSize)*ones(1,windowSize);
a = 1;

MM_CH1 = filter(b,a,CH1);
MM_CH2 = filter(b,a,CH2);
MM_CH3 = filter(b,a,CH3);
MM_CH4 = filter(b,a,CH4);
MM_CH5 = filter(b,a,CH5);
MM_CH6 = filter(b,a,CH6);
MM_CH7 = filter(b,a,CH7);
MM_CH8 = filter(b,a,CH8);
MM_CH9 = filter(b,a,CH9);
MM_CH10 = filter(b,a,CH10);
MM_CH11 = filter(b,a,CH11);
MM_CH12 = filter(b,a,CH12);

database_emg_filtrado50Hz = vertcat (MM_CH1, MM_CH2, MM_CH3, MM_CH4,
MM_CH5, MM_CH6, MM_CH7, MM_CH8, MM_CH9, MM_CH10, MM_CH11, MM_CH12);
```

## APÊNDICE E – CÓDIGO FEITO NO MATLAB PARA PLOTAR OS GRÁFICOS DA REDE FILTRADA

```

%Plotagem dos graficos para os dados da rede filtrada
%Plotagem de cada canal (movimento) da saida da rede comparando com a entrada
redePlot = 0.01*database_emg_TCC;
%Rede original
figure(1)
subplot(3,1,1);
plot(redePlot(1,1:89000))
hold on
plot(FFB_TANSIG_TCC_outputs(1,1:89000))
title('Repouso');
subplot(3,1,2);
plot(redePlot(1,1:89000))
hold on
plot(FFB_TANSIG_TCC_outputs(2,1:89000))
title('Movimento 1');
subplot(3,1,3);
plot(redePlot(1,1:89000))
hold on
plot(FFB_TANSIG_TCC_outputs(3,1:89000))
title('Movimento 2');
figure(2)
subplot(2,1,1);
plot(redePlot(1,1:89000))
hold on
plot(FFB_TANSIG_TCC_outputs(4,1:89000))
title('Movimento 3');
subplot(2,1,2);
plot(redePlot(1,1:89000))
hold on
plot(FFB_TANSIG_TCC_outputs(5,1:89000))
title('Movimento 4');

%Plotagem dos limiares de decisao para cada movimento
%e do gráfico com trigger
figure(3)
subplot(2,1,1);
plot(FFB_TANSIG_TCC_outputs(1,1:89000))
hold on
plot([1, 89000], [0.70, 0.70])
title('Repouso - Limiar de decisão');
subplot(2,1,2);
plot(TRIGGER_REPOUSO(1:89000))
title('Repouso - Trigger');

```

```
figure(4)
subplot(2,1,1);
plot(FFB_TANSIG_TCC_outputs(2,1:89000))
hold on
plot([1, 89000], [0.88, 0.88])
title('Movimento 1 - Limiar de decisão');
subplot(2,1,2);
plot(TRIGGER_MOV1(1:89000))
title('Movimento 1 - Trigger');
figure(5)
subplot(2,1,1);
plot(FFB_TANSIG_TCC_outputs(3,1:89000))
hold on
plot([1, 89000], [0.97, 0.97])
title('Movimento 2 - Limiar de decisão');
subplot(2,1,2);
plot(TRIGGER_MOV2(1:89000))
title('Movimento 2 - Trigger');
figure(6)
subplot(2,1,1);
plot(FFB_TANSIG_TCC_outputs(4,1:89000))
hold on
plot([1, 89000], [0.96, 0.96])
title('Movimento 3 - Limiar de decisão');
subplot(2,1,2);
plot(TRIGGER_MOV3(1:89000))
title('Movimento 3 - Trigger');
figure(7)
subplot(2,1,1);
plot(FFB_TANSIG_TCC_outputs(5,1:89000))
hold on
plot([1, 89000], [0.50, 0.50])
title('Movimento 4 - Limiar de decisão');
subplot(2,1,2);
plot(TRIGGER_MOV4(1:89000))
title('Movimento 4 - Trigger')
```