



USO DE REDES NEURAIS ARTIFICIAIS PARA CONTROLE DE UMA MÃO VIRTUAL POR MEIO DE SINAIS ELETROMIOGRÁFICOS DO ANTEBRAÇO

Alexandre Henrique Pereira Tavares*¹, Josué Silva Morais¹

¹FEELT – Universidade Federal de Uberlândia

Resumo – As próteses mioelétricas mais modernas disponíveis no mercado para membros superiores têm o seu funcionamento baseado no reconhecimento de padrões de sinais eletromiográficos. Este processo pode ser obtido posicionando eletrodos sobre a pele, que serão responsáveis por captar o sinal elétrico dos músculos e estes são enviados a um sistema encarregado de processar o sinal e reconhecer alguns padrões. Existem diversas técnicas para o reconhecimento de padrões, como a classificação por métodos estatísticos (como a correlação) e as redes neurais artificiais, esta última será a técnica utilizado no presente trabalho. Serão expostas as técnicas de extração e processamento do sinal eletromiográfico dos músculos do antebraço, utilizando oito eletrodos, até o reconhecimento de padrões por redes neurais artificiais, para se conseguir mover uma mão virtual em tempo real. Por fim, são apresentados os resultados da rede neural em relação a quantidades diferentes de padrões, ou seja, de posições da mão, e diferentes técnicas de pré-processamento dos sinais digitais. Observou-se que o erro de reconhecimento para somente dois padrões (mão aberta e fechada) foi de apenas 3%, mas para o reconhecimento de três e quatro padrões, o sistema apresentou erros de cerca de 40%.

Palavras-Chave – Prótese de Mão; Redes Neurais Artificiais; Sinais Eletromiográficos.

USE OF ARTIFICIAL NEURAL NETWORKS FOR THE CONTROL OF A VIRTUAL HAND BY ELECTROMYOGRAPHIC SIGNS OF THE FOREARM

Abstract - The most modern myoelectric prostheses available on the market for upper limbs have their functioning based on the recognition of electromyographic signal patterns. This process can be obtained by placing electrodes on the skin, which will be responsible for capturing the electrical signal of the muscles and these are sent to a system in charge of processing the signal and recognize some patterns. There are several techniques for pattern recognition, such as classification by statistical methods (such as correlation) and artificial neural

*alexandre.tavares@ufu.br

networks, the second being the technique used in the present work. The techniques of extracting and processing the electromyographic signal of the forearm muscles using eight electrodes will be exposed to the recognition of patterns by artificial neural networks to be able to move a virtual hand in real time. Finally, the results of the neural network are presented in relation to different amounts of patterns, that is, of hand positions, and different preprocessing techniques of the digital signals. It was observed that the error of recognition for only two patterns (open and closed hand) was only 3%, but for the recognition of three and four patterns, the system presented errors around 40%.

Keywords – Artificial Neural Network; Electromyographic signals; Hand Prosthesis.

I. INTRODUÇÃO

Na busca de métodos eficazes para resolução de problemas na sociedade na área da saúde e assim como em outras, a tecnologia demonstra-se como uma aliada nessa evolução. A inteligência artificial aplicada à Engenharia Biomédica na reabilitação humana almeja sistemas cada vez mais inteligentes e refinados que proporcionem maior controle e adaptação em dispositivos como próteses, melhorando assim a qualidade de vida e a inclusão social de pessoas com deficiências [2,3], pois sabe-se que o uso de redes neurais artificiais se apresenta como uma ferramenta de reconhecimento de padrões que pode ser utilizada em diversas aplicações.

O objetivo deste trabalho é o desenvolvimento de um sistema em tempo real inteligente, baseado em redes neurais artificiais para reconhecimento de padrões de sinais eletromiográficos (EMG) dos músculos do antebraço, visando 4 diferentes movimentos da mão: mão aberta, mão segurando objetos, movimento de pinça e por último a mão completamente fechada.

A literatura informa que diferentes músculos do antebraço estão relacionados aos movimentos da mão e sinais EMG podem ser medidos nestes músculos mesmo após a amputação da mão [1]. O sinal EMG corresponde a um sinal de controle muscular e consiste em um potencial elétrico produzido pela contração de um músculo [4]. Ao reconhecer em qual posição a mão do usuário está, o sistema irá

movimentar a mão virtual, no mesmo instante, de acordo com a posição da mão real.

O processamento do sinal EMG pode ser dividido em três etapas: (a) pré-processamento com filtragem, retificação e amplificação do sinal; (b) segmentação e extração das características do sinal; e (c) processamento do sinal EMG, por meio de um sistema de classificação [5].

As redes neurais artificiais (RNA) são modelos computacionais, inspirados nos neurônios humanos, capazes de reconhecer e classificar padrões com base de exemplos através de um algoritmo de aprendizagem [6]. Este processo de aprendizagem se dá por meio de um algoritmo de treinamento que deve ser capaz de ajustar iterativamente os pesos sinápticos da RNA. Uma característica de uma RNA é a capacidade de generalização, ou seja, após um conjunto de padrões de entrada pré-classificados em sua fase de treinamentos, a mesma pode receber padrões diferentes dos utilizados na etapa de treino e então classificá-los adequadamente [7].

II. SINAIS MIOELÉTRICOS

Para o conjunto de treinamento, validação e teste da rede neural artificial, foram captados vários sinais Mioelétricos (SMEs). Estes sinais foram adquiridos de uma pulseira chamada *Myo Gesture Control Armband*, disponível no mercado por U\$135,00 (fonte: Amazon.com). Este *hardware* dispõe de 8 eletrodos bipolares embutidos, bateria interna recarregável, transmissor e receptor *bluetooth* e sensores giroscópio, magnetômetro e acelerômetro. Assim o dispositivo é capaz de fornecer sinais de EMG, posição, rotação e aceleração em 3 eixos.

Durante todo o processo de aquisição de dados e teste do projeto, foi seguido um padrão de posicionamento da pulseira na região do antebraço. O *hardware* foi posicionado sempre a um terço da distância entre a origem e inserção do músculo extensor ulnar do carpo, ou seja, mais próximo da região proximal. As Figuras 1.a, 1.b, 1.c e 1.d mostram os gráficos dos sinais EMG dos 8 eletrodos para as quatro posições de mão usadas durante a fase de treinamento da rede neural, com duração de dois minutos.

Figura 1.a: Gráfico dos sinais EMG, referentes aos 8 eletrodos, para a mão aberta, por um período de 2 minutos.

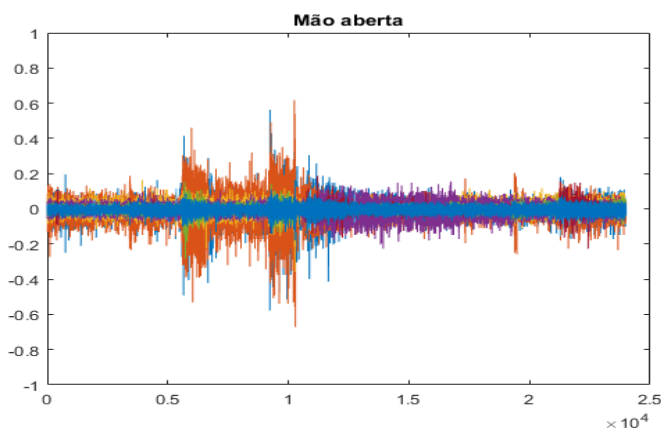


Figura 1.b: Gráfico dos sinais EMG, referentes aos 8 eletrodos, para a mão segurando um objeto, por um período de 2 minutos.

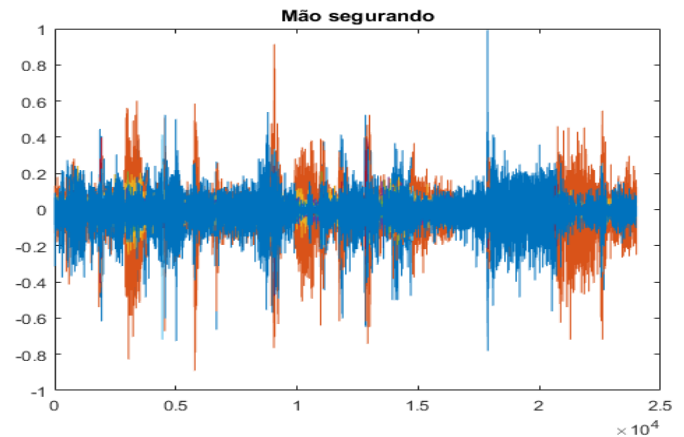


Figura 1.c: Gráficos dos sinais EMG, referentes aos 8 eletrodos, para a mão na posição de pinça, por um período de 2 minutos.

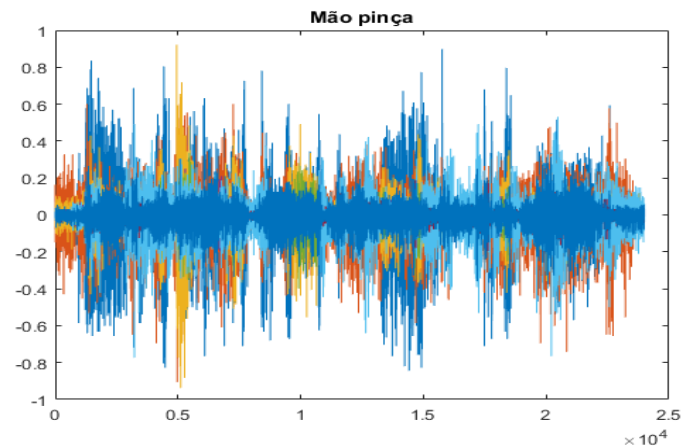
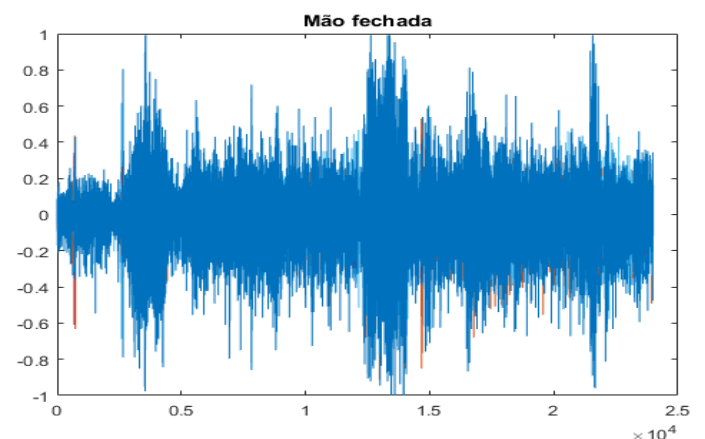


Figura 1.d: Gráfico dos sinais EMG, referentes aos 8 eletrodos, para a mão fechada, por um período de 2 minutos.




Outro padrão adotado foi a posição do eletrodo de referência da Myo (contendo o logotipo da empresa iluminado com luz de LED), o centro do mesmo foi alinhado ao encontro das veias cefálica mediana e basílica mediana, além disso, o LED indicador de bateria ficava apontado ao sentido do dedo. Para a etapa de testes da rede neural, foram extraídos outros

sinais EMG, seguindo os padrões descritos anteriormente, mas desta vez com duração de 30 segundos. Assim, pôde-se comparar o desempenho da rede neural artificial.

III. MODELAGEM DA MÃO

A modelagem da mão foi feita no *software* Blender, assim como as animações dos 4 movimentos da mão e as transições entre cada um deles. Feito isso, o arquivo foi transferido para o *software* Unity, que permite controlar os movimentos da mão por meio de comandos externos. Estes comandos externos eram captados pelo sistema em tempo real, desenvolvido no *software* Matlab, de acordo com a posição atual da mão do usuário e eram enviados instantaneamente ao Unity para mover a mão com o mesmo padrão de movimento da mão real. As 4 posições da mão virtual (aberta, segurando um objeto, formato de pinça e fechada, respectivamente) foram definidas previamente e são mostradas na Figura 2.

Figura 2: Posições da mão virtual modeladas no software Blender.



IV. AQUISIÇÃO E PROCESSAMENTO DOS DADOS

Para a aquisição de dados, foi utilizado o *software* Matlab. Para ser possível a conexão entre a pulseira Myo e o Matlab, foi preciso acessar o SDK do *hardware* e executar um *script* escrito em C++. A aquisição de dados foi realizada com frequência de amostragem de 200 Hz, inicialmente foi proposta a utilização de uma frequência de amostragem de 1 kHz, mas devido às limitações do processador do *hardware* e limitações do *software*, a mesma foi mantida em 200 Hz, para se ter uma melhor sensação de sistema em tempo real.

A amplitude do sinal no domínio do tempo encontra-se na faixa de (-128, 128), este intervalo é especificado no *datasheet* do *hardware*, sendo os limites do intervalo referentes ao valor máximo da corrente elétrica produzida pelo antebraço, em torno de 800 mV [1], quando na presença da contração mais forte do usuário. Após o tratamento dos dados, o sinal foi reduzido para a faixa de (-1, 1), com o propósito de facilitar os cálculos da rede neural. O sinal EMG foi adquirido e gravado em uma matriz de 8 colunas, sendo cada uma responsável pelos sinais de um único eletrodo.

A etapa posterior consistiu em separar o sinal captado em amostras de 400 ms (milissegundos), como a frequência de amostragem foi definida em 200 Hz, os dados de cada amostra continham 40% desse valor, ou seja, formando uma matriz de 80 linhas e 8 colunas. Após gravar os dados da amostra na matriz descrita anteriormente, foi feita a transformação da matriz em um vetor de apenas uma coluna, para facilitar o uso dos dados na entrada da rede neural artificial.

Após a aquisição do sinal no tempo, normalização e amostragem, foi feita a Transformada de Fourier, considerando toda a faixa de frequência do sinal, ou seja, de 0 a 200 Hz. Feita a transformação do domínio do tempo para frequência de cada amostra, o resultado foi gravado em outra matriz, contendo novamente 8 colunas, sendo que cada uma representava os dados no domínio da frequência para o sinal de cada eletrodo. Por último, foi feito o cálculo da correlação dos sinais por eles mesmos. O resultado dessa etapa gerou as sequências de autocorrelação e correlação cruzada para todas as combinações das colunas da matriz de cada amostra.

As matrizes resultantes das etapas 2 e 3 do processamento, referentes à Transformada de Fourier e Autocorrelação também foram transformadas em um vetor de apenas uma coluna, para se adequarem às entradas da rede neural artificial.

V. REDE NEURAL ARTIFICIAL

O reconhecimento de padrões dos sinais EMG do antebraço e a discriminação entre os quatro diferentes tipos de movimento da mão foram realizados por uma Rede Neural Artificial. O *software* usado para a implementação da rede neural artificial foi o mesmo do processamento e aquisição dos sinais EMG, o Matlab. Após a aquisição dos dados e a amostragem do sinal no domínio do tempo, da frequência e autocorrelação dos dados, todas essas informações foram transformadas em um só vetor ordenado e este foi utilizado diretamente na entrada da rede neural.

O sistema foi implementado, testado e executado em um computador pessoal, objetivando entregar uma resposta em tempo real, sem que o usuário perceba um atraso entre o comando (mexer a mão) e a saída (movimento da mão virtual). Por isso, houve a preocupação em adequar a complexidade da rede neural às limitações físicas do hardware utilizado, para evitar o problema do atraso na resposta.

Após vários testes de arquiteturas diferentes da rede neural, decidiu-se utilizar uma rede Perceptron Multicamadas (também conhecida como MLP – *MultiLayer Perceptron*) de 3 camadas, ou seja, de 2 camadas escondidas, ou ocultas, e uma camada de saída. A saída da rede neural apresentava 4 neurônios, cada um responsável por um estado da mão (aberta; segurando algum objeto; pinça; completamente fechada).

Em relação à quantidade de neurônios das camadas escondidas, notou-se um pequeno atraso da resposta quando utilizada uma rede neural de 50 neurônios por camada, o que prejudicou a experiência de uso do sistema. Por isso, foi escolhida a utilização de 20 neurônios em cada camada escondida. Para o treinamento foi usado o método *backpropagation* [10]. Pelo mesmo motivo, foi preciso tomar cuidado com a etapa de pré-processamento do sinal, que não poderia exigir muito processamento do sistema e tempo, comprometendo a proposta de sistema em tempo real.

Para o ajuste dos pesos, foi utilizada uma taxa de aprendizagem η constante igual a 0.5, também foi incrementado o termo *momentum* aos ajustes dos pesos sinápticos, sendo a constante de *momentum* também definida para o valor de 0.5, a Equação 1 mostra a fórmula utilizada para ajuste dos pesos sinápticos.

$$w = w_{anterior} + \eta \times Y \times \delta + \beta \times (w - w_{anterior}) \quad (1)$$

Onde:

- w - Matriz de pesos.
- η - Taxa de aprendizagem.
- Y - Saída da respectiva camada de neurônios.
- β - Constante de *momentum*.
- δ - Termo delta do método *backpropagation*.

A função de ativação de todos os neurônios das camadas escondidas e de saída, foi a Sigmoide Bipolar (Equação 2) com a constante k igual a 1. Estes valores foram determinados empiricamente.

$$f(x) = \frac{1}{1 + e^{-kx}} \quad (2)$$

Em relação ao critério de parada do treinamento, foi definido o erro quadrático médio (EQM) alvo (entre a saída desejada e a saída obtida) de todas as amostras igual a 1×10^{-6} , assim o treinamento somente era encerrado se todas as amostras apresentassem um EQM menor que 1×10^{-6} . Esse critério de parada não foi suficiente para os casos onde a rede deveria identificar mais de 3 padrões, pois a rede não convergiu, mesmo depois de mais de uma hora de treinamento. Assim, para os testes em que haviam mais de 3 padrões de posição de mão a se identificar, foi usado outro critério de parada. Este foi definido como um valor fixo de ciclos (1000 ciclos), ou quando o erro quadrático médio tinha o seu valor acrescido de um ciclo para outro.

VI. RESULTADOS

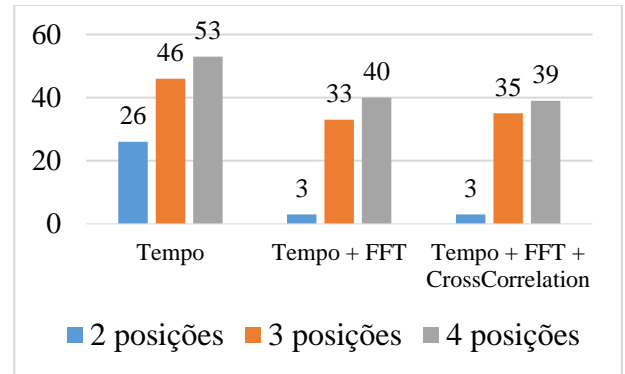
Como dito na seção anterior, a arquitetura da rede neural artificial foi ajustada e definida, baseada em testes feitos para a identificação de dois padrões de movimento (mão aberta e fechada) e três padrões (mão aberta, fechada e pinça).

Após definida a arquitetura da rede neural, foram feitos testes de desempenho para o reconhecimento dos padrões. Foi utilizado o método de validação cruzada *holdout* para o teste de capacidade de generalização, sendo que dois terços das amostras foram utilizadas no treinamento e o um terço restante foi utilizado no teste [11].

Assim, foram feitos testes de reconhecimento de apenas dois padrões (mão aberta e fechada); para três padrões (mão aberta, pinça e fechada); quatro padrões (mão aberta, pinça, segurando objeto e fechada). Além da análise do desempenho em relação à quantidade de padrões a serem reconhecidos, foi estudada a influência de certas técnicas de pré-processamento no resultado. Primeiramente a rede neural deveria reconhecer os padrões apenas dos sinais no domínio do tempo, depois a transformada no domínio da frequência foi acrescentada e por último a autocorrelação foi implementada e acrescida às entradas da rede neural. É importante salientar que as técnicas

de pré-processamento foram usadas da mesma forma no treinamento e no teste da rede neural. A Figura 3 mostra a porcentagem de erro das saídas do sistema em cada um dos casos.

Figura 3: Porcentagem do erro da resposta da rede neural em relação à quantidade de padrões a se identificar e às técnicas de pré-processamento.



VII. CONCLUSÕES

Com os padrões reconhecidos, é possível implementar o sistema em uma prótese real de mão. Assim, uma pessoa que não tenha a mão, mas tenha um coto restante no antebraço será capaz de movimentar a mão protética.

É preciso reforçar que os sinais EMG foram colhidos de uma pessoa normal e podem não funcionar da mesma forma para pessoas amputadas. Por isso, ao desenvolver o projeto ao nível descrito acima, é importante colher os dados de várias pessoas com o membro superior amputado, visto que os pacientes amputados têm uma maior dificuldade de gerar padrões diferentes [8, 9].

O resultado se mostrou bastante satisfatório para o reconhecimento de dois padrões, mas para três e quatro padrões, o erro da saída da rede neural foi elevado.

Os diversos testes realizados com arquiteturas diferentes da rede neural artificial e com técnicas diferentes de pré-processamento do sinal mostraram que a segunda tem maior influência no reconhecimento correto dos padrões, se comparados à arquitetura da rede neural. Este resultado é evidenciado pelo fato que os erros gerados no teste de capacidade de generalização para 2 movimentos foram bastante próximos quando utilizados 20 neurônios nas camadas escondidas e 300 neurônios nas camadas escondidas, variando em menos de 2%. Porém, ao acrescentar a transformada no domínio do tempo para a frequência no sinal de entrada, este mesmo erro caiu de 26% para 3%, o que mostra a importância desta técnica específica de pré-processamento no resultado.

Em futuros trabalhos, propõe-se o teste de outras arquiteturas de redes neurais, a incrementação de outras técnicas de inteligência artificial e novas técnicas de processamento digital de dados, para assim ser possível identificar mais precisamente os mesmos movimentos descritos (almejando diminuir o erro de identificação da fase de testes) e outros mais precisos e delicados da mão e dos dedos.

Pode-se apontar como limitação deste trabalho a frequência de amostragem da aquisição de dados no *software* Matlab. O espectro de frequência do sinal EMG dos músculos do antebraço está presente principalmente entre 0 e 250 Hz, mas ainda assim, há alguns sinais remanescentes em frequências até 500 Hz [7]. Por isso, o sistema desenvolvido não é capaz de captar todas as informações disponíveis dos sinais EMG dos músculos da região do antebraço.

REFERÊNCIAS

- [1] Y. Su, M. H. Fisher, A. Wolczowski, G. D. Bell, D. J. Burn, and R. X. Gao. Towards an EMG - Controlled Prosthetic Hand Using a 3-D Electromagnetic Positioning System. *IEEE transactions on instrumentation and measurement*, pages 178–186, 2007.
- [2] de Carvalho, G. L. (2004). Proposta de um método de projeto de próteses de membros superiores com a utilização da engenharia e análise do valor. Master's thesis, Universidade de São Paulo, São Paulo.
- [3] Chan, F. H. Y., Yang, Y.-S., Lam, F. K., Zhang, Y.-T., and Parker, P. A. (2000). Fuzzy emg classification for prosthesis control. *IEEE Transactions on Rehabilitation Engineering*, 8(3):305–311.
- [4] Mattioli, Fernando E. R. et al (2010). Utilização de redes neurais para a classificação de sinais EMG aplicados no controle de próteses virtuais de mão. Disponível em: <http://www.lbd.dcc.ufmg.br/colecoes/wrva/2010/0040.pdf>. Acesso em: 07 julho de 2018.
- [5] de Barros, K. R. (2005). Metodologia para classificação de sinais emg para controle de ~ próteses com baixo esforço computacional. Master's thesis, Universidade Federal de Uberlândia, Uberlândia.
- [6] Ferreira, Evelyne L.; Gouveia junior, Maury M. (2016). Sistema Neural para Reconhecimento de Padrões em Sinais EMGs para Controle de Braço Robótico. Disponível em: <http://www.lbd.dcc.ufmg.br/colecoes/eniac/2016/043.pdf>. Acesso em: 07 julho de 2018.
- [7] Almeida, Roberto Coelho de (2016); Faceroli, Silvana Terezinha. reconhecimento de padrões mioelétricos do movimento dos dedos da mão utilizando redes neurais artificiais. Disponível em: <http://periodicos.jf.ifsudestemg.edu.br/multiverso/article/download/15/14>> Acesso em: 07 julho de 2018.
- [8] B. Hudgins, P. Parker, R. N. Scott, “A New Strategy for Multifunction Myoelectric Control”, *IEEE Trans. On Biomedical Engineering*, Vol. 40, No. 1, pp. 82-94, 1993.
- [9] P. J. Gallant, E. L. Morin, L. E. Peppard, “Feature-based classification of myoelectric signals using artificial neural networks”, *Medical & Biological Engineering & Computing*, 36, pp. 485-489, 1998.
- [10] M. Caudill, C. Butler, “Understanding Neural Networks: Computer Explorations”, The MIT Press, Massachusetts, Vol 1, pp. 171- 180, 1996.
- [11] J. A. Baranaukas, “Métodos de amostragem e validação de Algoritmos”, Departamento de Física e Matemática – FFCLRP-USP.