

PSI2672 - Práticas em Reconhecimento de Padrões, Modelagem e Neurocomputação

Professor: Emilio Del Moral Hernandez

Apresentação dos projetos finais - Grupo 1



Escola Politécnica
Universidade de São Paulo

São Paulo, Junho de 2016

Membros do grupo



António Martins Miranda
NUsp: 7644342



Sam Jeong
NUsp: 8041074




Felipe Cirne Conceição
NUsp: 7958602

Projetos de redes neurais artificiais

- Reconhecedor: Classificação da fibrilação atrial a partir do eletrocardiograma;
- Regressor: Cancelador ativo de ruído.

Classificação da fibrilação atrial a partir do eletrocardiograma

Normalmente a fibrilação atrial é caracterizada quando a frequência de ocorrência dos picos não é estável – podem levar a incapacidade de bombear o sangue e podem causar outros problemas vasculares e circulatórios [1].



Motivação

A Fibrilação Atrial é uma patologia que pode levar a desenvolver outras patologias e agravamento desta patologia pode levar até a morte. [1]

Atualmente há uma grande quantidade de pesquisa realizada e sendo realizada sobre o reconhecimento de Fibrilação Atrial [1].

Este projeto visou encontrar um método simples e prático usando a rede neural para realizar a classificação com uma taxa de acerto (acurácia) elevada.

Utilidade

- Servir de auxílio para classificação e detecção da fibrilação atrial.
- Um método automático e prático, que ao apresentar taxa de acertos elevados poderia substituir a tarefa de um médico.

Coleta de dados

- PhysioNet [2]:
- É um banco de dados que contem os sinais de eletrocardiograma normais e os que apresentam fibrilação atrial.
- Também contém outros sinais biológicos que não são relevantes para o projeto.

Foram coletados 4 sinais longos (2 com fibrilação e 2 sem fibrilação)

- PhysioToolkit[2]:
- É uma ferramenta que permite extração de algumas características importantes dos sinais existentes no banco de dados

Metodologia

1. Identificar uma extração de características importantes;
2. Implementar a rede neural;
3. Verificar a qualidade da rede neural.

Extração de características e preprocessamentos

- Primeira possibilidade - ideia / uso de conhecimento já adquirido:

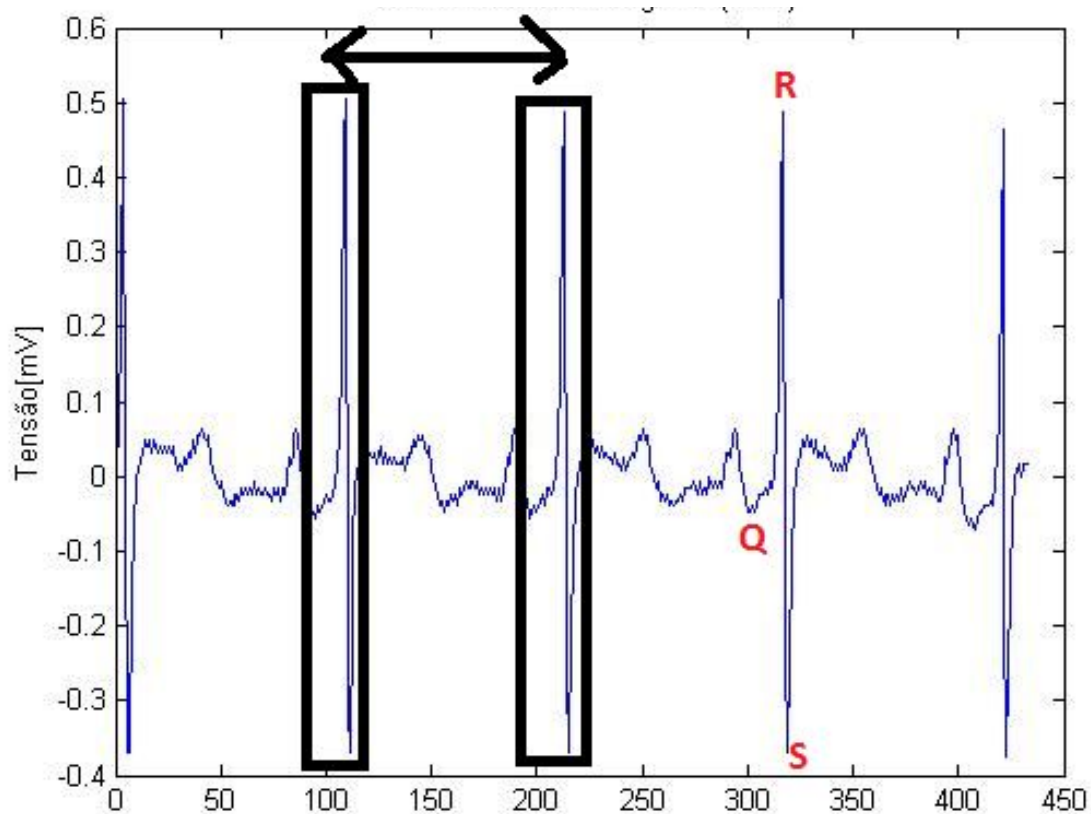
Utilizar componentes espectrais (transformada de Fourier) do ciclo de eletrocardiograma.

- Segunda possibilidade - Bibliografia encontrada:

Utilizar parâmetros obtidos a partir dos intervalos RR do sinal de eletrocardiograma [3].

- Opção escolhida - uso da bibliografia encontrada. Os resultados obtidos inicialmente para a primeira ideia foi de acurácia de 45% - valor baixo.

Intervalos RR



Implementação

- Uso do PhysioToolkit[2]:

função ‘sqrs’ para cálculo dos intervalos e armazenamento dos valores no arquivo “.sqrs”

função ‘rdann’ para transformar os valores armazenados em um vetor no MATLAB[4].

- Gerando:

247 amostras com 50 intervalos RR com fibrilação atrial.

382 amostras com 50 intervalos RR normal.

Foram selecionados 334 para treinamento: 234(70%) para treinamento, 50(15%) teste e 50(15%) verificação.

- Adicional - não contido na bibliografia:

Cálculo da média, desvio padrão, mediana, máximo e mínimo.

Entradas e saídas


- 5 entradas obtidas a partir do intervalo RR:
 - Média;
 - Desvio padrão;
 - Mediana;
 - Máximo;
 - Mínimo.
- 1 saída:
 - valor 1 (se tem);
 - valor -1 (se não tem).

Otimização da rede neural

- Variação do número de neurônios na camada escondida, de 1 a 200 neurônios;
- Foi realizada 100 treinamentos para cada configuração de número de nós;
- Foi utilizada a performance da rede neural, entropia cruzada média (quanto menor melhor), como taxa de erro em relação aos testes para a otimização.

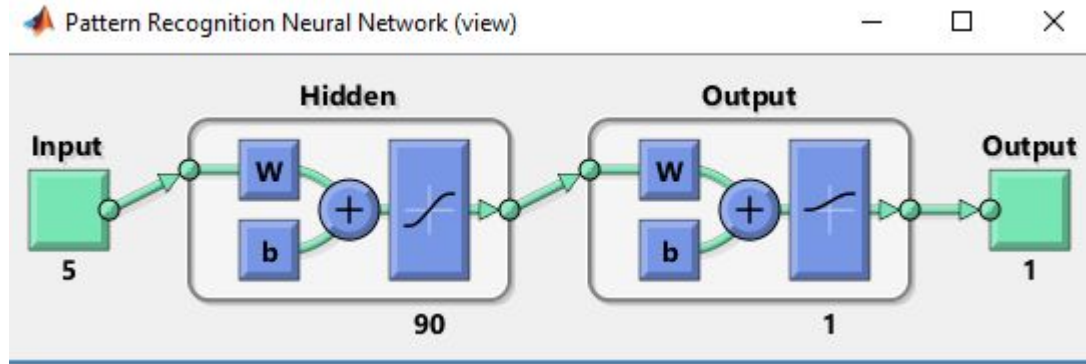
Optimização da rede neural

Foi verificada a qualidade da rede com a variação da quantidade de neurônios na camada escondida - determinando a quantidade de neurônios na camada escondida.

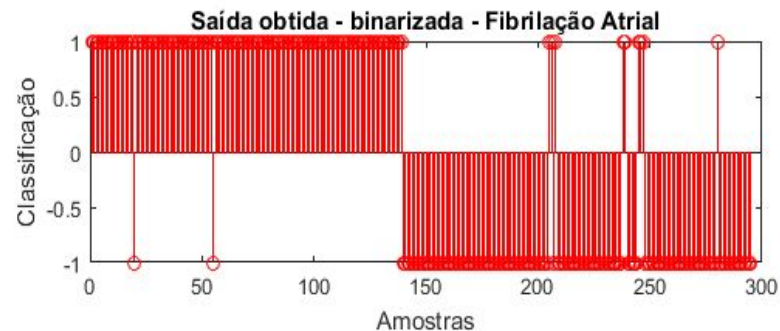

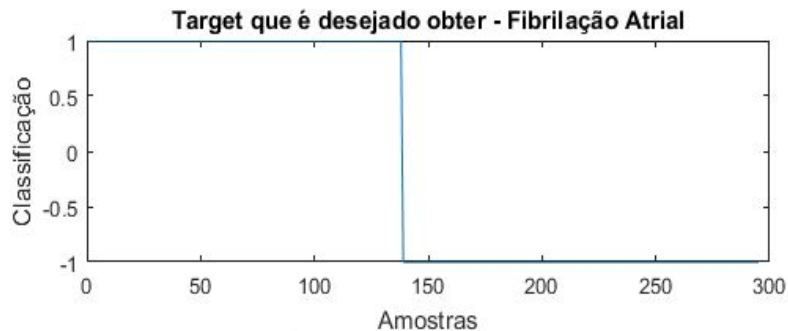


Topologia da rede neural otimizada

Topologia adotada: 5-90-1 (sigmoide na camada escondida e linear na saída)



Resultados da rede neural otimizada



Resultados da rede neural otimizada

Foram usados 295 amostras restantes, não utilizados no treinamento, para verificação da qualidade.


Confusion Matrix

	0	1	
0	157 53.2%	78 26.4%	66.8% 33.2%
1	0 0.0%	60 20.3%	100% 0.0%
	100% 0.0%	43.5% 56.5%	73.6% 26.4%
	0	1	

Target Class

1 - tem fibrilação
0 - não tem fibrilação

Curva ROC



Referências bibliográficas

- [1] SOCIEDADE BRASILEIRA DE CARDIOLOGIA. Diretrizes brasileiras de fibrilação atrial. Arquivos Brasileiros de Cardiologia, vol.92, n.6, supl.1, p.1-39, 2009.
- [2] GOLDBERGER AL, AMARAL LAN, GLASS L, HAUSDORFF JM, IVANOV PCH, MARK RG, MIETUS JE, MOODY GB, PENG C-K, STANLEY HE. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. Circulation, vol.101, n.23, p.e215-e220, 2000.
- [3] Monitors Alireza Ghodrati, Bill Murray, Stephen Marinello , RR Interval Analysis for Detection of Atrial Fibrillation in ECG, 30th Annual International IEEE EMBS Conference Vancouver, British Columbia, Canada, August 20-24, 2008.
- [4] © 2016 The MathWorks, Inc. MATLAB and Simulink are registered trademarks of The MathWorks, Inc.


Cancelador ativo de ruído

Com o aumento da tecnologia e equipamentos industriais, tal como ventiladores e transformadores, problemas com ruídos acústicos têm sido cada vez mais evidentes.

O controle de sons acústicos é abordado usando dois métodos: passivo e ativo. Os métodos passivos, que implicam a utilização de materiais isoladores de ruídos, tais como telhas antirruído, silenciadores e isolamento, são grandes, custosos e ineficientes para frequências baixas, onde os canceladores de ruídos ativos se destacam.

O controle ativo de ruído (ANC), cancela o ruído primário baseando no princípio da superposição. Um sinal antirruído com a mesma amplitude e fases opostas é produzida e combinada com o ruído primário.

Cancelador ativo de ruído



Tenta-se com a rede neural antecipar o sinal de ruído para que , ao somar o sinal predito, em contra fase, o ruído seja cancelado.

Motivação

- Estudar propriedades não lineares das redes neurais e seus comportamentos de redes como preditores de eventos não lineares;
- Estudar e aplicar técnicas de processamento capazes de melhorar o desempenho da rede;
- Construir uma rede neural eficaz no cancelamento de ruídos;
- Demonstrar que a rede neural é uma alternativa mais adaptável do que os sistemas convencionais de controle ativo de ruídos.

Utilidades e aplicações

Sistemas tradicionais de controle ativo de ruídos são construídos para cancelar sons específicos, enquanto que um sistema de controle ativo de ruído com rede neural é adaptável a diferentes tipos de ruídos, dependendo dos dados de treinamento.

O controle ativo de ruído tem aplicações na área de atenuação de ruídos de equipamentos de:

1. Transporte: helicóptero, aviões, navios, motos, etc;
2. Aparelhos: dutos de ar-condicionado, refrigeradores, etc;
3. Industrial: aspiradores, compressores, transformadores, ventiladores, etc.

Coleta de dados

Signal Processing Information Base (SPIB)

Home

Database

Noise Data

This page contains different noise data measured in field by Speech Research Unit (SRU) at Institute for Perception-TNO, Netherlands, United Kingdom, under the project number 2589-SAM (Feb. 1990). All files listed below have duration of 235 seconds and are acquired by considering a sampling rate of 19.98 KHz, an analog to digital converter (A/D) with 16 bits, an anti-aliasing filter, and without a pre-emphasis stage.

- **White Noise** acquired by sampling a high-quality analog noise generator (Wandel & Goltermann), which results in equal energy per Hz bandwidth.
- **Pink Noise** acquired by sampling a high-quality analog noise generator (Wandel & Goltermann), yielding equal energy per 1/3 octave.
- **Speech Babble** acquired by recording samples from 1/2" B&K condenser microphone onto digital audio tape (DAT). The source of this babble is 100 people speaking in a canteen. The room radius is over two meters; therefore, individual voices are slightly audible. The sound level during the recording process was 88 dBA.
- **Factory Floor Noise 1** acquired by recording samples from 1/2" B&K condenser microphone onto digital audio tape (DAT). This noise was recorded near plate-cutting and electrical welding equipment.

- Para a coleta de dados foi usado o banco de dados “Signal Processing Information Base”(SPIB);
- Nele encontramos diferentes dados de sons extraídos de ambientes reais;
- Para o treinamento da rede neural foi usado os dados do “Speech Babble” (ruído de 100 pessoas falando num refeitório);
- Extraímos 2000 amostras de treino do Speech Babble.

Entradas e saída

- Como entradas da rede neural, temos 20 pontos sequenciais, representados por números reais, do sinal sonoro;
- Como saída foi definida como o valor (real) previsão do 21º ponto, baseado nos 20 pontos sequenciais do sinal sonoro usados como entradas.

Configurações e treinamento

1. Subdivisão aleatória dos dados em 2 grupos (validação cruzada k-fold):
 - a. Grupo de treino (80% dos dados);
 - b. Grupo de teste (20% dos dados).
2. Função de treinamento da rede neural:

No MATLAB, as melhores funções de treinamento para um projeto de regressão que também sejam rápidas, são o “trainscg” (Scaled Conjugate Gradient) e o “trainlm” (Levenberg-Marquardt). Optamos pela função “trainscg” que é rápida e apresenta um bom desempenho para problemas de regressão, principalmente quando o problema envolve o cálculo de muitos pesos, ou em redes neurais grandes.

Processamentos

Ao longo das bibliografias consultadas neste projeto, não foi recomendada e nem mencionada nenhuma técnica específica ou comum de pré/pós processamento.

Os processamentos “default” do MATLAB foram as técnicas que geraram os resultados mais satisfatórios.

Pré-processamentos e Pós-processamentos:

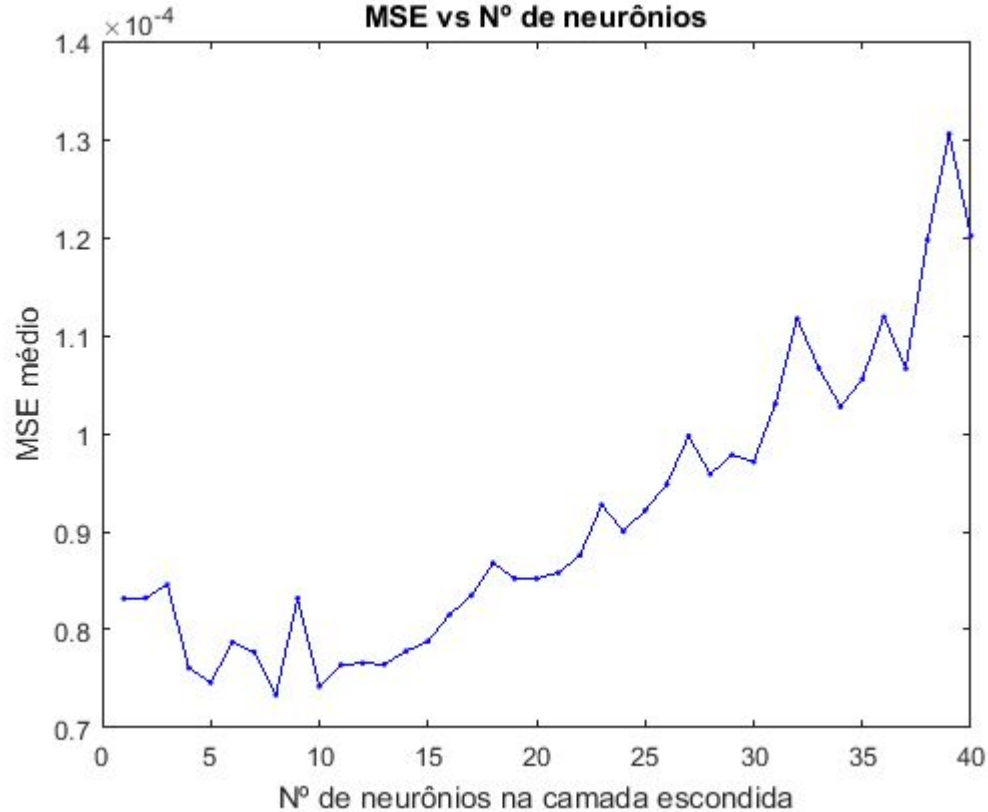
- “removeconstantrows” - remoção de linhas constantes;
- “mapminmax” - normalização [-1 1].

Optimização da rede neural

Metodologia:

1. Incremento gradual do número de neurônios na camada escondida desde 1 até 40;
2. Para cada número de neurônios na camada escondida, é computado um conjunto de 100 MSE;
3. Computar o MSE médio e a atenuação média para cada número de neurônios na camada escondida;

Optimização da rede neural




Medida de qualidade

$$\dots \text{Noise Attenuation} = 10 \times \log_{10} \frac{\text{Input Noise Energy}}{\text{Remained Noise Energy}}$$

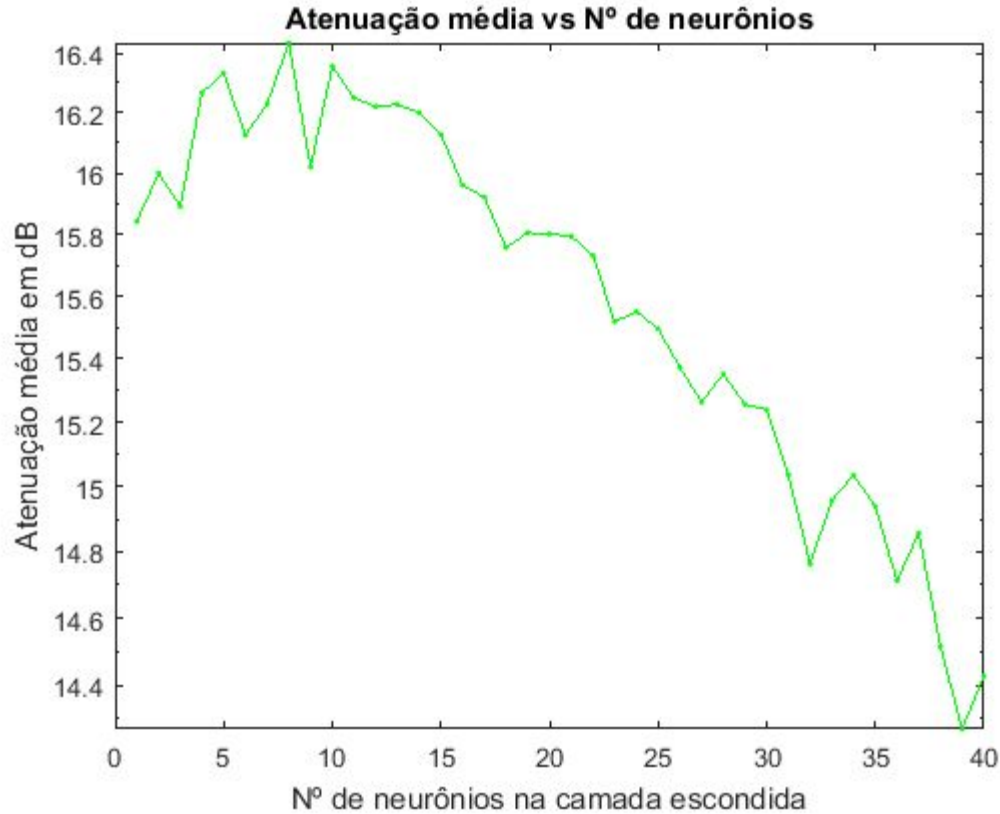
Rede neural e topologia

Implementamos com a função “fitnet”, recomendado pelo MATLAB como regressor, uma rede neural de duas camadas, com “tansig” e “purelin” como funções de transferências das camadas escondida e saída respectivamente.

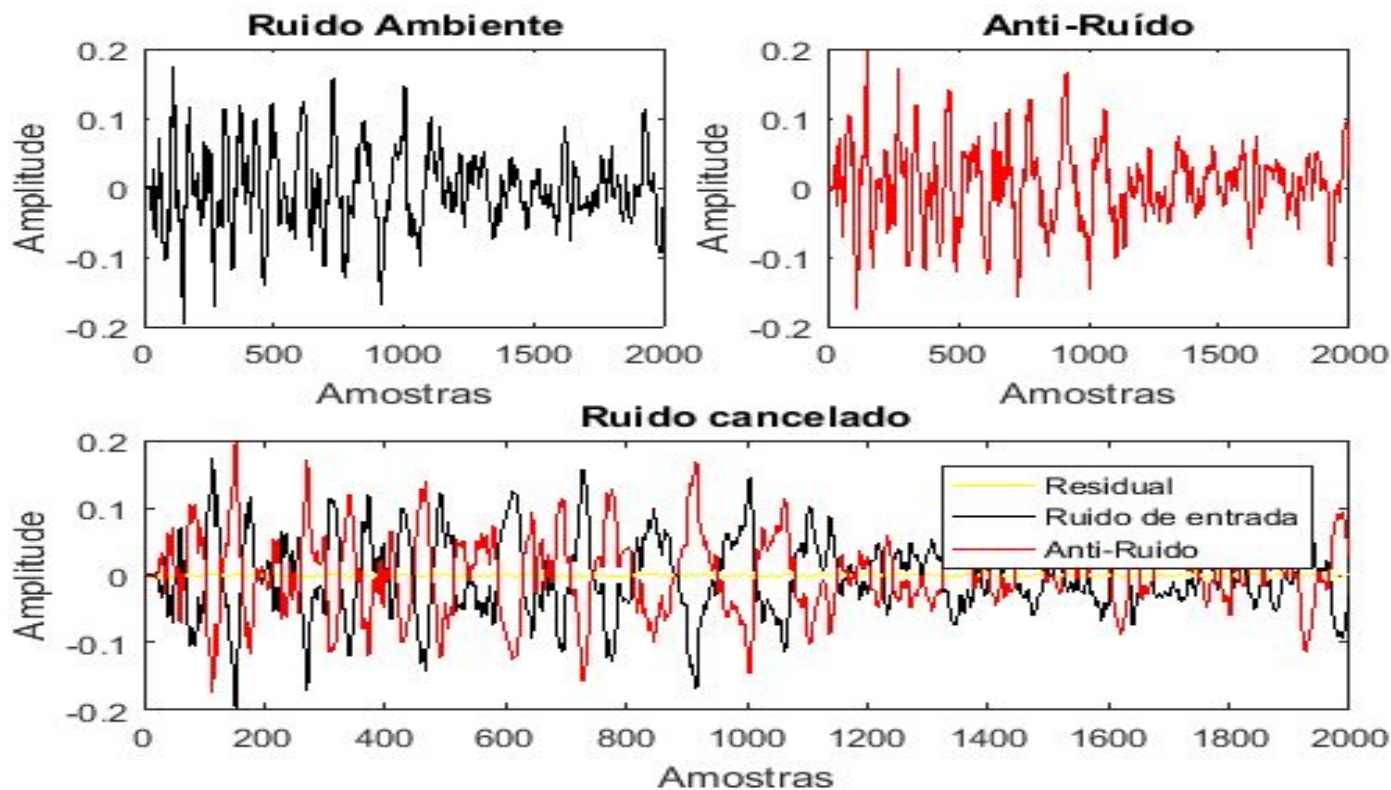
Tendo em conta o gráfico de otimização da rede neural, a topologia final da rede ficou 20-8-1.



Resultados da rede neural otimizada



Resultados da rede neural otimizada



Referências bibliográficas

- [1] C.K. Chen, and T. D. Chiueh, “Multilayer perceptron neural networks for active noise cancellation,” In Proc. IEEE Int. Symp. Circuits and Systems, vol. 3, pp. 523-526, May 1996.
- [2] M. Salmasi, H. Mahdavi-Nasab, and H. Pourghassem, “Evaluating the Performance of MLP Neural Network and GRNN in Active Cancellation of Sound Noise” , Canadian Journal on Artificial Intelligence, Machine Learning and Pattern Recognition Vol. 2, No.2, February 2011.
- [3] T. Krukowicz, “Active noise control algorithm based on a neural network and nonlinear input-output system identification model”, Journal on Archives of Acoustics, vol. 35, no.2, pp.191-202, May 2010.
- [4] Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth, “Neural Network Toolbox User's Guide”, MATLAB (2016a), March 2016.
- [5] Signal Processing Information Base. Disponível em: < <http://spib.linse.ufsc.br/noise.html> >.

Dúvidas?!