
Em Revisão:

Segmentação automática e classificação de sons cardíacos através das transformada de wavelet empírica e características de potência.

Pedro Narváez, Steven Gutierrez e Winston S.Percybrooks
Department of Electrical and Electronics Engineering, Universidad del Norte, Barranquilla,
Colombia
Publicado em 13 Julho de 2020

Revisão por Francisco Relvão
Universidade de Coimbra, 2022

Motivação e Objetivo

- Doenças cardiovasculares compõem 32% das mortes mundiais em 2019.
 - Auscultação de experiência e habilidade do profissional de saúde, habilidade que se encontra em declínio nestes profissionais.
 - Auscultação e eletrocardiogramas requerem equipamento caro e especializado, o que afeta comunidades rurais.

 - **Objetivo: Classificar sons cardíacos como normais ou anormais. São propostos dois métodos.**
-

Na Literatura

São usados vários metodologias para segmentação:

- Transformadas
- Filtros de sinal
- Cálculo Matricial
- Processos estocásticos

E são também usados diferentes métodos de aprendizagem de máquina.

Na Literatura: Segmentação

Table 1. Summary of previous work in the automatic segmentation of heart sounds.

Author	Dataset	Method
[9]	37 recordings of heart sounds	Normalized Average Shannon Energy
[10]	80 recording of heart sounds	S-transform and Shannon Energy
[11]	77 recording of heart sounds	Wavelet decomposition and reconstruction (normalized average Shannon energy (NASE))
[12]	Physionet [20] and Pascal [21]	Hidden Markov model (HMM)
[13]	Physionet database [20]	Logistic regression and hidden semi-Markov model (HSMM)
[15]		Wavelet Decomposition and Spectrogram
[16]	Pascal database [21]	Butterworth band pass filter with order 2 and Homomorphic filter
[18]		Chebyshev type I low-pass filter and Shannon envelope
[19]		Band-pass Butterworth sixth-order filter and Shannon envelope
[22]	Physionet database [20]	HSMM-convolutional neural network (CNN)
[23]	Pascal database [21]	Discrete wavelet transform and Hilbert transformation
[24]	Physionet [20] and Pascal [21]	Adaptive sojourn time HSMM

Na Literatura: Classificação

Author	Number of Heart Cycles	Segmentation	Feature Extraction (Number of Features)	Classifier	Results
[25]	N:200; A:800	Manually	MFCC + DWT (43 F)	SVM	A: 97%
[26]	N: 2488; A: 665	Not applicable	Statistical domain, Frequency domain and MFCC (27 F)	XgBoost	S: 94.5%; E: 91.3%; A: 92.9%
[27]	N: 155; A: 133	Manually	LPC and MFCC coefficients (80 F)	SVM; KNN	A: 94,6%; E: 98,6%; S: 89,4%
[28]	N: 2488; A: 665	Manually	1D – Convolutional neural network (CNN)	DNN	S: 91.5%; E: 71.6%; A: 87.5%
			MFCC and 2D – CNN	DNN	S: 92.5%; E: 76.6%; A: 89.3%
[29]	N: 320; A: 141	Not applicable	Long short-term memory (LSTM)	DNN	A: 80.8%
[30]	N: 399; A: 399	[13]	Time, time-frequency and perceptual domain. (90 F)	ANN	S: 90,1%; E: 93,1%
[31]	N: 669; A: 722	[13]	MFSC and CNN	DNN	A: 93,7%
[32]		[13]	Time and frequency domain, wavelet and statistics (29 F)	RF + LB + CSS	S: 79.6%; E:80.6%
[33]		Hilbert transformation	Statistical properties, Heart rate (53 F)	Logic rules	S: 91.3%; E:77%
[34]			CWT	SVM, KNN	A: 86%
[35]	N: 2488; A: 665	[13]	Time features and MFCC (13 F)	SVM	S: 91.8%; E: 82%; A: 97%

Segmentação Automática

Método Proposto de Segmentação

O método contém 7 passos.

Transformada wavelet empírica: evolução da amplitude das frequência em função do tempo. Permite escolher intervalos de frequência sem aplicar filtros. Tem um grande custo computacional, mas menor que a aplicação de vários filtros diferentes..

Energia média de Shannon: envelopamento do sinal para o tornar mais simples.

Lobos: sons cardíacos após serem envelopados.

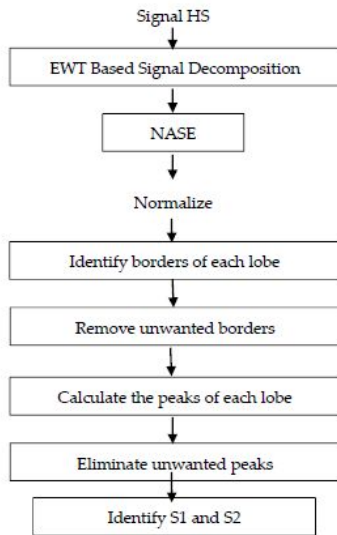
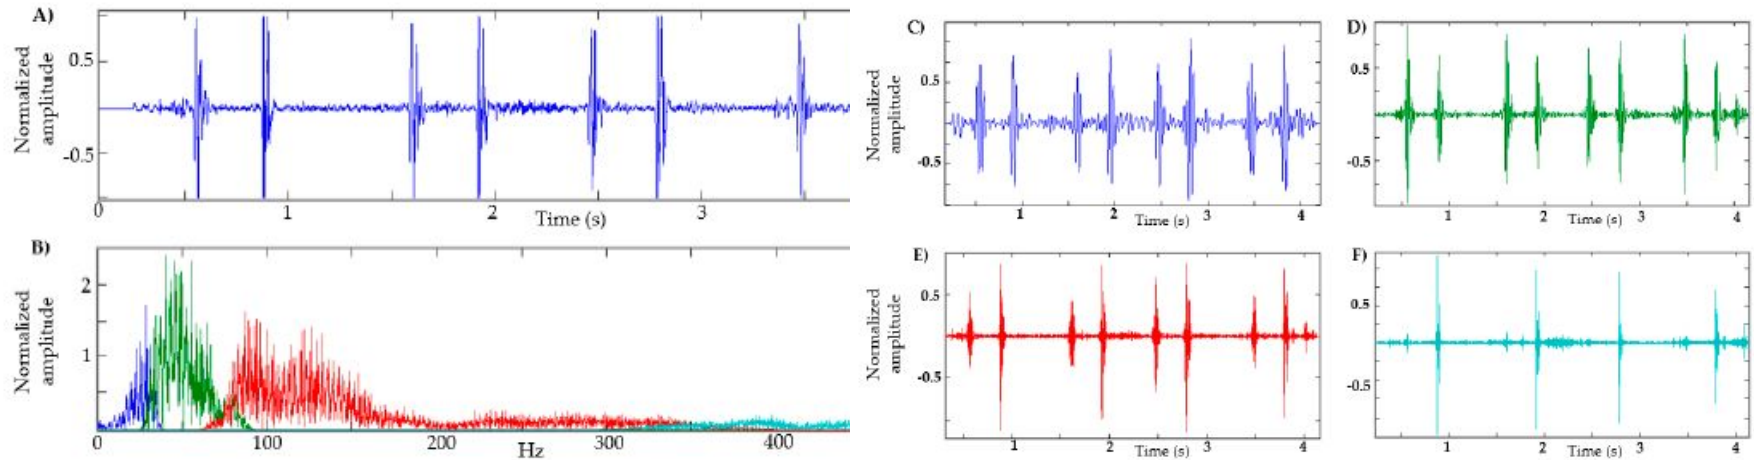


Figure 1. Block diagram for the proposed segmentation system.


Método Proposto de Segmentação

Transformada wavelet empírica: separação do sinal sem filtros.





Método Proposto de Segmentação

Energia média de Shannon: Delineação do sinal



Método Proposto de Segmentação

Amplificação de sinais fracos



Classificação automática

Método Proposto de Classificação

- Apenas se faz a distinção entre sons **normais e anormais**
- Serão utilizados 4 modelos de aprendizagem:
 - Support Vector Machines - (SVM)
 - K-th nearest neighbor - (KNN)
 - Random forests
 - Multilayer perceptron
- Input: Características dos intervalos de potência obtidas na segmentação.
- Output: Dois rótulos - normal ou anormal

$$P = \frac{1}{2N+1} \sum_{n=-N}^{n=+N} |x(n)|^2$$


Resultados

Resultados: Segmentação

Segmentação automática: Bons resultados, quando comparados à literatura.

Table 4. Results of segmentation for dataset A. (HB: heartbeat).

HS (File Name)	HB	Average Error	HS (File Name)	HB	Average Error
201101070538	11.5	15,792.91	201103101140	9	58,920.83
201101151127	10	177,625.15	201103140135	9.5	24,891.94
201102081152	9.5	159,024.94	201103170121	10	343.15
201102201230	11.5	17,384.91	201104122156	11.5	173,664.78
201102270940	8.5	159,194.17	201106151236	9.5	56,598.00



Erro = Posição automática do batimento i - Posição manual do batimento i

Resultados: Classificação

Table 12. Results of accuracy between the methods in [25–27] and the proposed method.

Feature Extraction	Classifier			
	SVM	KNN	RF	MLP
[25]: MFCC	74.65%	85.96%	87.20%	85.83%
[25]: DWT	86.95%	88.19%	92.17%	90.31%
[25]: MFCC + DWT	90.68%	91.18%	91.42%	91.55%
[26]: Statistical, frequency and perceptual	84.47%	93.66%	93.66%	92.54%
[27]: LPC	88.19%	92.91%	92.91%	94.16%
[27]: MFCC	94.90%	94.65%	96.52%	96.52%
[27]: LPC + MFCC	96.27%	95.52%	95.27%	97.26%
Proposed Method: EWT + Power	92.42%	99.25%	99.00%	98.63%

Table 13. Results of specificity between the methods in [25–27] and the proposed.

Feature Extraction	Classifier			
	SVM	KNN	RF	MLP
[25]: MFCC	76.92%	86.92%	87.94%	82.82%
[25]: DWT	85.38%	83.84%	91.79%	88.46%
[25]: MFCC + DWT	90.76%	90.00%	90.00%	91.53%
[26]: Statistical, frequency and perceptual	86.06%	95.90%	95.18%	94.69%
[27]: LPC	91.54%	96.63%	91.31%	94.31%
[27]: MFCC	94.85%	96.76%	95.47%	97.13%
[27]: LPC + MFCC	97.61%	98.09%	94.22%	97.91%
Proposed Method: EWT + Power	100.00%	100.00%	99.22%	100.00%

Métricas usadas
para a comparação.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} * 100$$

$$Specificity = \frac{TN}{FP + TN} * 100$$

$$Sensitivity = \frac{TP}{FN + TP} * 100$$

Resultados: Classificação

Table 17. Confusion matrix of proposed method.

Machine Learning	Confusion Matrix	
	Normal	Abnormal
SVM	Normal	415
	Abnormal	0
KNN	Normal	61
	Abnormal	329
Random Forest	Normal	415
	Abnormal	0
ANN	Normal	6
	Abnormal	384
Random Forest	Normal	412
	Abnormal	3
ANN	Normal	5
	Abnormal	385
ANN	Normal	415
	Abnormal	0
ANN	Normal	11
	Abnormal	379

Conclusão

Conclusão

- Bons resultados para ambos os métodos propostos, tendo a literatura como comparação.
 - Foram usadas mais bases de dados, o que implica melhor resultados estatísticos, não existindo uma comparação direta com alguns estudos.
 - Independentemente tipo de aprendizagem, os resultados são bons, portanto, o método de segmentação pode ser a causa.
 - Ainda assim, este método é limitado por ruído de grande amplitude ao longo de várias frequências.
-