



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

**INPE-13004-PRE/8281**

## **ANÁLISE DE PADRÕES GRADIENTES DA VARIABILIDADE DA FREQUÊNCIA CARDÍACA**

Juliana de Mattos Guerra Simões\*

\*Bolsista UNIVAP

Relatório Final de Projeto de Iniciação Científica (PIBIC/CNPq/INPE), orientado pelo  
Dr. Reinaldo Roberto Rosa

INPE  
São José dos Campos  
2005

# **ANÁLISE DE PADRÕES-GRADIENTES DA VARIABILIDADE DA FREQUÊNCIA CARDÍACA**

Juliana de Mattos Guerra Simões (Univap, bolsista PIBIC/CNPq)  
Reinaldo Roberto Rosa (LAC/CTE/INPE)

## **RESUMO**

Este trabalho tem como objetivo a continuidade ao projeto de Iniciação Científica em andamento desde Julho de 2003, no qual pretende-se avaliar os padrões da variabilidade da frequência cardíaca através da técnica de análise de padrões gradientes (GPA). Esta técnica permite caracterizar a dinâmica, relacionada à formação e evolução de padrões espaço-temporais em sistemas não-lineares, baseando-se na aplicação de operadores computacionais que quantificam quebras de simetria e desordem de fase em escalas locais e globais de uma dada estrutura espaço-temporal. O objetivo deste trabalho é analisar as características do momento gradiente de primeira ordem,  $F_A$ , através da técnica GPA1D - GPA adaptado para o domínio exclusivamente temporal - de séries temporais do intervalo RR do eletrocardiograma (ECG) submetidos a liberação miofascial e, fazer posteriormente uma análise complementar com a técnica de GWS (Global Wavelet Spectra), que será utilizada como ferramenta de validação do GPA1D espectral introduzido por Assireu et al. (2005). A variação do intervalo RR no ECG indica a variabilidade da frequência cardíaca (VFC). Os resultados obtidos até o momento indicam a possibilidade de distinção dos padrões de variabilidade presentes nos sinais de diferentes estados (liberação miofascial e repouso), o que não tem sido possível através de técnicas convencionais. A metodologia GPA1D, em conjunto com o GWS, abre ainda a possibilidade de investigar a influência dos sistemas simpático e parassimpático nos estados de liberação miofascial e repouso. Tais resultados se tornam importantes uma vez que a VFC é considerado um indicador precoce e sensível do comprometimento da saúde, indicando boa ou má adaptabilidade do controle autonômico cardíaco, sendo muito importante no estudo e no diagnóstico clínico de patologias cardiovasculares, bem como para investigar os possíveis efeitos da microgravidade sobre a dinâmica cardíaca.

## SUMÁRIO

	PÁG.
CAPÍTULO 1 – INTRODUÇÃO.....	3
1.1 – Esboço Geral.....	3
CAPÍTULO 2 – VARIABILIDADE DA FREQUÊNCIA CARDÍACA.....	5
2.1 – Apresentação dos Dados.....	9
CAPÍTULO 3 - CARACTERIZAÇÃO DE PADRÕES DE VARIABILIDADE.....	11
3.1 - Análise de Padrões-Gradientes.....	12
3.2 - Estudo Complementar por Transformada de Wavelets.....	17
CAPÍTULO 4 – DESENVOLVIMENTO.....	26
4.1 – Metodologia.....	26
4.2 - Resultados.....	27
CAPÍTULO 5 - DISCUSSÃO E CONCLUSÃO.....	46
REFERÊNCIAS BIBLIOGRÁFICAS.....	51
APÊNDICE A - Eletrocardiograma e a Influência Autonômica na Frequência Cardíaca.....	53
APÊNDICE B – Técnicas de Fisioterapia: Liberação Miofascial.....	58
APÊNDICE C – Espaço de Fase.....	60

# CAPÍTULO 1

## INTRODUÇÃO

A Engenharia Biomédica e o Processamento de Sinais Biológicos permitem inúmeras possibilidades de procedimentos terapêuticos não invasivos, aumentando dessa forma, a capacidade de diagnóstico, especialmente na área cardiovascular. A análise da variabilidade da frequência cardíaca (VFC) possibilita a observação e compreensão dos mecanismos extrínsecos do controle do ritmo cardíaco em situações fisiológicas normais e patológicas. O fato da análise da VFC ser uma técnica não invasiva a torna o procedimento de escolha na avaliação fina da função do sistema nervoso autônomo (SNA) em muitas condições clínicas [1].

A técnica da análise de padrões-gradientes (GPA, do termo inglês: *gradient pattern analysis*) permite caracterizar, com alta sensibilidade, a dinâmica relacionada à formação e evolução de padrões espaço-temporais em sistemas não-lineares, baseando-se na aplicação de operadores computacionais que quantificam quebras de simetria e desordem de fase em escalas locais e globais de uma dada estrutura espaço-temporal ou puramente temporal (GPA1D). Uma característica importante desta técnica é a sua alta sensibilidade para detectar pequenas modificações na variabilidade de um sinal que, em geral, não são detectadas por outras técnicas usuais, sendo assim, uma ferramenta importante no estudo da variabilidade fina da frequência cardíaca [4,5].

### 1.1 – ESBOÇO GERAL

Neste trabalho, os sinais utilizados serão introduzidos no capítulo 2, no qual será abordada a variabilidade da frequência cardíaca. Será explicado como a VFC se comporta no repouso e no exercício físico, que é a proposta deste trabalho. Também terá uma breve explanação dos métodos de análise de VFC encontrados na literatura. Outros assuntos relacionados aos dados são abordados nos Apêndices A e B, que são intitulados: Eletrocardiograma e a Influência Autonômica na Frequência Cardíaca e Liberação Miofascial, respectivamente.

O capítulo 3 trata das ferramentas de análise utilizadas neste trabalho. É iniciado por uma descrição sobre caracterização de padrões. A análise de padrões-gradientes é então descrita e posteriormente detalhada, seguida por um estudo complementar com Wavelets. Uma descrição sobre espaço de fases, no contexto da técnica GPA1D, é encontrada no Apêndice C.

O capítulo 4 descreve as aplicações das técnicas nos sinais de interesse. A metodologia de aplicação utilizada descreve as etapas que permitiram a realização de uma análise robusta e coerente dos diferentes sinais. O capítulo é finalizado com a apresentação dos resultados.

A discussão e a conclusão fazem parte do capítulo 5, onde o trabalho é então finalizado. Os resultados são analisados e discutidos, e o assunto é concluído com a proposta de trabalhos futuros.

## CAPÍTULO 2

### VARIABILIDADE DA FREQUÊNCIA CARDÍACA

A análise de sinais de variabilidade da frequência cardíaca (VFC) é importante quando se estuda o sistema nervoso autônomo, pois ajuda a avaliar o equilíbrio entre as influências simpáticas e parassimpáticas no ritmo cardíaco.

O ramo simpático do sistema nervoso aumenta a frequência cardíaca, implicando em intervalos mais curtos entre os batimentos e diminui a VFC. Por sua vez, o ramo parassimpático a desacelera, resultando em intervalos maiores entre batimentos e aumenta a VFC. Assim, a variabilidade da frequência cardíaca pode ser medida com base nos intervalos dos batimentos, os quais são frequentemente obtidos dos intervalos RR, que são os intervalos de tempo entre duas ondas R consecutivas [7].

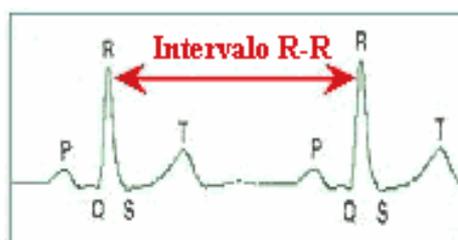


Figura1: Intervalo RR do eletrocardiograma

As variações hemodinâmicas que ocorrem batimento-a-batimento expressam a resposta fisiológica de uma série de comandos neurohumorais na tentativa de sustentar a função cardiovascular. O coração não tem seus batimentos regulares com intervalos fixos, assim, variações da frequência cardíaca (VFC), moduladas principalmente pelo SNA, são normais e esperadas em indivíduos saudáveis. A VFC mostra alterações com a respiração, estresse físico e mental, exercício, alterações hemodinâmicas e metabólicas.

A VFC pode ser determinada durante registros eletrocardiográficos de curta duração e, nestes casos, geralmente em associação com testes provocativos (manobras respiratórias, testes posturais, exercício isométrico e dinâmico, estimulação carotídea, provas farmacológicas, etc.) ou, mais frequentemente, durante monitorização eletrocardiográfica ambulatorial [20].

Alterações nos padrões de VFC provem um indicador precoce e sensível do comprometimento da saúde. Uma alta variabilidade na frequência cardíaca é sinal de boa adaptabilidade, implicando em um indivíduo saudável com os mecanismos de controle autonômicos funcionando bem. Por outro lado, uma baixa variabilidade é frequentemente indicadora de adaptabilidade anormal ou insuficiente do sistema nervoso autônomo,

implicando na presença de mau funcionamento fisiológico, pelo qual se faz necessário maior investigação para se ter um diagnóstico preciso [19].

A análise de VFC tem sido utilizada no diagnóstico e prognóstico de muitas doenças: doenças cardiovasculares, doenças neurológicas, doenças pulmonares, doenças endócrinas e metabólicas, etc. [15].

## **VFC em repouso e em exercício físico dinâmico**

### Em Repouso

É bem reconhecido que o sistema nervoso autônomo exerce papel importante na regulação cardíaca. Por meio de metodologia relativamente simples e não invasiva, ou seja, a variabilidade da frequência cardíaca (VFC), é possível obter-se informações quantitativas específicas sobre modulação das atividades vagal e simpática cardíacas. Particularmente, a técnica de análise do espectro de potência dos intervalos R-R do eletrocardiograma tem se mostrado de grande utilidade para quantificar, em condições de repouso ou exercício físico, a magnitude do tônus simpático e parassimpático atuante no nódulo sinusal. Essa metodologia tem sido utilizada na avaliação de riscos de complicações graves no período pós-infarto do miocárdio e em outras cardiopatias, nas quais se percebe redução da VFC; destaca-se, também sua utilidade para estudar certas drogas sobre a função autonômica.

A relação entre VFC e o envelhecimento tem sido objeto de estudo de vários autores, pois com o aumento da idade ocorre redução da VFC. Esse achado deve-se ao fato de, no envelhecimento, surgirem mudanças no balanço autonômico, com predominância simpática. Portanto, a VFC tem sido considerada importante marcador biológico do envelhecimento e assume relevância por que a redução da VFC com a idade está relacionada com o aumento da morbidade e mortalidade por doenças cardiovasculares.

### Em Exercício Físico

A literatura refere que o treinamento físico regular pode ser capaz de modificar o balanço autonômico cardíaco, tanto em indivíduos normais como em portadores de doenças cardiovasculares. Contudo existem discordâncias quanto ao efeito do treinamento físico avaliado por meio da VFC, pois, apesar de muitos trabalhos demonstrarem modificações de componentes espectrais, outros não o fizeram.

A caracterização do limiar de anaerobiose (LA) por meio da VFC tem sido objeto de alguns estudos: submetendo um indivíduo a níveis de potência de esforço físico submáximas, em degraus descontínuos, no início com potências muito baixas, evoluindo para mais elevadas (com intervalos de tempo para recuperação das variáveis aos valores basais), pode-se observar duas fases de comportamento da FC e a influência do sistema simpático e parassimpático sobre elas.

A primeira fase é encontrada em baixos níveis de potência, abaixo do valor correspondente ao LA, sendo caracterizada pela inibição do tônus parassimpático sobre o nódulo sinusal, com conseqüente taquicardia. Há rápido incremento da FC, alcançando

valor de pico por volta dos primeiros 10 a 20 segundos, a partir desse ponto, nota-se estabilização dos valores após o primeiro minuto de exercício.

A segunda fase é observada em níveis de potencia acima do LA, na qual a contribuição simpática começa a ser predominante e aumenta em proporção ao incremento do esforço físico. A estimulação simpática é responsável pelo incremento de FC, percebida do 1º ao 4º minuto do exercício físico dinâmico. O estudo da função do sistema nervoso autônomo com mecanismo de controle durante o exercício físico dinâmico permite possível identificação da potencia na qual ocorre estabilização da FC caracterizando, de forma indireta, o LA [17].

### **Análise da VFC**

Devido aos diferentes mecanismos de funcionamento do sistema de controle do ritmo cardíaco, mudanças das suas atividades podem ser identificadas e quantificadas por técnicas no domínio do tempo e na frequência. Embora a interpretação desse tipo de dados exija alguma cautela, ela provê a base para avaliação quantitativa não invasiva da atividade autônoma [1].

As metodologias atuais usadas para análise da VFC são amplamente baseadas em técnicas lineares para análise de dados em tempo real e gravados de ECG, no domínio do tempo e da frequência.

Para uma análise convencional no domínio do tempo, a variabilidade das séries temporais derivadas do ECG gravado é estatisticamente resumida usando cálculos convencionais como SDNN (desvio padrão do intervalo de tempo entre duas ondas R consecutivas resultante da despolarização do nódulo sinoatrial.) e RMSSD (raiz quadrada da diferença entre dois intervalos-RR adjacentes). Dependendo do comprimento das séries de ECG analisadas, que pode variar de alguns minutos até 24 horas, e a escolha de medidas no domínio do tempo, tanto os componentes curtos quanto os longos podem ser quantificados e caracterizados.

Enquanto as medidas no domínio do tempo ajudam avaliar a magnitude das variações temporais no ritmo cardíaco autonomicamente modulado, a análise no domínio da frequência prove uma composição espectral dessas variações.

A análise da VFC no domínio do tempo é aceita como “invariância no tempo” ou “estacionaridade” do sinal, por exemplo, os componentes individuais do espectro não mudam ao longo da aquisição do sinal.

Através do uso de algoritmos computacionais eficientes como a transformada rápida de Fourier, o sinal é decomposto em componentes espectrais individuais e suas intensidades, usando análise de densidade de potencia espectral (PSD). Esses componentes espectrais são agrupados em três bandas distintas: muito baixa frequência (VLF), baixa frequência (LF) e alta frequência (HF) [15].

A literatura tem estudado uma diversidade de mecanismos que possam explicar a associação entre a VFC e os diferentes processos patofisiológicos a partir da utilização de métodos tradicionais e de novos métodos de análise por meio de técnicas de sistemas

dinâmicos não-lineares. Os métodos não lineares baseiam-se na teoria do caos (fenômenos altamente irregulares, mas não ao acaso).

Métodos analíticos derivados da dinâmica não-linear têm possibilitado novas abordagens para o estudo e entendimento do comportamento da frequência cardíaca. Inúmeras ferramentas utilizam a dinâmica não-linear e a modelagem matemática para estudar o comportamento da VFC e verificar a existência de alguma relação entre a VFC e causas de morte devida a doenças cardíacas [8].

### **Métodos lineares:**

#### a) Domínio do Tempo

##### a1) Análise de índices estatísticos

###### Baseados em intervalos RR, individualmente

- SDNN
- SDANN
- SDNN index

###### Baseados em intervalos RR adjacentes

- pNN50
- rMSSD

##### a2) Análise de índices geométricos

- Índice triangular
- Plotagem de Lorenz

##### a3) Outros

- Índices de turbulência

#### b) Domínio da Frequência

##### b1) Transformação de Fourier

b2) Autoregressão

**Métodos não lineares:**

- Dimensão fractal
- Entropia
- Expoentes de Lyapunov

**2.1 – APRESENTAÇÃO DOS DADOS**

Os sinais utilizados neste trabalho são os intervalos entre duas ondas R consecutivas, o que se denomina variabilidade da frequência cardíaca (VFC).

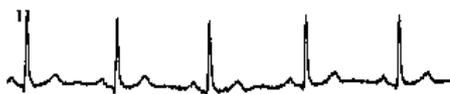


Figura 2: Exemplo de um sinal típico de ECG

Os sinais foram coletados de voluntárias sedentárias, com idade entre 21 a 40 anos com ausência de distúrbios que alterem a VFC, através de um eletrocardiógrafo digital Micromed acoplado a um microcomputador Dell Computer Corporation. Os sinais foram processados pelo Software Ergo PC Elite 13W da Micromed, que extraiu os intervalos RR através de algoritmos de detecção de picos. [1].

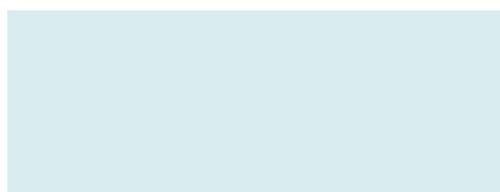
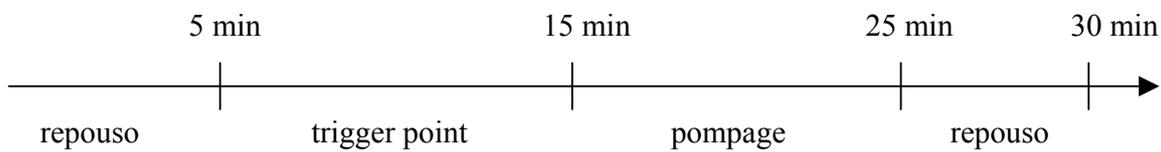


Figura 3: Exemplo de Intervalo RR

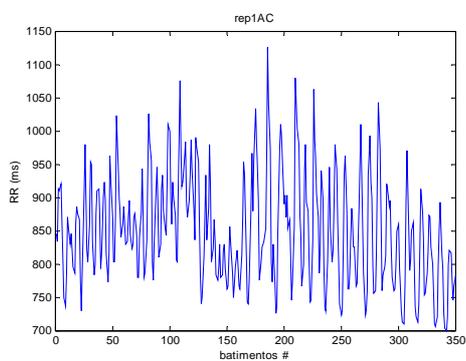
Para a análise com Wavelets foi necessário fazer a interpolação dos sinais. Para isso, foi utilizado Splines cúbicas.

O sinal de ECG foi inicialmente coletado em repouso durante 5 minutos, então o procedimento de liberação miofascial foi aplicado durante 20 minutos, sendo 10 minutos com a técnica de trigger point e 10 minutos com a técnica pompage. Finalmente, coletou-se

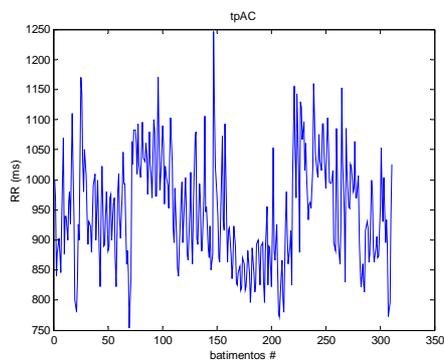
5 minutos de repouso após as técnicas.



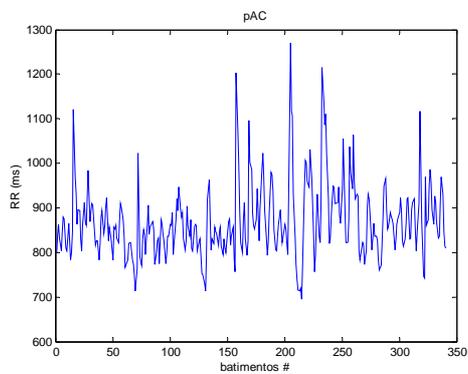
A)



B)



C)



D)

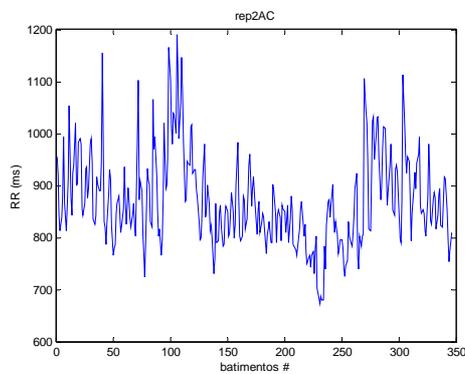


Figura 5: Exemplo das séries temporais utilizadas neste trabalho. (A) Sinal referente ao repouso inicial (B) Sinal referente à técnica trigger point (C) Sinal referente à técnica pompage (D) Sinal referente ao repouso final.

## CAPÍTULO 3

### CARACTERIZAÇÃO DE PADRÕES

Caracterizar padrões de variabilidade em sinais com variabilidade complexa na engenharia biomédica tem sido desafio para auxiliar no diagnóstico fino dos regimes fisiológicos registrados no sinal. Em virtude de algumas técnicas de fisioterapia (liberação miofascial e pompage, por exemplo) os intervalos RR tornam-se mais complexos devido aos períodos intercalados (lineares e não-lineares) de estímulos e normalidade. Dessa forma, a caracterização de padrões de variabilidade do ECG estimulados por fisioterapias torna-se imprescindível na compreensão e classificação dos tipos de respostas do SNA sobre o controle cardíaco devido aos estímulos fisioterápicos.

O reconhecimento de padrões é o estudo de como as máquinas observam seu entorno, aprendem a distinguir padrões de interesse e tomam decisões razoáveis sobre as categorias desses padrões. Um padrão é uma descrição de um objeto que pode ser classificado como: concretos (espaciais: caracteres, imagens; temporais: formas de onda, séries etc.) e abstratos (raciocínio, soluções a problemas etc.). Um computador consegue reconhecer padrões, convertendo-os em sinais digitais e comparando-os com outros sinais já armazenados na memória.

O problema do reconhecimento de padrões é reconhecer padrões que sejam, em algum sentido, “os mesmos”, apesar de ter experimentado uma variedade de transformações permitidas. Os padrões na vida real apresentam transformações geométricas lineares (rotação, escala e translação), deformações não lineares e variância de iluminação e background. Os métodos tradicionais de reconhecimento de padrões carecem da habilidade para reconhecer o mesmo padrão com certo tipo de variância. Entre as principais técnicas de extração de características invariantes, pode-se destacar: os momentos estatísticos, as transformadas de Fourier, as transformadas wavelets, o casamento de grafos e redes neurais como as redes de pulso acoplado.

Três abordagens básicas para a construção de características são usadas: estatística, estrutural e neural. Na abordagem estatística, as características são obtidas pela manipulação de medidas puramente numéricas ou booleanas. O conjunto de medidas características para o reconhecimento é extraído dos sinais que aqui constituem os dados propriamente ditos. Posteriormente estes conjuntos de medidas alimentaram funções estatísticas para separar as classes.

Na abordagem estrutural, as características correspondem, de alguma maneira, com a percepção humana dos objetos. Características que são invariantes a certas transformações devem ser utilizadas. Quando características invariantes não podem ser encontradas, uma alternativa é normalizar o objeto analisado, a fim de encontrar um tamanho padrão. Ainda pode-se classificar os métodos de reconhecimento como neurais, ou seja, todos os métodos que utilizam redes neurais no módulo de reconhecimento. Também podem ser encontrados na literatura métodos híbridos de reconhecimento, ou seja, métodos que combinam abordagens estatísticas, estruturais e neurais [10].

O reconhecimento de padrões tem provocado um grande interesse nas últimas décadas, interesse que surgiu com a utilização dos computadores e por causa das numerosas aplicações. A complexidade de um sistema de reconhecimento de padrões é alta devido a que muita da informação disponível na vida real, apresenta-se na forma de padrões complexos, sofrendo transformações e deformações não lineares.

O uso de computadores digitais programáveis nas tarefas de análise de sinais e classificação de padrões constitui exemplos de aplicação nos campos da inteligência artificial e de processamento de sinais biomédicos. Para que seja possível o processamento de sinais, métodos eficazes devem ser utilizados na fase de extração de características, reconhecimento e classificação de padrões, presentes nos sinais. Dentre estes sinais, o ECG, constitui um tipo de sinal biológico que registra a excitação elétrica do músculo cardíaco. As funções wavelets constituem uma das mais eficazes técnicas de extração de características invariantes em sinais não estacionários e podem ser aplicadas à rotina de reconhecimento de padrão [10].

### 3.1 – ANÁLISE DE PADRÕES-GRADIENTES

A técnica GPA permite caracterizar regimes complexos, como intermitência e turbulência, durante a formação e evolução de padrões espaço-temporais em sistemas não-lineares. A técnica baseia-se na aplicação de operadores computacionais que quantificam quebras de simetria e desordem de fase em escalas locais e globais de um dado padrão espaço-temporal [5].

A Análise de Padrões-gradientes analisa padrões espacialmente gerados em duas dimensões (x, y) e é representado pela matriz das amplitudes:

$M = L^{\ell \times \ell} \{M(1, 1), \dots, M(i, j), \dots, M(\ell, \ell) \mid i, j \in I \text{ e } M \in \mathfrak{R}\}$ . Essencialmente é uma grade quadrada, L, com as dimensões espaciais, x e y, estando discretizadas em  $\ell \times \ell$  pixels, com  $i = 1, \dots, \ell$  e  $j = 1, \dots, \ell$ . Assim, uma sucessão dinâmica de N grades,  $L_0, L_1, \dots, L_N$  está relacionada à visualização da evolução temporal de um envelope de amplitude  $M_{x,y,t} \equiv \varepsilon(x; y; t)$ .

Dentro do formalismo GPA, um campo vetorial gradiente  $G_t = \nabla[\varepsilon(x,y)]_t$ , composto por V vetores r, onde cada vetor  $r_{i,j}$ , localizado na posição (i,j) do campo gradiente, caracterizado por sua norma e fase ( $r_{i,j} = (r, \varphi)$ ), pode ser descrito pela composição de quatro momentos gradientes: o momento gradiente de primeira ordem,  $g_1$ , uma medida global da distribuição de todos os vetores, isto é, de todas as normas e suas respectivas fases localizadas no campo gradiente, o momento gradiente de segunda ordem,  $g_2$ , que calcula a desordem existente no módulo dos vetores, o momento gradiente de terceira ordem,  $g_3$ , que calcula a desordem existente na fase dos vetores e o quarto momento,  $g_4$ , que é a medida global da norma dos vetores e da fase dos vetores. Esses momentos estão apresentados graficamente na figura 6.

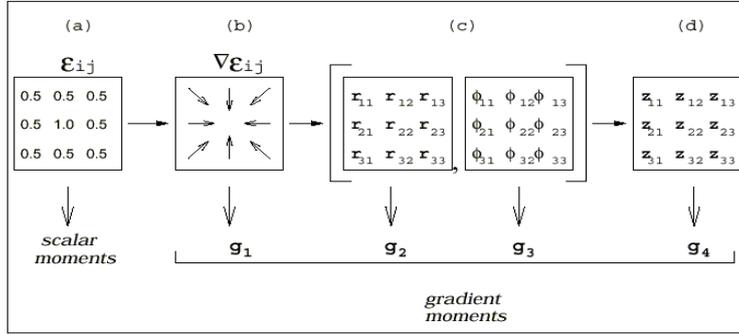


Figura 6: Momentos dos Gradientes: (a) Momento escalar, (b) Momento gradiente de primeira ordem, (c) Momentos gradiente de desordem e (d) Momento da medida global da norma e da fase.

A medida de quebras de simetrias do campo gradiente,  $F_A$ , relacionada a par de medidas ( $|g_4|$ ,  $\Phi g_4$ ) pode ser obtida por meio do operador computacional  $F_A$  [4], que mede o grau de fragmentação assimétrica das amplitudes. Padrões bidimensionais sem fragmentação ou padrões fragmentados com simetria total possuem  $F_A$  nulo (não há desordem na distribuição). Este operador computacionalmente gera uma medida da assimetria global do padrão espaço-temporal, quantificando, no tempo, as possíveis quebras de simetria. O operador  $F_A$  é especialmente caracterizado pela não-linearidade e é definido por:

$$F_A = \frac{I-L}{L} \quad (I \geq L > 0) \quad (1)$$

Onde  $L$  é o número de vetores assimétricos e  $I$  o número de barras de correlação gerado pela triangulação de Delaunay tomando um ponto local de cada vetor assimétrico como vértice.

A triangulação de Delaunay  $T_D(L, I)$ , neste contexto, é um campo fracionário com dimensão menor que a dimensão da grade (igual a 2). Quando não há nenhuma correlação assimétrica no padrão, o número total de vetores assimétricos é zero, e então, por definição,  $F_A$  é nulo. Para uma determinada grade de tamanho  $\ell \times \ell$ , o padrão totalmente desordenado gera o mais alto valor para  $F_A$ , padrões conectivos compostos por estruturas em forma de rolos e labirintos, por exemplo, apresentam valores específicos não-nulos para  $F_A$  [5].

### Análise de Padrões de Gradientes de Séries Temporais (GPA1D)

A análise de série temporais é um procedimento estatístico em que os dados das séries são considerados como parte de um processo estocástico. As propriedades estatísticas de séries temporais podem ser usadas para determinar as similaridades e as diferenças entre grupos de dados distintos. A fim explorar uma maneira mais eficiente de caracterizar

padrões de variabilidade em séries temporais curtas e não estacionárias, tem sido utilizado um operador do GPA.

Para aplicar o GPA às séries temporais é necessária uma etapa preliminar, que é converter uma seqüência de pontos de dados da série em uma seqüência de padrões-gradientes.

Dados experimentais consistem tipicamente em medidas discretas de um único observador  $X(t) = \{X(t_1), \dots, X(t_i), \dots, X(t_n)\}$ , cuja definição de tempo é dada por  $\tau = t_{i+1} - t_i$ . Para uma notação mais conveniente, escreve-se a série de tempo discreta como  $X(t) = \{X_1, \dots, X_i, \dots, X_n\}$  com  $X_i \in \mathbb{R}$ .

Para aplicar o GPA converte-se  $X(t)$  em uma seqüência de  $\ell \times \ell$  matrizes, com a condição  $\ell \geq 3$ . O comprimento da variabilidade temporal ( $\Upsilon$ ) é dado por  $\Upsilon = (\ell^2 - 1)\tau$ . Note que a definição temporal mais elevada da variabilidade é obtida agrupando os dados em uma fileira de  $3 \times 3$  matrizes. Este caso elementar, nós chamamos  $(9-1)\tau$  padrão de variabilidade. Assim, cada seqüência de nove pontos da série de tempo dada produz a matriz  $M_{X_9}$ :

$$\begin{pmatrix} X_{11}^i & X_{12}^{i+1} & X_{13}^{i+2} \\ X_{21}^{i+3} & X_{22}^{i+4} & X_{23}^{i+5} \\ X_{31}^{i+6} & X_{32}^{i+7} & X_{33}^{i+8} \end{pmatrix}$$

O campo gradiente  $\nabla M_{X_9}$  é composto por nove vetores e especifica quantitativamente as variações em um dado ponto. É o indicador quantitativo apropriado das mudanças na distribuição destes máximos, ou seja, um indicador do padrão da variabilidade. Nesta aproximação, os valores relativos em vez dos valores absolutos da amplitude na matriz são dinamicamente relevantes.

A distribuição espacial dos vetores no campo gradiente  $\nabla M_{X_9}$  conterà muitos vetores com a mesma magnitude, com uma pequena tolerância, e estas formarão pares simétricos se tiverem orientações opostas, caso contrário, formarão pares assimétricos. Após ter removido todos os pares de vetores simétricos, o número de vetores assimétricos são denominados L. Qualquer quebra de simetria pode ser quantificada conectando-se os pontos médios dos vetores L com as linhas retas I, gerando o campo de *triangulação de Delaunay*  $T_D(L, I)$ . Os únicos valores possíveis para o parâmetro  $F_A$ , calculados de  $\nabla M_{X_9}$ , são restringidos ao domínio discreto  $D_9$  composto por:  $\{0.778; 0.889; 1.000; 1.111; 1.222; 1.333\}$ , o que pode ser provado por considerações geométricas [6]. Uma característica importante do primeiro momento gradiente é a sua alta sensibilidade para detectar pequenas modificações na variabilidade de um sinal que, em geral, não são detectadas por outras técnicas usuais.

## Descrição simplificada de GPA

O Operador de Fragmentação Assimétrica é uma técnica eficiente para caracterizar padrões de variabilidade espacial e faz parte do método de análise de padrões dos campos gradientes. O pressuposto adotado no desenvolvimento do GPA é o de que a complexidade de um padrão espacial é caracterizada pela sua falta de simetria e pelo seu grau de fragmentação. Essas propriedades do padrão (falta de simetria e fragmentação) podem ser resumidas no Operador de Fragmentação Assimétrica ( $F_A$ ). Padrões simétricos apresentam valores de  $F_A$  iguais ou próximos a zero. A partir da análise de aproximadamente 200 simulações de padrões, concluiu-se que o aumento de  $F_A$  corresponde a um aumento da quantidade e da extensão de contornos e de estruturas finas em diferentes padrões. A Figura 7 ilustra os resultados das simulações, onde se pode observar que à medida que o padrão espacial se torna mais complexo e que há um aumento da variabilidade de pequena escala, o valor de  $F_A$  aumenta. Este operador ( $F_A$ ) propicia uma investigação da complexidade espaço-temporal contida na série espaço-temporal.

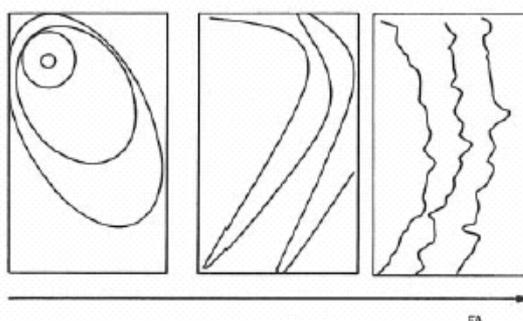


Figura 7: Resposta teórica do  $F_A$  à complexidade do padrão espacial

A técnica GPA foi originalmente desenvolvida para operar com matrizes. Tal técnica foi adaptada possibilitando a aplicação em séries espaço-temporais unidimensionais. Por não se basear em propriedades estatísticas da série, mas somente nas propriedades locais das simetrias do padrão gradiente, o método apresenta a importante propriedade de ser menos dependente do comprimento da série, quando comparado às técnicas estatísticas convencionais. Isto abre a possibilidade ao método de localizar, ao longo de entornos, quais são as regiões com maior complexidade morfométrica.

A análise baseada no Fator de Assimetria ( $F_A$ ) do padrão de gradientes consiste em gerar campos vetoriais, a partir de matrizes numéricas (Fig. 8). Por conveniência metodológica aplicada às estruturas complexas, os vetores simétricos são removidos e, portanto apenas os vetores assimétricos são mantidos. Pela análise da Figura 8 percebe-se que, embora a matriz relativa a Figura 8(c) corresponda a um processo mais complexo (mais irregular) quando comparado ao apresentado na Figura 8(b), a simples comparação entre o número de vetores oriundos do campo gradiente ( $V$ ) e o número de vetores assimétricos ( $L$ ) não permitiria uma separabilidade dos diferentes processos representados

por estas matrizes. Devido a isto, há necessidade de uma segunda operação que permita distinguir entre estes campos gradientes.

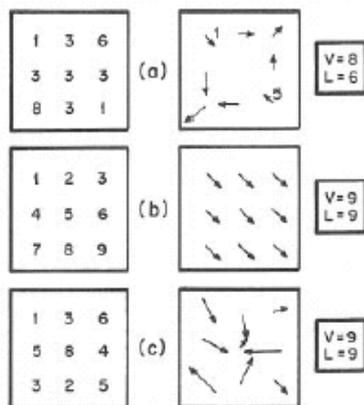


Figura 8: Matrizes representativas de campos vetoriais assimétricos. (a) 6 vetores assimétricos, (b) e (c) todos os vetores são assimétricos.

Dada uma distribuição cartesiana  $P$  com  $p$  pontos, o processo de união destes pontos através de linhas usando como critério à necessidade dos vértices dos triângulos resultantes estarem sempre em conexão com estes pontos é conhecido como Triangulação de Delaunay. Também faz parte do critério o não cruzamento das linhas que unem os pontos (Fig. 9). Note que agora é possível distinguir as matrizes, mesmo estas tendo iguais valores de  $V$  e  $L$ . O número de linhas ( $I$ ) utilizado para unir, via triangulação de Delaunay, os centros de cada vetor, é diferente. Portanto, com a quantidade  $I$  é possível distinguir diferentes matrizes quanto a sua correspondência em termos de complexidade, já que  $I$  é diretamente proporcional ao nível de desordem espacial (complexidade) do campo gradiente (fórmula 1).

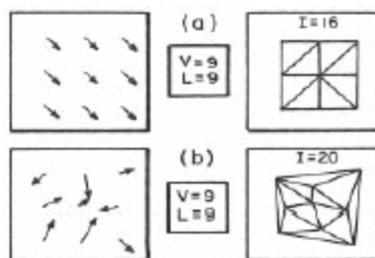


Figura 9: Campo de triangulação para (b) e (c) da figura 12.

Como esta técnica foi originalmente desenvolvida para tratar campos bidimensionais representados através de matrizes numéricas. Com o intuito de estender as aplicações do método para séries unidimensionais, foi feita a seguinte adaptação: cada nove

pontos da série são convertidos em uma matriz 3x3 e o método é, desta forma, aplicado ao longo da série. Um valor médio, considerando cada um dos  $F_{AS}$  obtidos ao longo da série é gerado. A figura 10 exemplifica o método. Um exemplo de uma série unidimensional com nove pontos (Fig.10a) que é convertida em uma matriz 3x3 (Fig. 10b) e finalmente os campos de gradiente e de triangulação são gerados (Figs. 10c e 10d, respectivamente). A escolha de se utilizar matrizes 3x3 deve-se à possibilidade das análises serem feitas na melhor janela de resolução e sem comprometimento da robustez do método.

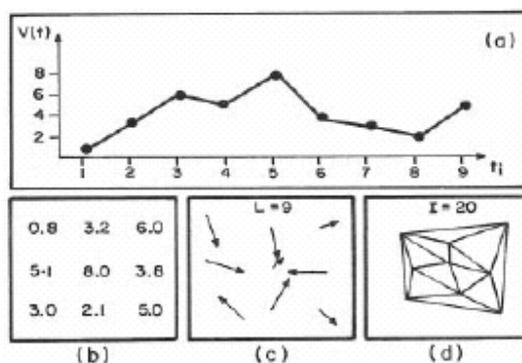


Figura 10: (a) Típico padrão de variabilidade, (b) Matriz correspondente, (c) Campo gradiente correspondente (9 vetores assimétricos), (d) Campo de triangulação com 20 linhas conectoras.

### 3.2 - ESTUDO COMPLEMENTAR POR TRANSFORMADA DE WAVELETS

Atualmente, o estudo de sinais não-estacionários exige abordagens matemáticas robustas de análise para poder compreender os fenômenos físicos que estão agindo em qualquer sistema natural. Uma destas ferramentas é a Transformada de Wavelets, capaz de analisar séries-temporais obtidas de qualquer sistema físico. A Transformada de Wavelets tem sido aplicada nas mais diversas áreas do conhecimento, desde estudos sobre turbulência atmosférica, processamento de sinais até sistemas hidrológicos. O uso desta ferramenta se faz necessário devido ao fato de que as séries-temporais tomadas de qualquer sistema físico possuem características não-estacionárias. Entenda-se como característica não-estacionária as séries-temporais cujo seus momentos estatísticos, média, variância, e etc, variam em qualquer segmento tomado desta série [14].

A análise com Wavelets tem se tornado uma ferramenta comum na análise de variações locais de potencia em series temporais. Através da decomposição de uma série temporal em espaço tempo-frequência, é possível determinar os modos dominantes de variabilidade e como esses modos variam no tempo [12].

Wavelets são nada mais que ondas pequenas (ondeletes, em francês) com determinadas propriedades que as tornam adequadas a servirem de base para decomposição de outras funções. São funções que satisfazem a certos requisitos matemáticos e são usadas na representação de dados ou de outras funções. Elas utilizam a idéia de aproximação

usando a superposição de funções. Esta idéia tem sua origem no trabalho de Joseph Fourier, que no século XIX descobriu que poderia utilizar senos e cossenos para representar outras funções [11].

A transformada de Fourier, o método mais comumente usado para analisar variabilidade, não oferece uma avaliação fácil desta dinâmica devido à limitação inerente da sua hipótese de estacionaridade. Por outro lado, a transformada de wavelets permite a análise de sinais não estacionários [18].

A novidade em relação a Fourier é que a análise em wavelets não é feita segundo a frequência, mas sim segundo a escala. Os algoritmos wavelet processam dados em diferentes escalas e resoluções, permitindo que seja visto tanto o global quanto os detalhes.

Em análises wavelet, um sinal é dividido em aproximação e detalhe. Esta aproximação é então dividida em uma aproximação de segundo-nível e detalhe, e o processo se repete. Para uma decomposição de nível-n, há  $n + 1$  caminhos possíveis para decompor ou codificar o sinal [12].

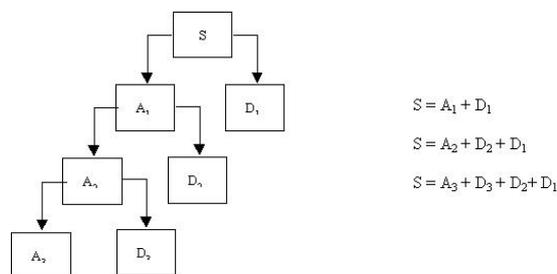


Figura 11: Árvore da análise wavelet.

Uma das vantagens básicas no uso de wavelets é que um evento pode ser simultaneamente descrito, tanto no domínio da frequência quanto no domínio do tempo, diferentemente da Transformada de Fourier onde um evento é descrito somente no domínio da frequência ou no domínio do tempo. Esta diferença permite uma análise em multiresolução dos dados de diferentes maneiras, em diferentes escalas. Uma extensa classe de sinais biológicos pode ser analisada por este método, tal como o ECG. A escolha de uma determinada função wavelet é influenciada pelos seguintes fatores:

1. ortogonalidade e não-ortogonalidade: em uma análise, a wavelet ortogonal produz um espectro wavelet que contém blocos discretos de wavelets, utilizadas no processamento de sinais por ser capaz de obter uma representação mais compacta do mesmo. Desafortunadamente, se numa análise de uma série temporal ocorrer um salto não periódico na amostra, obtém-se um espectro wavelet diferente. No entanto, em uma análise wavelet não-ortogonal, obtém-se uma redundância de larga escala em momentos temporais adjacentes, que são altamente correlacionados. Sua utilização é indicada em casos em que suaves variações contínuas são esperadas na wavelet.

2. complexa ou real: uma função wavelet complexa retornará informações sobre amplitude e fase e é mais bem adaptada para desempenhar a captura de comportamentos oscilatórios.

3. extensão: a extensão de uma função wavelet é um desdobramento do tempo da amplitude de uma wavelet. A resolução de uma função wavelet é definida pelo balanço entre a extensão no espaço real e a extensão no espaço de Fourier. Uma função estreita obtém uma boa resolução no tempo, porém uma insatisfatória resolução na frequência, enquanto que em uma função larga ocorrerá o inverso, uma boa resolução na frequência e uma deficiente resolução no tempo.

4. Figura: a função wavelet irá refletir o tipo das características contidas em uma dada série temporal. Em séries temporais onde há saltos de formas ou passos, indica-se à utilização de funções tais como as de Haar.

As wavelets são projetadas para obter em altas frequências, uma boa resolução no tempo, mas uma fraca resolução na frequência. O mesmo não ocorre em baixas frequências, onde se obtém uma boa resolução da frequência e uma restrita resolução no tempo [10].

Wavelets podem ter caráter fractal, e terem padrões que se repetem em escalas diferentes. A análise de sinais com wavelets permite a extração de dados coerentes tanto no domínio da frequência quanto no do tempo (ou espaço, para imagens). [11]

A idéia central da análise em ondeletas consiste em decompor um sinal a diferentes níveis de resolução, processo conhecido como Multiresolução. A representação de multiresolução fornece uma moldura hierárquica simples para interpretação de informação do sinal. A diferentes resoluções, os detalhes de um sinal geralmente caracterizam diferentes estruturas físicas do mesmo. A uma resolução mais grosseira, estes detalhes geralmente caracterizam as grandes estruturas que fornecem o contexto. Com o aumento da resolução, obtemos detalhes mais finos. O processo de decomposição ocorre da seguinte maneira. Considere inicialmente uma função  $f$  contida no espaço das funções quadraticamente integráveis  $L_2(\mathbb{R})$ . Portanto, a energia da função  $f$  é limitada ao longo de todo o eixo dos reais, isto é:

$$\int_{-\infty}^{+\infty} |f(t)|^2 dt < \infty. \quad (2)$$

O produto escalar ou produto interno, denotado pelo símbolo  $(\bullet)$ , e a norma para o espaço  $L_2(\mathbb{R})$  são definidos como se segue:

$$f \bullet g = \int_{-\infty}^{+\infty} f(t) \cdot g(t) dt \quad (3)$$

e

$$|f| = \sqrt{f \bullet f}. \quad (4)$$

Se a função  $g$  possuir norma unitária, então o resultado do produto escalar entre  $f$  e  $g$  corresponderá à operação de projeção de  $f$  sobre  $g$ . Considere, agora, um conjunto de funções ortonormais  $\psi_k(t)$ ,  $k \in \mathbb{N}$ , ou seja, ortogonais e de módulo 1, formando uma base para o espaço  $L_2(\mathbb{R})$ . Pela condição de ortogonalidade:

$$\Psi_m \cdot \Psi_n = 0, \quad (5)$$

para todo  $m$  diferente de  $n$ .

Definimos então a expansão da função  $f$  em uma série ortonormal como sendo a combinação linear das funções base ponderadas pelas projeções de  $f$  sobre cada uma delas, isto é,

$$f(t) = \sum_{k=-\infty}^{\infty} \langle f, \Psi_k \rangle \Psi_k(t), \quad (6)$$

fazendo  $F(k) = \langle f, \psi_k \rangle$ ,  $k \in \mathbb{N}$ , e  $\langle f, \psi_k \rangle = f \cdot \psi_k$  é uma outra forma de expressar o produto interno ou escalar.

$$f(t) = \sum_{k=-\infty}^{\infty} F_k \Psi_k(t), \quad (7)$$

onde  $F_k$ , define a transformada da função  $f(t)$ . Imbutido nesta abordagem está o fato da base  $\psi_k(t)$  possuir suporte igual a toda extensão do eixo real, isto é, cada função base  $\psi_k(t)$  decai a zero somente nos limites  $\pm\infty$ . No entanto, se a base possuir suporte limitado, decaindo para zero muito rapidamente, então a melhor maneira desta base cobrir todo o eixo dos reais será através de translações do tipo:

$$\Psi_{k,l}(t) = \Psi_k(t-l), \quad l \in \mathbb{N}. \quad (8)$$

Da mesma maneira, observando a base da Transformada de Fourier, pode-se constatar que cada função base (as exponenciais complexas) é obtida a partir de simples dilatações na frequência. Reunindo estas duas propriedades, dilatação e translação, em um único protótipo de função base, obtemos as chamadas funções ondeletas, onde as dilatações e as translações são dadas por duas variáveis nomeadas  $a$  e  $b$ , respectivamente. Portanto, o termo ondeleta refere-se a um conjunto de funções com forma de pequenas ondas geradas por dilatações,  $\psi(t) \rightarrow \psi(2t)$ , e translações,  $\psi(t) \rightarrow \psi(t+1)$ , de uma função base

geradora simples  $\psi(t)$ , a ondeleta-mãe. Esta deve ser quadraticamente integrável dentro de um intervalo de tempo real ou espaço  $[L2(\mathcal{R})]$ , isto é, deve apresentar energia finita [14]. A imposição de que a sua energia média seja zero, constitui a condição de admissibilidade da função:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{2}} \Psi\left(\frac{t-b}{a}\right) \quad (9)$$

de forma que a expansão em série de ondeletas e a transformada são definidas como

$$\langle f, \Psi_{a,b} \rangle = \int_{-\infty}^{+\infty} f(t) \Psi\left(\frac{t-b}{a}\right) dt. \quad (10)$$

### Tipos de Wavelets

Há dois tipos de funções wavelets, as Contínuas e as Discretas, cada qual útil para determinadas aplicações.

As ondeletas discretas são utilizadas para a decomposição e filtragem de qualquer série-temporal. A sua aplicabilidade neste aspecto advém do fato de que estas ondeletas não provocam retundâncias de coeficientes entre escalas (frequências). A ondeleta discreta mais comum é a ondeleta de Haar. A figura 12 mostra a ondeleta de Haar, onde se nota que ela é uma função escada. Por ser discreta, esta categoria de ondeletas trabalham com sinais temporais que tenham comprimentos da ordem de potência de dois mais próxima, ou seja,  $2^n = s$ , onde  $s$  é o comprimento total da série, e  $n$  é o número de frequências possíveis para a decomposição[14].

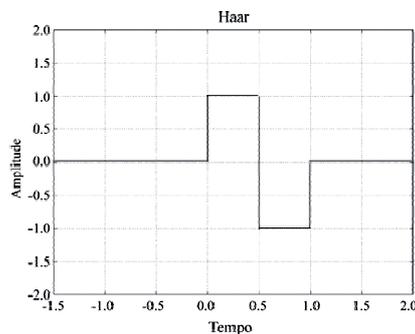


Figura 12: Ondeleta Haar

A figura 13 mostra a série-temporal decomposta nas cinco primeiras frequências do sinal original, enquanto que a figura 8 mostra o sinal de baixa frequência do sinal original. A decomposição nas últimas seis frequências corresponde aos baixos períodos de oscilação do sinal original. Também, devido à forma da ondeleta de Haar, percebe-se que estas oscilações de baixos períodos tornaram-se retangulares. Este procedimento de decomposição em várias escalas disponíveis através da Transformada em Ondeletas Discretas, permite estudar características particulares de cada frequência, ou seja, estudar fenômenos que ocorrem somente em determinadas escalas (frequências). Além disso, permite realizar filtrações passa-baixo, passa-alto ou passa-banda.

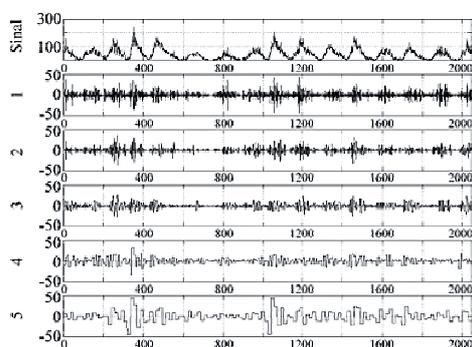


Figura 13: Decomposição do sinal original nas 5 primeiras frequências

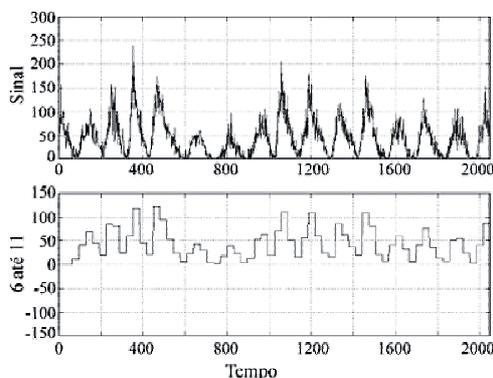


Figura 14: Decomposição do sinal original e a soma das 6 últimas frequências

As ondeletas contínuas são comumente utilizadas para visualizar, em um diagrama tridimensional, a relação existente entre as componentes de diferentes frequências em função da escala temporal do sinal estudado, onde estas relações são comumente categorizadas como não-lineares. Fisicamente, em um sistema natural qualquer, é importante tentar buscar relações entre os diversos fenômenos físicos atuantes no sistema

natural. Por isso, as ondeletas contínuas propiciam um meio matemático adequado para esta busca através do diagrama. Nesta visualização gráfica de uma série-temporal, o eixo y é dedicado a escala de frequências, o eixo x é dedicado a escala de tempo, e por fim, um terceiro eixo dedicado a intensidade de energia (comumente representado por cores em um diagrama). As ondeletas contínuas mais comuns são: a Morlet e a Chapéu Mexicano, dentre outras [7]. A figura 15 mostra ambas funções ondeletas construídas a partir de rotinas disponíveis em Matlab [14].

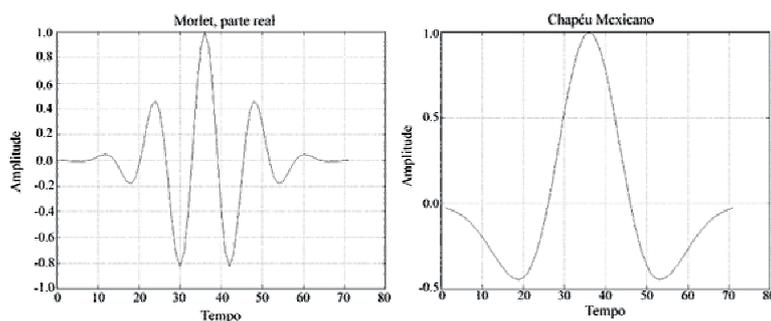


Figura 15: Funções ondeleta de Morlet e Chapéu Mexicano

A função ondeleta a ser utilizada deve possuir um formato característico próximo das características encontradas na série-temporal [14].

Existem ainda, algumas famílias de wavelets:

Haar: É a primeira e a mais simples de todas. É descontínua e equivale a Daubechies 1 (db1).

Daubechies: Compactly-supported orthonormal wavelets.

Biorotogonal: Apresenta a propriedade de fase linear, que é necessária na reconstrução de sinais e imagens. Utiliza duas wavelets, uma para decomposição e outra para reconstrução, o que gera propriedades interessantes.

Coiflets: A função wavelet possui  $2N$  momentos iguais a zero e a função escala tem  $2N-1$  momentos iguais a zero.

Symlets: São wavelets simétricas. Foi proposta como uma modificação da família Daubechies pela própria, possuindo características similares a desta família.

Morlet: Não possui função escala e é explícita.

Mexican Hat: Também não possui função escala, mas não é explícita.

Meyer: A wavelet e a função escala estão definidas no domínio de frequência.

As wavelets possuem um vasto campo de aplicações. A compressão de imagens pode ser considerada a mais conhecida das aplicações, mas existem ainda aplicações no

processamento de sinais, astronomia, acústica, engenharia nuclear, neurofisiologia, música, ótica, fractais e em aplicações matemáticas puras, como na resolução de equações diferenciais parciais [12].

### Global Wavelet Spectra (GWS)

O espectro de ondeleta global, mais conhecido por GWS é um procedimento que consiste em somar toda a energia associada a cada período ou escala  $a$ , de acordo com a Eq. 11. É uma forma similar do espectro de energia obtido via Transformada Rápida de Fourier, conhecida pela sigla FFT [14].

$$M(a) = \int |W(a,t)|^2 dt. \quad (11)$$

Se um lado vertical através de um gráfico de wavelets for uma medida do espectro local, então o espectro wavelet de tempo médio de um determinado período é:

$$\bar{W}_n^2(s) = \frac{1}{n_a} \sum_{n=n_1}^{n_2} |W_n(s)|^2 \quad (12)$$

onde o novo índice  $n$  é atribuído arbitrariamente ao ponto médio de  $n_1$  e de  $n_2$ , e  $n_a = n_2 - n_1 + 1$  é o número dos pontos calculados sobre a média. Repetindo (12) em cada etapa, uma gera um gráfico de wavelet suavizado por uma determinada janela. Um caso extremo de (12) é quando a média é o excesso todos os espectros locais de wavelet, que dá o espectro de wavelet global:

$$\bar{W}^2(s) = \frac{1}{N} \sum_{n=0}^{N-1} |W_n(s)|^2 \quad (13)$$

Na figura 16 a linha contínua espessa mostra o espectro de wavelet global normalizado,  $W^2(s)/\sigma^2$ . A linha contínua fina na figura 16 mostra um espectro suavizado com uma média de cinco pontos. Note quanto mais o espectro de Fourier é suavizado mais se aproxima do GWS, com a quantidade de suavização necessário que diminui com escala crescente.

O espectro de wavelet global fornece uma estimativa sem viés e consistente do verdadeiro espectro de potência de uma série temporal. Finalmente, sugeriu-se que GWS poderia fornecer uma medida útil do espectro de base de picos nos espectros locais.

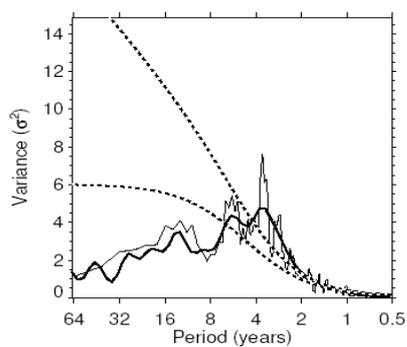


Figura 16: Comparação do Espectro de Fourier (linha contínua fina) e o Espectro de Wavelets Global (linha contínua espessa)

## **OBJETIVO**

O objetivo deste trabalho é fazer a análise de padrões-gradientes dos intervalos RR em sinais de ECG durante o repouso e liberação miofascial e usar a transformada de Wavelets como técnica complementar.

## **CAPÍTULO 4**

### **DESENVOLVIMENTO**

#### **4.1 – METODOLOGIA**

##### **1) Aquisição do sinal**

- Primeiramente obteve-se o sinal proveniente do eletrocardiograma, utilizando-se a derivação II (filtros passa-banda 0,5–100 Hz e notch de 60 Hz, frequência de amostragem 300 Hz e 12 bits de resolução).
- O sinal foi tratado pelo pacote Ergo PC Elite 13 W da Micromed, que usa um algoritmo de comparação de nível para a detecção do complexo QRS, de forma que se obteve os intervalos RR.
- A metodologia empregada refere-se ao trabalho de Ana Teresa, cujos sinais são utilizados neste trabalho [1].

##### **2) Interpolação do sinal**

Para que fosse possível aplicar Wavelets nestes sinais foi necessário interpolá-los, para isso foi utilizado o método com Splines Cúbicas.

##### **3) Análise com GPA**

- Primeiramente os sinais foram rodados em um programa em IDL que extraia os valores de  $F_A$ .
- Depois, o resultado era rodado em um programa em Matlab que gerava um espaço de fase e plotava os valores de  $F_A$  sobre a série temporal.

##### **4) Análise com Wavelets**

Os sinais interpolados foram rodados em um programa em Matlab para gerar os periodogramas e extrair os valores de  $\beta_w$ .

## 4.2 –RESULTADOS

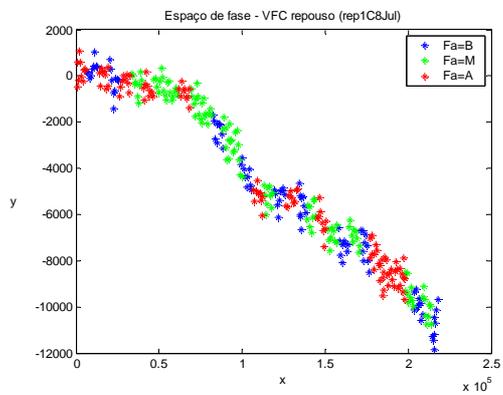
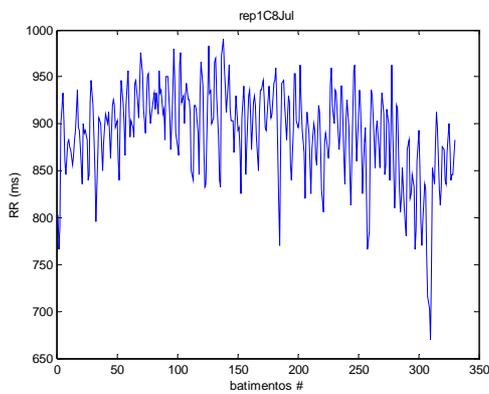
Nome	Nº de pontos	Tempo	Média	Auto-cor (1 ponto)	$\langle F_A \rangle \pm \sigma$	Análise GPA	$\beta_w$
1) rep1AC	350	297	851.469	0.685750	$1,123122 \pm 0,159028$	Turbulento	0.87265
2) tpAC	311	294	948.910	0.583781	$1,104376 \pm 0,157254$	Turbulento	-0.27484
3) pAC	341	295	870.276	0.628206	$1,03395 \pm 0,183268$	Turbulento	-0.03229
4) rep2AC	342	300	871.826	0.707332	$1,030029 \pm 0,187722$	Turbulento	-0.17995
5) rep1C8Jul	330	292	889.606	0.660319	$1,066666 \pm 0,164421$	Turbulento	0.35997
6) tpC8Jul	331	295	896.447	0.661650	$1,057142 \pm 0,133998$	Turbulento	-0.40987
7) pC8Jul	331	299	908.846	0.619270	$1,044444 \pm 0,157833$	Caótico	0.40686
8) rep2C8Jul	301	290	968.522	0.476611	$1,093749 \pm 0,164878$	Turbulento	-0.07781
9) rep1C15Jul	325	285	881.931	0.432406	$1,136506 \pm 0,172581$	Turbulento	0.19391
10) tpC15Jul	341	287	845,053	0.797561	$1,030863 \pm 0,158707$	Caótico	-0.4137
11) pC15Jul	331	288	875,517	0.810658	$1,075282 \pm 0,177048$	Turbulento	-0.31721
12)rep2C15Jul	320	293	918.803	0.639005	$1,081698 \pm 0,158104$	Turbulento	-0.18617
13) rep1Ek	340	284	837.844	0.647222	$1,049382 \pm 0,180669$	Turbulento	1.2205
14) tpEk	321	293	916.561	0.580495	$1,09477 \pm 0,157697$	Turbulento	0.14962
15) pEk	291	280	968.869	0.622432	$1,046594 \pm 0,15937$	Caótico	-0.05185
16) rep2Ek	321	283	884.692	0.463837	$1,067401 \pm 0,165161$	Turbulento	0.94288
17) rep1Gio	296	293	994.530	0.395376	$1,025089 \pm 0,175905$	Caótico	-0.19661
18) tpGio	296	287	974.456	0.552959	$1,057347 \pm 0,154523$	Caótico	0.094715

19) pGio	301	290	966.990	0.531570	$1,065971 \pm 0,180031$	Turbulento	0.37098
20) rep2Gio	301	286	955.628	0.511202	$1,013888 \pm 0,164032$	Caótico	0.12087

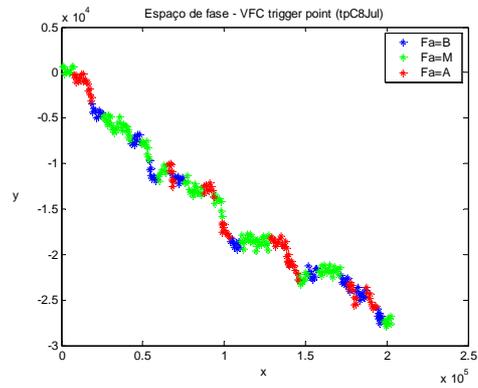
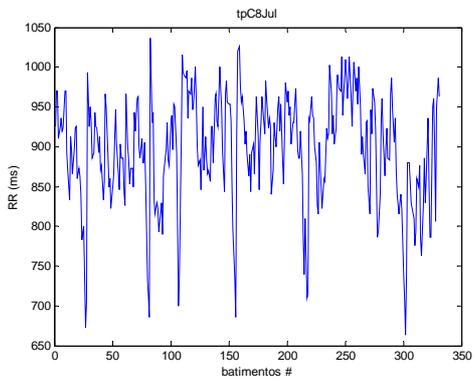
Tabela1: Tabela de dados  
(Tempo referente a duração da série interpolada)

Paciente C18Jul

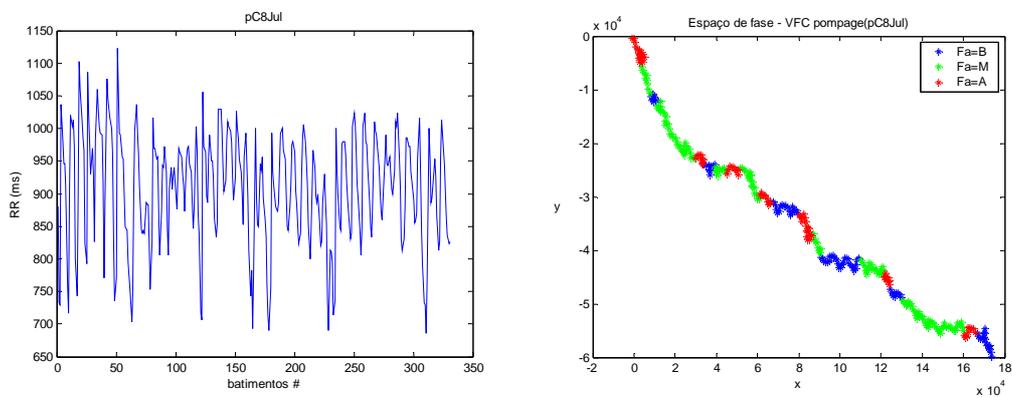
A)



B)



C)



D)

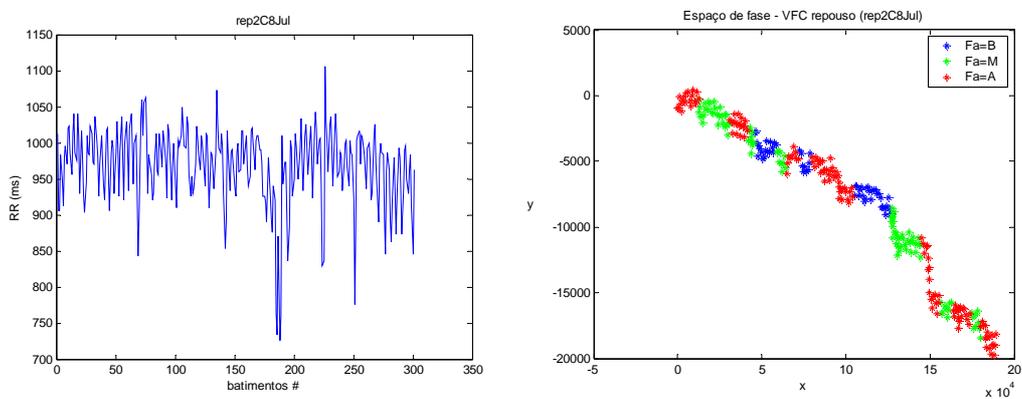


Figura 17: Séries temporais referentes ao intervalo RR e o seu respectivo gráfico de GPA Espectral do paciente denominado C8Jul: (A) repouso inicial (B) trigger point (C) pompage (D) repouso final

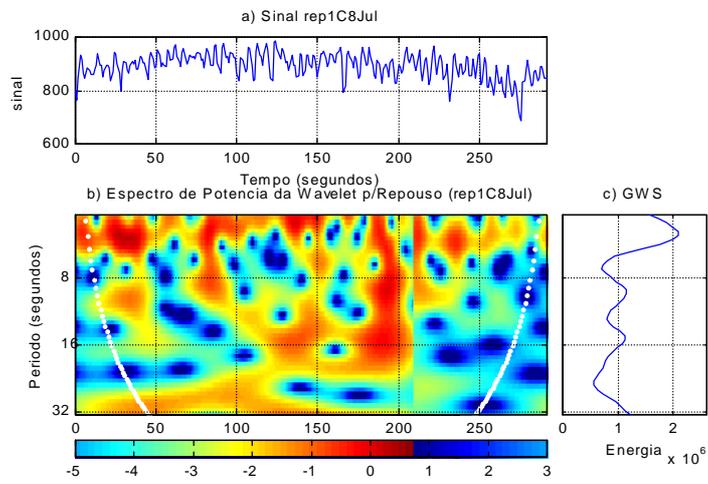


Figura 18: Periodograma referente a paciente C8Jul no repouso inicial

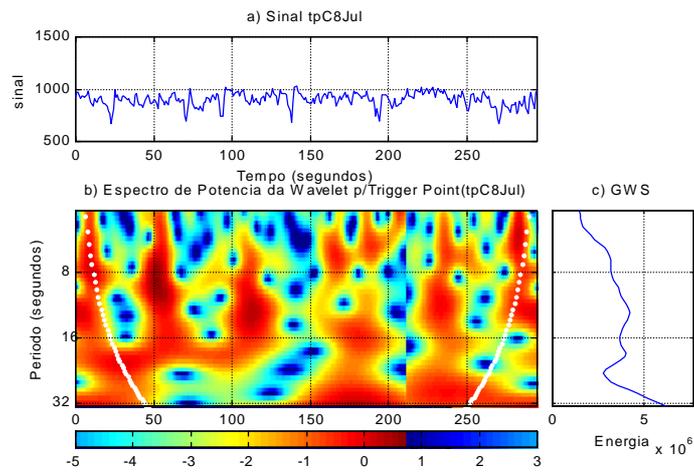


Figura 19: Periodograma referente a paciente C8Jul durante a técnica de trigger point

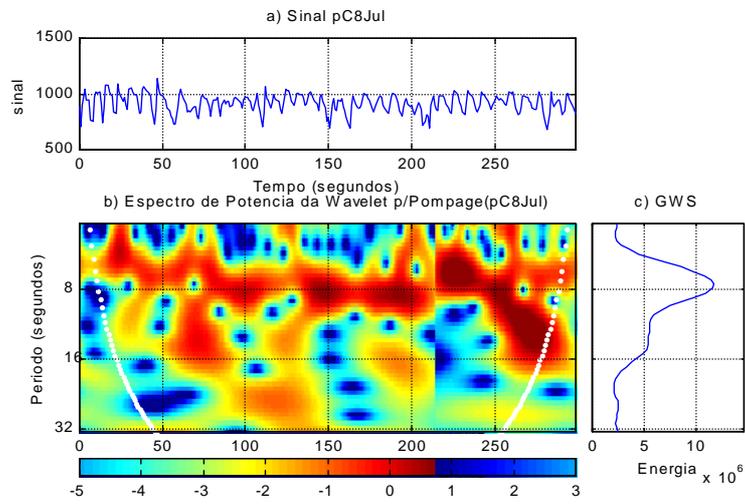


Figura 20: Periodograma referente a paciente C8Jul durante a técnica pompage

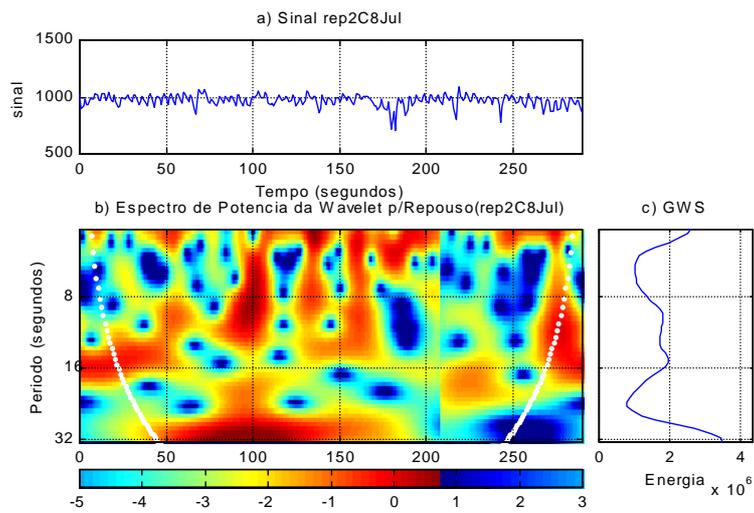
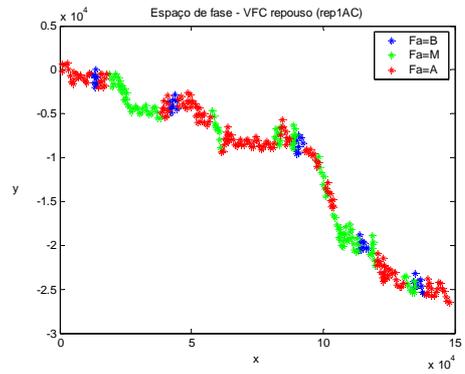
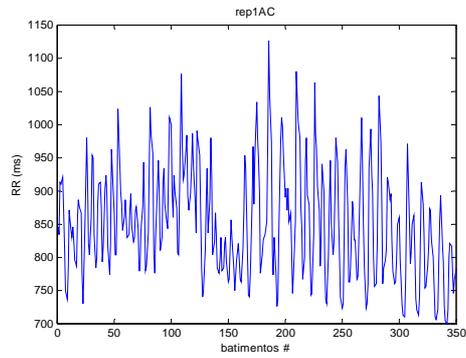


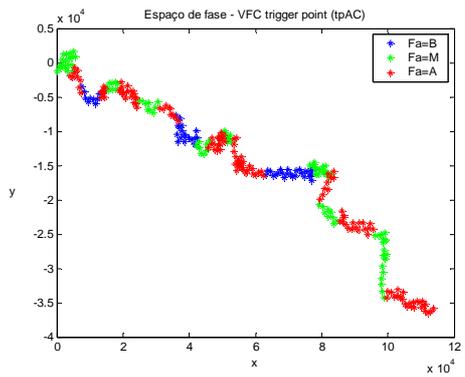
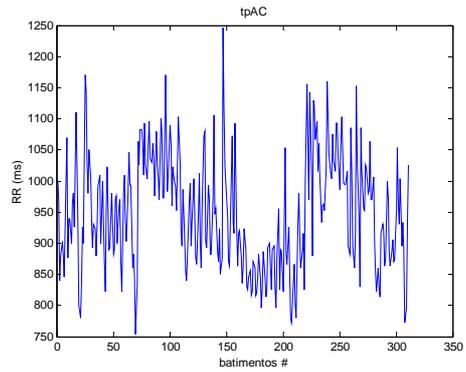
Figura 21: Periodograma referente a paciente C8Jul no repouso final

## Paciente AC

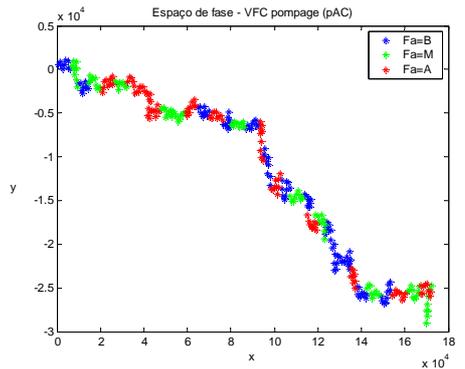
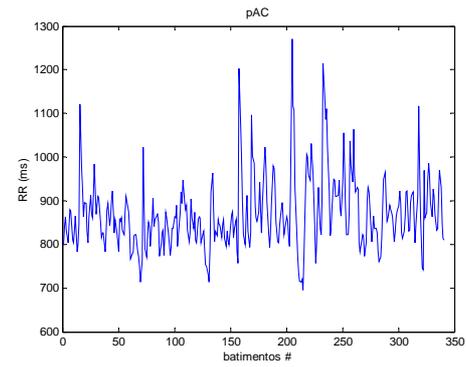
A)



B)



C)



D)

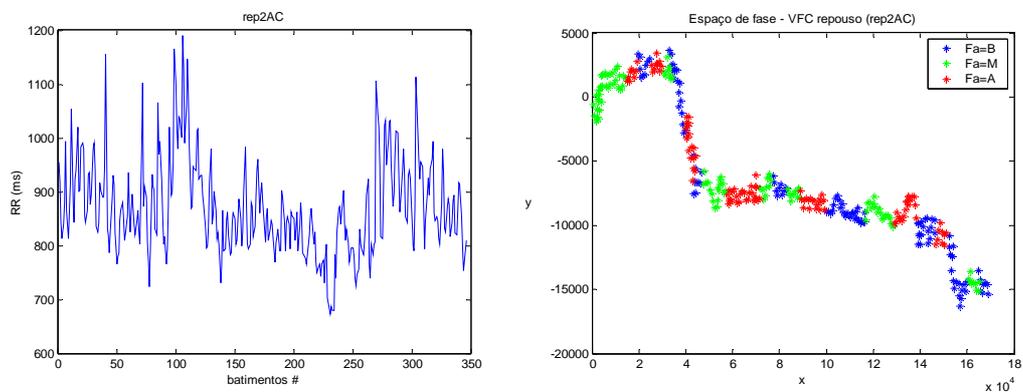


Figura 22: Séries temporais referentes ao intervalo RR e o seu respectivo gráfico de GPA Espectral do paciente denominado AC: (A) repouso inicial (B) trigger point (C) pompage (D) repouso final

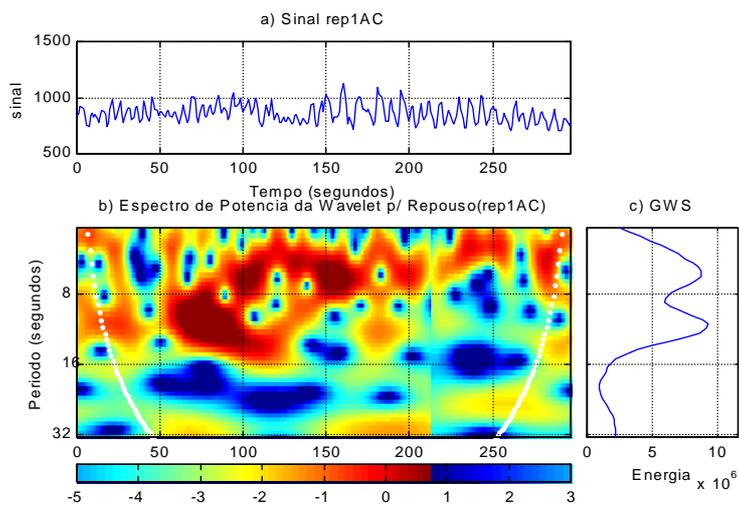


Figura 23: Periodograma referente a paciente AC no repouso inicial

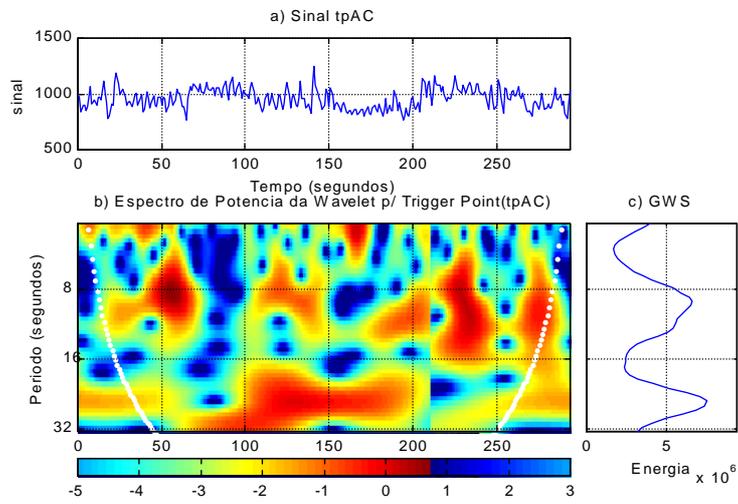


Figura 24: Periodograma referente a paciente AC durante a técnica de trigger point

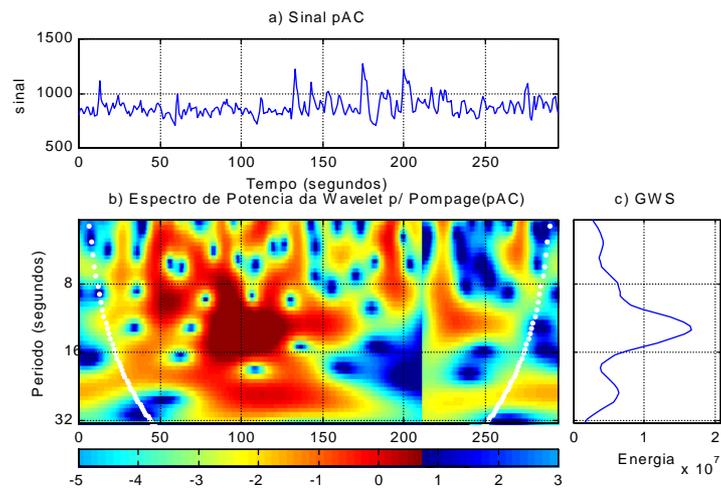


Figura 25: Periodograma referente a paciente AC durante a técnica pompage

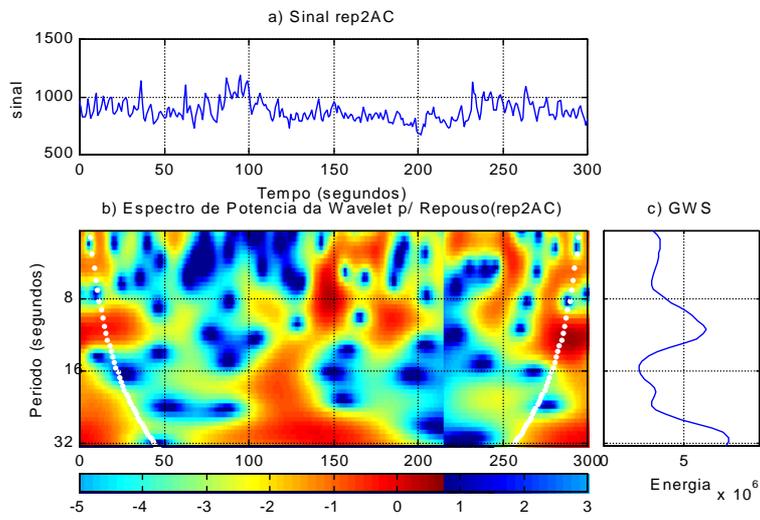
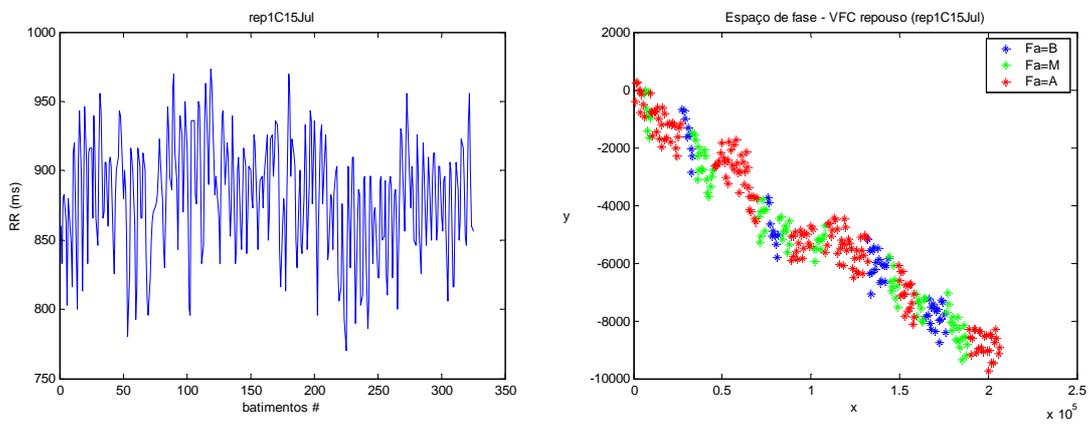


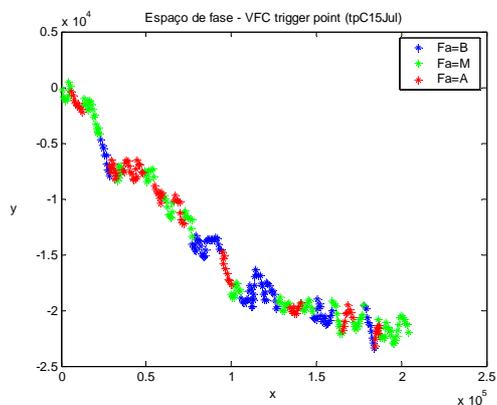
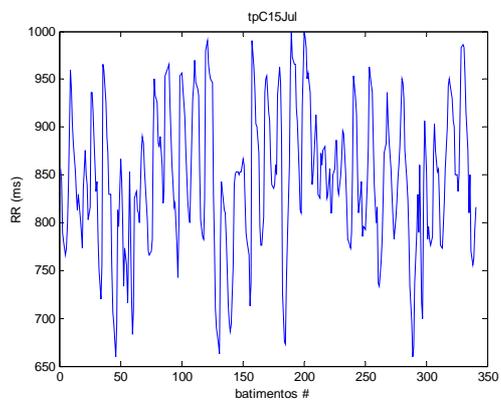
Figura 26: Periodograma referente a paciente AC no repouso final

Paciente C15Jul

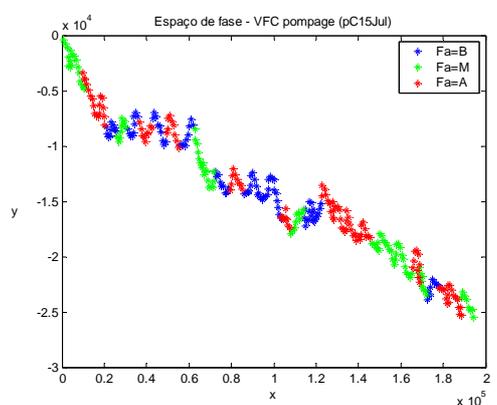
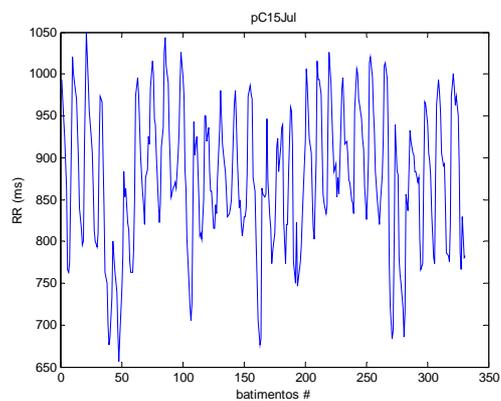
A)



B)



C)



D)

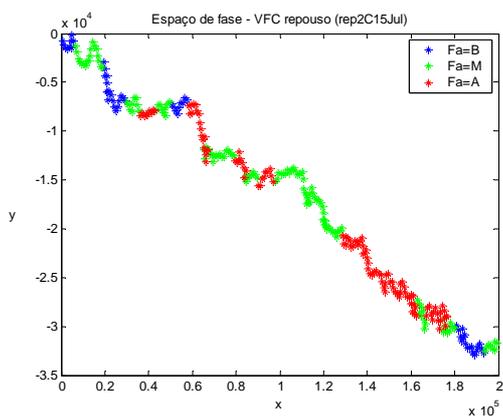
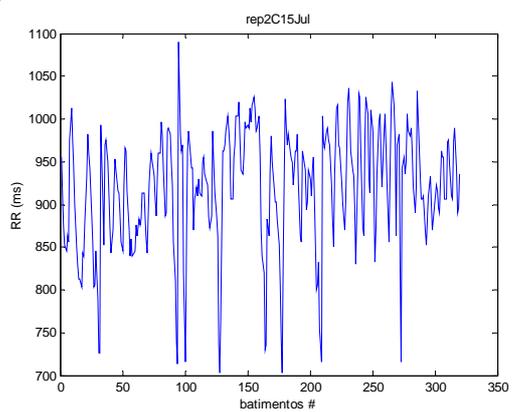


Figura 27: Séries temporais referentes ao intervalo RR e o seu respectivo gráfico de GPA Espectral do paciente denominado C15Jul: (A) repouso inicial (B) trigger point (C) pompage (D) repouso final

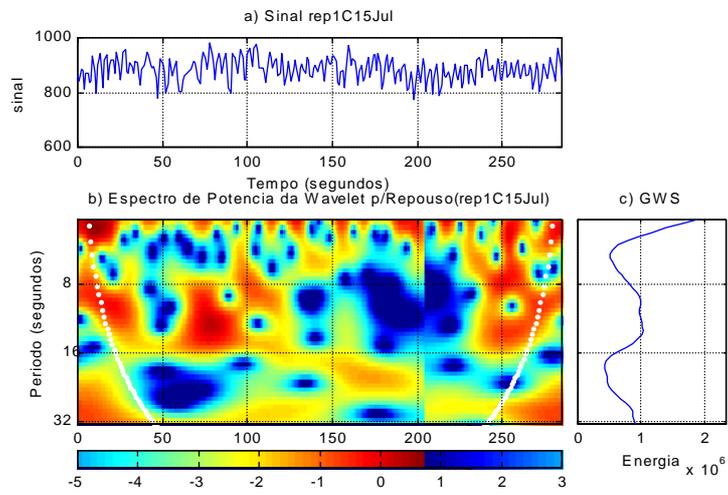


Figura 28: Periodograma referente a paciente C15Jul no repouso inicial

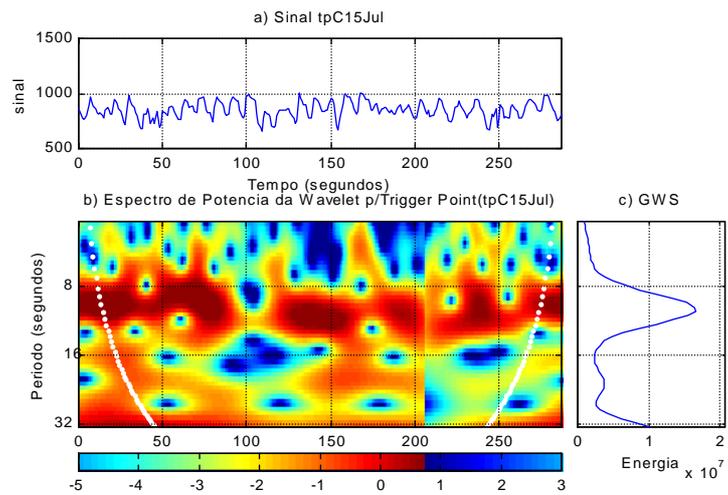


Figura 29: Periodograma referente a paciente C15Jul durante a técnica de trigger point

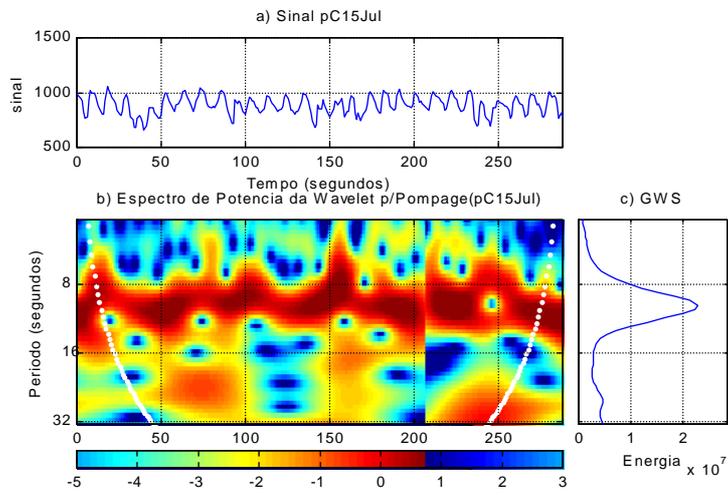


Figura 30: Periodograma referente a paciente C15Jul durante a técnica pompage

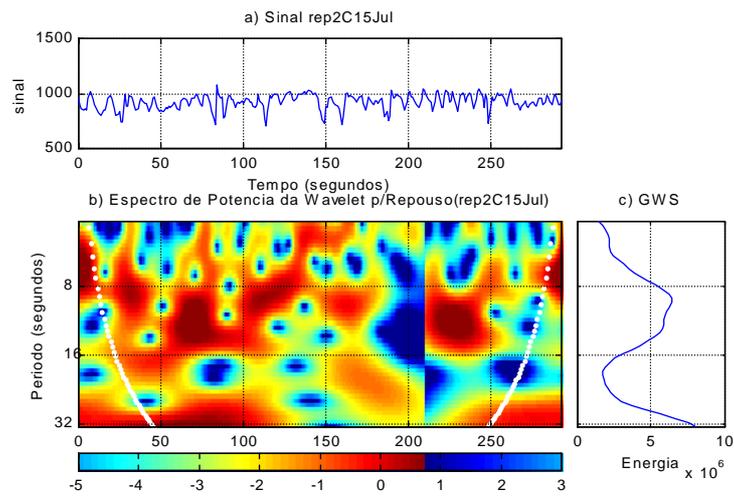
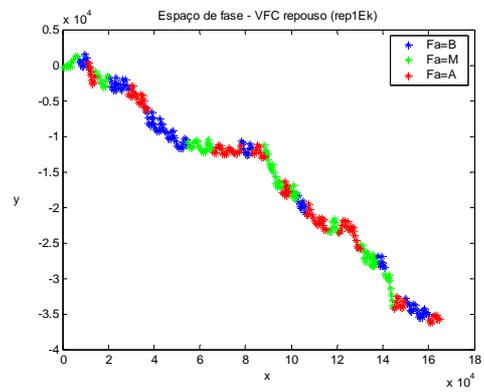
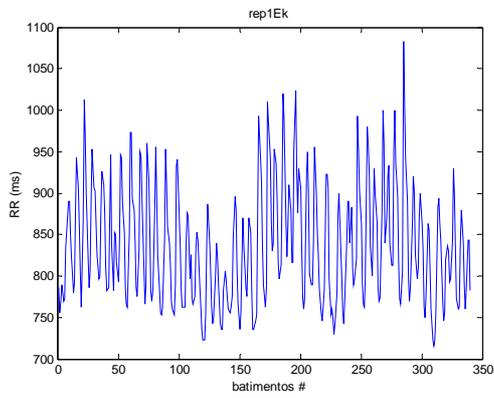


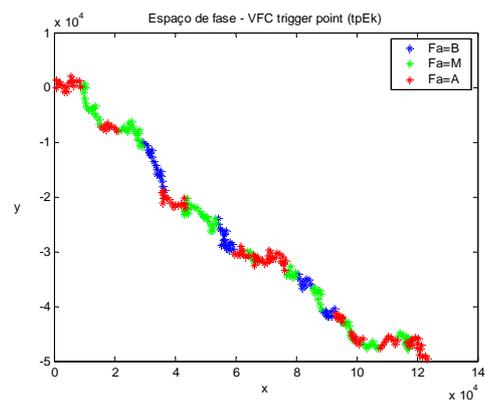
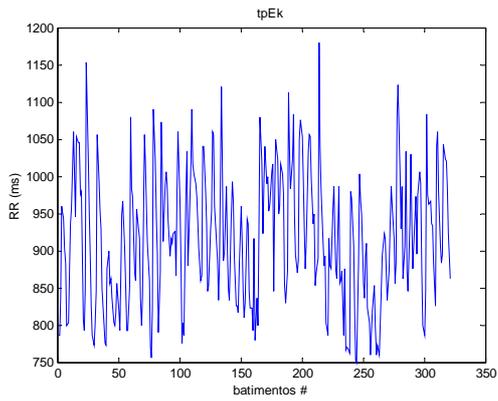
Figura 31: Periodograma referente a paciente C15Jul no repouso final

## Paciente Ek

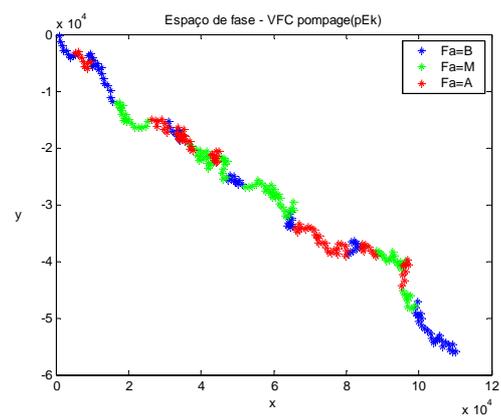
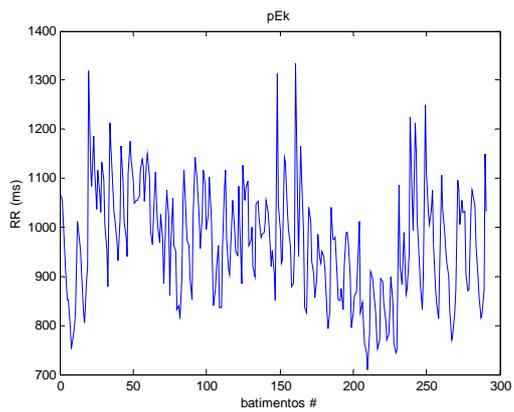
A)



B)



C)



D)

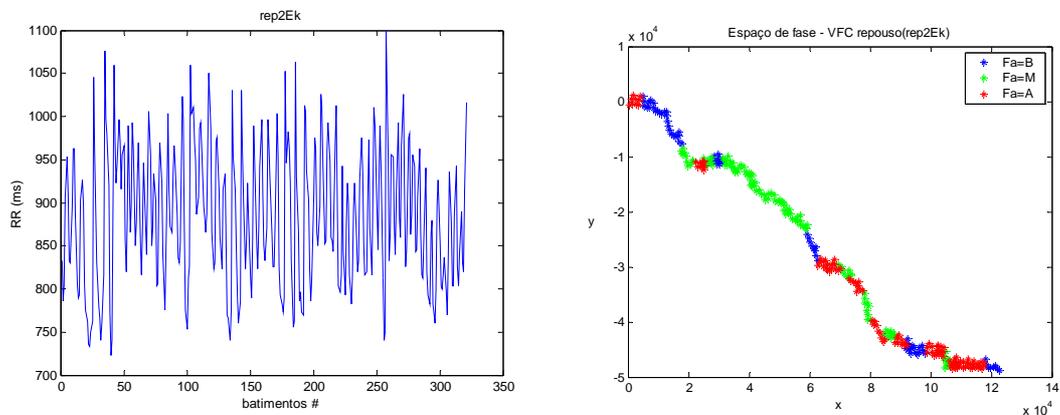


Figura 32: Séries temporais referentes ao intervalo RR e o seu respectivo gráfico de GPA Espectral do paciente denominado Ek: (A) repouso inicial (B) trigger point (C) pompage (D) repouso final

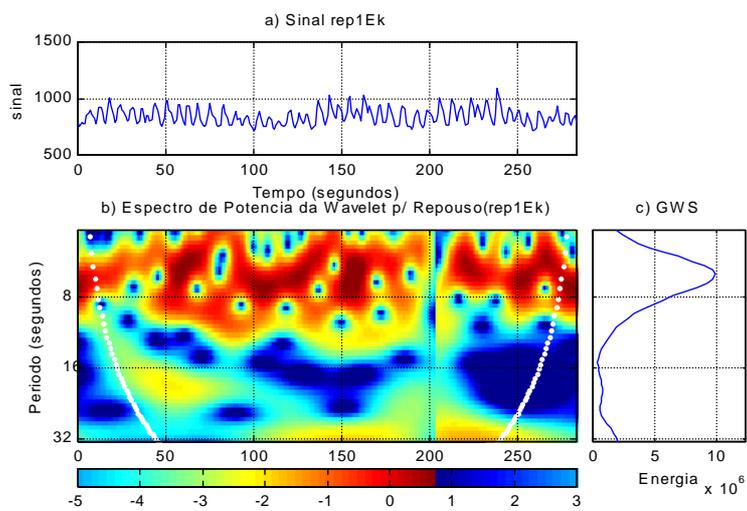


Figura 33: Periodograma referente a paciente Ek no repouso inicial

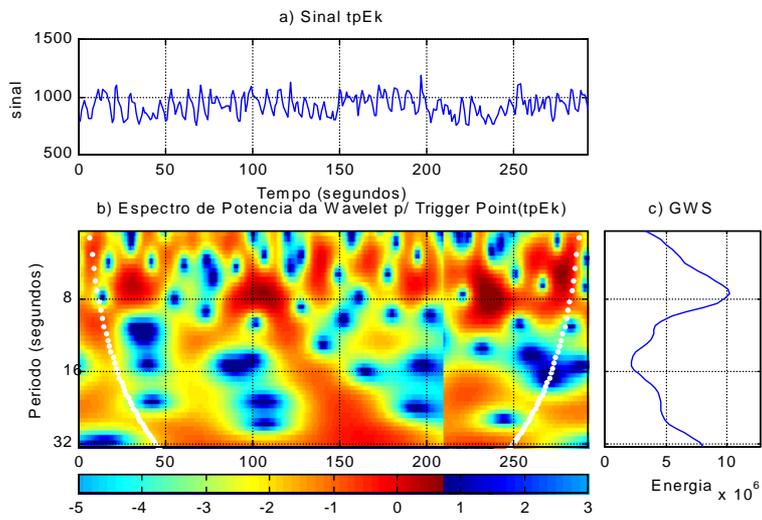


Figura 34: Periodograma referente a paciente Ek durante a técnica trigger point

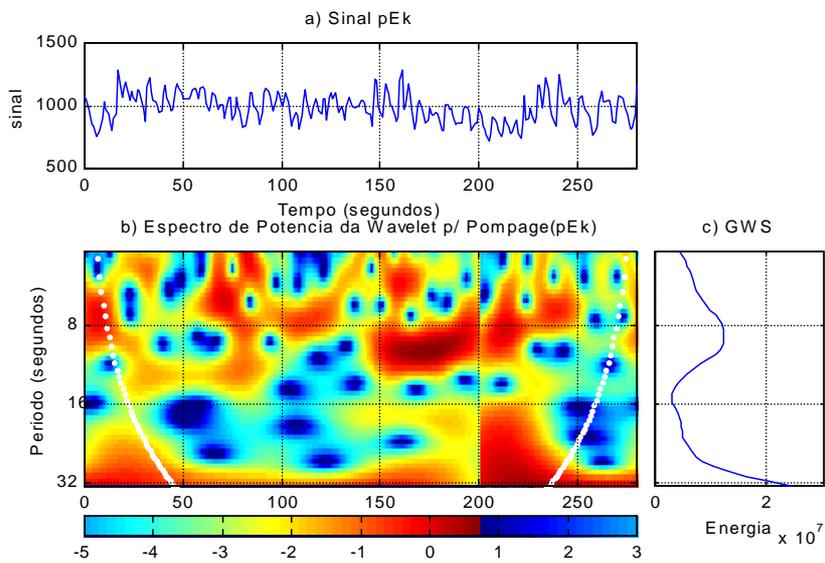


Figura 35: Periodograma referente a paciente Ek durante a técnica pompage

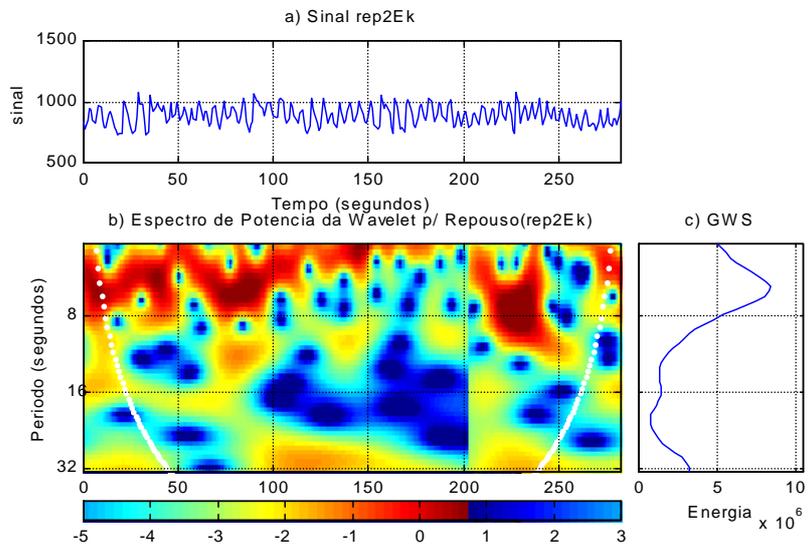
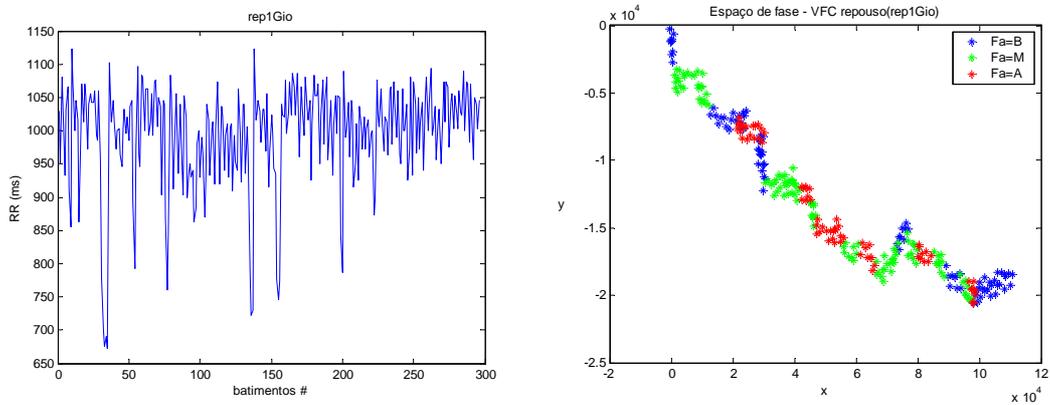


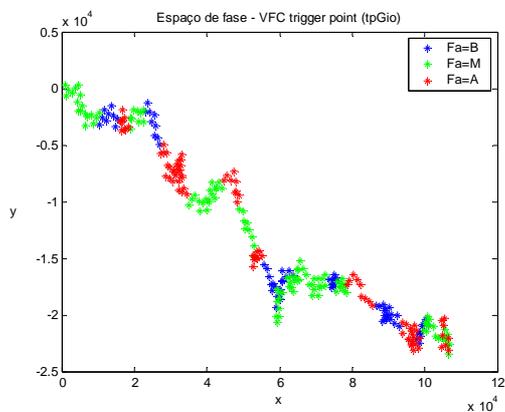
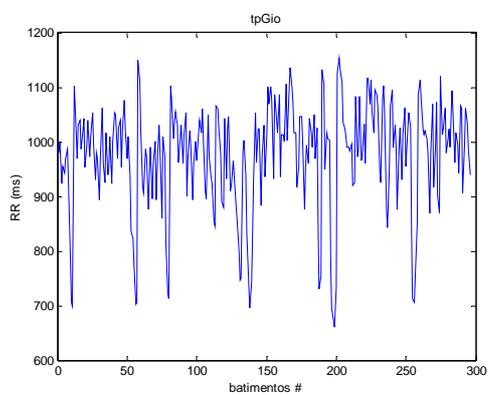
Figura 36: Periodograma referente a paciente Ek e no repouso final

Paciente Gio

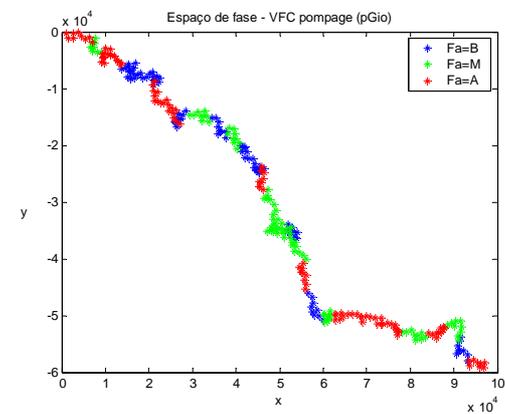
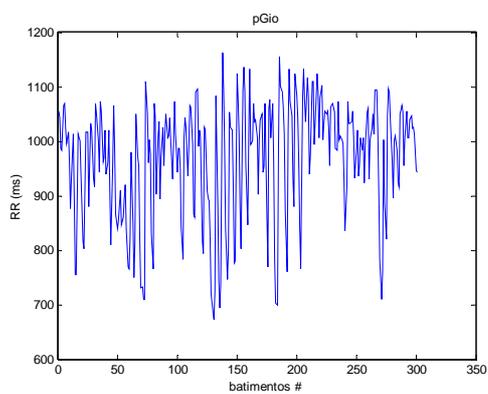
A)



B)



C)



D)

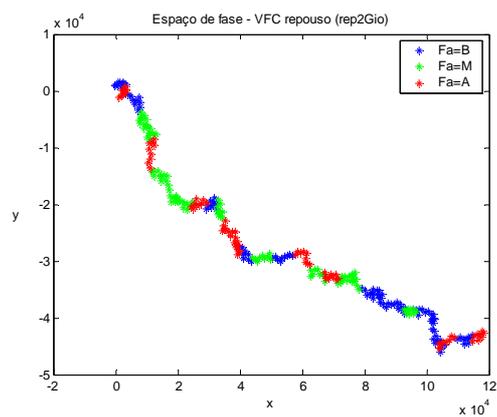
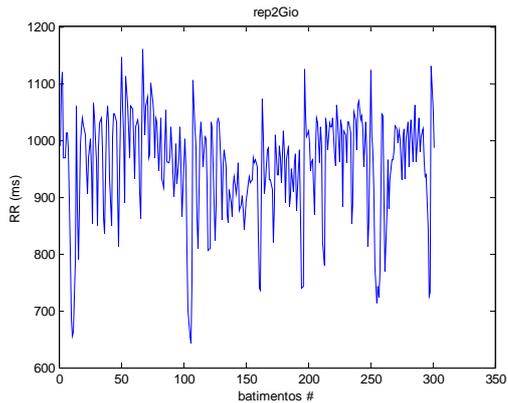


Figura 37: Séries temporais referentes ao intervalo RR e o seu respectivo gráfico de GPA Espectral do paciente denominado Gio: (A) repouso inicial (B) trigger point (C) pompage (D) repouso final

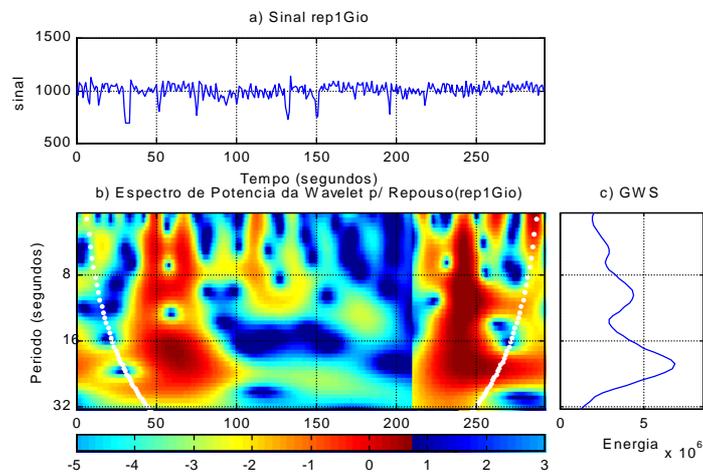


Figura 38: Periodograma referente a paciente Gio no repouso inicial

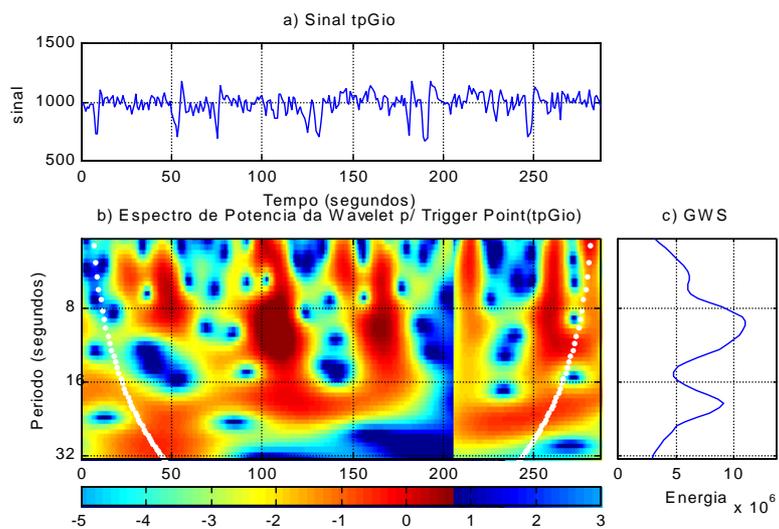


Figura 39: Periodograma referente a paciente Gio durante a técnica de trigger point

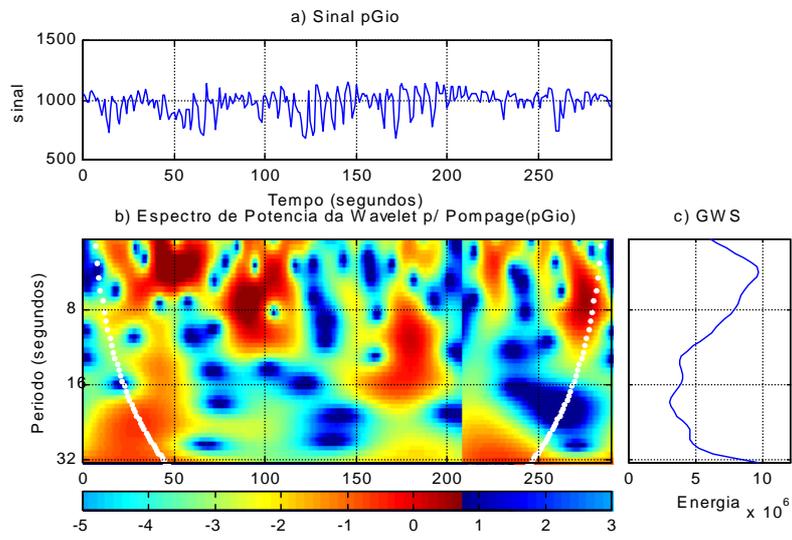


Figura 40: Periodograma referente a paciente Gio durante a técnica pompage

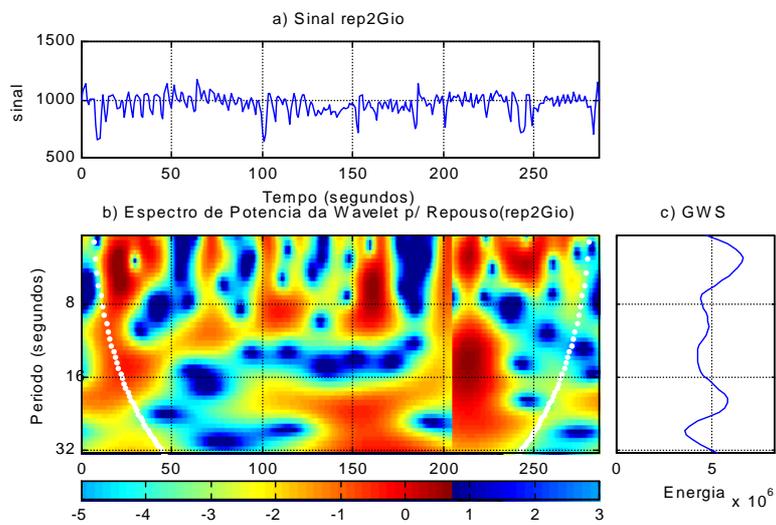


Figura 41: Periodograma referente a paciente Gio no repouso final

## CAPÍTULO 5

### DISCUSSÃO E CONCLUSÃO

Os resultados da tabela 1 indicam que a média dos intervalos RR varia em torno de 910 (837 – 994) ms, de forma que somente com índices estatísticos não é possível distinguir os sinais obtidos a partir das diferentes técnicas (repouso e liberação miofascial), não sendo possível assim caracterizar esses sinais.

Com o valor médio de  $F_A$  podemos classificar os sinais quanto a sua complexidade (variabilidade do tipo turbulenta é a mais freqüente), porém, de acordo com a tabela 1, apenas os valores das assimetrias não permitem distinguir os diferentes processos de repouso e liberação miofascial. Para isso, a técnica foi refinada (GPA1D espectral) e implementada pelo cálculo das leis de potência obtidas a partir dos espectros globais de ondeletas.

Foi realizada uma análise com GPA espectral, que consiste na sobreposição dos valores de  $F_A$  sobre a série temporal representada em um espaço de fase (Apêndice C), de forma que se torna possível investigar a trajetória do sinal e a possível presença de um atrator no sistema, além de melhorar a visualização do sinal. Esta análise preliminar nos indicou a possibilidade de distinção dos sinais, uma vez que no repouso os sinais se mostraram com regimes mais regulares e durante as técnicas de fisioterapia houve uma maior variabilidade; como visto na Paciente C8Jul, em que as escalas do eixo y para as técnicas estão em potência de  $10^4$  e para o repouso em potência de  $10^3$ .

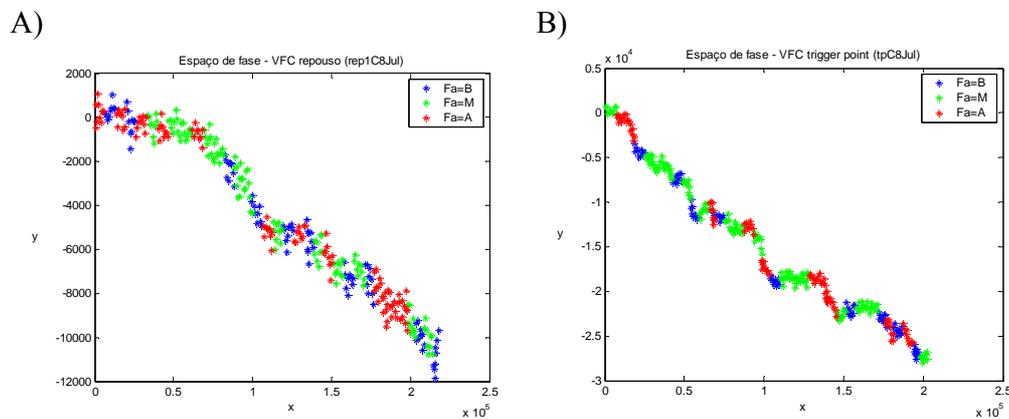
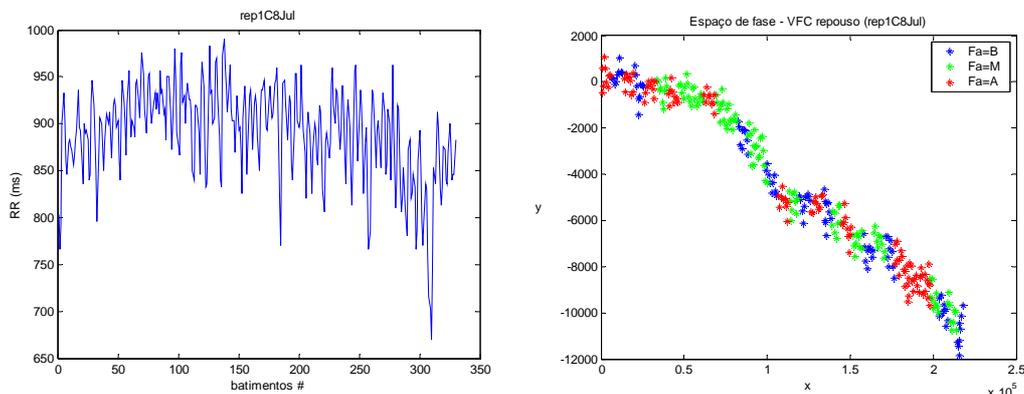


Figura 42: Gráficos da técnica de GPA espectral da paciente C8Jul referentes ao repouso inicial (A) e a técnica de trigger point (B).

Verificou-se também, que quanto maior o desvio padrão dos sinais menor é a *clusterização*, em outras palavras, quanto menor os níveis de intermitência mais espalhados estão os pontos no espaço de fases, ou quanto maior o nível de spikes (picos) mais concisos

estão os pontos; o que também pode ser visto na paciente C8Jul na qual os pontos dos gráficos referentes ao repouso estão mais espalhados e para as técnicas estão mais concisos.

A)



B)

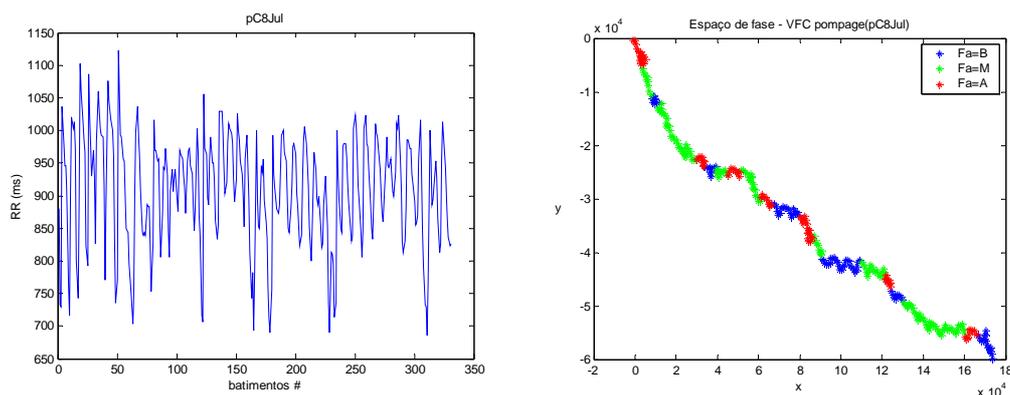


Figura 43: Figuras das séries temporais com seus respectivos gráficos de GPA espectral da paciente C8Jul referentes ao repouso inicial (A) e técnica de pompage(B)

Para que esta análise possa ser concluída será necessária uma interpretação mais detalhada dos resultados, além da aquisição de mais sinais (amostras).

Para uma maior compreensão da influência das técnicas na clusterização dos pontos será necessário um estudo sobre as componentes do sinal que foram usados para a construção do espaço de fase (Apêndice C).

Em relação à análise com wavelets pode-se concluir que os sinais não são aleatórios e sem auto-correlação, uma vez que  $\beta w \neq 0$ . Esse resultado sugere a presença de uma componente determinístico ou estocástico que gere flutuações não-gaussianas e correlações de curto e longo alcance na dinâmica do sistema cardíaco. Modelos que serão futuramente investigados, no contexto deste trabalho, são aqueles do tipo *Fitzhug-Nagumo* [27].

Através da observação dos periodogramas verifica-se uma possibilidade de distinguir os sinais de diferentes técnicas (repouso e liberação miofascial), uma vez que há uma maior formação de picos nos sinais referentes às técnicas de fisioterapia. Consta-se, considerando as figuras 44 B e 44 C, a formação de picos na mesma escala de variação (entre 8 e 16 s).

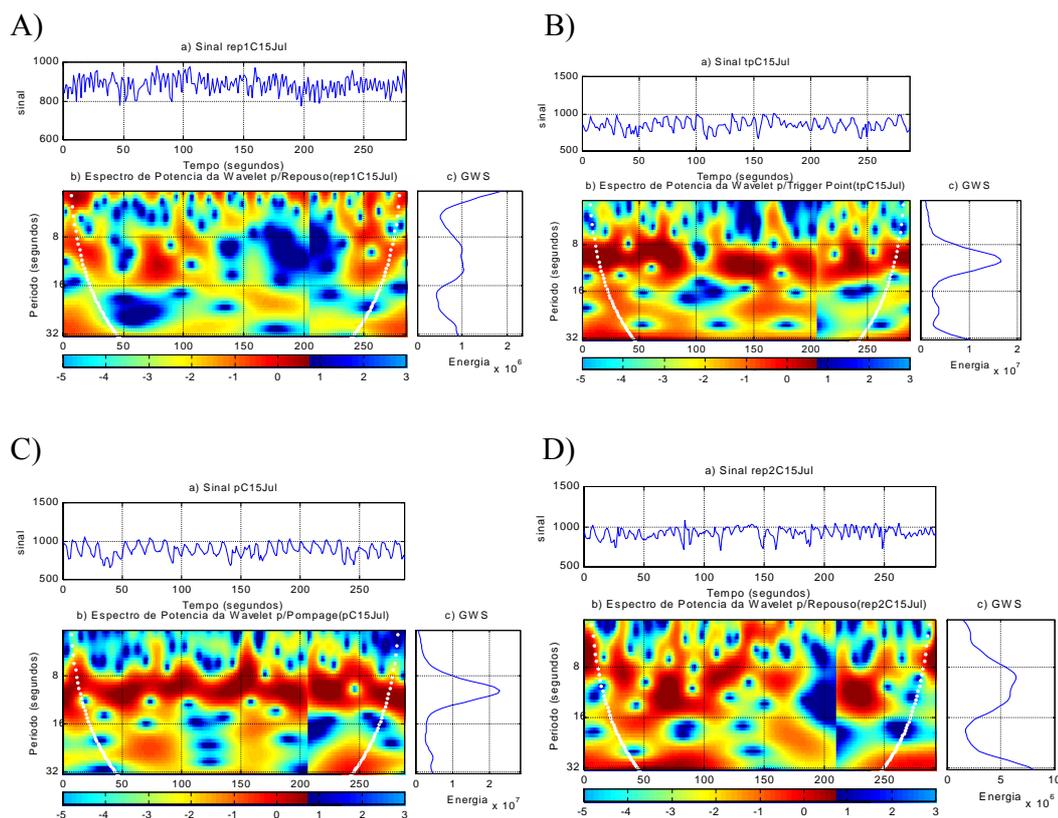


Figura 44: Periodograma do Paciente C15Jul referente ao repouso inicial(A), à técnica de trigger point (B) , à técnica pompage (C) e ao repouso final (D).

Em geral, o comportamento do GWS, no sentido qualitativo, se manteve o mesmo nos sinais referentes à mesma técnica, ou seja, teve a mesma característica nos 4 tipos diferentes de sinais. A figura 45 mostra o periodograma de dois pacientes, nos quais o GWS tem o mesmo tipo de comportamento, ou seja, no intervalo de 0 a 8 s o sinal aumenta, entre 8 e 16 s o sinal tem um pico e já começa a decrescer, entre 16 e 32 s o sinal volta a aumentar.

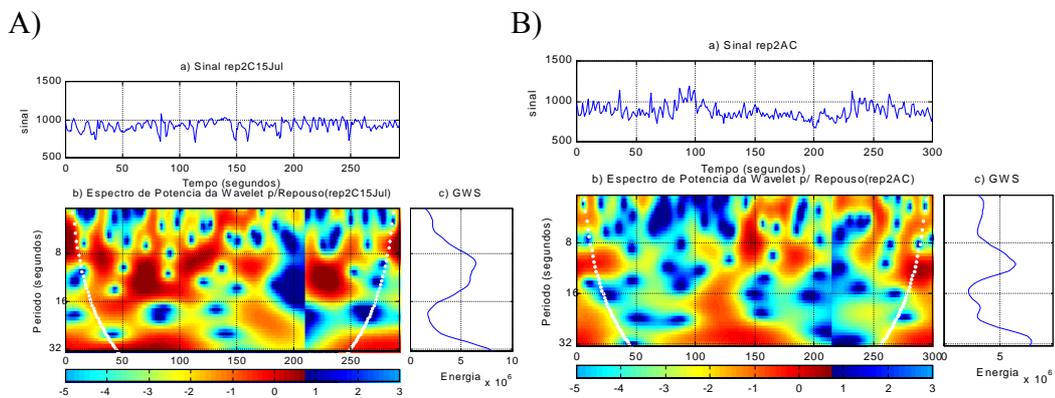


Figura 45: Periodograma do repouso final da paciente C15Jul (A) e AC (B).

Com a análise de GWS também pode ser possível indicar a influência dos sistemas simpático e parassimpático no repouso e durante as técnicas de liberação miofascial, uma vez que a influência do sistema simpático está relacionado com baixas freqüências e do parassimpático com altas freqüências ( $0,003-0,15$  Hz = Baixa freqüência,  $0,15-0,4$  Hz = Alta freqüência) [21]. Isto está explícito na figura 46 na qual ocorre um pico durante o repouso em uma determinada faixa de freqüência (em torno de 0 s) e já durante as técnicas de fisioterapia este pico se encontra em outra faixa de freqüência (em torno de 8 s).

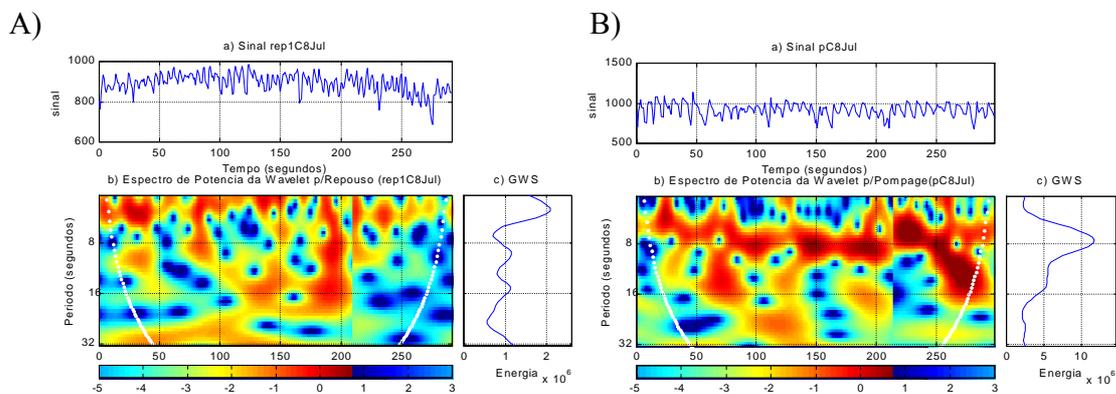


Figura 46: Periodogramas da paciente C8Jul no repouso inicial (A) e durante a técnica pompagem (B).

## TRABALHOS FUTUROS

Para conclusão deste trabalho de Iniciação Científica deverá ser feita uma análise espectral, ou seja, uma caracterização fina por meio da análise cromática (GPA espectral) comparativa com a análise de Wavelets ( $\beta_w$ ), além do que já foi mencionado acima.

Para a análise com wavelets, mais sinais deverão ser analisados para que se possa confirmar os resultados preliminares encontrados neste trabalho.

Propõe-se para continuação deste trabalho no mestrado à validação das técnicas em questão e a utilização da técnica de Kulback-Liebler para confirmação dos resultados. Também é proposto o estudo de sinais de ECG referente a condições de microgravidade que seriam adquiridos junto ao Marshall Space Flight Center (NASA).

A partir de uma caracterização robusta dos diferentes regimes e técnicas associadas, propomos investigar modelos desenvolvidos para descrição da excitação cardíaca a partir de estímulos não-lineares. Considerando o contexto deste trabalho, modelos do tipo *Fitzhug-Nagumo* [27] serão analisados.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Ferreira, A. T. R., Efeitos na liberação miofascial na modulação autonômica do coração em sujeitos saudáveis, Dissertação de mestrado, Univap, 2004.
- [2] Junior, V.P.; Lopes, H.S., Reconhecimento de Padrões em Sinais Eletrocardiográficos com Rede Neurofuzzy e Algoritmos Genéticos, Braz. Conference on Neural Networks, 42-46, 1999.
- [3] Guyton, A.C.; Hall, J.E., Fisiologia Humana e Mecanismos de doenças, 6<sup>ed.</sup>, Guanabara, Rio de Janeiro, 1998.
- [4] Rosa, R. R.; Sharma, A. S.; Valdivia, J.A., Characterization of assymmetric fragmentation patterns in spatially extended systems, Int. Journal of Modern Physics C, v.10 (1), 147-163, 1999.
- [5] Rosa, R. R., Campos, M.R., Ramos, F. M. *et al*, Gradient pattern analysis of structural dynamics: application to molecular system relaxation, Int. Journal of Modern Physics C, v.33 (3), 605-610, 2003.
- [6] Assireu, A.T.; Rosa, R. R; Vijaykumar, J.A. *et al*, Gradient pattern analysis of short nonstationary time series: na application to Lagrangian data from satellite tracked drifters, Physica D, v. (168/169), 397-403, 2002.
- [7] Carvalho, J.L.A.; Rocha, A. F.; Nascimento, F. A., Desenvolvimento de um sistema para análise da variabilidade da frequência cardíaca, Anais CBEB, v.5, 345-348, 2002.
- [8] Oliveira, D. J.; Gomes, M. E. D.; Aguirre, L.A., Análise da variabilidade da frequência cardíaca baseada no estudo de modelos identificados, Anais CBEB, v.5, 356-358, 2002.
- [9] Guerra, J.M.; Tierra-Criollo, C.J.; Ferreira, A.T.R.; Rosa, R.R., Costa Junior, R.A., Análise de padrões-gradientes da variabilidade da frequência cardíaca, apresentado no IV Encontro Regional de Matemática Aplicada e Computacional realizado de 16 a 20 de maio de 2004. Livro de Resumos: p. 56.
- [10] Manzan, W. A.; Barbar, J. S.; Kanaan, E. E, O Uso de Wavelets no Reconhecimento de Padrão em ECG, Uberlândia, Disponível em: <<http://www.tecsi.fea.usp.br>>, Acesso em 14 de Nov 2004.
- [11] Regis, R. A. F., Wavelets e as Artes Multiresolucionárias, Disponível em: <<http://www.lsi.usp.br>>, Acesso em 11 de Nov 2004.
- [12] Torrence, C.; Compo, G.P., Pratical Guide to Wavelet Analysis, Bulletin of American Metereological Society, v.79, n.1, p.61-78,1998.
- [13] Ishikawa, Y, Wavelet Theory-Based Analysis of High-Frequency,High-Resolution Electrocardiograms:A New Concept for Clinical Uses, Progress in Biomedical Research. v. 7, n.3, 179-184, 2002.
- [14] Bolzan, M. J. A., Análise da transformada em ondeletas aplicada em sinal geofísico, Rev. Bras. Ens. Fis., v.26, n.1, 2004.
- [15] Chandra, T; Yeates, D.B., Heart Rate Variability Analysis – Current and Future Trends, Revista Businessbriefing: Global healthcare, Technology & Services, 2003.
- [16] Maia, I.G.; Francisco, F.E.S.C., Eletrofisiologia Clínica e Intervencionista das arritmias cardíacas, Ed. Revinter, Rio de Janeiro, 1997.

- [17] Regenga, M.M., *Fisioterapia em cardiologia da UTI a reabilitação*, Ed. Roca, São Paulo, 2000.
- [18] Pichot, V.; Gaspoz, J.M., Wavelet transform to quantify heart rate variability and to assess its instantaneous changes, *Appl Physiol*, v. 86, n. 3, 1081-1091, 1999.
- [19] Pumprla, J.; Howorka, K, Functional assessment of heart rate variability: physiological basis and practical, Elsevier Science, *International Journal of Cardiology*, v. 84, n. 1 , 1-14, 2002.
- [20] Rassi, Jr., A.; Compreendendo melhor as medidas de análise da variabilidade da frequência cardíaca, *Jornal de Cardiologia*, Disponível em <[www.cardios.com.br](http://www.cardios.com.br)>, Acesso em 03 de Fev 2005.
- [21] TASK FORCE of the European Society of cardiology and the north America society of pacing and electrophysiology, Heart rate variability: standards of measurement, physiological interpretation and clinical use, *Circulation*,v.93, n.5,p.1043-1065, 1996.
- [22] Assireu, A.T.,et al, Aplicação do Operador de Fragmentação Assimétrica ( $F_A$ ) na caracterização de controles geomorfológicos em reservatórios hidroelétricos, *Revista Brasileira de Geociências*, v.34, n.4, 501-508, 2004.
- [23] Assireu, A.T., Aplicação do Operador de Fragmentação Assimétrica ( $F_A$ ) na comparação de dados coletados *in situ* por diferentes sensores e transmitidos pelos satélites brasileiros SCD e CBERS: um exemplo de aplicação ao Sistema de Monitoramento Ambiental (SIMA), 2005.
- [24] Packard, N.H.; Crutchfield, J.P., Geometry from a time series. *Phys. Rev. Lett.*, v.45, 712-716, 1980.
- [25] Tsonis, A.A.; Elsner, J.B., Multiple attractors, fractal basins and long-term climate dynamics, AGU Spring Meeting, Baltimore, Abstract Volum, May29-June2, 1990.
- [26] Rosa, R.R., et al, *Physica A*, 1998.
- [27] Aliev, R.R.; Panfilov, A.V., A simple two-variable model of cardiac excitation, *Chaos, Solitons and Fractals*, v.7, 293-301,1996.

## APÉNDICE A

### ELETROCARDIOGRAMA

O eletrocardiograma (ECG) é uma das formas de registro da atividade elétrica do coração, e reflete os eventos elétricos do conjunto de suas células. É uma técnica desenvolvida por Augustus Waller em 1887 e aprimorada com a descoberta do galvanômetro por Johann Schweigger e Willem Einthoven.

O ciclo completo da batida do coração consiste em três fases. Na primeira fase (Diástole) o sangue enche as aurículas e cerca de 80% dos ventrículos. Na segunda fase (Sístole Auricular ou Contração Atrial) as aurículas contraem-se pela ativação do nódulo SA e empurram o resto do sangue que contém para os ventrículos. Uma fração de segundo depois ocorre a terceira fase do ciclo (Sístole Ventricular) que é caracterizada pela contração dos ventrículos devido ao impulso elétrico do nódulo AV. Posteriormente, devido a uma diferença de pressão as válvulas à saída dos ventrículos se abrem e assim o sangue corre para fora do coração para a artéria pulmonar ou para a aorta.

O ciclo tem três ondas que correspondem aos impulsos das atividades elétricas do coração. A onda P representa o impulso elétrico que causa a contração das aurículas. O complexo QRS (formado por três ondas: Q, R e S) representa o impulso da contração dos ventrículos e a onda T corresponde à recuperação elétrica dos ventrículos quando estes voltam para repouso. Os aurículos têm também esta recuperação, mas a onda é encoberta pelo complexo QRS dos ventrículos.

Este processo cardíaco produz sinais elétricos que passam para os tecidos vizinhos e chegam à pele. Assim, com a colocação de eletrodos no tórax, podemos gravar as variações de ondas elétricas emitidas pelas contrações do coração. O registro dessas ondas pode ser feito numa tira de papel ou num monitor e é chamado de eletrocardiograma (ECG). No coração normal, um ciclo completo tem duração total menor do que 0,8 segundos [2].

Num traçado cardiológico o movimento destas ondas representa uma informação essencial do estado de saúde do coração. Depois de uma disfunção do coração, como um ataque cardíaco, o ciclo cardíaco pode-se alterar e assim mostrar as lesões no coração provocadas pelo acontecimento anormal, de modo que o eletrocardiograma representa um precioso meio de diagnóstico [3].

Para uma melhor compreensão deste processo, será abordada a atividade elétrica de uma única célula miocárdica.

A atividade elétrica da célula miocárdica compreende a sucessão cíclica de dois eventos: o potencial de repouso (potencial de membrana de  $-90\text{mV}$ ) e o potencial de ação. Na célula em repouso (polarizada), o potássio ( $\text{K}^+$ ) está em maior concentração no meio intracelular do que no intersticial. Quando a célula é ativada ocorrem trocas iônicas, aumenta a permeabilidade ao sódio ( $\text{Na}^+$ ) que entra rapidamente na célula, ocorrendo simultaneamente um incremento da saída do íon  $\text{K}^+$ , e então se inverte a polaridade da célula, que vai de  $-90\text{mV}$  a  $+30\text{mV}$  numa fração de milissegundo. A repolarização da

célula fará com que ela volte às condições basais ( $-90\text{mV}$ ), ocorrendo a troca iônica com expulsão ativa de  $\text{Na}^+$  e entrada ativa de  $\text{K}^+$ .

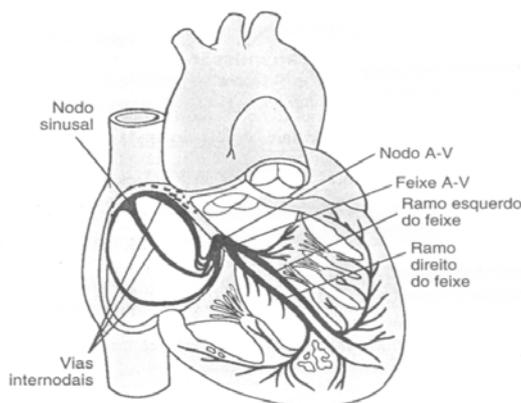


Figura 47: Nodo sinusal e o sistema Purkinje, mostrando também o nodo atrioventricular, as vias atriais internodais e os ramos ventriculares do feixe.

A Figura 47 mostra o sistema especializado excitatório e condutor do coração, que controla as funções cardíacas. Muitas fibras cardíacas têm capacidade de auto-excitação, processo que pode produzir descarga e contração rítmica automáticas. O nodo SA apresenta auto-excitação em maior grau, por essa razão normalmente controla a frequência dos batimentos cardíacos, sendo considerado o marcapasso natural do coração. O potencial de repouso da membrana da fibra sinusal tem negatividade máxima de entre apenas  $-55$  a  $-60\text{mV}$ , em comparação com  $-85$  a  $-90\text{mV}$  para a fibra muscular ventricular.

Três tipos de canais iônicos da membrana têm papel importante nas alterações de voltagem do potencial de ação no músculo cardíaco: canais rápidos de sódio, canais lentos de cálcio-sódio e canais de potássio. A abertura dos canais rápidos de sódio, por cerca de décimos de milésimos de segundos, é responsável pela rápida deflexão ascendente do potencial de ação observada no músculo ventricular, devido ao rápido influxo de sódio para o interior da fibra. Em seguida, o platô do potencial de ação ventricular é causado pela abertura dos canais lentos de cálcio-sódio, durante cerca de três décimos de segundo, durante esse tempo esses íons fluem para o interior da fibra muscular ventricular. Imediatamente após o início do potencial de ação, a permeabilidade da membrana do músculo cardíaco diminui para o  $\text{K}^+$  cerca de 5 vezes; essa permeabilidade reduzida diminui acentuadamente o efluxo de  $\text{K}^+$  durante o platô do potencial de ação, impedindo o retorno precoce da voltagem do potencial de ação para seu valor de repouso. Quando os canais lentos de cálcio-sódio fecham, a permeabilidade da membrana para o  $\text{K}^+$  aumenta rapidamente e o potencial de ação volta para seu valor de repouso (fig. 2A).

No nodo SA, devido a menor negatividade do potencial de repouso ( $-55\text{mV}$ ), os canais rápidos de sódio estão inativados. A razão disso é que quando o potencial de membrana permanece menos negativo que  $-60\text{mV}$ , por mais de alguns milissegundos, as

comportas de inativação fecham os canais rápidos de sódio e permanecem fechadas. Portanto, somente os canais lentos de cálcio-sódio podem ser ativados e produzir o potencial de ação mais lento que o do músculo ventricular. A repolarização também ocorre de forma mais lenta (fig.2B).

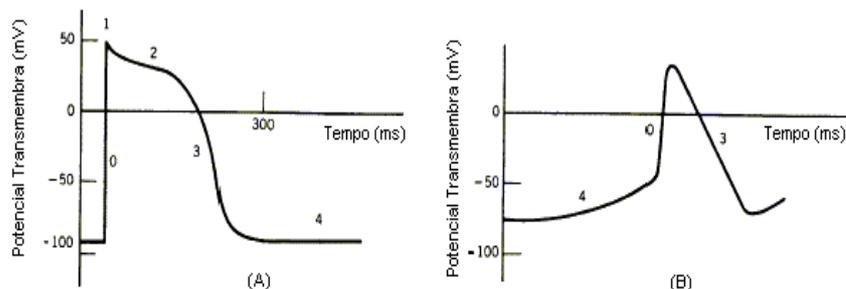


Figura 48: Potenciais de ação: (A) de uma fibra ventricular e (B) de uma fibra do NSA.

O nodo SA controla o batimento cardíaco devido ao fato que a sua frequência rítmica de descarga é maior que em qualquer outra parte do coração, assim o nodo SA excita outros tecidos potencialmente auto-excitatórios, antes que possa ocorrer sua auto-excitação [3].

## INLUENCIA AUTONOMICA NA FREQUENCIA CARDIACA

Através de reflexos específicos e gerais, o sistema nervoso autônomo (SNA) exerce um papel fundamental sobre toda a atividade cardíaca. Suas ações se estendem aos mecanismos fisiológicos, bem como sobre aqueles relacionados com doenças cardíacas. Arcos reflexos aferentes enviam informações a partir do coração para os centros autonômicos cerebrais, sendo as mesmas processadas e enviadas de volta ao mesmo, por vias eferentes. As respostas desenvolvem-se de forma muito rápida e tem como finalidade básica manter a homeostasia local [16].

Embora a automaticidade cardíaca seja intrínseca a vários marcapassos teciduais, a frequência e ritmo cardíacos estão amplamente submetidos ao controle do sistema nervoso autônomo (SNA). O nodo SA é densamente innervado pelas divisões autonômicas, simpática e parassimpática. A frequência cardíaca (FC) reflete o efeito modulatório do SNA sobre a frequência elétrica intrínseca das células marcapasso do coração.

Classicamente o SNA divide-se em cadeia simpática (S) e parassimpática (PS), tendo ambas características individuais próprias e atividade exercida por receptores sensoriais especializados e modulados por neurotransmissores. O neurotransmissor representa a substância química liberada pela terminação nervosa.

A influência parassimpática na FC é mediada via liberação de acetilcolina pelo nervo vago. Receptores de acetilcolina muscarínicos respondem a essa liberação aumentando a permeabilidade da membrana celular ao  $K^+$ . Isso provoca aumento da negatividade no interior das fibras, efeito de hiperpolarização, o qual faz com que o tecido

excitável fique menos excitável.

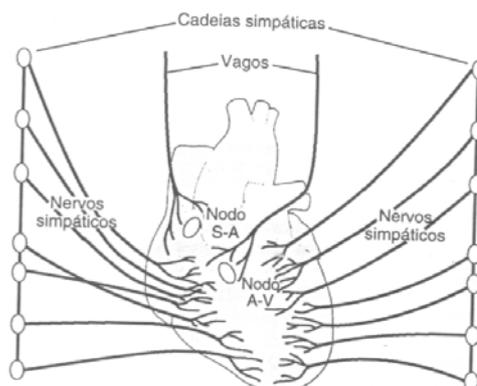


Figura 49: Inervação Autonômica do Coração

Este estado de hiperpolarização diminui o potencial de repouso da membrana do nodo SA para um valor mais negativo ( $-65$  a  $-75\text{mV}$ ) que o normal ( $-55$  a  $-60\text{mV}$ ). Portanto, a elevação do potencial de membrana do nodo SA provocada pelo influxo de  $\text{Na}^+$  necessita mais tempo para alcançar o potencial limiar para excitação. Isso diminui a frequência da ritmicidade das fibras nodais. Se a estimulação vagal é muito forte, é possível parar a auto-excitação rítmica desse nodo. Portanto, a ativação parassimpática ou vagal retarda a FC, aumentando o tempo de condução átrio-ventricular, deprime a excitabilidade das fibras condutoras especializadas e do miocárdio.

A influência simpática na FC é mediada pela liberação de norepinefrina (noradrenalina) nas terminações nervosas simpáticas. O mecanismo exato pelo qual esse neurotransmissor atua sobre as fibras musculares cardíacas ainda não está completamente elucidado, mas acredita-se que ele aumente a permeabilidade da fibra aos íons  $\text{Na}^+$  e  $\text{Ca}^{++}$ . No nodo SA o aumento da permeabilidade ao  $\text{Na}^+$  produz potencial de repouso positivo, resultando em um aumento da frequência da variação de membrana para o valor limiar da auto-excitação, conseqüentemente acelerando a auto-excitação e, portanto, aumentando a FC. Além disso, no nodo AV a maior permeabilidade ao  $\text{Na}^+$  diminui o tempo de condução dos átrios para os ventrículos. O aumento da permeabilidade ao  $\text{Ca}^{++}$  é responsável pelo aumento na força contrátil do músculo cardíaco sob influência da estimulação simpática. Assim, a ativação simpática aumenta a FC, diminui o tempo de condução átrio-ventricular, intensifica a excitabilidade das fibras condutoras especializadas e do miocárdio, e aumenta a contratilidade.

Sob condições de repouso, o tono vagal prevalece e a FC tende a diminuir. Não obstante, as atividades vagal e simpática interagem constantemente.

Devido ao fato de que o nodo sinusal é rico em acetilcolinesterase, o efeito de qualquer impulso vagal é breve porque a acetilcolina é hidrolisada rapidamente. Influências parassimpáticas sobrepõem-se a efeitos simpáticos provavelmente através de dois

mecanismos independentes: uma redução induzida colinergicamente da norepinefrina liberada em resposta à atividade simpática e uma atenuação colinérgica da resposta a um estímulo adrenérgico [3].

Encontra-se hoje, muito bem definido, a importância do SNA cardíaco na regulação dos mecanismos de saúde e doença. Seu papel como agente precipitador da morte súbita ou de outros eventos cardíacos maiores estão muito bem estabelecidos. Assim, com a moderna tecnologia, abrindo novos caminhos ou simplificando em muito os já existentes, poderemos prever para um futuro próximo, e baseado nos conhecimentos já adquiridos e nos que certamente ainda virão, intervenções mais efetivas e visões mais abrangentes sobre o SNA cardíaco, mudando co isso a historia natural da doença coronariana, bem como de outras patologias cardíacas [16].

## APÊNDICE B

### LIBERAÇÃO MIOFASCIAL

A teoria da LM baseia-se no princípio que um trauma físico, estresse crônico, ações repetitivas, inflamação, infecção, ou desequilíbrios estruturais tais como má oclusão, restrição óssea, discrepância no comprimento das pernas, ou outras anormalidades estruturais podem gerar uma tensão fascial inapropriada. A fâscia é um tecido conjuntivo de sustentação, invólucro de órgãos e músculos; reveste, divide, envolve, dá coesão e é parte integrante da estrutura e função do tecido mole em todo o corpo, desde o interior do crânio até a sola dos pés. O tecido miofascial se reorganiza em resposta às linhas de tensão impostas ao corpo, acrescentando desalinhamento e/ou contratura para proteger o indivíduo de traumas reais ou imaginários.

Quando existe uma restrição fascial, as forças podem não ser distribuídas apropriadamente, o que pode favorecer o aparecimento de lesões. O tempo todo as tensões fasciais se espalham e se existe alguma restrição fascial o corpo começa a sair do seu alinhamento tridimensional, causando ineficiência biomecânica e alto consumo de energia no movimento e postura .

Além das alterações biomecânicas, a presença de lesões no tecido mole em conexões com a fâscia que o reveste pode ativar o envolvimento do SNA e produzir mudanças vasomotoras, tróficas, viscerais ou metabólicas. Os sintomas desaparecem quando a lesão é normalizada.

Estudos relatam que disfunções nas articulações vertebrais têm mostrado afetar a função cardíaca e a modulação do SNA; declaram também que a manipulação dessas articulações diminui a FC e a pressão sanguínea. A influência sobre o SNA pode depender da qualidade e técnica de fisioterapia manual aplicadas, bem como do segmento vertebral manipulado.

Uma disfunção miofascial pode ocorrer devido à presença de pontos gatilhos. Pontos gatilhos (PG) miofasciais são pequenos pontos de hipersensibilidade dentro de uma banda tensa do tecido muscular ou fâscia. Eles são doloridos sob compressão e podem evocar dor referida característica em áreas afastadas da sua localização atual.

As áreas alvo dos PGs ficam em partes dos músculos mais propensos ao estresse mecânico e estão localizados em posições similares nos indivíduos, produzindo entre outras mudanças, inadequabilidade circulatória e diminuição no aporte de oxigênio local.

A estimulação dos PGs podem causar mudanças no SNA periférico, tais como transpiração local excessiva, piloereção, vasodilatação local e eritema .

Foi registrada uma correlação negativa do nervo simpático muscular (NSM) com a FC provocada pela manobra da acupuntura; seus resultados sugerem a co-ativação do NSM e o vagal cardíaco.

A técnica de inativação do PG é comumente usada em terapia esportiva para alívio da dor e para induzir relaxamento muscular após lesão, tem mostrado reduzir a quantidade

e intensidade dos PGs.

Clinicamente é comum combinar outras técnicas de LM com a digito-pressão para a inativação dos PGs.

Uma pressão suave e sustentada da fáscia pode causar uma liberação das restrições fasciais do sistema. Uma pressão pequena aplicada suavemente e mantida por um tempo irá permitir um meio da viscosidade fluir para uma extensão maior do que quando uma carga pesada é aplicada rapidamente. Além disso, um estímulo fraco aumenta a atividade fisiológica e um estímulo muito forte inibe ou anula a atividade, o que pode explicar como a pressão suave, sustentada da liberação miofascial pode causar mudanças consistentes e melhorar o sistema fascial.

Pompage é uma manobra capaz de tensionar lenta, regular e progressivamente um segmento corporal, colocando sob tensão o tecido elástico aí contido. Este procedimento age sobre o tecido conjuntivo de revestimento, que é o elemento elástico do corpo humano, restabelecendo seu comprimento ideal, estimulando a circulação de líquidos nela contidos, facilitando a nutrição da cartilagem articular.

Um dos objetivos da pompage é o relaxamento muscular. Nos casos de contratura e retrações, quando as moléculas de actina e miosina interpenetram-se excessivamente, há diminuição do comprimento muscular, no que são seguidas pelos elementos conjuntivos do músculo. A pompage, realizada no sentido das fibras musculares, promove um deslizamento dessas moléculas em sentido contrário e aumenta o comprimento total do músculo.

Em um primeiro tempo, lenta, regular e progressivamente a estrutura muscular é tensionada até onde o permitir, para não haver reflexo miotático direto. Em um segundo tempo, a tensão obtida deve ser mantida. Esse é o tempo principal da pompage muscular. O alongamento da estrutura miofascial ocorre graças à elasticidade dos elementos conjuntivos e também ao escorregamento excêntrico dos filamentos de actina entre os de miosina, e esses são fenômenos lentos. O tensionamento é mantido durante 20 a 30 segundos. O terceiro tempo é o tempo de retorno, que deve ser lento, uma vez mais, para não provocar um reflexo contrátil do músculo [1,2].

## APÊNDICE C

### ESPAÇO DE FASE

De acordo com a teoria de sistemas dinâmicos, a melhor forma de estudar a dinâmica de um sistema é através do espaço de estado. O espaço de estado é formado por um conjunto de coordenadas que representam as variáveis descritivas do sistema. Para cada passo de tempo, o sistema pode ser representado por um ponto neste estado de espaço. A partir da conexão destes pontos, define-se uma trajetória que descreve a evolução do sistema. Esta trajetória converge para um atrator, o qual descreve assintoticamente o estado final do sistema. O atrator pode ser uma estrutura topológica simples, como um ponto ou um ciclo limite, como pode ser também uma estrutura caracterizada por geometria fractal. Se a descrição matemática de um sistema dinâmico é dada, o número de variáveis é conhecido e a geração do estado de espaço e do atrator é imediata. Se, no entanto, a formulação matemática de um sistema for desconhecida, o espaço de estado pode ser substituído pelo espaço de fase. O espaço de fase pode ser construído a partir dos dados observados de uma variável  $x(t)$  de um determinado sistema e seus sucessivos deslocamentos.

Assim, dada uma observação  $x(t)$ , é possível gerar o estado completo do vetor  $X(t)$  usando-se  $x(t+\tau)$  como a primeira coordenada,  $x(t+2\tau)$  como a segunda coordenada e  $x(t+m\tau)$  como a última coordenada. Neste contexto,  $\tau$  é o intervalo ou o incremento dos dados [24,25].

Como as grandezas utilizadas neste trabalho são todas escalares, foi feito o seguinte para que estas variáveis pudessem ser representadas num espaço de fase:

- 1) Seja  $\alpha = \Delta G / \Delta t$ , onde  $G$  é a grandeza escalar em análise;
- 2) A fim de obter uma grandeza adimensional para  $\alpha$ , seja:  $\theta = \alpha / \max(\text{abs}(\alpha))$ , com  $\theta_* = \theta * \pi$
- 3) Assumindo-se que  $\theta$  (definido acima) é um equivalente de direção, pode-se definir as componentes de  $G$  como:

$$\begin{aligned} G_x &= G \cos(\theta) \\ G_y &= G \sin(\theta) \end{aligned} \quad (11)$$

- 4) A partir de (11) pode-se construir a pseudotrajetória que retrata a evolução temporal da dinâmica associada à grandeza em questão, a partir da adaptação da seguinte formulação:

$$(x,y) = (G_{x0}, G_{y0}) + \sum (G_{xi}, G_{yi}), (i = 1,2,\dots) \quad (12)$$