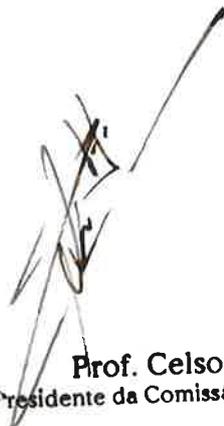


UNIVERSIDADE DE SÃO PAULO

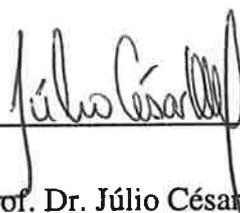
Instituto de Física

**Estudo de sinais de ECG utilizando métodos matemáticos
para análise de sistemas dinâmicos não lineares**

Henrique Hamaguchi



Prof. Celso Luiz Lima
Presidente da Comissão de Pós-Graduação



Orientador: Prof. Dr. Júlio César Bastos de Figueiredo

Dissertação de Mestrado apresentada ao
Instituto de Física para a obtenção do título
de Mestre em Ciências

Comissão Examinadora:

Prof. Dra. Carmen Pimentel Cintra do Prado – Universidade de São Paulo (USP)

Prof. Dr. Júlio César Bastos de Figueiredo – Instituto do Coração (InCor)

Prof. Dr. Luis Anibal Diambra – Universidade do Vale do Paraíba (UNIVAP)



SÃO PAULO

2006



SBI-FUSP

del. 29/03/06

FICHA CATALOGRÁFICA
Preparada pelo Serviço de Biblioteca e Informação
do Instituto de Física da Universidade de São Paulo

Hamaguchi, Henrique

Estudo de sinais de ECG utilizando métodos matemáticos para análise de sistemas dinâmicos não lineares. São Paulo , 2006

Dissertação (Mestrado) - Universidade de São Paulo
Instituto de Física – Depto. de Física Nuclear

Orientador: Prof. Dr. Júlio César Bastos de Figueiredo
Área de Concentração: Física

Unitermos:

1. Eletrocardiograma;
2. Séries Temporais;
3. Sistemas Dinâmicos

USP/IF/SBI-018/2006

Para Lúcia e Hideyuki. Pelo carinho e
dedicação durante todos estes anos.

AGRADECIMENTOS

À minha família pelo apoio ao longo do desenvolvimento desta dissertação.

Ao professor Júlio, pela importância em minha formação, pela orientação e pela amizade.

Aos amigos do Instituto de Física, Alexandre, Alexsandro, Julian, Marcelo e Tadashi, pelo companheirismo e incentivo.

Aos amigos Andréa e Carlos pela ajuda no processo de revisão da tese.

Ao Amir pela ajuda na área computacional.

Ao CNPq pelo auxílio financeiro.

Aos professores do Instituto de Física, que de uma forma ou de outra contribuíram para esta dissertação.

Ao Departamento de Informática do Instituto do Coração (InCor) que forneceu a infraestrutura.

RESUMO

Esta dissertação visa estudar a aplicabilidade e a importância prognóstica de métodos matemáticos não lineares no estudo das variações da frequência cardíaca bem como no das mudanças morfológicas em sinais de eletrocardiograma. Apresentaremos uma revisão geral desse assunto focando em técnicas de análise não linear para o estudo de sinais de eletrocardiograma (ECG) visando construir uma base de conhecimentos que permita, no futuro, a abordagem de novos aspectos dessas metodologias. Como resultado do aprendizado, é gerado um programa que utiliza algumas das técnicas descritas ao longo da dissertação. Ao final da dissertação, abordaremos as vantagens e desvantagens dos métodos não lineares, concluindo que são ferramentas promissoras para a análise de sinais de ECG.

ABSTRACT

This dissertation presents a study about the applicability and the prognostic importance of nonlinear mathematical methods in the variations of heart frequency as well as in the morphological changes in the electrocardiogram signs. We will present a general revision of this subject focusing on application of nonlinear analysis for the study of electrocardiogram (ECG) signs in order to provide a base of knowledge that allows, in the future, the approach of new aspects of these methodologies. As a result this work, it was built a program that uses nonlinear analysis described along the dissertation. At the end of this document, we describe the advantages and disadvantages of the nonlinear methods, concluding that they are promising tools in the analysis of ECG signs.

SUMÁRIO

AGRADECIMENTOS.....	I
RESUMO	II
ABSTRACT	III
LISTA DE FIGURAS	VI
LISTA DE TABELAS.....	X
ABREVIATURAS.....	XI
1 INTRODUÇÃO.....	1
1.1 OBJETIVOS DA DISSERTAÇÃO.....	1
1.2 O ESTUDO DO ELETROCARDIOGRAMA (ECG).....	2
2 ELETROFISIOLOGIA DO CORAÇÃO	6
2.1 O MÚSCULO CARDÍACO.....	6
2.2 SISTEMA DE CONDUÇÃO CARDÍACA.....	9
2.2.1 <i>Metodologias e Convenções</i>	11
2.2.2 <i>Nomenclatura do ECG e o Ciclo Cardíaco</i>	14
3 MÉTODOS CLÁSSICOS DE ANÁLISE DO ECG.....	16
3.1 ANÁLISE NO DOMÍNIO DO TEMPO.....	17
3.2 ANÁLISE NO DOMÍNIO DA FREQUÊNCIA	19
3.3 LIMITAÇÕES DA ANÁLISE CLÁSSICA DE VFC.....	21
4 ANÁLISE DE SÉRIES TEMPORAIS NÃO LINEARES.....	24
4.1 INTRODUÇÃO.....	24
4.2 CONCEITOS BÁSICOS DE SISTEMAS DINÂMICOS	25
4.3 RECONSTRUÇÃO DE TAKENS	29
4.4 NÃO ESTACIONARIDADE	31
4.4.1 <i>Diagramas de Recorrência</i>	32
4.5 DIMENSÕES DE CORRELAÇÃO	34
4.6 REDUÇÃO DE RUÍDO NÃO LINEAR	36
4.6.1 <i>Redução de Ruído com Projeções Locais</i>	37
4.7 DISTÂNCIAS ESTATÍSTICAS	42
4.8 ENTROPIA APROXIMADA (APEN).....	45
4.9 DETRENDED FLUTUATION ANALYSIS (DFA).....	48

5	USO DE MÉTODOS NÃO LINEARES PARA ANÁLISE DO ECG.....	52
5.1	O ECG	52
5.1.1	<i>Não Linearidade no ECG</i>	52
5.1.2	<i>Não Estacionaridade do ECG</i>	54
5.2	RECONSTRUÇÃO DO ESPAÇO DE FASE DO ECG	56
5.3	REDUÇÃO DE RUÍDO DO ECG.....	58
5.4	DIMENSÃO DE CORRELAÇÃO DO ECG.....	61
5.5	DETECÇÃO DE MUDANÇAS NOS SINAIS DE ECG	67
5.6	ANÁLISE DE DFA NO ECG.....	76
6	PROGRAMA PARA ANÁLISE NÃO LINEAR DO ECG.....	81
6.1	MOTIVAÇÃO.....	81
6.2	FUNCIONALIDADES	82
7	CONCLUSÕES	88
	APÊNDICE A – OBSERVÁVEIS LINEARES	91
	APÊNDICE B – PHYSIONET.....	95
	APÊNDICE C – CÓDIGO FONTE DO PROGRAMA.....	97
	BIBLIOGRAFIA	113

LISTA DE FIGURAS

Figura 2.1: Anatomia do coração. Fonte: Rocha & Júnior 1973.....	7
Figura 2.2: Registro típico do potencial de ação de uma célula miocárdica. Fonte: Hobbie 1997.....	8
Figura 2.3: Esquema da secção transversal do coração mostrando o sistema de condução dos impulsos elétricos. Fonte: Motta 1992.....	10
Figura 2.4: Planos para análise do ECG. Fonte: Motta 1992.....	11
Figura 2.5: Representação esquemática da orientação espacial das derivações bipolares clássicas.....	12
Figura 2.6: Representação esquemática da orientação espacial das derivações precordiais. Fonte: Hobbie 1997.....	13
Figura 2.7: O ciclo cardíaco e seus principais constituintes. Fonte: Motta 1992.....	14
Figura 3.1: Histograma de densidade de amostra dos intervalos RR utilizados para o cálculo do índice triangular VFC. Fonte: Task Force 1996.	18
Figura 3.2: Tacograma de um sinal de uma pessoa saudável em repouso (a) e a densidade espectral obtida pela transformada de Fourier (b) e pelo modelo autoregressivo (c). Fonte: Task Force 1996.	20
Figura 3.3: Série temporal de duas frequências cardíacas, uma de uma pessoa saudável (a) e outra de uma pessoa com insuficiência cardíaca congestiva (b). Ambas têm médias e variância próximas (c). Fonte: Bolis & Licinio 1999.....	22
Figura 4.1: Diagramas de referência de: (a) uma função periódica, (b) de um sistema caótico e (c) do ruído branco. Fonte: Blasco 2004.....	33
Figura 4.2: Visão esquemática de uma variedade local. Fonte: Kantz & Schreiber 1998.	42

- Figura 4.3: DFA: As linhas verticais pontilhadas indicam janelas de tamanho $n = 100$, e os segmentos de linhas representam a tendência estimada em cada janela pelo ajuste dos mínimos quadrados. Fonte: Bolis & Licinio 1999. 50
- Figura 5.1: Diagrama de recorrência para os segmentos PT de sinal de ECG. Fonte: Kantz & Schreiber 1998. 55
- Figura 5.2: Um sinal de ECG normal (a) e reconstruções do espaço de fase para (b) $s = 4$ ms, (c) $s = 12$ ms e (d) $s = 24$ ms. Fonte: Figueiredo & Furuie 2001a. 57
- Figura 5.3: Reconstruções de Takens para o sinal de ECG. Fonte: Richter, et al. 1998.... 59
- Figura 5.4: Acima: um ECG fetal utilizando eletrodos na cervical. Meio: a componente materna é removida. Abaixo: flutuações randômicas são removidas. Fonte: Kantz & Shreiber 1997. 60
- Figura 5.5: ECG de uma pessoa com CHD. Fonte: Wang, et al. 2000. 62
- Figura 5.6: $\log_2 C(N, r)$ versus $\log_2 r$ para a mesma pessoa da figura 5.4. Fonte: Wang, et al. 2000. 63
- Figura 5.7: D_2 versus $\log_2 r$ para a mesma pessoa da figura 5.4. Fonte: Wang, et al. 2000. 63
- Figura 5.8: Dimensão de correlação versus a dimensão de imersão, são mostradas quatro curvas que correspondem a curva de referência (1) $D_2 = m$, (2) ruído branco, (3) uma derivação V_5 de uma pessoa saudável, e (4) uma derivação V_5 de uma pessoa com CHD. Fonte: Wang, et al. 2000. 64
- Figura 5.9: Atratores reconstruídos para o mesmo sinal de ECG utilizando diferentes porções do sinal. Fonte: Figueiredo & Furuie 2001a. 67
- Figura 5.10: Distribuição estatística $\{g_{ij}\}$ obtida do atrator de um sinal normal de ECG. Fonte: Figueiredo & Furuie 2001a. 68

- Figura 5.11: Esquema para a análise do sinal usando distâncias estatísticas: N_{ref} é o número de pontos do atrator de referência correspondendo a distribuição $\{g_{ij}\}$, N é o número de pontos de cada janela usada para reconstruir os atratores correspondentes a distribuição $\{p_{ij}\}$ e n é o número de pontos de separação entre cada janela. Fonte: Figueiredo & Furuie 2001a.70
- Figura 5.12: Sinal normal da Physionet (sel16795): (a) sinal de ECG, (b) análise dpg. Fonte: Figueiredo & Furuie 2001a.70
- Figura 5.13: Sinal sel872 da Physionet: (a) sinal de ECG, (b) análise de dpg. Fonte: Figueiredo & Furuie 2001a.71
- Figura 5.14: Atratores correspondentes aos instantes de tempo indicados na figura 5.13. Fonte: Figueiredo & Furuie 2001a.72
- Figura 5.15: (a) Atrator reconstruído de um sinal de ECG normalizado. (b) O mesmo atrator distribuído sobre uma malha uniforme com 5 bits de resolução (cada célula representa o total de pontos que caem dentro de cada célula). (c) Uma malha *quadtree* gerada da distribuição da malha uniforme. Fonte: Figueiredo & Furuie 2001b.74
- Figura 5.16: Dpg do sinal sel872 da base dedados Physionet para: $m = 2$, $\tau = 12$ ms e $b = 9$. Fonte: Figueiredo & Furuie 2001b.75
- Figura 5.17: Uma série temporal de intervalos de batimentos cardíacos (A) e uma série randomizada (B). Sucessivas ampliações de subconjuntos da série mostrando que ambas as séries são auto-similares. Fonte: Peng, et al 2000.76
- Figura 5.18: (a) Análise de DFA para as séries temporais observadas na figura 5.17. (b) Análise do espectro de potência para as séries temporais observadas na figura 5.17. Fonte: Peng, et al 2000.77
- Figura 5.19: Análise de DFA para três séries temporais de intervalos de batimentos cardíacos: pessoas jovens saudáveis, pessoas idosas e pessoas com CHF. Fonte: Stanley, et al 1999.78

-
- Figura 6.1: QuadTreeECG, interface gráfica para a entrada de dados desenvolvida para análise de distâncias estatísticas..... 83
- Figura 6.2: Dpg, interface gráfica para a entrada de dados desenvolvida para análise de distâncias estatísticas..... 84

LISTA DE TABELAS

Tabela 3.1: Principais índices de variação da frequência cardíaca (VFC). Fonte: Grupi 1998.....	17
Tabela 4.1: Funções de distâncias estatística utilizadas para o cálculo da distância entre duas distribuições p e g. Fonte: Wilson & Martinez 1997.....	45
Tabela 5.1: D_2 (das derivações de extremidade) dos sinais obtidos das 12 derivações simultâneas. Fonte: Wang, et al. 2000.	65
Tabela 5.2: D_2 (das derivações precordiais) dos sinais obtidos das 12 derivações simultâneas. Fonte: Wang, et al. 2000.	65
Tabela 5.3: D_2 (das derivações de extremidade) dos sinais obtidos das 12 derivações simultâneas para pacientes com infarto agudo do miocárdio. Fonte: Wang, et al. 2000. ..	65
Tabela 5.4: D_2 (das derivações precordiais) dos sinais obtidos das 12 derivações simultâneas para pacientes com infarto agudo do miocárdio. Fonte: Wang, et al. 2000. ..	65
Tabela 7.1: Comparação entre os métodos clássicos e não lineares apresentadas de análise de ECG.....	90

ABREVIATURAS

ApEn	Entropia aproximada (<i>entropy approximated</i>)
AS	nódulo sinoatrial
AV	nódulo atrioventricular
bpm	batimentos por minuto
CHD	<i>Congestive heart disease</i>
CHF	<i>Congestive heart failure</i> (CHF)
DFA	<i>Detrended Fluctuation Analysis</i>
ECG	Eletrocardiograma
R, L, F	punho direito (<i>right</i>), esquerdo (<i>left</i>) e tornozelo (<i>foot</i>)
VFC	variação da frequência cardíaca (<i>heart rate variability</i>)

1 INTRODUÇÃO

1.1 Objetivos da Dissertação

Esta dissertação visa estudar a aplicabilidade e a importância prognóstica de métodos matemáticos de análise não linear no estudo das variações da frequência cardíaca e no estudo das mudanças morfológicas nos sinais de eletrocardiograma (em situações normais e patológicas). Visa também apresentar uma revisão geral desse assunto, construindo um retrato do que existe hoje de mais importante na aplicação de técnicas de análise não linear, para o estudo de sinais de eletrocardiograma. Busca-se construir uma base de conhecimentos que permita, no futuro, a abordagem de novos aspectos dessas metodologias. Também é um objetivo, o desenvolvimento de algoritmos que apliquem algumas das técnicas de análise não linear, estudadas nesta dissertação, em sinais de eletrocardiograma.

1.2 O Estudo do Eletrocardiograma (ECG)

Os estudos sobre a variação da frequência cardíaca, e sobre as alterações morfológicas nos sinais de eletrocardiograma (ECG), desempenham um papel importante na cardiologia, principalmente pelo fato de tais estudos serem baseados em medidas não invasivas, simples de executar e facilmente reproduzíveis. Além disso, tais estudos fornecem importantes informações a respeito do prognóstico de pacientes com doenças cardíacas [Baselli, et al. 1987, David, et al. 1994, Ewing, et al. 1984, Huikuri, et al. 1996 Kleiger, et al. 1992, Öri, et al. 1992].

Hoje em dia, tanto os estudos da variação da frequência cardíaca como das alterações morfológicas do ECG são, em grande parte, feitos com o uso de técnicas baseadas em métodos clássicos de análise de sinais como, por exemplo, os métodos de análise no domínio do tempo e da frequência [Bigger, et al. 1992, Malliani, et al. 1991]. Todavia, um conjunto de métodos e ferramentas analíticas e numéricas, originadas principalmente do estudo da dinâmica dos sistemas não lineares na física e na matemática, têm servido de base para obtenção de resultados promissores no estudo dos sinais de ECG [Goldberger & West 1987, Kantz & Schreiber 1998, Kaplan & Goldberger 1991, Wang, et al. 2000].

Evidências de que o coração, mesmo sob condições fisiológicas normais, não é um oscilador periódico [Babloyantz & Destexhe 1988] e de que os modelos associados à manutenção da função cardíaca são fundamentalmente não lineares [Goldberger & West 1987, Kaplan & Goldberger 1991] apontam para a importância do uso de métodos de estudo baseados em ferramentas de análise não linear, a maioria oriunda do estudo de sistemas dinâmicos que apresentam o chamado *comportamento caótico*. O termo

comportamento caótico é usado para denotar um tipo de evolução temporal de um sistema dinâmico sensível às condições iniciais [Crutchfield, et al. 1987]. Apesar da existência de comportamento caótico em sinais de ECG ainda ser muito discutida [Kantz & Schreiber 1998], o uso de ferramentas analíticas e numéricas desenvolvidas para o estudo e detecção deste tipo de comportamento em sistemas dinâmicos tem sido amplamente aplicado ao estudo desse tipo de sinal [Goldberger 1990, Goldberger 1996, Kaplan & Goldberger 1991]. Por exemplo, a técnica de reconstrução de Takens, que corresponde a um método para a representação do espaço de fase de um sistema dinâmico a partir de uma série temporal, pode ser usada em estudos qualitativos sobre a variância da frequência cardíaca [Huikuri, et al. 1996, Tulppo, et al. 1996]. Os diagramas de Takens, diagramas nos quais os valores no tempo do ECG são colocados em um gráfico como função dos valores do ECG em instantes anteriores no tempo, também foram usados para separar sinais de ECG em várias classes [Schechtman, et al. 1993, Woo, et al. 1994] e para identificar comportamento possivelmente caótico em sinais de ECG [Tulppo, et al. 1996]. O uso da técnica de Takens aplicada a sinais de ECG ainda é um assunto muito discutido, uma vez que alguns requisitos necessários para a reconstrução do diagrama de Takens de um sistema, a partir da série temporal, podem não ser satisfeitos em um sinal de ECG [Kantz & Schreiber 1998]. Contudo, o sucesso do uso da técnica em alguns casos mostra a necessidade de mais estudos, principalmente no sentido de definir limites mais específicos para sua aplicação. Outro tipo de técnica importante na análise não linear de sinais de ECG envolve o uso de métodos baseados em medidas de informação de um sinal. Uma dessas técnicas é a do cálculo da *Entropia Aproximada* (Approximated Entropy – ApEn). A ApEn é uma medida usada para quantificar a regularidade e a previsibilidade de um sinal a partir de um trecho da série temporal original. A ApEn foi desenvolvida para

classificar séries temporais de sistemas complexos, que incluem tanto sistemas determinísticos como processos estocásticos [Pincus 1991, Pincus & Huang 1992, Pincus & Viscarello 1992]. O uso dessa medida, aplicada a sinais temporais, permite discernir o grau de complexidade de um sinal utilizando uma quantidade relativamente pequena dos dados. Outro método que envolve o uso de medidas de informação é o *Cálculo de Distâncias Estatísticas* [Diambra 1999]. Este método foi utilizado em um trabalho do Serviço de Informática do Instituto do Coração do Hospital das Clínicas da Universidade de São Paulo, onde se estudou a detecção de mudanças de comportamento dinâmico em sinais de Holter de longa duração [Figueiredo & Furuie 2001a, Figueiredo & Furuie 2001b].

Vários outros métodos de análise não linear também são importantes e podem ser aplicados na análise de sinais de ECG, como por exemplo, o cálculo de dimensões fractais, que fornece uma idéia a respeito da complexidade de um sistema dinâmico a partir da dimensão de seu espaço de fase [Iyengar, et al. 1996, Yamamoto, et al. 1995], e o cálculo de expoentes de Lyapunov, que mede a taxa de divergência de trajetórias próximas em um espaço de fase [Casaleggio & Braiotta 1997].

Esses métodos têm fornecido novas idéias e técnicas para a compreensão de sistemas dinâmicos complexos. Nesta tese, estudaremos como esses métodos podem ser usados para a análise dos sinais de ECG. No capítulo 2 serão apresentados os conceitos fisiológicos básicos dos fenômenos elétricos associados à atividade cardíaca para o estudo do ECG, e também explicaremos como se obtém o registro do ECG na prática clínica. No capítulo 3 serão descritas algumas técnicas clássicas de análise de sinais utilizadas para estudos sobre a variação da frequência cardíaca e alterações morfológicas do ECG. No

capítulo 4 serão apresentadas as teorias e ferramentas utilizadas para o estudo de sistemas dinâmicos não lineares, que fornecem uma base para os métodos de análise de sinais de ECG, que serão discutidos nas aplicações apresentadas no capítulo 5. No capítulo 6 será apresentado um programa que implementa um conjunto de algoritmos voltado para a análise de sinais de ECG com o uso de cálculos de distâncias estatísticas [Figueiredo & Furuie 2001a, Figueiredo & Furuie 2001b]. Finalmente, no capítulo 7 apresentaremos as conclusões deste trabalho e apontaremos direções para trabalhos futuros.

2 ELETROFISIOLOGIA DO CORAÇÃO

Neste capítulo, serão apresentados os conceitos fisiológicos básicos dos fenômenos elétricos associados à atividade cardíaca, necessários para a interpretação da morfologia do ECG. Também será explicada a maneira como o ECG é usualmente registrado na prática clínica.

2.1 O Músculo Cardíaco

O *coração humano* é dividido em quatro cavidades: dois átrios e dois ventrículos. Esse conjunto de cavidades mantém a circulação sanguínea para o resto do corpo por meio de contrações rítmicas. As paredes do coração são compostas de três camadas: internamente, uma membrana serosa chamada de *endocárdio*; no meio, uma camada composta de um tecido muscular chamada de *miocárdio*; e, externamente, outra membrana serosa chamada de *epicárdio*. Os átrios e os ventrículos do mesmo lado se comunicam entre si através dos orifícios atrioventriculares, porém as cavidades do lado esquerdo não se comunicam com as do lado direito, as paredes que separam esses dois

lados são chamadas de *septo interatrial* (separam os átrios) e *septo interventricular* (separam os ventrículos) (figura 2.1).

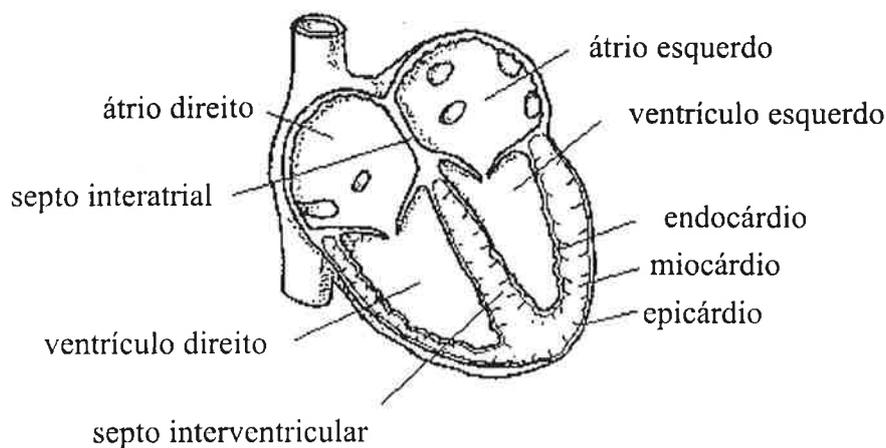


Figura 2.1: Anatomia do coração. Fonte: Rocha & Júnior 1973.

O miocárdio é constituído de células que apresentam quatro propriedades: (1) *excitabilidade*, capacidade de responder a um estímulo, (2) *contratibilidade*, a resposta ao estímulo é representada pela contração muscular, (3) *automatismo*, a propriedade de originar, dentro de si mesma, o impulso que determina a contração e (4) *condutividade*, o processo de ativação se propaga por toda a musculatura cardíaca. Essas células são chamadas de *células miocárdicas*.

Quando o interior da célula miocárdica está carregado negativamente em relação ao exterior (aproximadamente 80 mV), é dito que a célula está *polarizada* (figura 2.2). Se a célula está polarizada e não existem influências externas (estímulos) sobre a mesma, é dito que a célula encontra-se em *estado de repouso*, e a diferença de potencial através da

membrana da célula é definida como *potencial de repouso*. Esse potencial é determinado pelas diferenças nas concentrações iônicas dos fluidos interno e externo à membrana celular e pelas diferenças na permeabilidade da membrana para os diferentes íons.

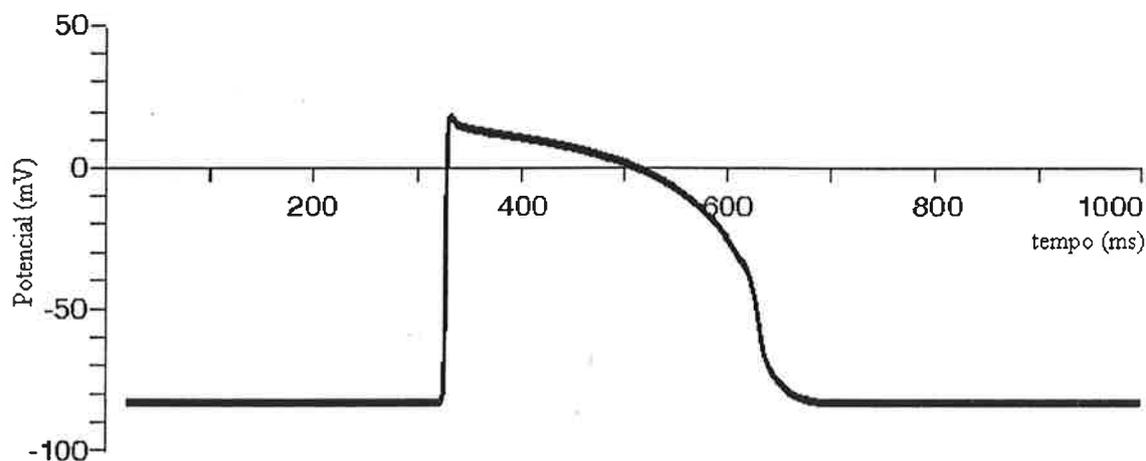


Figura 2.2: Registro típico do potencial de ação de uma célula miocárdica. Fonte: Hobbie 1997.

Já o *potencial de ação*, ou estímulo, resulta de uma alteração transitória na permeabilidade iônica da membrana, o que permite o movimento de certos íons segundo seus gradientes elétrico e de concentração (químico). Entende-se aqui gradiente elétrico/químico como uma força de origem elétrica/química que conduz o sistema em direção ao estado de equilíbrio eletroquímico. Quando se inicia o processo de estimulação muscular, que será descrito adiante, o interior da célula miocárdica se torna positivo. Essa fase é denominada de *despolarização*. A despolarização causa a contração progressiva das células miocárdicas à medida que um impulso é transmitido ao longo do miocárdio. Após a despolarização, as concentrações iônicas tendem a apresentar-se como estavam no estado de repouso, ou seja, as células voltam a apresentar negatividade no seu interior e positividade no exterior, essa fase é denominada de *repolarização*. Ao longo deste período de repolarização, o músculo cardíaco entra em relaxamento.

2.2 Sistema de Condução Cardíaca

No miocárdio existe um sistema de condução que permite uma rápida transmissão do estímulo elétrico através do próprio músculo, levando-o a contração. A fim de maximizar a força da contração, a contração dos átrios é sempre seguida pela contração dos ventrículos, garantindo desta forma uma eficiente ejeção de sangue nas artérias. Antes de descrever o sistema de condução, é necessário entender de onde surge o estímulo inicial para contração do miocárdio.

Nem todas as células miocárdicas apresentam o mesmo potencial de ação, algumas células são capazes de gerá-lo espontaneamente, ou seja, despolarizam-se sem a necessidade de um estímulo. Essas células são chamadas de *células marca-passo*. A propagação do potencial de ação tem origem em um nódulo formado por um tecido marca-passo que está localizado na parede posterior do átrio direito, esse nódulo é denominado de nódulo sinoatrial (SA). O estímulo do nódulo SA gera uma onda de despolarização que, conforme o estímulo passa através dos átrios, produz uma contração chamada de atrial. O sistema de condução cardíaco pode ser visualizado na figura 2.3.

Entre os átrios e os ventrículos existe um nódulo que faz a conexão elétrica entre eles, esse nódulo é chamado de nódulo atrioventricular (AV). O estímulo propagado atinge o nódulo atrioventricular (AV) cerca de 20-30 ms após sua partida do nódulo SA. Neste ponto, a transmissão do estímulo se torna mais lenta, o que garante que os átrios despejem o sangue para os ventrículos antes que os mesmos se contraíam. Após a passagem do nódulo AV, a despolarização estende-se rapidamente sobre um feixe de fibras, chamado de feixe de His, que divide-se em dois ramos, chamados de ramo

esquerdo e direito. Esses ramos por sua vez, se subdividem em feixes de fibras conhecidas como fibras de Purkinge.

A distribuição do tecido condutor e a velocidade de condução dos vários tecidos garantem que a transmissão do impulso atinja mais de 50% da massa ventricular em um intervalo de 10 ms, garantindo a contração quase síncrona. Uma descrição mais detalhada da fisiologia do coração pode ser vista em Rocha & Júnior [1973].

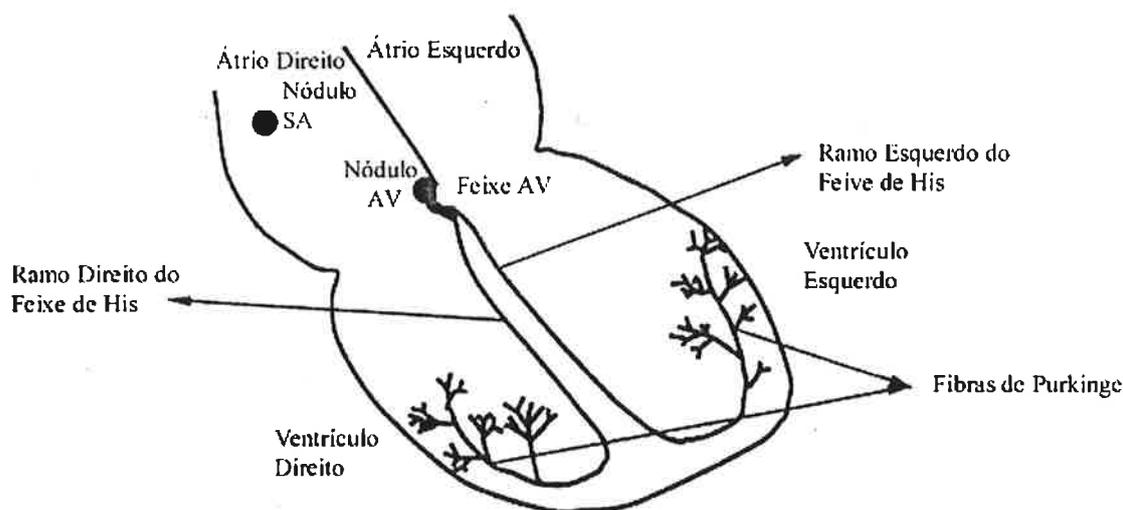


Figura 2.3: Esquema da secção transversal do coração mostrando o sistema de condução dos impulsos elétricos. Fonte: Motta 1992.

O eletrocardiograma é o registro da diferença de potencial por meio de eletrodos aplicados sobre a superfície corporal, tal registro representa a soma de todas as alterações elétricas que ocorrem no coração em determinado instante [Hobbie 2000], ou seja, através do sinal de ECG é possível conhecer parte do comportamento do coração. O registro instantâneo da atividade cardíaca sobre um período de observação contínua gera uma série temporal que é chamada de eletrocardiograma [Bolis & Licinio 1999].

2.2.1 Metodologias e Convenções

Os sinais de eletrocardiograma são largamente empregados como uma ferramenta de diagnóstico na prática clínica a fim de avaliar a condição cardíaca dos pacientes, pois são baseados em medidas não invasivas, simples de executar e facilmente reproduzíveis [Talmon 1983].

A princípio pode-se obter o eletrocardiograma em qualquer ponto da superfície corporal, mas existem pontos padronizados onde se colocam eletrodos com essa finalidade. Esses eletrodos podem ser ligados entre si permitindo a obtenção de doze diferentes registros, cada uma dessas ligações é conhecida como uma *derivação* do eletrocardiograma. As derivações estão divididas em dois grupos: *derivações de extremidade*, que permitem apreciação da atividade elétrica sobre o plano frontal, e *derivações precordiais*, que permitem a apreciação da atividade elétrica sobre o plano

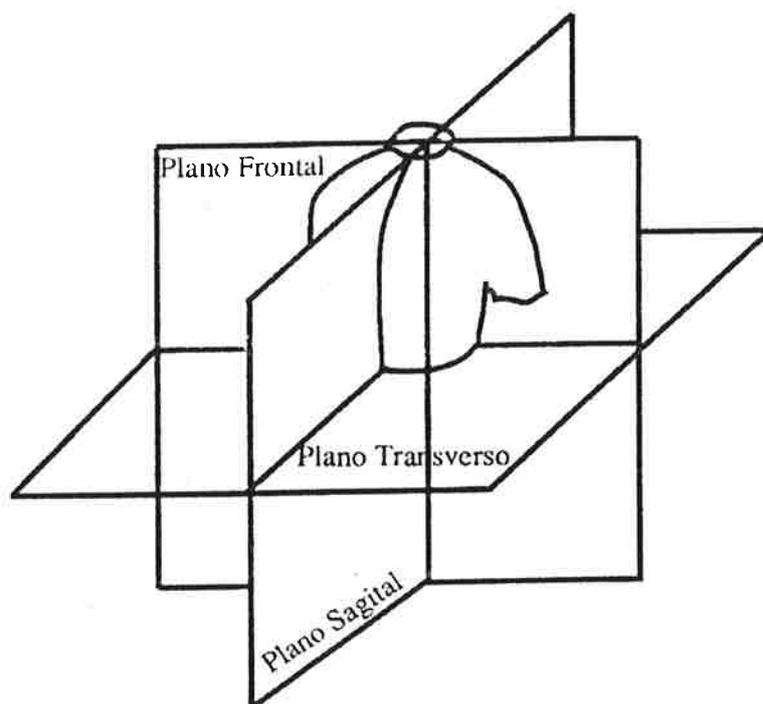


Figura 2.4: Planos para análise do ECG. Fonte: Motta 1992.

transversal (figura 2.4). Em ambos os tipos de derivações um eletrodo aplicado ao tornozelo direito é ligado a terra para evitar interferências eletromagnéticas sobre o registro.

Nas derivações de extremidade os eletrodos estão localizados sobre os punhos e o tornozelo. Os eletrodos aplicados aos punhos recebem, respectivamente, os nomes de R (right) sobre o punho direito e L (left) sobre o punho esquerdo. O eletrodo aplicado ao tornozelo esquerdo recebe o nome de F (foot). As derivações de extremidade se subdividem em derivações unipolares e derivações bipolares. As bipolares (DI, DII, e DIII) (figura 2.5) correspondem à diferença de potencial entre duas extremidades. As diferenças de potencial são:

$$\begin{aligned} V_I &= V_L - V_R, \\ V_{II} &= V_F - V_R, \\ V_{III} &= V_F - V_L. \end{aligned} \quad (2.1)$$

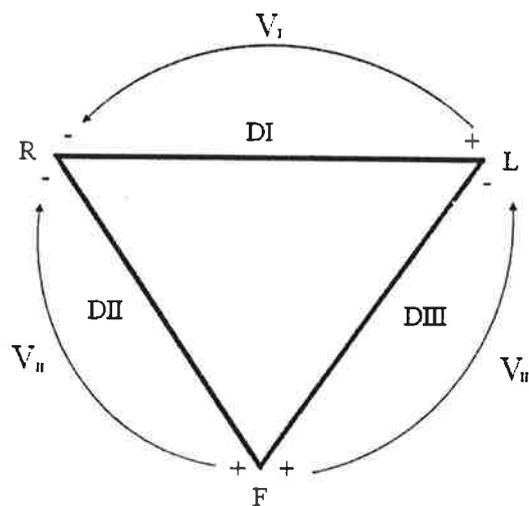


Figura 2.5: Representação esquemática da orientação espacial das derivações bipolares clássicas.

Já as derivações unipolares, também chamadas de *a* (aumentadas), correspondem à diferença de potencial em uma das extremidades (R, L ou F) quando comparada com outras duas extremidades restantes ligadas entre si:

$$aVR = V_R - \frac{1}{2}(V_L + V_F), \quad (2.2)$$

$$aVL = V_L - \frac{1}{2}(V_F + V_R),$$

$$aVF = V_F - \frac{1}{2}(V_R + V_L).$$

Nas derivações unipolares temos a seguinte configuração:

aVR: eletrodo em R; eletrodos em L e F ligados entre si;

aVL: eletrodo em L; eletrodos em F e R ligados entre si;

aVF: eletrodo em F; eletrodos em R e L ligados entre si.

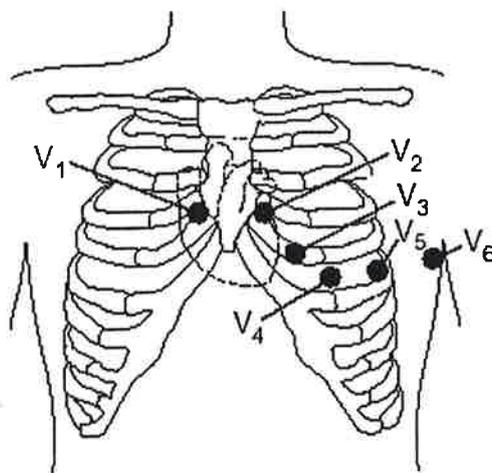


Figura 2.6: Representação esquemática da orientação espacial das derivações precordiais. Fonte: Hobbie 1997.

Nas derivações precordiais, um eletrodo é colocado na superfície torácica sucessivamente em seis posições: V1, V2, V3, V4, V5 e V6 (figura 2.6). Este eletrodo recebe o nome de C (central). Os três eletrodos de extremidade (L, R e F) estão ligados entre si.

2.2.2 Nomenclatura do ECG e o Ciclo Cardíaco

O *ciclo cardíaco* representado pelo sinal de ECG se apresenta como a curva da figura 2.7. As ondas, regiões que não apresentam potencial nulo, são chamadas de *deflexões*. A distância entre duas ondas é chamada de *segmento*, e a distância que envolve deflexões e segmentos é definida como *intervalo*. Por exemplo, a distância entre dois sucessivos picos da onda R é chamada de intervalo RR. A seguir são caracterizados os principais constituintes do ciclo cardíaco [Motta 1992]:

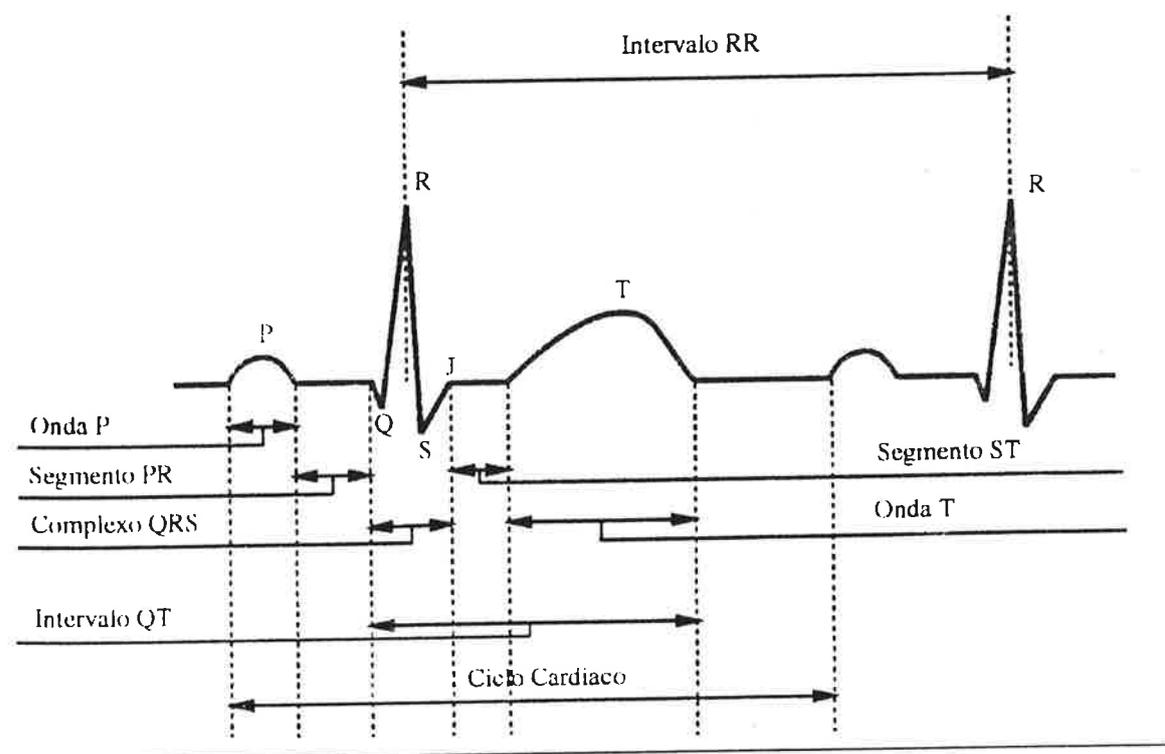


Figura 2.7: O ciclo cardíaco e seus principais constituintes. Fonte: Motta 1992.

- *Onda P*: deflexão produzida pela despolarização dos átrios. Exibe morfologia arredondada, amplitude de até 0,25 mV, dura em média 80 ms, e representa o estímulo conforme ele se propaga do átrio até o nódulo AV.
- *Segmento PR*: indicado pela linha isoeétrica, medindo aproximadamente 80 ms, durante este segmento não há diferenças de potencial registráveis no ECG. Durante este período o impulso está se propagando através do nódulo AV.
- *Complexo QRS*: deflexão produzida pela despolarização dos ventrículos, dura em média 80 ms, e representa o estímulo conforme ele se propaga através dos ventrículos.
- *Segmento ST*: corresponde à parte do sinal compreendida entre o final do complexo QRS, chamado de ponto J, e o início da onda T.
- *Onda T*: deflexão produzida pela repolarização ventricular. Exibe amplitude entre 0,1 e 0,5 mV.

No capítulo seguinte, veremos alguns dos métodos clássicos utilizados para o estudo do comportamento desse tipo de sinal.

3 MÉTODOS CLÁSSICOS DE ANÁLISE DO ECG

A condição cardíaca é geralmente refletida na morfologia do ECG e na *frequência cardíaca*, definida como o número de batimentos por minuto (bpm) do coração [Teich, et al. 2001]. Desta forma, é possível obter informações sobre a atividade elétrica do coração através de estudos da variação da frequência cardíaca (VFC) e das alterações morfológicas do ECG. No entanto, na maioria dos trabalhos sobre a dinâmica do coração, os pesquisadores focam predominantemente a análise da variação da frequência cardíaca (VFC), pois esta fornece alguns prognósticos importantes sobre pacientes com doenças cardíacas [Seely & Macklem 2004].

A análise da VFC é caracterizada pelas chamadas medidas de flutuação dos intervalos RR no sinal de ECG. O uso dos intervalos RR é justificado pelo fato dos picos do complexo QRS serem de fácil identificação, o que permite que as medidas do intervalo RR possam ser realizadas com poucos erros [Teich, et al. 2001]. A maioria dos estudos sobre VFC é baseada em métodos clássicos de análise de sinais, tais como a análise no domínio do tempo e análise no domínio da frequência. [Baselli, et al. 1987, David, et al. 1994, Ewing, et al. 1984, Huikuri, et al. 1996, Kleiger, et al. 1992, Öri, et al. 1992].

3.1 Análise no domínio do tempo

Os métodos mais simples de análise da VFC são aqueles baseados nas chamadas medidas no domínio do tempo. Usualmente, a flutuação da frequência cardíaca tem sido baseada em índices estatísticos sobre os intervalos RR, tais como a média e o desvio padrão [Mäkikallio 1998]. Dependendo do segmento do ECG analisado, o intervalo de tempo pode variar de 5 minutos a 24 horas e pode ser caracterizado e quantificado pelos índices estatísticos dos intervalos RR [Task Force 1996]. Na tabela 3.1 estão reunidos os principais desses índices.

Índice	Unidade	Definição
RRMED	ms	Média de todos os intervalos RR
SDNN	ms	Desvio padrão de todos os intervalos RR
SDANN	ms	Desvio padrão da média dos intervalos RR calculada em segmentos de 5 minutos
SDNNi	ms	Média dos desvios padrão dos intervalos RR calculados em segmentos de 5 minutos
RMSSD	ms	Raiz quadrada da média das diferenças sucessivas ao quadrado entre RR adjacentes
PNN50%	%	Porcentagem das diferenças sucessivas entre os intervalos RR que são > 50 ms

Tabela 3.1: Principais índices de variação da frequência cardíaca (VFC). Fonte: Grupi 1998.

Também existem os métodos geométrico-estatísticos que são utilizados mais frequentemente para analisar se intervalos RR incorretos foram considerados na análise dos outros índices estatísticos de VFC presentes da tabela 3.1. Esses métodos utilizam uma distribuição de densidade D gerada a partir do histograma das durações dos intervalos RR (figura 3.1). O método de processamento geométrico-estatístico mais simples é denominado índice triangular de VFC. A idéia consiste em aproximar a forma do histograma por um triângulo, onde a altura deste triângulo é equivalente ao pico

principal do histograma, o máximo da distribuição de densidade (Y). O índice triangular de VFC é definido como a integral da distribuição de densidade (o número total de todos os intervalos RR) dividido pelo máximo da distribuição de densidade. Como a área do triângulo é a integral da distribuição de densidade, o índice triangular de VFC é igual à *área do triângulo*/ Y (figura 3.1).

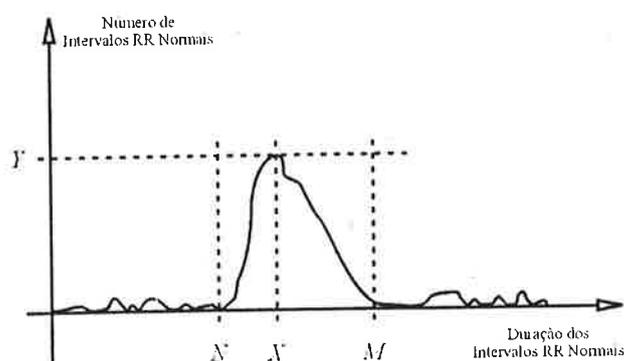


Figura 3.1: Histograma de densidade de amostra dos intervalos RR utilizados para o cálculo do índice triangular VFC. Fonte: Task Force 1996.

Outro método geométrico-estatístico mais refinado é o da interpolação triangular do histograma dos intervalos RR (*TIRR – Triangular Interpolation of RR interval*). Neste método, é ajustada uma função multilinear $q(t)$ à distribuição de densidade D , tal que $q(t) = 0$ para $t \leq N$ e $t \geq M$ e $q(X) = Y$, e tal que a integral

$$\int_0^{+\infty} (D(t) - q(t))^2 dt \quad (3.4)$$

é mínima entre todas as seleções de todos os valores de N e M . Geometricamente, esse método é capaz de identificar um triângulo para o qual a diferença dos quadrados entre o histograma e o triângulo é a mínima entre todos os triângulos possíveis. A largura da linha base do triângulo ($M-N$) é tomada como outra medida de VFC [Farrell, et al. 1991, Malik, et al. 1989]. Como algumas vezes uma onda T alta ou um ruído podem ser identificados

como o pico de uma onda R, tais medidas incorretas cairão fora do pico principal do histograma, podendo ser facilmente identificadas, ou seja, a técnica na verdade serve como ferramenta de pré-seleção dos intervalos RR que podem ser considerados para outros estudos da VFC.

A literatura aponta que a variação sobre os índices estatísticos no domínio do tempo está associada a um aumento do risco de mortalidade em pessoas tais como: idosos, pessoas com doença na artéria coronária, com pós-infarto do miocárdio ou com insuficiência cardíaca congestiva [Seely & Macklem 2004].

3.2 Análise no domínio da frequência

Desde a introdução da análise espectral como um método de estudo da VCF [Akselrod, et al. 1981], um número cada vez maior de investigadores vem utilizando este método. A análise espectral de VFC envolve a decomposição da série temporal de intervalos RR em uma soma de funções periódicas de diferentes amplitudes e frequências. O espectro de potência reflete a intensidade das flutuações da frequência cardíaca presentes em diferentes frequências que compõem o sinal de ECG e pode ser estimado por dois métodos de aproximação: um não paramétrico, usando a transformada de Fourier (FFT), e um paramétrico, usando o modelo autoregressivo (AR) (Apêndice A).

Para visualizar a série de intervalos RR obtida a partir do sinal de ECG, constrói-se um gráfico das durações das seqüências dos intervalos RR como uma função dos batimentos cardíacos, chamado de *intervalo tacograma RR* ou, mais concisamente, *tacograma* (figura 3.2-a).

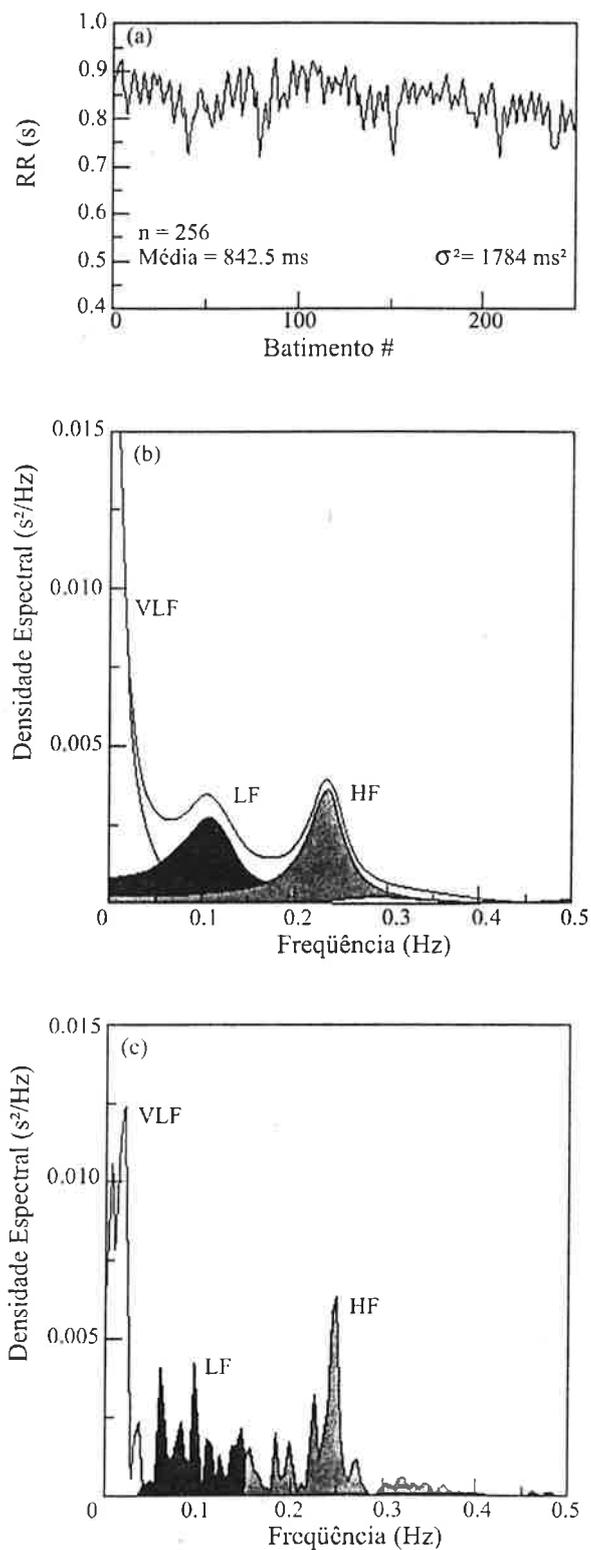


Figura 3.2: Tacograma de um sinal de uma pessoa saudável em repouso (a) e a densidade espectral obtida pela transformada de Fourier (b) e pelo modelo autoregressivo (c). Fonte: Task Force 1996.

Comumente, os pesquisadores dividem o espectro de potência dentro de diferentes bandas espectrais e calculam a potência referente a cada banda [Task Force 1996]. Em registros curtos (1-5 minutos) costuma-se decompor a potência em três bandas distintas: (1) banda de alta frequência (HF), oscilando a uma frequência de 0,15 a 0,40 Hz; (2) banda de baixa frequência ou LF (0,04 a 0,15 Hz); (3) banda de muito baixa frequência ou VLF (<0,003 Hz) [Task Force 1996]. Na figura 3.2(b) e na figura 3.2(c), vemos a densidade espectral da seqüência de intervalos RR obtidos do sinal de ECG de uma pessoa saudável em repouso.

Existe grande evidência que as contribuições das frequências para VFC são alteradas no estado patológico. Essas alterações podem ser vistas, por exemplo, no espectro de potência para pessoas com: insuficiência cardíaca, infarto do miocárdio e doença na artéria coronária [Seely & Macklem 2004].

3.3 Limitações da Análise Clássica de VFC

Apesar da análise linear da VFC possuir potencial de valor clínico, tais aplicações são muito restritas pelas seguintes razões. Primeiro, o estudo de índices estatísticos baseados nos momentos da distribuição dos valores medidos (média e desvio padrão) requer métodos adicionais para a distinção de sinais fisiológicos [Bolis & Licinio. 1999]. Como exemplo, na figura 3.3 vemos duas seqüências de intervalos entre batimentos, um para indivíduo normal e um outro para um sujeito com insuficiência cardíaca congestiva, em inglês, *congestive heart failure* (CHF), uma incapacidade do coração de efetuar as suas funções de forma adequada como consequência de outras enfermidades, do próprio coração ou de outros órgãos. A inspeção visual deixa claro que existem diferenças na

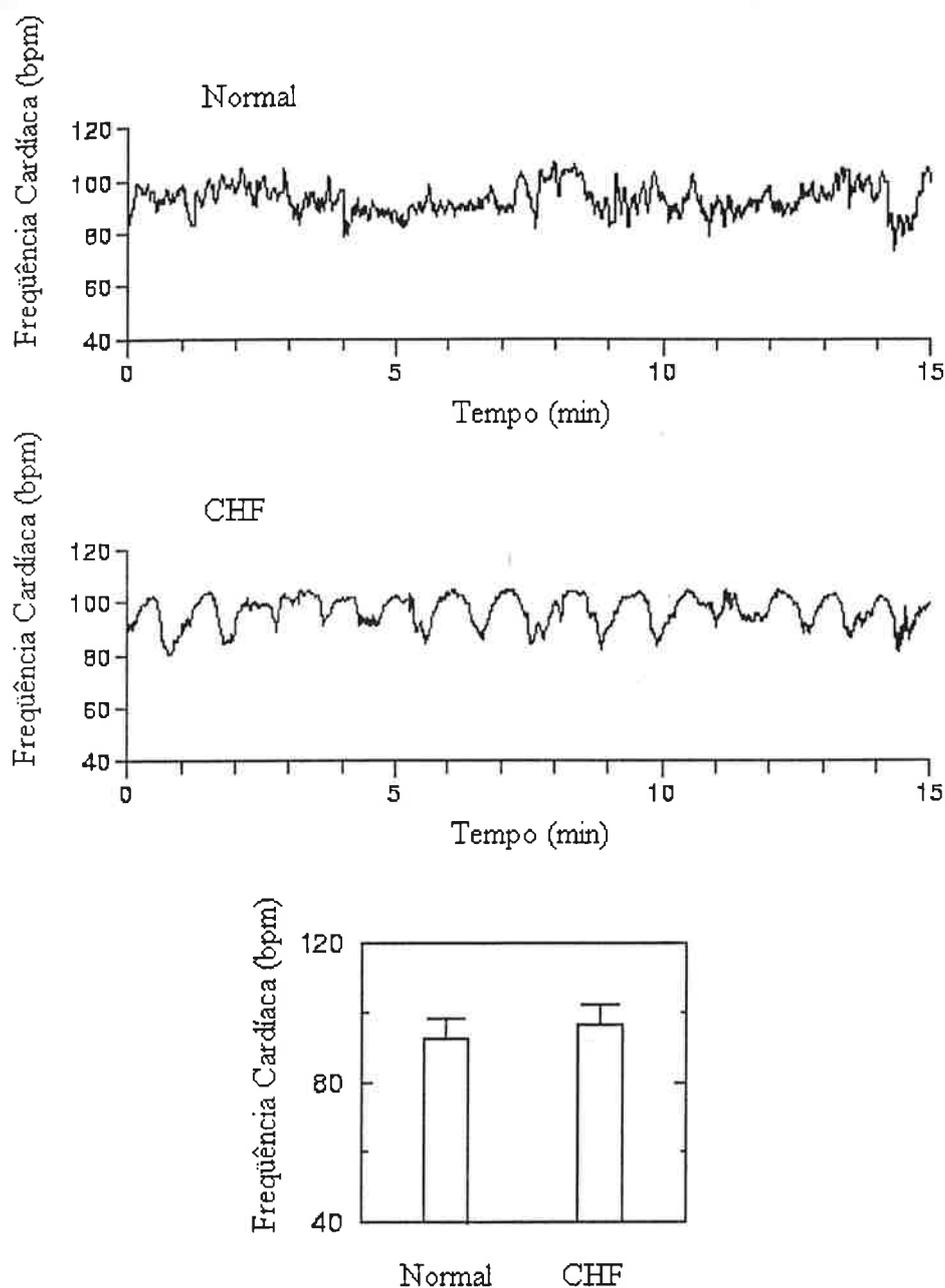


Figura 3.3: Série temporal de duas frequências cardíacas, uma de uma pessoa saudável (a) e outra de uma pessoa com insuficiência cardíaca congestiva (b). Ambas têm médias e variância próximas (c). Fonte: Bolis & Licinio 1999.

dinâmica que gera os dois sinais, apesar dos sinais apresentam praticamente a mesma média e o mesmo desvio padrão. Segundo, para se estimar os parâmetros da dinâmica linear, necessitamos de um grande conjunto de dados, o que requer que o paciente fique

imobilizado por horas. Isto é quase impossível na rotina da prática clínica [Wang, et al. 2000]. Terceiro, se uma quantidade suficiente de dados do intervalo RR é obtida de um longo registro de ECG, o estado fisiológico do paciente pode mudar significativamente [Wang, et al. 2000]. Tais mudanças violam as pré-condições do cálculo do espectro de potência, isto é, o sistema estudado não permaneceria no estado estacionário e nem próximo do estado estacionário (apêndice A). Quarto, existe uma diferença fundamental entre um traço de ECG completo e a seqüência de intervalos RR. Pode-se estar desprezando informações importantes contidas entre os intervalos RR [Kantz & Schreiber 1998].

4 ANÁLISE DE SÉRIES TEMPORAIS NÃO LINEARES

Neste capítulo apresentaremos algumas teorias e ferramentas, utilizadas para o estudo de sistemas dinâmicos e séries temporais não lineares, que formam a base para os métodos de análise de sinais de ECG que serão discutidos no próximo capítulo.

4.1 Introdução

De modo não rigoroso, sistemas dinâmicos podem ser definidos como estruturas matemáticas utilizadas para modelar fenômenos físicos cujos estados, ou uma descrição instantânea deles, evoluem no tempo. Pode-se atribuir às aplicações destes modelos as seguintes funções: preditiva, na qual o objetivo é prever estados futuros do sistema a partir de observações do passado e do estado presente do sistema; diagnóstica, na qual o objetivo é deduzir quais dos possíveis estados passados do sistema poderiam ter conduzido ao presente estado; e aplicativa, na qual o objetivo é prover uma teoria para os fenômenos físicos em questão. Estas três características correspondem às necessidades

básicas científicas no sentido de se prever, explicar, e entender os fenômenos físicos [Figueiredo 2000].

Usualmente, os modelos matemáticos desenvolvidos para expressar a evolução temporal dos sistemas dinâmicos são definidos por um conjunto de equações diferenciais ordinárias (EDOS), mas vale ressaltar que, dependendo do fenômeno natural que estamos estudando e do tipo de hipóteses que fazemos para tentar compreendê-lo, podemos chegar a outros tipos de modelos matemáticos que dizem respeito a sistemas de equações integrais, equações funcionais, aplicações m -dimensionais com tempo discreto, etc., e todos estes são, genericamente, considerados sistemas dinâmicos.

4.2 Conceitos Básicos de Sistemas Dinâmicos

Para descrever um sistema dinâmico em dado instante no tempo é necessário definir um espaço matemático abstrato constituído pelas variáveis dinâmicas do sistema. Este espaço é conhecido como *espaço de fases* (ou ainda *espaço de estado*). Cada ponto desse espaço de fases representa um estado do sistema. Se há m variáveis dinâmicas no sistema, o estado é especificado por um vetor $\vec{x} \in \mathbf{R}^m$. Esse sistema pode ser descrito como uma aplicação m -dimensional ou por um sistema de m equações diferenciais ordinárias de primeira ordem. No primeiro caso o tempo é uma variável discreta:

$$\vec{x}_{i+1} = \vec{F}(\vec{x}_i), \quad i \in \mathbf{Z} \quad (4.1)$$

e no segundo caso é uma variável contínua:

$$\frac{d\bar{x}(t)}{dt} = \bar{f}(t, \bar{x}(t)), t \in \mathbf{R}. \quad (4.2)$$

Na segunda situação, \bar{f} é chamada de *fluxo*. Se \bar{f} não depende explicitamente do tempo, o fluxo é chamado de fluxo *autônomo*. A seqüência de pontos \bar{x}_i ou $\bar{x}(t)$ que representa a evolução das soluções é conhecida como *trajetória de fase* ou *linhas de fluxo* do sistema dinâmico. E \bar{x}_0 e $\bar{x}(0)$ são as *condições iniciais* de (4.1) e (4.2), respectivamente. As trajetórias de fase típicas, ou tenderão para o infinito conforme o tempo evolui, ou ficarão sempre em uma região limitada. O comportamento observado depende da forma de \bar{F} (ou, respectivamente, \bar{f}) e das condições iniciais. Muitos sistemas admitem ambos os tipos de soluções. O conjunto de condições iniciais que leva para o mesmo comportamento assintótico é chamado de *bacia de atração*.

Um sistema dinâmico, no qual os elementos de hiper-volume contendo as condições iniciais no espaço de fase se contraem conforme o sistema evolui, é chamado de sistema dissipativo. Temos que sobre esse hiper-volume,

$$|\det \mathbf{J}_{\bar{F}}| \text{ ou } \nabla \bar{f} < 0, \text{ respectivamente.} \quad (4.3)$$

Onde $\mathbf{J}_{\bar{F}}$ é a matriz Jacobiana de derivadas de \bar{F} : ($\mathbf{J}_{\bar{F}} = \partial / \partial x^{(j)} F_i(\bar{x})$). Logo, a dinâmica tenderá a permanecer confinada a uma região do espaço de fase [Thompson & Stewart 1986]. Este conjunto é invariante¹ sobre a evolução dinâmica do sistema e é chamado de

¹ Um conjunto S é um conjunto invariante de um fluxo $\varphi(x_0, t)$ se para qualquer $x_0 \in S$ tivermos $\varphi(x_0, t) \in S$ para todo $t \in \mathbf{R}$ [Tufillaro, et al. (1992)]

atrator do sistema [Eckmann 1981]. Exemplos simples de atratores são pontos fixos (após um tempo transiente estabelece-se um *estado estacionário*) ou *ciclos limites* (o sistema aproxima-se de um movimento periódico). Existem outros tipos de atratores que são encontrados em muitos sistemas, são eles os *atratores estranhos* e os *atratores quase-periódicos*.

De acordo com uma definição de Ruelle & Takens [1971a, 1971b], um atrator é denominado estranho quando as suas linhas de fluxo *dependem sensivelmente* das condições iniciais. Em um atrator estranho, pontos inicialmente próximos se separarão exponencialmente depois de um intervalo suficientemente longo. Mas como em um sistema dinâmico os elementos de volume no espaço de fase se contraem, mantendo o atrator em uma região limitada do espaço de fase, a única maneira pela qual as soluções podem divergir exponencialmente numa região limitada de um espaço de fase é se o fluxo se contrair em algumas direções e se expandir nas outras, permanecendo assim em uma região finita. Esse processo de formação dos atratores estranhos é conhecido por processo de *dobra e estiramento* (ou *foliação*) [Ferrara & Prado 1994]. Uma descrição mais detalhada desse processo pode ser vista em Thompson & Stewart [1986] e em Gukenheimer & Holmes [1983].

Sistemas determinísticos representados por atratores estranhos no espaço de fase apresentam algumas características fundamentais: (a) *imprevisibilidade*, ou seja, o conhecimento do estado do sistema durante um tempo arbitrariamente longo não permite prever, de maneira imediata, a evolução posterior. A imprevisibilidade está associada à dependência das condições iniciais. (b) *espectro contínuo de frequências*, caracterizando um comportamento aperiódico. E (c) *invariância de escala*, significando uma certa

estrutura hierárquica com característica de *auto-similaridade* nas estruturas do espaço de fase.

Essas características definem o chamado *comportamento caótico* de um sistema. Em razão disto, os atratores estranhos são também *atratores caóticos*. O *comportamento caótico* de um sistema, representado principalmente pela dependência das condições iniciais, é resultado das características dinâmicas do sistema, não sendo produzido por perturbações de natureza estocástica. Por isso, esse comportamento é caracterizado como *caótico determinístico*. Também existem os atratores quase-periódicos. Estes são gerados por sinais onde há uma composição de duas ou mais frequências incomensuráveis. Nesses casos as órbitas nunca se fecham e o atrator preenche densamente o espaço de fase.

Em muitas situações, ao se estudar um sistema dinâmico surgem alguns problemas. Isso se deve ao fato de que, muitas vezes, a única fonte de informação que temos é uma série temporal experimental, onde se desconhecem as equações de movimento do sistema que produziram essa série [Ferrara & Prado 1994]. Nos processos regulares, isto é, processos periódicos, multi-periódicos ou quase-periódicos, tal problema pode ser resolvido mais facilmente, pois os processos podem ser identificados através de métodos tradicionais de análise de sinais experimentais: a análise do espectro de potência e da função de autocorrelação.

Já em sinais irregulares, o ponto de partida é utilizar os métodos de análise de séries temporais não lineares, visto que a irregularidade é uma característica que pode ser causada por sistemas dinâmicos não lineares. Eventualmente pode-se pensar na incorporação de uma componente estocástica pelo sinal irregular. Desta forma temos que

assumir que a componente estocástica é pequena e essencialmente não muda as propriedades não lineares [Kantz & Schreiber 1997].

Nas próximas seções, apresentaremos um resumo dessas técnicas, discutiremos as suas limitações e descobriremos quais informações pode-se extrair de sinais experimentais desses procedimentos.

4.3 Reconstrução de Takens

Para analisar as propriedades dinâmicas de um atrator associado a uma série temporal discreta é necessário reconstruí-lo em um espaço de fases de dimensão adequada. A primeira idéia de como fazer isto foi proposta por Packard et al. [1980]. Nesse trabalho mostrou-se que as derivadas sucessivas de uma variável, $d\{x_j\}^m / dt^m$, contêm informações sobre a evolução temporal das outras variáveis do sistema. Este método, embora eficaz, apresenta algumas limitações: amplifica erros experimentais e erros inerentes ao cálculo numérico das derivadas, e também se torna pouco prático se o número de variáveis independentes for muito grande.

Os problemas constatados com o método de Packard et al., são evitados utilizando-se um procedimento proposto por Takens em 1980 [Takens 1980]. Takens demonstrou que é possível reconstruir certas propriedades topológicas do atrator original utilizando um método simples. Vetores m -dimensionais são reconstruídos a partir de uma série temporal $\{x_j\}$ por meio do vetor

$$\bar{\xi}_i = \{x(t_j), x(t_j + s), \dots, x(t_j + (m-1)s)\} \quad (4.4)$$

onde m é chamada de *dimensão de imersão* e s é o *passo de reconstrução*.

A escolha do passo de reconstrução e da dimensão de imersão são fundamentais para a utilização do método de reconstrução de Takens. Critérios que visam automatizar a escolha do passo de reconstrução foram propostos [Buzug, et al. 1990, Fraser & Swinney 1996], mas um método baseado na inspeção visual de um gráfico $x(t_j) \times x(t_j - s)$, denominado *gráfico de primeiro retorno* [Ferrara & Prado 1994], ainda é o mais utilizado. Uma simples inspeção visual deste gráfico nos fornece informações sobre os valores de s para os quais $x(t_j)$ e $x(t_j - s)$ estão ainda fortemente correlacionados. Nessa situação, o atrator fica comprimido próximo a diagonal do gráfico, indicando que $x(t_j)$ e $x(t_j - s)$ não podem ser usados como variáveis independentes no espaço de fase. Devemos procurar por um passo s que forneça, no gráfico de primeiro retorno, uma distribuição uniforme de pontos e que seja pouco sensível a pequenas variações nesse passo.

De maneira análoga, a escolha da dimensão de imersão m é avaliada reconstruindo-se o atrator em espaços de imersão de dimensões sucessivamente crescentes e inspecionando-se visualmente o atrator reconstruído, procurando uma distribuição de pontos que seja uniforme e não comprimida na diagonal. Embora existam métodos numéricos para automatizar a determinação da dimensão de imersão, normalmente são necessárias uma boa dose de experimentação numérica e inspeção visual antes de se obter a dimensão adequada à reconstrução de um sinal [Ferrara & Prado 1994].

Assim como no método de Packard et al., o método de Takens não reconstrói o atrator original, mas fornece um atrator cujas propriedades topológicas são preservadas em relação ao atrator original [Thompson & Stewart 1986], e apresenta vantagens em relação ao primeiro método citado. O algoritmo de reconstrução de Takens é rápido e não apresenta problemas de amplificação de erros.

4.4 Não Estacionaridade

Geralmente, uma medida científica é útil se é reprodutível, ao menos em princípio. No caso de medidas de séries temporais, reprodutibilidade está muito conectada a estacionaridade. Tanto os métodos lineares quanto os métodos não lineares de análise de séries temporais requerem algum tipo de estacionaridade. Portanto, usualmente, mudanças na dinâmica durante as medidas constituem uma complicação não desejada na análise [Glass & Kaplan 1993]. Mais recentemente autores começaram a explorar a informação contida nas variáveis ao longo do tempo como parte essencial da dinâmica do sistema subjacente [Schreiber & Kaplan 1995a], isto ficará mais claro no capítulo 5, quando analisaremos os sinais de ECGs.

De forma intuitiva, podemos dizer que um processo é estacionário se as suas propriedades estatísticas não mudam com o passar do tempo. A estacionaridade requer que os parâmetros relevantes do sistema em estudo devem ser fixos e constantes durante um período de medida (e o mesmo quando este for reproduzido). Este requerimento deve ser cumprido não somente pelo experimento, mas também pelo processo tomado em um ambiente selecionado. Se um processo sob observação é probabilístico, as distribuições de probabilidade não variam no tempo, esta é uma definição de forte estacionaridade. Se há

regras determinísticas governando a dinâmica, estas regras não podem mudar durante o tempo coberto por uma série temporal [Kantz & Schreiber 1997]. Na prática, uma definição mais fraca de estacionaridade, chamada de estacionaridade de segunda ordem, é empregada. Ela requer apenas que a média, o desvio padrão e a covariância permaneçam constantes durante a série temporal [Glass & Kaplan 1993].

Não existe um consenso sobre a definição de estacionaridade de séries temporais. Então parece razoável requerer apenas que a duração das medidas seja longa quando comparada às escalas temporais do sistema. Se este for o caso, então todas as mudanças temporais podem ser modeladas como parte da dinâmica [Kantz & Schreiber 1997].

4.4.1 Diagramas de Recorrência

A manifestação mais relevante de não estacionaridade de um sistema dinâmico não linear é a estreita relação entre o tempo e o espaço de fase. A ferramenta gráfica que estabelece essa relação de maneira qualitativa para o estudo de sistemas dinâmicos é conhecida como diagrama de recorrência, proposto por Eckmann et al. [1987] e modificado por Koebbe & Mayer-Kress [1992].

A proposta de Koebbe & Mayer-Kress é a seguinte: considerar que a série temporal $\{\bar{x}_i\}_{i=1}^N$ representa a trajetória de um sistema no espaço de fase, com $\bar{x}_i \in R^d$. O diagrama de recorrência é então baseado na seguinte matriz:

$$\mathbf{R}_{i,j} = \Theta\left(\varepsilon - \|\bar{x}_i - \bar{x}_j\|\right) \quad i,j = 1, \dots, N, \quad (4.5)$$

onde Θ é a função Heaviside que tem valor 1 se o argumento for maior ou igual a zero e valor zero se o argumento for negativo, $\|\cdot\|$ denota a norma e ε é um limite pré-definido. Então o valor 1 representa um ponto preto e 0 um ponto branco no diagrama de

recorrência. Vale ressaltar que este método depende então dos parâmetros ε e d utilizados.

Consequentemente, obtemos uma matriz $N \times N$, a qual é simétrica com relação a diagonal $i = j$. Para exemplificar a interpretação dos sistemas utilizando diagramas de recorrência, na figura 4.1 são considerados três sistemas distintos: periódico, caótico e com ruído branco.

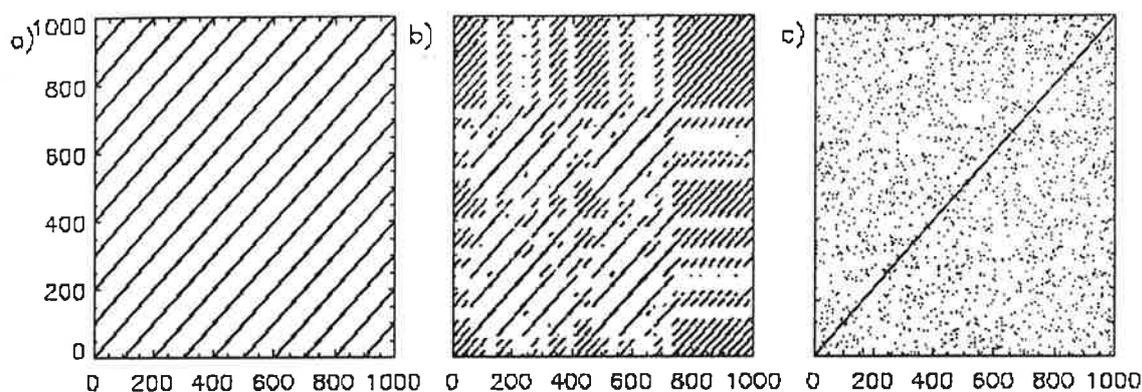


Figura 4.1: Diagramas de referência de: (a) uma função periódica, (b) de um sistema caótico e (c) do ruído branco. Fonte: Blasco 2004.

O diagrama de recorrência da função periódica (figura 4.1-a) consiste de linhas paralelas separadas por uma distância T (na direção vertical e horizontal), onde T é o período da função [Kaplan & Glass 1995]. Isto é devido ao fato de que, após um período, a posição no espaço de fase é a mesma. O diagrama de recorrência do ruído branco (figura 4.1-c) é homogêneo, indicando a randomicidade do sistema. No caso de um sistema caótico (figura 4.1-b), no diagrama de recorrência predominam estruturas intermediárias entre aquelas de sistemas periódicos e de um sistema puramente estocástico. A distância (direção perpendicular a diagonal principal) entre as linhas diagonais não é constante. Isto é devido à presença de escalas múltiplas temporais em sistemas caóticos. As linhas

diagonais são interrompidas, devido à divergência exponencial de trajetórias próximas (que é um indício de caos). Quando a trajetória de um sistema retorna para a vizinhança de um ponto visitado no espaço de fase, ela comporta-se similarmente a situação precedente, característica do determinismo. Porém, devido às condições iniciais serem levemente diferentes, as trajetórias após certo tempo se separam e as linhas são interrompidas.

4.5 Dimensões de Correlação

Considere uma seqüência de N pontos de um atrator reconstruído a partir da imersão de uma série temporal em um espaço de dimensão m (utilizando a técnica de Takens). Seja $B(r)$ o número mínimo de caixas de lado r necessárias para cobrir todo o conjunto de pontos. A probabilidade p_i de um ponto arbitrário do atrator cair na i -ésima caixa será dada por

$$p_i = \lim_{N \rightarrow \infty} \frac{N_i}{N}, \quad (4.6)$$

onde N_i é o número de pontos que caem na caixa i .

A dimensão de correlação é dada por

$$D_2 = \lim_{r \rightarrow 0} \frac{\log \sum_{i=1}^{B(r)} p_i^2}{\log r} \quad (4.7)$$

A dimensão de correlação é atualmente muito utilizada devido ao fato de poder ser calculada facilmente com o algoritmo desenvolvido por Grassberger & Procaccia [1983].

Grassberger e Procaccia observaram que a probabilidade de dois pontos do atrator caírem dentro de uma mesma caixa de tamanho r é dada por $\sum_{i=1}^{B(r)} p_i^2$. E que essa probabilidade pode ser aproximada, para $N \rightarrow \infty$, pela probabilidade de que dois pontos do atrator estejam separados por uma distância menor ou igual a r , ou seja,

$$\sum_{i=1}^{B(r)} p_i^2 \approx C(m, r) = \lim_{N \rightarrow \infty} \frac{1}{N^2} \sum_{i, j=1}^N \Theta \left[r - |x_i^{(m)} - x_j^{(m)}| \right], \quad (4.8)$$

onde m é a dimensão do espaço, N é o número de pontos do atrator, $x_i^{(m)}$ é o vetor m -dimensional associado ao i -ésimo ponto do atrator reconstruído e Θ é a função de Heaviside. $C(m, r)$ é conhecida como integral de correlação e representa a fração de todas as distâncias, entre pares distintos de pontos sobre a trajetória de fase do atrator, que não excedam um certo valor r . $C(m, r)$ é uma função crescente e monotônica em r , e devido à normalização, possui valor máximo igual a 1.

Utilizando a equação (4.7) na equação (4.8) temos que

$$D_2 \approx \lim_{r \rightarrow 0} \frac{\log C(m, r)}{\log r}. \quad (4.9)$$

Isto é, D_2 é a inclinação da reta definida pelo gráfico $\log C(r) \times \log r$, para r pequeno.

Ao se trabalhar com sinais experimentais, usualmente uma série temporal $\{x_i\}$ de uma única variável, deve-se proceder à *reconstrução de Takens*. Desta forma, utiliza-se os vetores $\bar{x}_i = \{x(t_j), x(t_j + s), \dots, x(t_j + (m-1)s)\}$, onde m é a dimensão de imersão e s é o passo de reconstrução. A integral de correlação é escrita como

$$C(r) = \lim_{N \rightarrow \infty} \frac{1}{N^2} \sum_{\substack{i,j=1 \\ i \neq j}}^N \Theta \left[r - |\xi_i - \xi_j| \right] \quad (4.10)$$

e D_2 é obtido como no caso de aplicações e fluxos conhecidos.

Como na prática desconhecemos qual é a dimensão de imersão adequada à reconstrução do atrator, procede-se da seguinte forma: a integral de correlação é representada graficamente como função de r (numa escala log-log) para toda uma gama de dimensões de imersão m . Para cada dimensão de imersão, obtém-se então um valor $D_2(m)$ correspondente. Como a integral de correlação não pode crescer mais rápido que r^m , as inclinações das retas no gráfico $\log C(r) \times \log r$ serão aproximadamente iguais ao valor de m se $m < D_2$, convergindo (quando essa convergência existe) para D_2 quando a dimensão do espaço for suficientemente alta para a reconstrução do atrator.

Para se ter confiança no valor $D_2(m)$ obtido, os dados experimentais devem ser tais que possibilitem a reconstrução e o cálculo de $D_2(m)$ até m da ordem de $2D_2 + 1$ [Ferrara & Prado 1994].

4.6 Redução de Ruído Não Linear

Os sinais experimentais estão, em maior ou menor grau, contaminados com ruído. Tal fato compromete a reconstrução de Takens, que teoricamente, aplica-se a sinais desprovidos de ruído. Desta forma justifica-se desenvolver métodos de *redução de ruído* em sinais experimentais, problema que está intimamente ligado com a previsão teórica do comportamento do sistema, ou seja, com a *reconstrução da dinâmica* do sistema.

A redução de ruído pode ser compreendida como uma decomposição de um sinal em uma parte que nos interessa e em outra parte que não nos interessa. Assumindo que os dados de uma série temporal s_n seguem uma regra de evolução determinística, mas são medidos com algum ruído η , temos:

$$s_n = x_n + \eta_n, \quad x_{n+1} = F(x_{n-m+1}, \dots, x_n). \quad (4.11)$$

Se a dinâmica é desconhecida, temos que identificar F a partir da série experimental conhecida, ou seja, reconstruir a dinâmica. O problema de identificação de F é conhecido na literatura como sombrear (“shadowing”) uma órbita ruidosa com outra sem ruídos. Uma das abordagens para resolver esse problema é conhecida como reconstrução da dinâmica por projeções locais [Ferrara & Prado 1994].

4.6.1 Redução de Ruído com Projeções Locais

Tanto para a previsão quanto para a redução de ruído de uma série temporal, é necessário de alguma forma expressar as equações dinâmicas F . Um ponto de partida consiste na reconstrução de Takens do atrator de dimensão m . Então por conveniência, assumimos uma evolução em coordenadas de atraso $\vec{\xi}_N$ e utilizamos o atraso igual a unidade. Uma previsão de um valor futuro é então obtida por uma aplicação estimada \hat{F} aos últimos dados $\vec{\xi}_N$ disponíveis, fornecendo uma previsão para a medida seguinte \hat{s}_{N+1} . Para propor a redução de ruído é necessário ter informação sobre a estrutura dinâmica para construir uma seqüência de dados \hat{x}_n , $n=1, \dots, N$ que aproximam-se daqueles medidos e que são consistentes com a dinâmica estimada. Ou seja,

$$\hat{x}_{n+1} = \hat{F}(\hat{x}_{n-m+1}, \dots, \hat{x}_n) + \eta_n', \quad (4.12)$$

onde $\langle \eta'^2 \rangle$ é a discrepância residual das equações dinâmicas que seriam menores do que a variância do ruído η na equação (4.11).

Uma maneira clássica de aproximar as equações dinâmicas subjacentes a um sinal determinístico é pelo uso de aplicações lineares locais. Se a aplicação \hat{F} (ou equação diferencial) for uma função contínua e diferenciável por partes, então poderemos linearizar \hat{F} localmente na vizinhança de cada ponto \bar{x}_n :

$$\begin{aligned} \hat{F}(\bar{x}) &= \hat{F}(\bar{x}_n) + \mathbf{J}_0 (\bar{x} - \bar{x}_n) + O(\|\bar{x} - \bar{x}_n\|^2) \\ &\approx \mathbf{J}_n \bar{x} + \vec{b}_n. \end{aligned} \quad (4.13)$$

A matriz J_n é o Jacobiano de \hat{F} em \bar{x}_n e \vec{b}_n é um vetor constante. Eckmann & Ruelle [1985] sugeriram que a aproximação linear acima pode ser obtida de uma série temporal experimental pelo ajuste dos mínimos quadrados. Eckmann et al. [1986] usou os ajustes lineares para estimar os expoentes de Lyapunov de uma série temporal. Aplicações lineares locais foram mais tarde utilizadas para a previsão de séries temporais por Farmer & Sidorowich [1987].

Podemos expressar a relação linearizada acima (4.13) de uma maneira implícita usando coordenadas de atraso. Uma aplicação $x_{n+1} = F(x_{n-m+1}, \dots, x_{n-1})$ de dimensão $m-1$, pode ser escrita implicitamente como

$$\tilde{F}(x_{n-m+1}, \dots, x_n) \equiv \tilde{F}(\bar{x}_n) = 0, \quad (4.14)$$

ou linearizada conforme

$$\bar{a}^{(n)} \cdot \mathbf{R}(\bar{x}_n - \bar{x}^{(n)}) = 0. \quad (4.15)$$

Onde,

$$\bar{x}^{(n)} = |U_n|^{-1} \sum_{n' \in U_n} \bar{x}_{n'}, \quad (4.16)$$

é o centro de massa dos vetores de atraso em uma pequena vizinhança U_n de \bar{x}_n e $\bar{a}^{(n)}$ representa vetores que são ortogonais à $\bar{x}_n - \bar{x}^{(n)}$. Além disso, é introduzida uma matriz diagonal \mathbf{R} que permite focar a redução de ruído sobre as coordenadas mais estáveis dos vetores de atraso. Isto pode ser feito escolhendo R_{11} e R_{mm} grandes e todas as outras entradas diagonais $R_{ii} = 1$. Para $R = 1$, obteríamos projeções ortogonais. Para uma seqüência s_n com ruído, a equação 4.15 não será válida devido ao erro relacionado ao ruído:

$$\bar{a}^{(n)} \cdot \mathbf{R}(\bar{\xi}_n - \bar{\xi}^{(n)}) = \eta_n. \quad (4.17)$$

A idéia básica do método é corrigir cada vetor de atraso $\bar{\xi}_n$ individualmente buscando minimizar o ruído η_n [Richter, et al 1998]. Vale a pena ressaltar que a dinâmica de $\bar{\xi}_n$ é equivalente a de \bar{x}_n .

Para a aproximação linear há uma direção no espaço de fases, $\vec{a}^{(n)}$, na qual o atrator não se estende. No que segue, suprimiremos a notação (n) , mas guardaremos em mente que a equação linear é válida somente localmente na direção $\vec{a}^{(n)}$.

Ao expressarmos a dinâmica de forma implícita (equação 4.14), adicionamos uma dimensão ao sistema, ou seja, agora o sistema possui dimensão m . No entanto, a dinâmica real do sistema pode confinar as trajetórias em uma variedade² de dimensão menor m_0 . Desta forma, podemos encontrar $Q = m - m_0$ sub-espacos mutuamente independentes \vec{a}^q , $q = 1, \dots, Q$ preenchendo (4.15) e (4.17). O espaço linear expandido por estes Q vetores é conhecido como espaço nulo no ponto \vec{x}_n . Desde que o atrator livre de ruído não se estende neste espaço, as componentes de $\vec{\xi}_n$ encontradas devem ser devidas ao ruído. O algoritmo de redução de ruído por projeção local tenta identificar tal espaço nulo e então remover a componente correspondente de $\vec{\xi}_n$.

Assumindo que o espaço nulo é Q -dimensional, devemos tentar encontrar vetores ortonormais \vec{a}^q tal que a projeção local do vetor $\mathbf{R}(\vec{\xi}_n - \bar{\xi})$ seja mínima sobre o espaço nulo. Para isto utilizamos os multiplicadores de Lagrange. Se usarmos a notação $z_n = \mathbf{R}(\vec{\xi}_n - \bar{\xi})$, a projeção de \vec{z}_n sobre o espaço nulo será $\sum_{q=1}^Q \vec{a}^q \cdot (\vec{a}^q \cdot \vec{z}_n)$. Devemos requerer que $\sum_{n \in U_n} \left[\sum_{q=1}^Q \vec{a}^q \cdot (\vec{a}^q \cdot \vec{z}_n) \right]^2$ seja mínimo para obter a escolha correta do conjunto de \vec{a}^q . Introduzindo o vínculo que \vec{a}^q deve ter unidade de comprimento obtida

² Variedade é um espaço topológico que é localmente Euclidiano [Weisstien, et al. 1999].

por meio de multiplicadores de Lagrange λ^q , e usando o fato que os \bar{a}^q são ortogonais, $\bar{a}^q \cdot \bar{a}^{q'} = 0$, $q \neq q'$. Precisamos minimizar a função Lagrangiana

$$L = \sum_{n \in U_n} \left[\sum_{q=1}^Q \bar{a}^q \cdot (\bar{a}^q \cdot \bar{z}_n) \right]^2 - \sum_{q=1}^Q \lambda^q \cdot (\bar{a}^q \cdot \bar{a}^q - 1) \quad (4.18)$$

com respeito a \bar{a}^q e λ^q . Isto pode ser feito separadamente para cada q fornecendo

$$C\bar{a}^q - \lambda^q \bar{a}^q = 0, \quad q = 1, \dots, Q, \quad (4.19)$$

onde C é a matriz covariância $m \times m$ dos vetores z_n , dentro da vizinhança U_n ,

$$C_{ij} = \sum_{n \in U_n} (\bar{z}_n)_i (\bar{z}_n)_j. \quad (4.20)$$

As soluções da equação (4.20) são os autovetores ortogonais \bar{a}^q e autovalores λ^q de C . O mínimo global será dado pelos autovetores do mais baixo autovalor de Q . A componente de ruído do vetor \bar{z}_n pode então ser removida e trocada por

$$\hat{z}_n = z_n - \sum_{q=1}^Q \bar{a}^q \cdot (\bar{a}^q \cdot \bar{z}_n). \quad (4.21)$$

Finalmente, podemos escrever o resultado em termos dos vetores de atraso originais:

$$\hat{\xi}_n = \bar{\xi}_n - \Delta \bar{\xi}_n = \bar{\xi}_n - \mathbf{R}^{-1} \sum_{q=1}^Q \bar{a}^q \cdot \left[\bar{a}^q \cdot \mathbf{R} (\bar{\xi}_n - \bar{\xi}) \right]. \quad (4.22)$$

Essa aproximação da projeção está ilustrada na figura 4.2. Se os pontos dentro de uma variedade de dimensão m_0 estão contaminados pelo ruído, eles estarão espalhados ao redor da variedade em todas as direções disponíveis, em uma amplitude correspondente ao nível de ruído. Agora, podemos aproximar esta nuvem de pontos por um elipsóide o

qual é descrito por uma forma quadrática dada pela matriz covariância local C . Os autovetores e autovalores fornecem a direção e as magnitudes dos eixos principais do elipsóide ajustado. No caso livre de ruído, as Q direções principais mais baixas têm autovalores iguais a zero, enquanto as direções remanescentes se expandem localmente pela variedade. Na presença de ruído, podemos identificar as Q direções principais com os menores autovalores, como sendo as direções dominadas pelo ruído.

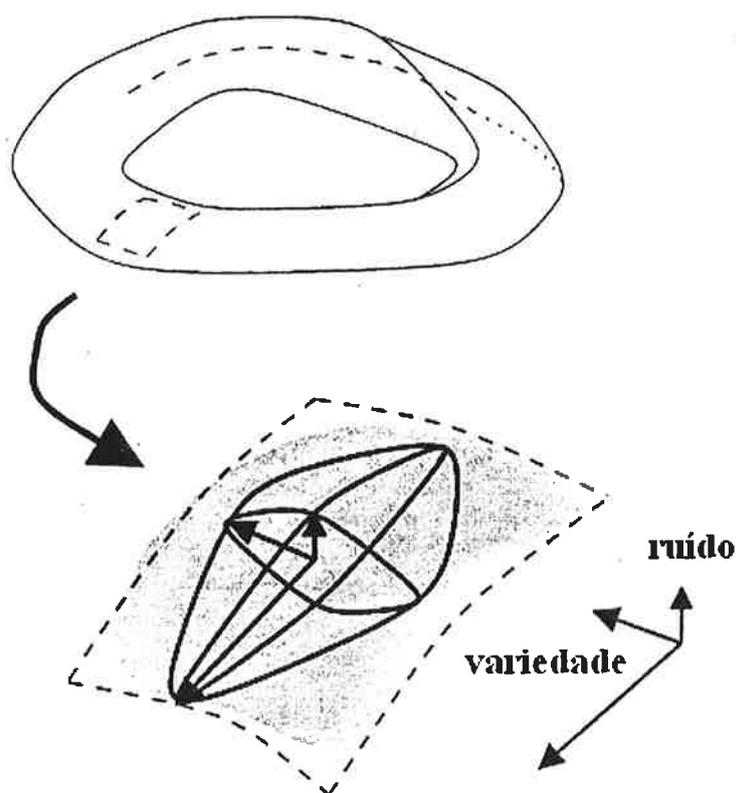


Figura 4.2: Visão esquemática de uma variedade local. Fonte: Kantz & Schreiber 1998.

4.7 Distâncias Estatísticas

Podemos determinar a divergência ou distância entre duas distribuições de probabilidade p e g . A quantidade de informação associada a uma distribuição p em

relação à quantidade de informação associada a uma distribuição g é chamada de medida relativa de informação - $d(p,g)$ e representa a distância estatística entre essas duas distribuições de probabilidade [Jaymes 1988].

Para diferenciar atratores reconstruídos podemos utilizar um método que considera a distância entre a distribuição de pontos gerados por dois atratores reconstruídos, em um espaço m -dimensional, como duas distribuições estatísticas de probabilidade em um espaço m -dimensional [Diambra 1999]. Dessa forma, utiliza-se um cálculo de distância estatística entre distribuições de probabilidade para se obter uma medida da distância entre os atratores reconstruídos no espaço de fases. Nesta seção, veremos como isso é feito.

Diambra utilizou a idéia que a entropia relativa pode ser usada para a distinção do comportamento entre diferentes sistemas dinâmicos. Para isso, considere uma distribuição de probabilidade $p(x)$, com $\int p(x)dx = 1$, a entropia pode ser definida de forma funcional como

$$S_f(p(x)) = -\int f(p(x))dx, \quad (4.23)$$

onde f é uma função convexa. A entropia de Shannon é definida por $f(p) = p \ln p$. Todavia, Diambra utiliza a entropia de ordem q ou a entropia generalizada de Tsallis [1988], que é aquela onde o operador funcional é dado pela forma $f_q(p) = (q-1)^{-1}(p^q - p)$. Essa entropia é a que melhor descreve sistemas físicos com ordem maior que 1 [Tsallis 1988]. Note que, um invariante importante dos sistemas dinâmicos determinísticos é a dimensão de correlação que é a dimensão de ordem 2 (D_2).

Usando esta forma funcional, pode-se escrever 4.23 como:

$$S_q(p(x)) = (q-1)^{-1} \left(1 - \int p^q(x) dx \right). \quad (4.24)$$

A distância de ordem q associada à uma entropia f é dada pela distância de Kullback-Leibler [Kullback 1959]:

$$d_f(p : g) = \int f \left[\frac{p(x)}{g(x)} \right] g(x) dx, \quad (4.25)$$

onde a condição geral $f(1) = 0$ é imposta, o que garante $d_f(p : p) = 0$. Se substituirmos f na equação (4.25) pelo operador funcional correspondente à entropia de Tsallis, $f_q(p) = (q-1)^{-1}(p^q - p)$, obtemos a distância de ordem q (agora parametrizada com q):

$$d_q(p : g) = (q-1)^{-1} \left(\int p^q(x) g^{1-q}(x) dx - 1 \right), \quad (4.26)$$

Este resultado pode ser escrito para distribuições discretas de probabilidade. Sejam duas distribuições de probabilidade $\{g_i\}$ and $\{p_i\}$ com $i = 1, \dots, N$ normalizadas a unidade. A distância de ordem q será dada por

$$d_q(p : g) = (q-1)^{-1} \left[\left(\sum_{i=1}^N p_i^q g_i^{1-q} \right) - 1 \right] \quad (4.27)$$

onde assume-se que se $g_i = 0$, o correspondente p_i também é zero.

Outras funções de distância para o cálculo da distância estatística também podem ser utilizadas, por exemplo: a *Chebychev*, a métrica *chi-square*, a distância de correlação, a distância Euclideana e a métrica de Manhattan [Wilson & Martinez 1997]. Várias destas distâncias estão apresentadas na tabela 4.1. Por exemplo, Figueiredo & Furuie [2001a] utilizaram a distância de correlação para determinar a distância estatística entre duas

distribuições de probabilidade. A escolha da melhor distância para a determinação da distância entre atratores ainda é um problema em estudo.

$$\text{Chebychev: } D(p, g) = \sum_{i=1}^m |p_i - g_i|$$

$$\text{Chi-square: } D(p, g) = \sum_{i=1}^m \frac{1}{\text{sum}_i} \left(\frac{p_i}{\text{size}_p} - \frac{g_i}{\text{size}_g} \right)^2$$

onde, sum_i é a soma de todos os valores para o atributo i ocorrendo nas distribuições p e g , size_p é a soma de todos os valores da distribuição p e size_g é a soma de todos os valores da distribuição g .

$$\text{Correlação: } D(p, g) = \frac{\sum_{i=1}^m (p_i - \bar{p}_i)(g_i - \bar{g}_i)}{\sqrt{\sum_{i=1}^m (p_i - \bar{p}_i)^2 (g_i - \bar{g}_i)^2}}$$

$$\text{Euclideana: } D(p, g) = \sqrt{\sum_{i=1}^m (p_i - g_i)^2}$$

$$\text{Manhattan: } D(p, g) = \sum_{i=1}^m |p_i - g_i|$$

Tabela 4.1: Funções de distâncias estatística utilizadas para o cálculo da distância entre duas distribuições p e g . Fonte: Wilson & Martinez 1997.

4.8 Entropia Aproximada (ApEn)

Na tentativa de se obter uma medida física que caracterizasse a complexidade da dinâmica apresentada por um dado sistema, Pincus [1991] propôs uma medida conhecida como entropia aproximada (Approximate Entropy -ApEn). Esta medida busca quantificar a regularidade nos dados de uma série temporal, e pode ser aplicada a conjuntos de dados

relativamente curtos e ruidosos. A ApEn tem sido aplicada na análise de uma grande variedade de sinais fisiológicos [Fusheng, et al. 2001]. A seguir apresentaremos o método da ApEn utilizado para medir a complexidade em séries temporais.

Considere uma série temporal consistindo de uma seqüência estroboscópica de N medidas $\{v(t_0); v(t_0 + \tau_s); \dots; v(t_0 + (N-1)\tau_s)\}$ realizadas em intervalos de tempo τ_s . Utilizando a técnica de reconstrução de Takens, podemos construir os vetores (ou padrões) de dimensão m ,

$$\mathbf{v}(t) = \{v(t); v(t-\Delta); \dots; v(t-(m-1)\Delta)\} \quad (4.28)$$

onde $\Delta = n\tau_s$, ($n \in N$), é o tempo de atraso ou *delay*.

Define-se a distância entre $\mathbf{v}(i)$ e $\mathbf{v}(j)$ como sendo a máxima distância absoluta entre os elementos escalares correspondentes, ou seja,

$$d[\mathbf{v}(i), \mathbf{v}(j)] = \max(|v(i+k-1) - v(j+k-1)|), k = 1, 2, \dots, m. \quad (4.29)$$

Para cada $i \leq N - (m-1)\Delta$, calculamos a quantidade C_i^m :

$$C_i^m(r) = \frac{1}{N - (m-1)\Delta} \sum_j \Theta(r - d[\mathbf{v}(i), \mathbf{v}(j)]) \quad (4.30)$$

onde $\Theta(x)$ é a função Heaviside. $C_i^m(r)$ representa a fração de padrões que assemelham-se ao padrão de referência i com uma certa tolerância r . Se definirmos

$$\Phi^m(r) = \frac{1}{N - (m-1)} \sum_i \ln[C_i^m(r)], \quad (4.31)$$

teremos que a entropia aproximada será dada por:

$$ApEn(m, r) = \lim_{N \rightarrow \infty} [\Phi^m(r) - \Phi^{m+1}(r)]. \quad (4.32)$$

Na prática, o número de pontos N é finito, e o resultado obtido através do procedimento acima é uma estimativa da $ApEn$. Esta estimativa é denotada por

$$ApEn(m, r, N) = \Phi^m(r) - \Phi^{m+1}(r). \quad (4.33)$$

Assim, a $ApEn$ basicamente quantifica a freqüência de não ocorrência de padrões ao longo da série temporal. Isso significa que a presença repetitiva de padrões em uma série temporal fará com que a $ApEn$ seja relativamente baixa (baixa entropia). Já quanto menos previsível o processo, ou seja, quanto mais complexo o processo, maior será a $ApEn$ (alta entropia).

Para uma dada série temporal, em geral obtém-se diferentes valores de $ApEn$ para diferentes valores de r e m . Por exemplo, a $ApEn(m, r, n)$ cresce com a queda de r conforme $\log(2r)$. Na escolha dos parâmetros m e r para o cálculo da $ApEn$, a mais importante diretriz é a consistência, pois o que podemos fazer apenas, estritamente falando, é uma comparação relativa de dois sistemas. Para dois sistemas A e B, podemos determinar a regularidade relativa entre eles, ou seja, se $ApEn [A]$ é menor do que a $ApEn [B]$ para um par de valores de m e r , então segue que $ApEn [A]$ será sempre menor do que a $ApEn [B]$ para qualquer outro valor de m e r .

A ApEn é fundamentalmente uma estatística de regularidade e não um índice direto de complexidade em sistemas fisiológicos, acreditava-se que estados patológicos apresentavam uma redução da complexidade do sistema e uma conseqüente diminuição da entropia. Entretanto Vaillancourt e Newell confirmaram que um aumento da ApEn não necessariamente implica em um aumento da complexidade fisiológica. Isto pode simplesmente estar relacionado à quebra em correlações de múltiplas escalas ou devido a perturbações sutis no controle não linear [Goldberger, et al. 2002]. Então a perda de complexidade é melhor avaliada utilizando-se técnicas de escala e outras medidas que podem detectar e quantificar a presença de correlações de longo alcance em séries temporais não estacionárias, bem como possíveis interações não lineares.

4.9 Detrended Fluctuation Analysis (DFA)

Uma importante questão em análise de séries temporais fisiológicas é distinguir entre flutuações intrínsecas geradas por um sistema complexo e aquelas causadas por estímulos externos ou ambientes atuantes sobre o sistema [Iyengar, et al. 1996]. Para este fim, foi introduzido por Peng et al. [1994] o método conhecido por *Detrended Fluctuation Analysis* (DFA). As vantagens da DFA sobre os métodos padrão é que ela permite a detecção de correlações de longo alcance reconstruídas a partir de séries temporais aparentemente não estacionárias.

Presume-se que variações que surgem por causa de estímulos externos causam efeitos locais, porém variações devidas à dinâmica intrínseca do sistema podem exibir correlações de longo alcance. A DFA tenta quantificar a presença ou ausência de uma correlação de longo alcance.

A DFA é uma medida invariante de escala. Ela estima a tendência de todas as escalas, incluindo tendências que exibem propriedades fractais (padrões similares de variação através de escalas temporais múltiplas). Uma componente do cálculo de DFA envolve a subtração da tendência local (mais provavelmente relacionada a estímulo externo) a fim de estabelecer correlações que são causadas pela não estacionaridade, e ajuda a quantificar a caráter de correlações fractais de longo alcance representando a natureza intrínseca do sistema.

Considere uma série temporal $B(i)$, $i = 1, \dots, N$. Primeiro calculamos a série $y(k)$ dada por

$$y(k) = \sum_{i=1}^k [B(i) - \bar{B}], \quad (4.34)$$

onde \bar{B} é a média dos $B(i)$ calculada sobre toda a série. Esta série $y(k)$ representa uma estimativa de tendências. Por exemplo, se a diferença $B(i) - \bar{B}$ permanece negativa, então $y(k)$ aumenta em valor absoluto conforme k aumenta. Esta função tendência $y(k)$ é dividida em janelas de comprimento igual a n . Em geral não é possível dividir exatamente os N pontos da série dentro de janelas de comprimento n , então para cada valor de n , denominaremos \tilde{N} o maior múltiplo de n inferior ou igual a N .

Em cada janela, a tendência local $y_n(k)$ é calculada por uma representação linear da função $y(k)$ naquela janela usando o método dos mínimos quadrados. A série $y(k)$ é então "redirecionada" pela subtração da tendência local. A série $y(k)$ redirecionada é representada por:

$$F(n) = \sqrt{\frac{1}{N} \sum_{k=1}^{\tilde{N}} [y(k) - y_n(k)]^2}. \quad (4.35)$$

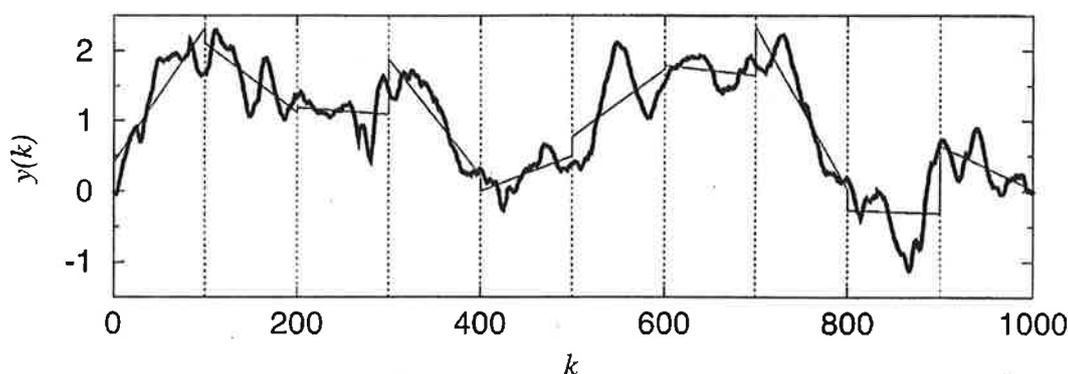


Figura 4.3: DFA: As linhas verticais pontilhadas indicam janelas de tamanho $n = 100$, e os segmentos de linhas representam a tendência estimada em cada janela pelo ajuste dos mínimos quadrados. Fonte: Bolis & Licinio 1999.

Este cálculo é repetido sobre todas as escalas de tempo para fornecer a relação entre $F(n)$ e a janela de tamanho n (figura 4.3). Tipicamente, $F(n)$ aumentará com o tamanho da janela n . Os detalhes computacionais de DFA são descritos por Peng et al. [1994] e Buldyrev et al. [1995].

O passo seguinte consiste em ajustar uma função de potência γn^α a $F(n)$. Para isso é calculado o melhor ajuste linear utilizando um gráfico $\log F(n) \times \log n$. A inclinação desse gráfico determina o expoente de escala (ou o parâmetro de auto-similaridade), α . Um α de 0,5 corresponde ao ruído branco, $\alpha = 1$ representa ruído $1/f$, e $\alpha = 1,5$ indica ruído Browniano ou movimento randômico [Iyengar, et al. 1996].

Também podemos calcular o espectro de potência $P(f)$ versus a frequência f da série temporal e representá-los em um gráfico log-log. Se a relação for linear, temos que:

$$P(f) \sim f^{-\beta}. \quad (4.36)$$

Onde expoente β está relacionado com o expoente de escala α por $\beta = 2\alpha - 1$ [Ivanov, et al. 2001]. Essa relação pode ser útil para comparar se os métodos estão de acordo quanto a caracterização da presença e do tipo de correlação.

5 USO DE MÉTODOS NÃO LINEARES PARA ANÁLISE DO ECG

Neste capítulo apresentaremos as considerações sobre o estudo de ECG com o uso de métodos matemáticos de análise de sistemas dinâmicos não lineares. Também discutiremos algumas aplicações consideradas importantes e que utilizam esses métodos.

5.1 O ECG

5.1.1 Não Linearidade no ECG

Inicialmente devemos explicar qual a motivação para o uso de métodos matemáticos de análise de sistemas dinâmicos não lineares no estudo de sinais de ECG. Os sistemas não lineares, compostos de múltiplas subunidades, não podem ser entendidos quando suas componentes são analisadas individualmente. Esta estratégia de reducionismo falha porque as componentes da rede não linear interagem, ou seja, são acopladas. O fato de um sistema possuir componentes não lineares não necessariamente implica que a não linearidade será refletida nos sinais que medimos a partir desse sistema, apesar disso, a aplicação de métodos matemáticos não lineares para o processamento de

séries temporais fisiológicas tem sido justificada pelo comportamento irregular exibido nas próprias séries. Essa irregularidade é caracterizada pela presença de auto-sustentação, ondas aperiódicas, mudanças abruptas e/ou caos [Goldberger 1996].

Os métodos não lineares de análise de séries temporais surgiram para estudar a dinâmica de sistemas caóticos determinísticos. Todavia, a presença de caos na dinâmica fisiológica do coração ainda é um assunto que gera muita divergência e pesquisa. Acreditava-se que as flutuações caóticas nos sinais fisiológicos eram produzidas por condições patológicas, tal como a atividade elétrica gerada durante a fibrilação ventricular [Kaplan & Goldberger 1991]. Porém, algumas evidências atuais não suportam a visão de que a resposta irregular da fibrilação ventricular por si só represente caos determinístico [Bosanac & Bogunovic 2002]. Além disso, não há evidências de que outras arritmias denominadas caóticas, tal como a taquicardia multifocal, satisfaçam os critérios técnicos para o estabelecimento da presença de caos. Há contudo uma hipótese de que as flutuações sutis da frequência cardíaca, observadas durante o ritmo sinusal normal em pessoas saudáveis em repouso, são devidas em parte a caos determinístico [Kantz & Schreiber 1997], e que uma variedade de patologias, tal como a *congestive heart failure* (CHF), podem envolver decréscimos dessas flutuações caóticas [Bolis & Licinio 1999].

Apesar dessas discussões, devemos ressaltar que não são apenas as evidências de não linearidade sobre a atividade cardíaca que motivam o estudo do ECG com uso de métodos matemáticos não lineares. A utilização de tais métodos sobre sinais onde o determinismo não está claramente presente proporcionou resultados promissores, estimulando outros pesquisadores a fazerem o mesmo. Estes métodos acabaram fornecendo novas idéias e técnicas para a compreensão de sistemas complexos e são

também considerados ferramentas mais eficientes do que os métodos tradicionais de processamento linear na caracterização do estado de um sistema não linear [Kantz & Schreiber 1997, Wang, et al. 2000].

5.1.2 Não Estacionaridade do ECG

Um problema inevitável na análise de sinais de ECG é o da não estacionaridade. A frequência cardíaca depende da atividade física do indivíduo, e o ritmo sinusal pode ter a sua frequência modulada pelas condições do meio ambiente [Glass 1996]. No entanto, estudos revelam que o espectro de potência dos intervalos RR obedecem uma lei de potência ($P=1/f$), e até mesmo em pessoas saudáveis, que se encontram em repouso, os intervalos RR são não estacionários e flutuam de uma maneira irregular [Ivanov, et al. 2001]. Mas a estacionaridade não pode ser vista apenas como uma complicação para a descrição estatística dos dados de ECG, uma vez que alguns métodos não lineares não a requerem, extraindo informações do ECG que são úteis para a realização de um diagnóstico [Stanley, et al. 1999].

Uma representação do ECG no espaço de fase reconstruído pode oferecer uma base poderosa para o estudo de mudanças na morfologia da onda. Considere um aumento da frequência cardíaca instantânea, o ciclo de ECG aparecerá mais contraído no espaço de fase, porém esta contração não pode ser descrita por um simples fator de re-escala [Kantz & Schreiber 1998]. Logo, para se detectar a estacionaridade desse sinal, pode-se utilizar uma variação dos diagramas de recorrência em partes do ciclo do ECG, começando pela onda P até o fim da onda T. Isso é feito porque a maioria dos trabalhos sugere que o intervalo PT do ECG é responsável pelo seu caráter determinístico enquanto, o intervalo TP é randômico [Ritcher, et al. 1998]. Na figura 5.1 observa-se que o diagrama de

recorrência para o trecho PT exibe estruturas intermediárias entre um sistema periódico e um sistema puramente estocástico, assemelhando-se desta forma a um sistema caótico.

É bastante razoável supor que o ECG é estacionário, ou aproximadamente estacionário, em um curto período de tempo [Wang, et al. 2000]. Esta interpretação fornece o fundamento para as possíveis aplicações clínicas dos métodos não lineares em seu estudo. Para satisfazer o critério de estacionaridade do ECG, muitos autores consideraram que o tempo de amostragem do sinal deva ser suficiente para conter um número adequado de ciclos cardíacos. Por exemplo, o ciclo de ECG dura em média 200 ms, para uma taxa de amostragem de 250 Hz, tem-se 300 ciclos em um minuto. Nesse período seria razoável supor que o sinal de ECG é estacionário [Wang, et al. 2000].

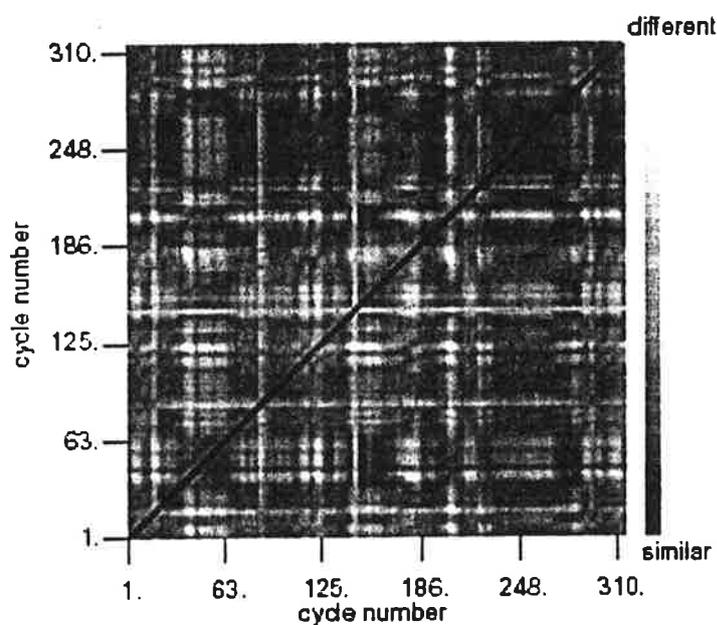


Figura 5.1: Diagrama de recorrência para os segmentos PT de sinal de ECG. Fonte: Kantz & Schreiber 1998.

5.2 Reconstrução do Espaço de Fase do ECG

Como foi dito no capítulo 4, o procedimento padrão para estudar o comportamento dinâmico de um sistema (representado por uma determinada medida observável) é a reconstrução do espaço de fase. O observável pode ser o sinal de ECG. Um tipo de reconstrução dos sinais de ECG é o chamado vetorcardiograma. O vetorcardiograma reconstrói um espaço de fase a partir de dados obtidos por eletrodos que são colocados em diferentes locais do corpo, o que fornece uma reconstrução espacial. Desde que o ECG representa um fenômeno de propagação, onde o deslocamento espacial é equivalente ao deslocamento temporal, o espaço de fase resultante é similar ao espaço de fase obtido através de outras técnicas de reconstrução [Figueiredo & Furuie 2001a].

Existe outra forma de se proceder a reconstrução do espaço de fase. Considera-se que a evolução temporal do ECG pode ser descrita por um sistema dinâmico evoluindo em um espaço de fase de, possivelmente, infinitas dimensões. Então, utilizando a técnica de reconstrução de Takens, seria possível reconstruir um espaço de fase do sinal topologicamente equivalente ao espaço de fase original [Takens 1980]. Este método tem sido muito adotado em análise de sinais [Richter, et al. 1998 & Kantz & Schreiber 1997].

O teorema de Takens [1980] estabelece algumas condições para que a reconstrução do espaço de fase preserve as medidas invariantes do sistema, tais como a dimensão de correlação e a entropia de informação. Respeitando essas condições, podemos reconstruir parte do espaço de fase de uma série temporal sem o conhecimento do espaço de fase real do sistema. A escolha do passo de reconstrução s , como discutido no capítulo 4, é de considerável importância na tentativa de reconstruir o atrator que representa o sistema dinâmico gerado a partir dos dados.

A despeito de existirem critérios para automatizar a escolha do passo de reconstrução, tais como os métodos propostos por Buzug et al. [1990] e Fraser & Swinney [1986], muitos trabalhos adotam o método de inspeção visual para determinar essa escolha, onde busca-se observar se o atrator está completamente estendido ou comprimido no espaço de fase. Para exemplificar esse processo de escolha do passo de reconstrução, mostramos como ele foi obtido no trabalho de Figueiredo & Furuie [2001a]. Na figura 5.2 vemos um sinal de ECG normalizado (figura 5.2-a) e três representações de espaço de fase de duas dimensões reconstruídos para diferentes valores de s : $s = 4$ ms (figura 5.2-b), $s = 12$ ms (figura 5.2-c) e $s = 24$ ms (figura 5.2-d). Se s é muito pequeno, $x(t)$ está próximo de $x(t + s)$ e o atrator é comprimido na vizinhança da diagonal do espaço de fase (figura 5.2-b) e não está completamente estendido. Se s é muito grande, o atrator dobra-se e o gráfico do espaço de fase deforma-se (figura 5.2-d). Observa-se que o atrator considerado ideal foi para $s = 12$ ms (figura 5.2-c), pois este passo de reconstrução gera um atrator completamente estendido.

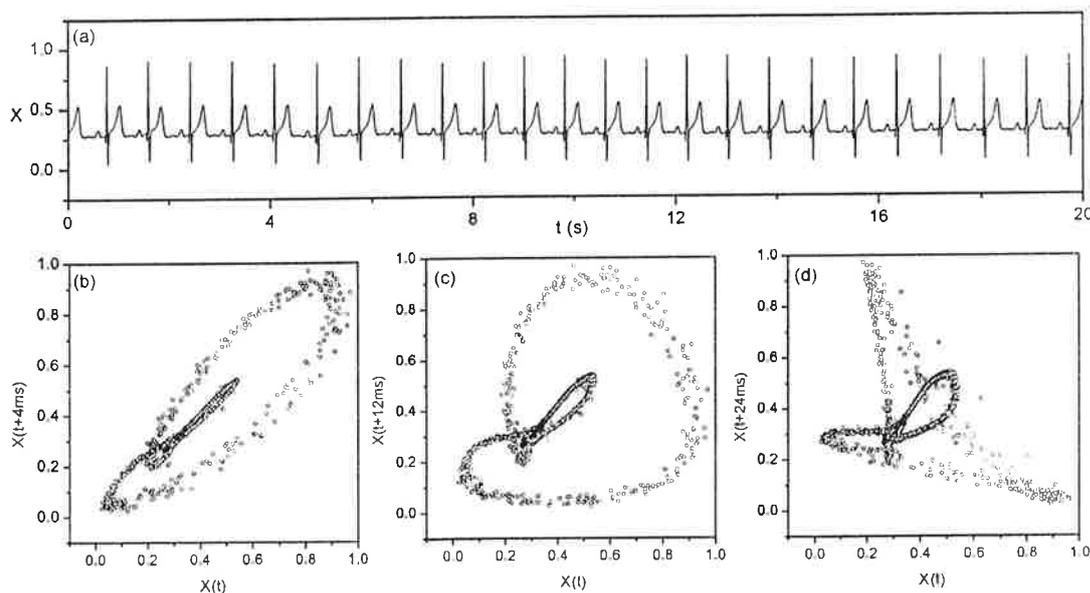


Figura 5.2: Um sinal de ECG normal (a) e reconstruções do espaço de fase para (b) $s = 4$ ms, (c) $s = 12$ ms e (d) $s = 24$ ms. Fonte: Figueiredo & Furuie 2001a.

5.3 Redução de Ruído do ECG

O algoritmo de redução de ruído descrito no capítulo 4 foi inicialmente utilizado por Schreiber & Kaplan [1195a] para suprimir ruído em ECGs. Nesse caso o ruído foi considerado uma contaminação não desejada, não contendo nenhuma informação relevante. Essa redução de ruído pode ser considerada como o caso particular da tarefa mais geral de separação de sinais, onde um dos sinais é a contribuição ruidosa, isso mostra que a metodologia desenvolvida para a redução de ruído pode ser generalizada para outros sinais [Schreiber & Kaplan 1195b].

Um exemplo prático é o problema da extração do ECG fetal. Deseja-se medir a atividade elétrica do coração do feto não invasivamente, ou seja, sem o uso de eletrodos fixados dentro do útero da mãe. Desta forma, eletrodos podem ser aplicados sobre a superfície corporal da mãe, a maioria sobre o abdômen e, dependendo da localização desses na pele, é possível obter um sinal de ECG que possui duas componentes, uma componente maternal dominante e uma componente fetal. Então o problema resume-se a separar essas duas componentes, mas esse problema não pode ser resolvido facilmente por técnicas de filtragem linear. A filtragem linear falha uma vez que as diferenças entre as componentes – maternal e fetal – não podem ser definidas no domínio espectral de frequências. A razão disto é que o espectro das duas componentes é muito similar e possui fortes contribuições de banda larga. Portanto, considera-se o ECG materno como o sinal e a componente fetal como o ruído. Pode-se então aplicar o algoritmo de redução de ruído não linear para separar ambas as partes. Se considerarmos que o sinal pode ser tratado como um sinal não totalmente determinístico, mas com uma componente randômica entre os ciclos de ECG, representada pelos intervalos TP. Então ao realizarmos a reconstrução

de Takens para representar o sinal de ECG no espaço de fases, a trajetória permanecerá mais tempo próxima à parte inferior esquerda da variedade, no nó $x_n = x_{n-20ms} = 0$ (figura 5.3), que correspondente as baixas amplitudes do sinal. Isto fará com que o procedimento de redução de ruído não afete o intervalo TP, ao passo que o intervalo restante do ECG, que dá o caráter determinístico a série, será fortemente influenciado pela redução de ruído.

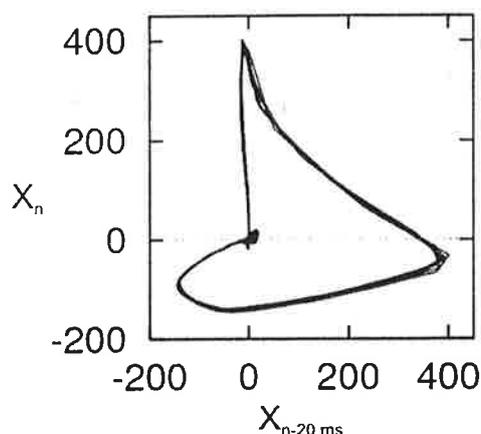


Figura 5.3: Reconstruções de Takens para o sinal de ECG. Fonte: Richter, et al. 1998.

Em um primeiro trabalho Schreiber e Kaplan [1995b] superpuseram dois ECGs de maneira a obter um ECG similar ao ECG abdominal materno, e testaram o algoritmo de redução de ruído não linear. Eles sabiam que a componente fetal era 2,5 vezes mais rápida e 20 vezes menor em amplitude do que a parte materna. Nesse caso tratava-se de uma situação quase livre de ruído. Schreiber & Kaplan [1995b] ainda investigaram o caso em que a componente fetal é mascarada por ruído. Nesta situação, a componente fetal pôde ser separada do ECG materno e então, por meio de um segundo passo de redução de ruído, das flutuações randômicas. Na figura 5.4 é mostrado um registro de ECG real de um feto de 16 semanas. Os dados foram tomados por Hofmeister [1994]. Nesta situação, um eletrodo foi colocado sob o abdômen da mãe e outro no colo do útero. A segunda

linha mostra o resultado do primeiro passo de separação, onde somente o sinal materno é removido. A segunda aplicação do algoritmo de redução de ruído resulta na obtenção do ECG fetal.

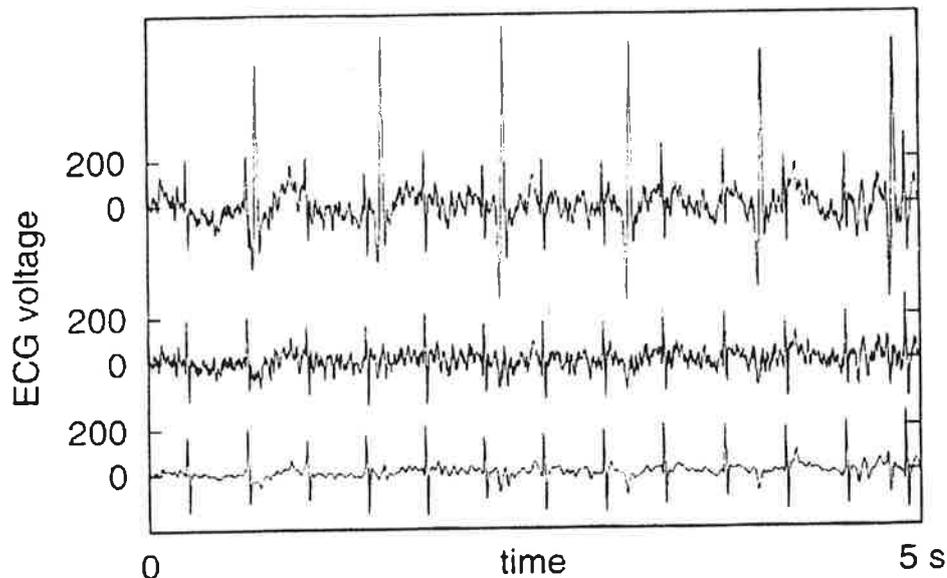


Figura 5.4: Acima: um ECG fetal utilizando eletrodos na cervical. Meio: a componente materna é removida. Abaixo: flutuações randômicas são removidas. Fonte: Kantz & Shreiber 1997.

Essa aplicação mostra que as técnicas não lineares podem ser muito úteis aonde o determinismo pode não ser bem estabelecido. Apesar do fato de muitas pessoas gastarem tempo discutindo se o ECG é caótico ou possui ruído, é muito mais proveitoso descobrir qual é a aproximação mais útil para um dado experimento. Se um conjunto de dados é estocástico em algum grau, isso não significa que nós somos forçados usar exclusivamente métodos estocásticos. A técnica de redução de ruído pode ainda ser aplicada a outros problemas, tais como detecção de pulsos em sinais de eletroencefalograma e em remoção de ruídos em eletromiograma [Kantz & Schreiber 1998].

5.4 Dimensão de Correlação do ECG

A fim de caracterizar a dinâmica do coração, esteja ele saudável ou não, pode-se utilizar a dimensão de correlação que é obtida através dos sinais de ECG. Essa idéia vem sendo aprimorada com o tempo. Em 1998, Babloyantz & Destexhe partiram da premissa de que o coração de uma pessoa saudável não é um oscilador perfeito [Babloyantz & Destexhe 1998], e que ao invés disso, é um sistema caótico que tem dimensão de correlação entre 3,6 a 5,2. Fojt & Holcik [1998] também calcularam a dimensão de correlação de sinais normais de ECG, e encontraram valores entre 2,1 e 2,8. A maioria dos pesquisadores escolhia apenas os sinais de ECG de uma das várias derivações para analisar as características dinâmicas não lineares, e com um número pequeno de casos. Acreditava-se também que a dimensão de correlação do coração era única e não tinha relação com a posição dos eletrodos sobre o corpo. No entanto, em um trabalho recente de Wang et al. [2000], foi levado em consideração que o tecido do coração é heterogêneo no espaço e a propagação do sinal elétrico no coração é anisotrópica, e resolveu-se investigar a dimensão de correlação de sinais de ECG com as 12 derivações simultâneas. Wang et al. calcularam a dimensão de correlação de cada uma das 12 derivações para dois grupos: um composto de 30 pessoas com doença coronária cardíaca (CHD), idade média de $65,85 \pm 9,16$ anos, ritmo sinusal normal e pressão sanguínea normal; e outro grupo composto de 30 pessoas saudáveis com idade média similar ($69,75 \pm 5,5$ anos) e sem histórico cardíaco. As pessoas estavam completamente relaxadas e deitadas sobre a cama em um quarto silencioso por vários minutos antes de se começar a registrar o ECG. Durante a tomada dos registros, as pessoas eram solicitadas para respirarem normalmente e permanecerem em repouso. Inicialmente, deve-se escolher um passo de reconstrução s adequado utilizando a inspeção visual para o atrator reconstruído em um espaço de fases.

Nesse trabalho foi escolhido $s = 15$ ms como adequado, com o atrator completamente estendido.

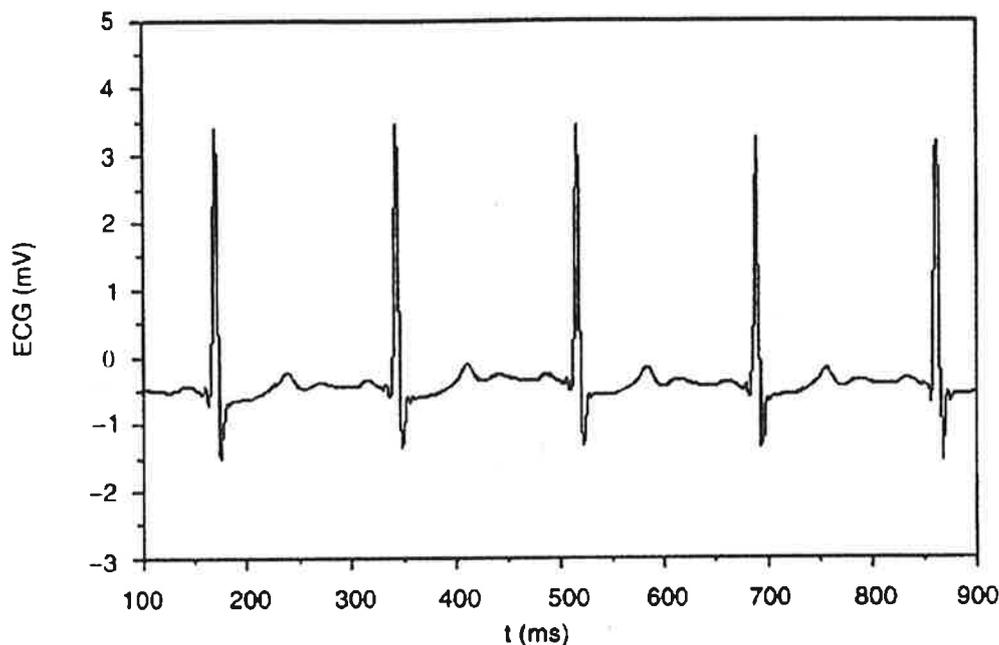


Figura 5.5: ECG de uma pessoa com CHD. Fonte: Wang, et al. 2000.

A figura 5.5 mostra a derivação V_5 do ECG de um típico paciente com CHD. Na prática, como não se sabe qual é a dimensão adequada à reconstrução do atrator, representa-se para várias dimensões a curva de $\log_2 C(N, r) \times \log_2 r$ (figura 5.6) dessa derivação. Pode-se observar que conforme a dimensão de imersão m aumenta, surge uma região chamada de região de escala. Nessa região de escala as curvas tendem a ser retas e paralelas indicando que a dimensão da derivação convergiu para um valor fixo, não havendo mais mudanças na inclinação para valores maiores que m . Esta é a dimensão D_2 do sistema. No caso da derivação V_5 da figura 5.5, os autores obtiveram $D_2 = 2,73$ como a dimensão do sistema (figura 5.7).

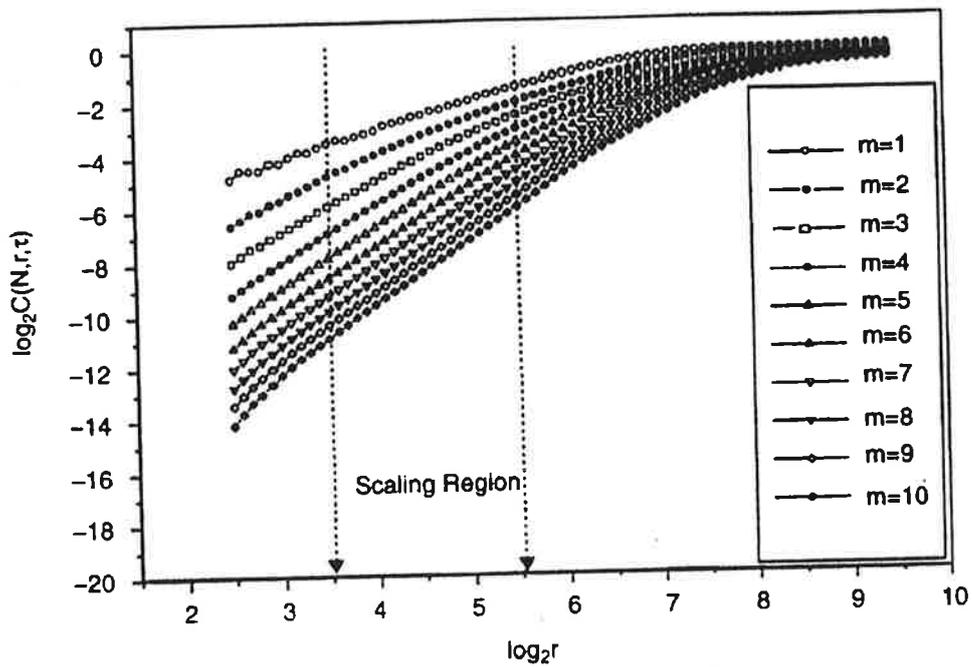


Figura 5.6: $\log_2 C(N, r)$ versus $\log_2 r$ para a mesma pessoa da figura 5.4. Fonte: Wang, et al. 2000.

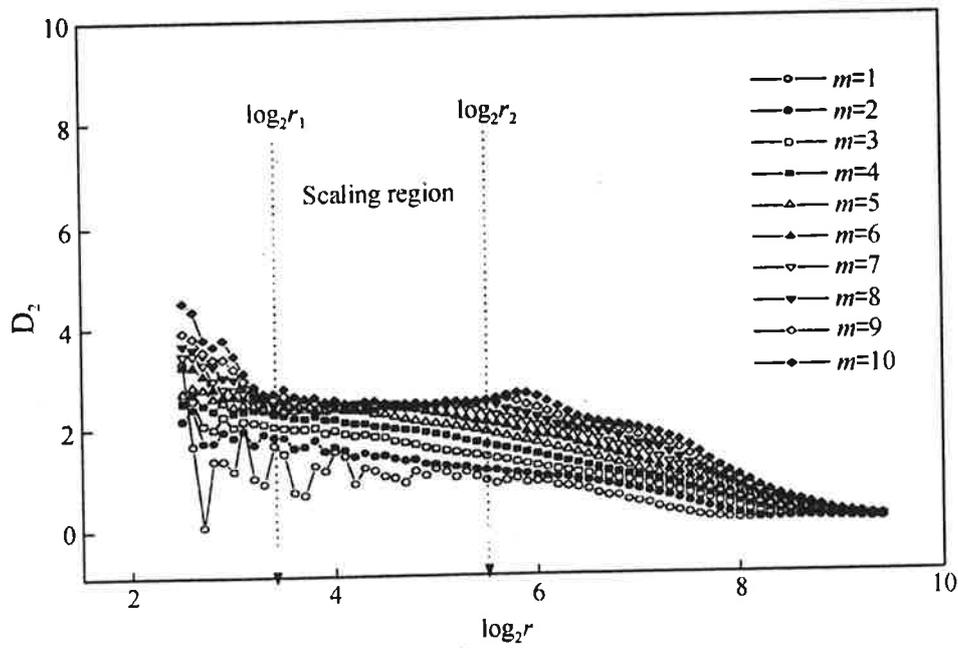


Figura 5.7: D_2 versus $\log_2 r$ para a mesma pessoa da figura 5.4. Fonte: Wang, et al. 2000.

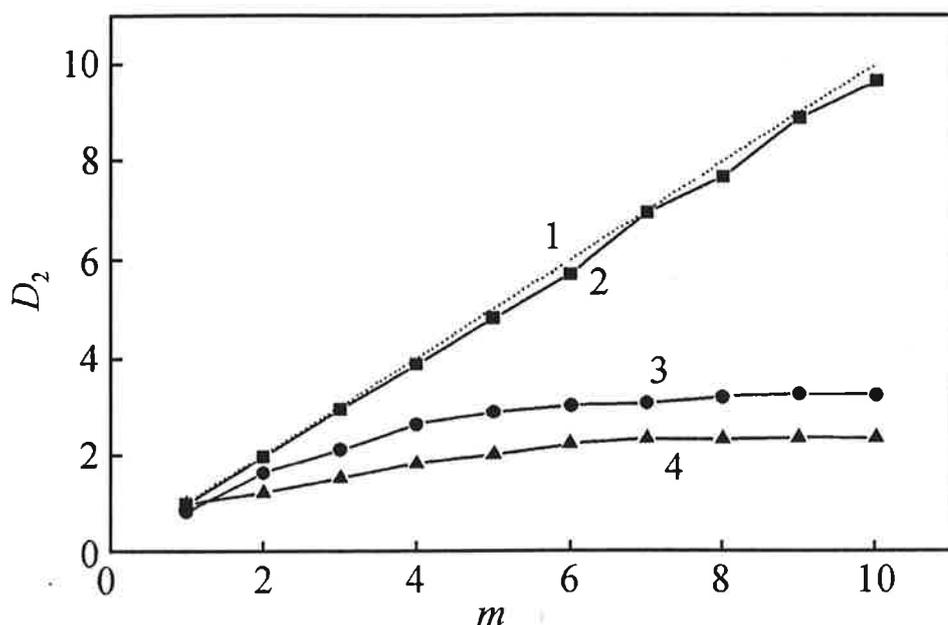


Figura 5.8: Dimensão de correlação versus a dimensão de imersão, são mostradas quatro curvas que correspondem a curva de referência (1) $D_2 = m$, (2) ruído branco, (3) uma derivação V_5 de uma pessoa saudável, e (4) uma derivação V_5 de uma pessoa com CHD. Fonte: Wang, et al. 2000.

Para analisar a convergência da dimensão de correlação, representa-se a dimensão de correlação em função da dimensão de imersão, como na figura 5.8. No trabalho de Wang et al., observou-se quatro curvas que correspondem a curva de referência $D_2 = m$, ruído branco, uma derivação V_5 de uma pessoa saudável, e uma derivação V_5 de uma pessoa com CHD. A conclusão foi de que não importa se a pessoa é saudável ou possui CHD, a dimensão de correlação sempre converge. Veja que para o ruído branco, a dimensão de correlação foi quase coincidente com a curva de referência.

Desta forma foi obtida a dimensão de correlação de cada uma das 12 derivações das 60 pessoas. Cada D_2 obtida era um não-inteiro. Isso demonstrou a forte característica não linear da dinâmica do ECG. Para satisfazer a pré-condição de estado estacionário, ou aproximadamente estacionário, a taxa de amostragem deveria conter um número

suficiente de ciclos cardíacos. Por esta razão, Wang et al. utilizaram 1 minuto de dados coletados, que seria equivalente a aproximadamente 300 ciclos, considerado por eles apropriado para estimar a dimensão de correlação.

Derivação	I	II	III	AVR	AVL	AVF
Pessoas com CHD	3,42±1,33	3,22±1,28	3,51±1,29	3,38±1,33	3,59±1,42	3,34±1,27
Pessoas saudáveis	4,14±1,14	3,75±1,23	3,95±1,21	4,66±0,77	4,81±0,86	4,48±0,75
Valores de P	0,0567	0,1082	0,1703	0,0000	0,0002	0,0000

Tabela 5.1: D_2 (das derivações de extremidade) dos sinais obtidos das 12 derivações simultâneas. Fonte: Wang, et al. 2000.

Derivação	V ₁	V ₂	V ₃	V ₄	V ₅	V ₆
Pessoas com CHD	3,03±0,93	3,22±0,61	2,79±0,43	2,89±0,85	2,73±0,69	2,85±0,65
Pessoas saudáveis	3,60±0,95	3,32±0,71	3,40±0,87	3,35±0,86	3,22±0,79	3,36±0,84
Valores de P	0,0235	0,0039	0,0062	0,0445	0,0142	0,0093

Tabela 5.2: D_2 (das derivações precordiais) dos sinais obtidos das 12 derivações simultâneas. Fonte: Wang, et al. 2000.

Derivação	I	II	III	AVR	AVL	AVF
AMI	2,34±0,60	2,37±0,21	2,71±0,53	2,45±0,41	2,61±0,52	2,62±0,43

Tabela 5.3: D_2 (das derivações de extremidade) dos sinais obtidos das 12 derivações simultâneas para pacientes com infarto agudo do miocárdio. Fonte: Wang, et al. 2000.

Derivação	V ₁	V ₂	V ₃	V ₄	V ₅	V ₆
AMI	2,52±0,30	2,38±0,4	2,52±0,18	2,61±0,18	2,61±0,33	2,51±0,21

Tabela 5.4: D_2 (das derivações precordiais) dos sinais obtidos das 12 derivações simultâneas para pacientes com infarto agudo do miocárdio. Fonte: Wang, et al. 2000.

Nas tabelas 5.1 e 5.2, observa-se que as dimensões de correlação de diferentes derivações do sinal de ECG são diferentes. Aquelas obtidas a partir das derivações de extremidades são maiores do que as dimensões de correlação obtidas a partir das derivações precordiais, não importando se são pessoas com CHD ou não.

Além da distribuição característica da dimensão de correlação, é possível também distinguir entre pessoas saudáveis e pessoas com CHD. Testes T de dois conjuntos de dados da mesma derivação mostraram que exceto para as derivações I, II e III, os valores de p são menores do que 0,05, indicando diferenças estatisticamente significantes dos coeficientes de correlação. Ainda, para a mesma derivação, a D_2 dos pacientes com CHD

são geralmente mais baixas do que a de pacientes saudáveis. Isto sugere que a complexidade da dinâmica do ECG é reduzida sob as condições de isquemia muscular cardíaca. Em particular, observou-se que para sete pessoas que tiveram infarto agudo do miocárdio (AMI) dentre os 30 pacientes com CHD, o decréscimo de D_2 foi muito maior, (tabelas 5.3 e 5.4). Isto também sugere que a complexidade do atrator do ECG é reduzida com dano global do músculo cardíaco. Todas as dimensões de correlação obtidas foram menores do que 6. Isto demonstra que, embora o coração seja um sistema complexo de alta dimensão, o comportamento de longa evolução no espaço de fases cai eventualmente para um atrator de dimensão abaixo de 6.

A razão para a obtenção de diferentes valores de dimensão de correlação para as diferentes derivações do sinal ECG para pessoas saudáveis pode ser devido à rota percorrida pelo sinal para cada derivação e também devido a não homogeneidade do tecido cardíaco. Já para pessoas com CHD, além das razões já mencionadas, os diferentes valores obtidos para a dimensão de correlação também podem estar relacionados com a isquemia local do coração.

Em particular, o pulso de despolarização, originado no nódulo sinusal viaja ao longo da rede His-Purkinge, excita o músculo cardíaco e causa a contração do miocárdio. A aparência caótica da dinâmica do ECG pode estar relacionada com esta atividade. O estreitamento ou bloqueio das artérias coronárias pode causar a morte de algumas células musculares, de tal forma que a complexidade do sistema decresce. Do mesmo modo, a condutividade elétrica das áreas danificadas do músculo cardíaco decresce, conduzindo a uma atividade cardíaca enfraquecida e a redução da complexidade do coração [Wang, et al. 2000].

5.5 Detecção de Mudanças nos Sinais de ECG

Tem sido proposta recentemente por vários autores, uma comparação quantitativa entre atratores que pode ser relevante em muitos problemas diferentes, tais como estabelecer um critério para não estacionaridade, estudar convergência de soluções caóticas, estudar o efeito da redução de ruído não linear de atratores caóticos entre outras aplicações [Diambra 2001]. Isso motivou um recente trabalho de Figueiredo & Furuie [2001a] que, interessados em detectar mudanças na dinâmica da evolução temporal do sinal de ECG, utilizaram distâncias estatísticas para calcular as diferenças entre os atratores obtidos de porções distintas do sinal (em diferentes instantes de tempo). Foram utilizadas distâncias estatísticas de ordem 2 por estar relacionada com a dimensão de correlação (D_2) e com a integral de correlação que são importantes na caracterização de sistemas dinâmicos [Diambra 1999].

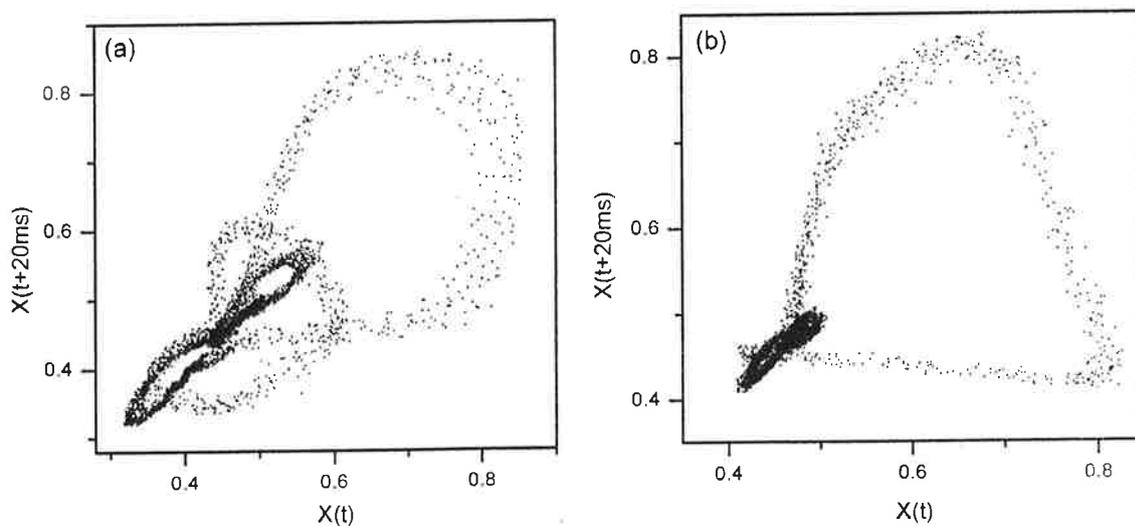


Figura 5.9: Atratores reconstruídos para o mesmo sinal de ECG utilizando diferentes porções do sinal. Fonte: Figueiredo & Furuie 2001a.

Por exemplo, na figura 5.9 podem ser observados dois atratores reconstruídos para o mesmo sinal de ECG usando diferentes porções de um sinal. Além dos atratores pertencerem ao mesmo sinal de ECG, eles representam diferentes comportamentos dinâmicos. Para estabelecer uma comparação quantitativa entre os dois atratores reconstruídos em um espaço de fase de dimensão 2, discretiza-se o espaço de fase de cada atrator em B caixas de tamanho r . Desta forma obtém-se as distribuições: $\{g_{i,j}\}$ e $\{p_{i,j}\}$. Cada elemento $g_{i,j}$ e $p_{i,j}$ é dado por um número de pontos do atrator que caem dentro da caixa (i, j) (figura 5.10).

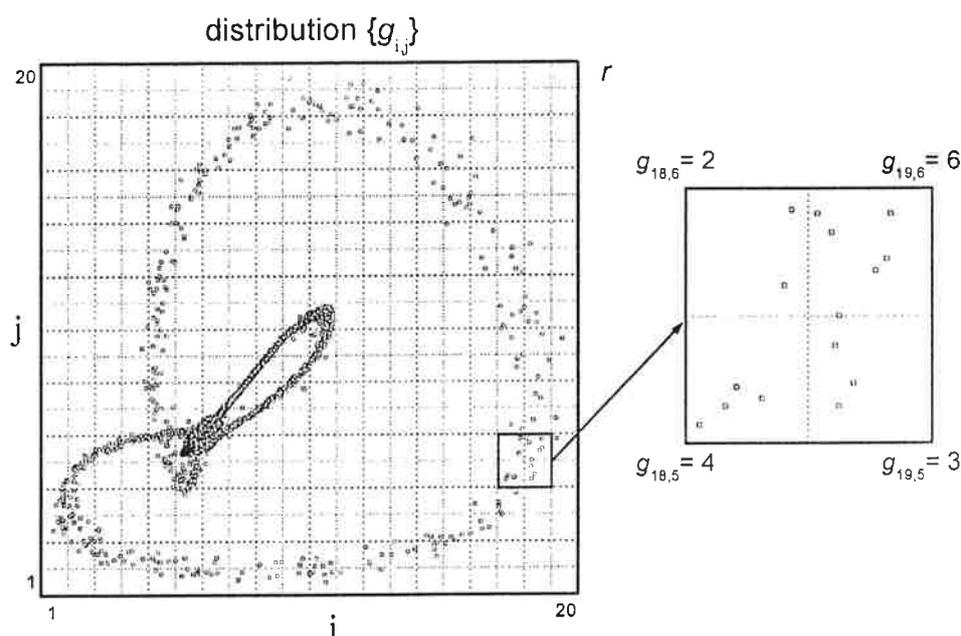


Figura 5.10: Distribuição estatística $\{g_{i,j}\}$ obtida do atrator de um sinal normal de ECG. Fonte: Figueiredo & Furuie 2001a.

A ordem das distâncias calculadas também é igual a 2 ($q = 2$). Considerando estas observações e substituindo na equação 4.27, a dpg é então dada por

$$dpg = \left(\sum_{i=1}^{B(r)} \sum_{j=1}^{B(r)} \frac{(p_{i,j})^2}{g_{i,j}} \right) - 1, \quad (5.1)$$

onde $B(r)$ é o número de caixas de tamanho r necessários para cobrir o atrator reconstruído (de séries temporais de ECG).

Nota-se que o parâmetro r (o tamanho da caixa) é um parâmetro crítico. Para altos valores de r o cálculo da dpg fornece apenas as grandes mudanças no comportamento de atratores dinâmicos, porém, para pequenos valores de r , o resultado pode ser fortemente influenciado pelo ruído. No trabalho de Figueiredo & Furuie [2001a] foram utilizados dois sinais da base de dados Physionet (apêndice B): um de ECG com ritmo sinusal normal (*sel16795*) e outro sinal de ECG com arritmia supraventricular (*sel872*). Estes dois sinais correspondem a 15 minutos de sinais e são normalizados (amplitude) à unidade. Figueiredo & Furuie adotaram o valor de $r = 1/500$ para estudo, o que implica em uma matriz de 500×500 caixas de tamanho r para a discretização do espaço de fase do sinal normalizado - $B(r) = 500$. Outros valores de r foram testados sendo que para estes dois sinais os melhores resultados foram obtidos para r próximo a $1/500$. Os primeiros 5000 pontos iniciais de cada sinal (20 s) foram escolhidos ($N_{ref} = 5000$) para reconstruir, usando a técnica de reconstrução de Takens com $m = 2$ e $s = 12$ ms, um atrator de referência correspondente à distribuição $\{g_{i,j}\}$. É interessante notar que não importa se a parte inicial do sinal é normal do ponto de vista patológico. O importante é escolher uma parte representativa da maioria do sinal. Nesse trabalho, em ambos os casos os 20 s satisfizeram este requerimento. Usando janelas de $N = 3000$ pontos (12 s) separados por $n = 750$ pontos (3 s), foi realizada a reconstrução do sinal, para cada janela, os atratores obtidos corresponderam às distribuições $\{p_{i,j}\}$ da figura 5.11.

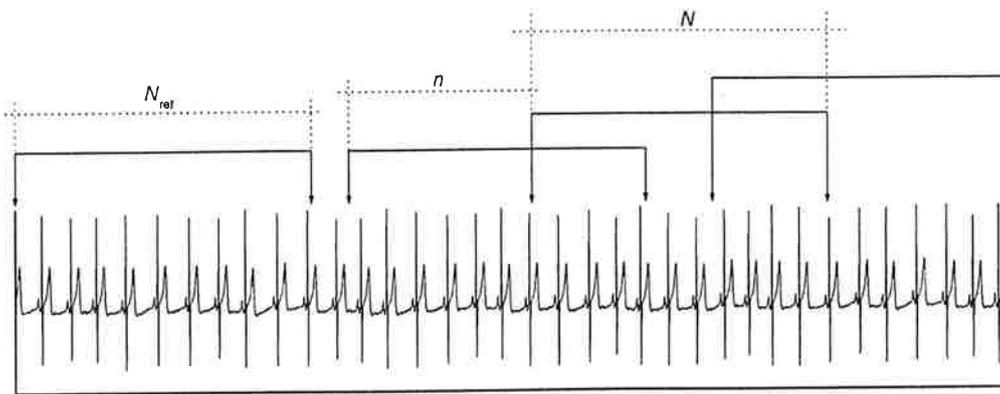


Figura 5.11: Esquema para a análise do sinal usando distâncias estatísticas: N_{ref} é o número de pontos do atrator de referência correspondendo a distribuição $\{g_{i,j}\}$, N é o número de pontos de cada janela usada para reconstruir os atratores correspondentes a distribuição $\{p_{i,j}\}$ e n é o número de pontos de separação entre cada janela. Fonte: Figueiredo & Furuie 2001a.

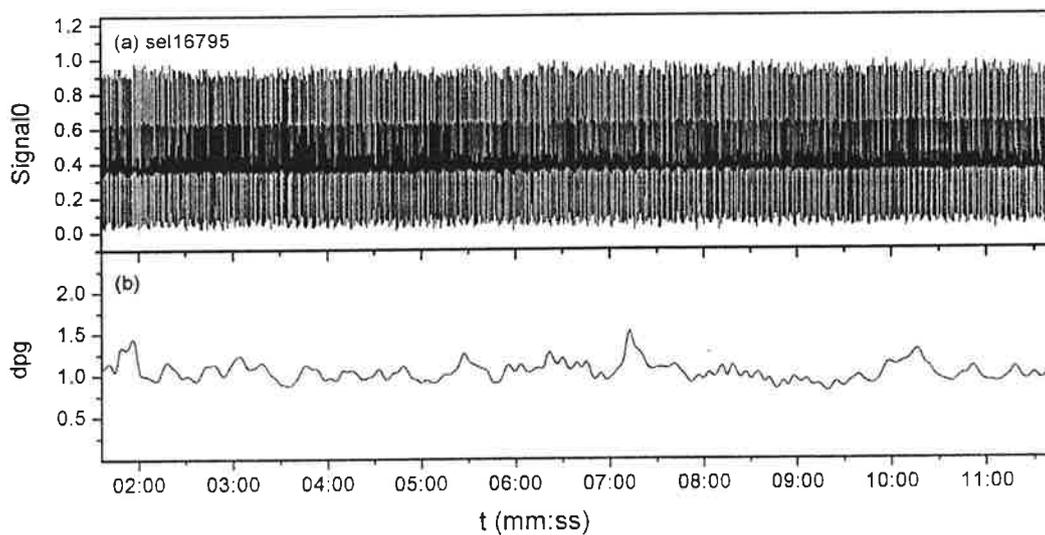


Figura 5.12: Sinal normal da Physionet (sel16795): (a) sinal de ECG, (b) análise dpg. Fonte: Figueiredo & Furuie 2001a.

Os valores calculados da dpg são atribuídos para o instante referente ao centro de cada janela. A figura 5.12 mostra os resultados para o sinal normal (sel16795). Na figura 5.12 a distância dpg entre cada um dos atratores reconstruídos e o atrator de referência oscilou em torno de $dpg = 1$ (a média da dpg neste caso foi aproximadamente 1,03) com

valor máximo de $dpg = 1,66$. A ausência de picos pronunciados denota que nenhuma mudança no comportamento dinâmico do sistema pode ser detectada pelo uso de distâncias estatísticas (ao menos para os valores dos parâmetros utilizados e para o atrator de referência escolhido). Os valores que as distâncias estatísticas podem assumir estão intimamente relacionados com os valores dos principais parâmetros utilizados no processo de cálculo: m , s e r . Os valores da dpg podem variar muito de acordo com a escolha destes parâmetros e uma boa quantidade de experimentação ainda se faz necessária para escolhê-los [Figueiredo 2001a].

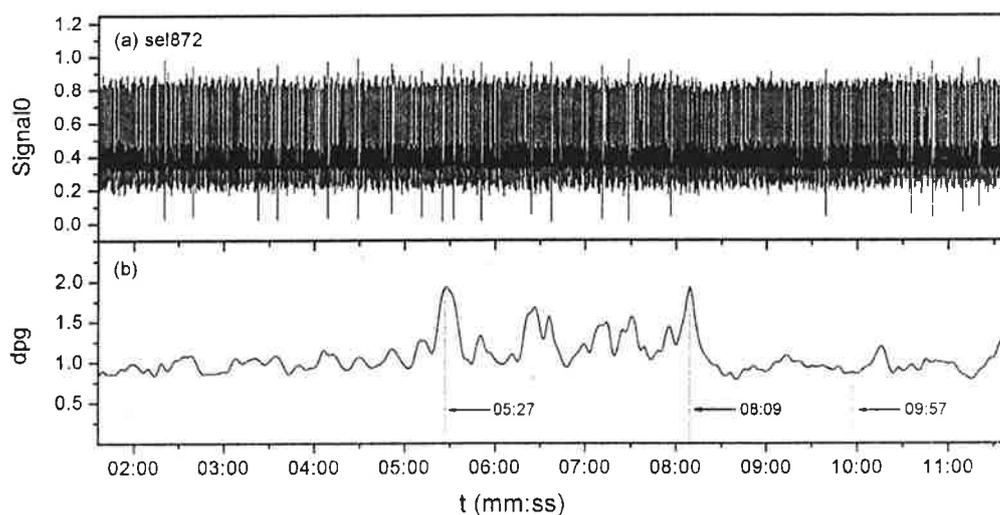


Figura 5.13: Sinal sel872 da Physionet: (a) sinal de ECG, (b) análise de dpg . Fonte: Figueiredo & Furuie 2001a.

No caso do sinal sel872, a figura 5.13 mostra o resultado. Ao contrário do comportamento observado na figura 5.12 o gráfico da distância estatística da figura 5.13 apresenta uma região de picos pronunciados que vão desde aproximadamente $t = 5:30$ até aproximadamente o instante $t = 8:00$ do sinal de ECG. Os valores de dpg oscilam (assim como na figura 5.12) ao redor de $dpg = 1$ (a média da dpg foi 1,07 neste caso).

Porém, o valor máximo do sinal, foi encontrado no instante $t = 8:09$, com o valor $dpg = 2,10$. O comportamento do gráfico da dpg indica que o ECG apresenta uma acentuada mudança no comportamento dinâmico no intervalo, aonde ocorrem os picos. Embora não tenha sido possível identificar exatamente o tipo de mudança que ocorreu naqueles instantes. Por isso é necessário reconstruir os atratores e comparar com o atrator de referência.

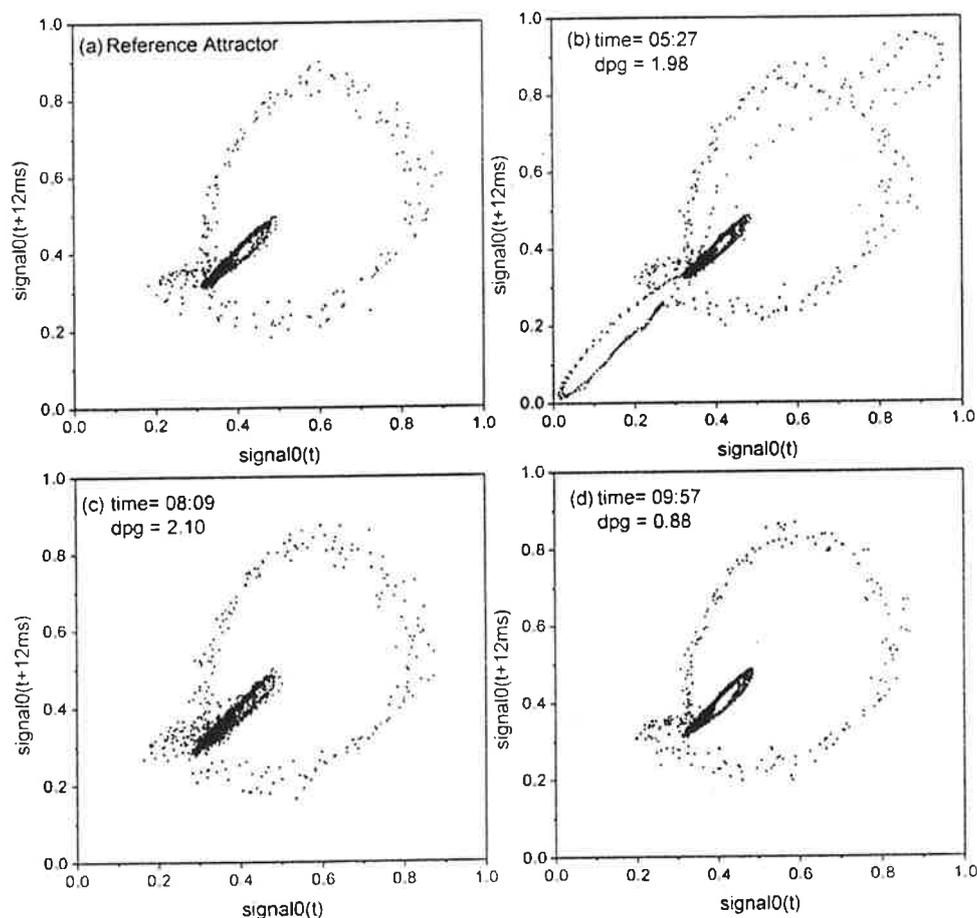


Figura 5.14: Atratores correspondentes aos instantes de tempo indicados na figura 5.13. Fonte: Figueiredo & Furuie 2001a.

Na figura 5.14 foram selecionado três instantes de tempo, dois que correspondem aos picos mais altos no gráfico da dpg (indicando grandes mudanças no comportamento

do sinal). Estes instantes são os instantes $t = 05:27$ e $t = 08:09$. Também foi escolhido outro instante ($t = 09:57$) aonde a distância dpg , em relação ao atrator de referência, apresenta o valor mais baixo. Todos estes instantes estão indicados na figura 5.13.

Para cada um destes instantes foram tomados 12 s do ECG para a obtenção do valor da dpg para reconstruir os atratores 2D correspondentes. Os resultados são mostrados na figura 5.14. Observa-se que a dinâmica no instante $t = 05:27$ (figura 5.14-b) e $t = 08:09$ (figura 5.14-c) apresenta grandes diferenças em relação ao comportamento dinâmico utilizado com referência para o sinal (o atrator de referência na figura 5.14-d). O atrator na figura 5.14-b apresenta mudanças morfológicas em alguns segmentos do complexo QRS e o atrator da figura 5.14-c aparentemente apresenta flutuações nos segmentos P e T. Na figura 5.14-c também observa-se que o comportamento dinâmico aproxima-se do comportamento dinâmico do atrator de referência. Portanto, em todos os casos, o gráfico da dpg tem sucesso na detecção de mudanças no comportamento do sinal de ECG.

Em outro trabalho, Figueiredo & Furuie [2001b] apontaram que o uso de uma malha uniforme para construir uma distribuição estatística possui alguns problemas, o principal é que a malha não leva em conta o fato de algumas regiões do atrator do ECG terem baixa densidade e alta dispersão espacial, como o complexo QRS. Portanto, pequenas alterações morfológicas no complexo QRS são tratados da mesma forma estatística que as mudanças morfológicas nos segmentos ST. Outro problema é o tempo elevado necessário para se comparar duas distribuições usando a malha uniforme. A solução para esses problemas foi o uso de um método de decomposição *quadtree* para a construção das malhas uniformes. O princípio básico do método *quadtree* é cobrir a região plana de interesse por um quadrado e então, recursivamente, particionar quadrados

dentro de quadrados menores até que, dentro de cada quadrado, haja um número menor ou igual de pontos ao estabelecido por um *threshold*. Uma distribuição estatística discreta pode ser feita a partir do atrator reconstruído por Takens considerando o vetor

$$\bar{\Xi}(t) = \text{int} \left[\bar{\xi}(t)(2^b - 1) + 1 \right], \quad (5.2)$$

onde b representa a resolução em *bits* pra a discretização do espaço. A figura 5.15-b mostra, para $b = 5$, a distribuição estatística obtida na figura 5.15-a. Nesta figura, cada célula da malha p_i ($i = 1, 2, 3, \dots, 2^b$) corresponde ao total de pontos de $\bar{\Xi}(t)$ que caem dentro da célula i .

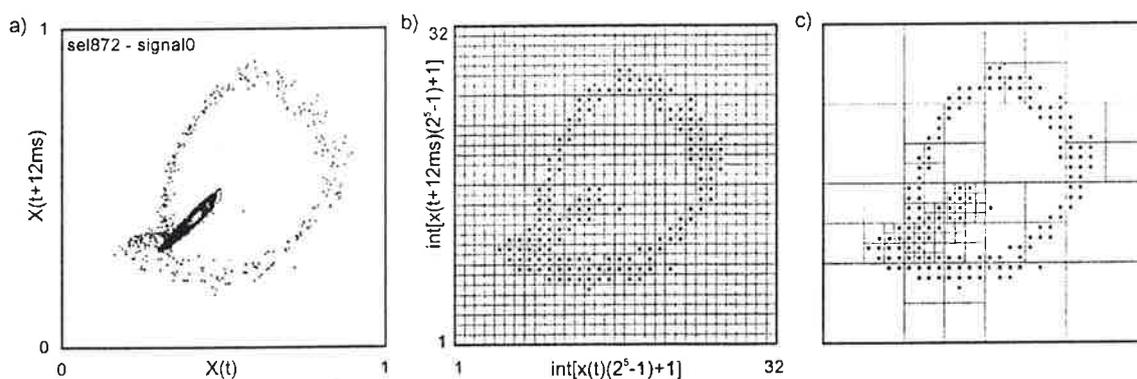


Figura 5.15: (a) Atrator reconstruído de um sinal de ECG normalizado. (b) O mesmo atrator distribuído sobre uma malha uniforme com 5 bits de resolução (cada célula representa o total de pontos que caem dentro de cada célula). (c) Uma malha *quadtree* gerada da distribuição da malha uniforme. Fonte: Figueiredo & Furuie 2001b.

A figura 5.15-c mostra a decomposição *quadtree* para a distribuição da figura 5.15-b (o *threshold* utilizado foi o valor médio das células na malha uniforme). Para comparar os atratores é preciso medir a distância entre as distribuições $p = \{p_i\}$ e $g = \{g_i\}$ geradas por dois pontos que estão distribuídos sobre a malha de referência (que pode ser uniforme ou *quadtree*). A distância utilizada foi a distância de correlação. O uso da decomposição *quadtree* no espaço de fases faz o processamento ser mais rápido e mais acurado devido

ao número menor de caixas e ao fato da decomposição da malha ser ajustada com a densidade local dos pontos do atrator. Na figura 5.16 observa-se o mesmo sinal analisado pela malha uniforme e pelo método *quadtree*. Para os baixos valores da Dpg correspondendo as partes do sinal onde o comportamento dinâmico é similar ao do intervalo de referência, Figueiredo & Furuie [2001b] observaram que os valores oscilam por volta de $Dpg = 0,2$. As regiões aonde a distância de correlação apresentou picos acentuados indicam uma acentuada mudança no comportamento dinâmico do ECG. Nestes casos a malha *quadtree* apresentou mais sensibilidade em relação à malha uniforme.

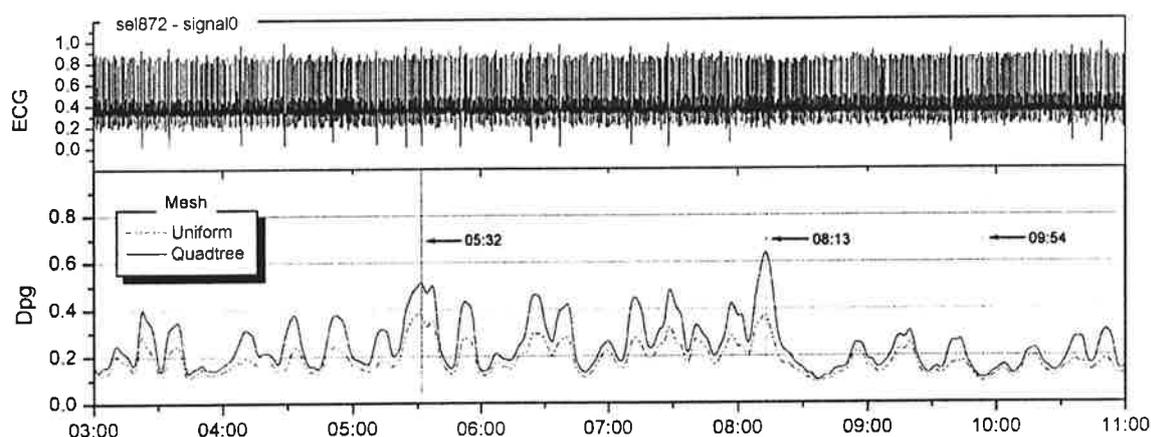


Figura 5.16: Dpg do sinal sel872 da base de dados Physionet para: $m = 2$, $\tau = 12$ ms e $b = 9$. Fonte: Figueiredo & Furuie 2001b.

Embora os resultados dessa técnica tenham se mostrado eficiente na proposta de identificar as mudanças morfológicas no ECG, mais estudos são necessários para uma escolha adequada dos parâmetros.

5.6 Análise de DFA no ECG

A DFA é uma técnica que foi inicialmente utilizada para detectar correlações de longo alcance em seqüências de DNA, e tem sido crescentemente utilizada na análise de sinais biológicos [Peng, et al. 1994]. Como as séries temporais de batimentos cardíacos exibem comportamento irregular, não satisfazendo o requerimento de estacionaridade, e como aparentemente possuem uma estrutura fractal, diversos trabalhos adotam a técnica de DFA para a análise da variação da frequência cardíaca.

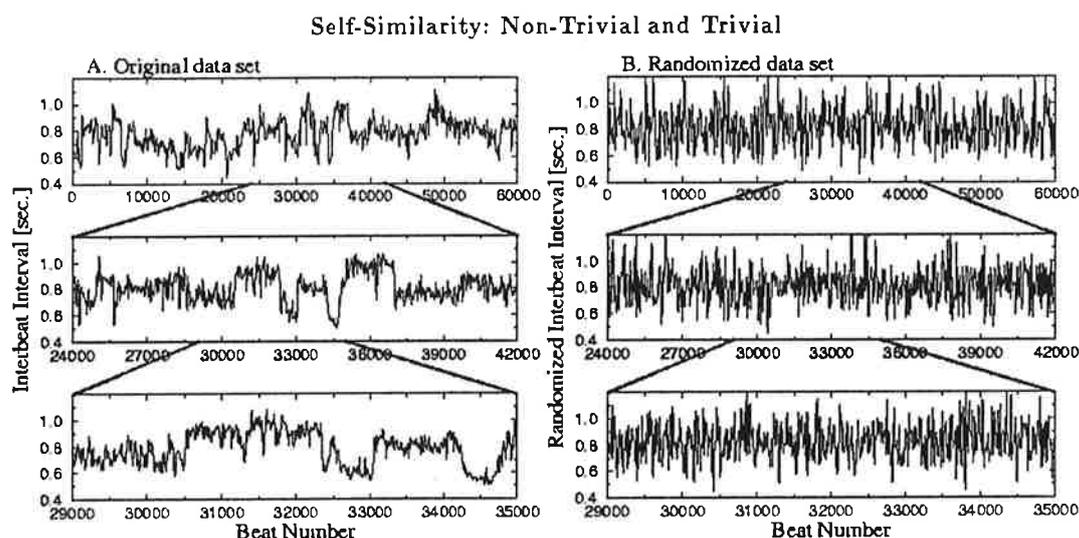


Figura 5.17: Uma série temporal de intervalos de batimentos cardíacos (A) e uma série randomizada (B). Sucessivas ampliações de subconjuntos da série mostrando que ambas as séries são auto-similares. Fonte: Peng, et al 2000.

Para exemplificar o uso da técnica DFA para o estudo da frequência cardíaca, descreveremos o trabalho desenvolvido por Peng et al. [2000]. Nesse trabalho, o algoritmo de DFA foi aplicado para um grande conjunto de dados, correspondente a aproximadamente 24 horas de uma série temporal de batimentos cardíacos de uma pessoa saudável, e outra série temporal artificial, gerada pela randomização da seqüência dos dados da série original (figura 5.17). Observa-se na figura 5.18 que a análise de DFA para

a pessoa saudável mostrou comportamento de escala com expoente $\alpha = 1$ para $n = 30$, consistente com a dinâmica $1/f$, indicativo de provável estrutura fractal dos dados [Kobayashi & Mysha1982]. E, como esperado, o conjunto de dados randomizados mostrou um expoente $\alpha = 0,5$, indicando randomicidade não correlacionada. A análise do espectro de potência corrobora com os resultados de DFA, mas vale ressaltar que o expoente β , derivado do espectro de potência, é menos preciso porque o requerimento de estacionaridade para a análise de Fourier não é satisfeito neste caso.

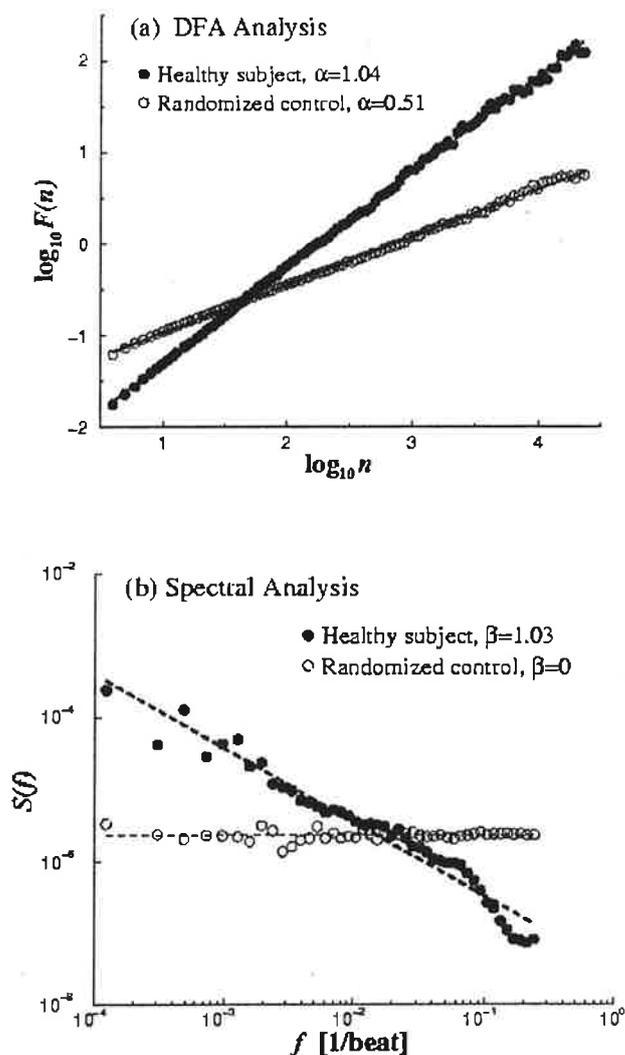


Figura 5.18: (a) Análise de DFA para as séries temporais observadas na figura 5.17. (b) Análise do espectro de potência para as séries temporais observadas na figura 5.17. Fonte: Peng, et al 2000.

Outros trabalhos com DFA têm demonstrado mudanças marcantes na dinâmica da frequência cardíaca de pessoas portadoras de patologias [Goldberger, et al. 2002, Iyengar, et al. 1996, Peng, et al. 1995, Stanley, et al. 1999]. Em outro estudo realizado por Peng et al. [1995] foi realizada a análise de DFA para uma série temporal de intervalos de

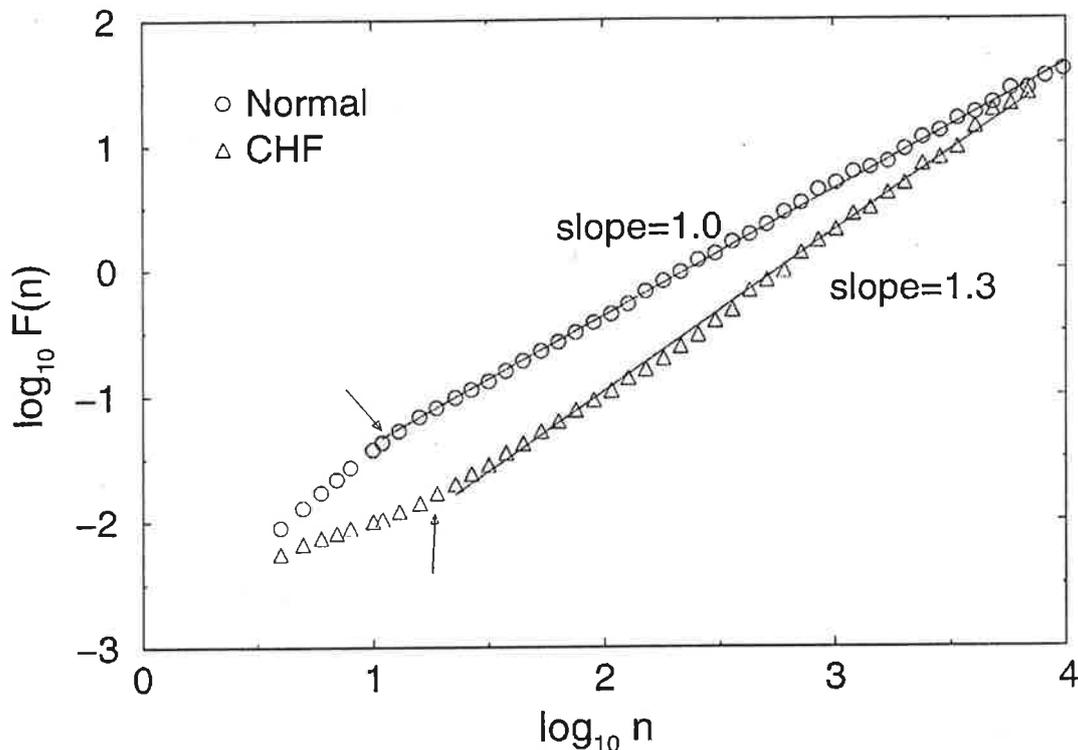


Figura 5.19: Análise de DFA para três séries temporais de intervalos de batimentos cardíacos: pessoas jovens saudáveis, pessoas idosas e pessoas com CHF. Fonte: Stanley, et al 1999.

batimentos cardíacos de uma pessoa saudável e de uma pessoa com CHF (figura 5.19). Note que para grandes escalas temporais, a pessoa saudável apresenta quase que uma perfeita lei de potência para mais de 20 horas de coleta de dados ($20 \leq n \leq 10000$) com $\alpha = 1$, enquanto que para pessoas com CHF, temos $\alpha = 1,3$. Este resultado indica que há uma diferença significante entre o comportamento de escala entre estados saudáveis e estados patológicos, consistente com a quebra de correlações de longo alcance [Iyengar ,

et al. 1996]. Ainda na figura 5.19, Peng et al. [1995] notou que a análise de DFA exhibe, tanto para a pessoa saudável quanto para a pessoa com CHF, duas regiões com expoente α de escala distintos, separados por um ponto de quebra próximo de $n = 10$, esse fenômeno é chamado de *crossover*. Para pessoas saudáveis, o expoente α estimado para $n < 10$ batimentos é maior do que aquele estimado para $n > 10$. A teoria, proposta por Peng et al., é de que isto se deve, provavelmente, ao fato de que para escalas temporais curtas ($n < 10$), a flutuação dos intervalos entre os batimentos apresenta uma oscilação suave associada com a respiração, então surge um α maior do que o do restante da série. E para escalas temporais maiores, a flutuações entre os intervalos refletem a dinâmica intrínseca de um sistema complexo, o comportamento aproxima-se a $1/f$ como notado anteriormente. Em contraste, para o conjunto de dados patológicos (figura 5.19), para escalas temporais curtas, a flutuação é quase randômica ($\alpha = 0,5$) e conforme n aumenta, as oscilações tornam-se mais suaves.

Para sistematizar o estudo de alteração das correlações de longo alcance com patologias que ameaçam a vida, Goldberger et al. [2002] analisaram os dados de batimentos cardíacos de três grupos de pessoas: (1) 29 pessoas (17 homens e 12 mulheres) sem evidência clínica de doença cardíaca (20-64 anos), (2) 10 pessoas (17 homens e 12 mulheres) com síndrome de morte súbita (35-82 anos) e (3) 15 adultos com CHF (22-71 anos). Os dados, de cada pessoa, continham aproximadamente 24 horas de ECG de gravação com aproximadamente 10^5 batimentos. Para o grupo de pessoas saudáveis, observou-se $\alpha = 1,00 \pm 0,10$. Este resultado confirma que flutuações de frequência cardíaca de pessoas saudáveis exibem comportamento de correlação de lei de potência de longo alcance, similar ao observado em muitos sistemas dinâmicos longe do equilíbrio [Mallamace & Stanley 1997]. Além disso, ambos os grupos patológicos mostraram desvio

significante de correlações de longo alcance em relação às pessoas saudáveis. Para o grupo de pessoas com CHF, foi encontrado $\alpha = 1,24 \pm 0,22$, enquanto que para o grupo de pessoas com síndrome da morte cardíaca súbita foi encontrado $\alpha = 1,22 \pm 0,25$. Resultados similares foram obtidos quando as séries temporais foram divididas em três subconjuntos de aproximadamente 8 horas cada e foi repetida a análise, mostrando que os dados não podem ser atribuídos a diferentes níveis de atividades diárias.

Uma análise similar [Goldberger, et al. 2002] foi usada para estudar o efeito fisiológico da idade: 10 jovens (21-34 anos) e 10 idosos (68-81 anos) saudáveis foram submetidos a 2 horas de repouso. Para as pessoas jovens, o expoente de escala teve um α próximo de 1,0. Para as pessoas idosas, as séries temporais de batimentos cardíacos exibem duas regiões de escala. Uma de curto alcance ($n \leq 11$) com $\alpha = 1,5$ e outra de longo alcance ($n > 11$) com $\alpha = 0,5$. Expoentes de curto alcance e de longo alcance foram significativamente diferentes em pessoas idosas quando comparadas com pessoas jovens. De fato, as alterações no comportamento de escala estão associadas com a idade fisiológica e exibem diferentes padrões para as pessoas com CHF.

Além disso, em pacientes que sofreram infarto do miocárdio, o decréscimo do coeficiente de escala $\alpha(n \leq 11)$ é um forte indício de risco de arritmia ventricular [Tapanainen, et al. 2002]. Logo, a alteração do expoente de escala da DFA fornece um diagnóstico adicional e uma informação prognóstica que são independentes das análises no domínio do tempo e da frequência [Ho, et al. 1997].

6 PROGRAMA PARA ANÁLISE NÃO LINEAR DO ECG

A partir dos estudos realizados para esta dissertação foi possível reproduzir um programa proposto inicialmente por Figueiredo & Furuie [2001a], para a detecção de mudanças morfológicas no sinal de ECG.

6.1 Motivação

O estudo e a revisão teórica de métodos matemáticos para a análise de sinais de ECG motivaram o uso de ferramentas computacionais. Hoje em dia, o processo de aprendizagem demanda o uso de tais ferramentas que consolidam conceitos que são fundamentados pela teoria. Embora nesse trabalho os métodos não lineares aqui estudados tenham sido focados mais sob a ótica teórica, sem dúvida podem ser considerados métodos teórico-computacionais, e implementados em programas. E desenvolver um programa, sem dúvida, é como materializar parte do conhecimento adquirido, dentro de uma aplicação que, de certa forma, complementa o documento escrito.

O programa implementado foi desenvolvido através do *software* Matlab. O programa tem como principal função calcular diferenças entre dois atratores gerados a partir de uma série de ECG, identificando mudanças morfológicas significativas. Conceitos como reconstrução de Takens, entropia generalizada, dimensão de correlação e métricas de distância entre atratores foram necessários para o desenvolvimento desta ferramenta. Mas antes de explicar seu funcionamento, é importante destacar algumas de suas características. A primeira é a *facilidade* de uso, proporcionada pelas interfaces gráficas que auxiliam não somente na entrada de dados como também na compreensão dos métodos utilizados, uma vez que apresentam gráficos e informações relevantes sobre aos dados analisados. Outra característica é a *integridade* dos cálculos, embora o programa não exija cálculos complicados que envolvam conhecimentos mais apurados de cálculo numérico, houve sem dúvida a preocupação com sua exatidão. Tentou-se também manter a *clareza* da lógica através da documentação do programa com os devidos comentários. Houve a tentativa de manter um equilíbrio entre *eficiência* e *estrutura mais simplificada*, às vezes abrindo mão de um pouco de eficiência para manter uma estrutura bastante simplificada, uma vez que, pelo menos por enquanto, esse programa foi implementado para fins de pesquisa. E, por último, também houve uma preocupação com a modularidade, aqui traduzidas por várias funções que auxiliam numa futura modificação e/ou implementação.

6.2 Funcionalidades

Na primeira interface (figura 6.1), podemos selecionar um sinal de ECG e visualizá-lo. Feito isso, selecionamos uma parte do sinal de ECG e configuramos os parâmetros

para a reconstrução de um atrator de referência do sinal. Podemos maximizar partes do atrator e ainda determinar a resolução em *bits* da figura do atrator. A janela à direita da figura 6.1 mostra o particionamento *quadtree*, podendo visualizar como o espaço de fase do atrator foi dividido. Na parte inferior da tela é possível verificar as estatísticas de preenchimento das caixas.

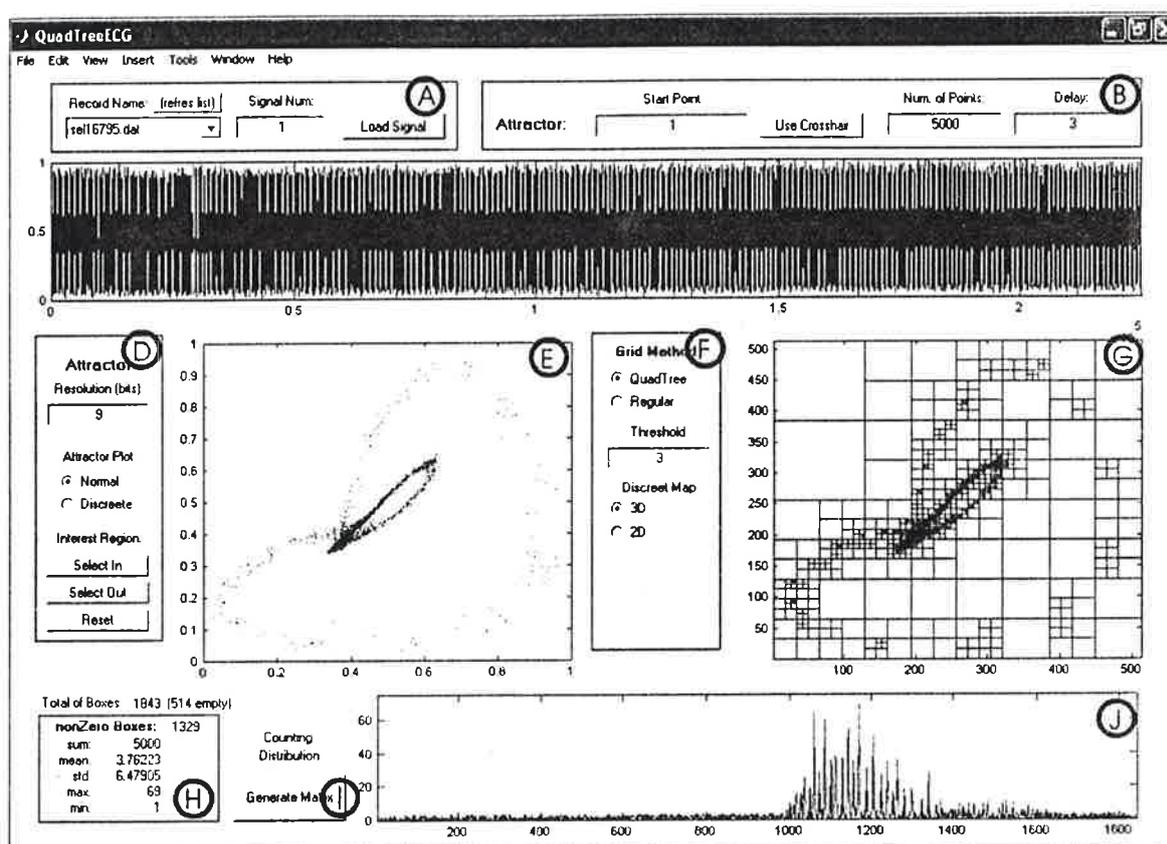


Figura 6.1: QuadTreeECG, interface gráfica para a entrada de dados desenvolvida para análise de distâncias estatísticas.

Na segunda interface (figura 6.2) podemos calcular a distância entre o atrator referência e o atrator de um ponto selecionado utilizando uma métrica determinada pelo usuário. Os dois atratores (o de referência e o de comparação) podem ser visualizados simultaneamente.

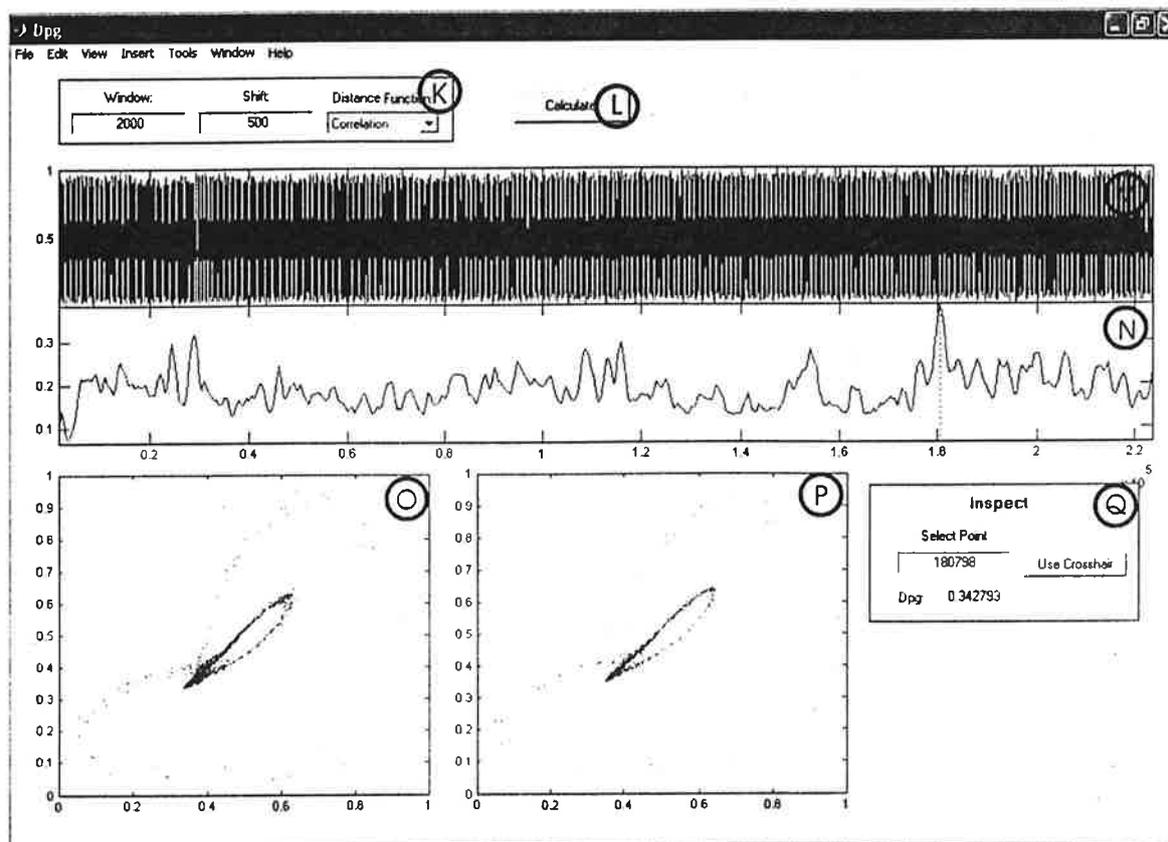


Figura 6.2: Dpg, interface gráfica para a entrada de dados desenvolvida para análise de distâncias estatísticas.

Agora, descreveremos os itens de configuração utilizados nas duas interfaces gráficas. Começando pela interface denominada de QuadtreeECG (figura 6.1):

[A] *Record Name*: Lista os nomes dos arquivos de entrada. Permite a seleção de um deles para o início do processamento.

Botão *Refresh*: Atualiza a lista dos nomes dos arquivos de entrada.

Signal Num: Seleciona qual sinal será analisado.

Botão *Load Signal*: Carrega o sinal selecionado.

[B] *Start Point*: Configura o primeiro ponto da série do sinal de ECG utilizado para a reconstrução do atrator de referência pelo método de Takens.

Botão *Use Crosshair*: Seleciona, com o uso do ponteiro, o *Start Point* sobre a janela da série do sinal do ECG.

Num. of Points: Configura o número de pontos a ser utilizado na reconstrução do atrator de referência.

Delay: Configura o passo de reconstrução.

[C] Janela com a série temporal do ECG.

[D] *Resolution*: Configura a resolução do atrator reconstruído.

Attractor Plot: Esta chave, do tipo *check box*, permite escolher se o atrator será reconstruído sem a distribuição estatística (*normal*) ou com a distribuição estatística (*discrete*).

Interest Region: Existem três botões que permitem a seleção de uma região de interesse sobre o atrator: *Select In*, *Select Out*, *Reset*. Ao clicar sobre um dos primeiros dois botões, deve-se selecionar uma área configurada pela seleção de dois pontos via *mouse* sobre a janela do atrator, selecionando ou excluindo essa área delimitada por estes dois pontos. Também é possível recuperar o atrator original (inteiro) clicando sobre o botão *Reset*.

[E] Janela com atrator de referência reconstruído pelo método de Takens.

- [F] *Grid Method*: Esta chave, do tipo *check box*, permite escolher se o atrator vai ser reconstruído em uma grade regular (*Regular*) ou com o particionamento *quadtree* (*Quadtree*).

Threshold: mostra o valor do threshold calculado pelo programa.

Discrete Map: Esta chave, do tipo *check box*, indica se o particionamento levará em conta a densidade de pontos que caíram nas caixas (3D) ou somente se a caixa foi preenchida ou não (2D).

- [G] Janela com a região do atrator particionada.

- [H] Estatística das caixas utilizadas para a reconstrução do atrator selecionado:

Total of Boxes: total de caixas utilizadas no particionamento.

nonZero Boxes: número de caixas com algum ponto (não vazias) do atrator.

sum: soma dos pontos de todas as caixas.

mean: média de pontos em todas as caixas não vazias.

std: desvio padrão do número de pontos nas caixas não vazias.

max: o número máximo de pontos em uma caixa

min: o número mínimo de pontos em uma caixa não vazia.

- [I] *Generate Matrix*: gera uma matriz que contém os índices das caixas com os respectivos números de pontos em cada uma delas.

[J] *Counting Distribution*: este gráfico contém uma distribuição para o número de pontos em cada caixa.

Na segunda interface, a Dpg (figura 6.2), temos:

[K] *Window*: configura o número de pontos a ser utilizado para a reconstrução dos atratores.

Shift: configura o passo de deslocamento da janela.

Distance Function: lista as funções distância e permite a seleção de uma delas para ser utilizada no cálculo da distância entre os atratores.

[L] Botão *Calculate*: inicia o cálculo da função distância.

[M] Janela com a série temporal do ECG.

[N] Janela com a distância entre os atratores.

[O] Janela com a atrator referência reconstruído.

[P] Janela com o atrator de um determinado ponto que será selecionado.

[Q] *Inspect*: clicando sobre o botão *Use Crosshair* é possível selecionar um ponto para calcular a distância entre os atratores, o valor deste ponto pode ser visualizado em *Select Point* e a distância para este ponto também é fornecida pela *dpg*.

O código fonte do programa pode ser visto no apêndice C.

7 CONCLUSÕES

A utilização de alguns dos métodos matemáticos para a análise de sistemas dinâmicos não lineares possibilita uma melhor compreensão do comportamento dos sinais de ECG. Algumas aplicações baseadas nesses métodos mostram resultados interessantes e levam à novas idéias que geram novos métodos de diagnóstico e/ou prognóstico de patologias cardíacas. Vimos que: (1) o método de redução não linear de ruído por projeção local é capaz de fornecer um resultado considerado inovador, uma vez que as técnicas clássicas não obtêm resultados tão satisfatórios na extração de um ECG fetal, (2) o cálculo da dimensão de correlação permite diferenciar pessoas com CHD de pessoas saudáveis, indicando que pode vir a servir como ferramenta diagnóstica discriminante, além de sugerir que existe a possibilidade dessa técnica futuramente vir a auxiliar na localização de isquemias cardíacas; (3) o cálculo das distâncias estatísticas entre atratores é capaz de identificar mudanças morfológicas significativas em um mesmo sinal de ECG. Esse método detecta de maneira satisfatória mudanças proeminentes em um sinal de ECG de pacientes com arritmias específicas, e futuramente pode, e deve, ser avaliado com outras patologias e (4) a DFA é capaz de diagnosticar CHD através do parâmetro α de

auto-similaridade do sinal. A DFA tem grande potencial clínico uma vez que a auto-similaridade sofre alterações em situações patológicas e em pessoas idosas.

Na tabela 7.1, podemos observar que os métodos não lineares de análise de sinais ECG apresentam algumas vantagens técnicas em relação aos métodos clássicos: (1) não requerem, em geral, estacionaridade; (2) podem ser aplicados tanto aos estudos morfológicos como de VFC; (3) necessitam, em geral, uma quantidade pequena de dados e; (4) os métodos de filtragem não linear são capazes de discriminar e separar sinais que possuem um espectro contínuo. Apesar desses métodos serem mais eficientes do que os clássicos na caracterização do estado de um sistema não linear, ainda não se pode dizer que as técnicas não lineares são mais poderosas na hora de se realizar um diagnóstico e/ou prognóstico. Tais métodos necessitam de mais estudos para estabelecer parâmetros mais confiáveis que futuramente devem ser capazes de ser utilizados na prática clínica. Por exemplo, o passo de reconstrução, a dimensão do espaço de fase reconstruído e a vizinhança utilizada para o cálculo da dimensão de correlação são parâmetros que precisam ser escolhidos de forma mais objetiva e sistemática. Então podemos dizer que, de certa forma, as análises não lineares e clássicas são complementares, uma vez que do ponto de vista de diagnóstico, as técnicas clássicas já possuem métodos criteriosos para determinar a presença de patologia.

Esse trabalho também pode ser visto como um estudo pioneiro no tocante à investigação e definição mais precisa das limitações dos métodos não lineares, permitindo dessa forma a implementação de algoritmos baseados nesses métodos para a aplicação clínica. Futuramente, pretende-se aperfeiçoar o programa apresentado nesta dissertação, fazendo com a entropia aproximada (ApEn) seja utilizada para se obter um segmento do

ECG considerado normal para a reconstrução do atrator de referência. Também pretende-se fazer um estudo mais detalhado sobre a sensibilidade das distâncias estatísticas na discriminação de atratores.

Tipo de análise	Descrição	Vantagens	Limitações	Exemplo de Aplicação
Clássica				
Análise no domínio do tempo	Cálculo estatístico sobre os intervalos RR	Fácil de calcular; uso aprovado clinicamente; distinção entre variações alta e baixa	Média e desvio padrão possuem baixo poder de distinguir sinais; requer estacionaridade e periodicidade; perda de informação sobre o sinal de ECG	Diagnóstico por VFC
Análise no domínio da frequência	Representação dos dados através do espectro de potência	Fácil de calcular; uso aprovado clinicamente; distinção entre variações alta e baixa	Requer estacionaridade e periodicidade; perda de informação sobre o sinal de ECG	Diagnóstico por VFC
Não Linear				
DFA	Identifica as variações intrínsecas do sistema	Não requer estacionaridade	Requer um grande conjunto de dados (aproximadamente 24 h de sinal de ECG)	Diagnóstico por α (índice de auto-similaridade)
ApEn	Mede o grau de desordem do sinal	Requer poucos pontos ($n \geq 50$)	Necessita de técnicas complementares, pois a não estacionaridade e o ruído podem influenciar o cálculo da ApEn	Alterações da ApEn estão relacionadas a mudanças fisiológicas
Filtro não linear	Separa um sinal nas componentes principais	Distinção de sinais em um espectro contínuo	Depende da escolha adequada dos parâmetros m, s, Q , e depende da vizinhança U_n	Extração de ECG fetal
Distâncias Estatísticas	Quantifica a diferença morfológica entre dois atratores	Algoritmo de fácil implementação; utiliza o sinal inteiro do ECG; requer poucos pontos (15 min de sinal de ECG)	Depende da escolha adequada dos parâmetros m, s, r	Detecção de mudanças morfológicas no ECG
Dimensão de Correlação	Calcula a dimensão fractal de um atrator	Algoritmo de fácil implementação	Depende da escolha adequada dos parâmetros m, s, ϵ	Diagnóstico para CHD e potencial para localização de isquemias

Tabela 7.1: Comparação entre os métodos clássicos e não lineares apresentadas de análise de ECG.

APÊNDICE A – OBSERVÁVEIS LINEARES

Uma revisão sobre os conceitos dos processos estatísticos lineares, espectro de potência e funções de correlação são vistos aqui. O sistema mais simples que gera uma saída não periódica é um processo estocástico linear com uma entrada irregular. A medida x_n de um estado n no tempo pode ser caracterizada por uma distribuição de probabilidade subjacente $p(x_n)$ por observação de uma seqüência de valores. Um processo estocástico é chamado de estacionário se as distribuições são constantes no tempo: $p(x_n) = p(x)$.

Desde que não conhecemos a princípio qual a distribuição de probabilidades é gerada pelos dados, podemos inferir informações sobre a série temporal. A média, que fornece a melhor estimativa para uma dada medida, e a variância, que reflete o quadrado das flutuações, podem ser estimadas da distribuição respectivamente por:

$$\langle x \rangle_n = \frac{1}{N} \sum_{n=1}^N x_n, \quad (\text{a.1})$$

$$\sigma^2 = \frac{1}{N-1} \left(\sum_{n=1}^N x_n^2 - N \langle x \rangle^2 \right). \quad (\text{a.2})$$

O desvio padrão é definido como a raiz da variância. As duas quantidades acima não fornecem informações sobre a evolução temporal do sistema, mas tal informação pode ser obtida pela autocorrelação de um sinal. A autocorrelação de um tempo de atraso τ é dado por

$$c_v = \frac{1}{\sigma^2} \langle (x_n - \langle x \rangle)(x_{n-v} - \langle x \rangle) \rangle = \frac{\langle x_n x_{n-v} \rangle - \langle x \rangle^2}{\sigma^2}, \quad (\text{a.3})$$

quando representamos $x_n \times x_{n-v}$, a autocorrelação quantifica como os pontos estão distribuídos. Se eles estiverem espalhados sobre o plano, então $c_v = 0$. Se eles tenderem ao longo da diagonal $x_n = x_{n-v}$, então $c_v > 0$, e se eles estiverem fechados na linha $x_n = -x_{n-v}$, então $c_v < 0$. Os dois últimos casos refletem a tendência de x_n e x_{n-v} serem proporcionais um ao outro, o qual faz a função de autocorrelação refletir correlações plausíveis.

A seguir, é visto um caso particular de distribuição, a Gaussiana:

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\langle x \rangle)^2 / 2\sigma^2}. \quad (\text{a.4})$$

A união de distribuições de medidas múltiplas é também Gaussiana. Como consequência, seus segundos momentos são dados por autocorrelações. Desde que a distribuição Gaussiana multivariada é completamente especificada pelo primeiro e segundo momentos, tal processo randômico gaussiano é completamente descrito

estatisticamente pela média, variância e função de autocorrelação. E também conhecido como processo randômico gaussiano.

Aqui podemos fazer uma observação, se um sinal é periódico no tempo, então a função de correlação é também periódica no intervalo ν . A autocorrelação em processos estocásticos decai a uma taxa que depende do processo. E autocorrelações de sinais de sistemas determinísticos caóticos decaem exponencialmente com o aumento de ν . Ou seja, autocorrelações não são uma característica suficiente para distinção entre sinais caóticos determinísticos e randômicos.

Ao invés de descrever as propriedades estatísticas de um sinal no espaço real, podemos estudá-las no espaço de Fourier. A transformação de Fourier estabelece uma correspondência unívoca entre o sinal em certos tempos (domínio do tempo) e como certas frequências contribuem para o sinal (domínio da frequência).

A transformada de Fourier de uma série temporal discreta é dada por

$$\tilde{x}_k = \frac{1}{\sqrt{N}} \sum_{n=1}^N x_n e^{2\pi i k n / N} \quad (\text{a.5})$$

As frequências em unidades físicas são $f_k = k / N\Delta t$, onde $k = -N/2, \dots, N/2$ e Δt é o intervalo de amostragem. A normalização é tal que a transformação inversa somente quantifica uma troca de sinal na exponencial e uma mudança de k e n .

O periodograma, muito utilizado para analisar séries temporais, é baseado na transformada de Fourier da série $\{x_n\}$, através de $P_k = |\tilde{x}_k|^2$. De acordo com o teorema de Wiener-Khinchin, o espectro de potência de um processo é igual a transformada de Fourier da função de autocorrelação. O espectro de potência total é uma quantidade que

aumenta linearmente com o comprimento da série temporal, podendo ser obtido tanto no domínio da frequência como no domínio do tempo, e é dado por $P = \sum_{n=1}^N |\tilde{x}_k|^2 = \sum_{k=-N/2}^{N/2} |\tilde{x}_k|^2$ (teorema de Parseval). Um método alternativo para a estimativa do espectro de potência é a utilização de modelos autoregressivos (AR). Estes modelos assumem que o sinal é um processo randômico estacionário com valor médio igual a zero e que a entrada é uma seqüência de ruído branco com valor médio zero e variância σ^2 . O modelo da equação pode ser escrito como

$$x_n = \sum_{i=1}^p a_i x(n-i) + e_n, \quad (\text{a.6})$$

onde p é a ordem do modelo e a_i é o parâmetro do modelo. A ordem de p do modelo pode ser determinada por vários métodos (não descrito aqui). O espectro de potência então é dado por

$$P(f) = \frac{\Delta t \sigma^2}{\left| 1 - \sum_{i=1}^p a_i \exp(-2\pi i f \Delta t) \right|^2}, \quad (\text{a.7})$$

onde $P(f)$ é a estimativa do espectro de potência, f é a frequência, e Δt é o intervalo de amostragem.

Picos finos no espectro de potência indicam comportamento oscilatório e são bons indicadores em sinais lineares e não lineares. Contribuições de bandas largas, porém, tem uma interpretação menos clara desde que eles podem ser devido à irregularidade estocástica ou determinística. Portanto, o espectro de potência é somente limitado no uso para estudo de sinais com possibilidade de estruturas determinísticas.

APÊNDICE B – PHYSIONET

Physionet (www.physionet.org) é uma base de dados para o estudo de sinais fisiológicos, fundada em 1999, e formada por pesquisadores do Boston's Beth Israel Deaconess Medical Center/Harvard Medical School, Boston University, e MIT, sob a coordenação do National Center for Research Resources of National Institutes of Health (EUA).

O sítio da Physionet foi projetado para disponibilizar uma grande coleção de sinais fisiológicos complexos, sob a forma de arquivos digitais, e diversos programas de código aberto para a visualização e processamento destes sinais. O sítio também contém um fórum multidisciplinar para facilitar a disseminação de descobertas de informações de sistemas complexos. Além de prover o acesso eletrônico livre e aberto aos dados (sinais) e aos programas (toolkits), a Physionet também oferece um serviço de tutoriais on-line para ajudar e estimular os usuários no uso cada vez mais avançado de seus recursos. Trata-se, portanto, de um serviço público mundial (acessível pela World Wide Web) que pretende estimular novas pesquisas e investigações no estudo de sinais fisiológicos complexos.

O público alvo da Physionet são cientistas, matemáticos, engenheiros, clínicos e estudantes que trabalham com ciências biomédicas e tecnologias relacionadas, ou seja, a Physionet pretende agir com investigadores de diferentes disciplinas.

A base de dados da Physionet possui alguns sítios espelhos, que são sítios idênticos ao localizado no sítio www.physionet.org, um deles é mantido pelo Instituto do Coração (InCor) do Hospital das Clínicas da Faculdade de Medicina na Universidade de São Paulo (<http://physionet.incor.usp.br/>). Estes sítios espelhos fornecem um acesso melhor, especialmente onde a conexão para o Estados Unidos pode ser lenta.

Na presente dissertação, foram utilizados alguns sinais de ECG disponíveis no PhysioBank, o banco de dados fisiológicos complexos da Physionet. A seguir é realizada uma descrição dos sinais aqui utilizados:

- MIT-BIH Normal Sinus Rhythm Database. Esta base de dados possui 18 sinais de ECG de duas derivações, cada sinal com segmentos de 20 a 24 horas, para pessoas sem diagnóstico de anormalidades cardíacas.
- MIT-BIH Supraventricular Arrhythmia Database. Esta base de dados possui 78 sinais de ECG de duas derivações, cada sinal com segmento de 30 minutos.

Mais detalhes sobre a base de dados Physionet podem ser fornecidos por Moody et al. [2001] e no próprio sítio da Physionet.

APÊNDICE C – CÓDIGO FONTE DO PROGRAMA

O programa apresentado no capítulo 6 foi desenvolvido no Matlab R14 versão 7.5, e requer as seguintes bibliotecas: *toolbox splines* e *toobox images*. O código fonte é apresentado a seguir:

Arquivo DpgECG.m

```
clc;
clear all;
global Ref_recfull
global Ref_atrator
global Ref_mapa
global Ref_vetorContagens
global Ref_nPtos
global Ref_nBits
global Ref_delay
global Ref_CON
global Ref_A
global Ref_S
global Ref_xi
global Ref_yi
global Ref_matrizClasses
global Ref_nPtosEfetivos
global Dpg_graph
global OriginQuadtree
global Ref_atratorIntRef
```

QuadTreeInterface

Arquivo QuadTreeInterface.m

```
function varargout = QuadTreeInterface(varargin)

if nargin == 0 % Inicia ainterface gráfica

    fig = openfig(mfilename, 'reuse');
```

```

% Utiliza o sistema de cores do sistema operacional
set(fig, 'Color', get(0, 'defaultUicontrolBackgroundColor'));

% Generate a structure de chamadas de subfunções
handles = guihandles(fig);
guidata(fig, handles);

% Carrega a lista de arquivos do diretório
global arquivos
arquivos = dir ('.\Sinais\*.dat');
arquivos = {arquivos.name};
set(handles.popupmenuRecordName, 'String', arquivos);

% Configuração de parâmetros via interface
set(handles.radiobuttonMapa3D, 'Value', 1);
set(handles.radiobuttonAttractorNormal, 'Value', 1);
set(handles.radiobuttonQuadTreeGrid, 'Value', 1);
global xi
global yi
xi = [0 1 1];
yi = [0 1];

if nargin > 0
    varargout{1} = fig;
end

elseif ischar(varargin{1}) % Chama uma subfunção
    try
        [varargout{1:nargout}] = feval(varargin{:});
    catch
        disp(lasterr);
    end
end

% -----
function varargout = pushbuttonLoadSignal_Callback(h, eventdata, handles,
varargin)
set(handles.textStatus, 'String', 'Status: Lendo o Sinal...');
global recfull
global atratorFull
global arquivos

% Verifica o numero do arquivo escolhido
filename = ['./Sinais/', arquivos(get(handles.popupmenuRecordName, 'Value'))];

% Retira o ".dat" do arquivo
filename = filename(1:length(filename)-4);

% recfull recebe o sequencia temporal
recfull = fun_LeSinal(filename, ...
    str2num(get(handles.editSignalNum, 'String')));

% Normalização do sinal
recfull = recfull - min(min(recfull));
recfull = recfull ./ max(max(recfull));

% Filtro para excluir a frequência de 60Hz
aux = recfull(3:length(recfull), :) - 2*cos(2*pi*60/125) .* recfull(2:length(recfull)-
1, :) + recfull(1:length(recfull)-2, :);
clear recfull;
recfull = aux;

% Configura o grafico de recfull (ECG)
set(handles.axesSignal, 'HandleVisibility', 'on');
set(gcf, 'CurrentAxes', handles.axesSignal);

```

```

plot(recfull);
set(handles.axesSignal,...
    'XLim', [0 length(recfull)],...
    'YLim', [min(recfull) max(recfull)]);
set(handles.axesSignal,'HandleVisibility','off');

editStartPoint_Callback(h, eventdata, handles, varargin)

% -----
function varargout = popupmenuRecordName_Callback(h, eventdata, handles,
varargin)
pushbuttonLoadSignal_Callback(h, eventdata, handles, varargin);
% -----
function varargout = editResolution_Callback(h, eventdata, handles, varargin)
global atratorRef
global atratorIntRef
global nPtosEfetivos
global xi
global yi

nBits = str2num(get(handles.editResolution,'String'));

atrator_ylim = [yi(1) yi(2)];
atrator_xlim = [xi(1) xi(2)];
atratorRef_backup = atratorRef;

if xi(3)==1
    indices = find(atratorRef(:,1)>=atrator_xlim(1) & ...
        atratorRef(:,1)<=atrator_xlim(2) & ...
        atratorRef(:,2)>=atrator_ylim(1) & ...
        atratorRef(:,2)<=atrator_ylim(2));
    atratorRef = atratorRef(indices,:);
    atratorRef(:,1) = atratorRef(:,1)-atrator_xlim(1);
    atratorRef(:,1) = atratorRef(:,1)./(atrator_xlim(2)-atrator_xlim(1));
    atratorRef(:,2) = atratorRef(:,2)-atrator_ylim(1);
    atratorRef(:,2) = atratorRef(:,2)./(atrator_ylim(2)-atrator_ylim(1));
else
    indices = find(atratorRef(:,1)<=atrator_xlim(1) | ...
        atratorRef(:,1)>=atrator_xlim(2) | ...
        atratorRef(:,2)<=atrator_ylim(1) | ...
        atratorRef(:,2)>=atrator_ylim(2));
    atratorRef = atratorRef(indices,:);
end

pushbuttonAttractor_Callback(h, eventdata, handles, varargin)
nPtosEfetivos = length(atratorRef);

atratorIntRef = [ ...
    fix(atratorRef(:, 1) ...
        ./1.001.*(2^nBits-1))+1 ...
    fix(atratorRef(:, 2) ...
        ./1.001.*(2^nBits-1))+1];

atratorRef = atratorRef_backup;
pushbuttonAttractor_Callback(h, eventdata, handles, varargin);
pushbuttonQuadTree_Callback(h, eventdata, handles, varargin)

% -----
function varargout = editThreshold_Callback(h, eventdata, handles, varargin)
pushbuttonQuadTree_Callback(h, eventdata, handles, varargin)

% -----
function varargout = editStartPoint_Callback(h, eventdata, handles, varargin)
set(handles.textStatus,'String','Status: Gerando Atrator...');
global recfull

```

```

global atratorRef
global delay
global nPontosRef

% Configura os parâmetros via interface
nPontosRef = str2num(get(handles.editNumOfPoints, 'String'));
delay      = str2num(get(handles.editDelay, 'String'));
inicioRef  = str2num(get(handles.editStartPoint, 'String'));

ylim = get(handles.axesSignal, 'YLim');

% Configura o gráfico do atrator de referência
set(handles.axesSignal, 'HandleVisibility', 'on');
set(gcf, 'CurrentAxes', handles.axesSignal);
hold on
set(handles.editStartPoint, 'String', fix(inicioRef))
line_handle = findobj('LineStyle', ':');
delete(line_handle)
set(gcf, 'CurrentAxes', handles.axesSignal);
line([inicioRef inicioRef], ylim, 'LineStyle', ':', 'LineWidth', 2, 'Color', [0 1 0]);
hold off
set(handles.axesSignal, 'HandleVisibility', 'off');

% o atrator de referência é criado
atratorRef = [recfull(inicioRef      : inicioRef+nPontosRef-1) ...
              recfull(inicioRef+delay : inicioRef+nPontosRef-1+delay)];

pushbuttonAtrator_Callback(h, eventdata, handles, varargin)
editResolution_Callback(h, eventdata, handles, varargin)

% -----
function varargout = editNumOfPoints_Callback(h, eventdata, handles, varargin)
editStartPoint_Callback(h, eventdata, handles, varargin)

% -----
function varargout = editDelay_Callback(h, eventdata, handles, varargin)
editStartPoint_Callback(h, eventdata, handles, varargin)

% -----
function varargout = pushbuttonAtrator_Callback(h, eventdata, handles,
varargin)
global recfull
global atratorRef
global atratorIntRef

% Configura os parâmetros resolução e tipo de atrator (normal ou discreto) via
interface gráfica
nBits = str2num(get(handles.editResolution, 'String'));
KeyAtratorNormal = get(handles.radiobuttonAtratorNormal, 'Value');
set(handles.axesAtrator, 'HandleVisibility', 'on');
set(gcf, 'CurrentAxes', handles.axesAtrator);
% Se for normal
if KeyAtratorNormal==1
    plot(atratorRef(:,1), atratorRef(:,2), '.', 'MarkerSize', 4, 'Color', [0 0 0]);
    set(handles.axesAtrator, ...
        'XLim', [0 1], ...
        'YLim', [0 1]);
    % Se for discreto (transformação para um distribuição estatística)
else
    plot(atratorIntRef(:,1), atratorIntRef(:,2), '.', 'MarkerSize', 4, 'Color', [0 0
0]);
    set(handles.axesAtrator, ...
        'XLim', [1 (2^nBits-1)+2], ...
        'YLim', [1 (2^nBits-1)+2]);
end
end

```



```

set(handles.axesAttractor,'HandleVisibility','off');

% -----
function varargout = pushbuttonUseCrosshair_Callback(h, eventdata, handles,
varargin)
ylim = get(handles.axesSignal,'YLim');
set(handles.axesSignal,'HandleVisibility','on');
set(gcf,'CurrentAxes',handles.axesSignal);
[xi,yi,but] = ginput(1);
set(handles.editStartPoint,'String',fix(xi))
set(handles.axesSignal,'HandleVisibility','off');
editStartPoint_Callback(h, eventdata, handles, varargin)

% -----
function varargout = radiobuttonMapa2D_Callback(h, eventdata, handles, varargin)
if get(handles.radiobuttonMapa2D,'Value')==1
    set(handles.radiobuttonMapa3D,'Value',0)
else
    set(handles.radiobuttonMapa3D,'Value',1)
end
pushbuttonQuadTree_Callback(h, eventdata, handles, varargin)

% -----
function varargout = radiobuttonMapa3D_Callback(h, eventdata, handles, varargin)
if get(handles.radiobuttonMapa3D,'Value')==1
    set(handles.radiobuttonMapa2D,'Value',0)
else
    set(handles.radiobuttonMapa2D,'Value',1)
end
pushbuttonQuadTree_Callback(h, eventdata, handles, varargin)

% -----
function varargout = radiobuttonAttractorNormal_Callback(h, eventdata, handles,
varargin)
if get(handles.radiobuttonAttractorNormal,'Value')==1
    set(handles.radiobuttonAttractorDiscrete,'Value',0)
else
    set(handles.radiobuttonAttractorDiscrete,'Value',1)
end
pushbuttonAttractor_Callback(h, eventdata, handles, varargin)

% -----
function varargout = radiobuttonAttractorDiscrete_Callback(h, eventdata,
handles, varargin)
if get(handles.radiobuttonAttractorDiscrete,'Value')==1
    set(handles.radiobuttonAttractorNormal,'Value',0)
else
    set(handles.radiobuttonAttractorNormal,'Value',1)
end
pushbuttonAttractor_Callback(h, eventdata, handles, varargin)

% -----
function varargout = pushbuttonQuadTree_Callback(h, eventdata, handles,
varargin)
set(handles.textStatus,'String','Status: Calculando o QuadTree...');

global recfull
global atratorRef
global atratorIntRef
global mapaRef
global matrizContagensRef
global vetorContagensRef
global nBits
global CON

```

```

global A
global S
global Key3D

nBits      = str2num(get(handles.editResolution, 'String'));
threshold  = str2num(get(handles.editThreshold, 'String'));

mapaRef = zeros(2^nBits, 2^nBits);

Key3D = get(handles.radiobuttonMapa3D, 'Value');
GridMethod = get(handles.radiobuttonQuadTreeGrid, 'Value');

vetorContagensRef = transpose(zeros*[1:4^nBits]);
for i=1:length(atratorIntRef)
    mapaRef(atratorIntRef(i,1), atratorIntRef(i,2)) = ...
        Key3D*mapaRef(atratorIntRef(i,1), atratorIntRef(i,2))+1;
    vetorContagensRef((atratorIntRef(i,2)-1)*2^nBits+atratorIntRef(i,1)) = ...
        mapaRef(atratorIntRef(i,1), atratorIntRef(i,2)); % alteracao
end

threshold = ceil(mean(mean(nonzeros(mapaRef))));
set(handles.editThreshold, 'String', threshold);
S = zeros(2^nBits, 2^nBits)+1;
set(handles.axesQuadTree, 'HandleVisibility', 'on');
set(gcf, 'CurrentAxes', handles.axesQuadTree);

if GridMethod==1
    f = @fun_QuadtreeSplit;
    S = qtdecomp(mapaRef, f, threshold);
    [CON A] = fun_GeraGraficoQuadtree(S);
    vetorContagensRef = fun_GeraVetorContagens(S, mapaRef);
    gplot(CON, A, 'k');
else
    plot(atratorIntRef(:,1), atratorIntRef(:,2), '.', 'MarkerSize', 4, 'Color', [0 0
0]);
    set(handles.axesQuadTree, 'GridLineStyle', '-');
    set(handles.axesQuadTree, 'XTick', transpose([1:length(vetorContagensRef)]));
    set(handles.axesQuadTree, 'YTick', transpose([1:length(vetorContagensRef)]));
    set(handles.axesQuadTree, 'XTickLabel', '');
    set(handles.axesQuadTree, 'YTickLabel', '');
    grid(handles.axesQuadTree);
end

set(handles.axesQuadTree, ...
    'XLim', [1 (2^nBits-1)+2], ...
    'YLim', [1 (2^nBits-1)+2]);
set(handles.axesQuadTree, 'HandleVisibility', 'off');

set(handles.textTotalOfBoxes, 'String', [num2str(length(vetorContagensRef)) ('
...
num2str(length(vetorContagensRef)-length(nonzeros(vetorContagensRef))) ...
' empty')]);
set(handles.textNonZeroBoxes, 'String', length(nonzeros(vetorContagensRef)));
set(handles.textSum, 'String', sum(vetorContagensRef));
set(handles.textMean, 'String', mean(nonzeros(vetorContagensRef)));
set(handles.textMax, 'String', max(vetorContagensRef));
set(handles.textMin, 'String', min(nonzeros(vetorContagensRef)));
set(handles.textStd, 'String', std(nonzeros(vetorContagensRef)));

set(handles.axesCountingDistribution, 'HandleVisibility', 'on');
set(gcf, 'CurrentAxes', handles.axesCountingDistribution);
Cor = [0 0 1];
if max(vetorContagensRef)>threshold
    Cor = [1 0 0];

```

```

end
plot(vetorContagensRef, 'Color', Cor);
set(handles.axesCountingDistribution, ...
    'XLim', [1 length(vetorContagensRef)], ...
    'YLim', [0 max(vetorContagensRef)+std(nonzeros(vetorContagensRef))]);
set(handles.axesCountingDistribution, 'HandleVisibility', 'off');

set(handles.textStatus, 'String', '');

set(handles.pushbuttonGenerateMatrix, 'Visible', 'on');

% -----
function varargout = pushbuttonGenerateMatrix_Callback(h, eventdata, handles,
varargin)

global recfull
global atratorRef
global atratorIntRef
global mapaRef
global matrizContagensRef
global vetorContagensRef
global nBits
global CON
global A
global S
global Key3D
global delay
global nPontosRef
global Ref_xi
global Ref_yi
global Ref_matrizClasses
global Ref_nPtosEfetivos
global OriginQuadtree

global Ref_recfull
global Ref_atrator
global Ref_mapa
global Ref_vetorContagens
global Ref_nPtos
global Ref_nBits
global Ref_delay
global Ref_CON
global Ref_A
global Ref_S
global Ref_Key3D
global Ref_vetorLocalizacao
global xi
global yi
global nPtosEfetivos

set(handles.textStatus, 'String', 'Gerando Matriz de Classes...');
GridMethod = get(handles.radiobuttonQuadTreeGrid, 'Value');
if GridMethod==1
    matrizClassesRef = fun_GeraMatrizClasses(S, mapaRef);
else
    [xx yy] = find(sparse(ones(2^nBits, 2^nBits)));
    matrizClassesRef = full(sparse(xx, yy, [1:4^nBits]));
end

set(handles.textStatus, 'String', 'Mapeando Pontos do Atrator...');

Ref_recfull = recfull;
Ref_atrator = atratorRef;
Ref_mapa = mapaRef;
Ref_matrizContagens = matrizContagensRef;

```

```

Ref_vetorContagens =vetorContagensRef;%./nPtosEfetivos;
Ref_nPtos =sum(vetorContagensRef);% PontosRef;
Ref_nBits =nBits;
Ref_delay =delay;
Ref_CON =CON;
Ref_A =A;
Ref_S =S;
Ref_Key3D =Key3D;
Ref_xi = xi;
Ref_yi = yi;
Ref_matrizClasses = matrizClassesRef;
Ref_nPtosEfetivos = nPtosEfetivos;
OriginQuadtree = fun_Quadtree2Origin(CON,A);

save quadtree.dat OriginQuadtree -ASCII

set(handles.textStatus,'String','');
set(handles.pushbuttonGenerateMatrix,'Visible','off');
% -----
function varargout = pushbuttonSelectIn_Callback(h, eventdata, handles,
varargin)
global xi
global yi
set(handles.axesAttractor,'HandleVisibility','on');
set(gcf,'CurrentAxes',handles.axesAttractor);
hold on
but = 1;
[xi,yi,but] = ginput(2);
yi(2)=yi(1)+(xi(2)-xi(1));
A = [0 1 0 1; 1 0 1 0; 0 1 0 1; 1 0 1 0];
if but == 1
    line_handle = findobj('LineStyle',':');
    delete(line_handle)
    gplot(A,[xi(1) yi(1);xi(1) yi(2); xi(2) yi(2);xi(2) yi(1)],':m')
end

hold off
xi(3) = 1; %Select In
set(handles.axesAttractor,'XLim',[xi(1) xi(2)]);
set(handles.axesAttractor,'YLim',[yi(1) yi(2)]);
set(handles.axesAttractor,'HandleVisibility','off');
editResolution_Callback(h, eventdata, handles, varargin)

% -----
function varargout = pushbuttonSelectOut_Callback(h, eventdata, handles,
varargin)
global xi
global yi
set(handles.axesAttractor,'HandleVisibility','on');
set(gcf,'CurrentAxes',handles.axesAttractor);
hold on
but = 1;
[xi,yi,but] = ginput(2);
yi(2)=yi(1)+(xi(2)-xi(1));
hold off
xi(3) = -1; %Select In
set(handles.axesAttractor,'XLim',[0 1]);
set(handles.axesAttractor,'YLim',[0 1]);
set(handles.axesAttractor,'HandleVisibility','off');
editResolution_Callback(h, eventdata, handles, varargin)

% -----
function varargout = pushbuttonZoomReset_Callback(h, eventdata, handles,
varargout)
global xi

```

```

global yi
xi = [0 1 1];
yi = [0 1];
editResolution_Callback(h, eventdata, handles, varargin)

% -----
function varargout = radiobuttonRegularGrid_Callback(h, eventdata, handles,
varargin)
if get(handles.radiobuttonRegularGrid,'Value')==1
    set(handles.radiobuttonQuadTreeGrid,'Value',0)
else
    set(handles.radiobuttonQuadTreeGrid,'Value',1)
end
pushbuttonQuadTree_Callback(h, eventdata, handles, varargin)

% -----
function varargout = radiobuttonQuadTreeGrid_Callback(h, eventdata, handles,
varargin)
if get(handles.radiobuttonQuadTreeGrid,'Value')==1
    set(handles.radiobuttonRegularGrid,'Value',0)
else
    set(handles.radiobuttonRegularGrid,'Value',1)
end
pushbuttonQuadTree_Callback(h, eventdata, handles, varargin)

% -----
function varargout = pushbuttonRefreshList_Callback(h, eventdata, handles,
varargin)
global arquivos
arquivos = dir ('.\Sinais\*.dat');
arquivos = {arquivos.name};
set(handles.popupmenuRecordName,'String',arquivos);

```

Arquivo fun_LeSinal.m

```

function recfull = fun_LeSinal(recname,recsig);
try
    heasig = readheader([recname '.hea']);
catch
    msgbox('Arquivo inexistente!','Erro','error');
    recfull = [];
    return
end
t = [1 heasig.nsamp];
% reading ECG signal file with format 212
if heasig.fmt(1)==212
    recfull=rdsign212([recname '.dat'],heasig.nsig,t(1),t(2));
else
    msgbox('Erro ao ler o arquivo de sinal!');
end
recfull = recfull(:,recsig);

```

Arquivo fun_GeraGraficoQuadtree.m

```

function [CON,A] = fun_GeraGraficoQuadtree(S)
[linhas colunas val] = find(S);% val e o numero de pontod de cada caixa

horizontais = colunas+val;
verticais = linhas+val;

tamanho = length(linhas);

x_classes = [transpose(1:tamanho)

```

```

transpose(1:tamanho)
];
y_classes = [
transpose(tamanho+1:tamanho*2)
transpose(tamanho*2+1:tamanho*3)
];
CON = sparse(x_classes,y_classes,1);
A = [linhas colunas
linhas horizontais
verticais colunas
length(S)+1 1
length(S)+1 length(S)+1
1 length(S)+1];

```

Arquivo fun_GeraVetorContagens.m

```

function vetorContagens= fun_GeraVetorContagens(S,Mapa)
maxDim = max(max(nonzeros(S)));
minDim = min(min(nonzeros(S)));
dim = maxDim;
vetorContagens = [];
while (dim >= minDim)
% [blockvalues, x_upper, t_upper] = qtgeblk (Mapa, S, dim) retorna
% um vetor contendo blocos de dimensão dimxdim na decomposição quadtree
% de Mapa. S e uma matriz esparsa retornada por qtdecomp, contém a
% estrutura quadtree. blockvalues e um array de dimensão dimxdimxk,
% onde k e o numero de blocos de dimensao dimxdim na decomposicao
% quadtree; se não há nenhum bloco do tamanho especificado, todas
% as saídas são retornadas com matrizes vazias. x_upper são vetores
% contendo as coordenadas das linhas e das colunas do canto
% esquerdo (parte superior)dos blocos
[blockValues, x_upper, y_upper] = qtgetblk(Mapa, S, dim);
blockSum = [];
for i=1:length(x_upper)
blockSum = [blockSum
sum(sum(blockValues(:,:,i)))]];
end
vetorContagens = [vetorContagens
blockSum];
dim = dim/2;
end

```

Arquivo fun_GeraMatrizClasses.m

```

function matrizClasses = fun_GeraMatrizClasses(S,Mapa)
maxDim = max(max(nonzeros(S)));
minDim = min(min(nonzeros(S)));
dim = maxDim;
matrizClasses=Mapa;
classe = 1;
while (dim >= minDim)
[blockValues, x_upper, y_upper] = qtgetblk(Mapa, S, dim);
if not(isempty(blockValues))
newvals=[];
for i=1:length(x_upper)
newvals(:,:,i) = zeros(dim,dim)+classe;
classe = classe + 1;
end
matrizClasses = qtsetblk(matrizClasses,S,dim,newvals);
end

```

```

    dim = dim/2;
end

```

Arquivo fun_GeraMatrizClasses.m

```

function [OriginQuadtree] = fun_Quadtree2Origin(CON,A)
[i j] = find(CON);
OriginQuadtree = zeros(2*length(i),2);
l = 1;
for k=1:length(i)
    OriginQuadtree(l ,:) = A(i(k),:);
    OriginQuadtree(l+1,:) = A(j(k),:);
    l = l+2;
end

```

Arquivo DpgInterface.m

```

function varargout = DpgInterface(varargin)
if nargin == 0 % Inicia a interface gráfica
    fig = openfig(mfilename,'reuse');
    % Utiliza o sistema de cores do sistema operacional
    set(fig,'Color',get(0,'defaultUicontrolBackgroundColor'));
    % Gera uma estrutura de chamadas de subfunções
    handles = guihandles(fig);
    guidata(fig, handles);

    set(handles.popupmenuDistance,'Value',1);

    if nargin > 0
        varargout{1} = fig;
    end
elseif ischar(varargin{1}) % Chama uma subfunção
    try
        [varargout{1:nargout}] = feval(varargin{:});
    catch
        disp(lasterr);
    end
end
% -----
function varargout = popupmenuDistance_Callback(h, eventdata, handles, varargin)
% -----

function varargout = pushbuttonCalculate_Callback(h, eventdata, handles,
varargin)

tic
global Ref_recfull
global Ref_atrator
global Ref_mapa
global Ref_vetorContagens
global Ref_nPtos
global Ref_nBits
global Ref_delay
global Ref_CON
global Ref_A
global Ref_S
global Ref_Key3D
global Ref_xi
global Ref_yi
global Ref_matrizClasses

global desloc
global nPontos

```

```

global limite
global Dpg_graph

inicio = 1;
nPontos = str2num(get(handles.editWindow, 'String'));
desloc = str2num(get(handles.editShift, 'String'));

Dpg_graph = zeros(fix((length(Ref_recfull)-nPontos)./desloc)-1,2);
total = fix((length(Ref_recfull)-nPontos)./desloc);

limite = total*desloc+nPontos-fix(nPontos./2);

set(gcf, 'CurrentAxes', handles.axesRecfull);
plot(Ref_recfull, 'Color', [0.1 0.1 1]);
set(handles.axesRecfull, ...
    'XLim', [desloc+nPontos-fix(nPontos./2) limite], ...
    'YLim', {min(Ref_recfull) max(Ref_recfull)});
set(handles.axesRecfull, 'YTick', [0.5 1]);
h=waitbar(0, 'Gerando Gráfico Dpg');
for j = 1:total
    atrator= [Ref_recfull((j-1)*desloc+1:(j-1)*desloc+nPontos) ...
        Ref_recfull((j-1)*desloc+1+Ref_delay:(j-1)*desloc+nPontos+Ref_delay)];

    atrator = CutAttractor(atrator, Ref_xi, Ref_yi);

    atratorInt = [fix(atrator(:, 1) ...
        ./1.001.*(2^Ref_nBits-1))+1 ...
        fix(atrator(:, 2) ...
        ./1.001.*(2^Ref_nBits-1))+1];

    vetorContagens = Ref_vetorContagens*0;

    for i=1:length(atratorInt)
        coordenada=Ref_matrizClasses(atratorInt(i,1), atratorInt(i,2));
        vetorContagens(coordenada) = vetorContagens(coordenada)+1;
    end
    vetorContagens=100*vetorContagens/sum(vetorContagens);

    switch get(handles.popupmenuDistance, 'Value')
        case 1
            Dpg = fun_Chebychev(Ref_vetorContagens, vetorContagens);
        case 2
            Dpg = fun_Chisquare(Ref_vetorContagens, vetorContagens);
        case 3
            Dpg = fun_Correlation(Ref_vetorContagens, vetorContagens);
        case 4
            Dpg = fun_Euclidean(Ref_vetorContagens, vetorContagens);
        case 5
            Dpg = fun_Manhattan(Ref_vetorContagens, vetorContagens);
    end

    Dpg_graph(j,1)= j*desloc+nPontos-fix(nPontos./2);
    Dpg_graph(j,2)= Dpg;

    waitbar(j/total,h)
end
close(h)

set(handles.textStatus, 'String', '');
GraficoDpg(h, eventdata, handles, varargin)

atrator = Ref_atrator;
atrator = CutAttractor(atrator, Ref_xi, Ref_yi);
set(gcf, 'CurrentAxes', handles.axesAtratorRef);
plot(atrator(:,1), atrator(:,2), '.', 'MarkerSize', 4, 'Color', [0.1 0.1 0.1]);

```

```

set(handles.axesAtratorRef,...
    'XLim', [0 1],...
    'YLim', [0 1]);

if not isempty(get(handles.editSelectedPoint,'String'))
    plota_atrator(h, eventdata, handles, varargin);
end
toc
save dpg.dat Dpg_graph -ASCII;
% -----
function varargout = pushbuttonUseCrosshair_Callback(h, eventdata, handles,
varargin)
ylim = get(handles.axesDpg,'YLim');
set(gcf,'CurrentAxes',handles.axesDpg);
hold on
but = 1;
while but == 1
    [xi,yi,but] = ginput(1);
    if but == 1
        set(handles.editSelectedPoint,'String',fix(xi));
        plota_atrator(h, eventdata, handles, varargin); but=0;%Henrique
    end
end
hold off

% -----
function varargout = GraficoDpg(h, eventdata, handles, varargin)
global desloc
global nPontos
global Ref_nPtos
global limite
global Dpg_graph

set(gcf,'CurrentAxes',handles.axesDpg);
hold on

if not isempty(findobj('Color','b'))
    delete(findobj('Color','b'));
end

fnplt(csaps(Dpg_graph(:,1),Dpg_graph(:,2)), 'b')
delete(findobj('Color','r'));

set(handles.axesDpg,'XLim', [desloc+nPontos-fix(nPontos./2) limite]);
set(handles.axesDpg,'YLim', [min(Dpg_graph(:,2)) max(Dpg_graph(:,2))+0.1]);
hold off

% -----
function varargout = plota_atrator(h, eventdata, handles, varargin)
global nPontos
global Ref_delay
global Ref_recfull
global Dpg_graph
global Ref_nPtos
global Ref_vetorContagens
global Ref_vetorLocalizacao
global Ref_xi
global Ref_yi
global Ref_nBits
global Ref_matrizClasses

xi=str2num(get(handles.editSelectedPoint,'String'));
line_handle = findobj('LineStyle',':');
delete(line_handle)
set(gcf,'CurrentAxes',handles.axesDpg);

```

```

line([xi xi],ylim,'LineStyle',':','LineWidth',2,'Color',[1 0 0]);

inicio = xi-fix(nPontos./2);

atrator = [Ref_recfull(inicio      : inicio+nPontos-1) ...
           Ref_recfull(inicio+Ref_delay : inicio+nPontos-1+Ref_delay)];
atrator = CutAttractor(atrator,Ref_xi,Ref_yi);

set(gcf,'CurrentAxes',handles.axesAtrator);
plot(atrator(:,1),atrator(:,2),'.','MarkerSize',4,'Color',[0.1 0.1 0.1]);
set(handles.axesAtrator,...
      'XLim',[0 1],...
      'YLim',[0 1]);

atratorInt = [fix(atrator(:, 1) ...
                ./1.001.*(2^Ref_nBits-1))+1 ...
              fix(atrator(:, 2) ...
                ./1.001.*(2^Ref_nBits-1))+1];
vetorContagens = Ref_vetorContagens*0;
for i=1:length(atratorInt)
    coordenada=Ref_matrizClasses(atratorInt(i,1), atratorInt(i,2));
    vetorContagens(coordenada) = vetorContagens(coordenada)+1;
end
vetorContagens=100*vetorContagens/sum(vetorContagens);

switch get(handles.popupmenuDistance,'Value')
    case 1
        Dpg = fun_Chebychev(Ref_vetorContagens, vetorContagens);
    case 2
        Dpg = fun_Chisquare(Ref_vetorContagens, vetorContagens);
    case 3
        Dpg = fun_Correlation(Ref_vetorContagens, vetorContagens);
    case 4
        Dpg = fun_Euclidean(Ref_vetorContagens, vetorContagens);
    case 5
        Dpg = fun_Manhattan(Ref_vetorContagens, vetorContagens);
end
set(handles.textDpg,'String',Dpg); % alteracao
save atrator.dat atrator -ascii

% -----
function varargout = editSelectedPoint_Callback(h, eventdata, handles, varargin)
plota_atrator(h, eventdata, handles, varargin);

% -----
function varargout = editWindow_Callback(h, eventdata, handles, varargin)

% -----
function varargout = editShift_Callback(h, eventdata, handles, varargin)

% -----
function atrator = CutAttractor(atrator,Ref_xi,Ref_yi)
if Ref_xi(3)==1
    indices = find(atrator(:,1)>=Ref_xi(1) & ...
                  atrator(:,1)<=Ref_xi(2) & ...
                  atrator(:,2)>=Ref_yi(1) & ...
                  atrator(:,2)<=Ref_yi(2));
    atrator = atrator(indices,:);
    atrator(:,1) = atrator(:,1)-Ref_xi(1);
    atrator(:,1) = atrator(:,1)./(Ref_xi(2)-Ref_xi(1));
    atrator(:,2) = atrator(:,2)-Ref_yi(1);
    atrator(:,2) = atrator(:,2)./(Ref_yi(2)-Ref_yi(1));
else
    indices = find(atrator(:,1)<=Ref_xi(1) | ...
                  atrator(:,1)>=Ref_xi(2) | ...

```

```

        atrator(:,2)<=Ref_yi(1) | ...
        atrator(:,2)>=Ref_yi(2));
    atrator = atrator(indices,:);
end

```

Arquivo fun_Chebychev.m

```

function Dpg = fun_Chebychev(Ref_vetorContagens, vetorContagens)
warning off;

n = abs(Ref_vetorContagens-vetorContagens);

Dpg = max(n);

warning on;

```

Arquivo fun_Chisquare.m

```

function Dpg = fun_Chisquare(Ref_vetorContagens, vetorContagens)
warning off;

pj = sum(vetorContagens);
pi = sum(Ref_vetorContagens);
Ref_vetorContagens = Ref_vetorContagens./ ...
    (pi+pj);
vetorContagens = vetorContagens./ ...
    (pi+pj);
pj = sum(vetorContagens);
pi = sum(Ref_vetorContagens);

piv = Ref_vetorContagens;
pjb = vetorContagens;
pv = Ref_vetorContagens+vetorContagens;

Chi2_vetor = (piv./pi)-(pjb./pj);
Chi2_vetor = Chi2_vetor.^2;
Chi2_vetor = Chi2_vetor./pv;
Chi2 = sum(Chi2_vetor(find(isfinite(Chi2_vetor))));

Dpg = sqrt(Chi2);
warning on;

```

Arquivo fun_Euclidean.m

```

function Dpg = fun_Euclidean(Ref_vetorContagens, vetorContagens)
warning off;

pv = Ref_vetorContagens-vetorContagens;
pv = sum(pv.^2);

Dpg = sqrt(pv);
%Dpg = Dpg;
warning on;

```

Arquivo fun_Manhattan.m

```

function Dpg = fun_Manhattan(Ref_vetorContagens, vetorContagens)
warning off;

pv = abs(Ref_vetorContagens-vetorContagens);
pv = sum(pv);

```

```
Dpg = pv;  
warning on;
```

Arquivo fun_Correlation.m

```
function Dpg = fun_Correlation(Ref_vetorContagens, vetorContagens)  
m = corrcoef(Ref_vetorContagens, vetorContagens);  
Dpg = 1-max(0,m(1,2));
```

BIBLIOGRAFIA

Akselrod S, Gordon D, Ubel FA, Shannon DC, Cohen RJ. Power spectrum analysis of heart rate fluctuation: a quantitative probe of beat-to-beat cardiovascular control. *Science*. 1981; **213** : 220-222.

Babloyantz A, Destexhe A. Is the normal heart a periodic oscillator? *Biol Cybern*. 1998; **58** : 203-211.

Baselli G, Cerutti S, Civardi S, Lombardi F, Malliani A, Merri M, Pagani M, Rizzo G. Heart rate variability signal processing: A quantitative approach as an aid to diagnosis in cardiovascular pathologies. *Int J Bio-Med Comput*. 1987; **20** : 51-70.

Bigger JTJ, Fleiss JL, Steinman RC, Rolnitzky LM, Kleiger RE, Rottman JN. Frequency domain measures of heart period variability and mortality after myocardial infarction. *Circulation*. 1992; **85** : 164-171.

Blasco MCR. *Synchronization Analysis by Means of Recurrences in Phase Space*. Tese de doutorado, Universidade de Postdam, 2004.

Bolis CL, Licinio J. *The Autonomic Nervous System*. World Health Organization, Geneva, 1999.

Bosanac, Gordan; Bogunovic, Nikola: Nonlinear Information Processing in Extracting Predictive Attributes of an ECG Signal, Proc. of The 6th Multiconf. on Systemics,

Cybernetics and Informatics, Vol. II, July 14-18, 2002, Orlando, FL, USA, p. 275-279.

Buldyrev SV, Goldberger ALHS, Mantegna RNMME, Peng C-K, Simons M, Stanley HE. Long-correlation properties of coding and noncoding DNA sequences: GenBank analysis. *Phys Rev E*. 1995; **51** : 5084-5091.

Buzug TR, Pfister G. Optimal reconstruction of atrange attractors from purely geometrical arguments. *Europhys Lett*. 1990; **13** : 605-610.

Casaleggio A, Braiotta S. Estimation of Lyapunov Exponents of ECG Time Series -The Influence of Parameters The Influence of Parameters. *Chaos, Solitons & Fractals*. 1997; **8** : (10)1591-1599.

Crutchfield JP, Farmer JD, Packard NH, Shaw RS. Chaos. *Sci Am*. 1987; **255** : 38-39.

David LD, Billon N, Costagliola D, Jailon P, Funck-Brentan C. Reproducibility of non-invasive measurements and of short-term variability of blood pressure and heart rate in healthy volunteers. *Br J Clin Pharmacol*. 1994; **38** : 109-115.

Diambra L. Statistical distance of q-order. Em: VI Latin American Workshop on Nonlinear Phenomena, 1999, Huerta Grande, Out 12-16. VI Latin American Workshop on Nonlinear Phenomena: Abstracts Book, 1999.

Diambra L. Divergence measure between chaotic attractor. *Physical Review E*. 2001; **64** : (3)1-4.

Eckmann J-P. Roads to turbulence in dissipative dynamical systems. *Rev Mod Phys*. 1981; **53** : 643-654.

Eckmann J-P, Ruelle D. Ergodic theory of chaos and strange attractors. *Rev Mod Phys*. 1985; **57** : 617-619.

Eckmann J-P, Kamphorst SO, Ruelle D, Cilberto S. Lyapunov expoents from a time series. *Phys Rev A*. 1986; **34** : 4971-4979.

Eckmann J-P, Kamphorst SO, Ruelle D. Recurrence plots of dynamical systems. *Europhys Lett*. 1987; **4** : 973-977.

Ewing DJ, Neilson JM, Travis P. New method for assessing cardiac parasympathetic activity using 24 hour eletrocardiograms. *Br Heart J*. 1984; **52** : 396-402.

Farmer JD, Sidorowich JJ. Predicting chaotic time series. *Phys Rev Lett*. 1987; **59** : 845-848.

Farrel TG, Bashir Y, Cripps T, Malik M, Poloniecki J, Bennett E. D.; Ward, Ward DE, Camm AJ. Risk stratification for arrhythmic events in postinfarction patients based on heart variability and ambulatory aletrocardiographic variables and the signal-averaged eletrocardiogram. *J Am Coll Cardiol*. 1991; **18** : 687-697.

Ferrara NF, Prado CPCD. Caos: Uma introdução. Edgar Blücher, São Paulo, 1994.

Figueiredo JCB. *Equações Diferencias Não Lineares com Três Retardos: Estudo Detalhado das Soluções*. Tese de doutorado, Instituto de Física da USP, 2000.

Figueiredo JCB. ; Furuie SS. Statistical distances to detect changes in the normal behavior of ECG-Holter signals. Em: SPIE - Medical Imaging, 2001, San Diego. Medical Imaging 2001: Ultrasonic Imaging and Signal Processing. Bellingham : SPIE PRESS, 2001.

Figueiredo JCB. ; Furuie SS. Statistical Distance of Quadtree Partitioned Attractors: Detecting Changes in The Normal Behavior of ECG Signals. Em: Computers in Cardiology, 2001, Rotterdam. Proceeding of Computers in Cardiology 2001, 2001. p. 521-524.

Fraser AM, Swinney HL. Independent coordinates for strange attractors from mutual information. *Phys Rev A*. 1986; **33** : 1134-1140.

Fojt O, Holcik J. Applying nonlinear dynamics to ECG signal processing. *IEEE EMB Mag*. 1998; **17** : (2)96-101

Fusheng Y, Bo H, Qingyu T. Approximate entropy and its application in biosignal analysis. Em: In: Nonlinear Biomedical Signal Processing Vol. II. New York: IEEE Press, 2001, 72-91-213.

Glass K, Kaplan DT. Complex Dynamics in Physiology and Medicine. *Med Prog*

Technol. 1993; **19** : (3)115-128.

Glass L. Dynamical of cardiac arrhythmias. *Physics Today*. 1996; **49** : 40-45.

Goldberger AL, West BJ. Applications of nonlinear dynamics to clinical cardiology. *Ann New York Acad Sci*. 1987; **504** : 155-212.

Goldberger AL. Nonlinear dynamics and fractals and chaos: applications to cardiac eletrophysiology. *Ann Biomed Eng*. 1990; **18** : 195-198.

Goldberger AL. Non-linear dynamics for clinicians: chaos theory and fractals and complexity at the bedside. *Lancet*. 1996; **347** : 1312-1314.

Goldberger AL, Amaral LAN, Hausdorff JM, Ivanov PC, Peng C-K. Fractal dynamics in physiology: Alterations with disease and aging. *PNAS*. 2002; **99** : 2466-2472.

Grassberger P, Procaccia I. Measuring the strangeness of atrange attractors. *Physica D*. 1983; **9** : 189-208.

Grupi CJ. Variabilidade da Frequência Cardíaca (Parte 1). Diagnósticos em Cardiologia (1a Edição). 1998; Disponível em: <http://cardios.com.br/jornal-02/tese.htm>.

Gukenheimer J, Holmes P. Nonlinear oscillations, dynamical systems and bifurcations of vector fields. Springer-Verlag, New York, Heidelberg e Berlin, 1983.

Ho KK, Moody GB, Peng C-K, Mietus JE, Larson MG, Levy D, Goldberger AL. Predicting survival in heart failure case and control subjects by use of fully automated methods for deriving nonlinear and conventional indices of heart rate dynamics. *Circulation*. 1997; **96** : 842-848.

Hobbie RK. Intermediate physics for medicine and biology. Springer-Verlag, New York, 1997.

Hofmeister JF, Slocumb JC, Kottmann LM, Picchiottino JB, Ellis DG. A noninvasive method for recording the eletrical activity of the human uterus in vivo. *Biomed Instr Technol*. 1994; **9** : 391-394.

Huikuri HV, Seppänen T, Koistinen MJ, Airaksinen KEJ, Ikäheimo MJ, Castellanos A, Myerburg RJ. Abnormalities in beat-to-beat dynamics of heart rate before the spontaneous onset of life-threatening ventricular tachyarrhythmias in patients with prior myocardial infarction. *Circulation*. 1996; **93** : 1836-1844.

Ivanov PC, Amaral ANA, Havlin S, Rosenblum MG, Stanley HE, Struzik ZR. From $1/f$ noise to multifractal cascades in heartbeat dynamics. *Chaos*. 2001; **11** : (3)641-652.

Iyengar N, Peng C-K, Morin R, Goldberger AL, Lipsitz LA. Age-related alterations in the fractal scaling of cardiac interbeat dynamics. *Am J Physiol*. 1996; **271** : R1078-R1084.

Jaymes ET. Maximum Entropy and Bayesian Methods in Science and Engineering. Kluwer Dordrecht: 1988, 24-35.

Kantz H, Schreiber T. Nonlinear time series analysis. Cambridge University Press, Cambridge, 1997.

Kantz H, Schreiber T. Human ECG - nonlinear deterministic versus stochastic aspects. *IEE Proceedings - Science, Measurement and Technology*. 1998; **145** : (6)279-284.

Kaplan D, Glass L. Understanding nonlinear dynamics. Springer-Verlag, New York, 1995.

Kaplan DT, Goldberger A. L. Chaos in cardiology. *J Cardiovasc Electrophysiol*. 1991; **2** : 342-354.

Kleiger RE, Stein PK, Bosner MS, Rottman JN. Time domain measurement of heart rate variability. *Cardiol Clin*. 1992; **10** : 487-498.

Kobayashi M, Mysha T. $1/f$ Fluctuation of heart beat period. *IEEE Trans Biomed Eng*. 1982; **29** : 456-457.

Koebbe M, Mayer-Kress G. Use of the recurrence plots in the analysis of time series data. Em: Nonlinear modeling and forecasting, Santa Fe Institute Studies in the Science of Complexity. Addison Wesley, 1992, 361-378.

Kullback S. Information Theory and Statistics. J. Wiley, New York, 1959.

Mäkikallio T. *Analysis of heart rate dynamics by methods derived from nonlinear mathematics. Clinical applicability and prognostic significance.* Dissertação de mestrado, University of Oulu, 1998.

Malik MFT, Cripps TRCAJ. Heart rate variability in relation to prognosis after myocardial infarction: selection of optimal processing techniques. *Eur. Heart J.* 1989; **10** : 1060-1074.

Mallamace F, Stanley HE, Physics of Complex Systems, Course CXXXIV. Amsterdam: Proceedings o Enrico Fermi School on Physics, Course CXXXIV, 1997.

Malliani A, Pagani M, Lombardi F, Cerutti S. Cardiovascular neural regulation explored in the frequency domain. *Circulation.* 1991; **84** : 482-492.

Moody GB, Mark RG, Goldberger AL. Physionet: a web-based resource for the study of physiologic signals. *IEEE Engineering in Medicine and Biology.* 2001; **20** : 70-75.

Motta GHMB. *Especificações formais orientadas a objetos: aplicação no desenvolvimento de um sistema para processamento do eletrocardiograma de esforço.* Tese de mestrado, Universidade Federal de Pernambuco, 1992.

Öri Z, Monir G, Weiss J, Sayhouni X, Singer D. H. Heart rate variability and frequency domain analysis. *Cardiology Clinics.* 1992; **10** : 499-537.

Packard NH, Crutchfield JD, Farmer JD, Shaw RS. Geometry from a time series. *Phys Rev Lett.* 1980; **45** : 712-716.

Peng C-K, Buldyrev SV, Havlin S, Simons M, Stanley HE, Goldberger AL. On the mosaic organization of DNA sequences. *Phys Rev E.* 1994; **49** : 1691-1695.

Peng C-K, Havlin S.; Stanley, Stanley HE, Goldberger AL. Quantification of scaling exponents and crossover phenomena in nonstationaruty heartbeat time series. *Chaos.* 1995; **5** : 82-87.

Peng C-K, Hausdorff JM, Goldberger AL. Fractal mechanisms in neural control: Human heartbeat and gait dynamics in health and disease. Cambridge University Press,

Cambridge, 2000.

Pincus SM. Approximate entropy as a measure of system complexity. *Proc Natl Acad Sci USA*. 1991; **88** : 2297-2301.

Pincus SM, Viscorello RR. Approximate entropy: a regularity statistic for fetal heart rate analysis. *Obst Gynecol*. 1992; **79** : 249-255.

Pincus SM, Huang WM. Approximate entropy: statistical poroperties and applications. *Commum Stat Theory Meth*. 1992; **21** : 3061-3077.

Pincus S. M. approximate entropy as a measure of system complexity. *Proc. Natl. Acad. Sci. USA*. 1991; **88** : 2297-2301.

Richter M, Schreiber T, Kaplan DT. Fetal ECG extraction with nonlinear state-aspase projections. *IEEE Trans Bio-Med Eng*. 1998; **45** : 133-137.

Ritcher M, Schreiber T. Phase space embedding of electrocardiograms. *Phys Rev E*. 1998; **58** : 6392-6398.

Rocha M, Júnior S. Fisiologia e Circulação. Edart - São Paulo Livraria Editora LTDA, São Paulo, 1973.

Ruelle D, Takens F. On the nature of turbulence. *Commun Math Phys*. 1971; **20** : 167-192.

Ruelle D, Takens F. On the nature of turbulence. *Commun Math Phys*. 1971; **23** : 343-344.

Schechtman VL, Harper RK, Harper RM. Development of heart rate dynamics during sleep-waking states in normal infants. *Pediatr Res*. 1993; **34** : 618-623.

Schreiber T, Kaplan DT. Nonlinear noise reduction for electrocardiograms. *Chaos*. 1995; **6** : 87-92.

Schreiber T, Kaplan DT. Signal separation by nonlinear projections: The fetal electrocardiogram. *Phys Rev Lett*. 1995; **53** : (5)R4326-R4329.

Seely AJE, Macklem PT. Complex systems and the technology of variability analysis. *Critical Care*. 2004; **8** : R367-R384.

Stanley HE, Amaral LAN, Goldberger ALHS, Ivanov PC, Peng C-K. Statistical physics and physiology: Monofractal and multifractal approaches. *Physica A*. 1999; **270** : (309-324).

Takens F. Dynamical Systems and Turbulence. Em: Lecture Notes in Mathematics. New York, Heidelberg e Berlin: Springer-Verlag, 1980, 366-381.

Talmon JL. *Pattern recognition of the ECG. A structured analysis*. Tese de mestado, Vrije Universiteit Te Amsterdam, 1983.

Tapanainen JM, Thomsen PE, Torp-Pedersen C, Makikallio TH, Still AM, Lindgren KS, Huikuri HV. Fractal analysis of heart rate variability and mortality after an acute myocardial infarction. *Am J Cardiol*. 2002; **90** : 347-352.

Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology. Heart rate variability: standards of measurement, physiological interpretation, and clinical use. *Circulation*. 1996; **93** : 1043-1065.

Teich MC, Lowen SB, Jost BM, Vibe-Rheymer K, Heneghan C. Heart Rate Variability: Measures and Models. Em: Nonlinear Biomedical Signal Processing Vol. II. New York: IEEE Press, 2001, 159-213.

Thompson JM, Stewart HB. Nonlinear dynamics and chaos. John Wiley, Chichester, New York, Brisbane, Toronto e Singapore, 1986.

Tapanainen J. M.; Thomsen, Thomsen PE, kober L, Torp-Pedersen C, Makikallio TH, Still AM, Lindgren KS, huikuri HV. Fractal analysis of heart rate variability and mortality after an acute myocardial infarction. *Am. J. Cardiol.*. 2002; **90** : 347-352.

Tsallis C. Possible Generalization of Boltzmann-Gibbs Statistics. *J Stat Phys*. 1988; **52** : 479-487.

Tufillaro NB, Abbott TA, Reilly JP. An experimental approach to nonlinear dynamics and

chaos. Addison-Wesley, Redwood City, 1992.

Tulppo MP, Mäkikallio TH, Takala TES, Seppänen T, Huikuri HV. Quantitative beat-to-beat analysis of heart rate dynamics during exercise. *Am J Physiol.* 1996; **271** : H244-H252.

Wang Z, Ning X, Zhang Y, Du G. Nonlinear dynamics characteristics analysis of synchronous 12-lead ECG signals. *IEE Engineering in Medicine and Biology.* 2000; 110-115.

Weisstein WE, et al. "Manifold." De *MathWorld*--A Wolfram Web Resource. Disponível em: <http://mathworld.wolfram.com/Manifold.html>.

Wilson DR, Martinez TR. Improved Heterogeneous Distance Functions. *Journal of Artificial Intelligence Research.* 1997; **6** : 1-34.

Woo MA, Stevenson WG, Moser DK, Middlekauff H. R. Complex heart rate variability and serum norepinephrine levels in patients with advanced heart failure. *J Am Coll Cardiol.* 1994; **23** : 565-569.

Yamamoto Y, Nakamura Y, Sato H, Yamamoto M, Kato K, Hughson R. L. On the fractal nature of heart rate variability in humans: effects of vagal blockade. *Am J Physiol.* 1995; **269** : R830-R837.