

Universidade Estadual de Campinas
Faculdade de Engenharia Elétrica e de Computação
Departamento de Engenharia de Computação e Automação Industrial

Este exemplar corresponde a redação final da tese
defendida por Denys Emílio Campion Nicolosi
Nicolosi e aprovada pela Comissão
Julgada em 17 / 09 / 1999.
Orientador

**Compressão de Sinais de Eletrocardiograma : Uma
Contribuição ao seu Estudo**

Autor : Denys Emílio Campion Nicolosi

Orientador :

Prof. Dr. Márcio Luiz de Andrade Netto

Co-Orientador :

Prof. Dr. Dalton Soares Arantes

Dissertação apresentada à Faculdade de
Engenharia Elétrica e de Computação da
Universidade Estadual de Campinas como
parte dos requisitos exigidos para a obten-
ção do Título de Doutor em Engenharia
Elétrica.

Campinas, SP - Brasil

1999

I.ª CHAMADA:
F/UNICAMP
N547c
Ex.
OMBO BC/40350
ROC. 278/2000
C D
RECO 25.11.00
ATA 12/02/2000
* CPD

CM-00138060-3

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

N547c Nicolosi, Denys Emílio Campion
Compressão de sinais de eletrocardiograma: uma
contribuição ao seu estudo / Denys Emílio Campion
Nicolosi.--Campinas, SP: [s.n.], 1999.

Orientadores: Márcio Luiz de Andrade Netto, Dalton
Soares Arantes.

Tese (doutorado) - Universidade Estadual de
Campinas, Faculdade de Engenharia Elétrica e de
Computação.

1. Compressão de dados (Telecomunicações). 2.
Engenharia biomédica. 3. Eletrocardiografia. 4. Análise
de componentes principais. I. Andrade Netto, Mário
Luiz de II. Arantes, Dalton Soares. III. Universidade
Estadual de Campinas. Faculdade de Engenharia Elétrica
e de Computação. IV. Título.

Banca Examinadora

Prof. Dr. Márcio Luiz de Andrade Netto
Instituição : FEEC/UNICAMP - Presidente

Prof. Dr. Fernando José Von Zuben
Instituição : FEEC/UNICAMP

Prof. Dr. José Raimundo de Oliveira
Instituição : FEEC/UNICAMP

Prof. Dr. Jurandir Nadal
Instituição : COPPE-UFRJ

Prof. Dr. Osamu Saotome
Instituição : ITA

Campinas, 17 de Setembro de 1999.

RESUMO

A área de Compressão de Dados de sinais digitalizados de Eletrocardiograma, ECG, tem grande importância prática pela economia de espaço de memória, de arquivo, ou de tempo de transmissão que ela viabiliza, e é considerada uma área efervescente, onde trabalhos científicos de excelente nível têm sido publicados.

Neste trabalho, desenvolve-se um procedimento novo de criação experimental da função taxa da distorção ("Rate Distortion Function"), $R(D)$, utilizada em comunicações e com raízes na Teoria da Informação. O método desenvolvido realiza a decomposição do sinal em componentes principais (Principal Component Analysis) e cria a curva $R(D)$ através da recuperação parcial desses componentes principais. A taxa R é computada através da entropia das Funções de Densidade de Probabilidade dos pesos (scores) de cada componente principal utilizado nesta recuperação parcial, obtendo-se então a relação $R \times D$. Os resultados obtidos representam uma referência para esta área, pois impõem um limitante inferior para a melhor taxa de compressão que se pode obter para esses sinais.

Foi possível também caracterizar a Função de Densidade de Probabilidade para sinais de ECG, que não tinha sido bem explorada na literatura. Constatou-se que ela se aproxima fortemente de uma função Laplaciana. Com estes resultados e experiências obtidas, foi possível ainda criar um esquema inédito de compressão de sinais de ECG por técnica de decomposição parcial do sinal em Componentes Principais, utilizando o algoritmo "NIPALS - Non Linear Iterative Partial Least Squares", que obteve desempenho bem próximo do previsto pela curva $R(D)$ obtida. Quando seu desempenho foi comparado com a dos esquemas atuais e vigentes, se posicionou entre os melhores. Foi explorada também, a título de estudo e revisão, uma técnica de compressão por Redes Neurais Artificiais, arranjadas como "Auto-Associadoras", que apresentou, na literatura especializada, o melhor desempenho já obtida até o ano de 1999.

ABSTRACT

Data Compression of Electrocardiogram digitalized signals is a very important subject in many aspects, such as memory and space economy or data transmission, and it is considered an area in constant development with excellent scientific works worldwide.

In this work, a new procedure for the experimental computation of the Rate Distortion Function, $R(D)$, is developed. This is a function which is commonly used in Communications and whose origins are in the Information Theory. This work presents a novel procedure for determining the $R(D)$ function, by means of a decomposition of the signal in its principal components (Principal Components Analysis). The $R(D)$ curve is then created through the partial recuperation of these principal components, as a function of the distortion D obtained from this partial recovery. The Rate "R", is then obtained using each of the Principal Component score values derived from its probability density function, in such a way that the relation "R x D" is obtained..

It was also possible in this work, to characterize the probability density function for ECG signals, which have not been well explored in the literature : We have concluded that this density is very close to a Laplacian function, which is a surprising result.

With these results and other experiments, it was possible to create a new scheme for the efficient compression of ECG signals through a partial decomposition of the signal in its Principal Components. This method was based on the "NIPALS" algorithm - Non Linear Iterative Partial Least Squares, and resulted in a performance very close to the lower bound specified by the $R(D)$ function. Its performance compared favorably with the best methods used today for ECG signal compression.

We also explored a compression technique based on Artificial Neural Network, arranged as "Auto-Associator", which has the best performance ever presented until 1999 in the specialized literature. This study then completed our work of exploration of the compression limits for Electrocardiogram signal.

Key Words : Compressão, ECG, Rate Distortion Function, NIPALS, Principals Component Analysis

Dedicatória

Aos meus pais, Emílio e Dalva

Aos meus filhos, André e Sara

Ao povo simples deste Brasil, que sofre sem muitas perspectivas, mas que tem uma fé e esperança tão fortes por dias melhores, que sinto que preciso ainda aprender muito com eles...

Agradecimentos

Ao CNPq, projeto RHAЕ n° 260.347/95-00, pelo incentivo a esta linha de pesquisa desenvolvida no Instituto Dante Pazzanese de Cardiologia e Fundação Adib Jatene.

Ao Instituto Dante Pazzanese de Cardiologia e Fundação Adib Jatene pelo incentivo e apoio.

A UNICAMP, Departamento de Engenharia de Computação e Automação Industrial da Faculdade de Engenharia Elétrica e de Computação, pelo excelente acolhimento de minhas propostas, e pela oportunidade de aprendizado.

Ao professor Marcio Luiz de Andrade Netto, que sempre confiou e apoiou este trabalho, me deixando livre para criar.

Ao professor Dalton Soares Arantes, que além de extremamente simpático e atencioso, é um grande gerador de idéias e contribuiu muito para a realização deste trabalho.

Ao professor Renato M. E. Sabbatini, que foi quem gerou em mim o primeiro interesse em estudar sistemas Holter com técnicas avançadas.

Aos Engenheiros Mauro Persano e Jorge Martines Lopes pelo apoio, tanto no projeto e execução, como na digitação dos textos. A Claudia Brunetti pelo apoio na datilografia e traduções.

Aos colegas do Instituto Dante Pazzanese de Cardiologia que sempre me apoiaram nas propostas que costumo apresentar nesta instituição, em especial ao Rodrigo Araês Caldas Farias, pela excelente companhia proporcionada durante os cursos na UNICAMP. Ao Eng. Fabbryccio A. C. M. Cardoso, doutorando da Unicamp, pelo inestimável trabalho de conversão do original desta tese, no formato Word, para o formato \LaTeX 2 ϵ .

Dom Juan : - Os guerreiros combatem a vaidade por uma questão de estratégia, e não de princípio. Seu erro é compreender o que digo em termos morais.

Castaneda : - Considero-o um homem altamente moral, Dom Juan.

Dom Juan : - A impecabilidade não é nada mais do que o uso apropriado da energia. As minhas afirmações não tem um pingão de moralidade. Economizei energia, e isso me torna impecável.(!)

O Fogo Interior, Carlos Castaneda, pg.26, 1984.

Denys Emílio Campion Nicolosi

Campinas, Setembro de 1999.

Conteúdo

1	Introdução	2
2	Técnicas de Compressão de ECG	6
2.1.	Origem e necessidade das técnicas de compressão	6
2.2.	As Técnicas Atuais de Compressão	7
2.2.1.	Introdução	7
2.2.2.	Revisão	8
3	Levantamento Experimental da Rate Distortion Function R(D) para Sinais de ECG do Tipo Ambulatorial	22
3.1.	Fundamentos da compressão, do desempenho, do erro, do grau de compressão e da fidelidade	22
3.1.1.	Técnicas de Compressão	22
3.1.2.	Fundamentos	23
3.1.3.	Modelos Probabilísticos	31
3.2.	Caracterização do sinal de ECG quanto à compressão e função de densidade de probabilidade	32
3.2.1.	Cálculo de $h(x)$	33
3.3.	Estatística de Ordem Superior : Análise de Componentes Principais	37
3.3.1.	Procedimento	37
3.3.2.	Resultados desta decomposição em PCs	38
3.3.3.	Resultados Obtidos	41
3.3.4.	Demonstração da equivalência entre as fórmulas original de Shannon e a Alterada	45

4	Compressão de sinais de ECG por Técnicas Avançadas	47
4.1.	Por Redes Neurais Artificiais	47
4.1.1.	Introdução : Revisão das principais técnicas adaptativas e com redes neurais para compressão de ECG	47
4.1.2.	Revisão das principais técnicas para compressão de ECG utilizando Redes Neurais Artificiais	53
4.1.3.	O Compressor Desenvolvido	61
4.1.4.	Resultados	68
4.2.	Compressão por Análise de Componentes Principais	69
4.2.1.	Compressão pelo Algoritmo de NIPALS	69
4.2.2.	O Compressor Desenvolvido	76
4.2.3.	Resultados	82
5	Materiais e Métodos	88
5.1.	Utilizando a base de dados do MIT-BIH (1992)	88
5.1.1.	Configuração das Derivações de ECG	89
5.1.2.	Gravação e Reprodução Analógica	90
5.1.3.	Digitalização	91
5.1.4.	Anotações no Banco de Dados	92
5.2.	Parâmetros de validação e medida de performance	93
5.2.1.	Estimativa da Função de Densidade de Probabilidade	93
5.2.2.	Distância de Kullback-Leibler ou Divergência Assimétrica	95
5.2.3.	Algoritmo NIPALS	96
5.2.4.	Erro RMS, o erro PRD e Qualidade do sinal	101
5.3.	Parâmetros de comparação de Algoritmos de Compressão	108
5.3.1.	Introdução	108
6	Discussão	114
6.1.	A curva $R(D)$ como referência para desenvolvimento de Algoritmos de Compressão	114
6.2.	Estado da Arte dos algoritmos de compressão	115

6.3.	O sistema de compressão implementado (PCA- NIPALS) e sua relação com a Curva $R(D)$	120
6.4.	O sistema desenvolvido (PCA-NIPALS) comparado com os existentes de maior desempenho	121
6.5.	O futuro dos sistemas de compressão de ECG	121
7	Conclusões	123
A	Princípios de Eletrocardiografia Tompkins [78]	133
A.1.	Eletrocardiografia Básica	133
A.1.1.	Eletrodos	135
A.1.2.	O gerador cardíaco equivalente	136
A.1.3.	Geração do ECG	140
A.1.4.	Os padrões de Leads (Derivações de ECG)	143
A.1.5.	Os padrões de “Leads Aumentados”	144
A.1.6.	Sistema de Leads de ECG	146
A.1.7.	Características do sinal de ECG	151

Lista de Figuras

3.1	Ilustração do Teorema do Valor Médio.	26
3.2	fdp obtida de todos os sinais da base de dados.	34
3.3	A fdp de primeira ordem do sinal 122.	35
3.4	A fdp de primeira ordem do sinal 212	35
3.5	A fdp de primeira ordem de todos os sinais centradas no valor 980	36
3.6	Pulsos do sinal 100 sincronizados e truncados em função da onda R	39
3.7	Pulsos do sinal 100 reamostrados para ter tamanho fixo de 285 amostras	39
3.8	Fdp dos scores da PC1 e cálculo da divergência assimétrica	40
3.9	Fdp dos scores da PC2 e cálculo da divergência assimétrica	40
3.10	Fdp dos scores da PC3 e cálculo da divergência assimétrica	41
3.11	Curvas $R(D)$ de todos os sinais da base de dados	42
3.12	Curvas $R(D)$ de todos os sinais da base de dados desenhada junto com as obtidas por Hamilton e Tompkins [29].	43
3.13	Curva $R(D)$ Operacional por PCA e a $RLS(D)$ de Shannon	44
4.1	Mostra do desempenho do Compressor por Kohonen	59
4.2	Desempenho do Compressor de Iwata (Superior= Sinal Original)	62
4.3	Visualização da tela de simulação do compressor RNA	67
4.4	Desempenho do compressor RNA com os sinais do MIT-BIH	72
4.5	Mostra do compressor RNA com o sinal 106 do MIT-BIH, ilustrando um pulso ectópico que a rede não consegue representar.	72
4.6	Mostra do compressor RNA com o sinal 100 do MIT-BIH, ilustrando 285 amostras , que foi interrompido em 9000 épocas.	73

4.7	Mostra do compressor RNA com o sinal 100 do MIT-BIH, ilustrando 285 amostras , que foi interrompido em 50000 épocas.	73
4.8	Um pulso original do sinal 106	74
4.9	O mesmo pulso do sinal 106 comprimido e recuperado por 7 PCs	75
4.10	Pulso 1990, anômalo, do sinal 106 - Pulso Original	75
4.11	Pulso 1990 do sinal 106 comprimido e recuperado com 7 PCs	76
4.12	Filme do sinal comprimido e recuperado em função de cada PC de 1 até 7 e no fim, o sinal original.	77
4.13	Ilustração do ocorrido com o sinal 100	79
4.14	Fotos dos autovetores para as PCs 3 e 2 para quatro blocos de sinal, mostrando que as suas formas são diferentes de bloco para bloco.	80
4.15	Visualização da tela de simulação do compressor PCA-NIPALS	83
4.16	Curva de desempenho do compressor PCA-NIPALS quando comparado com as curvas R(D) teóricas obtidas segundo o Capítulo 3.	84
4.17	Sinal 106 sendo operado pelo compressor PCA-NIPALS	84
4.18	Sinal 117 sendo operado pelo compressor PCA-NIPALS	87
5.1	Ilustração de trecho do sinal 104 original e recuperado com a técnica TP para um CR de aproximadamente 4.	104
5.2	Ilustração de trecho do sinal 104 original e recuperado com a técnica AZTEC para um CR de aproximadamente 4.	105
5.3	Ilustração de trecho do sinal 104 original e recuperado com a técnica CORTES para um CR de aproximadamente 4.	105
5.4	Ilustração de trecho do sinal 104 original e recuperado com a técnica DCT para um CR de aproximadamente 4.	106
5.5	Ilustração de trecho do sinal 108 original e recuperado com a técnica TP para um CR de aproximadamente 4.	106
5.6	Ilustração de trecho do sinal 108 original e recuperado com a técnica AZTEC para um CR de aproximadamente 4.	107
5.7	Ilustração de trecho do sinal 108 original e recuperado com a técnica CORTES para um CR de aproximadamente 4.	107

5.8	Ilustração de trecho do sinal 108 original e recuperado com a técnica DCT para um CR de aproximadamente 4.	108
5.9	Proposta de modelo de tabela para avaliação de algoritmos de compressão .	110
5.10	Proposta de modelo de curva $R(D)$ para avaliação de algoritmos de compressão	111
5.11	Proposta de modelo de resumo de explanação de algoritmos de compressão .	112
5.12	Proposta de modelo de amostra de sinal para avaliação de algoritmos de compressão	113
6.1	Resumo da área de Compressão de ECG.	117
6.2	Relação CR/PRD para o sinal 112 e o ponto obtido pelo compressor de Iwata para o mesmo sinal.	118
6.3	Relação CR/PRD para o sinal 100 e o ponto obtido pelo compressor de Iwata para o mesmo sinal.	119
6.4	Relação CR/PRD para o sinal 114 e o ponto obtido pelo compressor de Iwata para o mesmo sinal.	120
A.1	O objeto da eletrocardiografia é deduzir as condições elétricas e mecânicas do coração realizando medidas não invasivas do potencial da superfície do corpo.	134
A.2	Medidas de ECG no passado (aproximadamente 1900) por Einthoven.	135
A.3	Eletrodo de ECG prata-cloreto de prata. Muitos eletrodos modernos têm camadas de eletrólitos que são feitas de um gel consistente que tem propriedades adesivas. O gel minimiza os distúrbios da dupla camada de cargas.	136
A.4	Tanto as condições elétricas como mecânicas do coração são envolvidas na determinação das características da distribuição da atividade elétrica sobre a superfície do mesmo. Um modelo desta atividade é denominado "gerador cardíaco equivalente".	137
A.5	Triângulo equilátero de Einthoven. RA e LA são os braços direito e esquerdo e LL é a perna esquerda.	138
A.6	Modelo de tronco utilizado para desenvolver o "Frank Lead System" para vetocardiografia	139

A.7	Configuração básica para registrar um eletrocardiograma. Utilizando eletrodos presos ao corpo, o ECG é registrado com um amplificador de instrumentação. (a) Vista transversal (de topo) de uma fatia do corpo mostrando o coração e pulmões. (b) Vista frontal mostrando os eletrodos conectados aproximadamente numa configuração Lead II.	141
A.8	Eletrocardiograma para uma batida de coração normal mostrando amplitudes e tempos de duração típicos para as ondas P, QRS e T.	142
A.9	Relação entre o espalhamento da ativação elétrica cardíaca (representado em vários instante de tempo por um vetor de soma nos desenhos superiores) e a geração do ECG (nos desenhos inferiores).	142
A.10	Leads I, II e III são as diferenças de potencial entre os membros como indicado. RA a LA são os braços direito e esquerdo e LL é a perna esquerda.	143
A.11	O "Augmented Limb Lead aVL" é medido como mostrado.	144
A.12	Determinação da resistência de Thévenin para o circuito equivalente do aVL. (a) Todas as fontes de tensão são curto-circuitadas. (b) Isto resulta em uma associação paralelo dos dois resistores iguais. (c) A resistência equivalente de Thévenin tem valor de $R/2$	147
A.13	Num dispositivo prático para registrar aVL, um valor de resistência de $R/2$, igual ao valor da resistência equivalente de Thévenin, é adicionado ao terminal positivo do amplificador de instrumentação, para equilibrar a impedância em cada entrada do mesmo.	147
A.14	A solução gráfica vetorial para aVL em termos dos leads I e III.	148
A.15	As relações vetoriais entre todos os leads do plano frontal	148
A.16	Eletrocardiograma clínico padrão 12-lead. (a) Lead I. (b) Lead II. (c) Lead III. Note a polaridade do amplificador para cada um desses leads nos membros. (d) aVR. (e) aVL. (f) aVF; estes "Augmented Limb Leads" necessitam de redes de resistores que tiram a média dos potenciais de dois membros enquanto registram o terceiro. (g) Os Seis "V leads" são registrados em relação ao "Terminal Central de Wilson" que é a média de todos os três potenciais dos membros. Cada um dos seis leads (V1 a V6) são registrados a partir de uma posição anatômica diferente do tórax.	149

- A.17 O 12-lead ECG de um paciente normal do sexo masculino. Pulsos de calibração à direita indicam 1V. A velocidade de registro é de 25mm/s. Cada divisão menor é de 1mm, portanto, as maiores são de 5mm. Dessa forma, no lead I, a amplitude da onda R é de aproximadamente 1.1mV e o tempo entre batidas é de quase 1s (frequência do coração de, aproximadamente, 60bpm). 150
- A.18 Larguras de banda utilizadas em eletrocardiografia. A largura de banda clínica padrão para o "12-Lead ECG System" clínico é de 0.05 a 100Hz. Sistemas de monitoração utilizam tipicamente uma largura de banda de 0.5 a 50Hz. Cardiotacômetros, para determinação de frequência cardíaca em casos de batidas predominantemente normais, utilizam um simples filtro passa-bandas centralizado em 17Hz e com "Q" de, aproximadamente 3 ou 4. 151

Lista de Tabelas

2.1	Comparação entre várias técnicas de compressão de ECG	18
2.2	Comparação entre várias técnicas de compressão de ECG	19
2.3	Comparação entre várias técnicas de compressão de ECG	20
2.4	Comparação entre várias técnicas de compressão de ECG	21
4.1	Compressor Kohonen , dados da base de códigos	58
4.2	Ensaio do Compressor Kohonen em função da base de códigos	58
4.3	Performance do compressor por RNA como auto-associadora	63
4.4	-Desempenho do compressor RNA com os sinais do MIT-BIH	70
4.5	Desempenho do compressor RNA com os sinais do MIT-BIH	71
4.6	Desempenho do compressor PCA-NIPALS com os sinais do MIT-BIH	85
4.7	Desempenho do compressor PCA-NIPALS com os sinais do MIT-BIH	86
6.1	índice de Mérito dos Sistemas de Compressão versus data de publicação . . .	116

Nomenclatura

CP	Componente Principal
ECG	Eletrocardiograma
PRD	Percentual Root Mean Square Difference
PC	Principal Component
PCA	Principal Component Analysis
RMS	Root Mean Square
Pdf	Probability Density Function
RNA	Rede Neural Artificial
NIPALS	Non Linear Iterative Partial Least Squares
bits/sa	Bits/sample
bits/s	Bits/segundo
CR	Compression Ratio
VQ	Vector Quantization
AHA	American Heart Association
KNN	Kohonen Neural Network
MIT-BIH	Massachusetts Institute of Technology - Beth Israel Hospital
MLP	Multilayer Perceptron
ML	Maximum Likelihood
PLS	Partial Least Squares
VCG	Vetocardiograma
DC	Direct Current
AS	Atrial Sinus
AV	Atrioventricular
QRS	Complexo do Sinal do Eletrocardiograma
P	Onda P do Eletrocardiograma
CMRR	Common Mode Rejection Ratio

Capítulo 1

Introdução

As pesquisas em comunicações, hoje praticamente digitais, se concentram continuamente na otimização da capacidade de transmissão e/ou armazenamento de dados. Certos sistemas admitem um certo grau de erro ou distorção, outros não. Considerando-se o caso da compressão com perdas (implicando em erros e distorção), necessita-se avaliar a quantidade de informação envolvida no processo e a capacidade do sistema de transmissão (e/ou armazenamento), para se desenvolver algoritmos de compressão otimizados. A área que trata de compressão de dados sob o ponto de vista da Teoria da Informação é a chamada de “Rate Distortion Theory” (Shannon [73], Berger [10]).

A literatura seminal destas duas áreas é representada pelo artigo de C. E. Shannon [73], onde ele cita :

“O problema fundamental da comunicação é aquele da reprodução em um ponto, exata ou aproximadamente, da informação selecionada em um outro ponto”.

Claude Shannon usualmente “brincava” (Thomas [77]) em encontros e festas, de adivinhação de palavras de um texto, falando uma letra e esperando dos parceiros a adivinhação da próxima letra . Shannon concluiu que um texto inglês corriqueiro é aproximadamente 70% a 80% redundante.

Isto implica, como ilustração, que a quantidade de informação de textos desta língua pode ser otimizada! Em todas as áreas que envolve comunicação e/ou armazenamento de dados, se depara com duas questões básicas :

I Qual parte da informação deve ser transmitida ?

II Como ela deve ser transmitida ?

Em 1959, Shannon, em seu outro artigo fundamental (Hamilton [28]), tratou dos aspectos

citados no item I. Neste, Shannon definiu a “Rate Distortion Function” de uma fonte de informação, com respeito a critérios de fidelidade, e estabeleceu seus teoremas fundamentais.

Hoje em dia, preocupa-se mais com os aspectos práticos da aplicação desta teoria, a fim de se determinar os limites obtidos através da “Rate Distortion Theory”, atendendo ao quesito do item II.

Estes quesitos são os fundamentos da otimização dos processos de transmissão e/ou armazenamento de dados, sendo portanto, também, uma referência para atuação na área de compressão de dados de Eletrocardiograma (ECG). Avaliar a eficiência de um esquema de compressão de dados de ECG pressupõe o conhecimento a priori desta informação, tanto nos aspectos estáticos e dinâmicos, como também nos estatísticos. Na área motivo deste trabalho, admite-se obviamente compressão com perdas. A questão chave é :

- Dado um meio de comunicação e/ou armazenamento, sob quais condições é possível se criar um esquema de compressão que produza um sinal de saída com uma distorção média que não exceda um limite “ D ”, pré-estabelecido por critérios específicos da área em questão ?

Para responder a esta questão chave, tem-se duas medidas de fundamental importância na Teoria da Informação : a capacidade do sistema e a “Rate Distortion Function” $R(D)$ do sinal em questão e de seu esquema de compressão.

- A Capacidade “ C ” do sistema representa a taxa máxima de informação que se pode transmitir ou armazenar, com probabilidade de erro tão baixa quanto se queira.

- A Rate Distortion Function $R(D)$ é um limitante inferior para a taxa com que se pode representar um sinal, sujeita a uma distorção média igual a D . A taxa mínima com que o sinal produz a informação com perfeição (sem perdas) é chamada “Entropia da Fonte”, H .

Então, a “Rate Distortion Function” é a generalização do conceito de entropia, pois quando se exige distorção D nula ($D = 0$), tem-se $R(0) = H$.

Quando a distorção média D cresce, $R(D)$ decresce monotonicamente, e usualmente se tornará nula quando admite-se uma distorção D suficientemente alta.

O conhecimento da “Rate Distortion Function” é extremamente útil. Por exemplo, quando o objetivo é transmitir um sinal através de um canal com capacidade já estabelecida, então podem-se fazer as seguintes afirmações. Se o canal tem capacidade C , pode-se avaliar o grau de otimização possível através da curva $R(D)$. Se $C \geq R(D)$, pode-se otimizar o processo, isto é, existe o que melhorar nos esquemas de compressão (aumentando-se a taxa e diminuindo-se a distorção D). Se $C - R(D)$ é muito pequeno, então o esquema de compressão está perto do ótimo e, provavelmente, somente algoritmos muito sofisticados e/ou custosos

irão melhorar o desempenho já obtido. Se $C - R(D)$ é um valor considerável, ainda se tem chance de descobrir esquemas de compressão que permitam chegar a uma menor diferença $C - R(D)$.

Por outro lado, quando o objetivo é apenas reduzir ao máximo a taxa ou o tamanho do arquivo que deverá representar o sinal, para uma dada distorção D , então o limite máximo possível para essa redução é dado pela função $R(D)$.

Assim, a curva $R(D)$ é matéria básica para qualquer desenvolvimento de algoritmos de compressão.

Na área de Eletrocardiografia, uma revisão bibliográfica aponta apenas um artigo (Hamilton [28]) que, considerando a priori o sinal de eletrocardiograma (ECG) como sendo de distribuição estatística do tipo Gaussiana, levanta a curva $R(D)$ para uma base de dados do MIT-BIH (Massachusetts Institute of Technology - Beth Israel Hospital) [52], base de dados esta que é considerada uma referência para trabalhos de processamento digital de sinal de ECG na área.

Os mesmos pesquisadores (Hamilton [28]) chegam à conclusão de que o sinal não deve ser Gaussiano, pois foi possível obter esquemas de compressão com desempenho superior àquelas que os mesmos obtiveram da base de dados.

Com o propósito de levantar os parâmetros estatísticos e as medidas de informação deste tipo de sinal, desenvolveu-se nesta tese um procedimento de determinação da curva $R(D)$ para os sinais de ECG desta base de dados. O método baseou-se na decomposição dos sinais em suas componentes principais (PCA), equivalente aos auto-vetores da matriz de auto-covariância, e o conseqüente levantamento da função densidade de probabilidade (pdf) da matriz de pesos (projeções ou scores) em relação a cada componente principal obtido. A partir da caracterização dessas “pdf’s” (que concluiu-se que são aproximadamente Laplacianas) foi possível o levantamento, ponto a ponto, da curva $R(D)$ baseando-se na entropia obtida da distribuição estatística das projeções ou scores de cada componente principal obtido.

Assim, construiu-se uma curva $R(D)$ para cada um dos 48 sinais (pacientes) que a base de dados contém, gerando uma referência inédita para a área de Compressão de Dados de ECG. Vale ressaltar que a área de compressão de ECG pode ser considerada de grande importância na literatura atual (com algumas dezenas de artigos e propostas de esquemas de compressão, e em franca evolução) e que os pesquisadores até então avaliam os desempenhos de seus algoritmos geralmente através da base de dados do MIT-BIH [52], porém sem nenhuma referência absoluta e, inclusive, sem critérios na escolha dos sinais desta base de dados,

quando vão testar seus trabalhos.

Além disto, foram analisados alguns esquemas de compressão com técnicas avançadas. Foi desenvolvido aqui uma técnica de compressão por decomposição parcial do sinal em componentes principais, utilizando o algoritmo NIPALS-Non Linear Iterative Partial Least Squares, cuja aplicação original vem da quimiometria e sua aplicação em sinais é inédita. Vale ressaltar que a decomposição de um sinal em componentes principais é equivalente a transformada Karhunen-Loève para o caso discreto. O algoritmo NIPALS é, então, um procedimento matemático que determina os componentes principais ou auto-vetores de um sinal, ordenadas pela ordem decrescente dos respectivos auto-valores, e com custo computacional inferior ao da decomposição por matriz de covariância. Constatou-se que o desempenho dessa técnica, aplicada à compressão, teve como resultado um desempenho bastante próximo das curvas $R(D)$ geradas, isto é, próximo daquele previsto teoricamente. Pôde-se constatar também que o desempenho obtido foi posicionado entre os melhores encontrados na literatura especializada.

Capítulo 2

Técnicas de Compressão de ECG

2.1. Origem e necessidade das técnicas de compressão

A compressão de dados é uma arte ou ciência de representar informação de uma forma compacta. Esta representação compacta só é possível conhecendo-se e identificando estruturas que possam existir dentro destes dados. Com dados se representam os textos, os números oriundos de sinais biológicos, a voz, a imagem, ou ainda números que são representações de quaisquer outros processos. O código Morse, desenvolvido por Samuel Morse no século 19, é um exemplo de compressão (Sayood [70]), pois Morse notou que certas letras ocorriam mais freqüentemente que outras e, no sentido de se diminuir o tempo de transmissão da mensagem, ele atribuiu códigos mais curtos para aquelas letras que ocorriam mais freqüentemente. Por exemplo o “e” atribuiu a um “.”, o “a” a um “. -” e seqüências mais longas para as letras menos utilizadas como o “q” a um “- - . -”. O código Braille, também desenvolvido no século 19, também usa a freqüência de ocorrência das palavras para formação de um “código comprimido”, com grau de compressão de 20%, aproximadamente. Note que o que se usou nestes casos foi a estatística de ocorrência, ou da estrutura das palavras para realizar a estratégia de compressão, mas esta não é a única espécie de estrutura que se pode verificar dentro de um certo tipo de dados. Na voz, por exemplo, a construção física da voz define os tipos de sons que se pode gerar, isto é, este mecanismo impõe uma estrutura na produção da voz. Assim, uma adequada informação sobre a mecânica e dimensões da cavidade fonética pode criar uma representação muito mais comprimida da voz que aquela de apenas amostrar a mesma em intervalos e representá-las por números. O vocoder, desenvolvido por Homer Dudley no Bell Laboratories, em 1936, é um exemplo deste tipo de abordagem.

Pode-se também abordar a matéria de estrutura dos dados por outras formas. Por exemplo, as características do receptor dos dados pode ser levada em conta na compressão. No caso do ser humano, a percepção da voz e imagem tem limitações que podem ser aproveitadas na compressão destes sinais, como a limitação de frequência destes receptores biológicos.

Qual a necessidade básica a ser suprida pela compressão? A experiência mostra que a necessidade de armazenamento de informação no mundo cresce aproximadamente o dobro em relação à capacidade da tecnologia em aumentar a velocidade e/ou capacidade de armazenamento. As atividades humanas têm cada vez mais impacto no meio ambiente e a necessidade de se armazenar cada vez mais informações sobre todas as atividades do ser humano, da sociedade como um todo, do meio ambiente, de dados de cada ser humano, tanto no aspecto social como no físico e biológico, e o absurdo crescimento das comunicações entre as sociedades, faz cada vez mais necessário o desenvolvimento de novas técnicas de compressão de dados.

2.2. As Técnicas Atuais de Compressão

2.2.1. Introdução

Uma grande quantidade de publicações ocorreram nas últimas três décadas na área de compressão de dados de Eletrocardiograma (ECG).

Tais técnicas têm sido importantes na redução do volume de dados do referido sinal de ECG, tanto para transmissão quanto para armazenamento do mesmo. São aplicáveis nas áreas de diagnóstico e ambulatorial. Devido aos diferentes princípios utilizados e também diferentes procedimentos de avaliação dos mesmos, a comparação destas técnicas é bem difícil, trabalhosa, e em alguns casos a avaliação torna-se impossível, como será visto no decorrer deste texto. O propósito da compressão de dados é obter o máximo de compactação do volume de dados com a máxima preservação da morfologia do sinal, ou distorção mínima.

Técnicas de Compressão : Existem três grupos principais de técnicas de compressão utilizadas nesta área :

- a) Compressão Direta de Dados
- b) Métodos de Transformação
- c) Métodos de Extração de Parâmetros

Nas técnicas de Compressão Direta de Dados pode-se destacar :

- PCM diferencial (Differential Pulse Code Modulation)
- AZTEC (Amplitude Zone Time Epoch Coding)
- Turning Point
- CORTES (Coordinate Reduction Time Encoding System)
- Fan (apelido de “ventilador”)
- SAPA (Scan-Along Polygonal Approximation)
- Cycle to Cycle Compression
- Entropy Coding

As técnicas de Transformação se destacam :

- Fourier
- Walsh
- KLT (Karhunen-Loève)
- Harr
- DCT (Discrete Cosine Transform)
- Wavelet
- Principals Component Analysis

As de Extração de Parâmetros se destacam :

- Redes Neurais
- Fractais
- Métodos Sintáticos
- “Linear Prediction”
- Peak-Picking

2.2.2. Revisão

Jalaleddine [39] apresentou excelente trabalho que relata os princípios dos métodos citados na literatura desde 1973 até meados de 1988. Estendeu-se neste trabalho, a referida

revisão, então, deste estudo de 1989 até 1998, comentando as novas técnicas que surgiram nesta década e resumindo as que já constam no artigo de Jalaleddine [39] e finalmente se apresenta uma tabela que abrange mais de três décadas de trabalhos realizados na área de compressão de ECG.

Os primórdios da análise do sinal de ECG data de 1959, quando Scher e Young [71] analisaram o conteúdo de frequência do sinal de Eletrocardiograma. Também em 1960, Scher, Young e Meredith [72] analisaram o sinal de ECG por análise de componentes principais. Em 1964, Horan e cols [33] apresentaram um detalhado artigo explorando a análise de componentes principais do sinal de ECG. É muito interessante ler o artigo e sentir as dificuldades computacionais da época para realizar esta análise : digitalização “manual” do sinal, alimentação dos dados por cartão e redução das matrizes da análise a 20 pulsos de sinal por vez, “por causa de limitações do tamanho de memória do computador”. Estes artigos, apesar de não tratarem de compressão, são os principais trabalhos que, de alguma forma geraram a base da futura aplicação de técnicas de transformação em compressão de ECG. Em 1961, Holter [32] lançou a idéia de se gravar 24 horas de ECG como premissa para se observar anomalias em pacientes com sintomas difíceis de se observar na hora de um exame (de alguns minutos) em consultório.

Em 1964, Gardenhire [24] desenvolveu a técnica conhecida por “SAPA - Scan Along Polygonal Approximation” e também conhecida por Fan. Constitui-se de um interpolador de primeira ordem (FOI - 2 DF; First - order Interpolation with Two Degrees of Freedom). Obteve CR - Compression Ratio de 3,0 com erro PRD (Percentual Root Mean Square Difference) de 4%. Outros pesquisadores acrescentaram detalhes ao algoritmo, criando, por exemplo, o SAPA - 2, que é parecido com o algoritmo conhecido por Fan (ventilador), que também é um FOI - 2 DF (Barr e cols (1985) [8] publicaram nota que o SAPA - 2 e o Fan são equivalentes). A base teórica para os referidos algoritmos é que o desvio entre duas linhas retas (que se aproximam do sinal real) e o sinal original deve ser inferior a um certo erro ϵ , pré - determinado. O nome de “ventilador” (Fan), inclusive, vem destas duas retas com inclinações diferentes (que se cria em torno de pontos do sinal, os quais se quer aproximar pelas mesmas retas), dando a impressão de “linhas de ar” de um ventilador.

Em 1968, Cox e cols [19] lançaram o compressor conhecido como AZTEC - Amplitude Zone Time Epoch Coding; conhecido também como ZOI - Zero Order Interpolator; ele se baseia em pontos da amostra do ECG para gerar platôs e inclinações. Os valores são gerados por interpolações de ordem zero. Os valores armazenados de cada platô são sua amplitude e

tamanho da linha que foi interpolada entre os pontos, com uma “abertura” entre os pontos considerados dada por um fator “ ϵ ”. A produção de uma inclinação é gerada quando o número de amostras necessárias para criar um platô é menor que 3. Os valores armazenados da inclinação são a cota do último ponto desta inclinação. A expansão é realizada na ordem inversa ao descrito neste algoritmo. O resultado de compressão, “CR - Compression Ratio”, era de 10, porém com erro PRD de 28%. Produzia um sinal expandido inaceitável para a análise de um Cardiologista, pois o sinal ficava muito “quantizado”, isto é, com muitos degraus. Posteriormente, utilizou-se a técnica de filtragem para “amaciar” um pouco esta resposta.

Em 1973, Cox e Ripley [18], apresentaram trabalho explorando um codificador DPCM - Differential Pulse Code Modulation, cujos códigos eram classificados em “frequentes” e “infrequentes”. Os códigos “frequentes” foram classificados por Huffman, enquanto os códigos “infrequentes” tiveram palavra com tamanho fixo. Obtiveram CR de 2,8 mas não apresentaram um índice de erro para se concluir sobre sua relação qualidade-performance.

Ainda em 1973, Stewart e cols [75], desenvolveram técnica DPCM alterada, onde se comprimia 3 canais de ECG. Quando o valor absoluto da diferença entre pares adjacentes de amostras, em qualquer um dos 3 canais de ECG, excede um limiar pré-determinado, os dados são salvos. Obteve CR de 4,0 sem calcular o erro resultante.

Em 1975, Ahmed e cols [2], aplicaram as transformadas KLT - Karhunen - Loève Transform, CT - Cosine Transform e HT - Haar Transform, a sinais de ECG de cães. A melhor compressão foi obtida com a KLT, com CR de 3,0 também sem especificar erro.

Em 1977, Womble e cols [84] utilizaram a transformada KLT em sinal de VCG (Vetorcardiograma), dividindo o sinal em ondas P e complexo QRST, aplicando separadamente a transformada em cada uma das partes. Obteve CR de 12,0 sem reportar o erro obtido.

Em 1978, Mueller [54], se utilizou da técnica intitulada TP - “Turning-Point”, que processa três pontos do sinal por vez, onde um ponto é referência e os outros dois consecutivos terão análise de sua inclinação. Um deles será descartado em função do mesmo não se alinhar com a inclinação dada pelos próprios três pontos em questão. A compressão é fixa em 2 para 1. O erro PRD obtido foi de 5,3%, provavelmente porque os pontos salvos não representam intervalos de tempo igualmente espaçados.

Em 1979, Ruttinmann e Pipberger [69], se utilizaram do DPCM associado a predição linear, obtendo resultados melhores com predição linear de segunda ordem. Obteve CR de 7,8 com erro PRD de 3,5%.

Em 1980, Krishnakumar e cols [44], também realizaram um DPCM com predição linear ; obteve CR de 2,5 sem citar o erro associado.

Em 1982, Abenstein e Tompkins [1], desenvolveram o algoritmo intitulado CORTES - Coordinate Reduction Time Encoding System, que é um híbrido do AZTEC e do TP. O algoritmo TP é aplicado nas regiões de alta frequência (complexo QRS) enquanto o AZTEC é aplicado nas outras regiões, de baixa frequência. Os dois algoritmos são aplicados em paralelo e a decisão de utilização de um ou outro algoritmo é baseada no comprimento da palavra gerada pelos mesmos. Obteve CR de 4,8 com PRD de 7,0%.

O que se pode dizer dos trabalhos desenvolvidos até a década de 80 é que eles foram bem frutíferos na área de compressão direta de dados e, quem sabe se utilizando menos dos métodos de transformação devido ao alto custo computacional que as mesmas exigiam. Na década de 90, com o advento dos chips DSPs e inclusão prática de novas técnicas matemáticas no contexto de processamento de sinais, (RNA, Wavelet, Fractal, Fuzzy, etc) foi possível aos pesquisadores ampliarem mais a área de métodos de transformadas, inclusive, associando-se aos de compressão direta de dados, criando algoritmos extremamente sofisticados, utilizando-se em muito dos processos a adaptação em tempo real.

Ainda, porém, se continua utilizando, em 1999, as técnicas tradicionais de compressão direta de dados : Mammed e Ramamurthi [50] utilizaram-se da técnica de Quantização Vetorial de sinais multicanais de ECG. Primeiro o sinal de ECG é codificado com o algoritmo AZTEC estendido para vários canais (denominado m-AZTEC, multichannel AZTEC), onde a forma de onda é aproximada por linhas e ângulos e os “N” canais são codificados simultaneamente em uma seqüência de “N+1” vetores dimensionais, explorando a correlação que existe entre estes canais em relação aos parâmetros “duração” do AZTEC e utilizando juntamente a quantização vetorial classificada para otimizar o parâmetro “valor” do AZTEC. Eles obtiveram um “CR” (Compression Ratio) de 8,6 a uma frequência de amostragem de 200 Hz a 12 bits, com “PRD” (Percentual Root Mean Square Difference) de 24,5%. Não se utilizaram de uma base de dados para a avaliação e só mostraram resultados com pulsos extremamente regulares.

Hamilton e Tompkins [28] se utilizaram da subtração entre pulsos correntes do ECG e um pulso “médio” de ECG obtido dos próprios pulsos correntes. Em seguida é executada a primeira diferença do dado residual. Eles obtiveram resultados satisfatórios, com CR médio de 4,6 a uma frequência de amostragem de 100 Hz a 8 bits, com erro RMS de $11\mu V$. O trabalho é bem detalhado, utiliza a base de dados do MIT/BIH para a avaliação de desempenho, e

demonstra que este processo é importante, inclusive como pré-tratamento do sinal, para aplicação junto a outras técnicas de compressão.

Philips e Jonghe [63] exploraram a técnica de aproximação polinomial de ordem elevada. Eles expandiram o sinal de ECG por aproximação polinomial, chamando-as de “Polynomial Transform”. O sinal de ECG é analisado em cada período, onde é representado por um polinômio, e o esforço de aproximação é concentrado no complexo QRS e seu posicionamento relativo. Eles obtiveram um CR de 15, em uma frequência de 500 Hz a 10 bits, obtendo erro RMS de $15 \mu\text{V}$, que é excelente resultado. O problema é que eles não testaram exaustivamente o algoritmo com alguma base de dados e aparentemente o desempenho foi medido em relação a sinais bastante regulares no que se refere a período e morfologia.

Iwata e Cols [37] se utilizaram de Rede Neural Artificial (RNA) e processo adaptativo para extrair, através da camada escondida da RNA, a informação comprimida. A adaptabilidade se encontra no julgamento em “tempo real” do erro entre o sinal recuperado em relação ao original. Se o referido erro é crescente, uma segunda RNA inicia o novo aprendizado e substitui a anterior. Se o erro momentâneo é “enorme”, o sistema decide salvar estes “pulsos originais” no arquivo, sem qualquer compressão. A RNA é uma “Multilayer Perceptron”, com três camadas, sendo as entradas e saídas iguais, e que também é conhecida como auto-associador (Haykin [30]). O sistema ensina a rede com o pulso de ECG, com as entradas iguais às saídas (com 70 entradas e 70 saídas). A camada escondida tem apenas 2 neurônios de onde se extrai a compressão. Ele amostra o pulso de ECG em razões diferentes, sendo que o complexo QRS é o mais “detalhado”. Os resultados são “surpreendentes”, com CR de 15 a 100, a uma frequência de 100 Hz a 12 bits e erro RMS de 0,1% a 0,5%, avaliados com a base de dados do MIT/BIH [52].

McAuliffe [51] se utilizou de uma RNA do tipo Kohonen para criar um dicionário otimizado de vetores. Esta rede de Kohonen, não supervisionada, criou então este dicionário. O processo de compressão é controlado por medida de distância entre o vetor original e o vetor do dicionário que mais se aproxima do vetor original. O CR médio é de 8, e o autor não especificou a frequência de amostragem nem o número de bits de amostragem. O erro típico é de $17 \mu\text{V}$ RMS. Ele não utiliza base de dados para avaliação de seu algoritmo e ainda, aparentemente, só o testou com sinais regulares.

Tai [76] se utilizou da técnica de detecção baseada em interpolação linear entre os segmentos gerados pelas amostras selecionadas do sinal. As amostras que estão distantes do sinal codificado são especificadas por um grau de erro e então codificadas. Assim, regiões onde o

sinal varia rapidamente são codificadas com maior precisão. Obteve-se CR de 0,79 bits por amostra, porém com frequência de amostragem e resolução não especificadas, obtendo erro PRD de 0,2%, que não permite concluir sobre seu desempenho. O algoritmo foi testado com a MIT/BIH database [52] e base de dados do “Veterans General Hospital”.

Philips [62] se utiliza de técnica conhecida por “Time-Warped Polynomials”, aparentemente desenvolvida pelo próprio autor, onde ele apresenta uma classe de bases ortogonais, cujas funções de base e seus coeficientes dependem do tempo. Elas podem ser variadas no tempo, afim de acompanhar as mudanças que ocorrem no período do sinal de ECG. Ele obteve excelentes resultados com CR variando de 17 a 30, com frequência de amostragem de 500 Hz a 10 bits, com erro RMS de 12 μ V a 16 μ V. Ele não se utiliza de uma base de dados para avaliação do algoritmo e mostra apenas sinais com “bom” comportamento.

Nave e Cohen [56] se utilizam de predição de longo prazo para realizar a compressão. Sua predição é baseada em modelo auto-regressivo, mais especificamente a “SAR” - Subset Autoregressive Model. Ele explora a repetitividade do “pulso” de ECG, além da correlação entre as amostras adjacentes, e depois codifica os resíduos com quantização adaptativa e código de Huffman. Obteve um CR médio de 11,7 para um PRD de 8,0% e não se utilizou de uma base de dados conhecida para a avaliação (usa base de dados própria).

Cetin e cols [15], se utilizaram de processamento de razão variável (Multirate Processing) e da Transformada DCT (Discrete Cosine Transform) e KLT (Karhunen-Loève Transform) para comprimir ECG de múltiplas derivações. De 12 derivações, se reduz a 8, devido ao fato das derivações III, AVR, AVL e AVF serem composição linear das derivações I e II. Assim, com as derivações I, II, V1, V2,...V6, o sistema trabalha em ordem crescente de correlação. Aplica-se a seguir, para cada canal, as transformadas KLT e DCT em cada sinal (a fim de compará-las neste algoritmo). As transformadas, então são divididas em dois grupos de energia (alta e baixa). As de alta energia são comprimidas pela técnica “Subband Coding”. As de baixa energia são comprimidas pela técnica “Multirate Transform Coding”. A DCT traz resultados um pouco inferiores, porém com menor custo computacional. Obteve-se, com sinais não provenientes de base de dados, resultados com CR de 4 a 8 e PRD de 3,7% a 6,2%. É um esquema bastante complexo, com performance média.

Konstantinides e Natarajan [43] se utilizaram de aproximação linear por retas denominado “Piecewise - Linear Approximation” , com um erro de aproximação programável de 30 mV e utilizam um sinal de ECG de 750 mV de pico. O algoritmo é preparado para implementação em um DSP mas que, aparentemente, até a data de publicação, não tinha sido

realizado. Não apresenta testes com sinais típicos e não especifica qualquer tipo de medida de erro.

Al-Nashash [4][3], utilizou-se da técnica de Fourier, onde os coeficientes da Transformada de Fourier são determinados de modo adaptativo, em função da mudança da morfologia do ECG. Um detector de erro quadrático atua nos ajustes dos coeficientes da transformada, incluindo um fator de estabilidade do processo. Obtém um CR típico de 16 e PRD de 3%, só que se utiliza de sinal de ECG gerado por software e, aparentemente, sem extensiva experimentação.

Anant e cols [5], se utilizaram da Transformada Wavelet, onde os coeficientes da mesma são, após sua obtenção, codificados por quantização vetorial. Os resultados parecem ser ótimos, porém o autor não especifica o “rate” inicial utilizado e conclui que obteve rates de 1,1 a 1,5 bits/sample, com erro PRD de 4,8% a 5,5%. Ele se utiliza da base de dados do MIT/BIH. Se ele, como hipótese, utilizou-se do arquivo original, tem-se “rate” de 11 bits/sample e então um CR de 7,3 a 10.

Provaznik e Kozumplik [64], também se utilizaram da Transformada Wavelet para obter coeficientes tal que, aqueles que tem pequena influência, são descartados. Os coeficientes mais significativos são, então, codificados por entropia, segundo Huffman. O resultado é de um CR de 9,2 com um PRD de 3,0%, próximo dos resultados de Anant e cols[5]. Se utiliza da base de dados da CSE para análise do desempenho.

Oien e cols [59], se basearam em fractais para realizar compressão de ECG. A compressão por Fractais para realizar compressão de ECG se baseia na auto-similaridade de um “bloco de dados”. Os parâmetros extraídos são codificados por quantização vetorial. Obtém-se CR de 5,5 com PRD de 4,5%. Se utiliza da base de dados do MIT/BIH para avaliação destes resultados.

Lee e Yoon [47], se utilizaram da transformada Wavelet e de interpolação por Fractais para realizar a compressão. O artigo não é detalhado. Obtém CR de 10,6% e não especifica o PRD obtido. Se utiliza da base de dados do MIT/BIH.

Tuzman e cols [79], também se utilizaram da Transformada Wavelet. Eles constroem um dicionário de batimentos cardíacos e codificam cada batimento “parecido” como sendo um código de acesso a este dicionário. Os batimentos com morfologia fora do dicionário, são incluídos progressivamente no mesmo. O dicionário é decomposto por Wavelet e assim armazenado. Cita um CR de 30, porém resultado apenas obtido com sinais regulares. Não cita o PRD em função deste CR e nem mostra resultados visuais com um sinal típico de

ECG. Também não usa base de dados, e portanto não se pode concluir nada a priori.

Ribbum [67], se utiliza de predição linear, especificamente a “Code Excited Linear Prediction” para realizar compressão. Ele realiza a quantização “LP” e cria um dicionário de vetores para codificar o sinal, baseado em erro quadrático. Se o erro é muito grande, se requantifica o referido sinal em relação a vetores do dicionário de “tamanho reduzido”, diminuindo o “bit-rate”. Obtém-se CR de 5,2 com PRD de 7,6%. Se utiliza da base de dados do MIT/BIH para a referida análise.

Hilton [31], se utiliza de “Wavelet por Pacotes” (Packet Wavelet) para realizar compressão. Se utiliza da Wavelet conhecida por Embedded Zerotree Wavelet, EZW, aplicando-a em “blocos” de amostras de sinal de ECG. Usando Wavelet com coeficiente 4, obtém resultados excelentes, com CR variando de 8 a 24 e respectivo PRD de 0,22% a 1,62%, que é extremamente satisfatório.

Nave e Cohen [56], se utilizaram de análise por síntese como técnica de compressão de sinais de ECG. Consiste de um dicionário de pulsos de ECG, preditores de curto e longo prazo e quantizador residual adaptativo. Obtém-se um “rate” de 100 bits/s só que não declara a rate inicial. Obtém-se PRD de 8% e se utiliza da base de dados do MIT/BIH. Ele introduz comparação de erro em relação a uma nova medida de erro, proposta pelo autor, chamada “WDD” - Weighted Diagnostic Distortion, que não é utilizada por nenhum outro pesquisador.

Olmos e cols [60], se utilizaram da Transformada Karhunen-Loève, KLT, e quantização escalar para realizar compressão. A quantização dos coeficientes é adaptativa-preditiva, em função da periodicidade e morfologia dos pulsos de ECG. Obtém CR de 22 com PRD médio de 1,2%, que é um excelente resultado. Se utiliza da base de dados do MIT/BIH, porém não mostra resultado visual de um sinal recuperado com a referida técnica.

Tuzman e cols [80], se utilizaram da transformada Wavelet, para cada batimento cardíaco, que minimiza uma função de custo. Constrói-se dois dicionários, um dos batimentos e outro das respectivas transformadas. Os batimentos são classificados em normal e anormal, através do dicionário da transformada. Uma Rede Neural é treinada para classificar os batimentos em função das Wavelets obtidas. Então, a informação é quantizada. Obtiveram CR da ordem de 30, porém sem informar o respectivo PRD, que impede conclusões ou comparações. Também não utiliza base de dados para sua avaliação e nem mostra resultados visuais de algum sinal recuperado.

Cassen e English [14], se utilizaram de quantizador não linear e primeira diferença para

realizar compressão. Primeiramente é realizada a diferença de primeira ordem, e após se aplica quantização não-linear, cuja função de transferência foi baseada em minimização da entropia da função de densidade de probabilidade do sinal de ECG. Finalmente os valores quantizados são codificados por Huffman. Obtém-se um CR médio de 6,3 com PRD de 2 %. Não se utiliza de base de dados reconhecida para avaliação.

Lee e Buckley [46], se utilizaram de transformada em duas dimensões para realizar compressão. Os batimentos cardíacos são alinhados pelo complexo QRS, formando um arquivo 2-D. Aplica-se então a transformada “2-D” Discrete Cosine Transform (ou 2-D DCT) em blocos variáveis, sendo que o de tamanho 32x32, produziu o melhor resultado. Aplica-se então um valor de limiar, abaixo do qual os coeficientes da DCT são descartados. Após, os coeficientes restantes são então codificados. Com esta técnica, se obteve CR de 4 a 96, com respectivos PRDs de 2,2% a 14%. Mostra excelentes resultados, utilizando-se da base de dados do MIT/BIH [52].

Nguyen-Phi e Weinrichter [57], se utilizaram da Transformada Wavelet e codificação binária aritmética para compressão. O sinal de entrada é dividido em certo número de blocos que são transformados separadamente e depois codificados por um “Binary Arithmetic Coder”. Obtiveram CR de 2,5 a 20, com respectivos PRD de 1 a 8%. Se utilizaram da base de dados do MIT/BIH [52] para esta avaliação.

Blanchett e cols [13], se utilizaram da técnica conhecida por “Multirate Sampling” controlada por um fator de qualidade dado pela transformada KLT. A razão de amostragem é dada (para cada bloco de 200 batimentos) pela sua função de densidade espectral, de três partes do sinal : o bloco dos segmentos PQ, dos segmentos QRS e finalmente do ST. O número de coeficientes da transformada retidos pelo algoritmo é dependente da média RMS de erros relativa aos três blocos citados, calculada quando se recupera o sinal apenas com estes coeficientes retidos. Vale observar que a razão de amostragem é a mínima possível e diferente para cada bloco do sinal. Obteve um CR de 30 a 40 mas não especificou erro PRD nem mostrou nitidamente uma amostra do sinal recuperado. Utiliza a base de dados do MIT/BIH [52] para avaliação.

Cohen e Zigel [17], aplica a técnica de predição a longo prazo, agora aplicado a ECG multicanal. É a mesma técnica citada, nesta revisão, deste mesmo grupo (vide Nave [56]) aplicado à multicanal. Obteve um rate de 166 bits/s, mas não especificou o rate inicial para se calcular o CR. O PRD obtido é de 7,1%. Se utiliza da base de dados do MIT/BIH [52] para avaliação. A seguir apresenta-se as Tabelas 2.1, 2.2, 2.3 e 2.4, resumindo as propriedades

básicas dos compressores aqui citados. Os quadros das tabelas com o símbolo “?” representam que o dado não estava disponível no referido artigo. Os artigos que utilizam a medida de “erro PRD” o descrevem como :

$$\text{PRD} = \sqrt{\frac{\sum_{i=1}^n (x_{\text{org}}(i) - x_{\text{rec}}(i))^2}{\sum_{i=1}^n x_{\text{org}}^2(i)}} \times 100,$$

onde : x_{org} amostra o sinal original e x_{rec} amostra o sinal recuperado.

O cálculo da Razão de Compressão ou “Compression Ratio-CR” é simplesmente a relação entre o tamanho do arquivo do sinal original, dividido pelo tamanho do arquivo do sinal comprimido :

$$\text{CR} = \frac{\text{Número de bits do sinal original}}{\text{Número de bits do sinal compactado}}$$

Método	CR	Sample Freq. Hz / bits	μ Vrms or PRD%	Obs. :	Ref/data
Ortogonal Tranforms KLT, HT	3,0	400/?	?	Dogs ECG's	[2] 1975
Fourier Descriptors	7,4	250/12	7,0%	52 subjects, 10s records ECGs	[66] 1986
KLTransformations	12,0	250/12	?	?	??[18] 1977
DPCM - Linear Prediction and Entropy coding	7,8	500/8	3,5%	Veterans Administration Hospital (W.DC) 10s ECGs random samples	[69] 1979
DPCM - Linear Prediction	2,5	250/12	?	?	[44] 1980
DPCM - Delta Coding with Threshold	4,0	1000/8	?	"(?) Digitized ECG"	[75] 1973
Spline peak-picking with Entropy	10,0	500/8	14,0%	?	[34] 1985
Second - difference Entropy Coding	2,8	250/10	?	?	[18] 1973
AZTEC	10,0	500/2	28,0%	?	[19] 1968
Turning Point	2,0	200/12	5,3%	?	[54] 1978
SAPA	3,0	250/?	4,0%	?	[24] 1964

Tabela 2.1: Comparação entre várias técnicas de compressão de ECG

Método	CR	Sample Freq. Hz / bits	μV_{rms} or PRD%	Obs. :	Ref/data
CORTES	4,8	200/12	7,0%	?	[1] 1982
Neural Network Adaptive	15 to 100	100/12	0,1 a 0,5 % μV	MIT/BIH Database	[37] 1990
Classified Vector Quantization (VQ-codec m-AZTEC)	8,6	200/12	24,5%	12 minutes Holter tapes – multichannel	[50] 1990
Average Beat Subtraction and Residual Differencing	Average 4,6	Equival. To 100/8	11 μV	MIT/BIH Database	[28] 1991
High-Degree Polynomial Approximation	Medium 15	500/10	15 μV	Not use Database	[63] 1992
Kohonen Neural Network Vector Quantization	Medium 8	?	17 μV	Exercise ECGs	[51] 1992
Corner Detection	0,79 bits /sa	?	0,2%	MIT/BIH Database and Veterans Gen-Hosp ECG's	[76]1992
Optimaly time – Warped polynomials	17/ 30	500/10	16/12 μV	ECG of 42 patients	[62] 1993
Long – Term Prediction	11,7	250/10	8,0%	40 ECG records /I.C. Unit	[56] 1993

Tabela 2.2: Comparação entre várias técnicas de compressão de ECG

Método	CR	Sample Freq. Hz / bits	Vrms or PRD%	Obs. :	Ref/data
Multilead ECG with multirate Processing and Transf. Domain Techniques	4/8	500/12	3,7/6,2 %	12 ECG signals	[15] 1993
Piecewise – Linear Approximation	Medium 11	?	?	1000 ECG Data Samples	[43] 1994
Fourier Adaptive Coeff. Estimation	Medium 16	500/?	3%	“Software Simulated ECG”	[3][4] 1994,1995
Vector Quantization of Wavelet Coeff.	10?	360/12?	4,8% / 5,5%	MIT-BIH Database 100ECG Segments	[5] 1995
Wavelet – Based	9,2	500/8	3%	CSE library 125 rest records	[64] 1996
Fast Fractal - Based	5,5	360/12	4,5%	MIT-BIH Database	[59] 1996
Wavelet and Fractal Interpolation	10,6	200/12	?	MIT-BIH Database	??[29] 1996
Wavelet Based	30?	200/?	?	Not Signal Shown : 24 hours Holter	[79] 1996
Code Excited linear Prediction – CELP	5,2	360?/12	7,6%	MIT-BIH Database	[67] 1996
Wavelets and Wavelet Packed compression	8 to 24	360/11 and 250/12	0,22% to 1,62%	MIT database and Creighton Univ. Ventr. Tach. Database	[31] 1997

Tabela 2.3: Comparação entre várias técnicas de compressão de ECG

Método	CR	Sample Freq. Hz / bits	Vrms or PRD%	Obs. :	Ref/data
Analysis by Synthesis Adaptive	?? (100 bits /s)	?	< 8%	MIT-BIH Database	[85] 1997
Adaptative Quantizers and Orthogonal transforms	medium 22	?	medium 1,2%	MIT-BIH Database	[60] 1997
Wavelet Basis-Neural Network Classification	medium 30	200/8	?	?	[80] 1997
Non-linear Quantizer	Medium 6,3	125/8	2%	"150 ECG recordings"	[14] 1997
2-D Discrete Cosine Transform	4 to 96	250/12	2,2% to 14%	MIT-BIH Database; Meditronic Database	[46] 1997
Wavelet Transform and Binary Aritmetic Coding	2,5 to 20	?	1% to 8%	MIT-BIH Database	[57] 1997
KLT - Based Quality Control and Multirate Sampling	30 to 40	360/?	?	MIT-BIH Database : 10 minutes segments	[13] 1998
Multichannel Long-term Prediction	? (166 bits/s)	250?/?	7,1%	MIT/BIH Database	[17] 1998
Scan-Along Polygonal Approximation	10	250/12?	?	AHA Arrhythmia Database	[35] 1983
AZTEC with Variable Threshold	5,8	500/8	5,4%	?	[23] 1988

Tabela 2.4: Comparação entre várias técnicas de compressão de ECG

Capítulo 3

Levantamento Experimental da Rate Distortion Function $R(D)$ para Sinais de ECG do Tipo Ambulatorial

3.1. Fundamentos da compressão, do desempenho, do erro, do grau de compressão e da fidelidade

3.1.1. Técnicas de Compressão

As técnicas ou algoritmos de compressão podem ser divididos em duas grandes áreas :

- Compressão sem perda de informação.
- Compressão com perda de informação.

A compressão sem perdas é bastante aplicada em compressão de textos e em bancos de dados, onde uma pequena distorção da informação pode representar uma grande alteração no significado contextual.

A compressão com perdas se aplica onde a informação perdida pode ser recuperada parcialmente ou onde a distorção da informação não é significativa ou comprometedora. É onde se obtém o maior grau de compressão. Isto se aplica a inúmeras áreas como processamento de voz, vídeo, sinais biológicos e onde existem inúmeras técnicas a serem exploradas, depen-

dendo das características específicas de cada sinal em consideração.

Medida de Desempenho

A medida de desempenho utilizada normalmente é a razão de compressão (Compression Ratio, CR) que é a razão entre o número de bits necessário para representar os dados antes da compressão com relação ao número de bits necessários para se representar os dados após a compressão. Porém, esta medida isolada pode dizer pouco em certos casos. Tem-se então que associar esta importante medida a outros fatores, como quão complexa é a implementação do algoritmo, a memória requerida para a implementação, a rapidez de execução do algoritmo em uma certa máquina, a distorção introduzida na informação, a fidelidade e qualidade do sinal reconstruído e outras mensurações específicas de propriedade de cada tipo de sinal a ser comprimido.

Outra maneira de se mensurar a razão de compressão é obter o número médio de bits necessários para representar uma única amostra. Esta medida é conhecida como “Rate.”

3.1.2. Fundamentos

Antes de se abordar o assunto da compressão da informação, deve-se fundamentar a mensuração da informação em si. Claude Elwood Shannon [73], fundamentou este importante aspecto da teoria da informação.

Seja A um evento de saída de um experimento aleatório. Se $P(A)$ é a probabilidade deste evento A ocorrer, então a auto-informação associada com o evento A é dada por :

$$i(A) = \log_x \frac{1}{P(A)} = -\log_x P(A)$$

Como se sabe, $\log(1) = 0$ e $-\log(\omega)$ aumenta quando “ ω ” decresce de “1” para “0”. Isto é, se a probabilidade de um evento é baixa, a quantidade de auto-informação associada a este evento é alta, o que é bastante intuitivo.

Também, se dois eventos são independentes, “ A ” e “ B ”, a auto-informação associada à

ocorrência do evento “A” e do evento “B” será :

$$\begin{aligned} i(AB) &= \log_x \frac{1}{P(AB)} = \log_x \frac{1}{P(A)P(B)} = \\ &= \log_x \frac{1}{P(A)} + \log_x \frac{1}{P(B)} = i(A) + i(B) \end{aligned}$$

A unidade de informação depende da base “x” do logaritmo.

Se utiliza-se a base “2”, tem-se “bits”, com a base “e”, tem-se “nats” e base “10”, tem-se “hartleys”.

Para trabalhar com compressão que envolve perdas, é importante rememorar o conceito de Entropia Condicional :

Seja X uma variável aleatória independente, uniformemente distribuída, que toma valores de uma fonte alfabética $X = \{x_0, x_1, \dots, x_{N-1}\}$. Seja Y uma variável aleatória, uniformemente distribuída, que toma valores de um alfabeto de reconstrução : $Y = \{y_0, y_1, \dots, y_{M-1}\}$.

As entropias da fonte e da reconstrução serão dadas por, assumindo-se unidade de informação binária :

$$H(x) = - \sum_{i=0}^{N-1} P(x_i) \log_2 P(x_i)$$

e

$$H(y) = - \sum_{j=0}^{M-1} P(y_j) \log_2 P(y_j)$$

onde $-\log_2 P(x_i)$ e $-\log_2 P(y_j)$ representam a auto-informação associada aos eventos “ x_i ” e “ y_j ”.

Estas medidas, desenvolvidas por Shannon, implicam que a entropia é uma medida do número médio de símbolos binários necessários para a codificação da saída da fonte.

No caso de compressão com perdas, deve-se rever os eventos “A” e “B”, agora já citados como eventos dependentes.

A auto-informação contida no evento “A”, dado que um evento “B” ocorreu, será :

$$i(A | B) = \log_2 \frac{1}{P(A | B)} = -\log_2 P(A | B).$$

A entropia associada, chamada de entropia condicional será :

$$H(X | Y) = - \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} P(x_i | y_j) P(y_j) \log_2 P(x_i | y_j)$$

e

$$H(Y | X) = - \sum_{j=0}^{M-1} \sum_{i=0}^{N-1} P(y_j | x_i) P(x_i) \log_2 P(y_j | x_i)$$

A interpretação é que a entropia condicional é a medida da quantidade de incerteza sobre a variável aleatória “X”, a saída da fonte, dado que se sabe qual foi o valor obtido em “Y”, que é a saída da reconstrução.

O conhecimento adicional de “Y” deverá reduzir a incerteza sobre “X”, e pode ser mostrado que :

$$H(X | Y) \leq H(X).$$

No caso de base binária, a entropia condicional indica em quantos bits reside a incerteza sobre a fonte “X”.

Outra definição útil é a “Informação Média Mútua”. Lembrando a definição de quantidade de informação mútua :

$$I(x_i; y_j) = \log_2 \left[\frac{P(x_i | y_j)}{P(x_i)} \right],$$

tem-se a quantidade de informação média mútua dada por :

$$\begin{aligned} I(X; Y) &= \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} P(x_i; y_j) \log_2 \left[\frac{P(x_i | y_j)}{P(x_i)} \right] \\ &= \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} P(x_i | y_j) P(y_j) \log_2 \left[\frac{P(x_i | y_j)}{P(x_i)} \right] \\ &= \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} P(x_i | y_j) P(y_j) \log_2 P(x_i | y_j) - \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} P(x_i | y_j) P(y_j) \log_2 P(x_i) \\ &= H(X) - H(X | Y) = I(Y; X) \end{aligned}$$

Até agora, no caso, assume-se um alfabeto discreto. No caso de técnicas de compressão com perdas, deve-se alterar um pouco o enfoque.

Suponha que a fonte agora é uma variável aleatória contínua com distribuição contínua. Note que, se a variável é aleatória e contínua, a quantidade de auto-informação será :

$$i(x_i) = \log \frac{1}{P(x_i)} = \log \frac{1}{0} = \infty$$

que limita a aplicação direta da fórmula.

Então, para reinterpretar os conceitos de Informação e Entropia, deve-se discretizar a variável contínua, isto é, nossa variável definida no intervalo “ Δ ”. Tem-se, pelo Teorema do Valor Médio :

Em cada intervalo $[(i-1)\Delta, i\Delta]$, existe um número x_i tal que :

$$f_x(x_i)\Delta = \int_{(i-1)\Delta}^{i\Delta} f_x(x) dx$$

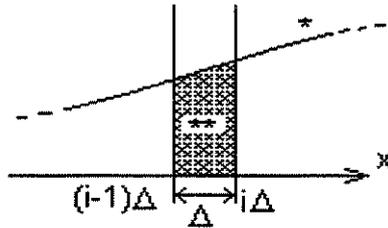


Figura 3.1: Ilustração do Teorema do Valor Médio.

Seja agora, uma variável discreta “ X_d ”. com função de distribuição de probabilidade $f_x(x_i)\Delta$. Então, pode-se dizer que :

$$P(X_d = x_i) = f_x(x_i)\Delta$$

Agora, pode-se aplicar novamente o conceito de entropia :

$$\begin{aligned} H(X_d) &= - \sum_{i=-\infty}^{\infty} P(x_i) \log_2 P(x_i) = - \sum_{i=-\infty}^{\infty} f_x(x_i)\Delta \log_2 f_x(x_i)\Delta \\ &= - \sum_{i=-\infty}^{\infty} f_x(x_i)\Delta \log_2 f_x(x_i) - \sum_{i=-\infty}^{\infty} f_x(x_i)\Delta \log_2 \Delta \\ &= - \sum_{i=-\infty}^{\infty} [f_x(x_i) \log_2 f_x(x_i)]\Delta - \log_2 \Delta \end{aligned}$$

Se $\Delta \rightarrow 0$, tem-se :

a) O primeiro termo :

$$H(X_d) = - \int_{-\infty}^{\infty} f_x(x) \log f_x(x) dx$$

está bem próximo da definição de entropia de fontes discretas.

b) O segundo termo : “ $-\log \Delta$ ”, irá para o infinito, que difere da conceituação de entropia discreta.

De qualquer modo, o primeiro termo da equação servirá como medida similar à entropia de casos discretos, sendo denominado Entropia Diferencial, de uma fonte contínua, dada por $h(x)$:

$$h(x) = - \int_{-\infty}^{\infty} f_x(x) \log_2 f_x(x) dx$$

Se a fonte é contínua e uniformemente distribuída no intervalo $[a, b]$, tem-se :

$$h(x) = - \int_a^b \frac{1}{b-a} \log_2(b-a) dx = \log_2(b-a).$$

Observe que se “ $b - a$ ” for menor que 1, a entropia diferencial torna-se negativa, enquanto que a entropia discreta nunca apresenta valores negativos.

Entropia Diferencial de Fonte com Função de Densidade de Probabilidade Gaussiana

Suponha que temos uma função com “fdp” dada por :

$$f_x(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp -\frac{(x-\mu)^2}{2\sigma^2}$$

A entropia diferencial será dada por :

$$\begin{aligned} h(x) &= - \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp -\frac{(x-\mu)^2}{2\sigma^2} \cdot \log_2 \left[\frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp -\frac{(x-\mu)^2}{2\sigma^2} \right] dx \\ &= - \log \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \int_{-\infty}^{\infty} f_x(x) dx + \int_{-\infty}^{\infty} \frac{(x-\mu)^2}{2\sigma^2} \cdot \log_2 e \cdot f_x(x) dx \\ &= \frac{1}{2} \log_2(2\pi\sigma^2) + \frac{1}{2} \log_2 e \\ &= \frac{1}{2} \log_2(2\pi e\sigma^2) \end{aligned}$$

Observe que a entropia diferencial de uma variável aleatória Gaussiana é diretamente proporcional à sua variância.

Pode-se provar (Berger [10]) que a função Gaussiana de variância σ^2 gera a maior entropia diferencial entre funções aleatórias com outras distribuições e mesma variância, isto é :

Seja uma variável aleatória “ X ”, com variância “ σ^2 ”, $h(x)$ terá como limite :

$$h(x) \leq \frac{1}{2} \log_2 (2\pi e \sigma^2)$$

Seja uma outra variável discreta “ Y_d ”, como já foi definido “ X_d ” anteriormente. É possível mostrar que :

$$H(X_d | Y_d) = - \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} [f_{X|Y}(x_i | y_j) \cdot f_Y(y_j) \cdot \log_2 f_{X|Y}(x_i | y_j)] \cdot \Delta \cdot \Delta - \log_2 \Delta$$

Sabe-se que, a informação mútua de duas variáveis aleatórias será dada por :

$$\begin{aligned} I(X_d; Y_d) &= H(X_d) - H(X_d | Y_d) \\ &= - \sum_{i=-\infty}^{\infty} f_X(x_i) \cdot \log_2 f_X(x_i) \cdot \Delta \\ &\quad + \sum_{i=-\infty}^{\infty} \left[\sum_{j=-\infty}^{\infty} [f_{X|Y}(x_i | y_j) \cdot f_Y(y_j) \cdot \log_2 f_{X|Y}(x_i | y_j)] \cdot \Delta \right] \cdot \Delta \end{aligned}$$

Observe que as expressões “ $\log_2 \Delta$ ” em $H(X_d)$ e $H(X_d | Y_d)$ se cancelam, e como $H(X)$ e $H(X | Y)$ não são iguais a infinito, quando se faz $\Delta \rightarrow 0$ em $I(X_d; Y_d)$, obtém-se :

$$I(X; Y) = h(X) - h(X | Y),$$

isto é, a informação mútua média no caso contínuo pode ser obtida pelo limite da informação mútua média no caso discreto e tem o mesmo significado físico.

Teoria da Razão de Distorção (Rate Distortion Theory)

A Teoria da Razão de Distorção é dedicada a se obter um compromisso entre a “Distorção” e o “Rate” em esquema de compressão com perdas.

O “Rate” é definido como o número médio de bits usado para representar cada valor amostrado. Uma maneira de representar o compromisso entre o “Rate” e a Distorção é a função da Razão de Distorção, “Rate Distortion Function”, $R(D)$.

$R(D)$, especifica o menor “Rate” no qual a saída de uma fonte pode ser codificada mantendo a distorção menor ou igual à D .

Sabemos que D é dada por (Sayood [70]) :

$$D = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} P(y_j | x_i) P(x_i) d(x_i; y_j)$$

onde : $d(x_i; y_j)$ é a medição de distorção entre “ x_i ” e “ y_j ”, medida esta que é definida para cada aplicação específica.

Note que, dada uma função de densidade de probabilidade $\{P(x_i)\}$ e uma medida específica de distorção $d(x_i; y_j)$, tem-se :

$$D = D \{P(y_j | x_i)\},$$

isto é, a distorção é função apenas da função densidade de probabilidade condicional em questão.

Isto implica que a restrição da distorção “ D ” ser menor que um certo valor arbitrado “ D^* ” é equivalente a dizer que a probabilidade condicional para o esquema de compressão em análise deve pertencer ao conjunto de probabilidades condicionais “ Γ ” que tenham a propriedade :

$$\Gamma = \{P(y_j | x_i)\} \text{ tal que } D \{P(y_j | x_i)\} \leq D^*$$

Shannon [73] mostrou que o mínimo “Rate” para uma dada distorção é :

$$R(D) = \min I(X, Y), \{P(y_j | x_i)\} \in \Gamma$$

A Função Razão de Distorção (Rate Distortion) para fontes Gaussianas

Suponha que se tem uma fonte de amplitude contínua, que tenha uma função de distribuição de probabilidade Gaussiana com média zero e variância “ σ^2 ”

Seja a medida de distorção :

$$d(x, y) = (x - y)^2$$

Seja a restrição de distorção :

$$E [(X - Y)^2] \leq D,$$

Quer-se então determinar $I(X, Y)$, e seu valor mínimo dada uma restrição de distorção, para um $D < \sigma^2$.

$$\begin{aligned} I(X, Y) &= h(X) - h(X | Y) \\ &= h(X) - h(X - Y | Y) \\ &\geq h(X) - h(X - Y) \end{aligned}$$

Para minimizar $I(X, Y)$ deve-se maximizar o termo “ $h(X - Y)$ ” da equação anterior, observando a restrição imposta.

Este termo é maximizado se $(X - Y)$ for Gaussiano, e se a restrição $E[(X - Y)^2] \leq D$ tornar-se $E[(X - Y)^2] = D$.

Então, $h(X - Y)$ é a entropia diferencial de uma fonte aleatória com distribuição Gaussiana e variância “ D ”, que faz o limite inferior de $I(X, Y)$ tornar-se :

$$I(X, Y) \geq \frac{1}{2} \log(2\pi e \sigma^2) - \frac{1}{2} \log(2\pi e D) = \frac{1}{2} \log \frac{\sigma^2}{D}$$

Esta informação média mútua pode ser determinada se Y for Gaussiano com média zero e variância ($\sigma^2 = D$) :

$$f_{X|Y}(x | y) = \frac{1}{\sqrt{2\pi D}} \exp \frac{-x^2}{2D}$$

Se quer também a consideração $D > \sigma^2$. Se $Y = 0$, tem-se :

$$I(X, Y) = 0 \quad E[(X - Y)^2] = \sigma^2 \leq D$$

Em resumo, se tem :

$$R(D) = \begin{cases} \frac{1}{2} \log \frac{\sigma^2}{D}, & \text{para } D < \sigma^2 \\ 0, & \text{para } D > \sigma^2 \end{cases}$$

Semelhante ao fato da entropia diferencial para fonte Gaussiana, a função Razão de Distorção para fonte Gaussiana é sempre maior que a Razão de Distorção para qualquer outra fonte com distribuição contínua e mesma variância. Isto é especialmente útil porque para muitas fontes é muito difícil calcular esta Razão de Distorção. Nestas situações é útil se ter o limite superior da Razão de Distorção de uma variável contínua aleatória. Shannon [73] descreveu tal limite, e ele é apropriadamente chamado de “Limite Inferior de Shannon” que se reproduzirá, a seguir :

O limite inferior de Shannon para uma variável aleatória “ X ” e critério de erro $d(x, y) = (x - y)$ é dado por :

$$R_{\text{SLB}}(D) = h(X) - \log(2eD)$$

Se o critério erro é $d(x, y) = (x - y)^2$, tem-se :

$$R_{\text{SLB}}(D) = h(X) - \frac{1}{2} \log(2\pi eD)$$

Estes limites são muito úteis para se avaliar o desempenho de um certo esquema de compressão; isto é, nos casos de compressão com perdas, a função da Razão de Distorção tem o mesmo papel que a Entropia tem para casos de compressão sem perdas.

3.1.3. Modelos Probabilísticos

Um importante método de caracterizar uma fonte é dado pelo uso de modelos probabilísticos, cujo modelo permitirá a criação dos esquemas ótimos de compressão. Modelos probabilísticos são úteis para projetos de esquemas de compressão com perdas.

Quando se modela esquemas de compressão sem perdas, está-se querendo obter casamento exato entre a fonte emissora e a fonte comprimida. No caso da compressão com perdas procura-se uma correlação geral ao invés da exatidão entre a fonte emissora e a comprimida, devida ao fato, também, de que o modelamento da função de distribuição de probabilidade é levantada através de experimentos com a fonte emissora, ajustando-a a alguma função de distribuição de probabilidade analiticamente conhecida. As funções de distribuição “Uniforme”, “Gaussiana”, “Laplaciana” e “Gamma” são as mais utilizadas para tal.

- *Distribuição Uniforme* : Se não se sabe nada sobre a fonte emissora, exceto a faixa de valores de atuação, é indicado se utilizar esta função para modelar a fonte.

$$f_X(x) = \begin{cases} \frac{1}{b-a}, & \text{para } a \leq x \leq b \\ 0, & \text{para outros valores} \end{cases}$$

onde “ a ” e “ b ” são os limites da variável “ x ”.

- *Distribuição Gaussiana* : É o modelo mais utilizado, pois é matematicamente tratável e pelos teoremas do limite central, as distribuições devem tender a uma Gaussiana.

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \frac{-(x - \mu)^2}{2\sigma^2},$$

onde “ μ ” é a média, e “ σ^2 ” é a variância.

- *Distribuição Laplaciana* : Útil para modelamento de fontes que têm pico médio estatístico agudo. Aparece muito em modelamento de voz e imagem.

$$f_X(x) = \frac{1}{\sqrt{2\sigma^2}} \exp \frac{-\sqrt{2}|x|}{\sigma},$$

onde “ σ^2 ” é a variância de “ x ”, com média zero

- *Distribuição Gamma* : Útil para modelamento de fontes com pico médio estatístico muito agudo.

$$f_X(x) = \frac{\sqrt[4]{3}}{\sqrt{8\pi\sigma|x|}} \exp \frac{-\sqrt{3}|x|}{2\sigma},$$

onde “ σ^2 ” é a variância de “ x ”, com média zero.

Obtenção dos Modelos

Uma maneira de se estimar a Função de Distribuição de Probabilidade é através de histogramas, que consiste em dividir a faixa de variável de saída em “bins”, isto é, intervalos “ I_K ” e então encontrar o número dos valores “ n_k ” que caem dentro de cada intervalo “ I_K ”.

O gráfico de $\frac{n_k}{n_T}$, onde “ n_T ” é o número total de saídas consideradas, dá uma idéia de como se aparenta a referida distribuição. Porém pode haver grandes distorções em relação ao intervalo adotado “ I_K ”. Se os “bins” são muito largos, pode-se filtrar detalhes importantes do gráfico.

Se os “bins” são muito estreitos, pode-se ficar perdido em detalhes da forma gráfica e não visualizar o comportamento global .

Deve-se utilizar, após optar por uma das fontes conhecidas como referência, de testes de consistência. Note que a base do logaritmo é dependente da base de códigos desejada.

3.2. Caracterização do sinal de ECG quanto à compressão e função de densidade de probabilidade

Shannon deduziu as funções $R(D)$ para sinais Gaussianos estacionários com e sem memória, como visto na Seção 3.1. Quando o sinal tem distribuição não Gaussiana e/ou com

comportamento não-estacionário, deve-se aplicar técnicas práticas para sua obtenção.

O limite inferior de Shannon $R_{\text{SLB}}(D)$, com critério de erro gradativo é dado por :

$$R_{\text{SLB}}(D) = h(X) - \frac{1}{2} \log_2(2\pi e D)$$

3.2.1. Cálculo de $h(x)$

A primeira tarefa, então, é o cálculo de $h(x)$, que pode ser dada por (Seção 3.1)

$$h(x) = - \sum_{i=-\infty}^{\infty} [P(x_i) \cdot \log_2 P(x_i)] \cdot \Delta - \log_2 \Delta,$$

onde “ Δ ” é o “bin” em questão.

Para este caso o “ Δ ” é o menor degrau de quantização da base de dados, que é de 2048 degraus (11 bits); tem-se então :

$$\begin{aligned} h(x) &= - \sum_{i=0}^{2047} [P(x_i) \cdot \log_2 P(x_i)] \cdot 1 - \log_2 1 \\ &= - \sum_{i=0}^{2047} [P(x_i) \cdot \log_2 P(x_i)], \text{ em bits/sample} \end{aligned}$$

Foi levantada a curva de Função de Densidade de Probabilidade (fdp) de toda a base de dados do MIT-BIH [52], inicialmente com uma Estatística de Primeira Ordem.

Estatística de Primeira Ordem e Caracterização da fdp

A curva é obtida computando-se a contagem acumulada dos eventos discretizados em 2048 degraus (11 bits) em bins de “ I_K ” degraus, obtendo-se a quantidade de ocorrências dentro de cada bin (n_K) e traçando a fdp normalizada pela somatória das ocorrências de toda a base de dados (n_T), isto é :

$$\text{fdp} = \sum_{i=0}^{2047} \frac{n_K}{n_T}$$

A Figura 3.2 ilustra a fdp normalizada obtida de acordo com o acima descrito. À primeira vista, a curva aparentou ter “2 picos”, como se fossem duas fdps misturadas.

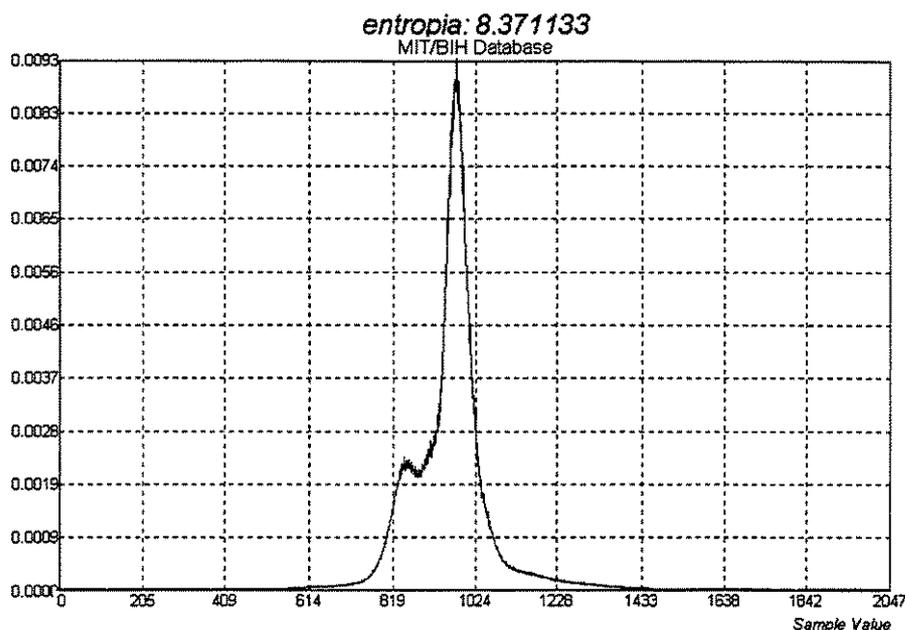


Figura 3.2: fdp obtida de todos os sinais da base de dados.

Para “detalhar” este evento, decidiu-se traçar as curvas fdp separadas de cada um dos 48 pacientes da base de dados, e em nenhuma se obteve duplo pico significativo. Nas Figuras 3.3 e 3.4 ilustra-se as fdps dos pacientes “122” e “212”. No relatório técnico número RTC-DCA 001/99 [58] são apresentadas todas as 48 curvas obtidas.

O que se nota é que existe um grupo delas que tem valor médio diferente das demais.

Isto é ilustrado com o sinal “122”, que tem valor médio centrado no degrau de amostragem “840” (de uma faixa de conversão que é numerada de 0 até 2047, vide Figura 3.3) e o sinal “212” que tem valor médio centrado no degrau “980” (vide Figura 3.4). Isto certamente é devido a algum “off-set” dos amplificadores de instrumentação utilizados na captação destes sinais.

Esta base de dados tem aproximadamente 20 anos de idade, e os pacientes foram escolhidos em períodos diferentes e é possível que tenha havido pequenos desvios de “zero” no registro (as versões originais desta base de dados são analógicas, gravadas em fitas magnéticas através de gravador de instrumentação).

Como se observou que a maioria dos sinais tem valor médio centrado perto do degrau “980”, resolveu-se realizar a fdp de cada sinal centrada neste valor médio. Obteve-se as curvas

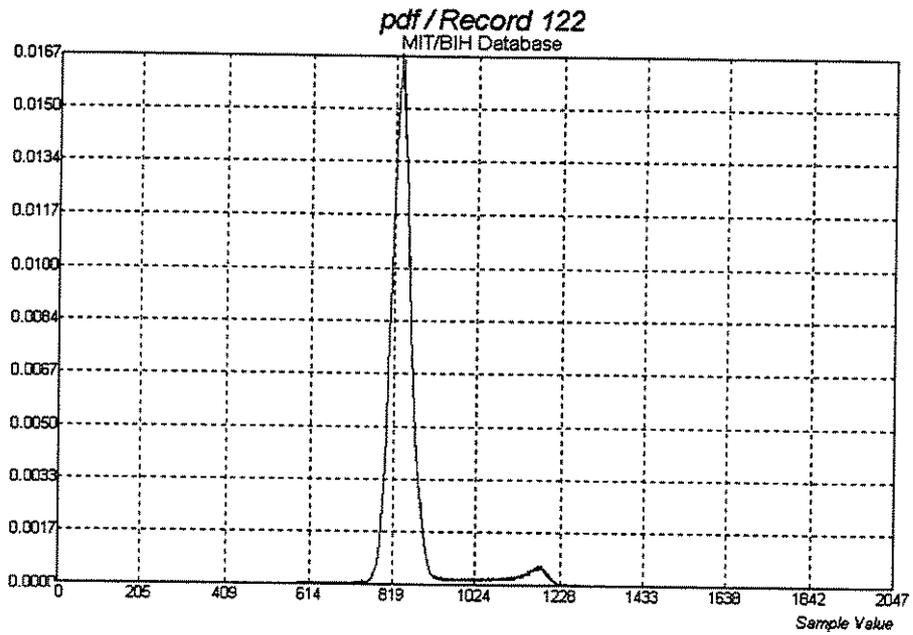


Figura 3.3: A fdp de primeira ordem do sinal 122.

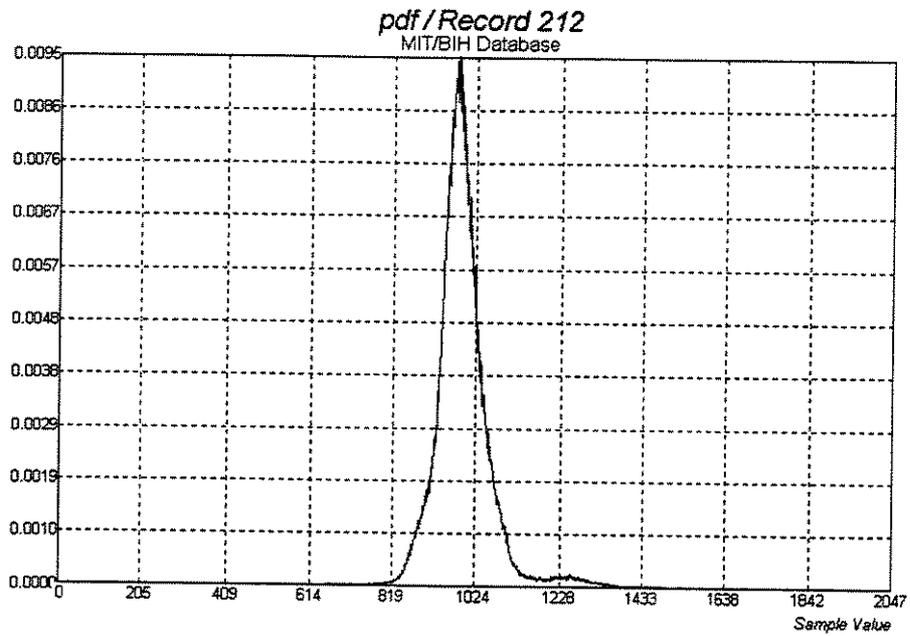


Figura 3.4: A fdp de primeira ordem do sinal 212

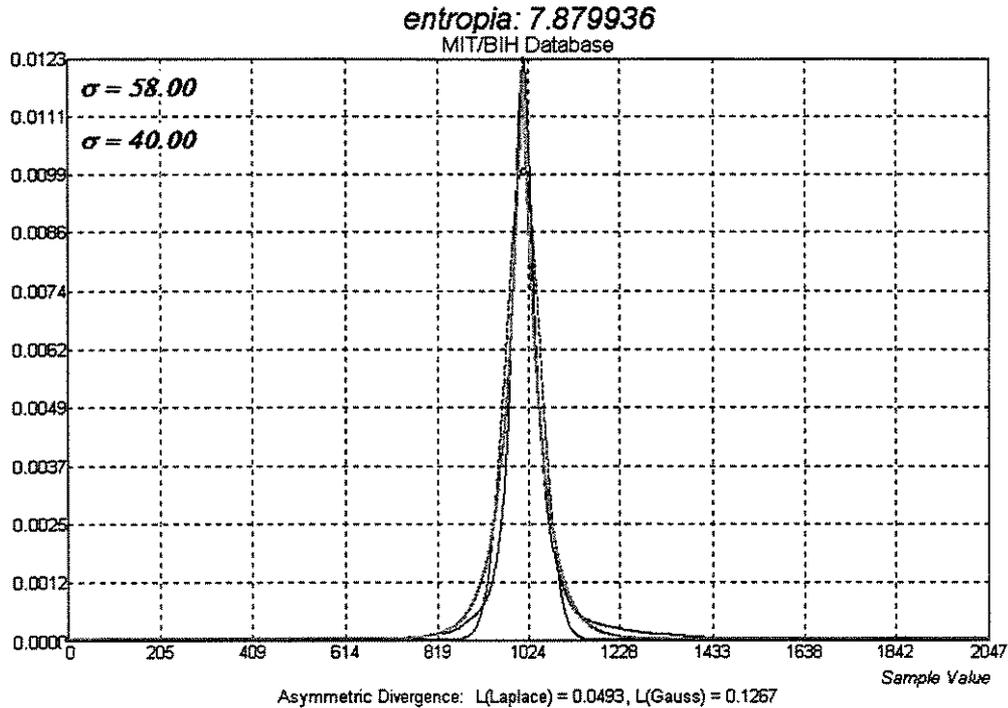


Figura 3.5: A fdp de primeira ordem de todos os sinais centradas no valor 980

ilustradas na Figura 3.5.

Nota-se visualmente que a fdp não aparenta, a priori, ser uma fdp Gaussiana. Para análise da similaridade destas fdps utilizou-se a técnica de divergência de “Kullback e Leibler” [45] (vide Capítulo 4).

A Figura 3.5 ilustra também as curvas desenhadas das fdps Gaussiana e Laplaciana, após otimização automática de casamento das mesmas com a fdp experimental, em função do cálculo da divergência assimétrica de Kullback-Leibler.

O melhor casamento entre a fdp experimental e as de Gauss e Laplace apresentaram :

- Divergência Assimétrica para Laplace = 0,0493
- Divergência Assimétrica para Gauss = 0,1267

Isto, então, indica melhor casamento para a Laplaciana com relação à Gaussiana.

A entropia $h(x)$ obtida é de :

$$h(x) \cong 7,88 \text{ bits/sample}$$

Como a estatística de primeira ordem não tem capacidade de capturar as propriedades de “repetitividade” de um sinal, que é o caso do sinal de ECG, optou-se também por realizar estatísticas de ordem superior.

3.3. Estatística de Ordem Superior : Análise de Componentes Principais

Utilizou-se o modelamento PLS (Partial Least Squares), mais precisamente o algoritmo NIPALS (Non-Linear Iterative Partial Least Squares, vide Capítulo ??) para decomposição do sinal em seus Componentes Principais, para cada um dos 48 sinais da base de dados. (Vale ressaltar que as mesmas tomaram aproximadamente 1500 horas de computação para serem obtidas).

3.3.1. Procedimento

Para realização deste procedimento, foi necessário :

1. Sincronizar todos os sinais em relação ao pico do complexo “QRS” do sinal de ECG (vide Figura 3.6) e truncagem do tamanho de cada um destes sinais de um único batimento, com valor proporcional a 40% e 60% do tamanho do vetor, à esquerda e direita do pico do complexo QRS. Cada pedaço do sinal tratado conforme esta técnica será, a partir de agora, chamado de “pulso”. O pico do complexo QRS, onda R, é acusado em outro arquivo da base de dados. Este sinal original é amostrado na frequência de 360 Hz.
2. Reamostrar os pulsos do ECG para que cada vetor do pulso tenha sempre 285 amostras. Assim, obtém-se vetores de tamanho fixo (285 amostras) que permite o trabalho de Análise de Componentes Principais. A Figura 3.7 ilustra o sinal “100” após a realização dos itens 1 e 2 supracitados.
3. Centrar o sinal no valor zero (retirar o valor médio das amostras).
4. Aplicação da Análise de Componentes Principais por algoritmo NIPALS, para cada

sinal da base de dados, obtendo-se componentes principais, PCs, cuja reconstrução do sinal gerasse erros inferiores a $2,6\mu\text{VRMS}$, tarefa esta realizada para decomposição de todos os 48 sinais. As componentes principais, PCs, para os sinais 100 e 203 (considerado por esta análise como o “melhor” e “pior” sinal, respectivamente, em termos de desempenho possível de compressão), foram obtidos todos os PCs, isto é, 285 componentes. Vale observar que o algoritmo NIPALS foi escolhido pelo fato do mesmo obter menores erros numéricos que a técnica de “Decomposição da Matriz de Covariância”, quando se pretende truncar ou diminuir a precisão numérica no processo de sua computação (Wold [83]).

5. O levantamento da fdp da matriz de “scores” de cada autovetor obtido para cada sinal da base de dados. Vale ressaltar que é na matriz de “scores” (equivalente à matriz de covariância no caso de Decomposição por Matriz de Covariância) que se concentra a essência do poder de compressão da Análise de Componentes Principais, onde vale ressaltar que foi realizada com a mesma discretização do sinal original (11 bits ou 2048 degraus).
6. O cálculo da entropia de cada componente principal obtido, para cada sinal da base de dados.
7. A caracterização dos primeiros 30 PCs de todos os sinais, quanto à similaridade de sua fdp em relação às fdps Gaussiana e Laplaciana, e a mesma tarefa para os PCs 40 até 110, em intervalos de 10 em 10, segundo a medição de distância de Kullback-Leibler.
8. O levantamento das curvas $R(D)$ para cada sinal em função de cada PC obtido.

3.3.2. Resultados desta decomposição em PCs

A Figura 3.8. ilustra o PC número 1 obtido, já apresentando o resultado do cálculo da Divergência Assimétrica Otimizada, para semelhança entre a fdp experimental e as de Gauss e Laplace.

As Figuras 3.9 e 3.10 ilustram os PCs número 2 e 3 respectivamente.

No relatório técnico número RTC-DCA-001/99 (Nicolosi [58]), ilustram-se todas as curvas obtidas conforme proposto no item 6 supra. Em todas as curvas levantadas, o melhor

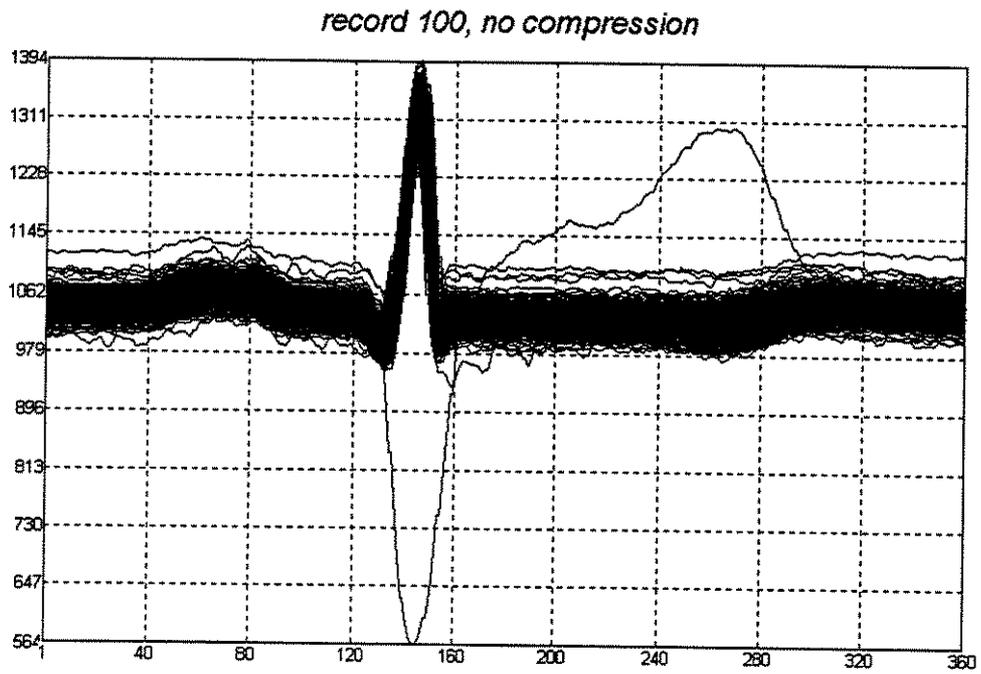


Figura 3.6: Pulsos do sinal 100 sincronizados e truncados em função da onda R

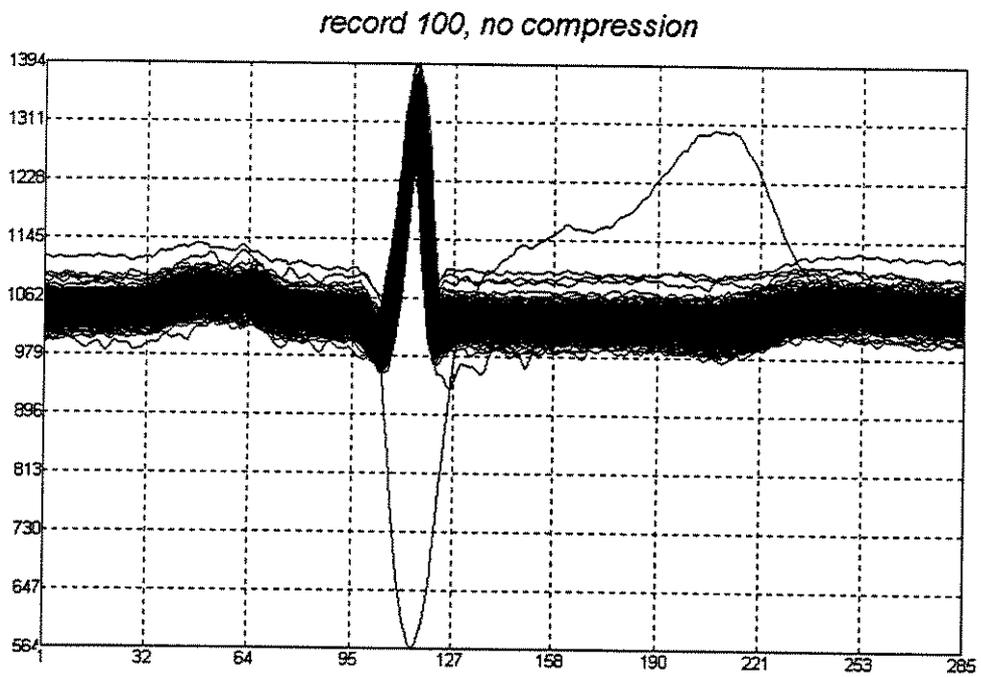


Figura 3.7: Pulsos do sinal 100 reamostrados para ter tamanho fixo de 285 amostras

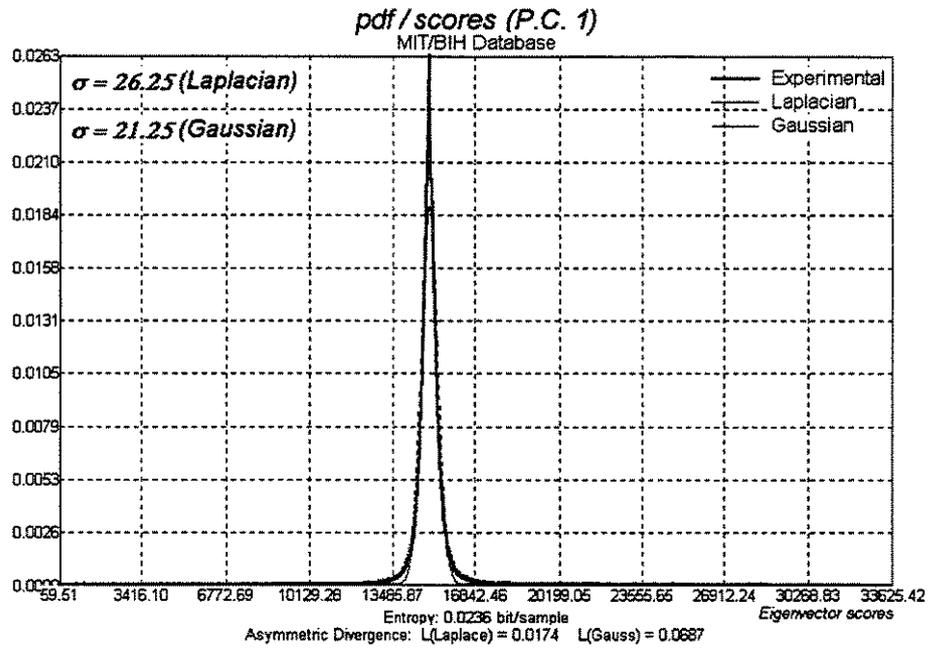


Figura 3.8: Fdp dos scores da PC1 e cálculo da divergência assimétrica

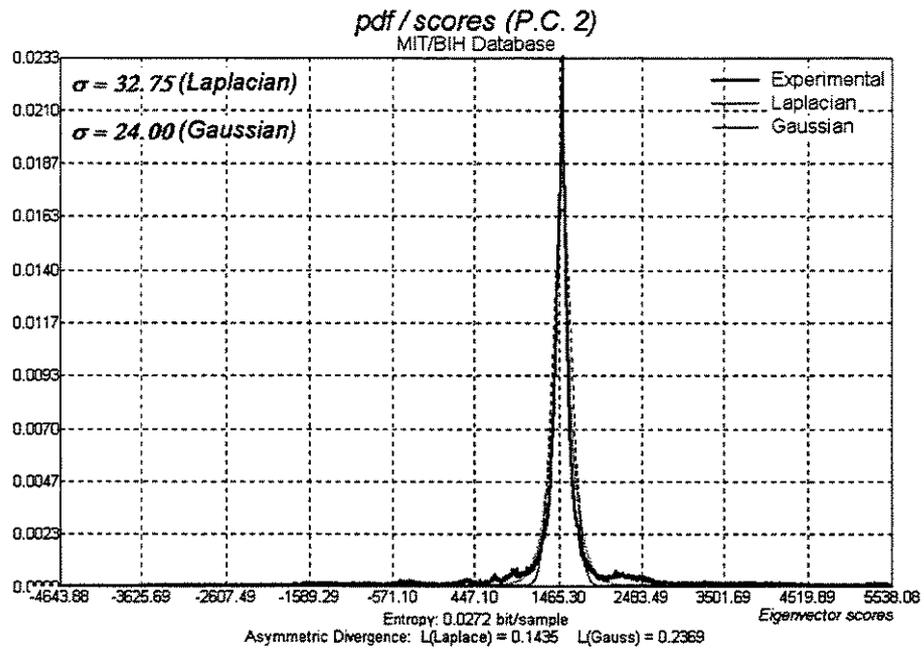


Figura 3.9: Fdp dos scores da PC2 e cálculo da divergência assimétrica

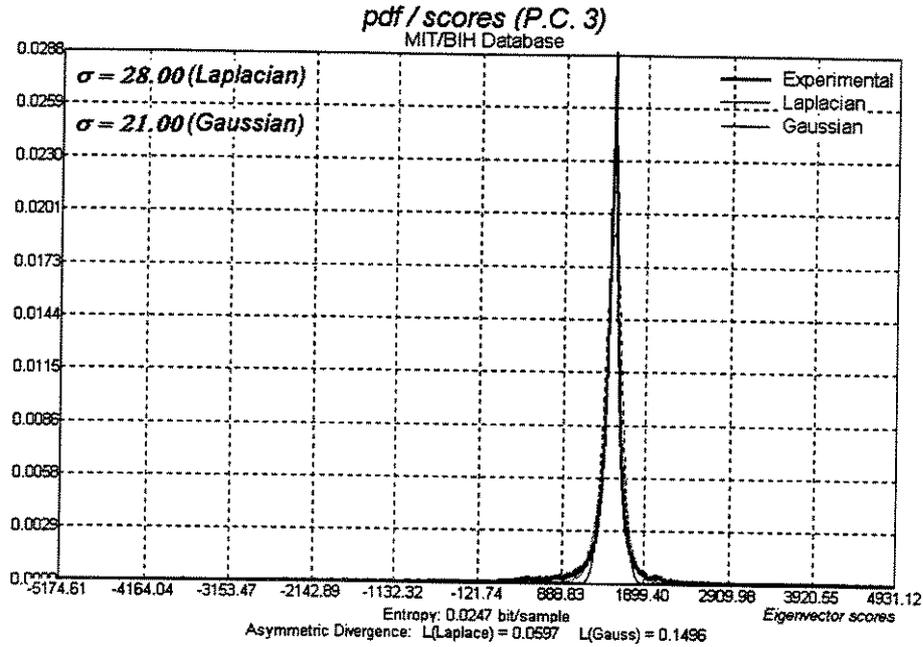


Figura 3.10: Fdp dos scores da PC3 e cálculo da divergência assimétrica

casamento se dá para a fdp Laplaciana. Pode-se inferir então, a priori, que o sinal de ECG Ambulatorial tem fdp aproximadamente Laplaciana.

Observa-se das curvas, também, que o cálculo da entropia de cada PC apresenta valor médio de :

$$h_{PC}(x) \cong 0,026\text{bits/sample/PC.}$$

Quando se calcula este valor acumulado nas 285 PCs, chega-se a :

$$H(x) = 7,41\text{bits/sample}$$

Este valor é muito próximo àquele obtido pela estatística de primeira ordem, que foi de 7,88 bits/sample.

3.3.3. Resultados Obtidos

No relatório técnico número RTC-DCA-001/99 (Nicolosi [58]), apresenta-se a tabela completa das entropias obtidas para cada PC de cada um dos 48 sinais.

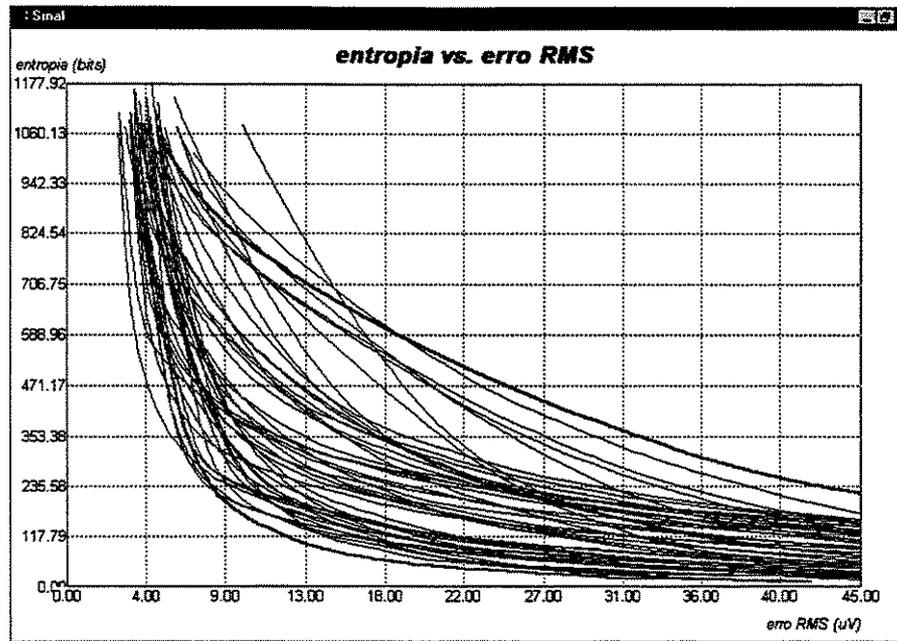


Figura 3.11: Curvas $R(D)$ de todos os sinais da base de dados

A Figura 3.11 ilustra a curva $R(D)$, nomeada neste trabalho de “Curva $R(D)$ Operacional”, para cada um dos sinais da base de dados, com limite de análise para erro de $2,6\mu\text{VRMS}$, onde as curvas em negrito representam os sinais “100” e “203”, sendo o “100” a curva inferior das obtidas. Ela está apresentada em “Bits/s”, onde para se obter o dado em “Bits/sample”, deve-se dividir os valores de R por 285. No relatório técnico número RTC-DCA-001/99 (Nicolosi [58]) se apresentam as curvas $R(D)$ separadas para cada sinal da base de dados. A Figura 3.12 ilustra a média das curvas $R(D)$, desenhada junto com a obtida por Hamilton e Tompkins [28], que consideravam o sinal de ECG como Gaussiano. Note que a curva média obtida neste trabalho e as obtidas pelos autores tendem a se alinhar a partir de um certo erro RMS. Isto é de se esperar, pois as fdps Laplaciana e Gaussiana não apresentarão grande diferença quando se compara a Gaussiana com a média de Laplacianas, em termos de cálculo de entropias em função do erro. A partir de $4,5\mu\text{VRMS}$, as curvas dos autores tomam valores que mostram desvio obtido por este trabalho, quando se assume a fdp como Laplaciana.

A Figura 3.13 ilustra a curva $R(D)$, para o sinal 100 com análise dos 285 componentes principais possíveis e a curva $R_{\text{LSB}}(D)$ dada por Shannon (vide Item 3.1.2.) para o sinal considerado. Esta figura apresenta ilustração da interpretação que se dá neste trabalho para a curva $R_{\text{LSB}}(D)$ obtida por Shannon em relação à $R(D)$ Operacional (obtida por “PCA”

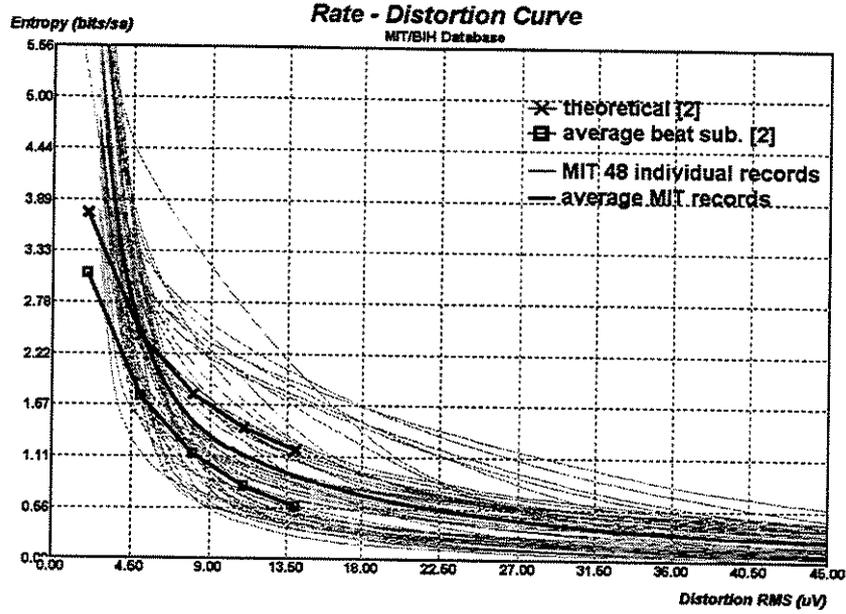


Figura 3.12: Curvas $R(D)$ de todos os sinais da base de dados desenhada junto com as obtidas por Hamilton e Tompkins [29].

parcial), cuja matéria será detalhada a seguir :

A curva $R(D)$ operacional obtida é baseada na decomposição do sinal em CPs e a obtenção do Rate em função da somatória acumulada das entropias parciais da fdp dos Scores de cada CP, que gera então um certo erro D quando se reconstrói o sinal apenas com estas CPs parciais.

O limite superior de Shannon, é função que referencia o “Rate” que se obtém quando se trunca a informação, em função de uma certa distorção D , e é dada por :

$$R(D) = h(x) - \frac{1}{2} \log(2\pi e D) \quad (3.1)$$

A curva experimental gera um $h(x)$ parcial, dado por :

$$h_{CPN}(x) = \sum_{i=1}^N h(x)_{CP_i} \quad (3.2)$$

Esta recomposição parcial do sinal implica em certo erro de reconstrução “ D_0 ”. Dado este resultado, pode-se aplicar a partir desta entropia parcial, a “Fórmula Adaptada de Shannon”, aqui proposta :

$$R_{LSBparcial}(D) = h_{CPN}(x) - \frac{1}{2} \log(2\pi e (D - D_0)) \quad (3.3)$$

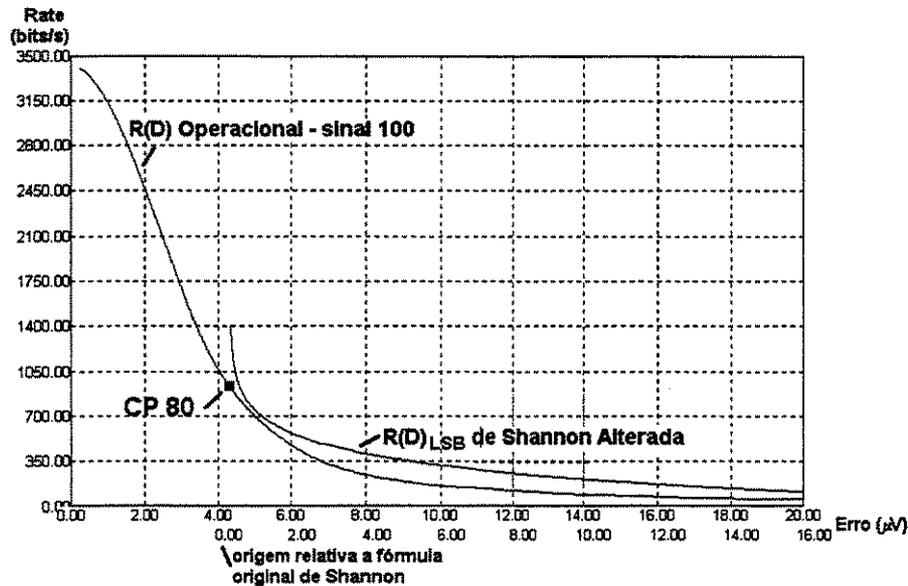


Figura 3.13: Curva $R(D)$ Operacional por PCA e a $R_L(D)$ de Shannon

Esta fórmula está numericamente ilustrada na Figura 3.13 e tem inspiração nos trabalhos de Viterbi e Omura [81] (pg 510) onde ele cita que um sinal pode ser decomposto em CPs por transformada KL, e, segundo Viterbi, obter-se-á :

$$R_L(D) = \lim_{N \rightarrow \infty} R_{L,N}(D),$$

onde $N =$ Transformada “KL” de ordem N .

Note que, baseado neste limite, se for aplicada a somatória parcial do Rate obtido para cada CP, tem-se um $R_L(D)_{CPN}$ parcial por recomposição de N componentes principais, que é o mesmo princípio deste trabalho, ilustrado na Equação 3.3.

Logo, pode-se inferir a aplicação deste conceito na fórmula de Shannon, que está representada na Equação 3.3 , a qual foi aplicada numericamente para o sinal 100 e ilustrada na Figura 3.13.

Nesta Figura 3.13 realizou-se o cálculo de um $h(x)$ parcial, para o sinal 100, com apenas 80 CPs. Em seguida se aplicou a fórmula proposta aqui, representada pela Equação 3.3, que gerou o resultado mostrado. Para cada “novo sinal” recomposto com “ N ” PCs, tem-se uma nova curva de Shannon.

Apesar deste texto não ter sido uma demonstração formal desta equivalência, a mesma

serve para intuir sobre esta alteração proposta.

3.3.4. Demonstração da equivalência entre as fórmulas original de Shannon e a Alterada

Introdução : “Seja “x” uma variável aleatória, a partir da qual irá se criar uma nova variável aleatória “y”, correlacionada com a original conforme exposto a seguir” :

Seja “x” uma variável aleatória representada pela decomposição desta mesma variável por “N” Componentes Principais, sendo que com “N” componentes a variável “x” é completamente representada (erro de reconstrução nulo).

Seja “y” uma variável aleatória, construída através de “M” Componentes Principais do sinal “x”, sendo $M < N$, componentes estes escolhidos em função da sua ordem decrescente de máxima variância ou autovalor.

Esta variável “y” pode ser considerada então como uma nova variável, na qual é possível aplicar a fórmula do “Limite Inferior de Shannon”, $R_{LSB}(D)$, para critério de erro quadrático :

$$R_{LSB}(D) = h(y) - \frac{1}{2} \log(2\pi e D)$$

A correlação entre as variáveis é dada pelo fato de “y” ser uma recomposição parcial de “x”, através da representação de “x” por M Componentes Principais, causando um erro quadrático de reconstrução D_0 de “y” em relação a “x”.

A curva $R_{LSB}(D)$, desta variável “y” terá então a referência “zero” do erro D deslocada de valor D_0 com relação a variável original “x”, já que “y” é uma imagem de “x” com erro de reconstrução D_0 .

Assim, para expressar a curva $R(D)$ de “y” relacionada àquela de “x”, deve-se criar um nova referência de zero para a curva de “y”, que estará deslocada de valor D_0 em relação a referência zero da curva $R(D)$ de “x”, isto é :

$$D(y) = D(x) - D_0,$$

válida apenas para valores de $D(y) > D_0$. Deste modo, a equação $R_{LSB}(D)$ de “y”, que é variável parcial de “x”, quando referida à variável aleatória original “x”, será dada por :

$$R_{LSB\text{parcial}}(D) = h_{CPN}(x) - \frac{1}{2} \log(2\pi e(D - D_0)), \text{ para } D > D_0.$$

c.q.d.

Capítulo 4

Compressão de sinais de ECG por Técnicas Avançadas

4.1. Por Redes Neurais Artificiais

4.1.1. Introdução : Revisão das principais técnicas adaptativas e com redes neurais para compressão de ECG

O modelo de Kohonen na aplicação na compressão de dados

Existe uma grande conexão entre os algoritmos desenvolvidos para compressão adaptativa de dados e os mapas auto-organizáveis, propostos por Kohonen [41].

Os algoritmos utilizados comumente trabalham com a codificação de um dado em uma forma compacta e este dado pode ser recuperado com o menor erro possível. É óbvio o interesse em se querer obter o máximo grau de compressão possível e logo, um certo erro sempre haverá.

O método chamado de quantização vetorial é uma classe dos procedimentos de compressão que minimizam o erro envolvido na descompressão. Os mapas auto-organizáveis podem ser considerados como uma generalização deste procedimento.

A função de vizinhança utilizada nestes, otimiza a quantidade de erro obtendo uma minimização ótima em relação às técnicas tradicionais.

Os “mapas” tem uma segunda e também importante conexão aos vários procedimentos da análise de dados por Componente Principais .

Nestes procedimentos, procura-se descrever tão bem quanto possível a distribuição dos pontos de dados localizados em um espaço multidimensional, utilizando-se um espaço de dimensão inferior.

Os problemas de compressão de dados e os de obter uma boa projeção do espaço multidimensional em um espaço inferior são extremamente importantes em inúmeras tarefas que envolvem processamento da informação.

O processo de formação dos mapas é adaptativo e é excitado por uma seqüência aleatória dos sinais de entrada. Matematicamente falando, o processo corresponde à uma mudança adaptativa do mapa até que este se dirija à uma situação de estado estacionário.

Quantização Vetorial e Compressão de Dados

Um dos mais importantes pré-requisitos para qualquer espécie de processo de informação é o estabelecimento de uma codificação apropriada dos dados em consideração.

No caso do cérebro, estas codificações foram determinadas pela natureza, sendo que “mapas cerebrais” são estudados para tentar decifrar esta codificação .

No caso de um sistema artificial de processamento da informação, a decisão por uma codificação de dados é função do projetista, e também a determinação de quais propriedades são mais importantes e quais devem ser utilizadas para a codificação específica.

Todavia, existem mais aspectos a se revelar. Um destes aspectos é o tamanho médio do código exigido para a transmissão de uma especificada quantidade de informação.

Se os caracteres são estatisticamente independentes, o limite inferior para a codificação será :

$$S = \sum_i P_i \log_2 P_i \quad (4.1)$$

onde :

P_i = probabilidade de ocorrência do i -ésimo caractere

S = quantidade de informação de Shannon transmitida em média em um canal

Todavia, a suposição de haver caracteres estatisticamente independentes raramente é verdade. Se forem exploradas as relações entre os caracteres, será possível encontrar códigos mais eficientes.

Por exemplo, no caso da Linguagem, poder-se-ia codificar as palavras no lugar das letras individuais, realizando assim uma compactação. Este tipo de otimização de código é de particular importância quando grandes quantidades de dados são armazenados ou transmitidos. Isto é particularmente importante em processamento de imagem. A quantidade de dados para transmitir um quadro do tipo “raster” com resolução de 1000 por 1000 pixels e 256 níveis de cinza requer a transferência de 1 M bytes de dados!

Todavia, na maioria das imagens, pixels adjacentes são extremamente correlacionados, e pode resultar em uma codificação mais eficiente que a codificação direta .

Um estudo generalizado desenvolvido para esta tarefa é o método chamado de “quantificação vetorial”. Este método supõe que os dados são apresentados na forma de um conjunto de dados vetoriais $v(t)$, $t = 1, 2, 3, \dots$. O índice t numera os vetores. Cada componente do vetor $v(t)$ pode ser binário, inteiro ou pode assumir valor analógico, correspondendo, p. ex., aos códigos de uma seqüência de cinzas correspondentes ao pixel da imagem, ou amplitudes de um sinal de voz, sinais biológicos, etc .

A compressão dos dados ocorre pela aproximação de cada vetor $v(t)$ ao vetor de referência w_s de mesma dimensão.

Isto pressupõe que exista um conjunto W finito de vetores w_s , determinados de tal maneira que sempre existe um “bom” vetor de aproximação $w_s \in W$, para um vetor de dados qualquer $v(t)$. O conjunto W de vetores de referência define a base de dados vetorial a se assinalar para que cada vetor $v(t)$ se relacione a um dado vetor de referência $w_s \in W$, através do qual a diferença $\delta = \|v(t) - w_s\|$, onde $\|\cdot\|$ representa a norma, assume um valor mínimo sobre todos os vetores da base de códigos vetorial.

Assim, o índice “ s ” de w_s é o índice que especifica o vetor $w \in W$ que melhor representa o vetor $v(t)$, i.e., a melhor aproximação. No caso de uma base de códigos com N vetores de referência, se exigirá a especificação de ao menos $\log_2 N$ bits.

Então, quanto menor a base de códigos escolhida, melhor será o fator de compressão resultante. Note que a distribuição de probabilidade dos códigos “ s ” pode ser não uniforme. Em certas circunstâncias, o assinalamento de palavras de códigos curtos para os vetores mais

freqüentes, irá aumentar ainda mais a eficiência do código .

Todavia, este ganho tem um preço : o dado original não poderá mais ser exatamente recuperado dos códigos “s”, pois só se tem o vetor w_s disponível. Isto cria um erro de reconstrução que é igual ao erro de aproximação $\delta = \|v - w_s\|$, onde se fez $v(t) = v$ por simplificação.

Logo, é crucial para todo o procedimento a construção de uma boa base de códigos W . Ela deve conter suficientes e bem distribuídos vetores de referência para permitir uma boa aproximação de cada vetor v pelo vetor de referência w_s .

A formulação matemática desta exigência, em geral, acaba se direcionando para o erro de reconstrução quadrática :

$$E[W] = \int \|v - w_{s(v)}\|^2 P(v) dv, \quad (4.2)$$

onde, $P(v)$ é a densidade de probabilidade descrevendo a distribuição dos vetores de dados v . E $[W]$ depende do conjunto W de todos os vetores de códigos w_s . Uma exigência freqüentemente apropriada demanda a minimização de E sujeita a uma restrição de um certo número fixo e prescrito de vetores w_s . Todavia, isto também leva a uma redução arbitrária do efeito de compressão, já que o esforço requerido para especificar um dado valor de “s” aumenta com o número N de vetores de referência.

A minimização de E com respeito aos valores de referência w_s é um problema complicado de otimização não-linear, que em muitos casos não se conhece a solução fechada. Portanto, deve-se optar pelos métodos de aproximação. Estes métodos de aproximação estão extremamente relacionados com o algoritmo de formação dos mapas de Kohonen. Os mapas gerados pelo procedimento de Kohonen [41] podem ser considerados neste contexto, como uma base de códigos do procedimento de quantização vetorial, na qual a propriedade de preservação da topologia dos mapas levam a modificação da quantidade de erro original citado pela equação $E[W]$.

Mapas Auto-organizáveis e Quantização Vetorial

A construção de uma boa base de códigos exige a minimização do erro médio de reconstrução $E[W]$ com respeito aos vetores de referência w_s . O procedimento mais simples

para isto é pelo gradiente. Começando-se com valores iniciais de $w_s(0)$, todos os vetores de referência serão mudados de acordo com :

$$\begin{aligned} w_s(t+1) &= w_s(t) - \frac{\varepsilon}{2} \frac{dE}{dw_s} \\ &= w_s(t) + \varepsilon \int (v - w_s(t)) P(v) dv \end{aligned} \quad (4.3)$$

Para um parâmetro ε suficientemente pequeno, a aplicação repetida desta Equação 4.3 leva à diminuição de $E[W]$ até um mínimo local. A Equação 4.3 foi sugerida inicialmente por Linde, Buzo e Gray [49] e é conhecida como “procedimento LGB”. Embora este procedimento não garanta que o mínimo global seja alcançado, em muitos casos importantes o mínimo local encontrado fornece uma solução suficientemente boa.

Se for exigido um melhor mínimo local, ele pode ser encontrado repetindo-se o procedimento com valores iniciais diferentes ou com ajuda da técnica de “annealing”.

Todavia, tomando o procedimento desta forma requer um conhecimento da probabilidade de distribuição $P(v)$ dos vetores de dados. Usualmente, $P(v)$ não é conhecida explicitamente. Esta dificuldade pode ser evitada substituindo-se a Equação 4.3 por uma forma mais simples, onde para cada passo da Equação 4.4, um novo vetor de dados v é selecionado aleatoriamente da distribuição desconhecida utilizada :

$$w_{s(v)}(t+1) = w_{s(v)}(t) + \varepsilon (v - w_{s(v)}(t)) \quad (4.4)$$

Para pequenos valores de ε (tamanho do passo), o acúmulo de muitos passos individuais na Equação 4.4 levará a uma realização aproximada da integração dada na Equação 4.3. Observe que, neste caso, o parâmetro t que dá o próximo passo, nas Equações 4.3 e 4.4, não é exatamente o mesmo.

Se for comparada a Equação 4.4 com a regra de adaptação no modelo de Kohonen de mapas auto-organizáveis, é possível mostrar que a Equação 4.4 representa um caso especial do algoritmo de Kohonen que resulta, no limite, na cooperação da vizinhança.

“O algoritmo de Kohonen pode, portanto, ser entendido como a generalização do procedimento de quantização vetorial para compressão de dados” (Ritter e cols [68]).

Os pesos das “ligações sinápticas” w_r correspondem aos vetores de referência, o mapa fornece a base de códigos e a escolha do ganho de excitação “ s ” para um sinal de entrada

v , define o mapeamento $v \rightarrow s(v)$, i.e., corresponde aos passos de codificação do procedimento de quantização vetorial. Os chamados “campos receptivos” do sistema de mapas auto-organizáveis são justamente aqueles sinais para os quais o procedimento de codificação leva ao mesmo centro “ s ” de excitação.

A introdução do conceito de vizinhança, i.e., funções de vizinhança (Ritter [68]) “hrs”, levam-nos à modificação da distribuição dos vetores de referência comparados com a quantização vetorial padrão. O deslocamento médio de um vetor de referência, torna-se :

$$\langle \Delta w_s \rangle = \sum_s \text{hrs} \int_{F_s} (v - w_s) P(v) dv \quad (4.5)$$

Isto quer dizer que um deslocamento de w_s agora ocorrerá na direção do centro médio de gravidade de todos os campos F_s , onde a contribuição de cada campo é ponderada pela função de vizinhança “hrs.” Em estado estacionário, cada vetor de referência w_s então, coincide com a densidade média ponderada, onde o ponderamento é tomado com relação à vizinhança e inclui contribuições com peso relativo “hrs” de todos os campos na vizinhança “ s ”, os quais $\text{hrs} \neq 0$.

Isto leva a minimização do erro de reconstrução (Equação 4.2), que cria expressão modificada. No caso de cadeia unidimensional de vetores de referência, cada um com “ n ” vizinhos em ambos os lados , chega-se à :

$$E[W] = \int \|v - w_{s(v)}\|^r P(v) \quad (4.6)$$

onde o expoente “ r ” é diferente de 2. Tomando um valor menor dado por :

$$r = \frac{1}{2} + \frac{3}{2(n+1)} \quad (4.7)$$

Esta equação pode ser interpretada como : “A inclusão de uma região de vizinhança em cada passo de adaptação leva a uma quantização vetorial que, relativo ao erro quadrático (Equação 4.2), fornecerá menor erro de quantização” (Ritter [68]).

4.1.2. Revisão das principais técnicas para compressão de ECG utilizando Redes Neurais Artificiais

Compressão de ECG por RNA de Kohonen

A seguir será efetuada uma análise do artigo de McAuliffe [51], sobre utilização de redes neurais do tipo Kohonen na compressão de sinais de ECG com paciente em exercício, que até o ano de 1999 foi o único artigo a explorar esta técnica na área. Cita o autor :

“O propósito de qualquer esquema de compressão de dados é maximizar a compressão e minimizar a distorção. A técnica de quantização vetorial, VQ, Vector Quantization, utilizada em imagem e voz é utilizado neste trabalho.”

“A VQ utiliza um codificador para substituir um vetor de entrada X_n , por um vetor da base de códigos do codificador. A compressão do dado é obtida usando o endereço do vetor da base de códigos em lugar do vetor original. Se a base de códigos tem K elementos, a razão de quantização R , em bits por vetor, é definida como :”

$$R = \log_2 K$$

“A razão de compressão, então, r , em bits por amostra será :”

$$r = R/J$$

onde J é o número de amostras em cada vetor.

“A razão de compressão teórica a ser obtida pode ser calculada, por exemplo, com amostras de 16 bits e uma base com 128 códigos” ; onde :

- $r = 3,5$ e $CR = 3,5$ para um tamanho de vetor de 2.
- $r = 0,7$ e $CR = 22,9$ para um tamanho de vetor de 10.

“Isto dá um grande potencial de compressão, comparável ou superior às técnicas tradicionais”.

“O objetivo, então, é criar a melhor base de códigos possível, que melhor e mais genericamente represente os dados de entrada”.

“Neste artigo, o trabalho foi realizado utilizando-se uma rede neural do tipo Kohonen. A vantagem de utilizar rede neural é que não necessita conhecimento estatístico, a priori, dos sinais eletrocardiográficos, embora um pré-processamento mínimo seja necessário”.

“As redes de Kohonen realizam aprendizado não supervisionado, chamadas de “self-organizing features map”. Esta topologia de redes utiliza as relações de vizinhança dos nós ou vetores da rede na base de códigos. Uma região de vizinhança enlaça estes nós (ou vetores) na base de códigos que está mudando adaptativamente para cada vetor de treinamento em cada passo do sistema”.

“Com cada apresentação dos vetores de entrada, um novo centro de vizinhança é determinado para o melhor casamento dele com um vetor da base de códigos. Durante este processo de adaptação, grandes regiões de vizinhança se sobrepõem, incorporando muitos dos mesmos vetores da base de códigos”.

“Portanto, o impacto de cada vetor de entrada é mudar a topologia global da base de códigos. Muitas formas e tamanhos de vizinhança têm sido usados com sucesso. A chave é disparar o processo com funções de vizinhança relativamente largas e ir estreitando-as para funções menores. Isto permite que ocorra alto nível de mudança no início, face ao fator de ganho “ α ”, em paralelo com o processo, também ser o máximo possível. A maioria do ordenamento e estruturação, então, ocorrerá na fase inicial, com apenas pequenos ajustes ocorrendo nos estágios posteriores.”

Compressão de Dados Eletrocardiográficos A compressão de dados eletrocardiográficos traz novas restrições às soluções típicas de compressão. Com dados de imagem e voz, os ouvidos e olhos humanos agem naturalmente como filtros de amaciamento do sinal, permitindo que uma certa quantidade de erro seja perdoada.

Com o Eletrocardiograma (ECG), não apenas a distorção total deve ser baixa, mas também certas áreas do sinal precisam ser preservadas com a maior fidelidade morfológica possível para se realizar posteriormente medidas com precisão.

A interpretação do ECG no exercício exige menos medição, mas ainda requer alta integridade do complexo QRS e segmento ST do ECG. É incluído nos padrões de medição de fidelidade : o índice de fidelidade de reconstrução pela raiz quadrada do erro médio, erro médio de pico e erro absoluto máximo. Em exercício , existe muita contaminação do sinal

por ruído, artefatos musculares e variação da linha de base.

Criação da Base de Códigos (McAuliffe [51]) “O primeiro passo para treinar a rede neural é montar um bom conjunto de treinamento que melhor varra o espaço de dados eletrocardiográficos. Três diferentes cenários de treinamento foram tentados. O primeiro usa a rede neural de Kohonen (KNN) para criar uma base de códigos de 256 vetores que se espalham por todo o espaço de dados. O resultado foi aceitável em áreas não críticas do ECG, mas muito insatisfatório nos complexos QRS e T, tanto no exame visual como pela distorção medida.”

“A segunda tentativa foi criar duas bases de códigos; uma para frequência baixa e outra para alta frequência. As duas bases de códigos foram treinadas separadamente. Isto melhorou o desempenho mas não ao nível da expectativa.”

“A terceira tentativa melhorou dramaticamente os resultados. O método, inspirado no esquema de Cheung [16] para quantização vetorial adaptativa, realiza a criação “on-line” da base de códigos para vídeo e voz. Os resultados foram bem melhores quando o processo de criação da base de códigos foi modificada.”

“A base de códigos eletrocardiográficos atual é criada pelo treinamento apenas dos vetores de baixa frequência. Quatro grupos de dados eletrocardiográficos de exercício de diferentes indivíduos foram utilizados como conjunto de treinamento. Um total de 5000 vetores de cada grupo (625 vetores por “lead”) foram selecionados. Se a diferença entre todas as amostras sucessivas no vetor for menor que $50\mu V$, o vetor é considerado de baixa frequência.”

“O tamanho da base de códigos foi de 128 vetores. A vizinhança inicial foi ajustada para 121 vetores, com arranjo circular da base de códigos, isto é, o vetor da base de códigos “127” ficou adjacente ao vetor “0”, para propósito de cálculo de adaptação e vizinhança.

O ganho $\alpha(t)$ foi ajustado inicialmente para 0,9. Dois esquemas diferentes de decaimento de $\alpha(t)$ foram utilizados com igual sucesso. O primeiro foi decaimento linear no tempo, e o segundo foi exponencial.”

“A base de códigos foi inicializada com vetores selecionados aleatoriamente do conjunto de treinamento e este conjunto de treinamento foi embaralhado antes de cada passo. Foram planejados 10 passos para o período inicial de treinamento, durante os quais o tamanho da vizinhança e o $\alpha(t)$ decaíram dramaticamente e onde a maior parte da ordenamento se

realizou . Mais dez passos sobre o conjunto de treinamento foram usados na fase de ajuste fino . O tamanho do vetor foi deixado como variável por ser de muito interesse no estudo, devido à natureza do ECG.”

Codificação “A criação da base de códigos pode ser realizada “off-line” . Dois esquemas de pré-processamento foram examinados. O primeiro usa somente dados em estado bruto, que foram previamente filtrados, produzindo banda de 0,05 à 100 Hz. O segundo usa um filtro de eliminação da linha de base e com o mesmo se produziu os melhores resultados.”

“O algoritmo de codificação é mostrado a seguir. O algoritmo permite codificação apenas de dados de baixa frequência; as áreas críticas (QRS e T) permanecem sem compressão. Isto efetivamente reduz a razão teórica de compressão dada anteriormente mas garante a preservação das áreas mais críticas.”

Algoritmo de Codificação

1. Capture o vetor do ECG de exercício.
2. Encontre o vetor de codificação mais próximo da base de códigos.
3. É a “distorção” menor que o máximo limite?
4. SIM : Inserir o índice do vetor de código no arquivo comprimido.
5. NÃO : Marcar o vetor como “original” e inseri-lo no arquivo comprimido.
6. Volte ao passo 1.

Decodificação O algoritmo de decodificação é mostrado em seguida . A codificação é realizada de uma maneira que assegure ao decodificador distinguir entre um índice que o aponta como sendo de alta frequência ou não.

Algoritmo de Decodificação

1. Colher o vetor de ECG convertido
2. É um índice na base de códigos?
3. SIM : Inserir o vetor de codificação no arquivo de reconstrução
4. NÃO : Decifrar o código e inserir o vetor original no arquivo de reconstrução
5. Voltar ao Passo 1.

Testes de Comparação (McAuliffe [51]) “O primeiro teste examina os resultados obtidos da codificação de três testes de exercícios diferentes utilizando a mesma base de códigos. Os três componentes de dados totalizaram aproximadamente 25 M bytes. Em cada um dos testes tinha-se diferentes níveis de ritmo cardíaco e vários níveis de interferência por ruído . A comparação foi realizada variando-se o “tamanho ” do vetor de 2 amostras até 10 amostras e utilizando dois valores diferentes de máximo valor de distorção . A distorção pode ser definida por :”

$$\text{Distorção} = \sum_{\text{tam. do vetor}} (\text{distância})^2 ,$$

onde : distância = distância entre o vetor original e o escolhido da base de códigos.

“Se a distância ao quadrado é ajustada para $1875\mu V$, então a distância será limitada no máximo à $43\mu V$ por amostra em cada vetor”. (Este é o limite inferior citado no artigo e na figura exposta). Cita o autor que a distância de $43\mu V$ ainda não está próxima aos padrões da CSE de $20\mu V$ e longe das recomendações da American Heart Association, AHA, de 1989, para transmissão e armazenamento digital de ECG, que é de $10\mu V$. Porém, a especificação da AHA (Knoebel [42] e Bailey [7]) se refere à conversão analógica-digital inicial do sinal, e ainda é um limite desejável como “ideal”, apenas. Se a distância quadrática for o dobro, i.e., $3750\mu V$ por vetor amostrado a distância será de $61\mu V$ por amostra. Estes dois pontos servem como delineador para separar componentes de alta dos de baixa frequência durante o processo de codificação e foi definido arbitrariamente.”

“Para estudar os efeitos do processo de criação da base de códigos, tal base foi construída utilizando vetores de treinamento gerados de diferentes partes de quatro testes de exercício. Esta outra base de códigos foi comparada com a primeira usando o mesmo conjunto de testes, com o objetivo de ver o quanto a base de códigos pode generalizar. O objetivo do sistema, entretanto, é tirar a necessidade a priori de conhecimento sobre os dados a serem codificados.”

“O conjunto de teste utilizado foi selecionado para ser uma mistura de diferentes ritmos cardíacos e níveis de ruído; primariamente a base de códigos 1 foi dominada por alta frequência cardíaca e a base de códigos 2 por baixa frequência cardíaca.”

Base de Cód. 1	F.PO	C.EO	A.E1	J.R2
	HR = 48	HR = 132	HR = 132	HR = 156
Base de Cód. 2	M.PO	Y.EO	J.EO	N.RO
	HR = 78	HR = 84	HR = 138	HR = 90

Tabela 4.1: Compressor Kohonen , dados da base de códigos

Composição da Base de Códigos OBS : P = estágio de descanso; E = estágio de exercício; N^o= número do "File" ; HR =Frequência cardíaca . Ex : J.E1 = "File" do indivíduo J , segundo "file", no estágio de exercício.

Resultados Ambas as bases de códigos tiveram performance similar na codificação dos testes e do treinamento. Isto é mostrado na tabela a seguir, onde os valores de erro estão em μV .

	Base de Códigos 1			Base de Códigos 2		
	Max	Min	Med	Max	Min	Med
Erro RMS	28,6	8,6	18,35	29,1	7,9	17,2
Erro médio de pico	175	110	120	175	85	125
Erro max. absoluto	20	5,35	11,9	23,5	4,65	11,5
CR	19	3,5	8,4	18	3,4	8,0

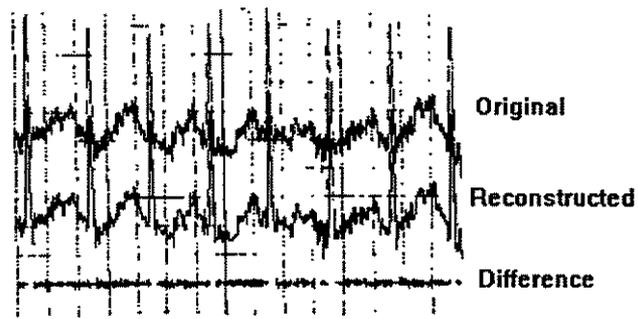
Tabela 4.2: Ensaio do Compressor Kohonen em função da base de códigos

A Figura 4.1, mostra o resultado obtido pelo autor para :

- A Melhor caso para Lead II , comprimento do vetor = 4 amostras , resultando CR =4,1.
- B Pior caso para Lead II , comprimento do vetor = 10 amostras, resultando CR = 2,4.
- C Pior caso para Lead II , comprimento de vetor = 10 amostras , resultando CR = 3,5.

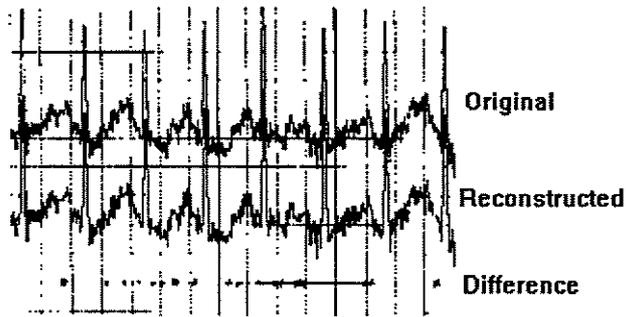
“Foi feito também estudo com todo o set do ECG de exercício e obteve CR global em torno de 6. No ensaio, foi utilizado o filtro de “dePinto” [20], para eliminação de artefatos musculares .Vê-se que a técnica já chega perto da performance dos métodos tradicionais citados no início do trabalho. Isto mostra que um novo campo de pesquisa se abre para a utilização de redes neurais para auxílio ou realização de compressão de sinais, no caso o ECG”.

Vetor com comprimento de 4 amostras



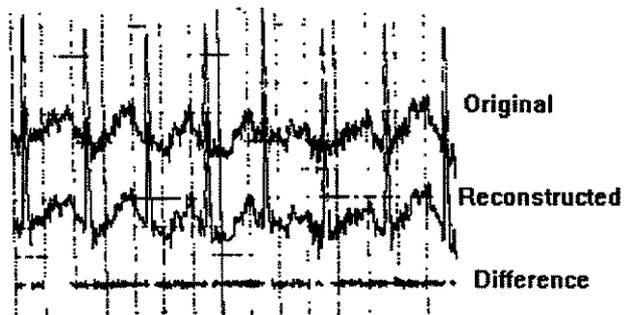
A - melhor caso lead II

**Vetor com comprimento de 10 amostras
com limite inferior**



B - pior caso lead II

**Vetor com comprimento de 10 amostras
com limite superior**



C - pior caso lead II

Figura 4.1: Mostra do desempenho do Compressor por Kohonen

Conclusão parcial desta técnica

1. A técnica de quantização vetorial por utilização de base de códigos utilizando KNN mostra ser promissora também para compressão de sinais de ECG.
2. O autor sugere criar ainda uma base de códigos bidimensional, em termos temporal e espacial (o tempo e os vários Leads de ECG ao mesmo tempo).
3. O autor sugere ainda utilizar outras bases de dados de ECG para melhorar o desempenho da rede KNN e conseqüentemente da base de códigos.
4. Obviamente , o que diminui o alto CR obtido teoricamente e na prática para a técnica é o fato de sinais de alta frequência não ter nenhuma compressão.
5. Apesar de hoje em dia se obter CR bem mais alto com técnicas similares ou equivalentes, este artigo é uma referência para trabalhos na área de compressão de ECG por KNN. Vide os resultados obtidos pelo autor na página seqüente.

Compressão de ECG por RNA Perceptron como Autoassociadora

Análise do artigo de Iwata [37], sobre utilização de redes neurais do tipo Perceptron na compressão de sinais de ECG :

Uma alternativa extremamente viável de se comprimir sinais de ECG através de Redes Neurais foi proposta e implementada por um grupo de aplicações de um neurocomputador do “Nagoya Institute” (Iwata [38] e [37]), onde foi aplicada uma técnica de compressão utilizando uma Rede Neural Artificial, do tipo Perceptron de três camadas, onde as camadas de entrada e saída são compostas de 70 unidades cada. A camada escondida se constitui de apenas 2 unidades, de onde se extrai a compressão do sinal. O algoritmo de aprendizado é o tradicional “backpropagation”. A rede é ensinada por supervisão, sendo que os sinais alimentados na entrada e saída são os mesmos, a fim de proporcionar a extração da compressão.

A compressão do sinal é realizada em tempo real, de maneira a se “seguir” o sinal no tempo, para extração de seu código comprimido. O sistema é ainda bem mais sofisticado, pelo fato de utilizar duas redes neurais iguais em tempo real, para que tenha uma no estado de espera, que irá atuar caso o sinal se distancie muito do atual, e fazendo com que tenha que aprender de novo sobre o mesmo sinal do paciente. O processo de decisão de fazer atuar

a “rede de espera” é o de erro quadrático. Se o erro for pequeno, o sinal comprimido será extraído da rede que já aprendeu; se o erro cresce, o sistema decide acionar a rede de espera para a mesma aprender com a nova morfologia do sinal. Após o aprendizado, ela começa a atuar como extratora do código de compressão. Então a antiga rede se torna a de espera. Além disto, o sistema, decidindo que o erro é muito grande (isto é, o sinal mudou muito de morfologia), guarda o sinal original até que se reestabeleça um novo padrão, onde as redes possam de novo atuar como extratoras do código de compressão.

A compressão final do sistema se situa de 1 :15 até 1 :100; com “erro RMS” de 0,1 a 0,5%, que é um grande resultado atual!. Esta medida de erro não é padrão, e por isso foi adicionada na Tabela 4.3, que trata do desempenho do compressor em questão, uma outra coluna de erro PRD equivalente, que é a medida reconhecida mundialmente para avaliação de compressores de ECG.

O trabalho é bastante empírico, no sentido de se criar as redes e ir truncando arbitrariamente os valores armazenados dos pesos da camada escondida e de interconexão, em função da observação do erro RMS porcentual obtido.

Os autores chegam à conclusão de que são necessários 4 bits para se representar adequadamente os pesos de ativação da camada escondida e 8 bits para representar os pesos de ativação de interconexão (entre as camadas externa e interna da rede). Para efeito de comparação, foram extraídos dos gráficos os CRs obtidos para os sinais que foram expostos no referido artigo. Como eles utilizaram a base de dados do MIT-BIH, fica fácil realizar comparações, mesmo que parciais :

A Figura 4.2 a seguir ilustra os resultados obtidos pelos pesquisadores com algumas amostras de sinais da base de dados do MIT-BIH :

4.1.3. O Compressor Desenvolvido

Compressão de sinais de ECG com “RNA Multilayer Perceptron” com três camadas arranjadas como um “Auto-associador”.

Introdução : As redes intituladas “multilayer feedforward neural networks” são as redes mais utilizadas em inúmeras aplicações. Em geral se apresentam com uma camada de entrada, uma ou mais camadas intituladas “escondidas” e uma camada de saída. Cada entrada se

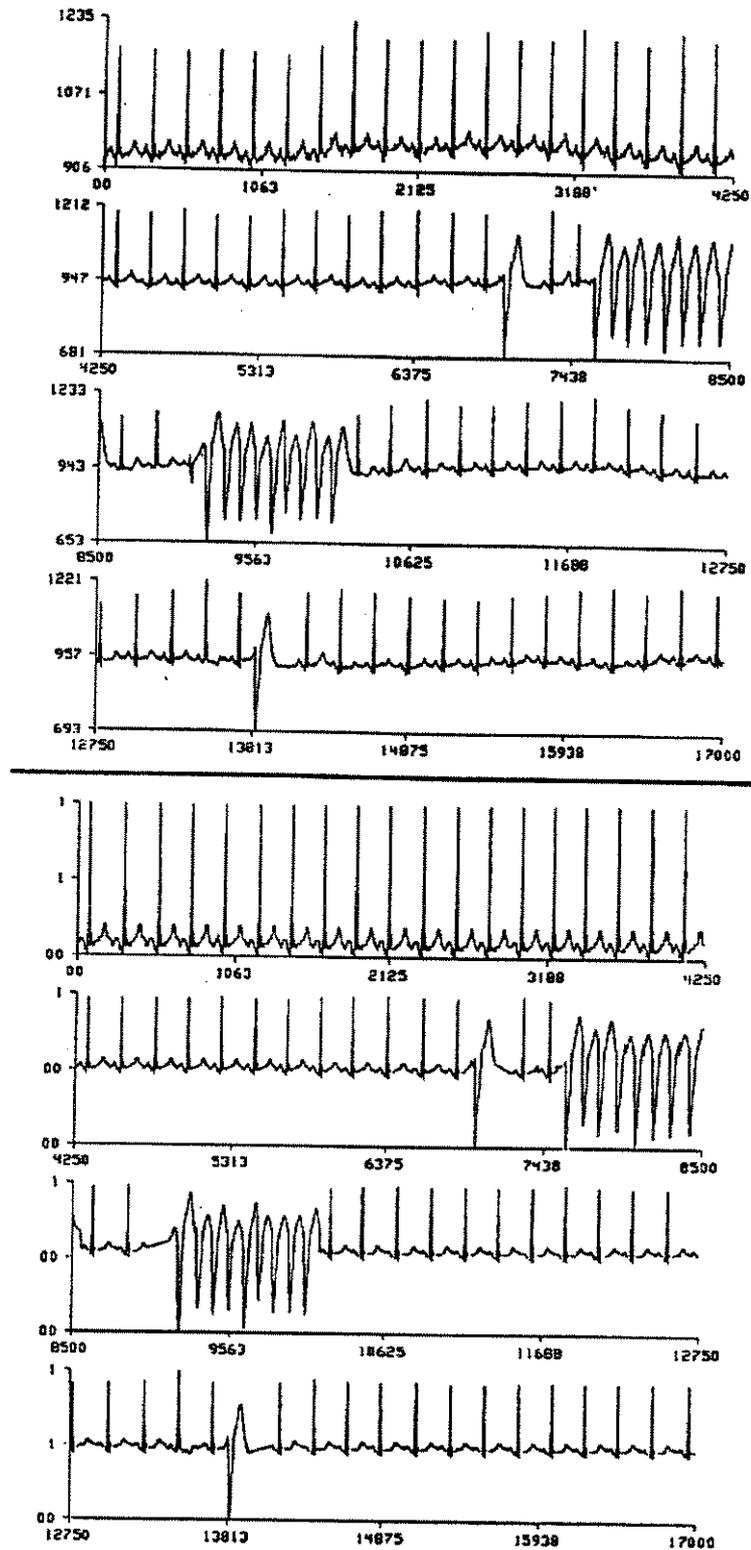


Figura 4.2: Desempenho do Compressor de Iwata (Superior= Sinal Original)

SINAL	Erro RMS%	Erro- μV	Erro PRD%	CR
100	0,05	5	0,12	67
101	0,44	44	1,1	77
102	0,27	27	0,65	16
103	0,05	5	0,12	77
106	0,26	26	0,64	42
112	0,18	18	0,43	100
113	0,26	26	0,64	53
114	0,24	24	0,57	42
115	0,1	10	0,24	115
117	0,5	50	1,2	22

Tabela 4.3: Performance do compressor por RNA como auto-associadora

conecta aos neurônios da camada seguinte como se fossem neurônios naturais, sendo que cada neurônio, então recebe todos os sinais da camada anterior, sendo caracterizado por um somatório ponderado destas entradas por pesos de interconexão associada a cada entrada. Esta somatória é então tratada por uma função de discriminação, em geral não-linear, que então transmite seu resultado para a próxima camada. Logo, o sinal de entrada se propaga pela rede em direção direta da entrada para a saída, camada por camada, dando o nome de “Feedforward”. Estas redes também tem o nome de “Multilayer Perceptron” (MLP), (Haykin [30]), pois sua estrutura básica é de um neurodo do tipo Perceptron, idealizado por Rosenblatt e como a estrutura da MLP é de múltiplas camadas, esta rede pode realizar classificação de padrões de entrada em mais de duas classes.

A maneira de se “programar”, ou treinar a rede, é supervisionada, usando como parâmetro de aprendizado a retropropagação do erro entre sua resposta e a grandeza de supervisão.

Este algoritmo é baseado na regra do “aprendizado por correção de seus erros”, técnica esta muito conhecida e utilizada pelos seres humanos em inúmeras fases do aprendizado. O nome popular deste algoritmo para redes neurais é “Backpropagation”. Ele consiste da realização de duas fases básicas: uma direta, onde o vetor de entrada é aplicado às entradas da rede e que se faz propagar até a saída, produzindo então um vetor de saída. Nesta fase, os pesos de interconexão da rede são mantidos fixos. Na segunda fase, a de retro-propagação,

todos os pesos de interconexão são ajustados de acordo com a regra de correção de erros . Na verdade, a resposta da rede na fase direta é subtraída do valor desejado (vetor de alvo ou “target”) que então produz um sinal de erro. Este erro é retro-propagado pela rede, com relação aos pesos de interconexão. Este, então é o algoritmo básico do “Back-propagation Learning.”

Características da MLP

a Cada neurônio contém uma não-linearidade após o evento da somatória, que colabora com a função discriminante da rede. Esta não-linearidade deve ser diferenciável em toda sua faixa, pois o algoritmo usa a derivada desta função, e assim se obtém melhor desempenho computacional. A função mais utilizada é a função sigmóide, definida por :

$$\text{out } j = \frac{1}{1 + \exp(-\text{hid } j)}$$

onde “out j ” é a saída resultante, e “hid j ” é a resultante da somatória dos pesos de interconexão da camada de entrada e camada escondida.

- b A rede tem ao menos uma camada escondida, a fim de permitir um processamento mais efetivo dos vetores de entrada.
- c A rede tem um auto grau de conectividade, isto é, todos os neurônios de entrada são conectados a todos os neurônios da camada escondida, que por sua vez tem todos seus neurônios conectados à camada de saída .

Algoritmo Utilizado :

Foi utilizado o algoritmo de treinamento publicado por Fausett [21]. O algoritmo implementado se resume a seguir :

Passo 0 Inicialize os pesos. (Utilize valores iniciais aleatórios pequenos.)

Passo 1 Enquanto a condição de parada é falsa, realize os passos de 2 a 9.

Passo 2 Para cada par de treinamento, realize os passos de 3 a 8.

Feedforward :

Passo 3 Cada unidade de entrada ($X_i, i = 1, \dots, n$) recebe um sinal de entrada x_i e transmite este sinal para todas as unidades da camada posterior (as unidades escondidas).

Passo 4 Cada unidade escondida ($Z_j, j = 1, \dots, p$) soma seus sinais de entrada, $z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij}$, e aplica sua função de ativação para computar o sinal de saída, $z_j = f(z_in_j)$, e então envia este sinal para todas as unidades da próxima camada (unidades de saída).

Passo 5 Cada unidade de saída ($Y_k, k = 1, \dots, m$) soma seus sinais ponderados de entrada, $y_in_k = v_{0k} + \sum_{i=1}^n x_i v_{ik}$, e aplica sua função de ativação para computar o sinal de saída, $z_k = f(z_in_k)$.

Retropropagação do erro :

Passo 6 Cada unidade de saída ($Y_k, k = 1, \dots, m$) recebe um padrão de alvo correspondente àquele padrão específico de entrada, computa seu termo de informação de erro, $\delta_k = (t_k - y_k) f'(y_in_k)$, calcula seu termo de correção de peso (usado para atualizar o peso w_{jk} , mais tarde), $\Delta w_{jk} = \alpha \delta_k z_j$, e calcula seu termo de correção de erro de “Bias”, ou Polarização, (usado para atualizar o peso w_{ok} , mais tarde), $\Delta w_{ok} = \alpha \delta_k$, e envia δ_k para as unidades da camada anterior.

Passo 7 Cada unidade escondida ($Z_j, j = 1, \dots, p$) soma suas respectivas entradas deltas, (vindas de unidades da camada anterior),

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk},$$

multiplica pela derivada de sua função de ativação para calcular o termo de erro, $\delta_j = \delta_in_j f'(z_in_j)$, calcula seu termo de correção de peso, $\Delta v_{ij} = \alpha \delta_j x_i$, e calcula seu termo de correção de “bias”, (usado para atualizar o peso v_{oj} , mais tarde), $\Delta v_{oj} = \alpha \delta_j$.

Atualização dos pesos e polarizações (bias) :

Passo 8 Cada unidade de saída ($Y_k, k = 1, \dots, m$) atualiza seus pesos e bias ($j = 0, \dots, p$) :

$$w_{jk}(\text{novo}) = w_{jk}(\text{velho}) + \Delta w_{jk}$$

Cada unidade escondida ($Z_j, j = 1, \dots, p$) atualiza seus pesos e bias ($i = 0, \dots, n$) :

$$v_{ij}(\text{novo}) = v_{ij}(\text{velho}) + \Delta v_{ij}$$

Passo 9 Testa a condição de parada.

A rede MLP como Compressora /Expansora de Sinais

Se uma rede MLP tem o mesmo número de entradas e saídas , é possível indicar como saída desejada o mesmo sinal de entrada. Se ainda a camada escondida tiver menos neurônios que a entrada, será criado um extrator de códigos comprimidos através desta camada escondida.

Assim , a rede treinada desenvolve uma representação condensada do sinal que se extrai pela camada escondida. Observe que esta técnica é uma forma de auto-organização da rede.

Quando se quiser expandir o sinal comprimido, é apenas necessário se multiplicar os pesos da camada escondida pelos pesos de interconexão entre esta camada e à saída. O nome deste tipo de arranjo da rede MLP é conhecida por “autoencoder ” ou “autoassociator” (Haykin [30]).

O Compressor Desenvolvido

Foi desenvolvido uma rede MLP com 70 entradas , 2 neurônios na camada escondida e 70 saídas . O número de entradas e da camada escondida se baseia no artigo citado anteriormente (Iwata [37]), do grupo de desenvolvimento do “Nagoya Institute of Technology” de um neurocomputador aplicado na compressão de sinais de ECG para aplicação em Holters totalmente digitais.

No trabalho do grupo de Nagoia, foi realizado um estudo da resolução necessária para um erro médio inferior à 0,5% RMS, através de ensaios com a base de dados de ECG do MIT-BIH, onde puderam testar o sistema com variadas resoluções do tamanho da palavra da camada escondida e chegaram à conclusão que apenas 4 bits de resolução da camada escondida satisfazia a necessidade. Como 12 bits de resolução do sinal de entrada é mais que suficiente para qualquer diagnóstico posterior, chegaram a um CR de :

$$CR = 70 \cdot (12\text{bits})/2 \cdot (4\text{bits}) = 105,$$

o que é um enorme potencial de razão de compressão.

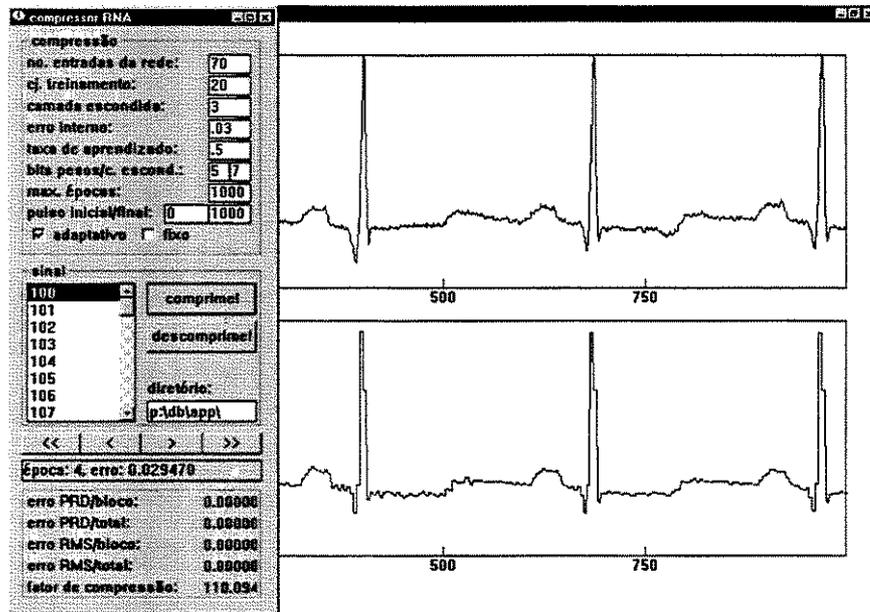


Figura 4.3: Visualização da tela de simulação do compressor RNA

O que foi implementado :

Desenvolveu-se o algoritmo citado, porém com possibilidade de se alterar vários parâmetros do sistema, a fim de se observar a experimentação realizada pelo autor, já que o artigo é muito resumido e não se explora detalhes.

Na Figura 4.3 apresenta-se a disposição de tela do programa que realiza a compressão.

Note que foi deixado os seguintes parâmetros como “ajustáveis” :

1. **nºentradas da rede** : tamanho do vetor de entrada, que corresponde diretamente ao número de entradas da rede neural (default=70).
2. **c.j.treinamento** : quantidade de pulsos do arquivo que serão utilizados para treinamento da rede neural (default=20).
3. **camada escondida** : número de neurônios da camada escondida.
4. **erro interno** : erro quadrático absoluto.
5. **taxa de aprendizado** : valor inicial da taxa de aprendizado, que se deixou variável, segundo sugere Haykin [30].
6. **bits pesos/c.escond.** : valor de truncagem dos valores dos pesos de interligação e da camada escondida.

7. **máx.épocas** : número máximo de épocas que se deseja deixar o algoritmo convergindo, na fase de aprendizado, independentemente de ter alcançado o erro interno estabelecido no item 4.
8. **pulso inicial/final** : seleção do trecho de arquivo no qual vai se aplicar o processo de compressão, medido em número de pulsos, que também se nomeia por um “bloco” de sinal.
9. **adaptativo** : opção de se inserir no futuro algum procedimento de adaptabilidade.
10. **fixo** : algoritmo fixo, sem processo de adaptabilidade.
11. **Sinal** : os códigos dos sinais da base de dados do MIT-BIH que se vai realizar a compressão e descompressão, selecionável através da barra de rolagem.
12. **Comprime** : Botão de disparo do processo de compressão.
13. **Descomprime** : Botão de disparo do processo de descompressão do arquivo já comprimido.
14. **Diretório** : diretório onde se localizam os referidos sinais.
15. **Botões de sentido “Esquerdo” lento e rápido, e “Direito” lento e rápido** : Dado que um certo sinal foi selecionado, comprimido e depois descomprimido, permite visualizar o arquivo dos sinais original e descomprimido, em função do “eixo do tempo virtual”.
16. **Erro PRD/bloco** : Erro PRD calculado no bloco do sinal que se está vendo na tela.
17. **Erro PRD/total** : Erro PRD calculado em todo o arquivo do sinal selecionado.
18. **Erro RMS/bloco** : Erro RMS calculado no bloco do sinal que se está vendo na tela.
19. **Erro RMS/total** : Erro RMS calculado em todo o arquivo do sinal selecionado.
20. **Fator de Compressão** : O CR obtido em todo o arquivo do sinal em questão.

4.1.4. Resultados

A Tabela 4.4 ilustra os resultados típicos que se obtém quando se aplica a RNA compressora desenvolvida, com requisitos parecidos com aqueles aplicados no compressor PCA-NIPALS (que será apresentado a seguir), isto é, blocos de 240 pulsos de ECG, porém com

reamostragem do sinal para 70 amostras, como foi proposto por Iwata [37]. Nota-se que não se conseguiu obter os resultados de baixo erro citados por Iwata [37], porém obteve-se maiores índices de compressão que o mesmo obteve. Nestas tabelas, o asterisco representa que a iteração foi truncada, pois foi considerada como máximo de número de épocas, para efeito prático, o valor 1000. Na Figura 4.4 se apresenta a curva $R(D)$ obtida com o compressor desenvolvido. Nota-se também que não se consegue obter erros inferiores, em média, a $85\mu V$, que pode ser devido ao baixo “sampling rate” que se utilizou, de apenas 70 amostras por pulso, segundo o autor.

Quando se impõe uma razão maior, por exemplo de 285 amostras, a rede não converge para sinais mais complexos, inviabilizando sua aplicação. Ilustra-se na Figura 4.5 a aplicação da rede para um trecho de sinal onde há apenas, uma extra-sístole, que faz a rede repetir o pulso mais provável, que ela tinha aprendido anteriormente, indicando que ela está muito especializada. Quando se opta por fazê-la mais generalista, aumentando-se o número de pulsos do ciclo de aprendizado, a mesma não converge em termos práticos de futura utilização, que seria de até 1000 épocas. Quem sabe seja este o motivo do autor diminuir tanto esta razão de amostragem, pois com 70 pulsos a mesma converge rapidamente para boa parte dos sinais, porém, esta razão de amostragem está fora das exigências da área. O curioso é que mesmo quando se permite o sistema aprender por muitas épocas, como ilustrado nas Figuras 4.6 e 4.7, o erro não caiu significativamente, como se era de esperar pelo artigo do autor. Inclusive o sinal 100 com 50.000 épocas, até incrementou o nível de ruído aleatório no sinal descomprimido, indicando, provavelmente, que a rede encontra vários mínimos locais com profundidades próximas, pois a forma de onda média tem a mesma morfologia da original, aparentemente.

4.2. Compressão por Análise de Componentes Principais

4.2.1. Compressão pelo Algoritmo de NIPALS

No Capítulo 3.3., foi vista a descrição do processo de Análise de Componentes Principais (PCA) por Algoritmo de NIPALS. O mesmo procedimento pode ser aplicado para realizar

Sinal	Erro _{total} PRD %	Erro _{total} μV	CR	Épocas
100	1,8	80	161	4
101	6,5	286	167	36
102	2,9	129	160	4
103	2,5	112	170	4
104	4,6	203	148	1000*
105	2,2	99	142	4
106	6,7	300	165	1000*
107	6,1	271	170	1000*
108	4,5	196	205	7
109	5,2	227	137	1000*
111	3,7	167	170	1000*
112	4,0	154	140	4
113	4,6	210	207	1000*
114	3,0	133	217	4
115	4,9	204	190	1000*
116	7,0	265	152	1000*
117	3,4	132	239	1000*
118	4,8	185	164	1000*
119	8,5	318	131	1000*
121	2,4	90	154	1000*
122	4,5	171	106	4
123	5,3	204	185	1000*
124	3,3	128	186	1000*

Tabela 4.4: -Desempenho do compressor RNA com os sinais do MIT-BIH

Sinal	Erro _{total} PRD %	Erro _{total} μV	CR	Épocas
200	7,1	318	99	1000*
201	1,6	70	102	348
202	2,6	116	173	1000*
203	7,6	343	84	1000*
205	9,6	430	84	1000*
207	8,3	374	156	1000*
208	6,1	274	111	1000*
209	2,4	107	126	1000*
210	3,4	151	134	1000*
212	4,4	198	130	1000*
213	5,2	226	109	1000*
214	7,1	318	114	1000*
215	3,7	165	106	4
217	9,3	165	106	1000*
219	4,9	200	156	1000*
220	2,9	119	167	4
221	3,0	132	149	1000*
222	2,0	94	160	1000*
223	3,4	141	146	4
228	8,8	393	151	66
230	6,1	273	145	1000*
231	4,5	200	181	1000*
232	11,7	523	200	1000*
233	11,7	523	111	1000*
234	3,3	147	129	1000*

Tabela 4.5: Desempenho do compressor RNA com os sinais do MIT-BIH

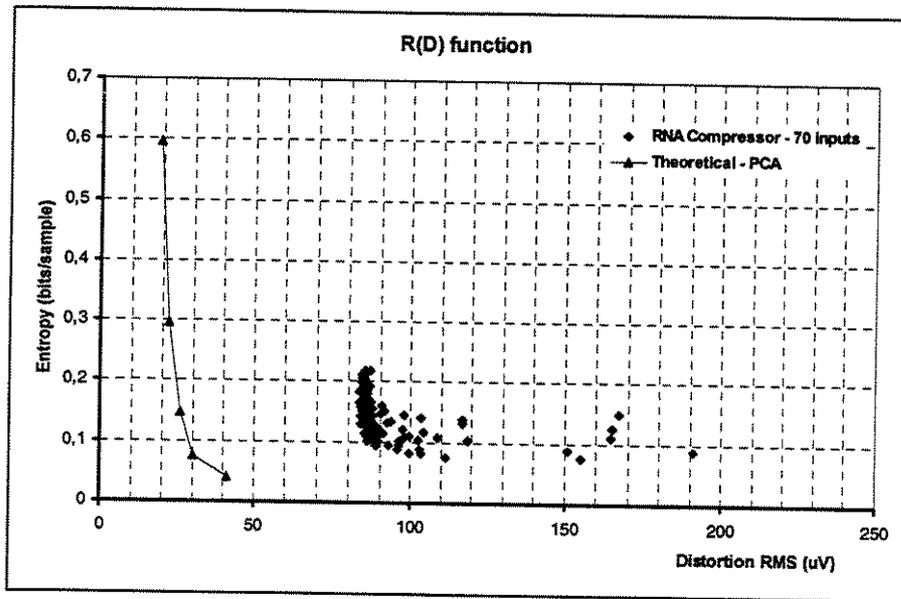


Figura 4.4: Desempenho do compressor RNA com os sinais do MIT-BIH

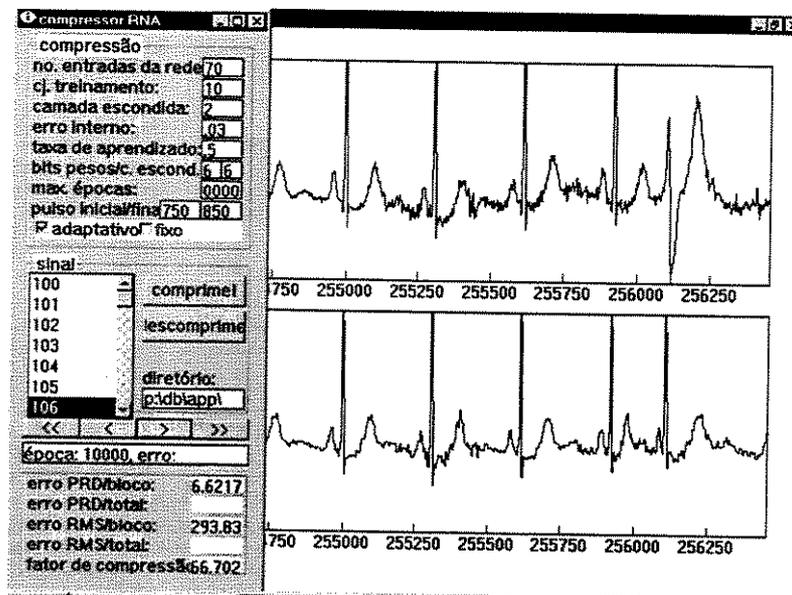


Figura 4.5: Mostra do compressor RNA com o sinal 106 do MIT-BIH, ilustrando um pulso ectópico que a rede não consegue representar.

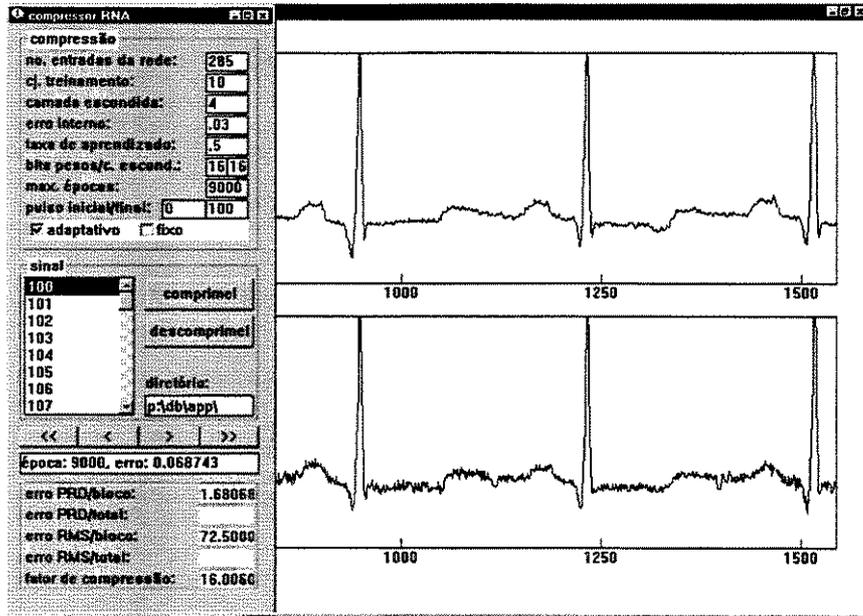


Figura 4.6: Mostra do compressor RNA com o sinal 100 do MIT-BIH, ilustrando 285 amostras , que foi interrompido em 9000 épocas.

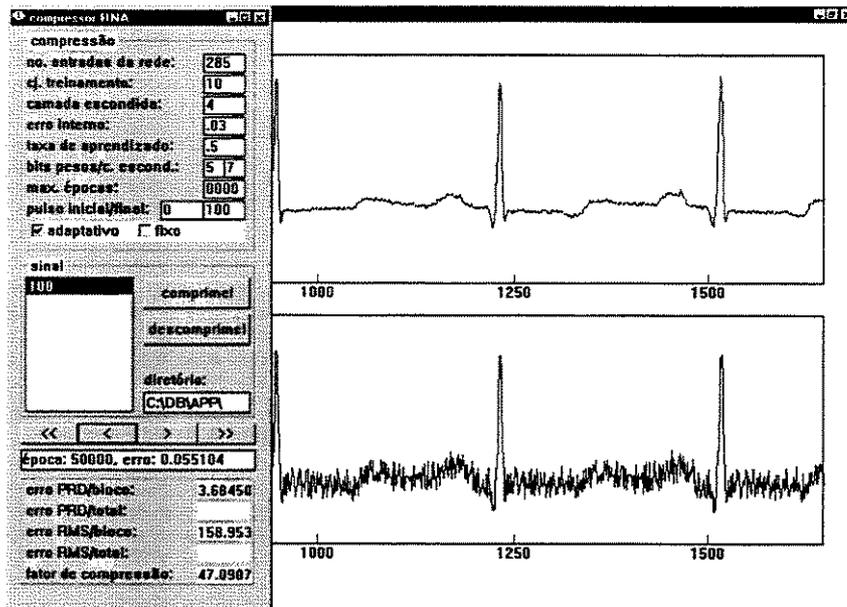


Figura 4.7: Mostra do compressor RNA com o sinal 100 do MIT-BIH, ilustrando 285 amostras , que foi interrompido em 50000 épocas.

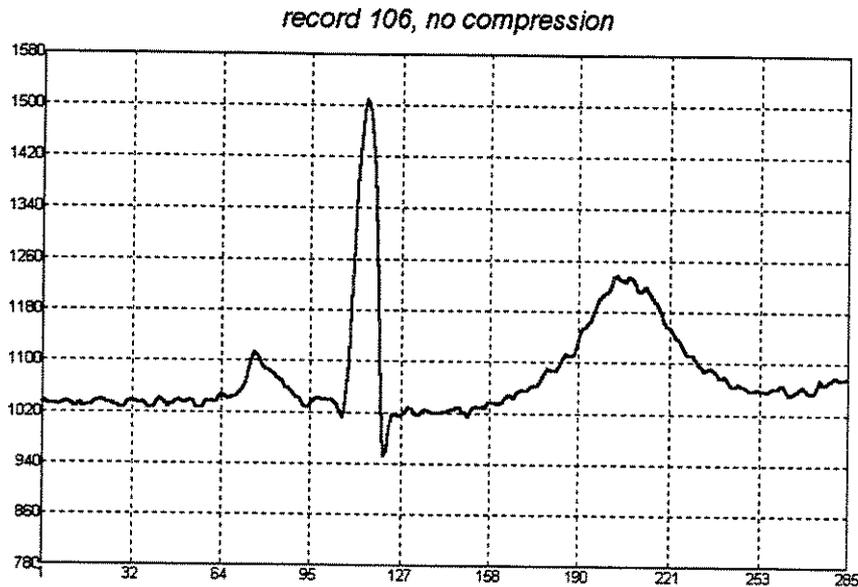


Figura 4.8: Um pulso original do sinal 106

compressão do sinal de ECG. O algoritmo básico é o mesmo (Vide Item 5.2.3) excetuando-se que, ao invés de se determinar o PC através de uma matriz com todos os pulsos de cada sinal (têm-se aproximadamente 2000 pulsos para cada sinal de paciente com tempo total de meia hora), monta-se uma matriz com 240 pulsos (um quadro), de onde se extrai os autovetores, autovalores e scores destes 240 pulsos. O processo se repete de quadro em quadro. Foi realizado um ensaio de compressão e descompressão em função do número de componentes principais utilizadas, e observou-se que com 7 PCs obtém-se erro RMS típico de $50\mu V$ (0,5% do fundo de escala) e morfologia excelente quando comparada com o original.

A Figura 4.9 ilustra a recuperação do primeiro pulso do sinal 106 com esta técnica. A Figura 4.8 mostra o mesmo primeiro pulso original.

Na Figura 4.11, ilustra-se o mesmo processo de compressão e recuperação para o pulso numerado como 1990 do sinal 106, que é um pulso anômalo. A Figura 4.10 ilustra este pulso original.

A Figura 4.12 ilustra um “filme” do sinal comprimido e recuperado em função de cada PC, de número 1 até 7, acumulativamente, e no fim apresenta-se o sinal original.

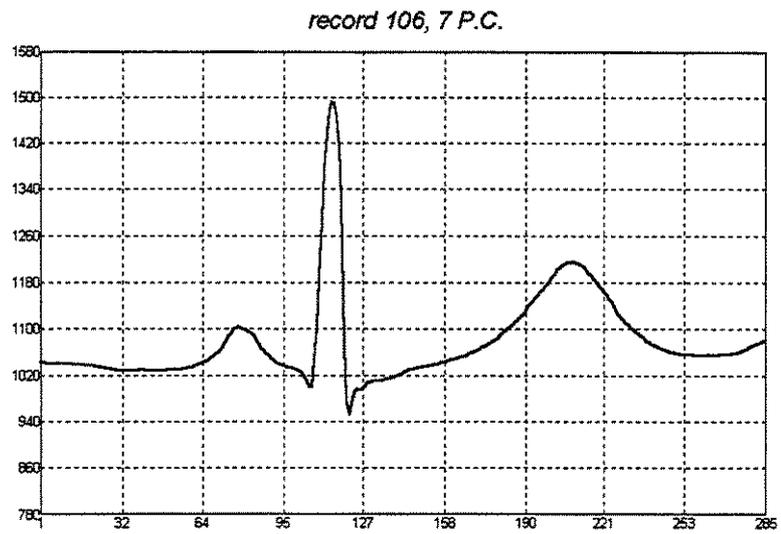


Figura 4.9: O mesmo pulso do sinal 106 comprimido e recuperado por 7 PCs

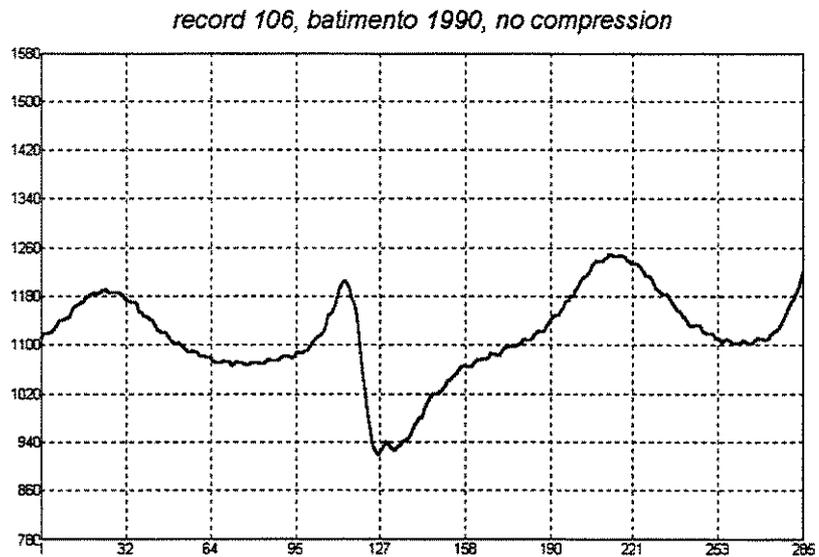


Figura 4.10: Pulso 1990, anômalo, do sinal 106 - Pulso Original

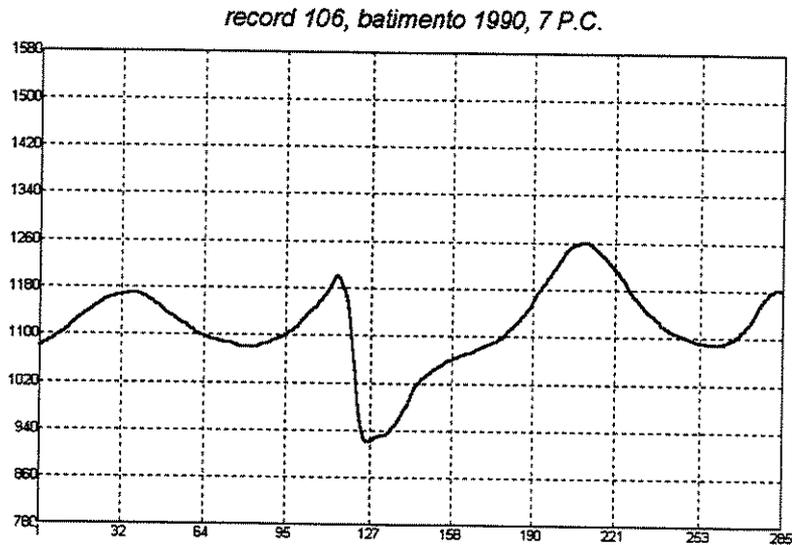


Figura 4.11: Pulso 1990 do sinal 106 comprimido e recuperado com 7 PCs

4.2.2. O Compressor Desenvolvido

Introdução

Um cálculo do poder de compressão desta técnica é ilustrado a seguir :

- tamanho da matriz (quadro) : 285×240 amostras
- resolução das amostras : 11 bits
- número de componentes principais : 7 PCs
- resolução dos scores (ou coeficientes) : 16 bits
- tamanho dos autovetores : 285×11 bits
- tamanho da matriz de scores : 240×16 bits

Então, tem-se em cada quadro :

- Sinal original = $(285 \times 240 \times 11)$ bits
- Sinal comprimido = $7 \times (285 \times 11 + 240 \times 16)$

$$CR = \frac{285 \times 240 \times 11}{7(285 \times 11 + 240 \times 16)} = 15,4 : 1$$

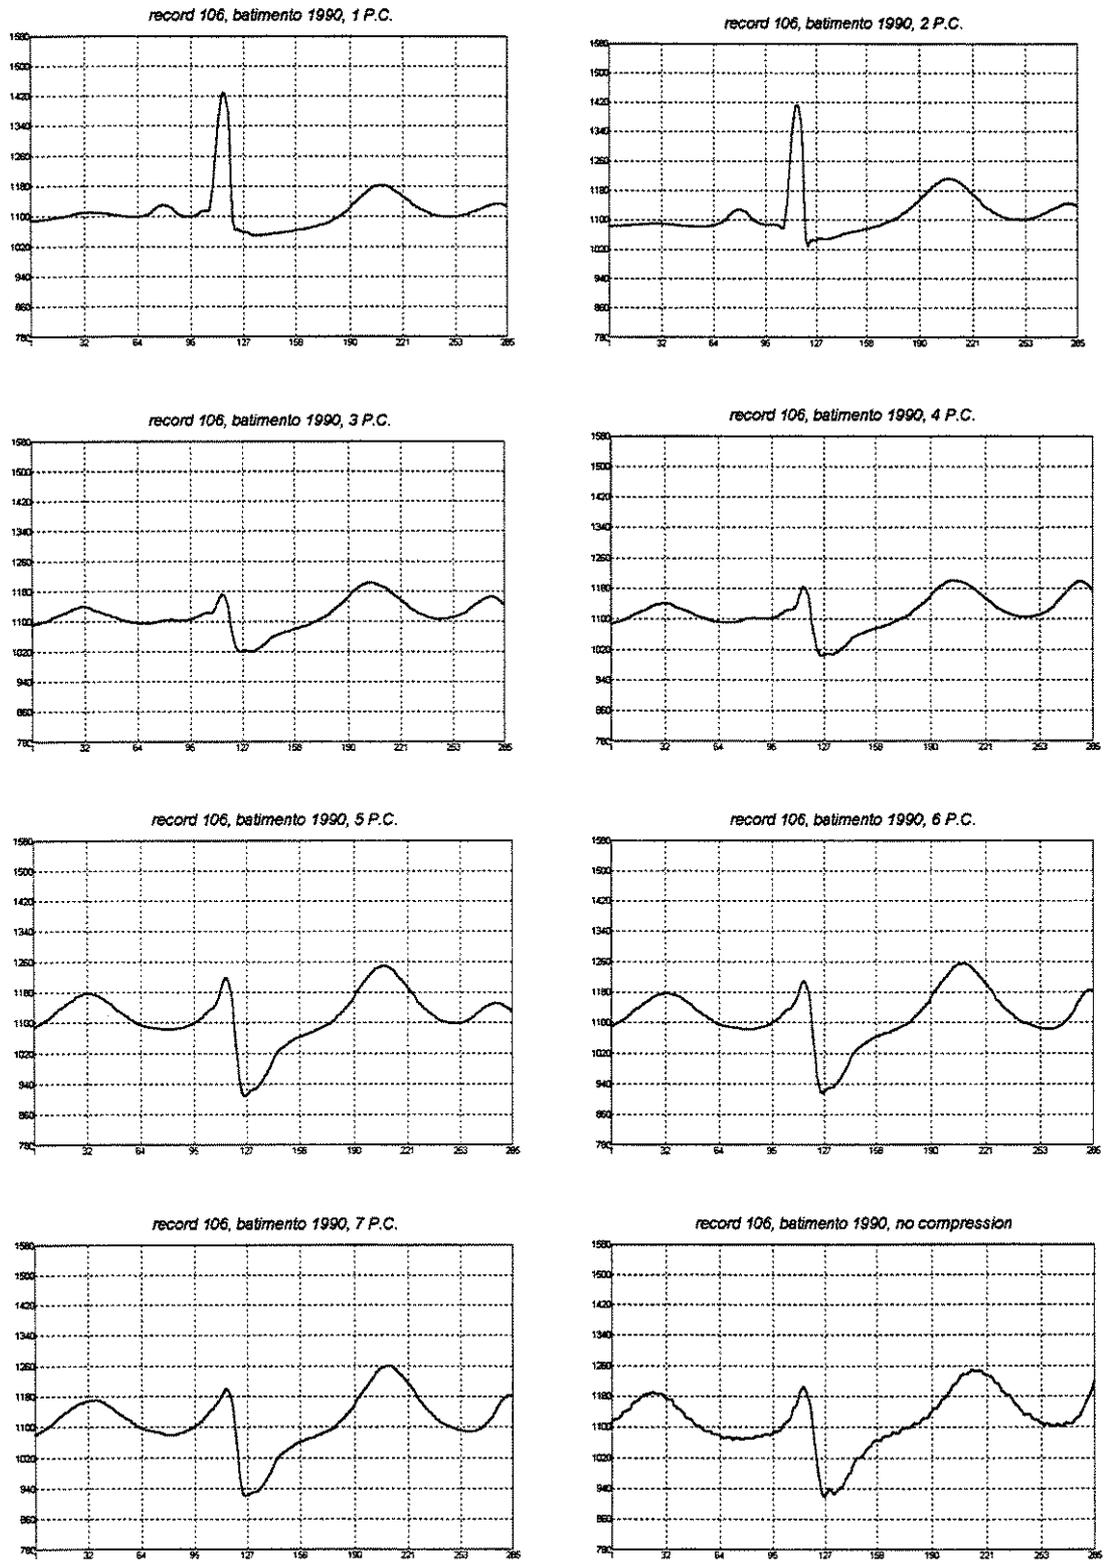


Figura 4.12: Filme do sinal comprimido e recuperado em função de cada PC de 1 até 7 e no fim, o sinal original.

Se for truncada a resolução dos scores para 7 bits e os autovetores para 5 bits, tem-se :

$$CR = \frac{285 \times 240 \times 11}{7(285 \times 5 + 240 \times 7)} = 34,6 : 1$$

Se, além de truncar a resolução dos scores para 7 bits e os autovetores para 5 bits, se utilizar apenas 3 PCs, tem-se :

$$CR = \frac{285 \times 240 \times 11}{3(285 \times 5 + 240 \times 7)} = 80,7 : 1$$

Se, além de truncar a resolução dos scores para 7 bits e os autovetores para 5 bits, se utilizar 1 PC, tem-se :

$$CR = \frac{285 \times 240 \times 11}{1(285 \times 5 + 240 \times 7)} = 242 : 1$$

Isto demonstra o potencial do algoritmo. É possível, então, se otimizar o processo com :

- a) Truncagem da resolução dos valores dos scores e dos autovetores.
- b) Diminuição automática e adaptativa do número de PCs.
- c) Aproveitamento dos autovetores do quadro passado no quadro futuro.
- d) Aumento do tamanho do quadro.
- e) Codificação do sinal comprimido por Huffman.

Um ensaio deste processo com o software desenvolvido, com o sinal 106 completo (e cumprindo os itens “a”, “b” e “d” supra), com processo adaptativo e com truncagem dos Scores em 5 bits e truncagem dos Loadings (autovetores) em 7 bits, produziu um CR de 21,6.

Com o sinal 117, obteve-se um CR global de 71,9. Lembra-se que neste ensaio foi programado para o algoritmo salvar no mínimo 3 PCs e com os valores de truncagens supracitados. Pode-se então comparar este resultado com o valor acima obtido teoricamente de 80,7. Foi então, no caso de aplicação com um sinal “super bem comportado”, atingido na prática quase o limite teórico previsto !

É importante ressaltar que os arquivos obtidos após a compressão foram passados por um compressor de Huffman (que inclusive faz primeiramente a estatística do sinal e em seguida cria a tabela de códigos de compressão) e o arquivo aumentou de tamanho, indicando que não se tem muito mais a extrair do arquivo !

Vide a seguir uma ilustração do ocorrido com o sinal 100. A extensão “.PAK” é o sinal comprimido e a extensão “.HUF” é o arquivo após ser comprimido por Huffman. É provável que o aumento do tamanho do arquivo foi devido ao algoritmo ter acrescentado ao mesmo a tabela de compressão (que ele cria após realizar a estatística do sinal). Neste caso, parece que o algoritmo de Huffman não otimizou nada do arquivo, isto é, o arquivo comprimido por PCA-NIPALS é totalmente descorrelacionado, acusando a eficiência da compressão, como descrito pela Figura 4.13.

```

O volume da unidade P é Servidor1
Diretório de P:\db\APP

CD100   ANN       17.724  31/10/97  14:34  CD100.ANN
CD100   HUF       32.695  22/06/99  22:01  CD100.HUF
CD100   OUT     1.296.000  28/11/97  10:50  cd100.out
CD100   PAK       32.120  22/06/99  22:00  cd100.pak
4 arquivo(s)                1.378.539 bytes
0 diretório(s)             194.183.168 bytes livres

```

Figura 4.13: Ilustração do ocorrido com o sinal 100

Tentou-se explorar o item “c” - Aproveitamento dos autovetores do quadro passado no quadro futuro, porém não se obteve o sucesso que era esperado. Imaginava-se que os autovetores de cada bloco do sinal tivesse, para cada respectivo PC, a mesma distribuição ou “forma de onda”, para que se pudesse utilizar os autovetores do bloco atual no próximo, permitindo aumentar um pouco mais o CR, chegando perto da situação ideal de compressão. Porém, descobriu-se que os autovetores de cada bloco para um dado PC não são correlacionados, o que invalida a obtenção de um ganho adicional de compressão com esta metodologia. A Figura 4.14 ilustra esta situação.

Nota-se que as formas de onda dos autovetores, para PCs maiores que 1, não apresentam similaridade entre as mesmas de cada bloco do sinal comprimido, o que torna ineficaz a metodologia de aproveitamento do autovetor de um PC de um bloco atual para o futuro bloco .

Esta técnica proposta, aqui denominada de ”PCA-NIPALS” é inédita e supera a todas as técnicas já divulgadas na literatura especializada, exceto, aparentemente, pela compressão

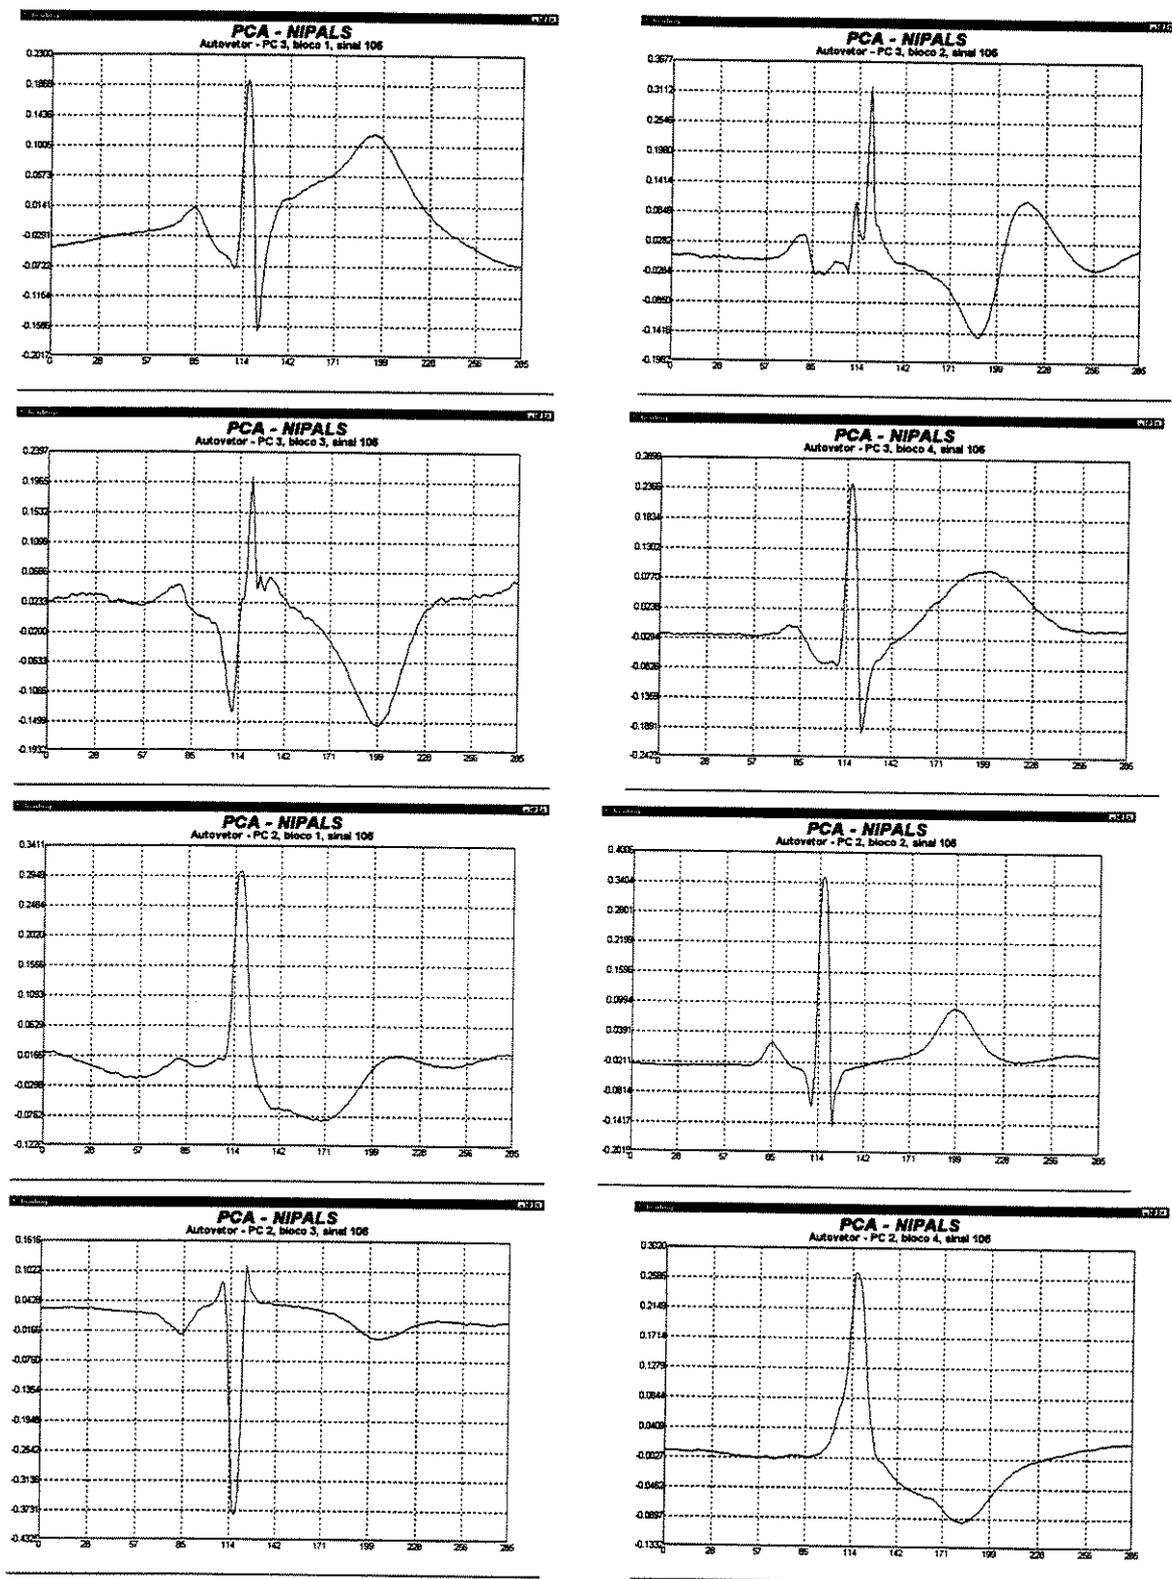


Figura 4.14: Fotos dos autovetores para as PCs 3 e 2 para quatro blocos de sinal, mostrando que as suas formas são diferentes de bloco para bloco.

por Rede Neural Artificial arranjada como auto-associadora. Não é superada exatamente na “capacidade de compressão”, mas na qualidade do sinal obtido quando se exige altas compressões. No caso do compressor desenvolvido, para se obter compressões maiores que 80 :1, deve-se utilizar de apenas uma ou duas PCs (PC1 e PC2), e quando se faz isto com este compressor, a qualidade visual do sinal recuperado não é boa. Assim, o artigo de Iwata [37], revisto neste trabalho, apresenta erro RMS mais baixo, o que o torna hipoteticamente o de melhor desempenho.

Quanto À convergência computacional, o compressor desenvolvido “ganha” do realizado por RNA, por ser extremamente rápido, permitindo menor custo computacional quando comparado ao do processo com RNA.

A Figura 4.15 apresenta a disposição na tela do programa que realiza a compressão, intitulado neste trabalho por “PCA-NIPALS”. Note que foi deixado como “parâmetros alteráveis” (para permitir flexibilidade na etapa do desenvolvimento do mesmo) os seguintes :

1. **Amostras/batimento** : Tamanho do vetor reamostrado.
2. **Batimentos/bloco** : Tamanho do bloco de vetores nos quais se realizará a compressão.
3. **Componentes/bloco** : Número de CPs que se vai comprimir o sinal. Só aplicável quando se opta pelo processo de compressão chamado “fixo” (vide item 7), isto é, “não adaptativo”.
4. **Erro interno** : Critério de parada da iteração para análise de cada componente principal, baseado no erro quadrático interno de convergência do algoritmo NIPALS (default : $9000=94,8 \mu V$).
5. **Erro mínimo μV** : Critério de parada da decomposição do sinal em um certo número de CPs, válidas para cada bloco de sinal.
6. **Bits scores/loadings** : Escolha do número de bits que se vai truncar as grandezas “Scores” e “Loadings” (que são, respectivamente, os pesos e os auto-vetores da cada CP do sinal).
7. **Min.componentes** : Número mínimo de CPs que vai representar o sinal, independente de qualquer outra imposição exigida no programa pela respectiva tela.
8. **Fixo** : Opção para sistema fixo de CPs (que não se utilizou mais porque o processo adaptativo tem desempenho superior).

9. **Adaptativo** : processo de definir o número variável de CPs em função do erro mínimo.
10. **Filtro** : Filtro digital de média movel.
11. **Sinal** : os códigos dos sinais da base de dados do MIT-BIH que estarão sujeitos a compressão e descompressão, selecionável através da barra de rolagem.
12. **Comprime** : Botão de disparo do processo de compressão.
13. **Descomprime** : Botão de disparo do processo de descompressão do arquivo já comprimido.
14. **Diretório** : diretório onde se localizam os referidos sinais.
15. **Botões de sentido “Esquerdo” lento e rápido, e “Direito” lento e rápido** : Dado que um certo sinal foi selecionado, comprimido e depois descomprimido, permite visualizar o arquivo dos sinais original e descomprimido, em função do “eixo do tempo virtual”.
16. **Erro PRD/bloco** : Erro PRD calculado no bloco do sinal que se está vendo na tela.
17. **Erro PRD/total** : Erro PRD calculado em todo o arquivo do sinal selecionado.
18. **Erro RMS/bloco** : Erro RMS calculado no bloco do sinal que se está vendo na tela.
19. **Erro RMS/total** : Erro RMS calculado em todo o arquivo do sinal selecionado.
20. **Fator de Compressão** : O CR obtido em todo o arquivo do sinal em questão.

4.2.3. Resultados

A Figura 4.16, apresenta os resultados de desempenho do compressor desenvolvido, para os sinais 100 e 203, que representam o “melhor e pior” casos de compressão, respectivamente. Neste caso se impôs um número mínimo de CPs de 1, a fim de caracterizar o algoritmo em sua versão mais “pura”.

Note que ele acompanha bem as curvas teóricas obtidas, e como dever-se-á utilizá-lo na prática com erro mínimo de $50\mu V$, considera-se sua desempenho a partir deste ponto como quase ideal.

Não se pode esquecer que no caso ideal obtido na curva, matéria do Capítulo 3, considera-se apenas as entropias de cada CP parcial acumulada, o que na prática não se tem como

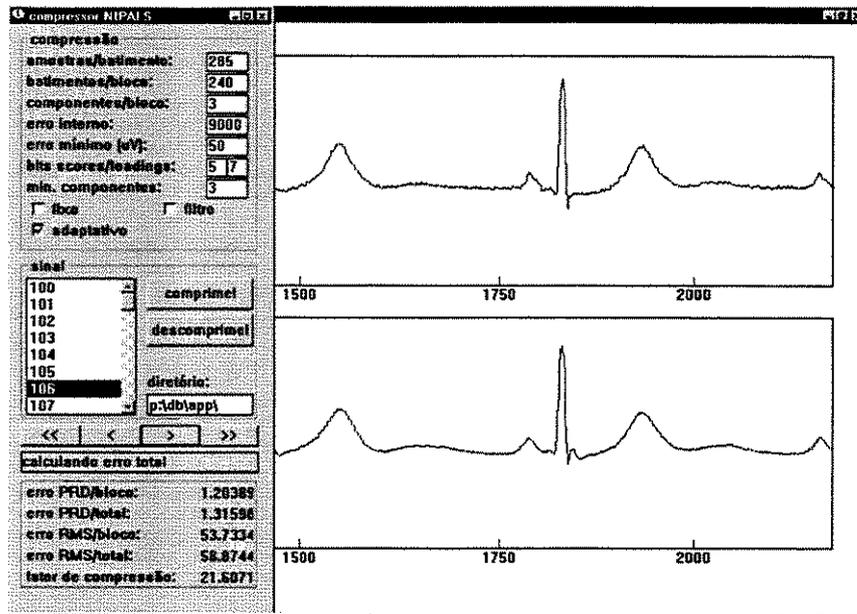


Figura 4.15: Visualização da tela de simulação do compressor PCA-NIPALS

atingir, pois existe um “overhead” no arquivo comprimido, devido aos dados adicionais que se precisa salvar, como : arquivo de indicação do pico do complexo QRS, valores de truncagem dos Scores e Loadings e respectivas faixas que se realizou as truncagens, entre outros.

As Tabelas 4.6 e 4.7 apresentam o desempenho deste compressor para cada sinal da base de dados do MIT-BIH.

As Figuras 4.17 e 4.18 apresentam amostras dos sinais originais e estes mesmos após serem comprimidos e descomprimidos pelo compressor PCA-NIPALS, sinais estes de número 106 e 117. Nota-se boa definição e fidelidade dos mesmos quando comparados com os originais.

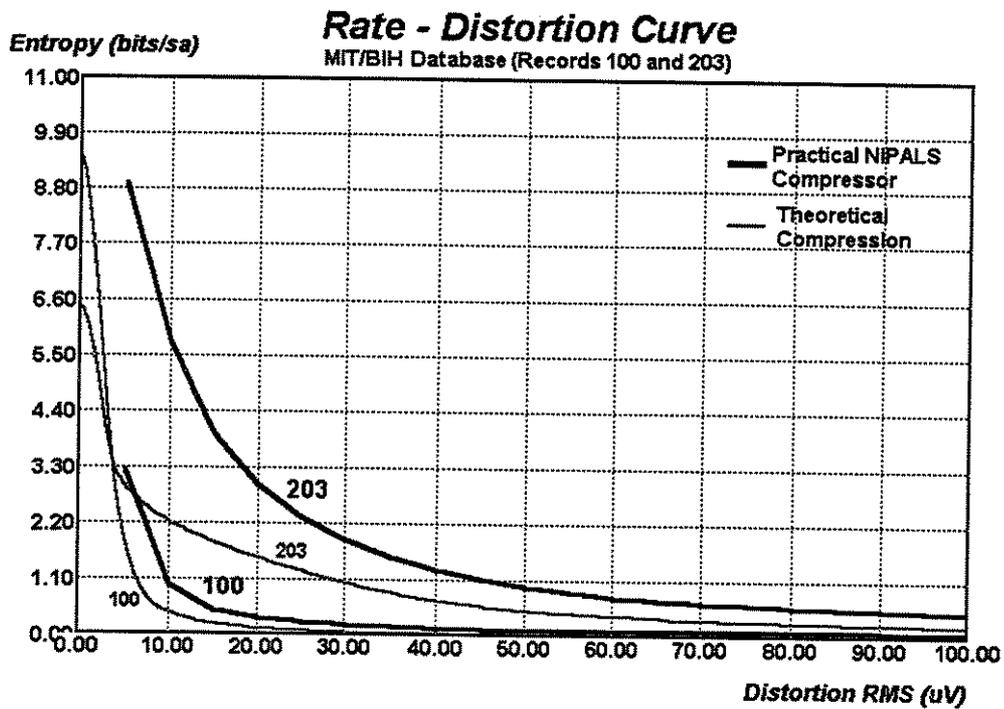


Figura 4.16: Curva de desempenho do compressor PCA-NIPALS quando comparado com as curvas R(D) teóricas obtidas segundo o Capítulo 3.

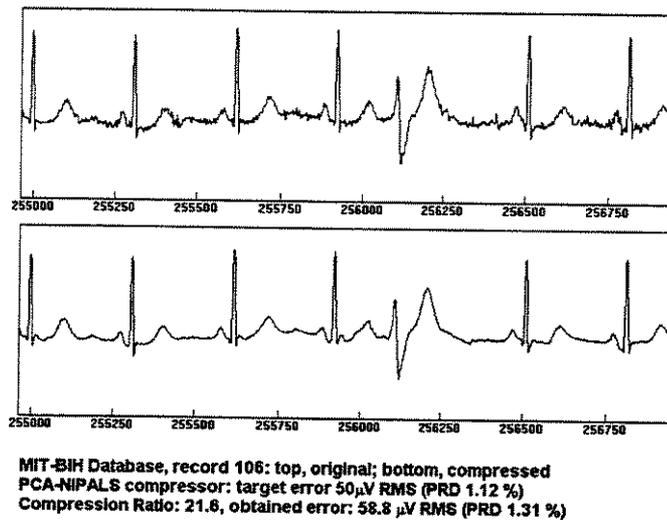


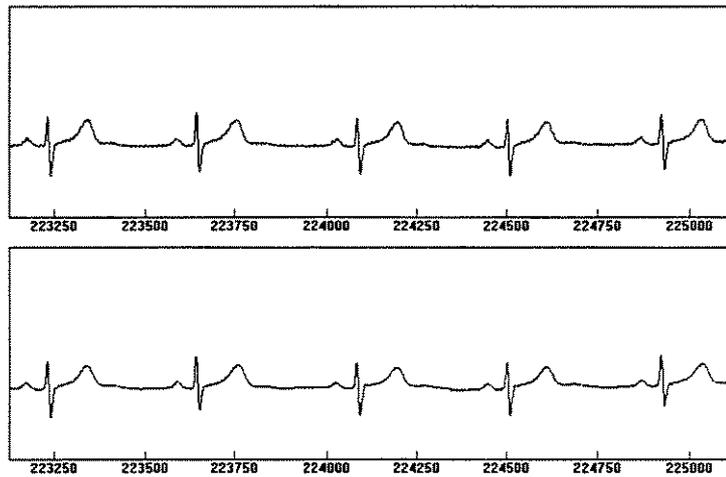
Figura 4.17: Sinal 106 sendo operado pelo compressor PCA-NIPALS

Sinal	Errototal μV	Errototal PRD %	CR
100	38,5	0,9	53,5
101	61,3	1,4	59,1
102	46,3	1,1	52,6
103	52	1,2	52
104	60	1,4	20,2
105	73,6	1,6	20,6
106	59,7	1,3	20,7
107	74,1	1,7	16,2
108	70,5	1,6	41,6
109	43,6	1,0	41,1
111	61,2	1,4	53,0
112	40,4	1,0	47,3
113	61,7	1,4	39,9
114	46,3	1,0	58,7
115	61,8	1,5	46
116	60	1,2	25
117	48,1	1,2	71,9
118	67,2	1,7	21,5
119	67,4	1,7	20,6
121	40,2	1,0	64,3
122	41,6	1,1	47,7
123	56,2	1,4	65,6
124	68,2	1,7	51,2

Tabela 4.6: Desempenho do compressor PCA-NIPALS com os sinais do MIT-BIH

Sinal	Errototal μV	Erro PRDtotal %	CR
200	63,7	1,4	15,5
201	51,1	1,2	40,1
202	58,2	1,3	44,1
203	85,4	1,9	10,5
205	37,3	0,9	41,2
207	62,4	1,3	34,2
208	70,1	1,6	14,1
209	58,3	1,3	26,3
210	54	1,2	36,5
212	60,0	1,3	25,5
213	81,9	1,8	13,4
214	65,6	1,5	23,8
215	53,9	1,2	24,1
217	77	1,7	18,6
219	72	1,8	21
220	55,5	1,4	38,1
221	56,8	1,3	29,1
222	50,4	1,1	25,2
223	58,1	1,4	27,6
228	61,9	1,4	26,1
230	61,3	1,4	23,9
231	52,2	1,2	40,8
232	68,8	1,6	61,9
233	72,8	1,6	14,8
234	54,6	1,2	43,5

Tabela 4.7: Desempenho do compressor PCA-NIPALS com os sinais do MIT-BIH



MIT-BIH Database, record 117: top - original; bottom - compressed
PCA-NIPALS compressor: target error 50 μ V RMS (PRD 1.12 %)
Compression Ratio: 76.4, obtained error: 44.3 μ V RMS (PRD 1.15 %)

Figura 4.18: Sinal 117 sendo operado pelo compressor PCA-NIPALS

Capítulo 5

Materiais e Métodos

5.1. Utilizando a base de dados do MIT-BIH (1992)

A Base de Dados de ECG intitulada “ MIT-BIH Arrhythmia Database”, foi construída no Beth Israel Hospital Arrhythmia Laboratory entre 1975 e 1979. Aproximadamente 60% dessas gravações foram obtidas de pacientes internos ao hospital. Ela contém 23 gravações, numeradas de 100 a 124, e outras 25 gravações, numeradas de 200 a 234 (propositalmente não em seqüência), escolhidas aleatoriamente de um conjunto de 4000 gravações de Holters realizadas na instituição. Foram selecionados de maneira a incluir uma variedade de fenômenos clínicos raros e típicos para representar muito bem os sinais obtidos de um Holter de ECG. Cada gravação tem 30 minutos de duração.

O primeiro grupo tem representatividade na variedade de formas de onda e artefatos que um detector de arritmia pode encontrar em rotinas clínicas. Foi gerada uma tabela de números aleatórios para a seleção das gravações e do segmento de 30 minutos. Segmentos selecionados desta forma só foram descartados se ambos os sinais de ECG estivessem fora de qualidade adequada para análise visual por especialistas.

As gravações do segundo grupo foram escolhidas para incluir arritmias com complexos ventriculares, juncionais e supraventriculares, e também anormalidades de condução. Muitas destas gravações foram selecionadas em função de suas propriedades de ritmo, variação da morfologia do complexo QRS, ou qualidade de sinal que poderia ser esperada para avaliar o desempenho de detectores de arritmia.

Foram gravações de 25 homens com idade entre 32 e 89 anos, e 22 mulheres com idades entre 23 e 89 anos. A gravação 201 e 202 originou-se da mesma mulher.

5.1.1. Configuração das Derivações de ECG

Na maioria das gravações, os sinais que aparecem na parte superior são uma derivação “Lead II” modificada, obtida pelo posicionamento dos eletrodos no tórax. O sinal inferior é usualmente uma derivação “Lead VI” modificada (ocasionalmente podem ser V2 ou V5 ou até V4), e os eletrodos são também posicionados no tórax. Esta configuração é rotineiramente usada no BIH Arrhythmia Laboratory. Complexos QRS normais são usualmente destacados nos sinais superiores. O eixo dos “leads” para o sinal inferior posiciona-se perto do eixo elétrico cardíaco médio, produzindo sinais geralmente bifásicos ou quase isoeletrícos.

Portanto, batimentos normais são freqüentemente difíceis de se discernir no sinal inferior, embora batimentos ectópicos sejam freqüentemente mais destacados (veja, por exemplo, o sinal 106). Uma exceção notável está no sinal 114, onde o mesmo é reverso. Nas gravações 102 e 104, não foi possível utilizar o modo “Lead II” modificado por causa das vestimentas cirúrgicas utilizadas no paciente, e então utilizou-se a derivação V5 modificada nos sinais superiores destas gravações.

5.1.2. Gravação e Reprodução Analógica

As gravações originais foram realizadas através de nove gravadores marca “ Del Mar Avionics” modelo 445, de dois canais, aqui designados de A até I :

Grav													
A	102	107	111	115	121								
B	212												
C	203												
D	118	124	217										
E	101	103	106	108	112	117	119	122	209	219	220	223	233
F	104	109	123	205	207	210	215	221					
G	100	105	114	116	213	214	222	228					
H	113	201	202	231									
I	200	230	232	234									

OBS : Não se sabe qual gravador foi utilizado para o sinal 208.

Durante o processo de digitalização, as fitas analógicas foram acionadas com o gravador modelo Del Mar Avionics 660. As fitas analógicas utilizadas nas gravações 112, 115 até 124 e 205, 220, 223 como também 230 até 234 foram acionadas no dobro da velocidade real; as outras foram acionadas na velocidade real. O desvio fixo entre os dois sinais pode chegar a valores tão altos como 40 ms em alguns casos. Adicionando-se ao desvio citado, existem variações microscópicas na fita, tanto no processo de gravação como no de reprodução, o que introduz um desvio variável, que pode ser comparado com o desvio fixo já citado. Este problema, que também ocorre com a “AHA Data Base” (American Heart Association), pode representar dificuldades quando se utilizam métodos de análise que envolvam os dois canais em tempo real.

Variações de velocidade de grandeza inferior não deverão causar problemas em detectores de arritmia. É difícil evitar o colamento ou escorregamento da fita durante a reprodução em baixa velocidade e vários episódios destes foram comentados e marcados nas anotações comentadas. “Wow” e “Flutter” devem ser estudados cuidadosamente no contexto dos estudos de variação dos batimentos cardíacos, já que não foi possível realizar compensações de Flutter nestas gravações. Um grande número de artefatos tem sido identificados e relacionados

com componentes mecânicos específicos, como :

Frequência (Hz)	Fonte
0,042	Pressão da roldana de gravação
0,083	Captador Playback-só para o dobro de vel.
0,090	Captador de gravação
0,167	Captador Playback-só para velocidade real.
0,18 a 0,10	Take-up reel
0,20 a 0,36	Supply reel

Os artefatos mais importantes são aqueles por volta de 0,167 Hz, nos sinais que foram reproduzidos em tempo real. O outro mais significativo é o de 0,090 Hz; o de 0,083 Hz, nas gravações reproduzidas no dobro da velocidade, tem amplitude aproximadamente igual ao de 0,090 Hz. O de 0,042 Hz é de amplitude bem baixa. As outras frequências, relativas a correia de acionamento (0,042 Hz, 1,96 Hz, 9,1 Hz e 42 Hz) não parecem ser artefatos notáveis. As frequências dos últimos dois artefatos listados na tabela dependem da quantidade de fita existente nos rolos do gravador; o rolo de fornecimento da fita causa mais artefato que o de recebimento da mesma. Outras frequências geradas pelo rolo de fornecimento estão na faixa de 0,10 Hz a 0,18 Hz e também entre 0,30 e 0,54 Hz. Quatro gravações incluem batimento de marca-passo (sinais 102, 104, 107 e 217). As gravações originais não apresentam sinais de marca-passo com suficiente fidelidade para permitir serem reconhecidos pelo “slew-rate” e duração, o método comumente usado para processamento em tempo real.

5.1.3. Digitalização

As saídas analógicas da gravação foram filtradas para limitar a saturação do conversor A/D, bem como evitar os efeitos de “aliasing”, utilizando um filtro passa-banda de 0.1 a 100 Hz, relativo ao tempo real. Os sinais limitados em banda foram digitalizados a 360 Hz por sinal, relativo ao tempo real, usando um “hardware” construído no próprio MIT Biomedical Center Engineering Laboratory. Esta frequência de amostragem foi encontrada para facilitar implementações de filtros digitais do tipo “notch”, com relação à frequência de 60 Hz.

Como as gravações foram realizadas com baterias, a maioria dos ruídos de 60 Hz presentes

nos sinais apareceu durante a reprodução. Nas gravações que foram digitalizadas no dobro do tempo real, este ruído aparece como sendo de 30 Hz, relativo ao tempo real.

As amostras de cada sinal foram adquiridas quase simultaneamente (desvio de alguns microssegundos). Como já foi citado, o desvio analógico foi muito maior que este valor. Os conversores A/D eram unipolares, com 11 bits de resolução em uma faixa de $\pm 5\text{mV}$. Os valores de amostragem, portanto, estão na faixa de 0 a 2047 passos, com o valor de 1024 correspondendo a zero volts.

As amostras de 11 bits foram gravadas no formato “8-bit first difference”, para otimização do armazenamento dos dados. Dada a frequência de amostragem e a resolução do A/D, a codificação por diferença implica em um “slew-rate” máximo de $\pm 225\text{mV/s}$. Na prática, este limite foi excedido muito pouco, apenas durante o período em que ocorreu muito ruído, tendo se dado em poucas gravações. Este efeito na qualidade de gravação dos sinais é totalmente desprezível. Como os bancos de dados são reconstruídos pela diferença entre os mesmos, nenhuma informação é perdida e ganha-se espaço considerável no armazenamento dos mesmos.

5.1.4. Anotações no Banco de Dados

Um grupo inicial de marcas de cada batimento foi obtido com um detector do complexo QRS, sensível à derivada, que marcou cada evento como batimento normal. Então, duas cartas idênticas de 150 pés foram registradas, para cada sinal, com estas marcas de batimento normal. Cada uma destas cartas, foi então enviada a Cardiologistas, que trabalharam independentemente. Os Cardiologistas adicionaram marcas nos batimentos onde o detector perdeu a detecção automática, ou detecções falsas e também mudaram os nomes dos batimentos que eram anormais. Eles também adicionaram nomes para os ritmos, qualidade do sinal e comentários.

As anotações foram transcritas destas cartas e verificadas automaticamente, comparando-se batimento por batimento e gerada outra carta, onde eram anotadas as marcas e comentários dos Cardiologistas na margem do papel, com todas as discrepâncias ressaltadas. Cada discrepância foi resolvida por consenso. As correções foram transcritas e foram analisadas por um programa de auditoria, que conferiu a consistência e que localizou os dez mais curtos

e dez mais longos intervalos RR, com o propósito de conferir problemas de batimentos falsos ou perdas deles.

Nas cópias antigas da base de dados, a maioria das anotações (marcas) foram posicionadas no pico do QRS, porém as anotações realizadas manualmente nem sempre têm a mesma precisão de posicionamento. Nas cópias da base de dados realizadas após 1983, as anotações dos batimentos foram mudadas da sua posição original. O ECG foi digitalmente passado por um filtro passa-banda, com o propósito de enfatizar o complexo QRS, e cada marca de batimento foi movida para o maior pico local, depois de corrigir o desvio de fase causado pelo filtro. Alguns batimentos foram manualmente realinhados. O resultado é que as anotações geralmente aparecem no pico da onda R, e estão localizados com precisão suficiente para ser arquivo de referência utilizável para quesitos de realização de média da forma de onda e estudos da variabilidade do batimento cardíaco, mas nunca se esquecendo das observações de “wow” e “flutter” já mencionadas. Na documentação destes sinais, cada nome é posicionado de maneira que a marca fiducial das anotações corresponda ao canto esquerdo do nome.

A base de dados contém aproximadamente 109.000 batimentos anotados. Dezesesseis foram corrigidos desde os oito primeiros anos que a mesma foi lançada (nas gravações 104, 108, 114, 203, 207, 217 e 222); adicionalmente, todos os eventos de “bloqueio de ramo esquerdo” na gravação 214 foram originalmente chamados de “batimento normal”. Os nomes dos ritmos têm sido substancialmente revisados e agora são incluídas anotações para ritmos com marca-passo, bigeminia, trigeminia, que foram perdidas nas cópias anteriores.

5.2. Parâmetros de validação e medida de performance

5.2.1. Estimativa da Função de Densidade de Probabilidade

Introdução

Pode-se considerar, para efeitos práticos, três métodos de estimativa da função de densidade de probabilidade, fdp :

- Métodos Paramétricos

- Métodos Não-paramétricos
- Métodos Semi-paramétricos Baseados em Distribuições Mistas

Nos métodos paramétricos assume-se que a fdp deve ter uma forma específica e que deve conter um certo número de parâmetros que serão otimizados, a fim de casar o modelo à distribuição dos dados. Em geral, tenta-se aproximar a fdp à distribuição Gaussiana, devido a suas inúmeras propriedades que facilitam a análise. A vantagem desta técnica é que se pode avaliar rapidamente a resposta do sistema para um novo vetor de entrada, pois a fdp é conhecida.

Nos métodos não-paramétricos não se assume "a priori" nenhuma fdp particular, determinando-se a fdp inteiramente pela sua distribuição de dados, que podem ser levantadas por histogramas, por "kernel", pelos K vizinhos mais próximos, etc. A desvantagem é que, para um novo vetor de entrada, a estimativa da fdp pode ser computacionalmente custosa.

Nos métodos semi-paramétricos baseados em distribuições mistas, tenta-se encontrar o melhor dos dois últimos métodos, utilizando-se uma classe bastante genérica de formas funcionais, nas quais o número de parâmetros pode ser independentemente aumentado no modelo, porém baseando-se em misturas de distribuições. O custo computacional também pode ser alto, no sentido de se obter o modelo final das fdps misturadas.

Estes procedimentos são dependentes do número de dados que se tem disponível. A técnica de levantamento da fdp por histograma, que é uma técnica não-paramétrica, é muito simples e pode ser muito eficiente se muitos dados estão disponíveis.

Na base de dados do MIT tem-se, aproximadamente, 109.000 de pulsos de ECG, que é uma quantidade bastante expressiva, estatisticamente.

Devido a este fato, optou-se pelo levantamento das fdps de primeira ordem e ordens superiores pelo seu histograma, e foi obtido sucesso nesta técnica.

A princípio, tendia-se a interpretar as fdps obtidas por fdps misturadas; porém, após constatar-se que era problema de "off-set" de alguns sinais da base de dados (e sua posterior compensação), obteve-se fdp fortemente parecida com a distribuição Laplaciana.

A constatação desta afirmação foi realizada através da medição de distância proposta por Kullback e Leibler (Kullback [45]) que será detalhada a seguir.

5.2.2. Distância de Kullback-Leibler ou Divergência Assimétrica

Seja $p(x)$ uma função de densidade de probabilidade conhecida, onde se quer verificar se a fdp estimada estatisticamente, tem similaridade com a fdp modelo e em que grau isto ocorre.

Pode-se realizar uma medida de distância entre estas duas funções pelo conceito da “Esperança do negativo do logaritmo da Verossimilhança”, que resultará (Kullback [45]) em :

$$L = - \int p(x) \ln \left(\frac{\tilde{p}(x)}{p(x)} \right) dx$$

onde :

L é a medida resultante.

$\tilde{p}(x)$ é o modelo da fdp a qual se deseja medir a distância

$p(x)$ é a fdp conhecida (experimental).

Como o sinal de ECG é discretizado em 2048 degraus, tem-se :

$$L = - \sum_{i=0}^{2047} p(x_i) \ln \left(\frac{\tilde{p}(x_i)}{p(x_i)} \right)$$

Se $L = 0$, tem-se fdps exatamente iguais. Se $L > 0$, tem-se medida absoluta proporcional às semelhanças entre a fdp experimental e a fdp de referência.

Esta medida de divergência assimétrica foi aplicada nas análises de semelhança entre as fdp experimental e a fdp Laplaciana, como também entre a fdp experimental e a fdp Gaussiana. Foram realizados testes, também, em relação às distribuições Gama e de Cauchy, porém como se obteve “ L ” muito alto comparados aos produzidos pela Laplaciana e Gaussiana, estas duas outras fdps foram descartadas da análise. Fixou-se então o trabalho em se determinar qual das duas referidas fdps (Laplaciana e Gaussiana) se aproximava mais da fdp experimentalmente levantada.

Algoritmo da Divergência Assimétrica

1. Inicializar um vetor a , de 2048 elementos, fazendo com que todos os seus elementos sejam iguais a zero.

2. Ler seqüencialmente cada amostra do sinal. Para cada amostra lida, incrementar o elemento a_i correspondente (0 - 2047).
3. Somar cumulativamente os valores de cada elemento do vetor a_i .
4. Dividir cada elemento do vetor pela somatória. O vetor a é agora uma aproximação da curva densidade de probabilidade do sinal.
5. Verificar qual elemento do vetor tem valor máximo. Este elemento corresponderá ao ponto médio da curva densidade de probabilidade Gaussiana ou Laplaciana, em relação a qual a divergência assimétrica será calculada.
6. Determinado o valor médio, resta determinar o valor de σ . Para um determinado valor de σ , é calculada a divergência assimétrica em relação às distribuições Laplaciana e Gaussiana :

$$L_{\text{Gauss}} = \sum_i \left(\frac{a_i}{\sum_i a_i} \right) \ln \left(\frac{\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(i-\mu)^2}{2\sigma^2}}}{\left(\frac{a_i}{\sum_i a_i} \right)} \right)$$

$$L_{\text{Laplace}} = \sum_i \left(\frac{a_i}{\sum_i a_i} \right) \ln \left(\frac{\frac{1}{\sqrt{2\sigma^2}} e^{-\frac{|i-\mu|\sqrt{2}}{\sigma}}}{\left(\frac{a_i}{\sum_i a_i} \right)} \right)$$

7. O valor de σ é ajustado iterativamente, de modo a minimizar a divergência assimétrica entre a fdp experimental e cada uma das fdps (Laplaciana e Gaussiana) separadamente, e finaliza-se o processo quando se obtém o mínimo de divergência para cada uma das duas distribuições (Laplaciana e Gaussiana) separadamente.

5.2.3. Algoritmo NIPALS

Algoritmo para Compressão de Sinais de ECG utilizando Análise de Componentes Principais por NIPALS

Introdução : O algoritmo conhecido por NIPALS foi inicialmente desenvolvido para realizar a estimativa de modelos nos quais o número de incógnitas a ser estimado aumenta com

o número de observações. O método de Máxima Verossimilhança (Maximum Likelihood, ML) tende a ser muito complexo quando se tem muitas incógnitas, e ainda existem casos onde a ML não é consistente, quando o número de incógnitas aumenta indefinidamente com o número de amostra (Wold [83]). Dentro de condições de regularidade estocástica, a regressão por Mínimos Quadrados (Least Squares) fornece estimativa consistente das relações lineares que são especificadas em função da esperança condicional, ou preditores (Wold [83]). A técnica conhecida por Partial Least Squares, PLS, é um nome de uma classe de métodos utilizados para relacionar blocos de variáveis medidas em grupos de objetos. A modelagem com PLS tem grande potencial como método de análise de dados em muitos ramos da ciência. Este potencial é ainda raramente utilizado, mas PLS está atingido larga aceitação entre cientistas (Geladi [25]). Com isto, muitos ramos da ciência estão se utilizando de algoritmos idênticos ao PLS, com nomes diferentes, bem como algoritmos que são diferentes em essência, nomeados de PLS (Geladi [25]).

O trabalho pioneiro de PLS foi desenvolvido pelo prof. Herman Wold, que trabalhou em algumas universidades da Suécia. Foi iniciado em sua tese de doutorado, trabalho este desenvolvido entre 1932 e 1938, na Universidade de Stockholm. Após obtenção de seu título de PhD, prof. Wold iniciou estudos em regressão e modelos econométricos. Isto o levou a um método básico, nos meados de 1960, que tomou consistência com sua experiência acumulada em modelagem multivariável e modelamento não-determinístico (soft modeling). Em 1964, o prof. Herman Wold inventou o NIPALS - Non Linear Iterative Partial Least Squares, método este que foi publicado em 1966 (Geladi [25]). Este método, atualmente, é largamente utilizado em quimiometria, como se pode observar em vários artigos que são publicados em revistas de alto nível científico, como o Journal of Chemometrics e Chemometrics and Intelligent Laboratory.

A aplicação do NIPALS, para extração de componentes principais, foi na realidade uma reinvenção do mesmo método que foi sugerido por Fisher em 1923 (Geladi [25]).

O método foi primeiramente chamado de NILES (Non -Linear Estimation by Iterative Least Squares Procedures). Estes métodos são aplicáveis em (Wold [83]) :

1. Componentes Principais.
2. Correlações Canônicas.
3. Modelo Híbrido de Componentes Principais, Correlações Canônicas e Regressão Múl-

tipla.

4. Componentes Principais no caso de Informação Parcial.
5. Sistemas Interdependentes.
6. Parâmetros em um Modelo ou em Estrutura Residual.
7. Regressão por Quociente.
8. Análise de Fator (Factor Analysis).
9. Servo-mecanismos que envolvam erros nas equações e também nas variáveis.

NIPALS pode ser interpretado por :

“Como computar componentes principais por uma seqüência iterativa de regressões simples de Mínimos Quadrados” (Geladi [25]).

Houve um evento importantíssimo, ocorrido no “WorkShop de Cartigny” em 1979, com a liderança do prof. Wold, que foi de tamanho sucesso nesta área, cujo produto de idéias, “tomará ainda mais de 20 anos para serem absorvidas e testadas” (Geladi [25]). O prof. Wold vislumbrava aplicações nas seguintes áreas :

- a. Química Orgânica
- b. Química Analítica
- c. Química Médica
- d. Educação e Psicologia
- e. Ciências da Administração
- f. Economia
- g. Ciência Política
- h. Ciências Ambientais

Outra propriedade importante dos algoritmos do tipo PLS é a rapidez da execução dos mesmos o que, para futura aplicação do algoritmo de compressão de ECG em um DSP, será de grande valia. A seguir, apresenta-se o algoritmo NIPALS, adaptado, neste caso, para aplicação de compressão de sinais de ECG por análise de componentes principais, e eliminação daqueles menos significativos em termos de erro RMS de reconstrução do sinal :

“Dado um arquivo digitalizado de sinal de ECG, cria-se um procedimento, baseado em Componentes Principais, por técnica conhecida por NIPALS, onde se extraem e se armazenam os componentes principais mais significativas do referido sinal, levando-se em conta o erro gerado na reconstrução do mesmo. Este arquivo foi então compactado por este princípio, e sua descompactação é o processo inverso do descrito até aqui ”.

Método :

1. Ler o arquivo e armazená-lo na memória, na forma de matriz, onde cada linha corresponde a um pulso de ECG, que também chamar-se-á de vetor. Este vetor tem como referência o pico do complexo QRS, onda **R**. As amostras do vetor que se posicionam a direita da onda **R** são determinadas pela razão de 60% do intervalo **R-R** relativo ao pulso posterior ao referido. As amostras do vetor que se posicionam a esquerda são determinadas pela razão de 40% do intervalo **R-R** relativo ao pulso anterior. O vetor é reamostrado de modo que a sua dimensão, em amostras, permaneça fixa. Cria-se, então, uma matriz que representa um bloco de “*m*” pulsos de ECG, que doravante será chamada de matriz **A**. É criado um número suficiente de matrizes para representar todo o arquivo.
2. O objetivo da aplicação da Análise de Componentes Principais é representar cada matriz de pulsos de ECG como o produto de duas matrizes : a matriz de Loadings (autovetores da matriz de pulsos) e a matriz de Scores (pesos ou coeficientes relativos de cada autovetor). Em forma matricial :

$$\mathbf{A} = \mathbf{S} \cdot \mathbf{F},$$

onde : **A** = matriz dos vetores que correspondem aos pulsos de ECG ; **S** = matriz dos Scores (pesos) ; **F** = matriz dos Loadings (autovetores). O algoritmo utilizado para a determinação das matrizes de Loadings e Scores é o algoritmo NIPALS (Non-linear Iterative Partial Least Squares), que será descrito a seguir.

- (a) Atribuir um primeiro autovetor como sendo um dos vetores da matriz **A** :

$$\mathbf{F}_i = \mathbf{A}_1$$

- (b) Calcular o autovalor correspondente ao autovetor : $\lambda_{i,i} = (\mathbf{F}_i^2)^{1/2}$

- (c) Normalizar o autovetor : $\mathbf{F}'_i = \mathbf{F}_i/\lambda_{i,i}$
 - (d) Calcular os scores correspondentes ao autovetor. $\mathbf{S}_i = \mathbf{A}\mathbf{F}'_i$
 - (e) Testar a convergência, calculando o erro quadrático entre o vetor de Scores \mathbf{S}_i atual, em relação ao calculado na passagem anterior. Se o erro calculado for menor do que um valor de limiar pré-estabelecido, o autovetor \mathbf{F}_i e o vetor de Scores \mathbf{S}_i são correspondentes ao componente principal “ i ” extraído do sinal ; pular para o Passo 2(h). Se esta for a primeira passagem, ou se o erro quadrático for superior ao valor limiar, seguir para o Passo 2(f).
 - (f) Recalcular o autovetor : $\mathbf{F}_i = \mathbf{S}_i\mathbf{A}$
 - (g) Voltar para o passo 2(b).
 - (h) Se o número “ f ” de componentes principais requeridos foi atingido por “ i ”, concluir o processo. Caso contrário, calcular a matriz de resíduos, com a finalidade de calcular o próximo componente principal : $\mathbf{A} = \mathbf{A} - \mathbf{S}_i\mathbf{F}_i$
 - (i) Voltar ao Passo 2(a) para calcular o próximo componente principal ($i + 1$).
3. Foram obtidos, no Passo 2, os autovetores e vetores de Scores correspondentes ao número “ f ” de componentes principais calculado. Este número “ f ”, para que seja obtido o efeito de compressão, deve ser menor do que o número total de componentes principais.
4. O segundo passo da compressão é a quantização dos Scores e Loadings obtidos. Para isso, computa-se a faixa r obtida de valores, dos Scores e Loadings de cada componente principal, e discretiza-se a mesma em n valores, onde :

$$n = 2^b - 1,$$

onde b é o número de bits representando a quantização desejada ;

5. Armazena-se, então, em um arquivo (chamado arquivo comprimido), os Scores e Loadings quantizados correspondente a cada bloco de pulsos, o número de blocos criados, o número de bits usados na quantização, e a posição de cada onda \mathbf{R} no arquivo.
6. Na descompressão, recuperam-se as informações contidas no arquivo comprimido, visando a recomposição parcial do sinal original através da multiplicação dos Scores e Loadings.

5.2.4. Erro RMS, o erro PRD e Qualidade do sinal

Introdução : “O Erro PRD e RMS e Avaliação Clínica da Qualidade dos Sinais Digitalizados de ECG”.

Alguns pesquisadores, Nave e Cohen[56], Gold [27], Berson e cols[11] e entidades, principalmente a “AHA”, American Heart Association (Bailey [7]; Knoebel [42]) vem trabalhando para aperfeiçoar e padronizar os processos de representação digital do sinal de ECG e, em particular, a medição da fidelidade, ou do erro e distorção, no caso da compressão e recuperação dos sinais digitalizados do Eletrocardiograma. No trabalho da AHA de 1990, Bailey [7], após várias considerações sobre o assunto de compressão, resumiu que :

“Para efeito de leitura visual do ECG, a conversão A/D (Sampling Rate and Bit Resolution) deve ser suficiente para manter os critérios F1.”

O Critério F1 cita :

“For Routine Visual Reading” :

“F1 : Derivation of recorded output from an exact linear representation of the input signal may not exceed $25 \mu V$ or 5%, whichever is greater”. Lembra-se aqui que o padrão da Eletrocardiografia é ter sinal de 1mV de pico médio, e com amplificação que produza pico médio de 1 V no complexo QRS, que corresponde a 1 cm no papel de gravação do ECG.

O Critério F4 cita :

“F4 : Mean Square error divided by mean square amplitude of a deflection may not exceed 1%”.

Este critério F4 refere-se ao artigo de Barr e Spach [9], que aparentemente foi o primeiro a realizar trabalho detalhado sobre o problema da frequência de amostragem para sinais de ECG; dizem estes autores :

“Para comparação quantitativa das formas de onda “original” e “reconstruída”, o erro médio foi definido como a diferença quadrática média entre todo o sinal original e todo o sinal reconstruído, dividido pelo valor médio quadrático de todo o sinal original. A fração resultante foi multiplicada por 100, de maneira a expressá-la em percentual.”

Eles apenas descreveram esta medida, que parece que se tornou um padrão para a área.

Os artigos que utilizam a medida de “erro PRD” a escrevem como :

$$\text{PRD} = \sqrt{\frac{\sum_{i=1}^n (x_{\text{org}}(i) - x_{\text{rec}}(i))^2}{\sum_{i=1}^n x_{\text{org}}^2(i)}} \times 100,$$

onde : x_{org} amostra original e x_{rec} amostra do sinal recuperado, que é literalmente o proposto pelos autores.

O critério F4 já citado e atribuído a estes autores, também sugere que “este erro não exceda 1%”, que deste modo é a “regra sugerida e vigente”.

Não se descobriu nenhum outro trabalho que melhor detalhe, controle ou complemente esta proposição do valor de 1%.

Outros autores como Nave e Cohen[56] criticam este critério de erro PRD, (não o valor percentual sugerido, mas o critério de medida), pois a inspeção visual dos sinais e a referida medida nem sempre estão bem correlacionadas, conforme será exposto ainda neste capítulo.

Nave e Cohen [56] citam : “O PRD não leva em conta o uso em diagnóstico ; não sendo uma boa medida do verdadeiro erro na compressão. Todavia, ele é fácil de calcular e é extensivamente usado na literatura de compressão.” Estes autores criaram uma outra proposta de medida, que até hoje só foi utilizada pelo próprio Cohen e colegas e nunca foi comentada ou criticada por outros pesquisadores. Ela foi chamada de “WDD”, Weighted Diagnostic Distortion Measure (Zigel e cols[86]) que comparam a onda **P** e sua morfologia, duração da onda QT, elevação do segmento ST, etc, entre o sinal original e o reconstruído. O cálculo é difícil de se obter, pois é necessário capturar em todo o arquivo do sinal estes segmentos isolados, o que é outro problema da área de processamento de sinais de ECG e que também pode causar erros por si.

O erro RMS e o erro RMS Percentual são também medidas utilizadas por alguns pesquisadores, e pela própria definição de erro RMS são procedimentos equivalentes ao do erro PRD, obtendo-se apenas resultados numéricos diferentes.

No trabalho utilizou-se os três termos e medidas, que para efeito de praticidade foram aplicadas em :

- Erro RMS absoluto (μVRMS) : utilizado no cálculo do “erro interno”, nos ciclos iterativos do algoritmo , (pois estes são realizáveis em “tempo real”), e onde não se tem um

arquivo passado de sinal suficientemente grande para aplicação coerente do conceito de erro PRD. Também foi aplicada onde a área teórica original o exigia (como na teoria da Rate Distortion Function).

- Erro RMS% e Erro PRD : Aplicadas nas medidas de erro global dos algoritmos de compressão, pois se deseja comparar os resultados obtidos com os de outros autores que as utilizaram como medida de referência.

O Erro PRD e Inspeção Visual

O erro PRD sofre realmente de discrepância entre o valor numérico obtido e a qualidade visual do sinal. O trabalho de Lima e cols [48], serve como ilustração. As formas de onda apresentadas são as obtidas pelos mesmos, quando reproduziram os algoritmos tradicionais intitulados por “Turning Point”, ou TP, o AZTEC, o CORTES e a DCT (vide Item 2.2.) e que também se utilizaram da base de dados do MIT-BIH para análise da relação entre CR e distorção PRD.

As Figuras 5.1(a) e 5.1(b) ilustram respectivamente, alguns pulsos do sinal 104 original e a recuperação do mesmo com a técnica TP com CR de 4, aproximadamente. Obteve-se erro PRD de 58,9%. As Figuras 5.2(a) e 5.2(b) ilustram, respectivamente, os mesmos pulsos do sinal 104 original e o recuperado com aplicação da técnica AZTEC, com CR aproximado de 4, onde se obteve erro PRD de 42,8%. Note que, apesar do erro PRD na técnica AZTEC ser menor, o sinal é visualmente “discretizado” e inaceitável para diagnóstico.

As Figuras 5.3(a) e 5.3(b) ilustram o mesmo caso com a aplicação da técnica CORTES, obtendo-se erro PRD de 11,77%; note que o sinal é tão “ruim” quanto o obtido com o AZTEC, que tinha erro PRD de 42,8%!

As Figuras 5.4(a) e 5.4(b) ilustram o mesmo procedimento com a técnica DCT. O Erro PRD é de 36% e ele se parece mais com o original que as outras técnicas aqui citadas. Compare, por exemplo, este resultado com o CORTES (figuras 5.3(a) e 5.3(b)), cujo erro PRD foi de 11,77% e note que visualmente o “melhor sinal” é o DCT, mesmo com erro PRD maior, (apesar de aparecer contaminação de ruído de alta frequência)!

As Figuras 5.5(a) e 5.5(b), 5.6(a) e 5.6(b), 5.7(a) e 5.7(b), 5.8(a) e 5.8(b) mostram, respectivamente, pulsos do sinal 108 original e descomprimido para as técnicas já citadas,

também com CR de 4.

Note que, por exemplo, com a técnica CORTES para este trecho do sinal 108, obteve-se erro PRD de 12,99% e com a técnica DCT, valor de 11,33%. O resultado obtido pelo CORTES tem sinal visualmente inaceitável, apesar do erro obtido ser quase o mesmo. A técnica TP obteve, neste mesmo caso, erro PRD de 24,06% e a DCT valor de 11,33%, com “aparências” praticamente iguais!

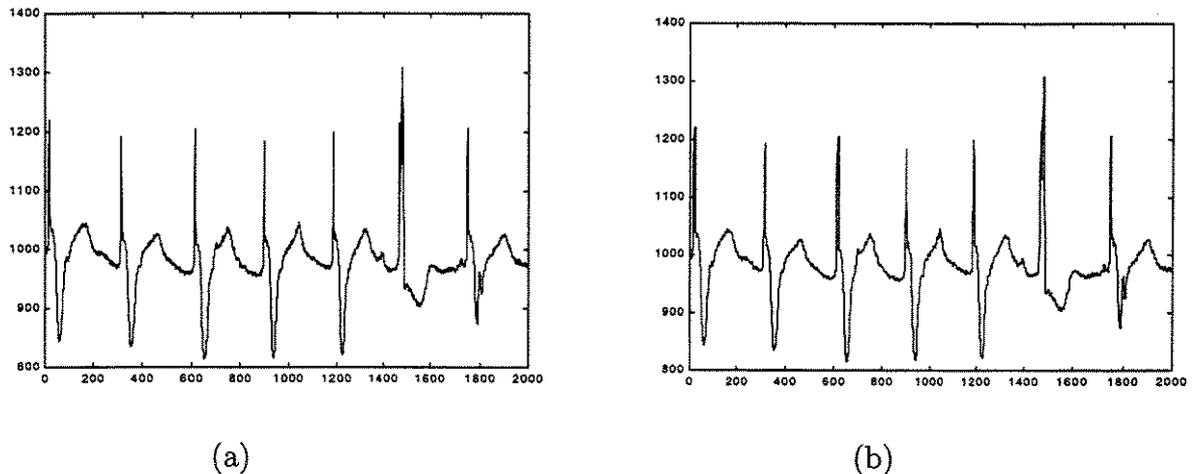
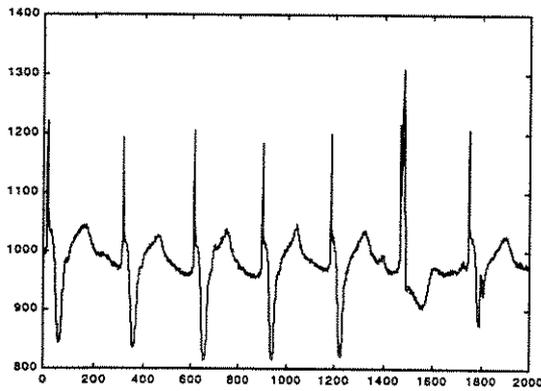


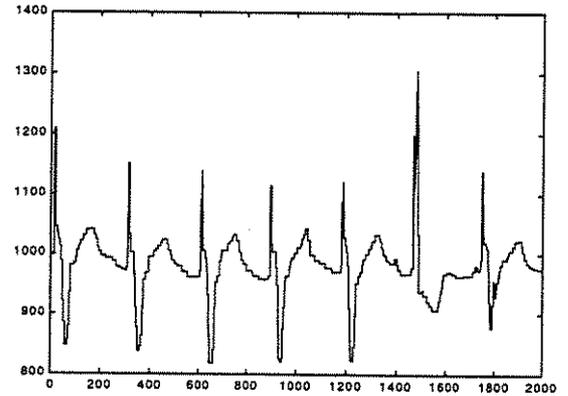
Figura 5.1: Ilustração de trecho do sinal 104 original e recuperado com a técnica TP para um CR de aproximadamente 4.

Pela experiência obtida no desenvolvimento dos algoritmos, algumas técnicas geram “atraso no tempo”, de algumas amostras, no sinal recuperado, o que cria um grande erro PRD, sem ser este erro propriamente importante, pois se o atraso for constante ele não precisa ser levado em conta (o sinal gravado não precisa ter relação temporal fixa com o original, ela precisa apenas ser linear).

Assim, muitas vezes a técnica produz um sinal muito “digitalizado”, porém sem apresentar atraso, e cria um erro PRD menor que um sinal visualmente melhor e mais fidedigno, mas que apresenta um certo atraso constante em relação ao original, causando uma medida maior de erro. Isto ocorrerá principalmente nos cálculos de erro situados no trecho do complexo QRS dos pulsos, onde um atraso de algumas amostras representará erros instantâneos altíssimos. Vale ressaltar que as medições de erro RMS e RMS% sofrem da mesma deficiência, isto é, não existe ainda um procedimento adequado para dar um índice de fidelidade visual do sinal de ECG

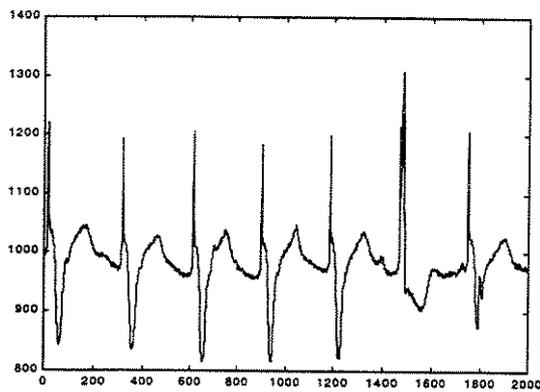


(a)

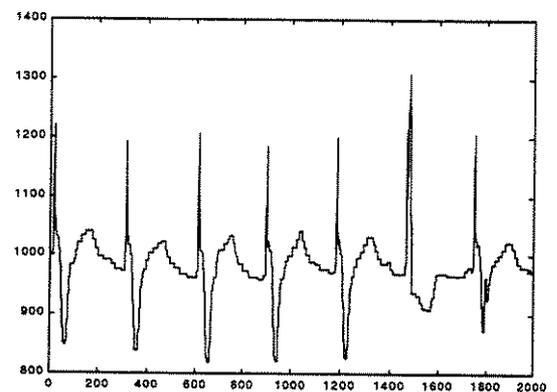


(b)

Figura 5.2: Ilustração de trecho do sinal 104 original e recuperado com a técnica AZTEC para um CR de aproximadamente 4.

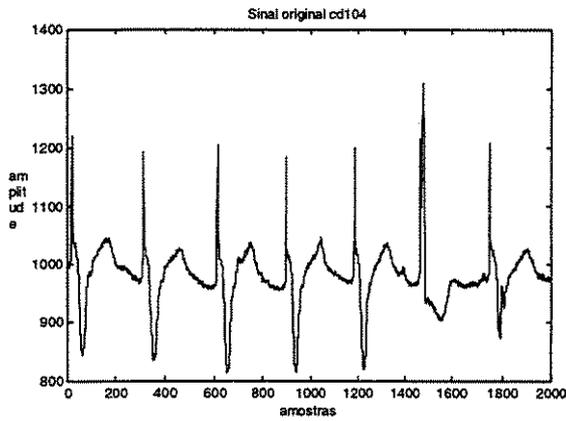


(a)

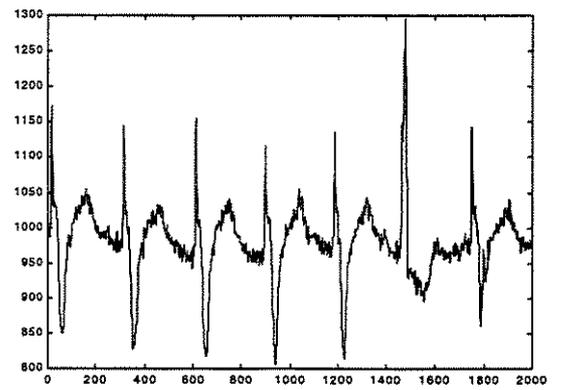


(b)

Figura 5.3: Ilustração de trecho do sinal 104 original e recuperado com a técnica CORTES para um CR de aproximadamente 4.

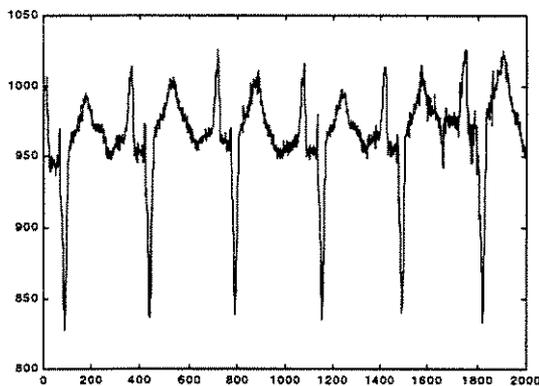


(a)

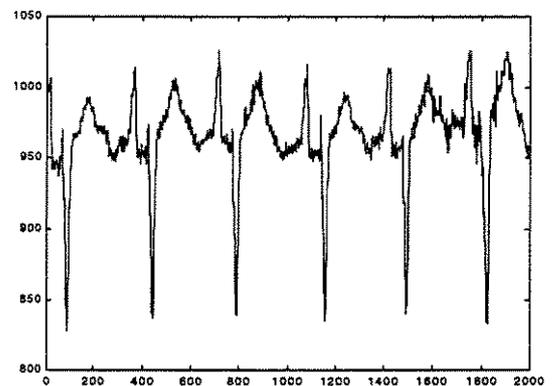


(b)

Figura 5.4: Ilustração de trecho do sinal 104 original e recuperado com a técnica DCT para um CR de aproximadamente 4.

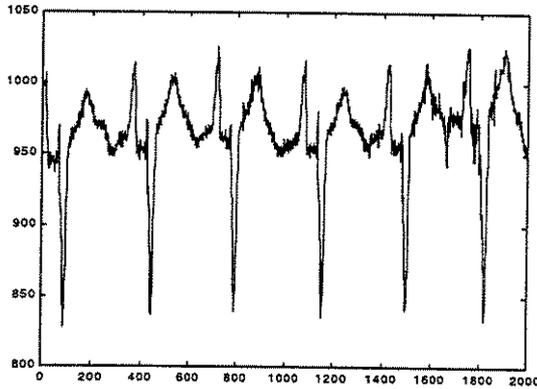


(a)

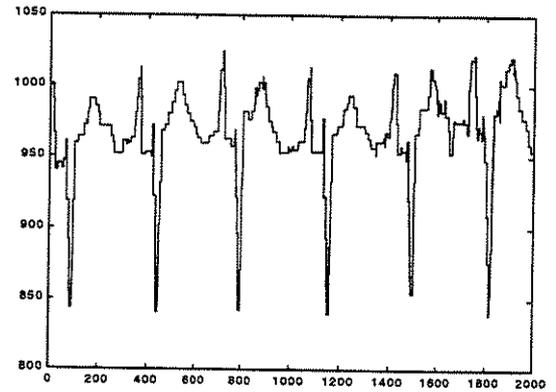


(b)

Figura 5.5: Ilustração de trecho do sinal 108 original e recuperado com a técnica TP para um CR de aproximadamente 4.

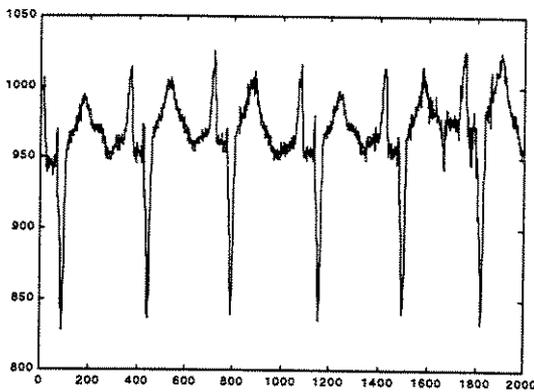


(a)

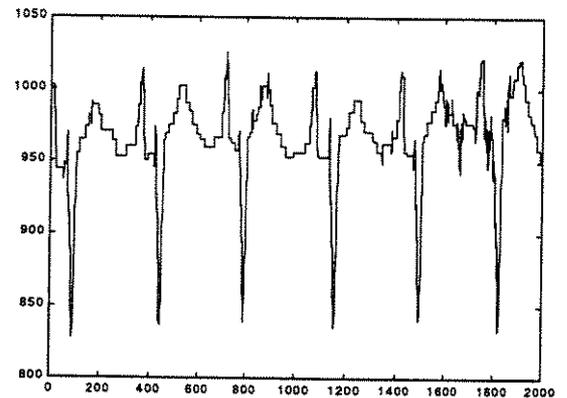


(b)

Figura 5.6: Ilustração de trecho do sinal 108 original e recuperado com a técnica AZTEC para um CR de aproximadamente 4.



(a)



(b)

Figura 5.7: Ilustração de trecho do sinal 108 original e recuperado com a técnica CORTES para um CR de aproximadamente 4.

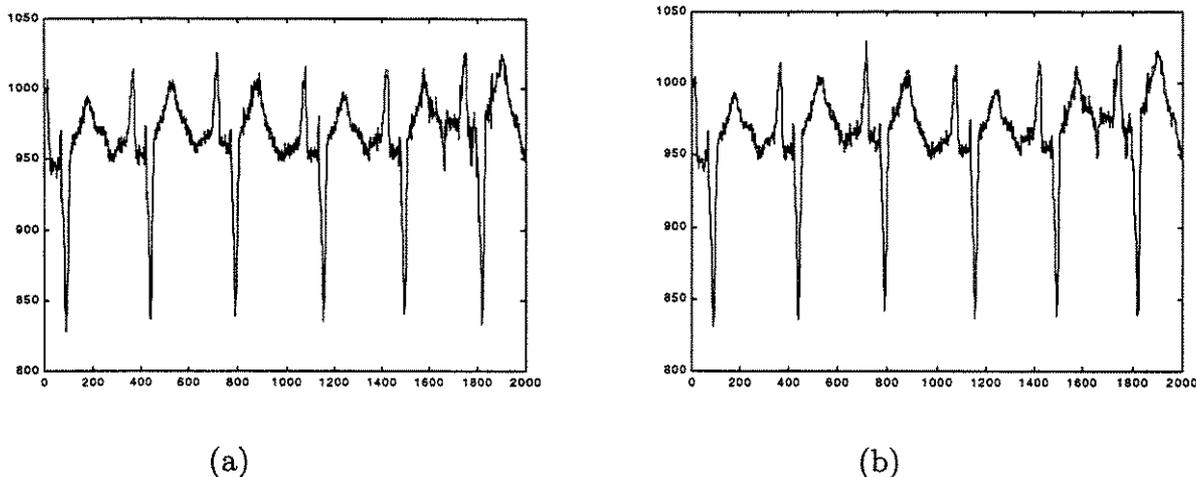


Figura 5.8: Ilustração de trecho do sinal 108 original e recuperado com a técnica DCT para um CR de aproximadamente 4.

Apesar disto, estas são as únicas medidas atualmente aceitas e utilizadas na literatura, e foi este o procedimento utilizado neste trabalho.

O Cálculo da Razão de Compressão - CR

O cálculo da Razão de Compressão ou “Compression Ratio-CR” é simplesmente a relação entre o tamanho do arquivo do sinal original, dividido pelo tamanho do arquivo do sinal comprimido.

$$CR = \frac{\text{Número de bits do sinal original}}{\text{Número de bits do sinal compactado}}$$

5.3. Parâmetros de comparação de Algoritmos de Compressão

5.3.1. Introdução

Quando são analisadas as Tabelas 2.1, 2.2, 2.3 e 2.4, no Capítulo 2.2. deste trabalho, verifica-se a grande desuniformidade de dados que são apresentados nos artigos publicados

na área. Os pontos de interrogação nestas tabelas representam omissões dos autores quanto a dados básicos, enquanto as observações se restringem ao fato do pesquisador ter utilizado alguma base de dados reconhecida pela comunidade científica.

Para um compressor de sinais de ECG pode-se destacar, como dados importantes para uma completa caracterização do mesmo, os seguintes :

1. CR obtido para todos os sinais padrões da base de dados, utilizado na avaliação do mesmo, ou pelo menos, o CR relativo ao “melhor sinal”, isto é , o mais regular por todo o período deste referido arquivo, como também e principalmente o CR obtido para o “pior sinal”, isto é, aquele que apresenta as irregularidades maiores e mais frequentes durante todo o seu arquivo. Se o pesquisador tiver condições de ter as curvas $R(D)$ dos sinais , é mais fácil identificar quais são estes dois limites. Senão, pode-se fazer inspeção visual dos mesmos e fazer um julgamento subjetivo. No caso da base de dados do MIT, obteve-se pela análise visual que os sinais 100 e 117 eram os mais regulares, enquanto que o sinal 203 era o mais irregular, o que foi confirmado quando foram levantadas as curvas $R(D)$ de todos os sinais desta base de dados.
2. Traçar experimentalmente a curva $R(D)$ do compressor desenvolvido, sempre que for possível.
3. Declarar claramente qual base de dados foi utilizada e quais sinais foram utilizados nos testes. O melhor será sempre utilizar um total de 24 horas de ECG, como é o caso da base de dados do MIT (48 sinais com meia hora cada).
4. Declarar qual é o Sampling Rate utilizado nos sinais de teste.
5. Declarar qual o número de bits dos mesmos sinais (resolução).
6. Mostrar sempre, para uma avaliação visual do desempenho do compressor, um trecho de sinal com ao menos 5 pulsos, que apresente um dos pulsos com alguma alteração importante, como uma extra-sístole, para que se possa avaliar efetivamente o seu desempenho em casos críticos. Os pesquisadores mais experientes e renomados assim o fazem, enquanto os demais, apresentam trechos de sinal totalmente regular que não quer dizer nada, tanto em termos científicos como de engenharia. (vide a reprodução do artigo de Iwata neste trabalho, Figura 4.1 e 4.2, e do compressor desenvolvido, Figura 4.17, para se ter uma idéia do aqui proposto).

Nome do Algoritmo	Detector de onda Q	CR:para o pior /melhor sinal	Sampling Freq. / Bits
<i>PCA-NIPALS</i>	<i>Da base de dados</i>	<i>13,5 / 71,9</i>	<i>285 / 11</i>

Erro pior /melhor sinal: PRD% ou RMS μ V	Nome da Database utilizada	Quais sinais foram utilizados	Foi implementado para teste em Real Time?
<i>85,4μV / 48,1μV</i>	<i>MIT-BIH</i>	<i>Todos</i>	<i>Sim, a ser testado no futuro</i>

Figura 5.9: Proposta de modelo de tabela para avaliação de algoritmos de compressão

7. Declarar se utilizou detector da onda R por algoritmo próprio ou se foi utilizado o sinal de referência da própria base de dados.
8. Estabelecer o método de medida de erro de reconstrução do sinal. O certo é sempre caracterizar o erro para todos os sinais da base de dados. O erro mais aceito é o erro PRD (Percentual Root Mean Square Difference). O segundo mais aceito é o erro RMS. Os dois não são boas indicações da performance, fato este constatado por vários pesquisadores, mas são os únicos mais aceitos (Vide Item 5.2.4.).

Além destas sugestões, propõe-se uma “tabela padrão” para que o pesquisador preencha com os dados que tem, na tentativa de gerar informações que possam ser úteis para outros pesquisadores.

A seguir apresenta-se as tabelas propostas para a área, inseridas nas figuras a seguir expostas, preenchido com os dados do compressor PCA-NIPALS desenvolvido :

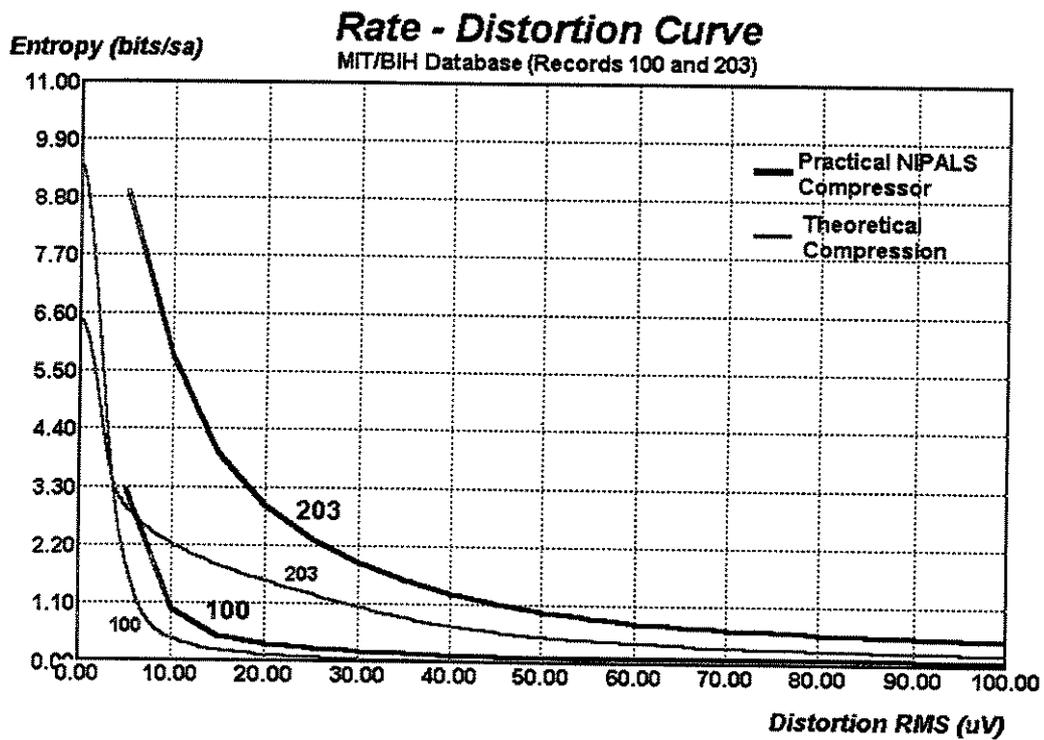


Figura 5.10: Proposta de modelo de curva $R(D)$ para avaliação de algoritmos de compressão

Ambiente/ máquina utilizada no desenvolvimento	Windows/PC/C++
Descrição Resumida do Algoritmo :	
<p>1-Ler o arquivo e armazena-lo na memória, na forma de matriz, onde cada linha corresponde a um pulso de ECG, que também chamaremos de vetor. Este vetor tem como referência o pico do complexo QRS, onda R. As amostras do vetor que se posicionam a direita da onda R são determinadas pela razão de 60% do intervalo R-R relativo ao pulso posterior ao referido. As amostras do vetor que se posicionam a esquerda são determinadas pela razão de 40% do intervalo R-R relativo ao pulso anterior. O vetor é reamostrado de modo que a sua dimensão, em amostras, permaneça fixa. Cria-se, então, uma matriz que representa um bloco de “m” pulsos de ECG, que doravante será chamada de matriz A. É criado um número suficiente de matrizes para representar todo o arquivo.</p> <p>2-O resultado da aplicação da Análise de Componentes Principais é a representação de cada matriz de pulsos de ECG como o produto de duas matrizes: a matriz de Loadings (autovetores da matriz de pulsos) e a matriz de Scores (pesos relativos de cada autovetor). Em forma matricial:</p> $A = S \cdot F$ <p>onde:</p> <p>A = matriz dos vetores que correspondem aos pulsos de ECG</p> <p>S = matriz dos Scores (pesos)</p> <p>F = matriz dos Loadings (autovetores)</p> <p>O algoritmo utilizado para a determinação das matrizes de Loadings e Scores é o algoritmo NIPALS (Non-linear Iterative Partial Least Squares), que será descrito a seguir.</p> <p>2.1-Atribuir um primeiro autovetor como sendo um dos vetores da matriz :</p> $A: F_1 = A_1$ <p>2.2-Calcular o autovalor correspondente ao autovetor: $\lambda_{i,i} = (F_i^2)^{1/2}$</p> <p>2.3-Normalizar o autovetor: $F_i = F_i / \lambda_{i,i}$</p> <p>2.4-Calcular os scores correspondentes ao autovetor. $S_i = A F_i$</p> <p>2.5-Testar a convergência, calculando o erro quadrático entre o vetor de scores S_i atual em relação ao calculado na passagem anterior. Se o erro calculado for menor do que um valor limiar pré-estabelecido, o autovetor F_i e o vetor de scores S_i são correspondentes à componente principal “i” extraída do sinal; pular para o passo 2.8. Se esta for a primeira passagem, ou se o erro quadrático for superior ao valor limiar, seguir para o passo 2.6.</p> <p>2.6. Recalcular o autovetor: $F_i = S_i A$</p> <p>2.7. Voltar para o passo 2.2.</p> <p>2.8. Se o número “f” de componentes principais requeridos foi atingido por “i”, concluir o processo. Caso contrário, calcular a matriz de resíduos com a finalidade de calcular o próximo componente principal: $A = A - S_i F_i$</p> <p>2.9. Voltar ao passo 2.1 para calcular o próximo componente principal (i + 1).</p> <p>3-Foram obtidos, no passo 2, os autovetores e vetores de Scores correspondentes ao número “f” de componentes principais calculados. Este número “f”, para que seja obtido o efeito de compressão, deve ser menor do que o número total de componentes principais.</p> <p>4-.O segundo passo da compressão é a quantização dos Scores e Loadings obtidos. Para isso, computa-se a faixa r obtida de valores, dos Scores e Loadings de cada componente principal, e discretiza-se a mesma em n valores, onde:</p> $n = 2^b - 1$ <p>onde:</p> <p>b é o número de bits representando a quantização desejada.</p> <p>5-Armazena-se então em um arquivo, chamado arquivo comprimido, os Scores e Loadings quantizados correspondentes a cada bloco de pulsos, o número de blocos criados, o número de bits usados na quantização, e a posição de cada onda R no arquivo.</p> <p>6-.Na descompressão, recuperam-se as informações contidas no arquivo comprimido, visando a recomposição parcial do sinal original através da multiplicação dos Scores e Loadings.</p>	

Figura 5.11: Proposta de modelo de resumo de explanação de algoritmos de compressão

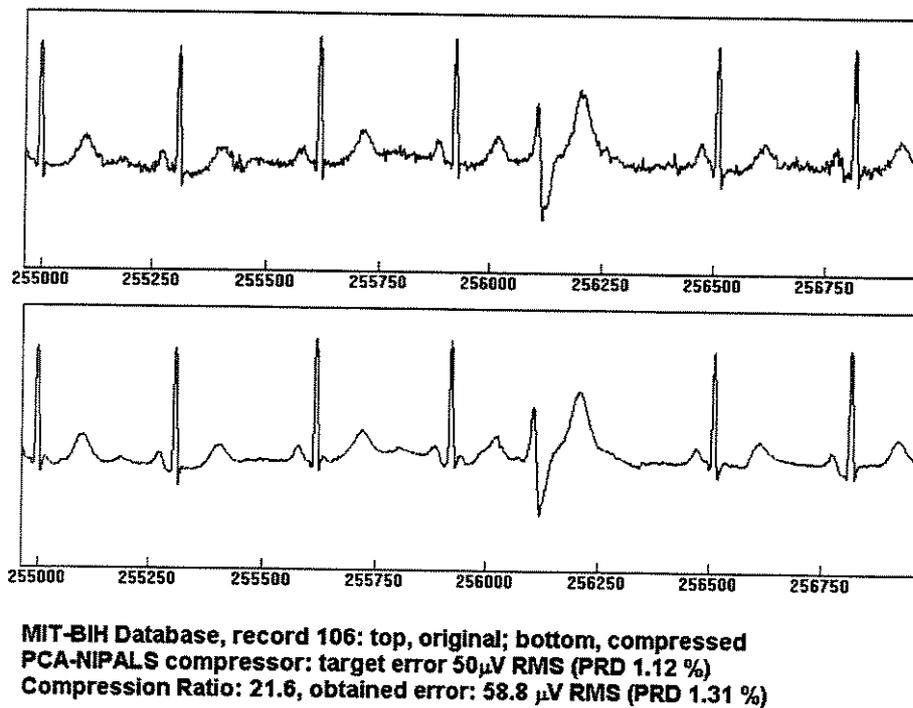


Figura 5.12: Proposta de modelo de amostra de sinal para avaliação de algoritmos de compressão

Capítulo 6

Discussão

6.1. A curva $R(D)$ como referência para desenvolvimento de Algoritmos de Compressão

O procedimento desenvolvido para o levantamento da curva nomeada neste trabalho por “Curva $R(D)$ Operacional” pode se tornar padrão para qualquer área experimental de processamento de sinais, onde se tenha uma base de dados de referência ou uma quantidade de dados suficiente para realizar uma estatística do mesmo.

Ela tem consistência com a representação do sinal por Componentes Principais, e tem uma interpretação de sua função relacionada à consagrada equação de Shannon, através de uma pequena alteração da mesma, que são duas modestas e úteis contribuições a área de Processamento Digital de Sinais.

Mais especificamente, na área de Eletrocardiografia, é uma contribuição inovadora, pois não se tinha ainda caracterizado o sinal de ECG quanto à sua Função de Distribuição de Probabilidade, fdp, que se concluiu ser muito próxima da função de Laplace, enquanto a literatura especializada tendia a assumi-la com Gaussiana.

A obtenção das Curvas $R(D)$ Operacionais para todos os sinais da base de dados do MIT-BIH é também uma contribuição à área, pois, com as mesmas, um pesquisador da área de compressão de sinais de ECG tem referências específicas de cada sinal desta famosa base de dados, para posicionar efetivamente o desempenho do seu esquema de compressão com uma referência absoluta. Além da comparação tradicional, é possível saber se ele está

próximo do limite teórico de compressão daquele sinal, e avaliar a recompensa que se pode obter caso queira realizar um esforço adicional no seu esquema a fim de melhorá-lo.

6.2. Estado da Arte dos algoritmos de compressão

Pela revisão realizada e apresentada no Capítulo 2.2 deste trabalho, nota-se que os esquemas que realmente têm capacidade de extrair os limites de compressão dos sinais de ECG (como também se nota nas áreas de áudio e vídeo), são os caracterizados por utilização de alguma operação de “transformada” no sinal e/ou extração de parâmetros por intermédio de algum tipo de transformação.

Para realizar uma comparação mais efetiva dos mesmos, criou-se um “Índice de Mérito” de Compressão, que é dado por :

$$I = \frac{CR}{PRD} @ PRD,$$

onde :

CR = Razão de Compressão, já definido.

PRD = Erro PRD, já definido.

Este índice permitiu criar a Tabela 6.1 (obtida apenas para artigos que apresentaram os referidos dados), que gera algumas observações importantes a seguir apresentadas. Os dados apresentados nesta tabela são resumidos na Figura 6.1

Nota-se que, segundo este índice, o compressor de melhor performance é o de Iwata [38], com valor de 191,00. Em segundo lugar se posiciona o trabalho de Philips [62], com 67,15. Em terceiro lugar vem os desenvolvidos neste trabalho ; o com Rede Neural com valor 38,1 e o PCA-NIPALS com 36,9, e em quarto lugar um grupo de trabalhos, com valores próximos de CR/PRD, dados por McAuliffe [51] com 18,8, Olmos [60] com 18,3, Hilton [31] com 17,4 e Tompkins [78] com 16,7. A Tabela 6.1 também ilustra um gráfico dos índices de mérito em função do ano de publicação do artigo.

A primeira coisa a se observar é que se destacam os compressores que se utilizam de transformadas, e que os mesmos se iniciam em 1990. A partir deste ano, os índices de mérito apresentam valores inferiores a uma década e a partir da utilização de transformadas passam para valores bem superiores a uma década.

Artigos	Data	CR/PRD	Nome do Autor-Técnica	Classific.
Ref.	Data	CR/PRD	Obs :	Pos.
[24]	1964	0,75		
[19]	1968	0,3571		
[54]	1978	0,3775		
[69]	1979	2,23		
[1]	1982	0,6857		
[34]	1985	0,714		
[66]	1986	1,05		
[23]	1988	1,0741		
[37]	1990	191,00	IWATA- RNA Autoassociator	1°
[50]	1990	0,351		
[28]	1991	16,727	TOMPKINS-Average Beat Subtraction	4°
[63]	1992	0,375		
[51]	1992	18,823	McAULIFFE-RNA Kohonen	4°
[62]	1993	67,142	PHILIPS-Time Warped Polynomials	2°
[56]	1993	1,4625		
[15]	1993	1,2		
[4]	1995	5,333	Al-NASHASH-Fourier Adaptive Coefficients	
[5]	1995	2		
[64]	1996	3,066		
[59]	1996	1,222		
[67]	1996	0,6842		
[31]	1997	17,391	HILTON-Packet Wavelet.	4°
[60]	1997	18,333	OLMOS-Adaptive KLT	4°
[14]	1997	3,15		
[46]	1997	6,1728	LEE-2D Discrete Cossine Transform	
[57]	1997	2,8125		
[tese]	1999	36,957	DENYS-NIPALS-Principal Components Analysis	3°
[tese]	1999	38,01	DENYS-RNA-Autoassociator	3°

Tabela 6.1: índice de Mérito dos Sistemas de Compressão versus data de publicação

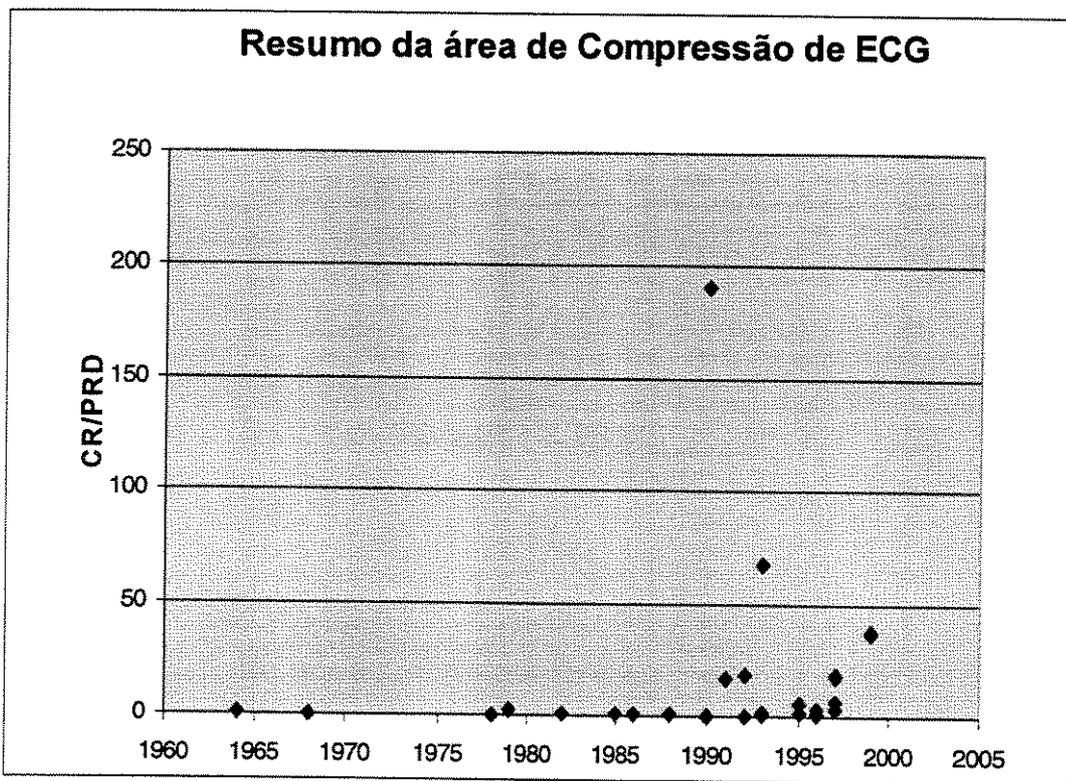


Figura 6.1: Resumo da área de Compressão de ECG.

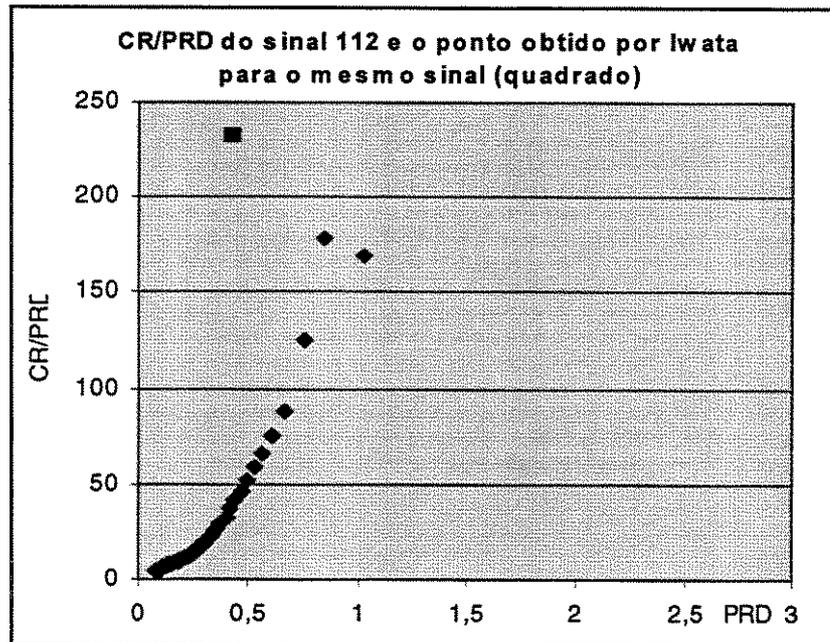


Figura 6.2: Relação CR/PRD para o sinal 112 e o ponto obtido pelo compressor de Iwata para o mesmo sinal.

O desempenho do compressor de Iwata [37] é imbatível até hoje.

Para se aprofundar mais nesta discussão criou-se curvas da relação CR/PRD para alguns sinais da base de dados que Iwata se utilizou, mostrada na Figura 6.2, 6.3 e 6.4. Na mesma curva se apresenta a relação CR/PRD para o compressor de Iwata, para o com RNA desenvolvido e para o compressor PCA-NIPALS desenvolvido.

Nota-se que o ponto gerado pelo trabalho de Iwata está acima das relações CR/PRD obtidas pelo próprio sinal (teórico) em questão, enquanto que os outros compressores se posicionam abaixo desta.. Para se posicionar pontos acima da referida curva, seria necessário que a Rede Neural de Iwata criasse código comprimido através de relações muito não lineares, porém se sabe que a rede que ele utilizou, com apenas uma camada escondida, não deve possibilitar se obter desempenho extremamente melhor daquele obtido por componentes principais. Foi tentado contacto com o autor, mas não se teve resposta que pudesse dirimir as dúvidas citadas, que ficam então como sugestão futura de trabalho.

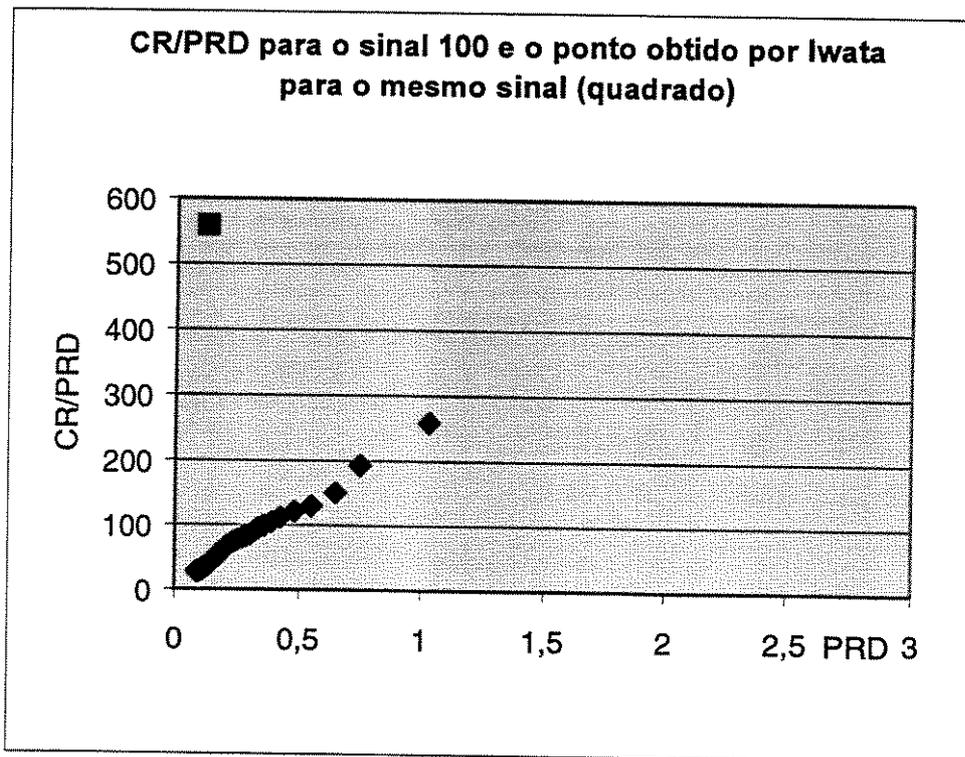


Figura 6.3: Relação CR/PRD para o sinal 100 e o ponto obtido pelo compressor de Iwata para o mesmo sinal.

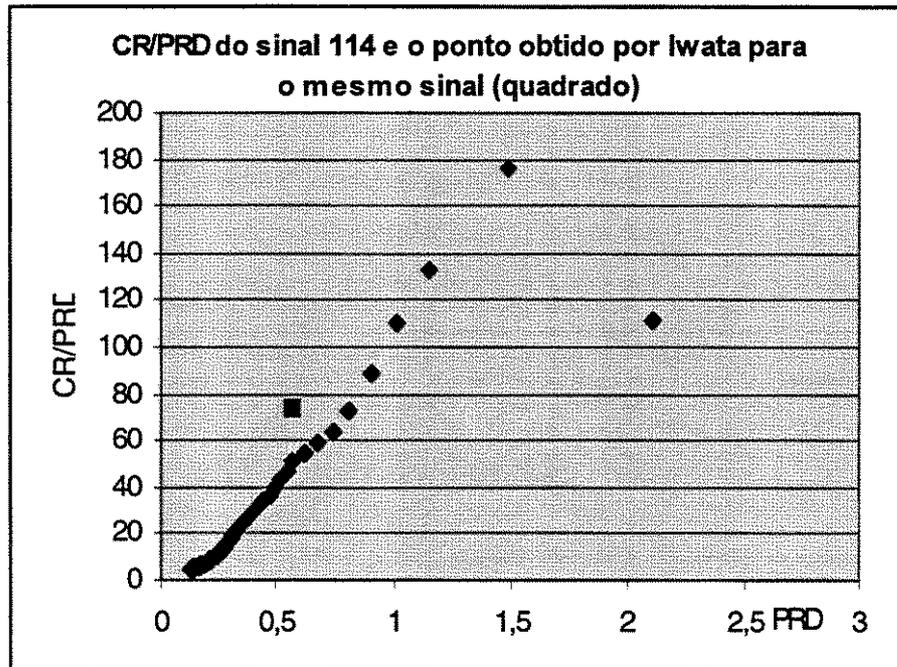


Figura 6.4: Relação CR/PRD para o sinal 114 e o ponto obtido pelo compressor de Iwata para o mesmo sinal.

6.3. O sistema de compressão implementado (PCA- NIPALS) e sua relação com a Curva $R(D)$

Na Figura 4.16, apresentou-se a curva $R(D)$ obtida teoricamente e a obtida através do compressor PCA-NIPALS, valendo ressaltar que este esquema criado é inédito na área.

Observou-se por esta curva que o mesmo está perto do desempenho máximo possível para erro PRD em torno de 1% (equivalente nesta curva ao erro RMS de $50 \mu\text{VRMS}$).

Também se verificou, pelos cálculos teóricos de compressão, realizados no Capítulo 4.2.2., que em certos sinais chega-se bem perto do previsto teoricamente (lembrando que nunca se poderá igualar ao desempenho de qualquer algoritmo prático com o previsto teoricamente, pois um esquema prático de compressão, por mais eficiente que seja, sempre criará um “overhead” no arquivo comprimido, a fim de guardar informações no arquivo comprimido que não são previstas teoricamente). Como os sinais utilizados para estas análises são de trinta minutos de duração cada um (que é $1/48$ do tempo prático de gravação de ECG de

Holter-24 hrs), acredita-se que este “overhead” tenda a diminuir em um sinal de 24 horas, otimizando mais ainda o esquema proposto.

A curva $R(D)$ experimental obtida através do compressor PCA-NIPALS acompanhou a mesma forma daquela obtida teoricamente, com tendência a piorar sua performance para erros menores, o que é de se esperar, pois para erros menores o algoritmo tem que salvar mais componentes principais, aumentando o overhead de informações necessárias a se guardar no arquivo comprimido.

6.4. O sistema desenvolvido (PCA-NIPALS) comparado com os existentes de maior desempenho

Como pode ser visto na Tabela X.X, o sistema desenvolvido se posiciona em terceiro lugar, considerando sua relação CR/PRD, ou Índice de Mérito.

Em primeiro lugar fica posicionado o de Iwata??, apesar das considerações realizadas no item 6.2. Em segundo lugar se posiciona o de Philips [62], que se utiliza de técnica intitulada “time Warped Polynomials”, que é uma transformada que o próprio autor desenvolveu e seu artigo é bastante convincente e de excelentes resultados.

Em terceiro lugar se posiciona o compressor desenvolvido neste trabalho, o que é um feito bastante satisfatório, visto a quantidade de experiência acumulada nesta área e a especialização que têm certos pesquisadores que obtiveram desempenho inferior ao desenvolvido neste trabalho. Até a finalização deste trabalho, não se obteve sucesso de contacto com o pesquisador Akira Iwata [37], autor este que obteve o melhor desempenho de todos os esquemas até hoje realizados, o que deixa em aberto a dúvida levantada no item 6.2, relativo ao fato de o pesquisador ter obtido pontos CR/PRD aparentemente fora do admissível.

6.5. O futuro dos sistemas de compressão de ECG

Visualiza-se o futuro dos sistemas de compressão abrangendo as seguintes propriedades :

1. Sistemas baseados cada vez mais em transformadas, devido a seu excelente desem-

penho e, cada vez mais com possibilidade de implementação em tempo real, devido aos poderosos chips “DSPs” encontrados no mercado.

2. Sempre será associado ao esquema de compressão por transformadas, um esquema de adaptabilidade, que é o “segredo” de se obter maior desempenho : adaptar suas condições e técnica específica de compressão, em tempo real, em função do tipo de sinal que ocorre no momento. Foi assim que se extraiu o melhor desempenho geral do compressor desenvolvido e também é a técnica aplicada pelos pesquisadores que obtém excelentes resultados.
3. Aproveitar-se do poderoso processamento disponível nos chips DSP e já realizar a análise dos sinais anômalos que hoje em dia é feito em um microcomputador externo, que colhe o sinal comprimido, o descomprime e depois inicia a análise de morfologias alteradas e estatísticas de frequência de batimentos, de intervalos entre partes do pulso de ECG, extrassístoles, etc.
4. Aproveitamento cada vez maior das técnicas de compressão de imagens para aplicação em ECG, pois o sinal de ECG (quando alinha-se cada pulso do ECG e monta-se um bloco de pulsos como se fosse uma imagem) quando visto como uma imagem, permite extrair o máximo de eficiência, pois o sinal de ECG é quase regular e periódico, o que permite, neste caso, a aplicação eficiente de técnicas de transformação como realizadas com imagens.
5. Conexão do Holter a um sistema de telefonia celular digital que possa avisar o Médico e transmitir, em tempo real, através de técnicas de reconhecimento de padrões, o trecho de sinal alterado. Assim, seu paciente com o Holter, tendo alguma arritmia, poderá ser entrevistado naquele mesmo instante pelo Médico, e que com isto, colherá mais dados do paciente do que ocorre atualmente, onde o paciente anota resumidamente seus sintomas em um caderno, para depois de 24 horas ou mais, reportar-se ao Médico.

Capítulo 7

Conclusões

1. A curva $R(D)$ desenvolvida pode servir de referência para a área de compressão de ECG, devido a sua utilidade na aferição da capacidade de compressão que o pesquisador pode retirar de cada sinal da base de dados do MIT. O procedimento realizado para obtenção desta curva é novo e então estas são contribuições originais deste trabalho.
2. A descoberta de que a Função de Densidade de Probabilidade, fdp, é fortemente Laplaciana é uma contribuição também inovadora, pois se acusa na literatura que a fdp é aproximadamente Gaussiana, sem verificação profunda desta afirmação, que é errônea.
3. O estado da arte em técnicas de compressão se mostra ser compressão baseadas em transformadas, e juntamente sempre se apresentando o sinal de ECG em arranjo equivalente a duas dimensões, como o mesmo fosse uma imagem. Além disso, os melhores desempenhos são sempre obtidos com processos adaptativos em tempo real, obtendo-se assim um conjunto de procedimentos que extrai o melhor Índice de Mérito da área de compressão de ECG.
4. O compressor PCA-NIPALS desenvolvido, é simples, de desempenho satisfatório e de custo computacional modesto, sendo viável implementá-lo em um DSP. Esta técnica aplicada neste compressor é inédita na literatura, e portanto também é contribuição à área de compressão de ECG.
5. A proposta de criação de um Índice de Mérito e sua utilização neste trabalho (baseado na relação CR/PRD @ PRD), é outra contribuição que pode ser considerada das mais importantes, pois a referida área não tinha até agora uma Figura de Mérito que se

pudesse comparar os vários esquemas de compressão até hoje desenvolvidos, deixando sempre uma dúvida em relação a como se comparar (com uma medida simples de se obter), os diferentes esquemas de compressão propostos.

Bibliografia

- [1] ABENSTEIN , J.P. , TOMPKINS, W.J. , “New data-reduction algorithm for real time ECG analysis.”,IEEE Trans. Biomed. Eng., vol BME-29, pp 43-48, jan. 1982.
- [2] AHMED, N., MILNE, P.J. AND HARRIS, S.G, “Electrocardiographic Data Compression via Orthogonal Transforms . IEEE Trans. on Biom. Eng. v. BME-22, , pp. 484-487, n°6, nov. 1975.
- [3] AL-NASHASH, H.A.M. ,“A dynamic Fourier series for the compression of ECG using FFT and adaptive coefficient estimation”, Med. Eng. Phys., vol 17, pp 197-203, 1995.
- [4] AL-NASHASH, H.A.M., “ECG Data Compression Using Adaptive Fourier Coefficients Estimation”, Med. Eng.Phys., vol 16, pp 62-66, Jan. 1994.
- [5] ANANT ,K., DOWLA ,F. , RODRIGUES, G. “ Vector Quantization of ECG Wavelet Coefficients”, IEEE Signal Proc. Letters, vol 2, n°7, pp 129-131,July 1995.
- [6] ANDRADE NETTO, M. L. , “Notas de Aula do Professor - Curso de Redes Neurais”, IA353, UNICAMP, 1994.
- [7] BAILEY, J. et al , “Recommendation for Standardization and Specification in Automated Electrocardiography : Bandwith and Digital Signal Processing” , Circulation 81 :2,pp 730-9, 1990.
- [8] BARR, R.C., BLANCHARD, S.M. , DIPERSIO, D.A., “SAPA - 2 is the Fan”IEEE Trans. Biom. Eng., vol BME-32, n°5, May 1985.
- [9] BARR,R.C., SPACH, M.S., “Sampling Rates Required for Digital Recording of Intracellular and Extracellular Cardiac Potentials”, Circulation, vol 55, n°1, Jan.1977.
- [10] BERGER,T. , “Rate Distortion Theory- A Mathematical Basis for Data Compression”, Prentice Hall,1971.

- [11] BERSON, A.S., WOJICK, J.M., PIPBERGER, H.V., "Precision Requirements for Electrocardiographic Measurements Computed Automatically", IEEE Trans. Biom. Eng., vol BME-24, July, 1977.
- [12] BISHOP, C.M. , "Neural Networks for Pattern Recognition", Clarendon Press-Oxford, 1997 pp 57-59.
- [13] BLANCHETT, T., . KEMBER, G.C, FENTON G.A., " KLT Based Quality Controlled Compression of Single-Lead ECG", IEEE Trans. Biom. Eng. vol 45, n°7 ,pp 942-945, July 1998.
- [14] CASSEN, M. , ENGLISH, M. J., "Computationally Efficient ECG Compression Scheme Using a Non-Linear Quantizer", Computers in Cardiology, IEEE Comp. Soc. Press., vol 24, pp 283-286, 1997.
- [15] ÇETIN, A.E, KÖYMEN, H. , AYDIN, M.C. , "Multichannel ECG Data Compression by Multirate Signal Processing and Transform Domain Coding Techniques", IEEE Trans Biom. Eng. vol 40, n°5 pp 495-499, 1993.
- [16] CHEUNG, K.M. , " Adaptive vector-quantization scheme ". NASA Technical Brief., Vol.16, n°2, Feb. 1992.
- [17] COHEN, A. , ZIGEL, Y., "Compression of Multichannel ECG Through Multichannel Long-Term Prediction", IEEE Eng. Med. Biol. , pp 109-115, Jan-Feb. 1998.
- [18] COX ,J.R. , RIPLEY, K.L. , "Compact Digital Coding of Eletrocardiographic Data", Proc.VI Int. Conf. Syst. Sci, Jan. 1973.
- [19] COX, J.R., NOLLE, F.M. , FOZZARD, H.A., OLIVER, G.C. , "AZTEC, a preprocessing program for real-time ECG rhythm analysis", IEEE Trans. Biomed. Eng., Vol BME-15, pp. 128-129, Apr. 1968.
- [20] dePINTO V. , "Filters for Reduction of Baseline Wander and Muscle Artifact in ECG", J. of Electrocardiology 25(Suppl) : 40, 1992.
- [21] FAUSETT, L., "Fundamentals of Neural Networks :Architectures, Algoritms and Applications". Prentice Hall International Editions, 1994
- [22] FRIENSEM, G.M. et al , "A Comparison of the Noise Sensitivity of Nine Detection Algoritms". IEEE Trans on Biom. Eng., vol 37, n°1, Jan., 1990.

- [23] FURHT, B. , PEREZ, A. "An Adaptive Real-time ECG Compression Algorithm with Variable Threshold," IEEE Trans. Biom. Eng., vol 35, n°6, pp 489 -494, June 1988.
- [24] GARDENHIRE , L.W. , "Redundancy reduction, the key to adaptive telemetry", Proc. Nat. Telemetry Conf. pp. 1-16, 1964.
- [25] GELADI, P, "Notes on the History and Nature of Partial Least Squares (PLS) Modelling", Journal of Chemometrics, vol.2, pp 231-246, 1988.
- [26] GELADI, P. , "Notes on the History and Nature of Partial Least Squares (PLS) Modelling", Journal of Chemometrics, vol.2, pp 231-246, 1988.
- [27] GOLD, R.P., "Do we need a new standard for electrocardiographs?", British Heart Journal, 54 :119-20,1985.
- [28] HAMILTON, P.S. , TOMPKINS, W.J. , "Compression of the Ambulatory ECG by Average Beat Subtraction and Residual Differencing", IEEE Trans. Biom. Eng., Vol 38, n°3, pp 253-259, March 1991.
- [29] HAMILTON, P.S., TOMPKINS, W.J. , "Theoretical and Experimental Rate Distortion Performance in Compression of Ambulatory ECG's", IEEE Transactions on Biomedical Engineering, vol. 38, no 3, March 1991, pp 260- 66.
- [30] HAYKIN,S. , "Neural Networks : A Comprehensive Foundation". Macmillan College Publishing Company,1994.
- [31] HILTON ,M.L., "Wavelet and Wavelet Packet Compression of Eletrocardiograms", IEEE Trans. Biom. Eng., vol 44, n°5, pp 394-399, May 1997.
- [32] HOLTER, N.J. "New Method for Heart Studies", Science, vol 134, pp 1214-1220, 1961.
- [33] HORAN, L.G., FLOWERS, N.C., BRODY, D.A. "Principal Factors Waveforms of the Thoracic QRS Complex", Circulation Research, vol XV, pp 519-526, Aug 1964.
- [34] IMAI, H., KIMURA, N. , YOSHIDA, Y. , "An efficient encoding method for eletrocardio- graphy using SPLINE functions", Syst. Comput. Japan, vol 16, n°3, pp 85-94, 1985.
- [35] ISHIJIMA, M. , and Cols, "Scan-Along Polygonal Approximation for Data compression of Electrocardiograms", IEEE Trans. Biom. Eng., vol BME-30, n°11, pp 723-729, Nov 1983.

- [36] ISHIJIMA, M., SHIN, S.B. , G.H. Hostetter and J. Skansky, "Scan-alone polygonal approximation for data compression of electrocardiograms", IEEE Trans., Biom. Eng., BME-30, pp723-729, 1983.
- [37] IWATA, A., Y., NAGASAKA , SUZUMURA ,N. , "Data Compression of ECG using Neural Network for Digital Holter Monitor", IEEE Eng. Med. Biol., pp 53-57, sep.-1990.
- [38] IWATA. A., YOSHIDA Y., MATSUDA S. ,SATO Y.,SUZUMURA,N. , "An Artificial Neural Network Accelerator Using General Purpose 24 Bits Floating Point Digital Signal Processor". Proc. of Int. Joint Conf. on Neural Networks, Washington DC 2 :171-175,1989.
- [39] JALALEDDINE, S.M.S., et al , "ECG Data Compression Techniques - A Unified Approach" . IEEE Trans. on Biom. Eng., vol 37, n^o4, Apr. 90, pp 329-43.
- [40] JAYANT, N.S. ,NOLL, P. , " Digital Coding of Waveforms :Principles and Applications to Speech and Video" ,Prentice Hall,N.J.1986.
- [41] KOHONEN, T. , "Self-Organization and Associative Memory". Springer Verlag. NY, 1989.
- [42] KNOEBEL, S.B. et al , "Guidelines for Ambulatory Electrocardiography-ACC-AHA Task Force",Circulation,Vol.79,n^o1,pp.206-15, Jan. 1989.
- [43] KONSTANTINIDES, K. , NATARAJAN , B.X. , "An Architecture for Lossy Compression of Waveforms Using Piecewise-Linear Aproximation",IEEE Trans. Signal Proc. Vol, 42, n^o9 pp 2449-2454, Sep. 1994.
- [44] KRISHNAKUMAR, A.S., KARPOWICZ, J.L., BELIC, N., SINGER, D.H , JENKINS, J.M. , "Microprocessor - based data compression scheme for enhanced digital transmission of Holter recording.", Computers in Cardiology, Long Beach, CA, pp. 435-437, 1980.
- [45] KULLBACK, S. A. , LEIBLER, R. A., "On Information and Sufficiency", Leibler Annals of Mathematical Statistics, 22, pp.79-86, 1951.
- [46] LEE, H. , BUCKLEY, K.M., "Heart Beat Data Compression using Temporal Beats Alignment and 2-D Transforms", Conf on Signals, Systems and Computers, IEEE Comp. Soc. Press, pp 1224-1228, 1997.

- [47] LEE, W. H. , YOON, Y.R., “ ECG Data Compression using Wavelet and Fractal Interpolation”, 18 th Ann. I. Conf. IEEE Med. Biol. Soc, pp. 1388-1389, 1996.
- [48] LIMA,C.A, Carvalho,C.A.D., Rocha,M.V., Botter,E.A., “Compactação de sinais eletrocardiográficos”, Trabalho de Graduação, Univ. São Judas Tadeu,1998.
- [49] LINDE,Y.,BUZO,A.,GRAY,R.M., “An Algorithm for Vector Quantizer Design”.IEEE Trans. Comm.,28 :84-95,1980.
- [50] MAMMEN, C.P. , RAMAMURTHI, B. , “Vector Quantization for Compression of Multichannel ECG”, IEEE Trans. Biom. Eng., pp 821-825, vol 37, n°9, sep. 1990.
- [51] McAULIFFE, J.D. , “Data Compression of the exercise ECG using a Kohonen Neural Network”, J. Electrocardiology, vol 26 Supplem., pp 80-89, 1992.
- [52] MIT-BIH DATABASE, “Massachusetts Institute of Technology-Beth Israel Hospital Database”. Harvard-MIT Division of Health Sciences and Technology;Biomedical Engineering Center, Dr. George Moody ,July 1992.
- [53] MIYASHITA, Y., ITOZAWA, T., KATSUMI, H., SASAKI, S., “Short Communication Comments on the Nipals Algorithm”, Journal of Chemometrics, vol.4, pp 97-100, 1990.
- [54] MUELLER, W.C. , “Arrhythmia detection program for an ambulatory ECG monitor”, Biomed. Sci. Instrument., vol 14, pp. 81-85, 1978.
- [55] MURTHY, I.S.N., NIRANJAN, V.C. , “Decompositon of ECG by Linear Filtering”. Comp. Biol. Med., v.22, n°1/2 , pp 13-22,1992.
- [56] NAVE , G. , COHEN , A. , “ECG Compression Using Long- term Predition”, IEEE Trans. Biomed. Eng.,vol 40, n°9, pp 877-885, sep 1993.
- [57] NGUYEN-PHI, K., , WEINRICHTER, H.,“ ECG signal coding using Wavelet transform and binary arithmetic coder”,Int. Conf. Information, Communication, and Signal Processing, vol 3, pp 1344-1348, IEEE Press, Sep. 1997.
- [58] NICOLOSI, D.E.C., ANDRADE NETTO, M. L., ARANTES, D. S. - Procedimentos e Resultados da determinação da Rate Distortion Function para sinais de ECG e Algoritmos implementados para compressão de sinais de ECG - Relatório Técnico N°RTC-DCA-001/99, 1999.
- [59] OIEN, G., KRAKELAND, H. , NARSTAD ,G., “Fast Fractal - based ECG Signal Compres-sion”, 18th Ann. I. Conf. IEEE Eng. Med. Biol. Soc., pp 1378-1379, 1996.

- [60] OLMOS, S., RIOS, I., GARCIA ,J., JANÉ, R., LAGUNA, P., "Scalar Quantizers for Compression of ECG Signal with Orthogonal Transforms", Computers in Cardiology, IEEE, Comp. Soc. Press.,vol 24, pp. 419-422, 1997.
- [61] PHATAK, A., JONG, S., "The Geometry of Partial Least Squares. Journal of Chemometrics, vol.11, pp 311-338, 1987.
- [62] PHILIPS, W. , "ECG Data Compression with Time-Warped Polynomials", IEEE Trans. Biom. Eng., vol 40, n°11, pp 1095-1101, nov. 1993.
- [63] PHILIPS, W. , JONGHE , G. DE , "Data Compression of ECG's by High-Degree Polynomial Approximation", IEEE Trans. Biom. Eng. vol 39, n°4, pp 330-337, Apr. 1992.
- [64] PROVAZNIK, I., KOZUMPLIK ,J., "Wavelet-Based Compression of ECG Signals", 18 th Ann. I. Conf. IEEE Eng Med. Biol. Soc., pp. 1210-1211, 1996.
- [65] RATHIE, P.N., VERDUGO, A.C.G., "On the Entropy of Continuous Probability Distributions, IEEE Transactions on Information Theory, vol. II-24, no 1, Jan.1978.
- [66] REDDY, B.R.S. AND MURTHY, I.S.N., "ECG data compression using Fourier descriptors", IEEE Trans. Biomed. Eng. Vol BME-33, pp. 428-434, Apr 1986.
- [67] RIBBUM ,B., "Using CELP for compression of ECG Signals", 18 th Ann. Int. Conf. IEEE Eng. Med. Biol. Soc., pp 1380-1381, 1996.
- [68] RITTER, H., MARTINEZ,T., SCHULTEN, K. , "Neural Computation and Self-Organizing Maps", Addison-Wesley. 1992.
- [69] RUTTIMANN, U.E. , PIPBERGER, H.V , "Compression of the ECG by prediction or interpolation and entropy encoding", IEEE Trans. Biomed. Eng., vol BME-26,pp 613-623, nov. 1979.
- [70] SAYOOD, K. , "Introduction to Data Compression". Morgan Kaufman Publ.,Cal., 1996.
- [71] SCHER, A.M. , YOUNG, A.C. "Frequency Analysis of the Electrocardiogram", Circulation Research, vol VIII, pp 344-346, March 1960a.
- [72] SCHER, A.M., YOUNG, A.C. , MEREDITH, W.M. "Factor Analysis of the Electrocardiogram," Circulation Research, vol VIII, pp 519-526, May 1960b.

- [73] SHANNON, C. E. , “A Mathematical Theory of Communication”, Bell Syst. Tech. J., vol 27, pp 379-423 and 623 - 656, 1948.
- [74] SHANNON, C. E. , “Coding Theorems for a Discrete Source with a Fidelity Criterion”. IRE Nat'l Conv. Rec, part 4 , 142-163, 1959.
- [75] STEWART, D., DOWER,G.E. , SURANYI, O. , “An ECG compression code, ” J. Electrocardiol., vol 6, n^o2, pp 175-76,1973.
- [76] TAI, S. C. , “ECG Data Compression by Corner Detection” , Med. & Biol. Eng. & Computing, nov, 1992, pp 584-90.
- [77] THOMAS, K. , “Entropy : the Key to Data Compression”, Dr. Dobb's Journal ,Feb 1991.
- [78] TOMPKINS , W. J., Editor. , “Biomedical Digital Signal Processing”, Prentice Hall, N.J., 1993.
- [79] TUZMAN ,A., COSTA ,M., BARTESAGHI ,R., ROBINS, T., “Wavelet Based Compression of Holter ECG Signals”,18 th. Ann. I. Conf. IEEE Med. Biol. Soc., pp. 1218-1219, 1996.
- [80] TUZMAN, A.S. CHIALANZA, M. ACOSTA, R. BORTESAGHI, T. HOBBS, A. FONSECA, “Best Wavelet Basis Design for Joint Compression - Classification of long ECG Data Records”, Computers in Cardiology, IEEE Comp. Soc. Press, Vol 24, pp. 287-290, 1997.
- [81] VITERBI, A.J., OMURA, J.K , “Principles of Digital Communication and Coding” . Mc Graw-Hill Book Co.,1979.
- [82] BIOMEDICAL SIGNAL PROCESSING-VOLUME II : “ Compression and Automatic Syntactic Recognition- Biomedical Signal Processing, ch 4,pp. 87-111 ,Methods 1985.
- [83] WOLD, H., LYTTKENS, E., “Nonlinear Iterative Partial Least Squares (NIPALS) Estimation Procedures” , Regression Techniques,Bull. ISI,Vol43,1969.
- [84] WOMBLE, M.E., HALLIDAY, J.S., MITTER, S.K., LANCASTER, M.C. AND TRIEBWASSER, J.H. , “Data Compression for storing and transmitting ECGs/VCGs”, Proc. IEEE. Vol. 65, pp 702 - 706 May, 1977.

- [85] ZIGEL, Y., COHEN, A., ABU-FUL, A., WAGSHAL, A., KATZ, A., “ Analysis by Synthesis ECG Signal Compression”, Computers in Cardiology, IEEE, Comp. Soc. Press. , vol 24, pp 279 282, 1997.
- [86] ZIGEL, Y., COHEN, A., KATZ, A., “A Diagnostic Meaningful Distortion Measure for ECG compression”, Computers in Cardiology, IEEE, Comp. Soc. Press. , , pp 117,120, 1996.

Apêndice A

Princípios de Eletrocardiografia

Tompkins [78]

Uma das principais técnicas para diagnosticar doenças do coração é baseada no Eletrocardiograma (ECG). A Eletrocardiografia ou monitoração de ECG permite a dedução de muitos defeitos elétricos e mecânicos do coração através da medida de ECG, que são potenciais medidos na superfície do corpo. Com um monitor de ECG, pode-se determinar a frequência do coração e outros parâmetros cardíacos.

A.1. Eletrocardiografia Básica

Existem três técnicas básicas utilizadas em eletrocardiografia clínica. A mais familiar é o eletrocardiograma clínico padrão. Este corresponde ao teste realizado no consultório de um médico, no qual 12 diferenças de potencial chamadas “Leads ou derivações de ECG” são registradas da superfície do corpo de um paciente em repouso. Um segundo método utiliza um outro conjunto de potenciais da superfície do corpo, como entrada para um modelo vetorial em três dimensões da excitação cardíaca. Isto produz uma visão gráfica da excitação do coração chamada vetocardiograma (VCG). Finalmente, para monitoração por um longo período na unidade de terapia intensiva ou em pacientes ambulatoriais, uma ou duas derivações de ECG são monitoradas e/ou gravadas para procurar distúrbios no ritmo das batidas do coração que tragam risco à vida. Este método é denominado “Análise de Arritmias”.

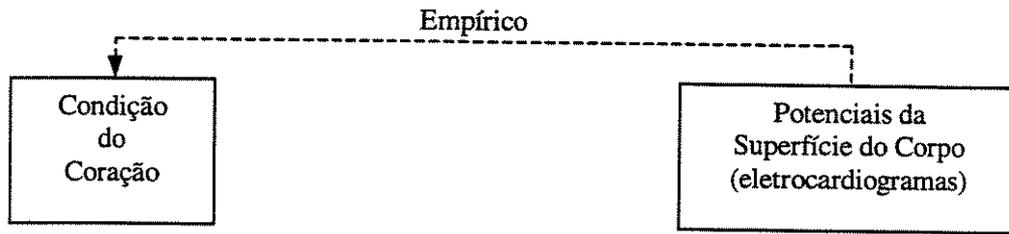


Figura A.1: O objeto da eletrocardiografia é deduzir as condições elétricas e mecânicas do coração realizando medidas não invasivas do potencial da superfície do corpo.

Portanto, as três técnicas básicas utilizadas em eletrocardiografia são :

1. ECG clínico padrão (12 leads).
2. VCG (3 leads ortogonais).
3. ECG de monitoração (1 ou 2 leads).

A Figura A.1 mostra o objetivo básico da eletrocardiografia. Através da observação de sinais elétricos gravados apenas na superfície do corpo, um procedimento completamente não invasivo, os cardiologistas tentam determinar o estado funcional do coração. Apesar do ECG ser um sinal elétrico, alterações no estado mecânico do coração levam a alterações em como a excitação elétrica distribui-se sobre a superfície do coração, dessa forma alterando o ECG da superfície do corpo. A área da Cardiologia é baseada, entre outras medidas, na gravação de ECGs de milhares de pacientes durante muitos anos, e na observação de relações entre as formas de onda do sinal e diferentes anormalidades. Dessa forma, a eletrocardiografia clínica é altamente empírica, baseada principalmente em conhecimento experimental. Um Cardiologista aprende os significados das várias partes do sinal de ECG de “experts” que aprenderam de outros “experts”.

A Figura A.2 mostra como os mais antigos ECGs foram registrados por Einthoven, aproximadamente na virada do século. Soluções de água com sal forneciam a conexão elétrica com o corpo. O galvanômetro servia de instrumento de medida para registrar o ECG.



Figura A.2: Medidas de ECG no passado (aproximadamente 1900) por Einthoven.

A.1.1. Eletrodos

Com o passar do tempo, foram desenvolvidos eletrodos metálicos para conexão elétrica com o corpo. Um eletrólito, geralmente composto de solução salina em um gel, forma a interface elétrica entre o eletrodo de metal e a pele. No corpo, correntes são produzidas pelo movimento de íons, enquanto que em um cabo correntes são provocadas por movimento de elétrons. Sistemas de eletrodos fazem a conversão de correntes “iônicas” para correntes “eletrônicas”.

Metais condutivos, tais como bronze folheado e níquel, são utilizados como eletrodos de ECG mas apresentam um problema : os dois eletrodos necessários para se adquirir um ECG, juntamente com o eletrólito e o corpo cheio de sais, agem como uma “bateria”. Pode haver um off-set de potencial DC através dos eletrodos, tão grande quanto o maior pico do sinal de ECG. Uma camada dupla de cargas (íons positivos e negativos separados por uma distância) ocorrem no eletrólito. Movimentos do eletrodo, tais como os causados pelo movimento do paciente, perturbam esta camada dupla e mudam o “off-set” DC. Como este potencial de “off-set” é amplificado aproximadamente 1000 vezes através de um amplificador de ECG,

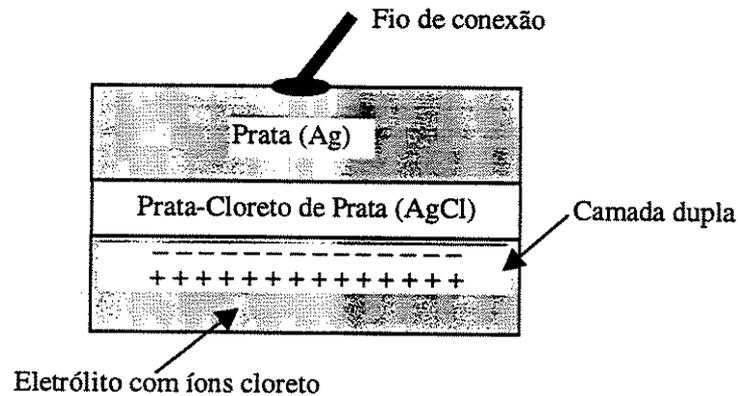


Figura A.3: Eletrodo de ECG prata-cloreto de prata. Muitos eletrodos modernos têm camadas de eletrólitos que são feitas de um gel consistente que tem propriedades adesivas. O gel minimiza os distúrbios da dupla camada de cargas.

pequenas alterações levam a grandes deslocamentos da linha de referência no sinal de saída. Um eletrodo que se comporta desta forma é denominado eletrodo polarizável e é útil apenas para pacientes em repouso.

O material mais utilizado para eletrodos atualmente é prata-cloreto de prata (Ag-AgCl), já que se aproxima de um eletrodo não polarizável. A Figura A.3 mostra tal eletrodo. Este tipo de eletrodo tem um potencial de off-set bem pequeno. Ele possui uma camada de Cloreto de Prata depositada sobre uma placa de Prata. Os íons de Cloreto movem-se no corpo, no eletrólito, e na camada de AgCl, onde são convertidos para fluxo de elétrons na placa de Ag e transmitidos pelos cabos de conexão. Este método reduz o "off-set" de potencial para um valor bastante pequeno, quando comparado ao pico do sinal de ECG. Portanto, movimentos do eletrodo causam um deslocamento muito menor na linha de referência no ECG amplificado do que um eletrodo polarizável.

A.1.2. O gerador cardíaco equivalente

A Figura A.4 mostra como um modelo físico denominado gerador cardíaco equivalente pode ser utilizado para representar a atividade elétrica cardíaca. O modelo físico mais popular é uma fonte de corrente de dois polos, que é representada matematicamente como um

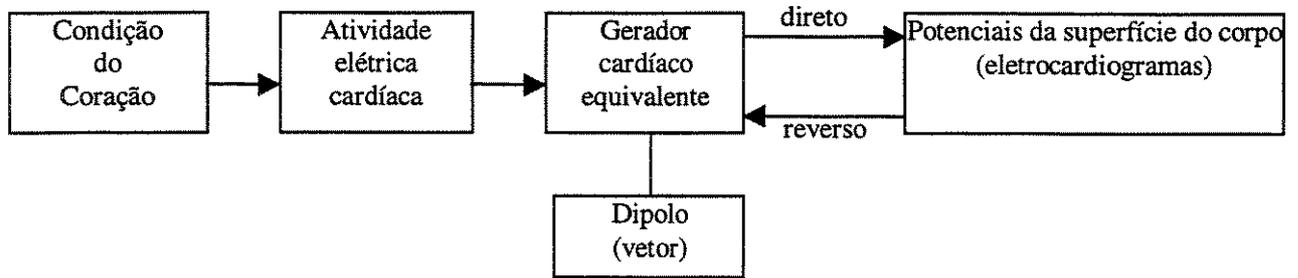


Figura A.4: Tanto as condições elétricas como mecânicas do coração são envolvidas na determinação das características da distribuição da atividade elétrica sobre a superfície do mesmo. Um modelo desta atividade é denominado "gerador cardíaco equivalente".

vetor variante no tempo, o que resulta no vetocardiograma clínico (VCG). Einthoven postulou que a excitação cardíaca poderia ser modelada como um vetor. Ele também notou que os membros são como conexões diretas a pontos no torso, já que os fluxos de corrente gerados no interior do corpo pela fonte bipolar fluem primeiramente dentro do tórax e não fluem significativamente para os membros. Portanto, Einthoven visualizou uma situação onde eletrodos poderiam apenas ser conectados a cada um dos ombros e também a um ponto próximo a parte inferior do corpo para que não fosse obrigado a utilizar soluções salinas.

Einthoven desenhou um triângulo utilizando os vértices nos dois ombros e membros inferiores e observou que os lados do triângulo tinham aproximadamente o mesmo comprimento. Este triângulo, mostrado na Figura A.5, tornou-se conhecido como o "Triângulo Equilátero de Einthoven". Se o vetor representando a distribuição da excitação cardíaca é conhecido, então a diferença de potencial medida entre dois membros (dois vértices do triângulo) é simplesmente proporcional à projeção do vetor no lado do triângulo que conecta os membros. A Figura A.5 mostra a relação entre o vetor de Einthoven e cada um dos três leads (terminais de contacto) dos membros (leads I, II e III). Os sinais positivos mostram qual conexão é ligada à entrada positiva do amplificador, para cada lead.

Um dipolo de corrente corresponde a uma fonte e um sorvedouro de corrente separados por uma distância. Já que este dipolo tem módulo e direção que mudam durante o batimento do coração, conforme as células no coração se despolarizam, isto leva à representação vetorial :

$$\mathbf{p}(t) = p_x(t)\hat{\mathbf{x}} + p_y(t)\hat{\mathbf{y}} + p_z(t)\hat{\mathbf{z}},$$

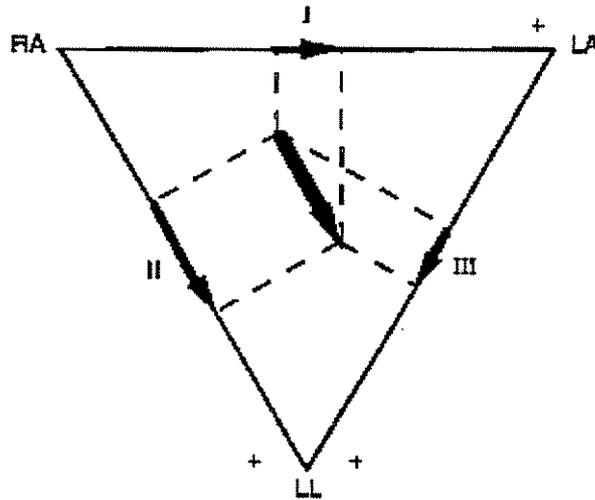


Figura A.5: Triângulo equilátero de Einthoven. RA e LA são os braços direito e esquerdo e LL é a perna esquerda.

onde $\mathbf{p}(t)$ é o vetor cardíaco variante no tempo, $p_i(t)$ são os componentes ortogonais do vetor também denominados por “leads escalares”, e \hat{x} , \hat{y} , \hat{z} , são vetores unitários nas direções x , y e z .

Um proeminente pesquisador em VCG nos anos 50 chamado Frank, modelou uma reprodução do corpo em gesso como o mostrado na Figura A.6; impermeabilizou-o, e o preencheu com água e sal. Ele colocou uma fonte de dois polos composta por um conjunto de dois eletrodos num bastão no modelo de tronco, na posição do coração. Uma fonte de corrente fornecia corrente aos eletrodos que produziam fluxos de corrente no volume condutor. Dos eletrodos localizados no gesso, Frank mediu a distribuição de potencial superficial do corpo em vários pontos do tórax provenientes da fonte de corrente. Das medidas neste estudo, ele encontrou coeficientes geométricos de transferência que relacionam a fonte de dois polos com cada um dos potenciais superficiais do corpo.

Uma vez conhecidos os coeficientes de transferência, o problema da eletrocardiografia pode ser resolvido para qualquer fonte de dois polos. A solução seguinte fornece o potencial em qualquer ponto arbitrário da superfície do corpo para um dado bipolo cardíaco. Expressando-se matematicamente :

$$v_n(t) = t_{nx}p_x(t) + t_{ny}p_y(t) + t_{nz}p_z(t)$$

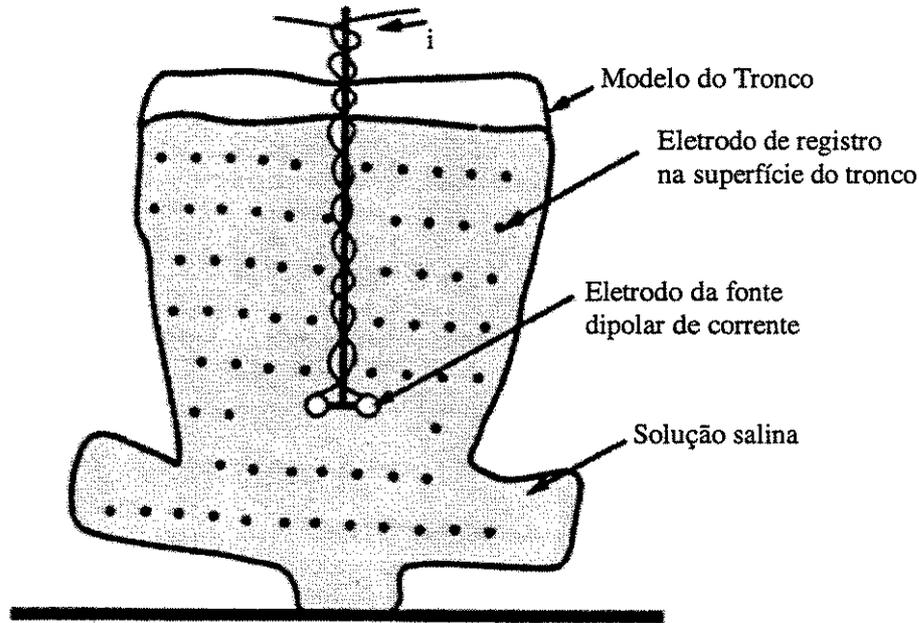


Figura A.6: Modelo de tronco utilizado para desenvolver o "Frank Lead System" para vetocardiografia

Esta solução mostra que o potencial $v_n(t)$ (ou seja, o ECG) em qualquer ponto n da superfície do corpo é dado pela soma linear dos produtos de um conjunto de coeficientes de transferência $[t_{ni}]$ (únicos para um dado ponto), pelos componentes ortogonais dos vetores correspondentes $[p_i(t)]$. Os ECGs são variantes no tempo devido à variação do dipolo, enquanto que os coeficientes de transferência são dependentes apenas da geometria do tórax e não-homogeneidades. Portanto, para um conjunto de k potenciais da superfície do corpo (leads), há um conjunto de k equações que podem ser escritas na forma vetorial :

$$\mathbf{V} = \mathbf{T} \times \mathbf{P}$$

onde \mathbf{V} é um vetor $k \times 1$ representando os potenciais variantes no tempo, \mathbf{T} é uma matriz $k \times 3$ de coeficientes de transferência, fixos para um dado indivíduo, e \mathbf{P} é o vetor do coração 3×1 , variante no tempo.

É claro que o vetor cardíaco e os coeficientes de transferência são desconhecidos para um dado indivíduo. Porém, se houver uma forma de determinar este vetor cardíaco, pode-se utilizá-lo na solução do problema e obter o ECG para qualquer posição da superfície do corpo. O método para resolver este problema é baseado num modelo físico do tronco

humano. Este modelo fornece coeficientes de transferência que relacionam ao vetor cardíaco os potenciais em vários pontos da superfície do corpo. Com esta informação, selecionamos três leads de ECG que resumem as características intrínsecas do ECG normal que se deseja simular. Então, resolvemos o problema inverso para encontrar o vetor do dipolo cardíaco

$$\mathbf{P} = \mathbf{B} \times \mathbf{V}$$

onde \mathbf{B} é uma matriz $3 \times k$ dos coeficientes dos leads, que é diretamente obtida da inversão da matriz de coeficientes \mathbf{T} . Portanto, para os três componentes do vetor cardíaco, há três equações lineares da forma :

$$p_x(t) = b_{x1}v_1(t) + b_{x2}v_2(t) + \dots + b_{xk}v_k(t) \quad (\text{A.1})$$

É selecionado k leads na superfície do corpo $[v_1(t), v_2(t), \dots, v_k(t)]$, para os quais os coeficientes dos leads são conhecidos a partir do modelo físico do tronco humano, pode-se resolver o problema inverso e registrar o vetor cardíaco variante no tempo. Uma vez que se tem os componentes deste dipolo, resolvemos o problema utilizando a Equação A.1 para obter o ECG para qualquer ponto na superfície do corpo.

A.1.3. Geração do ECG

A Figura A.7 mostra como um ECG é medido utilizando eletrodos presos à superfície do corpo e conectados a um amplificador de instrumentação. Para os instantes no tempo, nos quais o vetor aponta em direção ao eletrodo conectado ao terminal positivo do amplificador, o sinal de saída do ECG terá sentido positivo. Se apontar para o eletrodo negativo, o ECG será negativo. O movimento variante no tempo do vetor cardíaco produz o ECG da superfície do corpo para uma batida de coração gerando as ondas **P** e **T** características e o complexo **QRS**. A Figura A.8 mostra os registros do lead II para uma batida do coração de um ECG normal típico.

A Figura A.9 ilustra o espalhamento da excitação cardíaca representada por um vetor em diferentes pontos do tempo, que se relaciona à origem do ECG na superfície do corpo para uma configuração de amplificador como aquela mostrada na Figura A.7. Na Figura A.9(a), a despolarização lenta do átrio, que começa no nó sinoatrial (AS), produz a onda **P**.

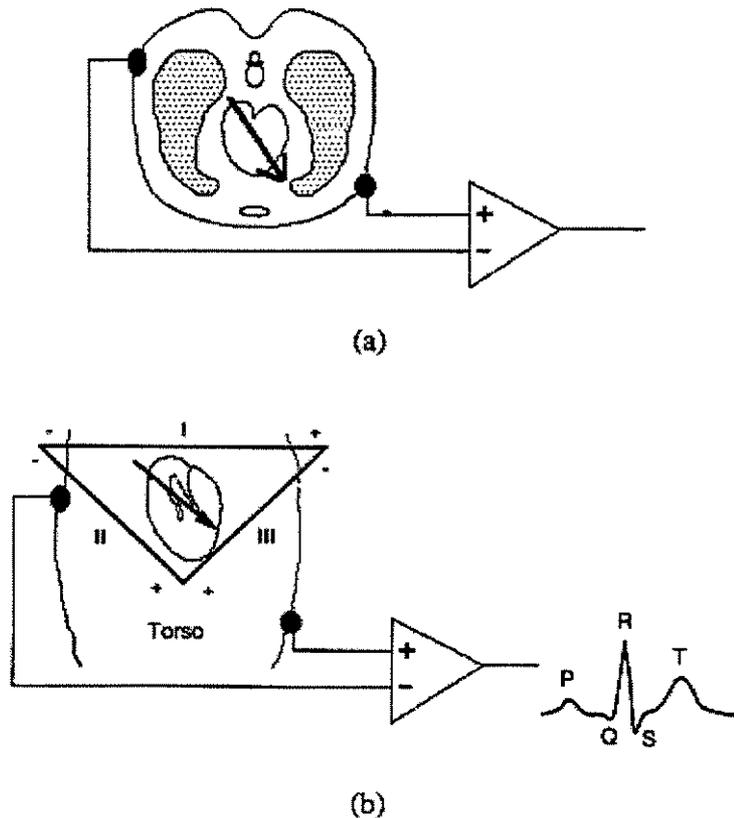


Figura A.7: Configuração básica para registrar um eletrocardiograma. Utilizando eletrodos presos ao corpo, o ECG é registrado com um amplificador de instrumentação. (a) Vista transversal (de topo) de uma fatia do corpo mostrando o coração e pulmões. (b) Vista frontal mostrando os eletrodos conectados aproximadamente numa configuração Lead II.

Como mostra a Figura A.9(b), o sinal é atrasado no nó atrioventricular (AV), resultando em uma região “isoeétrica” depois da onda **P**; então, devido às fibras condutoras de Purkinje, começa a levar o estímulo rapidamente ao músculo ventricular, onde há o início da onda **Q**. Na Figura A.9(c), a rápida despolarização do músculo ventricular é descrita como um vetor grande e rápido, que começa a produzir a onda **R**. A Figura A.9(d) ilustra que o vetor máximo representa um ponto no tempo onde a maioria das células estão despolarizadas, originando o pico da onda **R**. Na Figura A.9(e), a fase final da despolarização ventricular ocorre conforme a excitação se estende em direção à base dos ventrículos (para o topo na figura) originando a onda **S**.

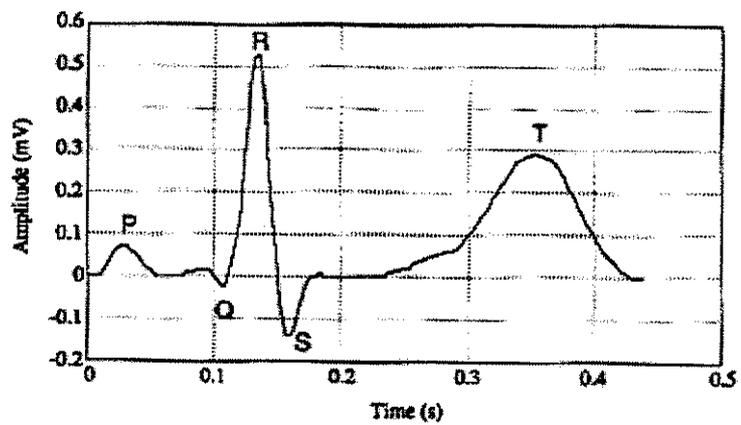


Figura A.8: Eletrocardiograma para uma batida de coração normal mostrando amplitudes e tempos de duração típicos para as ondas P, QRS e T.

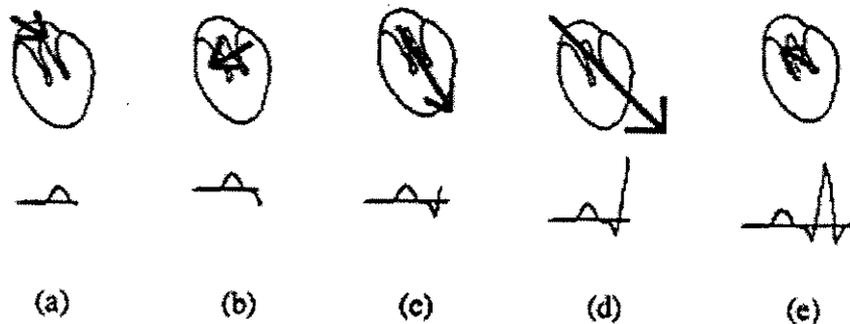


Figura A.9: Relação entre o espalhamento da ativação elétrica cardíaca (representado em vários instante de tempo por um vetor de soma nos desenhos superiores) e a geração do ECG (nos desenhos inferiores).

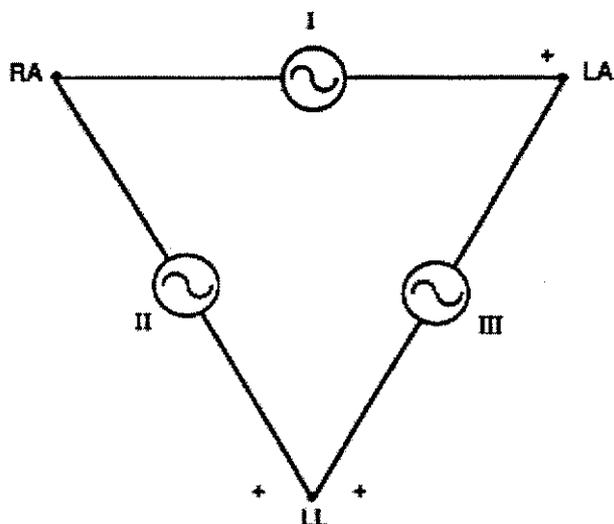


Figura A.10: Leads I, II e III são as diferenças de potencial entre os membros como indicado. RA a LA são os braços direito e esquerdo e LL é a perna esquerda.

A.1.4. Os padrões de Leads (Derivações de ECG)

A Figura A.10 mostra como se pode observar as diferenças de potencial entre os braços como fontes ideais, já que se faz cada medida de tensão utilizando um amplificador de instrumentação com uma impedância de entrada bastante alta. É claro que estas três tensões formam uma malha fechada de medidas. Da lei das tensões de Kirchoff, a soma das tensões numa malha é igual a zero. Portanto :

$$II - I - III = 0$$

Pode-se reescrever esta equação para expressar qualquer um desses leads, em termos dos outros dois leads :

$$II = I + III$$

$$I = II - III$$

$$III = II - I$$

É portanto claro que uma dessas tensões é completamente redundante; pode-se medir quaisquer duas e calcular a terceira. De fato, isto é exatamente o que monitores de ECG

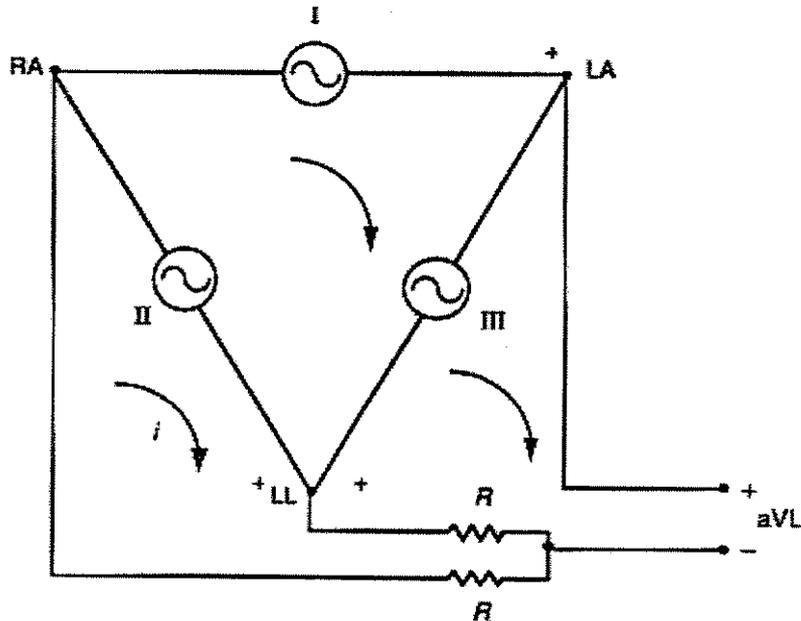


Figura A.11: O "Augmented Limb Lead aVL" é medido como mostrado.

modernos fazem. A maioria dos monitores medem os leads I e II e calculam o lead III. Pode-se perguntar porque calcular o lead III, se ele é redundante, isto é, não há nova informação que já não esteja presente nos leads I e II. Para responder a esta questão, devemos retornar à Figura A.1 e lembrar que os Cardiologistas aprenderam as relações entre doenças e ECGs através da observação de um conjunto padrão de leads, e relacionando a aparência de cada um a cada anormalidade diferente. Já que estes três leads foram selecionados desde o princípio da eletrocardiografia, a análise de cada um deles é importante para o Cardiologista.

A.1.5. Os padrões de "Leads Aumentados"

A instrumentação antiga tinha baixo ganho de amplificação, não adequado para produzir traços de ECG grandes o suficiente para todos os casos, e assim o esquema ilustrado na Figura A.11 tinha o objetivo de produzir sinais de maior amplitude. Neste caso, como exemplo, o sinal no braço esquerdo, denominado "Augmented Limb Lead aVL", é medido utilizando-se a média dos potenciais nos outros dois membros como referência.

Pode-se analisar esta configuração utilizando a teoria de circuitos. Da malha de baixo, à

esquerda :

$$i \times T + i \times R - II = 0$$

ou

$$i \times R = \frac{II}{2} \quad (A.2)$$

Da malha de baixo à direita :

$$-i \times R + III + aVL$$

ou

$$aVL = i \times R - III \quad (A.3)$$

Combinando as Equações A.2 e A.3 tem-se :

$$aVL = \frac{II}{2} - III = \frac{II - 2 \times III}{2}$$

Da malha no topo ao centro :

$$II = III + I$$

Substituindo, tem-se :

$$aVL = \frac{III + I - 2 \times III}{2} = \frac{I - II}{2} \quad (A.4)$$

(4)

Esta é a tensão equivalente de Thévenin para o “Augmented Limb Lead aVL ” como uma média dos dois eletrodos dos membros frontais. É claro que “ aVL ” é um lead redundante, já que pode ser representado em termos de dois outros leads. Os dois outros “Augmented Leads”, “ aVR ” e “ aVF ”, similarmente, podem ser expressados como funções dos leads I e III. Portanto, encontra-se aqui três leads adicionais, e todos podem ser calculados a partir de dois dos leads frontais e portanto são todos redundantes, sem nenhuma nova informação. Porém, devido à natureza empírica da eletrocardiografia, o médico ainda precisa ver a aparência destes leads para facilitar o diagnóstico.

A Figura A.12 mostra como a resistência equivalente de Thévenin é obtida curto-circuitando-se as fontes de tensão ideais e olhando-se para os terminais de saída. A Figura A.13 ilustra que um sistema de registro inclui um resistor adicional de valor igual à resistência equivalente de Thévenin, conectado à entrada positiva do amplificador diferencial de instrumentação. Isto equilibra a resistência em cada entrada do amplificador para assegurar uma taxa de rejeição de modo comum ótima (CMRR).

A Figura A.14 mostra como resolver vetorialmente, para um “Augmented Limb Lead”, em função de dois dos eletrodos padrão dos membros. Os eletrodos dos membros são representados por vetores orientados nas direções dos lados de seus triângulos correspondentes, mas centralizados numa origem comum. Para encontrar “aVL” neste exemplo, utiliza-se os vetores dos dois eletrodos dos membros que se conectam ao membro sendo medido, neste caso, o braço esquerdo. Utiliza-se o lead I como um dos vetores a somar, já que seu lado positivo está conectado ao braço esquerdo. Torna-se negativo o vetor para o “limb lead III” (isto é, rotacionamos de 180°), já que seu lado negativo está conectado ao braço esquerdo. O lead “aVL” é a metade do vetor soma dos leads I e -III (Veja Equação A.4).

A Figura A.15 mostra o conjunto completo de vetores, representando os membros frontais. Desta representação, pode-se rapidamente encontrar os três “Augmented Limbs” como função dos leads frontais.

A.1.6. Sistema de Leads de ECG

Há três tipos básicos de leads de ECG utilizados em Cardiologia. O mais popular é o método de “12 Leads” que define o conjunto de 12 diferenças de potencial que resultam no ECG clínico padrão. Um segundo sistema designa as posições dos eletrodos para gravar o VCG. Sistemas de monitoração analisam tipicamente um ou dois leads.

A Figura A.16 mostra como os 12 leads do ECG clínico padrão são registrados, e a Figura A.17 mostra o “12-Lead ECG System” padrão para um paciente normal. O amplificador de instrumentação é um projeto especial para eletrocardiografia. Nos novos monitores de ECG baseados em microprocessadores, existem oito amplificadores de ECG similares que registram simultaneamente os leads I, II e V1 a V6. Eles então computam os leads III, aVL, aVR, e aVF para o relatório final.

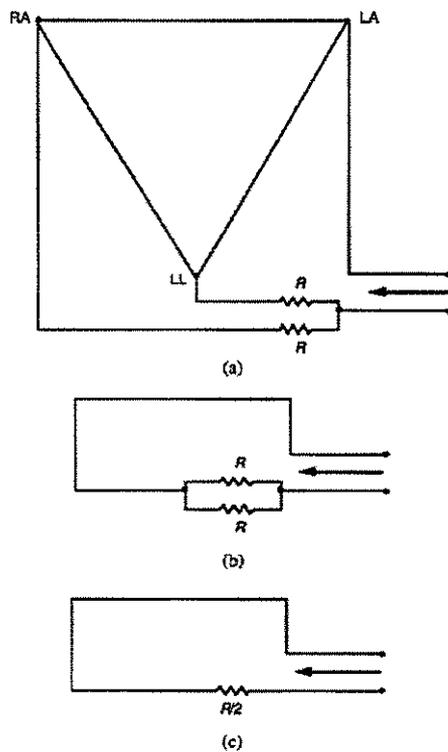


Figura A.12: Determinação da resistência de Thévenin para o circuito equivalente do a_{VL} . (a) Todas as fontes de tensão são curto-circuitadas. (b) Isto resulta em uma associação paralelo dos dois resistores iguais. (c) A resistência equivalente de Thévenin tem valor de $R/2$.

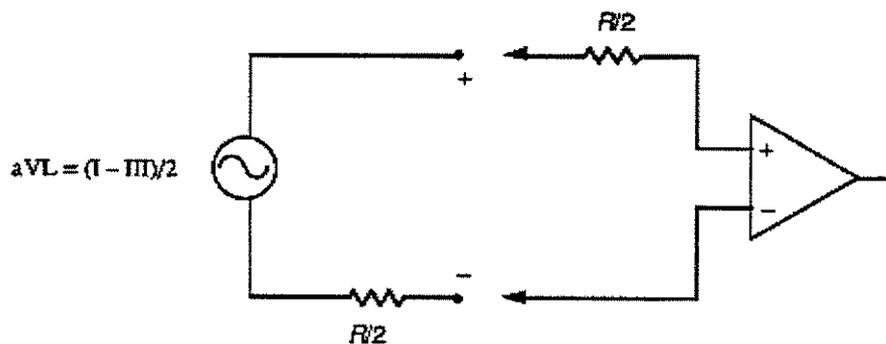


Figura A.13: Num dispositivo prático para registrar a_{VL} , um valor de resistência de $R/2$, igual ao valor da resistência equivalente de Thévenin, é adicionado ao terminal positivo do amplificador de instrumentação, para equilibrar a impedância em cada entrada do mesmo.

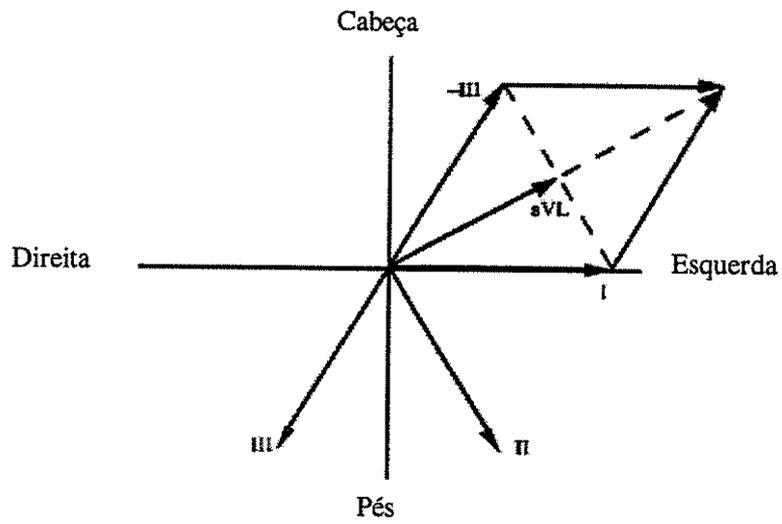


Figura A.14: A solução gráfica vetorial para aVL em termos dos leads I e III.

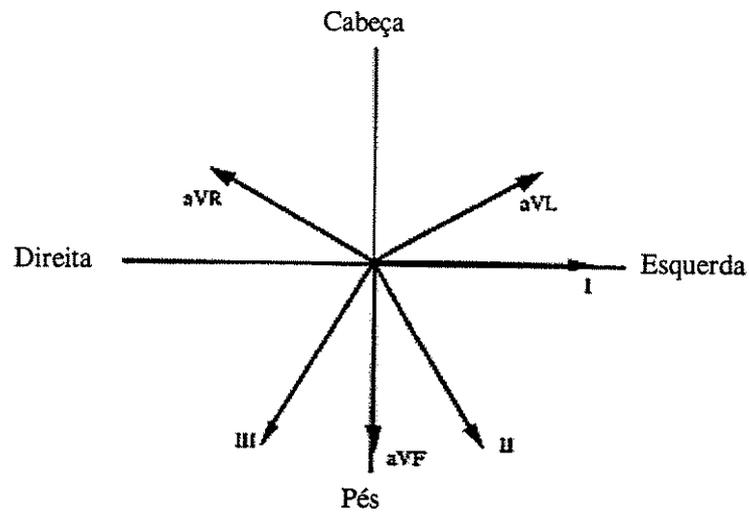


Figura A.15: As relações vetoriais entre todos os leads do plano frontal

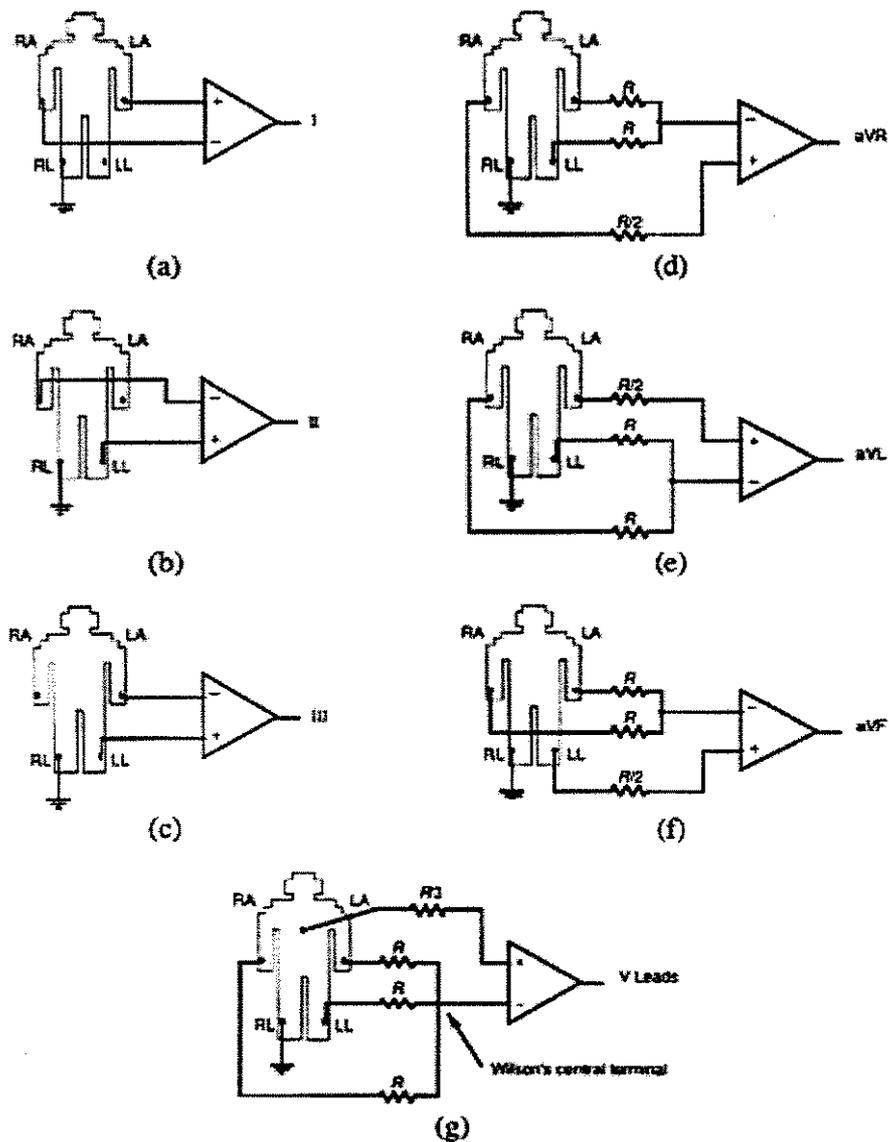


Figura A.16: Eletrocardiograma clínico padrão 12-lead. (a) Lead I. (b) Lead II. (c) Lead III. Note a polaridade do amplificador para cada um desses leads nos membros. (d) aVR. (e) aVL. (f) aVF; estes "Augmented Limb Leads" necessitam de redes de resistores que tiram a média dos potenciais de dois membros enquanto registram o terceiro. (g) Os Seis "V leads" são registrados em relação ao "Terminal Central de Wilson" que é a média de todos os três potenciais dos membros. Cada um dos seis leads (V1 a V6) são registrados a partir de uma posição anatômica diferente do tórax.

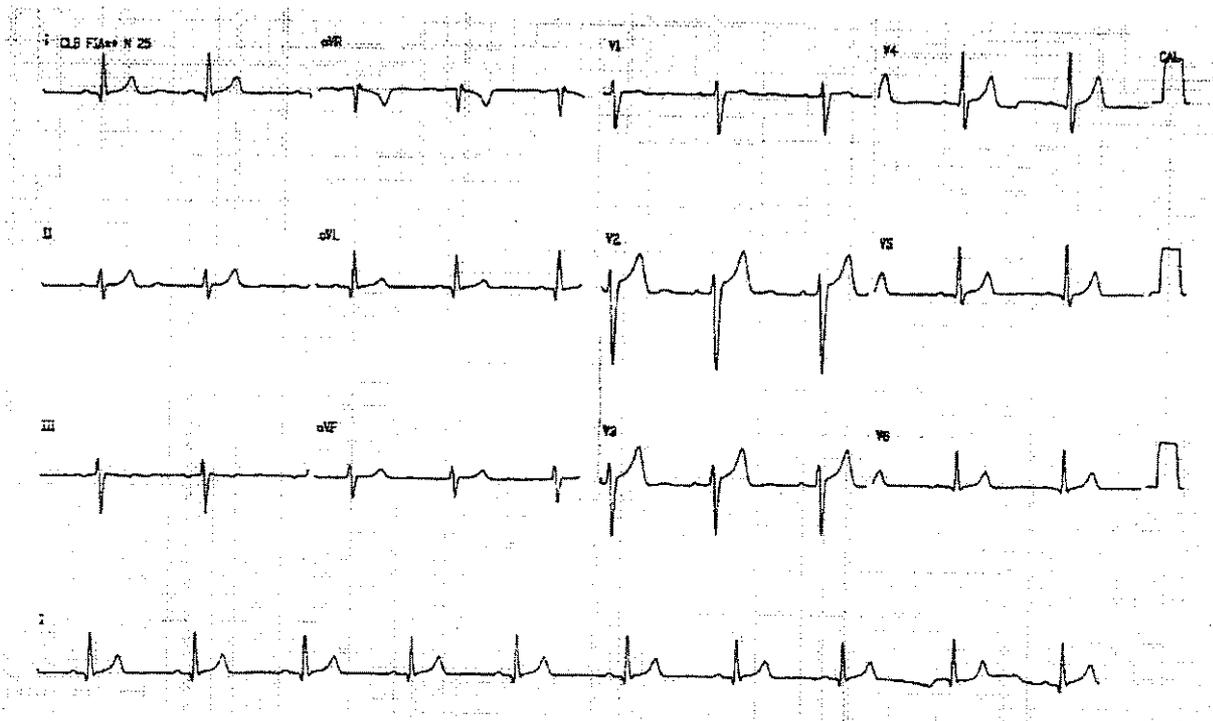


Figura A.17: O 12-lead ECG de um paciente normal do sexo masculino. Pulsos de calibração à direita indicam 1V. A velocidade de registro é de 25mm/s. Cada divisão menor é de 1mm, portanto, as maiores são de 5mm. Dessa forma, no lead I, a amplitude da onda R é de aproximadamente 1.1mV e o tempo entre batidas é de quase 1s (frequência do coração de, aproximadamente, 60bpm).

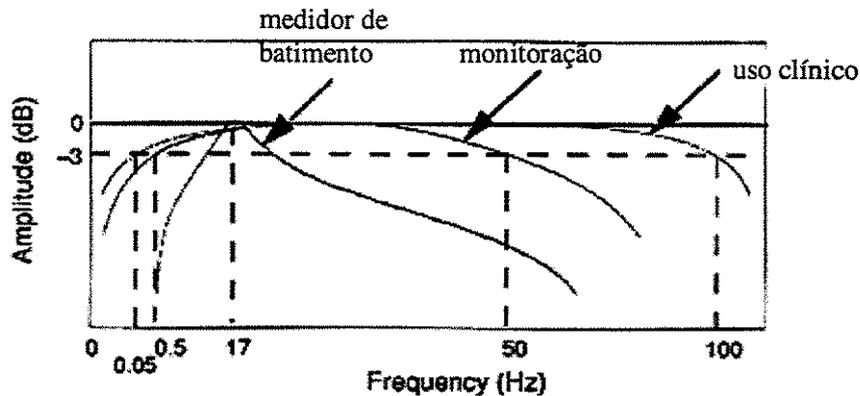


Figura A.18: Larguras de banda utilizadas em eletrocardiografia. A largura de banda clínica padrão para o "12-Lead ECG System" clínico é de 0.05 a 100Hz. Sistemas de monitoração utilizam tipicamente uma largura de banda de 0.5 a 50Hz. Cardiotacômetros, para determinação de freqüência cardíaca em casos de batidas predominantemente normais, utilizam um simples filtro passa-bandas centralizado em 17Hz e com "Q" de, aproximadamente 3 ou 4.

A.1.7. Características do sinal de ECG

A Figura A.18 mostra três larguras de banda utilizadas para diferentes aplicações em eletrocardiografia (Tompkins e Weber [78]). A largura de banda clínica utilizada para registrar o "12-Lead ECG System" padrão é 0,05-100 Hz. Para aplicações de monitoração, tais como pacientes em tratamento intensivo e para pacientes em ambulatório, a largura de banda está restrita a 0,5 - 50Hz. Nestes ambientes, distúrbios no ritmo (arritmias) são de mais interesse que alterações morfológicas súbitas na forma de onda. Portanto, a largura de banda restrita atenua o ruído de maior freqüência causado por contrações musculares (eletromiográficas ou ruído EMG) e o ruído de menor freqüência causado por movimentação dos eletrodos (alterações de referência). Uma terceira largura de banda, utilizada para medidores de freqüência cardíaca (cardiotacômetros), maximiza a relação sinal-ruído para detecção do complexo QRS. Tal filtro passa as freqüências do complexo QRS enquanto rejeita ruído e inclusive as ondas "não QRS" do sinal, tais como as ondas P e T. Este filtro auxilia a detectar os complexos QRS, mas distorce o ECG de tal maneira que a aparência do sinal filtrado não é clinicamente aceitável. Uma outra aplicação que não é descrita aqui estende a largura de banda até 500Hz para medir potenciais tardios. Estes são eventos menores, de alta-freqüência, que ocorrem

no ECG em seguida ao complexo QRS.

A amplitude de pico de um sinal de ECG está na faixa de 1mV, portanto um amplificador de ECG com ganho de, tipicamente 1000, leva o pico do sinal para uma faixa de, aproximadamente, 1V, que é um padrão na área.