

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

EVALDO RENÓ FARIA CINTRA

**PROPOSTA DE UM SISTEMA DE MONITORAMENTO E
DIAGNÓSTICO DE ELETROCARDIOGRAMA PORTÁTIL**

Tese submetida ao programa de Pós-Graduação
em Engenharia Elétrica como parte dos
requisitos para obtenção do Título de Doutor em
Ciências em Engenharia Elétrica.

Área de Concentração:
Engenharia Elétrica

Orientadores:
Prof. Dr. Tales Cleber Pimenta
Prof. Dr. Robson Luis Moreno

Agosto de 2011
Itajubá - MG

Aos meus pais, Delma Renó Faria Cintra e José Carlos Cintra, que sempre incentivaram meus estudos, e à minha esposa, Maria Aparecida dos Reis, apoio constante durante este trabalho.

AGRADECIMENTOS

Agradeço a *Deus* por permitir que eu chegasse até aqui. Sua presença me confortou nas horas difíceis e sempre me transmitiu a força necessária para continuar.

Ao Prof. Dr. Robson Luis Moreno, mestre e grande amigo. Agradeço pelo seu grande estímulo e amizade durante todos esses anos.

Ao Prof. Dr. Tales Cleber Pimenta, pela colaboração e atenção dada durante todo o tempo de desenvolvimento deste projeto.

Aos amigos Paulo César Crepaldi, Luis Henrique de Carvalho Ferreira e Evandro Daniel Calderaro Cotrim, pelas enriquecedoras discussões e assistência constante.

A todos que, embora não citados, mas que direta ou indiretamente colaboraram na realização deste trabalho, estendo meus sentimentos de imensa gratidão.

Este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES.

RESUMO

Este trabalho apresenta uma proposta de processamento de sinais que é demonstrado na implementação de um sistema de diagnóstico de cardiopatias. O sistema recebe os sinais de derivações de um eletrocardiograma, fornecido por um banco de dados. Estes sinais são filtrados e processados de tal forma que na saída deste sistema é gerado o possível diagnóstico do paciente em análise.

Para o funcionamento deste sistema, o método adotado se baseia no agrupamento nebuloso, para reduzir a quantidade de amostras de dados a serem processadas, visando facilitar o processamento e reduzir o hardware dedicado para este fim.

O agrupamento nebuloso permite extrair as principais características, ou grupos, de um sinal de entrada, e através destas características e das funções de pertinência, que relacionam os grupos, fornece regras que podem ser utilizadas em vários tipos de aplicações de controle e tomadas de decisão. Este trabalho demonstra a possibilidade de utilização do agrupamento nebuloso para gerar os grupos, que representam as características principais de um sinal de eletrocardiograma, permitindo assim um diagnóstico de prováveis doenças cardíacas.

Para a geração do diagnóstico da cardiopatia, foi utilizada também a correlação para comparar os grupos de um sinal de um eletrocardiograma desconhecido com os grupos de um sinal de eletrocardiograma de um banco de dados de diagnóstico conhecido. A comparação que obtiver maior valor de correlação será reconhecida como o possível diagnóstico do paciente.

Este trabalho apresenta o resultado da aplicação do agrupamento nebuloso para a redução das amostras a serem processadas, através de simulações de um sistema criado para comprovar o funcionamento da técnica citada e também o resultado da implementação deste sistema em uma FPGA. O reduzido número de amostras do processo de agrupamento torna o processamento mais simples e simplifica a implementação do hardware. De acordo com os testes, o método obteve 85% de diagnósticos corretos.

ABSTRACT

This work presents a signal processing approach that will be validated by a cardiac diagnostic system implementation. The system receives signals from an electrocardiogram leads, but initially they come from database. These signals are filtered and processed so that the system outputs the possible diagnosis.

The system operation is based on fuzzy clustering that reduces the amount of data samples to be processed, thus facilitating the data processing and reducing the required hardware.

The fuzzy clustering, allows the extraction of the key features, or clusters, of an input signal. Based on the clusters membership functions it is possible to establish rules that can be used in a variety of decision making and control applications. This work demonstrates the possibility of using fuzzy clustering to generate the clusters that represent the main features of an ECG signal in order to diagnose cardiopathies.

The heart disease diagnosis also required correlation that was also used to compare the clusters of electrocardiogram under analysis and clusters of an ECG database of known diagnosis. The comparison that achieves the highest correlation is taken as the possible patient diagnosis.

This work presents the result the fuzzy clustering process used to reduce the number of samples to be processed through simulation. If a system specially designed to validate the technique works cited and through an FPGA implementation. The reduced number of samples of the clustering process turns the processing simpler and allows its hardware implementation. According to the tests conducted, the method achieves 85% correct diagnoses.

SUMÁRIO

RESUMO	
ABSTRACT	
LISTA DE FIGURAS	
LISTA DE TABELAS	
1 INTRODUÇÃO	01
1.1 Considerações iniciais	01
1.2 O tema da Tese, a justificativa e o problema do trabalho	03
1.3 Objetivos	04
1.4 Eletrocardiograma.....	05
1.5 Organização do trabalho.....	09
2 FUNDAMENTOS TEÓRICOS.....	10
2.1 Considerações iniciais.....	10
2.2 Sistema de pré-processamento.....	10
2.3 Filtro.....	11
3 PROCESSO DE AGRUPAMENTO PARA EXTRAÇÃO DE REGRAS.....	18
3.1 Função de pertinência.....	20
3.2 Modelo nebuloso Takagi-Sugeno.....	36
3.3 Aplicação do modelo Takagi-Sugeno para extração de regras de um sinal de eletrocardiograma.....	39
4 CORRELAÇÃO.....	46
4.1 Resultados das correlações.....	47
5 RESULTADOS EXPERIMENTAIS	51
5.1 Banco de dados	51
5.2 Testes realizados	51
5.3 Resultados obtidos	52
6 CONCLUSÕES.....	55
LISTA DE REFERÊNCIAS.....	56

LISTA DE FIGURAS

Figura 1 – Esquemático simplificado do Sistema para o diagnóstico de cardiopatias	02
Figura 2 – Sistema de condução do coração	06
Figura 3 – Derivações bipolares I, II, III	07
Figura 4 – Derivações unipolares aVF, aVL e aVR	07
Figura 5 – Derivações precordiais V1, V2, V3, V4, V5 e V6	08
Figura 6 – Sinal característico de um eletrocardiograma	08
Figura 7 – Sistema de pré-processamento.....	10
Figura 8 - Função de transferência de um filtro Butterworth	12
Figura 9 - Resposta em frequência (magnitude) do filtro <i>Butterworth</i> em função de sua ordem.....	13
Figura 10 - Linha de comando para a utilização do filtro passa baixa.....	13
Figura 11 - Gráfico da resposta em frequência do filtro utilizado.....	14
Figura 12 - Linhas de comando utilizadas para eliminar o nível DC do sinal.....	15
Figura 13 - Exemplo de um sinal de eletrocardiograma antes de passar pelo bloco de filtragem e eliminação do nível DC.....	16
Figura 14 - Linhas de comando utilizadas para eliminar o nível DC do sinal.....	17
Figura 15 - Exemplos para a comparação das velocidades	20
Figura 16 - Exemplo de função de pertinência brusca.	21
Figura 17 – Função de pertinência suave.....	21
Figura 18 - Funções de pertinência.....	22
Figura 19 – Função de pertinência triangular.....	23
Figura 20 – Função de pertinência sigma.....	24
Figura 21 – Função de pertinência Gaussiana.....	25
Figura 22 – Função de pertinência formada pela diferença de duas funções sigma.....	26

Figura 23 – Função de pertinência sino generalizada.....	27
Figura 24 - Função $\text{sen}(x_1.x_2)$	28
Figura 25 – Gráfico para função de pertinência sino.....	29
Figura 26 - Gráfico gerado pelo programa para função de pertinência sino.....	30
Figura 27- Gráfico do erro gerado entre o sinal esperado para o sistema e o sinal gerado do sistema.....	30
Figura 28 - Gráfico das funções de pertinência de Gauss	31
Figura 29 - Gráfico de saída do programa para função de pertinência Gauss.....	32
Figura 30 - Gráfico do erro gerado entre a função $\text{sen}(x_1.x_2)$ e a função gerada pelo programa, utilizando a função de pertinência de Gauss.....	33
Figura 31 - Gráfico com funções de pertinência com formato triangular.....	33
Figura 32 - Gráfico de saída para função de pertinência triangular.....	34
Figura 33 – Gráfico do erro gerado pelo programa entre a função desejada e a função ser gerada.....	35
Figura 34 - Sinal típico de eletrocardiograma.....	39
Figura 35 - Linhas de comando para geração de u_{ki} , X_e e Γ	40
Figura 36 - Rotina para criação da matriz diagonal X.....	42
Figura 37 - Rotina para criação da matriz dos coeficientes.....	43
Figura 38 - Rotina para a determinação do vetor v.....	44
Figura 39 - Gráfico que mostra a posição e o valor de cada grupo gerado pelo sistema de criação de regras.....	45
Figura 40 - Sinais em análise.....	49
Figura 41 - Sinais com forte correlação direta.....	49
Figura 42 - Sinais com forte correlação inversa.....	50

LISTA DE TABELAS

Tabela 1 – Vetores de entrada x e saída y para o sinal da Figura 34.....	40
Tabela 2 – Grau normalizado dos antecedentes u_{ki} gerados para cada regra.....	41
Tabela 3 – Matriz X_e , com uma coluna com as entradas e uma coluna preenchida com 1.....	41
Tabela 4 – Matriz X	42
Tabela 5 – Matriz θ dos coeficientes.....	43
Tabela 6 – Tabela que representa a matriz dos grupos criados.....	43
Tabela 7 - Posição de cada grupo no tempo.....	44
Tabela 8 - Obtenção dos parâmetros T_p , F_n e F_p	52
Tabela 9 - Tabela comparativa com outros estudos.....	53

1 INTRODUÇÃO

1.1 Considerações Iniciais

Várias pesquisas sobre saúde indicam que os problemas cardíacos são as maiores causas de mortes em seres humanos. De acordo com a *American Heart Association*, mais de 910 mil americanos morrem anualmente em consequência de doenças do coração e mais de 70 milhões vivem com alguma forma de doença do coração como pressão alta, derrame, angina [1]. Diante deste cenário, pesquisadores concentram esforços na busca de soluções que permitam detectar estes problemas com maior antecedência possível, aumentando desta forma as chances de sobrevivência destes pacientes, através de tratamentos específicos para um determinado diagnóstico.

Para fazer o diagnóstico sobre um determinado problema cardíaco, é preciso analisar os registros das variações de potenciais elétricos gerados pela atividade elétrica do coração. Estes sinais são obtidos através de um exame chamado eletrocardiograma [2].

O trabalho proposto, relacionado diretamente com o eletrocardiograma, consiste em demonstrar os resultados da adaptação de uma técnica de processamento de sinais, conhecida como agrupamento de regras, para sua aplicação em um sistema de diagnóstico de cardiopatias. A técnica de agrupamento de regras, frequentemente denominada de *clusterização*, é o processo de agrupar um conjunto de regras, objetos físicos ou abstratos em classes de regras ou objetos similares [3, 4].

O objetivo desta adaptação é utilizar essa técnica para identificar os pontos que descrevem as principais características de um sinal de eletrocardiograma. Com a identificação destes pontos, o processamento do sinal fica restrito a eles, diminuindo a quantidade de dados a serem processados e simplificando a implementação de um hardware para este fim.

A técnica de adaptação para obter as principais características de um sinal de eletrocardiograma é baseada no método de extração de regras nebulosas [5]. Este

método se baseia na criação de agrupamentos (regras) que serão utilizados em um sistema de controle.

Para demonstrar os resultados da utilização da adaptação do sistema de agrupamento nebuloso, foi criado um sistema para o processamento destes sinais, como o apresentado na Figura 1.

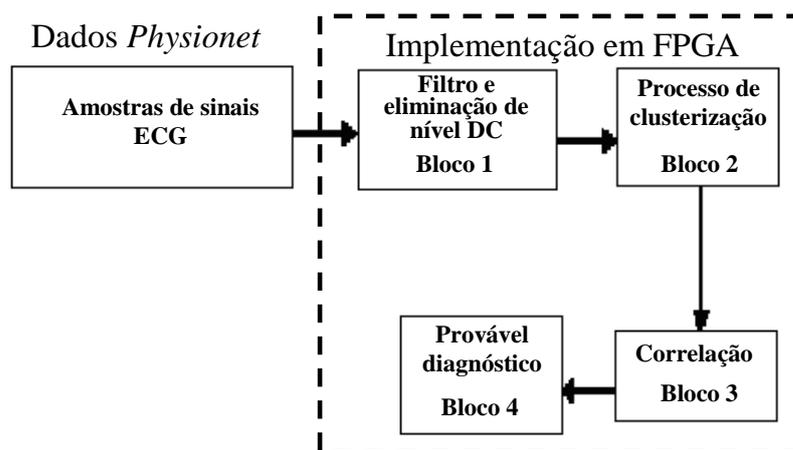


Fig. 1 – Esquemático simplificado do Sistema para o diagnóstico de cardiopatias.

O sistema proposto, apresentado na Figura 1, receberá amostras analógicas de um sinal de eletrocardiograma. As amostras dos sinais para a validação do sistema foram tiradas de um banco de dados denominado *Physionet* [6], que será detalhado no item 1.2.

Antes de serem processados, os sinais de entrada passam por um filtro, para eliminar ruídos de frequências altas, que são comuns em sinais de eletrocardiograma. Também é feita a eliminação de nível DC, pois tanto os ruídos como o nível DC podem interferir no resultado do processamento. Após a eliminação dos ruídos, é aplicado o método de extração de regras, que será discutido no capítulo 3, onde serão separadas apenas as amostras mais importantes do sinal a ser analisado.

No bloco 3, utiliza-se o método da correlação, conforme será abordado no capítulo 4, onde as amostras mais importantes do sinal em teste são comparadas com as principais amostras de sinais de um banco de dados de diagnósticos conhecidos e, de acordo com o resultado da correlação destes sinais, é gerado o provável diagnóstico do paciente.

1.2 O tema da Tese, a justificativa e o problema do trabalho

A Tese deste trabalho consiste na demonstração da viabilidade do uso da técnica de agrupamento nebuloso para diminuir a quantidade de amostras a serem processadas por um sistema de diagnóstico de cardiopatias, o que possibilita o desenvolvimento de um hardware programável (FPGA ou ASIC) que efetue o diagnóstico de cardiopatias, habilitando assim o recurso de diagnóstico em um hardware que possa estar disponível em regiões ou situações onde seja difícil o atendimento especializado de um cardiologista. Como exemplo pode ser citado o primeiro diagnóstico em ambulâncias de atendimento de emergência.

Alguns estudos [7-11] apresentam implementações em software que utilizam técnicas de processamento de sinais para interpretação de características de um eletrocardiograma, o que permite obter diagnósticos prévios de alguma cardiopatia em um paciente.

O sistema proposto neste trabalho consiste em apresentar os resultados da aplicação da adaptação da técnica proposta pela tese e, utilizando a correlação, gerar prováveis diagnósticos com a utilização de poucos pontos de um eletrocardiograma, viabilizando um hardware pequeno, barato, rápido e com desempenho comparável ao das implementações em software citadas na literatura.

Para comprovar a viabilidade de uso da técnica e validar os algoritmos de processamento de sinal, todos os resultados apresentados neste trabalho foram obtidos após modelamento em MatLab[®] [12]. Serão apresentados resultados do sistema através de comparações com outros estudos. A implementação em hardware será tema de outro trabalho, mas que já possui resultados comprovando a viabilidade de implementação em FPGA.

Para a verificação da eficácia do trabalho proposto, foi utilizado um banco de dados de sinais de eletrocardiogramas reais, onde cada sinal apresenta as principais características de um eletrocardiograma com uma determinada cardiopatia. O banco de dados utilizado foi obtido através do *PhysioNet* [6].

PhysioNet é um projeto cooperativo iniciado pelo *Boston's Beth Israel Deaconess Medical Center/Harvard Medical School, Boston University, Mc Gill University e Massachusetts Institute of Technology (MIT)*, que consiste em um serviço público para pesquisa de sinais fisiológicos complexos, financiado pelo *National Center for Research Resources* e pelo *National Institute of Health*. O *PhysioNet* oferece livre acesso via Internet a diversas bases de dados de sinais fisiológicos e softwares relacionados à leitura das mesmas.

Devido à presença de ruídos e de componentes DC, foi utilizado um sistema de pré-processamento que é composto de um filtro *Butterworth* de terceira ordem e um processamento para eliminar o nível de sinal DC presente junto com os sinais em análise, ambos implementados em *MatLab*[®].

1.3 Objetivos

O objetivo geral deste trabalho é comprovar, através do desenvolvimento e modelagem de uma técnica de agrupamento nebuloso implementada em *MatLab*[®], que é possível o processamento de sinais de eletrocardiograma, viabilizando uma implementação em hardware de baixo custo para um sistema de diagnóstico de cardiopatias. A técnica proposta possibilita que apenas alguns pontos da totalidade de pontos de um eletrocardiograma sejam tratados para obter um diagnóstico inicial de pacientes.

Este trabalho abriu espaço para que outros trabalhos, como exemplo um trabalho de doutorado em fase de finalização no grupo de microeletrônica da UNIFEI, sejam desenvolvidos na forma de hardware dedicado.

Os objetivos específicos, que derivam do objetivo geral, são:

- Dominar o processo de agrupamento nebuloso;
- Adaptar a técnica de agrupamento nebuloso para a aplicação desejada, uma vez que esta ainda não foi aplicada na identificação de cardiopatias;
- Realizar testes com sinais de eletrocardiogramas reais para a comprovação do funcionamento do sistema utilizado.

1.4 Eletrocardiograma [13-14]

O eletrocardiograma é o registro de todas as atividades elétricas originadas pelo coração. As informações obtidas através do eletrocardiograma são de grande importância para a determinação de algum distúrbio que possa estar ocorrendo no funcionamento ou na estrutura do coração.

O eletrocardiograma é obtido, através de um aparelho chamado de galvanômetro, que mede a corrente entre dois eletrodos colocados em pontos estratégicos do corpo humano.

No corpo humano, a célula em repouso, polarizada, é rica em potássio. O meio externo a esta célula é rico em sódio. Devido à presença de uma membrana semipermeável, ocorre uma diferença de concentração iônica, o que favorece a geração de um potencial. Desta maneira, a célula em repouso polarizada é mais negativa em relação ao meio externo que é mais positivo em relação à célula.

Quando a célula é ativada ocorre a despolarização celular onde o interior da célula passa a ficar mais positivo em relação ao meio externo. Após a repolarização, a célula volta às suas condições normais iniciais.

No coração existe um sistema de condução especializado, responsável pelo início e propagação do processo de ativação. O processo de ativação inicia no nodo sinoatrial, uma estrutura muscular especializada junto com a musculatura atrial próximo à junção superior à veia cava e ao átrio direito. Responsável por guiar o ritmo para qualquer estrutura do coração, o nodo sino atrial é o marca passo. Após a ativação do nodo sino atrial, o processo se propaga através de ambos os átrios. Durante o período da ativação atrial, somente o átrio esquerdo é despolarizado. Um resumo da estrutura descrita é apresentado na Figura (2).

O nodo sinusal se encontra na parede posterior do átrio direito. Ele é nutrido pela artéria do nódulo sinusal. É o local que comanda o ritmo cardíaco. A despolarização iniciada no nódulo sinusal se propaga pelo sistema de condução sinoatrial ativando o endocárdio e o epicárdio dos átrios.

Os feixes internodais ligam o nódulo sinusal ao nódulo átrio ventricular. O feixe internodal anterior fornece um ramo que chega até o átrio esquerdo.

O nódulo átrio ventricular recebe fibras do miocárdio atrial e de suas margens anterior e inferior emerge o feixe de His.

No feixe de His se originam o ramo direito e o ramo esquerdo. Estes continuam por uma rede subendocárdica de fibras de Purkinje.

A repolarização atrial não é registrada no eletrocardiograma porque ela ocorre ao mesmo tempo que a despolarização ventricular, que é um processo elétrico mais potente.

A Figura 2 apresenta um exemplo do sistema de condução do coração.

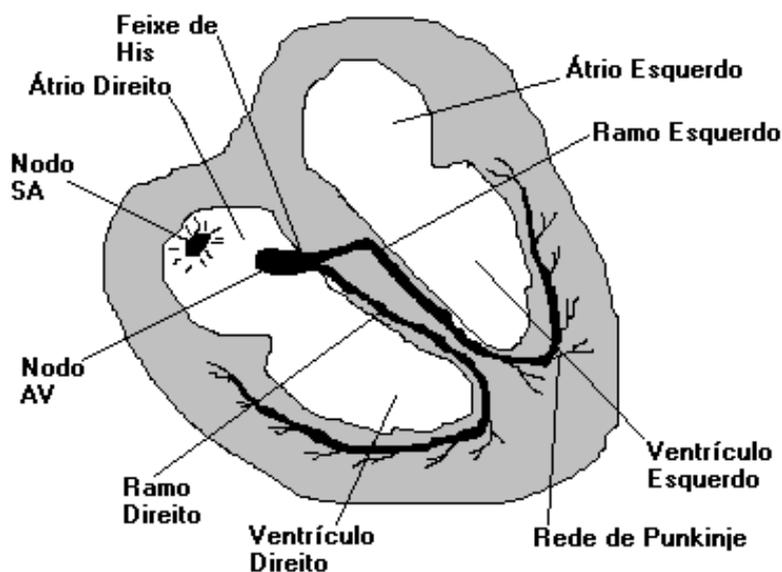


Fig. 2 – Sistema de condução do coração [14].

Devido a estes fenômenos elétricos gerados pelo coração, é possível medir diferenças de potencial na superfície do corpo humano. Dependendo dos locais no corpo humano onde os eletrodos do aparelho de medida são colocados, são caracterizadas as derivações correspondentes de cada sinal.

As derivações mais utilizadas são:

- As derivações bipolares, que são derivações obtidas pela utilização de dois eletrodos posicionados no corpo humano, como na Figura 3.

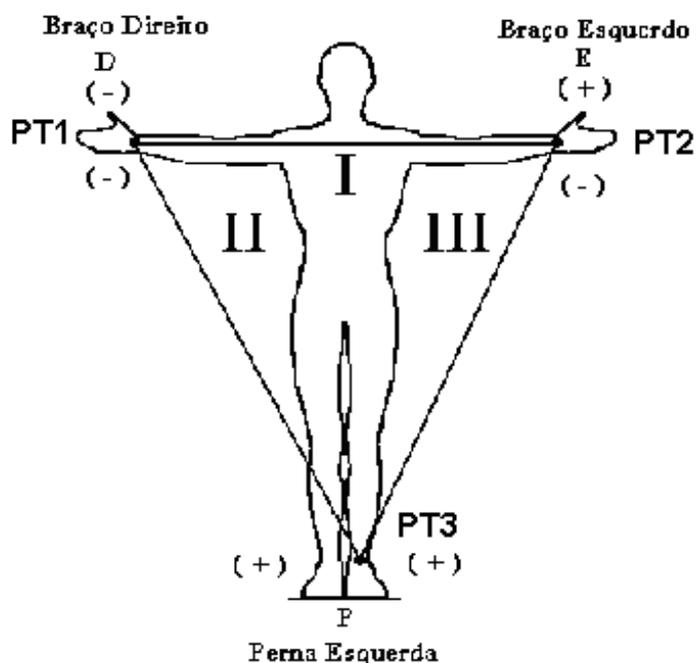


Fig. 3 – Derivações bipolares I, II, III [14].

- Nas derivações unipolares, um eletrodo é colocado em um dos pontos citados na derivação bipolar e o outro eletrodo é conectado em um terminal central, onde se tem o potencial zero para todo o ciclo cardíaco, como mostrado na Figura 4.

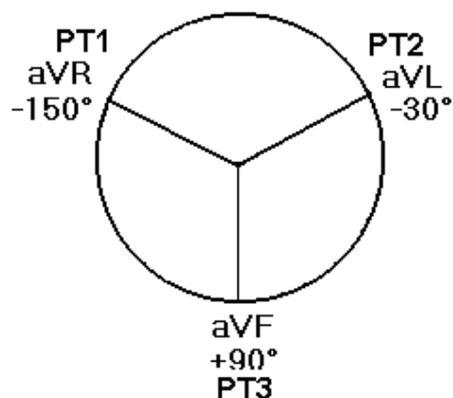


Fig. 4 – Derivações unipolares aVF, aVL e aVR [14].

- As derivações precordiais são obtidas através da análise que utiliza uma visão de um plano chamado de plano horizontal, que seria uma vista de cima do corpo humano. A Figura 5 mostra a posição destas derivações.

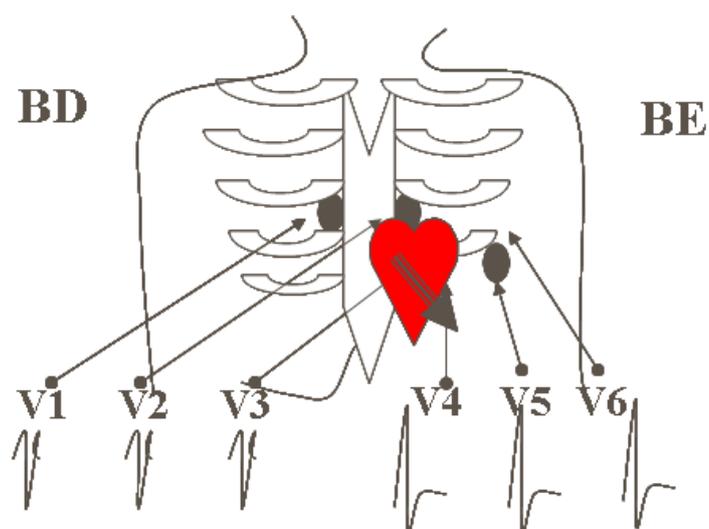


Fig. 5 – Derivações precordiais V1, V2, V3, V4, V5 e V6 [15].

Com estas derivações, é possível se obter sinais que podem indicar alguma anomalia no funcionamento do coração.

Na Figura 6 é apresentado um sinal característico de um eletrocardiograma com suas principais ondas e segmentos em destaque.

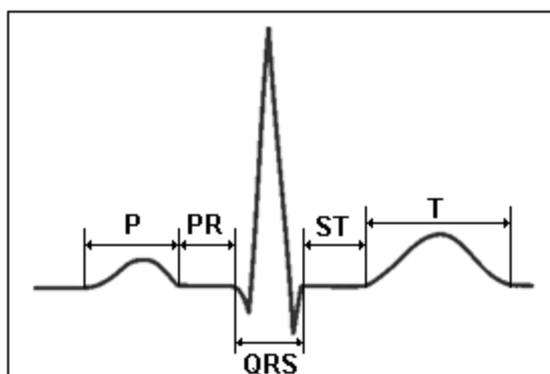


Fig. 6 – Sinal característico de um eletrocardiograma.

Cada segmento em destaque na Figura 6, representa uma etapa do processo de despolarização e repolarização celular.

A onda P representa o início da despolarização no átrio direito e depois no átrio esquerdo. O segmento PR descreve o momento em que o impulso elétrico caminha pelo feixe de His e pelos ramos direito e esquerdo. A despolarização dos ventrículos é representada pelo complexo QRS do gráfico. O segmento ST representa

a fase inicial da repolarização dos ventrículos e a onda T descreve a repolarização final dos ventrículos.

1.5 Organização do Trabalho

No capítulo 1, são descritos os objetivos, a justificativa para a escolha do tema, a metodologia geral, uma breve abordagem sobre eletrocardiograma e a organização do trabalho.

O capítulo 2 apresenta o sistema de pré-processamento bem como uma breve explanação sobre o filtro utilizado neste sistema e o processo de eliminação do nível DC.

O capítulo 3 aborda os conceitos sobre funções de pertinência e conceitos que envolvem o processo de agrupamento nebuloso e mostra alguns exemplos e aplicações, utilizando este processo.

No capítulo 4 será apresentado o conceito sobre correlação e exemplos sobre sua utilização.

O capítulo 5 mostrará os testes realizados, os resultados obtidos e comparações com outras técnicas utilizadas em outros trabalhos.

As conclusões e as propostas de trabalhos futuros encontram-se dispostas no capítulo 6.

2 FUNDAMENTOS TEÓRICOS

2.1 Considerações Iniciais

Conforme apresentado no Capítulo 1, o objetivo deste trabalho é demonstrar e aplicar uma adaptação da ferramenta de processamentos de sinais, o agrupamento nebuloso e a correlação para obter o diagnóstico dos pacientes. Porém, para se testar a eficácia do sistema, foi necessária a utilização de sinais de eletrocardiogramas reais. Devido à presença de ruídos, antes da análise do eletrocardiograma, foi utilizado um filtro para eliminar interferências de frequências mais altas e foi feita a eliminação do nível DC presente neste sinal. Para isto foi necessário criar um sistema de pré-processamento.

2.2 Sistema de pré-processamento

Junto com os sinais de eletrocardiograma, existem ruídos que são gerados pelos próprios eletrodos, utilizados para captar os sinais de eletrocardiograma, ou sinais de outros equipamentos. Devido à presença destes ruídos, antes do processamento destes sinais, foi necessário utilizar um sistema de pré-processamento para eliminar o ruído de frequências mais altas do que a frequência de um eletrocardiograma e que são comuns nestes sinais..

O sistema de pré-processamento tem a função de preparar o sinal para que ele possa ser processado sem a interferência de sinais indesejados.

A Figura 7 mostra o sistema de pré-processamento utilizado no sistema proposto.



Fig. 7 – Sistema de Pré-processamento.

De acordo com a Figura 7, o primeiro bloco do sistema de pré-processamento representa a entrada do sistema. De acordo com o banco de dados utilizado para os testes com os sinais reais de eletrocardiogramas, estes já foram fornecidos amostrados, ou seja, para este sistema o sinal de eletrocardiograma utilizado já estava amostrado com tempo de amostragem de 0,003s.

O segundo bloco representa a utilização de um filtro passa baixa, para a eliminação de ruídos de frequências mais altas. Neste projeto, após alguns testes, foi utilizado um filtro Butterworth, que será detalhado adiante.

O terceiro bloco representa a eliminação de nível DC presente nos sinais de eletrocardiograma. De acordo com [16], foi aplicada uma rotina de programação que, através do cálculo da média de um ciclo do sinal de eletrocardiograma, elimina o nível DC.

2.3 Filtro

O filtro tem a finalidade de eliminar sinais de frequências indesejadas. Existem quatro tipos de filtros: passa alta, passa baixa, elimina faixa e passa faixa.

No sistema proposto, verificou-se a necessidade da utilização de um filtro passa baixa para eliminar os ruídos que possuem frequência mais alta do que a frequência do eletrocardiograma. Estes ruídos presentes no eletrocardiograma estavam causando erros no sistema devido a alterações nas características do sinal em análise.

Utilizando a ferramenta MatLab[®] e realizando alguns ajustes verificou-se que, para esta aplicação, o filtro Butterworth apresenta resultados satisfatórios e por isto foi o escolhido. Sabe-se que este filtro tem como principal característica uma resposta em frequência sem ondulações em sua banda passante e uma resposta nula fora da sua faixa de passagem. Outra característica deste tipo de filtro é que alterando sua ordem, somente a inclinação da atenuação é alterada [17]. A magnitude da função de ordem N com uma banda passante com frequência de corte W_p é dada por:

$$|T(j\omega)| = \frac{1}{\sqrt{1 + e^2 \left(\frac{\omega}{\omega_p}\right)^{2N}}} \quad (2.1)$$

Onde,

ω é a frequência do sinal que está passando pelo filtro;

ω_p é a frequência de corte do filtro;

N é a ordem do filtro;

$T(j\omega)$ é a magnitude da função de transferência do filtro.

Nota-se que para este filtro a máxima variação da banda passante ocorre na frequência de corte, ou seja, quando $\omega = \omega_p$ [17].

A Figura 8 mostra um exemplo do gráfico da função de transferência (magnitude) do filtro Butterworth.

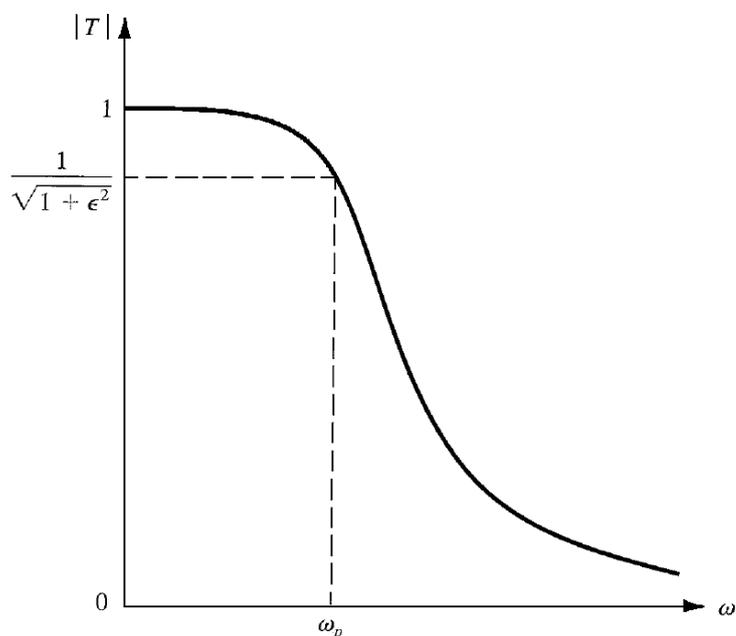


Fig. 8 – Função de transferência de um filtro *Butterworth* [17].

A Figura 9 apresenta várias funções de transferência do filtro *Butterworth* e as variações destas funções, de acordo com a variação da ordem (N) do filtro.

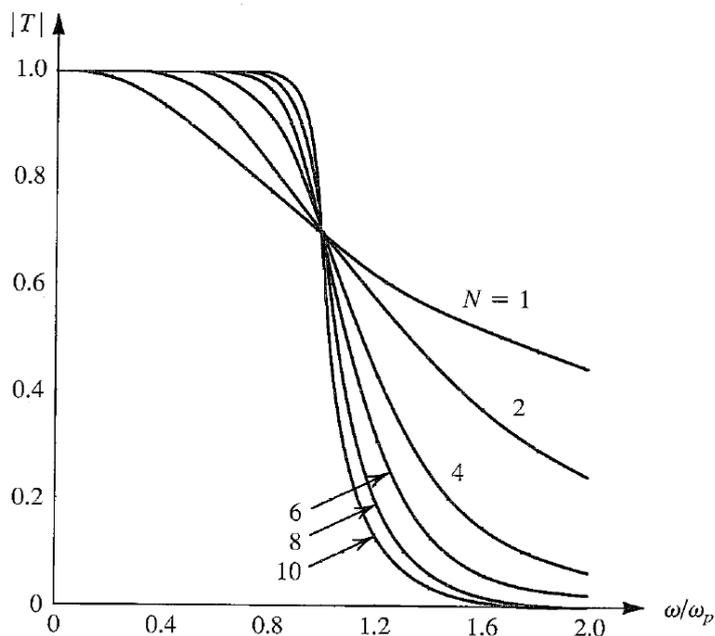


Fig. 9 – Resposta em frequência (magnitude) do filtro *Butterworth* em função de sua ordem [17].

De acordo com a teoria apresentada do filtro *Butterworth*, foi desenvolvido em MatLab[®] o filtro, utilizando algumas funções prontas do software. A Figura 10 mostra a função utilizada.

```

File Edit View Text Debug Breakpoints Web Window Help
[Icons] Stack: Base
118 %*****
119 %*****
120 %FILTRA FREQUENCIAS ALTAS
121 [B,A]=butter(3,1/(fs/24));
122 B % Mostrar coeficientes B
123 A % Mostrar coeficientes A
124 % Plotagem da resposta em frequência
125 hl=freqz(B,A,100);
126 figure(2)
127 plot(abs(hl))
128 grid
129 title('Resposta em frequência')
130 xlabel('frequência (Hz)')
131 ylabel('amplitude')
132 % Filtragem
133 figure(3)
134 y2=filter(B,A,x2);
135 y1 = y2;
136 plot(t,y1,'k-')
137 %*****

```

Fig. 10 – Linha de comando para a utilização do filtro passa baixa.

Na Figura 10 é possível verificar que na linha 121 são criados os coeficientes (A e B) do filtro. Os dados de entrada para este cálculo são a ordem do filtro (3) e a frequência de corte do filtro. De acordo com o comando Butter do MatLab®, a frequência de corte deve ser normalizada entre 0.0 e 1.0, com 1.0 correspondendo à metade da taxa de amostragem.

Após criar os coeficientes do filtro, na linha 134 é utilizado o comando para aplicar o filtro em um sinal x_2 , que contém as amostras de um sinal de eletrocardiograma.

Na Figura 11 é apresentado o gráfico de resposta em frequência do filtro Butterworth utilizado neste sistema. O gráfico foi gerado na linha de comando 127, da Figura 10. Usou-se um filtro de terceira ordem e com uma frequência de corte de aproximadamente 9 Hz.

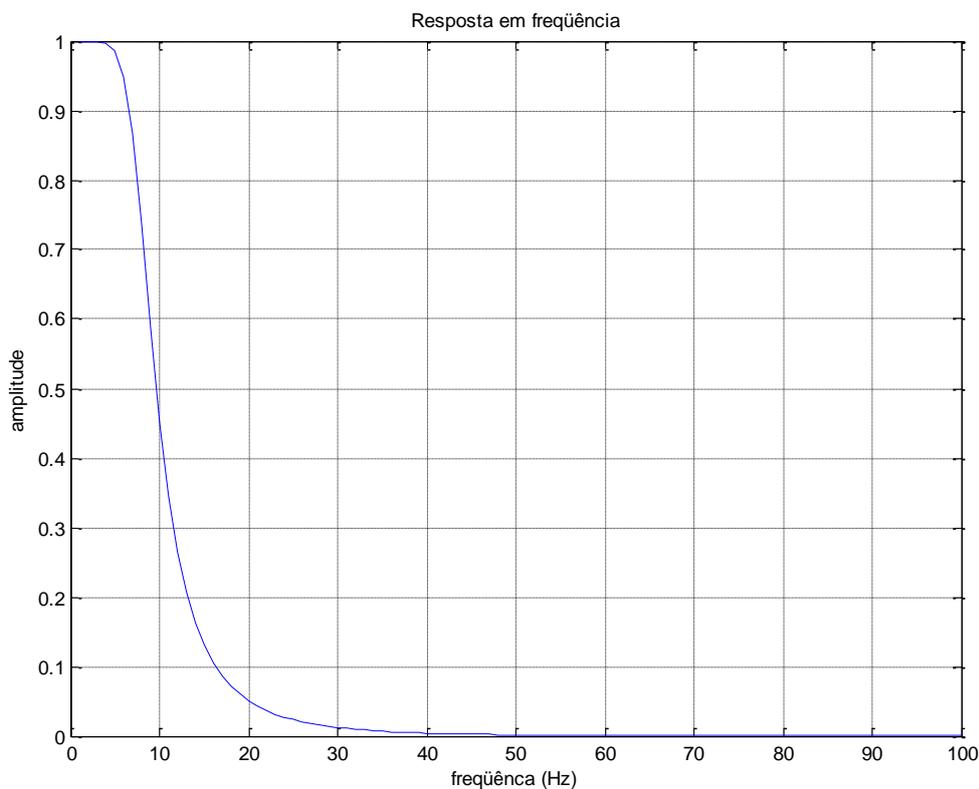
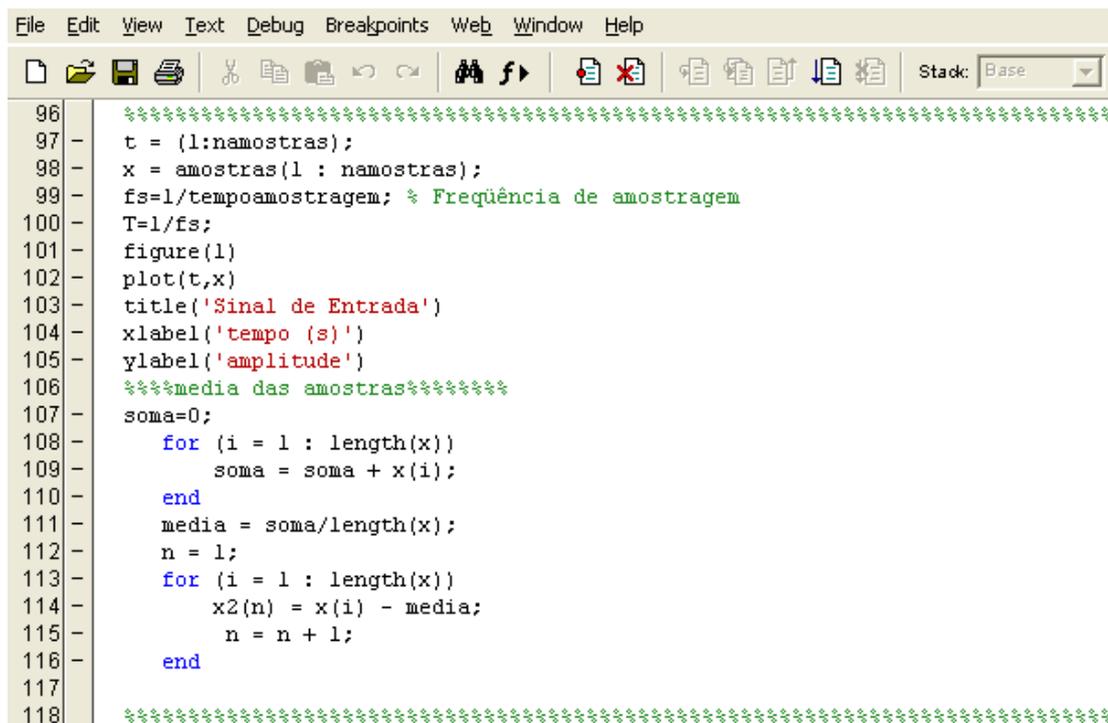


Fig. 11 – Gráfico da resposta em frequência do filtro utilizado.

Será apresentado um exemplo de aplicação do filtro proposto em um sinal de eletrocardiograma. Neste exemplo também foi aplicada uma rotina de processamento para eliminar o nível DC presente no sinal. Na Figura 12 são apresentadas as linhas de comando utilizadas para criar a rotina para a eliminação do nível DC do sinal de eletrocardiograma.



```

File Edit View Text Debug Breakpoints Web Window Help
[Icons] Stack: Base
96 ~ ~~~~~
97 - t = (1:namostras);
98 - x = amostras(1 : namostras);
99 - fs=1/tempoamostragem; % Freqüência de amostragem
100 - T=1/fs;
101 - figure(1)
102 - plot(t,x)
103 - title('Sinal de Entrada')
104 - xlabel('tempo (s)')
105 - ylabel('amplitude')
106 - ~~~~media das amostras~~~~
107 - soma=0;
108 -     for (i = 1 : length(x))
109 -         soma = soma + x(i);
110 -     end
111 -     media = soma/length(x);
112 -     n = 1;
113 -     for (i = 1 : length(x))
114 -         x2(n) = x(i) - media;
115 -         n = n + 1;
116 -     end
117 -
118 - ~~~~~

```

Fig. 12 – Linhas de comando utilizadas para eliminar o nível DC do sinal.

De acordo com a Figura 12, observa-se que o vetor x contém as amostras do sinal do eletrocardiograma. Na linha 111 é calculada a média do sinal. Entre as linhas 113 a 116 o valor da média é subtraído de cada amostra do sinal.

Na Figura 13 é apresentado um exemplo de um sinal característico de eletrocardiograma que será submetido ao filtro *Butterworth*.

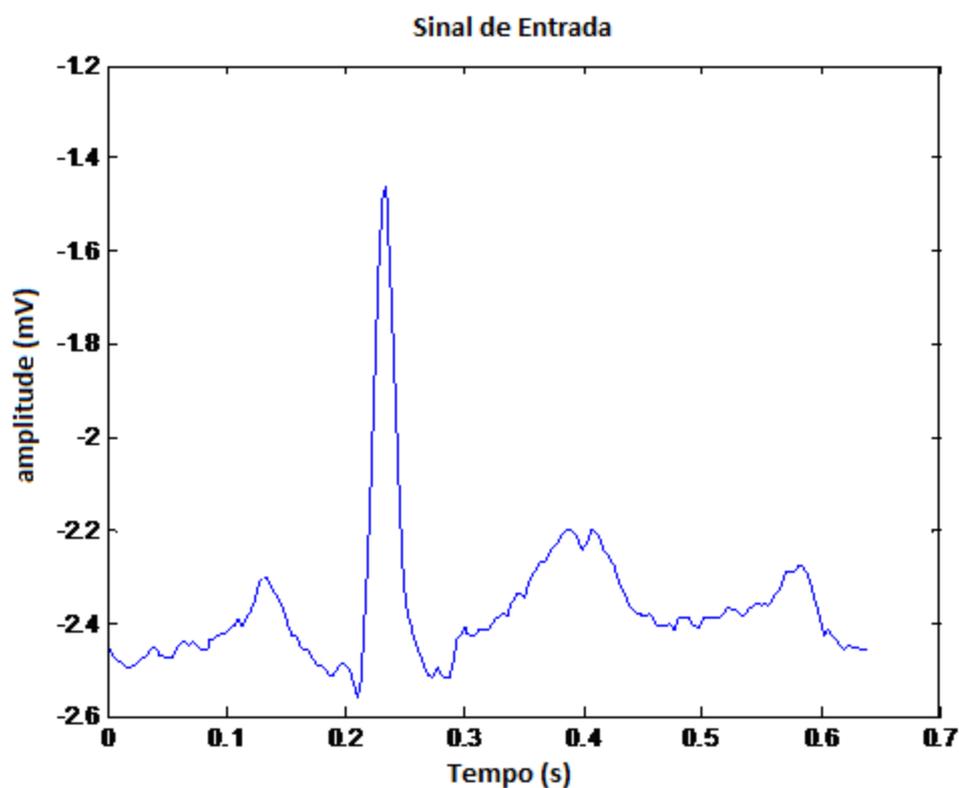


Fig. 13 – Exemplo de um sinal de eletrocardiograma antes de passar pelo bloco de filtragem e eliminação do nível DC.

O sinal do eletrocardiograma, apresentado na Figura 13 é aplicado na entrada de um filtro *Butterworth*. Este filtro elimina ruídos de frequências mais altas de tal forma que em sua saída é obtido um sinal de eletrocardiograma apenas com as características de funcionamento do coração. Através do processamento apresentado na Figura 12, é feita a eliminação de nível DC que estava somado a este sinal. Após este processamento o sinal passa a ter as características mostradas no gráfico da Figura 14 e então o sinal está pronto para ser processado e analisado.

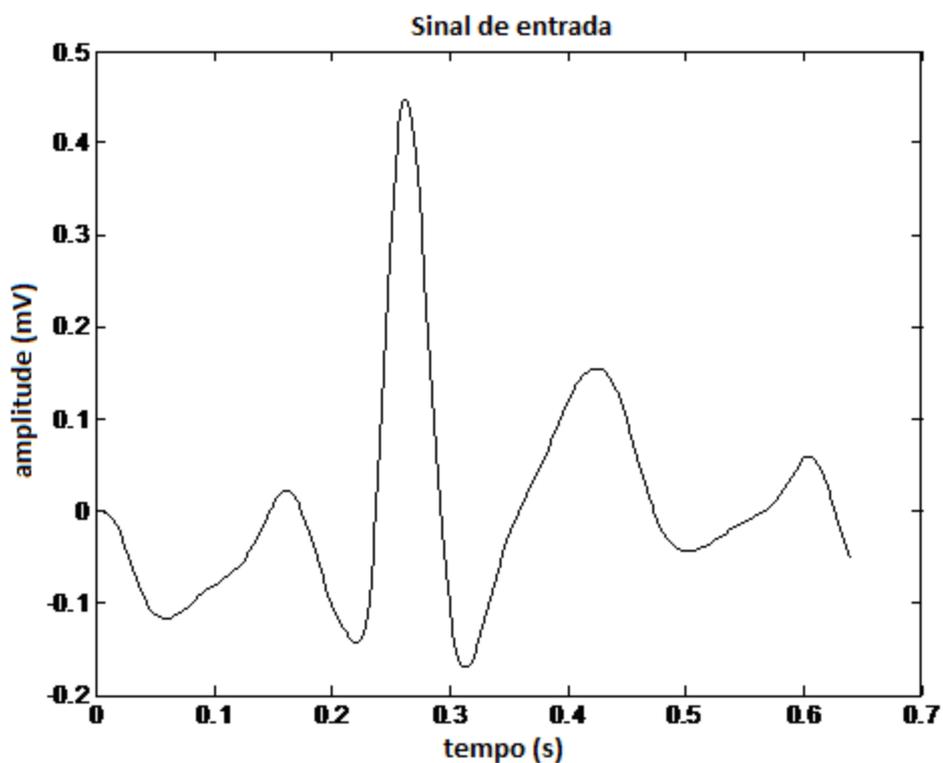


Fig. 14 – Exemplo de um sinal de eletrocardiograma após passar pelo bloco de filtragem e eliminação do nível DC.

Comparando o sinal da Figura 13 com o sinal da Figura 14, verifica-se que as principais características de variação do sinal foram preservadas, após a passagem pelo filtro.

3 PROCESSO DE AGRUPAMENTO PARA EXTRAÇÃO DE REGRAS

Neste capítulo serão apresentados os procedimentos de processamento de sinais realizados, para a execução da técnica de extração de regras. Para a extração das regras será utilizado o método dos mínimos quadrados ortogonais e o agrupamento difuso. Será apresentada a ferramenta na qual se fundamenta a tese proposta. Esta técnica é apresentada por Setnes [5].

De acordo com Setnes [5], será apresentado um sistema para extração de regras, a partir de dados de entrada e saída, por meio de um agrupamento difuso. Cada agrupamento corresponde a uma regra difusa IF-THEN. Também será proposto o uso do método ortogonal dos mínimos quadrados para remover *clusters* redundantes ou menos importantes, permitindo que no processo de agrupamento difuso, sejam geradas as regras mais importantes, ou seja, as regras que representam as principais características do sistema.

Regras difusas baseadas em modelos são utilizadas para modelar sistemas, com entradas e saídas de controle, através de regras IF-THEN.

Muitas vezes as regras difusas podem ser obtidas através de uma pessoa que conhece o funcionamento do sistema a ser modelado, porém, em sistemas mais complexos, ou onde o ser humano não é capaz de determinar estas regras, a utilização de um sistema de extração de regras se torna necessária.

A proposta de Setnes [5] é treinar um sistema para obter as regras de controle. Para o treinamento do sistema são utilizados dados de entrada e as respectivas saídas que devem ser geradas. A partir destas informações são criadas as regras nebulosas ou grupos. Com as regras criadas, cada agrupamento tem sua regra $y_i = ax_i + b$, que de acordo com a entrada x_i irá gerar o valor de y_i . Cada agrupamento irá gerar um valor de y_i , que será multiplicado pelo grau de pertinência correspondente à entrada x_i . O resultado final será a soma dos valores de y_i gerados por cada regra e multiplicados pelos seus respectivos graus de pertinência correspondentes à entrada x_i .

O trabalho proposto utiliza o método de criação de regras, onde cada regra corresponde a uma característica dos pontos que indicam as principais variações de um sinal de eletrocardiograma para isto foi utilizado o sistema proposto por Setnes. O sistema proposto por Setnes cria as regras para sistemas de controle. Para isto são necessárias informações das características da variável de entrada e da saída de controle correspondente para cada entrada. Através de um treinamento, são criadas regras de controle que garantem as características de controle do sistema. Para o sistema proposto, foi feita uma adaptação do sistema de Setnes onde as regras de controle descrevem as principais características de variação dos sinais de eletrocardiograma. Para isto, no treinamento do sistema proposto, têm-se como variáveis de entrada instantes de tempo de cada amostra de um sinal de eletrocardiograma e como saída de controle os valores das respectivas amostras correspondentes a cada instante de tempo. Serão geradas regras y_i para o sinal de eletrocardiograma. Como cada regra corresponde a um agrupamento, o sistema proposto utiliza o ponto onde se localiza o agrupamento gerado. Os agrupamentos se localizam nos locais que descrevem as principais características do sinal do eletrocardiograma, desta forma os grupos criados indicam as variações mais relevantes do sinal do eletrocardiograma.

A adaptação proposta neste trabalho consiste em utilizar a localização dos agrupamentos criados e o valor correspondente de y_i gerado para estes pontos. Os agrupamentos gerados serão os pontos do sinal utilizados no processamento e que geram o provável diagnóstico. Na adaptação da técnica de processamento, os agrupamentos não serão utilizados para controle de sistema. Com os grupos determinados, para gerar o diagnóstico do sinal em análise, não será preciso processar todas as amostras iniciais do sinal, mas sim as amostras correspondentes aos grupos gerados. Desta forma pretende-se diminuir o processamento para a geração do diagnóstico.

No modelo de agrupamento que será visto em 3.2, serão utilizadas funções de pertinência. Para isto foi desenvolvido um estudo das funções de pertinência básicas mais conhecidas e será apresentada a função escolhida para ser utilizada neste projeto.

3.1 Função de pertinência

Uma função de pertinência indica qual o grau de pertinência de um determinado elemento em relação a um conjunto nebuloso. O grau de pertinência pode variar entre $[0,1]$ [18].

Para melhor compreender a definição desta função, imagine a necessidade de diferenciar um carro em alta velocidade e um carro em baixa velocidade. Abaixo têm-se a ilustração de cinco carros com suas respectivas velocidades:

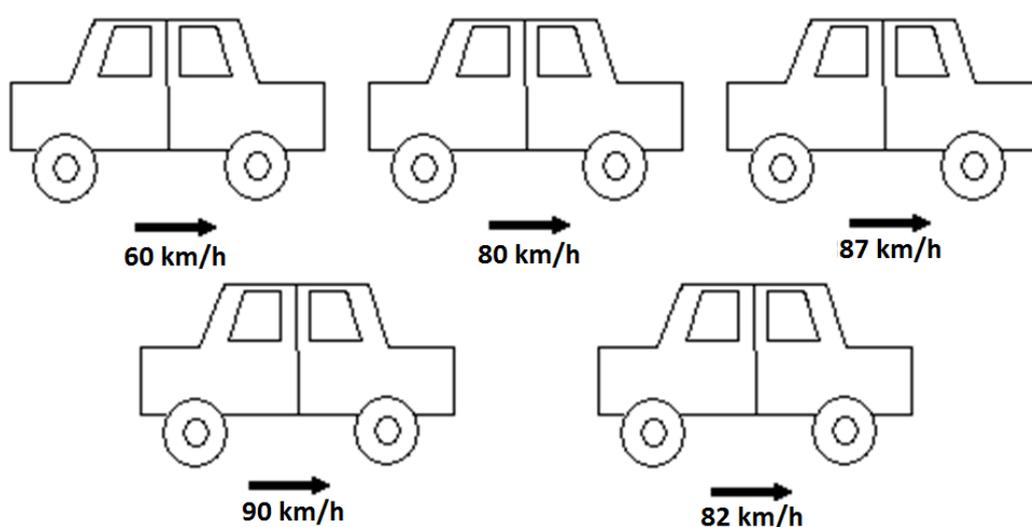


Fig. 15 – Exemplos para a comparação das velocidades.

Na Figura 15 são apresentados cinco carros com velocidades médias diferentes. Considera-se que um carro a uma velocidade acima de 80 km/h está acima da velocidade máxima permitida. Neste exemplo, os carros com a velocidade de 90 km/h, 87 km/h e 82 km/h serão considerados em alta velocidade, pois estão acima da velocidade máxima permitida. Mas, será correto afirmar que o motorista do carro a 82 km/h esteja em alta velocidade?

Para uma melhor classificação em situações como esta é que são utilizadas as funções de pertinência. Estas funções indicam o grau de pertinência de um elemento em relação a um determinado conjunto ou evento. No exemplo acima, o carro com 87 km/h com certeza possui um grau de pertinência bem maior, em relação ao

conjunto de carros acima da velocidade máxima permitida. Já o carro com velocidade de 82 km/h, terá um grau de pertinência menor, em relação ao carro com velocidade de 90 km/h.

Na primeira situação poderia ser utilizada a seguinte função de pertinência:

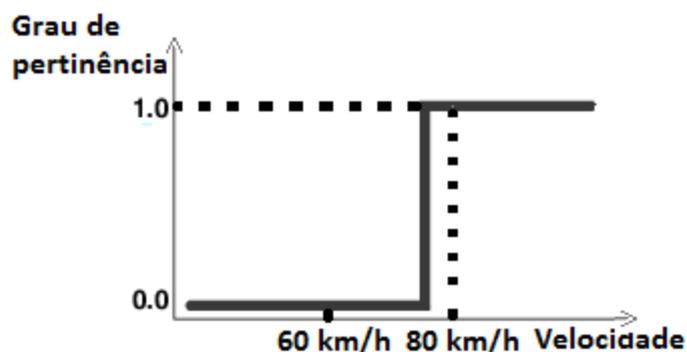


Fig. 16 – Exemplo de função de pertinência brusca.

A Figura 16 mostra uma função de pertinência de variação brusca. Esta função, de acordo com a variação de velocidade (eixo horizontal), varia o grau de pertinência (eixo vertical). Este valor pode variar entre $[0,1]$. Neste exemplo, como ocorre uma variação instantânea na velocidade de 80 km/h, de 0 para 1, qualquer carro que tiver uma velocidade um pouco maior que este valor será considerado em alta velocidade.

Na segunda situação, onde têm-se uma mudança no valor de *membership* mais suave, é apresentada a função da Figura 17.

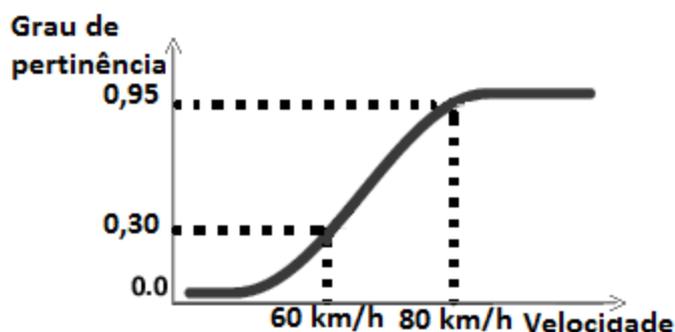


Fig. 17 – Função de pertinência suave.

A Figura 17 mostra uma função de pertinência suave, onde de acordo com a variação de velocidade (eixo horizontal), o valor do grau de pertinência (eixo vertical) varia de forma suave entre $[0,1]$.

Note que na primeira classificação (com variação brusca do grau de pertinência) um carro tem a velocidade considerada alta e o outro, baixa. Já na segunda classificação (com variação suave do grau de pertinência), um carro é considerado com velocidade baixa e o outro, com velocidade não muito alta, ou seja, o segundo carro não é considerado com velocidade alta, mas sim um grau entre velocidades consideradas altas e baixas.

De acordo com a aplicação, o formato destas funções de pertinência pode variar. Em um sistema real, a função de pertinência pode ser baseada em informações fornecidas por um operador do sistema que conhece a faixa de valores de variação de um determinado evento e a ação a ser tomada para cada situação. Através destas informações pode ser construída uma função de pertinência que mais se aproxime dos valores fornecidos pelo operador do sistema [18].

A Figura 18 mostra um exemplo de funções de pertinência com formato de Gauss. Note que as funções ficam espalhadas por toda a faixa de valores possíveis de entrada. Desta forma, de acordo com o valor da entrada do sistema, esta entrada terá um valor de pertinência em relação a cada conjunto nebuloso.

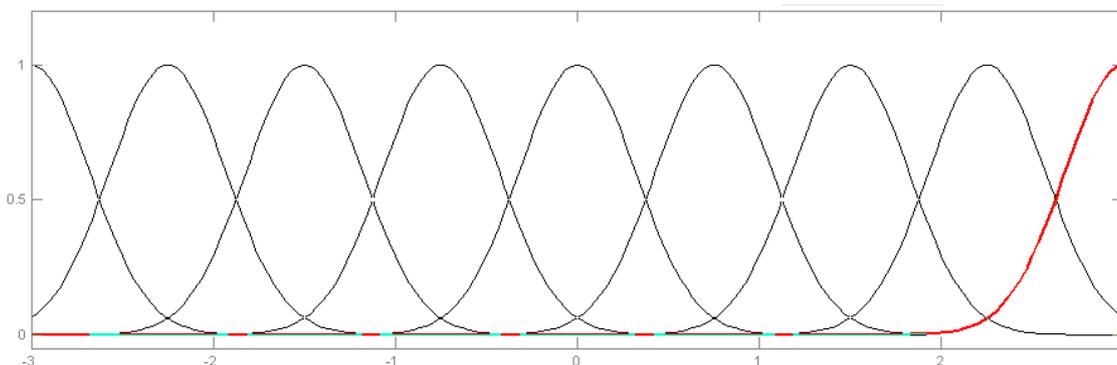


Fig. 18 – Funções de pertinência.

No exemplo da Figura 18, as entradas do sistema podem variar entre -3 até 3, logo para qualquer valor de entrada têm-se um grau de pertinência entre 0 e 1 para

cada conjunto nebuloso. Na Figura 18 é destacada uma função de pertinência, onde para entradas entre 2 e 3 têm-se valores de graus de pertinência maiores do que zero e para entradas menores do que 2, esta função tem um grau de pertinência igual a zero.

As Figuras 19 - 23 apresentam as funções de pertinência mais simples. É possível notar que cada função tem uma inclinação diferente, o que as torna mais adequadas em determinadas aplicações específicas. As funções foram geradas no software MatLab®.

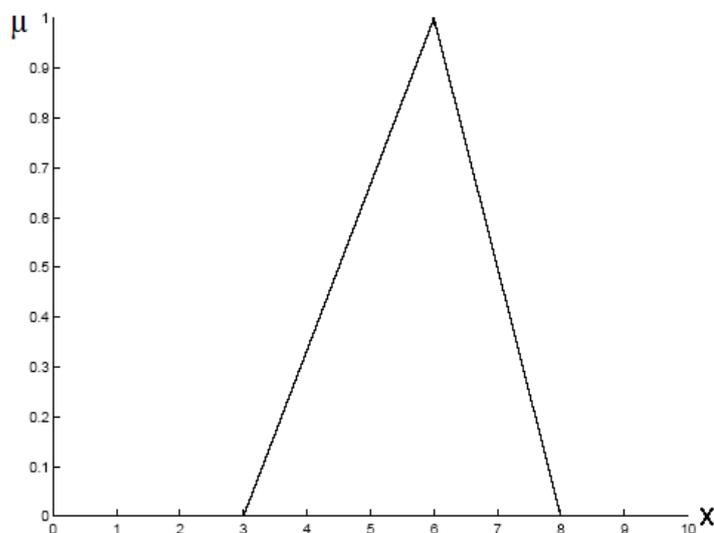


Fig. 19 – Função de pertinência triangular.

A função mostrada na Figura 19 é um exemplo de uma função de pertinência de formato triangular que possui variações entre o valor máximo 1 e o valor mínimo 0. Para se obter esta função têm-se:

$$\text{Para } x = [0,3] \rightarrow \mu = 0;$$

$$\text{Para } x =]3,6[\rightarrow \mu = \frac{x-3}{3};$$

$$\text{Para } x = 6 \rightarrow \mu = 1;$$

$$\text{Para } x =]6,8[\rightarrow \mu = \frac{8-x}{2};$$

$$\text{Para } x \geq 8 \rightarrow \mu = 0.$$

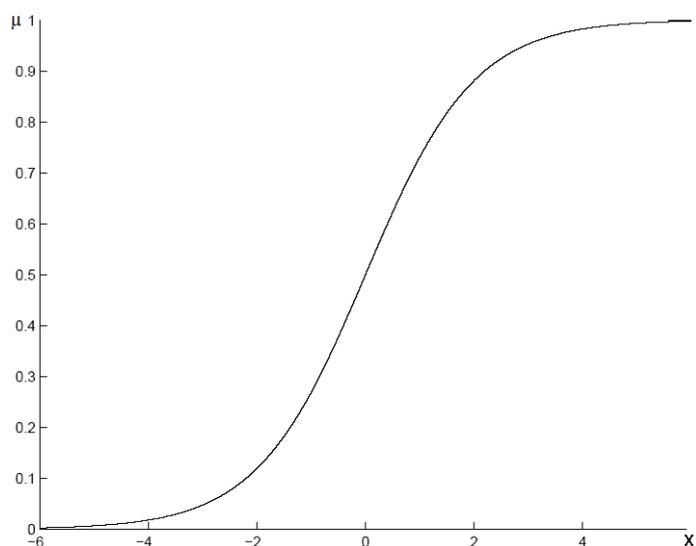


Fig. 20 – Função de pertinência sigma.

A Figura 20 mostra uma função de pertinência sigma, que possui uma variação mais suave, se comparada com as funções de pertinência analisadas anteriormente. Esta função, em um caso especial, pode ser calculada da seguinte maneira:

$$\mu = \frac{1}{1 - e^{-x}} \quad (3.1)$$

Existem também as funções de pertinência descritas por funções de distribuição Gaussiana normalizadas, como a apresentada na Figura 21.

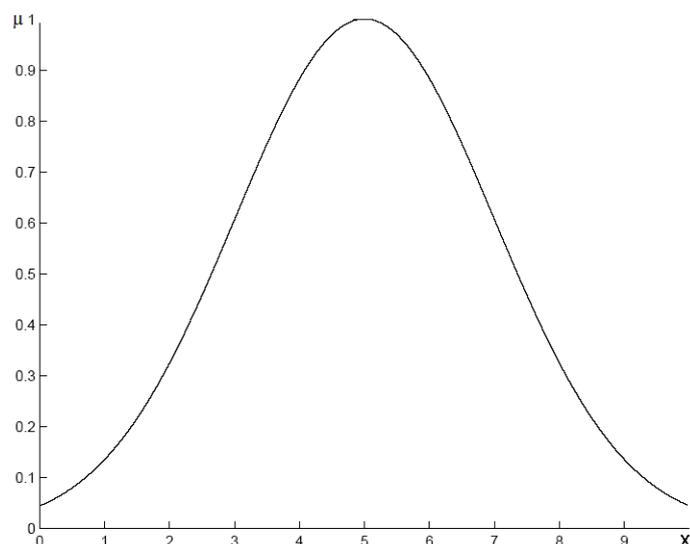


Fig. 21 – Função de pertinência Gaussiana.

A Figura 21 apresenta a função de pertinência Gaussiana. Se comparada com as outras funções anteriores, é de variação mais suave e terá um melhor resultado em sistemas que exigem em sua saída funções de variações suaves. Esta função, de acordo com a variação dos valores de x , no eixo horizontal, apresenta em sua saída, no eixo vertical, a função:

$$\mu(x, \sigma, \zeta) = e^{-\frac{(x-\zeta)^2}{2\sigma^2}} \quad (3.2)$$

Onde, σ é o desvio padrão e ζ é a média.

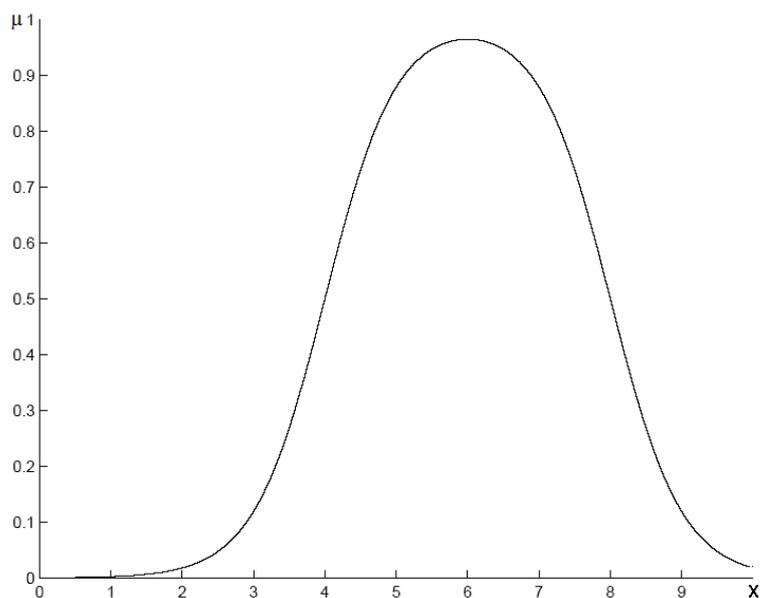


Fig. 22 – Função de pertinência formada pela diferença de duas funções sigma.

A Figura 22 mostra um exemplo de uma função que é formada pela diferença de duas funções sigmoideais. Esta função também possui uma variação mais suave e de acordo com a variação de x , no eixo horizontal, apresenta o valor de resposta, no eixo vertical definida pela função:

$$\mu(x, \alpha_1, \zeta_1, \alpha_2, \zeta_2) = [1 + e^{-\alpha_1(x-\zeta_1)}]^{-1} - [1 + e^{-\alpha_2(x-\zeta_2)}]^{-1} \quad (3.3)$$

Onde α_1 e α_2 determinam os valores de $f(x)$ para os quais a pertinência é 0,5 e os valores de ζ_1 e ζ_2 determinam com que velocidade a curva tende para zero.

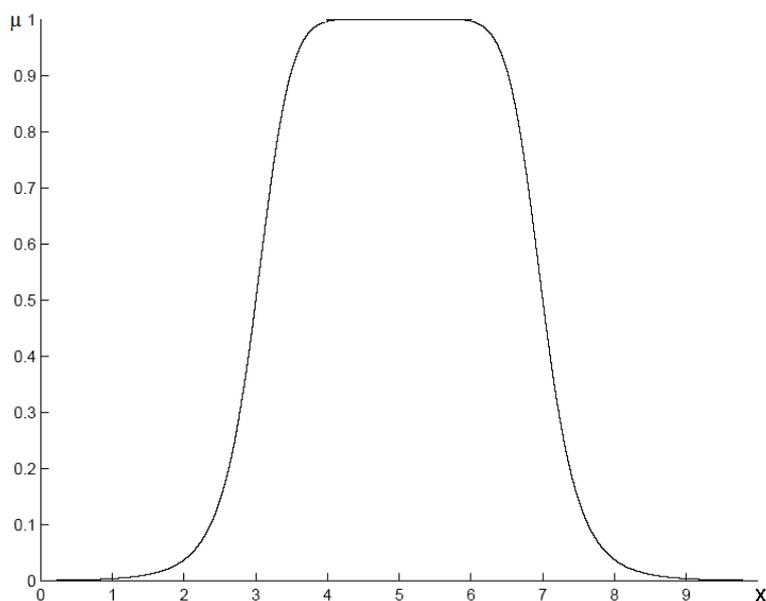


Fig. 23 – Função de pertinência sino generalizada.

A função da Figura 23 é conhecida pelo seu formato como função sino. Nota-se uma variação mais brusca entre seu valor máximo e mínimo. Esta função pode ser definida pela equação:

$$\mu(x, \alpha, \beta, \zeta) = \left[1 + \left| \frac{x - \zeta}{\alpha} \right|^{2\beta} \right]^{-1} \quad (3.4)$$

Onde α indica os pontos onde a pertinência é 0,5, β é um parâmetro que é determinado em função dos valores de x onde a função de pertinência é 0,9 e ζ indica o centro da curva.

De acordo com [18] os formatos das funções de pertinência mais utilizados são o triangular e o trapezoidal, devido à facilidade para gerar estas funções. Porém, em situações onde desempenho suave é considerado de grande importância, as funções de pertinência podem ter outros formatos como gaussiana, sigmóide, sino.

Para verificar e mostrar a influência do formato das funções de pertinência no funcionamento de um sistema de agrupamento nebuloso, serão analisadas três funções de pertinência de formatos diferentes atuando em uma mesma aplicação.

Nesta análise todas as funções de pertinência e todo o funcionamento do sistema foram desenvolvidos em MatLab[®].

O sistema utilizado para teste utiliza as funções de pertinência para criar regras de controle, que serão abordados no item 3.2. Neste exemplo, a função de controle deverá, de acordo com a entrada dos valores de x_1 e x_2 , gerar em sua saída o valor de $\text{sen}(x_1 \cdot x_2)$, ou seja, para valores de x_1 e x_2 de entrada, a saída deve gerar o resultado da função de controle.

Inicialmente são fornecidos, para o treinamento do programa, alguns valores de entrada do sistema e os valores de saída que devem ser gerados. Após o treinamento, com os valores de dados fornecidos, o programa gera funções de controle que serão capazes de gerar, na saída do sistema, valores que correspondem à função $\text{sen}(x_1 \cdot x_2)$, de acordo com o treinamento realizado. Esta aplicação utilizará 14 funções de pertinência e como primeiro exemplo, estas funções terão o formato seno e deverão atuar em toda a faixa de variação possível das entradas.

Na Figura 24 é apresentada a função de saída $\text{sen}(x_1 \cdot x_2)$, que o programa deverá gerar, para uma faixa de valores de x_1 e x_2 entre -3 e 3. Todas as funções e processamentos realizados, foram feitos em MatLab[®].

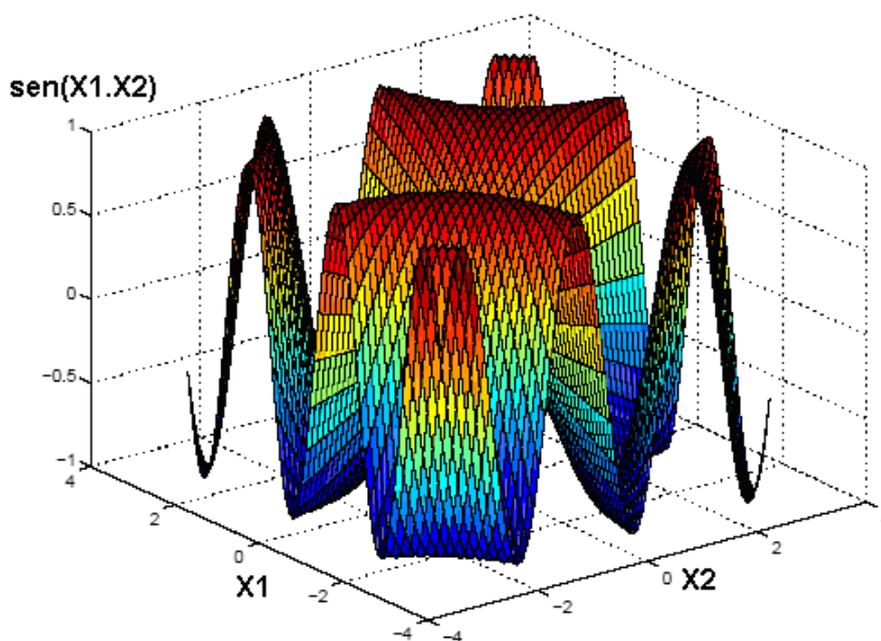


Fig. 24 – Função $\text{sen}(x_1 \cdot x_2)$.

O gráfico da Figura 24 mostra a função correta esperada na saída do programa onde se tem a variação de x_1 e x_2 entre $[-3,3]$ e o resultado de $\sin(x_1 \cdot x_2)$, que varia entre $[-1,1]$.

Na Figura 25 é apresentado o gráfico das funções de pertinência que serão utilizadas neste sistema.

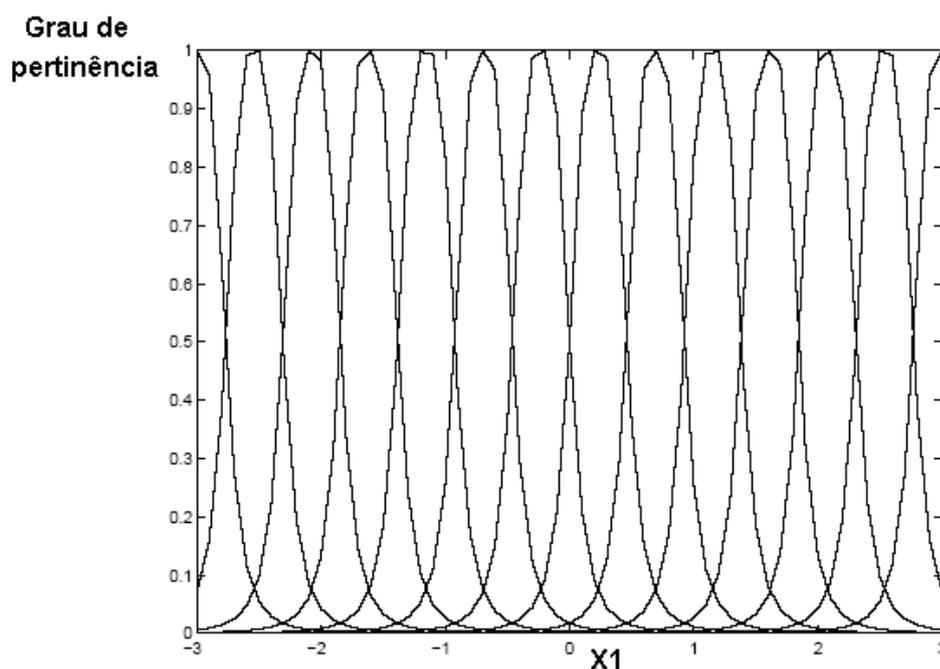


Fig. 25 – Gráfico de funções de pertinência de formato sino.

A Figura 25 apresenta o gráfico dos 14 conjuntos nebulosos utilizados pelas variáveis de entrada (x_1 e x_2). Como o programa está gerando uma função que relaciona x_1 e x_2 , se cada entrada trabalha com 14 conjuntos, o programa irá relacionar os 14 conjuntos de cada entrada, resultando em uma combinação de 196 grupos.

O gráfico da Figura 26 mostra a função gerada pelo programa, utilizando os 14 conjuntos e aplicando a técnica de agrupamento nebuloso, com formato sino, para cada entrada. Este gráfico mostra que o sinal gerado na saída do programa contém alguns erros, que são indicados pelas pequenas ondulações geradas na superfície da figura e que não apareceram no gráfico da função esperada da Figura 24.

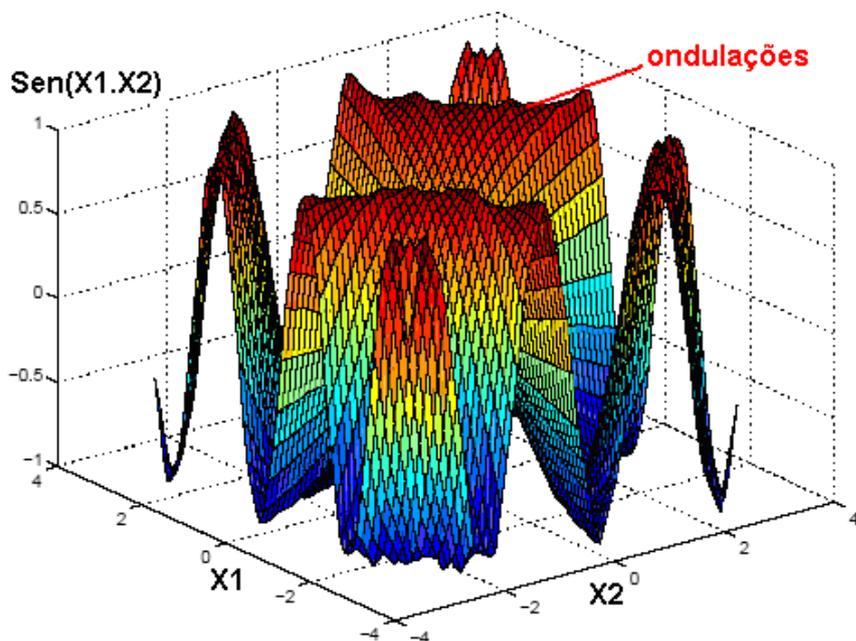


Fig. 26 – Gráfico gerado pelo programa para função de pertinência seno.

Na Figura 27 é apresentado o gráfico que mostra os erros gerados pelo programa. Este gráfico foi obtido subtraindo a função gerada pelo sistema de agrupamento nebuloso pela função de controle a ser gerada.

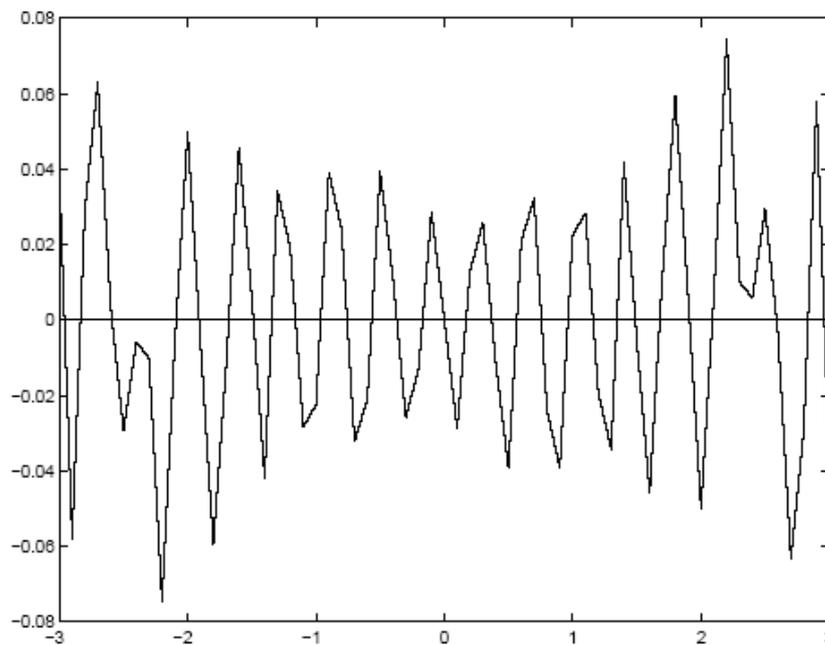


Fig. 27 – Gráfico do erro gerado entre o sinal esperado para o sistema e o sinal gerado pelo sistema.

O gráfico do erro gerado pelo programa foi calculado subtraindo a função gerada pelo sistema apresentada na Figura 26, pela função esperada apresentada na Figura 24. Verifica-se que dentro do intervalo entre $[-3,3]$, o maior erro gerado foi próximo de 0,08.

Para fins de comparação será utilizada a mesma função do exemplo anterior, $\text{sen}(x_1 \cdot x_2)$, mas a função de pertinência terá um outro formato. Neste exemplo tem-se uma função de pertinência de Gauss.

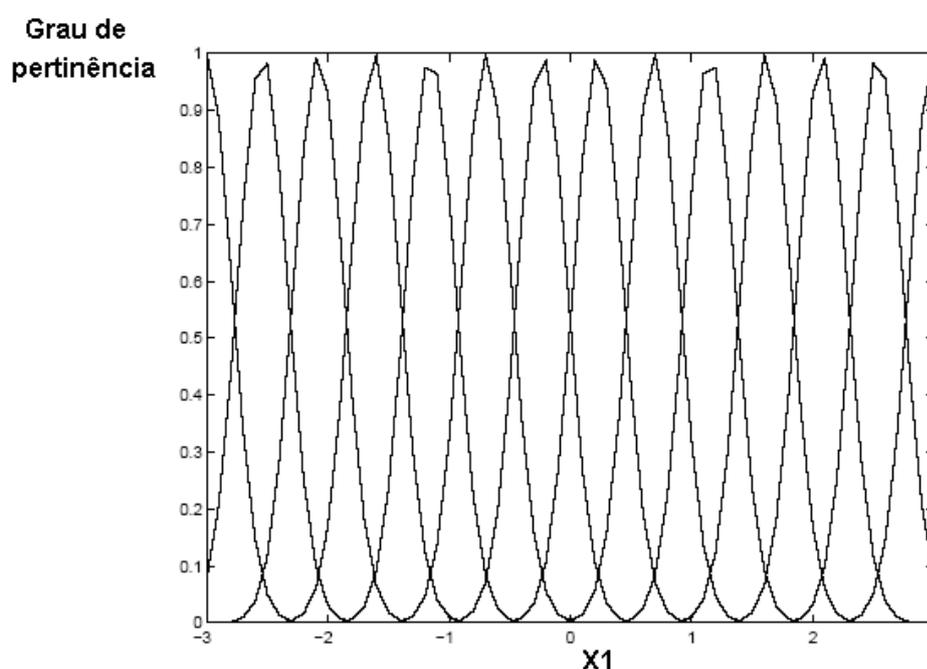


Fig. 28 – Gráfico das funções de pertinência de Gauss.

De acordo com a Figura 28, que apresenta o gráfico da função de pertinência de Gauss. Para gerar uma função seno esta função de pertinência apresenta um melhor resultado, ou seja, um erro menor.

A Figura 29 mostra a função de resposta gerada pelo sistema que recebeu em sua entrada x_1 e x_2 , variando entre $[-3,3]$ e gerou em sua saída uma função que deveria se aproximar da função $\text{sen}(x_1 \cdot x_2)$, utilizando a função de pertinência de Gauss. Para gerar a função de saída foi aplicada a técnica de agrupamento nebuloso, que de acordo com os dados de entrada gera em sua saída a função de controle do sistema. Neste caso a função de controle a ser gerada é a função $\text{sen}(x_1 \cdot x_2)$.

Comparando o gráfico de saída para esta função de pertinência, nota-se que praticamente não ocorreram ondulações na superfície da figura gerada.

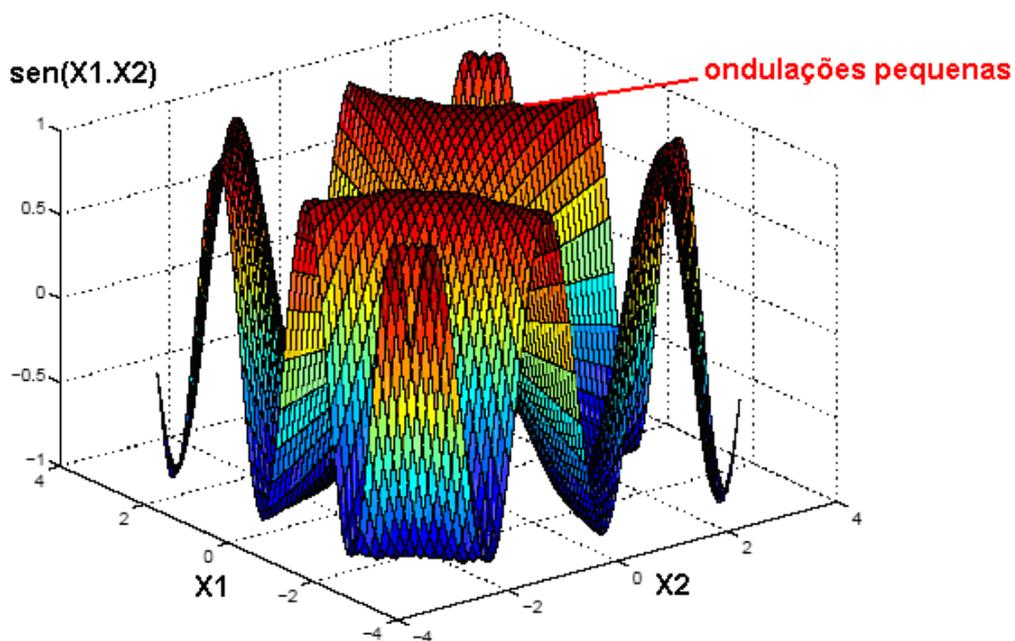


Fig. 29 – Gráfico de saída do programa para função de pertinência de Gauss.

De acordo com a Figura 30, o maior erro gerado entre a função esperada, dentro do intervalo entre $[-3,3]$, e a função gerada foi próximo de 0,03. Comparando com o erro gerado pela função que utilizou a função de pertinência seno o erro foi menor.

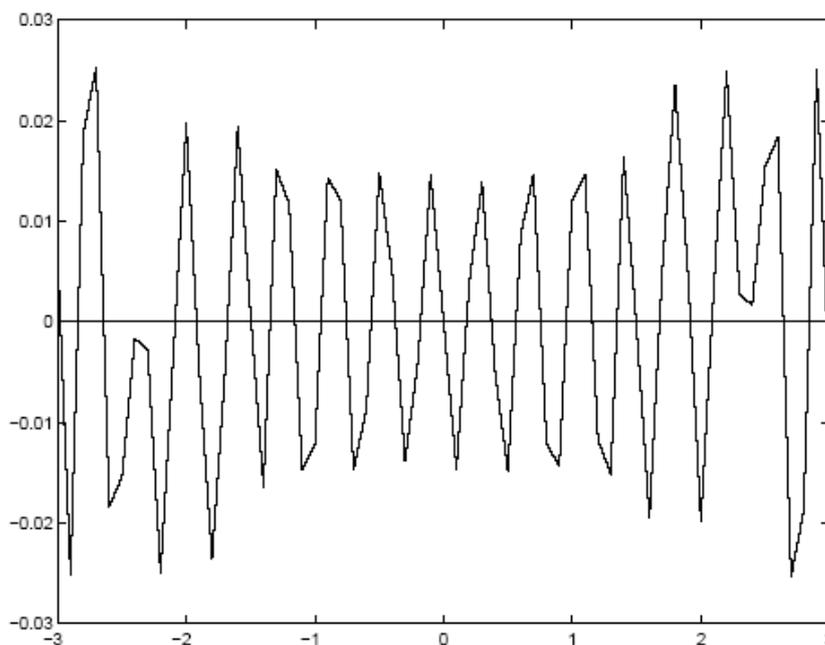


Fig. 30 – Gráfico do erro gerado entre a função $\sin(x_1 \cdot x_2)$ e a função gerada pelo programa, utilizando a função de pertinência de Gauss.

Na sequência das comparações, será utilizado o mesmo sistema apresentado anteriormente, mas agora utilizando funções de pertinência de formato triangular e trapezoidal. Com a variação das entradas x_1 e x_2 entre $[-3,3]$, deve gerar em sua saída a $\sin(x_1 \cdot x_2)$, mostrada abaixo. Neste caso serão utilizadas 14 funções de pertinência onde, destas funções, 10 tem o formato triangular e 2 tem formato trapezoidal.

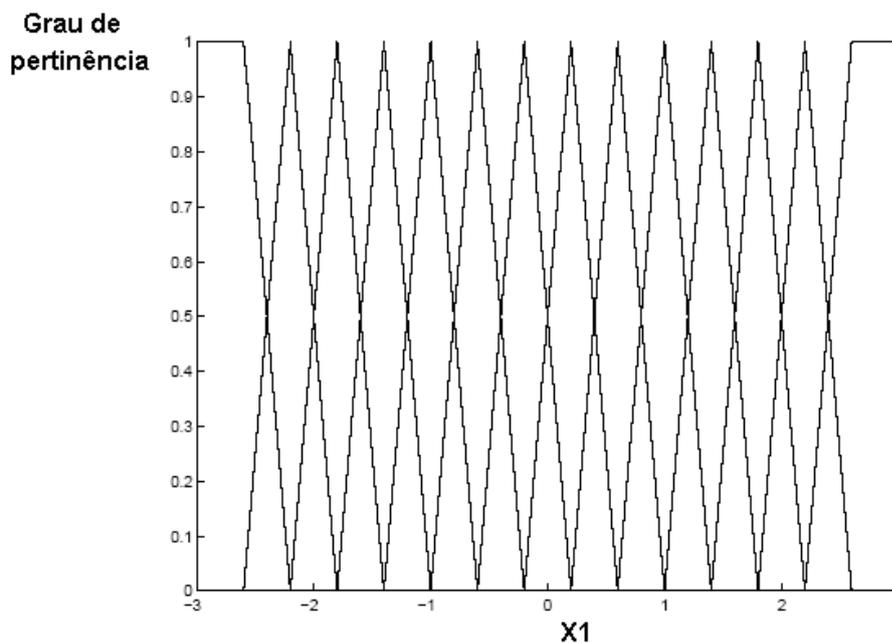


Fig. 31 – Gráfico com funções de pertinência com formato triangular.

A Figura 31 mostra as 14 funções de pertinência utilizadas para cada entrada (x_1 e x_2). Como estas duas entradas serão associadas para gerar a função de saída $\text{sen}(x_1 \cdot x_2)$, este programa terá um total de 196 regras.

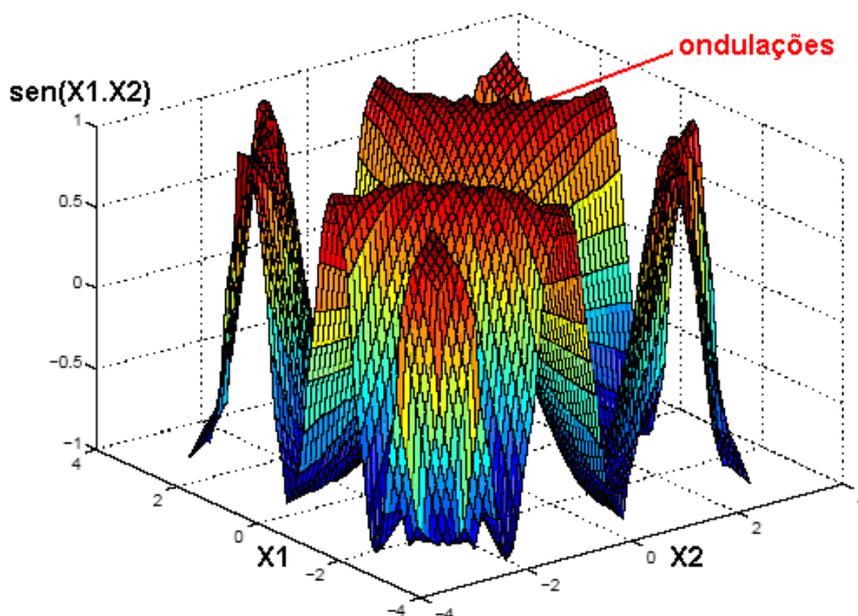


Fig. 32 – Gráfico de saída para função de pertinência triangular.

A Figura 32 apresenta o gráfico gerado pelo sistema que utiliza a técnica de agrupamento nebuloso e com funções de pertinência de formato triangular, onde para x_1 e x_2 variando entre $[-3,3]$ o sistema gerou uma função em sua saída que se aproxima da função esperada. Observa-se que o gráfico gerado pelo sistema está bastante deformado em relação aos gráficos gerados pelas outras funções de pertinência. Esta deformação é percebida pelas ondulações na superfície da figura indicada. Isto ocorre porque a função a ser gerada pelo programa é uma função de variação suave enquanto a função de pertinência de formato triangular possui uma variação mais brusca. Se comparada com as outras duas funções, a função triangular foi a que apresentou maior deformação na função de saída. A função de Gauss, que é a função de pertinência mais suave, foi a que proporcionou o melhor resultado.

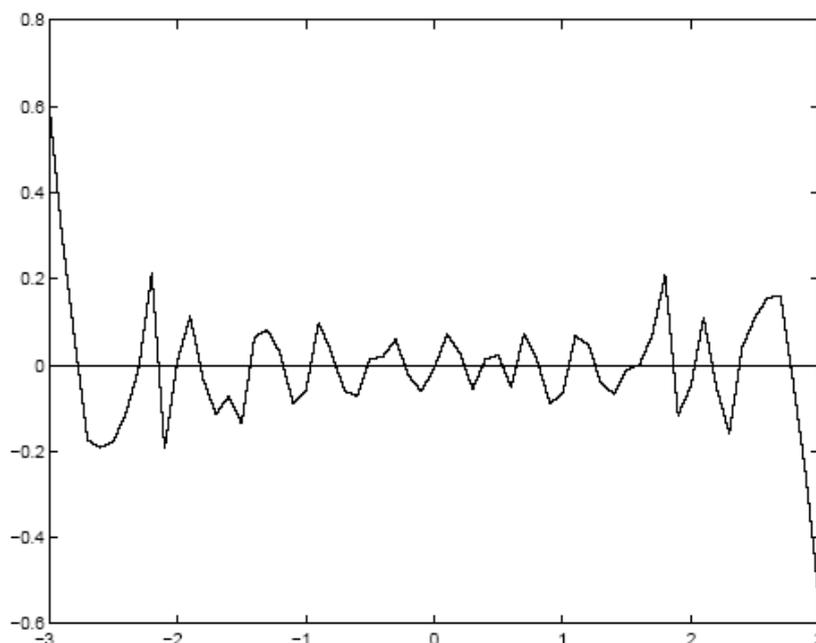


Fig. 33 – Gráfico do erro gerado pelo programa entre a função desejada e a função a ser gerada.

A Figura 33 mostra a função do erro gerado pelo sistema. Este erro foi gerado pela subtração da função gerada pelo sistema da função esperada. Nota-se que o maior erro chegou próximo de 0,6. O erro que utilizou a função de pertinência triangular foi maior, devido ao fato de que esta função possui variações mais bruscas, não apresentando um bom resultado para a função $\text{sen}(x_1 \cdot x_2)$.

De acordo com os resultados obtidos nestes exemplos apresentados, neste trabalho utilizaremos o formato da função de pertinência que proporcionou um melhor resultado, no caso a função de Gauss.

Existe ainda uma característica que também irá influenciar na precisão de resposta do sistema que é a quantidade de conjuntos nebulosos. Quanto maior a quantidade de conjuntos melhor será a resposta do sistema, porém também será maior a demanda computacional necessária para este sistema. Segundo [18] uma quantidade entre 2 a 7 conjuntos é o suficiente pois um aumento de 5 para 7 conjuntos de funções de pertinência triangulares resulta em uma melhora de 15%, de forma que um número maior do que 7 conjuntos não mais resultam em melhoras significativas no sistema.

3.2 Modelo nebuloso Takagi-Sugeno

O modelo nebuloso de Takagi-Sugeno é utilizado para extrair regras de um sistema que, de acordo com os sinais de entrada, devem gerar as saídas desejadas.

No modelo nebuloso de Takagi-Sugeno, as regras utilizadas são de acordo com a entrada ou funções de entrada. Se a entrada x corresponde a um antecedente nebuloso A_i , então a saída será $y_i = a_i x + b_i$, $i = 1, 2, \dots, M$, onde x é uma variável de entrada e y é sua saída conseqüente. O número de regras é denotado por M e A_i é o grupo de antecedentes nebulosos para a i -ésima regra [5].

Com funções de pertinência univariáveis $\mu_{ij}(x_j)$, o antecedente nebuloso do modelo Takagi-Sugeno é determinado por:

$$A_i(x) = \prod_{j=1}^n \mu_{ij}(x_j) \quad (3.6)$$

Onde n é o número de entradas do sistema.

Para uma entrada x_k , a saída total $y(k)$ do modelo é calculada de acordo com a contribuição de cada regra individual, dada pela expressão:

$$y(k) = \sum_{i=1}^M u_{ki} y_i(k) \quad (3.7)$$

u_{ki} é o grau normalizado pela antecedente causa da regra R_i ;

$$u_{ki} = \frac{A_i(x_k)}{\sum_{i=1}^M A_i(x_k)} \quad (3.8)$$

O modelo Takagi-Sugeno é dividido em duas partes:

A primeira é a determinação dos antecedentes nebulosos das regras A_i . Na segunda parte os antecedentes das regras são fixados e uma estimação por mínimos quadrados é aplicada para determinar os parâmetros a_i e b_i das regras.

Para determinar os coeficientes de cada regra considera-se uma coleção de N pares de dados de entradas e saídas de um sistema $\{x_k, y_k\}$ onde $k = 1, 2, 3, \dots, N$, com x_k sendo um vetor que contém todas as entradas $[x_1, x_2, \dots, x_k]$ e y_k o vetor das saídas correspondentes $[y_1, y_2, \dots, y_k]^T$. Monta-se uma matriz X_e , que é uma matriz com todos os dados de entrada em uma coluna e uma coluna unitária $[X, 1]$ com colunas $[x_k^T, 1]$. A ativação de cada regra é feita pela matriz Γ_i , que é uma matriz diagonal onde os elementos da diagonal principal são retirados da coluna i do grau normalizado das entradas para a regra i , que são denotadas por u_{ki} . Monta-se agora a matriz X' que é uma matriz de dimensões $N \times M.N$, composta pela multiplicação das matrizes Γ_i e X_e , como mostrado abaixo [5]:

$$X' = [\Gamma_1 \cdot X_e, \Gamma_2 \cdot X_e, \dots, \Gamma_M \cdot X_e] \quad (3.9)$$

Com a montagem das matrizes anteriores pode-se calcular o vetor θ' , que é um vetor de dimensões $M_{(n+1)} \cdot x1$ e que apresenta os coeficientes finais das regras a serem geradas:

$$\theta' = [\theta_1^T, \theta_2^T, \dots, \theta_M^T]^T \quad (3.10)$$

Cada elemento do vetor θ' apresenta os coeficientes de cada regra,

$$\theta_i^T = [a_i, b_i] \quad (3.11)$$

Logo o modelo de regressão pode ser obtido pela forma:

$$y = X' \cdot \theta' + e \quad (3.12)$$

Nesta equação e é o erro de aproximação. Para o cálculo de θ' utilizando o modelo de regressão têm-se:

$$\theta' = \left[(X')^T \cdot X' \right]^{-1} \cdot (X')^T \cdot y \quad (3.13)$$

A matriz θ é formada pelos pares de coeficientes a_i e b_i de cada regra.

Com a obtenção dos coeficientes de cada regra, aplica-se o algoritmo para a redução do número de grupos. Este algoritmo é obtido pela determinação do vetor v , de acordo com a equação 3.14.

$$v^{(l)} = \frac{\sum_{k=1}^N (u_{ki}^{(l-1)})^m \cdot Z_k}{\sum_{k=1}^N (u_{ki}^{(l-1)})^m}, \quad 1 \leq i \leq M \quad (3.14)$$

Onde

Z_k - é uma matriz em que cada coluna representa os pares de entrada e saída do sistema, como $Z_k = [X_k, Y_k]$.

m - é um parâmetro do processo de classificação nebulosa;

M - é o número de regras;

N - é o número de pares de entrada e saída;

l - é o número de interações.

Para o sistema proposto neste trabalho, foram gerados 20 grupos através do algoritmo para redução do número de grupos.

3.3 Aplicação do modelo Takagi-Sugeno para extração de regras de um sinal de eletrocardiograma

De acordo com o modelo Takagi-Sugeno apresentado no item 3.2, serão descritos os procedimentos para a aplicação do modelo na extração de regras para um sinal de eletrocardiograma.

Para a aplicação do modelo de extração de regras foi utilizado um sinal de eletrocardiograma do banco de dados *Physionet*, citado em 1.2. A Figura 34 apresenta o sinal utilizado como exemplo. Para este sinal são utilizadas 213 amostras com tempo de amostragem de 0,003s e que representa um sinal típico de eletrocardiograma. Todo o processamento descrito adiante foi realizado em MatLab®.

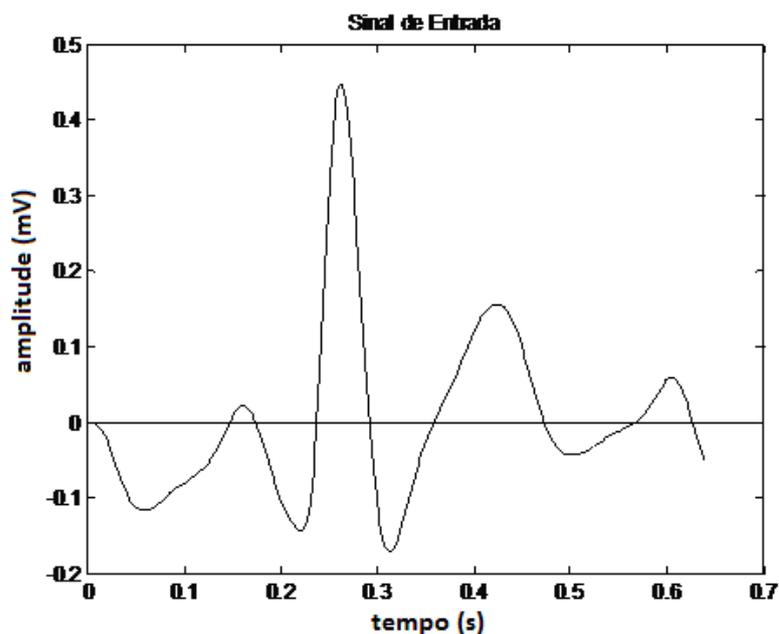


Fig. 34 – Sinal típico de eletrocardiograma.

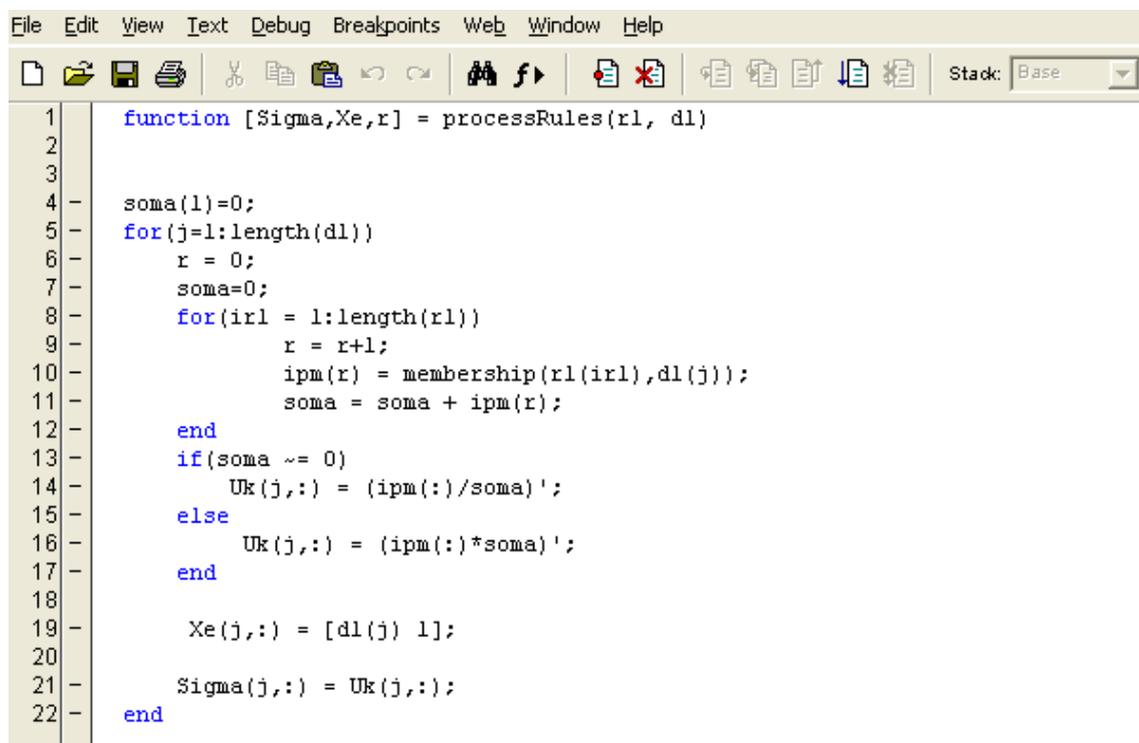
Foram criadas duas matrizes. Uma matriz x , que é um vetor onde cada elemento representa o instante de tempo de cada amostra do eletrocardiograma. Outra matriz y , que também é um vetor onde cada elemento representa o valor em mV de cada amostra do sinal de eletrocardiograma. Estes vetores são apresentados na tabela 1.

Tabela 1 – Vetores de entrada x e saída y para o sinal da Figura 34.

Amostras	X Amostras de entrada (s)	Y Amostras de saída (mV)
1	0,003	-0,0001
2	0,006	-0,0007
3	0,009	-0,0023
4	0,012	-0,0056
5	0,015	-0,0106
6	0,018	-0,0174
212	0,636	-0,0395
213	0,639	-0,0511

De acordo com [5], foram criadas as matrizes u_{ki} , X_e e Γ .

Para a criação das as matrizes u_{ki} , X_e e Γ , foram utilizadas as seguintes linhas de comando no MatLab®.



```

1 function [Sigma,Xe,r] = processRules(rl, dl)
2
3
4 soma(1)=0;
5 for(j=1:length(dl))
6     r = 0;
7     soma=0;
8     for(irl = 1:length(rl))
9         r = r+1;
10        ipm(r) = membership(rl(irl),dl(j));
11        soma = soma + ipm(r);
12    end
13    if(soma ~= 0)
14        Uk(j,:) = (ipm(:)/soma)';
15    else
16        Uk(j,:) = (ipm(:)*soma)';
17    end
18
19    Xe(j,:) = [dl(j) 1];
20
21    Sigma(j,:) = Uk(j,:);
22 end

```

Fig. 35 – Linhas de comando para geração de u_{ki} , X_e e Γ .

Conforme a Figura 35, na linha 1, é possível observar que para a geração das funções pretendidas são necessárias como entrada na rotina, os valores do grau de pertinência (r1) para cada amostra de entrada e os valores de cada amostra de entrada d1. As linhas de comando 4 -22 foram utilizadas para gerar as funções desejadas.

Com as informações de entrada, são geradas as matrizes de u_{ki} , X_e e Γ .

As tabelas 2-3 mostram as matrizes geradas de acordo com as rotinas da Figura 37.

Tabela 2 - Grau normalizado dos antecedentes u_{ki} gerados para cada regra.

Amostras	1	2	3	4	5	6	18	19	20
1	1	0	0	0	0	0	0	0	0
2	1	0	0	0	0	0	0	0	0
12	0,99192	0,0080817	0	0	0	0	0	0	0
13	0,98452	0,01548	0	0	0	0	0	0	0
201	0	0	0	0	0	0	0	0,95752	0,42484
202	0	0	0	0	0	0	0	0,95492	0,45007
203	0	0	0	0	0	0	0	0	1
213	0	0	0	0	0	0	0	0	1

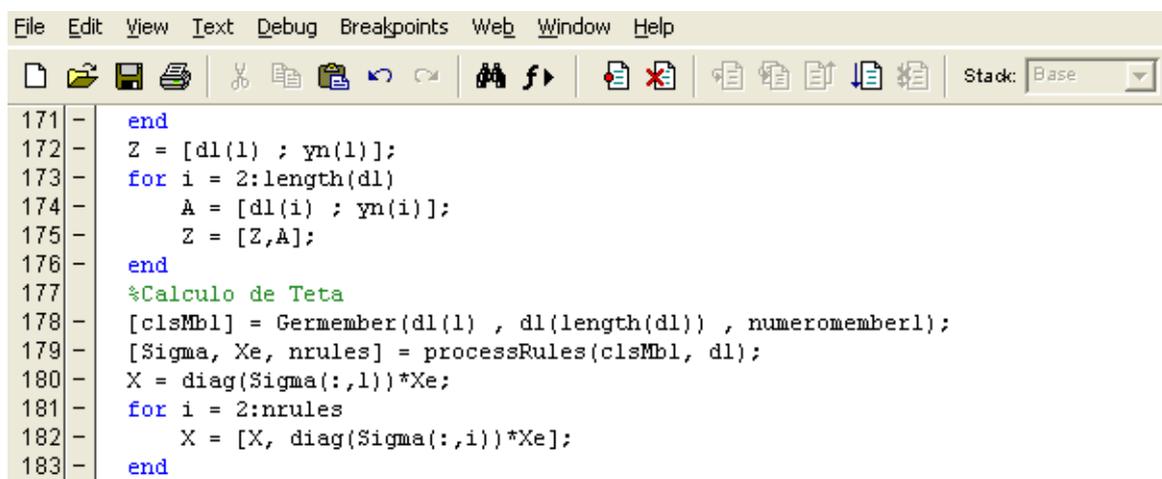
Através da tabela 2, que representa a matriz u_{ki} , é possível observar que a matriz criada tem 20 colunas, o que corresponde a 20 regras a serem criadas.

Tabela 3 - Matriz X_e , com uma coluna com as entradas e uma coluna preenchida com 1.

Amostras	Coluna 1	Coluna 2
1	0,003	1
2	0,006	1
3	0,009	1
212	0,636	1
213	0,639	1

Matriz diagonal Γ_i é de tamanho $N \times N$, onde N é o número de dados de entrada, e sua diagonal principal é formada pelos elementos da coluna i da matriz u_{ki} apresentada na tabela 2.

A matriz X é calculada, calculando o produto de Γ_i com X_e . A rotina utilizada para calcular a matriz X é apresentada pela Figura 38.



```

171 - end
172 - Z = [dl(1) ; yn(1)];
173 - for i = 2:length(dl)
174 -     A = [dl(i) ; yn(i)];
175 -     Z = [Z,A];
176 - end
177 - %Calculo de Teta
178 - [clsMbl] = Germember(dl(1) , dl(length(dl)) , numeromember1);
179 - [Sigma, Xe, nrules] = processRules(clsMbl, dl);
180 - X = diag(Sigma(:,1))*Xe;
181 - for i = 2:nrules
182 -     X = [X, diag(Sigma(:,i))*Xe];
183 - end

```

Fig. 36 – Rotina para criação da matriz diagonal X .

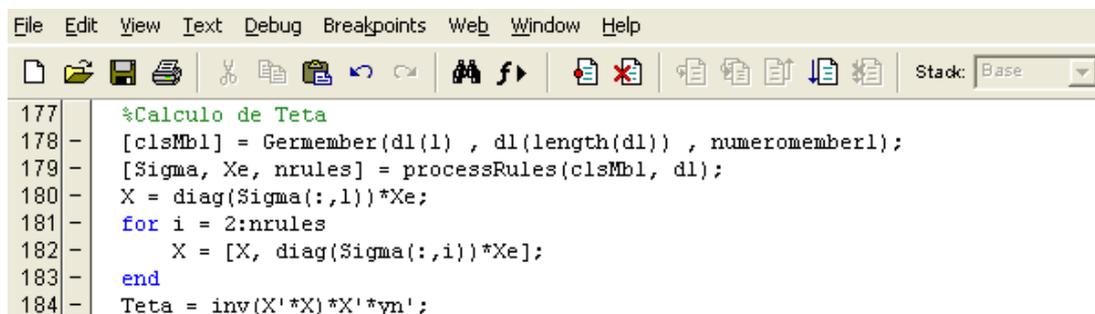
Na Figura 36, na linha 180 é possível observar a matriz X sendo criada em função das matrizes Γ_i com X_e .

A matriz X criada é apresentada pela tabela 4.

Tabela 4 – Matriz X .

	1	2		39	40
1	0,003	0		0	0
2	0,004	0		0	0
212	0	0		0,636	1
213	0	0		0,639	1

De acordo com as matrizes apresentadas nas tabelas 2 a 4, a matriz θ dos coeficientes das equações de cada regra do sistema pode ser criada. A Figura 39 apresenta a rotina para criar a matriz θ dos coeficientes.



```

177 %Calculo de Teta
178 - [clsMb1] = Gernember(dl(1) , dl(length(dl)) , numeromember1);
179 - [Sigma, Xe, nrules] = processRules(clsMb1, dl);
180 - X = diag(Sigma(:,1))*Xe;
181 - for i = 2:nrules
182 -     X = [X, diag(Sigma(:,i))*Xe];
183 - end
184 - Teta = inv(X'*X)*X'*yn';

```

Fig. 37 – Rotina para criação da matriz dos coeficientes.

Na Figura 39, na linha 184, o vetor θ , que na linha de comando é chamado de Teta, dos coeficientes é gerado.

Tabela 5 - Matriz θ dos coeficientes.

1	-0,0072
2	0,0164

40	2,3494

Com a matriz θ dos coeficientes de cada regra, é possível obter a posição de cada regra, para um sinal de eletrocardiograma, determinando-se a matriz v que apresenta os protótipos dos grupos criados. Esta matriz é apresentada na tabela 6.

A tabela 6 mostra os valores dos grupos criados.

Tabela 6 – Tabela que representa a matriz dos grupos criados.

Grupos	Valores (mV)
1	-0,05422
2	-0,10366
3	0,073309

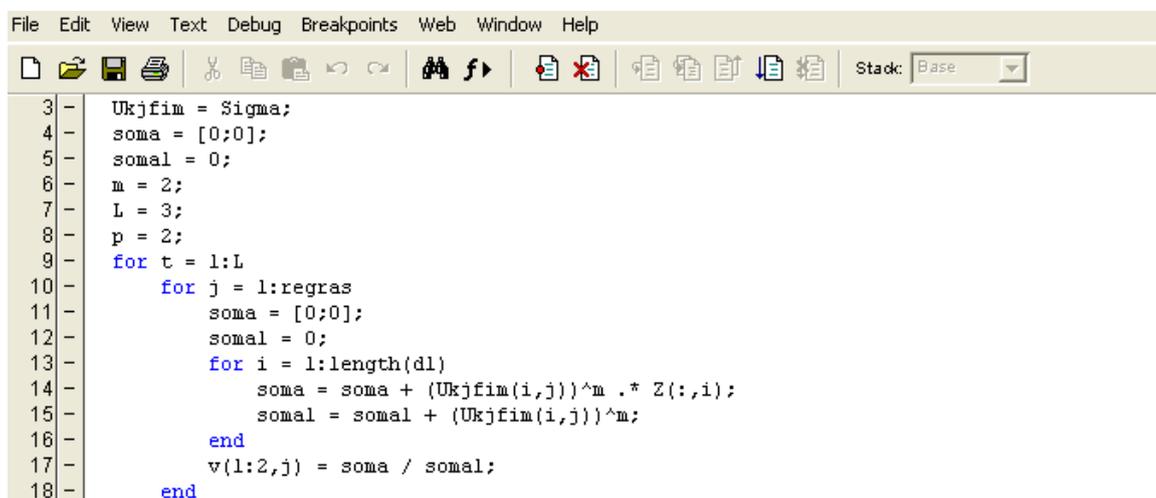
19	0,040244
20	0,0045919

A tabela 7 apresenta a posição de cada grupo no instante de tempo criado.

Tabela 7 – Posição de cada grupo no tempo.

Grupos	Posição (s)
1	0,0285621
2	0,077541
3	0,108087
18	0,56127
19	0,59262
20	0,62502

A Figura 40 apresenta a rotina em MatLab[®] utilizada para a determinação do vetor v.



```

File Edit View Text Debug Breakpoints Web Window Help
[Icons] Stack: Base
3 - Ukjfim = Sigma;
4 - soma = [0;0];
5 - somal = 0;
6 - m = 2;
7 - L = 3;
8 - p = 2;
9 - for t = 1:L
10 -     for j = 1:regras
11 -         soma = [0;0];
12 -         somal = 0;
13 -         for i = 1:length(d1)
14 -             soma = soma + (Ukjfim(i,j))^m .* Z(:,i);
15 -             somal = somal + (Ukjfim(i,j))^m;
16 -         end
17 -         v(1:2,j) = soma / somal;
18 -     end

```

Fig. 38 – Rotina para a determinação do vetor v.

Na Figura 38, é possível observar a rotina para a determinação do vetor v e as configurações utilizadas para os valores de m e l.

A Figura 39 apresenta o gráfico com os grupos determinados. Cada ponto indicado representa a posição do grupo determinado, neste caso a posição dos 20 grupos.

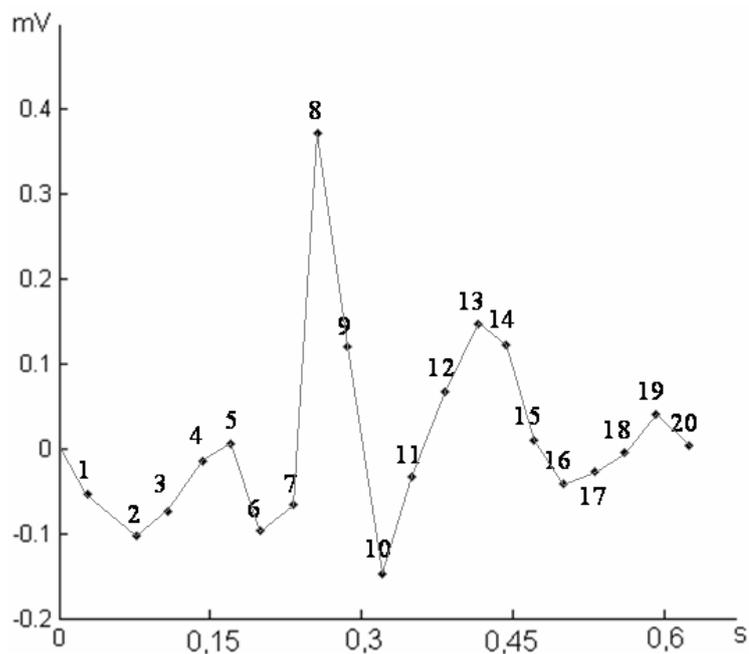


Fig. 39 – Gráfico que mostra a posição e o valor de cada grupo gerado pelo sistema de criação de regras.

4 CORRELAÇÃO

Muitos algoritmos computacionais são usados para obter o diagnóstico de cardiopatias, modelos ocultos de Markov [7], classificadores nebulosos [8], redes neurais artificiais e teoria dos conjuntos [19], detecção do intervalo QRS em tempo real [20]. A correlação foi utilizada neste trabalho para reduzir o processamento requerido e simplificar o hardware usado para implementar o sistema.

Pelo uso do agrupamento nebuloso as amostras foram reduzidas para um grupo de 20 amostras, que são representados pelos grupos gerados.

De acordo com a proposta inicial deste trabalho, após a identificação dos grupos, que indicam as principais variações do sinal de eletrocardiograma, indicadas na figura 6, será utilizada a correlação para gerar o possível diagnóstico para um determinado sinal em análise.

O conceito de correlação é baseado na relação definida pelas afirmações: Quando a variação de um fenômeno interfere na variação de outro fenômeno, diz-se que existe uma correlação entre eles. Como exemplo, quando há um aumento em um fenômeno, ocorrer um acréscimo no outro fenômeno ou quando há uma diminuição em um fenômeno existir uma diminuição também no outro fenômeno diz-se que existe uma correlação direta entre eles. Quando o aumento em um fenômeno acarreta uma diminuição em outro fenômeno ou quando a diminuição de um fenômeno acarreta no aumento em outro fenômeno, diz-se que existe uma correlação inversa entre estes dois fenômenos [21].

Neste trabalho será utilizada a correlação entre sinais para se comparar os grupos nebulosos, definidos pelo sistema proposto, do eletrocardiograma em análise com os grupos nebulosos dos sinais de um banco de dados com diagnóstico conhecido.

Visto que um sinal de eletrocardiograma não possui um equacionamento exato, serão utilizados os grupos nebulosos do sinal de eletrocardiograma, pois nesta aplicação é o suficiente, para que seja possível descobrir os possíveis diagnósticos.

4.1 Resultados das correlações

Quando se analisa a correlação entre dois fenômenos, têm-se três possíveis resultados. Dependendo do valor do coeficiente de correlação, é possível determinar a intensidade da correlação e qual o tipo de correlação [21].

Quando o coeficiente de correlação é negativo e mais próximo de -1 significa que existe uma forte correlação inversa entre os dois fenômenos analisados. Quando o coeficiente de correlação é negativo ou positivo, porém mais próximo de zero significa que não existe correlação entre os fenômenos analisados. Quando o coeficiente de correlação é positivo e mais próximo de 1 significa que existe uma forte correlação direta entre os fenômenos em análise [21].

A correlação pode ser utilizada no processamento de sinais para determinar a similaridade entre um sinal desconhecido e um conjunto de sinais conhecidos.

Neste trabalho, de posse dos pontos gerados pelo processo de agrupamento, foi feito o cálculo da correlação entre estes pontos e os grupos gerados para os sinais de um banco de dados conhecido. Seja X os grupos gerados do sinal em análise e Y os grupos de um sinal do banco de dados de diagnóstico conhecido. O índice de correlação ρ entre os dois grupos x e y é calculado como mostrado na equação (4.1) [21].

$$\rho = \frac{\sum x \times y}{n \times \sigma_x \times \sigma_y} \quad (4.1)$$

Onde

$$x = X - MX$$

$$y = Y - MY$$

$MX \Rightarrow$ é a média dos grupos do sinal em análise;

$MY \Rightarrow$ é a média dos grupos do sinal do banco de dados;

Ou seja:

$$MX = \frac{\sum X}{n} \quad (4.2)$$

$$MY = \frac{\sum Y}{n} \quad (4.3)$$

$n \Rightarrow$ é o número de grupos;

$\sigma_x \Rightarrow$ desvio padrão de x ;

$\sigma_y \Rightarrow$ desvio padrão de y ;

$$\sigma_x = \sqrt{\frac{\sum x^2}{n}} \quad (4.4)$$

$$\sigma_y = \sqrt{\frac{\sum y^2}{n}} \quad (4.5)$$

Como exemplo, sejam os dois sinais mostrados na Figura 40. Se observarmos suas características de variação é possível notar que não existe correlação entre eles. Feito o cálculo em MatLab[®] do índice de correlação entre eles pelo método descrito anteriormente, e foi obtido o valor do coeficiente de 0,15. Este coeficiente indica uma correlação fraca, como era de se esperar.

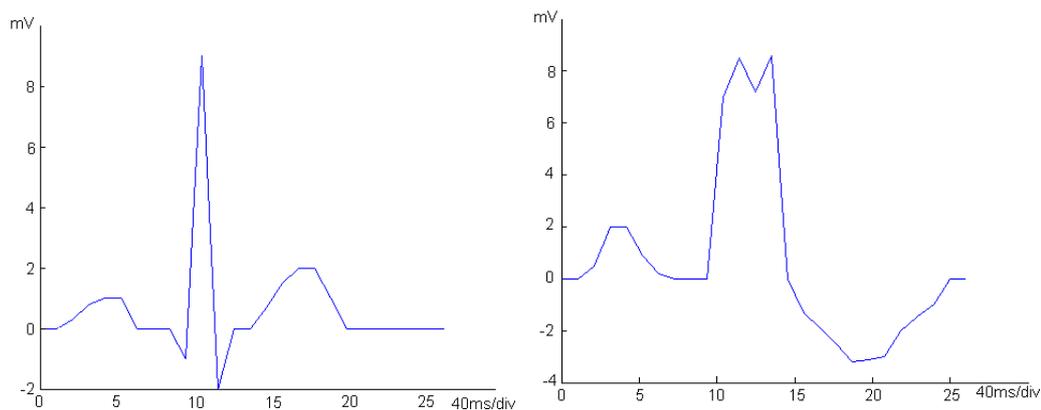


Fig. 40 – Sinais em análise.

Na Figura 41 são apresentados dois sinais que se assemelham. Foi feito o cálculo da correlação entre eles e o valor obtido para o coeficiente foi de 0,89. Este valor indica uma forte correlação direta, como era de se esperar.

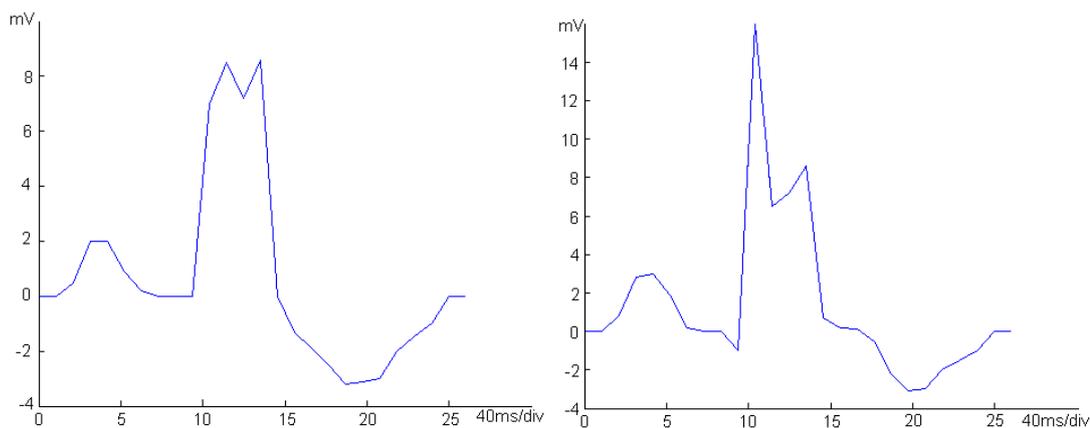


Fig. 41 – Sinais com forte correlação direta.

Na Figura 42 são apresentados dois sinais que mostram variação inversa. Foi feito o cálculo da correlação entre eles e o valor obtido do coeficiente foi de -0,89. Este valor indica uma forte correlação inversa entre estes sinais, como era de se esperar.

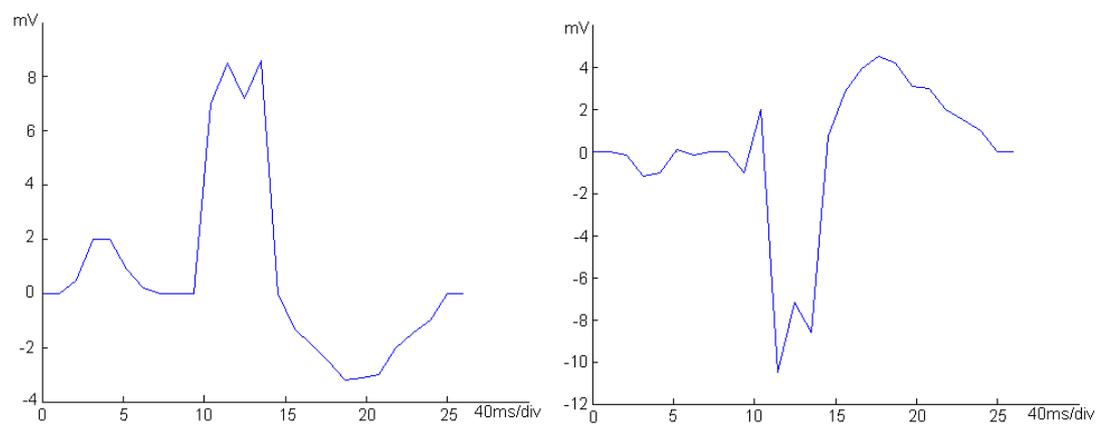


Fig. 42 – Sinais com forte correlação inversa.

5 RESULTADOS EXPERIMENTAIS

5.1 Banco de dados

De acordo com o processamento proposto, fez-se necessária a criação de um banco de dados de sinais de eletrocardiogramas com diagnóstico conhecido. No banco de dados montado para este trabalho foram armazenados 50 sinais com duas derivações, onde uma delas é uma derivação precordial, com 213 amostras cada um. Neste banco de dados foram utilizados sinais de eletrocardiograma característicos das seguintes cardiopatias: angina, infarto, hipertensão arterial.

Cada sinal do banco de dados passou pelo pré-processamento e depois foram armazenados apenas os grupos ou os pontos característicos de cada sinal.

5.2 Testes realizados

Os autores dos artigos estudados para validar o sistema, utilizaram como banco de dados *European ST-T*, fornecido pelo *PhysioNet*.

Antes de realizar os testes, foram verificados outros artigos, como [7], [10], [22], que, através de outras técnicas e utilizando o mesmo banco de dados, forneceram algumas figuras de mérito, que são os parâmetros Se e Pp , calculados segundo [23] da seguinte forma:

$$Se = \frac{Tp}{Tp + Fn} \quad (5.1)$$

Onde Tp e Fn são os diagnósticos corretos e os diagnósticos que não foram detectados respectivamente.

O parâmetro Se indica a porcentagem de diagnósticos corretos em relação aos diagnósticos não detectados.

$$Pp = \frac{Tp}{Tp + Fp} \quad (5.2)$$

Onde Fp indica os diagnósticos errados fornecidos pelo método.

O parâmetro Pp indica a porcentagem de diagnósticos corretos em relação aos diagnósticos errados fornecidos pelo sistema em teste.

A Tabela 8 apresenta um exemplo da determinação dos parâmetros Tp , Fn e Fp , para obter as figuras de méritos Se e Pp .

Tabela 8 – Obtenção dos parâmetros Tp , Fn e Fp .

Paciente	Diagnóstico	Parecer médico	Resultado final
1	Angina	Angina	TP
2	Angina	Angina	TP
3	Angina	Angina	TP
4	Infarto	Infarto e Angina	TP, FN
5	Infarto	Infarto e Angina	TP, FN
6	Infarto	Angina	FN, FP
73	Angina	Angina	TP

5.3 Resultados obtidos

Para a ferramenta matemática apresentada e os parâmetros a serem comparados, foram feitos testes para verificação da eficácia da ferramenta. Para isto, foi montado um banco de dados formado por amostras de sinais de

eletrocardiogramas com características de algumas cardiopatias como: angina, infarto, hipertensão arterial.

Foram feitos 37 diagnósticos de pacientes diferentes e com diagnósticos também diferentes. Cada sinal, antes de ser comparado com o banco de dados, passou por um processo de filtragem, onde neste sistema foi utilizado um filtro Butterworth de terceira ordem passa baixa, para eliminar ruídos de alta frequência e nivelamento do sinal, para eliminar ruídos de níveis DC que possam estar juntos com o sinal do eletrocardiograma.

A Tabela 9 mostra uma comparação dos parâmetros Se e Pp obtidos neste trabalho com os obtidos na literatura.

Tabela 9– Tabela comparativa com outros estudos.

Referências de artigos.	Diagnósticos corretos	Pp	Se
[7]	-	85 %	83 %
[8]	93 %	-	-
[10]	-	81 %	84 %
[20]	-	99 %	99 %
[22]	-	78 %	89 %
[24]	-	75 %	83 %
[25]	-	88 %	87 %
[26]	96 %	-	-
[Este Trabalho]	85 %	92 %	75 %

Na Tabela 9 nota-se que no sistema proposto, o resultado é similar aos de outros sistemas.

O sistema proposto é capaz de gerar prováveis diagnósticos com a mesma eficácia de outros sistemas de processamento. Pelo uso do processo de agrupamento

nebuloso, o processamento é reduzido, pois a correlação não é feita com todas as amostras do sinal.

O processamento realizado requer poucas amostras e conseqüentemente menos memória. O sistema pode ser implementado em uma FPGA com um simples processador.

O sistema já está sendo testado, por um outro trabalho do grupo de microeletrônica, e foi implementado em uma Xilinx Spartan®-3A Starter Kit com a Spartan-3A FPGA. Este é um quadro com baixo custo, que roda a 50 MHz.[26] [27]. Os resultados obtidos foram os mesmos utilizados em MATLAB®.

6 CONCLUSÕES

O resultado das simulações apresentado, permitiu verificar que o sistema tem um desempenho próximo dos resultados apresentados por outros trabalhos, no que diz respeito a possibilidade de fornecimento de diagnóstico. O sistema apresentado simplifica o hardware a ser desenvolvido, com um desempenho próximo do desempenho apresentado por outros trabalhos que utilizam outras técnicas de processamento de sinais.

Verificou-se que com a aplicação da técnica apresentada pela tese, o sistema ficou mais simples para ser implementado em um hardware dedicado, pois o processamento foi reduzido, com a redução de pontos do sinal a serem utilizados. Mesmo com a redução de pontos do sinal processado, o desempenho do sistema continuou próximo do desempenho apresentado por outros sistemas. Esta simplificação no desenvolvimento de hardware significa utilizar menos memória, processamento mais rápido e conseqüentemente redução do custo do hardware requerido para este sistema de diagnóstico de cardiopatias.

Com os resultados obtidos, o sistema mostra-se viável para ser utilizado na geração de prováveis diagnósticos. No início este sistema poderia auxiliar os cardiologistas, principalmente em regiões fora dos grandes centros onde os recursos são poucos e não possuem, às vezes, especialistas da área ou em plantões médicos onde é muito comum o médico de plantão não ser um especialista e o programa poderia auxiliá-lo ao fazer um diagnóstico de cardiopatias.

Devido à simplicidade dos cálculos utilizados, é possível prever uma maior facilidade para converter este programa em linguagem VHDL, possibilitando o desenvolvimento de um hardware que execute as funções propostas pelo sistema.

Com o trabalho proposto, fica demonstrada a possibilidade de desenvolvimento de um hardware dedicado para esta aplicação.

LISTA DE REFERÊNCIAS

- [1] Notícia divulgada em: www.cnn.com/2001/HEALT/10/30/heart.overview/index.html, posted 3:06 pm, EST, November 1, 2006.
- [2] CINTRA, Evaldo Reno Faria, **Diagnóstico de cardiopatias baseado no reconhecimento de padrões pelo método de correlação**, 2006, dissertação de mestrado, UNIFEI – Universidade Federal de Itajubá, Brasil.
- [3] RICH, Elaine; KNIGHT Kevin, **Inteligência Artificial**, Makron Books, 2ª. edição, 1993.
- [4] RUSSELL Stuart; PETER Norvig, **Inteligência Artificial**, Editora Campus, 2ª. edição, 2004.
- [5] M. Setnes, **Supervised Fuzzy clustering for Rule Extraction**, IEE TRANSACTIONS ON FUZZY SYSTEMS, Vol. 8, N° 4, August 2000.
- [6] Physionet PhysioBank MIT-BIH Arrhythmia Database. Disponível em: www.physionet.org/physiobank/database/mitdb. Acessado em 12 de agosto de 2010.
- [7] ANDREÃO R. V., **ST-Segment Using Ridden Markov Model Beat Segmentation: Application to Ischemia Detection**, Institut National des Télécommunications, France. Universidade Federal do Ceará, Fortaleza, Brazil. Computers in Cardiology 2004; 31:381 - 384.
- [8] ANURADHA, B.; REDDY, V. C. Veera, **Cardiac Arrhythmia Classification Using Fuzzy Classifiers**, Journal of Theoretical and Applied Information Technology, 2005 – 2008.
- [9] Li Shi; HUI Li; ZHIFU Sun; WEI Liu, **Research on Diagnosing Heart Disease Using Adaptive Network-based Fuzzy Interferences System**, Proceedings of International Joint Conference on Neural Networks, Orlando, Floeida, USA, August 12-17, 2007.
- [10] TADDEI A.; CONSTANTINO G. et AL., **A System for the Detection of Ischemic Episodes in Ambulatory ECG**. Computers in Cardiology, Vienne, Autriche, 1995, pp. 705 – 708, 1995.
- [11] ROSA, Izabel Cristina Ribeiro; MATTA, Cláudia Eliane, **Classificação de sinais eletrocardiográficos usando redes neurais artificiais**, VII Encontro Latino Americano de Iniciação Científica e IV Encontro Latino Americano de Pós-Graduação – Universidade do Vale do Paraíba.
- [12] MatLab – Software de Modelamento Matemático. Disponível em: <http://www.mathworks.com/products/matlab>. Acesso em 19/05/2010.

[13] FUGANTI, Cláudio José; OLIVEIRA, Divina Seila; RODRIGUES, Ricardo José; **Curso de Eletrocardiografia Básica**, CCS – Centro de Ciências da Saúde; UEL – Universidade Estadual de Londrina.

[14] STEIN, Emanuel, **Eletrocardiografia Prática um curso de auto-estudo**, Revinter; Editora Santuário.

[15] Figura apresentada pelo site o corpo humano. Disponível em: www.ocorpohumano.com.br. Acessado em 12 de agosto de 2010.

[16] BOYLESTAD, Robert L.; NASHELSKY, Louis, **Introdução à análise de Circuitos**, 8ª edição – São Paulo: Pearson Prentice Hall, 2004.

[17] SEDRA, Adel S.; SMITH, Kenneth, C., **Microeletrônica**, 4ª edição - São Paulo: Makron Boocs, 2000.

[18] SHAW, Ian S.; SIMÕES, Marcelo Godoy, **Controle e Modelagem Fuzzy**, Editora Edgard Blucher LTDA. FAPESP, 1ª edição.

[19] SETIAWAN, N.A.; VENKATACHALAM, P. A.; HANI, A. F. M., **Missing Data Estimation on Heart Disease Using Artificial Neural Network and Rough Set Theory**, IEEE International Conference on Intelligent and Advanced Systems, 2007.

[20] ZHENG, Huabin; WU, Jiankang, **Real-time QRS Detection Method**, 2008 10th IEEE Intl. Conf. on e-Health Networking, Applications and Service, HEALTHCOM 2008.

[21] CASTRO, Lauro Sodré Viveiros de, **Pontos de estatística**, 1964.

[22] MAGLAVERAS N., STAMKOPOULOS T. et. al. **An adaptive backpropagation neural network for real-time ischemia episodes detection: development and performance analysis using the European ST-T database**, IEEE Trans Biomed Eng 45(7):193-214, 1998.

[23] INAN, Omer T.; GIOVANGRANDI, Laurent; KOVACS, Gregory T. A., **Robust Neural-Network-Based Classification of Premature Ventricular Contractions Using Wavelet Transform and Timing Interval Features**, IEEE Transactions on Biomedical Engineering, Vol. 53, n. 12, December, 2006.

[24] VILA J., PRESEDO J. et al. Sutil, **Intelligent ischemia monitoring system**, Int J Med Inf 47(3): 193-214, 1997.

[25] JAGER, F.; MOODY, G. B.; MARK, R. G. **Detection of transient ST segment episodes during ambulatory ECG monitoring**, computers and biomedical research 31, 305 – 322, 1998.

[26] AFSAR, Fayyaz A.; AKRAM, M. U.; ARIF, M.; KHURSHID, J., **A Pruned Fuzzy k-Nearest Neighbor Classifier with Application to Electrocardiogram Based Cardiac Arrhythmia Recognition**, Proceedings of the 12th IEEE International Multitopic Conference, December 23.

[27] ARMATO, A.; NARDINI E., A. Lanatà; VALENZA, G.; C. Mancuso, E.P. Scilingo, D. De Rossi, **An FPGA based arrhythmia recognition system for wearable applications**, Ninth International Conference on Intelligent Systems Design and Applications, 2009.

[28] Xilinx inc., Spartan-3A/3AN FPGA Starter Kit Board, user guide, Jun, 2008.