

UNIVERSIDADE FEDERAL DE SANTA CATARINA-UFSC
CURSO DE PÓS GRADUAÇÃO EM CIÊNCIAS DA
COMPUTAÇÃO

MODELO CONEXIONISTA PARA
IDENTIFICAÇÃO DE EMISSÕES RADAR

POR

WILLIAM FREITAS DA SILVA E SILVA

*Dissertação submetida à Universidade Federal de Santa
Catarina para obtenção do grau de mestre em Ciências da
Computação.*

PROF. Dr. LUIS FERNANDO JACINTHO MAIA
ORIENTADOR
Florianópolis, Setembro de 1995

UM MODELO CONEXIONISTA PARA IDENTIFICAÇÃO DE EMISSÕES RADAR

WILLIAM FREITAS DA SILVA E SILVA

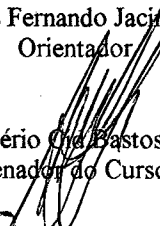
ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA OBTENÇÃO DO TÍTULO DE

MESTRE EM CIÊNCIAS DA COMPUTAÇÃO

ESPECIALIDADE SISTEMAS DE CONHECIMENTOS E APROVADA EM SUA FORMA FINAL PELO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA COMPUTAÇÃO

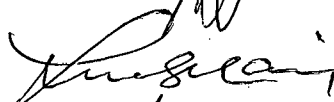


Prof. Luis Fernando Jacinto Maia, Dr.
Orientador



Prof. Rogério Chaves Bastos, Dr.
Coordenador do Curso

BANCA EXAMINADORA



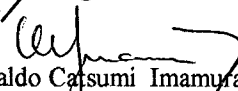
Prof. Luis Fernando Jacinto Maia, Dr. (Presidente)




Prof. Rogério Chaves Bastos, Dr.



Dr. Antonio Hugo Pereira Chaves



Dr. Osvaldo Catsumi Imamura



Prof. Fernando Alvaro Ostuni Gauthier, Dr.

A aqueles que acreditam.

À Meroça, Carol e Camilinha.

Agradecimentos.

Agradeço à todos aqueles que direta ou indiretamente contribuíram para a realização deste trabalho.

Aos mestrandos 94/95 pela amizade que encontrei.

Ao meu orientador pelo empenho e amizade.

Ao Prof. Dr. Adroaldo Raizer pelas oportunidades oferecidas.

Ao Dr. Catsumi Imamura pelas preciosas orientações.

Ao Prof. Dr. David Fernandes pelo incentivo.

Aos chefes Maj Av. Narcélio Ramos Ribeiro e Maj Av José Maria Gomes da Silva Neto pelas oportunidades criadas.

e principalmente à DEUS e ao nosso Sr JESUS CRISTO.

SUMÁRIO

CAPÍTULO I

INTRODUÇÃO

1.1- Introdução	1
1.2- Objetivos	1
1.3- Estrutura	2

CAPÍTULO II

CONCEITUAÇÕES BÁSICAS SOBRE EMISSÃO RADAR

2.1 Introdução	3
2.2 Tipos de detecção.	3
2.3 O RADAR.	3
2.3.1 Descrição dos tipos de RADAR	4
2.3.1.1 RADAR de onda contínua.	4
2.3.1.1.1 RADAR FM.	4
2.3.1.2 RADAR pulsado.	4
2.3.1.2.1 Terminologia aplicada ao RADAR modelado por pulsos.	5
2.4 Ambiente operacional.	6
2.4.1 Análise do sinal recebido.	8
2.4.1.1 Modulação.	8
2.4.1.2 Frequência de repetição de pulsos.	8
2.4.1.3 Intervalo de repetição de pulsos.	8
2.4.1.4 Largura de pulso.	10
2.4.1.5 Frequência.	10
2.4.1.6 Tipos de varredura.	11
2.4.1.7 Frequência da modulação de varredura.	14

CAPÍTULO III

APRENDIZAGEM E CONHECIMENTO DIFUSO

3.1 Processos de aprendizagem.	15
3.1.1 Aprendizagem por memorização.	15
3.1.2. Aprendizagem por aconselhamento	16
3.1.3 Aprendizagem por experiência	16
3.2 Conhecimento Difuso	16
3.2.1 Abordagens para o trato com a incerteza.	16
3.2.2 Conceitos básicos conjuntos difusos.	17
3.2.3 Aspectos a serem considerados.	19

CAPÍTULO IV

CONCEPÇÃO HEURÍSTICA

4.1 Introdução	20
4.2 O PROLOG.	20
4.3 Diferenças básicas entre as abordagens heurística e algorítmica	23
4.4 Aspectos relevantes na identificação de emissões RADAR	24

CAPÍTULO V

PARADIGMAS CONEXIONISTAS CLÁSSICOS.

5.1 Introdução.	26
5.2 Estruturas tradicionais de redes neurais.	26
5.2.1 Características básicas.	26
5.2.2 Diferenças entre as redes neurais e a máquina de Von Newmann	28
5.2.3 O relacionamento das redes neurais com o cérebro humano.	29
5.2.4 Limitações relacionadas às estruturas das redes.	29

5.2.5 Hard e Soft para redes neurais.	29
5.2.6 Aplicações em potencial.	30
5.2.7 Escolhas do design.	30
5.2.8 Implementações de redes neurais.	31
5.2.9 Aprendizagem.	32
5.2.9.1 Aprendizagem como mudança.	32
5.2.10 Paradigmas de aprendizagem.	33
5.2.10.1 Propagação reversa do erro .	33
5.2.10.2 Aprendizagem competitiva e inibição lateral.	34
5.2.11 Taxonomia das redes neurais.	35
5.2.11.1 Rede de Hopfield.	36
5.2.11.2 Rede de Haming.	37

CAPÍTULO VI

MODELO CONEXIONISTA .

6.1 Introdução.	39
6.2 Simulação numérica.	39
6.3 Fórmulas analíticas da implementação analógica.	39
6.4 Resultados obtidos.	44
6.5 VLSI(Very Large Scale Integration).	45
6.5.1 Introdução.	45
6.5.2 Origem da VLSI(VERY LARGE SCALE INTEGRATION)	45
6.5.3 Semicondutores.	46
6.5.4 Transistor MOS.	46
6.5.5 Propriedades dos circuitos de transistores.	50
6.5.6 Espelho de corrente.	52
6.5.7 Par diferencial.	53
6.5.8 Amplificador de transcondutância.	56
6.6 Comparação com a abordagem heurística.	60
6.6.1 Introdução.	60
6.6.2 Processamento simbólico Vs numérico.	60

CAPÍTULO VII

CONCLUSÃO

7.1 Propostas de trabalhos futuros. 62

ANEXO 1 63

REFERÊNCIAS BIBLIOGRÁFICAS 74

RESUMO

O crescente desenvolvimento tecnológico na área da eletrônica, tem revolucionado as técnicas e táticas utilizadas na exploração do espectro eletromagnético, como meio de promover a identificação de alvos. Em contrapartida, a pesquisa de sistemas que buscam imitar performances humanas, em tarefas que exijam processamentos simbólicos ou classificação de padrões, têm apresentado um notável aumento de interesse por parte da comunidade científica.

O desenvolvimento de sistemas que realizam diagnósticos de doenças ou sistemas capazes de promover a identificação de padrões de sons e imagens, dão uma boa idéia do quão é amplo o espectro de problemas solucionáveis por estas abordagens.

Uma breve concepção de uma abordagem heurística para a solução deste problema será realizada, de forma que obtenhamos um paralelo conceitual, sobre o qual possamos ressaltar algumas características de um modelo conexionista.

Os paradigmas da abordagem conexionista serão conceituados, de forma que, tenhamos o suporte teórico para que um modelo conexionista possa ser concebido. Algumas funções utilizáveis por estes modelos serão simuladas e um circuito capaz de implementá-las analogicamente será sugerido.

ABSTRACT

A growing technological development in the electronics, has revolutionized the technical and tactical means used at the exploitation of the electromagnetic spectrum, as target identifiers. In other hand, the survey at the systems that want to imitate the human performances, in tasks of symbolic process or pattern classification, has presented a notable augment of interest of the scientific community.

The development of the systems that make diseases diagnosis or perform sounds and images pattern identification, give us a good idea how big is the scope of the solutionable troubles for that approaches.

A brief conception of the heuristic approach will be realized, to permit that we get a conceptual parallel with we can stress some characteristics on a connexionist model.

The paradigm of the connexionist approach will be conceived, in a manner that we get the theoretical support to the connexionist model conception. Some functions usable for these models will be simulated and a able circuit to implement them analogically will be suggested.

LISTA DE FIGURAS.

FIG 1- Transmissão modulada por pulsos.	5
FIG 2- Vantagem em distância da detecção passiva sobre a ativa.	7
FIG 3- Tipos de modulação.	9
FIG 4- Comparação entre dois comprimentos de onda.	10
FIG 5- Relação entre frequência e alcance.	11
FIG 6- Varredura circular.	12
FIG 7- Varredura por setor.	12
FIG 8- Vista de cima de uma varredura por setor.	13
FIG 9- Varredura cônica.	13
FIG 10-Varredura com feixe em V.	14
FIG 11- Gráfico de graus de pertinência versus valores de frequência	18
FIG 12-Gráfico representativo de uma função de pertinência.	25
FIG 13-Entradas e saídas típicas de um processador.	27
FIG 14-Exemplo típico de uma rede de três camadas.	31
FIG 15-Resposta de uma rede de Hopfield após a convergência.	36
FIG 16-Rede de Haming.	38
FIG 17-Gráfico demonstrativo de conceito $F > F_i$.	40
FIG 18-Gráfico demonstrativo de conceito. $F < F_s$.	41
FIG 19-Curva de mapeamento.	42
FIG 20-Diagrama de um transistor.	47
FIG 21-Layout de transistores.	50
FIG 22-Curvas de saturação de corrente em função de V_{ds} .	51
FIG 23-Curva de saturação de corrente em função de V_{gs} .	51
FIG 24-Exemplos de circuitos espelho de corrente.	53
FIG 25-Circuito par diferencial.	54
FIG 26-Saída de corrente em função de diferenças de potencial.	56
FIG 27-Amplificador de transcondutância.	57
FIG 28-Curva de um amplificador de transcondutância.	58
FIG 29-Diagrama de um circuito identificador de emissões RADAR	59

TABELAS

Tabela 1- Graus de pertinência relativos a valores de frequência.	17
Tabela 2- Resultados obtidos na simulação.	44

LISTA DE ABREVIATURAS

ABREVIATURA	SIGNIFICADO
AM	Amplitude Modulation
CW	Continuos Wave
FM	Frequency Modulation
FRP	Frequência de Repetição de Pulsos
IA	Inteligência Artificial
IDT	Identificação
LP	Largura de Pulso
MAGE	Medidas de Apoio a Guerra Eletrônica
MIMA	Milhas Maritimas
PC	Potência de pico
PENAIID	Penetration Aid
PM	Potência Média.
PROLOG	Programing in Logig
RADAR	Radio detection and Ranging.
TR	Tempo de repetição(período).
VLSI	Very Large Scale Integration.

CAPÍTULO I

INTRODUÇÃO.

1.1 Introdução.

A exploração do espectro eletromagnético visando a identificação de alvos, tem sido uma área de pesquisa que vem recebendo grandes investimentos nos últimos anos. Novos equipamentos, táticas e estratégias vêm sendo desenvolvidas com fins de se otimizar os processos responsáveis por esta exploração. Processos de busca, interceptação, localização, gravação e análise de sinais eletromagnéticos, têm requerido operadores cada vez mais treinados para a operação dos equipamentos responsáveis por estes processos.

Ressalta-se, por um outro lado, que a pesquisa na área de desenvolvimento de sistemas que são capazes de demonstrar uma capacidade de aprendizagem, semelhante a verificada nos processos humanos de raciocínio, bem como, sistemas capazes de realizar tarefas de classificação de padrão, com velocidade e eficácia semelhantes às estruturas neurais biológicas, vêm atraindo cada vez mais, um maior volume de investimentos e pesquisas.

O escopo de aplicação deste trabalho vem a se enquadrar dentro deste contexto, quando serão realizadas conceituações e concepções de abordagens, responsáveis por otimizações e automatizações, de alguns dos processos acima citados.

1.2 Objetivos.

O objetivo deste trabalho é o de apresentar sugestões para a solução do problema de identificação de emissões RADAR. Buscar-se-á esta solução, apresentando-se sugestões que possam lidar com o grau de incerteza inerente a este processo e que possam nos fornecer respostas em tempo real.

Este processo de identificação se reveste de um certo grau de incerteza, haja visto, que uma mesma combinação de parâmetros, pode indicar a pertinência de uma emissão à vários tipos de RADAR.

Uma breve concepção da abordagem heurística também será realizada, com o intuito de possuímos no final deste trabalho, um referencial teórico que nos permita enfatizar algumas características do modelo conexionista proposto.

Procuraremos atingir o objetivo acima com a concepção de um modelo conexionista, que será realizada a partir da conceituação de alguns de seus paradigmas clássicos. Algumas funções de pertinência que poderão ser utilizadas por estes sistemas, serão simuladas numericamente, após o que citaremos, a nível de sugestão, alguns circuitos analógicos que poderão vir a implementar estas funções.

1.3 Estrutura.

Após uma breve apresentação do escopo deste trabalho, teremos como objetivo no segundo capítulo, a familiarização com os conceitos referentes a uma aplicação militar do espectro eletromagnético, ressaltando os aspectos que serão importantes para este trabalho. Conceitos de detecção ativa e passiva serão apresentados, ressaltando os parâmetros de interesse para análise do sinal RADAR, com a sua conseqüente classificação.

O terceiro capítulo versará sobre os aspectos dinâmicos no processo de identificação de emissões RADAR. Com relação aos aspectos dinâmicos dois serão os pontos tratados. O primeiro aspecto a ser considerado será na forma de uma breve introdução ao estudo da aprendizagem realizada por sistemas computacionais. O segundo será a teoria dos conjuntos difusos, utilizada para dar o suporte necessário à implementação do grau de incerteza existente neste processo.

O quarto capítulo versará sobre as conceituações básicas de uma abordagem heurística, dentro do escopo da teoria geral da Inteligência Artificial (IA). O objetivo deste capítulo é o de obtermos um suporte teórico, para que possamos traçar um paralelo conceitual com a abordagem conexionista, ressaltando assim algumas de suas características.

O quinto capítulo abordará alguns dos principais paradigmas das redes neurais, além de tratar de alguns processos de aprendizagem que podem ser implementados. Este capítulo visa fornecer o arcabouço teórico necessário, dentro do qual podemos utilizar algumas funções que terão seus comportamentos simulados numericamente.

O sexto capítulo apresentará uma simulação das funções acima descritas, sendo que a seguir citaremos, a nível de sugestão, um circuito analógico que poderia implementar estas funções. Este capítulo versará também sobre algumas das principais diferenças entre as abordagens conexionista e heurística, de forma que ressaltemos as características do modelo conexionista proposto.

O último capítulo trará uma breve conclusão, onde pretendemos citar algumas propostas para trabalhos futuros.

CAPÍTULO II

CONCEITUAÇÕES BÁSICAS SOBRE EMISSÃO RADAR.

2.1 Introdução.

Pretende-se com este tópico, definir o escopo de aplicação deste trabalho para o qual as soluções são propostas. A apresentação de alguns conceitos básicos que definem a aplicação do espectro eletromagnético na identificação de alvos será realizada.

O contexto, no qual equipamentos passivos e ativos de detecção são utilizados, será definido. Pretende-se assim, ressaltar a importância que a proposta ora realizada, possui na otimização e automatização de procedimentos que devem ser executados, com um alto nível de precisão e em tempo real pelos operadores dos equipamentos existentes para este fim.

2.2 Tipos de detecção.

Existe dois tipos básicos de detecção, quais sejam: a detecção ativa e a detecção passiva. A detecção ativa resulta da utilização do RADAR, que realiza a localização de alvos através da transmissão de ondas eletromagnéticas. A detecção passiva por sua vez, promove uma identificação de alvos a partir da análise dos parâmetros das transmissões que estes alvos possam efetuar, ou seja, é efetivada através de equipamentos receptores[FUN 90].

No escopo deste trabalho, estaremos sempre nos referindo na identificação passiva de alvos marítimos, através de equipamentos a bordo de aeronaves.

2.3 O RADAR.

É o equipamento responsável pela identificação ativa, sendo o termo RADAR uma abreviatura da expressão “Radio Detection and Ranging”. A detecção é derivada da propriedade de reflexão das ondas eletromagnéticas. Esta detecção nos fornece além da presença do objeto refletor, a sua direção e distância em relação a plataforma emissora.

Os parâmetros que compõe uma emissão RADAR serão conceituados, de forma que nos seja possível, visualizar como identificar um determinado tipo de RADAR a partir das emissões recebidas.

2.3.1 Descrição de tipos de RADAR.

Embora todos os tipos de RADAR operem baseados nos mesmos princípios, uma diversidade de métodos de transmissão e técnicas de medidas dos parâmetros de interesse, aparecem diferenciando o RADAR em duas grandes categorias, quais sejam, radares de onda contínua(CW) e os pulsados[MAL90].

2.3.1.1 RADAR de onda contínua.(CW)

Este tipo de RADAR opera com o seu transmissor praticamente de forma contínua,resultando em sinais de baixa amplitude e longa duração, quando comparados com a transmissão de pulsos curtos e de grande amplitude do RADAR pulsado. A forma mais simples de RADAR de onda contínua é o RADAR doppler, onde a distância e conseqüente determinação da presença do alvo é obtida pela medição da variação da frequência refletida do alvo, quando este se aproxima ou se afasta da fonte emissora, em relação a frequência transmitida. Este tipo de RADAR tem como grande inconveniente, o fato de não possibilitar a medida de distância do objeto refletor. O RADAR CW é aplicado de forma mais eficiente para detecção e determinação de velocidade de projéteis[MAC91].

2.3.1.1.1 RADAR FM

Este tipo de RADAR, semelhantemente ao RADAR CW, transmite continuamente e toma as suas medidas pela variação das frequências transmitida e recebida . Porém o que os difere, é a modulação em frequência da onda transmitida, o que permite a obtenção de medidas de distância de alvos estacionários e em movimento. A medida de distância ocorre porque o desvio da frequência ocorre a uma taxa fixa,o que nos possibilita converter a diferença da frequência transmitida e recebida em medidas de distância. Este tipo de RADAR porém nos apresenta uma grande limitação, que é a introdução de desvios doppler, que modificam a frequência do sinal eco, gerando imprecisões deste sinal quando lidamos com alvos de grande velocidade. Estes tipos de RADAR são amplamente utilizados para detecção de altitudes absolutas,onde o único alvo de real interesse é a terra ou o mar[MAL90].

2.3.1.2 RADAR pulsado.

O tipo de RADAR que será objeto de nosso estudo é o que possui transmissão modulada por pulsos, neste tipo de modulação temos um ciclo de transmissão de energia contida em pulsos, seguido por um período de escuta de qualquer sinal refletido,após o qual, o ciclo se repete. Este período de tempo de escuta será computado juntamente com a velocidade da luz, visando o cálculo da distância.

O RADAR com transmissão modulada por pulsos se divide ainda em dois grandes grupos, quais sejam, RADAR de pulso primário e RADAR de pulso secundário. A diferença básica entre estes é a de que o segundo permite a identificação positiva de alvos, desde que estes sejam cooperativos, ou seja, possuam um equipamento que responda as interrogações que são realizadas pelo transmissor. Identificação positiva pode ser entendida como uma identificação particular do alvo e não somente da sua presença, distância e direção.

2.3.1.2.1 Terminologia aplicada ao RADAR modulado por pulso.

A seguir será realizada a conceituação de alguns termos técnicos empregados a este conceito, pois qualquer análise de um determinado RADAR pulsado incluirá o estudo destes parâmetros. Podemos de acordo com a figura 1 visualizar o relacionamento dos diversos parâmetros envolvidos na modulação da transmissão RADAR por pulsos.




FIG 1-Transmissão modulada por pulsos.

Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

- L_p - Largura de pulsos.
- P_c - Potência de pico.
- T_r - Período de repetição de pulsos.
- P_m - Potência de média.

1- Um pulso possui uma potência de pico (P_c), que dura por um certo período de tempo (energia = potência * tempo) e que representa a amplitude do pulso transmitido.

2- A duração de transmissão do pulso representa a largura do pulso (L_p).

3- O intervalo entre a transmissão de um pulso e o início da transmissão do seguinte é o intervalo de repetição dos pulsos (T_r), que define a sua potência média (P_m).

4- O número de pulsos gerado por segundo é denominado de frequência de repetição de pulsos e é recíproco ao intervalo de repetição dos pulsos.

Por exemplo, a frequência de repetição de pulsos para um sistema cujo intervalo entre os pulsos é de $1000 \mu s$ será de:

Frequência de repetição = $1/1000 \mu s \implies 1000$ pulsos por segundo.

A diversidade destes parâmetros, nos permite visualizar que a sua combinação fornece uma gama variada de tipos de RADAR, com diversas aplicações possíveis. No nosso trabalho, estaremos sempre nos referindo aos aplicáveis na busca e identificação de alvos aéreos e que são utilizados por navios. Os principais tipos que podemos reportar são:

- RADAR de busca aérea.
- RADAR de busca de superfície.
- RADAR de busca combinada (aérea e de superfície).
- RADAR de controle de tiro.
- RADAR de navegação.

2.4 Ambiente operacional.

Enfatizar-se-á aqui, a aplicação de equipamentos à bordo de aeronaves, que possuam por função promover a identificação de alvos marítimos, a partir das emissões RADAR que estes possam transmitir. Os equipamentos passivos são responsáveis pela busca, interceptação, localização, gravação e análise das emissões RADAR presentes, se apresentando assim como uma boa alternativa na identificação de alvos. A grande vantagem deste método, é que não ocorre a denúncia da aeronave identificadora, o que poderia ocorrer se esta aeronave transmissora utilizasse um RADAR para a localização destes alvos [ELE88].

Podemos observar através da figura 2 a vantagem que a detecção passiva possui sobre a detecção ativa. Este fato ocorre devido ao decréscimo do nível de potência em função da distância da plataforma transmissora. Após percorrer uma determinada distância, o pulso transmitido não possui mais potência para dar um retorno eco ao RADAR transmissor, mas possui potência suficiente para sensibilizar os receptores dos equipamentos passivos.




FIG 2-Vantagem em distância da detecção passiva sobre a ativa.
Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

Um operador de um equipamento responsável pela identificação passiva de emissões RADAR se depara com os seguintes processos[MAE89]:

- Identificação da direção da emissão.

Esta identificação se torna necessária, pois é o primeiro passo na compilação de um determinado contexto de operação, conhecido operacionalmente como quadro tático.

- Identificação da frequência do sinal.

Dependendo do tipo de equipamento utilizado, pode ser o seu valor exato ou em termos de banda. Alguns equipamentos não possuem condições de determinar o valor exato da frequência, determinando-o em termos de bandas, o que dificulta em muito uma identificação segura do tipo de RADAR que está emitindo.

- Seleção da emissão de interesse.

Em muitos casos ocorre um quadro tático extremamente denso de emissões, o que resulta num grande número de vetores congestionando o tubo display do operador.

- Correlação do sinal de áudio com a FRP(Frequência de repetição de pulsos) do sinal recebido.

O tom do sinal de audio do sinal interceptado, pode auxiliar o operador a identificar se a FRP é alta ou baixa, o que somado à análise de outros parâmetros facilita a identificação do sinal recebido.

- Indicação de emissões CW ou pulsadas.

Em alguns equipamentos obtemos uma indicação prévia do tipo de emissão recebida.

- Leitura dos parâmetros analisados pelo equipamento.

Este item é o de principal importância, pois a partir dos parâmetros analisados, podemos inferir com relativo grau de segurança, qual o tipo de RADAR que é o responsável por aquela emissão, e será neste item que nos deteremos com maior profundidade.

- Alarme sonoro e visual de emissões que sejam consideradas ameaçadoras.

Podemos contar algumas vezes com equipamentos que de acordo com bibliotecas previamente arquivadas, nos indicam se a emissão é amiga ou hostil.

2.4.1 Análise do sinal recebido.

Os operadores devem manter a aeronave numa distância segura, de maneira que possa receber as emissões RADAR a serem analisadas e não corram o risco de serem detetados pelas mesmas. Isto se torna possível graças à vantagem que o horizonte de recepção destes equipamentos possui sobre o horizonte de detecção do RADAR. O controle do nível de potência do sinal recebido é o parâmetro mais seguro para que o operador monitore esta distância. Tomada esta primeira precaução, o operador deverá a seguir correlacionar todos os parâmetros recebidos, de forma a obter com o maior grau de segurança possível, o tipo de RADAR que está emitindo, e para tanto, citamos quais os parâmetros que devem ser analisados.

2.4.1.1 Modulação.

Como citado anteriormente, uma transmissão pode ser realizada de forma contínua(sem modulação), ou modulada em amplitude, frequência ou por pulsos, como será o caso em estudo. A modulação por pulsos implica em parâmetros como frequência de repetição de pulsos, largura dos pulsos e intervalo de repetição de pulsos.Estes tipos de modulação citados podem ser observados na figura 3.

Equipamentos digitais podem ser utilizados para a determinação do tipo de modulação.




FIG 3- Tipos de modulação.

Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

2.4.1.2 Frequência de repetição de pulsos(FRP).

Esta frequência se refere à razão na qual os pulsos são transmitidos e é medida em Hertz(ciclos/seg). Esta frequência pode determinar diretamente o máximo alcance teórico do sistema através da fórmula:

$$\text{Alcance} = 82.600/\text{FRP MIMA}(\text{Milhas Marítimas})$$

Pode-se abstrair diretamente desta fórmula que quanto maior a FRP menor será o máximo alcance teórico. Na maioria dos sistemas mais modernos há a variação da FRP, sendo que neste caso, o alcance teórico a ser considerado será o maior possível para este sistema.

2.4.1.3 Intervalo de repetição de pulsos.

É a recíproca matemática da FRP, e juntos formam a impressão digital de um RADAR, sendo que ainda existem outros parâmetros que devem ser considerados quando da análise de um sinal.

2.4.1.4 Largura de pulso.

É o tempo, dentro do qual ocorre a liberação de energia dentro de um pulso, sendo medido em μs (micro segundos). Este parâmetro afeta diretamente o poder separador em distância e alcance máximo de um sistema, da seguinte forma: larguras de pulso estreitas produzem bom poder separador em distância e alcance máximo reduzido. Em sistemas mais modernos podemos encontrar dispositivos de compressão de pulsos, que possuem como finalidade otimizar o poder separador em distância em relação à alvos de interesse.

2.4.1.5 Frequência.

Frequência, período de transmissão e comprimento de onda são parâmetros diretamente interrelacionados e que influenciam o desempenho de um sistema. A frequência é o número de ciclos completos por segundo, sendo o período o tempo que estes ciclos se completam e o comprimento de onda o espaço percorrido pela onda neste período. Os relacionamentos destes parâmetros podem ser observados pelas duas próximas figuras que se seguem. Quanto menores as frequências, maiores serão os comprimentos de onda e maiores os alcances:




FIG 4-Comparação entre dois comprimentos de onda.

Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

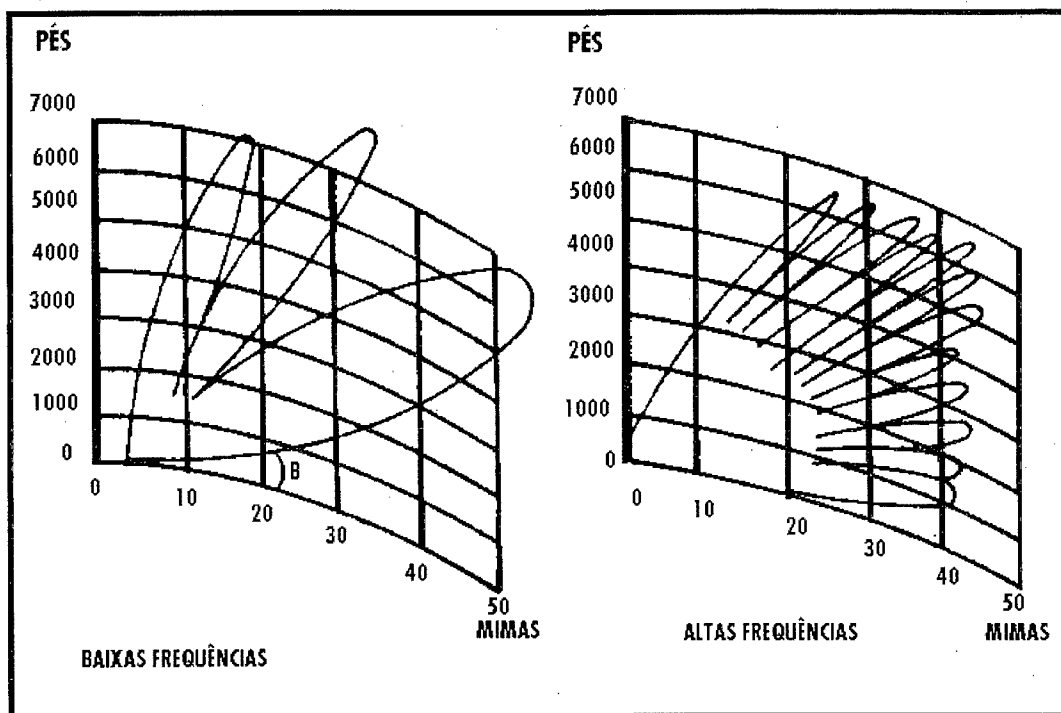


FIG 5-Relação de frequência e alcance.


Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

2.4.1.6 Tipos de varredura.

Este parâmetro é obtido pelas variações de intensidade do sinal de áudio e determinam o emprego do RADAR em questão. As figuras seguintes ilustram alguns dos tipos possíveis de varreduras.

Varredura circular.

Este tipo de varredura é o mais comumente encontrado, como também o mais simples. As antenas possuem uma boa direcionalidade horizontal, com um lóbulo que varia de 10° a 30° na vertical. Normalmente são utilizadas em radares de busca.




Varredura circular

FIG 6-Varredura circular.

Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

Varredura em setor:


Com setores fixos ou variáveis, este tipo de varredura é utilizada em radares de busca ou direção de tiro. Os setores podem ainda ser horizontais ou verticais, sendo que a maioria dos radares de busca utilizam a varredura por setor horizontal.



varredura por setor

FIG 7-Varredura por setor.

Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).



ponto A: dois pontos igualmente afastados.
 ponto B: dois pontos próximos em cada ciclo
 ponto C: dois pontos muito próximos em cada ciclo.

Vista de cima de uma varredura em setor

FIG 8- Varredura por setor-vista de cima.

Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

Varredura cônica:

Este tipo de varredura mede o deslocamento do alvo em relação ao eixo da antena, capacitando o equipamento a utilizar o acompanhamento automático. É mais utilizada em radares de direção de tiro.




FIG 9- Varredura cônica.

Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

Varredura com feixe em V:

Este tipo de varredura permite a obtenção de informações adicionais, além das normais de direção e distância, que é a determinação da altitude e com excelente precisão.




FIG 10-Varredura com feixe em V.

Fonte:(2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991).

2.4.1.7 Frequência da modulação de varredura.

As varreduras realizadas pelas antenas impõe uma modulação na transmissão, que redundando numa maior precisão em termos de marcação e distância. A frequência desta modulação é medida em SPR(segundos por rotação) na varredura circular,SPV(segundos por varredura) na varredura por setor e em Hertz nas demais. A determinação destas frequências por cronômetro ou equipamentos sofisticados permite que a relacionemos com o possível emprego de um RADAR[MAC91].

O conhecimento do relacionamento de alguns dos parâmetros acima citados do RADAR pulsado,tais como, largura de pulso,tipos de varredura realizada pelas antenas, frequência de repetição dos pulsos e frequência de transmissão, são os mais comuns para uma identificação destas emissões. Na concepção e na simulação de uma implementação conexionista que realizaremos neste trabalho, por uma questão de simplificação, não incluiremos os tipos de varredura das antenas, sugerindo esta análise para uma pesquisa posterior.

Pesquisas realizadas na aplicação de redes neurais em processos de identificação de emissões RADAR, podem ser encontradas em [DEN93]. Esta bibliografia, nos traz referências de implementações de redes neurais em equipamentos receptores, responsáveis pela análise de parâmetros.

Antes de efetivamente concebermos a implementação do modelo proposto, ressaltaremos alguns conceitos, que se referem a processos de aprendizagem, para que tenhamos uma visão preliminar de como algumas implementações poderiam se comportar inteligentemente e a teoria dos conjuntos difusos, que será a responsável pela trato com a incerteza inerente a este processo.

CAPÍTULO III

APRENDIZAGEM E CONHECIMENTO DIFUSO

3.1- Processos de aprendizagem.

Uma das discussões mais acirradas que encontramos quando da conceituação de máquinas inteligentes, é com relação a capacidade de absorção de novos conhecimentos.

Um grande passo para que esperemos um comportamento inteligente de uma máquina é informá-la de como se comportar aos diversos tipos de “inputs” recebidos, de forma a gradativamente melhorar o seu próprio desempenho, e para tanto podemos citar alguns paradigmas genéricos que nos torna possível esta tarefa.

A implementação dos processos de aprendizagem, fica como proposta para um próximo trabalho. Temos portanto, como objetivo tratarmos de maneira conceitual algumas premissas básicas. A protopéia (capacidade de aprender) pode ser verificada em sistemas computacionais simbólicos, onde a performance dos programas são otimizadas com o uso, ou em sistemas conexionistas, onde algoritmos podem fazer variar a relação dos pesos das conexões das redes neurais, ou ainda podem alterar parâmetros de elementos de circuitos VLSI [ARA88].

Uma das possíveis conceituações para a inteligência humana é quando uma pessoa se destaca pelo desempenho em certas atividades, e isto se torna visível quando esta pessoa demonstra uma determinada habilidade ou um certo grau de conhecimento a respeito de um certo domínio. No caso em questão, deveremos apenas esperar um comportamento inteligente de uma máquina, se fornecermos a esta o conhecimento ou a informarmos de como abstrair estes, a partir da interação com os “inputs” a que estiver submetida.

Basicamente temos três fontes de absorção de conhecimentos que podem ser utilizadas por homens ou máquinas, que serão vistos a seguir.

3.1.1 Aprendizagem por memorização.

Na aprendizagem por memorização temos a máquina absorvendo conhecimentos da forma mais rudimentar, ou seja, através do acúmulo dos dados. Esta forma de aprendizagem ocorre quando o recálculo dos dados é mais caro computacionalmente do que o seu armazenamento.

Apesar de trivial, alguns conceitos devem ser observados em implementações que requeiram este tipo de absorção de conhecimentos, que são a armazenagem organizada de dados e a generalização. A primeira citada, se torna

necessária, a medida em que a complexidade do problema aumenta e a segunda, a medida em que, a quantidade de fatos e objetos passíveis de serem colocados dentro de uma mesma classe se torna significativa.

3.1.2 Aprendizagem por aconselhamento:

Alguns programas em Inteligência Artificial melhoram significativamente o seu desempenho, quando recebem e são capazes de operacionalizar instruções específicas. Estas instruções podem, por exemplo, auxiliar estruturas de controle na busca da solução de um problema.

3.1.3 Aprendizagem por experiência.

Esta opção de aprendizagem se dá basicamente sem uma interação explícita com os "inputs", mas sim através de correlacionamentos realizados entre as estruturas utilizadas para a solução de um determinado problema e aquelas que serão necessárias para a solução de problemas novos com etapas semelhantes, ou até o mesmo problema, porém de um modo mais eficiente.

3.2 Conhecimento difuso.

Em certos domínios de conhecimento existentes, devemos lançar mão de ferramentas que nos possibilitem dimensionar a incerteza, como é o caso em questão do processo de identificação de emissões RADAR. Neste processo, uma mesma emissão pode possuir parâmetros, que a classifiquem como pertencente a mais de um tipo de RADAR.

Temos portanto, que os conceitos de informação e incerteza estão intimamente relacionados no processo de aprendizagem, que pode ser alcançado por um sistema, já que a medida que mais informações forem sendo apreendidas pelo sistema, menor será o grau de incerteza com que precisaremos lidar.

3.2.1 Abordagens para o trato com a incerteza.

Podemos citar algumas técnicas existentes na literatura[COH85], que procuram lidar com a incerteza, para que melhor nos situemos neste contexto.

Na heurística da diversificação, a incerteza é reduzida, dividindo-a entre vários eventos. Como por exemplo, numa corrida de cavalos, pode-se apostar em apenas um e torcer pela vitória, apesar do grande grau de incerteza ou pode-se diminuir esta incerteza diminuindo a aposta, mas apostando-se em todos ao mesmo tempo.

Uma segunda abordagem para o trato com a incerteza, é através do seu controle via estruturas que explorem a redundância que possa existir no processo.

Uma terceira abordagem que podemos citar se refere a teoria dos conjuntos difusos, que fornece um suporte teórico formal para o trato com a incerteza. Os conjuntos difusos permitem uma redução na complexidade através da flexibilização dos limites de pertinência.

3.2.2 Conceitos básicos de conjuntos difusos.

Um conjunto difuso pode ser definido matematicamente, atribuindo graus de pertinência do elemento ao conjunto, indicando o quanto de similar, que um determinado elemento possui com as características deste conjunto. Estes graus de pertinência, variam de 0 a 1, e são obtidos através de uma função de pertinência.

A utilidade da aplicação dos conjuntos difusos para uma determinada classe de problemas, depende de quanto a função de pertinência é apropriada para aquela determinada classe. Assim sendo, esta definição se torna o principal problema a ser resolvido, o que tem sido feito de forma empírica e através de testes sobre uma determinada população, de modo que se abstraia medidas de percepções subjetivas de pertinência.

Alguns conceitos básicos serão ressaltados para um melhor entendimento da utilização que será feita desta teoria. Iniciamos com o conceito de suporte de um conjunto difuso, que se refere ao conjunto de elementos do domínio que possuam um grau de pertinência diferente de zero, podemos melhor visualizar este conceito pelas próximas tabela e figura que se seguem[KLI88].

freq/ Giga	naveg	tiro	aérea	superficie
1	0	0	1	0
2	0	0	1	0
3	0	.8	.8	.1
4	0	1	.5	.2
5	0	1	.2	.4
6	0	1	.1	.6
7	0	1	0	.8
8	0	1	0	1
9	0	1	0	1

Tabela 1-Graus de pertinência relativos a valores de frequência.
 Fonte:(RICH, ELAINE and KEVIN,KNIGHT, Artificial Intelligence,1991.)

Nesta tabela , temos o relacionamento entre os valores de frequência em Giga Hertz, na primeira coluna e os seus respectivos graus de pertinência aos conjuntos difusos, formados pelos radares de navegação,tiro,busca aérea e busca de superfície.




FIG 11- Gráfico de graus de pertinência relativos a valores de frequência.
 Fonte:(RICH, ELAINE and KEVIN,KNIGHT, Artificial Intelligence,1991.)

Neste caso teremos que o suporte do conjunto difuso RADAR de tiro seria:

$$\text{Suporte(tiro)} = \{ 3,4,5,6,7,8,9\}$$

Uma notação utilizada para descrever conjuntos difusos é composta pelos pares formados pelos graus de pertinência e respectivos elementos do suporte e de acordo com o exemplo acima, teríamos que o conjunto difuso RADAR de tiro poderia ser descrito por:

$$\text{tiro} = .8/3, 1/4, 1/5, 1/6, 1/7, 1/8, 1/9.$$

A teoria dos conjuntos difusos é um dos modos mais simples e eficientes de realizarmos uma determinada simplificação, sem que haja a perda de informações relevantes. Esta teoria possibilita a flexibilização dos limites de pertinência existentes reduzindo a complexidade. Temos que inicialmente estabelecer uma relação satisfatória de custo-benefício entre a informação disponível e a quantidade de incerteza permitida, de modo que obtenhamos um grau mínimo de robustez. Ressaltamos que esta simplificação não implica necessariamente em perda de acuracidade ou significado. Assim temos que a teoria dos conjuntos difusos reduz a complexidade, eliminando o limite abrupto que define a pertinência de membros a um determinado conjunto.

Muitos outros conceitos poderiam ser explorados a respeito deste tema, porém esta pequena introdução é o suporte suficiente para abordarmos o nosso problema, maiores aprofundamentos podem ser obtidos em [KLI88],[KOS92].

3.2.4 Aspectos a serem considerados.

A teoria dos conjuntos difusos terá a sua aplicação melhor definida no decorrer deste trabalho. Será demonstrado como que funções de pertinência podem ser úteis na flexibilização de limites de pertinência. Esta flexibilização possibilita que haja uma redução da complexidade no trato com o problema, facilitando o seu tratamento.

É fundamental dentro do contexto de classificação de emissões RADAR, que haja meios de flexibilizarmos a definição da pertinência de alguns parâmetros a um determinado tipo de RADAR, pois um mesmo conjunto de parâmetros pode ser classificado dentro de mais de um tipo específico.

CAPÍTULO IV

CONCEPÇÃO HEURÍSTICA

4.1 Introdução.

Realizaremos neste tópico uma breve concepção heurística para solução do problema em questão. O uso de heurísticas na solução de um problema, se refere a inserção de conhecimentos específicos do domínio do problema nas estruturas responsáveis pela solução deste.

Esta concepção se encontra dentro do escopo da teoria geral de Inteligência Artificial(IA) e é aplicada para problemas que requerem processamentos simbólicos para a sua solução.

O objetivo de realizarmos esta breve concepção é de que possamos ter outros parâmetros, que nos possibilitem ao término deste trabalho, possuir um suporte conceitual que nos faculte ressaltar algumas características do modelo que será proposto.

Uma das principais características desta abordagem são estruturas que capazes de imitar os processos humanos de raciocínio, e isto é possível, através de ferramentas computacionais próprias que fornecem aos computadores uma grande capacidade de manipulação simbólica.

A utilização de heurísticas pressupõe a existência de estruturas que sejam responsáveis pela manipulação de base de conhecimentos, de modo que possa ser inserida nestas estruturas ou na própria base.

A inserção de heurísticas na base de conhecimentos, nos possibilita tornar os dados ativos diante do código responsável pela sua manipulação, diferentemente do que ocorre nos programas algorítmicos normais. Consideraremos neste caso, o código como mero interpretador dos conhecimentos que estão na base. Esta base de conhecimentos pode ser atualizada por novas cláusulas, que podem melhorar a performance obtida. A inclusão de novas cláusulas, pode se dar em função de interações que possam ocorrer com “inputs”específicos, o que caracterizaria um processo de aprendizagem.

4.2 O PROLOG.

O nosso objetivo neste tópico é expormos um pequeno exemplo em PROLOG. Esta ferramenta é composta de um interpretador e uma base de conhecimentos, sendo a sua utilização bastante trivial. O programador necessita

apenas inserir na base de conhecimentos um conjunto de cláusulas, que se relacionam de maneira lógica, ou seja, para que uma cláusula seja verdadeira todas as suas partes conjuntivas o devem ser.

O PROLOG é uma linguagem que utiliza a lógica de predicados e que procura por regras e fatos na base de conhecimentos que justifiquem um determinado objetivo[CHR87], este conceito poderá ser melhor observado no exemplo que será dado a seguir.

O caminho a ser seguido pelo interpretador é determinado pelas declarações contidas na base de conhecimentos, que será o ponto onde poderão ser incluídos os conhecimentos heurísticos[BRA86].

Esta estratégia parte da declaração a ser provada para a procura de fatos(constantes dentro de predicados) ou regras, cujo lado esquerdo coincida com a declaração do problema. Um procedimento de unificação é aplicado para se determinar quais fatos ou regras que podem ser aplicadas ao problema. Os caminhos são considerados segundo uma estratégia de busca em profundidade com retrocesso, e caso ocorra mais de uma parte conjuntiva, as partes deverão ser provadas na ordem em que aparecem.

Uma aplicação prática do PROLOG pode ser visualizada com um pequeno exemplo, cujo código fonte é exposto a seguir.

Neste exemplo podemos observar a realização de uma pesquisa numa lista(fregradar), que contém valores de frequência que podem ser encontrados num RADAR hipotético. Esta lista é um termo composto por um predicado(fregradar) e argumentos(5000,4000,3000,2000). Na cláusula seguinte(parametro_radar) podemos observar as várias partes conjuntivas, que separadas por vírgulas deverão ser provadas na ordem em que aparecem. Esta cláusula só obterá sucesso se realizar todas as partes conjuntivas com sucesso. As partes conjuntivas serão responsáveis pela leitura do dado, pela sua atribuição a uma variável e pela chamada de uma outra cláusula(achafreq) que será a responsável pela pesquisa do dado fornecido na lista existente.

Exemplo de um programa em PROLOG.

```
fregradar(5000,4000,3000,2000). / Lista de possíveis frequências de um RADAR./
parametro_radar:-cls,write('Informe frequencia do do RADAR : '),nl, / Pede a
frequencia /
    read(Frequencia), / Lê a freqüência /
    assert(freq(Frequencia), / Atribui o valor lido a uma variável/
    achafreq(freq,fregradar). / Determina se o parâmetro informado /
    / pertence ao RADAR em questão/
achafreq(X, []) :- write(X), tab(1), write('nao existe '),!, fail. /Pesquisa se a lista /
```

```
achafreq(X, [X|Xs]):- write(X), tab(1), write("e parametro"), !, /possui o parametro /  
achafreq(X, [_|Xs]):- achafreq(X,Xs). /informado/
```

Neste pequeno exemplo podemos destacar alguns pontos importantes.

Este código representa a base de conhecimentos que pode ser atualizável, sendo composta por fatos(lista freq radar- representação declarativa) e regras(cláusulas parametro_radar e achafreq- representação procedimental). O interpretador PROLOG seguirá o fluxo determinado pelas cláusulas.

O PROLOG possibilita através da cláusula (assert), que neste caso foi utilizada para atribuir um valor a uma variável, que possamos inserir na nossa base de conhecimentos, cláusulas novas. A inserção destas cláusulas poderia ser efetivada se alguma pré-condição fosse satisfeita, como por exemplo, o aparecimento de um determinado "input". Assim teríamos numa próxima execução desta base pelo interpretador, o caminho seguido e as ações realizadas diferentes da execução anterior, o que poderia melhorar o desempenho da aplicação e caracterizar um processo de aprendizagem.

A estratégia de controle utilizada pelo interpretador PROLOG(busca em profundidade com retrocesso) pode ser bem visualizada na execução da última cláusula, quando o interpretador pesquisará em todos os elementos da lista se há algum elemento coincidente com o parâmetro informado, até que uma condição de contorno, que seria uma lista vazia, seja alcançada.

Este pequeno código poderia ser aperfeiçoado, de modo que pudéssemos realizar pesquisas de parâmetros informados, em várias listas, realizando a identificação de algum conjunto de parâmetros, com um determinado tipo de RADAR. Como já foi citado, a base poderia ser atualizada em função de "inputs" que pudessem aparecer, caracterizando um comportamento inteligente, desde que houvesse uma melhora na performance.

No PROLOG é utilizada a hipótese do mundo fechado, onde os fatos importantes e aqueles que podem ser derivados estão contidos na base de conhecimento, ou seja, aqueles que lá não estiverem, por exclusão, não são considerados relevantes. O PROLOG possui como principais vantagens o fato de que o programador necessita apenas satisfazer determinadas regras e fatos, visto que a estrutura de controle é fixa, apesar de permitir com restrições alterações neste processo[RIC91].

O PROLOG assim se apresenta, como uma boa alternativa para que demonstremos um perfeito casamento entre as formas declarativas e procedimentais de representação de conhecimento, haja visto, a forma como o conhecimento é representado, através de fatos e regras. Isto nos possibilita que ao concebermos uma base de conhecimentos no PROLOG, estaremos dizendo ao seu interpretador qual

caminho seguir, a despeito de sua estratégia de controle ser fixa. Podemos conceber uma base de conhecimentos, de forma que esta possa ser alterada por novos “inputs”, caracterizando desta forma a aprendizagem.

As características acima citadas do PROLOG são bastante úteis para a concepção de um sistema que se baseasse no conceito intuitivo que possuímos do especialista humano. O especialista é o indivíduo detentor de uma vasta gama de conhecimentos específicos. Deste indivíduo, se espera decisões ou sugestões de assessoramento e estas, este faz a partir de uma base de conhecimentos que adquiriu durante a sua formação ou durante a sua vivência profissional. Estas decisões ou sugestões, além dos conhecimentos acumulados pressupõe hipóteses. Hipoteses estas, que são formuladas a partir de inferências realizadas sobre fatos e hipóteses antigas utilizando novos “inputs”, que chegam ao sistema.

Podemos então definir uma possível implementação heurística, como um sistema computacional que fosse capaz de utilizar uma base de conhecimentos limitada a uma determinada área, de modo que, seja capaz de acrescentar sobre esta base novos conhecimentos, inferir hipóteses, e tomar decisões ou fornecer sugestões.

Naturalmente surgem algumas perguntas, tais como, qual é realmente a característica que diferencia esta abordagem dos métodos algorítmicos convencionais e quais seriam as reais vantagens de sua utilização.

4.3 Diferenças básicas entre as abordagens heurística e algorítmica.

Iniciando com a característica que diferencia esta abordagem, temos que um programa convencional será sempre repetitivo, sendo os desvios de fluxo uma exceção e os dados sempre passivos diante do código. Na abordagem heurística, alguns dados são substituídos por conhecimentos, que ao contrário dos primeiros, se tornam ativos diante do código, direcionando o seu fluxo de acordo com a sua estrutura atual. Esta estrutura pode ser alterada de acordo com novos “inputs”, o que caracteriza o processo de aprendizagem e o comportamento inteligente do sistema.

Isto posto, podemos ressaltar que as principais vantagens desta abordagem, além da faculdade da aprendizagem, são:

- A base de conhecimentos é atualizável e passível de ser intercambiada entre vários elementos de uma mesma classe profissional, disseminando-se assim o conhecimento e melhorando o rendimento da referida classe.

- A utilização deste sistema, nos possibilita que mantenhamos a base de conhecimentos independentemente dos processos inferenciais, que dão suporte a sua

atualização , inferência de hipóteses, e tomada ou fornecimento de decisões, de forma, que temos uma grande versatilidade de utilização para estas informações.

4.4 Aspectos relevantes na identificação de emissões RADAR.

Com relação à inserção da teoria dos conjuntos difusos neste contexto, duas são as considerações que devem ser realizadas com relação à estrutura de conhecimento:

- O conhecimento é uma informação que terá a forma de fatos ou regras, sendo que estes poderão estar relacionados a fatores de certeza. Os fatores de certeza em questão se referem aos graus de pertinência que cada emissão deverá possuir em relação a um determinado conjunto difuso, que serão representados pelos diversos tipos de RADAR.

-O conhecimento é a informação que o programa precisa para se comportar inteligentemente. O fator de certeza se relaciona com a validade do fato ou a acuracidade da regra, que representam o conhecimento.

Para a inclusão de graus de pertinência nas emissões, ou mais propriamente nos parâmetros das emissões, podemos lançar mão de uma função de pertinência que acreditamos ser necessária e suficiente para modelarmos esta imprecisão. Os tipos de RADAR serão considerados, como os conjuntos difusos que serão definidos pelo mapeamento que a função de pertinência realizará entre os valores de cada parâmetro das emissões consideradas com cada grau de pertinência.

Uma possível função de pertinência é a que se segue[KLI88].

$$\mu(x) = \frac{1}{1 + 10(x - a)^2}$$

Onde temos que:

$\mu(x)$ --> grau de pertinência obtido.

x --> valores dos parâmetros a serem considerados.

a --> valor central que possuirá o maior grau de pertinência em relação ao conjunto difuso considerado.

Esta função tem a seguinte curva:

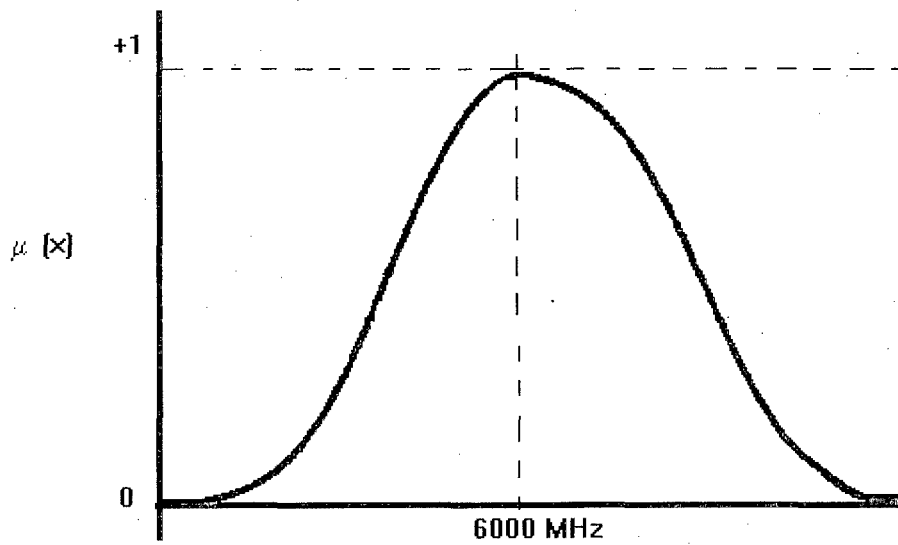


FIG 12-Gráfico representativo de uma função de pertinência.
Fonte:(RICH, ELAINE and KEVIN,KNIGHT, Artificial Intelligence,1991.)

Neste caso podemos considerar , o conjunto difuso como um RADAR de tiro, que poderia conter várias emissões com diferentes graus de pertinência, e o parâmetro (a) como o valor de 6000 MHz, que neste caso seria a frequência que melhor identificaria este conjunto.

CAPÍTULO V

ABORDAGEM CONEXIONISTA

5.1 Introdução.

O objetivo do estudo das redes neurais é o de tentar reproduzir o sistema de processamento humano nas tarefas de classificação de padrões. Estes modelos são compostos por elementos computacionais, que na maioria das vezes são não lineares, e lembram a estrutura nervosa do cérebro humano. Neste tópico trataremos das redes neurais dentro do seu paradigma clássico, que é o de sua apresentação em camadas. Os elementos acima citados são interligados por conexões, que possuem pesos ajustáveis durante o uso da rede, visando o aprendizado e a otimização da performance.

A estrutura do nosso sistema biológico de classificação de padrão, que é o grande inspirador dos modelos conexionistas, atua graças a interação, em tempo real, de milhões de neurônios competitivos e cooperativos, que garantem uma identificação em alta velocidade e de forma distribuída [DAY90].

Pesquisas em novas topologias de rede, novos algoritmos de aprendizagem, técnicas analógicas de implementação VLSI e a crença que um massivo paralelismo é essencial para bom desempenho nas tarefas de classificação de padrão, deram um grande impulso na pesquisa nesta área[HOP86].

Estes modelos, que serão citados, são blocos construtivos massivamente paralelos que ilustram os componentes de uma rede neural e os princípios de design, sendo que podem ser usados para a construção de modelos mais complexos.

5.2 Estruturas tradicionais de redes neurais.

5.2.1 Características básicas

As redes neurais de uma maneira geral tentam realizar boas performances nas tarefas de classificação de padrões, via uma densa interconexão de simples elementos computacionais. Para tanto é necessário que muitas hipóteses sejam perseguidas em paralelo à altas taxas de computação, o que torna os atuais sistemas computacionais pouco eficientes, quando comparados à performance humana.

Um outro ponto a ser ressaltado é na possibilidade de alguns algoritmos de classificação e "clustering" poderem ser realizados, utilizando componentes simples parecidos com neurônios. Redes de uma única camada podem implementar

algoritmos requeridos por classificadores gaussianos de máxima probabilidade e classificadores ótimos de erro mínimo para padrões binários corroidos por ruídos[LIP87].

Estes elementos computacionais são bem menos complexos que as CPU's que conhecemos, sendo tipicamente analógicos e não lineares, na maioria das vezes. A tarefa realizada por um simples nó é a soma dos inputs ponderados, sendo o resultado passado como operando a uma função não linear. O nó é caracterizado por um limiar interno e por um tipo de não linearidade, que na maioria das vezes se apresentam como funções sigmoidais. Nós mais complexos podem incluir integração temporal ou outros tipos de dependências além de operações mais complexas do que a soma. Um processador característico pode ser observado na figura 13.

Os modelos de redes neurais de uma forma geral são especificados pela topologia da rede, características dos nós e as regras de treinamento ou aprendizagem. Estas regras especificam um conjunto inicial de pesos e indicam como estes pesos devem ser adaptados durante o uso da rede para melhorar a performance. Estes dois tópicos de design e regras de treinamento são as áreas de maior pesquisa.

Os benefícios potenciais das redes neurais se estendem além das altas taxas de computação fornecidas pelo paralelismo massivo. Devido ao grande número de nós, estes modelos suportam um elevado grau de tolerância à perdas em relação às arquiteturas convencionais.

A capacidade de se adaptar e continuar aprendendo é fundamental em áreas onde os "inputs" variam bastante. Como por exemplo, temos no processo de reconhecimento de voz, onde existe uma grande variação de locutores, palavras, frases e ambientes. A adaptação também fornece um grau de robustez para compensar as variações existentes entre processadores. Esta característica adaptativa é a grande vantagem sobre as técnicas estatísticas de classificação de padrões.

Estes modelos conexionistas provam ser mais robustos quando distribuições são geradas por processos não lineares e fortemente não gaussianos[LIP87].

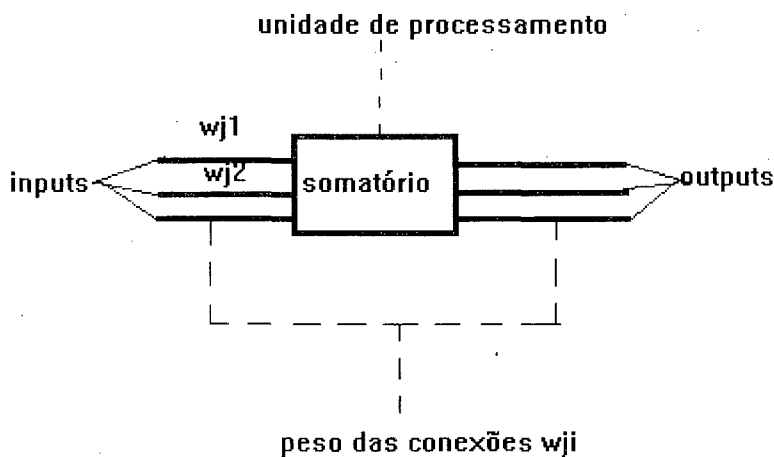


FIG 13- Entradas e saídas típicas de um processador.

Fonte:(DAYHOFF JUDITH,Neural Networks Architectures:An Introduction, 1990).

As redes neurais como sistemas maciçamente paralelos, se baseiam em arranjos densos de interconexões de processadores extremamente simples, que é a característica responsável pelo seu grande poder classificador e que servem atualmente para a soluções de problemas que atualmente ou são intratáveis, ou inconvenientes de serem tratados pelas arquiteturas convencionais de computadores.

A arquitetura básica das redes neurais se baseia numa simplificação da estrutura existente nas células nervosas do cérebro e reflete as funções básicas destas, sendo que oferecem uma abordagem efetiva para um largo espectro de problemas. Estas arquiteturas se sobressaem para problemas que envolvam delineamento, completamento ou classificação de padrões, como por exemplo: traslado de imagens dentro de palavras chaves ou mapeamento de imagens para comandos robóticos.

5.2.2 Diferenças básicas entre as redes neurais e a máquina de VON NEWMAN.

As máquinas tradicionais possuem apenas uma CPU que é capaz de realizar mais de uma centena de comandos básicos e em sequência, ao passo que, os processadores das redes neurais realizam uma ou no máximo, algumas poucas operações de forma paralela.

Uma função de soma é realizada nos seus "inputs" e trocas incrementais são realizadas nos parâmetros associados às interconexões para o ajuste destas. Esta simples estrutura é que caracteriza as redes neurais como ferramentas classificadoras de padrões ou realização de delineamento de padrões.

A arquitetura das redes neurais difere basicamente do processamento paralelo mais tradicional, pela maior proporção das interconexões em relação aos processadores, além de que estes processadores são comparáveis em complexidade às CPUs das máquinas tradicionais[DAY89].

Numa abordagem algorítmica para um problema de classificação de padrões, teríamos que realizar um pré-processamento de uma determinada imagem a ser classificada, seguida de um análise humana para determinar as principais características, para então desenvolvermos algoritmos específicos para a identificação de cada tipo de figura ou imagem.

Considerando uma abordagem conexionista para o mesmo problema, teríamos da mesma forma um pré-processamento da imagem, porém não teríamos a necessidade de desenvolvimentos de algoritmos e ainda poderíamos utilizar a mesma rede para a identificação de vários padrões, sendo que após cada apresentação, os pesos seriam reajustados automaticamente. Este treinamento é repetido várias

vezes, sendo que após o treinamento, a rede pode identificar os padrões para os quais foi treinada ou pode ser treinada para outros padrões totalmente diferentes[DAY90].

Se por um lado são poupados esforços pela não necessidade de desenvolvimentos de algoritmos ou utilização de recursos humanos na identificação de características, por outro, existem obstáculos que se resumem no tempo de treinamento, que pode ser desconhecido e na complexidade envolvida no “design” de uma rede, que possa ser utilizada para diversas aplicações.

As redes neurais podem inferir classificações de padrões desconhecidos, ou seja, para os quais não tenha havido treinamento específico, a partir de sua organização interna. Neste caso deverá existir uma camada de microprocessadores, que seja responsável pela detecção de características a partir das diferenças entre as classes de padrões apresentados para o treinamento da rede. Portanto, os padrões apresentados para o treinamento desta rede, devem se referir a classes genéricas e não simplesmente exemplos específicos.

5.2.3 O relacionamento das redes neurais com o cérebro humano.

Os neurônios do cérebro humano recebem “inputs” e os transferem da mesma forma a outros neurônios através de estruturas especializadas, as sinapses e os axônios. As sinapses podem ser basicamente de duas formas, as “excitatórias” e as “inibitórias”, recebendo a primeira, o neurônio terá mais possibilidade de disparar uma determinada ação, sendo na segunda, a possibilidade menor, poderíamos assim correlacionar estes estados com os pesos das conexões.

Os neurônios diferentemente da estrutura de uma rede neural, que pode ser binária ou contínua, só podem operar de forma contínua e podem ser entendidos numa primeira análise como um conversor de tensão em frequência.

5.2.4 Limitações relacionadas às estruturas das redes.

As limitações encontradas pela estruturas mais simples, formadas por no máximo duas camadas, possuem limitações, como por exemplo trabalhar com o OR-exclusivo. Limitações estas porém, que são superadas facilmente, com o acréscimo do número de camadas[MIN69].

5.2.5 Hard e soft para redes neurais

Duas são as principais características que podemos citar nestes tipos de sistemas e estas se referem ao massivo paralelismo presente nas arquiteturas das redes neurais e a forma distribuída do processamento, onde poderemos ter vários elementos computacionais trabalhando ao mesmo tempo numa mesma informação.

Para que este paralelismo seja realmente eficiente, é necessário que tenhamos em mente, que não poderemos lançar mão da mesma filosofia de desenvolvimento de soft que era utilizado pela computação sequencial tradicional.

Os algoritmos usados em redes fazem uso de muitos elementos idênticos, interconectados e arranjados em vetores paralelos, e por isso são quase que na sua maioria paralelos.

Este tipo de softt deve ser implementado em hard especial e possui como característica fundamental a necessidade de se integrar e utilizar grandes quantidades de informação. Um dos grandes problemas para o desenvolvimento de “softs” para redes neurais é que a distribuição das informações facilita que os erros também possam se propagar, o que torna a tarefa de depuração um tanto quanto difícil[JAC87].

Algumas características que ainda podemos citar, se referem a representação do conhecimento dentro destes sistemas. Nos sistemas neurais, não é possível a interação com o usuário, de forma que este possa ter uma maior segurança, tendo acesso à como que o sistema chegou a determinada resposta, a exemplo do que é realizado pelos sistemas especialistas. Uma outra característica, semelhante aos sistemas simbólicos é de que o desempenho da rede depende diretamente de como o conhecimento é representado.

5.2.6 Aplicações em potencial.

As aplicações para as redes neurais se verificam nas mais variadas áreas. Principalmente nas tarefas que requerem classificação, mapeamento e completamento de padrões a partir de dados incompletos. Citamos por exemplo, os processos de síntese e reconhecimento de voz, análise e processamento de imagens, classificação de sinais sísmicos e de RADAR e controle adaptativos. Além destas aplicações podemos também executar tarefas que lidem com processamento de conhecimento e implementações de memória associativa.

5.2.7 Escolhas de design.

Algumas opções devem ser realizadas antes que se passe à implementação propriamente dita de uma rede neural. Estas se referem a identificação dos tipos de padrões que devem ser representados e a forma de se representar estes padrões(esquema de representação).[DAY90].

As escolhas subsequentes são referentes a topologia, tamanho e número de camadas da rede, número de unidades de processamento e as respectivas interconexões. Alguns parâmetros dinâmicos devem também ser determinados e se referem aos processamentos específicos que são realizados pelas unidades e a forma como seus parâmetros internos são ajustados.

Os ajustes destes parâmetros seguem alguns paradigmas , entre estes citamos alguns como: propagação reversa do erro ,aprendizagem competitiva e inibição lateral e outros um pouco mais complexos que utilizam os primeiros como blocos construtivos, tais como, “Kohonen feature maps” e contra propagação. Alguns parâmetros internos da rede devem ser ajustados para otimizar o processo de aprendizagem, e estes parâmetros variam de acordo com o paradigma escolhido, como por exemplo na propagação reversa do erro, o parâmetro a ser ajustado experimentalmente é a taxa de aprendizagem. Uma rede de três camadas onde pode ser implementado a aprendizagem da propagação reversa do erro pode ser observada na figura 14.

Uma ultima opção de “design” que deve ser realizada é o conjunto de exemplos que serão apresentados para o treinamento da rede,sendo que a qualidade destes influenciará sobremaneira no desempenho desta rede. Logicamente que temos a possibilidade de combinarmos várias redes, cada qual com seu paradigma, de forma a obtermos melhores performances.

5.2.8 Implementações de redes neurais.

Além da simulação de redes neurais em computadores convencionais , que conforme o caso, podem vir acompanhados de processadores paralelos,tais como co-processadores matemáticos ou processadores de vetores, a implementação pode se dar em “hard” especializado, composto por componentes eletrônicos, pela utilização de dispositivos semi-condutores ou ainda pela combinação de computadores digitais e analógicos[DAY90],[MEA89].

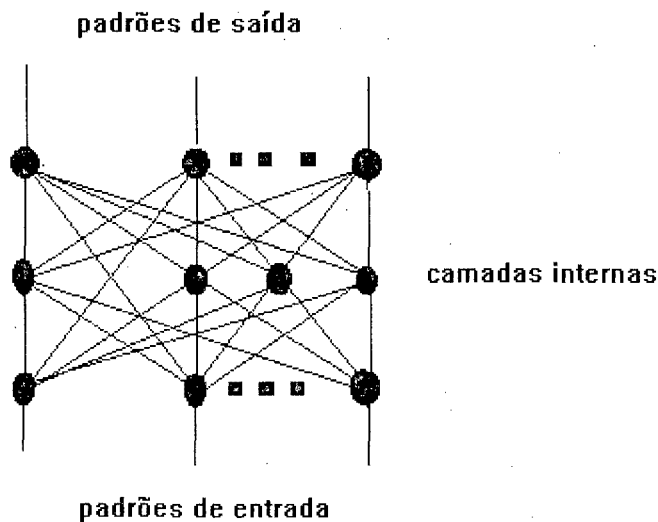


FIG 14-Exemplo de uma rede de três camadas.
 Fonte:(DAYHOFF JUDITH,Neural Networks Architetures:An Introduction, 1990).

5.2.9 Aprendizagem

5.2.9.1 Aprendizagem como mudança.

Aprendizagem e adaptação, no nosso caso, significam basicamente troca de valores de parâmetros, e fazem parte do comportamento inteligente de um sistema. Um sistema inteligente deve aprender novas associações, novos padrões, e novas dependências funcionais. Estes amostram o fluxo de experiência e codificam novas informações, comprimem ou quantizam o fluxo em pequenos, porém representativos conjuntos de protótipos. A amostragem dos dados muda os valores dos parâmetros do sistema, sendo que estes podem ser, por exemplo, pesos numéricos num produto interno de soma.

Aprendizagem significa invariavelmente mudança, e isto formalmente só é possível de ocorrer, se o vetor ou matriz dos parâmetros do sistema tem uma derivada em relação ao tempo diferente de zero. Em redes neurais a teia “sináptica” (o conjunto de valores que representam os pesos) é mormente representada por uma matriz e em assim sendo, temos que a aprendizagem será qualquer mudança em qualquer valor desta matriz.

As leis de aprendizagem descrevem um sistema dinâmico “sináptico”, como um sistema que codifica informação. Podemos imaginar um sistema dinâmico que codifica e decodifica informação, transformando estados iniciais em estados finais. As condições iniciais e as perturbações codificam as questões. O comportamento intermediário computa as perguntas. O ponto de equilíbrio fornece as respostas. Um exemplo no qual podemos observar o equilíbrio de um sistema dinâmico fornecendo as respostas, é através das respostas da rede de Hopfield, conforme pode ser observado na figura 15. Neste exemplo o padrão é identificado após a convergência da rede

Sistemas inteligentes devem ter a capacidade de generalizar. O seu conjunto de respostas excedem a sua experiência e estes sistemas devem ser capazes de associar respostas similares à estímulos similares.

Ressaltamos que existem dois tipos básicos de aprendizagem, que se referem quanto à presença ou não de supervisão no processo. No primeiro caso, teremos um processo de aprendizagem supervisionado, a medida em que for apresentado à rede uma resposta esperada desta, para cada “input”, o que servirá como parâmetro para possíveis correções, o inverso ocorre no segundo caso.

Após estas breves considerações, abordaremos de forma conceitual alguns processos de aprendizagem básicos existentes na literatura, apenas com o intuito de

bem situar a teoria das redes neurais, sem o real interesse de discussões mais profundas sobre este assunto.

5.2.10 Paradigmas de aprendizagem

5.2.10.1 Propagação reversa do erro.

Este paradigma pode ser utilizado em qualquer tarefa que exija mapeamento de padrões, variando desde aplicações militares como reconhecimento de emissões sonar de alvos até diagnósticos médico. Dado um padrão de entrada, a rede produz um padrão de saída associado. A facilidade de emprego deste algoritmo de aprendizagem se dá pela sua forma bastante trivial e intuitiva de correção dos erros. Os pesos são corrigidos em função das respostas erradas fornecidas pela rede[RUM89].

As redes que utilizam este paradigma normalmente possuem várias camadas, e quando são apresentadas a um valor de entrada, estes são propagados entre as camadas. O erro assim gerado é retornado em sentido contrário, provocando a correção dos pesos.

Este paradigma foi uma avanço em relação ao perceptron, que era limitado à somente duas camadas de unidades de processamento, com uma única camada de correção dos pesos. A limitação obtida resultava do fato dos padrões serem obrigatoriamente linearmente separáveis, fato este suplantado pelo paradigma em questão.

Este paradigma é notório pela sua capacidade de treinamento das camadas internas, não sendo restrito desta forma as limitações impostas pelos sistemas com uma única camada.

As camadas internas agem como unidades detetoras de características, respondendo por características específicas do padrão de entrada. É a correta distinção das características que nos permite classificar diferentes padrões, sendo que este paradigma o executa de forma automatizada. Basicamente uma rede que utiliza este paradigma possui no mínimo três camadas, uma de entrada, uma interna e uma de saída. As unidades de uma mesma camada podem ou não se comunicar, porém via de regra, se comunicam com todas as unidades das outras camadas.

A primeira camada tem como função apenas receber os “inputs” e passá-los às camadas internas através de conexões que possuem pesos. As unidades das camadas internas, por sua vez, recebem estes valores e procedem a uma soma ponderada. Este somatório é utilizado como operando de uma função, que pode ser por exemplo uma função sigmoideal, sendo o resultado passado para as camadas superiores até que cheguem à camada externa. Nesta camada haverá uma comparação destes valores com os valores apresentados como padrão, que fazem par

com os valores de entrada. A diferença causada entre os valores obtidos pela rede e o padrão são usados para o ajuste dos pesos de todas as conexões que chegam a camada externa. Em seguida estes erros são calculados para todas as unidades das camadas internas e os pesos que chegam a estas camadas ajustados. A dimensão deste erro definirá a dimensão a ser realizada nas respectivas conexões[DAY90].

A correção do peso da conexão é proporcional ao valor do erro calculado, ao valor de ativação da unidade de saída da conexão e a uma taxa de aprendizagem da rede definido pelo usuário e que varia de 0.25 a 0.75, sendo que valores muito elevados podem levar a uma instabilidade da rede.

Alguns parâmetros podem ser usados para medir a convergência do processo de aprendizado de uma rede, quanto menor o seu valor, mais próxima a rede estará de um nível confiável de respostas a serem obtidas. Isto é necessário porque não obteremos da rede, respostas como certo ou errado e sim, padrões que poderão estar próximos ou não do desejado. Problemas como um longo tempo de treinamento ou a convergência para mínimos locais, fazem parte deste processo e o tornam sujeito a um certo grau de indefinição. Técnicas específicas existem para minimizar estes problemas, porém não serão abordadas aqui.

5.2.10.2 Aprendizagem competitiva e inibição lateral.

No paradigma da aprendizagem competitiva, as unidades de cada camada competem entre si, sendo que a estas redes é apresentado um conjunto de padrões de entrada para o treinamento, sem que haja padrão de saída correspondente. A resposta é obtida em termos de classes de padrões. Este comportamento caracteriza o aprendizado não supervisionado, útil quando a classificação exata dos padrões não é conhecida, porém os dados desta classificação, podem ser agrupados por características em diferentes categorias.

Estas redes basicamente possuem duas camadas, uma de entrada e uma competitiva, onde as unidades de processamento irão competir entre si para responder ao padrão de entrada. O vencedor representará a resposta certa para o padrão de entrada. Este processo é acompanhado por um algoritmo que determina a classe vencedora[RUM86].

Neste paradigma cada interconexão existente entre as duas camadas possui um peso, que podemos restringir por questão de simplificação a valores de 0 a 1, bem como restringir o valor do somatório dos pesos que chegam a cada unidade de processamento a 1. Os pesos são setados aleatoriamente de forma a satisfazer a restrição imposta anteriormente ao somatório. Os vetores de entrada também serão binários. A soma ponderada é realizada em todas as unidades de processamento na camada competitiva, multiplicando os pesos de cada conexão pelo valor de ativação de cada unidade de processamento da camada de "inputs". A competição se

concretiza com a computação da unidade que contenha o maior resultado de sua soma ponderada.

O próximo passo será o ajuste dos pesos, sendo que somente os pesos da unidade vencedora serão ajustados, pela seguinte fórmula:

$$\Delta W_{ji} = g((x_i/m) - W_{ji})$$

Eq 5.1

onde temos:

g-> parâmetro de aprendizagem(0 a 1).

x_i-> valor de ativação da unidade extrema daquela conexão.

m->número de unidades de ativação que contém valores de ativação iguais a 1.

W_{ji}-> peso inicial.

ΔW_{ji}-> variação do peso.

Este valor, desta forma calculado será incrementado se o valor de ativação da unidade origem for igual a 1 e decrementado se for 0.

Este processo deverá ser repetido várias vezes e para diversos padrões de forma, que a rede possa computar respostas a diversos padrões a serem apresentados.

Neste paradigma cada unidade da camada de competição se especializa em selecionar um determinado tipo de padrão, sendo esta unidade a responsável pela resposta da rede aos diversos padrões que lhe são apresentados.

Um sistema competitivo de aprendizagem tende a formar “cluster” de determinados padrões de entrada, se os exemplos de entrada forem suficientemente distintos. O sistema se transforma assim num sistema estável, o contrário ocorrerá se os padrões de entrada não forem suficientemente distintos.

Um outro paradigma que junto com o anterior formam os elementos básicos para estruturas mais complexas é o de aprendizagem por inibição lateral, a diferença básica é de que a competição existe apenas entre as unidades de processamento vizinhas, além de possuir apenas uma única camada. Este procedimento é encontrado na natureza em atividades que requeiram a eliminação de contrastes, como por exemplo nos sistemas auditivos[BUL77].

5.2.11 Taxonomia das redes neurais.

Citaremos alguns modelos das redes neurais tradicionais, que podem ser classificados em dois grandes grupos, quais sejam, os que recebem “inputs” binários

e aqueles que trabalham na identificação de padrões formados por “inputs” contínuos. Dentro desta divisão ainda podemos sub-dividi-los em classes de modelos que variam de acordo com o tipo de aprendizagem a que podem ser submetidos, que pode ser supervisionada ou não[LIP87].

5.2.11.1 Rede de Hopfield

Usada com memória associativa ou para resolver problemas de classificação de padrões, a rede de Hopfield é específica para trabalhar com inputs binários. A saída de cada nó é enviada para todos os outros nós da rede via pesos específicos de cada conexão. Estes pesos são especificados em função dos padrões a serem reconhecidos.

Um padrão para o qual, a rede já tenha sido treinada e que esteja corroído, pode ser recuperado, e para tanto é dado como “input” à rede, forçando o seu “output” à casar com este padrão. A rede interage até que haja a convergência, o que ocorre quando não se observa mais variações dos “outputs”, quando é considerado que houve uma resposta da rede. A figura que se segue é um exemplo típico das respostas de uma rede de Hopfield. Neste caso a rede foi treinada para reconhecer os padrões de 0 a 8 e o padrão de entrada a ser reconstituído foi o numero 8.

0 1 2
3 4 5
6 7 8

8 8 8
8 8 8
8 8 8

FIG15- Resposta de uma rede de Hopfield após a convergência.

Fonte:(RICHARD P.LIPPMANN, An Introduction to Computing With Neural Nets, 1987).

A rede de hopfield, usada como memória associativa, dará a sua resposta em termos de recuperação do padrão apresentado na entrada e quando utilizada como classificadora de padrões, a resposta será a comparação do “output”, após a convergência, com exemplares de algumas classes.

Esta rede tem duas importantes limitações, quais sejam, o número de padrões que podem ser arquivados é limitado, sendo que se um número excessivo de padrões for arquivado, a rede pode convergir para um padrão diferente de todos os especificados. A segunda limitação é que o padrão de entrada será considerado instável se possuir muitos bits em comum com outros padrões, sendo que procedimentos existem para que se evite este problema.

5.2.11.2 Rede de Hamming

Neste tópico, não entraremos nos detalhes de implementação, apenas citaremos algumas características e vantagens sobre a rede de Hopfield.

Os exemplos que servem para testar a performance da rede de Hopfield, são obtidos quando invertemos aleatoriamente os bits de um determinado exemplar de acordo com uma determinada função de distribuição de probabilidade.

A rede de Hamming neste caso pode implementar um algoritmo classificador ótimo de erro mínimo, calculando a distância de Hamming para o exemplar de cada classe. A distância de Hamming será o número de bits entre o exemplar e o padrão distorcido de entrada que não se casam. O exemplar selecionado será aquele com a menor distância calculada. Com a implementação deste algoritmo pela rede de Hamming, verifica-se uma performance melhor do que a obtida pela rede de Hopfield. Comparações entre as duas redes em casos de reconhecimento de caracteres aleatórios tem demonstrado esta diferença em performance. O número de conexões requeridas também é sensivelmente menor, pois a diferença em número de interconexões requeridas aumenta linearmente com o acréscimo do número de inputs, já na rede de Hopfield o acréscimo é proporcional ao quadrado do número de "inputs". Um exemplo de uma rede de Hamming pode ser observado na figura 16.

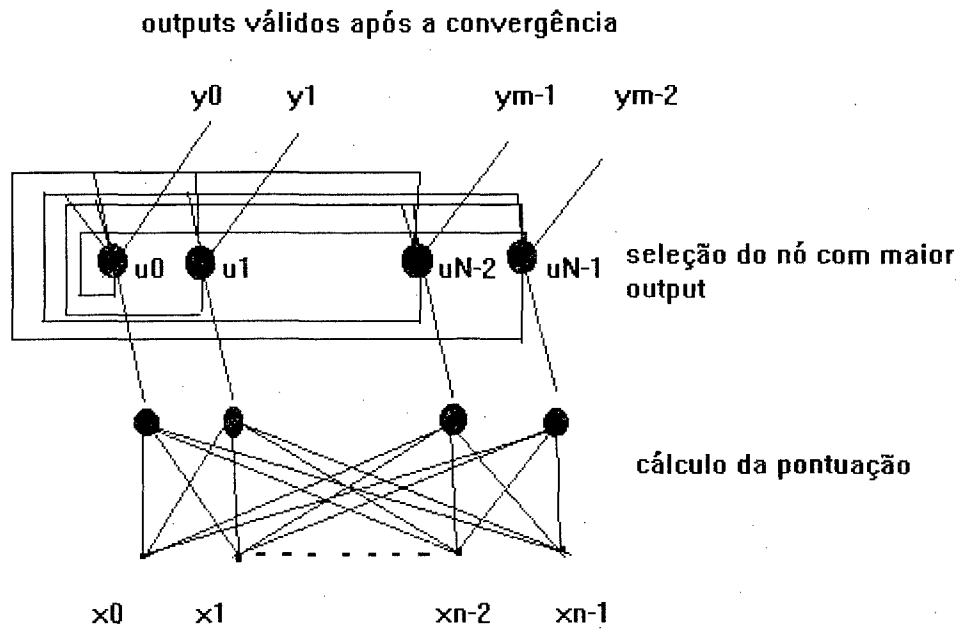


FIG 16-Rede de Haming.

Fonte:(RICHARD P.LIPPMANN, An Introduction to Computing With Neural Nets, 1987).

O nosso objetivo com estas conceituações que foram apresentadas, é que possamos ter uma visão de como poderíamos conceber um sistema conexionista na solução do problema em questão. O próximo capítulo trará a simulação numérica de algumas funções de pertinência, que poderiam ser computadas pelos elementos que formam as diversas camadas de uma rede, para em seguida, apresentarmos a nível de sugestão, alguns circuitos que as poderiam implementar.

CAPÍTULO VI

MODELO CONEXIONISTA .

6.1 Introdução.

Neste capítulo, apresentaremos algumas fórmulas analíticas, que permitirão uma visualização do comportamento desejado de algumas funções. Estas funções deverão ser capazes de realizar o mapeamento necessário, entre um conjunto de parâmetros e o grau de pertinência destes a um determinado tipo de RADAR. Após isto, ilustraremos com um circuito clássico, uma sugestão de uma possível implementação analógica.

6.2 Simulação numérica.

A simulação é uma ferramenta computacional de grande valia, quando necessitamos definir ou estudar os possíveis relacionamentos entre os componentes que formam um determinado sistema, ou prever performances quando as condições atuais são alteradas. A simulação, assim pode ser levada a feito através de modelos físicos ou matemáticos[LAW91]. No nosso caso, estaremos desenvolvendo um modelo analítico que terá a propriedade de representar os relacionamentos entre os componentes que fazem parte de um amplificador de transcondutância, responsável pela implementação analógica de uma tangente hiperbólica, que pode ser utilizada, para a concepção de uma curva que defina um mapeamento entre parâmetros RADAR e graus de pertinência destes parâmetros a determinados conjuntos difusos[MAI91].

Estaremos preocupados com o mapeamento de três parâmetros que julgamos fundamentais, para uma análise preliminar do sinal RADAR, quais sejam, a largura de pulso, a frequência de repetição de pulso, a frequência da portadora . Estes parâmetros transformados em diferenças de tensão podem servir como “inputs” para um amplificador de transcondutância.

6.3 Fórmulas analíticas da implementação analógica.

O amplificador de transcondutância, conforme já foi citado, terá na sua saída uma tangente hiperbólica, que será a função responsável pelo mapeamento anteriormente descrito.

Utilizaremos a curva seguinte para melhor explicar o mapeamento proposto.




FIG 17-Gráfico demonstrativo de conceito $F > F_i$.

Fonte:(Maia,L.F.J, Caracterização e Reconhecimento de conceitos. Tese de doutorado,1991).

.Consideremos por exemplo, o parâmetro frequência. Esta curva nos possibilita que definamos de uma maneira formal, quando uma frequência recebida é igual ou não a frequência F_i , que neste caso, é considerada como um limite inferior de um intervalo que define um determinado tipo de emissão.

Uma forma bastante trivial de definirmos se uma frequência é igual a F_i , é determinarmos, que esta não é maior e nem menor do que F_i .

A seguinte expressão analítica:

$$Z_{F_i} = \frac{1 - \frac{F_i}{F}}{1 + \frac{F_i}{F}}$$

Eq 6.1

expressa o conceito “Frequência maior que F_i ”, sendo zero para $F = F_i$, positiva para $F > F_i$ e negativa para $F < F_i$. A curva expressa por esta expressão é monotonicamente crescente com F tendendo assintoticamente para +1 quando $F \rightarrow \infty$ e a -1 quando $F \rightarrow 0$.

Esta expressão ainda poderia ser escrita da seguinte forma:

$$Z F_i = \frac{1 - Y F_i}{1 + Y F_i}$$

Eq 6.2

sendo $Y F_i = F_i/F$ o que nos forneceria, por exemplo, um valor de confirmação de $F > F_i$ de 0.5 (50%) para $F = 3 F_i$.

Poderíamos utilizar o mesmo raciocínio para um valor F_s , que seria considerado como o limite superior de um determinado intervalo de frequência.

A negação $F < F_s$ pode ser obtida analogicamente, invertendo-se a ordem da subtração das correntes geradas pelo par diferencial e subtraídas pelo espelho de corrente. Obteríamos analiticamente a seguinte equação representativa desta inversão:

$$Z F_s = \frac{1 - Y F_s}{1 + Y F_s}$$

Eq 6.3

sendo $Y F_s = F/F_s$.

Esta equação teria a seguinte forma:




FIG 18-Gráfico demonstrativo de conceito $F < F_s$.

Fonte: (Maia, L.F.J, Caracterização e Reconhecimento de conceitos. Tese de doutorado, 1991).

A partir destes dois conceitos “F maior que F_i ” e “F menor que F_s ”, demonstrados de uma forma analítica, poderemos definir o mapeamento anteriormente proposto.

Ilustraremos com a figura seguinte o mapeamento analógico a ser simulado, para então o definirmos de uma forma analítica.

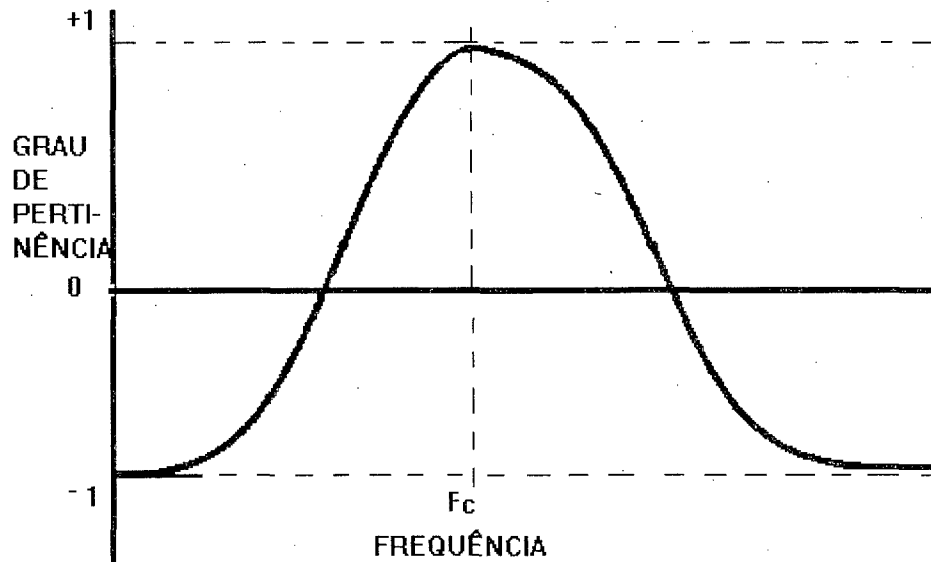


FIG 19- Curva de mapeamento.

Fonte:(Maia,L.F.J, Caracterização e Reconhecimento de conceitos. Tese de doutorado,1991).

Esta curva, que será uma combinação analítica das duas curvas anteriormente ilustradas, caracteriza o mapeamento entre os valores de entrada (parâmetros) e o grau com que estes parâmetros definem a pertinência de uma emissão a um determinado tipo de RADAR. Os valores +1 e -1 representam a concordância absoluta e a discordância total respectivamente e o valor zero representa o limite entre a concordância e a discordância.

Chamando o conceito de “F maior que F_i ” de I, que é definido em termos de ZF_i e YF_i e o conceito de “F menor que F_s ” de S, definido em termos de ZF_s e YF_s , poderemos formar uma composição de I e S. Chamaremos esta composição de F, que será definida em termos de YF e ZF, onde :

$$ZF = \frac{1 - YF}{1 + YF}$$

Eq 6.4

$$YF = YFi + YFs$$

Eq 6.5

a função ZF terá a forma da função apresentada na figura descrita anteriormente.

Cabe finalmente ressaltar, que algumas alterações nos valores de transcondutâncias dos circuitos em questão, podem alterar significativamente as formas das curvas apresentadas, o que nos permite, que através de processos de validação, otimizemos o nosso mapeamento. Estas alterações também serão simuladas de forma analítica, onde consideraremos estes possíveis valores como os expoentes W_i e W_s . Estas alterações podem ser computadas analiticamente, alterando os valores de YF calculado em 6.5 para:

$$YF = YFi^{W_i} + YFs^{W_s}$$

Eq 6.6

No nosso caso, as alterações em W_i e W_s , alterarão a inclinação das curvas conforme poderá ser observado nas simulações.

A combinação das pertinências de todos os parâmetros envolvidos no processos de identificação de emissões RADAR, pode ser realizada através de um conceito Z, que seria definido da seguinte forma:

$$Z = \frac{1 - YR}{1 + YR}$$

Eq 6.7

O conceito YR pode ser definido em função dos valores de YF, calculados de acordo com a equação 6.7 para cada parâmetro considerado, quais sejam, frequência, frequência de repetição de pulsos e largura de pulso.

$$YR = Yf + Yr + Yl$$

Eq 6.8

Onde teríamos os valores de Yf, Yr e Yl relacionados com os parâmetros, frequência, frequência de repetição de pulsos e largura de pulso respectivamente.

6.4 Resultados obtidos.

A simulação numérica acima descrita foi implementada em linguagem C, conforme código fonte constante do anexo 1, e alguns resultados obtidos podem ser observados na tabela que se segue.

RESULTADOS OBTIDOS.

PARÂMETROS : FREQ-->4.5 GIGAHz.

FRP-->3500 Mhz.

LP--> 1.1.0 μS

	GRAUS	DE	PERTINENCIA		
TIPO DE RADAR	FREQUENCIA		FRP	LP	IDT
DIREÇÃO DE TIRO	-0.52		0.57	0.40	-0.83
BUSCA COMBINADA	0.86		0.79	0.89	0.95
BUSCA AÉREA	-0.88		0.00	-0.99	-1.00
BUSCA SUPERFÍCIE	-0.99		0.89	-0.99	-1.00
NAVEGAÇÃO	-0.78		0.76	0.98	-0.99

TABELA 2- Resultados obtidos na simulação.

PARÂMETROS : FREQ-->3.5 GIGAHz.

FRP-->3000 Mhz.

LP--> 1.0 μS

	GRAUS	DE	PERTINENCIA		
TIPO DE RADAR	FREQUENCIA		FRP	LP	IDT
DIREÇÃO DE TIRO	0.57		0.86	0.72	0.81
BUSCA COMBINADA	0.64		0.69	0.91	0.84
BUSCA AÉREA	-0.14		0.86	-0.99	-1.00
BUSCA SUPERFÍCIE	-0.28		0.00	-0.99	-1.00
NAVEGAÇÃO	-0.99		0.96	-0.99	-0.99

TABELA 3- Resultados obtidos na simulação.

6.5 VLSI(Very Large Scale Integration)

6.5.1 Introdução.

Este tópico visa apresentar conceitos básicos, para que seja possível um bom entendimento dos circuitos que serão sugeridos. Estes circuitos poderão realizar analogicamente, as funções simuladas no tópico anterior, de forma que os apresentaremos como uma sugestão sujeita ainda a validações. Estas validações ficam como uma das propostas deste trabalho para posteriores pesquisas.

6.5.1 Origem da VLSI (Very Large Scale Integration).

Este paradigma era utilizado somente na concepção de dispositivos digitais que possuíam funções de armazenagem, comunicação e processamento de informações digitais, e nada que o levasse a ser utilizado como um suporte para um projeto analógico.

Uma grande pesquisa vem sendo realizada, tentando provar que os princípios de design analógicos existentes nos neurônios, com a sua conseqüente capacidade de aprendizagem, podem ser realizados de forma também analógica, em circuitos de silício.

A dificuldade de um melhor entendimento dos sistemas neurais, reside nas características destes, que computam funções com muitas variáveis de entrada. Uma outra grande dificuldade é a própria modelagem destes sistemas. Superado estes problemas, esperamos estar aptos a desenvolver sistemas, que são aplicáveis na

solução de problemas, que são intratáveis até mesmo pelos mais potentes computadores digitais.

Um grande obstáculo que aparece no desenvolvimento de sistemas computacionais baseados no paradigma neural, se refere à obtenção do grau de conectividade existente nos sistemas neurais biológicos. Dentro deste contexto, ressaltamos o papel da tecnologia VLSI, que pode ser aplicada para implementar uma computação analógica de larga escala, obtendo um elevado nível de conectividade. Esta conectividade é possível, graças ao rápido desenvolvimento da tecnologia de circuitos integrados em larga escala, que possibilita a fabricação de centenas de transistores interconectados numa simples pastilha de silício, possibilitando desta forma que possamos seguir os princípios de organização do sistema nervoso com o seu elevado grau de conectividade exigido[HOE72]. Isto posto, temos que foi dado um passo na direção de se vencer uma grande dificuldade na implementação de sistemas neurais que é a obtenção da alta conectividade. O outro passo seria o entendimento de todos os princípios de funcionamento dos sistemas neurais biológicos, que ainda será motivo de pesquisas por muito tempo.

Apesar de todas as diferenças existentes entre o sistema nervoso e um sistema computacional, algumas características podem ser ressaltadas como comuns aos dois, quais sejam, ambos processam informações e os sinais são representados por diferenças de potencial elétrico. As informações por sua vez são conduzidas por ligações formadas por condutores envolvidos por excelentes isoladores elétricos.

Devido a dissipação de energia, existe uma condição absoluta para que seja possível o processamento de informações, tanto nos sistemas computacionais quanto no sistema nervoso, que é a existência do ganho. Este ganho, que no sistema nervoso é obtido por complexos processos metabólicos, nos sistemas computacionais analógicos é conseguido através de dispositivos ativos, que serão descritos posteriormente.

Algumas conceituações básicas serão citadas, antes que passemos aos circuitos que serão objeto de nossa sugestão.

6.5.3 Semicondutores.

Os elementos da coluna IV da tabela periódica dos elementos químicos são os componentes básicos dos semicondutores intrínsecos, pois como possuem quatro elétrons na última camada, formam entre si cristais perfeitos. Estes elétrons são compartilhados entre estes átomos, de forma que estas moléculas na sua forma natural não possuem cargas livres, sejam estas positivas ou negativas.

Quando acrescentamos a estes compostos, átomos das colunas III ou V, estaremos inserindo nestas moléculas cargas elétricas livres, positivas ou negativas respectivamente, formando assim os cristais que são utilizados na implementação

dos transistores. Estes poderão ser denominados de transistores porta-p ou porta-n, conforme o caso.

6.5.4 Transistor MOS-(região ativa-Metalica/ isolador - Óxido/ porta - Semi-condutor).

Como exemplo de um dispositivo ativo, temos o transistor que é um dispositivo que controla o fluxo de corrente através da aplicação de um sinal de tensão, que condiciona exponencialmente o sinal de saída(corrente). O transistor é uma estrutura física que permite a tensão de um terminal controlar o fluxo de corrente para um outro terminal. Estes transistores são fontes controladas de correntes positivas ou negativas, sendo que o seu controle não extrai corrente dos terminais aos quais está conectado.

A dependência exponencial da corrente em relação a tensão do nó controlador(porta), permite controlarmos níveis de corrente sobre muitas ordens de magnitude e é dada pela distribuição de Boltzmann[MEA89].

$$I = I_0 e^{\frac{qV}{KT}}$$

Eq 6.9

I_0 é o fluxo das partículas em equilíbrio térmico para uma $V=0$.

I é o fluxo das partículas decrescida exponencialmente.

kT é 0.025 elétron-volt na temperatura ambiente, sendo K a constante de Boltzmann.

q é a carga.

V é a tensão.

A distribuição de Boltzmann é a base para todas as funções exponenciais nos sistemas neurais e eletrônicos em estudo, pois descreve o decréscimo exponencial no fluxo das partículas em equilíbrio térmico em função do gradiente de potencial[MEA89].

O funcionamento do transistor pode ser melhor visualizado a partir do diagrama abaixo.

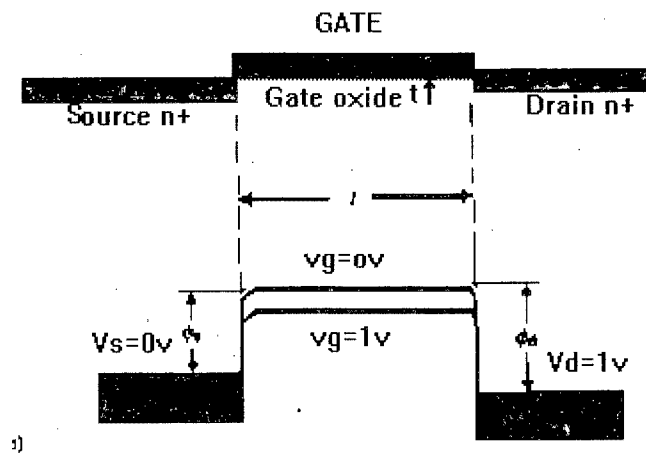


FIG 20- Diagrama de um transistor.
 Fonte:(MEAD,CARVER, Analog VLSI and Neural Systems,1989).

Podemos comparar a barreira de potencial entre a fonte e a saída, imposta por uma tensão que será aplicada no nó controlador, a uma barragem de uma represa. Existirá um fluxo de vapor de água sobre a barragem, resultante da condensação desta na superfície e que será proporcional ao gradiente de densidade formado do nível da água até a altura da barragem, ou seja, quanto mais alta a barragem, menor será o fluxo, pois menor será a densidade da água evaporada naquela altura.

Desta forma, temos que, quanto maior for o potencial aplicado ao nó controlador, menor será a corrente entre os dois pólos, e esta relação obedece a uma relação exponencial, conforme já foi citado.

A densidade de carga no nível de potencial, imposto no nó controlador, será:

$$N_s = N_0 e^{\frac{\phi_s}{KT}}$$

Eq 6.10

onde: N_0 é a densidade de carga no nível do nó fonte.

N_s é a densidade de carga no nível do potencial aplicado.

ϕ_s é a diferença de potencial entre o nó controlador e o nó fonte.

K é a constante de Boltzmann e

T é a temperatura.

O mesmo raciocínio pode ser aplicado ao nó dreno:

$$N_d = N_0 e^{\frac{\phi_d}{KT}}$$

Eq 6.11

Podemos colocar ϕ_s e ϕ_d em função de ϕ_0 , que é uma barreira própria do transistor, existente entre o nó fonte e a porta, sendo que a porta possui o mesmo potencial do nó controlador, e teremos:

$$\phi_s = \phi_0 + q(V_g - V_s)$$

Eq 6.12

$$\phi_d = \phi_0 + q(V_g - V_d)$$

Eq 6.13

onde V_g , V_s e V_d são respectivamente as tensões na porta, nó fonte e nó dreno.

Escrevendo as densidades de carga das equações 6.10 e 6.11 em termos de voltagens de nó fonte, nó dreno e porta teremos:

$$N_s = N_0 e^{\frac{\phi_0 + q(V_g - V_s)}{KT}}$$

Eq 6.14

$$N_d = N_0 e^{\frac{\phi_0 + q(V_g - V_d)}{KT}}$$

Eq 6.15

Teremos que a densidade de carga será uma função linear da distância L da porta, e assim :

$$\frac{dN}{dz} = \frac{N_d - N_s}{L} = \frac{N_1}{L} e^{\left[e \frac{-qV_g}{KT} - e \frac{-qV_d}{KT} - e \frac{-qV_s}{KT} \right]}$$

Eq 6.16

onde $N_1 = N_0 e^{-\phi_0 / (KT)}$

A corrente elétrica por unidade de largura da porta (W) será igual à:

$$\frac{I}{W} = q N v_{diff} = -q D \frac{dN}{dz}$$

Eq 6.17

onde D é a constante de difusão, sendo a velocidade de difusão dada por:

$$v_{diff} = -1 \frac{dn}{2N dh} \frac{KT}{m} t_f$$

Eq 6.18

onde t_f é considerado o tempo entre as colisões das partículas e m a sua massa.

Utilizando as equações 6.16 e 6.17 teremos a equação geral da corrente do transistor, variando negativamente em relação a diferença de potencial entre a porta e o nó fonte, como:

$$I = I_0 e^{-qV_g/KT} \left(e^{qV_s/KT} - e^{qV_d/KT} \right)$$

Eq 6.19

O equilíbrio térmico pode ser definido como o ponto em que as moléculas em suspensão na atmosfera, possuem a velocidade provocada pela força gravitacional igual a velocidade de difusão, criada pelo gradiente de densidade da atmosfera. Analogamente, este equilíbrio no campo da eletrônica, pode ser visualizado trocando a força gravitacional pela força eletrostática.

6.5.5 Propriedades dos circuitos de transistores.

Uma das principais propriedades dos transistores, é a diferença de potencial do nó dreno em relação ao nó fonte, que satura a corrente, cujos relacionamentos

podem ser observados no exemplo da fig 22. Um "layout básico dos transistores pode ser observado pela figura que se segue.




FIG 21-Layout de transistores.

Fonte:(MEAD,CARVER, Analog VLSI and Neural Systems,1989).




FIG 22-Crvas de saturação de corrente em função de V_{ds} .

Fonte:(MEAD,CARVER, Analog VLSI and Neural Systems,1989).

V_{ds} - Diferença de potência entre a porta e o nó fonte

Os valores de corrente saturada em função da diferença de potência entre a porta e o nó fonte pode ser observado abaixo.




FIG 23-Curva de saturação de corrente em função de Vgs.
 Fonte:(MEAD,CARVER, Analog VLSI and Neural Systems,1989).
 Vgs- Diferença de potencial entre a porta e o nó dreno.

Uma segunda propriedade que será destacada a seguir, aperfeiçoará a equação anteriormente citada, como a equação geral da corrente num transistor.

O fato é que os transistores não ideais, não são fabricados sobre meios neutros, conforme foi o modelo citado. O que ocorre, é que transistores porta-p são fabricados sobre condutores negativos e vice-versa, o que reduz a efetividade deste elemento, a medida que o controle do fluxo de corrente pela diferença de tensão fica comprometido.

Este efeito pode ser modelado por uma pequena alteração da equação 6.19 com a troca do fator KT/q por $KT/(qk)$ no primeiro exponencial, onde o elemento k é um parâmetro inerente a cada transistor, se mantendo praticamente constante num mesmo lote de fabricação. Observamos na fig 23, que a corrente saturada aumenta de um fator de e para cada 37 milivolts, o que nos fornece um valor de k igual a 0.676.

A equação 6.19 se transforma, para um transistor porta-n, em:

$$I = I_0 e^{k(V_g - V_s - V_d)} = I_{sat} (1 - e^{-V_d})$$

Eq 6.20

Podemos considerar o parâmetro KT como unidade de energia, que na temperatura ambiente será igual a 0.025 elétron-volt, já o parâmetro KT/q como unidade de potencial, que no nosso caso será igual a 0.025 volts. Isto significa que para que uma unidade de carga tenha uma variação de n unidades de KT/q volts no seu potencial, deverá ter uma variação de n unidades de KT elétron-volts na sua quantidade de energia.

Uma última característica a ser ressaltada é o nível de tensão limiar, que ocorre quando a quantidade de carga nos nós fonte e dreno começam a limitar o fluxo de corrente, em função do nível de potencial na porta que foi atingido. Após este valor ser alcançado a dependência da corrente saturada em relação à tensão da porta deixa de ser exponencial e passa a ser quadrática. O ideal, portanto é que o circuito opere abaixo deste valor.

6.5.6 Espelho de corrente.

Este circuito nada mais é do que um transistor com o seu nó de controle conectado ao seu nó dreno. Neste dispositivo, a diferença de potencial entre os nós fonte e dreno será sempre na ordem de milivolts, o que de acordo com a figura 22 garante a saturação do dispositivo. Neste caso, teremos a corrente obedecendo a dependência exponencial conforme gráfico da fig 23.




FIG 24- Exemplos de circuitos de espelho de corrente
 Fonte: (MEAD, CARVER, Analog VLSI and Neural Systems, 1989).

A figura acima ilustra um circuito que é utilizado nos casos em que temos por exemplo, uma fonte de cargas negativas e um "input" que necessita de cargas

positivas do mesmo valor oferecido pela fonte. O circuito em questão realiza esta inversão de polaridade da corrente.

Este circuito poderá ser utilizado na implementação de um amplificador de transcondutância, que por sua vez, pode ser utilizado na implementação analógica de uma função hiperbólica, que será utilizada na solução do nosso problema de identificação de emissões RADAR, como será visto posteriormente.

6.5.6 Par diferencial.

É um circuito simples, que será o responsável pela geração de um sinal de corrente como saída em função de entradas, que serão fornecidas em termos de diferenças de potencial. O circuito que realiza este processo é mostrado a seguir.




FIG 25-Circuito par diferencial.

Fonte:(MEAD,CARVER, Analog VLSI and Neural Systems,1989).

Neste circuito temos o transistor Qb usado como fonte de corrente, o potencial na porta Vb garante que a corrente de saída Ib esteja saturada. A divisão desta corrente em I1 e I2 depende dos valores de tensão V1 e V2. Esta divisão é o principal processo realizado por este circuito.

De acordo com as equações já apresentadas, temos que a corrente saturada Ib é:

$$I_b = I_0 e^{kV_g - V_s}$$

Eq 6.21

e as equações para as correntes I_1 e I_2 são:

$$I_1 = I_0 e^{kV_1 - V}$$

Eq 6.22

$$I_2 = I_0 e^{kV_2 - V}$$

Eq 6.23

A soma de I_1 e I_2 deve ser igual a I_b , de forma que:

$$I_b = I_1 + I_2 = I_0 e^{-V} \left(e^{kV_1} + e^{kV_2} \right)$$

Eq 6.24

Resolvendo esta equação para a tensão, teremos:

$$e^{-V} = I_b \frac{1}{I_0 \left(e^{kV_1} + e^{kV_2} \right)}$$

Eq 6.25

Substituindo a equação 6.25 nas equações 6.22 e 6.23 teremos:

$$I_1 = I_b \frac{e^{kV_1}}{e^{kV_1} + e^{kV_2}}$$

Eq 6.26

$$I_2 = I_b \frac{e^{kV_2}}{e^{kV_1} + e^{kV_2}}$$

Eq 6.27

Desta forma podemos observar, que se tivermos V_1 muitas unidades de $KT/(qk)$ maior do que V_2 , o transistor Q_2 será desligado e conseqüentemente toda a corrente irá para Q_1 , desta forma I_1 será próxima à I_b e I_2 será aproximadamente zero. O gráfico a seguir ilustra este processo.




FIG 26- Saídas de corrente em função de diferenças de potencial.
 Fonte:(MEAD,CARVER, Analog VLSI and Neural Systems,1989).

6.5.8 Amplificador de transcondutância.

Este circuito reúne todos os conceitos citados até o presente momento e visa implementar de uma forma analógica, uma função tangente hiperbólica, que será a responsável pela definição dos graus de certeza que uma determinada emissão pertence a um determinado tipo de RADAR.

O termo transcondutância se refere ao processo de transformação de uma diferença de tensão entre dois terminais num valor de corrente entre outros dois terminais, sendo que um amplificador utilizaria os dois circuitos acima citados, o espelho de corrente e o par diferencial[MEA89].

O amplificador de transcondutância após gerar duas correntes em função da diferença entre dois terminais, conforme foi descrito no par diferencial, utilizará o espelho de corrente para inversão de uma destas duas correntes, com subsequente soma, o que redundará numa curva tangente hiperbólica, que terá sua função demonstrada posteriormente. A figura seguinte ilustra este circuito.





FIG 27- Amplificador de transcondutância.
 Fonte:(MEAD,CARVER, Analog VLSI and Neural Systems,1989).

A operação realizada por este circuito, após a geração das duas correntes, é descrita a seguir:

$$I_1 - I_2 = I_b \frac{\frac{k(v_1 - v_2)/2}{e} - \frac{-k(v_1 - v_2)/2}{e}}{\frac{k(v_1 - v_2)/2}{e} + \frac{-k(v_1 - v_2)/2}{e}}$$

Eq 6.28

$$= I_b \tanh \left[\frac{k(v_1 - v_2)}{2} \right]$$

Eq 6.29

que pode ser visualizada pelo seguinte gráfico:




FIG 28- Curva de um amplificador de transcondutância.
Fonte:(MEAD,CARVER, Analog VLSI and Neural Systems,1989).

Um esquema ilustrativo de um circuito classificador de emissões RADAR, pode ser observado na figura 29.




Figura 29 - Diagrama de um circuito classificador de emissões RADAR.

6.6 Comparação com a abordagem heurística.

6.6.1 Introdução

Sistemas simbólicos, serão considerados neste tópico, como sistemas que manipulam “strings”. Apesar de números também poderem ser considerados como símbolos, estaremos sempre nos referindo, a manipulação sobre “strings”, que algumas ferramentas computacionais realizam.

Os sistemas simbólicos armazenam e processam regras proposicionais, sendo as regras, neste caso entendidas como implicações lógicas. O processo de inferência é definido através dos caminhos lógicos que são definidos pelas regras na sua base de conhecimento. A cadeia de inferência com encadeamento para frente procede dos antecedentes das regras para os consequentes e respondem perguntas do tipo “o que e se?”. A cadeia de inferência com encadeamento para trás procede dos consequentes das regras ou observações para os antecedentes. A complexidade da enumeração dos caminhos aumenta não linearmente com o número de regras acumuladas. Uma enumeração de caminhos em tempo real pode se tornar combinatoriamente proibitiva numa extensa base de conhecimentos, requerendo heurísticas ou estratégias de busca de aproximação, fato este inexistente em sistemas neurais.

7.3 Processamento simbólico Vs numérico.

Comparando estes dois paradigmas, estaremos comparando a programação e o aprendizado, entre a inferência lógica e a dinâmica não linear que evolui no tempo, o fluxo de inferências através da árvore do conhecimento e o equilíbrio do sistema dinâmico.

Não podemos obter derivadas de um símbolo, pois é necessário que tenhamos uma função contínua. A representação simbólica nos permite facilmente representar conhecimentos estruturados como regras, mas impede que apliquemos as ferramentas da matemática numérica e que implementemos diretamente os sistemas de IA em circuitos integrados.

De uma forma resumida temos que nos estimadores livres de modelo, caso em que podemos enquadrar ambas as abordagens, o usuário não necessita explicitamente estabelecer como que os “outputs” do sistema dependem dos “inputs”, podem se dividir em dois grandes grupos, que dependem da forma de como que o conhecimento é representado, se de forma estruturada ou não e do tipo de manipulação exercida, se numérica ou simbólica, temos então:

Tipo de conhecimento	Tipo de processamento	
Estruturado	Simbólico	Numérico
Não estruturado	Lógica proposicional	Sistemas neurais

De um modo geral temos que os sistemas especialistas da IA exploram o conhecimento estruturado codificado através da engenharia do conhecimento, porém o processa fora da estrutura analítica e computacional que as ferramentas numéricas nos proporciona, evitando assim que tenhamos a possibilidade de implementarmos o seu comportamento, em contra-partida as redes neurais exploram o conhecimento dentro desta estrutura, porém a aquisição não pode ser através de uma codificação direta e sim através da aprendizagem.

CAPÍTULO VIII

CONCLUSÃO

O objetivo proposto neste trabalho, foi o de apresentar uma sugestão para a solução do problema de identificação de emissões RADAR, que pudesse lidar com o grau de incerteza inerente a este processo e que pudesse nos fornecer respostas em tempo real. Este objetivo foi perseguido, com apresentação e simulação de funções, que demonstraram capacidade de mapear parâmetros de e-missões, com os seus respectivos graus de pertinência e com a sugestão de circuitos analógicos, que poderiam quando implementados, realizar estas funções em tempo real.

Foi apresentado neste trabalho, os paradigmas clássicos das redes neurais, de forma que pudéssemos ter o suporte teórico, suficiente para concebermos conceitualmente um sistema conexionista, para a identificação de emissões RADAR.

7.1 Propostas para trabalhos futuros

A especificação de um “design” ótimo de uma rede, que inclua a sua topologia, bem como, a escolha dos processos de aprendizagem, que podem ser efetuados, ficam como propostas para trabalhos futuros.

Algumas funções de pertinência foram simuladas. Funções estas, que podem vir a ser processadas pelos elementos computacionais da rede. Uma sugestão de implementação analógica foi apresentada, sendo que, fica também como proposta para trabalhos futuros, pesquisas que validem as funções ora propostas, ou ainda, um estudo mais aprofundado nos circuitos analógicos que podem ser implementados.

O tipo de varredura, também pode ser considerado para que haja uma melhor definição do tipo de RADAR, que contém uma determinada emissão. Algumas regiões de indefinição, conforme pode ser observado na tabela 3 de resultados obtidos, poderiam ser melhoradas com esta implementação, sendo esta mais uma proposta para trabalhos futuros

ANEXO 1

Código fonte de uma simulação qualitativa de um amplificador de transcondutância.

Este programa visa a implementação de funções que são capazes de realizar uma simulação qualitativa de um amplificador de transcondutância.

Este amplificador realiza analogicamente um tangente hiperbólica, que pode ser utilizada, para a implementação de uma função capaz de mapear o grau de pertinência de alguns parâmetros de emissões RADAR aos respectivos tipos de transmissores RADAR.

O compilador utilizado foi o turbo C 2.0 da Borland.

As funções serão descritas a seguir.

```
/ Inclusão de bibliotecas /
# include <stdio.h>
# include <math.h>
# include <graphics.h>
# include <process.h>

/Inicialização de variáveis e declaração de funções/
char Texto[1000];
char Tipo[30];
float calcula();
float central();
float fator_nor();
float traca_entada();
void plot();
void grafico();
void func_1();
void func_3();
void pinta();
void pintar();
void pinta_1();
void limpa();

/ Programa principal/
main()
{
/ Inicialização de variáveis /
int gdriver,gmode;
int opcao,opcao_1,t;
float res,par_1,par_11,par_2,par_21,par_3,par_31;
float ent_1,ent_2,para_cen;
```

```

detectgraph(&gdriver,&gmode);
initgraph(&gdriver,&gmode,"c:\\tc\\");
do
{
setcolor(25);
rectangle(1,1,120,30);

strcpy(Texto,"-->sua opcao");
plot(15,5,Texto);

rectangle(0,0,610,470);
strcpy(Texto,"IMPLEMENTACAO RELATIVA A DISSERTACAO DE MESTRADO
DO ALUNO");
plot(30,70,Texto);
strcpy(Texto,"WILLIAM FREITAS DA SILVA E SILVA.");
plot(120,82,Texto);
strcpy(Texto,"SIMULACAO QUALITATIVA DE UM AMPLIFICADOR DE
TRANCONDUTANCIA.");
plot(50,102,Texto);
strcpy(Texto,"Este amplificador, composto por um par diferencial e um espelho ");
plot(20,122,Texto);
strcpy(Texto,"de corrente,realiza uma tangente hiperbolica. Esta e' responsavel ");
plot(20,142,Texto);
strcpy(Texto,"pelo mapeamento dos valores de entrada dos parametros RADAR
");
plot(20,162,Texto);
strcpy(Texto,"a serem analisados, com seus respectivos graus de pertinencia, ");
plot(20,182,Texto);
strcpy(Texto,"aos tipos de RADAR em questao.");
plot(20,202,Texto);
strcpy(Texto,"Esta implementacao possui dois modulos, a saber:");
plot(100,222,Texto);

strcpy(Texto,"O primeiro modulo possibilita que o usuario entre com os parametros ");
plot(20,242,Texto);

strcpy(Texto,"RADAR (Freq-FRP-LP), que terao seus graus de pertinencia definidos
");
plot(20,262,Texto);

strcpy(Texto,"segundo uma curva com parametros fixos.");
plot(20,282,Texto);

```

```

strcpy(Texto,"O segundo modulo permite que todos os parametros considerados na
");
plot(20,302,Texto);

strcpy(Texto,"na implementacao da tangente hiperbolica sejam alterados, o que ");
plot(20,322,Texto);

strcpy(Texto,"redefine os graus de pertinencia obtidos, dando suporte assim, a um ");
plot(20,342,Texto);

strcpy(Texto,"possivel processo de validacao");
plot(20,362,Texto);

strcpy(Texto,"Opcao no campo previsto: 1-->Observacao de resultados");
plot(20,420,Texto);

strcpy(Texto,"                : 2-->Validacao");
plot(20,440,Texto);

strcpy(Texto,"                : 3-->Sair");
plot(20,460,Texto);

scanf("%d",&opcao_1);

/ Estrutura de controle /
switch(opcao_1)
{
case 1:
    limpa();
    pinta();
    break;

case 2:
    limpa();
    pinta_1();
    break;
}
}
while(opcao_1!=3);
}

/*****
*/

```

```

/ Função para plotagem de textos na tela /
void plot(int Escala, int Yi, char*pTexto)
{
int Xp, Xa;
outtextxy(Escala,Yi,pTexto);

}

```

```

/*****
**/ Função para limpar a tela /

```

```

void limpa()
{
    int gdriver,gmode;
    closegraph();
    clrscr();
    detectgraph(&gdriver,&gmode);
    initgraph(&gdriver,&gmode,"c:\\tc\\");
}

```

```

/*****
**/ Função responsável pela utilização do programa para observação de resultados de
acordo com uma curva pré-definida/

```

```

void pinta()
{
float par_1,par_2,par_3;
int opcao;
    setcolor(25);
    rectangle(0,0,600,455);
    rectangle(1,1,320,100);
    strcpy(Texto,"-->Freq(1 - 10 Giga)");
    plot(40,05,Texto);
    strcpy(Texto,"-->Frp (100-5000MHz)");
    plot(40,20,Texto);
    strcpy(Texto,"-->Lp(0.1-4.0 micro seg)");
    plot(40,35,Texto);
    strcpy(Texto,"Informe parametros de entrada(FREQ-FRP-LP),no campo previsto.");
    plot(60,370,Texto);
    scanf("\t %f",&par_1);
    scanf("\t %f",&par_2);
    scanf("\t %f",&par_3);
    limpa();
    setcolor(25);
}

```

```

rectangle(0,0,600,455);
rectangle(1,1,120,30);
strcpy(Texto,"-->sua opcao");
plot(15,5,Texto);
strcpy(Texto," Informe quais dados deseja obter");
plot(150,200,Texto);
strcpy(Texto,"1--->radar de tiro.");
plot(170,240,Texto);
strcpy(Texto,"2--->radar de busca combinada.");
plot(170,260,Texto);
strcpy(Texto,"3--->radar de busca aerea.");
plot(170,280,Texto);
strcpy(Texto,"4--->radar de busca de superficie.");
plot(170,300,Texto);
strcpy(Texto,"5--->radar de navegacao.");
plot(170,320,Texto);
strcpy(Texto,"6--->sair do programa.");
plot(170,340,Texto);
do
{
scanf("%d",&opcao);
limpa();
switch(opcao)
{
case 1: strcpy(Tipo,"tiro");
func_1(2.0,4.0,2000.0,4000.0,0.5,1.2,par_1,par_2,par_3,
10.0,10.0,10.2,10.2,10.3,10.3,Tipo);
break;
case 2: strcpy(Tipo,"busca combinada");
func_1(3.0,6.0,2500.0,4500.0,0.7,1.5,par_1,par_2,par_3,
10.2,10.2,10.2,10.2,10.2,10.2,Tipo);
break;
case 3: strcpy(Tipo,"busca aerea");
func_1(1.5,3.4,2500.0,3500.0,1.5,1.9,par_1,par_2,par_3,
10.2,10.2,10.2,10.2,10.2,10.2,Tipo);
break;
case 4: strcpy(Tipo,"busca superficie");
func_1(2.3,3.4,3000.0,4000.0,2.0,3.0,par_1,par_2,par_3,
10.2,10.2,10.2,10.2,10.2,10.2,Tipo);
break;
case 5: strcpy(Tipo,"navegacao");
func_1(5.0,8.0,2000.0,4000.0,1.5,3.4,par_1,par_2,par_3,
10.2,10.2,10.2,10.2,10.2,10.2,Tipo);
break;
}}

```



```

while(opcao!=6); }

/*****
/ Função responsável pelo cálculo dos graus de pertinência e plotagem de gráficos/
void func_1(f1,f2,frp1,frp2,lp1,lp2,par_1,par_2,par_3,
tranc_1,transc_2,transc_11,transc_21,transc_12,transc_22,tipo)

float f1,f2,frp1,frp2,lp1,lp2,par_1,par_2,par_3,
tranc_1,transc_2,transc_11,transc_21,transc_12,transc_22;
char tipo[30];
{
float ,res_freq,res_lp,res_frp,f,r,l,rf,res_final;

res_freq= calcula(f1,f2,par_1,transc_1,transc_2);

res_frp= calcula(frp1,frp2,par_2,transc_11,transc_21);

res_lp= calcula(lp1,lp2,par_3,transc_12,transc_22);

grafico(10,25.0,0.1,1.0,10.0,f1,f2,transc_1,transc_2);
traca_entrada(25.0,10.0,par_1,f1,f2,transc_1,transc_2);
strcpy(Texto,"FREQUENCIA");
plot(100,200,Texto);

grafico(20,200.0,10.0,100.0,5000.0,frp1,frp2,transc_11,transc_21);
traca_entrada(200.0,5000.0,par_2,frp1,frp2,transc_11,transc_21);
strcpy(Texto,"FRP");
plot(300,200,Texto);

grafico(40,400.0,0.01,0.1,4.0,lp1,lp2,transc_12,transc_22);
traca_entrada(400.0,4.0,par_3,lp1,lp2,transc_12,transc_22);
strcpy(Texto,"LP");
plot(500,200,Texto);

f=((1-res_freq)/(1+res_freq));
r=((1-res_frp)/(1+res_frp));
l=((1-res_lp)/(1+res_lp));
rf=pow(f,3)+pow(r,3)+pow(l,3);
res_final=((1-rf)/(1+rf));

printf("Para o radar de %s a pertinencia da emissao 'e:%f\n",tipo,res_final);
printf("Para o radar de %s a pertinencia da freq 'e:%f\n",tipo,res_freq);
printf("Para o radar de %s a pertinencia da frp 'e:%f\n",tipo,res_frp);
printf("Para o radar de %s a pertinencia da lp 'e:%f\n",tipo,res_lp);
printf("\n Sua proxima opcao:\n");

```

```
printf("1-Tiro 2-Busca combinada 3-Busca aerea.\n");
printf("4-busca de superficie 5-Navegacao 6->sair\n");
}
```

```
/******
/
```

```
/ Função responsável pela validação das funções de pertinência /
```

```
void pinta_1()
{
int optei;
int gdriver,gmode;
float fli,ft1,fls,ft2;
float rli,rt1,rls,rt2;
float lli,lt1,ljs,lt2;
float par_1,par_2,par_3;
limpa();

do
{
setcolor(25);
rectangle(05,20,600,130);
strcpy(Texto,"Informe para qual parametro voce pretende modelar a curva de
pertinencia");
plot(20,40,Texto);
strcpy(Texto,"1--->Frequencia");
plot(170,60,Texto);
strcpy(Texto,"2--->FRP");
plot(170,80,Texto);
strcpy(Texto,"3--->LP");
plot(170,100,Texto);
strcpy(Texto,"4--->Sair");
plot(170,120,Texto);

scanf("%d",&optei);
limpa();
if(optei!=4)
{
setcolor(25);
rectangle(0,0,600,455);
strcpy(Texto,"Informe parametros solicitados no campo previsto.");
plot(60,370,Texto);
strcpy(Texto,"-->Limite Inf Freq(1-10)/FRP(100-5000)/LP(0.1-4)");
```

```

plot(100,05,Texto);
scanf("%f",&fli);
strcpy(Texto,"-->Ganho 1 ");
plot(100,20,Texto);
scanf("%f",&ft1);
strcpy(Texto,"-->Limite Sup Freq(1-10)/FRP(100-5000)/LP(0.1-4) ");
plot(100,35,Texto);
scanf("%f",&fls);
strcpy(Texto,"-->Ganho 2 ");
plot(100,50,Texto);
scanf("%f",&ft2);

```

```

limpa();
pintar();
scanf("\t %f",&par_1);
limpa();
switch(optei)
{
case 1: setcolor(25);
        rectangle(0,0,600,455);
        func_3(200.0,0.1,1.0,10.0,fli,fls,par_1,ft1,ft2);
        break;
case 2:
        setcolor(25);
        rectangle(0,0,600,455);
        func_3(200.0,10.0,100.0,5000.0,fli,fls,par_1,ft1,ft2);
        break;
case 3:
        setcolor(25);
        rectangle(0,0,600,455);
        func_3(200.0,0.01,0.1,4.0,fli,fls,par_1,ft1,ft2);
        break;
}
}
}
while(optei!=4);
}

```

```

/*****
**

```

```

void pintar()
{

        setcolor(25);
        rectangle(0,0,600,455);

```

```

    rectangle(1,1,320,100);
    strcpy(Texto,"-->Parametro");
    plot(40,05,Texto);
}

/*****
*/
/*****
*/
/ Função responsável pelo cálculo dos graus de pertinência e plotagem de gráficos na tela/

void func_3(l1,inc,ini,tela,f1,f2,par_1,transc_1,transc_2)
float l1,inc,ini,tela,f1,f2,par_1,transc_1,transc_2;
{
float para_cen,res_freq;

res_freq= calcula(f1,f2,par_1,transc_1,transc_2);

grafico(10,l1,inc,ini,tela,f1,f2,transc_1,transc_2);
traca_entrada(l1,tela,par_1,f1,f2,transc_1,transc_2);
plot(100,200,Texto);

printf("Para o parametro em questao a pertinencia 'e:%f\n",res_freq);

}

/*****
**/

/*****
/
/ Função que executa o cálculo das funções de pertinência/
float calcula(entr_1,entr_2,entr_3,transc_1,transc_2)
float entr_1,entr_2,entr_3,transc_1,transc_2;
{

float radar_freq,ya,yb,yc,zc;

ya=pow((entr_1/entr_3),transc_1);
yb=pow((entr_3/entr_2),transc_2);
yc=1/(ya+yb);
zc=((yc-1)/(yc+1));
return(zc);
}

```

```

}

/*****
**/
/*****
*/
/ Função que plota os gráficos na tela/
void grafico(cor,l1,inc,ini,tela,freq_1,freq_2,transc_1,transc_2)
int cor;
float tela,l1;
float inc,ini,freq_1,freq_2,transc_1,transc_2;

{
float ya,yb,yc,zc,plot_x,plot_y,freq;
for(freq=ini;freq<=tela;freq+=inc)
{

ya=pow((freq_1/freq),transc_1);
yb=pow((freq/freq_2),transc_2);
yc=1/(ya+yb);
zc=((yc-1)/(yc+1));

    plot_y=350-(zc*135);
    plot_x=(freq*175/tela)+l1;
    putpixel(plot_x,plot_y,cor);
}

line((l1-20),350,580,350);
line(l1,155,l1,435);
}

/*****
*/
/ Função que traça graficamente o valor de pertinência no gráfico/
traca_entrada(l1,tela,freq_ent,freq_1,freq_2,transc_1,transc_2)
float l1,tela;
float freq_ent,freq_1,freq_2,transc_1,transc_2;
{
float zc,pont_x,pont_y;
zc=calcula(freq_1,freq_2,freq_ent,transc_1,transc_2);
pont_x=(freq_ent*175/tela)+l1;
pont_y=350-(zc*135);
line(pont_x,pont_y,pont_x,350);
line(l1,pont_y,pont_x,pont_y);
}

```

REFERÊNCIAS BIBLIOGRÁFICAS:

- [ARA88] ARARIBÓIA,G., Inteligência Artificial,Livros Técnicos e Científicos Editora Ltda, Rio de Janeiro 1988.
- [BRA86]BRATKO,IVAN.,Prolog Programing for AI, Addison-Wesley Publishing Company,Inc, England 1986.
- [BULL77] BULLOCK,T.H.R,ORKAND,and A.GRINNELL,Introduction to Nervous System, São Francisco,1977
- [CAM94] CAMPELO, R, EDUARDO e N,MACULAN., Algoritmos e Heurísticas: Desenvolvimento e Performance, Rio de Janeiro, 1994.
- [CHR87] CHRISTOPHER,S. MELLISH and WILLIAM,F CLOCKSIN,Programing in Prolog, Berllim 1987
- [COH85] COHEN,PAUL., Heuristic Reasoning about Uncertainty: An Artificial Intelligence Approach,Pitmam Publishing Ltd, London 1985.
- [DAY90] DAYHOFF JUDITH,Neural Networks Architetures:An Introdution,Van Nostrand Reihold International Company Limited ,NY 1990.
- [DEN93] DENNIS D. VACCARO, Electronic Warfare Receiving Systems, Artech House Publishers, London 1993.
- [DIA89] DIAPER,DAN, Knowledge Elicitation, principle, techniques and aplications,Unwim Bross,England 1989
- [ELE88] Eletronic Warfare Fundamentals of Naval Inteligence, Marinha Americana,1988
- [FUN90] Fundamentos da guerra eletrônica,Universidade da Força Aérea, Rio de Janeiro 1990.
- [FUR94] FURLAN,JOSE DAVI, Reengenharia da Informação,Makron Books,Rio de Janeiro,1994.
- [HOE72] HOENESEIN,B.and MEAD,C.A,Fundamental Limitations in Microelectronics,MOS Technology,Solid-State Electronics,15:819, 1972
- [HOP86] HOPFIELD JJ,and D.W.TANK,Computing with Neural Circuits. A model,Science,vol 223,625-633,August 1986.

[KLI88] KLIR,GEORGE J and TINA A.FOLGER, Fuzzy Sets, Uncertainty and Information, Prentice Hall INC, New Jersey 1992

[KOS92] KOSKO,B,Neural Networks and Fuzzy Systems, Prentice-Hall INC, New jersey,1992.

[LAW91] LAW,AVERRIL.M ,Simulation Modeling and Analysis Mc Craw-Hill Books,Singapore 1991

[LIP87] RICHARD P.LIPPMANN, An Introduction to Computing With Neural Nets,IEEE,Vol 3, No 4, pp 4-22,April 1987.

[JAC87] JAECKEL L.D,GRAF.H.P and HOWARD.R.E,Electronics Neural Network Chips,Applied Optics, Vol 2,No 6,5077,5080

[MAC91] 2/7 Grupo de Aviação,Manual de Combate Eletrônico, Florianópolis,1991.

[MAE89],EMBRAER,OTFN 1P-95-1,São José dos Campos ,1989.

[MAI91] Maia,L.F.J, Caracterização e Reconhecimento de conceitos. Tese de doutorado.
Faculdade de Engenharia Elétrica- Unicamp. Campinas,Sp, Novembro -1991.

[MAL90] 1/7 Grupo de Aviação, Manula de Combate Eletrônico, Salvador 1990.

[MEA89] MEAD,CARVER, Analog VLSI and Neural Systems,Addison-Wesley Publishing Company, USA 1989.

[MIN69] MINSKY,M and PAPERT,S ,Perceptrons,Cambridge,MA MIT PRESS.

[PAR90] PARTRIDGE,D and WILKS,YORICH ALEXANDER,The Foundations of Artificial Intelligence,Cambridge University Press, Great Britain 1990.

[RIB87] RIBEIRO,HORÁCIO,Introdução aos Sistemas especialistas, LTC,São Paulo 1987.

[RIC91] RICH, ELAINE and KEVIN,KNIGHT, Artificial Intelligence, Mc Graw-Hill Inc 1991.

[RUM86] RUMELHART.D.E and J.L.MCCLELLAND,Paralell Distributed Processing,Vol 1, Cambridge,Mass:MIT Press