



**UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
MESTRADO EM ENGENHARIA DE TELECOMUNICAÇÕES**

ANTONIO JOÃO CAVALCANTI RIBEIRO COUTINHO

**IDENTIFICAÇÃO DE MODULAÇÃO
UTILIZANDO REDES NEURAIS DO TIPO
MAPAS AUTO-ORGANIZADOS**

**NITERÓI-RJ
2013**



ANTONIO JOÃO CAVALCANTI RIBEIRO COUTINHO

**IDENTIFICAÇÃO DE MODULAÇÃO
UTILIZANDO REDES NEURAIIS DO TIPO
MAPAS AUTO-ORGANIZADOS**

Dissertação de Mestrado
apresentada ao Programa de Pós-
Graduação em Engenharia de
Telecomunicações da Universidade
Federal Fluminense como parte dos
requisitos para a obtenção do título
de Mestre em Ciências. Orientado
pelo Prof. Dr. Julio Cesar Rodrigues
Dal Bello e coorientado pelo Prof.
Dr. João Marcos Meirelles da Silva.

**NITERÓI-RJ
2013**

ANTONIO JOÃO CAVALCANTI RIBEIRO COUTINHO

**IDENTIFICAÇÃO DE MODULAÇÃO UTILIZANDO REDES NEURAIS DO TIPO
MAPAS AUTO-ORGANIZADOS**

Dissertação de Mestrado
apresentada ao Programa de Pós-
Graduação em Engenharia de
Telecomunicações da Universidade
Federal Fluminense como parte dos
requisitos para a obtenção do título
de Mestre em Ciências. Área de
Concentração: Sistemas de
Comunicações Móveis.

Aprovada em 08 de outubro de 2013.

BANCA EXAMINADORA

Prof. Dr. Julio Cesar Rodrigues Dal Bello – Orientador
Universidade Federal Fluminense - UFF

Prof. Dr. João Marcos Meirelles da Silva – Coorientador
Universidade Federal Fluminense - UFF

Prof. Dr. José Santo Guiscafré Panaro
Universidade Federal Fluminense - UFF

Prof. Dr. Eduardo Esteves Vale
Marinha do Brasil

Mestre em Ciências Italo Ramella
Marinha do Brasil

NITERÓI-RJ
2013

Aos meus amores queridos, esposa e filho.

Agradecimentos

Agradeço primeiramente a Deus pela sua anuência, permitindo a realização deste sonho, e por conduzir a minha vida em todos os momentos, sobretudo, naqueles em que enfrentei a provação da grave doença que me acometeu no ano passado, conduzindo-me à debilidade física e à necessidade de realizar uma cirurgia cardíaca.

Ao amigo desconhecido que me doou a válvula cardíaca, que me salvou a vida orgânica, permitindo-me prolongar meus dias neste plano. Pretendo honrá-lo, vivendo esta minha sobrevida com a dignidade de um homem de bem.

À minha esposa querida, Ana Paula, que salvou a minha vida, descobrindo precocemente a endocardite a que fui acometido, possibilitando o êxito no meu tratamento, e que esteve ao meu lado em todas as horas.

A meu filho, Yuri, que me inspirou a lutar a cada instante pela minha vida e vem sendo a alegria de meus dias.

Aos meus pais, Vânia e Renato, pelo seu apoio, dedicação e amor que sempre me dirigiram, sobretudo nos momentos difíceis de doença que passei.

Às minhas irmãs, Renata e Sheyla, por estarem ao meu lado quando mais precisei, inclusive velando meu leito no hospital a fim de garantir que não me faltasse nada, garantindo-me, na medida do possível, o mínimo de conforto.

Aos meus amados e saudosos avós, Antônio e Yvette, cuja lembrança e o exemplo carrego comigo todos os dias.

Aos meus demais familiares que nos momentos em que me encontrava internado ou convalescente se reversavam em cuidados a fim de possibilitar a minha recuperação.

Aos meus amigos Yona Lopes, David Acosta e Fidel Souza que muito contribuíram para a realização deste trabalho.

Aos meus orientadores, Prof. Dr. Julio Cesar Rodrigues Dal Bello e Prof. Dr. João Marcos Meirelles da Silva, que dirigiram e orientaram os meus estudos durante todo o curso e estavam sempre pré-dispostos a me ajudar. Sendo os meus grandes incentivadores neste trabalho, dando-me ânimo para trabalhar, mesmo no período de convalescência, a fim de realizar o meu objetivo e concretizar meu sonho.

Ao Prof. Dr. Panaro que prestimosamente me orientou, ajudando-me a alicerçar este trabalho.

Aos meus professores durante o curso de mestrado que com os seus ensinamentos contribuíram para a realização deste trabalho.

Ao CF(EN) Italo, que sempre me apoio e incentivou em todos os momentos do meu curso, compelindo-me a prosseguir mesmo quando estava convalescente e desanimado. E me ajudou administrativamente dentro da Organização Militar em que servimos para que eu tivesse as condições necessárias para retomar o mestrado de onde parei, devido à cirurgia e a endocardite, sem prejuízo ao meu curso.

À Marinha do Brasil que me propiciou esta oportunidade única de capacitação profissional que fará grande diferença futuramente no desempenho das minhas funções como engenheiro.

“A tarefa é, não tanto para ver o que ninguém viu ainda, mas pensar o que ninguém ainda pensou sobre o que todo mundo vê”.

ERWIN SCHRÖDINGER.

COUTINHO, A. J. C. R. **Identificação de modulação utilizando redes neurais do tipo auto-organizáveis**. Universidade Federal do Fluminense, 2013, 126f. Dissertação de mestrado de engenharia de telecomunicações.

Orientador: Prof. Dr. Julio Cesar Rodrigues Dal Bello.

Coorientador: Prof. Dr. João Marcos Meirelles da Silva.

O presente trabalho consiste em cinco simulações computacionais que foram desenvolvidas em Matlab a fim de averiguar a eficácia das redes neurais artificiais no processo de identificação automática de modulação, e na demodulação dos sinais digitais modulados previamente identificados. Inicialmente, se verifica na simulação um, se uma arquitetura M-SOM (*Multiple Self-Organizing Map*) com distância Euclidiana como medida de dissimilaridade, utilizada no processo de formação de agrupamento, e treinamento utilizando sinais modulados contaminados com 20 dB de SNR (*Signal-to-noise ratio*), se é capaz de identificar automaticamente sinais modulados e demodulá-los corretamente; buscase, na simulação dois, utilizar a mesma rede com a mesma métrica de dissimilaridade e treinamento, utilizando sinais modulados contaminados com vários níveis de SNR; já na simulação três, verifica-se se a rede M-SOM com treinamento utilizando sinais modulados contaminados com vários níveis de SNR e com a métrica *Manhattan* possui um desempenho melhor do que com a métrica Euclidiana. Na simulação quatro constrói-se uma rede M-ART (*Multiple Adaptive resonance theory*) de estrutura semelhante à da rede M-SOM com o propósito de verificar se esta rede também se torna apta a identificar automaticamente a modulação e também realiza a demodulação dos sinais modulados, utilizando-se como medida de dissimilaridade a distância Euclidiana e treinamento, utilizando sinais modulados contaminados com vários níveis de SNR. Na simulação cinco se utiliza a mesma rede com a métrica *Manhattan* como medida de dissimilaridade e treinamento utilizando sinais modulados contaminados com vários níveis de SNR para efeito comparação de desempenho com os resultados obtidos na simulação quatro. Ao final deste trabalho se chegou as seguintes conclusões: que a medida de dissimilaridade que possibilitou um melhor desempenho das redes neurais estudadas foi a distância Euclidiana e o processo de treinamento que propiciou um melhor desempenho das RNAs testadas foi o treinamento utilizando sinais modulados contaminados com vários níveis de SNR. Pode-se também observar que as duas redes auto-organizáveis, M-SOM e M-ART possibilitam a correta classificação automática dos sinais modulados apresentados e operam satisfatoriamente no

processo de demodulação destes sinais. As redes auto-organizáveis com aprendizado competitivo estudadas são, portanto, alternativas computacionais viáveis para substituir um equipamento *hardware* dedicado de reconhecimento automático de modulação, assim como, para integrar uma plataforma de um rádio definido por *software*, funcionando como estágio de demodulação dos sinais.

Palavras-chave: Redes auto-organizáveis. M-SOM. M-ART. Reconhecimento Automático de Modulação. Demodulação.

ABSTRACT

COUTINHO, A. J. C. R., Modulation identification using self-organizing neural networks, Federal Fluminense University, 2013, 126p. Thesis to Master degree in telecommunications engineering.

Advisor: Prof. Dr. Julio Cesar Rodrigues Dal Bello.

Co-Advisor: Prof. Dr. João Marcos Meirelles da Silva.

This thesis consists of five computer simulations that have been developed in Matlab in order to verify the effectiveness of artificial neural networks in the process of automatic identification of modulation and demodulation of digital signals modulated previously identified. Initially, intend in the simulation one, verify if an architecture M -SOM(Multiple Self-Organizing Map) with Euclidean distance as to the dissimilarity measure used in the process of forming the grouping, and using training signals modulated contaminated with 20 dB of SNR (Signal-to-noise ratio), is able to automatically identify modulated signals and demodulates them correctly ; looking up , in the simulation two, using the same network with the same metric dissimilarity and training using modulated signals contaminated with various levels of SNR, whereas in the three simulations ,it appears that the network M -SOM with training using modulated signals contaminated with various levels of SNR and the Manhattan metric has better performance than with the Euclidean metric . In the simulation four builds a network M-ART (Mutiple Adaptive resonance theory) like structure M-SOM network in order to verify that this network also becomes able to identify automatically the modulation and also performs demodulation of signals modulated using as dissimilarity measure and Euclidean distance training using modulated signals contaminated with various levels of SNR. In the simulation five, using the same network with the *Manhattan* metric as a measure of dissimilarity and training using modulated signals contaminated with various levels of SNR to effect performance comparison with the results obtained in the simulation four. At the end of this work has reached the following conclusions : that the dissimilarity measure which enabled better performance of neural networks studied was Euclidean distance and training process that provided better performance of ANN training was tested using modulated signals contaminated with various levels SNR. Can be also observed that the two self-organizing networks , M –SOM and M -ART enables the correct automatic classification

of modulated signals presented and operate satisfactorily in the demodulation process these signals. The networks self-organizing with competitive learning studied are thus viable alternatives to replace a device dedicated *hardware* for automatic recognition modulation , as well as a platform for integrating a *software* defined radio , operating as signal demodulation stage.

Key words: Self-Organizing Networks. M-SOM. M-ART. Automatic Modulation Recognition. Demodulation.

Lista de Ilustrações

Figura 2.1: Estrutura do neurônio biológico.	26
Figura 2.2: Neurônio artificial.	28
Figura 2.3: Funções de ativação.	29
Figura 2.4: Exemplo de rede neural como um grafo orientado.	31
Figura 2.5: Algumas arquiteturas de RNA.	33
Figura 2.6: Diagrama em blocos ilustrativo de aprendizado Supervisionado.	35
Figura 2.7: Diagrama em blocos ilustrativo de aprendizado não-supervisionado.	36
Figura 2.8: Diagrama em blocos ilustrativo de aprendizado por reforço.	36
Figura 2.9: Grade bidimensional de neurônios.	40
Figura 2.10: Tipos de estímulos produzidos de acordo com a função chapéu mexicano.	42
Figura 2.11: Rede de Kohonen.	45
Figura 2.12: Função de vizinhança gaussiana.	47
Figura 2.13: Redução da região de vizinhança.	47
Figura 2.14: Rede ART, uma topologia com conexões retro-alimentadas.	52
Figura 2.15: Fluxo de informações na Rede ART-1.	53
Figura 2.16: Diagrama em blocos de um RDS.	59
Figura 2.17: Proposta de um front-end de RF para um RDS.	59
Figura 2.18: Exemplo de implementação de um RDS.	60
Figura 2.19: Benefícios do rádio cognitivo.	62
Figura 2.20: Conceito de arquitetura de rádio cognitivo.	63
Figura 2.21: Elementos de um sistema de comunicação.	66
Figura 2.22: Modelo espectral para o ruído branco.	67
Figura 2.23: Modelo do canal do ruído branco.	68
Figura 2.24: Curva Gaussiana do ruído branco.	69
Figura 2.25: Exemplo de modulações digitais ASK, FSK e PSK.	71
Figura 2.26: Constelação de sinais para 2PSK e QPSK.	73
Figura 2.27: Constelação 8-PSK.	74
Figura 2.28: Efeito do ruído na modulação PSK.	75
Figura 2.29: Efeito do ruído constelações 4-PSK e 8-PSK.	75
Figura 2.30: Comparação da sensibilidade do receptor ao ruído para diferentes esquemas PSK e FSK.	77

Figura 3.1: Descrição gráfica das métricas Manhattan e Euclidiana.	84
Figura 4.1: Teste de generalização dos classificadores.	86
Figura 4.2: modulação FSK gerada no matlab.	90
Figura 4.3: modulação BPSK gerada no matlab.	90
Figura 4.4: modulação QPSK gerada no matlab.	91
Figura 4.5: Estrutura da trabalho.	96
Figura 4.6: Estrutura da rede SOM criada para classificação e demodulação.	97
Figura 4.7: Exemplo do mapeamento da rede SOM FSK.	99
Figura 4.8: Exemplo do mapeamento da rede SOM BPSK.	99
Figura 4.9: Rotulagem da rede SOM para demodulação.	100
Figura 4.10: Sinais do processo de demodulação 2FSK.	105
Figura 4.11: Sinais do processo de demodulação BFSK.	106
Figura 4.12: Estrutura da rede arte criada para classificação e demodulação.	108

Lista de gráficos

- Gráfico 4.1: Percentual de erro na demodulação FSK e BPSK com relação à SNR para primeiro cenário de treinamento da rede SOM. 102
- Gráfico 4.2: Percentual de erro na demodulação FSK e BPSK com relação à SNR para o segundo cenário de treinamento da rede SOM. 103
- Gráfico 4.3: Percentual de erro na demodulação de sinais FSK e BPSK com relação à SNR para o segundo cenário de treinamento da rede SOM e com o uso da métrica *Manhattan*. 104
- Gráfico 4.4: Percentual de erro na demodulação FSK e BPSK com relação à SNR para a rede ART com métrica Euclidiana. 111
- Gráfico 4.5: Percentual de erro na demodulação 2FSK , BPSK e QPSK com relação à SNR para a rede ART, utilizando a métrica *Manhattan*. 113

Lista de quadros

Quadro 4.1 : Síntese dos dados utilizados na geração dos sinais modulados.	93
--	----

Lista de tabelas

Tabela 2.1: Rádio cognitivo habilita novas aplicações e amplia o desempenho dos sistemas	62
Tabela 2.2: taxa de erro de bits (BER) para diferentes modulações digitais.	77
Tabela 4.1: Percentual de erro na demodulação 2FSK e BPSK com a SNR para primeiro cenário de treinamento da rede SOM.	101
Tabela 4.2: Percentual de erro na demodulação 2FSK e BPSK com a SNR para o segundo cenário de treinamento da rede SOM.	103
Tabela 4.3: Percentual de erro nas demodulações de sinais 2FSK e BPSK com a SNR para o segundo cenário de treinamento da rede SOM e com uso da métrica <i>Manhattan</i> .	104
Tabela 4.4: Percentual de erro na demodulação 2FSK , BPSK e QPSK com a SNR para a rede ART, utilizando a métrica Euclidiana.	111
Tabela 4.5: Percentual de erro na demodulação 2FSK , BPSK e QPSK com a SNR para a rede ART, utilizando a métrica <i>Manhattan</i> .	112
Tabela 4.6: Comparação do desempenho das redes no processo de classificação da modulação para BPSK e 2FSK.	114
Tabela 4.7: Comparação do desempenho das redes no processo de demodulação dos sinais.	114
Tabela 4.8: Erro teórico para modulação BPSK devido ao ruído (AWGN).	115
Tabela 4.9: Erro teórico para modulação 2FSK devido ao ruído (AWGN).	115

Lista de abreviaturas

- ART- Adaptive resonance theory.
- AWGN- Additive white Gaussian Noise.
- BER- Bit Error Rate.
- BPSK- Binary Phase Shift Keying.
- DSP- Digital Signal Processors.
- FI- Frequência Intermediária.
- FPGA- Field-Programmable Gate Arrays.
- FSK- Frequency-Shift Keying.
- GPP- General-Purpose Processors.
- IA- Inteligência Artificial.
- MLP-Multi Layer Perceptron.
- NSRBN- Sigmoidal Regression Blocks Networks.
- PSK- Phase Shift Keying.
- RAM-Reconhecimento Automático de Modulação.
- RDS- Rádio Definido por Software.
- RF- Rádio Frequência.
- RMS- Root Mean Square.
- RNA- Rede Neural Artificial.
- SNR- Signal-to-noise ratio , também abreviado por S/N.
- SoC- sistema programável no Chip (SoC).
- SOM – Self-Organizing Map ou Mapa Auto-Organizável.
- UAV-Unmanned Aerial Vehicle.

SUMÁRIO

CAPÍTULO I	19
1.INTRODUÇÃO	19
1.1 SITUAÇÃO PROBLEMA	21
1.2 JUSTIFICATIVA E RELEVÂNCIA	21
1.3 QUESTÕES NORTEADORAS	22
1.4 OBJETIVOS.....	22
1.4.1 Geral.	22
1.4.2 Específicos.	23
1.5 ORGANIZAÇÃO DO TEXTO	23
CAPÍTULO II	25
2. REVISÃO BIBLIOGRÁFICA.	25
2.1 HISTÓRICO.....	25
2.2 O SISTEMA NERVOSO.	26
2.3 REDES NEURAIS ARTIFICIAIS	30
2.4 ARQUITETURA DA REDE NEURAL	31
2.5 ALGORÍTIMO DE APRENDIZADO	33
2.6 PROJETO DE REDE NEURAL	36
2.6.1 Coleta de dados.	37
2.6.2 Configuração da rede.	38
2.6.3 Treinamento.	38
2.6.4 Teste.	39
2.7 REDE NEURAL DE KOHONEN OU SOM (SELF ORGANIZING MAP)	40
2.7.1 Conceituação.	40
2.7.2 O algoritmo da rede SOM.	44
2.7.2.1 Processo competitivo.....	45
2.7.2.2 Processo Cooperativo.	46
2.7.2.3 Processo Adaptativo.	47
2.7.3 Algoritmo de treinamento da rede.	48
2.8 REDE NEURAL DO TIPO ART.....	50
2.8.1 Conceituação.	50
2.8.2 Topologia.	52
2.9 RÁDIO DEFINIDO POR <i>SOFTWARE</i>	55
2.9.1 Conceituação.	55
2.9.2 Rádio adaptativo.	61

2.9.3 Rádio cognitivo.	61
2.9.4 Rádio inteligente.	64
2.9.4.1 Benefícios do SDR.	64
2.10 UTILIZAÇÃO DE REDES NEURAIS NO PROCESSAMENTO DE SINAIS	65
2.11 MODULAÇÃO DIGITAL	70
2.11.1 Conceituação	70
2.11.2 Modulação FSK.	71
2.11.3 Modulação PSK.	71
2.11.4 Modulação QPSK.	72
2.11.5 Modulação 8-PSK.	73
2.11.6 Efeito do ruído nas constelações	74
2.11.7 Taxa de erro de bits	75
CAPÍTULO III	79
3 TRAJETÓRIA METODOLÓGICA	79
3.1 TIPO DE ESTUDO	79
3.2 LOCAL DO ESTUDO	81
3.3 DETERMINAÇÃO DA AMOSTRA	81
3.4 COLETA E ANÁLISE DOS RESULTADOS	81
CAPÍTULO IV	85
4. ANÁLISE E DISCUSSÃO DOS RESULTADOS	85
4.1 DESCRIÇÃO	85
4.1.1 coleta e seleção dos dados	88
4.1.1.1 Modulações FSK, BPSK e QPSK.	89
4.1.1.2 Inserção de ruído Aditivo Gaussiano Branco.	91
4.1.1.3 Descrição da geração dos dados para treinamento e teste para a rede M-SOM (As amostras criadas para a rede M-ART foram geradas de forma análoga).	92
4.2 REDES AUTO-ORGANIZÁVEIS	93
4.3 REDE AUTO-ORGANIZÁVEL DO TIPO SOM (MAPAS DE KOHONEN)	94
4.3.1 Pré-processamento	97
4.3.2 Processo de reconhecimento automático de modulação	100
4.3.3 Processo de Demodulação	100
4.4 REDE ART	106
4.4.1 Reconhecimento automático de demodulação e demodulação usando a rede ART.	107
4.4.1.1 Fase de treinamento	108
4.4.1.2 Fase de classificação.	109

4.4.1.3 resultados obtidos com as simulações da rede ART.....	110
4.5 Comparação dos resultados obtidos com as RNAs.	113
4.6 COMPARAÇÃO DOS RESULTADOS OBTIDOS PELA REDE SOM DE KOHONEN COM O VALOR TEÓRICO IDEAL DA TAXA DE ERRO.	115

CAPÍTULO V

5. CONSIDERAÇÕES FINAIS.....	116
5.1 CONTRIBUIÇÕES	118
5.2 TRABALHOS FUTUROS	119
REFERÊNCIAS	120
OBRAS CONSULTADAS	124

CAPÍTULO I

1.INTRODUÇÃO

O presente trabalho possui como objetivo realizar um estudo do uso de redes neurais artificiais (RNAs) do tipo auto-organizáveis para o problema de Reconhecimento Automático de Modulação (RAM).

Segundo Horewicz, Nascimento Jr e Parrela (2008, p.1):

Reconhecimento automático de modulação digital de sinais de comunicações é um importante problema de processamento de sinais relacionado ao campo das comunicações. Encontra-se num passo intermediário entre a interceptação do sinal e a recuperação da informação, identificando automaticamente o tipo de modulação do sinal recebido para sua posterior demodulação. Possui diversas aplicações, tais como: vigilância eletrônica, avaliação de ameaças confirmação de sinais, gerenciamento do espectro eletromagnético, utilização em Rádios Definidos por *Software* (RDS), entre outros.

Segundo Baptista (2008, p.1), o reconhecimento e a classificação automática do formato da modulação de um sinal é uma tarefa importante nos sistemas modernos de rádio, especialmente em toda a temática relacionada com a gestão de espectro, trata-se de um assunto de grande atualidade e um problema relevante para:

- **Novos sistemas comerciais-** devido ao desenvolvimento da tecnologia de RDS (Rádio definido por *Software*) em que os receptores recebem informação suplementar do transmissor para a sua reconfiguração.
- **Nos organismos de regulação-** que possuem responsabilidades na gestão do espectro eletromagnético, e que necessitam efetuar a verificação da conformidade da sua utilização, assim como de identificar e localizar fontes de sinais clandestinas.
- **Aplicações militares-** na implementação de avançados sistemas, onde sinais amigáveis devem ser recebidos em segurança, enquanto os sinais “hostis” devem ser localizados e identificados.

Sem o conhecimento prévio dos parâmetros da transmissão, realizar o reconhecimento automático da modulação é uma tarefa difícil, e torna-se um desafio maior num cenário real, onde existe uma série de condicionantes relativas ao canal de transmissão que alteram as condições de recepção do sinal transmitido.

Para Freitas, Klautau e Costa (2008, p.2): “o classificador de modulação digital é um sistema que automaticamente identifica o tipo de modulação do sinal recebido, sem o conhecimento de alguns parâmetros prévios, tais como frequência da portadora, taxa de amostragem, nível de ruído etc.”.

Neste trabalho, serão utilizadas duas RNAs devido à sua capacidade intrínseca de realizar classificação de seus sinais de entrada: a rede do tipo mapa auto-organizável de Kohonen e a rede do tipo ART.

Como afirmado por Teuvo Kohonen (1990, p.13), uma das áreas em que se esperam resultados mais promissores para a sua nova arquitetura de redes neurais artificiais (os mapas auto-organizáveis de Kohonen) é a área de telecomunicações. A grande versatilidade apresentada pelas RNAs nas suas diversas arquiteturas e possíveis topologias gera um vasto campo de possibilidades de aplicações, cabe ao desenvolvedor definir o problema a ser solucionado pela rede neural, e com isto, definir qual a RNA que melhor se aplicará à situação em análise, assim como a melhor topologia a ser escolhida, bem como, os seus parâmetros e critérios de treinamento.

“As redes neurais artificiais vêm ganhando cada vez mais adeptos, de modo que as pesquisas nesta área estão evoluindo geometricamente, portanto, isto a torna uma tecnologia bastante promissora para o desenvolvimento de aplicações, utilizando inteligência artificial. O sucesso das redes neurais está diretamente relacionado com a sua alta versatilidade no que tange ao escopo de suas aplicações, pois existem aplicações para as mais variadas áreas, podendo ser utilizada para tarefas que vão desde o desenvolvimento de sistemas especialistas, passando por aplicações nas neurociências e podendo servir até mesmo para problemas complexos de análise estatística” (VIEIRA; ROISENBERG, 2006, p.14).

O presente trabalho consiste em desenvolver, em Matlab, uma rotina computacional que realize o reconhecimento automático de modulação e a demodulação de sinais modulados utilizando para este propósito uma rede neural artificial do tipo SOM (Self-Organizing Map ou Mapa Auto-Organizável).

As simulações empreendidas com a arquitetura proposta nesta dissertação são realizadas com a inserção de ruído aditivo gaussiano branco (AWGN) gerado no Matlab, visando aproximar o experimento das condições reais de um canal de propagação, auferindo, com isto, resultados mais precisos.

1.1 SITUAÇÃO PROBLEMA

Uma rede Neural Artificial do tipo Mapa Auto-Organizável é capaz de identificar corretamente um sinal digital e demodulá-lo?

1.2 JUSTIFICATIVA E RELEVÂNCIA

A Marinha do Brasil possui Estações Radiogoniométricas distribuídas pelo território nacional, sendo uma de suas atribuições monitorar as comunicações de embarcações localizadas em áreas fluviais ou marítimas de interesse. Sendo uma etapa essencial para essa tarefa, o reconhecimento do tipo de modulação do sinal monitorado, a fim de posteriormente se efetuar a sua demodulação, reconhecendo o conteúdo da transmissão com o propósito de colher informações estratégicas como: o tipo de embarcação (por exemplo, se é navio pesqueiro, de pesquisa científica, de guerra, cargueiro ou outros), sua nacionalidade, sua rota marítima, ou derrota, e seu propósito. De posse destas informações, pode-se, se for o caso, adotar conseqüentemente as contramedidas necessárias para resguardar os interesses nacionais, assim como gerar um banco de dados com informações relevantes sobre cada embarcação já monitorada.

As Estações possuem um *hardware* dedicado, que faz a identificação do tipo de modulação dos sinais recebidos, para que o operador demodule devidamente o sinal em um receptor (outro *hardware*).

Sintetizar o *hardware* supracitado em *software*, utilizando uma rede neural, poderá vir a aumentar os níveis de portabilidade, de processamento, de flexibilidade e de integração do sistema. Além de propiciar a redução de custos, (visto que, o *hardware* é importado, sendo com isto a sua manutenção onerosa), e a nacionalização do sistema (que é uma das diretrizes buscadas pela força a fim de se alcançar a independência tecnológica, e, por conseguinte, contribuir com a soberania nacional).

1.3 QUESTÕES NORTEADORAS

1.3.1 Redes neurais do tipo mapa auto-organizável (SOM) podem ser utilizadas na identificação e na demodulação de sinais digitais?

1.3.2 As redes neurais do tipo SOM possuem um desempenho satisfatório no processo de demodulação a ponto de substituir um *hardware* demodulador dedicado?

1.3.3 Como é o desempenho da rede neural do tipo SOM em comparação com o da rede neural do tipo ART no que diz respeito à identificação e à demodulação dos sinais digitais?

1.4 OBJETIVOS

1.4.1 Geral.

O trabalho tem como objetivo estudar o emprego de redes SOM na identificação e na demodulação dos sinais digitais visando substituir um *hardware* dedicado e caro por um *software* que utilizando intrinsecamente uma rede neural artificial que seja capaz de realizar as suas funções de forma a aumentar os níveis de portabilidade processamento, flexibilidade

e integração do sistema. Aumentando o nível de automação do processo de interceptação dos sinais, facilitando a sua utilização por parte dos operadores de uma estação Rádio.

1.4.2 Específicos.

Efetuar a identificação e a demodulação de sinais modulados em 2FSK e BPSK utilizando para este propósito redes neurais artificiais do tipo mapas auto-organizáveis.

1.5 ORGANIZAÇÃO DO TEXTO

O presente trabalho foi organizado em cinco capítulos. No capítulo um, há a introdução, a justificativa da pesquisa, as questões norteadoras e os objetivos do trabalho.

No capítulo dois, é realizada uma revisão da literatura contendo os conteúdos que servem de referência e suporte para o trabalho. Foi dada ênfase ao estudo das redes neurais artificiais, sobretudo as redes auto-organizáveis do tipo SOM de Kohonen e do tipo ART. São abordados tópicos sobre os sinais modulados utilizados nas simulações, ruído aditivo gaussiano que é gerado no Matlab a fim de ser acrescentado ao sinal modulado com o propósito de tornar as simulações mais próximas do real e um tópico sobre rádio definido por *software* que é uma plataforma que pode incorporar no seu estágio de recepção a tecnologia das RNAs.

No capítulo três há a descrição da metodologia aplicada no presente ao trabalho.

No capítulo quatro é realizada a análise dos dados obtidos. São realizadas cinco simulações no Matlab onde as redes neurais artificiais do tipo ART e do tipo SOM de Kohonen são treinadas em duas situações e testadas com duas medidas de dissimilaridade com o propósito de classificar os sinais modulados e demodulá-los. Os resultados obtidos são primeiramente apresentados em separado para cada uma das duas redes neurais e depois é apresentada uma comparação do desempenho das duas RNAs auto-organizáveis nos processos de identificação das modulações e de demodulação dos sinais.

E no capítulo cinco, são apresentadas as conclusões obtidas com o trabalho, são relacionadas propostas para trabalhos futuros e citadas as contribuições propiciadas por esta dissertação.

CAPÍTULO II

2. REVISÃO BIBLIOGRÁFICA.

2.1 HISTÓRICO

A busca de um modelo computacional que simule o funcionamento do cérebro humano data da década de 40 do século anterior com as pesquisas de McCulloch e Pitts (1943). Nas décadas de 50 e 60 se intensificaram as pesquisas sobre redes neurais artificiais e Rosenblat (1958) desenvolveu um novo método de aprendizagem para as redes neurais chamado de perceptron. No final na década de 60, Minsky e Pappert (1969) publicaram suas pesquisas e revelaram limitações do perceptron, o que juntamente com dificuldades tecnológicas da época, desestimulou novas pesquisas na área até a década de 80, quando Hopfield (1982) publicou um artigo sobre as propriedades associativas das RNAs, reacendendo o interesse nessa área de pesquisa.

Dois outros fatores foram responsáveis pela retomada de interesse na área: em primeiro lugar, o avanço da tecnologia, sobretudo da microeletrônica, que permitiu a realização física de modelos de neurônios e sua conexão de um modo antes impensável; em segundo, o fato de a escola de IA simbólica, a despeito de seu sucesso na solução de determinados tipos de problemas, não ter conseguido avanços significativos na resolução de alguns problemas simples para um ser humano. (BRAGA; CARVALHO; LUDERMIR, 2012, p.6).

Nos dias atuais, as redes neurais artificiais estão largamente presentes nas nossas vidas. Existem, aplicações realizando as mais diversas funções, como por exemplo: a navegação embarcada de veículos não tripulados, chamados de UAV (*Unmanned Aerial Vehicle*) ou *drones*, previsões climáticas ou financeiras, e o reconhecimento de face ou de voz. As redes neurais são também aplicadas atividades de lazer como jogos eletrônicos, como também, na administração de empresas, realizando a mineração de dados de banco de dados a fim de gerar informações estratégicas para a gestão de determinadas organizações.

As RNAs estão difundidas em diversas áreas de atuação: sistemas de controle e automação, sistemas de predição ou prospecção e classificação de padrões, gerando um abrangente, multifacetado e aberto campo de pesquisas a seu respeito.

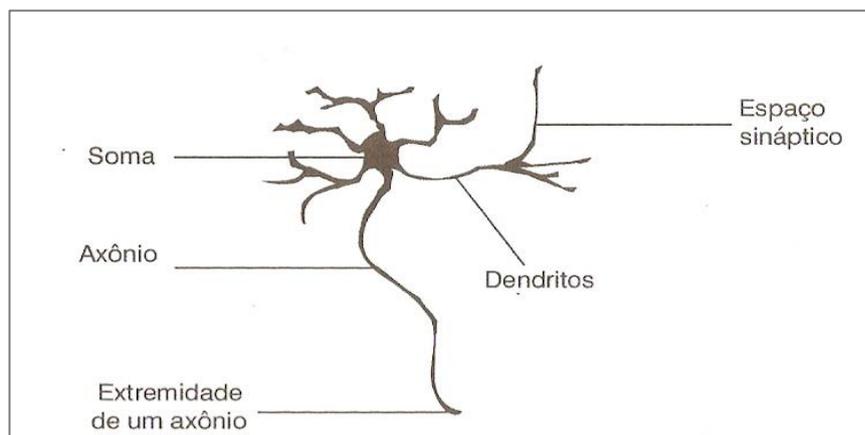
2.2 O SISTEMA NERVOSO.

Segundo Haykin (2008, p.27): As pesquisas em redes neurais artificiais têm sido motivadas desde seu início pelo reconhecimento que o cérebro processa informações de uma maneira diferente que o computador digital convencional. O cérebro humano é um computador, é um sistema de processamento de informações, altamente complexo, não linear e paralelo. E possui a capacidade de organizar seus constituintes estruturais, conhecidos como neurônios, de maneira a realizar certos processamentos.

O Sistema Nervoso é composto por bilhões de neurônios interligados entre si, que se comportam de maneira altamente complexa. Os principais componentes do neurônio biológico são os seguintes:

- **Dentritos:** recebem os sinais oriundos dos outros neurônios da rede neural;
- **Corpo do neurônio:** que também é chamado de soma e é responsável por combinar os sinais vindos dos outros neurônios; e.
- **Axônio:** é responsável por transmitir os sinais para outros neurônios.

A figura 2.1 ilustra o neurônio biológico:



Fonte: (BRAGA, CARVALHO e LUDERMIR, 2012, p.7).

Figura 2.1: Estrutura do neurônio biológico.

A comunicação entre os neurônios da rede é realizada através de impulsos (não é uma corrente elétrica, mas uma corrente de íons de sódio e de potássio). Antes de o sinal atingir o próximo neurônio, ele deve passar por uma sinapse, que consiste no processo de ligação entre o axônio e o dendrito. Esta passagem é química e acontece graças uma substância neurotransmissora.

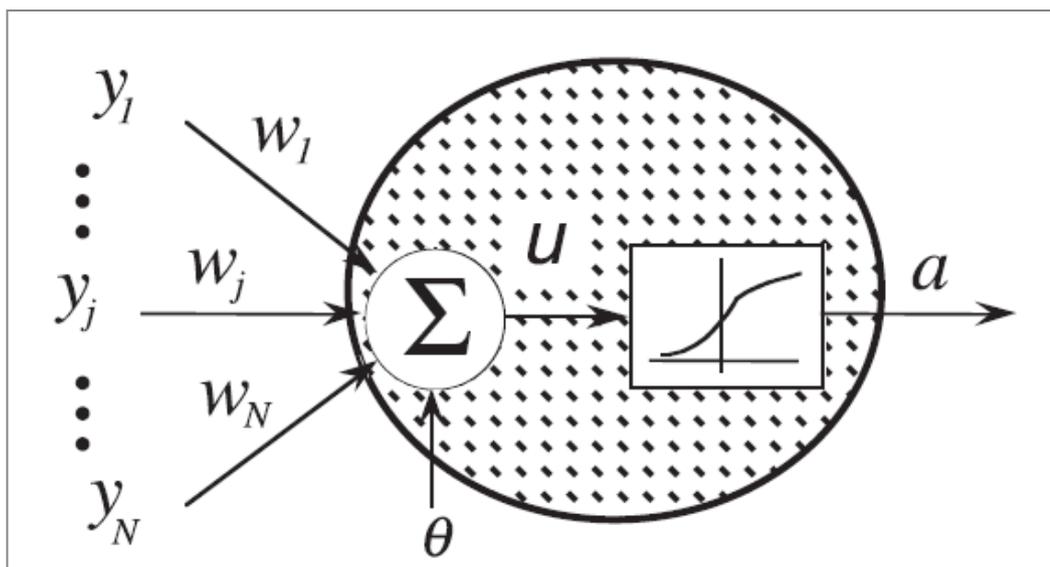
O ponto de contato entre a conexão axônica de um neurônio e o dendrito de outro é chamado de sinapse. É pelas sinapses que os neurônios se unem funcionalmente, formando as redes neurais biológicas. As sinapses funcionam como válvulas, e são capazes de controlar a transmissão de impulsos- isto é, o fluxo da informação entre neurônios na rede neural. (BRAGA; CARVALHO; LUDERMIR, 2012, p.6).

Se o sinal for acima de um limite (*threshold*), prossegue em frente, se for inferior a este limite ele é bloqueado. Na passagem através de um neurônio, um sinal pode ser atenuado ou amplificado, dependendo do dendrito de origem, pois a cada condutor está associado um peso pelo qual o sinal é multiplicado.

O cérebro humano é subdividido em regiões que executam trabalhos específicos, como por exemplo, processamento de imagens, processamento de sons, gerenciamento das atividades motoras, etc. Estes processamentos ocorrem em redes independentes que possuem arquiteturas diferentes, com números de neurônios e de sinapses diferentes, com diferentes valores de limites (*thresholds*) e de pesos. Estas redes são interligadas entre si e realizam um processamento em paralelo.

O conhecimento atual sobre a forma como as funções cerebrais são realizadas é ainda bastante obscuro. O que se tem, até o momento são teorias, as quais são reavaliadas a cada nova descoberta. No entanto, o comportamento individual dos neurônios biológicos é bem entendido do ponto de vista funcional, e é exatamente nesse comportamento conhecido que se baseiam as RNAs (BRAGA; CARVALHO; LUDERMIR, 2012, p.6).

O modelo de neurônio artificial mais simples que engloba as principais características de uma rede neural biológica, como por exemplo, paralelismo e alta conectividade, foi proposto por McCulloch and Pitts (1943), sendo ainda o modelo mais utilizado nas diferentes RNAs (SILVA; SPATI; FLAUZINO, 2010, p.33). Sendo ilustrado na figura 2.2.



Fonte: (HU et al., 2002, p.13).

Figura 2.2: Neurônio artificial.

O neurônio artificial ou matemático, de maneira similar ao neurônio biológico, recebe os sinais de entrada e devolve um único sinal de saída. Os axônios e os dendritos são representados pelas sinapses e a intensidade das ligações são representadas pelos pesos sinápticos.

Neste modelo, os sinais elétricos vindos de outros neurônios são representados pelos sinais de entrada, y_j , (sendo: $1 \leq j \leq N$) dentre os vários estímulos recebidos, alguns irão excitar menos e outros mais, o neurônio receptor, essa medida de quão excitatório é o estímulo é representada no modelo através de pesos sinápticos. Quanto maior o valor do peso implica que o estímulo é mais excitatório. Os pesos sinápticos são representados por w_j , onde j se refere ao terminal de entrada da sinapse à qual o peso se refere.

A soma é representada por uma composição de dois módulos, o primeiro é uma junção aditiva, somatório dos estímulos (sinais de entrada) multiplicado pelo seu fator excitatório (pesos sinápticos) e posteriormente uma função de ativação que definirá com base nas entradas e pesos sinápticos qual será a saída do neurônio. O axônio é aqui representado pela saída (a) obtida pela aplicação da função de ativação. Desta maneira, o estímulo pode ser inibitório ou excitatório, dependendo se o peso sináptico é negativo ou positivo.

Este modelo possui uma natureza binária, tanto os sinais de entrada, quanto os de saída, são valores binários. Segundo HAYKIN (1999), esta característica do modelo de McCulloch e Pitts foi referenciada como propriedade do “tudo ou nada”.

Matematicamente, pode ser representado por:

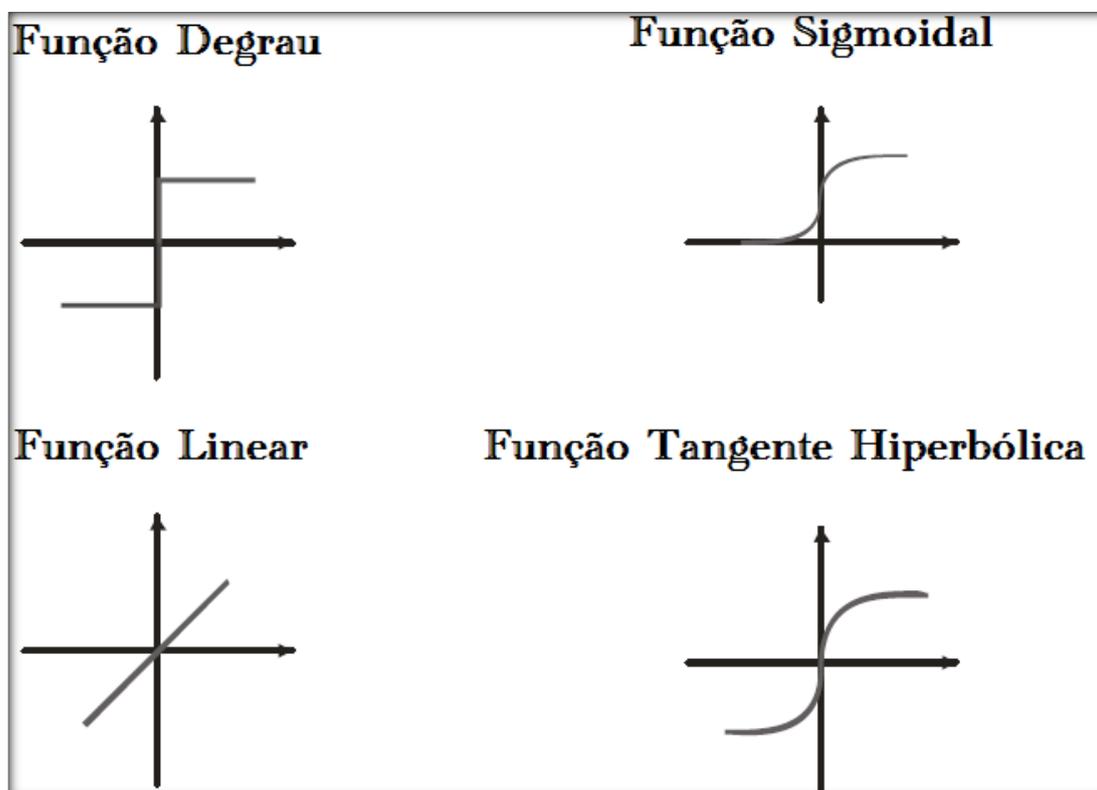
$$u = \sum_{j=1}^m w_{kj} * x_j + b_0 \quad (2.1)$$

$$a = f(u) \quad (2.2)$$

Onde, m é o número de entradas existentes, b_0 é o bias, e $f(u)$ é a função de ativação.

“A função de ativação é responsável por gerar a saída do neurônio a partir dos valores dos vetores de peso e da entrada” (BRAGA; CARVALHO; LUDERMIR, 2012, p.9).

Existem várias funções de ativação que podem ser utilizadas dependendo do objetivo desejado, ou seja, do tipo de problema a ser abordado. Mais notavelmente, temos as seguintes: função degrau, a função sigmoideal, a função linear e a função tangente hiperbólica apresentadas na figura 2.3.



Fonte: (HU et al., 2002, p.14).

Figura 2.3: Funções de ativação.

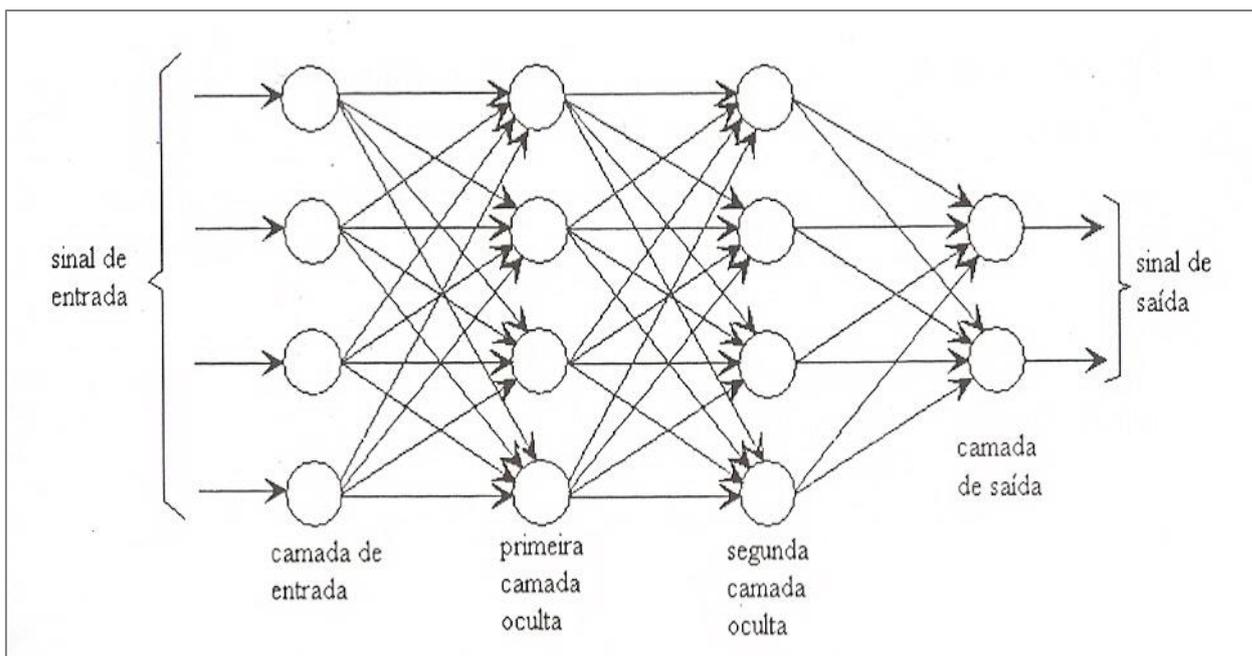
2.3 REDES NEURAIS ARTIFICIAIS

Uma Rede Neural Artificial (RNA) é um modelo matemático que se comporta de forma análoga à operação do sistema de uma rede neural biológica. As RNA são modelos computacionais com propriedades específicas como: capacidade de adaptação ou aprendizado, tolerância a falhas, capacidade de generalização e de agrupar ou classificar dados. Segundo Braga, Carvalho e Ludemir (2012, p.3), as RNAs são sistemas paralelos distribuídos formados por neurônios artificiais que calculam determinadas funções matemáticas, normalmente não lineares. Tais neurônios estão dispostos em uma ou mais camadas interligadas por um grande número de conexões, geralmente unidirecionais. E na maioria das topologias essas conexões estão associadas a pesos, os quais armazenam o conhecimento adquirido pela rede e servem para ponderar a entrada recebida pela RNA.

Uma RNA é constituída por um conjunto de neurônios interconectados que influenciam uns aos outros, formando um sistema maior capaz de armazenar conhecimento adquirido por meio dos exemplos apresentados. Tornando-se habilitada a realizar inferências sobre situações desconhecidas. “A arquitetura de uma rede neural artificial define como os seus diversos neurônios estão arranjados, ou dispostos, uns em relação aos outros. Esses arranjos são essencialmente estruturados através do direcionamento das conexões sinápticas” (SILVA; SPATTI; FLAUZINO, 2010, p.45).

Haykin (2012, p.28), define um RNA como: um processador maciçamente paralelamente distribuído, que tem a habilidade natural de armazenar conhecimento experimental e torná-lo disponível para uso. O conhecimento é adquirido no processo de aprendizagem através da interação com o ambiente, e é armazenado nos pesos sinápticos da rede.

As redes neurais são comumente apresentadas como um grafo orientado, onde os vértices são os neurônios e as arestas as sinapses, a direção das arestas informa o tipo de alimentação, ou seja, como os neurônios recebem sinais de entrada. Um exemplo de uma rede neural como um grafo orientado é mostrado na figura 2.4.



Fonte: LUDWIG JR e MONTGOMERY (2007, p. 15).

Figura 2.4: Exemplo de rede neural como um grafo orientado.

As redes neurais artificiais derivam sua capacidade em razão de sua estrutura massiva e paralela e da sua habilidade de aprender com experiências, onde esta experiência é transmitida por meio de exemplos obtidos do mundo real, definidos como um conjunto de características que levam a uma determinada situação. O conhecimento obtido pela rede neural é armazenado na forma dos pesos sinápticos, os quais são ajustados, a fim de tomar decisões a partir de novas entradas. O processo de ajuste dos pesos acontece graças ao algoritmo de aprendizagem responsável para que o conhecimento obtido através de exemplos seja gravado. Um exemplo de algoritmo de aprendizagem é o *back-propagation*.

2.4 ARQUITETURA DA REDE NEURAL

As conexões entre as camadas da rede são capazes de dar origem a diversas estruturas diferentes. Quando uma rede possui todas as saídas dos neurônios existentes em uma camada conectadas com todos os neurônios da camada que se segue, ela é denominada: rede amplamente conectada. Quando o sinal de saída de um neurônio servir como entrada para um ou mais neurônios em alguma camada anterior ou na mesma camada, dizemos que a

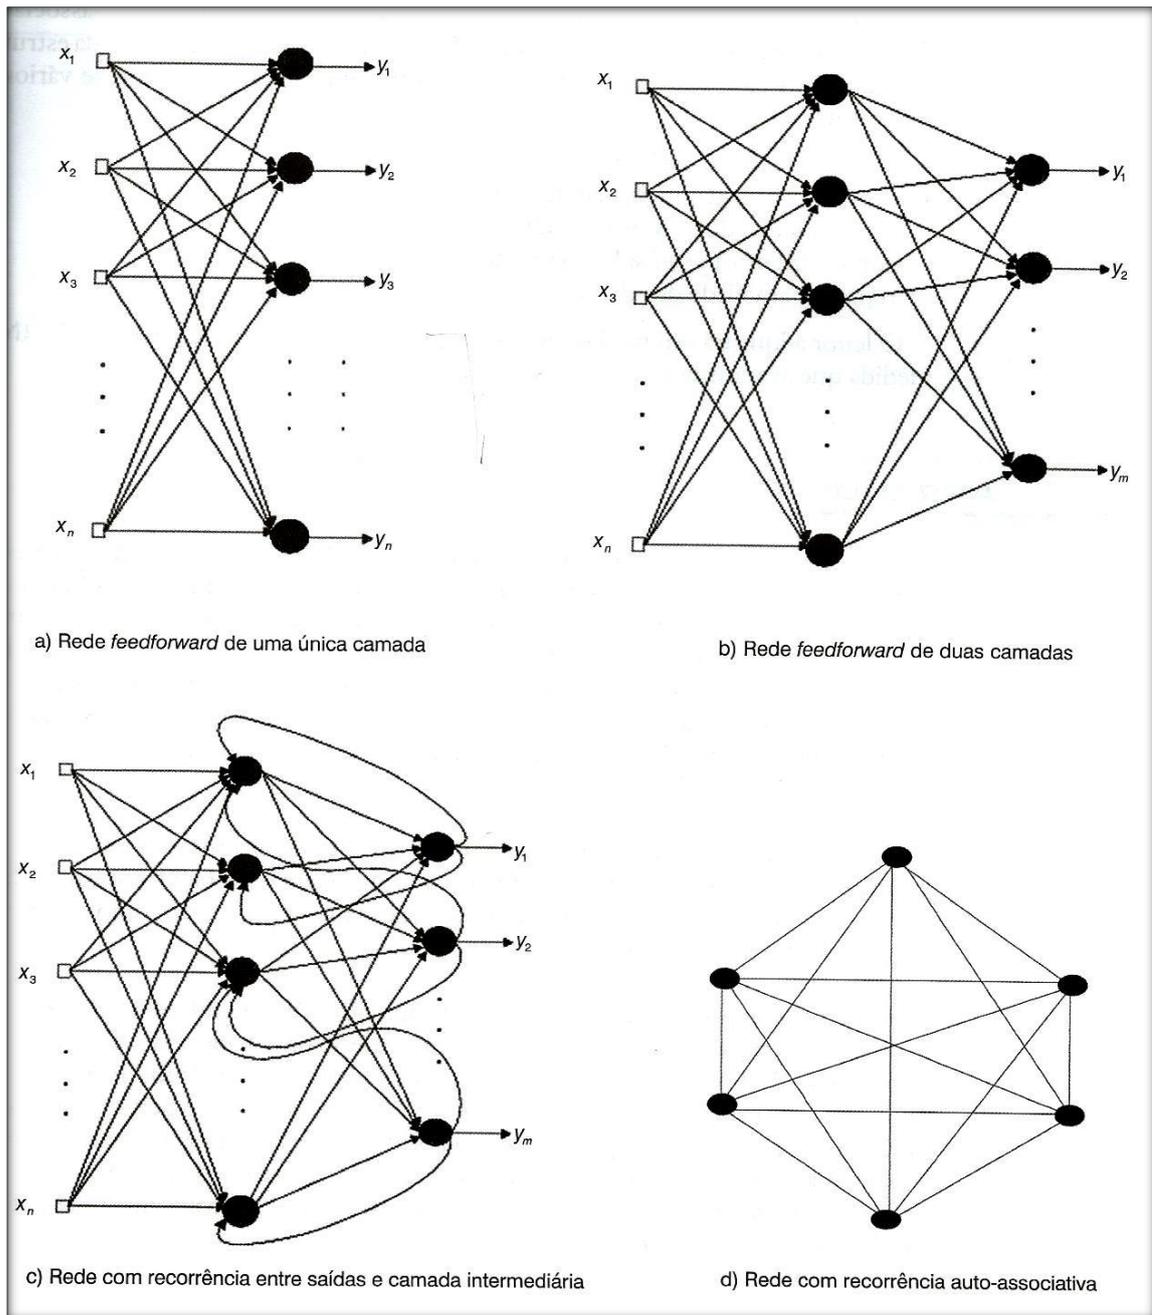
rede possui realimentação e esses laços de realimentação exercem grande influência na capacidade de aprendizado da rede neural (LUDWIG JR; MONTGOMERY, 2007, p.15).

De acordo com Silva, Spatti e Flauzino (2010, p.45), a arquitetura de uma RNA define a forma como os seus neurônios são arranjados uns em relação aos outros. Estes arranjos são definidos através do direcionamento das conexões sinápticas dos neurônios.

Segundo Silva, Spatti e Flauzino (2010, p.45), a topologia das redes neurais artificiais, considerando uma arquitetura específica, pode ser definida como sendo as diferentes formas de composições estruturais que esta rede pode assumir. A título de exemplo, podem-se ter duas topologias pertencendo a uma mesma arquitetura, onde uma é composta por 10 neurônios e outra composta por 20 neurônios. Ou ainda, uma rede com os neurônios com a função de ativação logística e a outra rede neural artificial com a função de ativação dos neurônios sendo a tangente hiperbólica.

O treinamento de uma arquitetura específica consiste na aplicação de passos ordenados com o objetivo de ajustar os pesos e os limiares dos neurônios. O algoritmo de aprendizagem é o processo de ajuste que a visa sintonizar a rede para que as suas respostas se aproximem dos valores esperados (SILVA; SPATTI; FLAUZINO, 2010, p.45).

Para Braga, Carvalho e Ludemir (2012, p.10): “Independentemente da função de ativação escolhida, neurônios individuais possuem capacidade computacional limitada. No entanto, um conjunto de neurônios artificiais conectados na forma de uma rede (neural) é capaz de resolver problemas de complexidade elevada”. A figura 2.5 ilustra algumas configurações possíveis de redes neurais artificiais.



Fonte: (BRAGA; CARVALHO; LUDERMIR, 2012, p.11).

Figura 2.5: Algumas arquiteturas de RNA.

2.5 ALGORÍTIMO DE APRENDIZADO

Uma rede neural artificial aprende sobre o seu ambiente através de um processo iterativo de ajustes realizados nos seus pesos sinápticos e nível do bias, e esse processo é conhecido como treinamento. Podendo depois de devidamente treinada ser utilizada em diversas áreas do conhecimento humano (LUDWIG JR; MONTGOMERY, 2007, p.16).

“Aprendizado é o processo pelo qual os parâmetros livres de uma rede neural são ajustados por meio de uma forma continuada de estímulo pelo ambiente externo, sendo o tipo de aprendizado definido pela maneira particular como ocorrem os ajustes dos parâmetros livres” (BRAGA; CARVALHO; LUDERMIR, 2012, p.12).

Segundo Ludwig JR e Montgomery (2007, p.17), existem diversos algoritmos de treinamento utilizados para ajustar os pesos sinápticos e os níveis dos bias. Podendo ser citados os seguintes:

- Aprendizagem por correção de erros (regra delta);
- Aprendizagem competitiva;
- Aprendizagem Hebbiana;
- Aprendizagem baseada em memória; e
- Aprendizagem de Boltzmann.

Nesse estudo, dar-se há ênfase a aprendizagem competitiva que é utilizada nas duas redes auto-organizáveis tratadas no texto e que são objetos desse trabalho: a rede SOM de Kohonen e a rede ART.

Haykin (2012, p.75) define aprendizagem no contexto das RNAs como: “A aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros livres ocorre”. É importante também ser mencionado à maneira como uma Rede Neural se relaciona com o ambiente, nesses termos existem os seguintes paradigmas de aprendizado que serão expostos a seguir.

- **Aprendizado Supervisionado:** usa-se um agente externo que, por sua vez, indica à rede a resposta desejada para o padrão de entrada. O aprendizado supervisionado é aplicado em problemas em que desejamos obter um mapeamento entre a entrada e a saída, sendo os

exemplos mais conhecidos de algoritmos para este tipo de aprendizagem a regra delta e a regra delta generalizada (algoritmo *back-propagation*) utilizadas em redes de múltiplas camadas;

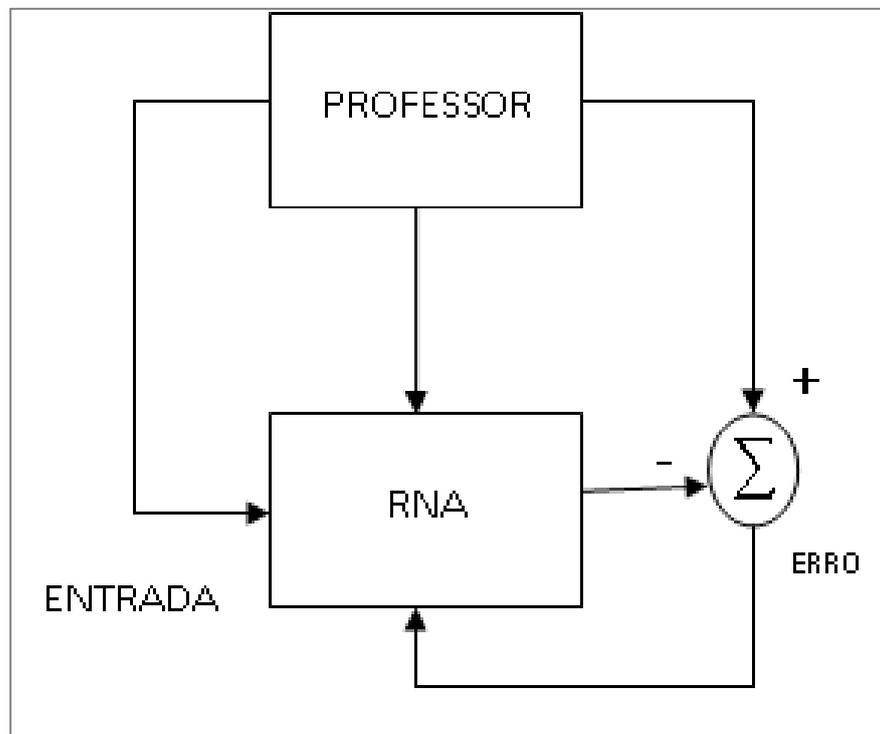


Figura 2.6: Diagrama em blocos ilustrativo de aprendizado supervisionado.

- **Aprendizado não supervisionado**, quando não existe um agente externo indicando a resposta à rede. Nele somente padrões de entrada são apresentados à rede, e a existência de regularidade nesses dados permite que o aprendizado se realize.

“Regularidade e redundância nas entradas são características essenciais para haver aprendizado não supervisionado” (BRAGA; CARVALHO; LUDERMIR, 2012, p.16).

Segundo Valença (2010, p.297): “O aprendizado não supervisionado não necessita das saídas desejadas para treinamento e por isso é conhecido como aprendizagem sem professor. Para o seu treinamento são usados apenas os valores dos exemplos da entrada da rede”.

Este tipo de aprendizado se aplica a problemas de classificação, sendo os modelos mais conhecidos: a rede ART e as redes com mapas auto-organizáveis de Kohonen.

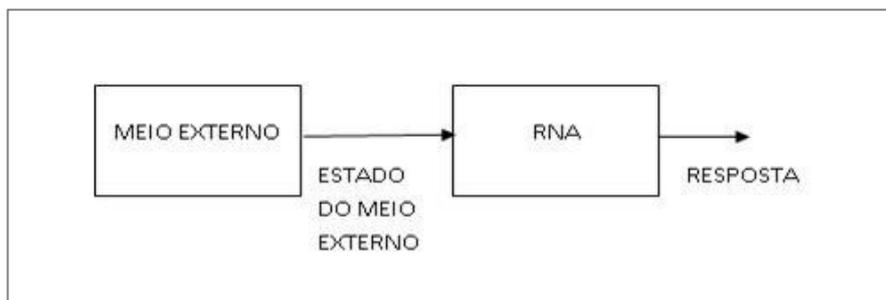


Figura 2.7: Diagrama em blocos ilustrativo de aprendizado não supervisionado.

- **Aprendizado por reforço:** Este tipo de aprendizado é muitas vezes classificado como um tipo particular de aprendizado supervisionado. Neste tipo de aprendizado, porém, um crítico externo reforça as boas ações executadas pela rede neural. Segundo Braga, Carvalho e Ludemir (2012, p.17) “O aprendizado por reforço se caracteriza como um processo de tentativa e erro que visa a maximizar o índice de desempenho escalar chamado de sinal de reforço”. O aprendizado por reforço é aplicado a tarefas de controle em que é possível errar durante a interação com o sistema que deve ser controlado.

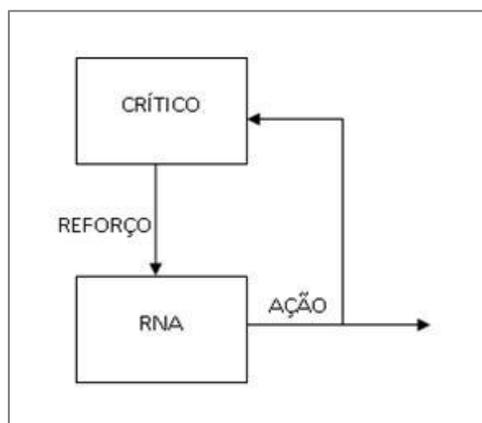


Figura 2.8: Diagrama em blocos ilustrativo de aprendizado por reforço.

2.6 PROJETO DE REDE NEURAL

De acordo com Ludwig Jr. e Montgomery (2007, p. 21 a 25), a arquitetura da RNA é critério do projetista, e deve ser testada para satisfazer os objetivos sem apresentar problemas

inerentes a esta estrutura, como por exemplo, decorando um conjunto de dados ao invés de aprender. Contudo no projeto da RNA algumas especificidades devem ser seguidas para se obter um desempenho satisfatório da rede neural projetada. Para a implementação de uma rede neural com bom desempenho se faz necessário seguir cinco etapas: coleta de dados, configuração da rede, treinamento da rede, teste da rede e integração da rede neural. Todas descritas no texto a seguir.

2.6.1 Coleta de dados.

Os dados utilizados na rede neural devem ser colhidos criteriosamente a fim reduzir a ocorrência de erros ou ambiguidades. As RNA baseiam-se nos dados coletados para extrair um modelo geral, por este motivo, a etapa de coleta de dados deve ser rigorosa a fim de evitar a geração de modelos espúrios.

Os dados coletados devem ser separados em dois conjuntos distintos: os dados utilizados no treinamento da rede neural e os dados que serão utilizados na fase de testes a fim aferir o desempenho da rede projetada.

“É recomendável a reordenação aleatória dos dados para prevenção de tendências associadas à ordem de apresentação dos dados (polarização)” (LUDWIG JR; MONTGOMERY, 2007, p. 22).

Segundo Silva, Spatti e Flauzino(2010, p.50):

Normalmente, o conjunto total das amostras disponíveis sobre o comportamento do sistema é dividido em dois subconjuntos, os quais são denominados de subconjunto de treinamento e subconjunto de teste. O subconjunto de treinamento, composto aleatoriamente com cerca de 60% a 90% das amostras do conjunto total, será usado essencialmente no processo de aprendizado da rede. Já o subconjunto de teste, cuja composição está entre 10% e 40% do conjunto total de amostras, será utilizado para verificar se os aspectos referentes à generalização de soluções por parte da rede já estão em patamares aceitáveis, possibilitando assim a validação da topologia assumida.

2.6.2 Configuração da rede.

Basicamente para efetuar a configuração de uma rede deve-se seguir quatro etapas:

- Definir a arquitetura da RNA (se a rede é MLP- *Multi Layer Perceptron*, Kohonen, etc.);
- Definir a topologia da RNA (o número de camadas da rede e o número de neurônios de cada camada);
- Definir qual o algoritmo de treinamento, a taxa de aprendizagem e os pesos da rede;
- Definir a função de transferência a ser utilizada (para uma rede MLP), ou a métrica de dissimilaridade (para redes do tipo SOM ou do tipo ART).

2.6.3 Treinamento.

Na etapa de treinamento são ajustados os pesos das conexões. São nesta fase que devem ser ajustados os parâmetros para que a RNA se habilite a responder corretamente a qualquer outro estímulo que lhe for apresentado.

Deve-se inicialmente determinar empiricamente os pesos sinápticos, o algoritmo de aprendizagem e o tempo de treinamento para a rede neural.

O treinamento é iniciado quando um exemplo é apresentado à RNA e termina quando todas as conexões estão devidamente treinadas, a fim de reconhecer todos outros exemplos apresentados à rede. Após o treinamento, a rede estará pronta para a etapa de teste e posteriormente para uso.

O grande segredo para criar uma rede neural eficaz é saber o momento de interromper o seu treinamento. Se a rede for treinada pouco, ela não irá aprender

corretamente os padrões apresentados. Se, por outro lado, a rede for treinada muito, ela irá decorar os padrões de treinamento e não irá generalizar devidamente novos padrões.

O ideal é que o treinamento venha a ser interrompido quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for admissível. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima (LUDWIG JR; MONTGOMERY, 2007, p. 24).

De acordo com Silva, Spatti e Flauzino (2010, p.51): “Durante o processo de treinamento de redes neurais artificiais, cada apresentação completa das amostras pertencentes ao subconjunto de treinamento, visando, sobretudo, o ajuste dos pesos sinápticos e limiares de seus neurônios, será denominado de época de treinamento”.

2.6.4 Teste.

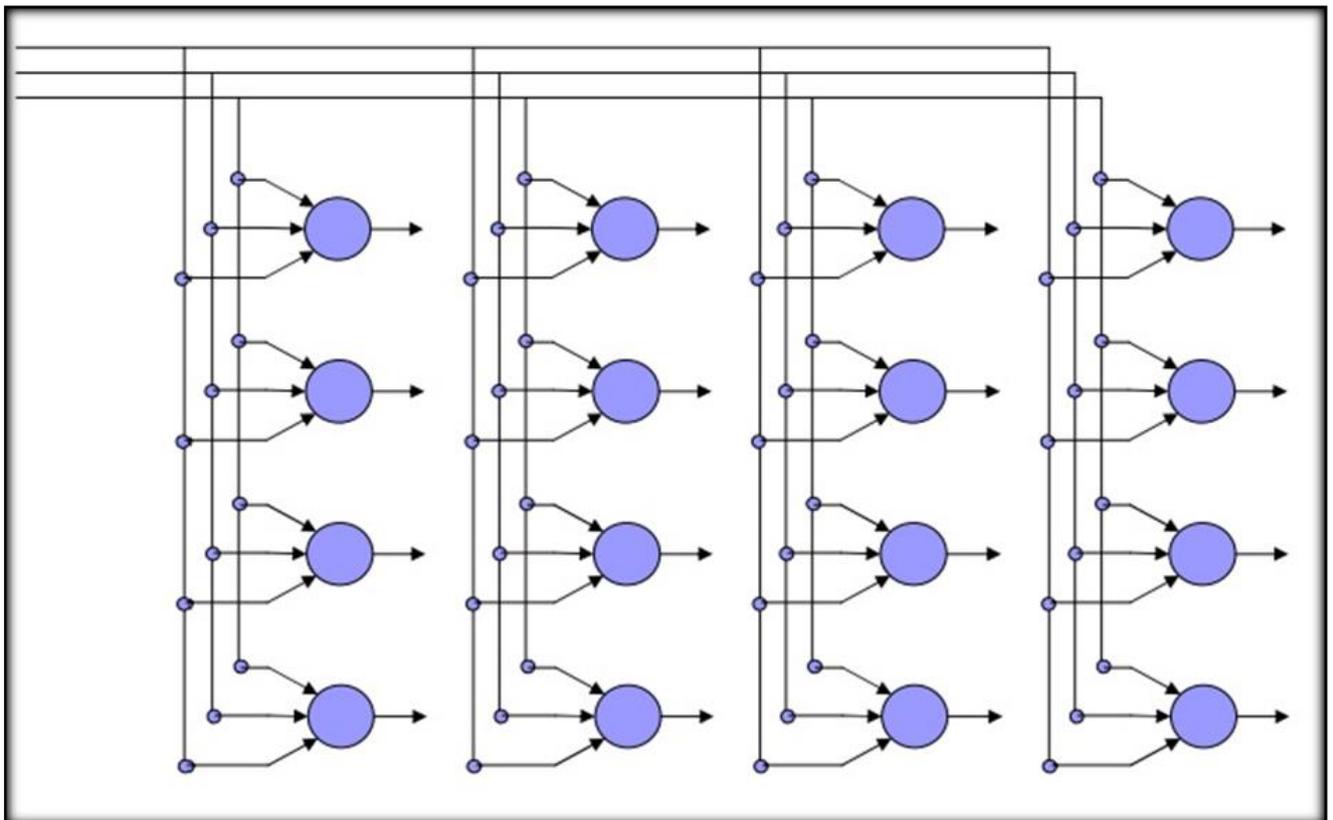
Nesta etapa de implementação da rede neural artificial utilizam-se os dados existentes no conjunto de dados coletados para a validação da rede. Estes dados ainda não foram apresentados à rede. Ao se apresentar estes dados para averiguação do desempenho da RNA deve-se verificar se a sua saída apresenta uma resposta adequada com o que se propõe o projeto.

Deve-se observar se os níveis de bias ou dos pesos estão muito pequenos, pois significa que estas conexões podem ser eliminadas ou se possuem valores muito maiores que os outros, o que significa a possibilidade de haver over-training, ou seja, a rede neural não consegue mais definir uma saída correta para os dados que estejam fora do padrão da entrada.

2.7 REDE NEURAL DE KOHONEN OU SOM (SELF ORGANIZING MAP)

2.7.1 Conceituação.

O Professor Teuvo Kohonen da universidade de Helsinki criou um modelo de rede neural que recebeu o seu nome. A rede de Kohonen é um modelo alimentado para frente de aprendizado não supervisionado (não se faz necessário apresentar a entrada e a saída esperada para que a rede aprenda). Esta rede é baseada na forma como o cérebro processa os sinais que são percebidos pelos sentidos, onde diferentes regiões processam diferentes informações. “Nesta estrutura, os neurônios estão dispostos como nós de uma grade que, normalmente, é uni ou bidimensional. No caso de um mapa bidimensional, a geometria é livre, podendo ser quadrada, retangular, triangular, etc.” (LUDWIG JR; MONTGOMERY, p. 75). A figura 2.9 exemplifica esta estrutura.



Fonte: Adaptado de: (HAYKIN, 2008, p. 487).

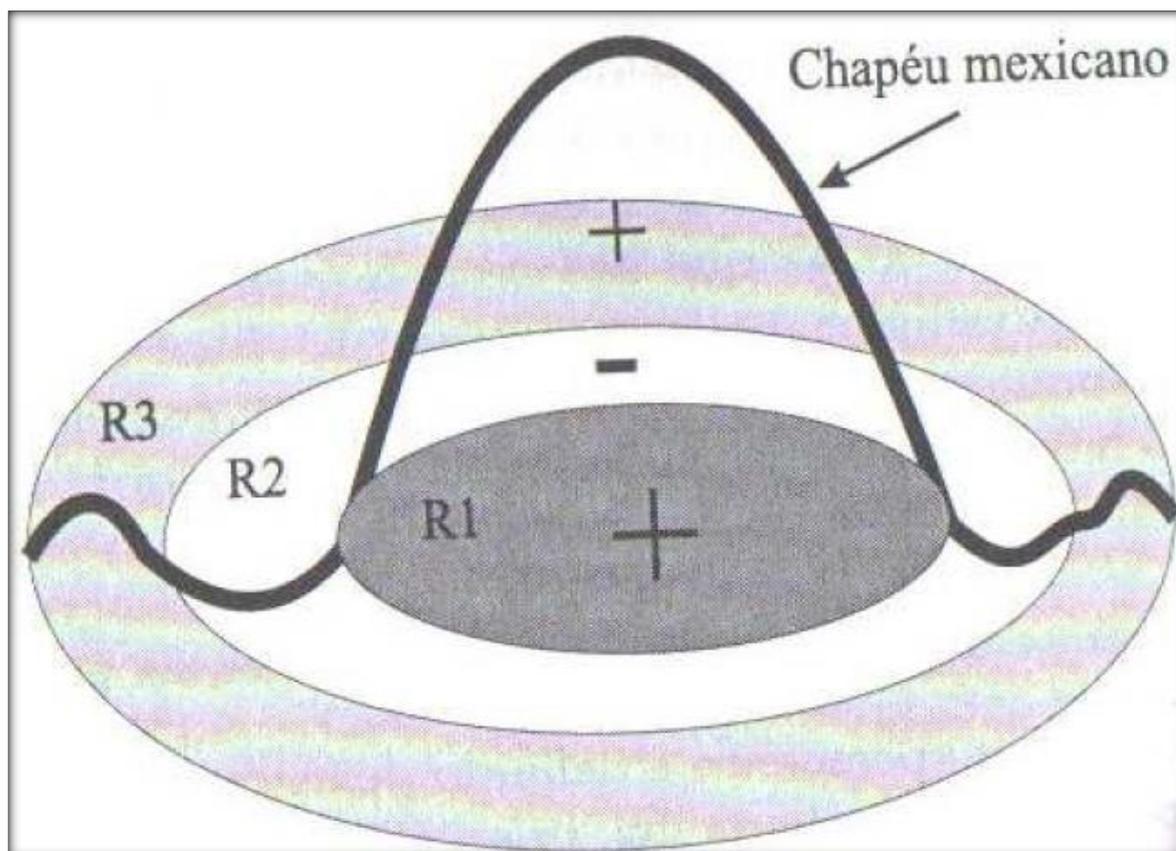
Figura 2.9: Grade bidimensional de neurônios.

Segundo Silva, Spatti e Flauzino (2010, p. 50): “A rede de Kohonen é a principal representante da arquitetura em estrutura reticulada, cujo o treinamento é realizado por meio de um processo competitivo”. Na figura 2.9 pode-se ver que os neurônios estão distribuídos no espaço bidimensional, e que nesta tipologia RNA os diversos sinais de entrada são inseridos em todos os neurônios da rede.

“A motivação para a criação deste modelo neural é a teoria de que, no cérebro, entradas sensoriais diferentes são mapeadas em regiões específicas do córtex cerebral. A isto se pode denominar de distribuição de probabilidade codificada por localização” (LUDWIG JR; MONTGOMERY, p. 76).

Segundo Braga, Carvalho e Ludimir (2012, p.99), as redes SOM possuem forte inspiração neurofisiológica sendo baseadas no mapa topológico presente no córtex cerebral. Observa-se que neurônios topologicamente próximos têm a tendência de responder a estímulos ou padrões semelhantes. Sabe-se também que esta ordenação topológica é resultado do uso de feedback lateral entre as células do córtex cerebral. Este feedback lateral é geralmente modelado em RNAs por uma função conhecida como “chapéu mexicano” (apresentada na figura 2.10), e cada neurônio influencia o estado de ativação de seus neurônios vizinhos de acordo com três formas possíveis:

1. Excitatória- se os vizinhos estão próximos a ele dentro da área de raio R1 da curva da função chapéu mexicano apresentada na figura 2.10.
2. Inibitória- se os vizinhos encontram-se dentro de uma área R2, mas fora da área formada por R1.
3. Levemente excitatória- se os vizinhos estão dentro da área de raio R3 e fora das áreas formadas pelos raios R1 e R2.



Fonte: (BRAGA; CARVALHO; LUDERMIR, 2012, p.99).

Figura 2.10: Tipos de estímulos produzidos de acordo com a função chapéu mexicano.

Para Haykin (2008, p.485), o modelo introduzido por Kohonen não se propõe a explicar detalhes neurobiológicos, ele captura as características fundamentais dos mapas computacionais do cérebro e ainda se mantém tratável do ponto de vista computacional.

Outra característica importante desta rede é que os neurônios são auto-organizáveis, isto significa que a rede à medida que se realiza o treinamento, vai criando grupos de neurônios especializados em certas entradas. Segundo Haykin (2008, p.486), o principal objetivo do mapa auto-organizável (SOM, *self-organizing map*) é transformar um padrão de sinal incidente de dimensão arbitrária em um mapa discreto e realizar esta transformação adaptativamente de uma maneira topologicamente ordenada.

A rede SOM funciona basicamente da seguinte forma: quando um padrão de entrada p é apresentado, a rede procura a unidade mais parecida com p . Durante o seu treinamento, a rede aumenta a semelhança do neurônio escolhido e de seus vizinhos ao padrão p . Desta forma, a rede constrói um mapa topológico onde os neurônios que estão topologicamente respondem de forma semelhante a padrões de entrada semelhantes. A rede SOM é uma rede biologicamente plausível, ou seja,

apresenta respaldo biológico. Assim, como no córtex cerebral, neurônios ativos apresentam conexões mais fortes com neurônios que estão fisicamente mais próximos (BRAGA; CARVALHO; LUDIMIR, 2012, p.99).

Para Braga, Carvalho e Ludimir (2012, p.99), através da utilização do conceito dos vizinhos topológicos dos neurônios vencedores, o algoritmo de treinamento da rede neural do tipo SOM emula o efeito da função chapéu mexicano. De acordo com este conceito, quando um neurônio vence a competição, não só ele tem os seus pesos ajustados, mas também os neurônios localizados na sua vizinhança.

Segundo Haykin (2008, p. 487), a figura 2.9 apresenta um diagrama esquemático de uma grade bidimensional de neurônios, consistindo em uma matriz de neurônios arranjados em linhas e colunas. Cada neurônio da grade está totalmente conectado com todos os nós de fonte da camada de entrada. Onde cada padrão de entrada apresentado à matriz ou grade de neurônios consiste tipicamente à de uma região localizada ou foco de atividade contra um fundo em repouso, sendo a localização e natureza deste foco variável de uma realização de padrão de entrada para outro.

Também para Haykin (2008, p. 487): “Todos os neurônios da grade devem, portanto, ser expostos a um número suficiente de diferentes realizações do padrão de entrada para assegurar que o processo de auto-organização tenha uma chance de amadurecer apropriadamente”. De acordo com Haykin (2008, p. 488): “a presença de redundância nos dados de entrada é necessária para a aprendizagem, pois fornece conhecimento”.

Para Haykin (2008, p. 487), o algoritmo responsável pela formação do mapa auto-organizável, primeiramente inicializa os pesos sinápticos da rede neural, e pode-se fazer isto atribuindo valores pequenos advindos de um gerador de números aleatórios, evitando, com isto, que nenhuma ordem prévia seja imposta ao mapa de características. Desde que a rede tenha sido devidamente inicializada, existem três processos essenciais envolvidos na formação da SOM conforme será descrito abaixo:

1. Competição- Para cada padrão de entrada, os neurônios da rede neural calculam os seus respectivos valores de uma função discriminante. Esta função provê as bases para a competição entre os neurônios. O neurônio em particular com o maior valor da função

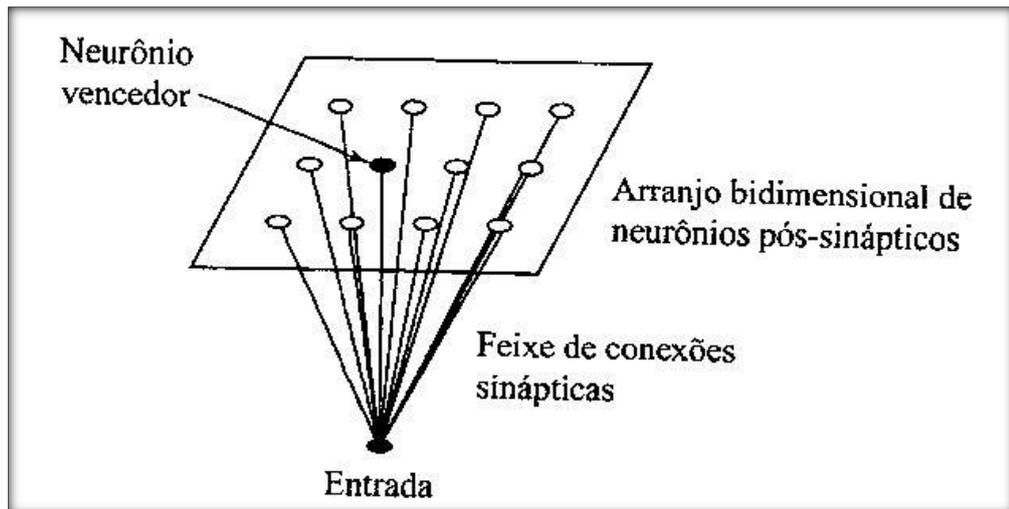
discriminante é considerado o vencedor da competição. No processo competitivo a rede define qual é o neurônio vencedor, ou seja, aquele que melhor atende ao estímulo de entrada. Este neurônio vencedor define o centro da classe e, a partir disto, a rede ajusta os pesos sinápticos dos neurônios vizinhos. O cálculo do neurônio vencedor normalmente é realizado utilizando-se a distância euclidiana. O neurônio que tiver uma menor distância do vetor de entrada é o vencedor.

2. Cooperação- Após o aprendizado competitivo existe um aprendizado por cooperação, o neurônio vencedor determina a localização espacial de uma vizinhança topológica de neurônios excitados, provendo, desta maneira, as bases para a cooperação entre os neurônios vizinhos, onde os neurônios próximos ao vencedor também recebem um ajuste nos seus pesos. Para calcular o quanto cada neurônio receberá de ajuste, consideramos a distância topológica que decresce com a distância lateral e com o tempo.

3. Adaptação Sináptica- Este último mecanismo permite que os neurônios excitados aumentem seus valores individuais da função discriminante em relação ao padrão de entrada através de ajustes apropriados, aplicados a seus pesos sinápticos. Os ajustes feitos são tais que a resposta do neurônio vencedor à decorrente aplicação de um padrão similar de entrada é aperfeiçoada.

2.7.2 O algoritmo da rede SOM.

O algoritmo que organiza a rede neural do tipo SOM inicia o processo atribuindo aos pesos sinápticos valores aleatórios pequenos, a fim de que não haja nenhuma organização prévia imposta ao mapa (LUDWIG JR; MONTGOMERY, p. 77). A figura 2.11 representa a rede SOM de Kohonen.



Fonte: (HAYKIN, 2008, p.486).

Figura 2.11: Rede de Kohonen.

“A formação do mapa é feita de forma adaptativa, considerando-se uma região de vizinhança nas proximidades do neurônio vencedor, partindo de uma inicialização de valores aleatórios para os neurônios, não caracterizando, contudo, uma organização pré-definida” (MEDEIROS, 2006, p. 121).

2.7.2.1 Processo competitivo.

Para Ludwig Jr e Montgomery (2007, p. 77), logo após, existe o processo competitivo onde um neurônio é escolhido como vencedor, ou seja, como o que melhor responde a uma determinada entrada. A escolha do neurônio vencedor é feita normalmente utilizando a distância euclidiana entre o vetor de entrada x e o vetor de pesos w_i (vale ressaltar que outras métricas também podem ser utilizadas), dadas pela expressão abaixo.

$$d_i(t) = \sum_{j=1}^N (x_j(t) - w_{ij}(t))^2 \quad (2.3)$$

Onde:

- w_{ij} é o valor de peso sináptico entre a entrada j e o neurônio i na iteração t ;
- i é o índice do neurônio;
- j é o índice do sinal de entrada;

- $x(i)$ é o valor do sinal de entrada;
- N é o número de sinais de entrada, ou seja, é o número de dimensões do vetor x ; e
- $d_i(t)$ é a distância euclidiana entre o vetor de pesos do neurônio i e o vetor de entrada, na iteração t .

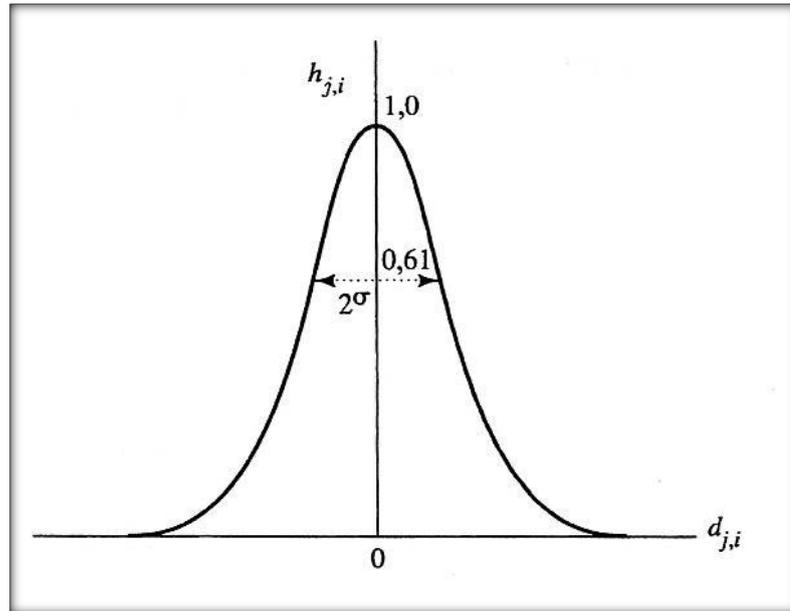
2.7.2.2 Processo Cooperativo.

De acordo com Ludwig Jr e Montgomery (2007, p.78), após a definição do neurônio vencedor, existe um processo cooperativo, onde os neurônios mais próximos do neurônio vencedor recebem um ajuste nos seus pesos sinápticos, e este ajuste é inversamente proporcional a sua distância do neurônio vencedor. Neste processo é usado o parâmetro vizinhança topológica h_{ik} para indicar o grau de cooperação entre os neurônios i e k e é representado pela função gaussiana abaixo, onde o termo l_{ik}^2 é a distância euclidiana entre os neurônios i e k . A variável σ é denominada de largura efetiva da vizinhança topológica e é calculado pela expressão 2.5, e é inversamente proporcional ao tempo, onde σ_0 é o valor inicial de σ , t é o número de iterações, e τ_1 é uma constante de tempo.

Segundo Valença (2010, p.301), no algoritmo competitivo se faz necessário que aconteça uma diminuição na região da vizinhança com o crescimento do número de iterações para que se haja a organização do mapa topológico. Ou seja, para que o algoritmo competitivo possa convergir se faz necessário que a região de vizinhança tenda a um erro quando o número de iterações tenderem a infinito. Para que seja alcançado este objetivo σ (largura efetiva da vizinhança topológica) deve decrescer com o número de iterações. Podemos observar este comportamento através da expressão 2.5 abaixo.

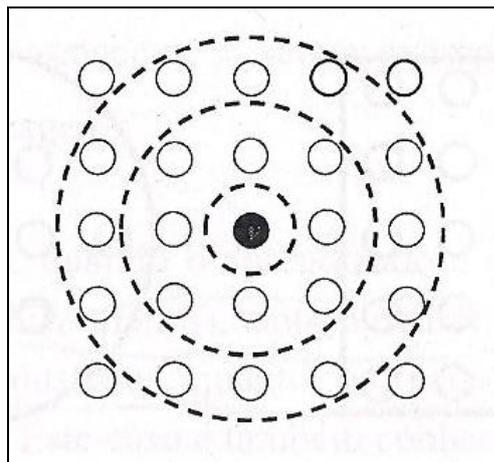
$$h_{ik} = e^{\left(-\frac{l_{ik}^2}{2\sigma^2}\right)} \quad (2.4)$$

$$\sigma(t) = \sigma_0 e^{(-t/\tau_1)} \quad (2.5)$$



Fonte: (HAYKIN, 2008, p. 490).

Figura 2.12: Função de vizinhança gaussiana.



Fonte: (VALENÇA, 2010, p. 302).

Figura 2.13: Redução da região de vizinhança.

2.7.2.3 Processo Adaptativo.

Após a cooperação acontece o ajuste dos pesos sinápticos da rede neural obedecendo a expressão 2.6, onde a variável $\eta(t)$ é a taxa de aprendizagem definida pela equação 2.7, onde podemos verificar que a taxa de aprendizagem é inversamente proporcional ao tempo. Sendo η_0 a taxa de aprendizagem inicial, a qual deve ser maior que zero e menor que um, e τ_2 é uma constante de tempo (LUDWIG JR ; MONTGOMERY, p. 79).

Para Valença (2010, p. 302): “A taxa de aprendizagem também decresce com o aumento do número de iterações de tal forma que se consigam ajustes cada vez mais finos”. Para tanto é utilizada uma função exponencial semelhante a de $\sigma(t)$, conforme pode ser visto na expressão 30 abaixo.

$$\Delta w_{ij} = \eta(t) h_{ik}(t) (x_j - w_{ij}) \quad (2.6)$$

$$\eta(t) = \eta_0 e^{(-t/\tau_2)} \quad (2.7)$$

2.7.3 Algoritmo de treinamento da rede.

Para Valença (2010, p. 303): Resumidamente, o algoritmo básico da rede SOM pode ser descrito nos seguintes passos:

Passo 1: Inicialização- escolha da topologia da rede e definição do número de iterações.

- O conjunto inicial de pesos é criado com valores pequenos;
- É atribuído para a vizinhança um valor grande o suficiente para incluir todas as unidades.
- Definir os valores para a taxa de aprendizagem e para as constantes τ_1 e τ_2 .

Passo 2: Apresentação dos exemplos de entrada.

• **Competição-** nesta etapa os exemplos de entrada são apresentados e é calculada a resposta dos neurônios de saída. Sendo o neurônio vencedor aquele que apresentar a menor distância euclidiana.

$$d_i(t) = \sum_{j=1}^N (x_j(t) - w_{ij}(t))^2 \quad (2.8)$$

- **Cooperação-** após se definir o neurônio vencedor, calcula-se o valor da vizinhança topológica (h_{ik}), dado pela expressão abaixo.

$$h_{ik} = e^{\left(\frac{l_{ik}^2}{2\sigma^2}\right)} \quad (2.9)$$

Passo 3: Ajuste dos pesos sinápticos.

- Os pesos sinápticos do neurônio vencedor e de todas as unidades dentro da região de vizinhança de unidade vencedora têm os seus pesos sinápticos ajustados na direção do vetor de exemplos apresentados na entrada da rede neural.

$$w_{ij}(\text{novos}) = w_{ij}(\text{antigo}) + \eta(t)h_{ik}(x_j - w_{ij}(\text{antigo})) \quad (2.10)$$

Passo 4: Cálculo de novos valores para $\sigma(t)$ (largura efetiva da vizinhança topológica) e para $\eta(t)$ (a taxa de aprendizagem).

$$\sigma(t) = \sigma_0 e^{(-t/\tau_1)}; e \quad (2.11)$$

$$\eta(t) = \eta_0 e^{(-t/\tau_2)} \quad (2.12)$$

Passo 5: Testar a condição de parada.

Passo 6: Incrementar o número de iterações e retornar ao passo 2. Repetir a rotina até que a condição de parada seja alcançada.

2.8 REDE NEURAL DO TIPO ART

2.8.1 Conceituação.

Segundo Silva, Spatti e Flauzino (2010, p. 264), a teoria da ressonância adaptativa (adaptive resonance theory-ART), criada por Grossberg, foi inspirada na observação de fenômenos biológicos envolvendo a visão, a fala, o desenvolvimento cortical e as interações cognitivo-emocionais. A motivação desta teoria é baseada em três princípios biológicos que são destacados pelas seguintes características:

- **Normalização de sinais-** capacidade dos sistemas biológicos em se adaptar a ambientes que se alteram frequentemente. Por exemplo, a visão humana que se adapta à quantidade de luz disponível.
- **Intensificação de contraste-** potencialidade de identificar detalhes a partir de observações sucessivas realizadas no ambiente. Por exemplo, o sistema respiratório é capaz de diferenciar de forma praticamente instantânea um ambiente limpo que começou a ser poluído por monóxido de carbono.
- **Memória de curto prazo-** possibilidade de armazenar, de maneira momentânea as informações sensoriais advindas do mecanismo de intensificação de contraste, antes que possam ser decodificadas visando à tomada de decisões.

Segundo Cardon, Muller e Navaux (1994, p. 27), a teoria da ressonância adaptativa, gerou um classificador que possui entrada binária, conexão retroalimentada e aprendizado não-supervisionado. A ideia de armazenamento dos padrões tem semelhanças com a rede de Kohonen, pois, que há distinção de zonas, a comparação entre distâncias vetoriais das somas ponderadas, e a escolha de um neurônio vencedor.

De acordo com Silva, Spatti e Flauzino (2010, p. 264), um dos atributos principais da rede ART é a sua capacidade de aprender novos padrões sem que haja a destruição dos conhecimentos anteriormente adquiridos na ocasião da apresentação das amostras. Esta

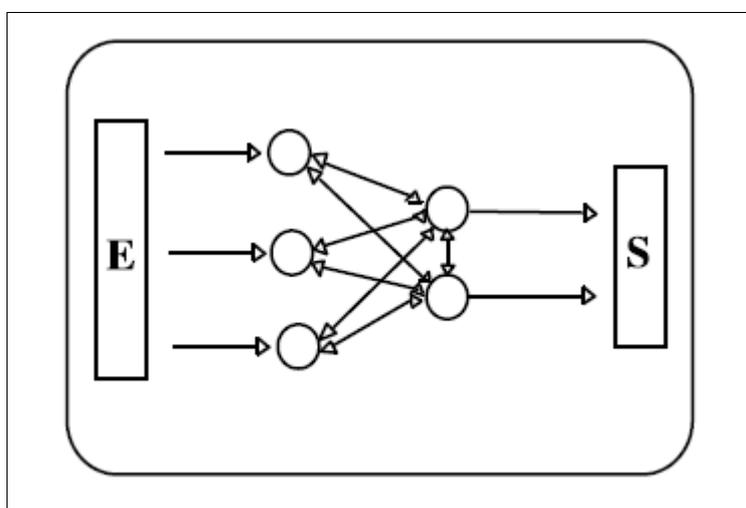
característica da rede está associada ao dilema da plasticidade-estabilidade, no qual a rede deve ser estável e preservar o conhecimento adquirido com o passar do tempo e concomitantemente adaptativa para incorporar as mudanças ocorridas no ambiente. Existem cinco topologias que se baseiam na arquitetura ART, e se classificam de acordo com o tipo de suas entradas e seus processos de treinamento, podendo ser:

- **ART-1-** Possui entradas binárias e treinamento não supervisionado;
- **ART-2-** Possui entradas binárias ou analógicas e treinamento não supervisionado;
- **ART-3-** Possui entradas binárias ou analógicas e treinamento não supervisionado e uma topologia multinível;
- **ART-MAP-** Possui entradas binárias ou analógicas e treinamento supervisionado em tempo real, utilizando-se duas redes ART em sua estrutura; e
- **FUZZY-ART-** Versão fuzzy da rede do tipo ART-MAP e possui aprendizado supervisionado.

Segundo Cardon, Muller e Navaux (1994, p. 30), o aprendizado da rede ART assemelha-se ao da rede SOM em sua forma de distribuição de pesos através da definição do neurônio vencedor, com a diferença de que na rede ART apenas o neurônio vencedor é atualizado, não havendo atualização dos pesos dos neurônios vizinhos. Esta rede neural possui a facilidade de não ter a necessidade de um aprendizado prévio, podendo adaptar-se de acordo com a necessidade. Porém, é muito sensível a padrões distorcidos e não faz uma boa diferenciação entre padrões semelhantes, e com isto, há uma limitação nas suas aplicações.

2.8.2 Topologia.

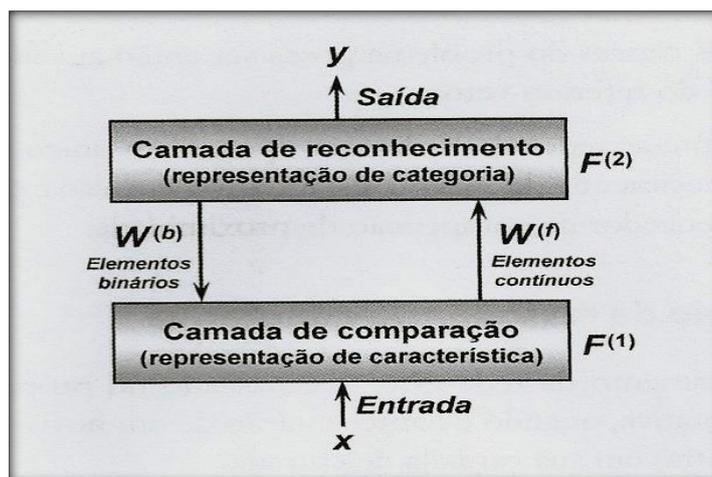
Na figura 2.14 é apresentada a estrutura topológica de uma rede ART-1, pode-se ver que existe a retropropagação dos sinais, o que permite à rede ART a seleção dos neurônios que melhor representariam um dado padrão de entrada. A interconexão entre dois nós de saída permite a inibição lateral entre eles para definição do valor máximo de saída. “A principal aplicabilidade das redes ART-1 está na solução de problemas de classificação de padrões, sendo também considerada como um sistema classificador de vetores” (SILVA; SPATTI; FLAUZINO, 2010, p. 264).



Fonte: Introdução às Redes Neurais Artificiais.

Figura 2.14: Rede ART, uma topologia com conexões retroalimentadas.

Observa-se na figura 2.15, que a rede ART-1 é constituída de duas camadas de neurônios que estão conectados com os outros. A camada que recebe os sinais de entrada, aqui chamada de $F(1)$, possui uma quantidade de neurônios que coincide com a dimensão das amostras de entrada, ou seja, com a dimensão do vetor de entrada, e tem a finalidade de passar para a camada $F(2)$ os padrões originais (SILVA; SPATTI; FLAUZINO, 2010, p. 266).



Fonte: (SILVA; SPATTI; FLAUZINO, 2010, p. 267).

Figura 2.15: Fluxo de informações na Rede ART-1.

O fluxo de informações impetrado pela camada F(1) é feedforward, sempre na direção da camada F(2). Por conseguinte, as informações realimentadas a partir da camada F(2), são constituídas dos sinais de entrada ponderados pela matriz de pesos (definida por $W(b)$) e formada por elementos binários (SILVA; SPATTI; FLAUZINO, 2010, p. 266).

A missão principal da camada F(1) é realizar uma comparação a fim de averiguar se o vetor de entrada(x) possui similaridade com o conjunto de vetores previamente armazenado. A camada F(2), conhecida como camada de reconhecimento, ou de saída, tem a missão de reconhecer e incorporar o conhecimento trazido pelo vetor presente na entrada para uma das classes representadas pelos seus neurônios. Sendo a quantidade de neurônios da camada F(2) dinâmica e varia com a necessidade da rede representar novas classes (SILVA; SPATTI; FLAUZINO, 2010, p. 267).

Segundo Silva, Spatti e Flauzino (2010, p. 267), outra característica da camada F(2), de maneira diversa dos neurônios da camada F(1), os seus neurônios competem entre si e o seu fluxo de informações realimenta a camada de entrada F(1). Onde a sua matriz de pesos ($W(f)$), constituída de elementos reais, tem o propósito de ponderar as características das componentes do vetor de entrada apresentado, de maneira a estimular que um dos neurônios que representam as classes possa ser ativado como sinal de reconhecimento deste vetor de entrada. De maneira análoga às redes de Kohonen, apenas um único neurônio da camada de reconhecimento da rede ART-1 estará ativo em cada ciclo, sendo este considerado o vencedor do processo competitivo.

Pode-se então sintetizar que a operação da rede ART 1 é a de buscar entre os padrões armazenados, correspondentes a cada classe, aquele que melhor se aproxima do padrão que é apresentado na entrada. No caso de não existir nenhuma classe, um novo nó é criado e a ele é associada uma nova classe (SILVA, 1998, p.60).

Segundo Silva (1998, p.60), a ativação da rede ART-1, após a etapa de aprendizagem, é baseada na cooperação-competição entre os nós. O algoritmo simplificado a seguir demonstra o modelo de cooperação-competição estabelecido para o processo de ativação e treinamento da Rede ART-1:

Passo 1. Inicialize parâmetros;

Passo 2. Enquanto a condição de parada for falsa realize os passos 3-10;

Passo 3. Para cada vetor de entrada, execute passos 4-9;

Passo 4. Processe atualização da camada F(1);

Passo 5. Enquanto a condição de reset for verdadeira, execute passos 6-8;

Passo 6. Encontre neurônio candidato para aprender o padrão corrente (processe a camada F(2) para localizar neurônio mais representativo);

Passo 7. Verifique validade da distância entre o padrão amostrado e o neurônio mais representativo;

Passo 8. Teste condição de reset: - Se o parâmetro reset é verdadeiro, então o neurônio corrente é inibido; retorne ao passo 5 ;

- Se o parâmetro reset é falso, então o neurônio corrente é habilitado para aprender; executar o passo 9;

Passo 9. Execute adaptação dos pesos do neurônio ganhador da camada F2;

Passo 10. Teste condição de parada.

2.9 RÁDIO DEFINIDO POR *SOFTWARE*

2.9.1 Conceituação.

O conceito de rádio definido por *software* (RDS) surgiu graças ao Departamento de Defesa dos Estados Unidos, que desejava que seus equipamentos de rádio fossem capazes de interagir com várias interfaces, e em diferentes faixas de frequências. Com o objetivo de simplificar os sistemas de radiocomunicação, tornando-os mais flexíveis e baratos, os seus componentes, como moduladores, demoduladores, e filtros, normalmente implementados através de hardware, deveriam passar a ser implementados por *software* em sistemas computacionais embarcados ou mesmo em computadores comuns.

Diante de necessidades crescentes de apoiar comunicações para várias missões; da utilidade da implantação rápida em diversos cenários; e da indispensabilidade de aumentar a interoperabilidade e reduzir os custos das operações; o exército dos Estados Unidos foi, e continua sendo um dos principais fomentadores do desenvolvimento do RDS. Um dos principais obstáculos para enfrentar esse desafio é que a maior parte dos sistemas de rádio foram predominantemente baseados em hardware, e são incapazes de serem atualizados sem um custo significativo devido a um necessário reprojeto do *hardware* (KOVARIK JR; BARD, 2007, p. 6).

Inicialmente, no passado, os projetos dos rádios militares eram orientados ao emprego de componentes eletrônicos dedicados. Com a evolução tecnológica, houve o aparecimento de rádios de *software* configuráveis, onde se podem escolher as formas de onda mais adequadas para diferentes cenários de combate. Nos últimos anos, com o desenvolvimento das soluções tecnológicas em radiocomunicação surgiu uma mudança de paradigma, o Rádio Definido por *Software*, tecnologia emergente em que os recursos anteriormente baseados em *hardware* tornaram-se definidos por *software*, e os usuários podem também introduzir novas aplicações no decorrer da utilização do equipamento rádio (PAIVA JÚNIOR et al, 2012, p.1).

Segundo o *Wireless Innovation Forum*, o RDS é definido como: “um rádio onde

algumas ou todas as funções da camada física são definidas por *software*”. Podendo ser considerado como uma coleção de tecnologias de hardware e *software* que permite que haja sistemas com arquitetura reconfigurável para redes sem fio e terminais móveis que possam ser adaptados ou melhorados através da atualização de seus *softwares* ou *firmwares*.

Segundo Miota (2000 apud Janson, 2012, p.14) define que “um rádio definido por *software* é um rádio cuja modulação de formas de onda do canal é definida em *software*. Isto é, as formas de ondas são geradas como sinais digitais amostrados, convertidas de digitais para analógicas através de conversor digital analógico (DAC) de banda larga, que captura todos os canais do nó do RDS. O receptor, por sua vez, captura o sinal, faz um abaixamento de frequência e demodula a forma de onda do canal por meio de um *software* que roda em um processador de uso geral”.

Com o RDS é possível executar novas funcionalidades por meio de *software* e transmitir formas de onda criptografadas em diferentes frequências de operação, utilizando um mesmo *hardware* genérico do rádio transceptor. Isso torna o sistema de rádio programável extremamente seguro e de fácil operação. Segundo o *wireless innovation forum* o RDS define uma coleção de tecnologias de *hardware* e *software* onde toda ou uma parte da operação do rádio é implementada através de *firmware* ou *software* em uma plataforma de suporte composta de *hardware* de processamento programável. Estes equipamentos são compostos por *field programmable gate arrays (FPGA)*, processador digital de sinais (PDS), processador de propósito geral (GPP) e sistema programável no *chip(SoC)*, ou outros processadores programáveis de aplicação específica. O uso destas tecnologias permite que novas funcionalidades possam ser adicionadas ao sistema de rádio sem que haja a necessidade de se adicionar novos *hardwares*.

Vários esforços têm sido feitos para a padronização de elementos-chave dentro da arquitetura RDS, proporcionando uma plataforma comum para o desenvolvimento de equipamentos de rádio. À primeira vista, o modelo funcional de um RDS é composto por um subsistema de *front-end* de RF, que realiza seleção de canais, *down-conversion* para a banda básica, e o encaminhamento de dados para uma unidade de processamento baseado em *software*. Nessa unidade de processamento, o conjunto de dados digitais é apresentado a diversas camadas (camadas de enlace, rede, segurança) para executar as tarefas de decodificação adequadas à extração da informação desejada. Este processo sofre uma

inversão no lado de transmissão, onde o sinal de entrada é codificado e modulado, de forma adequada para que haja a devida transmissão da informação. Este sinal é então passado para o subsistema de RF para inserção no canal rádio. Como exemplo de uma das zonas mais típicas de padronização, temos o framework de aplicações, onde é oferecido pelo fornecedor um conjunto de interfaces para instalar, configurar, controlar e liberar a operação de aplicações em uma plataforma SDR, que proporciona um ambiente de operação de *software* comum. Como exemplo de frameworks de aplicações para os sistemas SDR tem-se: o *Software Communications Architecture* (SCA), apoiado pelo Grupo de Trabalho do Fórum SDR SCA. O padrão SCA foi originalmente proposto pelo programa *Joint Tactical Radio System* (JTRS) que é um programa para o desenvolvimento de rádios para operações militares patrocinado pelo Departamento de Defesa dos EUA, e está se tornando o padrão para a construção de rádios militares e vem inspirando projetos acadêmicos e comerciais (PAIVA JUNIOR et al, 2012, p.1).

Durante os últimos anos os rádios definidos por *softwares* sofreram uma evolução, gerando tecnologias relacionadas, como por exemplo, os rádios cognitivos. Estes dispositivos podem se adaptar continuamente às mudanças no ambiente espectral, incluindo esquemas de modulação, codificação de canal, e largura de banda. Dadas as vantagens supracitadas, as pesquisas com os rádios definidos por *softwares* vêm acontecendo com muita ênfase em todas as áreas, como por exemplo: soluções de *hardware*, algoritmos, protocolos, implementações de *software* e aplicativos a fim de se atingir um rádio que consiste em nada mais do que uma antena, conversor analógico-digital, um processador digital e um conjunto de algoritmos e rotinas computacionais.

Atualmente, quase todos os rádios utilizam *softwares* na sua configuração, porém, isto não os faz na sua essência RDS. Nesses rádios, geralmente a substituição de itens da interface aérea baseados em *softwares* necessita de ajustes de hardware. No RDS “puro”, o objetivo é realizar a digitalização do sinal na antena, sendo todo o processamento restante realizado através de *software*. Com a facilidade de ajustes e modificações no rádio com a simples troca de *software*, tornando-se possível implementar rádios multibanda com alto nível de customização, permitindo ao usuário configurar o equipamento com segurança com as formas de onda que lhe sejam mais convenientes. (LIMA, 2004, p.3).

Janson (2012, p. 17) afirma: a arquitetura de rádio definido por *software* é dividida em 2 componentes principais: o *Front End* de radio que realiza o recebimento e a transmissão das frequências do sinal de rádio e o *Back End* de radio que realiza o processamento dos sinais de rádio. Desta forma, na tecnologia RDS o *hardware* compõe o *front-end* e o *software* domina o processamento no *back-end*.

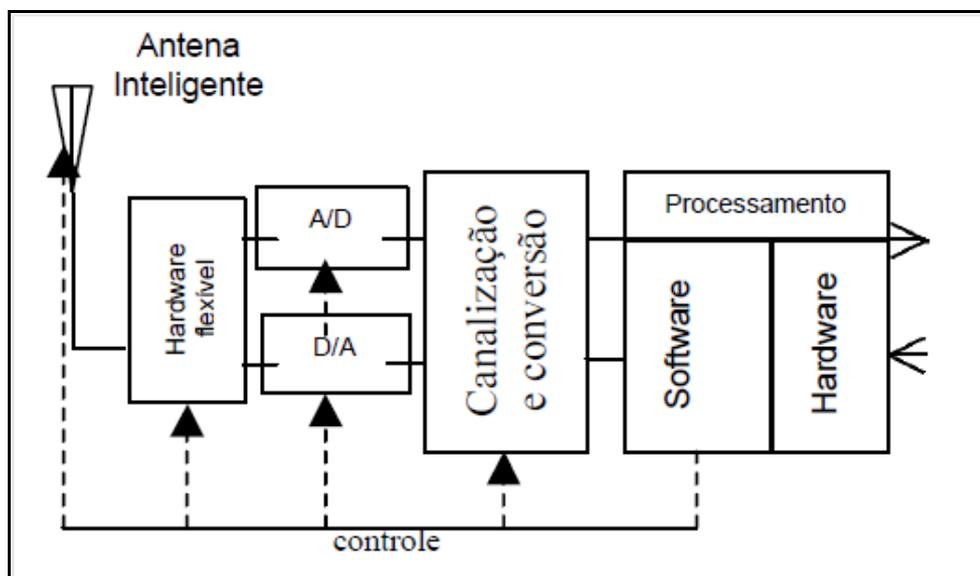
Na figura 2.16 temos o diagrama em blocos do módulo *front-end* de RF do RDS. Temos este estágio como praticamente o único que é totalmente composto por hardware. Podemos observar que a digitalização do sinal de rádio é deslocada da banda base para o estágio de RF de frequência intermediária (FI). Neste estágio, pretende-se que as conversões analógicas para digital e digital para analógico sejam realizadas imediatamente após o amplificador de baixo ruído e dos filtros *anti-aliasing* a fim de se eliminar o processamento analógico da FI (LIMA, 2004, p.3).

Na figura 2.17 é apresentada uma proposta para *front-end* de RF para um RDS. Segundo Lima (2004, p.3) os sinais de banda básica digitalizados são convertidos para a FI programável com rejeição de imagem. Os sinais de FI são *down*-convertidos para a banda básica pela seleção do canal desejado. Sendo o filtro passa-banda da entrada do módulo adotado para provocar uma melhoria nas características de rejeição de imagens e após a conversão realizada neste estágio, são executados os processamentos dos sinais tanto em hardware quanto em *software*, envolvendo todas as etapas de um rádio transceptor digital baseado em *hardware*, como por exemplo: equalização, codificação, sincronismo, modulação, demodulação, etc.

Arquiteturas SDR incluem transceptores que realizam conversão entre a banda base e a RF, exclusivamente no domínio digital, reduzindo a interface de RF para: um amplificador de potência do canal de transmissão, um amplificador de baixo nível de ruído para a etapa de recepção e o mínimo de filtragem analógica. Formas de onda são geradas como sinais digitais amostrados, convertidos de analógico para digital por meio de um conversor digital para analógico de banda-larga, e, em seguida, converte-se-á de FI para RF.

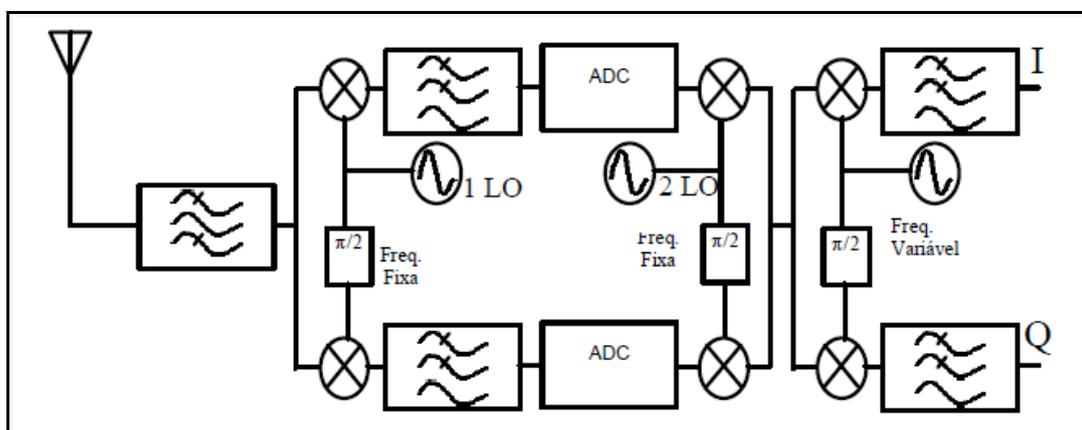
O receptor, de forma semelhante, emprega um conversor analógico para digital de banda larga, que capta todos os canais de RF relevantes e demodula a forma de onda pelo uso

de *software*. Um SDR realiza quantidades significativas de processamento de sinal em um processador de propósito geral.



Fonte: Artigo **RÁDIO DEFINIDO POR SOFTWARE: O PRÓXIMO SALTO NO MUNDO DAS TELECOMUNICAÇÕES E COMPUTAÇÃO**

Figura 2.16: Diagrama em blocos de um RDS.



Fonte: Artigo **RÁDIO DEFINIDO POR SOFTWARE: O PRÓXIMO SALTO NO MUNDO DAS TELECOMUNICAÇÕES E COMPUTAÇÃO**

Figura 2.17: Proposta de um front-end de RF para um RDS.

Como mostrado na figura 2.18 cada elemento de processamento em um multiprocessador SDR tem o seu próprio conjunto de módulos na sua organização. O conjunto para cada processador tem uma estrutura em camadas, com *hardware* na parte inferior, de processador específico de *software* no meio, e módulos de *software* que implementam a aplicação no topo. Os módulos de aplicativos de *software* contêm a capacidade de processamento para implementar o controle e da funcionalidade do rádio. Isto

interoperabilidade. As atualizações no rádio serão rivalizadas com os propósitos de disponibilizar novas técnicas de modulação, componentes criptográficos, aplicações entre outros, através de um simples download de novos componentes de *software*. (VEIGA; GUIMARÃES, 2004, p.1).

Segundo o *Wireless Innovation Forum*, o RDS pode atuar como uma tecnologia chave para uma variedade de outros equipamentos de rádio reconfigurável existentes no mercado. Enquanto a tecnologia RDS não é requerida para implementar algum desses tipos de rádio, ela pode prover mais flexibilidade para que estes equipamentos alcancem seu pleno potencial, ajudando a redefinir custos e aumentar o rendimento. Os sistemas de rádio que utilizam a tecnologia de rádio definidos por *software* são:

2.9.2 Rádio adaptativo.

Rádio adaptativo é o equipamento que monitora seu próprio desempenho e modifica os seus parâmetros para melhorar o seu desempenho. O uso da tecnologia RDS em sistemas de rádio adaptativo traz benefícios como maior grau de adaptação, maior desempenho do sistema e maior qualidade de serviço no link de comunicação.

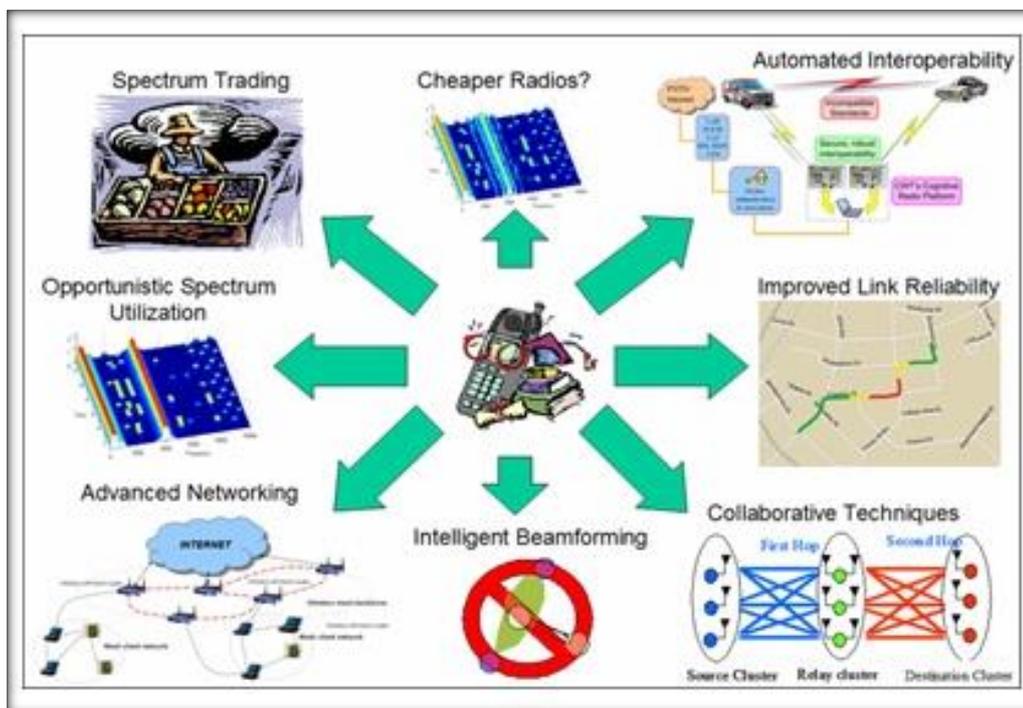
2.9.3 Rádio cognitivo.

Rádio cognitivo é o equipamento rádio em que os sistemas de comunicação estão cientes de seu estado interno e do meio-ambiente, tais como localização e utilização de espectro de frequência RF naquele local. Eles podem tomar decisões sobre o seu comportamento operacional mapeando essa informação em relação aos objetivos pré-definidos. Os rádios cognitivos costumam utilizar a tecnologia de rádio definido por *software*, rádio adaptativo e outras tecnologias para ajustar automaticamente o seu comportamento para alcançar os objetivos desejados. A utilização destes elementos é fundamental para permitir que os usuários finais possam aperfeiçoar a utilização do espectro de frequências disponíveis, e redes sem fio com um conjunto comum de *hardware* de rádio. Isto irá reduzir o custo para o usuário final, permitindo-lhe se comunicar com quem quer que seja, sempre que precisarem, e de maneira apropriada. A tabela 2.1 e a figura 2.19 ilustram novas aplicações e benefícios dos rádios cognitivos.

TABELA 2.1- Rádio cognitivo habilita novas aplicações e amplia o desempenho dos sistemas.

Nova proposta de aplicativos habilitados por rádio cognitivo.	Métricas de Desempenho Melhorado por rádio cognitivo.
<ul style="list-style-type: none"> • Acesso dinâmico de espectro; • Redes auto-organizadas; • Sistemas de bloqueio Cognitivo; • Gateways / pontes cognitivas; • Mercados de espectro em tempo real; • Sintética (Cooperativo) MIMO; • Gestão cognitiva do espectro; e • Encaminhamento Cognitivo. 	<ul style="list-style-type: none"> • Melhorar a interoperabilidade entre sistemas legados e emergentes; • Melhorar a confiabilidade do enlace; • Equipamentos rádios mais baratos; • Melhorar as técnicas SDR; • Vida útil da bateria estendida; • Melhorar a utilização e eficiência de espectro; e • A cobertura estendida do equipamento.

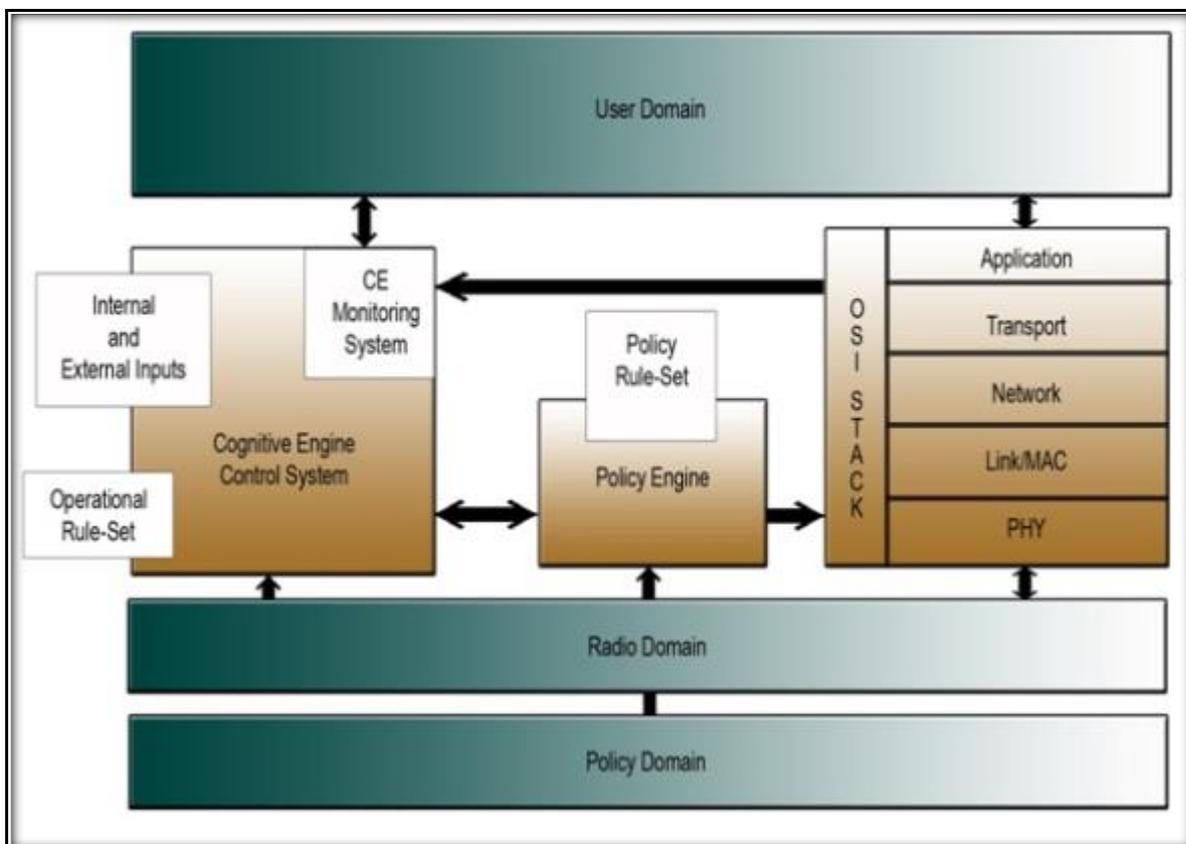
Fonte: *Wireless Innovation Forum*. Retirado do site: <http://www.wirelessinnovation.org/>.



Fonte: *Defining Cognitive Radio (CR) and Dynamic Spectrum Access (DSP)*. Retirado do site: <http://www.wirelessinnovation.org/>.

Figura 2.19: Benefícios do rádio cognitivo.

De acordo com o *wireless innovation forum* existem dois subsistemas em um rádio cognitivo: uma unidade cognitiva que toma decisões com base em várias entradas e uma unidade RDS flexível cujo funcionamento oferece uma gama de possíveis modos de operação. A unidade cognitiva é separada em duas partes, como mostrado no diagrama de blocos apresentado na figura 2.20. O primeiro é rotulado de *cognitive engine* (mecanismo cognitivo) e trabalha para aperfeiçoar uma meta de desempenho com base em *inputs* recebidos, definindo o atual estado interno do rádio, e do ambiente operacional. A segunda é o *policy engine* (mecanismo de política) e é usado para garantir que a solução fornecida pelo mecanismo cognitivo e está em conformidade com as normas regulamentares e outras políticas externas para o rádio.



Fonte: *Cognitive Radio Concept Architecture*. Retirado do site: <http://www.wirelessinnovation.org/>.

Figura 2.20: Conceito de arquitetura de rádio cognitivo.

2.9.4 Rádio inteligente.

Rádio inteligente é um rádio cognitivo que possui aprendizado de máquina, isso permite ao equipamento melhor se adaptar a mudanças no seu próprio desempenho, e do ambiente externo de propagação para melhor atender às necessidades do usuário. Além de utilizar tecnologias SDR, os sistemas de rádio cognitivos podem todos suportar acesso espectro dinâmico (DSA), permitindo que os sistemas possam selecionar o espectro de frequências em que eles operam em um dado local e num dado período de tempo, para aperfeiçoar o uso do espectro disponível e evitar a interferência com outras rádios ou outros sistemas.

2.9.4.1 Benefícios do SDR.

➤ **Para os fabricantes de equipamentos e integradores de sistemas, a tecnologia SDR permite:**

- Uma família de "produtos" a serem implementadas utilizando uma arquitetura de plataforma comum, permitindo que novos produtos sejam mais rapidamente introduzidos no mercado.

- *Software* para ser reutilizado através de "produtos", reduzindo os custos de desenvolvimento de forma dramática.

- *Over-the-air* ou outra reprogramação remota, permitindo que possam ocorrer "correções" em um rádio que está em serviço, reduzindo o tempo e os custos associados com a operação e manutenção.

➤ **Para os provedores de serviços de rádio comunicação, a tecnologia do SDR permite:**

- Novos recursos e capacidades para serem adicionados à infraestrutura existente sem

a necessidade de se realizar novamente grandes investimentos.

- O uso de uma plataforma de rádio comum para vários mercados, reduzindo significativamente o apoio logístico e despesas operacionais.

- *Downloads de software* remoto, através do qual a capacidade pode ser aumentada, upgrades de recurso pode ser ativado e novas funcionalidades geradoras de receita podem ser inseridas, da seguinte forma: Para os usuários finais - de quem viaja a negócios para os soldados no campo de batalha, a tecnologia SDR visa a reduzir os custos na prestação de usuários finais com acesso a comunicações sem fio onipresente - o que lhes permite comunicar-se com quem quer que seja que eles precisam, quando eles precisam e de qualquer maneira é apropriada.

O Reconhecimento Automático de Modulação consiste na identificação do tipo de modulação digital utilizada no sinal transmitido captado pelo receptor, sem nenhum conhecimento das características de amplitude, frequência, ou fase desse sinal. Tendo seu nível de dificuldade de implementação ampliado devido às características do canal de propagação como: desvanecimento e ruído.

O objetivo do presente trabalho, como será apresentado nos capítulos posteriores, é dar enfoque à etapa de demodulação de um transceptor. Nesta dissertação serão realizadas simulações computacionais, apresentando sinais modulados digitalmente à entrada de uma rede neural artificial com aprendizado competitivo, do tipo Mapa Auto-Organizável, e avaliar o resultado obtido. Espera-se conseguir que esta rede neural se torne apta, após a devida etapa de treinamento, a realizar a adequada demodulação dos sinais submetidos à sua entrada.

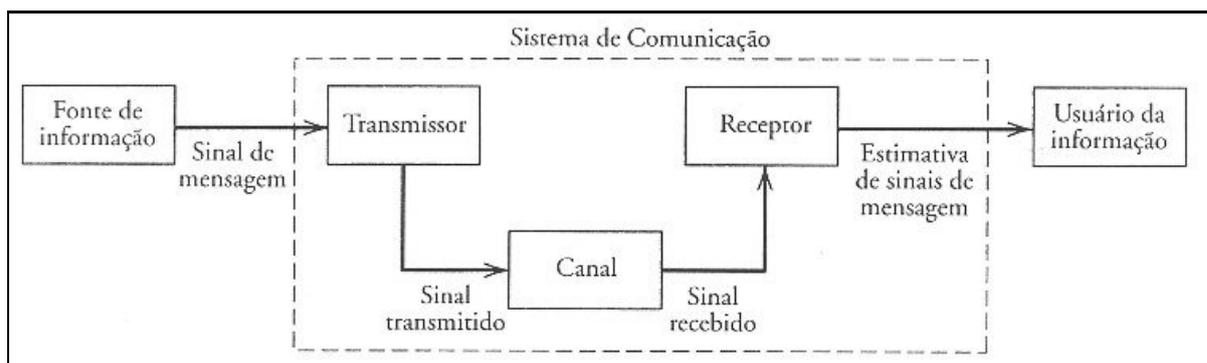
2.10 UTILIZAÇÃO DE REDES NEURAS NO PROCESSAMENTO DE SINAIS

Segundo Kovács (2006, p. 141) sinais são funções que servem para transportar informação de uma fonte de mensagens a um destinatário. As características específicas dos sinais dependem do canal de comunicações utilizado para este transporte.

O canal de comunicação é um meio físico que permite a conexão entre o equipamento transmissor e o equipamento receptor (ou dois equipamentos transceptores) em um sistema de comunicações.

Um canal de comunicações é definido pelo tipo de distorção que introduz nos sinais. Esta distorção pode ser : a) determinística linear, exemplo: a limitação da banda de frequência dos sinais; b) determinística não linear, exemplo: saturações; ou c) aleatória, exemplo: presença de ruídos (KOVÁCS, 2006, p. 141).

Segundo Kovács (2006, p. 141): “Sinais são processados no lado transmissor com a finalidade de produzi-los e configurá-los, e no lado receptor para extrair a informação neles contida, se possível com a máxima eficiência”. A figura 2.21 ilustra os elementos de um sistema de comunicação.



Fonte: (HAYKIN, 2007, p. 20).

Figura 2.21: Elementos de um sistema de comunicação.

Em sistemas eletrônicos de comunicação, a fonte geradora da informação, o canal de comunicação e o destinatário são elementos pré-definidos com características em geral muito bem especificadas (KOVÁCS, 2006, p. 142).

Em qualquer transmissão, o sinal recuperado no receptor é composto do sinal transmitido alterado pelas características do meio de propagação e acrescido de sinais indesejáveis que são conhecidos como ruídos.

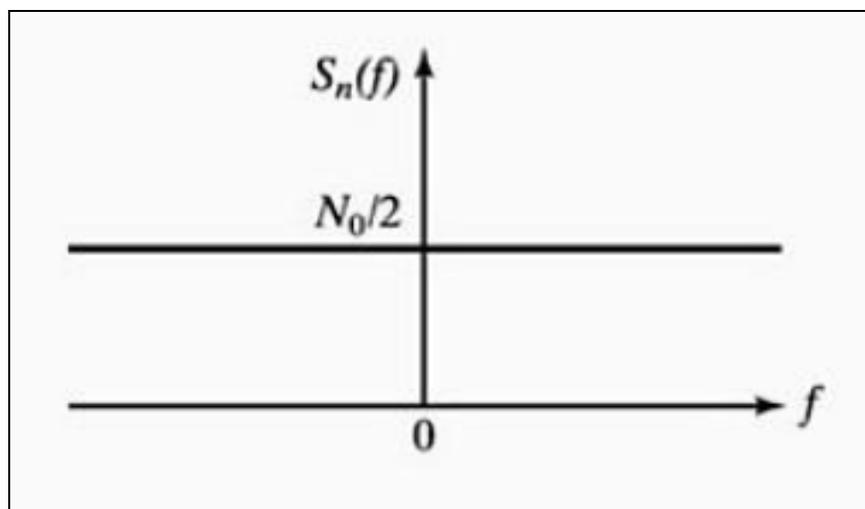
Os ruídos são um dos fatores mais limitativos e restritivos do desempenho dos sistemas utilizados em telecomunicações. Sendo a dimensão do ruído existente no sinal dimensionada através da razão entre a potência do sinal propriamente dito (representada por

S) e a potência do ruído existente (representada por N) representado pela relação sinal ruído (S/N), normalmente é expressa em decibéis (dB), calculada pela equação abaixo:

$$10 \log_{10}\left(\frac{S}{N}\right) \quad (2.13)$$

Segundo Haykin, Moher (2007, p.84): O ruído térmico pode ser considerado uma propriedade da matéria a uma temperatura absoluta superior a 0° K . O que interessa para a engenharia de telecomunicações é a distribuição do ruído térmico em função da frequência, isto é a densidade espectral do ruído, que para frequências de até 10^{12} Hz a densidade espectral do ruído (watts/Hertz) é aproximadamente constante e é dada por: $S_n(f) \equiv N_0/2$.

Podemos observar na figura 2.22 que a densidade espectral do ruído branco para a faixa de frequência entre, $-\infty < f < +\infty$, é constante e dada como supracitado por: $N_0/2$, ou seja, o ruído térmico é distribuído uniformemente em todas as frequências do espectro, por este motivo, o ruído térmico é também conhecido como ruído branco. Existem modelos matemáticos que descrevem o canal de comunicação que será utilizado. No presente estudo será adotado o modelo de canal Aditivo Gaussiano Branco (AWGN).



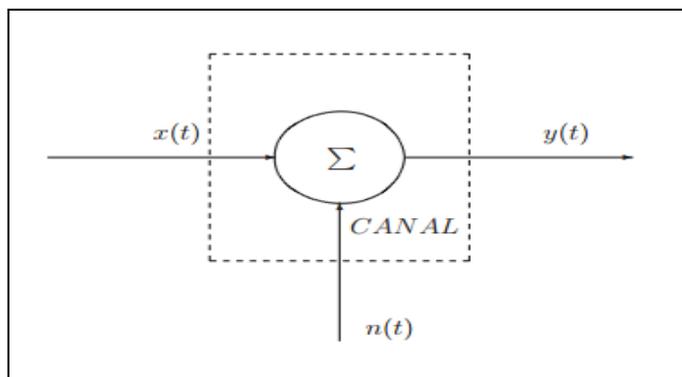
Fonte: (HAYKIN; MOHER, 2007, p. 85).

Figura 2.22: Modelo espectral para o ruído branco.

A figura 2.23 representa um canal de comunicação com ruído gaussiano, onde $x(t)$ representa o sinal de informação transmitido, $n(t)$ o ruído adicionado no canal e $y(t)$ o sinal recebido. O canal AWGN é completamente caracterizado pela distribuição de probabilidade

do ruído, que é uma distribuição gaussiana, sendo a função densidade de probabilidade definida pela equação descrita a seguir:

$$f(V_R) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{V_R^2}{2\sigma^2}} \quad (2.14)$$

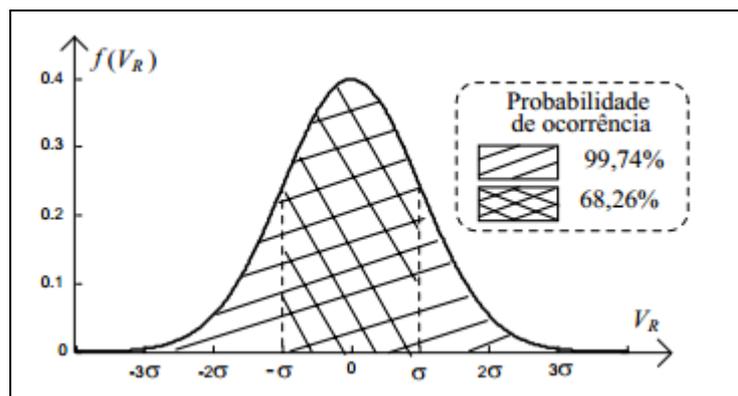


Fonte: *Transmissão de Imagem Através de Canal Ruidoso Usando Códigos LT*, Rio de Janeiro- RJ, 2009. Figura 2.23: Modelo de canal para o ruído branco.

O ruído branco tem a propriedade de ter distribuição Gaussiana, com valor médio nulo. Se os sinais de ruído são sinais de tensão V_R , significa que a distribuição desses sinais, a Função Densidade de Probabilidade $f(V_R)$, segue a curva de Gauss (NOCETI FILHO, S., 2002).

O ruído branco é um sinal com uma amplitude momentânea aleatória, assim como um ângulo de fase aleatório. Portanto, a relação sinal/ruído só pode ser baseada em um valor médio efetivo (RMS) da sua amplitude, isto é, os valores de pico instantâneos podem desviar desse valor de acordo com uma função de probabilidade (MIYOSHI; SANCHES, 2002, p. 88).

Segundo Miyoshi e Sanches (2002, p. 88) a curva de Gauss ou curva Gaussiana da densidade de probabilidade do ruído, dada pela figura 2.24, indica a probabilidade de que um certo valor de amplitude seja excedido.



Fonte: (NOCETI FILHO, S., 2002).

Figura 2.24: Curva Gaussiana do ruído branco.

A área sob a curva indica a probabilidade de ocorrência do sinal no tempo. A probabilidade da ocorrência de V_R estar compreendida entre $-\sigma$ e $+\sigma$ é de 68,26%. A probabilidade da ocorrência de V_R estar compreendida entre -3σ e $+3\sigma$ é de 99,74% (NOCETI FILHO, S., 2002).

O termo ruído branco se deve ao fato desse tipo de ruído se distribuir uniformemente em todas as faixas de frequência do espectro, possuir média nula e correlação nula entre suas amplitudes em instantes de tempos distintos. Ou seja, o valor da amplitude do ruído em um determinado instante independe daquele observado em outro instante de tempo qualquer. A degradação imposta pelo canal sobre o sinal pode ser quantificada através da relação sinal-ruído (SNR), que é a relação entre a potência do sinal e a potência do ruído (FONTES, 2012, p.24).

Os sinais que constituem a voz humana codificam uma variedade de informações e as redes neurais biológicas do sistema nervoso humano tem um desempenho de grande eficiência na extração destes conteúdos (KOVÁCS, 2006, p. 142). Espera-se que as redes neurais do tipo SOM que têm inspiração neurológica possam ter êxito na identificação dos sinais digitais modulados. Segundo Valença (2010, p. 298): “As redes de Kohonen têm uma inspiração neurofisiológica, uma vez que são baseadas em observações do comportamento cerebral, onde o treinamento não supervisionado é predominante”.

Para Vieira e Roisenberg (2006, p.2), existem classes de problemas que a complexidade algorítmica é muito grande, de modo a se tornar inviável a resolução algorítmica convencional. As RNAs são dispositivos que permitem certa tolerância a ruídos e a falhas, o que advém da sua capacidade de generalização, sendo capazes de suportar ruídos e imperfeições do ambiente, ainda mantendo um resultado desejado. As pesquisas realizadas com redes neurais têm se mostrado bastante promissoras em diversas áreas como engenharia,

computação e até mesmo nas neurociências. Sendo também de grande utilidade para problemas como reconhecimento de padrões, agrupamento, previsão de séries temporais, etc.

Resultados relevantes estão sendo alcançados na classificação de sinais bioelétricos como eletrocardiograma, o eletroencefalograma e o eletromiograma; na classificação para reconhecimento de imagens e na classificação de fonemas. (KOVÁCS, 2006, p. 149).

2.11 MODULAÇÃO DIGITAL

2.11.1 Conceituação

Podemos definir modulação como uma técnica utilizada para transmitir informações (sinal modulante) através de outro sinal denominado de portadora que possui características que favoreçam a propagação no canal de comunicação. No processo de modulação os seguintes parâmetros da portadora são modificados pelo sinal modulante: amplitude, fase ou frequência. Se o sinal modulante for analógico, tem-se um processo de modulação analógica; se for digital, tem-se um processo de modulação digital. A portadora é normalmente um sinal cosenooidal, que pode ser expresso da seguinte maneira: $Y(t) = A \cos(2\pi ft + \phi)$. Onde A representa a amplitude do sinal, f representa a sua frequência e ϕ representa sua fase.

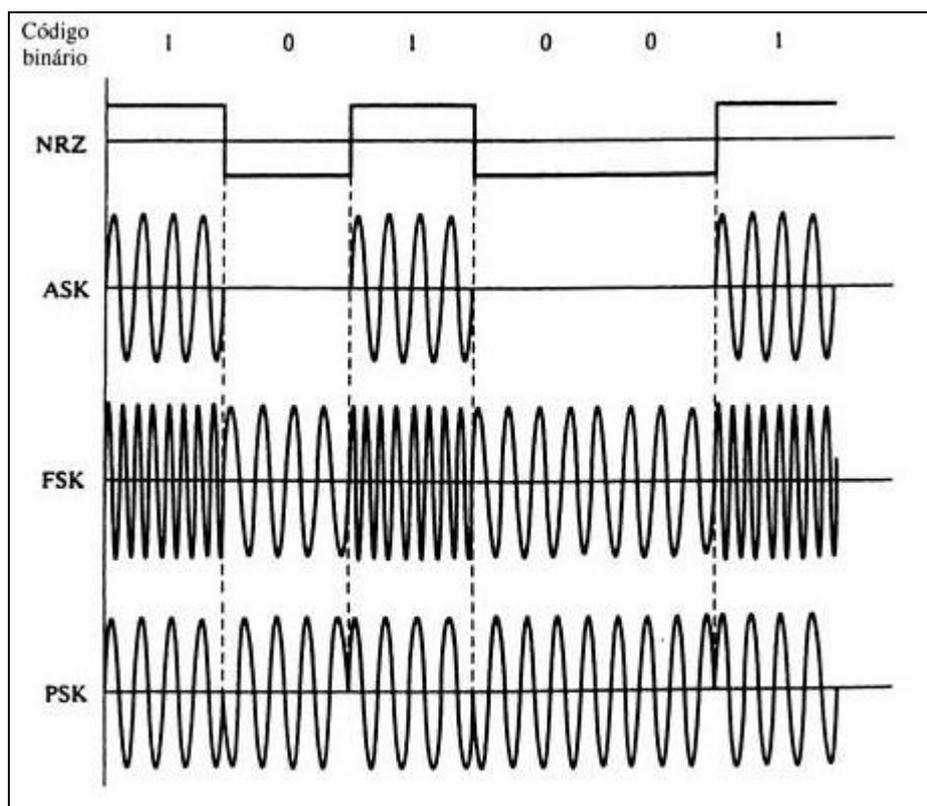
Com avanço das comunicações digitais, foram desenvolvidas técnicas de modulação capazes de transportar informações digitais através de uma portadora analógica. Sendo os sistemas puramente analógicos substituídos por sistemas digitais, que apresentam como vantagem maior confiabilidade e capacidade de transmissão. Nos subitens abaixo haverá a descrição dos tipos de modulações que serão utilizadas no presente trabalho a fim de comprovar, ou não, a eficácia das redes neurais artificiais do tipo SOM no processo de demodulação dos sinais.

2.11.2 Modulação FSK.

O processo de modulação por chaveamento de frequência (FSK) consiste na variação da frequência da onda portadora em função do sinal modulante. Segundo Haykin e Moher (2008, p.152): “Na modulação por chaveamento de frequência binária (BFSK – Binary Frequency-Shift Keying), os símbolos 1 e 0 são distinguidos através de duas ondas senoidais de frequências distintas”.

2.11.3 Modulação PSK.

O sinal PSK visto na figura 2.25, também é conhecido como BPSK (Binary PSK). Para esta modulação os valores de amplitude e frequência da portadora são constantes, variando apenas a fase em 180°. Uma mudança de fase representa mudança do bit 0 para o bit 1 ou vice-versa.



Fonte: (HSE, H. 2006).

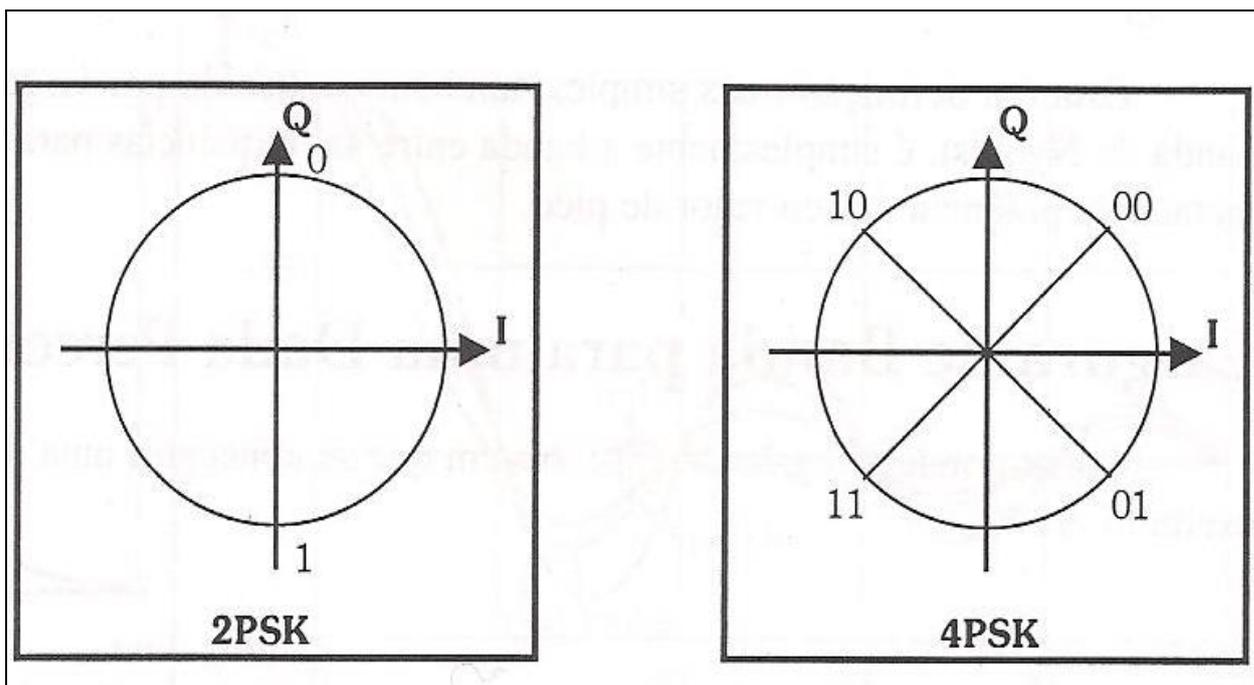
Figura 2.25: Exemplo de modulações digitais ASK, FSK e PSK.

2.11.4 Modulação QPSK.

As modulações 2FSK e BPSK são binárias, pois, só há dois símbolos possíveis em cada modulação, porém existem modulações com um maior número de símbolos. Uma forma de representar os símbolos da modulação é por meio do diagrama de constelação da modulação que representa as amplitudes e fases que a portadora pode assumir. Trata-se de um plano cartesiano representado pelos eixos x e y da portadora senoidal, onde a abscissa x é denominada de **I** (*In Phase*) e significa que o bit está na fase da portadora, já a ordenada y é denominada de **Q** (*In Quadrature*) e indica que o bit está na quadratura da portadora.

A modulação QPSK é uma técnica de modulação derivada do PSK, no entanto, na modulação QPSK são utilizados parâmetros de fase e quadratura da onda portadora para modular o sinal que contém a informação. Como agora são utilizados dois parâmetros, existem mais símbolos na constelação e são transmitidos mais bits por símbolo. Para transmitir 2 bits por símbolo na modulação QPSK, teremos 4 tipos de símbolos possíveis, a portadora pode assumir 4 valores de fase diferentes, cada um deles correspondendo a um dabit.

A figura 2.26 ilustra o diagrama de constelação para uma modulação QPSK (*Quaternary PSK*), havendo quatro fases possíveis ($+45^\circ$, -45° , $+135^\circ$ e -135°). Pode-se observar que na modulação QPSK cada ponto na constelação transporta a informação de dois bits do sinal modulante digital binário. “O diagrama de constelação é uma figura geométrica indicando as possíveis fases assumidas pelo sinal modulado e os possíveis caminhos de transição entre esses pontos” (BATISTA J. B. B., 2013, p.21).



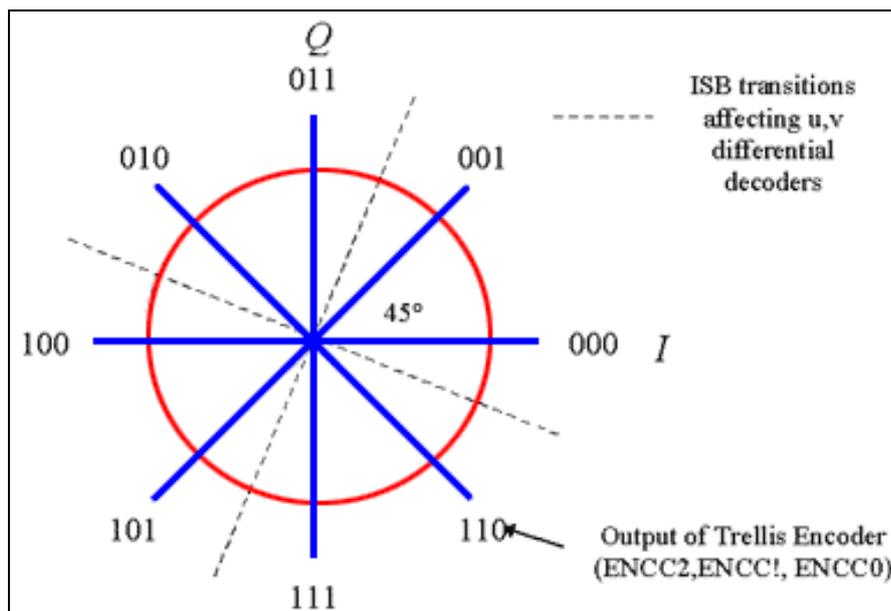
Fonte: (MIYOSHI; SANCHES, 2002, p. 81).

Figura 2.26: Constelação de sinais para 2PSK e para QPSK.

2.11.5 Modulação 8-PSK.

Pode ocorrer que a fonte do sinal modulante não seja binária, utilizando mais de dois símbolos para representar a informação. Nesse caso, recebe a denominação de M-ária, $M=2k$, $k=1,2,3, \dots$ Para uma fonte binária, $k=1$. Uma fonte M-ária possui $2k$ símbolos. k representa, por assim dizer, o número de bits que constitui uma mensagem gerada pela fonte (BATISTA J. B. B., 2013, p.10).

Para $k=3$, teremos o 8PSK, para $k=4$ teríamos o 16PSK e assim por diante. A modulação 8-PSK possui 8 estados e, por este motivo, existe uma codificação do sinal digital em tribits. Cada conjunto 3 bits do sinal poderá assumir 8 valores diferentes, de 000 até 111, e cada um destes valores corresponde a um fasor, como pode ser visto no diagrama de constelação da modulação 8-PSK apresentada na figura 2.27. A eficiência espectral teórica para esta modulação é de $3b/s/Hz$.



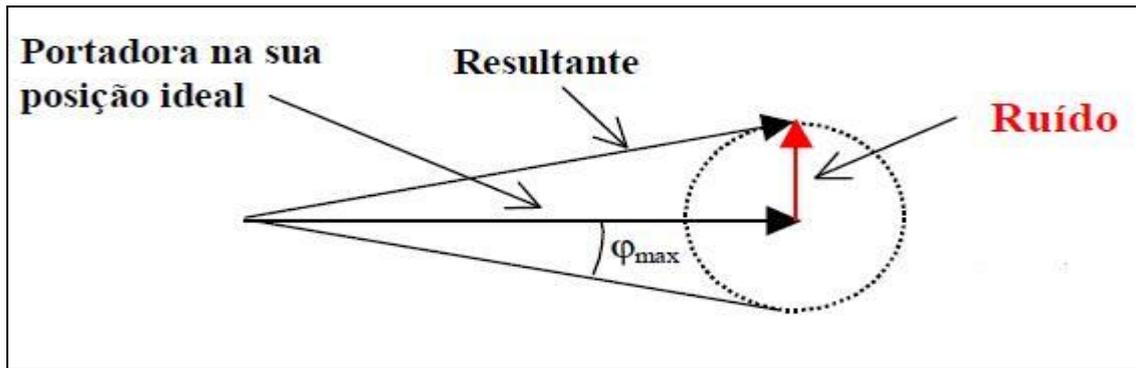
Fonte: <http://www.eetimes.com/design/communications-design/4018019/Pragmatic-TCM-Using-8-PSK-in-Satellite-Communications>.

Figura 2.27: constelação 8-PSK.

Outros tipos de modulação PSK são 16-PSK, 32-PSK, 64-PSK, no entanto, é importante frisar que quanto mais níveis forem utilizados mais difícil será a identificação dos símbolos na recepção.

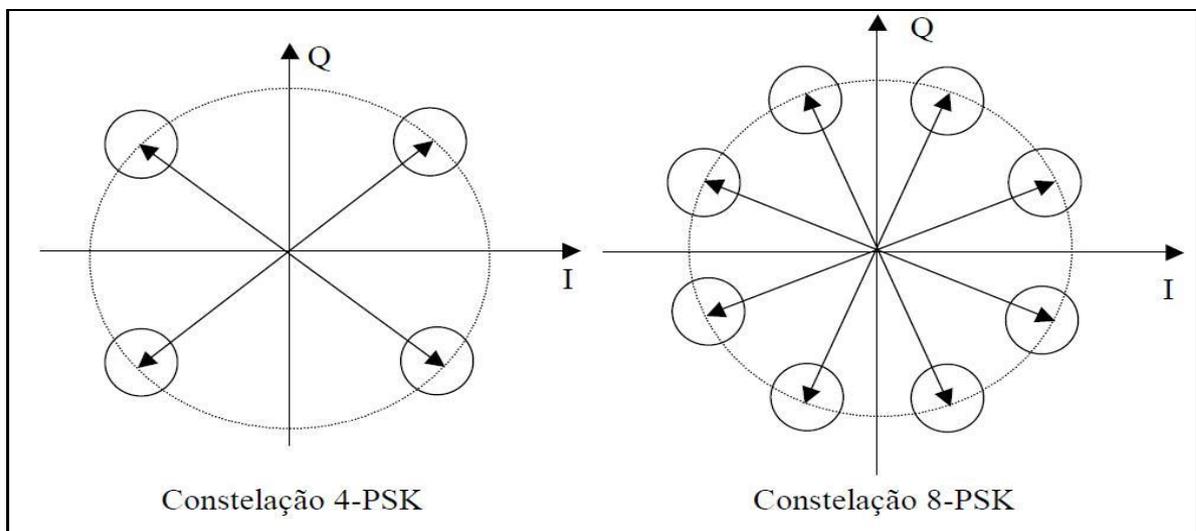
2.11.6 Efeito do ruído nas constelações

Cada fasor existente na constelação possui um círculo de indecisão, que corresponde à região onde o mesmo pode se desviar da sua posição ideal, graças ao ruído. No diagrama de constelação não pode existir a sobreposição dos círculos de indecisão, a fim de que não ocorram problemas na identificação do símbolo na recepção. Quanto mais afastados estiverem os círculos de indecisão, menor será a probabilidade de haver erros na detecção dos sinais modulados. Na figura 2.28 pode-se observar o efeito do ruído na modulação PSK.



Fonte: Apostila de Sistemas de Telecomunicações II do instituto superior de engenharia de Lisboa.
 Figura 2.28: Efeito do ruído na modulação PSK.

Podemos ver na figura 2.29, onde são apresentados um sinal 4-PSK e um sinal 8-PSK com as mesmas amplitudes de portadora, que os círculos de indecisão estão muito mais próximos na constelação 8-PSK do que na constelação 4-PSK. Demonstrando que a modulação 8-PSK está mais vulnerável ao ruído do que a modulação 4-PSK. Segundo Alencar (2001, p. 78) “A redução na distância entre os símbolos é um indicador qualitativo do aumento na taxa de erro de bit (BER)”.



Fonte: Apostila de Sistemas de Telecomunicações II do instituto superior de engenharia de Lisboa.
 Figura 2.29: Efeito do ruído nas constelações 4-PSK e 8-PSK.

2.11.7 Taxa de erro de bits

A transmissão não ideal de sinais ao longo de um canal com ruído AWGN provoca alterações na amplitude da onda de forma randômica, alterando assim a energia média de bit

e de símbolo. Podendo provocar a ocorrência de erros de detecção dos bits da informação (LOPES, 2012, p. 3).

Segundo Haykin e Moher (2008, p.176): A sensibilidade de um sistema de comunicações *wireless* é medida em termos da probabilidade média do erro de símbolo (P_e). Considerando que no sistema temos uma operação binária básica e que o símbolo é um bit, um sistema incorre em um erro quando um símbolo 1 é transmitido, mas o receptor entende que o símbolo é 0, ou vice e versa. A probabilidade P_e é obtida tomando-se a média dessas duas probabilidades de erro condicional com relação às probabilidades de obtenção dos símbolos 0 e 1, em tal situação P_e é designada como taxa de erro de bit (*BER, do inglês Bit Error Rate*).

Para Haykin e Moher (2008, p.176): Em um receptor coerente, a portadora gerada localmente está sincronizada com a portadora do transmissor tanto em fase quanto em frequência. E para os receptores coerentes operando nos esquemas de modulações simples como o BPSK, o QPSK e o BFSK foram derivadas fórmulas exatas para o cálculo de P_e .

A tabela 2.2 resume as taxas de erro de bits para os seguintes receptores:

- BPSK coerente;
- QPSK coerente; e
- 2FSK coerente.

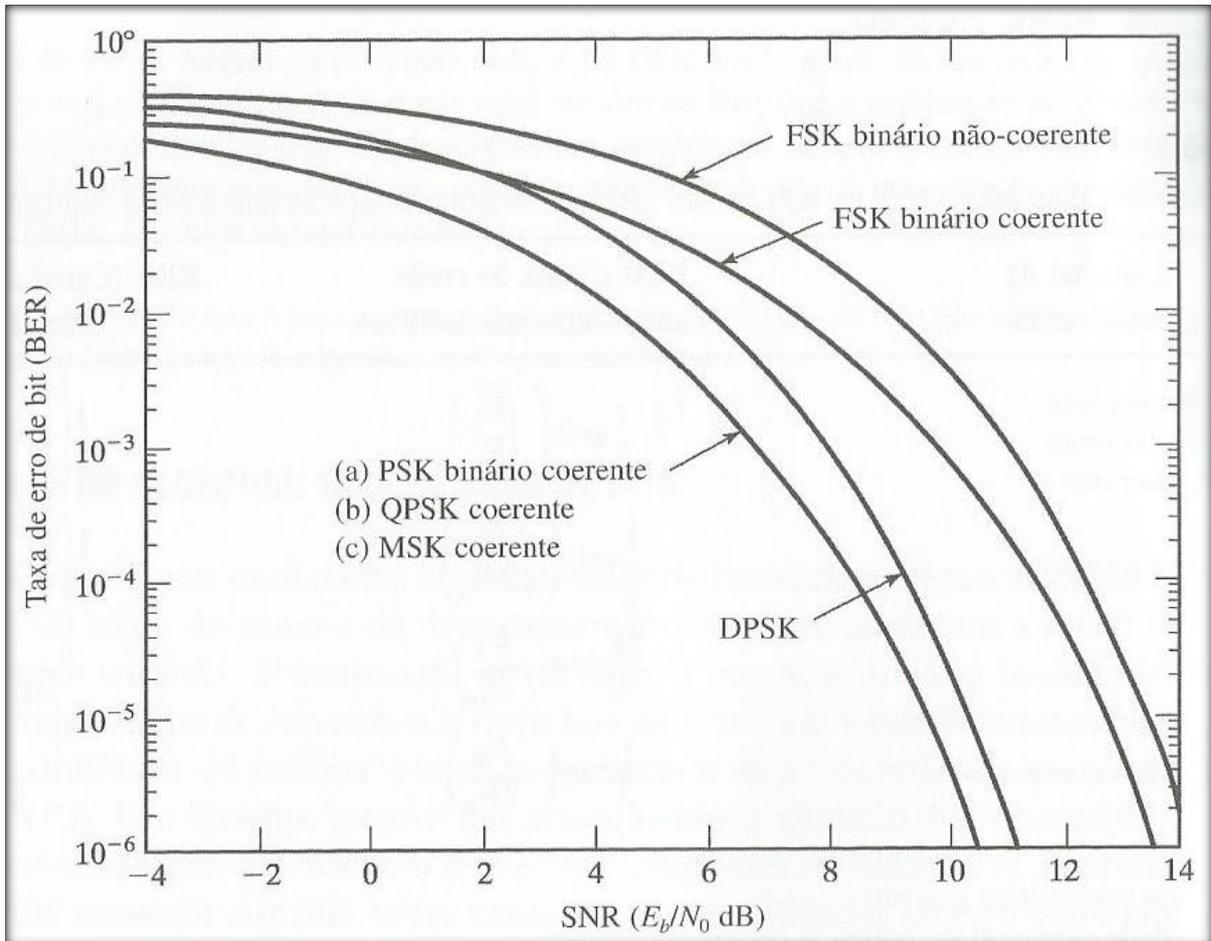
Onde N_0 é a densidade espectral de potência do ruído de canal e E_b é a energia transmitida por bit.

Tabela 2.2: Taxa de erro de bits (BER) para diferentes modulações digitais.

Modulação	Taxa de erro de bits (BER)
2FSK	$\frac{1}{2} \operatorname{erfc} \sqrt{\frac{E_b}{2N_0}}$
BPSK e QPSK	$\frac{1}{2} \operatorname{erfc} \sqrt{\frac{E_b}{N_0}}$

Fonte: (HAYKIN; MOHER, 2008, p. 177).

Na figura 2.30 são traçadas as curvas da BER em função da relação sinal ruído para um canal AWGN.



Fonte: (HAYKIN; MOHER, 2008, p. 178).

Figura 2.30: Comparação da sensibilidade do receptor ao ruído para diferentes esquemas PSK e FSK.

Segundo Haykin e Moher (2008): Para as modulações binárias a probabilidade de erro de bit é igual à probabilidade de erro por símbolo, pois um bit é também um símbolo. Para a modulação QPSK que possui dois bits por símbolo é dada pela seguinte equação:

$$P_{esim} = 1 - \left(1 - \frac{1}{2} \operatorname{erfc} \sqrt{\frac{E}{2N_0}}\right)^2 \quad (2.15)$$

Como E é a energia do símbolo e para QPSK $E = 2E_b$, que é a energia por bit, tem-se que:

$$P_{esim} = 1 - \left(1 - \frac{1}{2} \operatorname{erfc} \sqrt{\frac{E_b}{N_0}}\right)^2 \quad (2.16)$$

Como:

$$\left(1 - \frac{1}{2} \operatorname{erfc} \sqrt{\frac{E_b}{N_0}}\right)^2 = 1 - \operatorname{erfc} \left(\sqrt{\frac{E_b}{N_0}}\right) + \frac{1}{4} \operatorname{erfc}^2 \left(\sqrt{\frac{E_b}{N_0}}\right) \quad (2.17)$$

Temos então:

$$P_{esim} = 1 - \left(1 - \operatorname{erfc} \left(\sqrt{\frac{E_b}{N_0}}\right) + \frac{1}{4} \operatorname{erfc}^2 \left(\sqrt{\frac{E_b}{N_0}}\right)\right) \quad (2.18)$$

$$P_{esim} = \operatorname{erfc} \left(\sqrt{\frac{E_b}{N_0}}\right) - \frac{1}{4} \operatorname{erfc}^2 \left(\sqrt{\frac{E_b}{N_0}}\right) \quad (2.19)$$

Na região onde $\left(\sqrt{\frac{E_b}{N_0}}\right) \gg 1$ pode-se ignorar o termo quadrático da direita, então temos:

$$P_{esim} \cong \operatorname{erfc} \left(\sqrt{\frac{E_b}{N_0}}\right) \quad (2.20)$$

CAPÍTULO III

3 TRAJETÓRIA METODOLÓGICA

3.1 TIPO DE ESTUDO

“O método é o conjunto das atividades sistemáticas e racionais que, com maior segurança e economia, permite alcançar o objetivo - conhecimentos válidos e verdadeiros - traçando o caminho a ser seguido, detectando erros e auxiliando as decisões do cientista” (LAKATOS; MARCONI, 2010, p.65).

A presente pesquisa empregou o estudo do tipo dedutiva e experimental com uma abordagem quantitativa.

Pode-se afirmar que a metodologia utilizada é quantitativa, pois, esta é baseada em dados concretos, que podem ser verificados matematicamente, representados através de tabelas e gráficos e normalmente é aplicada nas pesquisas experimentais. Segundo Popper (1972 apud Dalfovo; Lana e Silveira, 2008, p.7) de uma forma geral, tal como a pesquisa experimental, os estudos de campo quantitativos guiam-se por um modelo de pesquisa onde o pesquisador parte de quadros conceituais de referência tão bem estruturados quanto possível, a partir dos quais formula hipóteses sobre os fenômenos e situações que quer estudar. Uma lista de consequências é então deduzida das hipóteses.

Segundo Diehl (2004 apud Dalfovo; Lana e Silveira, 2008, p.7): “entre os tipos de estudos quantitativos podem-se citar os estudos experimentais (que proporcionam meios para testar hipóteses)”.

Da mesma forma pode-se afirmar que a metodologia utilizada também é dedutiva, pois, se aplica naturalmente a pesquisas de natureza experimentais e se relaciona perfeitamente com o método quantitativo, pois, ela permite uma análise lógica e racional das proposições levando a obtenção da conclusão.

Para Boente e Braga (2004 apud Dalfovo; Lana e Silveira, 2008, p.4), segundo os procedimentos de coleta de uma pesquisa, a pesquisa será definida como experimental se esta envolve algum tipo de experimento que deve seguir um método a rigor científico para que a estrutura se faça eficiente.

Lakatos e Marconi (2010, p.74) afirma que, o argumento dedutivo tem o objetivo de explicar o conteúdo das premissas. Sob outro enfoque, ou os argumentos dedutivos estão corretos ou incorretos, ou as premissas sustentam de modo completo a conclusão, ou, quando a forma é logicamente incorreta, não a sustentam de forma alguma; portanto, não há graduações intermediárias.

Hymann (1967 apud Dalfovo; Lana e Silveira 2008, p.4), define-se quando indica pesquisa como experimental, quando há interpretações e avaliações na aplicação de determinados fatores ou simplesmente dos resultados já existentes dos fenômenos.

Gil (2002, p. 93) afirma que, o planejamento da pesquisa experimental implica no desenvolvimento dos seguintes passos:

- Formulação do problema;
- Elaboração dos objetivos e metas;
- Determinação do local e tempo da pesquisa;
- Operacionalização dos conceitos e variáveis;
- Elaboração dos instrumentos de coleta de dados;
- Pré-teste do instrumento;
- Seleção da amostra;
- Coleta e interpretação dos dados; e

- Apresentação dos resultados.

Para Gil (2002, p. 94) a pesquisa experimental inicia-se com algum tipo de problema ou indagação. Mais que qualquer outra, a pesquisa experimental exige que o problema seja colocado de maneira clara, precisa e objetiva.

Portanto Lakatos e Marconi (1991, p.61) elucidam que a pesquisa dedutiva, encaixa o fenômeno a ser explicado em um contexto de uniformidades, ao mesmo tempo em que salienta que deveria ser esperada a sua ocorrência, dadas as leis mencionadas e as pertinentes circunstâncias particulares.

Desta forma, este trabalho pretende obter uma constatação baseada em uma simulação laboratorial, sendo as condições de coleta de dados controlada, a fim de poderem gerar resultados decorrentes do experimento que possam ser devidamente interpretados e avaliados a fim de se gerar as conclusões do estudo.

3.2 LOCAL DO ESTUDO

O estudo foi realizado em laboratório.

3.3 DETERMINAÇÃO DA AMOSTRA

As amostras de sinais são formadas por sinais modulados em BPSK e 2FSK gerados no Matlab e contaminados com ruído AWGN.

3.4 COLETA E ANÁLISE DOS RESULTADOS

A fase de coleta de dados ocorreu no período de maio a junho de 2013 e a técnica utilizada foi à simulação computacional através da aplicação de rotinas desenvolvidas em Matlab, objetivando a geração de sinais.

Segundo Popper (1972 apud Dalfovo; Lana e Silveira, 2008, p.7) a coleta de dados enfatizará números (ou informações conversíveis em números) que permitam verificar a ocorrência, ou não, das consequências, e daí então a aceitação (ainda que provisória), ou não, das hipóteses. Os dados são analisados com apoio da Estatística (inclusive multivariada) ou outras técnicas matemáticas.

O material utilizado nesta pesquisa consistiu de um microcomputador munido do programa Matlab. A pesquisa consistiu em uma simulação computacional, com as rotinas essencialmente desenvolvidas no programa supracitado. Com base nos critérios de seleção da amostra e do *software*, se deu início ao processo de coleta, e posteriormente, foram processados os sinais.

Desta forma, este trabalho pretende obter uma constatação baseada em uma simulação laboratorial, sendo as condições de coleta de dados controlada, a fim de poder gerar resultados decorrentes do experimento que possam ser devidamente interpretados e avaliados a fim de se gerar as conclusões do estudo.

Neste trabalho, serão utilizadas as redes SOM em decorrência de sua habilidade de realizar o agrupamento dos dados apresentados nas suas entradas em classes ou categorias.

Primeiramente, será utilizada uma estrutura onde as redes SOM serão utilizadas para identificar a que tipo de modulação pertence o sinal de entrada apresentado à RNA. Estas redes estão dispostas em paralelo e geram uma região espacial para classificação dos sinais e que divide este espaço em várias regiões de decisão. O número de RNAs do tipo SOM utilizadas será igual ao número de classes que se pretende identificar, como neste estudo serão utilizados sinais modulados em 2FSK e BPSK existirão duas redes neurais do tipo SOM.

O algoritmo de reconhecimento automático de modulação, em decorrência da estrutura apresentada é baseado em processo de competição que ocorre entre as diversas redes existentes.

Na etapa de treinamento da estrutura, cada RNA é treinada individualmente, usando, para isto, um dos tipos modulação que se pretende que a estrutura seja capaz de reconhecer

automaticamente. Após a etapa de treinamento, teremos várias redes SOM, capaz, cada uma individualmente, de reconhecer um tipo específico de modulação.

Na etapa de teste, ou seja, de validação da rede neural, para cada vetor amostra será realizado um processo de competição em todas as redes SOM, buscando o neurônio mais próximo do vetor apresentado na entrada. A rede em que houver este neurônio com a menor distância Euclidiana será a rede que identifica o tipo de modulação.

Normalizam-se as amostras para evitar que uma dimensão se sobreponha as outras, e para evitar que o aprendizado, no caso das redes neurais, fique estagnado. Pode-se normalizar através do uso de alguns métodos de normalização, neste trabalho foram utilizadas as normas Euclidiana e *Manhattan*.

A rede neural desenvolvida neste trabalho faz a identificação dos sinais através de uma correta classificação das amostras processadas em *clusters* (agrupamentos).

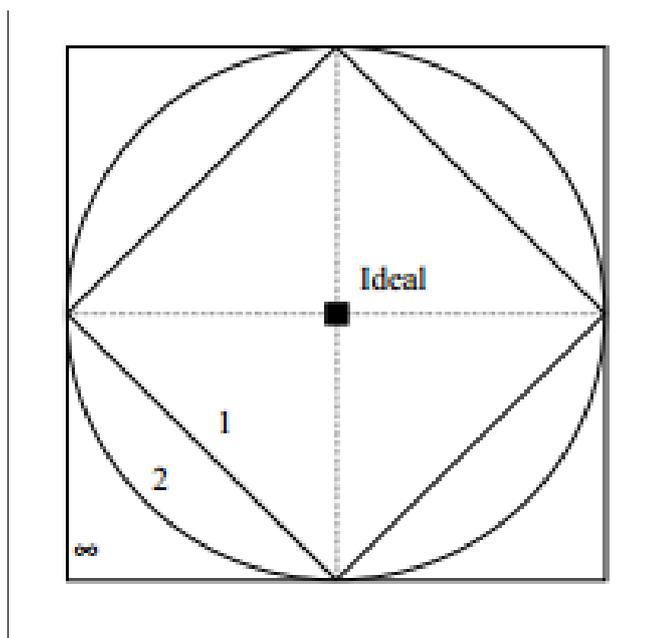
Foram empregados comparativamente dois tipos de normalização, para averiguar qual das normas geraria clusters mais homogêneos e qual delas penalizaria de maneira mais consistente os dados externos (*outliers*, ou dados fora da média, dados inconsistentes). A normalização serve para realizar a penalização dos *outliers*, e, por conseguinte seu expurgo, sendo apresentados os resultados obtidos na conclusão do presente trabalho.

Segundo Aikes Junior et al (2012, p.5), as medidas da Norma L_p , em especial a distância Euclidiana, estão entre as medidas de distância mais conhecidas e exploradas na literatura. Para o cálculo da distância baseado na Norma L_p , cada sequência é considerada um ponto no espaço W -dimensional. Dentre as mais conhecidas estão a distância Euclidiana e a distância *Manhattan*.

As medidas L_p Inteiras são nomeadas de acordo com o valor de p : $p=1$: *Manhattan*, também conhecida como *City Block* (L_1); e $p=2$: Euclidiana (L_2). Onde x e y são os vetores W -dimensionais, correspondentes às sequências e p define a medida de distância a ser utilizada.

$$L_p(x, y) = \left(\sum_{i=1}^W |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (3.1)$$

A utilização destas métricas para avaliar a distância ao ideal presta-se a uma descrição gráfica, conforme pode ser visto na figura 3.1, onde se mostram os lugares geométricos dos pontos às distâncias 1, 2 do ideal. A distância entre uma alternativa e o ideal é uma medida de dissemelhança, podendo usar-se uma métrica L_p para avaliar a dissemelhança, sendo, $p=1$ para norma *Manhattan* e $p=2$, para norma Euclidiana (MATOS, p.2).



Fonte: Conceitos úteis. Retirado do site: <http://paginas.fe.up.pt/~mam/normetr.pdf>.
 Figura 3.1: Descrição gráfica das métricas *Manhattan* e Euclidiana.

Segundo Lopes et al (2012, p.12) Métricas de dissimilaridades são utilizadas em redes neurais para medir a distância entre o vetor de entrada e os vetores de pesos dos neurônios. A métrica de dissimilaridade que normalmente é utilizada é a norma Euclidiana, porém, de acordo com as características do problema a ser enfrentado, podem ser utilizadas outras normas, como por exemplo, a norma *Manhattan*. Estas duas métricas propiciam a criação de clusters mais homogêneos e penalizam mais adequadamente os *outliers* que, por motivo de erro grosseiro ou falha, estão muito distantes da média.

CAPÍTULO IV

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

4.1 DESCRIÇÃO

“O ser humano é dotado de complexos circuitos neurais cerebrais que constam de variadas conexões entre seus neurônios (sinapses) interagindo entre si de modo a fazer emergir comportamento inteligente. Sendo assim, surge a ideia de que se conseguirmos modelar computacionalmente estas conexões neurais poderíamos fazer emergir comportamentos também inteligentes em máquinas. Neste contexto, surgem as redes neurais artificiais (RNAs) que são inspiradas na própria natureza das redes de neurônios e sinapses biológicas. Essa ideia de modelagem cerebral forma a vertente da inteligência Artificial chamada Inteligência Artificial Conexionista” (VIEIRA; ROISENBERG, 2006, p.1).

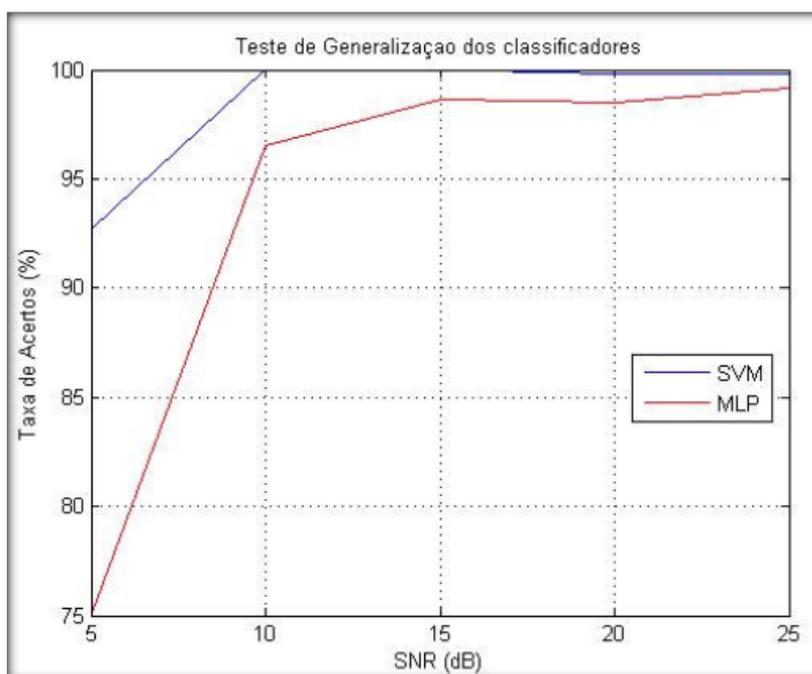
Os primeiros modelos de redes neurais artificiais começaram com um único neurônio artificial, tentando matematicamente e computacionalmente simular o neurônio biológico humano, depois, os pesquisadores, mais uma vez inspirados no cérebro (que possui sua grande capacidade de processamento, baseada na sua vasta rede neural biológica), fizeram a interligação de múltiplos neurônios artificiais formando uma rede neural artificial de fato, com o objetivo de conseguir realizar funções e resolver problemas mais complexos; surgiram então as redes baseada em camadas como, por exemplo, a *Multi-Layer Perceptron* que tem sua capacidade de processamento intrinsecamente ligada ao número de camadas escondidas que possui.

O Professor Teuvo Kohonen também motivado por inspiração cerebral, só que passando a visualizar o cérebro humano como uma estrutura com mais de uma dimensão, que é subdividida em áreas especializadas em realizar funções específicas. Desta maneira, ele criou os mapas auto-organizáveis de Kohonen que são capazes de resolver problemas baseados na sua topologia espacial.

As redes neurais têm obtido um desempenho satisfatório na extração de informações de ambientes saturados com diversos outros sinais que não são relevantes para a obtenção do resultado esperado, por esta razão espera-se que a RNA depois de ser devidamente treinada com os sinais modulados acrescidos do ruído AWGN, se torne capaz de realizar a classificação dos sinais e sua demodulação. Por exemplo, segundo Kováks (2006,p.149), resultados relevantes estão sendo alcançados na classificação de sinais bioelétricos como eletrocardiograma, o eletroencefalograma e o eletromiograma; na classificação para reconhecimento de imagens e na classificação de fonemas.

De acordo com Horewicz, Nascimento Jr e Parrela (2008, p.1), redes neurais artificiais do tipo MLP e classificadores do tipo Support Vector Machines (SVM), foram utilizadas para classificar esquemas de modulação digital, e ambos obtiveram uma boa capacidade de generalização para sinais com SNR acima de 10 dB. Com isto, verificou-se a habilidade destes métodos distintos na solução do problema de reconhecimento automático da modulação, evidenciando um melhor desempenho para as SVM, como pode ser apreciado na figura 4.1.

Neste trabalho, vamos nos ater às redes neurais, por isto, estamos particularmente interessados no desempenho obtido no artigo supracitado com a rede *Multi-Layer Perceptron* na classificação dos sinais.



Fonte: (HOREWICZ; NASCIMENTO JR; PARRELA, 2008, p.5).

Figura 4.1: Teste de generalização dos classificadores.

Segundo Zhou et al (2011, p.1 e 5) é possível realizar o reconhecimento automático de modulação e também o processo de demodulação de sinais digitais utilizando uma rede Múltipla de mapas de Kohonen. Foi proposto nesse artigo, um novo método baseado em múltiplos mapas auto-organizáveis (M-SOM), para realizar o reconhecimento da modulação diretamente em sinais normalizados sem uma informação específica de SNR. As redes M-SOM são treinadas em certas condições de SNR e o resultado é que a rede desenvolve a habilidade de realizar uma competente classificação dos sinais em diferentes situações de SNR, mesmo em ambientes com baixo SNR, obtendo uma classificação de sinais quase perfeita, próxima de 100% de acerto para todos os tipos de modulação testados no artigo. Adicionalmente ao reconhecimento automático da modulação, esta topologia possui a habilidade para realizar a demodulação dos sinais digitais em um estágio de recepção, podendo desta maneira realizar duas funções essenciais de um rádio definido por *software*.

De acordo Zhou et al (2011, p.2), no método proposto, não há a necessidade de treinar as RNAs em todos os SNR possíveis, sendo usado no experimento apenas amostras de sinais com SNR de 20 dB. E o resultado alcançado com o treinamento é um desempenho robusto da rede em diferentes ambientes ruidosos.

No presente trabalho, na simulação um, pretende-se reproduzir a estrutura sugerida para as redes SOM de Kohonen, a fim de, inicialmente, buscar-se confirmar a habilidade adquirida com esta estrutura para efetuar a demodulação de sinais digitais, utilizando para este propósito sinais modulados em 2FSK e BPSK.

Em um segundo momento, na simulação dois, após se confirmar a eficácia da topologia proposta no processo de classificação e demodulação; tendo em vista que o treinamento de uma RNA é importantíssimo para determinar o desempenho final da rede, propõe-se realizá-lo de uma maneira diferente ao sugerido no artigo supracitado, passando-se a realizar o treinamento da rede utilizando amostras com diferentes níveis de SNR cada.

Em um terceiro momento, na simulação três, visa-se a testar a métrica *Manhattan* em substituição da distância Euclidiana como medida de dissimilaridade empregada na formação dos clusters nos mapas de Kohonen da rede M-SOM, a fim de verificar se obteremos com isto, um desempenho melhor da rede neural estudada.

Após isto, na simulação quatro, visa-se a empregar a mesma topologia utilizada com múltiplos mapas de Kohonen com redes ART, obtendo uma estrutura com múltiplas redes ART (M-ART), e averiguar se esta configuração também tem um desempenho semelhante à anterior, sendo competente no processo de classificação e demodulação de sinais. São utilizados para este propósito sinais modulados em 2FSK, BPSK e adicionalmente ao realizado com a rede anterior (M-SOM), sinais modulados em QPSK.

A forma de treinamento utilizada com a rede M-SOM com múltiplos mapas de Kohonen, que vier a propiciar um melhor desempenho da RNA (utilizando o treinamento da rede com amostras com diferentes níveis de SNR, ou utilizando-se amostras todas com a mesma relação de sinal/ruído de 20 dB), será igualmente utilizada na topologia com múltiplas redes ART, pois, espera-se por indução que ela permita um desempenho superior com esta rede, assim como permitiu com a anterior.

Na simulação cinco, da mesma maneira que na simulação três, só que desta vez, com a arquitetura de rede ART, se faz o teste da métrica de *Manhattan* em comparação com a métrica da distância Euclidiana, que normalmente é utilizada, a fim de se averiguar qual das duas medidas de dissimilaridade permite um melhor desempenho para esta rede neural artificial.

Como supracitado no capítulo 2, que trata do projeto das redes neurais artificiais, uma das etapas a serem seguidas no desenvolvimento de uma RNA é a criação de um banco de dados contendo amostras relevantes que possam ser utilizadas com dois propósitos: inicialmente uma parte destas amostras é utilizada para possibilitar o treinamento da rede neural, e, com isto, o seu aprendizado; uma segunda parte destas amostras deverá ser utilizada em outra etapa do projeto da RNA que consiste no teste da rede e sua validação.

4.1.1 coleta e seleção dos dados

De acordo com Ludwig Jr e Montgomery (2007, p.21): “A coleta criteriosa dos dados relativos ao problema é fundamental para o desempenho de uma rede neural. Esta

tarefa requer uma análise cuidadosa dos dados. Além disso, os dados devem cobrir amplamente o domínio do problema, incluindo as exceções e as condições limites”.

Também segundo com Ludwig Jr e Montgomery (2007, p.22): “Os dados coletados são separados em duas categorias: dados de treinamento, que serão utilizados no treinamento da rede e dados de validação, que serão utilizados para verificar o desempenho da rede”. Por este motivo, os dados, ou seja, os sinais modulados utilizados para o treinamento e para a validação das redes neurais artificiais estudadas neste trabalho são gerados em laboratório, através do Matlab.

Neste trabalho serão utilizadas as modulações 2FSK, BPSK (e adicionalmente QPSK para a rede M-ART) para realizar o treinamento das RNAs, possibilitando o seu aprendizado, e, com isto, o seu correto funcionamento na identificação desses sinais modulados e sua demodulação.

Nos subitens abaixo haverá a descrição dos tipos de modulações que serão utilizadas no presente trabalho a fim de comprovar, ou não, a eficácia das redes neurais artificiais do tipo auto-organizáveis no processo de demodulação dos sinais digitais.

4.1.1.1 Modulações FSK, BPSK e QPSK.

A figura 4.2 foi gerada através do comando *subplot* do Matlab, apresentando de maneira clara como são gerados os sinais modulados em 2FSK, utilizados no presente trabalho. Temos duas formas de onda que foram geradas no programa, a primeira é o sinal contendo a informação, ou seja, o sinal modulante e a segunda forma de onda consiste no sinal já modulado em FSK pelo Matlab.

A figura 4.3, de forma análoga, foi gerada através do comando *subplot* do Matlab, apresentando de maneira clara como são gerados os sinais modulados em BPSK utilizados no presente trabalho. O sinal modulado visto na figura, também é conhecido como BPSK (*Binary PSK*). Para esta modulação os valores de amplitude e frequência da portadora são constantes, variando apenas a fase em 180°. Uma mudança de fase representa mudança do bit 0 para o bit 1 ou vice-versa.

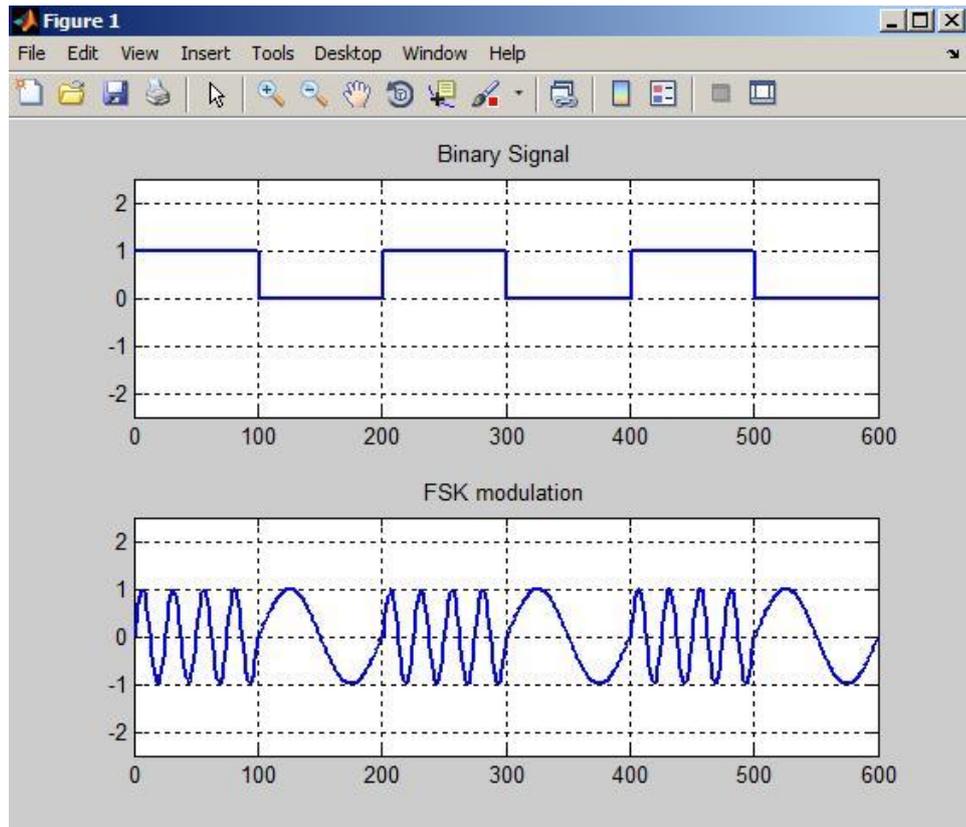


Figura 4.2: Modulação FSK gerada no Matlab.

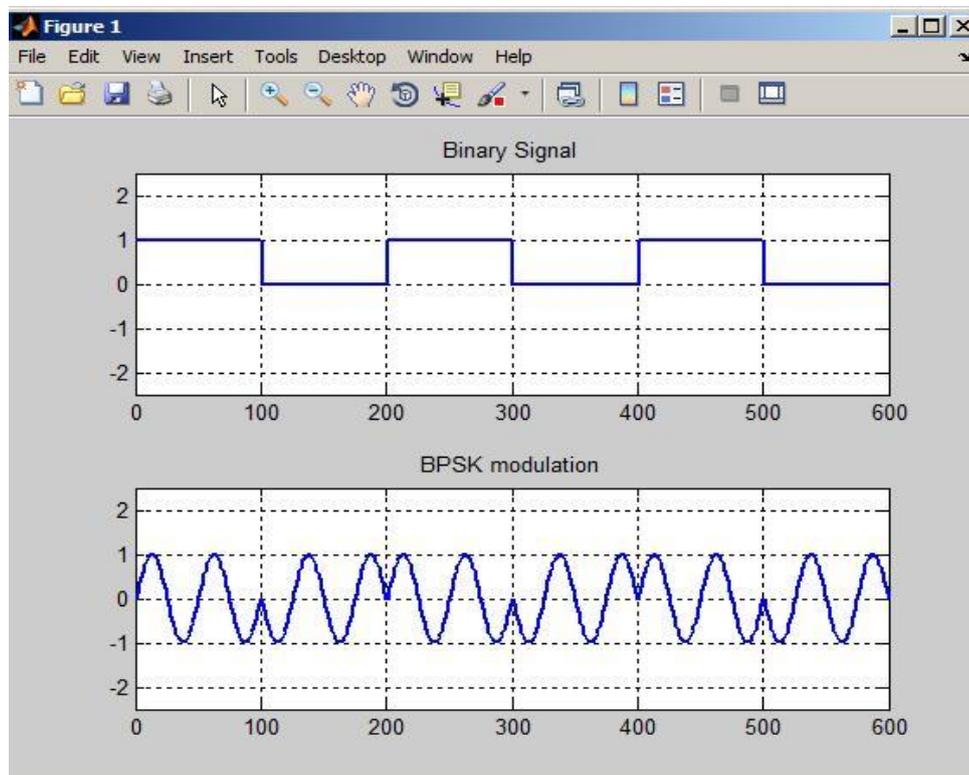


Figura 4.3: modulação BPSK gerada no Matlab.

O QPSK, que é uma modulação PSK onde $k=2$, dando origem a 4 símbolos possíveis para as mensagens da fonte, 00, 01, 10 e 11, e uma modulação MPSK, $M=4$. O prefixo Q significa Quadratura, indicando que existirão 2 portadoras em quadratura de fase (defasagem de 90° entre elas) (BATISTA J. B. B., 2013, p.12).

A figura 4.4 ilustra a geração das amostras do sinal modulado QPSK no Matlab.

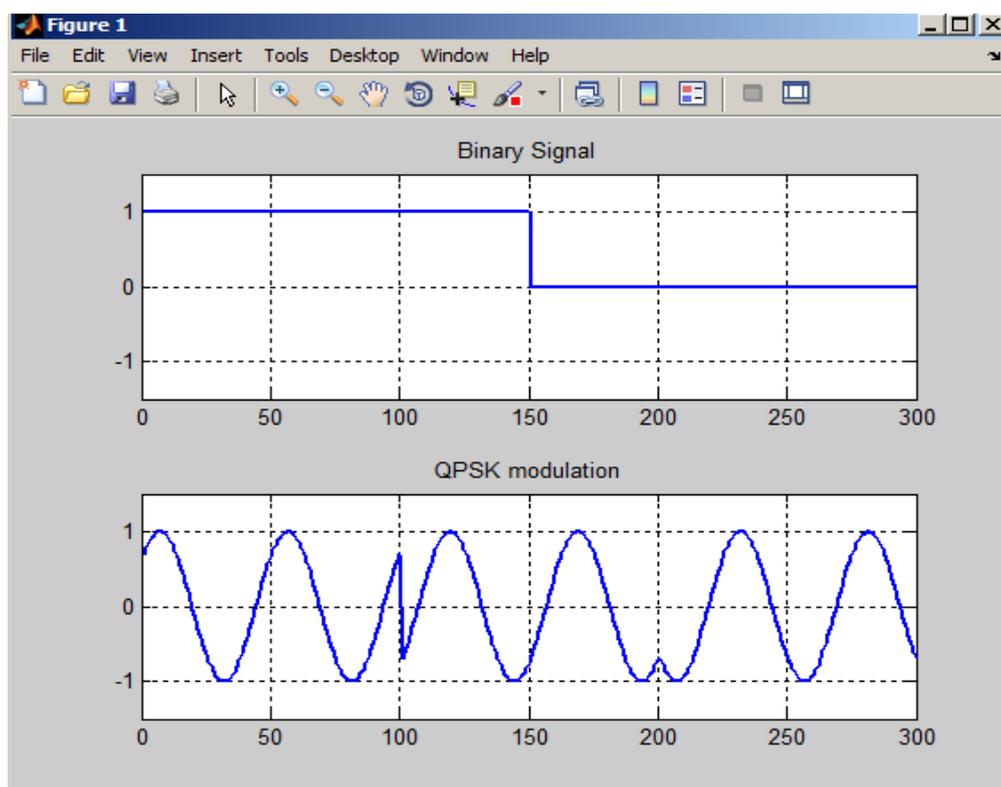


Figura 4.4: modulação QPSK gerada no Matlab.

4.1.1.2 Inserção de ruído Aditivo Gaussiano Branco.

Os ruídos são um dos fatores mais limitativos e restritivos do desempenho dos sistemas utilizados em telecomunicações, por este motivo, faz-se através do Matlab a inserção de ruído nas amostras para treinamento e teste das redes neurais, a fim de treiná-las e posteriormente testá-las em condições as mais próximas possíveis de um ambiente real de propagação de sinais. Ou seja, os sinais digitais modulados são contaminados proposadamente com ruído branco aditivo gaussiano (AWGN) para simular um canal real de propagação, tornando a simulação mais verossímil.

4.1.1.3 Descrição da geração dos dados para treinamento e teste para a rede M-SOM (As amostras criadas para a rede M-ART foram geradas de forma análoga).

As amostras de sinal usadas no conjunto de treinamento e as classificadas foram geradas utilizando *mfiles* do Matlab. Para a geração das amostras moduladas em 2-FSK foi escrito e comentado o script do arquivo `criar_fsk.m`, para as amostras moduladas em BPSK foi escrito e comentado o script `criar_bpsk.m`. Ambos se resumem a seguir:

Foi definida a frequência da portadora (usamos a mesma para ambas as modulações). Foi escolhida uma frequência de VHF referente ao canal 13 de TV aberta como exemplo.

Para a geração dos símbolos (0's e 1's) aleatórios, foi utilizada uma função do *Toolbox* do Matlab.

Para definir a quantidade de amostras foi criado um vetor *tsim* que define o tempo de símbolo. Foi definido, para melhor visualização dos símbolos em gráfico, que o tempo que melhor se ajusta é igual a dois períodos da função seno. O vetor *tsim* foi dividido em 30 unidades igualmente espaçadas (taxa de amostragem = $4 \cdot \pi / 30$). Isso implica que para cada símbolo temos 30 amostras.

Para a modulação 2-FSK foi criado um vetor de duas entradas que define as faixas laterais do sinal. Este vetor foi denominado de “df”. Para a modulação das amostras BPSK foi utilizado um vetor “fa” que carrega as duas possíveis fases utilizadas na modulação.

Um *looping* utilizando os vetores citados acima, cria uma matriz 30X20 que representa as 600 amostras do sinal modulado (2-FSK e BPSK). Essa matriz é transformada em um vetor linha denominado “Sinal” com as 600 amostras. Após isso, foi inserido o ruído gaussiano branco às amostras com a função AWGN do Matlab.

As dificuldades encontradas na etapa de treinamento consistiram na definição dos pesos sinápticos iniciais utilizados nos dois mapas de Kohonen, e na definição da quantidade de épocas de treinamento. Após realizar várias tentativas de treinamento, alterando-se empiricamente estes parâmetros, encontrou-se o melhor resultado para a inicialização dos

pesos com o valor zero, e com a utilização de duzentas épocas de treinamento. Por conseguinte, foram sob estas condições que os dois mapas foram treinados a fim de realizar a classificação dos sinais modulados e a sua demodulação neste trabalho.

Numero de Símbolos da modulação	M	2
Frequência da portadora	fp	216 Mhz
Tempo de Símbolo	tsim	30 entradas
Frequência das faixas laterais	df	-5 Khz e +5 Khz
Diferença de fase	fa	-pi/2 e pi/2
Vetor de Símbolos	x1	20 símbolos binários aleatórios
Matriz 30X20	S	600 amostras
Vetor linha 1X600	Sinal	600 amostras
Vetor linha 1X600	Sinal_AWGN	600 amostras

Quadro 4.1: Síntese dos dados utilizados na geração dos sinais modulados.

4.2 REDES AUTO-ORGANIZÁVEIS

É importante falar da rede MLP, não só pelo fato de querer dar ao texto uma ideia temporal da evolução das RNAs, mas também, com o propósito de apresentar um modelo de RNA que utiliza o aprendizado supervisionado, ou seja, um paradigma diferente do das redes auto-organizáveis. Além disso, a rede MLP apresenta a necessidade de um tempo de treinamento longo para muitas aplicações práticas, pretende-se verificar se nas simulações realizadas com as redes ART e de Kohonen, as redes passaram a operar satisfatoriamente assim como a MLP, de acordo com o artigo Horewicz, Nascimento Jr e Parrela (2008).

As redes auto-organizáveis são mais interessantes em situações práticas mais próximas do mundo real, onde não existe um supervisor gerenciando o aprendizado, como no caso das redes MLPs, onde o aprendizado é supervisionado. Como supracitado, dois tipos de redes auto-organizáveis foram escolhidas: SOM de Kohonen e ART, que utilizam algoritmos de aprendizado competitivo e não supervisionado.

A rede ART foi desenvolvida buscando-se resolver o problema da estabilidade vs plasticidade, ou seja, a rede não precisa recomeçar o seu treinamento do erro a cada instante em que houver alterações nos padrões apresentados na entrada, mantendo o conhecimento que já foi previamente adquirido.

4.3 REDE AUTO-ORGANIZÁVEL DO TIPO SOM (MAPAS DE KOHONEN)

Segundo Kohonen (1990, p. 1 a 3), os mapas auto-organizáveis têm o propósito de ser uma alternativa viável às arquiteturas de RNAs mais tradicionais. O resultado alcançado com o aprendizado é bastante natural, ao menos indicando que o processo adaptativo no mapa pode ser similar ao encontrado no cérebro. Por este motivo, é suficientemente justificável chamar estes mapas de RNA da mesma maneira que as redes tradicionais. A segmentação espacial de diferentes respostas e sua organização dentro da topologia dá um alto grau de competência em operações típicas de redes neurais artificiais. Sendo apropriado observar que estes mapas são usados no reconhecimento de padrões. Sendo as suas principais diferenças em relação a outros modelos de RNAs:

- 1- Maior ênfase no processamento distribuído da rede SOM;e
- 2- Como segundo aspecto, somente considerar a disposição espacial das unidades de processamento.

Para Kohonen (1990, p3), os mapas auto-organizáveis possuem um potencial intrínseco no seu processo de auto-organização para criar uma estrutura organizada de

grupos, sendo esta a base do modelo. Os mapas graças a sua estrutura altamente distribuída e seu processo adaptativo tem grande capacidade de reconhecimento de padrões complexos.

Segundo Kohonen (1990, p.3), os mapas podem ser utilizados colaborativamente com outras RNAs e pode-se também trabalhar com vários mapas em conjunto, formando uma estrutura mais complexa de rede SOM. O presente trabalho utiliza esta capacidade colaborativa da rede SOM com uma estrutura de múltiplos mapas SOM, sendo utilizado um mapa de Kohonen para cada tipo de modulação que se pretende classificar.

De acordo com Kohonen (1990, p.3), as suas expectativas pessoais do potencial industrial das redes SOM estão depositadas nas áreas de controle de processos, e telecomunicações. Por conseguinte, este trabalho pretende explorar o grande potencial inato dos mapas auto-organizáveis na área de telecomunicações, realizando a classificação e demodulação de sinais digitais. Buscando realizar este processo baseando-se nos padrões apresentados pelos sinais modulados, visto que, cada tipo de modulação possui uma constelação que lhe é própria, possibilitando, desta forma, sua distinção de outros tipos de modulação.

Este trabalho se propõe a efetuar a comparação entre duas redes neurais artificiais que utilizam os mapas auto-organizáveis, a RNA do tipo SOM de Kohonen e a rede ART, mas especificamente a rede ART-2A[Segundo Carpenter, Grosserg e Rosen (1991, p. 1), realiza o reconhecimento auto-organizável de sequências arbitrárias apresentadas na sua entrada, sejam sinais binários ou analógicos, de uma maneira mais rápida que a rede ART-2], no processo de reconhecimento automático de modulação e concomitantemente efetuar a demodulação do sinal de rádio.

Os dados utilizados relativos à rede ART são os mesmos utilizados na elaboração do artigo Reconhecimento Automático de Modulação Digital e Demodulação de sinais baseado em Redes Neurais Artificiais, escrito pelo autor desse trabalho em parceria com: Yona Lopes, David Acosta e Fidel Souza; e orientados pelos professores João Marcos Silva e José Panaro (LOPES et al, 2012).

Começaremos a abordagem sobre a simulação com a rede auto-organizável do tipo SOM de Kohonen. Para efetuar a geração do sinal modulado e ruidoso foi utilizado o

programa Matlab, após isto, o sinal gerado é carregado em outra rotina para a sua normalização, treinamento e classificação. Está sendo utilizada uma normalização simples, ao invés de cálculos mais complexos com FFT ou a transformada de Wavelet.

Conforme afirma Haykin (2008, p.485), o modelo introduzido por Kohonen não pretende explicar detalhes neurobiológicos, mas captura as características essenciais dos mapas computacionais do cérebro humano e ainda desta forma, se mantém tratável do ponto de vista computacional.

Na figura 4.5 é apresentada a estrutura do trabalho, desde a criação do sinal modulado, até a sua demodulação.

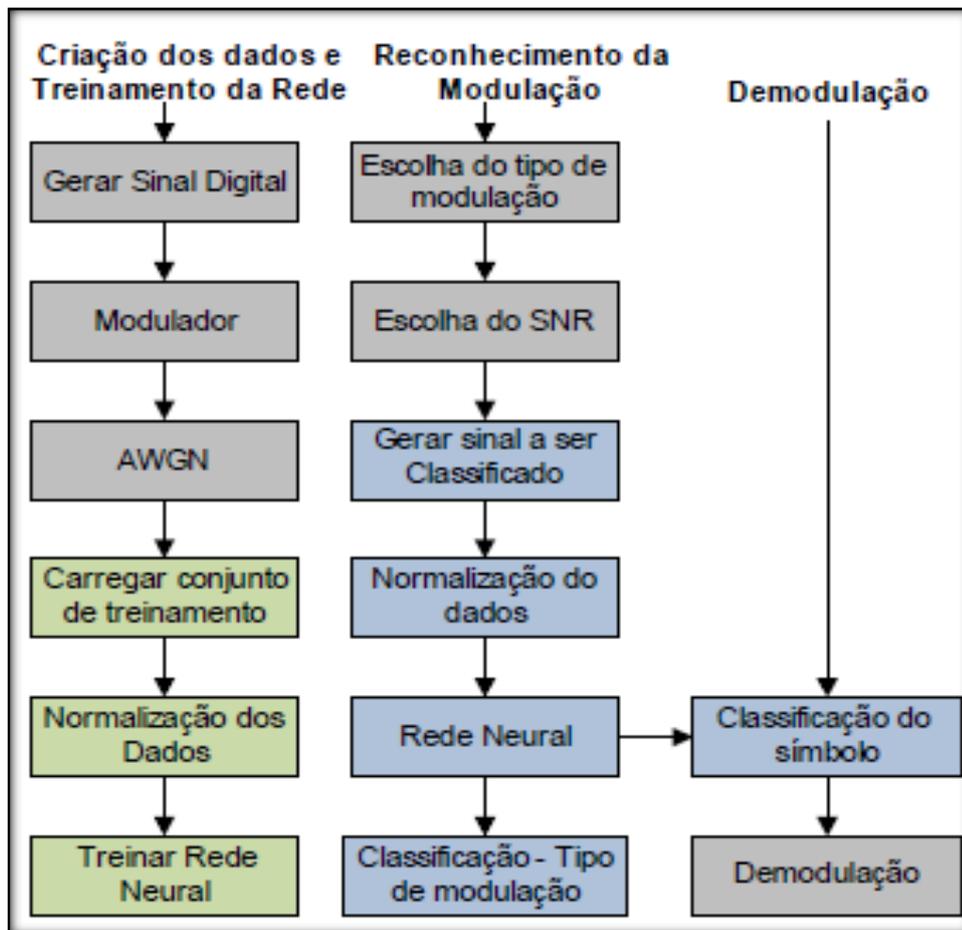


Figura 4.5- Estrutura da rede SOM utilizada na demodulação de sinais 2FSK e BPSK.

As redes M-SOM apresentam a topologia abaixo descrita na figura número 4.6.

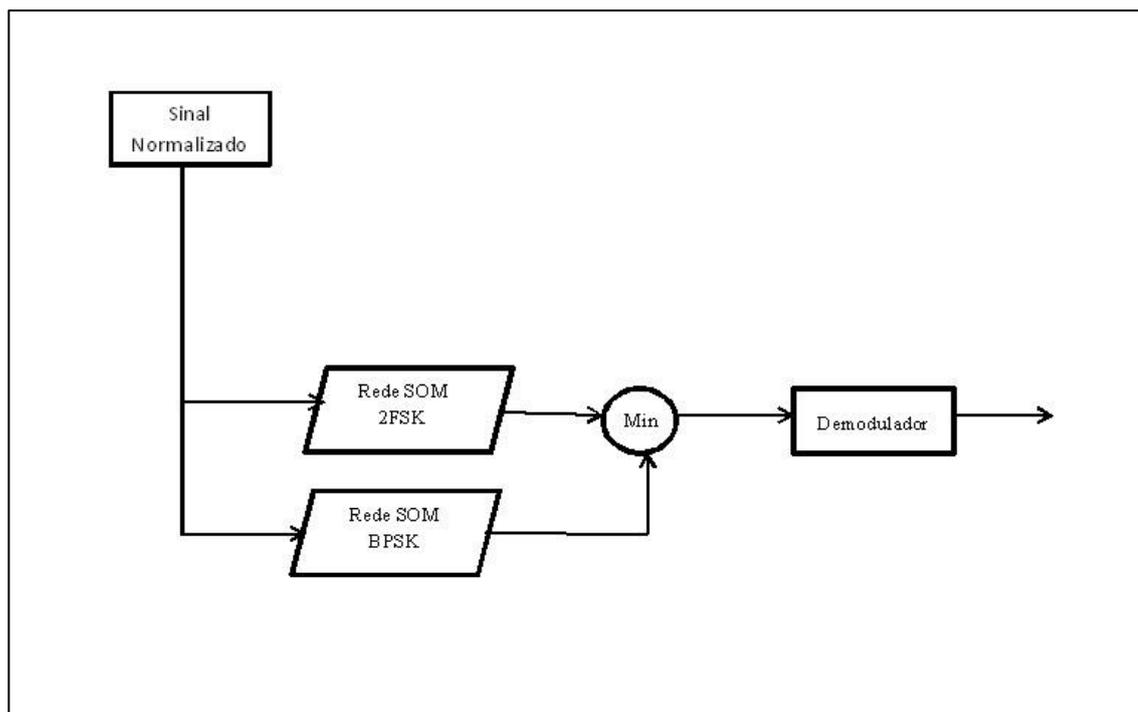


Figura 4.6 - Estrutura da rede SOM criada para classificação e demodulação.

Na entrada da RNA foram gerados sinais aleatórios para o treinamento da rede neural artificial. Foram criados 20 símbolos por sinal, com 30 amostras por símbolo com um SNR de 20 dB. Resultando em uma matriz de 30x20 para cada sinal gerado, sendo gerados 10 sinais.

4.3.1 Pré-processamento

Neste trabalho, para nenhuma das redes utilizadas (Kohonen e ART), foi empregada uma técnica de codificação de canal. Sendo os vetores dos sinais pré-processados antes de serem utilizados nas etapas de treinamento e de teste das redes neurais artificiais através de uma normalização.

Segundo Lopes et al (2012, p. 2), a normalização permite que valores diferentes possam ser comparados, sendo colocados em uma escala comum e em uma mesma faixa de valores para que possam ser comparados e analisados em conjunto. Normalizam-se as amostras para evitar que uma dimensão se sobressaia a outras e evitar que o aprendizado

fique estagnado. Este pré-processamento pode aperfeiçoar o treinamento das RNAs e melhorar com isto, a identificação de padrões.

Antes de apresentar os dados de entrada à RNA é necessário normalizar as amostras de entrada. A normalização dos sinais gerados é realizada usando-se a expressão a seguir. Para cada sinal são normalizados cada símbolo (vetor) independentemente.

$$R[K] = \frac{N*r[k]}{\sqrt{(\sum_{n=1}^N r[n]^2)}} \quad (4.1)$$

Onde $k=1,2,3\dots$

E, N o número total de amostras do sinal (vetor a ser normalizado).

Foram criadas duas redes neurais com camadas de saída na forma de grade, contendo 18x18 neurônios cada, a fim de reproduzir a estrutura proposta no artigo Zhou et al (2011, p.3), com topologia “hextop” e raio dos vizinhos igual a um. De 1 a 162 é representado no mapa o símbolo 1, e de 163 a 324 o símbolo 0. Já os pesos das redes neurais artificiais foram iniciados com zero.

O neurônio 260 foi selecionado arbitrariamente como peso inicial da classe 0 e o neurônio 27 como peso inicial da classe 1. Estes pesos iniciais correspondem aos carregados que definem os símbolos sem ruído dos sinais. Busca-se que estes neurônios e seus vizinhos imediatos sejam quem definam cada classe (símbolo) para cada SOM (BPSK e 2-FSK) treinada.

Após isto foi realizado o treinamento da rede SOM FSK, assim como seu mapeamento para as classes. Na figura 4.7 podemos observar a disposição topológica das classes e quais os neurônios do mapa foram treinados.

Sendo todo este procedimento repetido para a criação da rede SOM BPSK. Foi realizado o treinamento da rede SOM BPSK, assim como seu mapeamento para as classes. Na figura 4.8 podemos observar a disposição topológica das classes e quais os neurônios do mapa foram treinados.

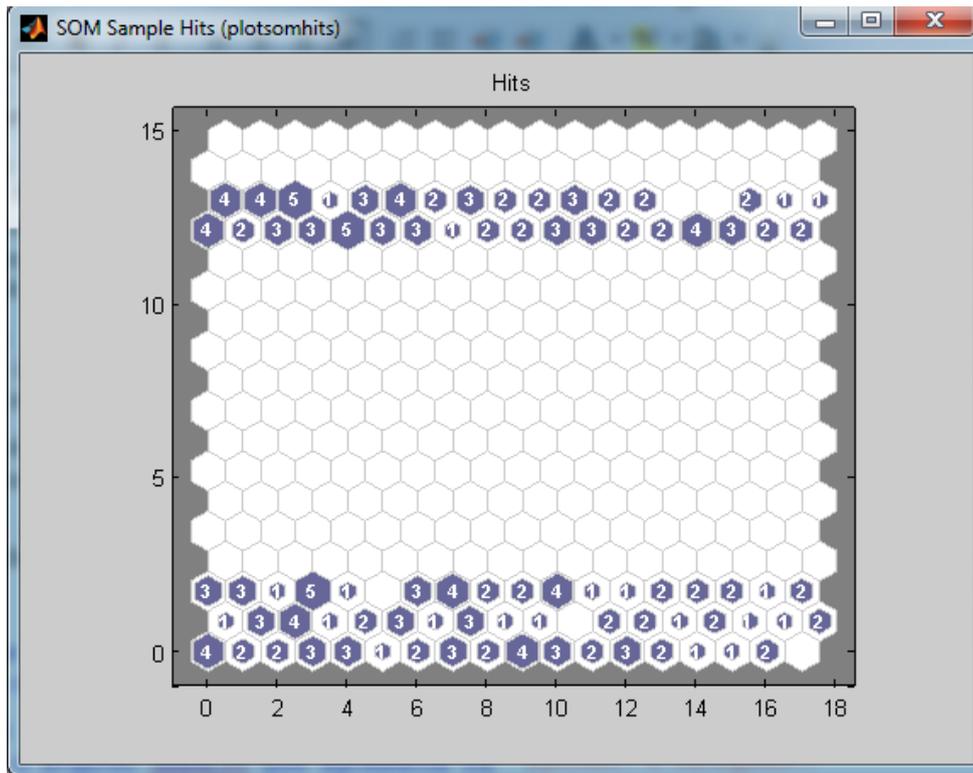


Figura 4.7: Exemplo do mapeamento da rede SOM FSK.

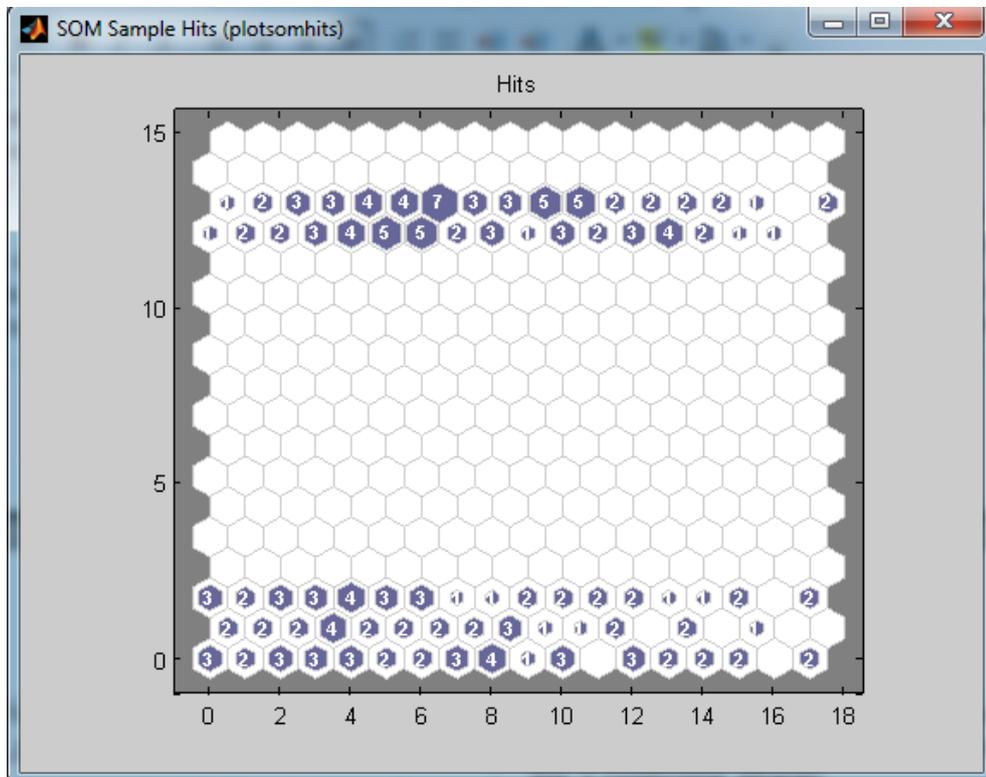


Figura 4.8: Exemplo do mapeamento da rede SOM BPSK.

Faz-se o treinamento apresentando os sinais 2FSK para a respectiva rede 2FSK. E age-se da mesma forma com a rede BPSK. No processo de reconhecimento automático de modulação é explorada a habilidade de agrupar existente entre os mapas de cada rede. Já no processo de demodulação é explorada a capacidade de agrupar dentro de cada rede.

4.3.2 Processo de reconhecimento automático de modulação

Cada uma das redes é treinada individualmente. Depois de treinadas, o sistema pode ser testado. A rede em paralelo que vencer a maioria das vezes nos testes é a que define o tipo de modulação. Se a rede vencedora for a rede BPSK, então, o tipo de modulação é o BPSK. São usados 20 símbolos e 30 amostras por símbolo.

4.3.3 Processo de Demodulação

Durante o treinamento em separado de cada rede do tipo SOM, os neurônios são rotulados com o seu símbolo correspondente a 0 ou 1. Na modulação digital, cada símbolo é representado por um bit (0 ou 1) para o caso de 2FSK e BPSK. Após a criação do sinal, modulação e adição de ruído obtêm-se a entrada da rede. A figura 4.9 apresenta como é feita a rotulagem da rede.

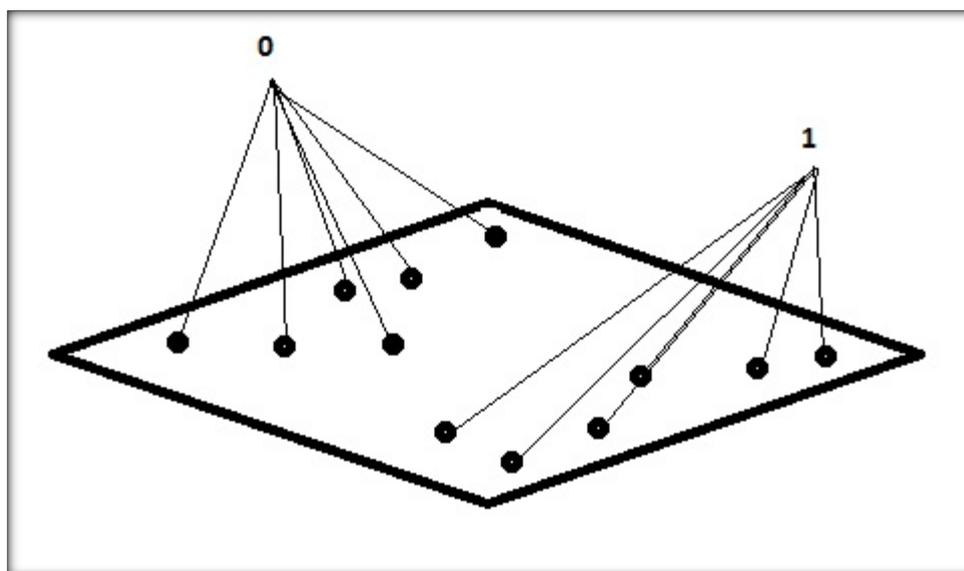


Figura 4.9 - Rotulagem da rede SOM para demodulação.

O resultado obtido na simulação um, com o processo de demodulação da RNA do tipo SOM de Kohonen pode ser constatado na tabela número 4.1 e no gráfico número 4.1 respectivamente. Nesta rede, o treinamento é feito com sinais apresentados à sua entrada com ruídos inseridos com uma relação sinal-ruído de 20 dB (cenário 1 de treinamento da rede). Pode-se verificar que a rede obteve um resultado satisfatório para os dois tipos de modulação apresentados para os diversos níveis de SNR, a partir de 5 dB.

Quanto ao reconhecimento automático dos dois tipos de modulações testados com a rede neural, obteve-se um desempenho semelhante ao apresentado no artigo Zhou et al (2011, p.1 a 5), para as modulações BPSK e 2FSK, conseguindo-se 100% de acerto no processo de classificação dos sinais modulados em todas as faixas de SNR, 0 dB, 5 dB, 10 dB, 15 dB e 20 dB.

Tabela 4.1: Percentual de erro na demodulação 2FSK e BPSK com a SNR para o primeiro cenário de treinamento da rede SOM.

SNR		0 dB	5 dB	10 dB	15 dB	20 dB
PERCENTUAL DE ERRO	BPSK	9%	6%	6,5%	4,5%	6%
	2FSK	20%	7,5%	4,5%	5,5%	3%

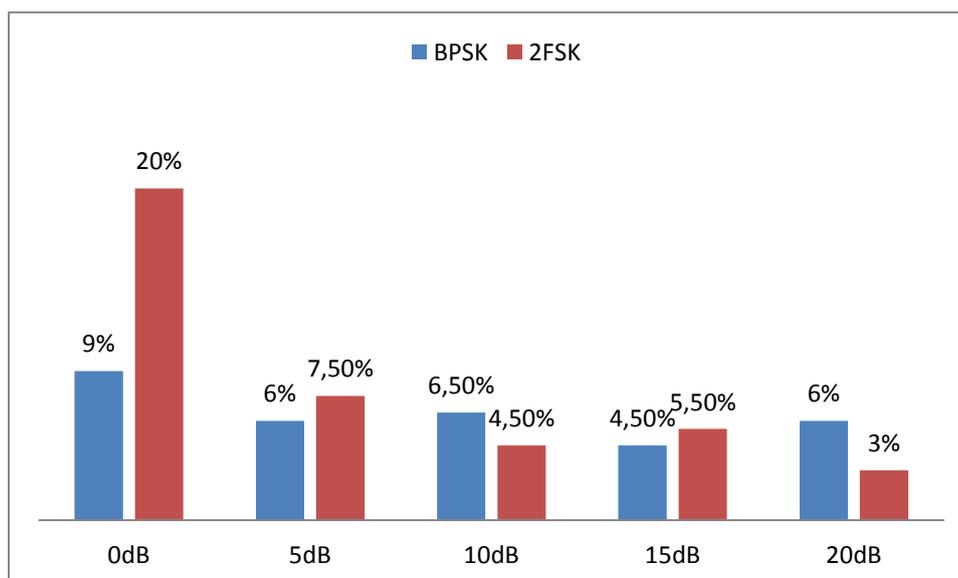


Gráfico 4.1: Percentual de erro na demodulação FSK e BPSK com relação à SNR para primeiro cenário de treinamento da rede SOM.

Como resultado obtido na simulação dois, com o processo de demodulação da RNA do tipo SOM de Kohonen, (para o treinamento feito com sinais apresentados à sua entrada com ruídos inseridos com diversas relações sinal-ruído, cenário 2 de treinamento), pode-se verificar que a rede obteve um resultado satisfatório para os dois tipos de modulação apresentados para os diversos níveis de SNR, a partir de 5db; porém, comparativamente com o cenário de treinamento anterior, obteve-se 100% de acerto na demodulação dos sinais para os dois tipos de demodulação a partir de níveis de SNR de 10 dB. Pode-se averiguar isto, na tabela número 4.2 e no gráfico número 4.2 respectivamente. Com isto, conclui-se que realizar o treinamento da rede com sinais de entrada contendo diversos níveis de SNR propicia uma melhoria no aprendizado da rede neural artificial, habilitando-a a realizar uma demodulação dos sinais com mais perícia.

Quanto ao reconhecimento automático dos dois tipos de modulações testados com a rede neural, obteve-se um desempenho idêntico ao apresentado no artigo Zhou et al (2011, p.1 a 5), e ao apresentado no cenário um supracitado, para as modulações BPSK e 2FSK, conseguindo-se 100% de acerto no processo de classificação dos sinais modulados em todas as faixas de SNR, 0 dB, 5 dB, 10 dB, 15 dB e 20 dB.

Tabela 4.2: Percentual de erro na demodulação 2FSK e BPSK com a SNR para o segundo cenário de treinamento da rede SOM.

SNR		0 dB	5 dB	10 dB	15 Db	20 dB
PERCENTUAL DE ERRO	BPSK	20%	6%	0%	0%	0%
	2FSK	21%	7,5%	0%	0%	0%

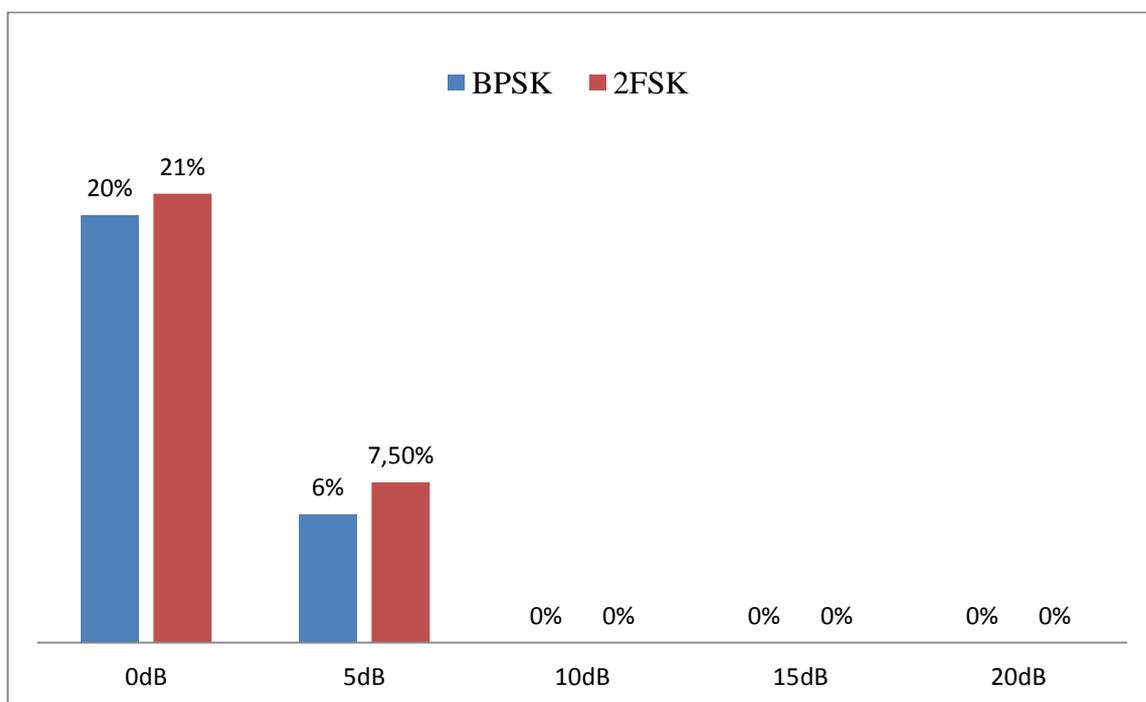


Gráfico 4.2: Percentual de erro na demodulação FSK e BPSK com relação à SNR para o segundo cenário de treinamento da rede SOM.

Simulação três: no artigo Zhou et al (2011, p.1 a 5), a métrica utilizada como medida de dissimilaridade no processo de criação de agrupamentos (*clusters*) pelos mapas de Kohonen da rede M-SOM foi a distância Euclidiana. A fim de testar outra medida de dissimilaridade, foi realizada uma nova simulação utilizando a métrica *Manhattan* em substituição da distância Euclidiana, e com a rede treinada cenário 2, onde a rede M-SOM é

treinada com sinais corrompidos com diversos níveis de SNR, pois, como supracitado, propiciou uma rede com melhor desempenho que a treinada com o cenário 1.

O resultado obtido pode ser observado na tabela número 4.3 e no gráfico número 4.3. Efetuando uma comparação com os resultados conseguidos com a simulação dois, que utilizou o cenário 2 de treinamento da rede e a distância Euclidiana como medida de dissimilaridade, concluiu-se que a rede apresenta melhores resultados com a distância Euclidiana do que com a métrica *Manhattan*.

Tabela 4.3: Percentual de erro nas demodulações de sinais 2FSK e BPSK com a SNR para o segundo cenário de treinamento da rede SOM e com uso da métrica *Manhattan*.

SNR		0 dB	5 dB	10 dB	15 dB	20 dB
PERCENTUAL DE ERRO	BPSK	12%	8%	4,5%	2%	1,5%
	2FSK	19%	1,5%	3,5%	4,5%	3,5%

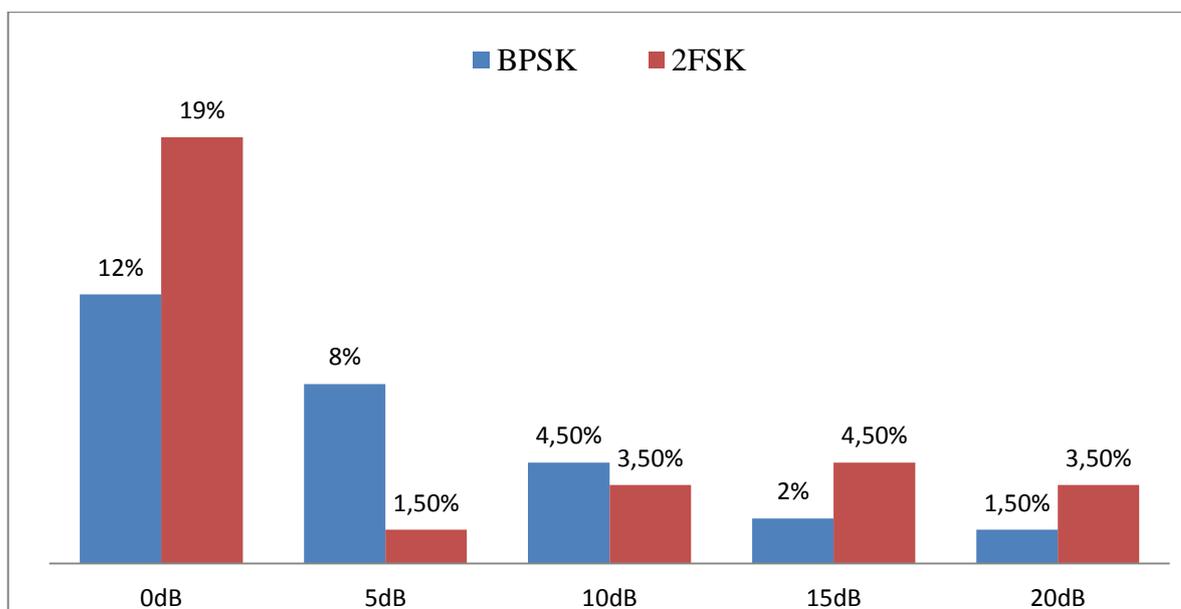


Gráfico 4.3: Percentual de erro na demodulação de sinais FSK e BPSK com relação à SNR, para o segundo cenário de treinamento da rede SOM e com o uso da métrica *Manhattan*.

Nas figuras 4.10 e 4.11 são apresentados os gráficos gerados no Matlab respectivamente para os testes com as modulações 2FSK e BPSK, durante todo o processo da geração do sinal de entrada até a demodulação. Foram gerados com o comando subplot; e podemos ver abaixo, o sinal de entrada, o sinal de entrada modulado, o sinal de ruído AWGN introduzido no sinal modulado e finalmente, o sinal demodulado pela RNA.

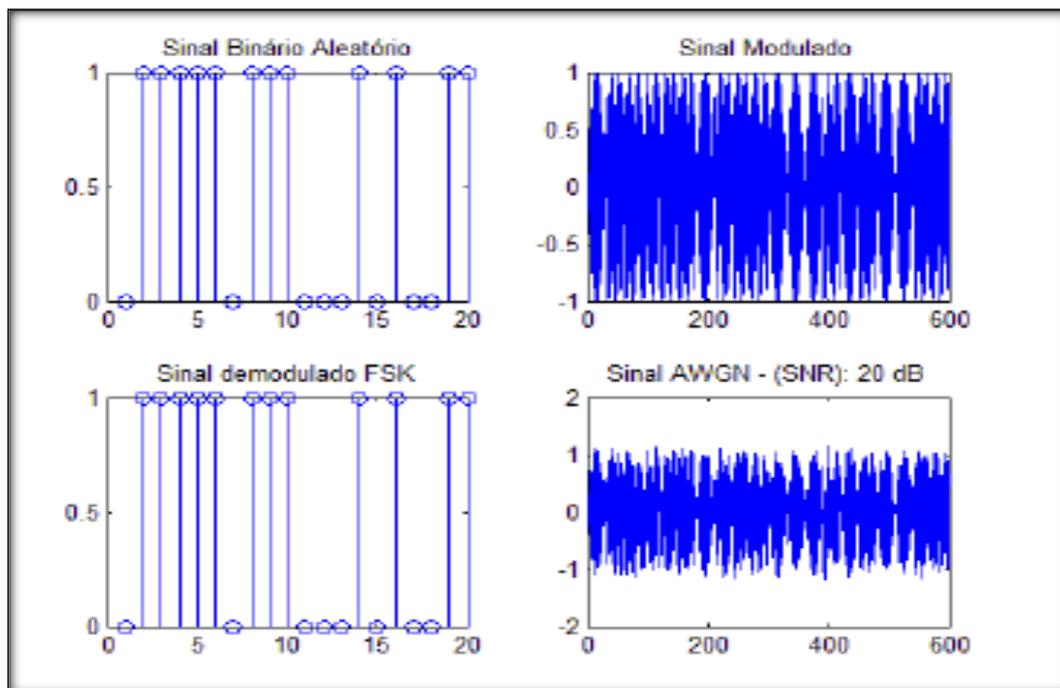


Figura 4.10 - Sinais do processo de demodulação 2FSK.

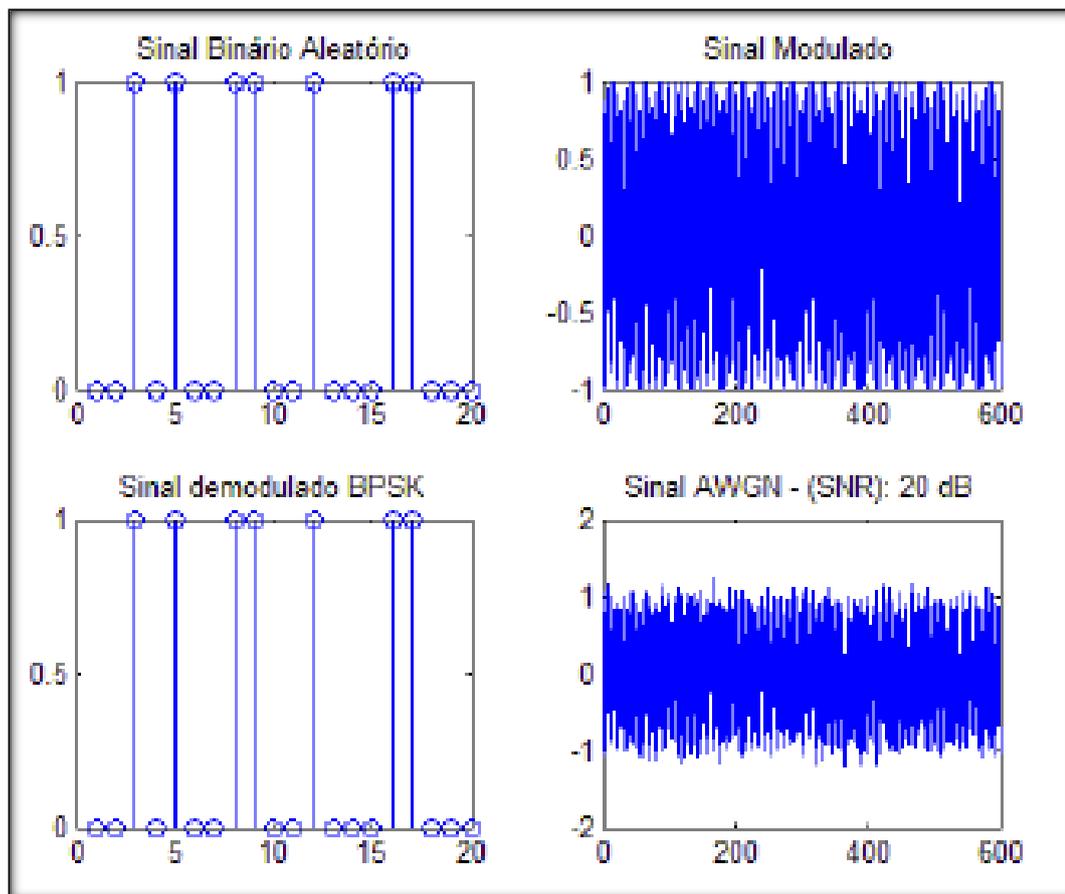


Figura 4.11 - Sinais do processo de demodulação BPSK.

4.4 REDE ART

A topologia utilizada na rede ART-2A desenvolvida na pesquisa é apresentada na figura 4.12. O sistema é semelhante ao da rede SOM apresentada anteriormente, sendo a diferença que são utilizadas redes ART ao invés de mapas de Kohonen.

Conforme Carpenter, Grossberg e Rosen (1990, p.1), a rede ART-2 processa entradas e saídas analógicas ou digitais. A rede ART-2A opera de forma análoga, porém ela é utilizada em detrimento da ART-2, pois, ela é de duas ou três vezes mais rápida em simulações em computadores convencionais, assim, tornando-a mais fácil de usar para resolver grandes problemas. O desempenho superior se deve ao algoritmo que possui implementações paralelas mais eficientes.

4.4.1 Reconhecimento automático de demodulação e demodulação usando a rede ART.

Segundo Lopes et al (2012, p.3), dependendo dos vetores apresentados na entrada de uma rede ART, esta vai ativando ou alterando os seus neurônios durante o seu treinamento. Como se busca classificar símbolos, e que entre as modulações analisadas pode haver símbolos semelhantes, é criada uma rede ART para cada tipo de modulação, permitindo assim diferenciar individualmente cada símbolo em cada tipo de modulação. Neste trabalho, são criadas 3 redes ART (figura 4.12) que são treinadas independentemente com seus respectivos símbolos. Estas redes são usadas posteriormente no processo de classificação, apresentando os símbolos do sinal a ser identificado. Cada uma das redes neurais tem um neurônio vencedor, este é comparado com os vencedores das outras duas redes, para finalmente decidir qual é o vencedor definitivo que representará o tipo de modulação desse símbolo.

De acordo com Lopes et al (2012, p.3), para preparar o processo de demodulação dos sinais, uma espécie de treinamento supervisionado é realizado. Como os valores dos símbolos "0" ou "1", ou "2" e "3" quando usado 4PSK, são conhecidos no treinamento, estes são usados para definir os pesos iniciais dos neurônios e para estimar o valor do parâmetro de vigilância que permita a menor ativação de neurônios possível em cada rede. Desta maneira, cada rede tem rotulados seus neurônios dependendo do símbolo. Durante a etapa de classificação, o neurônio ativado leva a etiqueta do símbolo ao qual corresponde, permitindo assim que depois de identificado o tipo de modulação, se obtenha o símbolo.

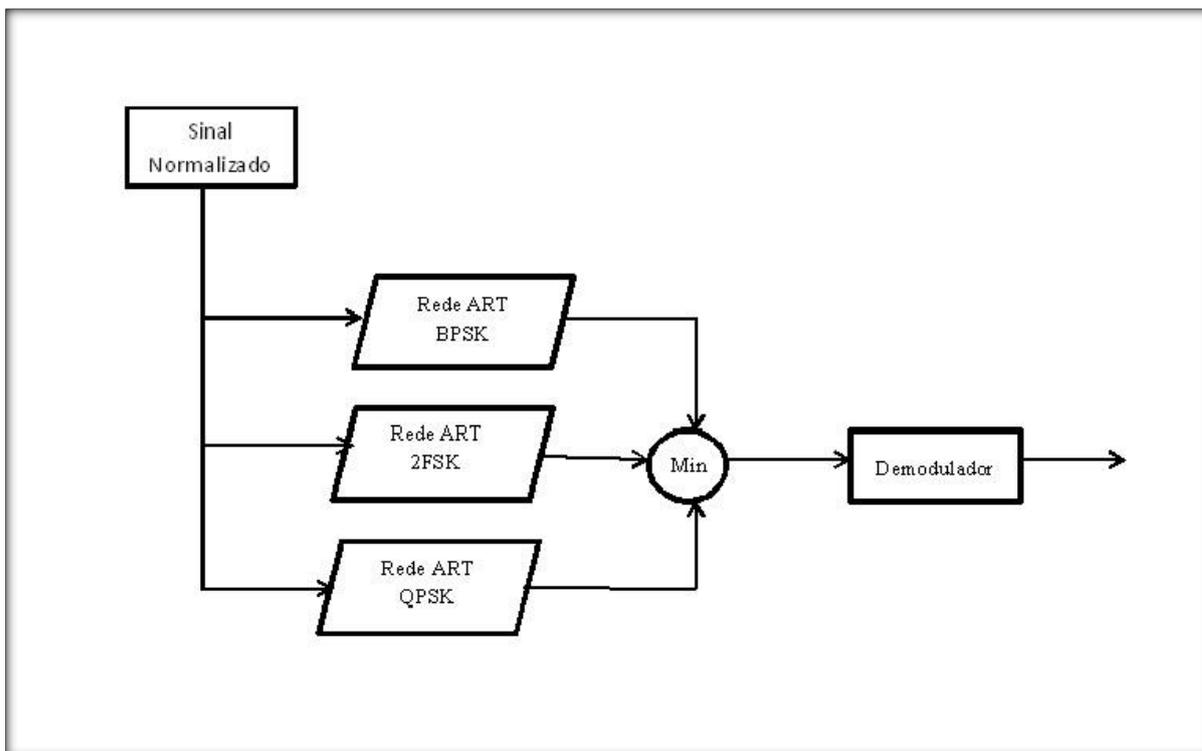


Figura 4.12- Estrutura da rede ART criada para classificação e demodulação.

4.4.1.1 Fase de treinamento

Conforme afirmado por Lopes et al (2012, p.3), a rede ART utiliza um algoritmo de aprendizado competitivo, onde os neurônios da sua camada de saída competem entre si para se tornarem ativos (para ver quem gera a menor distância ao vetor de entrada). Desta forma, para cada padrão de entrada apenas um neurônio de saída ou neurônio por grupo se torna ativo. Esta competição é chamada de: o vencedor leva tudo (*winner-takes-all*).

No processo de treinamento do sistema proposto, uma rede ART simplificada foi treinada independentemente para cada tipo de modulação, apresentando a cada rede unicamente os símbolos correspondentes à modulação. O processo de treinamento de cada rede ART segue as seguintes etapas da rotina abaixo:

1. Inicializar.

Definem-se os pesos iniciais com a média aritmética para cada tipo de símbolo. Estabelece-se o parâmetro de vigilância.

2. Apresentar entrada.

Apresenta-se um símbolo do banco de símbolos correspondente ao tipo de modulação. O símbolo é normalizado previamente.

3. Calcular a distância.

Calcula-se a distância entre o vetor apresentado e os pesos existentes na rede. Dependendo da norma ponderada selecionada é usada a equação para *Manhattan* ou a equação para a distância Euclidiana.

4. Selecionar o neurônio vencedor

É escolhido o neurônio vencedor de acordo com a menor distância encontrada. Se o "neurônio" vencedor é o de vigiância, será ativado um novo neurônio com os valores do vetor de entrada.

5. Atualizar pesos.

É usada equação abaixo para atualizar os pesos do neurônio vencedor. Os outros neurônios manterão seus pesos.

$$w_i(n + 1) = w_i(n) + \alpha[x(n) - w_i(n)]$$

6. Repetir.

Continuar apresentando os vetores de entrada (símbolos) enquanto estejam pendentes.

7. Finalizar.

Repetir o processo para o número de iterações estabelecido (para o número de épocas estabelecido).

4.4.1.2 Fase de classificação.

Nesta fase o sinal apresentado ao sistema é dividido em seus símbolos e estes são passados pelas três redes treinadas. Cada uma delas vai entregar o número do neurônio

vencedor e sua distância calculada. É selecionada a menor das três distâncias a qual é usada para definir o tipo de modulação. Finalmente, depois de fazer o mesmo processo para todos os símbolos do sinal, é realizada a demodulação de acordo com o maior número de símbolos classificados e é usada a etiqueta do neurônio ativado para obter o tipo de símbolo correspondente à modulação do sinal (LOPES ET AL, 2012, p.3).

4.4.1.3 resultados obtidos com as simulações da rede ART.

Na simulação quatro é utilizada a métrica Euclidiana para se gerar os agrupamentos de classificação, ou *clusters*.

O resultado obtido com o processo de demodulação da RNA do tipo ART pode ser constatado na tabela número 4.4 e no gráfico número 4.4 respectivamente. Nesta rede, o treinamento é feito com sinais apresentados à sua entrada com ruídos inseridos com relações de sinal-ruído diversas, da mesma forma que para o cenário 2 utilizado com a rede tipo SOM de Kohonen. Pode-se verificar que a rede obteve um resultado satisfatório para os três tipos de modulações apresentados para os diversos níveis de SNR a partir de 5 dB. Tendo um desempenho semelhante ao da rede SOM, e sendo capaz de classificar e demodular os sinais modulados em QPSK.

Quanto ao reconhecimento automático dos três tipos de modulações testados com a rede neural ART, obteve-se um desempenho idêntico ao apresentado no artigo Zhou et al (2011, p.5), para as modulações BPSK e 2FSK, conseguindo-se 100% de acerto no processo de classificação dos sinais modulados em todas as faixas de SNR, 0 dB, 5 dB, 10 dB, 15 dB e 20 dB. Porém teve um desempenho superior para a modulação QPSK em comparação ao que apresentado no artigo supracitado, pois, obteve 100% de acerto na classificação desta modulação, para todas as faixas de SNR, enquanto que no artigo, para os níveis de SNR de 0 dB foi obtido 99% de acerto e para SNR de 20 dB foi obtido 98% de acerto na classificação dos sinais.

Tabela 4.4: Percentual de erro na demodulação 2FSK, BPSK e QPSK com a SNR para a rede ART, utilizando a métrica Euclidiana.

SNR		0 dB	5 dB	10 dB	15 dB	20 dB
PERCENTUAL DE ERRO	BPSK	19%	1,15%	0%	0%	0%
	2FSK	21,04%	1,56%	0%	0%	0%
	QPSK	19,07%	2,41%	0,01%	0%	0%

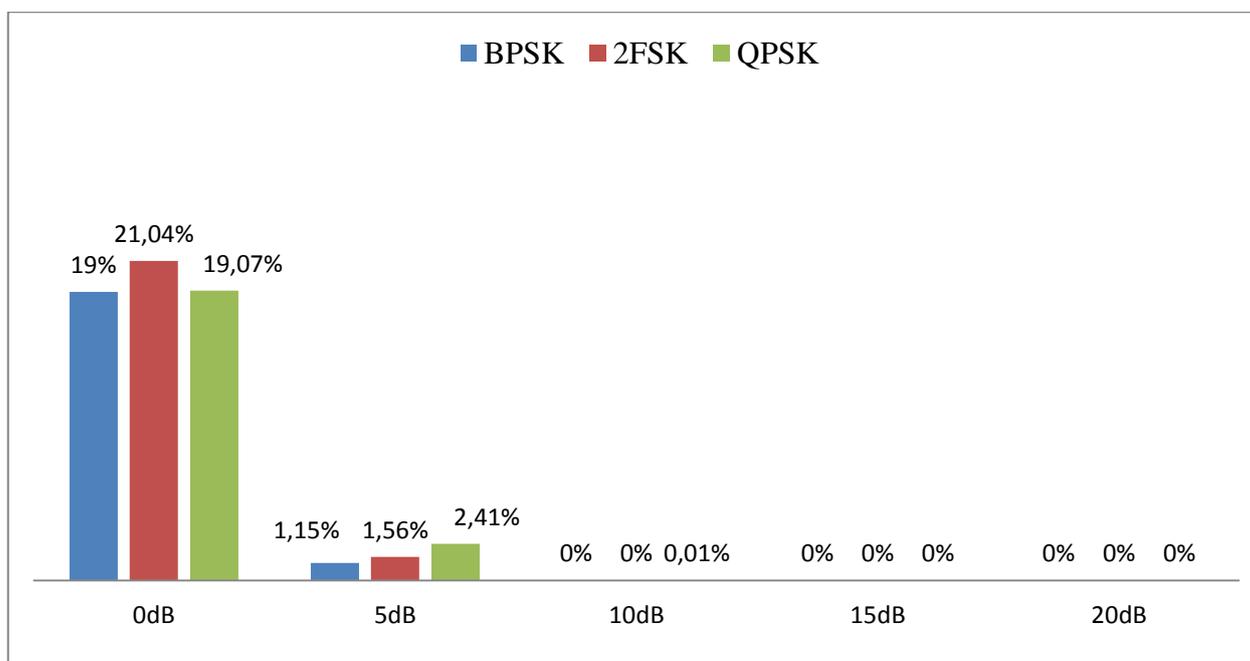


Gráfico 4.4: Percentual de erro na demodulação 2FSK, BPSK e QPSK com relação à SNR para a rede ART, utilizando a métrica Euclidiana.

Na simulação cinco é utilizada a norma *Manhattan* como métrica de dissimilaridade para se gerar os agrupamentos de classificação, ou *clusters*.

O resultado obtido com o processo de demodulação da RNA do tipo ART pode ser constatado na tabela número 4.5 e no gráfico número 4.5 respectivamente. Nesta rede, o

treinamento é feito com sinais apresentados à sua entrada com ruídos inseridos com relações sinal-ruído diversas, da mesma forma que para o cenário 2 utilizado com a rede tipo SOM de Kohonen. Pode-se verificar que a rede obteve um resultado satisfatório para os três tipos de modulações apresentados para os diversos níveis de SNR, a partir de 5 dB. Tendo um desempenho semelhante ao da rede SOM e sendo capaz de classificar e demodular os sinais modulados em QPSK.

Quanto ao reconhecimento automático dos três tipos de modulações testados com a rede neural ART, obteve-se um desempenho idêntico ao apresentado no artigo Zhou et al (2011, p.5), para as modulações BPSK e 2FSK, conseguindo-se 100% de acerto no processo de classificação dos sinais modulados em todas as faixas de SNR, 0 dB, 5 dB, 10 dB, 15 dB e 20 dB. No entanto, apresentou um desempenho superior para a modulação QPSK em comparação ao que foi apresentado no artigo supracitado, pois, obteve 100% de acerto na sua classificação, para todas as faixas de SNR, enquanto que no artigo, para os níveis de SNR de 0 dB foi obtido 99% de acerto e para SNR de 20 dB foi obtido 98% de acerto na classificação dos sinais.

Tabela 4.5: Percentual de erro na demodulação 2FSK , BPSK e QPSK com a SNR para a rede ART, utilizando a métrica *Manhattan*.

SNR		0 dB	5 dB	10 dB	15 dB	20 dB
PERCENTUAL DE ERRO	BPSK	29,13%	3,36%	0%	0%	0%
	2FSK	30,84%	4,84%	0,02%	0%	0%
	QPSK	24,69%	6,15%	0,08%	0%	0%

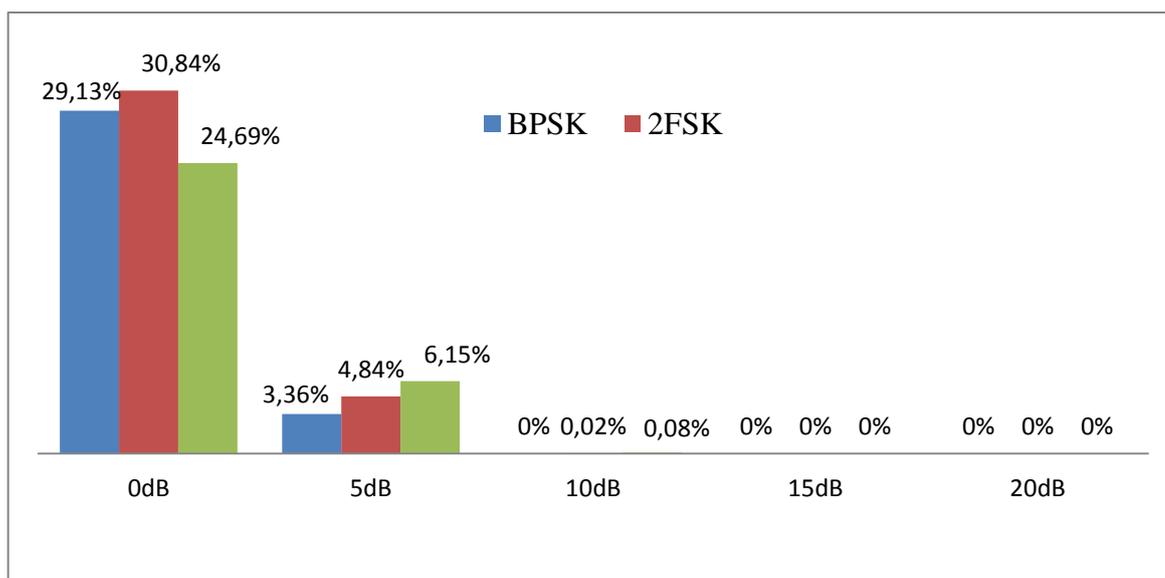


Gráfico 4.5: Percentual de erro na demodulação 2FSK, BPSK e QPSK com relação à SNR para a rede ART, utilizando a métrica *Manhattan*.

Comparando os resultados obtidos com as duas métricas testadas, verificou-se que a distância Euclidiana propicia um melhor desempenho às duas redes neurais artificiais estudadas, a do tipo M-ART e a rede M-SOM conseguindo um maior percentual de acerto na demodulação dos sinais apresentados à RNA.

4.5 COMPARAÇÃO DOS RESULTADOS OBTIDOS COM AS RNAS.

A tabela abaixo apresenta uma comparação, no que concerne à identificação dos sinais modulados, entre os resultados obtidos com as RNAs auto-organizáveis e com aprendizado competitivo e não supervisionado estudadas e com o resultado apresentado no artigo Horewicz, Nascimento Jr e Parrela (2008, p.5) para redes do tipo MLP que possuem um paradigma de aprendizado diferente (aprendizado supervisionado).

Foram utilizados para as redes do tipo SOM de Kohonen e do tipo ART os dados da simulação que obteve um melhor desempenho, com medida de dissimilaridade distância Euclidiana e treinamento com amostras contaminadas com ruído com vários níveis de SNR.

Podemos observar na tabela 4.6 que as redes ART e SOM obtiveram um desempenho igual entre si, conseguindo classificar as modulações BPSK e 2FSK com 100% de acerto

para todos os níveis de SNR presente nos sinais. Tendo um desempenho superior ao da rede MLP para todas as faixas de SNR analisadas.

Tabela 4.6: Comparação do desempenho das redes no processo de classificação da modulação para BPSK e 2FSK.

SNR	0 dB	5 dB	10 dB	15 dB	20 dB
MLP	-	0%	>96%	>98%	>98%
SOM	100%	100%	100%	100%	100%
ART	100%	100%	100%	100%	100%

Já a tabela 4.7 apresenta o desempenho das redes ART e SOM para o processo de demodulação dos sinais BPSK e 2FSK.

Foram utilizados para as redes do tipo SOM de Kohonen e do tipo ART os dados da simulação que obteve um melhor desempenho, com medida de dissimilaridade distância Euclidiana e treinamento com amostras contaminadas com ruído com vários níveis de SNR.

Podemos observar que o desempenho das duas redes é bastante semelhante com um desempenho ligeiramente superior para a rede ART para a faixa de 5 dB de SNR para as duas modulações analisadas.

Tabela 4.7: Comparação do desempenho das redes no processo de demodulação dos sinais.

	SNR	0 dB	5 dB	10 dB	15 dB	20 dB
BPSK	SOM	20%	6%	0%	0%	0%
	ART	19%	1,15%	0%	0%	0%
2FSK	SOM	21%	7,5%	0%	0%	0%
	ART	21,4%	1,56%	0%	0%	0%

4.6 COMPARAÇÃO DOS RESULTADOS OBTIDOS PELA REDE SOM DE KOHONEN COM O VALOR TEÓRICO IDEAL DA TAXA DE ERRO.

Tabela 4.8: Erro teórico para modulação BPSK devido ao ruído (AWGN).

BPSK	0 dB	5 dB	10 dB	15 dB	20 dB
COERENTE	7,9%	0,6%	-	-	-
NÃO COERENTE	18,4%	2,1%	-	-	-

Tabela 4.9: Erro teórico para modulação 2FSK devido ao ruído (AWGN).

2FSK	0 dB	5 dB	10 dB	15 dB	20 dB
COERENTE	15,9%	3,8%	-	-	-
NÃO COERENTE	30,3%	10,3%	-	-	-

De acordo com o gráfico presente na figura 2.30, pode-se verificar que para os níveis de SNR analisados de 15 dB e 20 dB seriam necessárias pelo menos em torno de milhões de amostras para haver um erro. Como foram utilizadas menos amostras para o teste das redes, pois as redes analisadas requerem poucas amostras para sua validação em comparação com outras RNAs, os resultados obtidos são coerentes.

Para a rede SOM de Kohonen desenvolvida, podemos observar que os valores de erros obtidos no processo de demodulação por esta rede são superiores aos valores ideais para um receptor coerente para os níveis de 0 dB e 5 dB, mas estão próximos desta referência ideal, demonstrando que o desempenho desta RNA é satisfatório.

CAPÍTULO V

5. CONSIDERAÇÕES FINAIS

Este trabalho não teve o propósito de esgotar o assunto, pois o mesmo é vasto e estimulante pelo seu potencial. A pesquisa apesar de ter sido fustigante, em alguns momentos, pelo caráter intuitivo e empírico do processo de desenvolvimento das RNAs, foi ao mesmo tempo inspiradora, pois a temática propicia uma vasta área de atuação e possibilidades. Passamos a visualizar que o processo de pesquisa científica, na sua origem, é essencialmente criativo, apesar de exaustivo.

A cada passo dado adiante na pesquisa, seja na leitura de fontes teóricas, interação com pesquisadores com grande experiência, ou constatação laboratorial, ficava ainda mais notória a grande diversidade de veredas que se poderia tomar.

Optou-se pela realização de experimentos com simulação computacional que é um recurso metodológico comum na produção acadêmica na área da engenharia por sua já comprovada eficácia.

Os resultados obtidos com os experimentos nas simulações evidenciam a grande aptidão cognitiva e computacional das RNAs do tipo Mapas Auto-Organizáveis no âmbito de permitir a criação de sistemas que identifiquem corretamente os sinais modulados e executem a sua demodulação.

As redes estudadas apresentaram uma boa capacidade de generalização alcançando um desempenho satisfatório, mesmo quando submetidas a uma SNR baixa.

A comparação realizada com as RNAs utilizando duas simulações diferentes, uma com a métrica Euclidiana e outra com a métrica *Manhattan* evidenciou que ambas atendem a expectativa do estudo, porém, a norma Euclidiana, apesar da pouca diferença, obteve um melhor resultado, formando *clusters* mais homogêneos e com isto, possibilitando um melhor desempenho das redes neurais artificiais em questão.

Conforme pode ser visto, com o sucesso obtido com as RNAs estudadas, a utilização de uma normalização das amostras dos símbolos representa uma alternativa interessante à utilização de outras técnicas de pré-processamento como a transformada de Fourier ou Wavelt, diminuindo a necessidade de grande capacidade de processamento matemático, permitindo, com isto, a sua implementação em computadores com desempenho de processamento baixo e sem processador matemático independente.

As RNAs de Kohonen e ART são uma alternativa válida pelo seu poder computacional e complexidade reduzida, abreviando o tempo de processamento para aplicações em tempo real.

Observamos que o desempenho das duas redes é bastante semelhante com um desempenho ligeiramente superior para a rede ART para a faixa de 5 dB de SNR para as duas modulações analisadas. Porém, a rede SOM de Kohonen possui uma vantagem adicional que pode ser útil no que diz respeito à classificação dos sinais, esta RNA não só possui a habilidade de definir os agrupamentos, como também, de definir uma ordenação entre eles devido à noção de vizinhança entre os neurônios.

A arquitetura dos mapas de Kohonen gera um mapeamento topológico dos dados apresentados na entrada da RNA, sendo capaz de agrupar os dados em *clusters*, e também realizar a localização dos *clusters* entre si baseados em similaridade, sendo capaz de preservar as relações de vizinhança dos dados de entrada. Permitindo, com isto, uma visualização espacial, facilitando a sua análise e verificação das relações existentes entre eles.

Pode-se utilizar esta habilidade para criar uma RNA do tipo SOM de Kohonen para classificar modulações mais complexas que as estudadas neste trabalho, e que agrupe sinais modulados não identificados em *clusters*, e a proximidade destes agrupamentos com os outros com sinais corretamente identificados pode dar uma ideia do tipo de modulação do sinal a priori não identificado.

5.1 CONTRIBUIÇÕES

- Confirmação que a topologia M-SOM é capaz de demodular sinais digitais efetivamente, além de realizar o reconhecimento automático de modulação.
- Aumentar o desempenho da rede M-SOM com uma nova proposta de treinamento utilizando amostras contaminadas com diversos níveis de SNR, ao invés de utilizar todas as amostras de treinamento com uma SNR fixa de 20 dB.
- Constatação que uma arquitetura semelhante à da rede M-SOM, feita com redes ART-2A, possui desempenho semelhante nos processos de AMR e demodulação de sinais.
- Constatação que as redes do tipo auto-organizáveis têm desempenho superior no reconhecimento de sinais modulados ao da rede neural artificial do *tipo Multi-Layer Perceptron* (MLP).
- Constatação que a métrica Euclidiana possibilita um melhor desempenho das redes neurais do tipo M-ART e do tipo M-SOM estudadas neste trabalho.
- Comparação dos resultados percentuais de erro obtidos pela rede SOM de Kohonen com os valores ideais para um canal AWGN, constatando que o desempenho da rede é satisfatório, pois a RNA obteve valores próximos do ideal.

5.2 TRABALHOS FUTUROS

Apresentam-se, a seguir, algumas sugestões para trabalhos futuros:

- Uso de outras redes no processo de reconhecimento automático de modulação e demodulação, notadamente redes que têm como base um algoritmo de abordagem construtiva chamadas de *Non-linear Sigmoidal Regression Blocks Networks* (NSRBN), por estarem baseadas em um princípio de auto-organização. Estas redes possuem uma forte capacidade de mapeamento.
- Efetuar comparações dos resultados obtidos entre as redes estudadas nesse trabalho, com os dados que forem apresentados pela RNA NSRBN.
- Utilizar redes híbridas (uma MLP processando os dados de treinamento e validação, utilizados na rede SOM).
- Testar outros tipos de esquemas de modulações mais complexos com as RNAs estudadas neste trabalho.
- Estudar o desempenho das redes neurais estudadas com outros tipos de ruídos, como por exemplo, o ruído rosa.
- Efetuar o treinamento e o teste das redes neurais estudadas com um banco de dados contendo sinais modulados reais (efetivamente gerados por um transmissor e propagados).
- Futuramente criar um protótipo de RNA para substituição de um *hardware* dedicado para classificação automática da modulação e de um demodulador como anteriormente mencionado nesta pesquisa.
- Como os processos de reconhecimento automático de modulação e de demodulação de sinais, podem ambos ser realizados pelas duas arquiteturas estudadas, pode-se futuramente integrá-las em uma plataforma de *hardware* programável, como por exemplo, uma FPGA (*field programmable gate arrays*) para construir um módulo de recepção de um SDR.

REFERÊNCIAS

AIKES JUNIOR *et al.* **Estudo da Influência de diversas Medidas de Similaridade na Previsão de Séries Temporais utilizando o Algoritmo kNN-TSP**, em XIX Encontro Nacional de Inteligência Artificial. Curitiba, PR, 2012. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/enia/2012/0060.pdf>>. Acesso em: 28 maio 2013.

ALENCAR, M. S. **Sistemas de Comunicações**. São Paulo: Editora Érica, 2001.
BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDIMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2 ed. Rio de Janeiro: LTC, 2012.

BAPTISTA, M. C. P.; CARVALHO, N. B. **Classificação automática da modulação de sinais digitais**. Disponível em: <<http://www.anacom.pt>>. Acesso em: 15 setembro de 2013.

CARDON, A.; MULLER, D. N.; NAVAUX. **Introdução às Redes Neurais Artificiais**. Disponível em: <http://www.inf.ufrgs.br/~danielnm/docs/intro_rna.pdf>. Acesso em: 10 julho de 2013.

CARPENTER, A. G.; GROSSBERG, S.; ROSEN, D. B. **ART-2A: Na Adaptive Resonance Algorithm for Rapid Category Learning and Recognition**. Disponível em: <<http://cns.bu.edu/>>. Acesso em: 10 maio 2013.

DIEHL, A. A. **Pesquisa em ciências sociais aplicadas: métodos e técnicas**. São Paulo: Prentice Hall, 2004 apud DALFOVO, M. S.; LANA, R. A.; SILVEIRA, A. **Métodos quantitativos e qualitativos: um resgate teórico**. Revista Interdisciplinar Científica Aplicada, Blumenau, v.2, n.4, p.01-13, Sem II. 2008 ISSN 1980-7031.

FREITAS, L. C.; KLAUTAU JR., A.; COSTA, J. C. W. A. **Classificadores de Modulação em Sensoriamento Espectral de Rádio Cognitivo**. I2TS'2008 - 7th International Information and Telecommunication Technologies Symposium. Iguazu Falls - Paraná State - Brazil. December 03-05, 2008.

FILHO, S. N. **Fundamentos sobre ruídos**. Disponível em: <<http://www.etelj.com.br/>>. Acesso em: 25 abr. 2013.

FONTES, A. I. R. **Classificação Automática de Modulação Digital com uso de Medida Teórica de Informação para Ambientes de Rádio Cognitivo**. Natal, 2012. Dissertação (Mestrado em Engenharia Elétrica e de Computação) Centro de Tecnologia da Universidade Federal do Rio Grande do Norte.

GIL, A. C. **Como elaborar projeto de pesquisa**. 4. ed. São Paulo: Atlas, 2002.

GILAT, A. **Matlab com Aplicações em Engenharia**. 2 ed. Porto Alegre: Bookman, 2006.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001.

HAYKIN, S. **SISTEMAS DE COMUNICAÇÃO ANALÓGICOS E DIGITAIS**. 4. ed. Porto Alegre: Bookman, 2007.

HAYKIN, S.; MOHER, M. **Sistemas modernos de comunicações wireless**. Porto Alegre: Bookman., 2008.

HOREWICZ, M. C.; NASCIMENTO JR., C. L.; PERRELA, W. J. **Reconhecimento Automático de Modulação Digital de Sinal de Comunicações**. Disponível em: <<ftp://labattmot.ele.ita.br/>>. Acesso em: 12 maio 2013.

HUNT, B. R. **A Guide to MATLAB for Beginners and Experienced Users**. New York, EUA: Cambridge University Press, 2001.

JANSON, J. **Radio Definido por Software: Estudo e Realização de Teste com uma Plataforma Livre**. Santa Catarina, 2012. 60f. Trabalho de Conclusão de Curso (Graduação em Curso Superior de Tecnologia em Sistemas de Telecomunicações) - Centro Federal de Educação Tecnológica de Santa Catarina, São José, Santa Catarina, 2012.

KOHONEN, T. **The Self-Organization Map**. Disponível em: <<http://www.http://www.eicstes.org/>>. Acesso em: 10 maio 2013.

KOVÁCS, Z. L. **REDES NEURAIS ARTIFICIAIS: Fundamentos e Aplicações**. 4. ed. São Paulo: Editora Livraria da Física, 2006.

KOVARIK JR, V. J.; BARD, J. **Software defined radio: the software communications architecture**. England: John Wiley & Sons Ltd, 2007.

LIMA, A. G. M. **RÁDIO DEFINIDO POR SOFTWARE : O PRÓXIMO SALTO NO MUNDO DAS TELECOMUNICAÇÕES E COMPUTAÇÃO**. Disponível em: <http://www.revdigonline.com/artigos_download/art_13.pdf>. Acesso em: 22 maio 2013.

LOPES, Y. et al. **Reconhecimento Automático de Modulação Digital e Demodulação de sinais baseado em Redes Neurais Artificiais**, em XXX SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES - SBRT'12, 13-16 DE SETEMBRO DE 2012, BRASÍLIA, DF.

LUDWING JR., O.; MONTGOMERY, E. **Fundamentos e Aplicações com Programas em C**. Rio de Janeiro: Editora Ciência Moderna Ltda, 2007.

MARCONI, M. A.; LAKATOS, E. M. **Fundamentos de metodologia de pesquisa**. 7. ed. SÃO PAULO: Atlas, 2010.

_____. **Metodologia do trabalho científico: procedimentos básicos, pesquisa bibliográfica, projeto e relatório, publicações e trabalhos científicos**. 7. ed. São Paulo: Atlas, 2012.

_____. **Metodologia científica**. 2. ed. São Paulo: Atlas, 1991.

MARTINELI, E. **Extração de conhecimento de Redes Neurais Artificiais**. São Carlos: USP - Dissertação de mestrado, 1999.

MATOS, M. A. C. C. **Conceitos úteis**. Disponível em <<http://paginas.fe.up.pt/~mam/normetr.pdf>>. Acesso em: 28 maio 2013.

MEDEIROS, L. F. **Redes Neurais em Delphi**. 2 ed. Florianópolis: Visual Books, 2006.

MITOLA, J. **Software radio architecture**. Wiley, 2000 apud JANSON, J. **Radio Definido por Software: Estudo e Realização de Teste com uma Plataforma Livre**. Santa Catarina, 2012. 60f. Trabalho de Conclusão de Curso (Graduação em Curso Superior de Tecnologia em Sistemas de Telecomunicações) - Centro Federal de Educação Tecnológica de Santa Catarina, São José, Santa Catarina, 2012.

MIYOSHI, E. M. ; SANCHES, C. A. **Projetos de Sistemas Rádio**. São Paulo: Editora Érica, 2002.

NOCETTI FILHO, S. **Fundamentos sobre ruídos: ruído branco e ruído rosa**. Back Staye. Vol 8, n° 98. Maio 2002.

PAIVA JUNIOR, N. M. et al. **Introdução ao Desenvolvimento de Rádios Definidos por Software para Aplicações de Defesa**, em XXX SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES - SBRT'12, 13-16 DE SETEMBRO DE 2012, BRASÍLIA, DF.

POPPER, Karl. **A lógica da pesquisa científica**. 2. ed. São Paulo: Cultrix, 1972 apud DALFOVO, M. S. ; LANA, R. A.; SILVEIRA, A. **Métodos quantitativos e qualitativos: um resgate teórico**. Revista Interdisciplinar Científica Aplicada, Blumenau, v.2, n.4, p.01-13, Sem II. 2008 ISSN 1980-7031.

SILVA, F. A. T. F. **Rede morfológica não-supervisionada-RMNS**. São José dos Campos, 1998. 129p. Tese (Doutorado em Computação Aplicada)- INPE, 1998.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artiliber, 2010.

TORRES, C. M. C. **Transmissão de Imagem Através de Canal Ruidoso Usando Códigos LT**. Rio de Janeiro, 2009. Dissertação (Mestrado em Engenharia Elétrica) Departamento de Engenharia Elétrica do Centro Técnico Científico da Pontifícia Universidade Católica do Rio de Janeiro.

VALENÇA, M. **Aplicando Redes Neurais: um guia completo**. Olinda-PE: Livro Rápido, 2005.

_____. **Fundamentos das Redes Neurais: Exemplos em Java**. 2 ed. Olinda,PE: Livro Rápida, 2010.

VEIGA, V. G. ; GUIMARÃES, B. **DOWNLOAD SEGURO EM RÁDIO DEFINIDO POR SOFTWARE (RDS)**. Disponível em: <http://www.revdigonline.com/artigos_download/art_9.pdf>. Acesso em: 24 maio 2013.

WHAT is Software Defined Radio? Disponível em: < <http://www.wirelessinnovation.org>>. Acesso em: 24 nov 2013.

VIEIRA, R. C.; ROISENBERG, M. **REDES NEURAIS ARTIFICIAIS: UM BREVE TUTORIAL**. Disponível em:< <http://www.das.ufsc.br/> >. Acessado em 10 agosto 2013.

XU. Y.; GE. L.; WANG B. Digital **modulation recognition method based on self-organizing map neural networks**, em *Wireless Communications,Networking and Mobile Computing, 2008. WiCOM '08. 4th International Conference on*, p. 1 –4, oct. 2008.

ZHOU, L. et al. **MSOM Based Automatic Modulation Recognition and Demodulation**, em *Sarnoff Symposium, 2011 34th IEEE*,p. 1 –5, may 2011.

OBRAS CONSULTADAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Informação e documentação – Referências – elaboração.** NBR 6023. Rio de Janeiro, 2002.

_____. **Informação e documentação – Sumário – elaboração.** NBR 6027. Rio de Janeiro, 2003.

_____. **Informação e documentação – Trabalhos Acadêmicos – apresentação.** NBR 14724. Rio de Janeiro, 2002.

_____. **Informação e documentação – citações em documentos – apresentação.** NBR 10520. Rio de Janeiro, 2002.

_____. **Informação e documentação – Numeração progressiva das seções de documento escrito – apresentação.** NBR 6024. Rio de Janeiro, 2003.

_____. **Informação e documentação – Resumo – apresentação.** NBR 6028. Rio de Janeiro, 2003.

Associação Brasileira de Normas Técnicas. Disponível em: <http://www.abnt.org.br/m2.asp?cod_pagina=963#>. Acesso em: 12/04/2012 às 22:00hs.

BACKES, A. **Linguagem C: completa e descomplicada.** Rio de Janeiro: Elsevier, 2013.

BLANCHET, G.; CHARBIT, M. **Digital signal and image processing using Matlab.** London: ISTE LTD, 2006.

CARSON, A. B. et al. **Communication systems: an introduction to signals and noise in electrical communication.** 4 ed. New York, EUA: McGraw-Hill, 2002.

CARVALHO, A. X. Y *et al.* **Clusterização hierárquica espacial com atributos binários.** Disponível em: <<http://ideas.repec.org/p/ipe/ipetds/1428.html>>. Acessado em: 12/04/2012 às 23:00hs.

COGNITIVE Radio Definitions and Nomenclature. Disponível em: <http://www.wirelessinnovation.org/>. Acesso em: 14 abr. 2013.

DE LA VEGA, A. S. **Teoria para processamento digital de sinais- versão A2012M06D18.** Niterói 2012, 175 p. Apostila do Departamento de Engenharia de Telecomunicações – Universidade Federal Fluminense.

DEMUTH, H.; BEALE, M. **Neural Network Toolbox For Use with MATLAB.** Natick, MA: The MathWorks, Inc, 2000.

FAUSETT, L. **Fundamentals of neural networks: architectures, algorithms, and applications.** Paramus: Prentice Hall, 1994.

FONTÁN, F. P.; ESPÍNEIRA, P. M. **Modeling the Wireless Propagation Channel. A Simulation Approach with MATLAB.** United Kindom: John Wiley & Sons Ltd, 2008.

FRANÇA, J. L. et al. **Manual para Normalização de Publicações Técnico-Científicas.** Belo Horizonte: Ed. UFMG, 2003.

GILAT, A. **Matlab com Aplicações em Engenharia.** 2 ed. Porto Alegre: Bookman,2006.

HAYKIN, S. **Sinais e Sistemas.** Porto Alegre: Bookman,2001.

HUNT, B. R. **A Guide to MATLAB for Beginners and Experienced Users.** New York, EUA: Cambridge University Press, 2001.

JAIN, R. **Art of Computer Systems Performance Analysis Techniques For Experimental Design Measurements Simulation And Modeling.** England: John Wiley & Sons, inc, 1991.

PEIXOTO, A. *et al.* **Transformada de distância.** Disponível em: <http://ftp.inf.puc-rio.br/pub/docs/techreports/00_35_peixoto.pdf>. Acessado em:12/04/2012 às 23:30 hs.

SILVA, J. B. C. **A dissertação clara e organizada.** Belém, Pará: Editora Universitária UFPA, 2007.

SOUZA NETO, S. P. **Técnicas de pesquisa.** Rio de Janeiro: UCB/EB-DEP-CEP, 2009.

WEEKS, M. **Digital Signal Processing Using MATLAB and Wavelets.** Hingham, Massachusetts: Infinity Science Press LLC, 2007.

YANG, W. Y et al. **Signal and Systems with MATLAB**. Natick,MA,USA: Springer,2009.