



Ministério da
Ciência e Tecnologia



INPE-16207-TDI/1539

MINERAÇÃO DE DADOS DE PADRÕES CLIMÁTICOS SAZONAIS USANDO A LÓGICA PARACONSISTENTE

Valdemir Silva Souza

Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada,
orientada pelo Dr. José Demisio Simões da Silva, aprovada em 13 de maio de 2009.

Registro do documento original:

<<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/04.30.22.30>>

INPE
São José dos Campos
2009

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3945-6911/6923

Fax: (012) 3945-6919

E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO:

Presidente:

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Membros:

Dr^a Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Haroldo Fraga de Campos Velho - Centro de Tecnologias Especiais (CTE)

Dr^a Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Dr. Ralf Gielow - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr. Wilson Yamaguti - Coordenação Engenharia e Tecnologia Espacial (ETE)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Jefferson Andrade Ancelmo - Serviço de Informação e Documentação (SID)

Simone A. Del-Ducca Barbedo - Serviço de Informação e Documentação (SID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Marilúcia Santos Melo Cid - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Viveca Sant´Ana Lemos - Serviço de Informação e Documentação (SID)



Ministério da
Ciência e Tecnologia



INPE-16207-TDI/1539

MINERAÇÃO DE DADOS DE PADRÕES CLIMÁTICOS SAZONAIS USANDO A LÓGICA PARACONSISTENTE

Valdemir Silva Souza

Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada,
orientada pelo Dr. José Demisio Simões da Silva, aprovada em 13 de maio de 2009.

Registro do documento original:

<<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/04.30.22.30>>

INPE
São José dos Campos
2009

Dados Internacionais de Catalogação na Publicação (CIP)

Souza, Valdemir Silva.

So89m Mineração de dados de padrões climáticos sazonais usando a lógica paraconsistente / Valdemir Silva Souza. – São José dos Campos : INPE, 2009.

105p. ; (INPE-16207-TDI/1539)

Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

Orientador : Dr. José Demisio Simões da Silva.

1. Lógica paraconsistente. 2. Rede neural artificial. 3. Padrões climáticos. 4. Mineração de dados. I.Título.

CDU 004.032.26

Copyright © 2009 do MCT/INPE. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de recuperação, ou transmitida sob qualquer forma ou por qualquer meio, eletrônico, mecânico, fotográfico, reprográfico, de microfilmagem ou outros, sem a permissão escrita do INPE, com exceção de qualquer material fornecido especificamente com o propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

Copyright © 2009 by MCT/INPE. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, recording, microfilming, or otherwise, without written permission from INPE, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

**Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de Mestre em
Computação Aplicada**

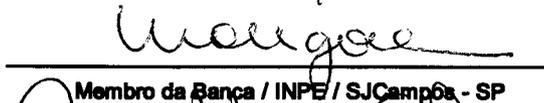
**Dr. Lamartine Nogueira Frutuoso
Guimarães**


Presidente / IEAVCTA / SJC Campos - SP

Dr. José Demisio Simões da Silva


Orientador(a) / INPE / SJC Campos - SP

Dra. Margarete Oliveira Domingues


Membro da Banca / INPE / SJC Campos - SP

Dr. Ivan Nunes da Silva


Convidado(a) / USP-São Carlos / São Carlos - SP

Aluno (a): Valdemir Silva Souza

São José dos Campos, 13 de maio de 2009

“A existência, porque humana, não pode ser muda, silenciosa, nem tão pouco pode nutrir-se de falsas palavras, mas de palavras verdadeiras, com que os homens transformam o mundo. Existir, humanamente, é pronunciar o mundo, é modificá-lo. O mundo pronunciado, por sua vez, se volta problematizado aos sujeitos pronunciantes, a exigir deles novo pronunciar. Não é no silêncio que os homens se fazem, mas na palavra, no trabalho, na ação-reflexão.”

Paulo Freire
Livro: Pedagogia do Oprimido

AGRADECIMENTOS

Agradecer sempre faz sentido, pois é o momento de valorizar os atos e ações recebidas por pessoas que acreditam em nós, independentemente do meio em que estamos envolvidos, assim, agradeço:

a minha família em especial a minha esposa Roberta L. P. Souza e minha filha Yollanda Caroline Souza por realmente me apoiar em todos os sentidos a vencer mais esta empreitada intelectual;

aos amigos de longa data e aos que conheci durante o processo para alcançar o título de mestre;

não posso deixar de agradecer ao meu orientador professor Dr. José Demisio Simões da Silva, pela oportunidade, força e compreensão que me direcionou no andamento deste trabalho;

por fim, aos envolvidos indiretamente, mas com decisões importantes ao andamento e finalização desta dissertação de mestrado que também têm a minha gratidão.

RESUMO

Esta dissertação apresenta uma técnica não-paramétrica que utiliza a Lógica Paraconsistente na Mineração de Dados Meteorológicos de reanálise dos históricos de informações de cinco regiões da América do Sul, de um período de 21 anos dos ciclos sazonais ocorridos entre os anos de 1980-2000. Esses dados são as entradas de uma Rede Neural Artificial baseada na Lógica Paraconsistente, que tem como objetivo gerar um conjunto reduzido de dados para ser submetido a uma Rede de Funções de Base Radial na elaboração de um modelo de previsão sazonal de clima. O processamento da rede neural paraconsistente contribui na identificação de padrões, por ciclos sazonais nos dados históricos do período 1980-1997. Para a validação da técnica de redução desenvolvida, o modelo de previsão obtido foi submetido aos dados extraídos do período de 1998-2000, para as mesmas áreas geográficas. Os resultados da previsão com modelo estabelecido apresentaram erros inferiores que as previsões obtidas pelo modelo proposto no trabalho de Pessoa (2004), que utilizou a Teoria dos Conjuntos Aproximativos sobre os mesmos dados para diminuir a complexidade dos dados e compor um modelo de previsão baseado em uma rede neural do tipo *Perceptron* de Múltiplas Camadas.

DATA MINING OF CLIMATIC PATTERNS USING THE PARACONSISTENT LOGIC

ABSTRACT

This work presents a non-parametric technique that uses the paraconsistent logic to develop a data mining based approach to analyze reanalysis meteorological data of five areas of South America composed of seasonal cycles, of 21 years from 1998 to 2000. The available data was used as inputs for a paraconsistent neural network to generate a reduced set to be submitted to a Radial Basis Function (RBF) network to derive a seasonal forecasting model. The paraconsistent neural network performs the identification of patterns of seasonal cycles from data extracted from 1980 to 1997. The remainder of the data (from 1998 to 2000) is used to validate the proposed RBF based forecasting method for the same geographical areas. The results produced by the proposed forecasting method were more accurate than the ones obtained in the work of Pessoa (2004) that used the Rough Sets Theory to reduce the embedded complexity of the same data set in order to construct a Multilayer Perceptron (MLP) neural network based forecasting model for seasonal cycles.

SUMÁRIO

	Pág.
LISTA DE FIGURAS	
LISTA DE TABELAS	
LISTA DE EQUAÇÕES	
LISTA DE SIGLAS E ABREVIATURAS	
1. INTRODUÇÃO	23
2. BASES TEÓRICAS.....	27
2.1 Mineração de Dados	27
2.1.1 O Processo de descoberta de conhecimento.....	28
2.1.2 Categorização da Mineração de Dados	29
2.1.3 Tarefas da Mineração de Dados	30
2.1.4 Técnicas de Mineração de Dados	31
2.2 Lógica Paraconsistente	31
2.2.1 As lógicas não-clássicas	31
2.2.2 Aspectos históricos da Lógica Paraconsistente	32
2.2.3 Teorias inconsistentes e teorias triviais	33
2.2.4 Princípios conceituais da Lógica Paraconsistente	34
2.3 A Lógica Paraconsistente anotada de anotação com dois valores (<i>LPAV2v</i>) ..	35
2.4 Modelo matemático de neurônios artificial	40
2.4.1 Rede Neural de Funções de Base Radial	43
2.4.2 Rede Neural Artificiais Paraconsistentes	46
3. METODOLOGIA	51
4. METEOROLOGIA E SELEÇÃO DA ÁREA DE ESTUDO	55
5. ABORDAGEM PARA A PREVISÃO DE DADOS METEOROLÓGICOS ...	61
6. RESULTADOS	65
6.1 Previsão de Precipitação	67
6.2 Previsão de Temperatura	74
7. CONCLUSÃO	81
REFERÊNCIAS BIBLIOGRÁFICAS	83
APÊNDICE A - REDES NEURAIS ARTIFICIAIS PARACONSISTENTES	87

LISTA DE FIGURAS

		Pág.
2.1	Etapas do processo <i>KDD</i>	28
2.2	Reticulado finito de Hasse com <i>LPA2v</i>	36
2.3	Quadrado unitário do plano cartesiano (reticula 12 posições)	39
2.4	Estrutura de um Neurônio Biológico	41
2.5	Modelo de um neurônio não-linear	42
2.6	Funções de ativação	43
2.7	Estrutura Básica da <i>Radial Basis Function</i> – <i>RBF1</i>	44
2.8	Estrutura Básica da <i>Radial Basis Function</i> – <i>RBF2</i>	46
2.9	Célula Artificial Paraconsistente Básica	48
3.1	Processo de busca dos registros	52
4.1	Grade	56
4.2	Grade Global de baixa resolução	56
4.3	Áreas selecionadas para as análises	59
5.1	Modelo de Rede Neural Artificial Paraconsistente	62
6.1	Imagem real – A3	70
6.2	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A3	70
6.3	Imagem real – A1	71
6.4	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A1	71
6.5	Imagem real – A1	71
6.6	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A1	71
6.7	Imagem real – A2	72
6.8	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A2	72
6.9	Imagem real – A4	72
6.10	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A4	72
6.11	Imagem real – A5	73
6.12	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A5	73
6.13	Imagem real – A2	73
6.14	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A2	73
6.15	Imagem real – A3	77
6.16	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A3	77
6.17	Imagem real – A5	77
6.18	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A5	77
6.19	Imagem real – A4	78
6.20	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A4	78
6.21	Imagem real – A3	78
6.22	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 3$ – A3	78
6.23	Imagem real – A1	79
6.24	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A1	79
6.25	Imagem real – A4	79
6.26	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A4	79
6.27	Imagem real – A3	80
6.28	Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 3$ – A3	80
A.1	Representa a <i>CNAPCa</i>	91
A.2	Representa a <i>CNAPCLsMax</i>	92
A.3	Representa a <i>CNAPCLsMin</i>	93

A.4	Representa a <i>CNAPCo</i>	94
A.5	Representa a <i>CNAPp</i>	95
A.6	Representa a <i>CNAPAdm</i>	96
A.7	Representa a <i>CNAPpm</i>	98
A.8	Representa a <i>CNAPRp</i>	99
A.9	Representa a <i>SNAPDeEv</i>	102
A.10	Representa a <i>UNAPMax</i>	103
A.11	Representa a <i>UNAPMin</i>	104
A.12	Representa a <i>UNAPMax</i>	105

LISTA DE TABELAS

		PÁG.
4.1	Atributos Meteorológicos utilizado	58
6.1	Relaciona a quantidade de padrões identificados	65
6.2	Erros quadráticos médios (Tolerância tipo 1, <i>Prec</i> , $\Delta=1$)	68
6.3	Erros quadráticos médios (Tolerância tipo 2, <i>Prec</i> , $\Delta=1$)	68
6.4	Erros quadráticos médios (Tolerância tipo 3, <i>Prec</i> , $\Delta=1$)	68
6.5	Erros quadráticos médios (Tolerância tipo 1, <i>Prec</i> , $\Delta=3$)	69
6.6	Erros quadráticos médios (Tolerância tipo 2, <i>Prec</i> , $\Delta=3$)	69
6.7	Erros quadráticos médios (Tolerância tipo 3, <i>Prec</i> , $\Delta=3$)	69
6.8	Erros quadráticos médios (Tolerância tipo 1, <i>Temp</i> , $\Delta=1$)	74
6.9	Erros quadráticos médios (Tolerância tipo 2, <i>Temp</i> , $\Delta=1$)	75
6.10	Erros quadráticos médios (Tolerância tipo 3, <i>Temp</i> , $\Delta=1$)	75
6.11	Erros quadráticos médios (Tolerância tipo 1, <i>Temp</i> , $\Delta=3$)	76
6.12	Erros quadráticos médios (Tolerância tipo 2, <i>Temp</i> , $\Delta=3$)	76
6.13	Erros quadráticos médios (Tolerância tipo 3, <i>Temp</i> , $\Delta=3$)	76

LISTA DE EQUAÇÕES

		Pág.
2.1	Soma Ponderada	43
2.2	Saída do Neurônio	43
2.3	Centros da RBF	44
2.4	Saídas da RBF	44
2.5	Equação Estrutural Base	46
2.6	Valor Superior de Controle a Certeza	48
2.7	Valor Inferior de Controle a Certeza	48
2.8	Valor Superior de Controle a Contradição	48
2.9	Valor Inferior de Controle a Contradição	48
3.1	Cálculo do grau de descrença	51
6.1	Erro Quadrático Médio	66
6.2	Erro Médio Absoluto	66
6.3	Ganho ou Perda	67

LISTA DE SIGLAS E ABREVIATURAS

LP	Lógica Paraconsistente
LPA2v	Lógica Paraconsistente Anotada de Anotação de dois valores
RNA	Rede Neural Artificial
RBF	Rede de Funções de Base Radial
RNAP	Rede Neural Artificial Paraconsistente
Prec	Precipitação
Temp	Temperatura
CNAP	Célula Neural Artificial Paraconsistente
UNAP	Unidade Neural Artificial Paraconsistente
SNAP	Sistema Neural Artificial Paraconsistente
DJF	Dezembro, Janeiro e Fevereiro
MAM	Março, Abril, Maio
JJA	Junho, Julho e Agosto
SON	Setembro, Outubro e Novembro
ftC	Fator de Tolerância à Certeza
ftCt	Fator de Tolerância à Contradição
ftR	Fator de Tolerância de Reconhecimento de Padrão
ftA	Fator de Aprendizagem
evF	Evidência Favorável
evCt	Evidência Contrária
CNAPCa	Célula Neural Artificial Paraconsistente de Conexão Analítica
CNAPCLsMax	Célula Neural Artificial Paraconsistente de Conexão Lógica Simples de Maximização
CNAPCLsMin	Célula Neural Artificial Paraconsistente de Conexão Lógica Simples de Minimização
CNAPCo	Célula Neural Artificial Paraconsistente de Complementação
CNAPp	Célula Neural Artificial Paraconsistente de Passagem
CNAPAdm	Célula Neural Artificial Paraconsistente de Aprendizagem, Desaprendizagem e Memorização
CNAPAp	Célula Neural Artificial Paraconsistente de Aprendizagem e Padrão Memorizado
CNAPRp	Célula Neural Artificial Paraconsistente e Reconhecimento de Padrão
vscc	Valor Superior de Controle a Certeza
vicc	Valor Inferior de Controle a Certeza
vsctt	Valor Superior de Controle a Contradição
vicct	Valor Inferior de Controle a Contradição

1. INTRODUÇÃO

Em meteorologia, a previsão climática é uma estimativa do comportamento médio atmosférico para médio e longo prazo. Um dos objetivos da previsão climática é estimar o volume de precipitação, em relação à média histórica, nos meses de chuva em uma determinada área, em um determinado ciclo sazonal. (CENTRO DE PREVISÃO DO TEMPO E ESTUDOS CLIMÁTICOS, 2003). Este tipo de previsão é importante para diversos segmentos da sociedade, como por exemplo, para o setor de agronegócios no Brasil. Este segmento da sociedade tem como demanda a excelência das safras. Para isso, faz-se necessário aliar estudos de variedades de sementes, enriquecimento do solo, máquinas modernas, estudo do escoamento das safras, com o estudo sistemático que procura entender o comportamento climático, de forma a empreender ações que possam minimizar os problemas devido às anomalias do clima.

O estudo do comportamento climático pode ser feito através da análise de informações disponíveis, oriundas de modelos meteorológicos e/ou de observações coletadas através de redes sensores terrestres, marítimos ou de satélites. Esta abordagem, entretanto, é complexa devido à quantidade de informações disponíveis adquiridas dos diversos tipos de sensores já disponíveis e, com o aumento do número de sensores, a complexidade pode aumentar ainda mais.

Esta disponibilidade de dados requer muito poder de processamento dos computadores tanto para o tratamento dos dados quanto para a execução dos modelos climáticos para gerar prognósticos do estado futuro da atmosfera, como é feito em vários centros meteorológicos no mundo.

A quantidade de dados e a complexidade dos modelos são dois fatores complicadores para o estudo do comportamento do clima, que têm fomentado a busca pelo desenvolvimento de novas abordagens de análise dos dados, que os minimizem.

Entretanto, em uma escala de previsão sinóptica do clima, pode se perguntar se os dados provenientes de várias fontes são necessários. Ou seja, a indagação pode ser colocada pensando na possibilidade de uso de um subconjunto dos dados, ao invés de todos os dados disponíveis, para a obtenção dos modelos.

Neste sentido, esta dissertação toma a hipótese da possibilidade de uso de conjuntos reduzidos, para realizar uma previsão sinóptica de clima, sem perda de precisão.

O trabalho baseia-se na abordagem proposta em Pessoa (2004) que propôs o uso de uma técnica de redução de dados usando uma abordagem baseada na teoria dos conjuntos aproximativos (TCA).

Entretanto, a técnica proposta nesta dissertação é baseada nos conceitos da lógica paraconsistente anotada, para conceber um método de redução de dados que permita a obtenção de um modelo de previsão de clima utilizando uma rede de funções de base radial. Os processos de estabelecimento dos conjuntos reduzidos e de obtenção dos modelos são realizados através de métodos de aprendizagem dos modelos de redes neurais utilizados.

Os resultados são generalizados para as áreas selecionadas no estudo de caso testando a eficiência do modelo de previsão. A identificação dos padrões através da aprendizagem realizada pela rede neural artificial paraconsistente é considerada como uma abordagem de mineração de dados.

Os padrões identificados, denominados centros de agrupamentos, são utilizados como entradas de uma rede de funções de base radial, que tem, por sua vez, suas saídas comparadas com os valores dos atributos reais disponibilizados.

A lógica paraconsistente usada como base para este trabalho é a lógica paraconsistente anotada de dois valores fundamentada por Abe (1992). Alguns exemplos de aplicações que utilizam essa lógica são citados em (PRADO, 2002; SOUZA, 2005; ÁVILA, 1996; DA SILVA FILHO, 2001), dentre outros. Todos esses trabalhos utilizam os princípios da lógica paraconsistente para tratar incertezas dadas como inconsistências presentes nos dados.

O trabalho de Prado (2002) utiliza a lógica paraconsistente no processo de descoberta de conhecimento em textos. O trabalho de Souza (2005) utiliza a lógica paraconsistente na descoberta de fraudes em *Internet Banking* analisando e criando perfis de clientes.

Os experimentos realizados de mineração, obtenção de modelo e de previsão de clima apresentaram resultados com erros que são comparados àqueles reportados em Pessoa (2004), tomados como referência para análise de desempenho do método proposto.

Portanto, este trabalho mostra a possibilidade da combinação da técnica de mineração de dados pela lógica paraconsistente e de uma rede de funções de base radial na concepção de uma alternativa de modelo para a previsão climática sinóptica com base no histórico de dados de reanálise disponível, diversificando a informação e podendo servir de suporte para os processos operacionais de previsão de clima.

A principal vantagem no uso de um sistema como proposto nesta dissertação, está no fato de que é possível fazer prognósticos de comportamento climático global de forma automática (ou semi-automática), utilizando conjuntos de dados reduzidos para a obtenção dos modelos.

Portanto, a motivação deste trabalho é estudar a concepção de uma técnica não paramétrica para a previsão sinóptica de clima em uma abordagem de mineração de dados.

O Capítulo 2 descreve as bases teóricas utilizadas no desenvolvimento da técnica proposta.

O Capítulo 3 traz uma breve descrição da metodologia aplicada em todas as etapas deste trabalho.

O Capítulo 4 descreve dados meteorológicos utilizados neste trabalho e os fundamentos da lógica paraconsistente.

O Capítulo 5 descreve a aplicação das técnicas abordadas os dados disponíveis e descritos no Capítulo 4.

O Capítulo 6 descreve os resultados obtidos e uma análise dos erros obtidos.

O Capítulo 7 apresenta as conclusões e sugestões de futuros trabalhos.

O Apêndice A descreve algumas aplicações da Lógica Paraconsistente mostrando o algoritmo do Para-Analisador e os conceitos básicos da Rede Neural Artificial Paraconsistente.

2. BASES TEÓRICAS

Neste capítulo são descritos alguns princípios das teorias que embasam o trabalho desenvolvido nesta dissertação.

2.1 Minerações de Dados

Mineração de Dados é um conjunto de técnicas computacionais para a extração de informações desconhecidas e potencialmente úteis em grandes volumes de dados através de um resumo compacto dos mesmos. O termo “Mineração de Dados” é somente um de vários termos, incluindo *extração de conhecimento*, *arqueologia de dados*, *colheita de informações* ou *descoberta de conhecimento em banco de dados* (*KDD - Knowledge Discovery in Databases*) Chen (2001), (FAYYAD, 1996).

As características principais do processo de Mineração de Dados são:

- O conhecimento descoberto é representado por uma linguagem de alto nível que pode ser entendido por humanos;
- As descobertas retratam o conteúdo de bases de dados;

Os termos *KDD* e mineração de dados algumas vezes são usados com o mesmo sentido. Isto ocorre quando em função da aplicação, o acrônimo *KDD* está diretamente relacionado à extração de conhecimento residente em uma base de dados, que utilizam sistemas gerenciadores de banco de dados. Entretanto, a Mineração de Dados, não pressupõe a especificação do tipo da fonte de dados, nem do formato dos mesmos (FAYYAD, 1996).

A pesquisa em *KDD* cresce com base na disseminação da tecnologia de bancos de dados e na premissa de que as grandes coleções de dados hoje existentes podem ser fontes de conhecimento útil, que está implicitamente representado e pode ser extraído.

No sentido, a *KDD* se vale de várias técnicas, dentre elas algumas de inteligência artificial e de estatística, para lidar com a incerteza relacionada às descobertas.

2.1.1 O Processo de descoberta de conhecimento

A descoberta de conhecimento é um processo que extrai conhecimento novo, útil e interessante a partir de bases de dados. É um processo que tem natureza iterativa e interativa e pode ser dividido em uma série de atividades (FAYYAD, 1996).

A mineração de dados, por sua vez, pode ser considerada um processo fundamento de *KDD*, em que são aplicados os algoritmos de extração de padrões nos dados. A Figura 2.1 apresenta uma representação do processo de *KDD*.

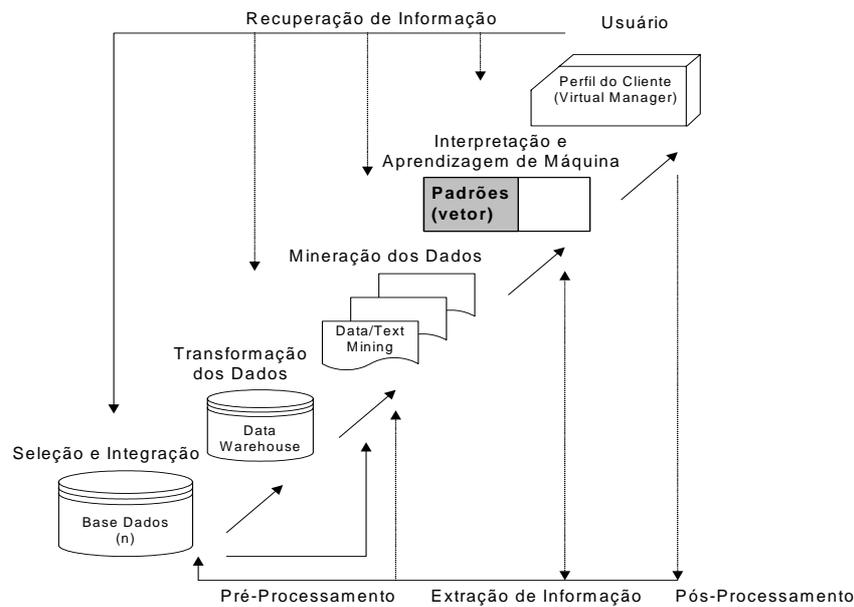


Figura 2.1 – Etapas do processo de *KDD*

De uma forma geral as etapas da *KDD* resumidamente são:

- Definição da **seleção dos dados** e integração: Inclui a descrição cuidadosa do problema; a avaliação da necessidade de uso da Mineração de Dados; a escolha do método; a decisão do formato dos dados de entrada e de saída; etc. As decisões consideram, em geral, a relação entre os custos financeiro e computacional e o benefício. Nesta fase também se determina os dados que necessários para o processo. Este é um passo importante, pois se reflete diretamente nos resultados.
- **Pré-Processamento**: Nesta etapa do processo são eliminados ruídos e dados errados. Também são estabelecidos: procedimentos para verificação da falta de dados; convenções para nomeação; e outros passos para tornar a base de dados consistente. Nesta etapa os dados devem ser normalizados e uma análise é realizada

para determinar e selecionar alguns atributos que podem ser descartados, bem como a necessidade de conversão dos dados para outro formato. Essa é a etapa mais lenta do processo, demandando cerca de 50-80% do tempo total de desenvolvimento de um processo de preparação de dados para mineração de dados.

- **Transformação dos dados:** Esse passo é realizado em função da necessidade, para auxiliar as demais etapas de KDD. A transformação pode incluir, por exemplo, a redução e a compressão de dados; a transformação de atributos não-categóricos em atributos categóricos; discretização de atributos contínuos; etc.
- **Mineração de Dados:** Esse passo consiste da aplicação dos algoritmos para descoberta de padrões nos dados. Esta etapa pode envolver a seleção de métodos, técnicas e modelos que sejam mais adequados para realizar a análise desejada, podendo demandar grande poder computacional em função da quantidade de dados disponível.
- **Interpretação:** Consiste na visualização dos resultados obtidos pelo processo de Mineração de Dados, para utilização como suporte à tomada de decisão pelo usuário. Este deverá avaliar a adequação dos padrões identificados pelo processo no tocante à extração de conhecimento desejado.

Vale ressaltar que após a obtenção do conhecimento, caso os resultados não sejam considerados satisfatórios o processo pode ser retomado a partir do ponto considerado mais oportuno para tal análise.

2.1.2 Categorização da Mineração de Dados

Existem muitos modos de categorizar ou classificar a mineração de dados. Um modo é classificar a mineração de dado de acordo com os seus objetivos. Neste caso duas categorias são propostas na literatura:

- **Descritiva:** Especializada na procura de padrões que são interpretáveis e descritos nos dados. Este tipo de mineração de dado descreve as características existentes nos dados (HOLSHEIMER, 1994).
- **Preditiva:** Envolve usar variáveis para prever valores desconhecidos e futuros de outras variáveis de interesse (WEISS, 1998).

2.1.3 Tarefas da Mineração de Dados

As *tarefas* ou funcionalidades da Mineração de Dados estão relacionadas com o domínio da aplicação e o interesse do usuário, indicando o tipo de conhecimento que deve ser descoberto. As tarefas resumidamente são:

- **Caracterização:** O objetivo da caracterização é generalizar, resumir e possivelmente comparar características dos dados. Por exemplo, é um tipo de caracterização saber qual tipo de pessoas são típicas compradoras de imóveis na cidade X, para casas novas com valor mínimo de \$500.000,00 (CHEN, 2001).
- **Associação:** Também chamado de *Market Basket Analysis* (dá-se esse nome porque os dados consistem em um conjunto de atributos binários chamados itens) ou análise de afinidades em aplicações de negócios, a associação é a descoberta de relações entre vários atributos ou transações. Por exemplo, considera-se como associação a análise que fornece informações para o gerente de uma vídeo-locadora como conhecer quais filmes sempre são alugados juntos ou se existe alguma relação entre alugar determinados gêneros de filmes e comprar pipoca ou refrigerante.
- **Classificação:** Frequentemente há interessados em classificar dados de acordo com valores em atributo classificador, também conhecido como meta ou objetivo. Nesta tarefa, que é a mais empregada em descoberta de conhecimento, cada registro pertence a uma classe. O princípio da classificação é descobrir algum tipo de relacionamento entre os atributos preditivos (WEISS, 1998) e o atributo objetivo, o que envolve uma função que mapeie os dados nas classes pré-definidas. Por exemplo, é classificação identificar que tipos de clientes seriam eventuais compradores de um livro de culinária, baseado em um banco de dados contendo dados sobre os clientes da editora nos países onde o livro foi publicado.
- **Regressão:** Envolve aprender uma função que mapeie os dados para predição de uma variável contínua. Esta tarefa é conceitualmente similar à classificação. A maior diferença é que na regressão o atributo meta é contínuo, enquanto que na classificação em geral é do tipo discreto.
- **Segmentação:** Segmentação ou *Clustering* consiste em agrupar os dados em novas classes. Isto é o que as pessoas fazem intuitivamente quando visualizam o

mundo e segmentam em grupos discretos, por exemplo, tipos de animais, plantas, veículos, etc. Nesta tarefa o algoritmo deve criar classes através da partição dos dados com valores de atributos semelhantes, ou seja, reunir em uma mesma classe as propriedades de interesse comum.

2.1.4 Técnicas de Mineração de Dados

Existem inúmeras técnicas que são empregadas na Mineração de Dados, sendo algumas delas (KOMOROWSKI, 1999), (CHEN, 2001), (ABE, 2008):

- Teoria dos Conjuntos Aproximativos (*Rough Sets Theory*);
- Conjuntos Nebulosos (*Fuzzy Sets*);
- Redes Neurais Artificiais;
- Lógica Paraconsistente;
- Indução de regras;
- Árvores de decisão;

Dentre as técnicas citadas acima, duas delas, a lógica paraconsistente e as redes neurais artificiais (especificamente uma rede de funções de base radial – *RBF*) serão utilizadas para a mineração de dados não-similares sobre os atributos de entrada (precipitação e temperatura).

2.2 Lógica Paraconsistente

A lógica paraconsistente é considerada uma lógica não-clássica capaz de desafiar as leis básicas da lógica clássica de valores binários, verdadeiro ou falso. A ciência lógica é a base e o fundamento da matemática. Ao que tudo indica, foi com os trabalhos do filósofo Aristóteles (384-322 a.C.) que houve o início dos estudos da lógica. A idéia era estabelecer um conjunto de regras rígidas, para que as conclusões pudessem ser aceitas como logicamente válidas. Trata-se de uma linha de raciocínio lógico baseado em premissas e conclusões, do tipo: “Todo ser vivo é mortal” (premissa 1), e em seguida é constatado que “O leão é um ser vivo” (premissa 2), tem-se que “O leão é mortal” (conclusão) (DA SILVA FILHO, 2008).

Com isso o raciocínio lógico clássico é fundamentado em quatro princípios básicos:

- Princípio da Identidade $\rho = \rho$: Toda proposição ou objeto é idêntico a si mesmo.
- Princípio da identidade proposicional, $\rho \rightarrow \rho$: Toda proposição implica ela mesma.
- Princípio do terceiro excluído, $\rho \wedge \neg \rho$: De duas proposições contraditórias, isto é, uma nega a outra, uma delas é verdadeira.
- Princípio da não-contradição, $\neg(\rho \vee \neg\rho)$: Entre duas proposições contraditórias, uma delas é falsa.

Dentro desse raciocínio a lógica clássica é binária; portanto, uma declaração é falsa ou verdadeira, não admitindo ser ao mesmo tempo parcialmente verdadeira e falsa.

2.2.1 As lógicas não-clássicas

Os estudos de tomadas de decisão para aplicações práticas demandam outros tipos de lógicas não fundamentadas nas regras da lógica clássica, que são denominadas lógicas não clássicas. Assim, estas lógicas violam as propriedades da lógica clássica que não admite indefinições, ambigüidades e contradições.

As lógicas não-clássicas estabelecem os conceitos de dualidade, sendo algo que pode e deve coexistir com seu oposto para se obter melhor precisão nas conclusões para a tomada de decisão. Sem muito rigor elas compõem dois grupos:

- As que complementam o escopo da lógica clássica;
- As que rivalizam com a lógica clássica.

As lógicas que pertencem à primeira categoria são chamadas de complementares da clássica, pois, possuem seus aspectos nos itens que a lógica clássica não é capaz de expressar. Exemplos de lógicas nessa categoria são: as lógicas epistêmicas, as lógicas modais tradicionais, as lógicas intencionais, as lógicas de ação, as lógicas de ações físicas, as lógicas combinatórias, as lógicas condicionais, entre outras.

As lógicas que pertencem a segunda categoria são aquelas que derrogam os princípios fundamentais das lógicas clássicas (heterodoxas), por meio da restrição ou modificação.

Motivados principalmente pelos avanços experimentados, sobretudo, da Inteligência Artificial, foram propostos vários sistemas lógicos para melhor representar conhecimento necessário para resolver problemas práticos. Alguns exemplos são: as lógicas intuicionistas, as lógicas não-monotônicas, as lógicas multivaloradas (ou lógicas polivalentes), a lógica de Lukasiewicz, a lógica de Post, a lógica de Godel, a lógica de Kleene, a lógica de Bochvar.

Por fim, com estudos de importância filosófica e uma matemática construída, surgem a teoria dos conjuntos aproximativos, lógicas paracompletas (que restringem o princípio do terceiro excluído), lógicas paraconsistentes (que restringem o princípio da não-contradição: sistemas C_n , lógicas anotadas, lógicas do paradoxo, lógicas discursivas, lógicas dialéticas, entre outras), lógicas não-aléticas (que são simultaneamente paracompletas e paraconsistentes), lógicas livres e outras (DA SILVA FILHO, 2008).

2.2.2 Aspectos históricos da Lógica Paraconsistente

Os precursores da lógica paraconsistente foram o lógico polonês *J. Lukasiewicz* e o filósofo russo *N. A. Vasilév*, que por volta de 1910, de maneira independente, sugeriram a possibilidade de uma lógica que restringiria, por exemplo, o princípio de contradição. *Vasilév* chegou a articular determinada lógica, que ele batizou de lógica imaginária (DA SILVA FILHO, 2008).

O primeiro lógico a estruturar um cálculo proposicional paraconsistente foi o polonês *S. Jaskowski*, discípulo de *Lukasiewicz*, que em 1948 publicou suas idéias sobre lógica e contradição, mostrando como se poderia construir um cálculo sentencial paraconsistente tendo motivação conveniente.

O sistema de *Jaskowski*, por ele chamado de lógica discursiva, desenvolveu-se posteriormente (a partir de 1968) em virtude das obras de autores como *J. Kota*, *L. Furmanowski*, *L. Dubikajtis*, *N. C. A. da Costa* e *C. Pinter*. Assim, chegou-se a construir uma verdadeira lógica discursiva, englobando um cálculo de predicados de primeira ordem e uma lógica de ordem superior.

Os sistemas iniciais de lógica paraconsistente, contendo todos os níveis lógicos, envolvendo cálculos proposicionais, de predicados e de descrições bem como lógicas de ordem superior, devem-se a *N.C.A. da Costa* (1954 em diante). Isto se realizou de maneira independente dos trabalhos dos autores mencionados como precursores.

Atualmente existem, inclusive, sistemas paraconsistentes de teorias de conjuntos estritamente mais fortes do que os clássicos, considerados subsistemas estritos e matemáticos paraconsistentes. As primeiras versões algébricas dos sistemas paraconsistentes surgiram por volta de 1965 e são conhecidos como álgebras de *Curry*, em homenagem ao lógico americano *H. Curry*. As semânticas iniciais dos sistemas paraconsistentes foram investigadas por volta de 1976 e são conhecidas como semântica de valorações.

A expressão “*lógica paraconsistente*” foi cunhada por *Francisco Quesada*, numa conferência pronunciada durante III Simpósio Latino-Americano de Lógica matemática, realizado na Universidade Estadual de Campinas – SP. Literalmente “paraconsistente” significa ao lado da consistência.

2.2.3 Teorias inconsistentes e teorias triviais

A mais importante razão da consideração da lógica paraconsistente foi obter teorias nas quais inconsistências sejam permitidas sem o perigo da trivialização. Em lógicas que não distingam convenientemente da lógica clássica, por exemplo, com respeito ao conceito de negação, em geral é válido o esquema $A \rightarrow (\neg A \rightarrow B)$ (em que ‘*A*’ e ‘*B*’ são fórmulas, ‘ \neg ’ é a negação de ‘*A*’ e ‘ \rightarrow ’ é o símbolo de implicação: de uma contradição, toda fórmula pode ser deduzida – ou seja, toda fórmula passa a ser verdadeira.

Admitindo como premissas fórmulas contraditórias *A* e $\neg A$.

Assim, se $A \rightarrow (\neg A \rightarrow B)$ constitui um esquema válido. Levando-se em conta as premissas apresentadas pela regra de dedução *Modus Ponens* (de *A* e de $A \rightarrow B$ deduz *B*) tem-se $\neg A \rightarrow B$ é arbitrária. Aplicando novamente a regra de *Modus Ponens* a essa última fórmula obtemos *B*. Porém, a fórmula *B* é arbitrária. Assim, de fórmulas contraditórias pode-se deduzir qualquer afirmação. Esse é o fenômeno da trivialização (DA SILVA FILHO, 2008).

2.2.4 Princípios conceituais da Lógica Paraconsistente

A seguir tem-se um resumo dos princípios teóricos da lógica paraconsistente como apresentado em (DA COSTA, 1999).

Seja T uma teoria fundada sobre uma lógica L , e suponha-se que a linguagem de T e de L contenha um símbolo para a negação \neg se houver mais de uma negação, uma delas deve ser escolhida, pelas suas características lógicas formais. A teoria T é *inconsistente* se ela possuir teoremas contraditórios; isto é, um é a negação do outro; caso contrário, T é *consistente*. A teoria T é *trivial* se todas as fórmulas da lógica $L \neg$ ou todas as fórmulas fechadas de $L \neg$ forem teoremas de T ; em hipótese contrária, T é *não-trivial*.

Analogamente, a mesma definição aplica-se a sistemas de proposições, conjunto de informações, etc. (levando-se em conta, naturalmente, o conjunto de suas conseqüências). Na lógica clássica e em muitas categorias de lógica, a consistência desempenha papel importante. Com efeito, na maioria dos sistemas lógicos usuais, se uma teoria T é trivial, então T é inconsistente e reciprocamente. Em outras palavras, lógicas como essas não separam os conceitos de inconsistências e de trivialidade.

Uma lógica L chama-se *Paraconsistente* se puder servir de base para teorias inconsistentes, mas não-triviais, ou como diz, uma Lógica Paraconsistente tem a capacidade de manipular sistemas inconsistentes de informações sem torna-se trivial.

Uma lógica L chama-se *Paracompleta* se ela puder ser a lógica subjacente as teorias nas quais se infringe a lei do terceiro excluído na seguinte forma: de duas proposições contraditórias uma delas é verdadeira.

Chama-se uma lógica *Não-Alética* quando esta for *Paracompleta* e *Paraconsistente* simultaneamente.

2.3 A Lógica Paraconsistente anotada de anotação com dois valores ($LPA2v$)

A anotação pode ser composta por $1, 2..n$ valores. Portanto, pode-se obter maior poder de representação sobre as anotações, ou evidências, expressam o conhecimento sobre a proposição p se a representação da anotação, em vez de ser feita por um único símbolo, for formada por dois símbolos que são representados por dois valores. Sendo τ o conjunto de pares ordenados de valores de grau de crença e grau de descrença que podem ser atribuídos a uma mesma proposição (Figura 2.2). Desse modo, pode-se utilizar um reticulado formado por pares ordenados, tal que $\tau = \{(\mu_1, \mu_2) | \mu_1, \mu_2 \in [0,1]\} \subset \mathfrak{R}$ (DA SILVA FILHO, 2008).

Lê-se: Há um conjunto que possui os valores dos graus de crença e descrença, tal que, os graus de crença e descrença pertençam ao intervalo fechado $[0,1]$ contido no conjunto dos números reais.

Nesse caso, também é fixado uma operação $\sim:|\tau|\rightarrow |\tau|$ em que o operador (\sim) constitui o símbolo lógico de negação \neg do sistema considerado. Os outros valores do reticulado são:

- \perp indica o mínimo de $\tau = (0,0)$
- \top indica o máximo de $\tau = (1,1)$
- \sup indica a operação de supremo
- \inf indica a operação de ínfimo supremo

Um reticulado de quatro vértices associado à Lógica Paraconsistente Anotada de Anotação com dois valores ($LPA2v$) pode ser representado no quadrado unitário no plano cartesiano, conforme a Figura 2.2.

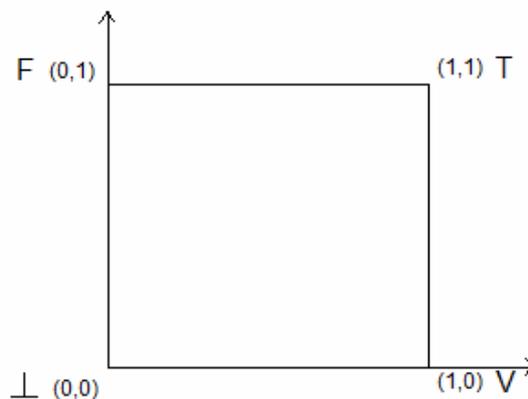


Figura 2.2 Reticulado finito de Hasse com anotação da $LPA2v$

\top = Inconsistente = $p(1,1)$

F = Falso = $p(0,1)$

V = Verdadeiro = $p(1,0)$

\perp = Indeterminado = $p(0,0)$

O primeiro elemento do par ordenado $p(\mu_1, \mu_2)$, (μ_1) representa o grau de crença em que sustenta a proposição p , e o segundo elemento (μ_2) representa o grau de descrença que nega ou rejeita a proposição p . Nos limites tem-se:

- $(\mu_1, \mu_2) = (1,1)$ indica “existência de grau de crença e descrença total”
- $(\mu_1, \mu_2) = (0,1)$ indica “existência de grau de crença nula e descrença total”
- $(\mu_1, \mu_2) = (1,0)$ indica “existência de grau de crença total e descrença nula”
- $(\mu_1, \mu_2) = (0,0)$ indica “existência de grau de crença e descrença nula”

a) Considerações sobre o reticulado associado à Lógica Paraconsistente anotada de anotação com dois valores ($LPA2v$)

Uma das interpretações válidas da Lógica Paraconsistente é descrita em (DA COSTA, 1999) e está resumida a seguir:

- Se p é um símbolo proposicional e $\mu_1 \in \tau$ é uma constante de anotação, então $p\mu_1$ é uma fórmula (atômica).
- Se p é um símbolo proposicional e $\mu_2 \in \tau$ é uma constante de anotação, então $p\mu_2$ é uma fórmula (atômica).
- Se A e B são fórmulas quaisquer, então $(\neg A)$, $(A \vee B)$, $(A \wedge B)$ e $(A \rightarrow B)$ são fórmulas.

Uma expressão da forma $p(\mu_1, \mu_2)$ é interpretada como: Crê-se em p com grau de crença até μ_1 e grau de descrença até μ_2 . As fórmulas: $(\neg A)$ é interpretada como a negação – ou negação fraca; $(A \vee B)$ é interpretada como a conjunção de A e B ; $(A \wedge B)$ é interpretada como disjunção de A e B ; e, $(A \rightarrow B)$ é interpretada como a implicação de B por A .

Assim sendo, tem-se: Seja então o reticulado de Hasse com anotação de dois valores, onde $\tau = \{(\mu_1, \mu_2) \mid \mu_1, \mu_2 \in [0,1] \subset \mathcal{R}\}$. Se p é uma fórmula básica, o operador $\sim: |\tau| \rightarrow |\tau|$, definido agora como $\sim(\mu_1, \mu_2) = (\mu_2, \mu_1)$, onde $\mu_1, \mu_2 \in [0,1] \subset \mathcal{R}$ e considera-se (μ_2, μ_1) uma anotação de p .

Uma interpretação para a Lógica Paraconsistente Anotada de Dois Valores ($LPA2v$) é apresentada em (DA COSTA, 1999). Sejam P um conjunto de símbolos proposicionais e F o conjunto de fórmulas, uma interpretação para $LPA2v$ é uma função $I: P \rightarrow |\tau|$. Dada como uma interpretação de I pode-se associar a uma valoração $VI: F \rightarrow \{0,1\}$ assim definida, onde F é uma fórmula dos pares ordenados $(0,1)$.

Se $p \in P$ e $\mu \in |\tau|$, então:

- $VI(p\mu) = 1$ se e somente se $I(p) \geq \mu$ e
- $VI(p\mu) = 0$ se e somente se não é o caso que $I(p) \geq \mu$;

Pela condição acima se tem que $VI(p\mu) = 1$ se e somente se $I(p) \geq \mu$, ou seja, $p\mu$ é verdadeira, segundo a interpretação I se a interpretação dada a p , $I(p)$, for maior ou igual ao “valor de crença” μ com respeito à proposição p . Ela é falsa, caso contrário.

Se puder demonstrar que há interpretações I e proposições $p\mu$, tais que $VI(p\mu) = 1$ e $VI(\neg p\mu) = 1$, ou seja, tem contradições verdadeiras nesta lógica. Isto é intuitivo se considerar proposições do tipo $p(0,5; 0,5)$. Sua negação $\neg p(0,5; 0,5)$ equivale a $p\sim(0,5; 0,5)$ que é também $p(0,5; 0,5)$. Ora, se $p(0,5; 0,5)$ for verdadeira, então é claro que sua negação também é verdadeira. Se ela for falsa, sua negação também é falsa.

b) Representação gráfica no plano cartesiano do reticulado de 12 posições da Lógica Paraconsistente anotada de anotação com dois valores ($LPAv2$)

A representação dada na Figura 2.2, contém informações do desenvolvimento de um algoritmo básico para a utilização da Lógica Paraconsistente (DA COSTA, 1999), pois a partir desse é possível a criação de novos algoritmos, cujo, sua finalidade é analisar e retornar os valores de certeza e contradição (Evidência Favorável e Contrária). Sua base é descrever a Lógica Paraconsistente definindo assim, a Célula Neural Artificial Paraconsistente, como base para descrever todas as células criadas para a formação da Rede Neural Artificial Paraconsistente (DA SILVA FILHO, 2001).

A Figura 2.3, apresenta um gráfico com as várias subdivisões e interpretações para o reticulado 12 da Lógica Paraconsistente, no Quadrado Unitário do Plano Cartesiano ($QUPC$).

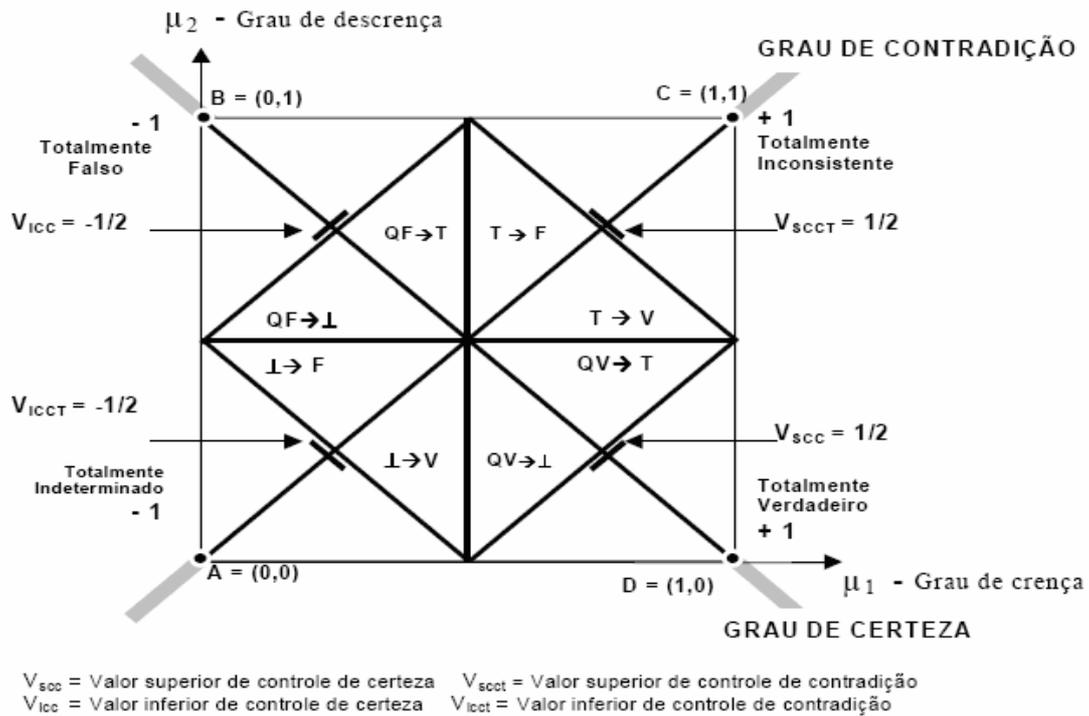


Figura 2.3 - Quadrado unitário do plano cartesiano (reticulado 12 posições)

FONTE: DA COSTA (1999)

No *QUPC* os segmentos determinados pelos pares ordenados $B = (0,1)$ e $D = (1,0)$, simbolizando por segmento de reta BD denomina-se uma linha perfeitamente definida (DA COSTA, 1999), significa que os valores de incidente são iguais aos valores determinados na matriz em análise, e pelos pares $A = (0,0)$ e $C = (1,1)$, simbolizado por segmento de reta AC , que se denomina como uma linha perfeitamente indefinida, isto significa que para todos os valores dos graus de crença existe um correspondente idêntico no grau de descrença.

Os eixos μ_1 e μ_2 representam os graus de crença e descrença. Os valores dos pontos dos pares cartesianos em seus estados estão subdivididos em:

Definições dos Estados Extremos

- V = Verdadeiro;
- F = Falso;
- T = Inconsistente;
- ⊥ = Indeterminado.

Definições dos Estados não-Extremos

$Qf \rightarrow \top$ = Quase falso tendendo ao Inconsistente

$Qf \rightarrow \perp$ = Quase falso tendendo ao Indeterminado

$\top \rightarrow V$ = Inconsistente tendendo ao Verdadeiro

$\top \rightarrow F$ = Inconsistente tendendo ao Falso

$Qv \rightarrow \top$ = Quase verdade tendendo ao Inconsistente

$Qv \rightarrow \perp$ = Quase verdade tendendo ao Indeterminado

$\perp \rightarrow V$ = Indeterminado tendendo ao Verdadeiro

$\perp \rightarrow F$ = Indeterminado tendendo ao Falso

As posições utilizadas na abordagem paraconsistente deste trabalho no *QUPC* (Figura, 2.3) são todos os valores extremos e apenas dois valores não-extremos, descrito como: Inconsistente tendendo a Verdadeiro e Quase verdade tendendo a Inconsistente.

2.4 Modelo matemático do neurônio artificial

As Redes Neurais Artificiais (*RNAs*) são inspiradas no funcionamento do cérebro, tentando assim imitá-lo por meio de técnicas computacionais com o fim de adquirir, armazenar e utilizar o conhecimento.

Algumas definições básicas sobre as redes neurais artificiais são:

- Haykin (1994) define uma Rede Neural como sistemas distribuídos massivamente paralelos que tem uma propensão natural para armazenar o conhecimento experimental e disponibilizá-lo para uso. Sendo que, em dois aspectos lembram o cérebro humano:
 - O conhecimento é adquirido pela rede através de um processo de aprendizado;
 - Conexões entre os neurônios, conhecidos como pesos sinápticos, são usadas para armazenar o conhecimento.

- Segundo Kohonen (1972), as *RNAs* são definidas como redes massivamente paralelas e interconectadas, de elementos simples. Esses elementos devem interagir como dados do mundo real, assim como o sistema nervoso biológico.

Os neurônios são as unidades fundamentais que compõem o cérebro. Cada neurônio é constituído de um corpo celular, ou *soma* que é o núcleo da célula; partindo do núcleo existem vários filamentos, chamados de *dendritos* e um mais longo denominado de *axônio*. A junção entre dois neurônios dá-se o nome de *sinapse* por os sinais se propagam de um neurônio para outro.

Substâncias químicas transmissoras são liberadas pelas sinapses e entram nos dendritos, aumentando ou baixando o potencial elétrico da célula. Quando o potencial alcança um limiar, um pulso elétrico, chamado de *potencial de ação*, é enviado pelo axônio. As sinapses que aumentam o potencial elétrico são chamadas de *excitatórias*, e as que baixam *inibitórias* (RUSSELL e NORVIG, 1995). A caricatura da estrutura de um neurônio biológico pode se observado na Figura 2.4.

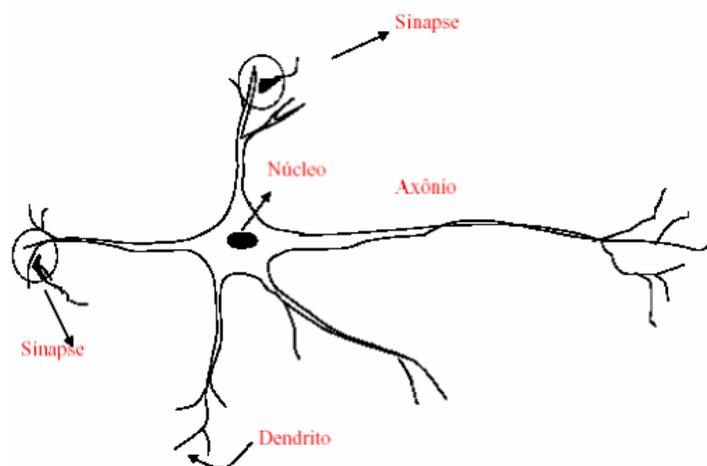


Figura 2.4 - Estrutura de um Neurônio Biológico

Assim como nos sistemas biológicos, as redes neurais artificiais, também têm como unidade principal o neurônio, que são conectados por ligações denominadas *conexões sinápticas*. Cada conexão age de maneira ponderada sobre sua entrada, formando um peso sináptico.

As *RNAs* apresentam como principais vantagens, suas características de adaptabilidade, generalização e tolerância a ruídos (HAYKIN, 1994). Essas características são de extrema importância na aplicação das redes neurais em diferentes tipos de problemas.

Existe uma grande diversidade de modelos de redes neurais, entretanto qualquer modelo de RNA pode ser descrito pela especificação dos seguintes componentes básicos:

- Modelo do neurônio;
- Estrutura da rede;
- Algoritmo de Aprendizado.

Um neurônio é uma unidade de processamento de informações fundamentais para operação de uma Rede Neural (HAYKIN, 1994).

São três elementos básicos que constituem um neurônio:

- Um conjunto de sinapses, que são caracterizadas por pesos.
- Um somador dos sinais de entrada, ponderados pelas suas respectivas sinapses.
- Uma função de ativação para limitar a amplitude do sinal de saída do neurônio. Tipicamente os sinais de saída são normalizados nos intervalos [0, 1] ou [-1, 1].

Na Figura 2.5 é mostrado um modelo de neurônio que possui, além dos elementos acima, um limiar b_k , que tem o efeito de subtrair a entrada u_k da função de ativação.

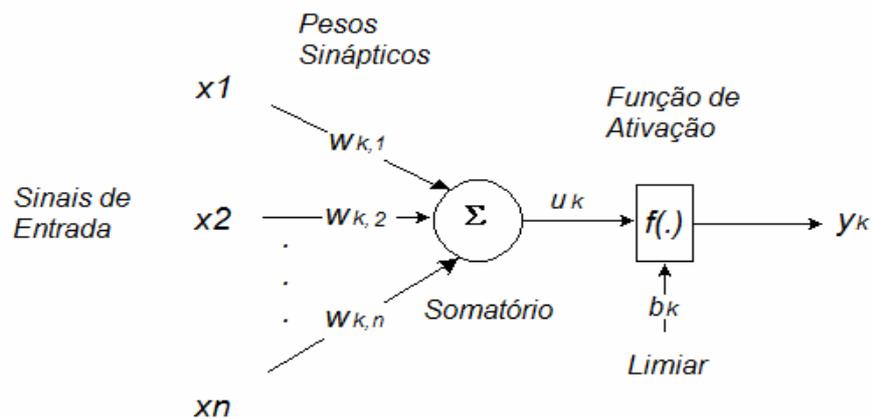


Figura 2.5 - Modelo de um neurônio não-linear

Matematicamente um neurônio k pode ser descrito como:

$$v_k = \sum_{j=1}^p w_{kj} x_j - b_k \quad (2.1)$$

$$f(.) = y_k = \varphi(v_k) \quad (2.2)$$

em que x_1, x_2, \dots, x_p são sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{kp}$ são pesos sinápticos do neurônio k ; v_k é a diferença entre a combinação linear dos sinais de entrada ponderadas pelos sinápticos e b_k é o limiar do neurônio; $f(.)$ é a função de ativação e y_k é o sinal de saída do neurônio.

Existem diversas funções de ativação que podem ser aplicadas nas redes neurais artificiais, as mais comuns estão representadas na Figura 2.6.

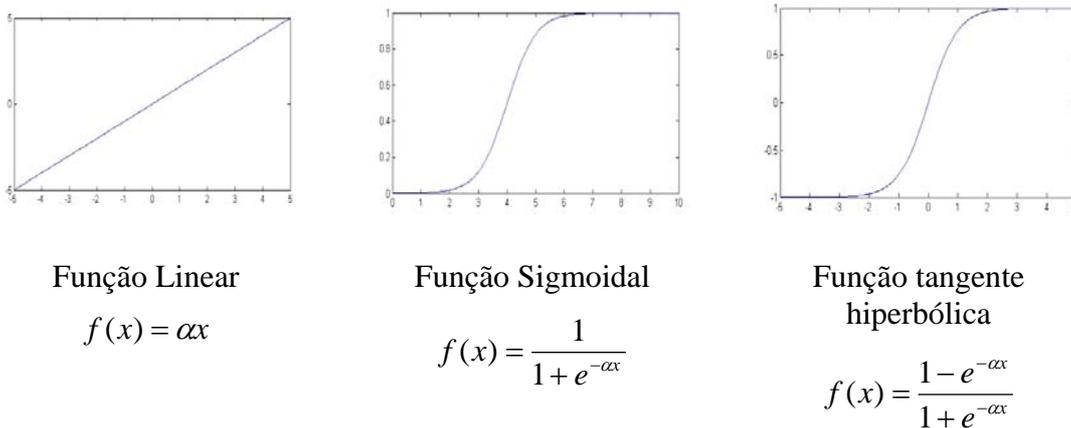


Figura 2.6 – Funções de ativação

2.4.1 Rede Neural de Funções de Base Radial

A construção de uma Rede Neural de Funções de Base Radial - *RBF* em sua forma mais básica envolve duas camadas, conforme mostra a Figura 2.7. Os nós da camada de saída calculam a combinação linear das funções de base radial. As funções de base radial na camada escondida produzem uma resposta localizada para o estímulo (padrão) de entrada, isto é, eles produzem uma resposta significativamente diferente de zero, somente quando o padrão de entrada está dentro de uma região pequena localizada no espaço de entrada. Por esta razão, tal rede neural algumas vezes é referenciada na literatura como redes de campos receptivos localizados (HAYKIN, 2001). Para o funcionamento da *RBF* são necessários os centróides e uma função de ativação relacionada com uma função de distribuição probabilística, por exemplo, gaussiana.

Dado um vetor de entrada, a saída de um nó simples será (Eq. 2.4):

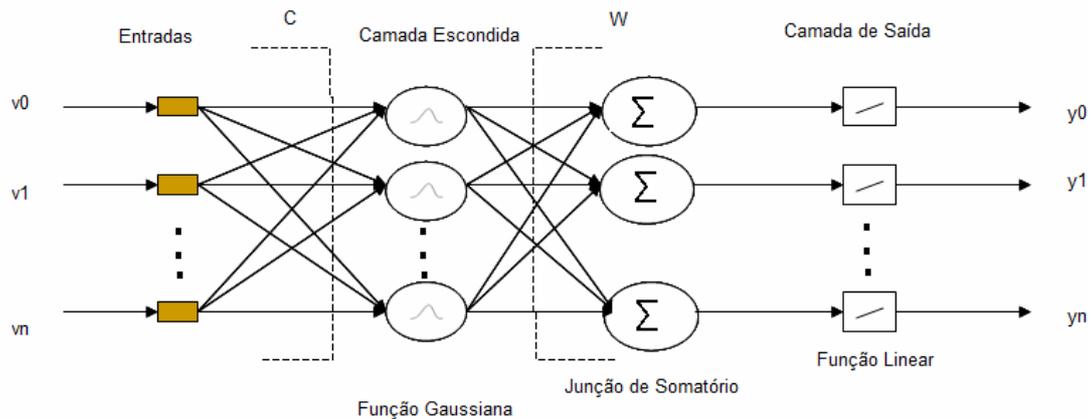


Figura 2.7 - Estrutura básica da Rede de Funções Radiais – RBF1

Dados N -vetores X (dados de entrada) de p -exemplares, representando p -classes (p classes dos meses no intervalo de tempo de 1980-1997), a rede é iniciada com o conhecimento dos centros representados na matriz C (Eq. 2.3).

$$C = [c_1 c_2 \dots c_k]^T \quad (2.3)$$

em que c_1, c_2, \dots, c_k representam o k centros, dos k vetores encontrados com centros. A camada de saída realiza a soma ponderada das saídas da camada escondida. Quando apresentando um vetor de entrada para a rede dado por:

$$y = W \cdot f(\|X - C\|) \quad (2.4)$$

em que f representa o vetor de saída funcional da camada escondida; X é o vetor de entrada; C é a matriz de centros; W é a matriz de pesos; e y é a saída da rede (a saída será um vetor se existirem múltiplas saídas).

O aprendizado na camada intermediária é executado usando tipicamente um algoritmo de "cluster", ou um algoritmo supervisionado para achar os centros (nós c na camada escondida). Neste trabalho é utilizada uma RNAP para determinar os centros (que são as conexões entre a camada de entrada e a camada intermediária).

A rede RBF e a rede perceptron de múltiplas camadas (MLP) são exemplos de redes neurais (feedforward) não-lineares. Ambas são aproximadores universais de funções, podendo uma rede RBF substituir uma MLP específica, ou vice-versa (HAYKIN, 2001). Contudo, estas duas redes diferem uma da outra em alguns importantes aspectos, como:

- Uma *RBF* (na sua forma mais básica) tem apenas uma camada intermediária, enquanto uma *MLP* pode ter uma ou mais camadas intermediárias;
- Os cálculos feitos nos nós de uma *MLP* localizados na camada intermediária ou na camada de saída diferem do cálculo dos nodos nas camadas escondida e de saída de uma *RBF*;
- A camada intermediária na *RBF* é não linear, enquanto que a camada de saída é linear. Já na *MLP*, usada como um classificador, as camadas intermediárias e de saída podem ser não-lineares; contudo, quando a *MLP* é usada para resolver problemas de regressão não-linear, uma camada linear na saída é geralmente a escolhida;
- A *RBF* utiliza cálculo da distância Euclidiana entre o vetor de entrada e o vetor que representa o centro de cada unidade na camada intermediária, enquanto que a *MLP* faz uso do cálculo utilizando o produto interno do vetor de entrada e o vetor peso sináptico daquela unidade.
- A *MLP* no processo de treinamento é na maioria das vezes lenta, dependendo do algoritmo de treinamento, sendo que os requisitos de memória são pequenos e o tempo de classificação é rápido. Por sua vez, a *RBF* no processo de treinamento é rápida e o requisito de memória é relativamente alto com tempo de classificação médio;
- Finalmente, a *MLP* constrói aproximadores globais para mapas de entrada-saída não-lineares. Conseqüentemente, eles são capazes de generalizar em regiões do espaço de entrada onde os dados de treinamento estão disponíveis. Por outro lado, *RBF* usando não-linearidade local com decréscimo exponencial, como é o caso da função de gaussiana, constrói aproximações locais para mapas de entrada-saída. Neste sentido, as *RBFs* são capazes de aprender mais rápido e têm sensibilidade reduzida com respeito à ordem de apresentação dos dados de treinamento.

Foram utilizadas duas *RBFs*, a primeira (*RBF1*) descrita na Figura 2.7 que possui vários vetores de saídas, a segunda (*RBF2*) possui como entradas o treinamento da *RBF1* e os dados dos vetores ao qual se deseja efetuar a previsão, esta última considerada como

centros, com apenas um vetor de saída que são os valores preditos, como descrita na Figura 2.8.

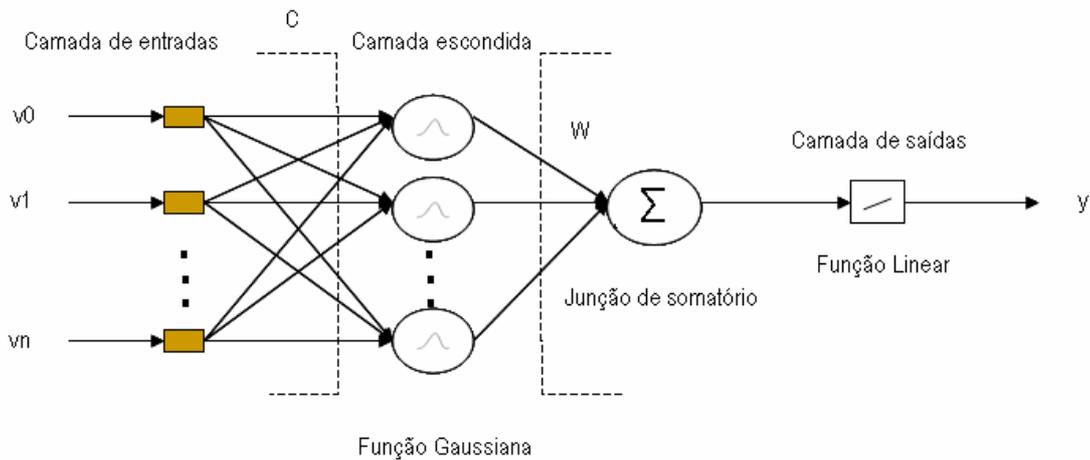


Figura 2.8 - Estrutura básica da Rede de Funções Radiais – RBF2

No contexto deste trabalho, a *RBF* foi escolhida por apresentar a possibilidade de usar os vetores encontrados pela rede neural paraconsistente, como centros de clusters associados aos padrões presentes nos dados analisados.

2.4.2 Rede Neural Artificial Paraconsistente

O modelo de Rede Neural Artificial Paraconsistente (*RNAP*) tem a finalidade de possibilitar a construção de unidades artificiais utilizando modelos mais próximos dos neurônios biológicos.

Uma *RNAP* utiliza a Equação Estrutural Básica (*EEB*), descrita como:

$$\mu r = \frac{\mu_1 - \mu_2 + 1}{2} \quad (2.5)$$

Lê-se μr = grau resultante, μ_1 = grau de crença e μ_2 = grau de descrença. A finalidade da *EEB* é gerar um sinal normalizado que implica na suavização desses valores como resultados da rede.

Na *RNAP* é necessário computar os sinais de graus resultantes (graus de crença e descrença), que são valorados no intervalo fechado de números reais [0,1]. Esses sinais são transmitidos por valores equacionados pela *EEB* através de células (métodos) descritas com base na Lógica Paraconsistente (Apêndice A).

Quando o valor do grau de crença é 1 considera-se como uma confirmação da proposição ou do padrão aplicado na entrada; se o grau de crença é 0 (zero) considera-se como uma negação lógica da proposição ou do padrão aplicado na entrada, ou se o grau de crença é $\frac{1}{2}$ (meio) considera-se como uma indefinição lógica da proposição ou do padrão aplicado na entrada.

As equações são muito simples nas Células Neurais Artificiais Paraconsistentes, que são os fundamentos lógicos da rede neural paraconsistente, elas utilizam a *EEB* para equacionar os sinais e, a partir do resultado obtido, sugere uma tomada de decisão que é transmitida em forma de grau resultante para outras Células Paraconsistentes. A conexão entre as células são consideradas sinapses e o seu conjunto forma as Unidades Neurais Artificiais Paraconsistentes que em alguns casos são consideradas como *Para-Perceptrons*, isto quando há pelo menos uma Célula Paraconsistente de Conexão Analítica e uma Célula Paraconsistente de Aprendizagem conectadas.

As interligações que recebem o nome de conexões sinápticas entre os *Para-Perceptrons*, formam uma rede por onde trafegam sinais representativos de proposições ou padrões que após as análises serão convertidos em ações, as quais são subentendidas como evidência favorável ou contrária ao resultado da análise desejada.

a) Células Neurais Artificiais Paraconsistentes

A Célula Neural Artificial Paraconsistente Básica (Apêndice A) é uma representação do Algoritmo Para-Analisador (ABE, 1999), possuindo como base apenas duas equações que determinam os Graus de Evidência Favorável e Contrário representados na descrição do reticulado 12 da Lógica Paraconsistente.

O processamento dos sinais com as equações do algoritmo para-analisador permite descobrir com que medida ou grau de evidência pode-se afirmar que uma proposição lógica seja falsa, verdadeiro, inconsistente ou indeterminada. A representação gráfica desta célula encontra-se na Figura 2.9 a seguir:

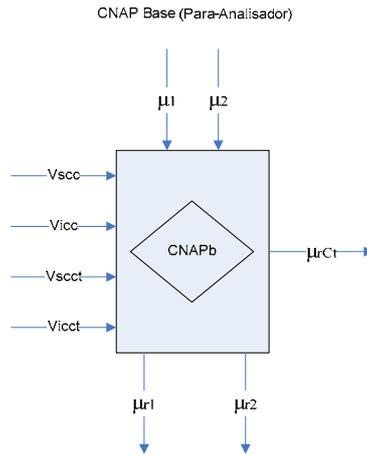


Figura 2.9 – Célula Artificial Paraconsistente Básica

Com a Célula Neural Artificial Paraconsistente Básica – *CNAPb* cria-se um conjunto de Células Neurais Artificiais Paraconsistentes, que tem como característica a normalização das saídas, pois, a saída pode representar o grau de evidência favorável dada pelo grau de certeza ($G_c = \mu_1 - \mu_2$) e/ou o grau de evidência contrária dada pelo grau de contradição ($G_{ct} = \mu_1 + \mu_2 - 1$) pertencente ao intervalo real $[-1, 1]$, ambos não podem ser utilizados como entradas de uma próxima célula.

O fator de tolerância à certeza, ftC , e o fator de tolerância à contradição, $ftCt$, servem para simplificar o funcionamento dessa célula sendo utilizados diretamente para calcular os seguintes limites: $vscC$ – Valor Superior de Controle a Certeza; $vicc$ – Valor Inferior de Controle a Certeza; $vscct$ – Valor Superior de Controle a Contradição; e, $vicct$ – Valor Inferior de Controle a Contradição;

$$vscC = \frac{1 + ftC}{2} \quad (2.6)$$

$$vicc = \frac{1 - ftC}{2} \quad (2.7)$$

$$vscct = \frac{1 + ftCt}{2} \quad (2.8)$$

$$vicct = \frac{1 - ftCt}{2} \quad (2.9)$$

b) Fatores de Tolerâncias

Na *RNAP* existem alguns fatores importantes para a faixa de atuação da Rede Neural, que se definem como:

- *Fator de tolerância à contradição (ftCt)*: Define-se a tolerância ao grau de contradição através de um valor normalizado: $0 \leq ftCt \leq 1$. A partir disto, se $|G_{ct}| < ftCt$, então, $\mu_r = (\mu_1 - \mu_2 + 1) / 2$, e ainda o sinal de resposta à contradição é $\mu_{rct} = 0$; caso contrário, $\mu_r = 1/2$ e $\mu_{rct} = G_{ct}$.
- *Fator de tolerância à certeza (ftC)*: Da mesma forma pode-se definir o fator de tolerância à certeza: $0 \leq ftC \leq 1$. A partir disto se $|G_c| > ftC$ então $\mu_r = (\mu_1 - \mu_2 + 1) / 2$, caso contrário $\mu_r = 1/2$.
- *Fator de tolerância de reconhecimento de padrão (ftR)*: Dado por um valor numérico de 0 a 1. A similaridade (*sm*) entre dois elementos será calculada por x_n dividido por k_n , sendo X_n o elemento n do vetor X que está sendo comparado com o elemento k_n , elemento n do vetor K . Caso todas as similaridades $sm(n)$ (com n variando de 0 a 1) calculadas sejam superiores ao fator de reconhecimento de padrão (*ftR*), diz-se que o vetor X é similar ao vetor K , com fator de similaridade mínima e *ftR*. Outra forma de se calcular o reconhecimento por similaridade é calcular a similaridade total ($sm(t)$), dada pela somatória de todas as similaridades $sm(n)$ entre os elementos, dividida pelo número de elementos do vetor.

Caso $sm(t) = ftR$, diz-se que o vetor foi reconhecido com fator de similaridade $sm(t)$, caso contrário, não se considera como reconhecido.

- *Fator de aprendizagem (ftA)*: Esse fator é ajustado em seu valor físico para a configuração do aplicativo podendo sofrer alterações, assim, novos valores lógicos são determinados durante a execução da *RNAP*. Esse valor é determinado no intervalo fechado $[0,1]$ como um valor real.

c) Evidência Favorável e Contrária

Os valores dos graus de evidência favorável e contrária têm seus valores dados no intervalo $[-1,1]$. Esses são utilizados para resultar melhores dados de análises, onde se tenta uma semelhança na forma humana de analisar e encontrar as soluções dos problemas.

3. METODOLOGIA

Esta dissertação tem como objetivo conceber um método de redução de dados climáticos de reanálises para obtenção de um modelo de previsão sinóptica de clima.

Nos parágrafos seguintes são descritos os diferentes passos adotados para desenvolver o trabalho.

Na seleção de dados adotou-se a mesma base de dados utilizada por Pessoa (2004) que coletou os dados da base de dados de reanálise do NCEP/NCAR (*National Centers for Environmental Prediction / The National Center for Atmospheric Research*) [<http://www.cdc.noaa.gov/data/reanalysis/reanalysis.shtml/>] para o período de janeiro de 1980 a dezembro de 2000, em uma área contida entre as latitudes [10° N, 35° S] e longitudes [80° W, 30° W], referente à América do Sul, com resolução espacial, em ambas as dimensões (x, y), de 2.5° e resolução temporal (t) de 1 mês.

Para a realização dos experimentos os dados dos anos de 1980-1997 foram selecionados para a criação dos perfis meteorológicos, enquanto que os dados dos anos de 1998-2000 foram utilizados para validar os modelos de previsão obtidos.

Para seguir com a abordagem de mineração de dados, os dados foram transformados para um espaço adimensional, ou seja, cada variável foi mapeada para o intervalo [0,1]. Os valores que correspondem à posição geográfica dos dados foram mantidos com seus valores originais.

O algoritmo aplicado na transformação dos dados considera a necessidade do algoritmo baseado na lógica paraconsistente para a determinação dos padrões.

A técnica utilizada caracteriza-se por ter a possibilidade de utilizar dois valores. O primeiro valor é o grau de crença e o segundo é grau de descrença calculado pela Equação 3.1. Estes valores são características da técnica baseada na lógica paraconsistente.

$$\mu_2 = 1 - \mu_1 \quad (3.1)$$

Os dados transformados são submetidos a um processo de aprendizado e memorização de longa duração dos históricos dos dados meteorológicos. A memorização acontece

com o armazenamento dos dados, discriminado no processamento da rede neural artificial paraconsistente.

A identificação dos padrões está relacionada com a classificação dos valores em grupos, por sua não-similaridade. Os registros que não possuem similaridades de acordo com os valores estimados das tolerâncias a “Certeza” (Crença) e “Contradição” (Descrença) são identificados como padrões para um determinado trimestre e automaticamente incluem os ciclos sazonais existentes para todas as regiões selecionadas e localizadas fisicamente por sua longitude e latitude.

O processo de identificação dos padrões é realizado da seguinte forma:

Identificam-se os padrões de um histórico conforme Figura 3.1.

Para minimizar o tempo de procura os registros idênticos foram desprezados, com isso houve um ganho nas buscas de aproximadamente 37,5% do tempo total.

Método de Otimização – Gerando Contradições

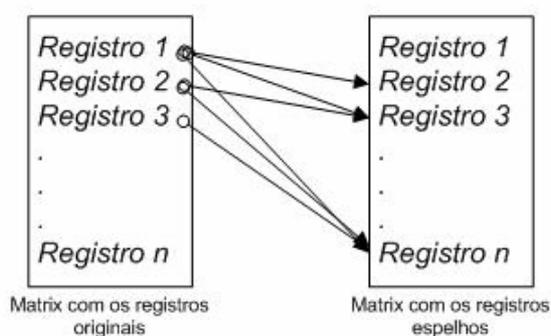


Figura 3.1 – Processo de busca dos registros

Quanto maior os fatores de tolerâncias (Certeza e Contradição) mais registros são identificados por não similaridades. Os valores que possuem similaridades aceitáveis são descartados na composição dos dados de identificação dos padrões.

Após a identificação dos padrões, estes formam os centros da *RBF*. Essa rede terá como entradas os sinais produzidos para a previsão de um ou três ciclos sazonais adiante. O treinamento da camada de saída da *RBF* é realizado para produzir a previsão dos atributos temperatura e precipitação.

As entradas da *RBF* são comparadas com os centros das funções de base radial pelo cálculo da distância euclidiana que é submetida, em seguida, à função de base radial. Nos experimentos conduzidos optou-se pela função Gaussiana com desvio padrão igual a 1.

O início da previsão ocorre no mês de Março, Abril e Maio de 1998 e sucessivamente para cada ciclo sazonal, assim, faz-se necessário o deslocamento dos dados para que sejam submetidos à *RNAP* na etapa de aprendizado e desta forma posso gerar novos centros.

Após o treinamento, foi realizada a validação dos modelos obtidos com os dados existentes no histórico dos anos 1998-2000. As saídas da rede *RBF*, tomada como previsões são comparadas com os valores reais existentes nos dados.

Para ser possível a previsão de forma eficaz foram estabelecidas duas regras dadas por:

- Na entrada da *RBF* é necessário identificar os valores do atributo que se deseja fazer a previsão.
- O resultado da *RBF* é um valor de previsão que necessita ser desnormalizado.

4. METEOROLOGIA E SELEÇÃO DA ÁREA DE ESTUDO

A meteorologia é definida como a ciência que estuda os fenômenos que ocorrem na atmosfera, e está relacionado ao estado físico, dinâmico, químico atmosférico e as interações entre elas e a superfície terrestre subjacente (INMET, 2003).

Em meteorologia há uma distinção entre tempo e clima que são conceitos usados para se entender o comportamento da atmosfera em diferentes "intervalos de tempo". O tempo é o estado da atmosfera em um determinado momento e lugar ou, é o estado da atmosfera com relação aos seus efeitos sobre a vida e as atividades humanas. Já o clima se refere às características da atmosfera inferidas por observações contínuas durante um longo período, como por exemplo, 30 anos (normal climatológica). O clima abrange um maior número de dados do que as condições do tempo para uma determinada área. Ele inclui considerações dos desvios em relação às médias, variabilidade, condições extremas e frequência de ocorrência de determinada condição de tempo. Assim, o clima representa uma generalização, enquanto o tempo lida com eventos específicos.

O clima tem influência direta sobre diversas atividades, tais como agricultura, a pesca, a geração e distribuição de energia elétrica, defesa civil, dentre outras. Por tantas tarefas dependerem do comportamento atmosférico, tanto a curto como em longo prazo, é importante entender os fenômenos naturais e assim se antecipar as possíveis calamidades que possam vir a ocorrer em casos de um clima atípico. A meteorologia está em contínuo aperfeiçoamento para cada vez tornar mais confiáveis e aumentar o prazo de previsão climática e do tempo. Entre as técnicas para a realização da previsão de tempo e clima são utilizados, pelos centros de previsão em todo o mundo os *modelos numéricos*.

Outro ponto importante é que uma região em análise é representada por uma grade, ou malha e a intersecção das linhas verticais e horizontais é um ponto da grade em questão, como mostra Figura 4.1.

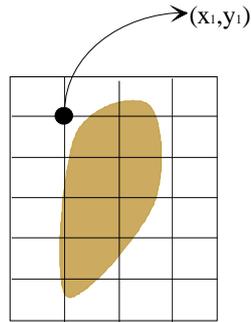


Figura 4.1 – Grade

Considera-se um breve relato de algumas técnicas utilizadas para a previsão do tempo ou clima em alguns centros de pesquisas meteorológicas dadas por:

a) Tipos de Modelo Numérico

Para previsão do clima e tempo existem os modelos numéricos, que é o nome dado à técnica que simula o estado da atmosfera, por meio de modelos físico-matemáticos resolvidos numericamente, através de técnicas computacionais. O prazo de previsão está diretamente relacionado com a resolução temporal (amostragem das variáveis de entrada, podendo ser em: minutos, horas, meses, etc.) e espacial (distância entre os pontos de grade) das variáveis. Em geral, modelos que trabalham com alta resolução (exemplo: 1 km) requerem um passo de integração menor, limitando o alcance de previsão em poucos dias. Já os modelos que operam com baixas resoluções (250 km, ver Figura 4.2), o alcance operacional da previsão pode chegar a ser mensal ou anual (GUTIÉRREZ, 2003).

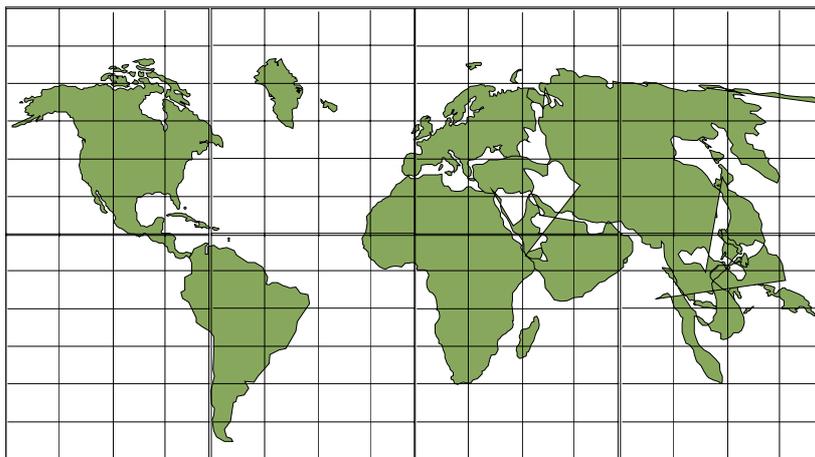


Figura 4.2 – Grade Global de baixa resolução

b) Previsão Climática

A previsão climática é uma estimativa do comportamento médio da atmosfera com alguns meses de antecedência. Por exemplo, pode-se prever se o próximo verão será mais quente ou mais frio que o normal, ou ainda, mais ou menos chuvoso. Todavia, tal estimativa não pode dizer exatamente quais serão a quantidade de chuvas ou quantos graus a temperatura estará mais ou menos elevada.

Para previsão climática, no *CPTEC* são utilizados modelos numéricos, alguns em caráter experimental, pois no Brasil e no mundo, essa é uma área que está em constante evolução com o propósito de torná-la mais confiável (*CPTEC*, 2003).

Neste trabalho são utilizados dados de reanálise que podem ser encontrados no endereço [<http://www.cdc.noaa.gov/data/reanalysis/reanalysis.shtml/>] oriundos do *NCEP/NCAR* (*National Centers for Environmental Prediction / The National Center for Atmospheric Research*) para o período de janeiro de 1980 a dezembro de 2000.

Estima-se que os dados de reanálise são o mais próximo dos fenômenos reais observados no ambiente estudado. A Tabela 4.1 descreve cada variável selecionada para o desenvolvimento do trabalho (seguindo o que foi proposto em Pessoa (2004)).

Tabela 4.1 – Atributos Meteorológicos utilizados

	Atributos	Descrição	Unidades de medida
1	mês	Mês	Inteiro
2	ciclo	Ciclo Sazonal	inteiro
3	lon	Longitude	°C
4	lat	Latitude	°C
5	temp	Temperatura – Temperatura da Superfície do Solo e a para as faixas continentais a interpolação com a Temperatura de Superfície do Mar.	°C
6	u850	Vento Zonal (850 hPa) – Componente do vento horizontal à superfície do planeta representado por u , é positivo no sentido de oeste para leste com direção (graus) vertical perpendicular a superfície no nível de pressão 850 hectoPascal, neste caso.	m/s
7	u500	Vento Zonal (500 hPa)	m/s
8	u300	Vento Zonal (300 hPa)	m/s
9	v850	Vento Meridional (850 hPa) - É positivo no sentido de sul para norte.	m/s
10	v500	Vento Meridional (500 hPa)	m/s

continua

Tabela 4.1 - Conclusão

11	v300	Vento Meridional (300 hPa)	m/s
12	shum	Umidade Específica – Medida acima 2m da superfície do solo, é a relação entre a massa de vapor de água e a massa de ar úmido em que o vapor de água está contido.	kg/kg
13	spres	Pressão atmosférica – Resulta da ação do ar atmosférico sobre os corpos nele inseridos.	mb
14	div	Divergência – Movimento do vento associado ao fluxo horizontal do ar para fora de uma região específica. Estando relacionado às variações de movimento vertical do vento e pressão atmosférica.	1/s
15	prec	Precipitação – Quantidade de chuva acumulada na superfície do solo.	mm/dia

As áreas escolhidas para o estudo estão apresentadas na Figura 4.3 e compreendem as coordenadas:

Área Total (Brasil): lon = 280°W, 330°W; lat = -35°S, 10°S;

Área 1: lon = 15.5°W, 25.5°W; lat = -7.5°S, 0°;

Área 2: lon = 45°W, 35°W; lat = -7.5°S, 0°;

Área 3: lon = 50.5°W, 60°W; lat = -22.5°S, -15°S;

Área 4: lon = 62.5°W, 52.5°W; lat = -27°S, -20°S;

Área 5: lon = 50°W, 60°W; lat = -35°S, -27.5°S;

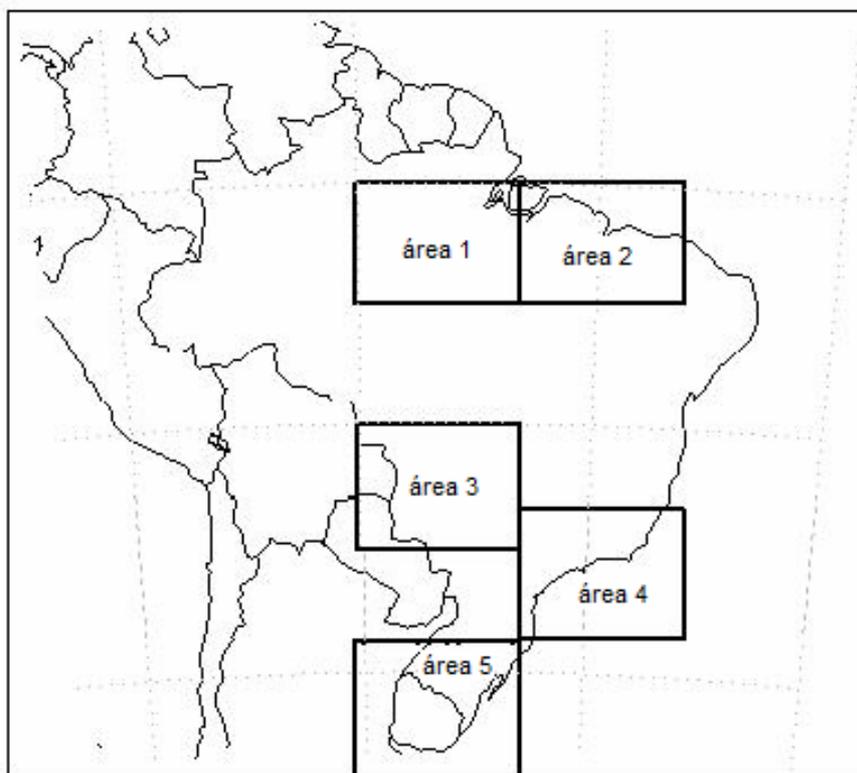


Figura 4.3 – Áreas selecionadas para as análises

Dos 21 anos de dados armazenados na base de dados, 72% foram reservados para treinamento, enquanto os outros 28% foram utilizados para validação, ou seja, para testar a abordagem de previsão climática desenvolvida neste estudo e verificar sua generalização.

As temperaturas da superfície do solo são interpolados com os dados de temperatura da superfície do mar (*TSM* ou do inglês *SST*) somente para as faixas continentais (longitudes que avançam ao mar), de modo a formar um só atributo denominado temperatura.

Foram incorporadas para as análises as componentes espaciais e temporais (*longitude*, *latitude* e *tempo*) mais os atributos de decisão (*temperatura* e *precipitação*), adicionalmente às variáveis mostradas na Tabela 4.1.

5. ABORDAGEM PARA A PREVISÃO DE DADOS METEOROLÓGICOS

Os dados são apresentados ao sistema de rede neural paraconsistente para a identificação dos centros existentes na base de dados no período entre os 1980-1997.

Os dados foram transformados para o intervalo fechado [0,1]. Essa transformação também é aplicada sobre dados de validação compreendidos entre os anos 1980-2000.

A aprendizagem ocorre sobre os dados dos anos entre 1980-1997. Essas informações formam uma matriz com os vetores que representam os perfis das ações climáticas. Esses vetores são aprendidos e memorizados por uma rede neural artificial paraconsistente, tendo como saídas a identificação dos padrões.

A validação da técnica de predição ocorre com os dados selecionados entre os anos 1998-2000, que não foram usados no treinamento das redes neurais. Nesse caso os dados da predição do trimestre desejado serão as entradas de uma *RBF*, que terá como retorno um valor que seja a predição dos atributos de decisão temperatura e precipitação.

As regras descritas abaixo são as bases para a abordagem e utilização do algoritmo da Rede Neural Paraconsistente para a identificação dos padrões necessários, que comportarão os centros dos históricos trimestrais, e são dada por:

- Há um total de 15 atributos que formam um registro das identificações dos dados meteorológicos conforme Tabela 4.1, sendo que, somente do quinto atributo ao último são válidos ao processamento da *RBF*, pois do primeiro ao quarto são atributos de posições das áreas selecionadas e a identificação do ciclo sazonal em questão;
- No reconhecimento processado pela *RNAP*, tem-se com retorno as evidências favoráveis e seu valor deve ser maior ou igual ao valor das evidências contrárias somente para os atributos de decisão;
- A soma de cada valor dos atributos reconhecidos por similaridades não pode ser maior que a soma dos valores dos atributos reconhecidos por não similaridades com exceção dos atributos de decisão;

- Cada atributo reconhecido por similaridade é marcado por um único valor, que é somado em um contador, o total dessa soma refere-se à quantidade de atributos que foram encontrados por similaridades de cada registro, esse valor não pode ser maior que o total de atributos que foram reconhecidos por não similaridade;
- A previsão de temperatura e precipitação pode ocorrer ao mesmo tempo para cada área selecionada por sua localização (longitude e latitude) e o trimestre ou ciclo sazonal que se deseja fazer a previsão.

A utilização da lógica paraconsistente tem em seu núcleo o tratamento intrínseco das incertezas, e também possui algoritmos simples que tendem a execuções rápidas, que reflete diretamente no desenvolvimento e futuras manutenções.

O modelo de *RNAP* utilizado é dado na Figura 5.1.

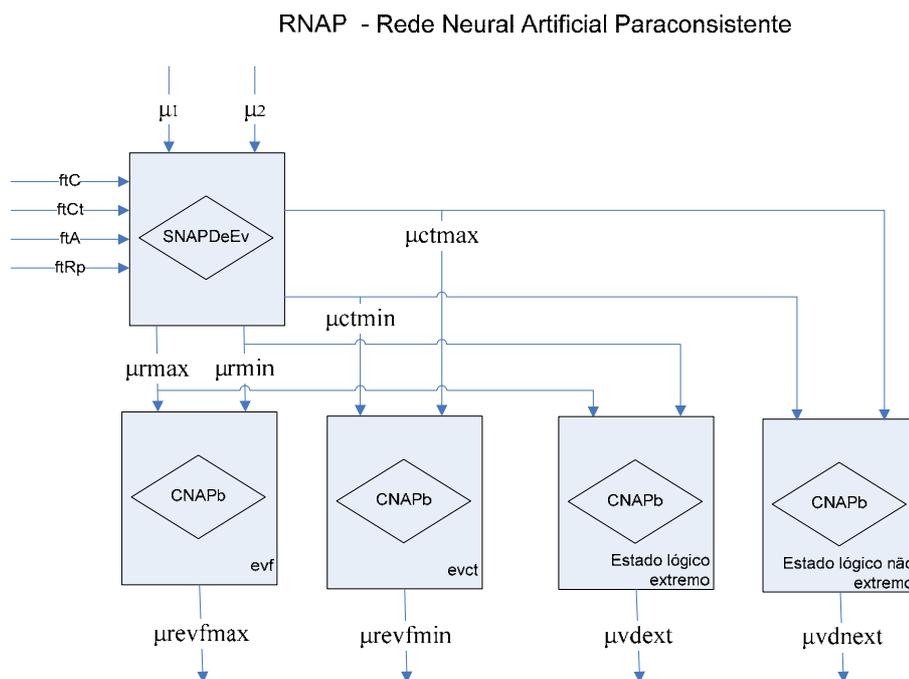


Figura 5.1 – Modelo de Rede Neural Artificial Paraconsistente

O modelo de *RNAP* apresentado na Figura 5.1 como uma nova técnica de mineração e dados não apresenta a necessidade de uma rede diferente para análise de cada área.

A ftA é denominado Fator de Aprendizagem, esse valor controla o tempo de aprendizado e a forma de aprendizado (específica ou genérica), sendo que, quanto mais próximo de 1 (um) mais lento é o processo e mais específica torna-se a *RNAP*. O ftR é

denominado Fator de Reconhecimento de Padrão que controla o reconhecimento ou a identificação dos padrões por similaridades, se o valor for muito próximo de 1 o reconhecimento torna-se mais idêntico. O $ftCt$ é denominado Fator de Tolerância a Contradição, nesse caso não há contradições explícitas devido ao tipo de ambiente ser determinístico. Esse fator determina o limite de contradição suportado entre os dois sinais aplicados. O ftC é denominado Fator de Tolerância a Certeza e é utilizado para controlar as ações da *CNAP*.

No Apêndice A encontram-se as descrições dos algoritmos das Células Neurais Paraconsistentes e a estrutura da Rede Neural Paraconsistente juntamente com as Unidades e os Sistemas Neurais Paraconsistentes formadas.

O primeiro bloco descrito como *SNAPDeEv* é um Sistema Neural Artificial Paraconsistente de Descobertas de Evidências que nesse caso recebe dois valores explícitos de entrada, sendo μ_1 o grau de crença dado pelos valores dos históricos meteorológicos e μ_2 o grau de descrença. Esses valores de entrada serão confrontados a fim de encontrar as não similaridades dos padrões desejados de acordo com os valores limites calculados em função dos valores de tolerâncias estabelecidos.

Assim, a saída da *RNAP* é um conjunto de registros que dispõem de pouca similaridade entre si, esses são considerados como centros, que serão as bases para o mapeamento de todos os registros do histórico de 1980-1997.

A cada ciclo sazonal predito é necessário, o deslocamento para a inclusão desse trimestre para uma nova previsão de outro ciclo sazonal e um melhor mapeamento da *RBF*, obviamente após os dados reais serem apresentados ao mês de previsão. Também possa ser necessário um novo processamento da *RNAP* para um novo mapeamento de imediato ou a *RBF* para encontrar novos centros.

Os valores de tolerância são ajustados externamente à *RNAP* e são estáticos na abordagem deste trabalho, mas em outras situações eles podem ser dinâmicos.

São apresentados os resultados com os diferentes valores de tolerância. As redes neurais paraconsistente e a *RBF*, utilizadas nessa dissertação, requereram muito tempo de processamento em função do tamanho da base de dados.

6. RESULTADOS

A Rede Neural Paraconsistente foi treinada para todos os trimestres. A apresentação dos resultados gráficos foi limitada para efeito de comparação com os resultados do trabalho de Pessoa (2004).

A previsão foi realizada para dois períodos: para um ciclo sazonal, por exemplo, com os dados do trimestre *MAM98* (Outono de 1998) foi feita a previsão para o trimestre de *JJA98* (Inverno de 1998); e para três ciclos sazonais à frente.

Para a obtenção dos resultados de previsão é necessário estabelecer alguns parâmetros básicos que são utilizados no controle da *CNAP*:

- O Fator de Tolerância à Certeza é ajustado com valor alto (próximo de 1). Nessa condição a *CNAP* tem alta tolerância aos valores dos graus de crença resultantes e, portanto admite, como saída, valores de resultantes baixos. Caso contrário admite saídas com valores resultantes altos e rejeita os valores baixos;
- O Fator de Tolerância à Contradição serve para impor um limite de contradição suportável. Toda vez que o grau de contradição for maior que o limiar de *ftCt* a saída gerará um estado lógico Indefinido ou Inconsistente e o grau resultante indefinido. Um valor baixo para o limiar de *ftCt* no contexto desse trabalho ocasionou um maior número de reconhecimento por similaridade.

Quanto maiores os fatores de tolerâncias, mais vetores deixaram de ser identificados como similares, aumentando o número de agrupamentos (*clusters*) não similares. A Tabela 6.1 mostra três situações com limites para as tolerâncias mencionadas, relacionando os respectivos totais de padrões identificados pela Rede Neural Paraconsistente de acordo com os valores de tolerâncias utilizados.

Tabela 6.1 – Relaciona a quantidade de padrões identificados

Tipo	ftC	ftCt	ftR	ftA	A1	A2	A3	A4	A5
1	0.65	0.15	0,35	0,92	553	550	498	452	524
2	0.65	0.55	0,35	0,92	757	625	632	741	697
3	0.85	0.60	0,35	0,92	861	890	875	913	976

Na Tabela 6.1 a coluna Tipo identifica os conjuntos de tolerâncias; ftC é o Fator de Tolerância à Certeza; $ftCt$ é o Fator de Tolerância à Contradição; ftR é o Fator de Reconhecimento de Padrão; ftA é o Fator de Tolerância à Aprendizagem; A1 é a área de estudo 1; A2 é área de estudo 2; A3 é área de estudo 3; A4 é a área de estudo 4; e A5 é a área de estudo 5.

Para a previsão dos atributos de decisão foi utilizada uma rede *RBF* que recebe os dados de cada área como entradas que são comparadas com os padrões encontrados pela rede neural RNAP, em seguida gera uma saída de acordo com o treinamento realizado.

Os resultados estão representados graficamente em imagens e também a comparação dos valores dos erros quadráticos médios obtidos é apresentada em tabelas, mostrando o desempenho do método proposto em comparação com os resultados de Pessoa (2004).

O desempenho do método é medido pelo cálculo dos erros que seguem:

O erro quadrático médio (*EQM*) dado por:

$$EQM = \sqrt{\frac{1}{Q} \sum_{k=1}^Q (\bar{t}(k) - \bar{y}(k))^2} \quad (6.1)$$

O erro absoluto médio (*EAM*) dado por:

$$EAM = \frac{1}{Q} \sum_{k=1}^Q |\bar{t}(k) - \bar{y}(k)| \quad (6.2)$$

, em que Q é o número de padrões de entrada, $\bar{t}(k)$ é o k -ésimo vetor desejado e $\bar{y}(k)$ é a k -ésima saída da rede.

No trabalho foram realizadas previsões para a precipitação e para a temperatura para 1 ciclo e 3 ciclos sazonais.

6.1 Previsão de Precipitação

As Tabelas 6.2 e 6.4 mostram resultados de previsão de precipitação e foram adaptadas do trabalho de Pessoa (2004) para incluir os resultados encontrados neste trabalho. Elas possuem em comum o mesmo alcance de um ciclo sazonal adiante sob a situação de tolerâncias do tipo 1 (Tabela 6.1). As colunas *Rede1-N_a*, *Rede2-N_a* e *Rede3-N_a* representam os resultados obtidos por Pessoa (2004). Na coluna *RNAP* encontram-se os valores calculados com a técnica que utiliza a Lógica Paraconsistente. Na Coluna Ganho ou Perda são apresentados os valores percentuais de comparação com os resultados de Pessoa (2004), dados por:

$$GP = (RedeX_{N_a} - RNAP)/RedeX_{N_a} \quad (6.3)$$

, se $GP > 0$ então a um ganho, caso contrário há uma perda.

Na última coluna encontram-se os valores dos erros absolutos médios.

Na Tabela 6.2 nota-se na coluna *RNAP*, para uma tolerância do tipo 1, que o valor do erro foi superior somente para o tipo de *Rede3-N_a*, para a área 4, significando uma diferença percentual de 3 % a maior. Nessa tabela, os valores em destaque representam os menores valores encontrados no trabalho de Pessoa (2004) para efeito de comparação.

Na Tabela 6.3, somente nas áreas 4 e 5 a *RNAP* apresentou erros maiores. Nessa tabela se está considerando o processamento da *RNAP* com tolerância tipo 2.

Na Tabela 6.4, para a área 5 houve uma diferença a maior de 31% em relação ao menor valor encontrado por Pessoa (2004), da saída produzida pela *Rede3-N_a*. O valor produzido pela *RNAP* considerou a tolerância tipo 3.

Tabela 6.2 – Erros quadráticos médios

(Tolerância tipo 1, *Prec*, $\Delta=1$)

	$\Delta=1$				Ganho/ Perda	Erro Médio
Áreas	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	1,37	1.42	1.39	1,37	0,00	0,54
2	1,70	1.78	1.90	1,37	19,00	0,59
3	1,18	1.62	1.46	1,17	1,00	0,50
4	1,22	1.20	1.17	1,20	-3,00	0,62
5	1,36	1.30	1.17	0,92	21,00	0,57

Tabela 6.3 – Erros quadráticos médios

(Tolerância Tipo 2, *Prec*, $\Delta=1$)

	$\Delta=1$				Ganho/ Perda	Erro Médio
Áreas	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	1,37	1.42	1.39	1,18	14,00	0,52
2	1,70	1.78	1.90	0,77	55,00	0,50
3	1,18	1.62	1.46	0,89	25,00	0,46
4	1,22	1.20	1.17	1,21	-3,00	0,57
5	1,36	1.30	1.17	1,42	-21,00	0,62

Tabela 6.4 – Erros quadráticos médios

(Tolerância tipo 3, *Prec*, $\Delta=1$)

	$\Delta=1$				Ganho/ Perda	Erro Médio
Áreas	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	1,37	1.42	1.39	1,31	4,00	0,55
2	1,70	1.78	1.90	1,66	2,00	0,60
3	1,18	1.62	1.46	0,93	21,00	0,48
4	1,22	1.20	1.17	1,15	2,00	0,62
5	1,36	1.30	1.17	1,53	-31,00	0,58

As Tabelas 6.5 a 6.7, também adaptadas do trabalho de Pessoa (2004), relacionam os erros quadráticos médios encontrados para a previsão de três ciclos sazonais adiante.

Observa-se que na Tabela 6.5 observa-se que o método proposto nesta dissertação produziu resultados superiores aos encontrados em Pessoa (2004) em todas as regiões relacionadas considerando uma tolerância do tipo 1.

Na Tabela 6.6, para a tolerância tipo 2, observa-se que na área 5 a *RNAP* produziu saídas com erro superior aos encontrados por Pessoa (2004). Já nas demais áreas houve

uma diferença significativa, como pode ser visto pelos valores de erros menores produzidos pela *RNAP*.

Na Tabela 6.7, para a tolerância do tipo 3, nota-se que a *RNAP* apresentou valores de erros superiores àqueles encontrados por Pessoa (2004) em 4 das áreas analisadas.

Tabela 6.5 – Erros quadráticos médios
(Tolerância tipo 1, Prec, $\Delta=3$)

Áreas	$\Delta=3$				Ganho/ Perda	Erro Médio
	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	1,46	1,36	1,33	1,10	17,00	0,43
2	2,00	1,86	2,01	0,72	61,00	0,47
3	1,09	1,27	1,01	0,94	7,00	0,40
4	1,25	1,23	1,24	0,96	22,00	0,50
5	1,11	1,04	1,09	0,74	29,00	0,46

Tabela 6.6 – Erros quadráticos médios
(Tolerância tipo 2, Prec, $\Delta=3$)

Áreas	$\Delta=3$				Ganho/ Perda	Erro Médio
	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	1,46	1,36	1,33	0,95	29,00	0,41
2	2,00	1,86	2,01	0,70	62,00	0,45
3	1,09	1,27	1,01	0,71	30,00	0,37
4	1,25	1,23	1,24	1,00	19,00	0,50
5	1,11	1,04	1,09	1,18	-13,00	0,44

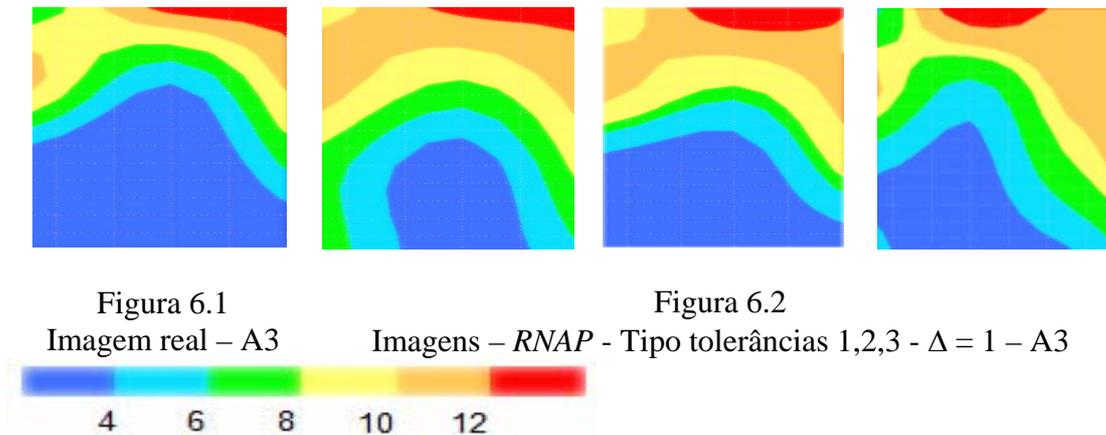
Tabela 6.7 – Erros quadráticos médios
(Tolerância tipo 3, Prec, $\Delta=3$)

Áreas	$\Delta=3$				Ganho/ Perda	Erro Médio
	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	1,46	1,36	1,33	1,55	-17,00	0,48
2	2,00	1,86	2,01	1,94	-4,00	0,57
3	1,09	1,27	1,01	1,02	-1,00	0,48
4	1,25	1,23	1,24	1,02	17,00	0,66
5	1,11	1,04	1,09	1,70	-63,00	0,59

As figuras que se seguem apresentam as previsões de precipitação, associados com a identificação de seus respectivos tipos de tolerâncias.

Na Figura 6.2 dada pelos valores tipo de tolerâncias 1, 2, 3, a *RNAP* apresenta uma normalidade em suas distribuições de precipitação quando comparada à Figura 6.1, que possui os dados reais. Os padrões apresentados abaixo representam a média dos valores das precipitações ocorridas na área 3 nos meses de *DJF98/99* para previsão de um ciclo sazonal adiante.

Imagens da área 3 – *DJF98/99* – Precipitação (*mm/dia*)



Na Figura 6.4 os padrões estimados estão muito próximos do real apresentado na Figura 6.3. A figura apresenta as médias dos valores das precipitações ocorridas na área 1 nos meses de *JJA98* para previsão de um ciclo sazonal adiante.

Nota-se uma superestimação dos valores na precipitação no intervalo de [10, 12] *mm/dia* nos padrões apresentados utilizando as tolerâncias 2, 3. Para essa previsão, utilizando todas as tolerâncias apresenta uma normalidade em suas distribuições quando comparada à Figura 6.3, que possui os dados reais.

Imagens da área 1 – JJA98 – Precipitação (mm/dia)

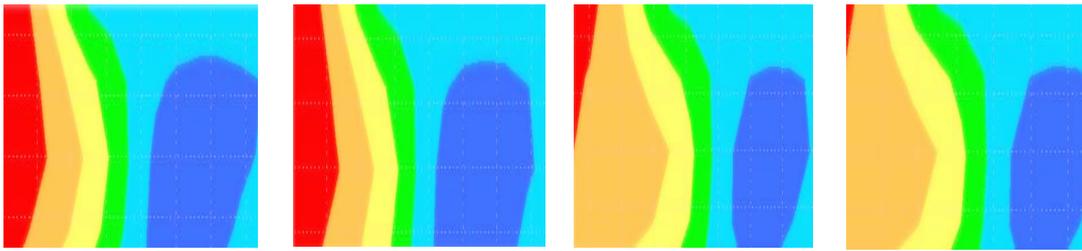
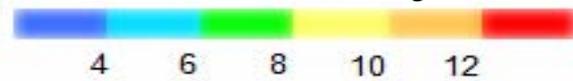


Figura 6.3

Imagem real – A1

Figura 6.4

Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A1



A Figura 6.6 apresenta as médias dos valores das precipitações ocorridas na área 1 nos meses de *SON98* para previsão de um ciclo sazonal adiante. Para o tipo de tolerância 1, a *RNAP* apresenta semelhança de suas distribuições de precipitação quando comparada à Figura 6.5 que possui os dados reais. Para o tipo de tolerância 2, a *RNAP* apresenta uma superestimação no intervalo [4,6] *mm/dia* no maior caso e variações no intervalo [6,10] *mm/dia*. Para o tipo de tolerância 3, houve uma superestimação do intervalo [4,10] *mm/dia* e uma minimização da estimação no intervalo [0,4] *mm/dia*, a *RNAP* não apresenta uma semelhança entre suas distribuições e as da Figura 6.5.

Imagens da área 1 – SON98 – Precipitação (mm/dia)

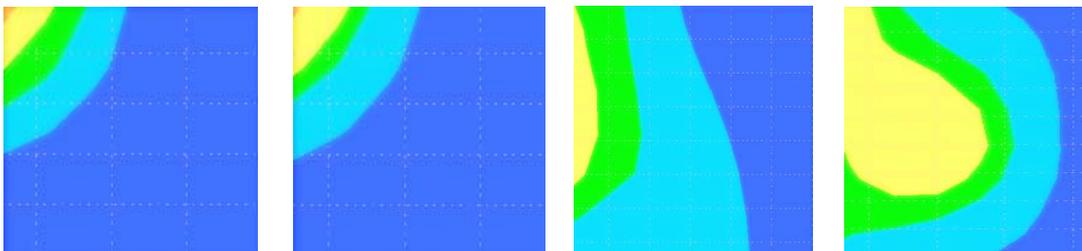
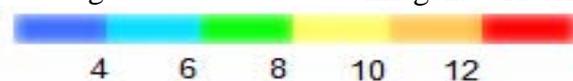


Figura 6.5

Imagem real – A1

Figura 6.6

Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A1



A Figura 6.8 apresenta as médias dos valores das precipitações ocorridas na área 2 nos meses de *DJF98/99* para previsão de um ciclo sazonal adiante. Para as tolerâncias 1 e 3 a *RNAP* apresenta uma semelhança de suas distribuições de precipitação quando comparada à Figura 6.7 com os dados reais. Para o tipo de tolerância 2, houve uma superestimação do intervalo [10,12] *mm/dia* e uma minimização da estimação dos

valores no intervalo $[0,4]$ mm/dia. A *RNAP* não apresenta semelhança de suas distribuições de precipitação quando comparada à Figura 6.7.

Imagens da área 2 – DJF98/99 – Precipitação (mm/dia)

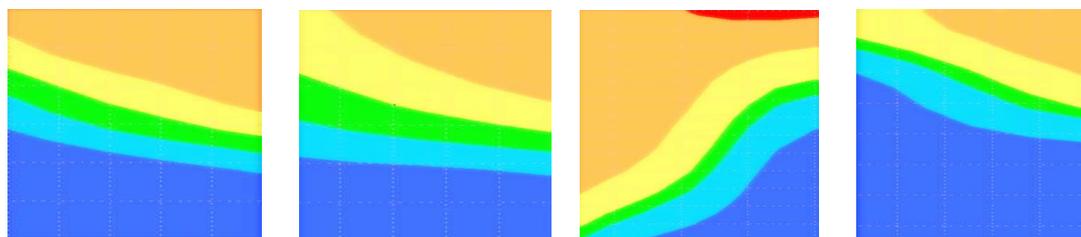


Figura 6.7

Imagem real – A2

Figura 6.8

Imagens – *RNAP* - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A2



A Figura 6.10 apresenta as médias dos valores das precipitações ocorridas na área 4 nos meses de *SON98* para previsão de um ciclo sazonal adiante. Para o tipo de tolerância 1 a *RNAP* apresenta uma minimização no intervalo $[6,8]$ mm/dia e uma semelhança de suas distribuições de precipitação quando comparada à Figura 6.9, com os dados reais. Para os tipos de tolerâncias 2 e 3 a *RNAP* apresenta uma superestimação do intervalo $[0,4]$ mm/dia, uma minimização da estimacão dos valores no intervalo $[6,8]$ mm/dia, mas ainda mostra uma semelhança com as distribuições da precipitação real.

Imagens da área 4 – SON98 – Precipitação (mm/dia)

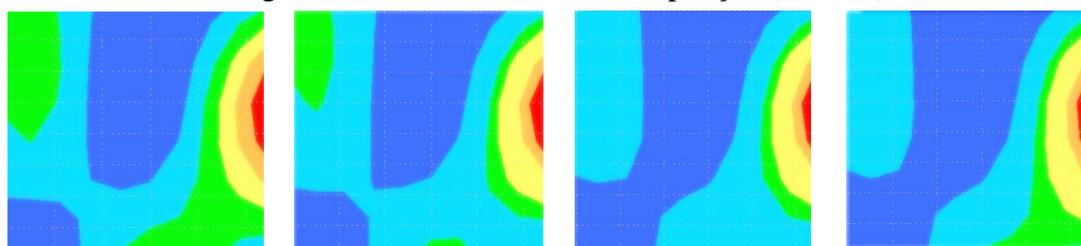


Figura 6.1.9

Imagem Real – A4

Figura 6.1.10

Imagens – *RNAP* - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A4



A Figura 6.12 apresenta as médias dos valores das precipitações ocorridas na área 5 nos meses de *DJF99/00* para previsão de um ciclo sazonal adiante. Para o tipo de tolerância 1 a *RNAP* não apresenta semelhança de suas distribuições de precipitação quando comparada à Figura 6.11 com os dados reais. Para os tipos de tolerâncias 2 e 3 houve

uma minimização da estimaco dos valores no intervalo [10,12] *mm/dia*, mas a *RNAP* apresenta semelhana de suas distribuices de precipitao.

Imagens da rea 5 – DJF99/00 – Precipitao (*mm/dia*)

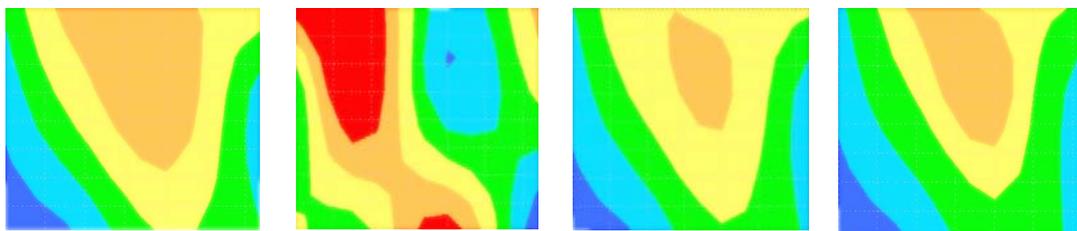
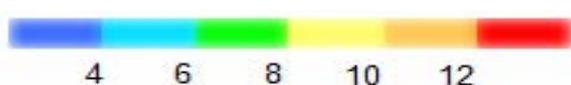


Figura 6.11

Imagem Real – A5

Figura 6.12

Imagens – *RNAP* - Tipo tolerncias 1,2,3 - $\Delta = 1$ – A5



A Figura 6.14 apresenta as mdias dos valores das precipitaes ocorridas na rea 2 nos meses de *MAM00* para previso de um ciclo sazonal adiante. Para os tipos de tolerncias 1 e 2 a *RNAP* apresenta semelhana de suas distribuices de precipitao quando comparada  Figura 6.15 que possui os dados reais. Para o tipo de tolerncia 3, a *RNAP* no apresenta semelhana de suas distribuices de precipitao com os dados reais.

Imagens da rea 2 – MAM00 – Precipitao (*mm/dia*)

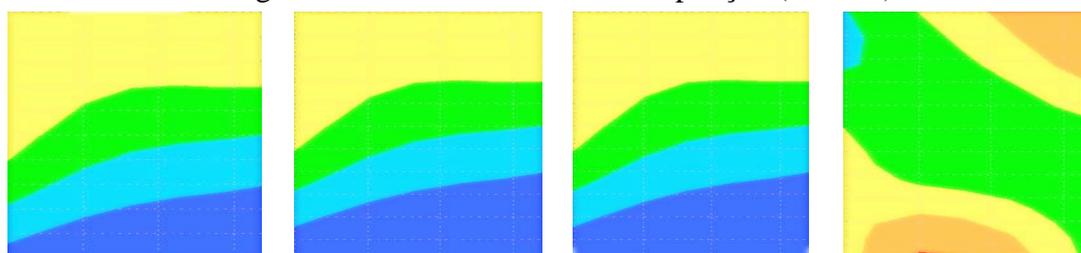


Figura 6.13

Imagem real – A2

Figura 6.14

Imagens – *RNAP* - Tipo tolerncias 1,2,3 - $\Delta = 1$ – A2



6.2 Previso de Temperatura

As Tabelas 6.8 a 6.10 mostram resultados de previso de temperatura e foram adaptadas do trabalho de Pessoa (2004) para incluir os resultados encontrados neste trabalho. Elas possuem em comum o mesmo alcance de um ciclo sazonal adiante sob a situao de

tolerâncias do tipo 1 (Tabela 6.1). As colunas *Rede1-N_a*, *Rede2-N_a* e *Rede3-N_a* representam os resultados obtidos por Pessoa (2004). Na coluna *RNAP* encontram-se os valores calculados com a técnica que utiliza a Lógica Paraconsistente.

Na Tabela 6.8 nota-se na coluna *RNAP*, para uma tolerância do tipo 1, que todos os valores dos erros foram superiores ao tipo de *Rede1..3-N_a*, sendo que na área 2 houve erros igual a zero, para as duas abordagens para as *Redes1..3-N_a* e a *RNAP*. Nessa tabela, os valores em destaque representam os menores valores encontrados no trabalho de Pessoa (2004) para efeito de comparação.

Na Tabela 6.9, a *RNAP* apresentou erros maiores quando comparada com todas as *Rede1..3-N_a*. Nessa tabela se está considerando o processamento da *RNAP* com tolerância tipo 2.

Na Tabela 6.10, para a área 1 houve 33% de diferença negativa em relação ao valor de erro encontrado por Pessoa (2004), significando que a *RNAP* perdeu em desempenho. Também a *RNAP* apresentou desempenho inferior para a área 3 com diferença de 4% e para a área 5 com diferença de 3%. Os valores produzidos pela *RNAP* considerou a tolerância tipo 3.

Tabela 6.8 – Erros quadráticos médios
(Tolerância tipo 1, *Temp*, $\Delta=1$)

	$\Delta=1$				Ganho/ Perda	Erro Médio
Áreas	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	0,48	0,48	0,50	0,42	13,00	0,54
2	0,52	0,50	0,50	0,50	0,00	0,49
3	1,58	1,44	1,95	0,50	65,00	0,56
4	0,60	0,62	0,54	0,49	9,00	0,51
5	1,00	0,93	0,96	0,56	40,00	0,59

Tabela 6.9 – Erros quadráticos médios
(Tolerância tipo 2, *Temp*, $\Delta=1$)

Áreas	$\Delta=1$				Ganho/ Perda	Erro Médio
	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	0,48	0,48	0,50	0,40	17,00	0,55
2	0,52	0,50	0,50	0,59	18,00	0,56
3	1,58	1,44	1,95	0,98	32,00	0,53
4	0,60	0,62	0,54	0,52	4,00	0,57
5	1,00	0,93	0,96	1,03	11,00	0,55

Tabela 6.10 – Erros quadráticos médios
(Tolerância tipo 3, *Temp*, $\Delta=1$)

Áreas	$\Delta=1$				Ganho/ Perda	Erro Médio
	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	0,48	0,48	0,50	0,64	-33,00	0,57
2	0,52	0,50	0,50	0,48	4,00	0,59
3	1,58	1,44	1,95	1,50	-4,00	0,56
4	0,60	0,62	0,54	0,54	0,00	0,60
5	1,00	0,93	0,96	0,96	-3,00	0,59

As Tabelas 6.11 a 6.13, também adaptadas do trabalho de Pessoa (2004), relacionam os erros quadráticos médios encontrados para a previsão de três ciclos sazonais adiante.

Observa-se que na Tabela 6.11 e o método proposto nesta dissertação produziu resultados superiores aos encontrados em Pessoa (2004) em todas as regiões relacionadas considerando uma tolerância do tipo 1.

Na Tabela 6.12, para a tolerância tipo 2, observa-se que na área 5 a *RNAP* produziu saídas com erro superior aos encontrados por Pessoa (2004). Já nas demais áreas houve uma diferença significativa, como pode ser visto pelos valores de erro menores produzidos pela *RNAP*.

Na Tabela 6.13, para a tolerância do tipo 3, nota-se que somente para a área 3, a *RNAP* apresentou valores de erros superiores àqueles encontrados por Pessoa (2004) sendo que nas 4 das áreas analisadas a *RNAP* apresentou valores de erros inferiores.

Tabela 6.11 – Erros quadráticos médios

(Tolerância tipo 1, *Temp*, $\Delta=3$)

	$\Delta=3$				Ganho/ Perda	Erro Médio
Áreas	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	0,42	0,42	0,46	0,39	7,00	0,56
2	0,51	0,52	0,47	0,38	19,00	0,58
3	1,61	1,35	1,65	0,94	30,00	0,55
4	0,73	0,73	0,77	0,64	12,00	0,60
5	1,06	0,96	0,98	0,83	14,00	0,58

Tabela 6.12 – Erros quadráticos médios

(Tolerância tipo 2, *Temp*, $\Delta=3$)

	$\Delta=3$				Ganho/ Perda	Erro Médio
Áreas	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	0,42	0,42	0,46	0,39	7,00	0,52
2	0,51	0,52	0,47	0,47	0,00	0,54
3	1,61	1,35	1,65	1,11	18,00	0,51
4	0,73	0,73	0,77	0,62	15,00	0,55
5	1,06	0,96	0,98	1,11	-16,00	0,53

Tabela 6.13 – Erros quadráticos médios

(Tolerância tipo 3, *Temp*, $\Delta=3$)

	$\Delta=3$				Ganho/ Perda	Erro Médio
Áreas	<i>Rede1-N_a</i>	<i>Rede2-N_a</i>	<i>Rede3-N_a</i>	<i>RNAP</i>	(%)	Absoluto
1	0,42	0,42	0,46	0,49	-17,00	0,56
2	0,51	0,52	0,47	0,48	-2,00	0,52
3	1,61	1,35	1,65	1,31	3,00	0,65
4	0,73	0,73	0,77	1,25	-71,00	0,59
5	1,06	0,96	0,98	1,20	-25,00	0,53

As figuras que se seguem apresentam as previsões de temperatura, associadas com a identificação de seus respectivos tipos de tolerâncias.

Na Figura 6.16 dada pelos valores tipos de tolerâncias, são apresentadas as médias dos valores das precipitações ocorridas na área 3 nos meses de *SON98* para previsão de um ciclo sazonal adiante. Para o tipo de tolerância 1 a *RNAP* apresenta distribuições de temperatura semelhante aos valores reais representados na Figura 6.15. Para os tipos de tolerância 2 e 3 observa-se que houve uma superestimação do intervalo [10,12] °C

mm/dia. As distribuições da *RNAP* não são semelhantes às distribuições de temperatura dadas pelos valores reais na Figura 6.15.

Imagens da área 3 – SON98 – Temperatura (°C)

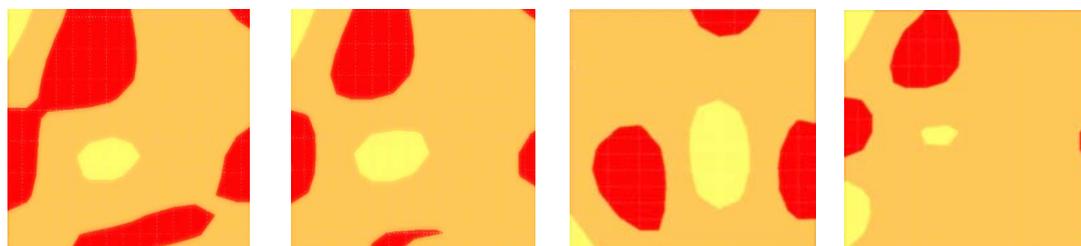


Figura 6.15

Imagem real – A3

Figura 6.16

Imagens – *RNAP* - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A3



Na Figura 6.18 são apresentadas as médias dos valores das temperaturas ocorridas na área 5 nos meses de *MAM98* para previsão de um ciclo sazonal adiante. Para o tipo de tolerância 1 a *RNAP* apresenta distribuição semelhante às distribuições de temperaturas dos dados reais da Figura 6.17. Para os tipos de tolerância 2 e 3, houve uma superestimação do intervalo [20,25] °C. As distribuições da *RNAP* não são semelhantes às distribuições de temperaturas reais dadas na Figura 6.17.

Imagens da área 5 – JJA98 – Temperatura (°C)

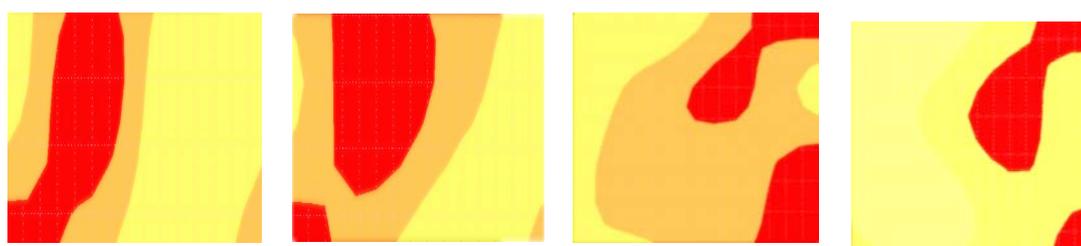
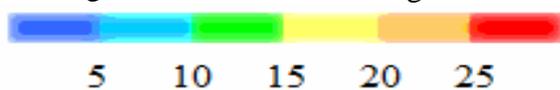


Figura 6.17

Imagem real – A5

Figura 6.18

Imagens – *RNAP* - Tipo tolerâncias 1,2,3 - $\Delta = 1$ – A5



A Figura 6.20 apresenta as médias dos valores das temperaturas ocorridas na área 4 nos meses de *JJA98* para previsão de um ciclo sazonal adiante. Para os tipos de tolerância 1 e 3 a *RNAP* apresenta distribuições de temperatura semelhantes às distribuições dos dados reais como visto na Figura 6.19. Para o tipo de tolerância 2, houve uma

superestimação do intervalo [20,25] °C. A *RNAP* apresenta distribuição de temperatura semelhante às distribuições de temperaturas reais na Figura 6.19.

Imagens da área 4 – JJA98 – Temperatura (°C)

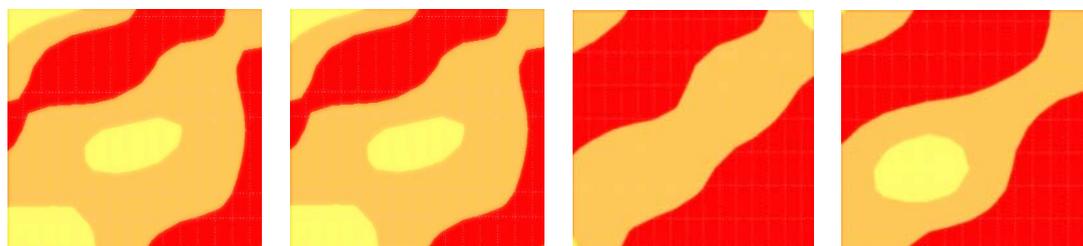
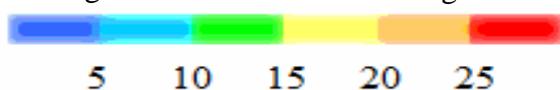


Figura 6.19
Imagem real – A4

Figura 6.20
Imagens – *RNAP* - Tipo tolerâncias 1,2,3 - $\Delta = 1$



Na Figura 6.22 dada são apresentadas as médias dos valores de temperaturas ocorridas na área 3 nos meses de *JJA99* para previsão de três ciclos sazonais adiante. Para os tipos de tolerâncias 1 e 2, a *RNAP* apresenta distribuições de temperaturas semelhantes quando comparada à Figura 6.21, que possui os dados reais. Para o tipo de tolerância 3, houve uma superestimação do intervalo [20,25] °C. A *RNAP* não apresenta semelhanças com as distribuições de temperaturas reais da Figura 6.21.

Imagens da área 3 – JJA99 – Temperatura (°C)

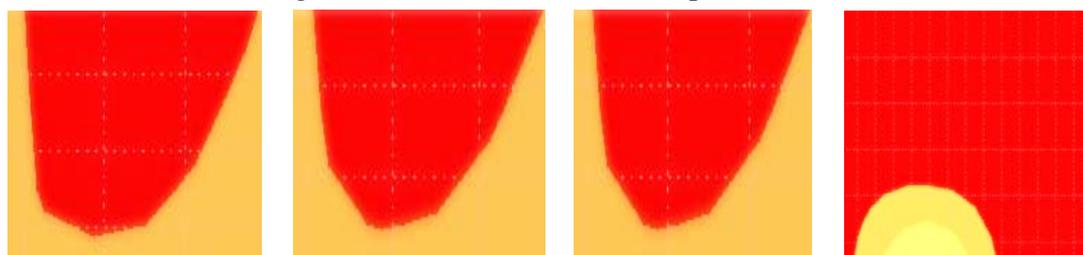


Figura 6.21
Imagem real – A3

Figura 6.22
Imagens – *RNAP* - Tipo tolerâncias 1,2,3 - $\Delta = 3 - A3$



Na Figura 6.24 estão mostradas as médias dos valores das temperaturas ocorridas na área 1 nos meses de *MAM98* para previsão de um ciclo sazonal adiante. Para os tipos de tolerâncias 2 e 3, a *RNAP* apresenta semelhança com as distribuições de temperaturas reais da Figura 6.23. Para o tipo de tolerância 1, houve uma superestimação do intervalo

[20,25] °C, mas a *RNAP* apresenta semelhança as distribuições de temperaturas reais da Figura 6.23.

Imagens da área 1 – MAM98 – Temperatura (°C)

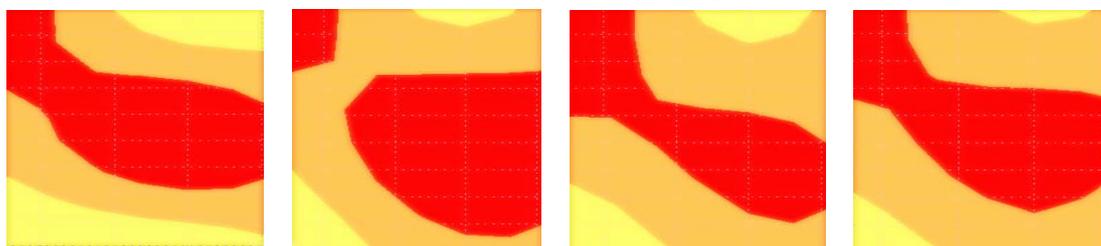
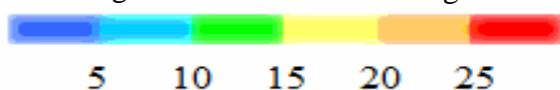


Figura 6.23

Imagem real

Figura 6.24

Imagens – *RNAP* - Tipo tolerâncias 1,2,3 - $\Delta = 1$



Na Figura 6.26 são apresentadas as médias dos valores das temperaturas ocorridas na área 4 nos meses de *DJF99/00* para previsão de um ciclo sazonal adiante. Para o tipo de tolerância 1, a *RNAP* não mostra semelhança de suas distribuições de temperaturas quando comparada à Figura 6.25, que possui os dados reais. Para os tipos de tolerância 2 e 3, houve uma superestimação do intervalo [15,20] °C, mas a *RNAP* apresenta semelhança das distribuições de temperaturas com os dados reais da Figura 6.25.

Imagens da área 4 – DJF99/00 – Temperatura (°C)

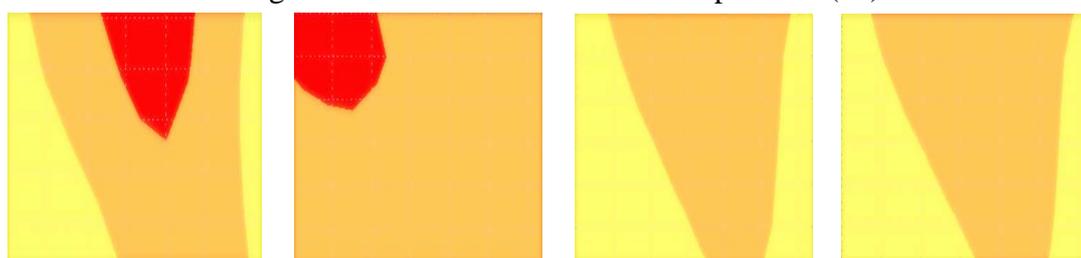


Figura 6.25

Imagem real

Figura 6.26

Imagens – *RNAP* - Tipo tolerâncias 1,2,3 - $\Delta = 1$



A Figura 6.28 apresenta as médias dos valores das temperaturas ocorridas na área 3 nos meses de *JJA00* para previsão de três ciclos sazonais adiante. Para os tipos de tolerâncias 1,2 e 3, a *RNAP* apresenta semelhança das distribuições de temperaturas quando comparada à Figura 6.27 com os dados reais.

Imagens da área 3 – JJA00 – Temperatura (°C)

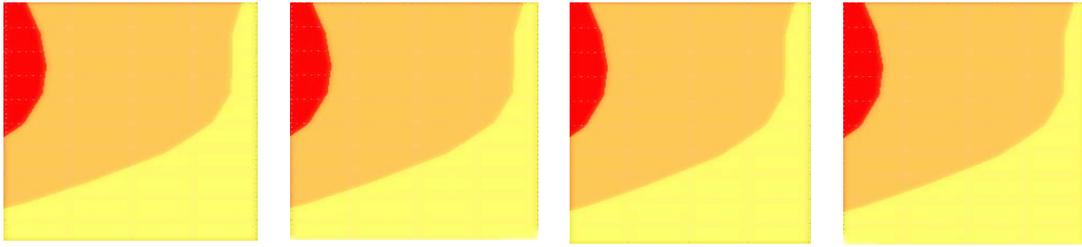
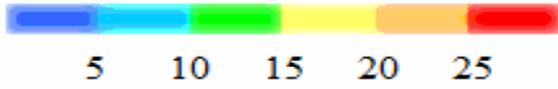


Figura 6.27
Imagem real

Figura 6.28
Imagens – RNAP - Tipo tolerâncias 1,2,3 - $\Delta = 3$



7. CONCLUSÃO

Esta dissertação propôs um método de redução de dados, em uma abordagem de mineração de dados, utilizando a Lógica Paraconsistente para implementar redes neurais. Os dados tratados são utilizados como entradas para uma Rede de Funções de Base Radial (*RBF*) para concepção de um modelo de previsão climáticas utilizando dados de reanálise, de 5 regiões da América do Sul, também utilizados no trabalho de Pessoa (2004). Foi seguido o mesmo método de seleção de dados.

A rede neural paraconsistente produziu 3 subconjuntos de dados utilizando 3 tolerâncias escolhidas de forma *ad hoc*, com base em experimentos. Tais conjuntos produziram modelos de previsão através do treinamento de redes *RBF*, para as quais os conjuntos reduzidos eram tomados como centros das funções de base radial.

Os resultados de generalização ou validação dos modelos são satisfatórios tendo apresentado ganhos significativos em alguns experimentos quando comparados com os resultados produzidos pela técnica utilizada por Pessoa (2004). Entretanto, em alguns casos houve perdas.

De acordo com a métrica de comparação utilizada, os resultados podem ser aceitos e considerados próximos ao real. Os gráficos apresentados no trabalho permitem uma análise visual qualitativa e as tabelas trazem os valores de erros que permitem a análise quantitativa do desempenho do método proposto.

As comparações qualitativas e quantitativas propostas neste trabalho mostram a eficácia da Lógica Paraconsistente na determinação dos centros das funções de base radial para o treinamento da *RBF*.

Os resultados encontrados permitem relacionar as contribuições apresentadas nesta dissertação como:

- Utilização da teoria da Lógica Paraconsistente na análise de dados climáticos de reanálise, em uma abordagem de mineração de dados;
- Criação de um método de auxílio à previsão de clima baseado na hibridização de duas técnicas de Inteligência Artificial, com a habilidade para prever padrões climatológicos.

Apesar dos resultados satisfatórios do método proposto, é preciso observar que ainda se faz necessário sintonizar melhor o método, utilizando uma base de dados de reanálise maior do que a utilizada neste trabalho. Isso certamente fornecerá mais subsídios para o estabelecimento de conjuntos de padrões mais eficientes para a tarefa de estabelecer o modelo de previsão. Inclusive isso pode ser uma explicação das diferenças de desempenho a menor, apresentada pelo método, quando comparado ao trabalho de Pessoa (2004).

Também a hibridização proposta nesta dissertação considerou o uso de uma rede neural do tipo Rede de Funções de Base Radial, para as quais é necessário especificar alguns parâmetros para caracterizar a abrangência das funções de base radial.

Para buscar melhor o desempenho do método proposto, sugerem-se alguns trabalhos futuros na mesma linha desta dissertação:

- Seleção de uma base de dados mais completa para aplicação do método, observando um maior número de tolerâncias, associadas ao par crença e descrença.
- Utilização de outros tipos de redes neurais artificiais supervisionadas para a concepção do modelo de previsão.
- Criação de um aplicativo que integre as duas abordagens apresentadas que possa ser utilizado de forma sistemática.

REFERÊNCIAS BIBLIOGRÁFICAS

ABE, J.M. **Fundamentos da lógica anotada**. Doutorado em lógica anotada, USP, São Paulo, 1992.

ABE, J. M. **On annotated model theory**. São Paulo: Coleção Documentos IEA-USP, série Lógica e Teoria da Ciência, n 11, 1993 (Relatório técnico).

ABE, J. M. **Introdução à lógica e aplicações**. São Paulo: Plêiade, 1999.

ALMEIDA, J. M. **Logics of formal inconsistency**. Doutorado, Universidade Técnica de Lisboa, Lisboa, 2005.

ÁVILA, B. C. **Uma abordagem paraconsistente baseada em lógica evidencial para tratar exceções em sistemas de frames com múltipla herança**. Doutorado lógica paraconsistente, USP, São Paulo, 1996.

BETTINI, C. et al. Testing complex temporal relationships involving multiple granularities and its applications to data mining. ACM SIGACT-SIFMOND-SIGART SYMPOSIUM IN PRINCIPLES OF DATABASE SYSTEMS (PODS), 1996, Montreal, Canada. **Extend Abstract**. Disponível em: <http://www.dsi.unimi.it/bettini/rec-pub.html> Acesso em: abril 2003.

CAMARGO Jr., H. **Introdução à previsão climática**. (Instituto Nacional de Pesquisas Espaciais, Cachoeira Paulista, 2004). Comunicação pessoal.

CHEN, Z. **Data mining and uncertain reasoning: an integrated approach**. New York: John Wiley & Sons, 2001.

DA COSTA, N.C.A.; et al. Remarks on annotated logic. Zeitschrift für Mathematische Logik und **Grundlagen der Mathematik**, v. 37, p 561-570, 1991.

DA COSTA, N. C. A.; et al. **Lógica paraconsistente aplicada**. São Paulo: Editora Atlas, 1999, ISBN 8522422184.

DA SILVA FILHO, J.I.; et al. **Fundamentos das redes neurais artificiais paraconsistentes**: destacando aplicações em neurocomputação. São Paulo: VilliPress, 2001, ISBN 8574730424.

DA SILVA FILHO, J.I.; et al. **Inteligência artificial com as redes de análises paraconsistentes – teoria e aplicações**, LTC, 2008, ISBN 9788521616313.

FAYYAD, U. et al. **From data mining to knowledge discovery: an overview**. Massachusets, EUA: AAAI Press, 1996.

FERNADES, A. M. da R. **Inteligência artificial: noções gerais**. Florianópolis: Visual Books, 2003.

GOEBEL, M.; GRUNWALD, L. A survey of data mining and knowledge discovery software tools. **SIGKDD Explorations**, v. 1, p. 20-33, 1999.

GUTÉRREZ, J. M et al. **Probabilísticas y neuronales en las ciencias atmosféricas**. Disponível em: <http://grupos.unican.es/ai/meteo/MeteoLab.html>. Acesso em: Abr 2004. Series Monográficas.

HAGAN, M. T. et al. **Neural network design**. Boston, EUA: PWS Publishing Company, 1995.

HAYKIN, S. **Redes neurais: princípios e práticas**. Porto Alegre: Bookman, 2001.

HAYKIN, S; et. al. **Sinais e sistemas**. Porto Alegre: Bookman, 2001.

HOLSHEIMER M.; SIEBES A. **Data mining: the search for knowledge in databases**. Amsterdam, Netherlands: CWI, 1994.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Meteorologia básica**. Disponível em: http://www.inmet.gov.br/aprenda_inmet/saiba_como/meteoro_basica. Acesso em: Abr. 2008.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Portal de previsões numéricas**. Disponível em: http://www.cptec.inpe.br/prevnum/exp_ensemble.shtml. Acesso em: Abr. 2008.

KOHONEN, T. Correlation matrix memories. **IEEE Transactions on computers**, v. 21, p. 353-359, 1972.

LORENZ, E. N. Deterministic non-periodic flow. **J. Atmos. Sci.**, v. 20, p. 130-141, 1963.

LORENZ, E. N. The predictability of a flow which possesses many scales of motion. *Tellus*, v. 21, p. 289-307, 1969.

PARSAYE, K.; et al. **Intelligent databases: object-oriented, deductive and hypermedia technologies**. New York: John Willey, 1989.

PRADO, J. C. A. **Redes neurais paraconsistentes e sua utilização para reconhecimento de padrões**. Dissertação (Mestrado em reconhecimento de padrões) – USP, São Paulo, 2002.

PESSOA, A. S. A. Aplicação da teoria dos conjuntos aproximativos na classificação de tarefas mentais utilizando sinais de EEG. In. Encontro de Modelagem Computacional, 6., 2003, Nova Friburgo. **Anais...** Rio de Janeiro: IPRJ/UERJ, 2003.

PESSOA, A. S. A. et al. Uma aplicação de mineração de dados geográficos utilizando a teoria dos conjuntos aproximativos. In. Congresso Nacional Matemática Aplicada e Computacional, 26., 2003, São José do Rio Preto. **Anais...** São Paulo: IBILCE/UNESP, 2003.

PESSOA, A. S. A. **Mineração de dados meteorológicos pela teoria dos conjuntos aproximativos na previsão de clima por redes neurais artificiais**. 2004. 146 p. (INPE-15665-TDI/1441). Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2004. Disponível em: <http://urlib.net/sid.inpe.br/jeferson/2005/02.15.15.46>. Acesso em: jul. 2009.

RUSSEL S. J.; NORVIG P. **Artificial intelligence: a modern approach**. New Jersey: Prentice Hall, 1995.

SHAFER, G. **A mathematical theory of evidence**. Princeton: Princeton University Press, 1976.

VAREJÃO-SILVA, M. A. **Meteorologia e climatologia** – versão digital 2. Recife, Pernambuco: 2006. Disponível em: http://www.agritempo.gov.br/publish/publicacoes/livros/METEOROLOGIA_E_CLIMATOLOGIA_VD2_Mar_2006.pdf. Acesso em: mai. 2008.

SLOWINSKI, R. **Intelligent decision support**. Handbook of Applications and Advances of the Rough Sets Theory. Dordrecht: Kluwer Academic Publishers, 1992.

SOUZA, V. S. In Redes neurais artificiais paraconsistentes aplicada no estudo de fraudes à conta de clientes acessadas via *internet*. In. Congresso Brasileiro de Redes Neurais, 7., 2005, Natal. **Anais...** Rio Grande do Norte: SBRN, 2005.

WEISS, S. M.; INDURKHIA, N. **Predictive data mining**: a practical guide. San Francisco, USA: Morgan Kaufmann, 1998, ISBN 1558604030.

APÊNDICE A – REDES NEURAIIS ARTIFICIAIS PARACONSISTENTES

Algoritmo Para-analisador

Esse algoritmo tem a finalidade de analisar e retornar os valores de certeza e contradição (Evidências Favorável e Contrária) como valores analógicos. Sua base é descrever a Lógica Paraconsistente definindo assim, a Célula Neural Artificial Paraconsistente Base, essa célula “_Matter_” é a base para descrever todas as células criadas para a formação da Rede Neural Artificial Paraconsistente.

Assim, o algoritmo para-analisador define-se pelo reticulado 12 da Lógica Paraconsistente.

As variáveis μ_1 e μ_2 representam os graus de crença e descrença.

- Definições dos Estados Extremos

T = Inconsistente

F = Falso

\perp = Indeterminado

V = Verdadeiro

- Definições dos Estados não Extremos

$\perp \rightarrow F \rightarrow$ Indeterminado tendendo a Falso

$\perp \rightarrow V \rightarrow$ Indeterminado tendendo ao Verdadeiro

T $\rightarrow F \rightarrow$ Inconsistente tendendo ao Falso

T $\rightarrow V \rightarrow$ Inconsistente tendendo ao Verdadeiro

$Q_v \rightarrow T \rightarrow$ Quase verdadeiro tendendo ao Inconsistente

$Q_v \rightarrow \perp \rightarrow$ Quase verdadeiro tendendo ao Indeterminado

$Q_f \rightarrow T \rightarrow$ Quase falso tendendo ao Inconsistente

$Q_f \rightarrow \perp \rightarrow$ Quase falso tendendo ao indeterminado

- Definições dos valores relacionais

$G_{it} \rightarrow$ Grau de inconsistência, onde:

$$G_{it} = \mu_1 + \mu_2 - 1 \text{ se e somente se } (\mu_1 + \mu_2) \geq 1$$

G_{id} → Grau de indeterminação, onde:

$$G_{id} = \mu_1 + \mu_2 - 1 \text{ se e somente se } (\mu_1 + \mu_2) \leq 1$$

G_v → Grau de verdade, onde:

$$G_v = \mu_1 - \mu_2 \text{ se e somente se } \mu_1 \geq \mu_2$$

G_f → Grau de falsidade, onde:

$$G_f = \mu_1 - \mu_2 \text{ se e somente se } \mu_1 < \mu_2$$

G_{ct} → Grau de contradição, onde:

$$G_{ct} = \mu_1 + \mu_2 - 1, \text{ onde, } 0 \leq \mu_1 \leq 1 \text{ e } 0 \leq \mu_2 \leq 1.$$

G_c → Grau de certeza, onde:

$$G_c = \mu_1 - \mu_2, \text{ onde, } 0 \leq \mu_1 \leq 1 \text{ e } 0 \leq \mu_2 \leq 1.$$

- Definições dos valores

v_{scc} → C_1 {Definição do valor superior de controle de certeza}

$$v_{scc} = (1+ftC)/2$$

v_{icc} → C_2 {Definição do valor inferior de controle de certeza}

$$v_{icc} = (1-ftC)/2$$

v_{sct} → C_3 {Definição do valor superior de controle de contradição}

$$v_{sct} = (1+ftCt)/2$$

v_{ict} → C_4 {Definição do valor inferior de controle de contradição}

$$v_{ict} = (1-ftCt)/2$$

Descrição do algoritmo

- Variável de ENTRADA

μ_1 {Grau de crença}

μ_2 {Grau de descrença}

- Variável de SAÍDA

Saída discreta = S_1 ,

Saídas Analógicos = μ_{FV} , μ_{FCt}

- Expressões matemáticas

$$0 \leq \mu_1 \leq 1 \text{ e } 0 \leq \mu_2 \leq 1$$

$$G_c = \mu_1 - \mu_2$$

$$G_{ct} = \mu_1 + \mu_2 - 1$$

- Determinação dos estados Lógicos Extremos

Se $G_c \geq C_1$ então $S_1 = V$

Se $G_c \leq C_2$ então $S_1 = F$

Se $G_c \geq C_3$ então $S_1 = T$

Se $G_c \leq C_4$ então $S_1 = \perp$

- Determinação dos estados Lógicos Não-Extremos

Se $0 \leq G_c < C_1$ e $0 \leq G_{ct} < C_3$ então

Se $G_c \leq G_{ct}$ então

$$S_1 = Qv \rightarrow T$$

Senão

$$S_1 = T \rightarrow V$$

Fim

Fim

Se $0 \leq G_c < C_1$ e $C_4 < G_{ct} \leq 0$ então

Se $G_c \geq |G_{ct}|$ então

$$S_1 = Qv \rightarrow \perp$$

Senão

$$S_1 = \perp \rightarrow V$$

Fim

Fim

Se $C_2 < G_c \leq C_1$ e $C_4 < G_{ct} \leq 0$ então

Se $|G_c| \geq G_{ct}$ então

$$S_1 = Qf \rightarrow \perp$$

Senão

$$S_1 = \perp \rightarrow F$$

Fim

Fim

Se $C_2 < G_c \leq 0$ e $0 \leq G_{ct} < C_3$ então

Se $|G_c| \geq G_{ct}$ então

$$S_1 = Qf \rightarrow T$$

Senão

$$S_1 = T \rightarrow V$$

Fim

Fim

- Variáveis de retorno

$$\mu_{Fv} = G_c \quad (\text{Evidência Favorável})$$

$$\mu_{Ct} = G_{ct} \quad (\text{Evidência Contrária})$$

a) Células Neurais Artificiais Paraconsistentes

As Células Neurais Artificiais Paraconsistentes são células bases da construção dos neurônios artificiais Paraconsistentes. De uma célula base foram construídas as outras que compõe nesse aplicativo a noção de “_framework_” Paraconsistente, permitindo de forma consistente a criação de novas células de acordo com a necessidade de solução ao ambiente de busca.

b) Célula Neural Artificial Paraconsistente de Conexão Analítica

A Célula Neural Artificial Paraconsistente de Conexão Analítica tem a função de fazer a interligação entre as células da *RNAP*, associando graus de crença conforme o objetivo da análise. O resultado dessa análise é um fator de crença único, obtido pela equação estrutural básica, que será uma entrada para outra célula artificial Paraconsistente.

Essa célula é o elo que permite diferentes regiões da *RNAP* efetuar o processamento de sinais de forma distribuída por meio de inúmeras conexões paralelas (sinápticas).

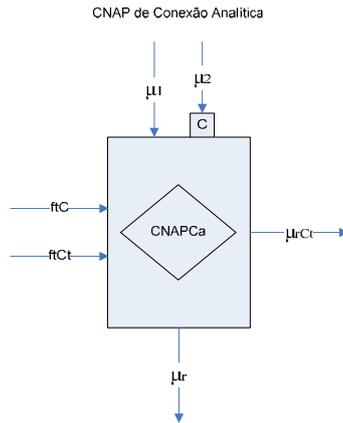


Figura A.1 Representa a *CNAPCa*

A Figura A.1 descreve de forma visual o algoritmo citado abaixo, de forma que se possa compreender mais facilmente sua atuação.

Entradas:

- 1- μ_1 ;
- 2- μ_2 ;

Entradas dos Fatores Externos:

- 1- ftC ;
- 2- $ftCt$.

Cálculos:

- 1- $\mu_2 = \mu_1 C_o = 1 - \mu_1$;
- 2- $G_c = \mu_1 - \mu_2$;
- 3- $G_{ct} = \mu_1 + \mu_2 - 1$;
- 4- $EEB = (G_c + 1)/2$;

Saídas:

- μ_r (lê-se: saída resultante)
- μ_{rCt} (lê-se: saída resultante da contradição)
- 1- Se $v_{icc} \leq EEB \leq v_{scc}$, então $\mu_r = EEB$ e $\mu_{rCt} = 0$;
- 2- Se $|G_{ct}| > ftCt$ e $|G_{ct}| > |G_c|$, então $\mu_r = EEB$ e $\mu_{rCt} = |G_{ct}|$;
- 3- Caso contrário $\mu_r = 1/2$ e $\mu_{rCt} = 0$.

Fim

c) **Célula Neural Artificial Paraconsistente de Conexão Lógica Simples de Maximização**

A Célula Neural Artificial Paraconsistente de Conexão Lógica Simples de Maximização tem a função de estabelecer o conectivo lógico “Or” entre os sinais que são representativos dos valores de entrada.

Essa maximização é executada através da Equação Estrutural Básica, que vai informar qual dos dois sinais é o de maior valor.

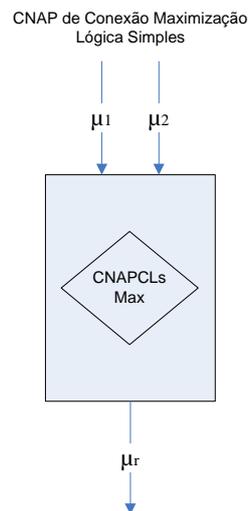


Figura A.2 Representa a *CNAPCLsMax*

A Figura A.2 descreve de forma visual o algoritmo citado abaixo, de forma que se possa compreender mais facilmente sua atuação.

Entradas:

- 1- μ_1 ;
- 2- μ_2 .

Cálculos: Nenhum.

Saídas:

- 1- Se $\mu_1 > \mu_2$ então
- 2- $\mu_r = \mu_1$
- 3- Senão
- 4- $\mu_r = \mu_2$.
- 5- Fim

Fim

d) Célula Neural Artificial Paraconsistente de Conexão Lógica Simples de Minimização

A Célula Neural Artificial Paraconsistente de Conexão Lógica Simples de Minimização tem a função de estabelecer o conectivo lógico “And” entre os sinais que são representativos dos valores de entrada.

Essa minimização é executada através da Equação Estrutural Básica, que vai informar qual dos dois sinais é o de menor valor.

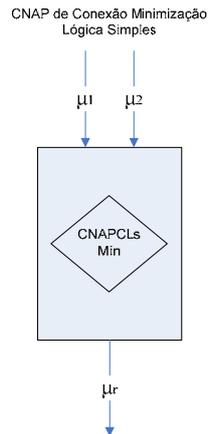


Figura A.3 Representa a *CNAPCLsMin*

A Figura A.3 descreve de forma visual o algoritmo citado abaixo, de forma que se possa compreender mais facilmente sua atuação.

Entradas:

- 1- μ_1 ;
- 2- μ_2 .

Cálculos: Nenhum.

Saídas:

Se $\mu_1 > \mu_2$ então

$$\mu_r = \mu_2;$$

Senão

$$\mu_r = \mu_1.$$

Fim

Fim.

e) Célula Neural Artificial Paraconsistente de Complementação

A Célula Neural Artificial Paraconsistente de Complementação tem a função de calcular o valor do complemento em relação à unidade do sinal de entrada.

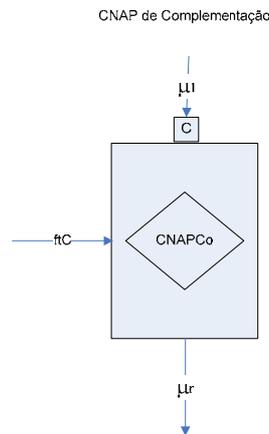


Figura A.4 Representa a *CNAPCo*

A Figura A.4 descreve de forma visual o algoritmo citado abaixo, de forma que se possa compreender mais facilmente sua atuação.

Entradas:

- 1- μ_1 ;

Entrada do Fator Externo:

- 1- ftC .

Cálculos:

- 1- $\mu_2 = \mu_1$;
- 2- $\mu_1 = \mu_2 C_0 = 1 - \mu_2$;
- 3- $G_c = \mu_1 - \mu_2$;
- 4- $EEB = (G_c + 1) / 2$

Saída:

- 1- Se $EEB \geq ftC$ então
- 2- $\mu_r = EEB$;
- 3- Senão
- 4- $\mu_r = 1/2$.
- 5- Fim

Fim

f) Célula Neural Artificial Paraconsistente de Passagem

A Célula Neural Artificial Paraconsistente de Passagem tem a função de repassar o valor do sinal para determinadas regiões da RNAP. A saída pode ser alterada, devido à comparação do valor de entrada com o do fator externo de contradição.

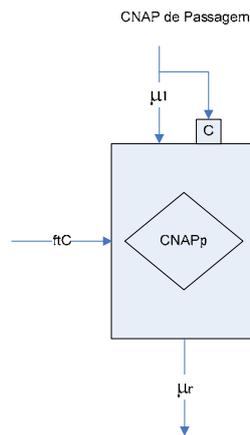


Figura A.5 Representa a *CNAPp*

A Figura A.5 descreve de forma visual o algoritmo citado abaixo, de forma que se possa compreender mais facilmente sua atuação.

Entradas:

- 1- μ_1 ;
- 2- μ_2 .

Entrada do Fator Externo:

- 1- ftC .

Cálculos:

- 1- $\mu_2 = \mu_1 C_o = 1 - \mu_1$;
- 2- $G_c = \mu_1 - \mu_2$;
- 3- $EEB = (G_c + 1) / 2$.

Saída:

- 1- Se $EEB \geq ftC$ então
- 2- $\mu_r = EEB$;
- 3- Senão
- 4- $\mu_r = 1/2$

5- Fim

Fim

g) Célula Neural Artificial Paraconsistente de Aprendizagem, Desaprendizagem e Memorização.

A Célula Neural Artificial Paraconsistente de Aprendizagem, Desaprendizagem e Memorização tem a função de aprender após um treinamento um padrão utilizando o método de análise Paraconsistente aplicado através de um algoritmo.

É possível, através da quantificação dos fatores externos de aprendizagem e desaprendizagem regular a velocidade de aprendizagem da célula, para valores altos tem-se uma aprendizagem mais lenta, com mais interações, e para valores mais baixos mais rápidos, com menos interações.

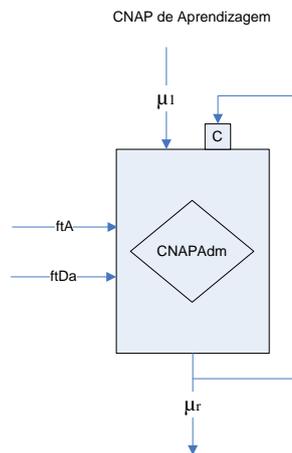


Figura A.6 Representa a *CNAPAdm*

A Figura A.6 descreve de forma visual o algoritmo citado abaixo, de forma que se possa compreender mais facilmente sua atuação.

Entradas:

1- μ_1 ;

Entrada do Fator Externo:

1- ftA ;

2- $ftDa$;

Cálculos:

1- Se $ftA = 0$ então

2- Se $ftDa \neq 0$ então

- 3- $\mu_2 = \mu_1 Co = 1 - \mu_1$
 - 4- $\mu_r = (1 - \mu_2) - (G_c - 1/2) * ftDa$
 - 5- Se ($\mu_r = 1/2$)
 - 6- Desaprendeu
 - 7- $ftA = \text{Valor nativo } ftA$
 - 8- Senão
 - 9- volta ao passo (6)
 - 10- Fim
 - 11- Fim
 - 10- Senão
 - 11- $\mu_2 = 1 - \mu_1$
 - 12- $\mu_r = (1 - \mu_2) - (\mu_r - \mu_1) * ftA$
 - 13- Se ($\mu_r = \mu_1$)
 - 14- Aprendeu
 - 15- $ftA = 0$
 - 16- Senão
 - 17- volta ao passo (11)
 - 18- Fim
 - 19- Fim
- Saída:**
- 1- μ_r
- Fim.**

h) Célula Neural Artificial Paraconsistente de Aprendizagem e Padrão Memorizado

A Célula Neural Artificial Paraconsistente de Aprendizagem e Padrão Memorizado, essa célula tem a função de consultar um padrão aprendido, fornecendo uma saída $\frac{1}{2}$ se estiver desativada. O sinal de entrada é comparado com o fator externo de padrão memorizado, influenciando no valor resultante de saída.

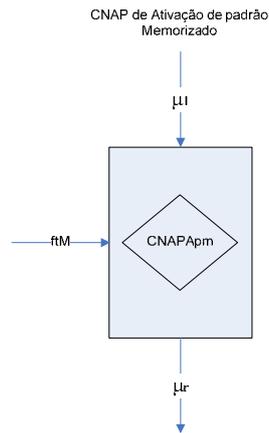


Figura A.7 Representa a *CNAPApM*

A Figura A.7 descreve de forma visual o algoritmo citado abaixo, de forma que se possa compreender mais facilmente sua atuação.

Entradas:

1- μ_1 ;

Entrada do Fator Externo:

1- ftM ;

Cálculos: Nenhum.

Saída:

Se $ftM \geq \mu_1$ então

$\mu_r = \mu_1$;

Senão

$\mu_r = 1/2$.

Fim

Fim

i) Célula Neural Artificial Paraconsistente e Reconhecimento de Padrão

A Célula Neural Artificial Paraconsistente e Reconhecimento de Padrão têm a função de reconhecer um padrão entre os sinais de entradas.

O fator externo de Reconhecimento de Padrão é utilizado para o cálculo dos Valores Superior e Inferior de Reconhecimento de Padrão, que será comparado com o resultado da Equação Estrutural Básica de Reconhecimento de Padrão.

O valor de saída igual a 1, significa sinal reconhecido, os demais o quanto foi reconhecido.

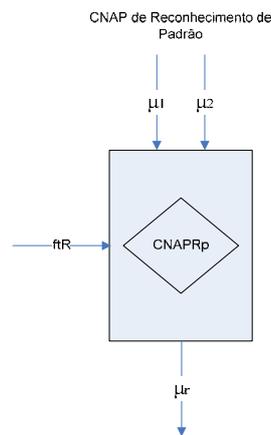


Figura A.8 Representa a *CNAPRp*

A Figura A.8 descreve de forma visual o algoritmo citado abaixo, de forma que se possa compreender mais facilmente sua atuação.

Entradas:

- 1- μ_1 ;
- 2- μ_2 ;

Entrada do Fator Externo:

- 1- ftR ;

Cálculos:

- 1- $vsrp = (1 + ftR) / 2$;
- 2- $virp = (1 - ftR) / 2$;
- 3- $G_c = \mu_1 - \mu_2$;
- 4- $EEBRp = 1 - |G_c|$

Saída:

$vsrp$ (valor superior de reconhecimento de padrão)

$virp$ (valor inferior de reconhecimento de padrão)

- 1- Se $EEBRp \geq vsrp$, então $\mu_r = 1$ (Verdade);
- 2- Se $EEBRp \geq virp$ então $\mu_r = EEBRp$ (Padrão foi reconhecido).

Estrutura da Rede Neural Artificial Paraconsistente

A Rede Neural Artificial Paraconsistente utilizada neste trabalho está estruturada respeitando a organização descrita na literatura, que são dadas por: Sistemas Neurais Artificiais Paraconsistentes que são compostos por Unidades Neurais Artificiais Paraconsistentes que por sua vez são formadas da composição das Células Neurais Artificiais Paraconsistentes.

Neste trabalho a Rede Neural Artificial Paraconsistente é composta por um Sistema e duas conexões com as Células Neurais Paraconsistentes Básicas, o objetivo é calcular os graus de evidências favorável e contrária, dada pelo cálculo dos graus de certeza e contradição e duas *CNAPs* que retornam os estados lógicos que foram a origem do mapeamento das posições utilizadas no reticulado apresentado na *LP*.

As Unidades Neurais Artificiais Paraconsistente são equivalentes aos neurônios artificiais, os *para-perceptrons*, pois possuem a estrutura modelada no conceito do neurônio *perceptron* análogo ao modelo matemático utilizado.

Quando uma *UNAP* se comunica com outra, essa comunicação se dá através de comunicações sinápticas semelhantes aos modelos das conexões do neurônio biológico.

Essas unidades se formam quando mais de uma célula se comunica entre si, e se assemelha com um neurônio quando essas comunicações acontecem em algum instante entre uma célula neural artificial de conexão analítica e uma célula neural artificial de aprendizagem, desaprendizagem e memorização.

a) *RNAP*

O Rede Neural Artificial Paraconsistente utilizada (Capítulo, 5) é composto com os objetos descritos com o seguinte algoritmo:

Entradas:

1- μ_1 ;

2- μ_2 ;

Objetos:

Quantidade de objetos paraconsistentes que compõe a RNAP é dado por um SNAPDeEv e quatro CNAPb, cuja ação é calcular valores diferentes de evidências para cada sinais de entradas, descritos como:

Saídas:

- 1- Grau Resultante de Reconhecimento;
- 2- Grau Resultante Maximizado;

Descrição a utilização da *CNAPb*

- a) A primeira *CNAPb*, tem seu valor de saída a resultante da evidência favorável (μ_{revf}) calculada através da equação do grau de certeza;
- b) A segunda *CNAPb*, tem seu valor de saída a resultante da evidência contrária (μ_{revct}) calculada através da equação do grau de certeza;
- c) A terceira *CNAPb*, tem seu valor de saída um valor discreto lógico extremo da lógica paraconsistente (μ_{vdext}) (Capítulo, 5);
- d) A quarta *CNAPb*, tem seu valor de saída um valor discreto lógico não extremo da lógica paraconsistente (μ_{vdnext}) (Capítulo, 5).

b) SNAPDeEv

O Sistema Neural Artificial Paraconsistente Descobertas de Evidências, nesse trabalho tem a função de aprendizagem e memorização de longa duração dos sinais meteorológicos, já transformados para os valores para o intervalo fechado [0,1] e reconhecidos por não similaridades.

Entradas:

- 1- μ_1 ;
- 2- μ_2 ;

Objetos:

Quantidade de *UNAPs* igual a 4 (quatro), onde se tem uma *UNAPMax*, *UNAPMin* e duas *UNAPCt*.

Saídas:

- 1- Grau de certeza resultante de maximização;

- 2- Grau de certeza resultante da minimização;
- 3- Grau de contradição resultante da maximização;
- 4- Grau de contradição resultante da minimização;

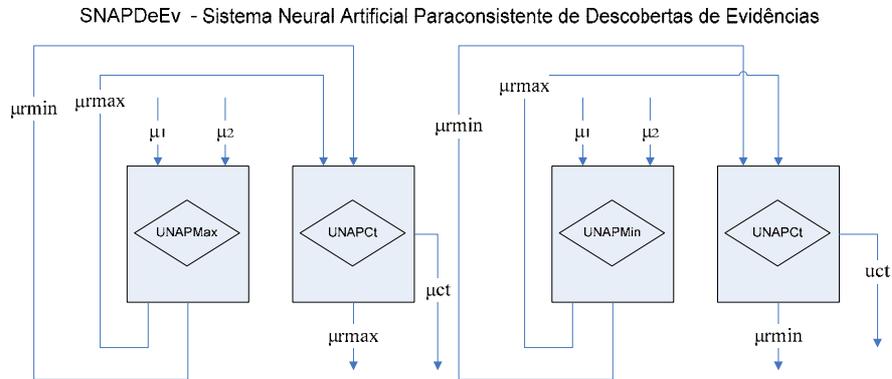


Figura A.9 Representa a *SNAPDeEv*

A Figura A.9 descreve visualmente em detalhes as ações de cada *UNAP*, o objetivo dessa figura é obter no processamento os valores resultantes máximo e mínimo, inclusive suas possíveis contradições, para serem utilizados nos cálculos de suas respectivas evidências. De posse desses valores o meteorologista pode tomar suas decisões aferidas de seus conhecimentos técnicos e operacionais.

c) *UNAPMax*

A Unidade Neural Artificial Paraconsistente de Maximização tem como finalidade reconhecer, numa seqüência de valores, qual o valor máximo entre eles, armazenando-o.

Entradas:

- 1- μ_1 ;
- 2- μ_2 ;

Objetos:

Quantidade de *CNAPs* igual a 6 (seis), onde se tem uma *CNAPCLSM_{max}*, *CNAPCLSM_{min}*, *CNAPR_p*, *CNAPC_o* e *CNAPAp_m* e *CNAPAd_m*.

Saídas:

- 1- Grau de Certeza Resultante da Maximização;
- 2- Grau de Contradição Resultante da Maximização Aprendida;

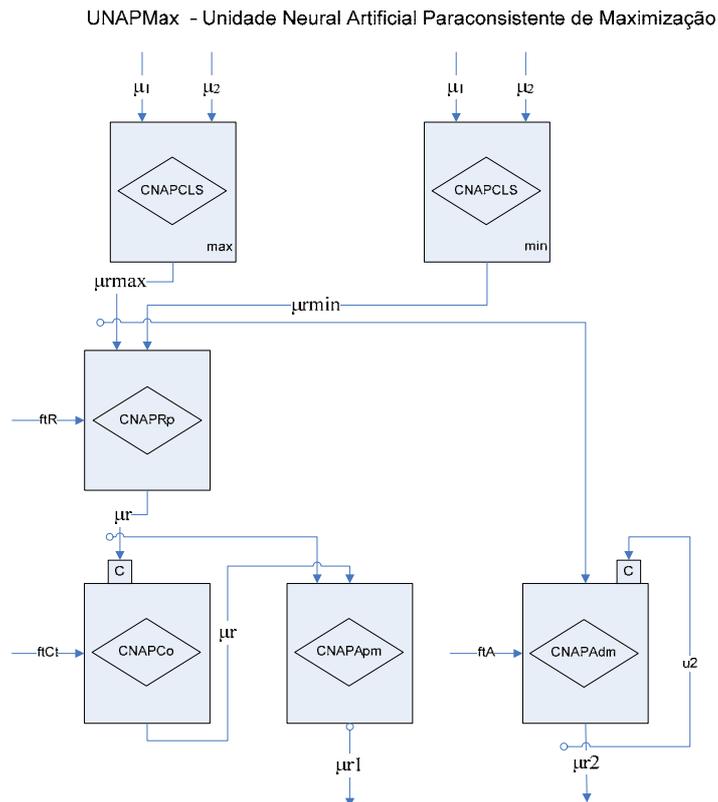


Figura A.10 Representa a *UNAPMax*

A Figura A.10 descreve visualmente em detalhes as ações de cada *CNAP* utilizada com o objetivo de obter no processamento os valores resultantes maximizados dos valores não aprendidos e aprendidos pela *CNAPAdm*, com o objetivo de serem utilizados nos cálculos das descobertas das possíveis contradições.

d) *UNAPMin*

A Unidade Neural Artificial Paraconsistente de Minimização tem como finalidade reconhecer numa seqüência de valores qual o valor mínimo entre eles, o armazenando.

Entradas:

- 1- μ_1 ;
- 2- μ_2 ;

Objetos:

Quantidade de *CNAPs* igual a 6 (seis), onde se tem uma *CNAPCLSMax*, uma *CNAPCLSMin*, uma *CNAPRp*, uma *CNAPCo*, uma *CNAPApm* e uma *CNAPAdm*.

Saídas:

- 1- Grau de Certeza Resultante da Minimização;
- 2- Grau de Contradição Resultante da Minimização Aprendida;

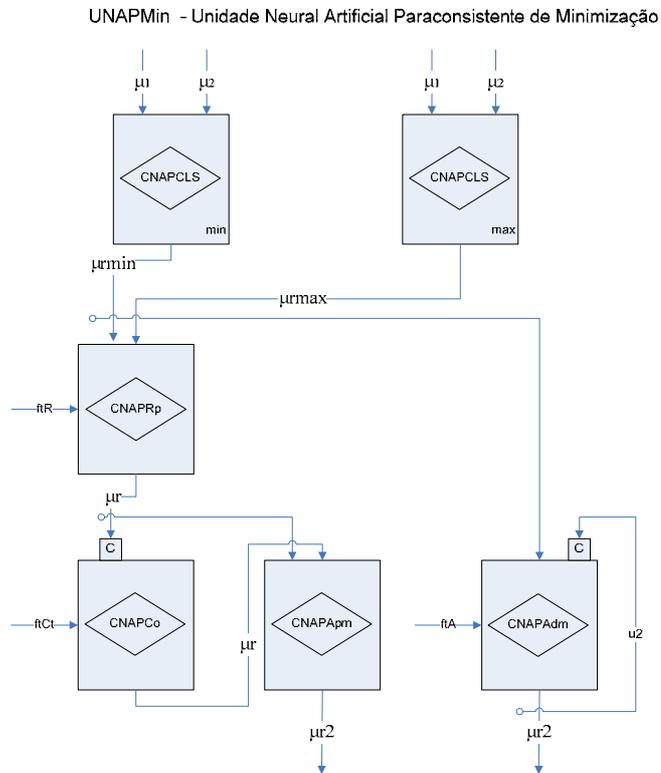


Figura A.11 Representa a *UNAPMin*

A figura B.3 descreve visualmente em detalhes as ações de cada CNAP utilizada com o objetivo de obter no processamento os valores resultantes minimizados dos valores não aprendidos e aprendidos pela CNAPAdm, com o objetivo de serem utilizados nos cálculos para as descobertas das possíveis contradições.

e) UNAPCt

A Unidade Neural Artificial Paraconsistente de Contradição tem como finalidade verificar se há valores contraditórios entre os sinais de entradas.

Entradas:

- 1- μ_1 ;
- 2- μ_2 ;

Objetos:

Quantidade de *CNAPs* igual a 7 (sete), onde se tem uma *CNAPRp*, duas *CNAPCo*, uma *CNAPp*, uma *CNAPCa*, , uma *CNAPApM* e uma *CNAPCLs*.

Saídas:

- 1- Grau de Contradição;
- 2- Grau Resultante;

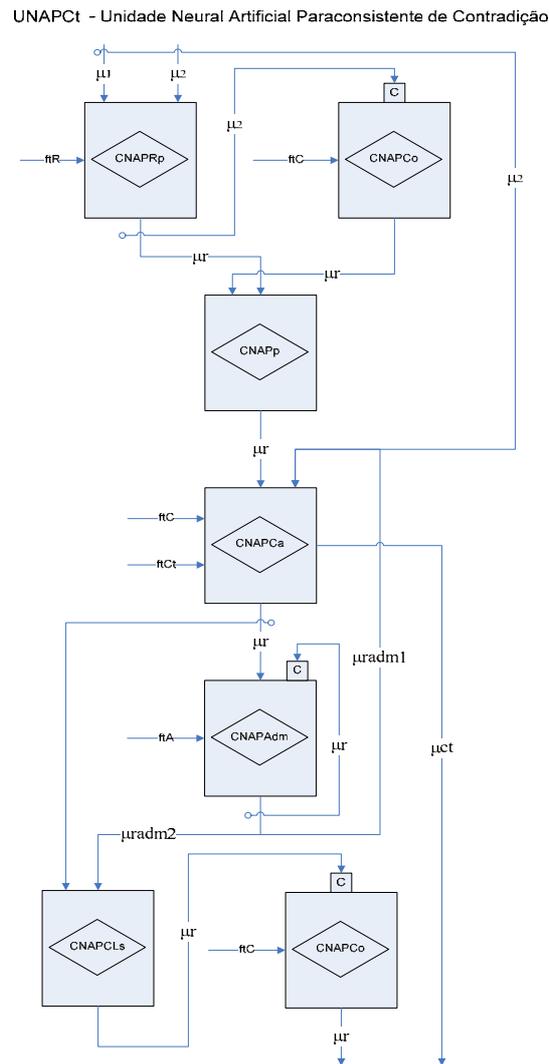


Figura A.12 representa a *UNAPMax*

A Figura A.12 descreve visualmente em detalhes as ações de cada *CNAP* utilizada com o objetivo de obter no processamento os valores resultantes das possíveis contradições encontradas após as *CNAPMax* e *CNAPMin*.