

Redes Neurais Artificiais Paraconsistentes aplicadas no Reconhecimento de Padrões dos Ciclos Sazonais para a Previsão Climática

Valdemir Silva Souza e José Demísio Simões da Silva

Laboratório Associado de Computação e Matemática Aplicada
Instituto Nacional de Pesquisas Espaciais (INPE) – São José dos Campos, SP

valdemir.silva@terra.com.br, demisio@lac.inpe.br

Resumo: Este trabalho descreve uma abordagem paraconsistente para o reconhecimento de dados meteorológicos, baseada em redes neurais paraconsistentes, aplicada a mineração de dados, especificamente para as variáveis de precipitação e temperatura dos ciclos sazonais (estação do ano), de acordo com as suas condições iniciais. A Lógica Paraconsistente descreve as ações lógicas das Redes Neurais Artificiais que são um conjunto de modelos de Neurônios Artificiais Paraconsistentes que são utilizados ao treinamento ou aprendizado de padrões. Aqui, A Rede neural Paraconsistente é revisada e seus elementos de processamentos, entradas e saídas são descritos. Os resultados apresentados são oriundos de uma rede neural paraconsistente desenvolvida para reconhecer os padrões meteorológicos que se encontram em um banco de dados disponível, neste caso, especificamente para apenas cinco regiões descritas da América do Sul que englobam mais as áreas do Brasil. Os dados de entradas são comparados por similaridades com as dados apreendidos e memorizados na Rede Neural Paraconsistente, esses dados são as variáveis que compõem os perfis do ciclo sazonal. Os resultados obtidos mostram a viabilidade, a usabilidade e a aplicabilidade do raciocínio paraconsistente na tomada de decisão relacionada à Previsão Climática.

Palavras chaves: Previsão Climática, Reconhecimento de Padrões, Ciclo Sazonal, Lógica Paraconsistente

1 Introdução

Há diversas técnicas de reconhecimento de padrões, que utilizam de tecnologias e modelos existentes, descritos nas literaturas (seção, 7). Isso corresponde a uma busca constante de algoritmos que analisam e extraem informações referentes às otimizações, classificações e mineração de dados.

A utilização das técnicas em Inteligência Artificial (IA) é cada vez mais aprimorada na adequação de processos que satisfaçam as necessidades de novos algoritmos no tratamento e reconhecimento de dados meteorológicos. Esse tipo de previsão é uma estimativa do comportamento médio atmosférico para médio e longo prazo (meses ou anos), de forma mais específica, mais qualitativo do que quantitativo. Por exemplo, é um dos objetos das previsões climáticas demonstrarem o quanto choverá em relação à média histórica nos meses de chuva de uma determinada região ou ciclo sazonal (estação do ano). Normalmente essas informações são transmitidas em três categorias: “acima da média”, “na média” e “abaixo da média histórica” (Centro de Previsão do Tempo e Estudos Climáticos, 2003).

Atualmente são utilizados dois métodos (Centro de Previsão do Tempo e Estudos Climáticos, 2003) para a previsão climática:

1. Método estatístico: utiliza equações matemáticas e conceitos de estatística.
2. Método dinâmico: utiliza equações matemáticas e conceitos físicos.

No CPTEC, é utilizado o método dinâmico, que se baseiam nas equações da primeira lei da termodinâmica, equações do movimento (2º lei de Newton), equação da continuidade de massa de ar e vapor de água conhecida como modelo de circulação geral atmosférico (MCGA). No MCGA são utilizadas as entradas conhecidas como *Condições Iniciais* (CI), compostas por variáveis atmosféricas, por exemplo: temperatura virtual,

divergência, vorticidade e umidade específica, que são calculadas a partir dos dados de temperatura, componente zonal e meridional do vento e umidade relativa, observados durante um período (1 dia corresponde a 1 condição inicial, portanto, se o modelo necessitar de 9 CI são necessários dados de 9 dias consecutivos para a análise). Através do processamento (*integrações*) destas informações no modelo, obtêm-se os resultados, chamados de *membros*. Para cada CI há um membro como resultado. Quando este modelo opera em modo *ensemble*, ou seja, são exigidas várias CI, sendo o resultado a média dos membros. Esse procedimento se faz necessário, pois segundo Murphy (Cavalcante et. al, 2002), é uma ferramenta necessária para reduzir os efeitos das CI em sistemas caóticos, como a atmosfera [10].

Porém segundo especialista em previsão climática, Camargo (2004), do CPTEC, o modelo não supre algumas necessidades de previsão, tal como padrões de precipitação para uma subárea do Centro-Oeste brasileiro. Deste tipo de informação é possível estimar para um período onde vai chover mais ou menos, ou ainda dizer qual subárea será mais quente e qual será mais fria.

No processo de previsão climática, a utilização da lógica paraconsistente para a descoberta de conhecimento nos dados meteorológicos, traz mais uma forma de aplicação da IA, no tratamento e respeito as informações que apresentam alto grau de incertezas. Ou seja, as inconsistências existentes na descoberta de conhecimento no banco de dados meteorológicos são analisadas e conseqüentemente valoradas no processo de aplicação da lógica paraconsistente em redes neurais artificiais. Isso pode proporcionar uma melhor estimativa na previsão climática. É importante salientar que o tratamento das informações é executado antes da rede neural da previsão, sendo assim, o processo de

descoberta de contradições (inconsistências) pode ocorrer e tratados na própria rede neural com a lógica paraconsistente.

Portanto, um aplicativo desenvolvido com tal técnica antecipa as ações climáticas com uma previsão que utiliza do reconhecimento das características e peculiaridades do histórico na linha do tempo, neste caso foi utilizado um histórico de 18 anos de dados meteorológicos, ao reconhecimento de padrões por similaridades. Assim, é possível encontrar perfis do ciclo sazonal, e com a técnica de mineração de dados descobrirem informações obscuras valorando as informações incertas, para auxiliar os meteorologistas nos processos da tomada de decisões numa previsão de qualidade.

2 Base de Conhecimento

A base de conhecimento é descrita como um conjunto de variáveis, que serão utilizadas para formar os perfis dos ciclos sazonais (estações do ano).

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 da superfície terrestre subjacente (Instituto Nacional de Meteorologia - 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 de observações contínuas durante um longo período, como por exemplo, 30 anos (normal climatológica). O clima abrange um maior número de dados 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.

Para a realização das análises foram coletados dados do *Climate Diagnostic Center/ National Oceanic and Atmospheric Administration* (CDC/NOAA) em [http://www.cdc.noaa.gov/], para o período de janeiro de 1980 a dezembro de 2000 (252 tempos ou 21 anos) e a área contida entre as latitudes [10° N, 35° S] e longitudes [80° W, 30° W], referente à América do Sul, em uma resolução espacial em ambas as dimensões (x, y) de 2.5° e resolução temporal (t) de 1 mês. As variáveis coletadas são mostradas abaixo:

TABELA 2.1 – VARIÁVEIS

	Variável	Descrição (nível)	Unidade
1	airt	Temperatura do ar (superfície)	°C
2	div	divergência (1 σ)	1/s
3	estacao	Estação do ano	–

4	lat	Latitude	graus
5	lon	Longitude	graus
6	prec	Precipitação (superfície)	mm/dia
7	shum	Umidade Específica (2 m)	kg/kg
8	spres	Pressão (Superfície)	mb
9	temp	Temperatura (0.1- 2 m)	°C
10	u300	Vento Zonal (300 hPa)	m/s
11	u500	Vento Zonal (500 hPa)	m/s
12	u850	Vento Zonal (850 hPa)	m/s
13	v300	Vento Meridional (300 hPa)	m/s
14	v500	Vento Meridional (500 hPa)	m/s
15	v850	Vento Meridional (850 hPa)	m/s

Para simplificação e agilidade computacional serão analisadas cinco subáreas da América do Sul, dispostas a cobrirem uma parte das cinco regiões brasileiras, pois devido à grande extensão territorial do Brasil, há muitos regimes de precipitação e conseqüentemente cada uma com seu clima típico.

As regiões são (Figura 6.2):

1. **Norte (N):** long = 67.5°W, 57.5°W; lat = -7.5°S, 0°;
2. **Nordeste (NE):** long = 45°W, 35°W; lat = -7.5°S, 0°;
3. **Centro-Oeste (CO):** long = 62.5°W, 52.5°W; lat = -22.5°S, -15°S;
4. **Sudeste (SE):** long = 52.5°W, 42.5°W; lat = -27°S, -20°S;
5. **Sul (S):** long = 60°W, 50°W; lat = -35°S, -27.5°S;




Figura 6.2 – Regiões selecionadas para análise

3 Lógica Paraconsistente

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.

Uma das interpretações válidas da Lógica Paraconsistente é descrita em (DA COSTA, 1999) e está resumida a 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 $\mu 1$ e grau de descrença até $\mu 2$. 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 $\tau = \{(\mu 1, \mu 2) | \mu 1, \mu 2 \in [0,1] \subset R\}$. 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 $\mu 1, \mu 2 \in [0,1] \subset R$ e considera-se $(\mu 2, \mu 1)$ 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.

Uma representação mais intuitiva relacionada ao contexto desse trabalho, se verifica com os seguintes exemplos, onde os valores das variáveis são comparados por:

■ Verdade – (1.0; 0.0)

As variáveis do ciclo sazonal (tabela 2.1) foram reconhecidas com grau de crença total e descrença nula.

Conclui-se: A rede neural reconheceu os valores numéricos coerentes aos fatores de tolerância desejados com sucesso.

■ Falsidade – (0.0; 1.0)

As variáveis do ciclo sazonal (tabela 2.1) foram reconhecidas com crença nula e grau de descrença total.

Conclui-se: A rede neural não reconheceu os valores numéricos coerentes aos fatores de tolerância desejados com sucesso.

■ Inconsistência – (1.0;1.0)

As variáveis do ciclo sazonal (tabela 2.1) foram reconhecidas com grau de crença total e descrença total.

Conclui-se: Houve o reconhecimento dos valores numéricos aos fatores de tolerância desejados com valores contraditórios descobertos.

4 Mineração de Dados e Reconhecimento de padrões

O sistema de duas formas foi concebido a análise dos dados na figura 4.1 está demonstrada a mineração de dados paraconsistente na busca por padrões percorrendo todos os elementos da matriz $M_{19 \times 12}$ pela matriz $N_{19 \times 12}$ denominado de método 1, dado pela equação:

$$y = \sum_{i=1}^n n(i), \text{ onde } n \text{ é o total de registros:}$$




Figura 4.1 – Método completo de mineração de dados

Na figura 4.2 representa-se a forma otimizada de busca, onde as linhas comuns entre os elementos das matrizes $M_{19 \times 12}$ e $N_{19 \times 12}$ não são analisadas, dessa forma, há uma economia de tempo de 48% no custo das buscas. Portanto, todos os resultados foram encontrados em 42% do tempo, denominado método 2 ou completo, dado

pela equação $y = \sum_{i=2}^n n(i) - 1$.




Figura 4.2 – Método das diferenças da mineração de dados

O método 2 é eficiente na otimização do tempo em 42% do tempo total, dessa forma o custo do tempo necessário para a entrada de dados na rede neural e o reconhecimento de padrões encontrados através da mineração de dados utilizando a lógica paraconsistente.

5 Rede Neural Artificial Paraconsistente

As arquiteturas conexionistas [6] são direcionadas para aprimorar fatores relevantes nos estudos das Redes Neurais das características que diferem o cérebro do computador. Por exemplo, o cérebro funciona com neurônios que quando comparados aos dispositivos digitais dos computadores, executam tarefas extremamente complexas, tais como: a análise de processamento paralelo; a interpretação de uma cena visual; a compreensão de uma frase; ou a interpretação de um som relacionado a uma imagem visual. Todas essas tarefas são executadas pelo cérebro em um tempo muito curto. O modelo de *Rede Neural Artificial Paraconsistente* (RNAP)[5] tem a finalidade de possibilitar a construção de unidades artificiais utilizando modelos mais próximos dos neurônios biológicos, efetivando assim a análise e resultados semelhantes aos efetuados pelo cérebro humano. As Redes Neurais [9] com a lógica fuzzy [8], utilizam conjuntos de pesos de valores diversos que multiplicam as entradas recebidas.

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

$$Grau_result = \frac{Grau_crença - Grau_descrença + 1}{2}$$

Essa equação computa os sinais dos graus de evidências valorados no intervalo fechado de números reais [0,1]. Os códigos são transmitidos por valores equacionados pela EEB através de células (métodos) descritas com a Lógica Paraconsistente. Quando o valor do grau de crença é 1 considera-se uma confirmação da proposição ou do padrão aplicado na entrada; se o grau de crença é 0 (zero) considera-se uma negação lógica da proposição ou do padrão aplicado na entrada, ou se o grau de crença é ½ (meio) considera-se uma indefinição lógica da proposição ou do padrão aplicado na entrada.

As equações da RNAP são muito simples porque as Células Neurais Artificiais Paraconsistentes (CNAPs), que são os fundamentos lógicos da rede paraconsistente, utilizam a EEB como descrito, para equacionar os sinais e, a partir do resultado obtido, tomam decisões e as transmitem em forma de graus resultantes as outras CNAPs. Utilizando-se de células com estas características formam-se as Unidades Neurais Artificiais Paraconsistentes (UNAPs), que são consideradas como Para-Perceptrons simples quando houver apenas uma Célula de Conexão Analítica (CNAPCa) e uma Célula de Aprendizagem, Desaprendizagem e Memorização (CNAPAdm). Por sua vez, conjuntos de UNAPs formam Sistemas Neurais Artificiais Paraconsistentes (SNAPs), onde estes conjuntos formam uma RNAP. Observou-se que as conexões entre os objetos da rede neural paraconsistente não obedecem a nenhuma hierarquia definida, onde a aleatoriedade das interligações desses objetos pode surgir em qualquer instância da RNAP.

A figura 4.1 descreve um neurônio artificial paraconsistente análogo a um neurônio biológico denominado como *Para-Perceptrom Simples* [5].

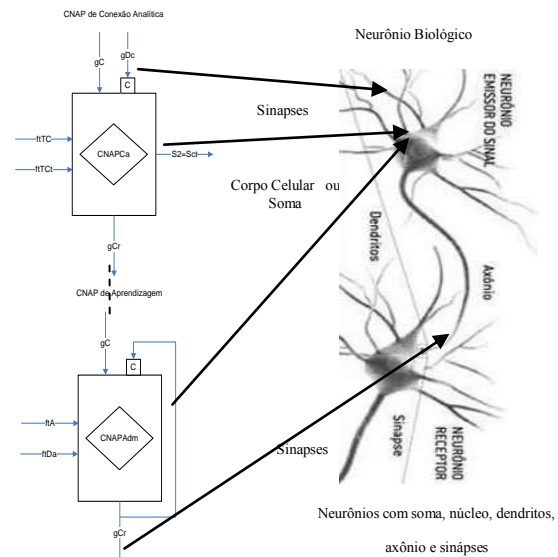


Figura 4.1 – Modelo de Para-Perceptrom Simples análogo a um neurônio biológico

As interligações que recebem o nome de conexões sinápticas no *Para-Perceptrom*, formam uma complexa rede por onde trafegam sinais representativos de proposições ou padrões que após as análises paraconsistentes, são convertidos em sinais que são as saídas resultantes desses objetos paraconsistentes e representa os graus de evidências favoráveis ou contrárias como resposta da RNAP.

5 Sistema de Reconhecimento Paraconsistente de Previsões Climáticas

O Sistema de Reconhecimento Paraconsistente de Previsões Climáticas tem como objetivo analisar e reconhecer os perfis por similaridades que compõem o histórico dos acontecimentos climáticos ao longo do tempo disponibilizado em uma base de dados de 21 anos de informações.

Nesse sistema, um conjunto de dados meteorológicos é aprendido pela RNAP, que posteriormente por similaridade obterá resultados de evidências favoráveis ou contrárias diante de novos dados de entradas, que servirão para simular a predição climática mediante fatores de tolerâncias externos, como descritos na tabela 5.1.

A Figura 5.1 mostra uma Rede Neural Artificial Paraconsistente de reconhecimento de padrão (RNAPRp). O primeiro objeto da RNAP é o Sistema Neural Artificial Paraconsistente de Reconhecimento de Padrão do Histórico (SNAPRpHist), que possui algumas entradas como fatores externos e uma entrada, grau de crença (gCB), os graus de descrenças são complementares ao de crença. Esses dados são representados numa matriz de valores reais no intervalo fechado [0,1], são utilizados para treinar a RNAPRp aprender os valores do perfil meteorológico.

O segundo objeto define o Sistema Neural Artificial Paraconsistente de Conexão Analítica (SNAPCa) para

treinar a RNAP com os valores de entrada em tempo real. É utilizado o algoritmo do método dos mínimos quadrados [1] externo à RNAP para calcular o grau de descrença.

Juntamente com o valor do grau de crença do histórico do perfil aprendido (gCB), são feitas as conexões analíticas que definem as ligações sinápticas e o reconhecimento de padrão; O terceiro objeto define o Sistema Neural Artificial Paraconsistente de Descoberta de Evidências Favoráveis e Contrárias (SNAPDeEv), nesse sistema os valores de saídas tratam de identificar a valorização dos dados memorizados e aprendidos na maximização “evidência favorável” e minimização “evidência contrária”. As saídas do SNAPDeEv são as entradas para as Células Neurais Artificiais Paraconsistentes Básicas (CNAPb), essa célula é a base

de todas as outras, pois utiliza o algoritmo Para-Analisador [5], neste trabalho é utilizado a representação simplificada do reticulado de 12 regiões da Lógica Paraconsistente [4].

Os fatores de tolerâncias têm importância relevante na RNAP, pois, as alterações ocorridas, modificam o comportamento da RNAP. Pois esses valores definem uma faixa de aceitação na análise e tomada de decisão. Na figura 4.1 tem-se: o ftTc, fator de tolerância a certeza; o ftTct, fator de tolerância a contradição; o ftCt, fator de contradição; ftTd, fator de tolerância a contradição; ftRp, fator de reconhecimento de padrão; o ftA fator de aprendizagem; ftDa, fator de desaprendizagem e ftM, fator de memorização, onde todos esses fatores são valorizados num intervalo fechado [0,1] dos números reais.

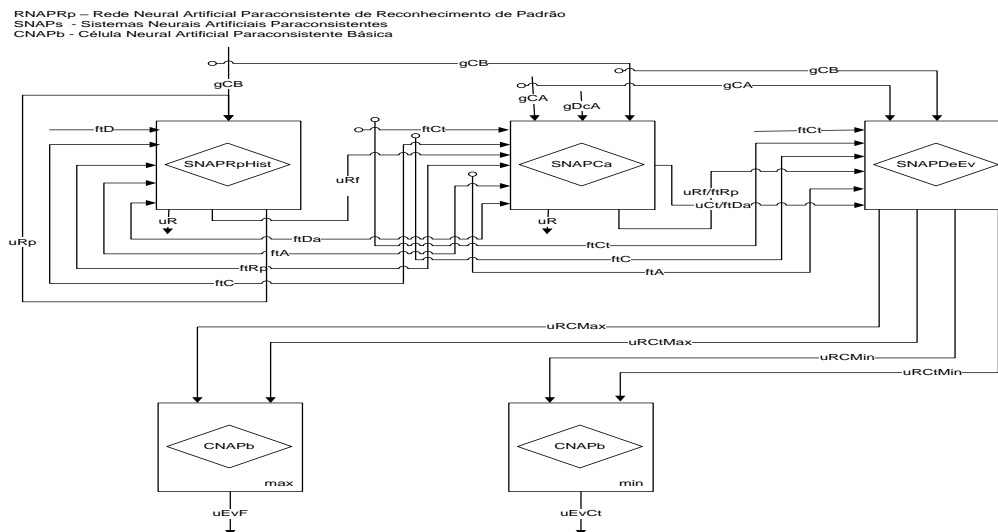


Figura 5.1 Modelo de Rede Neural Artificial Paraconsistente de Reconhecimento de Padrões

TABELA 5.1 – FATORES DE TOLERÂNCIAS

Descrição	Valor
Fator de Tolerância a Certeza	0,9975
Fator de Tolerância a Contradição	0,8479
Fator de Tolerância a Decisão	0,8900
Fator de Reconhecimento de Padrão	0,9497
Fator de Aprendizagem	0,9500
Fator de Desaprendizagem	0,9500

A tabela 5.1, representa os valores inicializados externamente a rede neural paraconsistente, esses valores são definidos como fatores de tolerâncias, nessa aplicação são valores estáticos, mas também podem ser dinâmico durante a aplicação. Os fatores mais sensíveis nessa convergência dos resultados encontrados foram os Fatores de Tolerância a Contradição e Reconhecimento de Padrão.

TABELA 5.2 – ÁREAS ANALISADAS

Qtd	Long	Lat	Qtd	Long	Lat
1	315°W	0°	11	3125°W	-25°S
2	315°W	-5°S	12	3125°W	-75°S

3	315°W	-25°S	13	3175°W	0°
4	315°W	-75°S	14	3175°W	-5°S
5	320°W	0°	15	3175°W	-25°S
6	320°W	-5°S	16	3175°W	-75°S
7	320°W	-25°S	17	3225°W	0°
8	320°W	-75°S	18	3225°W	-5°S
9	3125°W	0°	19	3225°W	-25°S
10	3125°W	-5°S	20	3225°W	-75°S

Cada linha da tabela 5.2, está relacionada com um arquivo que contém 21 anos de dados climáticos distribuídos nos 4 ciclos sazonais, de acordo com os dados especificados (seção, 2).

Na figura 5.2 apresenta os padrões encontrados normalizados, com a aplicação do Método-1 de otimização (seção, 4).

A normalização foi aplicada utilizando o algoritmo matemático, onde m é igual a maximização dos valores do vetor, que representa cada linha da matriz $M_{21 \times 12}$ de entrada, e y os valores otimizados, cujo as linhas são as áreas analisadas e as colunas os meses do ano:

$$m = \max(x); y(i) = \sum_{i=1}^{n=12} \frac{x_i}{m}$$

5.2, a visualização dos padrões analisados, utilizando a Lógica Paraconsistente é permitida que as diferenças mínimas encontradas em cada ciclo sazonal sejam

valoradas na previsão climática.




Fig. 5.2 Padrões encontrado com o Método 1

Na figura 5.3 está a representação dos padrões encontrados com a utilização do método 2, que é a otimização da busca por padrões.

Nota-se que a partir da quantidade de áreas analisadas 13 os padrões sofrem diferenças, criando um novo padrão.

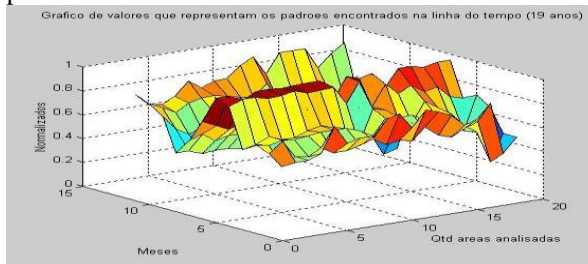


Fig. 5.3 Padrões encontrados com o Método 2

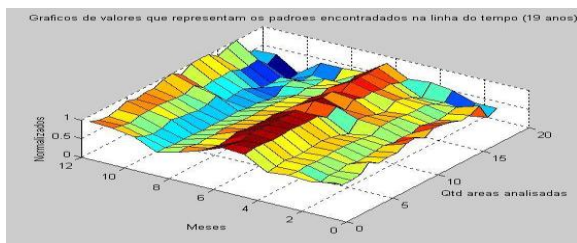


Fig. 5.4 Visualização dos padrões com o Método 2

6 Resultados

A busca de padrões na Previsão Climática das variáveis de precipitação e temperatura para cada área demarcada (seção, 2), apresentou que o método RNAP tem sua performance computacional alta na execução da rede neural e custo computacional baixo no tratamento dos dados a serem executados “in loco”.

A cada registro atmosférico enviado a rede neural, os resultados apresentaram o reconhecimento de padrões, através das concentrações dos resultados referentes às áreas e estações de origem, a figura 6.1, representa de forma visível a semelhanças das curvas de cada item da tabela 5.2. Assim, a previsões climáticas de acordo com as respostas encontradas com a Lógica Paraconsistente busca as diferenças não perceptíveis de forma não-trivial.

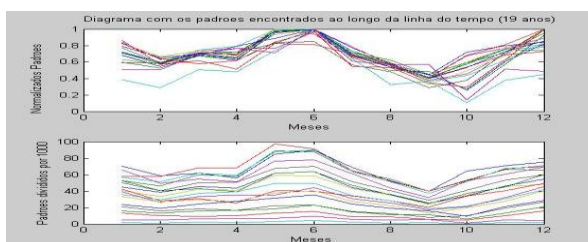


Figura 6.1 Comparação dos padrões encontrados (normalizados x valores divididos por 1000)

A previsão é concluída a partir dos valores maximizados em ordem decrescente de prioridades até seu último nível. A parte inferior da figura 6.1 é apenas uma visualização dos valores não normalizados e apenas divididos por 1000, para representar as diferenças existentes em suas quantidades por mês.

7 Conclusões

Utilizando a Lógica Paraconsistente como instrumento lógico da Rede Neural Artificial, notou-se que as incertezas são valoradas. Pois, são extraídas as informações relevantes à descoberta e reconhecimento de padrões. A Rede Neural Artificial Paraconsistente foi comparada com o método utilizado sem o tratamento das incertezas por uma rede neural artificial utilizando um *Perceptron* de multicamadas e outra, juntamente com um filtro de dados que utiliza a teoria dos conjuntos aproximativos [10].

Uma das vantagens em utilizar a Lógica Paraconsistente na identificação das incertezas que são ocasionadas por contradições, ou seja, inconsistências é o fato, desse tratamento estar intrínseco na própria Lógica Paraconsistente.

Portanto, é conclusiva a possibilidade de utilização e existência de um baixo custo computacional com a utilização da RNAP nesse segmento de mercado e pesquisa de dados meteorológicos especificamente previsões climáticas.

Referências

- [1] Da Fonseca, Jairo Simon, entre outros; Estatística Aplicada; São Paulo, SP, Editora Atlas, 1995, págs 141-154.
- [2] Fausett, Laurene; Fundamentals of Neural Networks – Architectures, algorithms and applications; Prentice Hall, 1994.
- [3] Prado, João Carlos Almeida. Redes Neurais Artificiais Paraconsistentes e sua utilização para reconhecimento de padrões; Dissertação de Mestrado, São Paulo, SP, 2002, USP.
- [4] Da Costa, Newton C. A., Abe, Jair Minor e outros. Lógica Paraconsistente Aplicada; São Paulo, SP, Editora Atlas, 1999, págs 21-117.
- [5] Da Silva Filho, João Inácio, Abe, Jair Minor. Fundamentos das Redes Neurais Artificiais Paraconsistentes. São Paulo, SP, Editora VillaPress, 2001, págs 85-223, 247-257.
- [6] Fialho, Francisco; Ciências da Cognição; São paulo, SP, Editora Insular, 2001.
- [7] Russel, Stuart e Norvig, Peter; Inteligência Artificial, São Paulo, SP, Editora Campus, 2004.
- [8] Haykin, Simon; Redes Neurais – Princípios e Prática; Porto Alegre, RS, Editora Bookman, 2002.
- [9] Neto, Luiz Garcia Palma; Redes Neurais Construtivas para *classificação* de padrões; Dissertação de Mestrado; Universidade Federal de São Carlos; São Carlos; 2004.
- [10] Pessoa, A. S. A.; Mineração de dados meteorológicos pela teoria dos conjuntos aproximativos na previsão de clima por redes neurais ; Dissertação de Mestrado; Instituto de Pesquisas Espaciais – INPE; São José dos Campos; 2004.