

USO DE REDES NEURAS ARTIFICIAIS E TEORIA DE CONJUNTOS APROXIMATIVOS NO ESTUDO DE PADRÕES CLIMÁTICOS SAZONAIS

JULIANA A. ANOCHI, JOSÉ DEMISIO S. SILVA

Laboratório Associado de Computação e Matemática Aplicada (LAC), Instituto Nacional de Pesquisas Espaciais (INPE)
Av. dos Astronautas, 1758, São José dos Campos-SP, CEP:12227-010, Brasil

Emails: juliana.anochi@lac.inpe.br, demisio@lac.inpe.br

Resumo - Este trabalho utiliza técnicas de Inteligência artificial baseado em um método de redução de atributos, para realização de previsão climática usando um modelo de Rede Neural Artificial. Para o desenvolvimento desta metodologia utilizou-se a Teoria dos Conjuntos Aproximativos para extrair informações relevantes dos dados, visando reduzir a redundância entre as variáveis. O processo de previsão climática foi desenvolvido sobre a região Nordeste do Brasil, para aprender o comportamento sazonal da variável de precipitação.

Palavras-chave - Previsão Climática, Teoria dos Conjuntos Aproximativos, Redes Neurais Artificiais.

Abstract - This work presents an Artificial Intelligence based approach for attribute reduction of reanalysis climate data to build a climate forecasting model using artificial neural networks. The methodology uses Rough Sets Theory for retrieving relevant information from the available data, thus reducing the correlation redundancy among the variables used for forecasting purposes. Neural network based forecasting models are developed for Northeast Brazil, by learning the seasonal behavior of the precipitation variable.

Keywords - Climate Forecasting, Rough Sets Theory, Artificial Neural Networks.

1. Introdução

Este trabalho apresenta um método de redução de atributos que utiliza a Teoria de Conjuntos Aproximativos (TCA) usada em processos de extração da informação e tomada de decisão em aplicações de Inteligência Artificial (IA). O objetivo do trabalho é derivar conjuntos de dados de dimensão reduzida (reduzidos ou reduções) para o treinamento de redes neurais artificiais (RNAs) para realizar a previsão climática, a partir de um conjunto de dados climáticos sazonais de reanálise.

O método de redução de dados apresentado é utilizado para adequar o volume de dados disponível para o processamento por RNAs, em especial durante a fase de treinamento, para a obtenção de modelos de previsão de clima. O modelo de previsão baseado em RNAs é proposto para criar alternativas para a aquisição de prognósticos de variáveis climáticas a serem utilizadas em processos de tomada de decisão. Portanto, este método visa, através de uma abordagem por mineração de dados, analisar e compreender o comportamento atmosférico, a partir de dados de reanálise, com intuito de identificar informações relevantes que possam ser usadas em processos de previsão climática.

O método de pré-processamento de dados é uma proposta de abordagem do problema relacionado com grandes volumes de dados, que tem se tornado frequente em função do aumento do número e da disponibilidade de sensores que permitem um melhor monitoramento de fenômenos físicos, em especial no caso do estado da atmosfera em Meteorologia. Assim, na Meteorologia a previsão de clima ou tempo pode envolver um grande número de variáveis, correspondentes às medidas ou observações dos fenômenos físicos que se relacionam com os processos da atmosfera.

Os fenômenos encontrados na natureza são altamente complexos e podem apresentar diferentes opções de comportamento. Em função das transformações ambientais o entendimento do comportamento climático tem sido cada vez mais, uma tarefa essencial para a humanidade que pode ser muito complexa em função da disponibilidade de dados, em particular, na Meteorologia, em que essa disponibilidade implica no aumento de dificuldade no processo de previsão meteorológica.

Quanto maior o número de informações obtidas sobre os fenômenos físicos atmosféricos, mais subsídios existirão para tentar melhorar a previsão. Mas isso implica diretamente no aumento da necessidade de recursos computacionais para manipular grandes volumes de dados, quando estes são usados em modelos de previsão que simulam a evolução dos fenômenos físicos.

cos. Por outro lado, o estudo dos dados históricos pode ajudar a criar padrões das condições da atmosfera e assim construir um modelo empírico de previsão.

Nesse trabalho propõe-se uma metodologia aplicada na previsão climática usando uma abordagem de mineração de dados, com o propósito de buscar reduções das variáveis de entrada para compor um modelo empírico de previsão usando uma rede neural do tipo Perceptron de Múltiplas Camadas (MLP), para construção de um modelo de previsão a partir de um conjunto de dados pré-processado pela TCA.

O pré-processamento é necessário para eliminar redundâncias e buscar a redução da dimensão dos dados para viabilizar o treinamento das RNAs, em termos de tempo de processamento para a obtenção de um modelo de previsão climática. O pré-processamento com a TCA busca identificar os atributos mais relevantes para o processo de previsão, permitindo assim uma redução da complexidade do problema.

Esse trabalho apresenta como vantagem a possibilidade de criar modelos de previsão climática a partir de um conjunto simplificado de dados e de realizar prognósticos do comportamento climático, utilizando modelos simplificados construídos diretamente dos dados utilizando redes neurais.

Os dados climatológicos de reanálise utilizados nos experimentos foram extraídos de quatro subáreas da região Nordeste do Brasil, onde se procurou aprender o comportamento dos fenômenos meteorológicos.

O restante deste trabalho está organizado da seguinte forma: a Seção 2 faz uma breve introdução ao problema de previsão climática; a Seção 3 traz os princípios teóricos da TCA; a Seção 4 introduz as redes neurais artificiais, destacando o perceptron de múltiplas camadas; a Seção 5 apresenta a metodologia utilizada no trabalho e descreve os dados utilizados; e a Seção 6 traz as conclusões do trabalho.

2. Previsão Climática

A previsão climática é definida como a estimativa do comportamento médio da atmosfera com alguns meses de antecedência. Por exemplo, em uma escala de tempo sazonal, pode-se prever se o próximo inverno será mais frio que a média, ou ainda, se haverá mais chuva que a estação anterior, ou seja, o objetivo da previsão climática é estimar as propriedades estatísticas do estado climático no futuro [1].

Tempo e clima são conceitos distintos usados em meteorologia para se entender o comportamento da atmosfera em diferentes intervalos de tempo. O estudo do Tempo refere-se às condições da atmosfera, em uma determinada região do planeta, em um intervalo de tempo muito curto, a partir do estado considerado. Essa é uma tarefa complexa devido ao dinamismo inerente do estado da atmosfera em relação aos seus efeitos sobre a vida e as atividades do ser humano. O estudo do Clima está no comportamento médio da atmosfera em um intervalo de tempo maior. É uma integração das condições do tempo em certo período representando uma caracterização mais abstrata [9].

A previsão do clima realizada por centros de previsão como o Centro de Previsão de Tempo e Clima do Instituto Nacional de Pesquisas Espaciais (CPTEC – INPE) e semelhantes, utilizam modelos que procuram descrever o comportamento das condições físico-químicas da atmosfera. Estes modelos são executados em sistemas computacionais de grande porte gerando como saídas possíveis estados futuros da atmosfera com alta resolução. Estas atividades apóiam estudos de impactos e vulnerabilidades e permitem que se façam projeções dos extremos climáticos do estado atmosférico.

Para realização de previsões climáticas existem os modelos numéricos. Dentre esses modelos existe o chamado Modelo de Circulação Geral Atmosférico (MCGA), que tem sido utilizado para a realização de previsão climática, de forma experimental, para estudar a variabilidade e as mudanças climáticas. Outro modelo numérico é o modelo regional, que é uma solução para aumentar a resolução do modelo sem aumentar o custo computacional. Este modelo prevê fenômenos de pequena escala como tempestades, brisa marítimas entre outros [1].

3. Teoria dos Conjuntos Aproximativos

A Teoria dos Conjuntos Aproximativos (TCA), proposta pelo matemático polonês Zdzislaw Pawlak em 1982, é um formalismo matemático, para o tratamento de informações incertas e imprecisas, por meio de aproximações de um conjunto de dados [8].

A TCA baseia-se nas similaridades entre objetos através de uma relação de indiscernibilidade que essencialmente considera que dois ou mais objetos são indiscerníveis (ou similares) se possuem os mesmos valores para todos os atributos que os caracterizam. Esta relação de indiscernibilidade permite que a TCA possa ser usada para construir subconjuntos de variáveis de uma base de dados que mantêm a informação da base, em um processo de eliminação de atributos irrelevantes proporcionando uma redução dos dados.

As principais vantagens do uso da TCA em relação a outras abordagens de tratamento da incerteza são: a possibilidade de gerar regras de decisão em função do processamento e o tratamento quantitativo e qualitativo da incerteza.

No desenvolvimento deste trabalho foi utilizado o sistema ROSETTA (Rough Set Toolkit for Analysis of Data – <http://www.lcb.uu.se/tools/rosetta>), que é um conjunto de algoritmos para análise tabular de dados sob a abordagem da TCA, construído como ferramenta de apoio a processos de mineração de dados e descoberta de conhecimento em banco de dados, cobrindo as diferentes etapas do processo. Uma característica importante do ROSETTA é a possibilidade de validação dos conjuntos reduzidos de dados e a análise das regras geradas durante o processo [7].

3.1. Sistema de Informação

A representação dos dados na abordagem TCA é feita através de um Sistema de Informação (SI) em que os dados são representados no formato de tabela, na qual as linhas correspondem aos objetos e as colunas representam os atributos [4].

A definição formal de um SI é um par ordenado $SI = (U, A)$ em que U , é um conjunto finito e não vazio de objetos, chamado de universo e A é um conjunto finito e não vazio de elementos chamados de atributos, tal que, $a: U \rightarrow V_a$ para todo $a \in A$. O conjunto V_a é o conjunto de valores de a , chamado de domínio de a .

Um Sistema de Decisão (SD) é um SI considerando um atributo de decisão d que não pertence ao conjunto de atributos A . Formalmente, $SD = (U, A \cup \{d\})$, em que $d \notin A$ é o atributo de decisão [5].

Um SD pode ser determinístico o qual descreve unicamente as decisões e ações a serem efetuadas quando são satisfeitas algumas condições ou não-determinístico se as decisões não são determinadas excepcionalmente pelas condições.

A Tabela 3.1 apresenta um exemplo de SD em que o atributo Chuva, referindo-se à ocorrência de chuva, é a decisão. O conjunto de objetos é $U = \{a_1, a_2, a_3, a_4, a_5, a_6\}$, o conjunto de atributos é $A = \{\text{Mês, Temperatura, Vento}\}$ e o atributo de decisão $d = \{\text{Chuva}\}$.

Tabela 3.1. Sistema de Decisão.

U	Atributos Condicionais			Decisão
	Mês	Temperatura	Vento	Chuva
a_1	Janeiro	alta	fraco	sim
a_2	Março	média	moderado	sim
a_3	Julho	baixa	forte	não
a_4	Setembro	alta	fraco	não
a_5	Março	média	moderado	não
a_6	Janeiro	alta	fraco	sim

3.2. Relação de Indiscernibilidade

A relação de indiscernibilidade é usada para medir a similaridade entre dois ou mais objetos, ou seja, vários objetos, caracterizados pelos mesmos valores de seus atributos, são indiscerníveis entre si. Essa é uma relação de equivalência que possui a capacidade de tratar problemas como: redundância de atributos idênticos ou à existência de atributos supérfluos, de modo que, apenas um objeto represente toda uma classe.

Dado um sistema de informação $SI = (U, A)$, então com qualquer conjunto $B \subseteq A$ existe uma relação de equivalência $IND_A(B)$ definida pela Expressão 1 que estabelece que dois objetos x e x' do conjunto U , são indiscerníveis para um subconjunto de atributos $B \subseteq A$, se para cada atributo a , de x e x' , em B , os valores forem iguais.

$$IND_A(B) = \{x, x' \in U^2 / \forall a \in B, a(x) = a(x')\} \quad (1)$$

A relação de indiscernibilidade $U/IND_A(B)$ para cada subconjunto $B \subseteq A$ no exemplo da Tabela 3.1 está representada na Tabela 3.2.

Tabela 3.2. Relação de Indiscernibilidade.

$U/IND_A(\{\text{Mês}\})$	$\{\{a_1, a_6\}, \{a_2, a_5\}, \{a_3\}, \{a_4\}\}$
$U/IND_A(\{\text{Temperatura}\})$	$\{\{a_1, a_4, a_6\}, \{a_2, a_5\}, \{a_3\}\}$
$U/IND_A(\{\text{Vento}\})$	$\{\{a_1, a_4, a_6\}, \{a_2, a_5\}, \{a_3\}\}$
$U/IND_A(\{\text{Mês}, \text{Temperatura}\})$	$\{\{a_1, a_6\}, \{a_2, a_5\}, \{a_3\}, \{a_4\}\}$
$U/IND_A(\{\text{Mês}, \text{Vento}\})$	$\{\{a_1, a_6\}, \{a_2, a_5\}, \{a_3\}, \{a_4\}\}$
$U/IND_A(\{\text{Temperatura}, \text{Vento}\})$	$\{\{a_1, a_4, a_6\}, \{a_2, a_5\}, \{a_3\}\}$
$U/IND_A(\{\text{Mês}, \text{Temperatura}, \text{Vento}\})$	$\{\{a_1, a_6\}, \{a_2, a_5\}, \{a_3\}, \{a_4\}\}$

Para o subconjunto $B = \{\text{Temperatura}\}$, os objetos $\{a_1, a_4, a_6\}$ e $\{a_2, a_5\}$ estão na mesma classe de equivalência e são indiscerníveis, ou seja, os objetos agrupados não podem ser discernidos entre si. Cada um desses grupos é uma classe. Por exemplo, a Tabela 3.3 mostra as classes construídas para o subconjunto $B = \{\text{Mês}, \text{Temperatura}, \text{Vento}\}$. A classe C_1 surgiu dos objetos $\{a_1, a_6\}$, a classe C_2 teve origem dos objetos $\{a_2, a_5\}$, a classe C_3 ocasionou-se do objeto $\{a_3\}$ e a classe C_4 surgiu do objeto $\{a_4\}$.

Tabela 3.3. Classe para $U/IND_A\{\text{Mês}, \text{Temperatura}, \text{Vento}\}$.

U	Atributos Condicionais		
	Mês	Temperatura	Vento
C_1	Janeiro	alta	fraco
C_2	Março	média	moderado
C_3	Julho	baixa	forte
C_4	Setembro	alta	fraco

3.3. Redução de Atributos

O processo de redução é feito através dos chamados redutos (RED), que são subconjuntos de atributos com capacidade de representar o conhecimento da base de dados, ou seja, são agrupados em classes os objetos que são indiscerníveis a partir da matriz de discernimento. Somente os atributos que preservam a relação de indiscernibilidade são mantidos na redução, ou seja, existe um subconjunto de atributos condicionais que mantêm a mesma partição, levando em consideração as classes formadas pelo atributo de decisão. Os atributos restantes são redundantes, ou supérfluos, desde que suas remoções mantenham a mesma classificação [5].

O procedimento de redução de atributos é feito pela função de discernimento $F_A(B)$ a partir da matriz de discernibilidade (ou matriz de discernimento) que é uma matriz simétrica construída a partir da comparação entre os valores dos atributos que discerne os objetos e aqueles que apresentam valores discerníveis são inseridos na matriz, ou seja, cada entrada consiste em um conjunto de atributos que difere os objetos x_i e x_j (Expressão 2) [7].

$$m_D(i, j) = \{a \in B / a(x_i) \neq a(x_j)\} \quad (2)$$

para $i, j = 1, \dots, n$ sendo $1 \leq i, j \leq n$ e $n = |U/IND_A(B)|$.

Considerando os atributos $\text{Mês} = M$, $\text{Temperatura} = T$ e $\text{Vento} = V$, com intuito da construção da matriz de discernimento $M_{i,j}(B)$ a partir da Tabela 3.3, tem-se na Tabela 3.4 a sua representação. Analisando a Tabela 3.3, observa-se que para as classes C_1 e C_2 os três atributos $\{\text{Mês}, \text{Temperatura}, \text{Vento}\}$ possuem valores diferentes, desta forma, esses atributos são inseridos na matriz na posição (1,2). O mesmo ocorre para as classes C_1 e C_3 , os três atributos com valores diferentes, são colocados na posição (1,3) na matriz e para as classes C_1 e C_4 o único atributo com valor diferente é $\{\text{Mês}\}$, este é inserido na matriz na posição (1,4) [6].

Tabela 3.4. Matriz de Discernimento.

	C ₁	C ₂	C ₃	C ₄
C ₁	∅	M, T, V	M, T, V	M
C ₂	M, T, V	∅	M, T, V	M, T, V
C ₃	M, T, V	M, T, V	∅	M, T, V
C ₄	M	M, T, V	M, T, V	∅

A função de discernibilidade $f(B)$ é uma função booleana com m variáveis (correspondente aos atributos a_1, \dots, a_m), construída a partir da concatenação dos atributos de cada célula da matriz de discernimento, onde os elementos são organizados pelas disjunções dos elementos $m_D(x_i, x_j)$ definida pela expressão:

$$f_A(a^1, \dots, a^m) = \left\{ m_D(i, j) / 1 \leq j \leq i \leq n, m_D(i, j) \neq \emptyset \right\} \quad (3)$$

Sendo $m_D(i, j) = \{a \mid a \in m_D(i, j)\}$. Utilizando a simplificação de expressões booleanas pela função de indiscernibilidade, define-se o conjunto mínimo de atributos necessários para discernir qualquer classe de equivalência das demais [8].

4. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são técnicas computacionais cujo funcionamento baseia-se na estrutura neural de seres vivos e que realizam tarefas de computação adquirindo conhecimento através de experiência, construída por um processo de aprendizagem. Algumas de suas vantagens importantes são as características de adaptabilidade, generalização e tolerância a falhas [4].

Existem vários tipos de RNAs que diferem em arquitetura ou forma de treinamento. Para o problema de construção de modelos de previsão, como proposto neste trabalho, que utiliza dados históricos do estado da atmosfera e a informação do fenômeno que se deseja, utiliza-se um Perceptron de Múltiplas Camadas (MLP), com treinamento supervisionado realizado pelo algoritmo de retropropagação do erro [4].

O algoritmo de retropropagação do erro, baseado nos mínimos quadráticos (regra Delta) e consiste na propagação da entrada pelas camadas sucessivas da MLP, até gerar uma saída que é comparada com o valor real disponível, gerando um erro que é retropropagado na MLP, camada por camada, sendo seguida pela modificação dos respectivos pesos.

A rede MLP possui as seguintes características: cada neurônio possui uma função de ativação não linear, pode assumir uma ou mais camadas escondidas de neurônios e alto grau de conectividade.

5. Metodologia

A área de estudo, para realização dos experimentos, compreende quatro subáreas da região Nordeste do Brasil que são mostradas na Figura 5.1. As coordenadas geográficas são relacionadas na Tabela 5.1, compreendendo 20 pontos de grade para a subárea 1, 15 para a subárea 2, 16 para a subárea 3 e 12 para a subárea 4.

Tabela 5.1. Coordenadas das subáreas de estudo.

Subárea	Longitude	Latitude
1	47°W, 40°W	-7.5°S, 0°
2	40°W, 35°W	-10°S, 0°
3	47°W, 40°W	-17.5°S, -10°S
4	40°W, 35°W	-10°S, -0°

Em cada subárea os dados são utilizados para construir uma base de dados reduzida, através da aplicação da TCA. Em seguida, a base de dados (ou a redução) obtida forma o conjunto de treinamento da rede neural (MLP) para a obtenção do modelo de previsão da respectiva subárea.

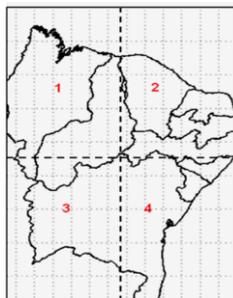


Figura 5.1. Subáreas de estudo.

O objetivo do presente trabalho é a obtenção de um modelo de previsão eficiente a partir de um conjunto de dados reduzidos, com base na hipótese de que algumas variáveis são mais adequadas para se estimar o estado futuro da atmosfera. Assim, para efeito de comparação, neste trabalho optou-se pela construção de dois modelos de previsão, baseados em RNA: um gerado a partir do treinamento de uma MLP usando todos os dados disponíveis na base de dados, e outro em que foram usados os dados pré-processados pela TCA, ou seja, os dados com redução da dimensão. O principal objetivo da comparação foi verificar se as reduções podem gerar modelos cujos resultados de previsão são comparáveis com aqueles obtidos utilizando-se todos os dados. A análise de custo computacional não foi tratada neste trabalho. No pré-processamento com a TCA, os atributos relevantes para o processo de previsão climática são selecionados, como aqueles com maior ocorrência, segundo a relação de indiscernibilidade, formando os redutos desejados para o treinamento da rede neural.

Os dados utilizados nos experimentos conduzidos neste trabalho foram coletados da base de dados de reanálise do NCEP/NCAR (National Centers for Environmental Prediction / The National Center for Atmospheric Research) [<http://www.ncep.noaa.gov/>].

O período de tempo compreende uma janela de 21 anos entre janeiro de 1980 e 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. A resolução espacial, em ambas as dimensões da grade, de 2.5° e resolução temporal (t) de 1 mês.

As variáveis contidas na base de dados são:

- Temperatura do ar (*airt*);
- Divergência (*div*);
- Precipitação (*prec*);
- Umidade específica (*shum*);
- Pressão da superfície (*spres*);
- Componentes do vento zonal em:
 - 300 hPa (*v300*);
 - 500 hPa (*v500*); e
 - 850 hPa (*v850*)
- Componentes do vento meridional em:
 - 300 hPa (*u300*);
 - 500 hPa (*u500*); e
 - 850 hPa (*u850*).

Do conjunto total de dados, foram selecionados 18 anos (janeiro de 1980 a dezembro de 1997) para o treinamento dos modelos de redes neurais e como entrada para o processamento pela TCA. Os demais 3 anos (janeiro de 1998 a dezembro de 2000) foram usados para a validação dos modelos. Destes dados de validação foi selecionado um subconjunto contendo 25% dos dados através de um processo de escolha aleatória, formando o conjunto de teste para o critério de parada antecipada no treinamento das redes. A métrica para quantificar o desempenho da previsão foi o erro quadrático médio E dado por:

$$E = \frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2 \quad (4)$$

em que N é o número de pontos da grade, y_k é o valor real no ponto de grade e \hat{y}_k é a estimaco produzida pela rede. Para a visualizaco e anlise dos resultados utilizou-se a ferramenta GrADS (Grid Analysis and Display System) que é um software utilizado para visualizaco e anlise de dados em pontos de grade [2].

5.1. Resultados

Para o processamento das reduoes dos atributos no ROSETTA, os dados so inicialmente discretizados e submetidos a um algoritmo de reduo que seleciona os atributos mais relevantes, como aqueles com ocorrncia igual ou superior a 70% (valor escolhido de forma ad hoc) de presena na funo de indiscernimento. Os resultados obtidos neste trabalho so apresentados na Tabela 5.2 para as 4 subreas de estudo.

Tabela 5.2. Redutos extraidos pela TCA.

Redutos			
Subrea 1	Subrea 2	Subrea 3	Subrea 4
airt	airt	airt	airt
u850	u850	u500	u500
u500	u500	v850	v850
v850	u300	v500	v300
v500	v500	v300	shum
v300	v300	spres	div
shum	shum	div	
div	spres		

Observe-se que das onze variveis citadas na Seo 5, oito so necessrias nas subreas 1 e 2, sete na subrea 3 e apenas seis na subrea 4. Estas reduoes so utilizadas ento para o treinamento das redes neurais de cada subrea, na busca pelo modelo de previso.

A natureza do problema de previso de clima, atravs de uma abordagem inversa como tratada neste trabalho, indica a necessidade de utilizar modelos de redes neurais com aprendizagem supervisionada. Neste trabalho optou-se por utilizar o modelo de rede de perceptrons de mltiplas camadas (MLP), instanciando as redes para as subregies tratadas, gerando no total 4 redes MLP. Para o treinamento da rede MLP faz-se necessrio estipular alguns parmetros que definem a rede a topologia e o tempo de treinamento para cada rede utilizada.

Para a definio da topologia das redes, cada uma teve sua topologia configurada variando-se, de maneira ad hoc, o nmero de neurnios nas camadas escondidas e o nmero mximo de pocas de treinamento, sobre o conjunto de treinamento. Os testes conduzidos levaram a uma topologia com uma camada escondida com 10 neurnios, submetida ao mximo de 10000 pocas, cada neurnio foi configurado com a funo de ativao do tipo logstica sigmoidal.

No treinamento de cada rede, foi utilizada a estratgia de parada antecipada com erro calculado sobre o conjunto de teste e comparado com o erro de treinamento durante cada poca de treinamento.

Aps o treinamento das redes estas foram validadas (generalizadas) utilizando todos os dados e as reduoes para gerar previsoes sobre os dados de validao. Observa-se que aqui, o conjunto de dados de validao é composto por todos os dados do perodo 1998 a 2000, incluindo os dados que foram utilizados para teste durante o treinamento.

A Tabela 5.3 apresenta o desempenho dos modelos de previso, para as quatro estaoes (est) do ano de 1998, considerando as 4 subreas de estudo.

Tabela 5.3. Erro Quadrtico Mdio.

Erro quadrtico mdio								
Estao	Subrea 1		Subrea 2		Subrea 3		Subrea 4	
	RNA	TCA	RNA	TCA	RNA	TCA	RNA	TCA
Outono	0.009	0.001	0.421	0.078	0.054	0.585	0.343	0.142
Inverno	0.021	0.002	0.315	0.141	0.348	1.012	1.176	0.176
Primavera	0.043	0.013	0.133	0.180	0.499	2.311	0.547	0.126
Vero	0.005	0.050	0.441	0.382	0.259	1.763	0.536	0.292

Uma análise qualitativa dos resultados pode ser vista nas Figuras 5.2 a 5.5, que apresenta simultaneamente os resultados obtidos no processo de previsão climática, usando todos os dados disponíveis e os dados processados pela TCA, para as quatro estações do ano 1998, nas quatro subáreas analisadas. Os mapas foram gerados utilizando a ferramenta GrADS.

As Figuras 5.2(a), 5.2(b) e 5.2(c) representam respectivamente: as situações observadas (denominadas REAL), a previsão obtida com os dados processados pela TCA e o resultado de previsão com o conjunto de dados completos. Observa-se que a previsão realizada com os dados pré-processados pela TCA, apresenta padrões visuais mais semelhantes àqueles mostrado na Figura 5.2(a).

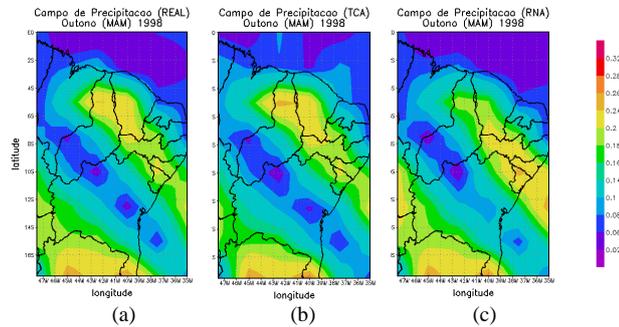


Figura 5.2. Previsão para estação Outono de 1998.

Na Figura 5.3 são apresentados os resultados da estimativa de precipitação para a estação inverno de 1998. Observa-se que a previsão realizada com os dados pré-processados pela TCA tem padrões mais compatíveis àqueles observados na Figura 5.3(a).

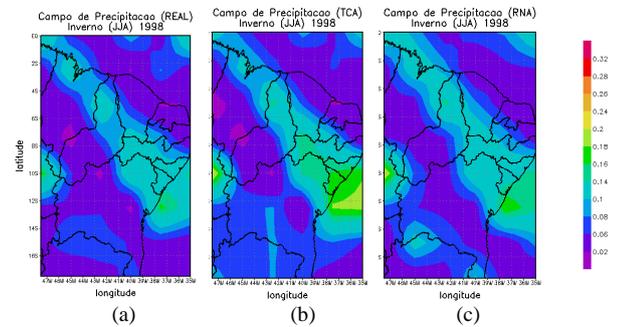


Figura 5.3. Previsão para estação Inverno de 1998.

Na Figura 5.4 são apresentados os resultados de precipitação obtidos para a estação verão de 1998. Observa-se que ambas as estimativas por redes neurais apresentaram padrões muito semelhantes àqueles presentes na Figura 5.4(a).

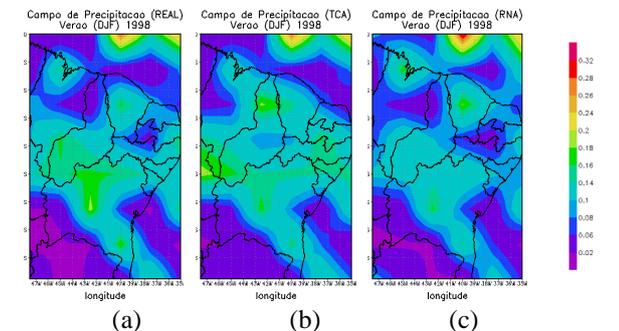


Figura 5.4. Previsão para estação Verão de 1998.

Na Figura 5.5 são mostrados os resultados de precipitação obtidos pelas redes neurais para a estação primavera de 1998. Também observa-se uma grande semelhança entre as estimativas encontradas pelas com a Figura 5.5(a) que representa a informação real desejada.

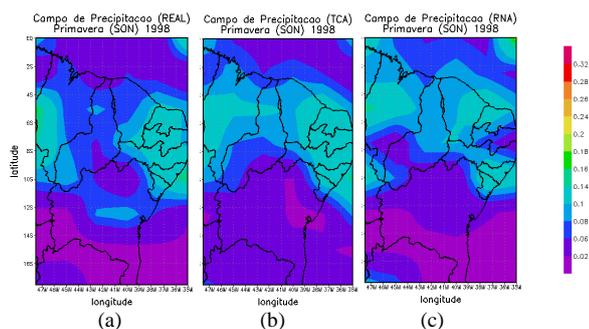


Figura 5.5. Previsão para estação Primavera de 1998.

6. Conclusão

Este trabalho apresentou uma proposta de um método de concepção de um modelo de previsão climática utilizando redes neurais.

Dois modelos foram gerados: um utilizando todos os dados disponíveis para treinamento e outro utilizando os dados obtidos de reduções calculadas pela Teoria dos Conjuntos Aproximativos.

Ambos os modelos foram validados com a submissão de um conjunto de dados não utilizado durante o treinamento das redes neurais. Nos testes conduzidos foi possível notar que os conjuntos reduzidos de dados geraram previsões muito compatíveis com as previsões realizadas pelo modelo que utiliza todos os dados, provando que é possível realizar a previsão com base em um subconjunto de variáveis que estão mais relacionadas com o comportamento físico da atmosfera.

Entretanto, como era de se esperar, há uma perda de precisão, como observado na Tabela 5.3 de resultados, sendo este o compromisso associado à simplificação do problema proposta neste trabalho.

Mas, dado que os modelos propostos no trabalho são concebidos utilizando redes neurais artificiais, pode ser possível melhorar a precisão dos resultados com outras estratégias de treinamento das redes neurais.

7. Referências Bibliográficas

- [1] Cavalcanti, I. F. A. Previsão climática no CPTEC-INPE. (2009). Disponível em: <<http://tucupi.cptec.inpe.br/products/climanalise/cliesp10a/precli.html>>. Acesso em: abr 2008.
- [2] Doty, B. Grid Analysis and Display System (GrADS). Maryland: Center for Ocean- Land-Atmosphere Studies (COLA). Disponível em: <<http://grads.iges.org/grads/head.html>>, Acesso em: 23-fev2009.
- [3] Fayyad, U. Shapiro, G.P., Smyth, P. (1996). From Data Mining to Knowledge Discovery in databases. AAAI Press.
- [4] Haykin S. (2001). Redes Neurais: Princípios e Práticas. 2ed. Porto Alegre: Bookman, 2001.
- [5] Komorowski, J. and Øhrn, A. (1999). Modelling prognostic power of cardiac tests using rough sets. Artificial Intelligence in Medicine. Vol. 15. pp. 167-191.
- [6] Komorowski, J.; Polkowski, L.; Skowron, A. (1998). Rough Set: A tutorial. Poland. pp. 118.
- [7] Øhrn, A. (1999). Discernibility and Rough Sets in Medicine: Tools and Applications. Tese de Doutorado, Norwegian University of Science and Technology, Department of Computer and Information Science, NTNU.
- [8] Pawlak, Z. (1982). Rough sets. International Journal of Computer and Information Sciences, Poland. Vol.1. pp. 341-356.
- [9] Vianello, R. L. e Alvez, A. R. (2000). Meteorologia Básica e Aplicações, Viçosa, UFV.