



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS  
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM METEOROLOGIA**



## **DISSERTAÇÃO**

**PREVISÃO DE SECA NA BACIA HIDROGRÁFICA DO AÇUDE EPITÁCIO  
PESSOA COM BASE EM REDES NEURAIS ARTIFICIAIS**

**Mestrando: Roni Valter de Souza Guedes  
Orientador: Francisco de Assis Salviano de Sousa**

**Campina Grande  
Fevereiro de 2011**

**Roni Valter de Souza Guedes**

**PREVISÃO DE SECA NA BACIA HIDROGRÁFICA DO AÇUDE EPITÁCIO  
PESSOA COM BASE EM REDES NEURAIAS ARTIFICIAIS**

Dissertação apresentada ao programa de Pós-Graduação em Meteorologia da Universidade Federal de Campina Grande em cumprimento às exigências para a obtenção do grau de Mestre em Meteorologia.

Área de Concentração: Meteorologia de Meso e Grande Escalas  
Subárea: Climatologia

**Orientador: Francisco de Assis Salviano de Sousa**

**Campina Grande**

Fevereiro de 2011

## FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

G924p Guedes, Roni Valter de Souza.

Previsão de seca na bacia hidrográfica do Açude Epitácio Pessoa com base em redes neurais artificiais / Roni Valter de Souza Guedes. — Campina Grande, 2011.

72 f.: il. col.

Dissertação (Mestrado em Meteorologia) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais.

Referências.

Orientador: Prof. Dr. Francisco de Assis Salviano de Sousa.

1. Previsão Hidrológica. 2. Índice de Chuva. 3. Modelagem. 4. Inteligência Artificial. I. Título.

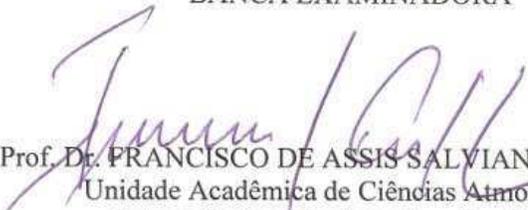
CDU 556.06(043)

RONI VALTER DE SOUZA GUEDES

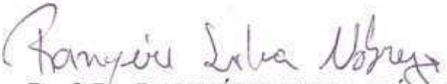
PREVISÃO DE SECA NA BACIA HIDROGRÁFICA DO AÇUDE EPITÁCIO  
PESSOA COM BASE EM REDES NEURAIS ARTIFICIAIS

DISSERTAÇÃO APROVADA EM 25/02/2011

BANCA EXAMINADORA

  
Prof. Dr. FRANCISCO DE ASSIS SALVIANO DE SOUSA  
Unidade Acadêmica de Ciências Atmosféricas  
Universidade Federal de Campina Grande

  
Prof. Dr. ENILSON PALMEIRA CAVALCANTI  
Unidade Acadêmica de Ciências Atmosféricas  
Universidade Federal de Campina Grande

  
Prof. Dr. RANYÉRE SILVA NOBREGA  
Departamento de Ciências Geográficas  
Universidade Federal de Pernambuco

Dedico este trabalho aos meus pais  
Dalton Guedes e Fátima Batista Guedes.

## AGRADECIMENTOS

Em primeiro lugar a Deus por ter me dado toda a energia e capacidade, toda a proteção e humildade, toda a ajuda e alegria. Aos meus pais, Dalton e Fátima, que tanto lutaram e acreditaram, dando todo o suporte necessário para que eu pudesse chegar a esta conquista. Aos meus três irmãos, Anderson, Dalton e Danila, pelo incentivo e exemplo. Aos meus amigos, Diego, Hérika e Rafaela, pela presença de sempre. A todos da turma de mestrado pelo companheirismo, atenção e ensino, especialmente a Francisco e Jonathan pela fibra moral, apoio e estudos. A Denise Alves e seus pais pelo amor, carinho e confiança.

A alguns professores da UACA que foram além da função de educar, principalmente ao Dr. Francisco de Assis pela disponibilidade e presteza para ajudar e orientar sempre que preciso.

A todos os não citados que influenciaram nesta caminhada, dando-me um pouco de cada um, fazendo-me evoluir cada vez mais, tanto do lado profissional como pessoal, sempre estimulando e animando em todos os momentos desde que cheguei a Campina Grande. Obrigado a todos por tudo mais, agora posso dizer que valeu a pena.

E ainda, ao Conselho Nacional de Pesquisa e Desenvolvimento Científico e Tecnológico – CNPq, pelo fornecimento da bolsa auxílio, dando condições para a realização deste projeto.

“O cérebro humano é como as redes neurais artificiais,  
sua inteligência depende das técnicas de aprendizagem”.

**Roni Guedes**

## LISTA DE FIGURAS

Figura 1. Ciclo hidrológico da água. Fonte: Machado (2005). .....	16
Figura 2. Tipo de chuva de acordo com sua formação. Fonte: Machado (2005). .....	17
Figura 3. Etapas gerais para de um processo de modelagem. Fonte: Machado (2005). .....	18
Figura 4. Exemplos de arquiteturas. Fonte: Adaptado de (Kröse; Smarg, 1996). .....	20
Figura 5. Modelo de RNA <i>feed-forward</i> recursivo com multi-passos .....	21
Figura 6. Célula de rede neural artificial. Fonte: Machado (2005). .....	22
Figura 7. Distribuição dos rios e divisão das sub-bacias. Fonte: Medeiros (2003). .....	29
Figura 8. Açudes monitorados para disponibilidade de recursos hídricos. Fonte: AESA.....	30
Figura 9. Relação dos postos pluviométricos utilizados .....	32
Figura 10. Climatologia do estado da Paraíba para o mês de dezembro. Fonte: DCA.....	34
Figura 11. Climatologia do estado da Paraíba para o mês de março. Fonte: DCA .....	34
Figura 12. Configuração de uma rede neural com três camadas. ....	39
Figura 13. Distribuição espacial da precipitação.....	40
Figura 14. <i>SPI</i> em escalas temporais diferentes: A. 1 mês, B. 3 meses, C. 6 meses, D. 12 meses, E. 24 meses. ....	41
Figura 15. Ajuste da rede para Barra de São Miguel, nas etapas de simulação (A) e previsão (B) .....	49
Figura 16. Ajuste da rede para Boqueirão, nas etapas de simulação (A) e previsão (B).....	49
Figura 17. Ajuste da rede para Cabaceiras, nas etapas de simulação (A) e previsão (B).....	50
Figura 18. Ajuste da rede para Camalaú, nas etapas de simulação (A) e previsão (B) .....	50
Figura 19. Ajuste da rede para Caraubas, nas etapas de simulação (A) e previsão (B).....	51
Figura 20. Ajuste da rede para Congo, nas etapas de simulação (A) e previsão (B).....	51
Figura 21. Ajuste da rede para Coxixola, nas etapas de simulação (A) e previsão (B).....	52
Figura 22. Ajuste da rede para Desterro, nas etapas de simulação (A) e previsão (B).....	52
Figura 23. Ajuste da rede para Gurjão, nas etapas de simulação (A) e previsão (B) .....	53
Figura 24. Ajuste da rede para Juazeirinho, nas etapas de simulação (A) e previsão (B) .....	53
Figura 25. Ajuste da rede para Monteiro, nas etapas de simulação (A) e previsão (B).....	54
Figura 26. Ajuste da rede para Olivedos, nas etapas de simulação (A) e previsão (B).....	54
Figura 27. Ajuste da rede para Passagem, nas etapas de simulação (A) e previsão (B).....	55
Figura 28. Ajuste da rede para Pocinhos, nas etapas de simulação (A) e previsão (B).....	55
Figura 29. Ajuste da rede para Prata, nas etapas de simulação (A) e previsão (B).....	56
Figura 30. Ajuste da rede para Salgadinho, nas etapas de simulação (A) e previsão (B).....	56

Figura 31. Ajuste da rede para São João do Tigre, nas etapas de simulação (A) e previsão (B) .....	57
Figura 32. Ajuste da rede para São José dos Cordeiros, nas etapas de simulação (A) e previsão (B) .....	57
Figura 33. Ajuste da rede para São Sebastião do Umbuzeiro, nas etapas de simulação (A) e previsão (B) .....	58
Figura 34. Ajuste da rede para Seridó, nas etapas de simulação (A) e previsão (B).....	58
Figura 35. Ajuste da rede para Serra Branca, nas etapas de simulação (A) e previsão (B).....	59
Figura 36. Ajuste da rede para Soledade, nas etapas de simulação (A) e previsão (B).....	59
Figura 37. Ajuste da rede para Sumé, nas etapas de simulação (A) e previsão (B) .....	60
Figura 38. Ajuste da rede para Sumé/Bananeiras, nas etapas de simulação (A) e previsão (B) .....	60
Figura 39. Ajuste da rede para Taperoá, nas etapas de simulação (A) e previsão (B) .....	61
Figura 40. Variação do erro com o número de épocas na previsão de 2 meses para a estação de Soledade .....	62
Figura 41. Curvas de regressões para a previsão de dois meses em Soledade.....	62
Figura 42. Curvas de regressões para a previsão de quatro meses em Soledade .....	63
Figura 43. Curvas de regressões para a previsão de seis meses em Soledade .....	64
Figura 44. Ajuste da rede para previsões de <i>SPI</i> em Soledade: (A) dois meses, (B) quatro meses e (C) seis meses .....	66
Figura 45. Ajuste da rede para previsões de <i>SPI</i> em Camalaú: (A) dois meses, (B) quatro meses e (C) seis meses .....	67

**LISTA DE TABELAS**

Tabela 1. Funções de transferência.....	23
Tabela 2. Postos pluviométricos selecionados. ....	33
Tabela 3. Classificação da precipitação baseada no <i>SPI</i> .....	35
Tabela 4. Redes de duas camadas com 12 neurônios na camada escondida.....	42
Tabela 5. Comparação entre as redes Cascade-forward e Feed-forward.....	42
Tabela 6. Teste com diferentes algoritmos de treinamento.....	43
Tabela 7. Teste com diferentes escalas temporais do <i>SPI</i> variando o número de neurônios...	44
Tabela 8. Teste com diferentes funções de transferência variando o número de neurônios....	45
Tabela 9. Teste da rede com três camadas. ....	46
Tabela 10. Desempenho e regressão de todas as estações para a rede escolhida.....	47
Tabela 11. Teste da rede para previsões de dois, quatro e seis meses para a estação de Soledade .....	65
Tabela 12. Teste da rede para previsões de dois, quatro e seis meses para a estação de Camalaú.....	65

## RESUMO

A seca afeta o ambiente natural de uma área quando persiste por um período mais longo. Desse modo, a previsão de seca desempenha um importante papel no planejamento e na gestão dos recursos naturais e sistemas de recursos hídricos de uma bacia hidrográfica. Na última década, a metodologia com base em Redes Neurais Artificiais (RNAs) tem mostrado grande habilidade na modelagem e previsão de séries temporais não-lineares e não-estacionárias. Este trabalho aplica a metodologia das RNAs para previsão das séries temporais do índice padronizado de precipitação (SPI - Standardized Precipitation Index) na bacia hidrográfica do açude Epitácio Pessoa - PB e avalia sua eficiência. A área de estudo (bacia hidrográfica do açude Epitácio Pessoa) é localizada no município de Boqueirão, uma região semi-árida do Estado da Paraíba. No processo e modelagem foram efetuadas mudanças sucessivas na configuração da rede a fim de se obter um modelo com o menor erro possível. A rede feed-forward backpropagation teve um dos melhores desempenhos, com uma estrutura de duas camadas e algoritmo de aprendizado de Levenberg - Marquardt. Dos 26 postos estudados no âmbito da bacia, o modelo proposto para previsão apresentou valores médios de regressão acima de 88 % e erro médio quadrático abaixo de 0,223. As previsões mostraram-se mais eficientes para escalas temporais de SPI maiores, no curto prazo. Verificou-se que à medida que se aumenta o horizonte temporal reduz-se a precisão da previsão. Os resultados indicam que previsões abaixo de três meses são consideradas satisfatórias, para prazos maiores é necessário melhorar o processo de aprendizagem da rede.

**Palavras-Chave:** índice de chuva, modelagem e inteligência artificial

## ABSTRACT

Drought affects the natural environment of an area when it persists for a longer period. Thus, the prediction of drought plays a major role in planning and resource management systems and water resources in a river basin. In the last decade, the methodology based on Artificial Neural Networks (ANN) has shown great skill in modeling and forecasting time series nonlinear and nonstationary. This work applies the methodology of ANNs for forecasting time series of Standardized Precipitation Index (*SPI*) in the Epiácio Pessoa river basin dam - PB and evaluates their effectiveness. The study area (Epiácio Pessoa river basin dam) is located in the semiarid region of Paraíba State. In the modeling process, subsequent changes were made to the Neural Network configuration in order to obtain a model with the smallest possible error. The feed-forward back propagation Neural Network had one of the best performances, with a two-layer structure and learning algorithm of Levenberg-Marquardt. Of the 26 gauge stations studied within the basin, the proposed model for prediction of regression showed values above 88% and mean square error below 0.223. The forecasts are more efficient for larger time scales of *SPI*, in the short term. It was found that as an increase the time horizon reduces the accuracy of the forecast. The results indicate that forecast less than three months is considered satisfactory. For longer terms is necessary to improve the learning process of the Neural Network.

**Keywords:** rainfall index, modeling, artificial intelligence.

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>13</b>
1.1 OBJETIVO .....	14
1.2 JUSTIFICATIVA.....	15
<b>2. FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>16</b>
2.1 PRECIPITAÇÃO .....	17
2.2 REDES NEURAIS ARTIFICIAIS .....	19
2.2.1 <i>Neurônio Artificial</i> .....	21
2.2.2 <i>Funções de transferência</i> .....	22
2.3 CARACTERÍSTICAS DA REDE NEURAL ARTIFICIAL .....	24
<b>3. REVISÃO BIBLIOGRÁFICA .....</b>	<b>26</b>
<b>4. MATERIAL E MÉTODOS .....</b>	<b>29</b>
4.1. LOCAL.....	29
4.1.1 Sub-bacia do Alto Paraíba .....	31
4.1.2 Sub-bacia do rio Taperoá.....	31
4.2 DADOS .....	31
4.2.1 Séries de <i>SPI</i> para a bacia .....	35
4.3 CONCEPÇÃO DA REDE.....	37
<b>5. RESULTADOS E DISCUSSÃO .....</b>	<b>40</b>
5.1 ESCOLHAS DA REDE .....	42
5.2 PREVISÕES PARA DOIS, QUATRO E SEIS MESES .....	61
<b>6. CONCLUSÕES E SUGESTÕES.....</b>	<b>68</b>
<b>7. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>69</b>

## 1. INTRODUÇÃO

Em muitas regiões a disponibilidade de recursos hídricos é adequada, porém mal distribuída geográfica e temporalmente. Os volumes de água armazenados são frequentemente subutilizados, quando deveriam propiciar vazões regularizadas visando o atendimento de demandas bem definidas e permitindo o equilíbrio entre a disponibilidade natural e a necessidade hídrica. O excesso de exploração de águas subterrâneas e o desmatamento ou desflorestamento desordenado, e/ou a construção não planejada de açudes, que armazenam a precipitação pluviométrica resultante de eventos, podem afetar potencialmente o ciclo hidrológico. Adicionalmente, os problemas que ocorrem devido à aleatoriedade dos eventos hidrológicos somam-se àqueles causados pela intervenção humana sobre o meio ambiente, já considerado, em diversos lugares, como crítico, afetando o clima local e a qualidade de vida da população.

A seca é uma característica natural do clima e sua recorrência é inevitável. No entanto, há ainda muita confusão no meio da comunidade científica e na tomada de decisões políticas sobre suas características. Pesquisas têm demonstrado que a falta de uma definição precisa e objetiva em situações específicas, tem sido um obstáculo à compreensão das secas que já levou a indecisão e a inação por parte de gestores públicos.

A variabilidade climática global pode ser responsabilizada pelo aumento do número de eventos de secas. A seca é um fenômeno que pode ter curta ou longa duração. Em casos graves, ela pode durar anos, com efeitos devastadores sobre a agricultura, abastecimento de água e a situação sócio-econômica de uma região. Em alguns casos pode ser difícil determinar quando uma seca começa ou termina.

Em todo o Planeta, entre 1967 e 1992, as secas afetaram 50% de 2,8 bilhões de pessoas que sofreram todos os tipos de catástrofes naturais. Por causa de impactos diretos e indiretos 1,3 milhões de vidas humanas foram perdidas, de um total de 3,5 milhões de pessoas mortas por catástrofes (OBASI, 1994). Quase 50% das áreas mais populosas do mundo são altamente vulneráveis à seca. Mais importante ainda, quase todas as grandes áreas agrícolas estão localizadas em regiões suscetíveis a ocorrência desse fenômeno que produzem uma complexa rede de impactos que abrange muitos setores da economia e atingem locais bem

além da área física que enfrenta a seca. No Nordeste do Brasil, sua ocorrência é comum, principalmente na região semi-árida (USDA, 1994).

A seca depende de sistemas meteorológicos que atuam na região e de fenômenos climáticos de grande escala que influenciam as variáveis que definem o comportamento e a circulação atmosférica. Sua ocorrência está associada a fenômenos como o El Niño e Dipolo do Atlântico (aquecimento/esfriamento do Atlântico Norte/Sul). Por exemplo, as secas do Nordeste brasileiro são influenciadas pelos fenômenos supracitados.

A classificação das secas pode ser feita através de inúmeros índices, o índice de seca conhecido por *SPI* (em inglês, *Standardized Precipitation Index*) foi desenvolvido com o objetivo de monitorar e analisar as secas em diferentes escalas de tempo. Esse índice é vantajoso em relação aos demais porque utiliza apenas dados mensais de precipitação. Desde que foi proposto por seu autor, o *SPI* vem sendo usado em vários estudos devido sua capacidade de quantificar o déficit ou excesso de precipitação em diversas escalas temporais, permitindo comparações entre regiões com diferentes características climáticas. Assim, diversos trabalhos científicos têm demonstrado o seu potencial no monitoramento do fenômeno das secas. No Brasil, o *SPI* é um dos métodos preconizados pelo Instituto Nacional de Meteorologia (INMET) para caracterizar anomalias de precipitação. Desde janeiro de 2002 o *SPI* vem sendo calculado para todo país e, recentemente, esses resultados têm sido disponibilizados para o público em forma de mapas.

A previsão de seca desempenha um papel importante na mitigação dos seus impactos, principalmente, sobre os sistemas de recursos hídricos. Um modelo de previsão de secas é extensivo à previsão de vazões que aperfeiçoam o gerenciamento desses recursos.

## 1.1 OBJETIVO

O objetivo deste estudo é propor um modelo baseado em técnicas de Redes Neurais Artificiais e no Índice de Precipitação Padronizado (*SPI*) para prever eventos de secas, em diferentes escalas temporais, no âmbito da bacia hidrográfica do açude Epitácio Pessoa.

## 1.2 JUSTIFICATIVA

O açude Epitácio Pessoa, mais conhecido como açude de Boqueirão, tem importância significativa para a economia do Estado da Paraíba. Esse açude armazena água para suprir a demanda de mais de 20 cidades, dentre elas a cidade de Campina Grande, com cerca de 397.000 habitantes. Devido à seca na região Nordeste do Brasil entre 1998 a 2000, o açude de Boqueirão, com capacidade para armazenar 450.424.550 metros cúbicos de água, quase entrou em colapso total, seu nível de água atingiu 16% de sua capacidade.

Este estudo se justifica porque pretende contribuir para o conhecimento da ocorrência de eventos de secas no âmbito da bacia hidrográfica do açude e subsidiar a tomada de decisão para gestão dos seus recursos hídricos. As informações adquiridas aqui, somadas as já existentes, servirão para melhorar a reformulação e redistribuição dos projetos existentes, bem como a implantação de novos projetos. O projeto do Rio São Francisco, precisa de informações sobre eventos de secas e suas previsões, a fim de se fazer o ajuste necessário para a manutenção dos níveis de vazão mínima sobre áreas específicas. Assim é crucial a utilização de técnicas inovadoras, ampliando os horizontes das pesquisas e a qualidade das informações.

## 2. FUNDAMENTAÇÃO TEÓRICA

Teoricamente, o Brasil possui uma grande quantidade de rios e assim existem muitos recursos hídricos no país. Mas na prática ocorre o problema da má distribuição geográfica desses recursos. Infelizmente, 78% da água doce do país se concentram na Região Norte, a de menor densidade demográfica. Esses recursos são definidos a partir de uma análise no ciclo hidrológico, que é uma sequência de processos representada pelos seguintes componentes: precipitação, infiltração, escoamento superficial, evaporação, transpiração, sublimação e condensação. Esses componentes juntos definem a disponibilidade de recursos hídricos de uma região.

O ciclo hidrológico é o conjunto dos diversos caminhos percorridos pela água do planeta entre a superfície e a atmosfera, impulsionado fundamentalmente pela energia solar, gravidade e rotação terrestre. Os principais processos que compõem o ciclo hidrológico são a evaporação e transpiração das plantas que suprem a atmosfera de vapor d'água; a precipitação que devolve a água à superfície terrestre; infiltração, que retém parte do volume precipitado e alimenta as plantas e os lençóis freáticos; e os escoamentos superficiais e de base que se encontram nos cursos de água mais estáveis formados pelos rios e seus afluentes os quais na sua maioria conduzem o escoamento aos oceanos (MACHADO, 2005) (Figura 1).

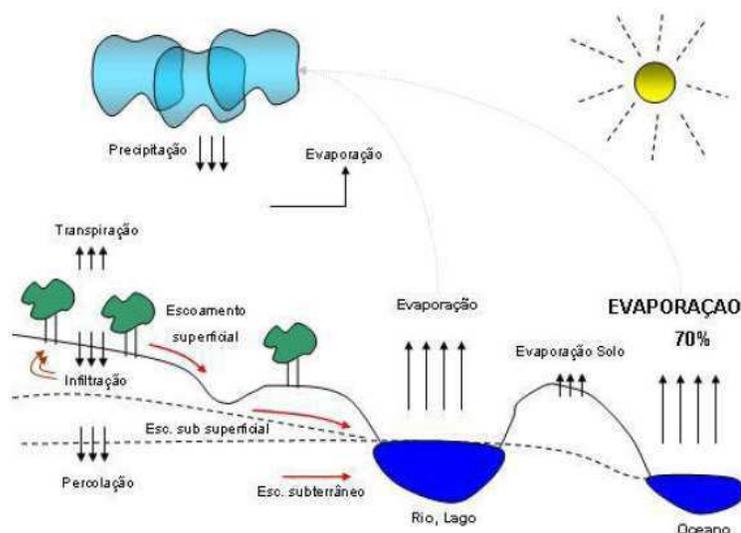


Figura 1. Ciclo hidrológico da água. Fonte: Machado (2005).

Na análise do processo chuva-vazão é preciso levar em conta todos os componentes citados. Araújo (2005) menciona que a importância dos modelos está, entre outros aspectos,

na simulação e previsão dos fenômenos físicos, sobretudo os de frequência rara, a curto, médio e longo prazos

## 2.1 PRECIPITAÇÃO

A precipitação é toda a água proveniente da atmosfera que atinge a superfície terrestre. Neblina, granizo, orvalho, geada, neve e chuva são as diferentes formas de precipitação da água. No nosso clima a maior contribuição e a mais importante dessas formas é a chuva. As chuvas podem ser classificadas em: convectivas, orográficas e frontais ou ciclônicas (MACHADO, 2005). Na Figura 2 é possível identificar as configurações descritas abaixo.

- Convectivas: acontece quando o ar úmido junto ao solo é aquecido e se desloca verticalmente. Na atmosfera, condensa parte do vapor de água para formar nuvens e precipitar. São, geralmente, chuvas de pequena duração e grande intensidade agindo sobre pequenas áreas.
- Orográficas: ocorrem quando o ar quente e úmido que sopra do oceano para o continente encontra uma barreira montanhosa, o ar sobe, se resfria, ocorre condensação, forma-se nuvens e ocorre a precipitação. São chuvas de baixa intensidade, durações mais prolongadas em relação às convectivas e agem sobre médias áreas.
- Frontais ou Ciclônicas: resultam do encontro de uma massa de ar quente com uma massa de ar frio. São chuvas menos intensas, de maior duração e atingem grandes áreas.

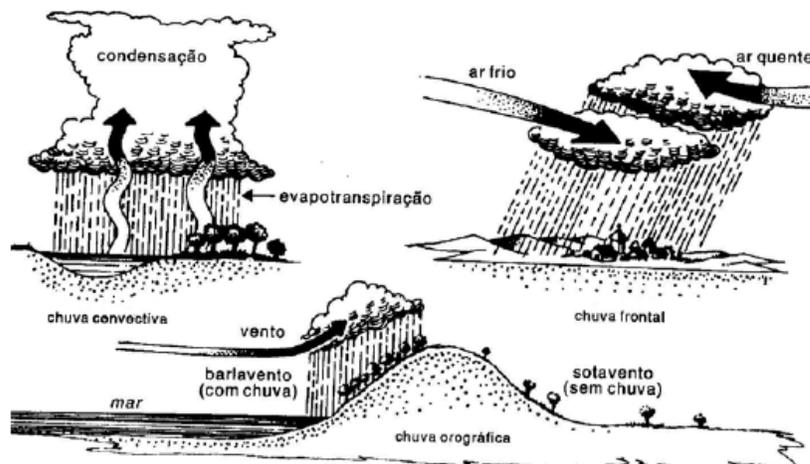


Figura 2. Tipo de chuva de acordo com sua formação. Fonte: Machado (2005).

Os processos ambientais no mundo real são geralmente bastante complexos tipicamente tridimensionais e dependentes do tempo. Tal complexidade pode incluir comportamentos não-lineares e componentes estocásticos sobre múltiplas escalas de tempo e espaço. Tradicionalmente, os modelos estatísticos têm sido utilizados para a previsão de seca hidrológica com base em métodos de séries temporais. Modelos de regressão e modelos auto-regressivos - média móvel (*ARMA*) são típicos modelos estatísticos de previsão de séries temporais. No entanto, eles são basicamente modelos lineares e supõe-se que os dados sejam estacionários. Esses modelos têm capacidade limitada para capturar a não-estacionaridade e a não-linearidade dos dados hidrológicos.

A análise univariada de Box-Jenkins, *ARIMA* (BOX et al. 1994), tem sido largamente utilizada para a previsão de variáveis hidrológicas de interesse, tais como, vazões anuais e mensais, precipitação, etc, que têm sido largamente aceita pelos profissionais durante as últimas décadas. No entanto, é necessário que os hidrologistas considerem modelos alternativos quando a não-linearidade e a não-estacionaridade desempenharem papéis significativos na previsão. Nas últimas décadas, as redes neurais artificiais (RNAs) têm mostrado grande habilidade na modelagem e previsão de séries temporais não-lineares e não-estacionárias em hidrologia e engenharia de recursos hídricos, devido à sua inata propriedade não-linear e sua flexibilidade para a modelagem.

Todo processo de modelagem segue uma sequência de passos, um resumo destas etapas esta descrito na Figura 3:

#### ETAPAS DO PROCESSO DE MODELAGEM

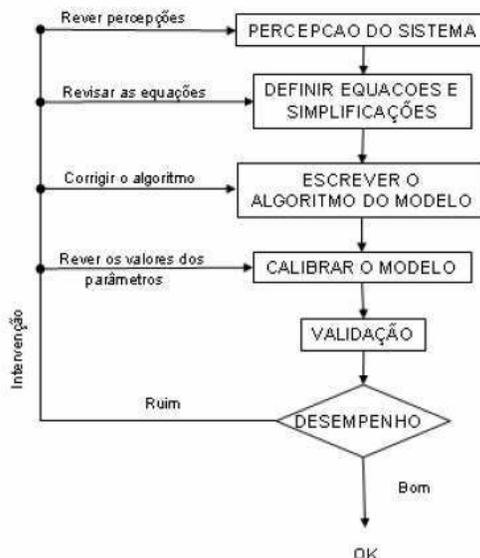


Figura 3. Etapas gerais para de um processo de modelagem. Fonte: Machado (2005).

## 2.2 REDES NEURAIAS ARTIFICIAIS

Redes Neurais Artificiais (RNAs) é um conceito da computação que visa trabalhar no processamento de dados de modo semelhante ao cérebro humano. O cérebro realiza processamentos de maneira paralela e de forma altamente complexa. O cérebro humano é composto de aproximadamente 10 bilhões de neurônios, que estão conectados uns aos outros através de sinapses, e juntos formam uma grande rede neural. As sinapses se comunicam através de estímulos gerados pela diferença de concentração de Na<sup>+</sup> (sódio) e K<sup>+</sup> (potássio), essa dinâmica possibilita uma alta capacidade de processamento e armazenamento de informações. Resumindo, as RNAs são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através de experiências (SOUSA, 2008).

As principais diferenças entre redes neurais artificiais e naturais estão na quantidade de unidades de processamento delas. Nas artificiais essas unidades são menores que nas naturais. Ao contrário das redes neurais artificiais, as redes neurais naturais não transmitem sinais negativos, sua ativação é medida pela frequência com que emitem pulsos, frequência de pulsos contínuos ou positivos. As redes naturais não são uniformes como as redes artificiais, seus pulsos não são síncronos ou assíncronos, devido ao fato de não serem contínuos, o que difere das redes artificiais.

Em 1943, a idéia da neurocomputação surgiu com o neurofisiologista McCulloch e o matemático Walter Pitts, fazendo as primeiras ligações com o cérebro humano. Em 1949, o psicólogo Donald Hebb demonstrou que a capacidade de aprendizagem em redes neurais vem da alteração da eficiência sináptica. Frank Rosenblatt (1962) mostrou o modelo dos perceptrons, onde os pesos das conexões eram adaptados a fim de se atingir a eficiência sináptica, hoje a base dos modelos atuais. Em seguida, Bernard Widrow e alguns estudantes desenvolveram um novo tipo de elemento de processamento chamado Adaline (rede linear adaptada), que utiliza uma lei de aprendizado diferente do perceptron (SOUSA, 2008).

Promessa de máquinas poderosas e previsões pouco confiáveis tiraram a credibilidade de muitos estudos e os avanços se tornaram pouco significativos durante um período de pesquisas silenciosas. Nos anos 80, o interesse pela neurocomputação emergiu com os artigos de John Hopfield, que relataram o uso de um algoritmo de aprendizado que estabilizava a rede

binária simétrica com realimentação. Assim, Rumelhart e McClland (1986), fizeram este campo de pesquisa “explodi” com a publicação do livro “*Parallel Distributed Processing*” (Processamento Paralelo Distribuído), em que introduziram o poderoso método “*backpropagation*” como algoritmo de aprendizado, sendo utilizado até hoje.

As RNAs são uma classe de modelos flexíveis não-lineares que podem descobrir padrões adaptativos a partir dos dados. Teoricamente, tem sido demonstrado que, dado um número adequado de unidades de processos não-lineares, as RNAs podem aprender com a experiência e estimar qualquer relação funcional complexa com alta precisão.

Existem inúmeros modelos de redes neurais que se diferenciam principalmente pela estrutura da rede, pelo algoritmo de aprendizagem, pelas funções de ativação empregadas, pela recorrência, dentre outras características. Podemos citar aqui os modelos *Perceptron*, *feed-forward*, *GMDH (Group Method of Data Handling)*, *NSRBN (Non Linear Sigmoidal Regression Blocks Networks)*, dentre outros. Uma boa descrição sobre essas redes pode ser encontrada em Valença (2005), onde se encontram também, informações sobre os algoritmos de aprendizagem, Backpropagation, Combinatorial e Iterativo Multicamadas. A Figura 4 mostra algumas arquiteturas que apresentam dinâmicas diferentes no fluxo dos dados.

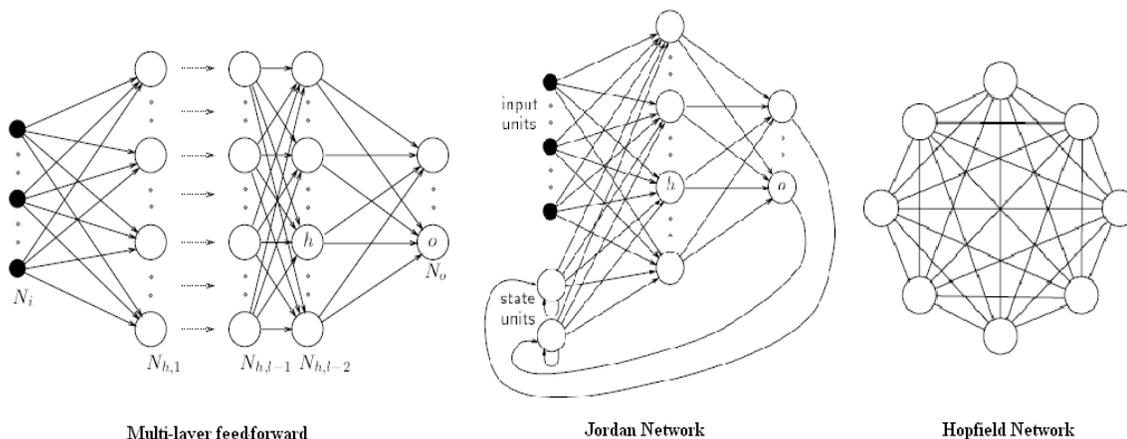


Figura 4. Exemplos de arquiteturas. Fonte: Adaptado de Kröse; Smarg, (1996)

Embora muitos tipos de modelos de redes neurais tenham sido propostos, o mais popular para previsão de uma série temporal é o modelo *feed-forward*. A Figura 5 mostra um típico modelo de três camadas *feed-forward* utilizado para efeitos de previsões. A entrada para os nós será defasada de observações anteriores, enquanto a saída fornece as previsões para o valor futuro. Os nós ocultos com as funções não-lineares de transferência são utilizados para processar as informações recebidas pelos nós de entrada.

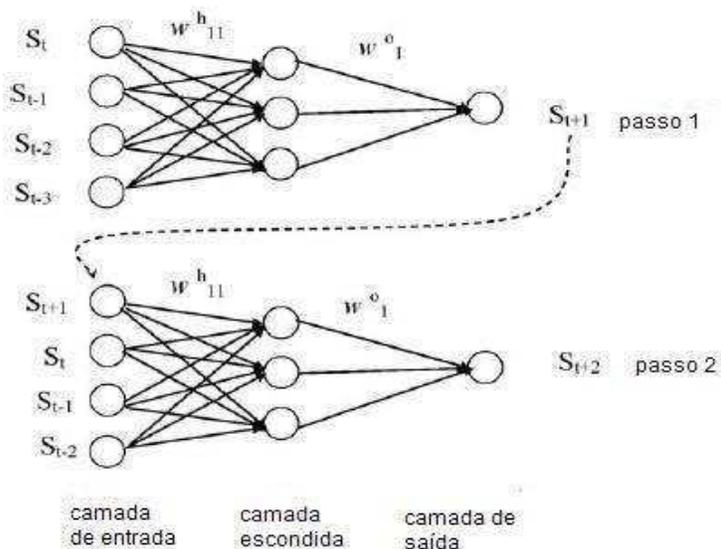


Figura 5. Modelo de RNA *feed-forward* recursivo com multi-passos

Para construir um modelo de previsão, a rede é processada através de três estágios: (1) o estágio de treinamento onde a rede é treinada para prever dados futuros, baseada em dados passados e presentes; (2) o estágio de testes no qual a rede é testada para parar o treinamento ou para manter-se em treinamento; (3) o estágio de avaliação, a rede deixa o estágio de treinamento e pode ser utilizada para a previsão futura dos dados e estimar os erros. Aqui o algoritmo *backpropagation*, desenvolvido por Rumelhart et al. (1986), será utilizado para o treinamento da rede.

### 2.2.1 Neurônio Artificial

Como mostrado na Figura 6 uma célula de rede é constituída pelos pesos, somatório e função de transferência. O seu funcionamento pode ser resumido pela seguinte sequência de ações: dados de entradas são fornecidos para a rede, esses dados são multiplicados por pesos, simulando sua entrada em uma célula neural, a seguir é feita a soma ponderada dos sinais de entrada, produzindo um nível de atividade que induz o estímulo na unidade de processamento que é a função de transferência, essa função vai emitir uma resposta ao estímulo recebido para os demais neurônios adjacentes. O neurônio artificial mostrado na Figura 6, ainda inclui a entrada de um elemento externo  $b$ , chamado viés (ruído aleatório). Isso significa que a

combinação linear da unidade somatório deve ser aumentada em um termo para implementar o termo  $b$ .

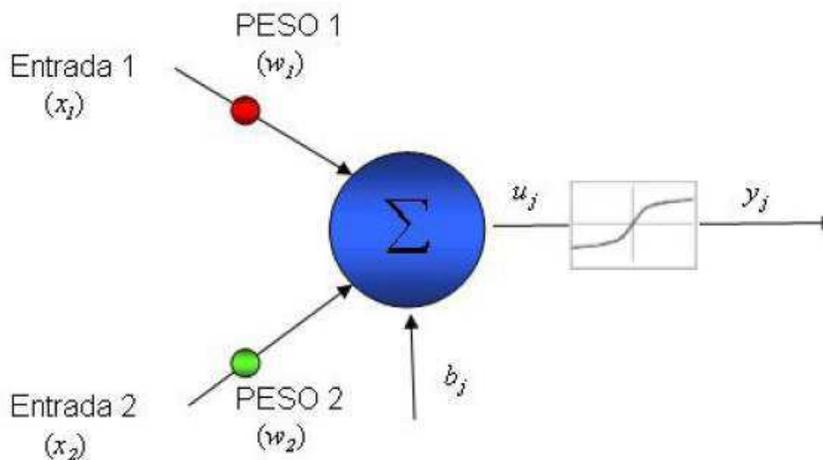


Figura 6. Célula de rede neural artificial. Fonte: Machado (2005).

### 2.2.2 Funções de transferência

A utilização da função de transferência permite às RNAs identificar relações lineares e não-lineares entre as variáveis de entrada e saída. Essa função diferencia a decisão neural baseada no potencial interno do neurônio e determina o valor a ser enviado aos demais neurônios (SANTOS E FILHO, 2003).

Existem inúmeras funções de ligação que podem ser utilizadas em redes neurais, dependendo do objetivo e tipo de variável em estudo. A Tabela 1 mostra inúmeras funções de transferência, as mais utilizadas são as Log-Sigmóide, Linear e Tan-Sigmóide.

Tabela 1. Funções de transferência

Nome	Função de transferência	Gráfico
Tangente hiperbólica sigmóide	$a = \text{tansig}(n)$	
Saturadas Lineares Simétricas	$a = \text{satlins}(n)$	
Linear Saturada	$a = \text{satlin}(n)$	
Base Radial	$a = \text{radbas}(n)$	
Linear Limite Rígido	$a = \text{purelin}(n)$	
Positiva linear	$a = \text{poslin}(n)$	
Logarítmica Sigmóide	$a = \text{logsig}(n)$	

Fonte: Adaptado de Demuth et. al, (2007).

### 2.3 CARACTERÍSTICAS DA REDE NEURAL ARTIFICIAL

A arquitetura das redes neurais pode ser classificada como estática, dinâmica, ou fuzzy, com uma ou várias camadas. Em rede simples, como a perceptron, a comunicação é unidirecional, possuindo um comportamento estático. Para o comportamento ser dinâmico, o fluxo de dados deve ser multidirecional, com os neurônios integrados, possuindo camadas misturadas. Cada neurônio da rede recebe um peso inicial, que se modifica de acordo com as interações de outros neurônios, dando início ao comportamento inteligente da rede.

Com a evolução das redes em busca de melhorias no desempenho e eficácia, suas estruturas ganharam mais elementos e possibilidades de comportamento. As redes “feedback” (recorrentes) são referenciadas como sistemas não-lineares dinâmicos, pois existe uma realimentação de sinais já propagados na rede. (LOKE, 1995). Algumas das vantagens das RNAs são (ASCE, 2000a):

- (1) Capacidade de reconhecer a relação entre as variáveis de entrada e saída sem explicitar considerações físicas;
- (2) Funcionam bem mesmo quando o conjunto de treinamento contém ruídos e estimativas de erros;
- (3) São capazes de se adaptar às soluções em longo prazo para compensar a evolução das circunstâncias;
- (4) Possuem outras características inerentes ao processo de informação e uma vez treinadas são fáceis de usar;

Outras vantagens são apontadas em SOUSA (2008):

- (5) As RNAs tomam suas próprias decisões embasadas nos conhecimentos adquiridos através de exemplos históricos;
- (6) Capacidade de generalização, mesmo com dados incompletos ou imprecisos as redes podem preencher as lacunas sem sofrer degradação; é algo como a interpolação e extrapolação da estatística, porém operacionalmente muito diferente;

- (7) Adaptabilidade, uma vez construída uma rede eficiente em dada aplicação ela pode ser utilizada em tempo real, sem necessidade de alteração na arquitetura; basta apenas re-treinar com base nos novos dados.

Mas como todos os modelos que estão em evolução, as redes neurais artificiais também apresentam algumas desvantagens:

- (1) Treinamento demorado, dependendo da aplicação, pode demorar horas ou até dias;
- (2) Caixa-preta, não se pode conhecer o motivo pelo qual a rede tomou determinada decisão, pois seus critérios são encriptados nas camadas escondidas. Na realidade essa desvantagem já está sendo resolvida, pois, algumas ferramentas de extração de regras de redes estão sendo desenvolvidas (ALVES, 2001).
- (3) Resultados desconcertantes, se os dados não forem bem tratados e o treinamento não for suficientemente bom, a rede pode chegar a conclusões contrárias às regras, cabendo o bom senso do profissional em tratar tais casos.

### 3. REVISÃO BIBLIOGRÁFICA

A relação entre chuva e vazão é altamente não-linear. Haykan (1994) cita que as RNAs com três camadas são capazes de aproximar qualquer função com características não-lineares. Conceitos preliminares de redes neurais (RNAs) e sua adaptabilidade à hidrologia são bem explicados em ASCE (2000a) e uma lista exhaustiva de referências sobre aplicações de RNA em hidrologia pode ser vista em ASCE (2000b). Sua aplicação em simulação e previsão de problemas de recursos hídricos tem mostrado grande habilidade e algumas das aplicações são mencionadas aqui.

Segundo Flood et al. (1994) a investigação de aspectos diferentes na modelagem com RNA é essencial para melhorar a previsão dos processos hidrológicos, como: arquitetura da rede, processo de modelagem, forma de entrada dos dados e métodos de estimativa de eficiência para validação do modelo.

Algumas das aplicações da RNA utilizaram modelagem ecológica como Acharya (2006) que utilizou um modelo de RNA *feed-forward* (unidirecional) com três camadas, constituída por uma camada de entrada, uma camada escondida e uma camada de saída para prever o grau de remoção de enxofre a partir de três tipos de carvão nativo utilizando culturas de *Acidithiobacillus ferrooxidans*. A RNA resultante mostrou previsão satisfatória de porcentagens de remoção de enxofre, com média dos desvios absolutos variando de 0,003 para 0,5 e a trama de paridade indica que as estimativas do modelo para o conjunto de teste foi bom.

Pasini et al. (2006) utilizaram uma rede neural feed-forward, treinada por meio de uma estratégia de retropropagação, usando uma regra generalizada Widrow-Hoff para atualizar a ligação dos pesos para a análise de forçantes/temperaturas relacionadas em diferentes escalas do sistema climático. As correlações encontradas pela rede neural mostraram que a consideração de dados ENSO leva para uma melhor captura de variabilidade interanual. E sugeriram desdobramentos na aplicação da nossa ferramenta de rede neural e novas metodologias sobre outras regiões do mundo.

Lorrai et al. (1995) modelaram o processo chuva-vazão na bacia de Araxisi na Sardenia, Itália, utilizando a rede “*Multilayer Perceptron*” (MLP). Nessa modelagem os autores usaram como variáveis de entrada da rede neural os valores médios da temperatura e da precipitação na área da bacia e, os valores observados nos seus respectivos pontos

(estações meteorológicas). Com os valores pontuais a rede neural mostrou melhoria na sua eficiência. De modo geral, os resultados obtidos com a RNA foram melhores que os obtidos pelo uso de um modelo conceitual para simular o processo chuva-vazão (Sousa, 2008).

Shamseldin (1997) aplicou RNAs em uma modelagem chuva-vazão definindo como dado de entrada um índice que tenta interpretar os valores de precipitação, pois é interessante se aproveitar ao máximo a ferramenta disponível na busca de formas alternativas de entrada de dados, e não somente àquelas empregadas em modelos convencionais.

Bussay et al. (1999) e Szalai e Szinell (2000) avaliaram a utilidade do *SPI* para descrever a seca na Hungria. Eles concluíram que o *SPI* foi adequado para quantificar a maioria dos tipos de evento de seca. A seca agrícola (ou seja, déficit de umidade do solo) foi representada pelo *SPI* em escala de 2 a 3 meses.

Lana et al. (2001) utilizaram o *SPI* para investigar padrões de precipitação na Catalunha, Espanha. Com ajuda da Análise em Componentes principais foi possível distinguir episódios de escassez ou excesso de chuva estabelecendo a classificação do tempo de duração destes eventos.

Hughes e Saunders (2002) estudaram a climatologia da seca na Europa com base em escalas temporais mensais, *SPI* de 3, 6, 9, 12, 18 e 24 meses no período de 1901-1999. O número e a duração média dos eventos de seca extrema com *SPI*-12 meses foi de  $6 \pm 2$  meses, e  $27 \pm 8$  meses, respectivamente. E a máxima duração média foi de  $48 \pm 17$  meses.

Anmala et al. (2000) utilizaram RNAs *feed-forward* e RNAs recorrentes com entradas de temperatura e chuva mensal para calcular a vazão média mensal em três bacias hidrográficas no Kansas, EUA. Durante o desenvolvimento os autores também analisaram a influência do número de treinamento. Ao final eles concluíram que as RNAs recorrentes apresentaram os melhores resultados entre todos os modelos empíricos e que os bons resultados foram obtidos para um número limite de iterações no treinamento.

Antonic *et al.* (2001) utilizaram uma RNA *feed-forward* com multicamadas *perceptions* (MLP) para desenvolver um modelo empírico, utilizando sete variáveis climáticas: temperatura média mensal do ar, temperatura do ar média diária, mínima e máxima, umidade relativa do ar média mensal, precipitação mensal, radiação solar global média mensal e evapotranspiração potencial mensal.

Olívio et al. (2002) aplicaram as técnicas de redes neurais artificiais ao problema de previsão de cheias fluviais, o tipo de rede neural escolhido foi a “perceptron” de múltiplas

camadas e o algoritmo de treinamento usado no estudo foi o retropropagação do erro. Foi inserido à rede, como padrão de entrada, o nível de água do rio a montante de uma seção de interesse e esperou-se uma resposta adequada da rede neural a previsão de níveis fluviométricos para 4, 6, 8 e 10 horas de antecedência. Os autores concluíram que redes neurais se prestam para a previsão de cheias e que os resultados poderiam melhorar caso fossem utilizados dados de entrada mais apropriados.

Almeida e Barbosa (2004) utilizaram RNAs com o objetivo de conhecer a previsão de secas hidrológicas para um horizonte de cinco dias. Este tipo de seca está normalmente defasada da seca meteorológica, dado que é necessário um período maior para que as deficiências da precipitação se manifestem no diversos componentes do sistema hidrológico. A rede neural possuía na camada de entrada onze neurônios e o algoritmo de treinamento usado nesse trabalho foi o do gradiente conjugado escalonado. Os resultados foram satisfatórios na previsão de vazão média diária para um horizonte de cinco dias e tal técnica auxilia na identificação de um possível início de evento de seca hidrológica.

Melesse e Hanley (2005) utilizaram uma rede neural *feed-forward* usando o algoritmo back-propagation para três diferentes ecossistemas (florestas, pastagens e terras agrícolas) utilizando fluxos de energia particionada, temperaturas do ar e do solo como variáveis de entrada para predizer o fluxo de carbono presente.

Sahoo et al. (2005) usaram uma RNA para prever a ocorrência de pesticidas em poços domésticos na zona rural a partir de informação escassa. Dentre os três modelos de RNA (*feed-forward back - propagation* (BP), *radial based function* (RBF) e *adaptive neural network-based fuzzy inference system* (ANFIS)) empregadas nessa pesquisa, a rede neural BP mostrou-se superior ao ANFIS e RBF.

Morais *et. al.* (2008) utilizaram o *SPI* com redes neurais para prever seca a partir de dados de uma única estação, onde foi analisado o desempenho de um tipo de rede neural para varias escalas temporais do *SPI*. Eles constataram que a escala de 12 meses (*SPI-12*) foi a mais adequada por apresentar menor variabilidade, uma vez que leva em conta o valor acumulado da precipitação, sendo, portanto, de mais fácil previsão.

## 4. MATERIAL E MÉTODOS

### 4.1. LOCAL

O relevo de uma bacia hidrográfica tem grande influência sobre os fatores meteorológicos e hidrológicos, dado que a velocidade de escoamento superficial é determinada pela declividade do terreno, enquanto que a temperatura, a precipitação e a evaporação são influenciadas pela altitude da bacia. A Figura 7 mostra a localização da bacia hidrográfica do açude Epitácio Pessoa no estado da Paraíba, mais conhecido como Açude de Boqueirão, com a sua divisão em duas outras sub bacias. A contribuição de vazões para Boqueirão vem principalmente das sub-bacias do Alto Paraíba e do Taperoá. Os cursos de águas naturais que cortam a região em estudo e que beneficiam de alguma forma o solo e a produção agropecuária da região são os seguintes: Rio Paraíba, Riacho do Marinho Velho, Riacho da Perna, Riacho dos Canudos, Riacho da Ramada, Riacho da Relva e Riacho do Feijão. Atualmente, segundo o Plano Diretor do Estado da Paraíba, o açude Epitácio Pessoa tem capacidade para 450. 424.550 de metros cúbicos de água (GALVÍNCIO et. al. 2006).

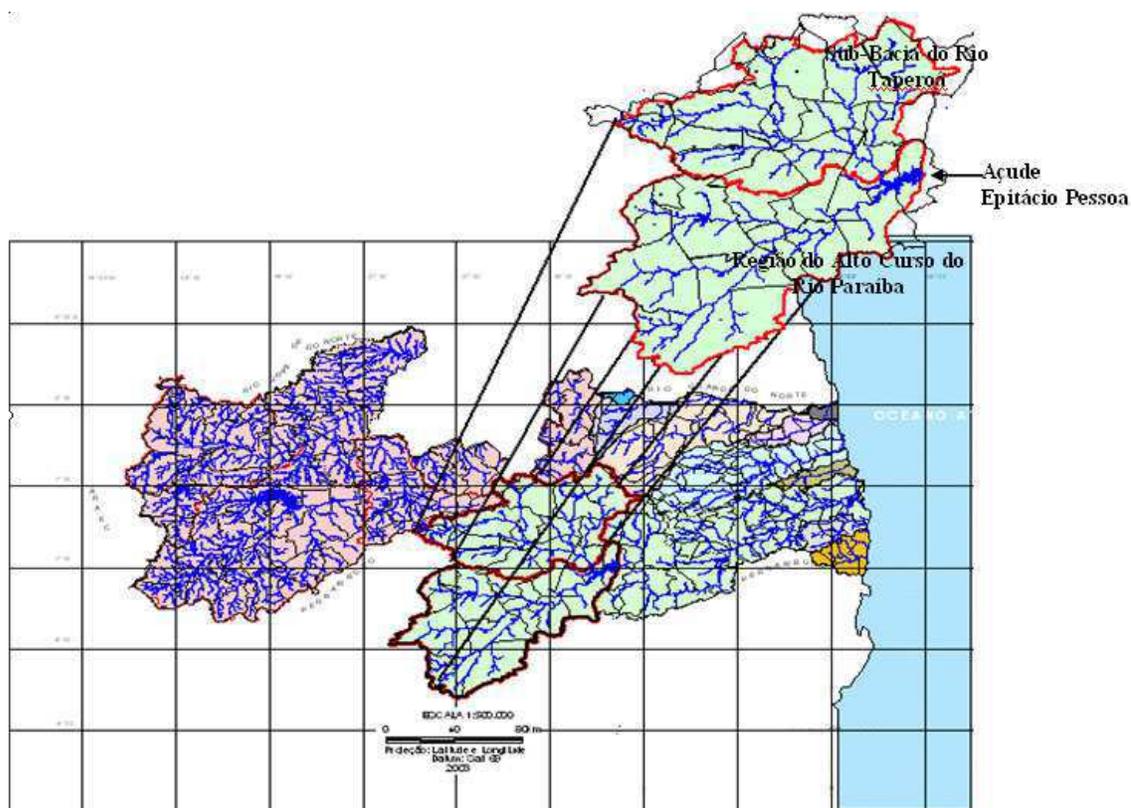


Figura 7. Distribuição dos rios e divisão das sub-bacias. Fonte: Medeiros (2003).

A bacia de Boqueirão pertence à grande bacia do rio Paraíba, um dos mais importantes do Estado. No que tange a hidrografia é pobre em seus amplos aspectos, de maneira que as condições hídricas são insuficientes para suprir o escoamento dos rios nos longos períodos de ausência de precipitação. Os rios e lagos do semi-árido são irregulares, de características intermitentes, onde a água superficial desaparece durante o período de estiagem. A paisagem dos rios e lagos temporários, onde a presença da água superficial é mais constante, apresenta um período de seca estacional bem marcada.

Através do Governo Federal e Estadual, foram construídos na área da bacia vários açudes públicos, que são utilizados no abastecimento das populações e rebanhos, irrigação, pesca e em algumas iniciativas de lazer e turismo regional. Esses reservatórios são as principais fontes de água da região e nas ocorrências de estiagens muitos deles entram em colapso, ocasionando conflitos pelo uso dos recursos hídricos e graves problemas de ordem social e econômica, como é o caso do Açude Epitácio Pessoa em Boqueirão (AESA, 2010). A Figura 8 mostra a distribuição dos açudes monitorados pela Agência Executiva de Gestão de Águas do Estado da Paraíba - AESA.

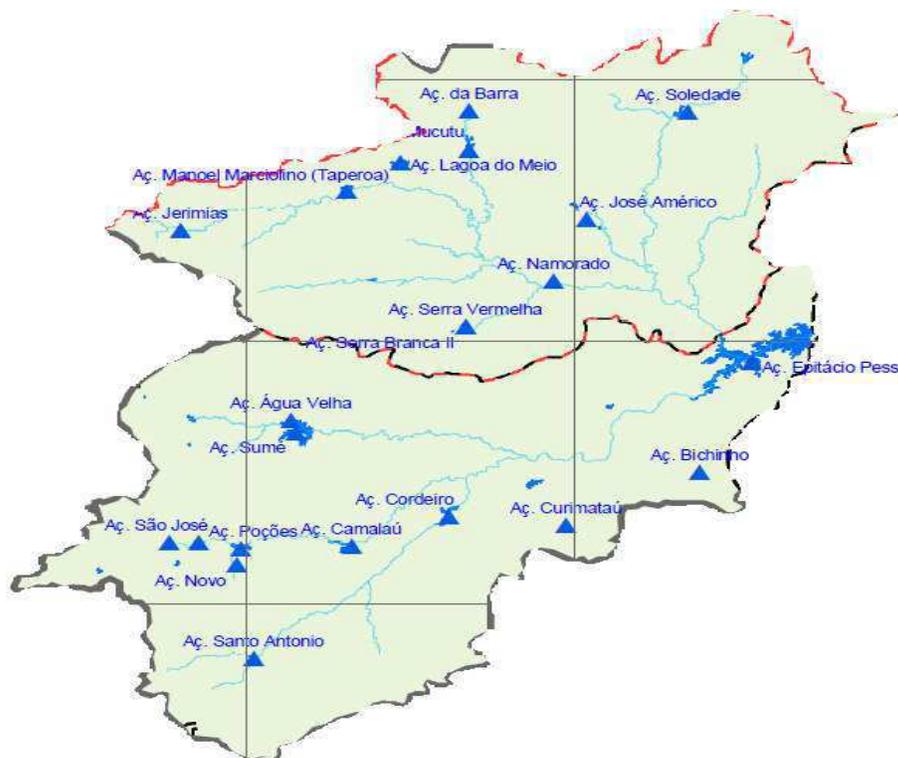


Figura 8. Açudes monitorados para disponibilidade de recursos hídricos. Fonte: AESA

#### 4.1.1 Sub-bacia do Alto Paraíba

Situada na parte sudoeste do Planalto da Borborema, a região do Alto Paraíba localiza-se entre as latitudes  $7,347^0$  e  $8,303^0$  sul e entre as longitudes  $36,128^0$  e  $37,356^0$  oeste de Greenwich. Limita-se ao sul e a oeste com o Estado de Pernambuco, e ao norte com a bacia do rio Taperoá. Nela estão inseridos, totais ou parcialmente, os municípios de Amparo, Barra de São Miguel, Boqueirão, Cabaceiras, Camalaú, Caraúbas, Congo, Coxixola, Monteiro, Ouro Velho, Prata, São Domingos do Cariri, São João do Cariri, São João do Tigre, São Sebastião do Umbuzeiro, Serra Branca, Sumé e Zabelê. A sub-bacia do Alto Paraíba drena uma área de  $6.717,39 \text{ km}^2$  através dos rios contribuintes Monteiros e Umbuzeiro e do rio Paraíba, que é o principal.

#### 4.1.2 Sub-bacia do rio Taperoá

Essa sub-bacia se situa na parte central do Estado da Paraíba, conformando-se sob as latitudes  $6,863^0$  e  $7,576^0$  sul e entre as longitudes  $36,167^0$  e  $37,023^0$  oeste. Limita-se com as sub-bacias do rio *ESP*Inharas e do rio Seridó a oeste, com a região do Alto Paraíba ao sul, com as bacias do Jacu e Curimataú ao norte e com a região do Médio Paraíba a leste. Seu principal rio é o Taperoá, de regime intermitente que nasce na Serra do Teixeira e desemboca no rio Paraíba. No interior da sub-bacia, distribuem-se completa e parcialmente os municípios: Assunção, Barra de Santa Rosa, Boa Vista, Cabaceiras, Cacimbas, Desterro, Gurjão, Juazeirinho, Junco do Seridó, Livramento, Olivedos, Parari, Pocinhos, Salgadinho, Santo André, Serra Branca, São João do Cariri, São José dos Cordeiros, Seridó, Soledade, Taperoá, Teixeira e Tenório. Drena uma área aproximada de  $5.668,25 \text{ km}^2$ . Recebe contribuições de cursos d'água como os rios São José dos Cordeiros, Floriano, Soledade e Boa Vista e dos rios riachos Carneiro, Mucum e da Serra.

#### 4.2 DADOS

Em muitas cidades da Europa, como por exemplo, Berlim e Paris, chovem por ano, em média 520 e 660 mm, respectivamente. Essa mesma quantidade precipita no semi-árido do Nordeste do Brasil. Dentre outros motivos, a diferença entre as cidades européias e a região

semi-árida está na taxa de evaporação, que na região é muito alta, e na irregularidade temporal e espacial da precipitação. A precipitação e a evaporação são os principais fatores que determinam a quantidade de água que realmente estará à disposição de todos os tipos de demandas da região.

Entretanto, é bastante conhecido que a Paraíba é o estado do Nordeste que apresenta uma das maiores variabilidades espacial nas chuvas, vez que o agreste/litoral apresenta precipitação média anual acima de 1083,4 mm ano, em média, seguida do sertão, com valores médios de 821,9 mm/ano e por fim a região do Cariri/Curimataú com média alcançando até 516,1 mm/ano. A localidade de Cabaceiras, localizada no Cariri Paraibano, registra média anual em torno de 300 mm enquanto que na faixa litorânea, distante aproximadamente 150 km, o total médio anual de precipitação é superior a 1500 mm. (ARAÚJO et al. 2003).

Neste estudo os dados mensais de precipitação pluvial foram adquiridos na Agência Nacional das Águas (ANA), para o período de 1965 a 2000, de 26 postos pluviométricos, representativas da bacia do açude Epitácio Pessoa (Boqueirão).

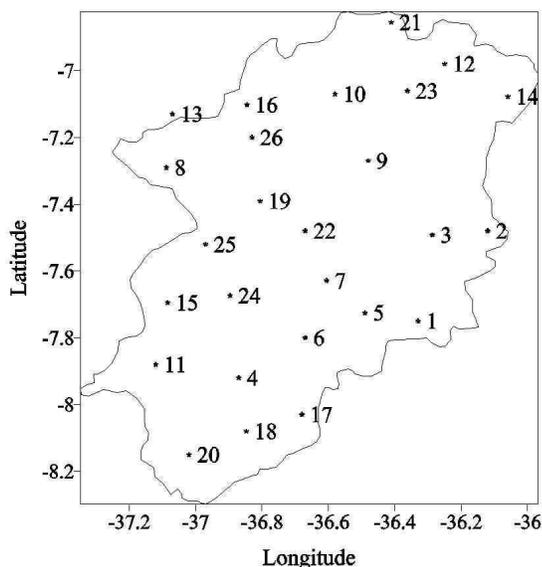


Figura 9. Relação dos postos pluviométricos utilizados

O período adotado não pode ser maior porque o interesse foi o de se trabalhar com séries completas e de mesmo tamanho para todos os postos. As localizações espaciais dos postos pluviométricos estão fornecidas na Figura 9, e na Tabela 2.

Tabela 2. Postos pluviométricos selecionados.

Número do posto	Longitude (°)	Latitude (°)	Relevo (m)	Município / posto
1	-36,318	-7,752	520	Barra de São Miguel
2	-36,136	-7,491	380	Boqueirão
3	-36,287	-7,492	390	Cabaceiras
4	-36,826	-7,890	365	Camalaú
5	-36,490	-7,725	460	Caraúbas
6	-36,659	-7,802	500	Congo
7	-36,606	-7,629	465	Coxixola
8	-37,088	-7,290	590	Desterro
9	-36,489	-7,248	480	Gurjão
10	-36,580	-7,068	570	Juazeirinho
11	-37,127	-7,885	596	Monteiro
12	-36,244	-6,989	545	Olivedos
13	-37,048	-7,136	340	Passagem
14	-36,059	-7,078	624	Pocinhos
15	-37,084	-7,695	600	Prata
16	-36,845	-7,102	410	Salgadinho
17	-36,68	-8,03	800	Santa Maria da Paraíba
18	-36,847	-8,080	616	São João do Tigre
19	-36,806	-7,391	610	São José dos Cordeiros
20	-37,010	-8,152	600	São Sebastião do Umbuzeiro
21	-36,411	-6,855	590	Seridó
22	-36,66	-7,482	450	Serra Branca
23	-36,362	-7,061	560	Soledade
24	-36,896	-7,674	510	Sumé
25	-36,963	-7,507	700	Sumé / Fazenda Bananeiras
26	-36,828	-7,216	500	Taperoá

Medeiros (2003) mostra um resumo dos principais sistemas atuantes no Nordeste e que influenciam a estabilidade atmosférica sob o estado da Paraíba, onde se encontram os sistemas frontais (KOUSKY, 1979), a Zona de Convergência Intertropical – ZCIT (UVO, 1989), os Vórtices Ciclônicos em Ar Superior – VCAS (KOUSKY E GAN, 1981), Distúrbios Ondulatórios de Leste – DOL (ESPINOZA, 1996) e a Zona de Convergência do Atlântico Sul (ZCAS). Climatologicamente, estes sistemas meteorológicos atuam de forma mais intensa no estado da Paraíba durante o verão, com exceção dos sistemas frontais que atuam mais ao norte no inverno. Em março, é característico à presença da Zona de Convergência Intertropical, que atua na parte norte do NEB e em maio, onde os Distúrbios Ondulatórios de Leste atuam na costa leste da região. Assim, a atuação desses principais sistemas determina o início de três regimes de chuvas anuais nas áreas de suas influências, Strang (1972) e Monte (1986). Além desses sistemas característicos ao clima da região, a presença de Vórtices Ciclônicos em Ar Superior atua de forma representativa entre os meses de dezembro e março, atingindo várias áreas do NEB. (CALBETE 1996).

A configuração da precipitação pluvial no estado da Paraíba indica um deslocamento dos sistemas meteorológicos, citados anteriormente, vindos de Oeste e Sudoeste a partir de meados de novembro, atingido o oeste do estado, onde se localiza o sertão (Figura 10).

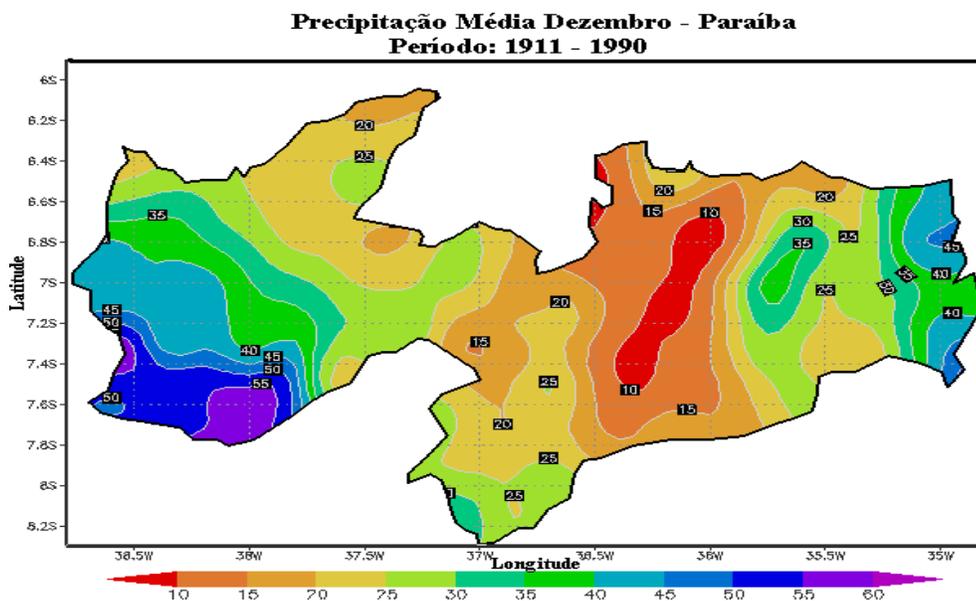


Figura 10. Climatologia do estado da Paraíba para o mês de dezembro. Fonte: DCA

Os valores de precipitação mensal passam a aumentar e se deslocar em direção ao litoral. Em concomitância com outros sistemas de leste, a precipitação em fevereiro aumenta em todo o estado, principalmente sobre a região da bacia hidrográfica do açude Epitácio Pessoa, atingindo seu máximo sobre a bacia no mês de março (Figura 11), persistindo até o mês de abril.

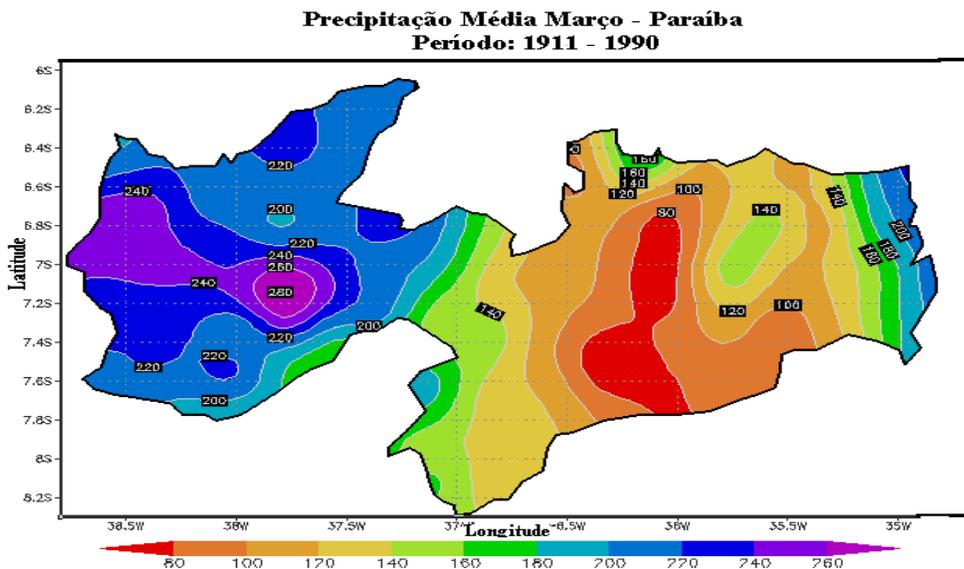


Figura 11. Climatologia do estado da Paraíba para o mês de março. Fonte: DCA

### 4.2.1 Séries de *SPI* para a bacia

O déficit de precipitação causa impactos na umidade do solo, nas vazões dos rios, no armazenamento dos reservatórios, no nível de água do lençol freático etc, em diferentes escalas temporais. McKee et al. (1993) desenvolveu o *SPI* para quantificar déficits de precipitação em múltiplas escalas. A natureza do *SPI* permite ao analista determinar a raridade de uma seca ou um evento úmido anômalo em um determinado período de tempo para qualquer local do mundo que tenha registros de precipitação. O evento seca ocorre no período em que o valor do *SPI* é continuamente negativo. O evento seca cessa quando o *SPI* se torna positivo. A Tabela 3 fornece uma classificação de seca baseada no *SPI*.

Tabela 3. Classificação da precipitação baseada no *SPI*.

<b>Valores do <i>SPI</i></b>	<b>Classe</b>
2,00 ou mais	Chuva extrema
1,50 a 1,99	Chuva severa
1,00 a 1,49	Chuva moderada
0,50 a 0,99	Chuva fraca
0,49 a -0,49	Normal
-0,50 a -0,99	Seca fraca
-1,00 a -1,49	Seca moderada
-1,50 a -1,99	Seca severa
-2,00 ou menos	Seca extrema

O uso do *SPI* apresenta as seguintes vantagens, discutidas por Hayes et al. (1999):

- 1) A principal razão do uso *SPI* é que ele é baseado apenas na precipitação. Desse modo, a avaliação de seca é possível, mesmo que outras informações hidrometeorológicas não estejam disponíveis;
- 2) O *SPI* não é afetado negativamente pela topografia;
- 3) O *SPI* é variável em escala temporal, isso permite descrever condições de secas importantes na meteorologia, na hidrologia e em aplicações agrícolas;
- 4) Por ser um índice padronizado, as frequências de eventos extremos em qualquer local e em qualquer escala temporal são consistentes;

5) O *SPI* pode detectar déficit de umidade mais rapidamente do que o PDSI (Palmer Drought Severity Index), que tem tempo de resposta na escala temporal em cerca de 8 a 12 meses.

O *SPI* é computado pelo ajuste de uma função densidade de probabilidade à distribuição de frequência da precipitação na escala temporal de interesse. Essa tarefa é realizada separadamente para cada mês (seja qual for a base temporal da precipitação) e para cada local. Os valores das probabilidades acumuladas são transformados pelo uso de uma distribuição normal padronizada. A distribuição gama é definida pela sua frequência ou função densidade de probabilidade como:

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \quad (1)$$

em que  $\alpha > 0$  é um fator forma,  $\beta > 0$  é um fator de escala, e  $x > 0$  é a quantidade de precipitação.  $\Gamma(\alpha)$  é a função gama definida como:

$$\Gamma(\alpha) = \int_0^{\infty} y^{\alpha-1} e^{-y} dy \quad (2)$$

o ajuste dos dados à distribuição necessita da estimativa dos parâmetros  $\alpha$  e  $\beta$ . Edwards e McKee (1997) sugerem que esses parâmetros sejam estimados pela aproximação de Thom (1958) para a máxima verossimilhança, como segue:

$$\hat{\alpha} = \frac{1}{4A} \left( 1 + \sqrt{1 + \frac{4A}{3}} \right) \quad \text{em que: } A = \ln(\bar{x}) - \frac{\sum x_i}{n}, \quad (3)$$

$$\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}} \quad (4)$$

Os parâmetros resultantes são utilizados para encontrar a probabilidade acumulada do evento de precipitação observado para dado mês e escala temporal, assim:

$$G(x) = \int_0^x g(x) dx = \frac{1}{\hat{\beta}^{\hat{\alpha}} \Gamma(\hat{\alpha})} \int_0^x x^{\hat{\alpha}-1} e^{-x/\hat{\beta}} dx \quad (5)$$

Fazendo  $t = x/\hat{\beta}$  a equação se reduz a uma função gama incompleta. Visto que a função gama é indefinida para  $x=0$  e uma amostra de dados de precipitação pode conter zeros, a probabilidade acumulada torna-se:

$$H(x) = q + (1 - q)G(x) \quad (6)$$

em que  $q$  é a probabilidade de ocorrência de precipitação zero.

A probabilidade acumulada  $H(x)$  é transformada em variável aleatória normal padronizada  $Z$  com média zero e variância um, que é o valor do *SPI*. Segundo Edwards e McKee (1997), Hughes e Saunders (2002), a conversão aproximada, fornecida por Abramowitz e Stegun (1965) é:

$$Z = SPI = - \left( t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \quad \text{para } 0 < H(x) \leq 0,5 \quad (7)$$

$$Z = SPI = + \left( t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \quad \text{para } 0,5 < H(x) \leq 1,0 \quad (8)$$

em que,

$$\text{em que } t = \sqrt{\ln\left(\frac{1}{(H(x))^2}\right)} \quad \text{Para } 0 < H(x) \leq 0,5 \quad (9)$$

$$\text{e } t = \sqrt{\ln\left(\frac{1}{(1-H(x))^2}\right)} \quad \text{Para } 0,5 < H(x) \leq 1,0 \quad (10)$$

e,

$$c_0 = 2,515517; \quad c_1 = 0,802853; \quad c_2 = 0,010308;$$

$$d_1 = 1,432788; \quad d_2 = 0,189269; \quad d_3 = 0,001308$$

#### 4.3 CONCEPÇÃO DA REDE

Na aplicação das redes neurais artificiais são necessárias três fases: montagem, treinamento e previsão. A primeira fase é a mais importante, pois nela que se define o tipo de rede, toda a sua arquitetura (camadas e neurônios ocultos), funções de ativação, tipo de propagação, algoritmo de aprendizado, etc. Toda à análise do processo de escolha da configuração da rede usada está descrito nos resultados.

Na segunda fase o treinamento da rede é processado com muita atenção, pois, é aqui onde ocorre o aprendizado da rede, captando as características da série (picos, aleatoriedade, sazonalidade, etc). Nesta fase, os dados são divididos, de forma que entre 50% e 70% são utilizados no aprendizado da rede, entre 15% e 30% na validação e entre 10% e 30% no teste da rede. A maneira como os pesos serão modificados é definida de acordo com o algoritmo de treinamento específico para cada modelo de redes neurais. Geralmente os pesos relativos a

cada neurônio são alterados de modo a tornar a rede capaz de representar a relação entre os dados de entrada e de saída. Neste processo a rede definiu um neurônio como principal, chamado de neurônio ativo, o peso deste neurônio se mantém constante e os demais que se adaptam ao mesmo. Os dois algoritmos mais difundidos são o algoritmo Levenberg-Marquardt e o algoritmo de retropropagação de erros (*error backpropagation*). Essa fase de aprendizado deve ser a mais rígida e eficiente, a fim de se evitar modelos espúrios. Todo o conhecimento de uma rede neural está armazenado nas “sinapses”, ou seja, nos pesos atribuídos às conexões entre os neurônios.

A terceira e última fase está ligada ao teste da rede, onde a rede é utilizada para fazer previsões e correções dos valores encontrados. Aqui, uma comparação com valores observados e valores previstos é feita através de medidas de erros, geralmente se utiliza a raiz do erro médio quadrático (MSE). Se os resultados não forem satisfatórios, o treinamento é reiniciado com as novas informações, modificando a quantidade de iterações e assim a própria rede altera suas informações sinápticas para melhorar a desempenho. A rede pode ser configurada para fazer todo o processo automaticamente.

Uma RNA para previsão de séries temporais implica em nós de entrada conectados a uma série de valores observados no passado para identificar os processos em tempo futuro. A função de ativação determina a relação entre entradas e saídas de um nó e uma rede.

São os nós na camada oculta que permitem às redes neurais detectar a característica, captar o padrão nos dados, e executar complicado mapeamento não-linear entre variáveis de entrada e de saída. Tem sido provado que apenas uma camada de unidades escondida é suficiente para uma RNA aproximar qualquer função não-linear complexa com a precisão desejada (Cybenko, 1989; Hornik et al., 1989). Os nós ocultos também permitem levar em consideração a presença de dados não-estacionários, com tendências e variações sazonais (Maier e Dandy, 1996). No caso de uma rede com uma camada escondida, existem várias orientações práticas, que incluem a utilização "2n+1" (Lippmann, 1987; Hecht-Nielsen, 1990), "2n" (Wong, 1991), "n" (Tang e Fishwick, 1993) neurônios escondidos para melhor precisão da previsão, onde n é o número de nós de entrada. Menos neurônios na camada oculta do que na camada de entrada têm funcionado bem, segundo (Fletcher e Goss, 1993; Zhang e Dong, 2001). A fim de determinar a melhor arquitetura da rede, o número de neurônios nas camadas de entrada e escondida será determinado por experimentação.

O desempenho das previsões resultantes do modelo de RNA é avaliado pela seguinte medida de ajuste:

$$\text{MSE} = \sqrt{\frac{1}{p} \sum_{i=1}^p [(x_o)_i - (x_s)_i]^2} \quad (11)$$

em que os índices  $o$  e  $s$  representam os valores observados e simulados da série *SPI*, respectivamente e  $p$  é número total de eventos considerados.

Matematicamente cada neurônio possui um peso associado ( $W_{ij}$ ) para cada dado ( $a_{ij}$ ) do vetor de entrada. O dado de entrada é então multiplicado por este peso. Outro parâmetro também importante é o bias ( $\theta$ ). Os bias controlam a ativação de cada neurônio de maneira que após a multiplicação do enésimo dado de entrada pelo peso, a ativação total do neurônio é calculada subtraindo-se seu valor, conforme a equação 12 (Baughman e Liu, 1995):

$$\text{Ativação Total} = x_j = \sum_{i=1} (w_{ij} + a_i) - \theta \quad (12)$$

Após o calculo realizado pela equação 12, o resultado passa então pela função ativação, conforme o calculo representado na equação 13.

$$y_j = F\left(\sum_{i=1} (w_{ij} + a_i) - \theta\right) \quad (13)$$

As funções de ativação tipicamente usadas na camada escondida são as funções logística sigmoidal (entre 0 e 1) e tangente hiperbólica (entre -1 e 1). Na camada de entrada, os neurônios são lineares e na de saída podem ser adotadas funções lineares ou a logística sigmoidal (Salvatore, 2007).

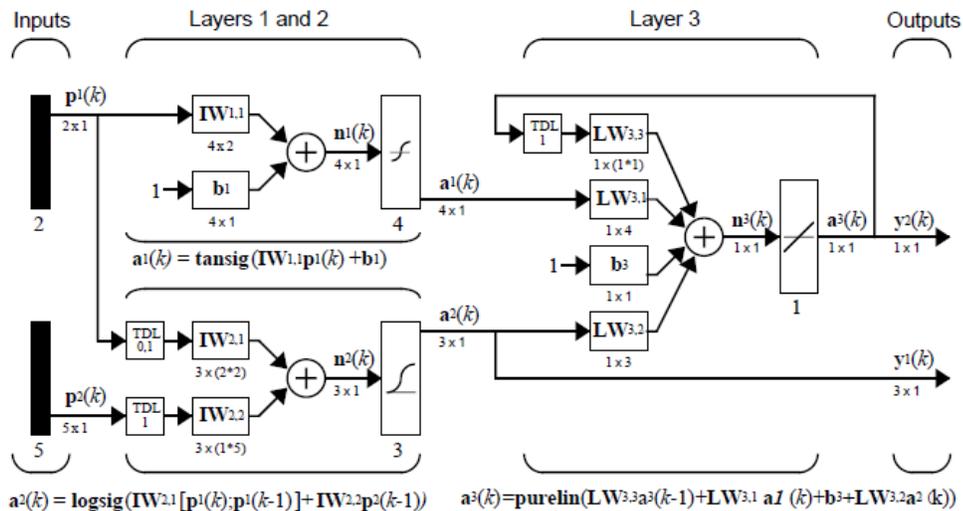


Figura 12. Configuração de uma rede neural com três camadas.

Fonte: Demuth (2007).

## 5. RESULTADOS E DISCUSSÃO

Na área da bacia do açude Epitácio Pessoa, a precipitação pluvial média do período de 1965 a 2000 registrou valores entre 340 mm e 750 mm. A Figura 13 mostra os valores abaixo de 500 mm (em laranja), compreendendo a parte nordeste e leste da bacia, enquanto os maiores valores de precipitação, acima de 500 mm, se encontram entre o oeste e sul da bacia (em azul). Esta divisão da precipitação média anual sobre a bacia concorda com a climatologia da Paraíba mostrada nas Figuras 10 e 11. O Planalto da Borborema interfere diretamente no deslocamento da umidade vinda de leste, pois retira energia dos sistemas meteorológicos durante sua propagação. Isto não acontece no lado oeste da bacia.

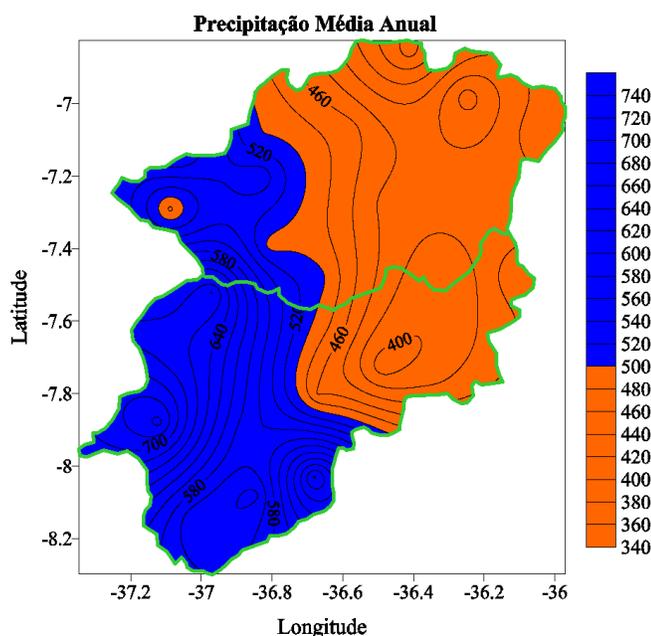
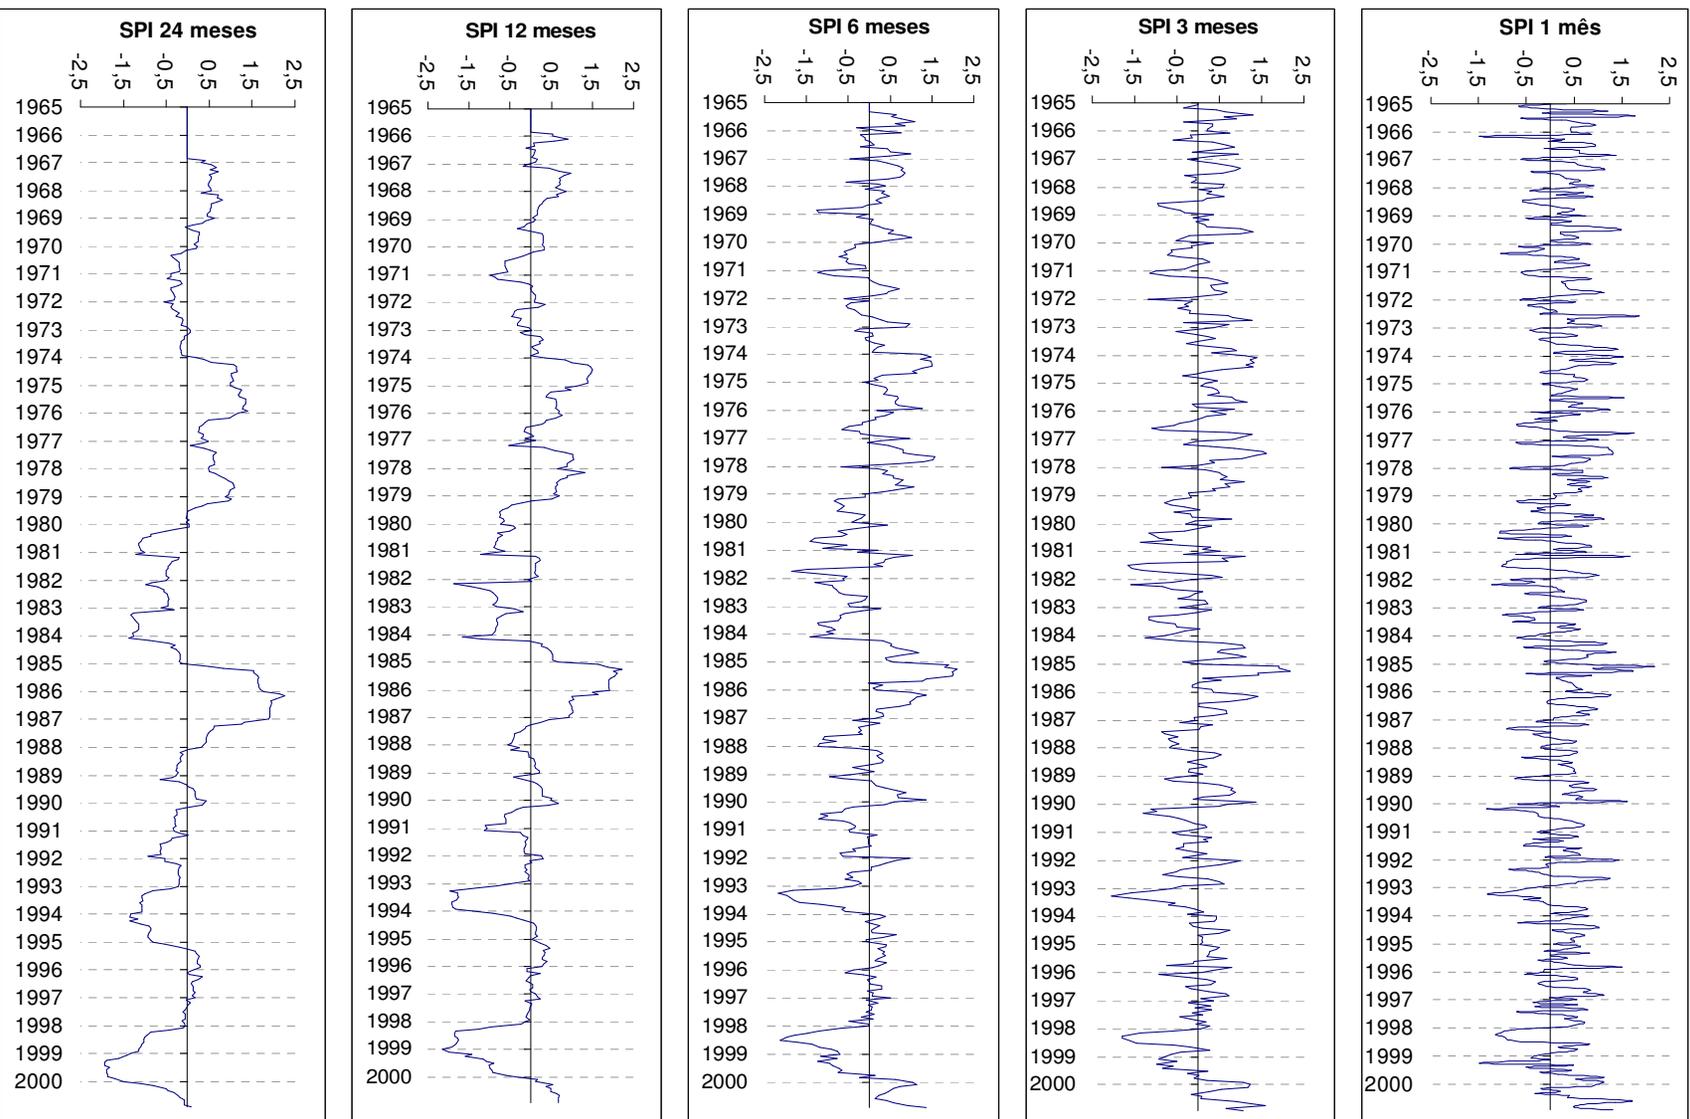


Figura 13. Distribuição espacial da precipitação.

Pode ser visto na Figura 14, que a curva do *SPI* tende à suavização à medida que se passa da escala temporal de 1 a 24 meses. Quanto maior for a escala temporal, menor será a variação, haja vista que as séries representam a precipitação acumulada para o mesmo período. Por essa razão, os gráficos com escala maior apresentam um atraso no início de suas séries. De maneira que as séries de *SPI* apresentam grande diferença na aleatoriedade dos dados quando se utiliza escalas temporais diferentes.

Para efeito de previsão, quanto menos aleatória for uma série, maiores serão as chances dos modelos encontrarem respostas satisfatórias. Assim, as séries de *SPI* com escalas temporais maiores são previstas com maior eficiência como veremos adiante.

Figura 14. SPI em escalas temporais diferentes: A. 1 mês, B. 3 meses, C. 6 meses, D. 12 meses, E. 24 meses.



## 5.1 ESCOLHAS DA REDE

Utilizou-se o posto pluviométrico de Barra de São Miguel para testar quatro tipos de redes. Nessa simulação as respostas das redes utilizadas estão na Tabela 4, onde R são valores de correlação entre a variável observada e a variável estimada pela rede, que são calculadas pelo algoritmo backpropagation presente nas duas primeiras redes. A melhor validação representa os menores valores do MSE encontrados durante a fase de validação. Nesta Tabela 4 ver-se que as duas melhores performances no geral foram das duas redes dos tipos *Cascade-forward* e *Feed-forward*. As outras duas redes, de Elman e Layer recurrent, além de apresentarem erros maiores, tiveram muitas iterações, consumindo mais tempo de processamento.

Tabela 4. Redes de duas camadas com 12 neurônios na camada escondida.

<b>REDES</b>	<b>R treino</b>	<b>R validação</b>	<b>R teste</b>	<b>R todos</b>	<b>Performance MSE</b>	<b>Melhor validação</b>
Feed-forward backpropagation	0,964	0,901	0,892	0,931	0,082	0,121
Cascade-forward backpropagation	0,965	0,910	0,901	0,940	0,080	0,114
Elman					0,089	0,230
Layer recurrent					0,091	0,123

Para decidir entre as duas melhores, foi feita uma comparação relativa ao número de neurônios diferentes na camada escondida, conforme mostrado na Tabela 5. Verifica-se que as duas redes têm desempenho semelhante, dependendo da quantidade de neurônios, sendo uma um pouco melhor que a outra. Decidiu-se utilizar as redes feed-forward, pois ela possui melhor desempenho com menos neurônios, o que é bom para o processamento; também grande parte das referências citadas utiliza esse tipo de rede.

Tabela 5. Comparação entre as redes Cascade-forward e Feed-forward.

<b>Tipo de Rede</b>	<b>Neurônios</b>	<b>R todos</b>	<b>MSE</b>	<b>Melhor validação</b>
Cascade-forward	08	0,935	0,112	0,149
Feed-forward		0,940	0,109	0,136
Cascade-forward	16	0,940	0,099	0,109
Feed-forward		0,923	0,080	0,130
Cascade-forward	24	0,890	0,130	0,360
Feed-forward		0,910	0,120	0,260

Para verificação do melhor algoritmo de treinamento montou-se uma rede feed-forward com 12 neurônios na camada escondida e treinou-se com cada algoritmo disponível no MatLab 2009a . Os desempenhos de cada algoritmo estão disponíveis na Tabela 6.

Tabela 6. Teste com diferentes algoritmos de treinamento.

<b>Algoritmos</b>	<b>Melhor Validação</b>	<b>Performance (MSE)</b>	<b>R (Todos)</b>
<u>trainbfg</u>	0,116	0,094	0,618
<u>trainbr</u>	6,66	18,3	0,94
<u>traincgb</u>	0,17	0,075	0,24
<u>traincgf</u>	0,13	0,113	0,34
<u>traincgp</u>	0,14	0,110	0,40
<u>traingd</u>	0,21	0,111	0,92
<u>traingda</u>	5,62	4,2	0,21
<u>traingdm</u>	0,313	16,7	0,87
<u>traingdx</u>	0,118	0,105	0,92
<u>trainlm</u>	<b>0,12</b>	<b>0,102</b>	<b>0,944</b>
<u>trainoss</u>	0,085	0,117	0,42
<u>trainr</u>	4,8	2,6	0,90
<u>trainrp</u>	0,137	0,141	0,92
<u>trainscg</u>	0,19	0,115	0,92

em que:

trainbfg - BFGS retropropagação quase-Newton;

trainbr - Regularização Bayesiana;

traincgb - Gradiente conjugado de retropropagação;

traincgf - Gradiente conjugado de retropropagação;

traingd – Gradiente descendente de retropropagação;

traingda – Gradiente descendente de retropropagação com regra de aprendizagem adaptativa;

traingdm - Gradiente descendente com retropropagação de momentum;

traingdx - Gradiente descendente com retropropagacao de momentum e regra de aprendizagem adaptativa;

trainlm - Retropropagação de Levenberg-Marquardt;

trainoss - Retropropagação de passo secante;

trainr - Aprendizagem com formação de funções elementares de ordem aleatória;

trainrp - Retropropagação resiliente;

trainscg - Gradiente de retropropagação conjugado e escalado

Os valores em vermelho em algumas tabelas 6 e 8 representam as melhores performances encontradas, assim, se verifica que o algoritmo de Levenberg-Marquardt se saiu

melhor que os demais. Alguns algoritmos também apresentaram erros pequenos, mas apresentaram valores baixos de regressão e também um número elevado de iterações. O segundo melhor algoritmo foi o traingdx, mais foi preciso 102 iterações, consumindo um intervalo de tempo maior. Assim, decidiu-se que todas as redes seriam do tipo feed-forward, com o algoritmo de treinamento de Levenberg-Marquardt,

Para se escolher a escala temporal do *SPI* que foi utilizada neste estudo, novamente outro posto pluviométrico foi escolhido aleatoriamente. O posto de Pocinhos teve seus dados separados em planilhas diferentes de acordo com a escala temporal para se determinar o comportamento da rede com mudanças de escala e de número de neurônios da camada escondida. A Tabela 7 resume esse teste.

Tabela 7. Teste com diferentes escalas temporais do *SPI* variando o número de neurônios.

<b>Escala temporal do <i>SPI</i></b>	<b>Neurônios</b>	<b>MSE</b>	<b>R para todos</b>
<b><i>SPI</i> 1 mês</b>	02	0,825	<0,70
	03	0,750	<0,70
	04	0,713	<0,70
	05	0,790	<0,70
	07	0,857	<0,70
	10	0,871	<0,70
<b><i>SPI</i> 3 meses</b>	05	0,635	0,77
	07	0,490	0,70
	10	0,480	0,70
	12	0,560	<0,70
<b><i>SPI</i> 6 meses</b>	03	0,420	0,80
	05	0,360	0,83
	08	0,420	0,84
	10	0,490	0,83
	12	0,400	0,82
	15	0,430	0,84
<b><i>SPI</i> 12 meses</b>	06	0,170	0,92
	09	0,170	0,93
	12	0,210	0,93
	15	0,310	0,91
	18	0,170	0,92
	21	0,250	0,93
	24	0,230	0,90
<b><i>SPI</i> 24 meses</b>	08	0,150	0,95
	12	0,100	0,95
	15	0,170	0,95
	18	0,150	0,92
	21	0,210	0,92
	24	0,210	0,90
	30	0,300	0,90
35	0,320	0,89	

Observa-se que as redes neurais apresentam redução no erro médio quadrático à medida que se aumentam as escalas temporais do *SPI*, melhorando também as regressões. Esse resultado já era esperado, conforme explicado anteriormente, pois as maiores escalas possuem menor variação no tempo, O *SPI* 12 meses e 24 meses apresentaram os melhores resultados, haja vista que essas duas escalas refletem padrões de precipitação em longo prazo. O *SPI* mais longo pode tender para zero, exceto quando uma tendência específica estiver ocorrendo (período seco ou chuvoso prolongado). Desse modo, os *SPI* - 12 e *SPI* - 24 estão diretamente associados à falta de água, vazões e níveis de água nos lençóis freáticos. Valores negativos desses índices podem estar, no entanto, associados a valores positivos em períodos inferiores a 12 e 24 meses respectivamente, o que pode em determinado momento mascarar os efeitos acumulados de um período longo com tendência para quantidades de precipitação reduzidas, sendo bem mais crítico no *SPI*- 24. Como a região em estudo apresenta período chuvoso curto, para evitar que os valores positivos de precipitação sejam mascarados, foi escolhido o *SPI* 12 meses, que pode identificar se a estação chuvosa foi suficiente para reduzir ou impedir os efeitos da seca na região.

Tabela 8. Teste com diferentes funções de transferência variando o número de neurônios.

Funções de transferência	Neurônios	R para todos	MSE	Melhor validação
<b>Tansig-Purelin</b>	04	0,936	0,110	0,169
	06	0,940	0,086	0,150
	08	0,910	0,101	0,103
	10	0,920	0,102	0,200
	12	0,950	0,072	0,150
	14	0,917	0,097	0,110
	16	0,940	0,105	0,220
	18	0,912	0,106	0,260
	20	0,900	0,150	0,270
<b>Tansig-Tansig</b>	06	0,880	0,097	0,220
	08	0,933	0,112	0,140
	10	0,930	0,109	0,150
	12	0,940	0,079	0,140
	14	0,890	0,088	0,180
<b>Logsig-Purelin</b>	04	0,944	0,088	0,155
	06	0,920	0,092	0,135
	08	0,940	0,088	0,139
	10	0,930	0,095	0,141
	12	0,940	0,090	0,160
	14	0,900	0,150	0,290

A Tabela 8 exibe o desempenho de várias redes, com variações do número de neurônios na camada escondida e também das funções de transferência (ou função de ligação) nas duas camadas, escondida e de saída, respectivamente.

Outras configurações de funções de transferência foram utilizadas, tais como purelin-purelin, purelin-tansig, purelin-logsig, logsig-logsig, logsig-tansig e tansig-logsig, mas nenhuma delas obteve resultados consistentes e foram descartadas. Dentre os resultados mostrados na Tabela 8, o melhor desempenho foi obtido usando a rede com 12 neurônios na camada escondida, associada às funções tansig-purelin. O segundo melhor desempenho foi com a configuração das funções tansig-tansig.

Foram testadas, ainda, redes com três camadas mais não se obteve melhorias significativas. Os dois melhores desempenhos com três camadas estão na Tabela 9. Também, as duas redes possuem 12 neurônios nas duas camadas escondidas.

Tabela 9. Teste da rede com três camadas.

<b>Função de Transferência</b>	<b>R todos</b>	<b>Mse</b>	<b>Melhor Validação</b>
Tansig-Tansig-Purelin	0.93	0.091	0.26
Tansig-Tansig-Tangsig	0.91	0.092	0.17

Na Tabela 10 pode ser visto que o desempenho da rede escolhida para todos os postos selecionados neste estudo. O melhor desempenho estimado pelo MSE foi o do posto de Sumé, igual a 0,040 e o pior desempenho foi para o posto de Juazeirinho, com MSE igual a 0,223. Os melhores desempenhos no geral foram para os postos de Sumé/Bananeiras e Camalaú, pois, apresentaram valores de regressões acima de 0,95 em todas as fases e ainda obtiveram valores pequenos de MSE e de melhor validação. Os resultados obtidos para todos os postos são considerados muito bons. É interessante observar que a fase de treinamento apresentou as melhores regressões, já a fase de validação, em média, apresentou os menores valores.

Tabela 10. Desempenho e regressão de todas as estações para a rede escolhida.

<b>Postos</b>	<b>R</b> <b>treino</b>	<b>R</b> <b>validação</b>	<b>R</b> <b>teste</b>	<b>R</b> <b>todos</b>	<b>Performance</b> <b>MSE</b>	<b>Melhor</b> <b>validação</b>
<b>Barra de São Miguel</b>	0,964	0,899	0,88	0,931	0,0914	0,198
<b>Boqueirão</b>	0,965	0,918	0,903	0,943	0,0817	0,133
<b>Cabaceiras</b>	0,962	0,821	0,884	0,917	0,1140	0,178
<b>Camalaú</b>	0,960	0,963	0,958	0,958	0,0846	0,095
<b>Caraíbas</b>	0,976	0,924	0,894	0,946	0,0850	0,143
<b>Congo</b>	0,979	0,927	0,955	0,962	0,0650	0,122
<b>Coxixola</b>	0,977	0,862	0,908	0,936	0,1000	0,248
<b>Desterro</b>	0,958	0,876	0,927	0,931	0,1150	0,165
<b>Gurjão</b>	0,959	0,876	0,870	0,928	0,1030	0,129
<b>Juazeirinho</b>	0,966	0,780	0,921	0,906	0,2230	0,218
<b>Monteiro</b>	0,957	0,886	0,919	0,922	0,0817	0,257
<b>Olivedos</b>	0,971	0,910	0,946	0,954	0,0563	0,135
<b>Passagem</b>	0,980	0,856	0,827	0,934	0,0805	0,209
<b>Pocinhos</b>	0,956	0,843	0,928	0,925	0,1640	0,253
<b>Prata</b>	0,965	0,886	0,921	0,941	0,1040	0,180
<b>Salgadinho</b>	0,964	0,933	0,942	0,952	0,0814	0,143
<b>São João do Tigre</b>	0,972	0,911	0,960	0,950	0,0602	0,183
<b>São José dos Cordeiros</b>	0,948	0,860	0,910	0,926	0,1630	0,128
<b>São Sebastião Umbuzeiro</b>	0,987	0,845	0,921	0,947	0,0440	0,219
<b>Seridó</b>	0,976	0,892	0,959	0,955	0,0867	0,107
<b>Serra Branca</b>	0,980	0,884	0,917	0,946	0,1020	0,227
<b>Soledade</b>	0,944	0,822	0,913	0,911	0,1140	0,223
<b>Sumé/ Bananeiras</b>	0,982	0,950	0,972	0,974	0,0600	0,082
<b>Sumé</b>	0,990	0,884	0,835	0,943	0,0400	0,129
<b>Taperoá</b>	0,979	0,888	0,919	0,947	0,1120	0,165

Após o treinamento da rede, fez-se a simulação e a previsão. Os ajustes da rede aos dados de *SPI*-12 meses, de todos os postos pluviométricos estudados, podem ser vistos nas Figuras 16 a 40. Os valores calculados dos *SPI* -12 meses estão nas linhas escuras e a resposta da rede na forma de previsão está nas linhas em vermelho.

Na fase de simulação pode ser notado que houve ótimos ajustes em relação às séries de *SPI* – 12 meses (Figuras A). Já nas séries previstas (Figuras B) houve um bom ajuste, a previsão acompanha a sazonalidade, com boas respostas para grande parte dos picos das séries temporais. Essa peculiaridade (representação dos picos das séries em previsão) é um dos resultados mais difíceis de obter-se em análise e previsão de séries temporais.

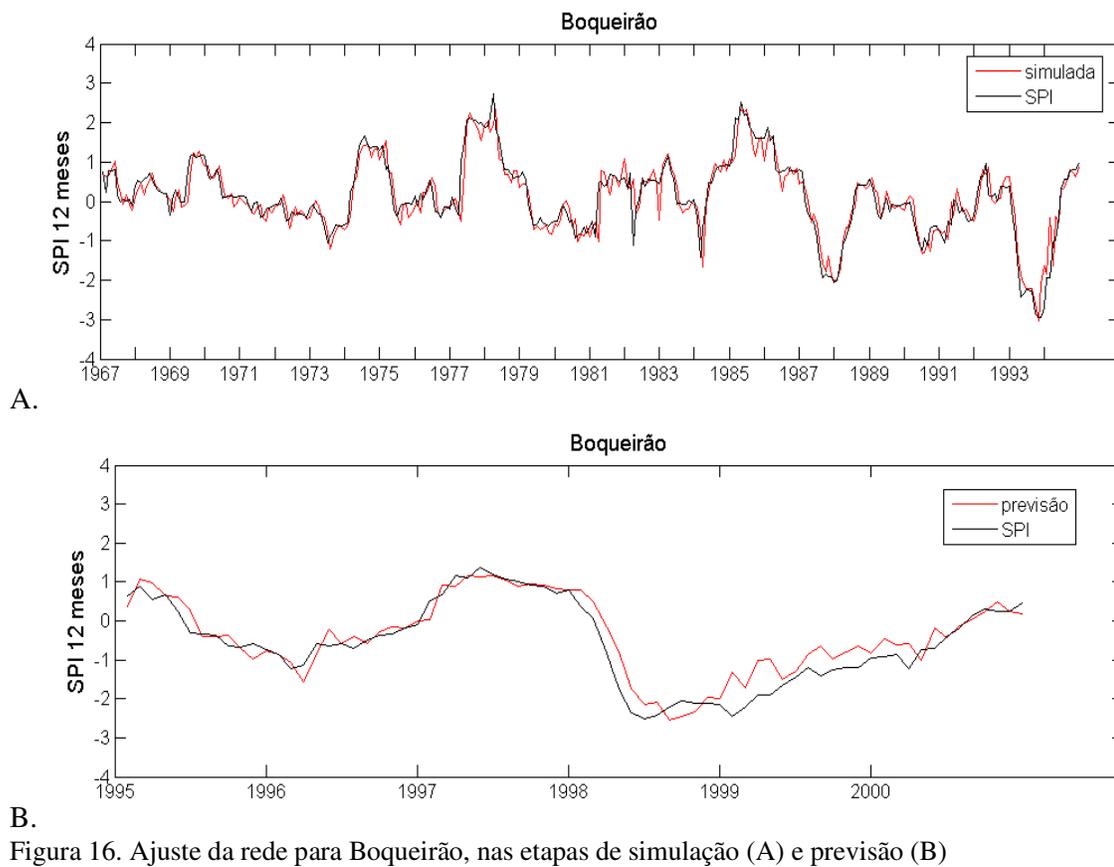
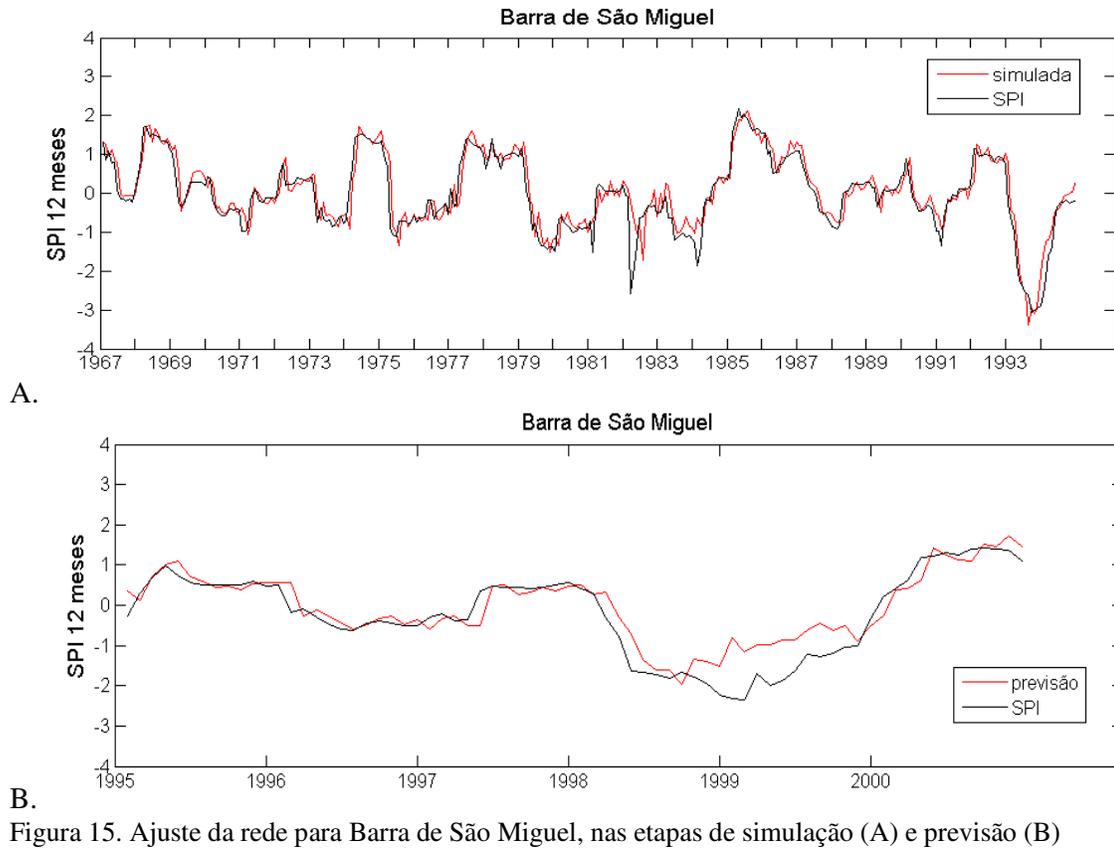
O comportamento do *SPI* na escala de 12 meses fornece informações da precipitação acumulada nesse período. Portanto, na análise das Figuras 15 a 39, deve-se levar em conta o atraso nas inclinações do gráfico para identificar períodos de excesso ou escassez de chuva. Dessa forma, é possível identificar neste estudo os anos de baixa pluviosidade e a categoria de

seca presente em cada época para cada ponto da bacia. Para localizar ocorrência de secas em cada posto pluviométrico, observam-se os pontos das séries que apresentam valores negativos, sendo a consequência de cada tipo de seca mais intensa quando seus valores negativos permanecem por mais tempo.

Podem-se fazer análises pontuais ou gerais da bacia hidrográfica em questão, é só comparar cada posto e a variação espacial e temporal dos valores de *SPI*. Para exemplificar, nas Figuras com letra A, referentes aos gráficos das simulações, observa-se que o ano de 1985, todos os postos apontam alto crescimento da série de *SPI*, indicando um ano muito chuvoso em toda a bacia. Já nas Figuras com letra B, referentes aos gráficos das previsões para 1 mês, o acumulado dos anos de 1998 e 1999, apresenta valores de *SPI* abaixo de -1,5 para todas as estações. Sendo assim, esses anos podem ser considerados como anos de seca severa em toda a bacia do açude Epitácio Pessoa, com alguns postos apresentando valores abaixo -2,0; em alguns meses, o que caracteriza seca extrema.

Após se identificar cada evento de seca ou de excesso de chuva, pode-se buscar explicações físicas e meteorológicas para a ocorrência destes eventos. Nos exemplos acima, uma das justificativas para o ano de 1998 foi a ocorrência do El Niño forte, que é um sistema que reduz a precipitação sobre o Nordeste Brasileiro. Já no ano de 1999, foi mais chuvoso, pois os valores de *SPI* começam a aumentar gradativamente, devido a esta escala representar o acumulado de 12 meses. Sabe-se que a seca não cessa rapidamente, principalmente seca do tipo severa ou extrema, nesses casos há atraso na disponibilidade de recursos hídricos, causado pela infiltração e percolação da água no solo. Nesse processo a recuperação dos níveis freáticos anteriores é demorada. Em rios perenes, a redução das chuvas faz com que o canal do rio passe a ser alimentado pelo escoamento subterrâneo, quando ocorrem secas severas ou extremas. A recuperação dos níveis históricos do lençol freático requer grande volume de precipitação para aumentar o fluxo do escoamento subterrâneo (Machado, 2005).

Das séries previstas, há um destaque para o posto de Monteiro que apresentou previsão fora do padrão comum (Figura 25. B). Pode ser notado que os últimos anos da série *SPI* – 12 meses são quase constantes. Em busca de resposta para esse comportamento incomum, analisou-se a série de precipitação no período estudado e verificou-se que as falhas dos dados, entre os anos de 1985 a 1997, foram preenchidas pela média aritmética. Em princípio, esse posto deveria ter sido descartado, mas se decidiu aplicar a metodologia de *SPI* / RNAs para mostrar que o preenchimento de falhas em dados observados nem sempre é bem vindo.



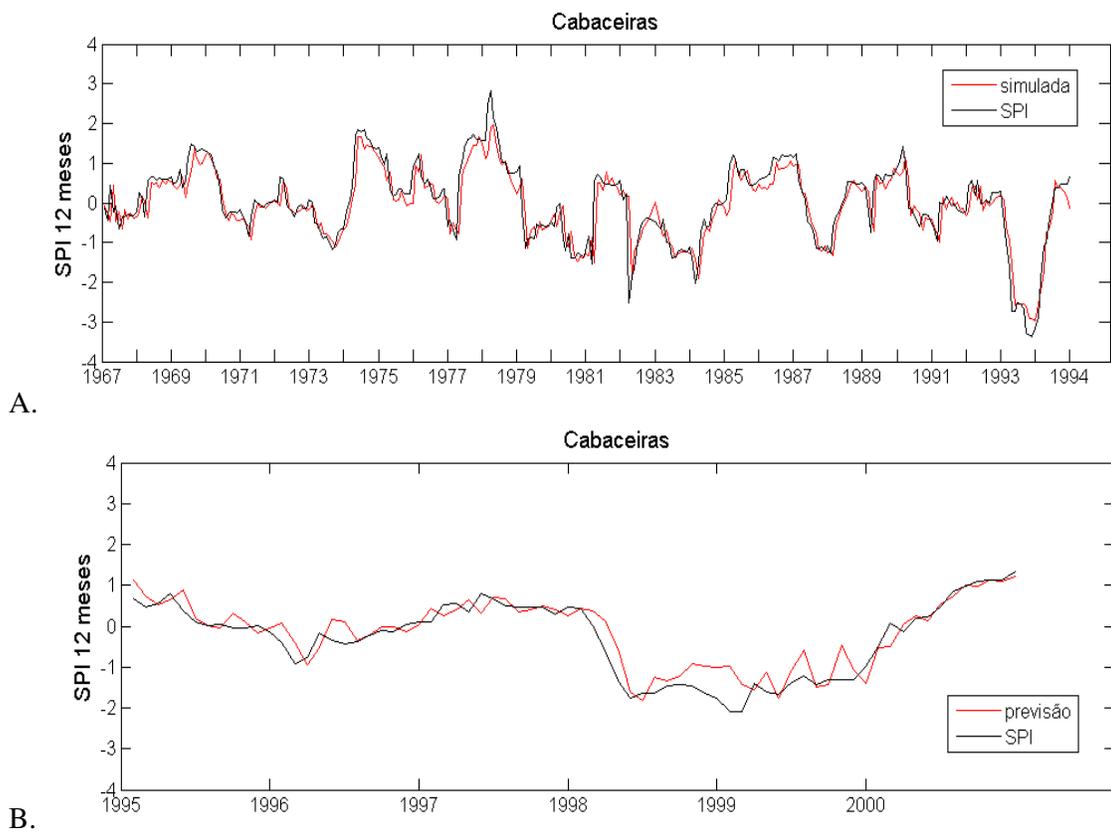


Figura 17. Ajuste da rede para Cabaceiras, nas etapas de simulação (A) e previsão (B)

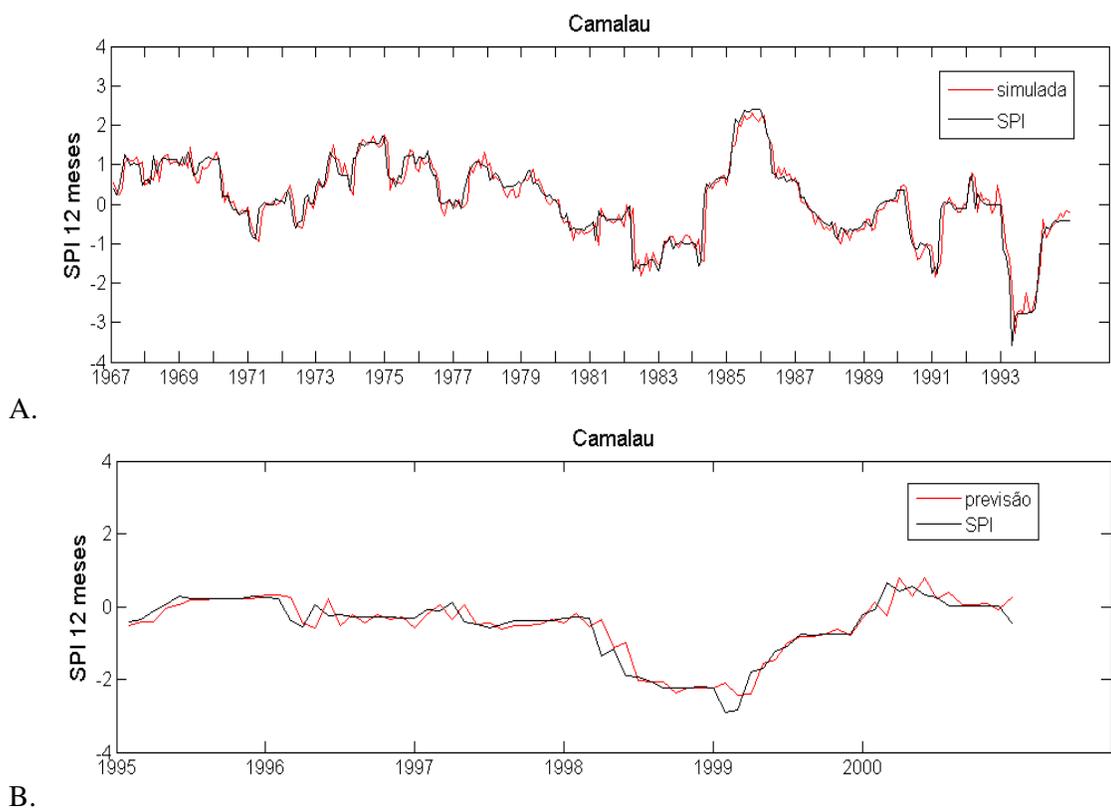


Figura 18. Ajuste da rede para Camalau, nas etapas de simulação (A) e previsão (B)

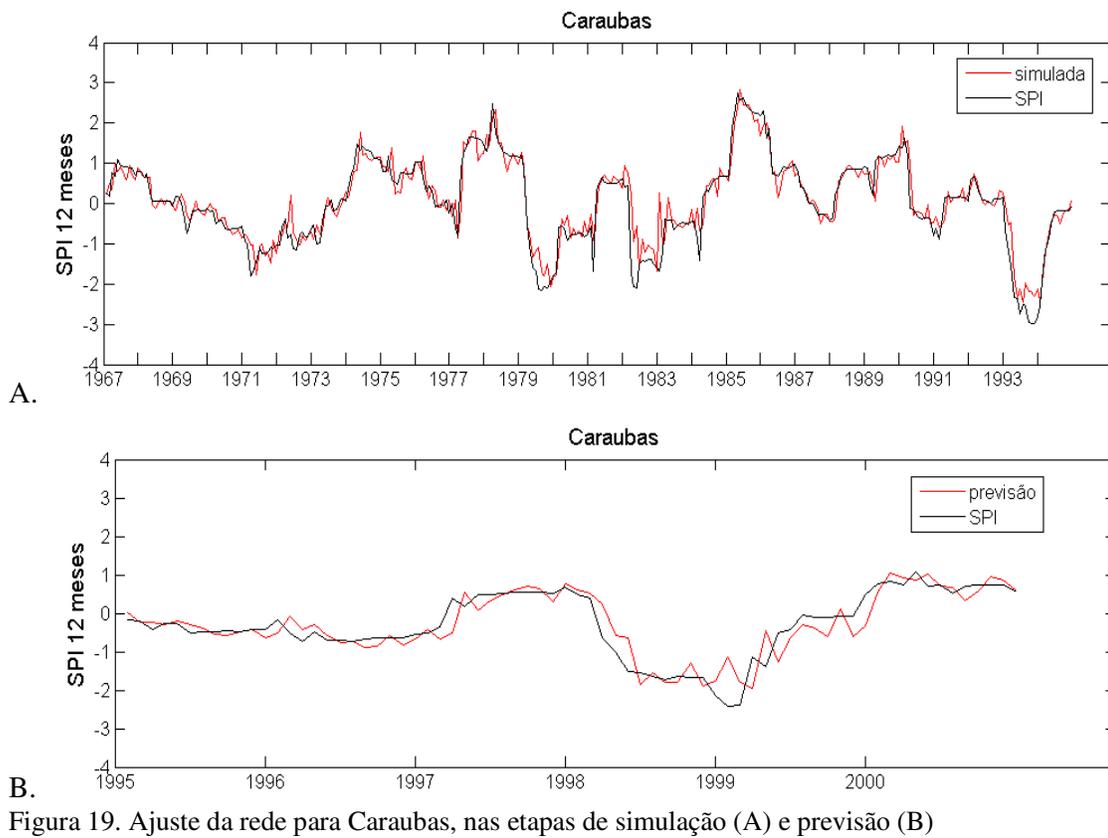


Figura 19. Ajuste da rede para Caraubas, nas etapas de simulação (A) e previsão (B)

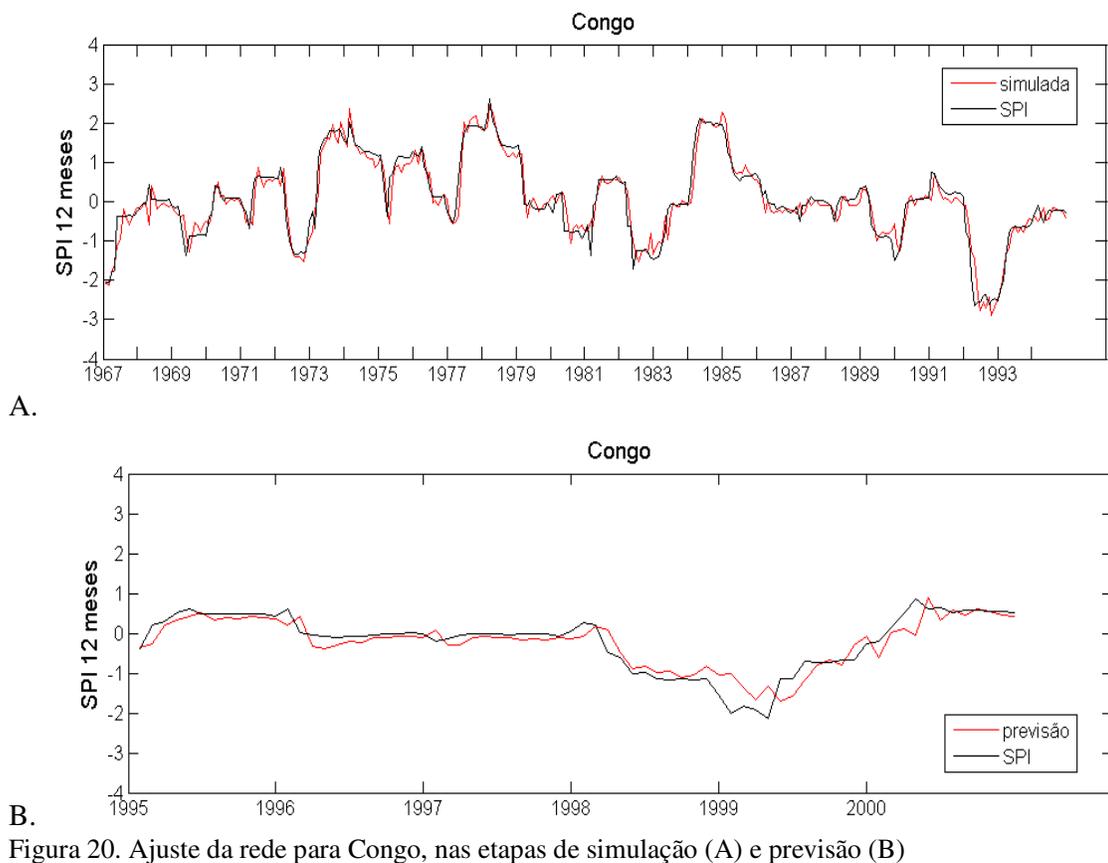


Figura 20. Ajuste da rede para Congo, nas etapas de simulação (A) e previsão (B)

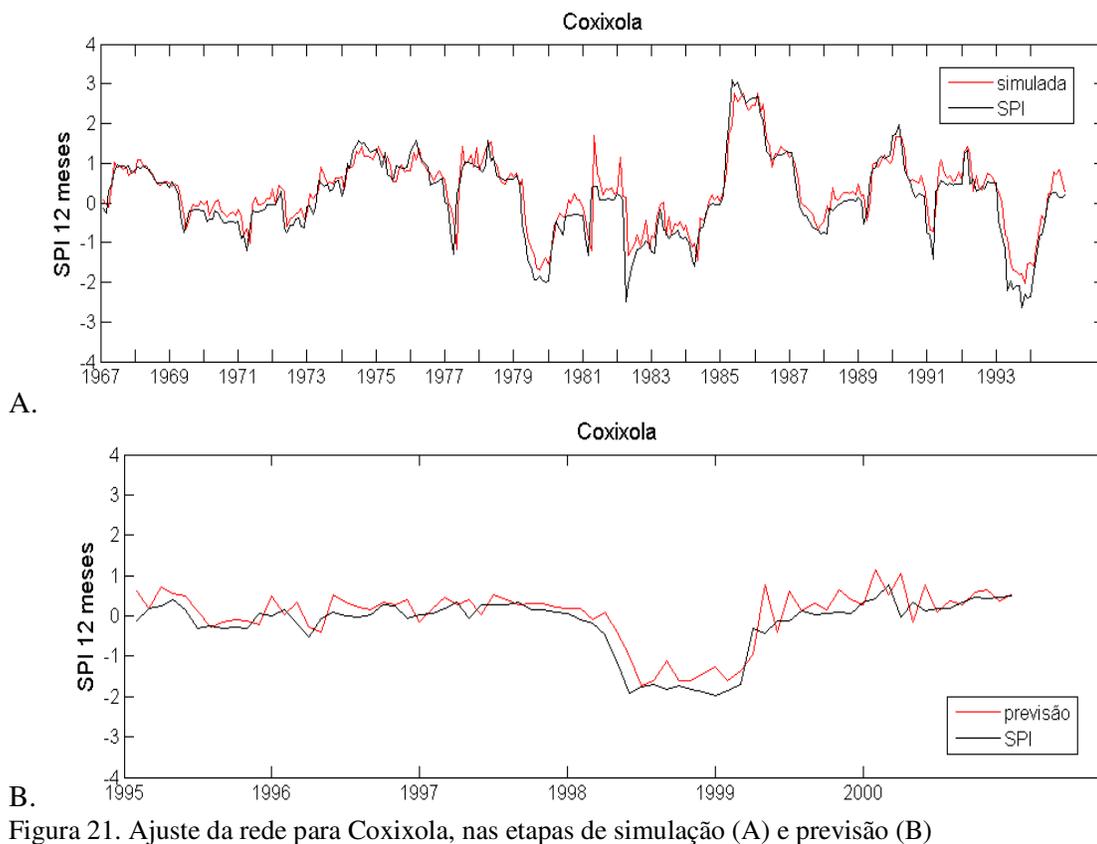


Figura 21. Ajuste da rede para Coxixola, nas etapas de simulação (A) e previsão (B)

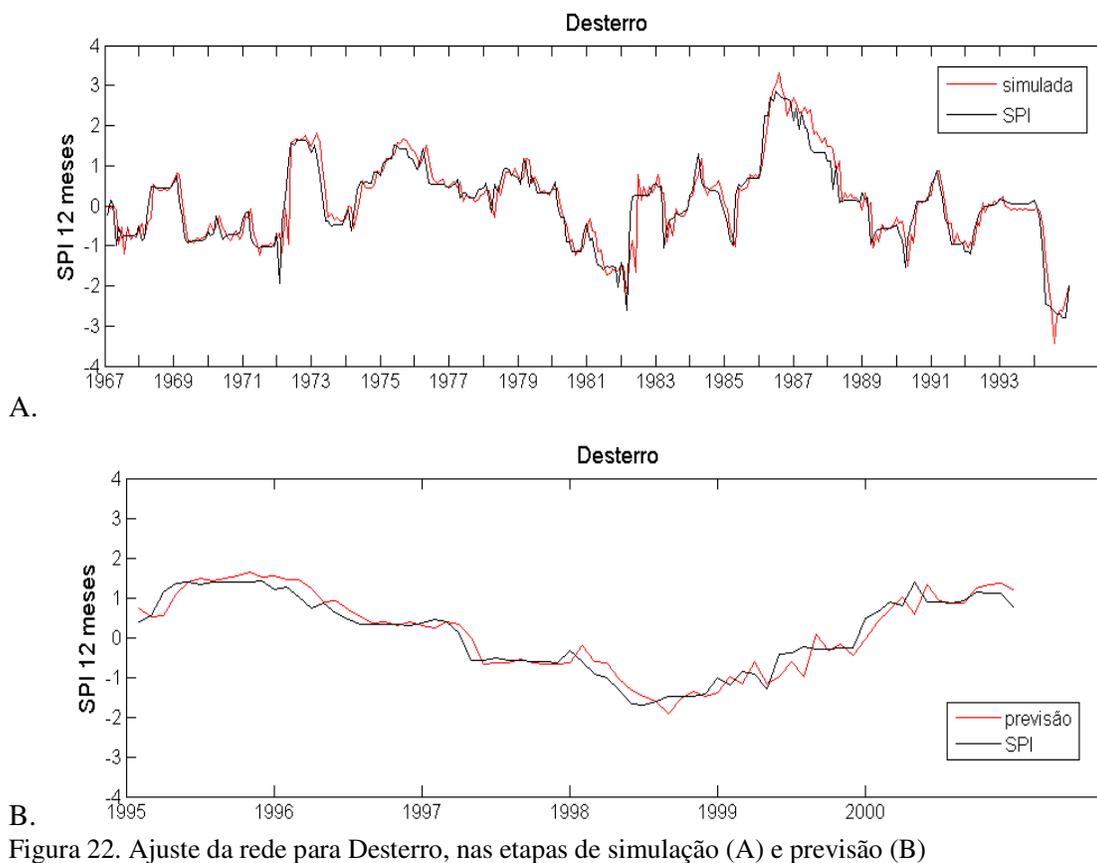


Figura 22. Ajuste da rede para Desterro, nas etapas de simulação (A) e previsão (B)

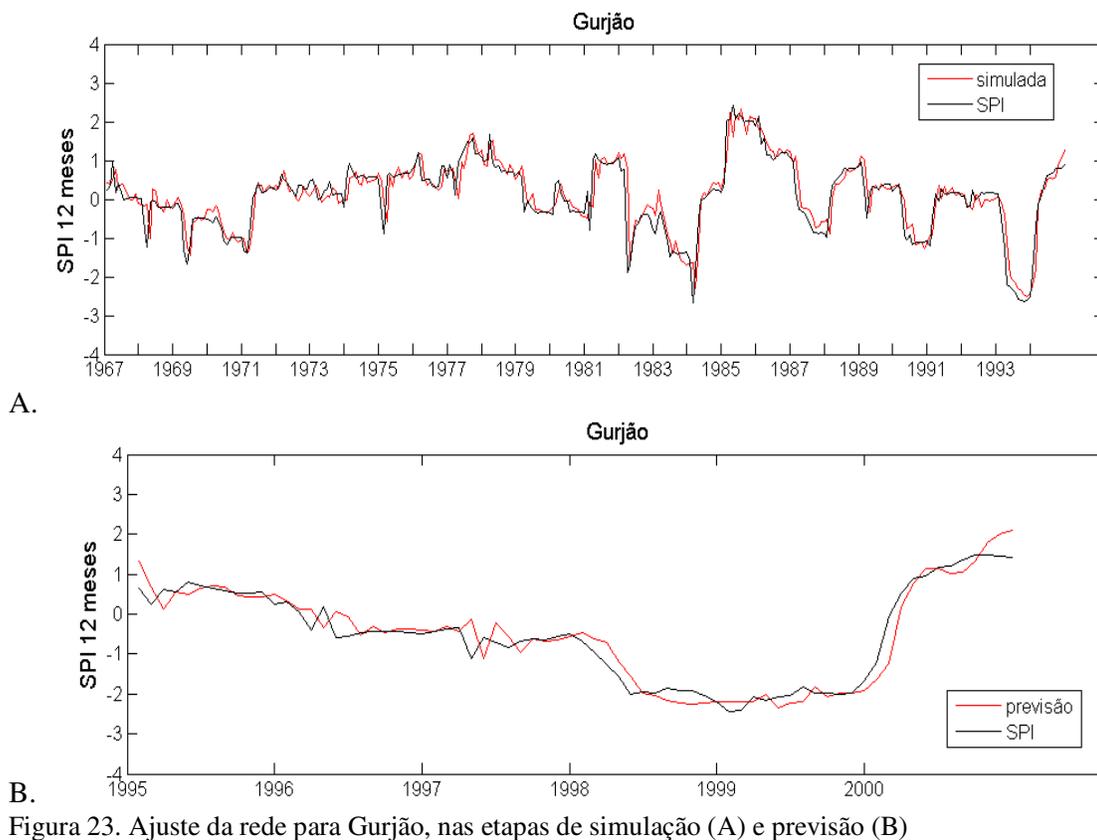


Figura 23. Ajuste da rede para Gurjão, nas etapas de simulação (A) e previsão (B)

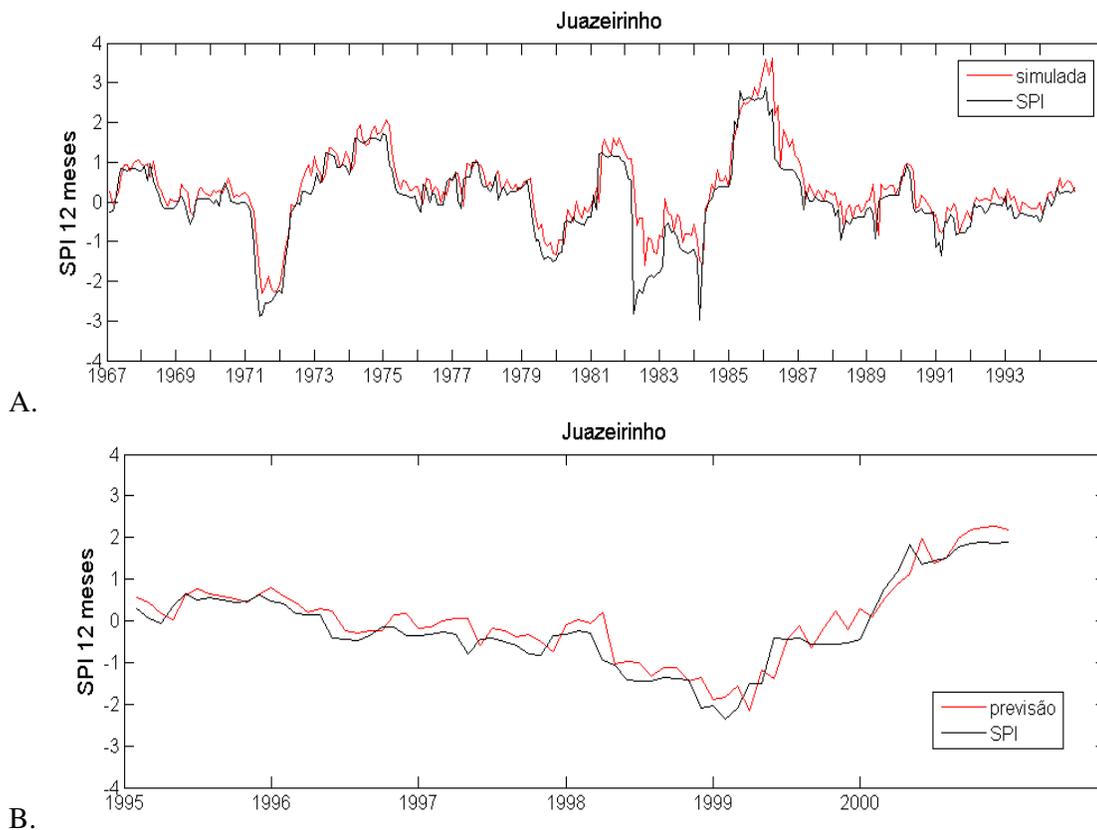


Figura 24. Ajuste da rede para Juazeirinho, nas etapas de simulação (A) e previsão (B)

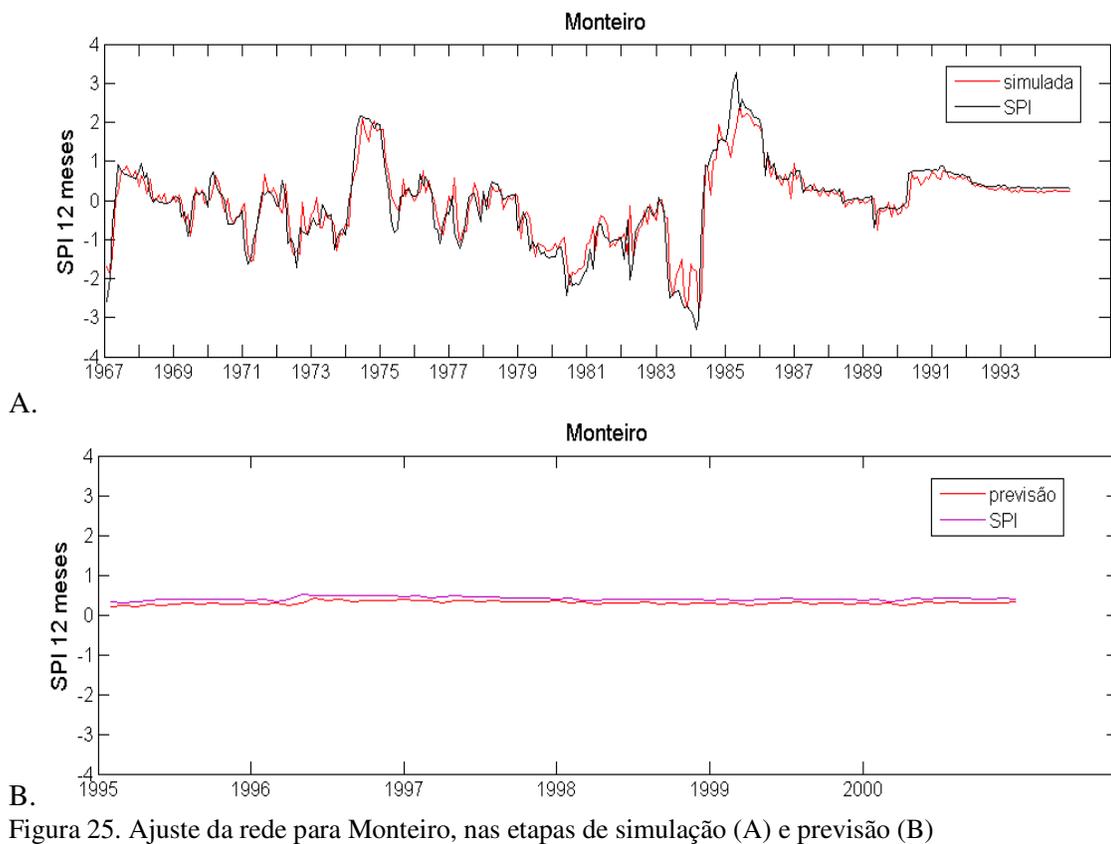


Figura 25. Ajuste da rede para Monteiro, nas etapas de simulação (A) e previsão (B)

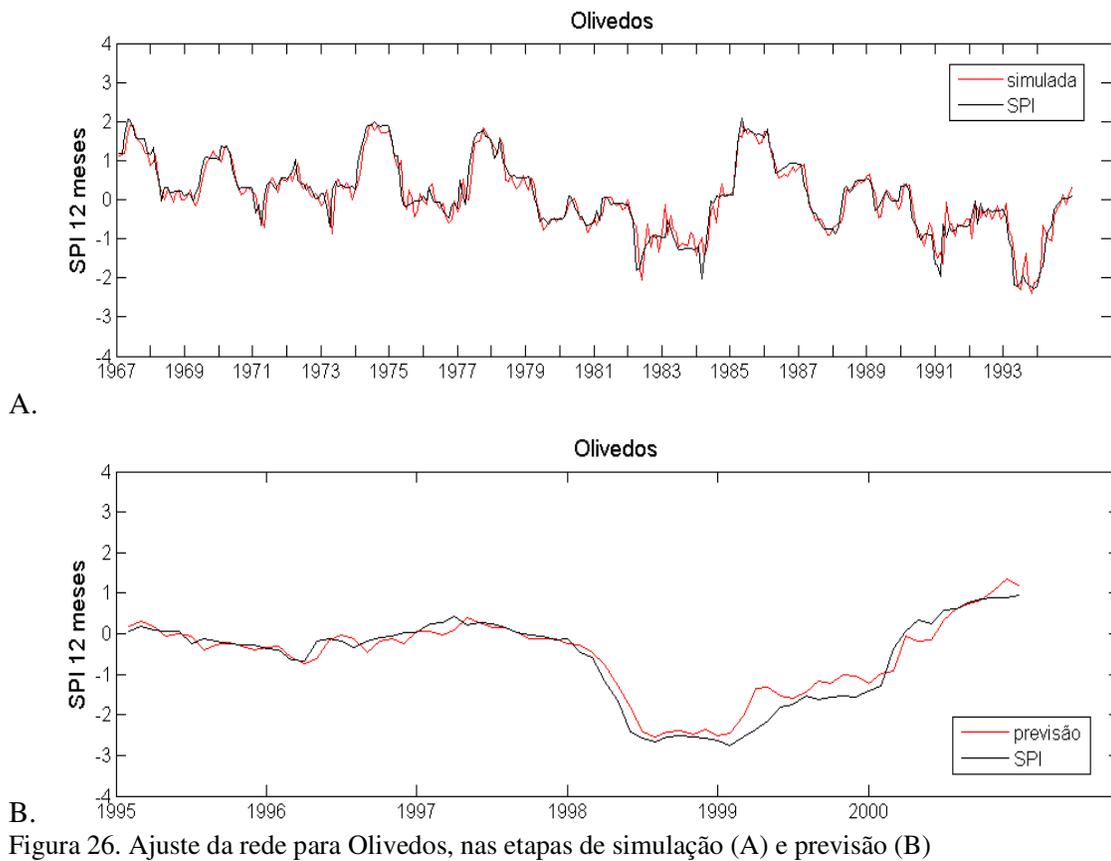
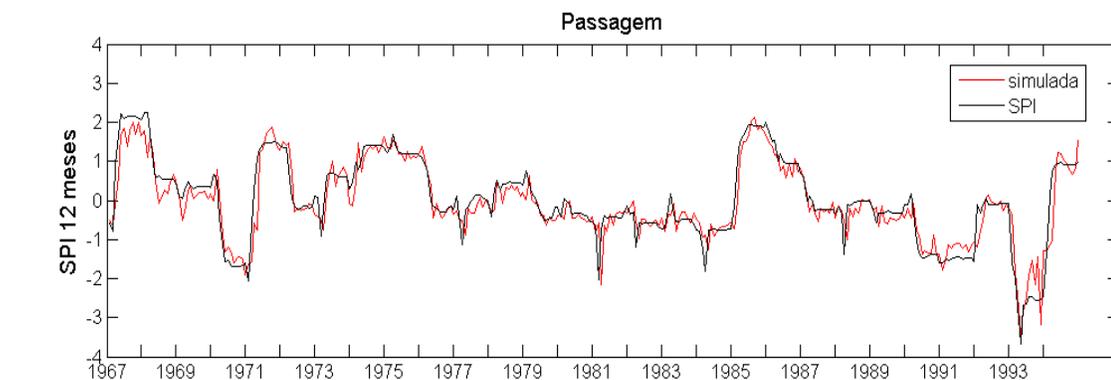
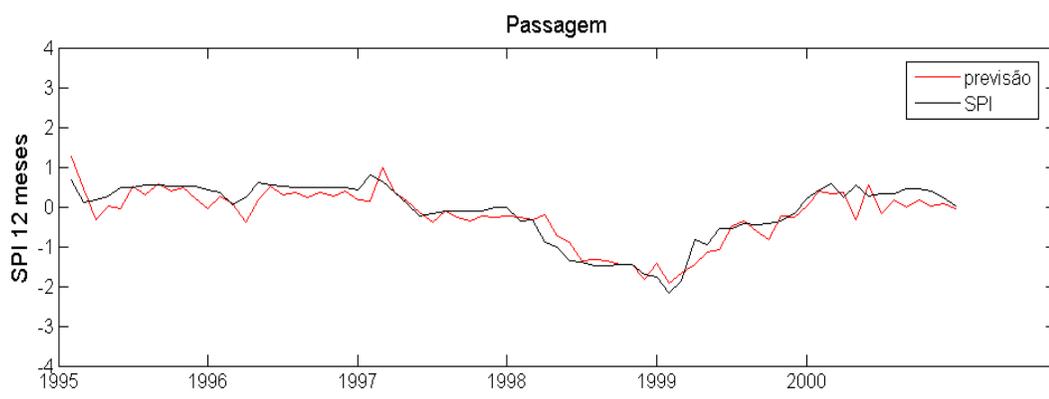


Figura 26. Ajuste da rede para Olivedos, nas etapas de simulação (A) e previsão (B)

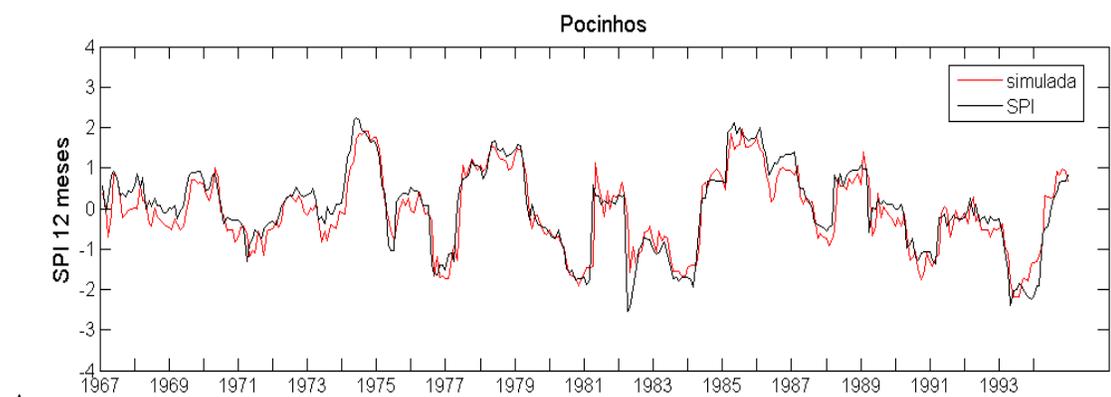


A.

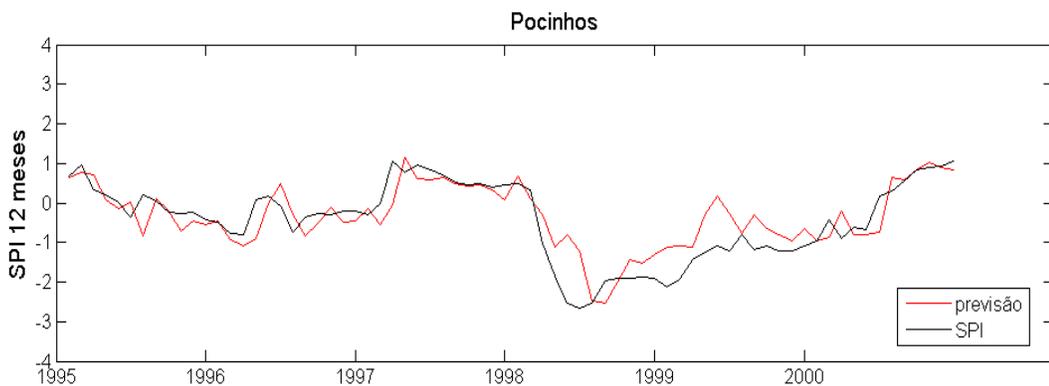


B.

Figura 27. Ajuste da rede para Passagem, nas etapas de simulação (A) e previsão (B)



A.



B.

Figura 28. Ajuste da rede para Pocinhos, nas etapas de simulação (A) e previsão (B)

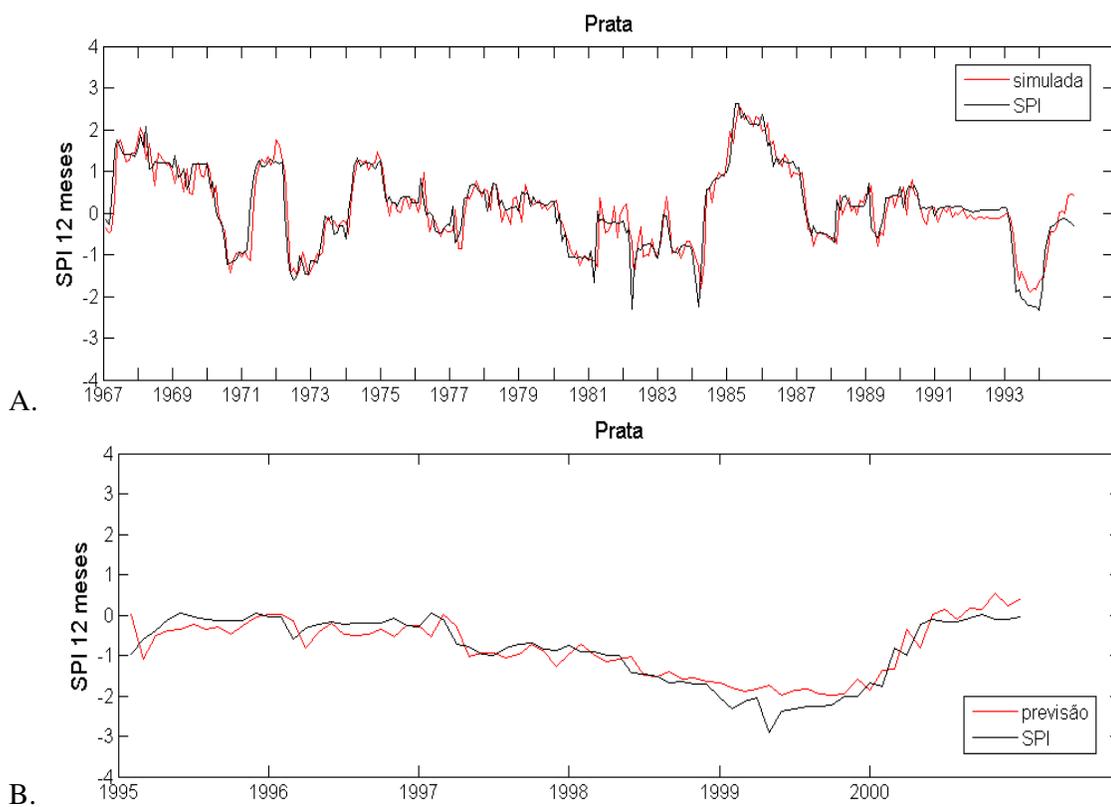


Figura 29. Ajuste da rede para Prata, nas etapas de simulação (A) e previsão (B)

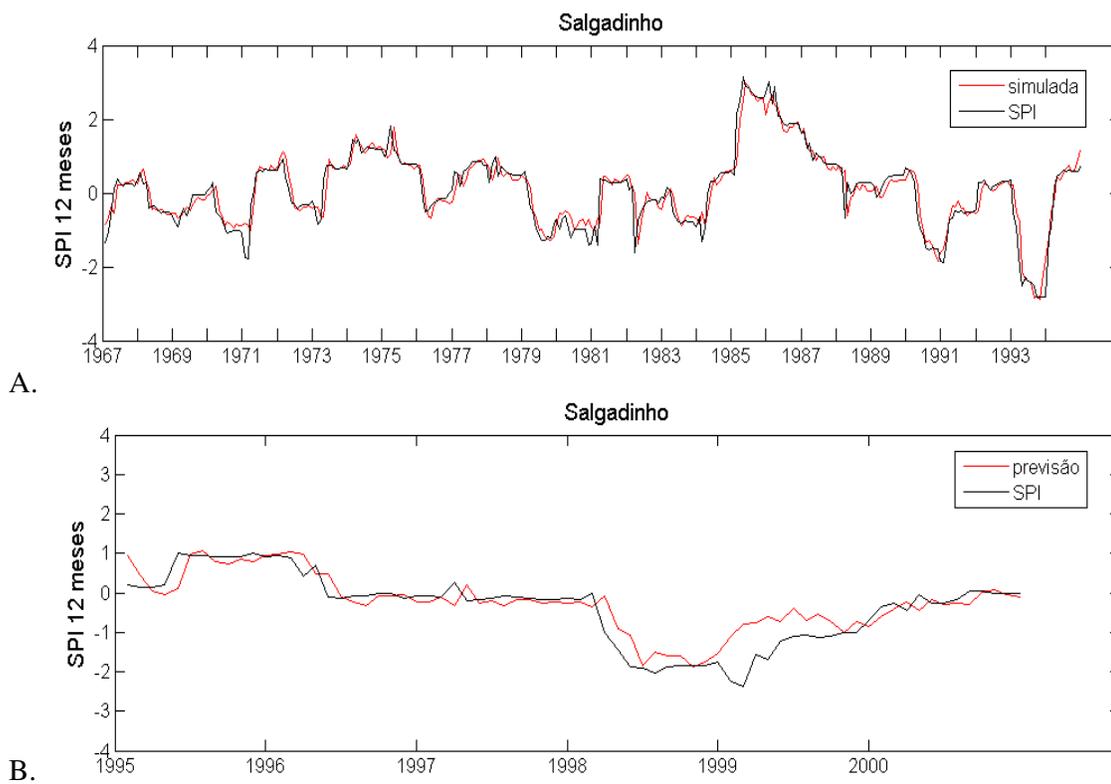
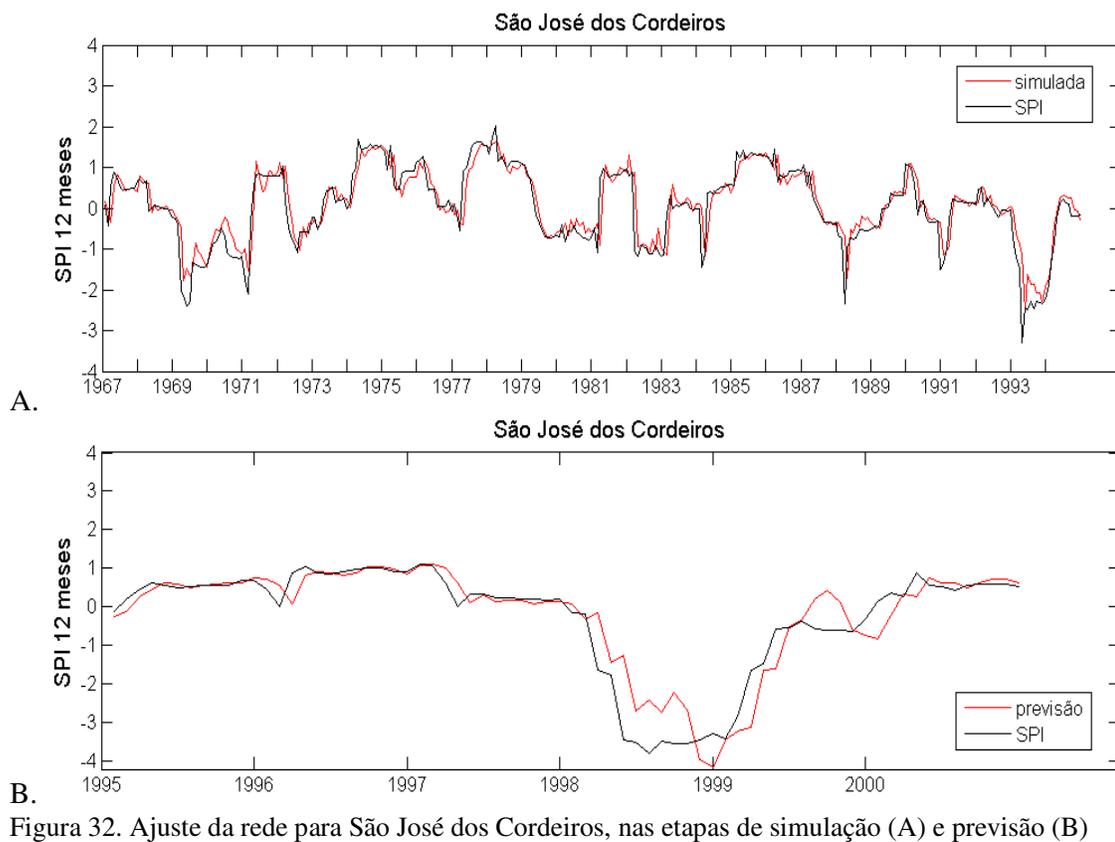
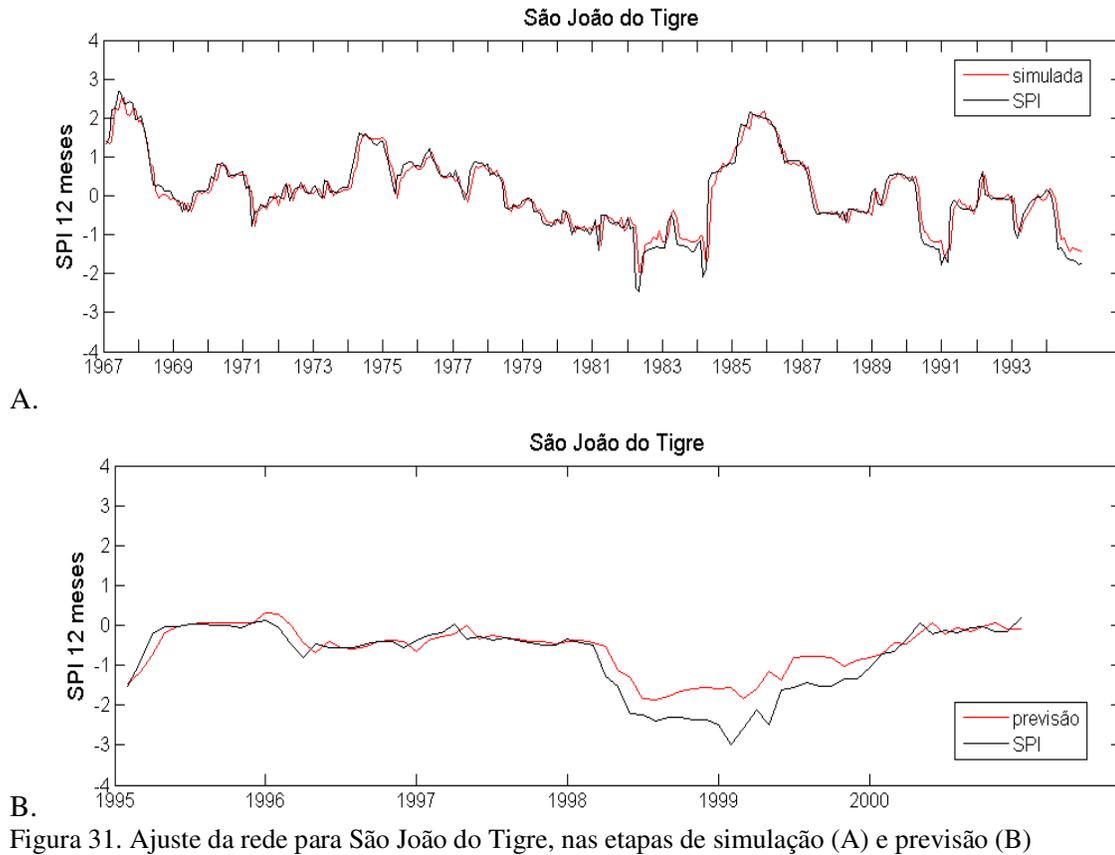


Figura 30. Ajuste da rede para Salgadinho, nas etapas de simulação (A) e previsão (B)



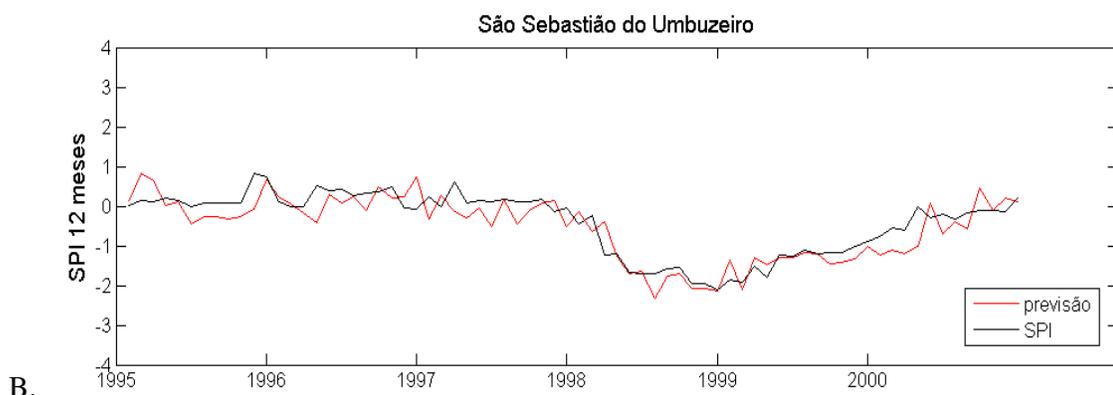
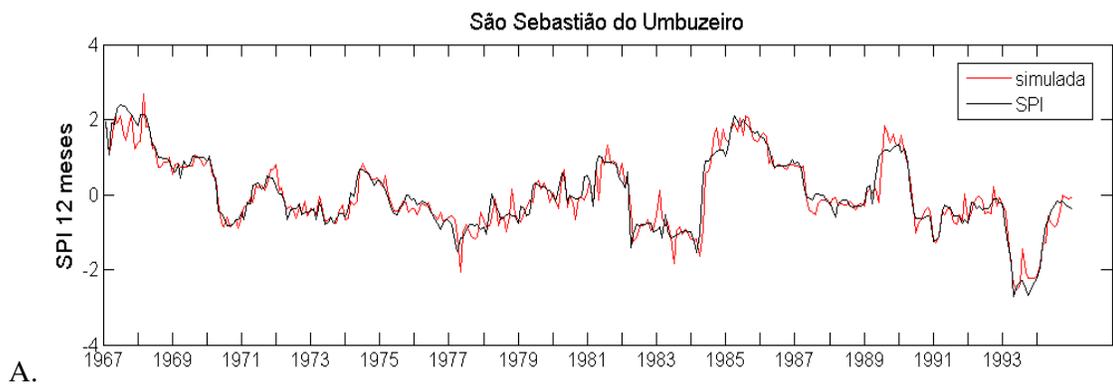


Figura 33. Ajuste da rede para São Sebastião do Umbuzeiro, nas etapas de simulação (A) e previsão (B)

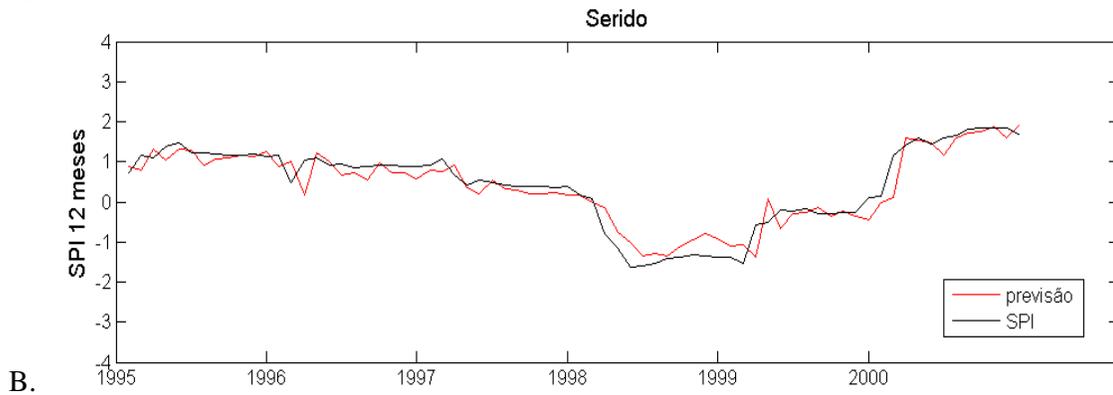
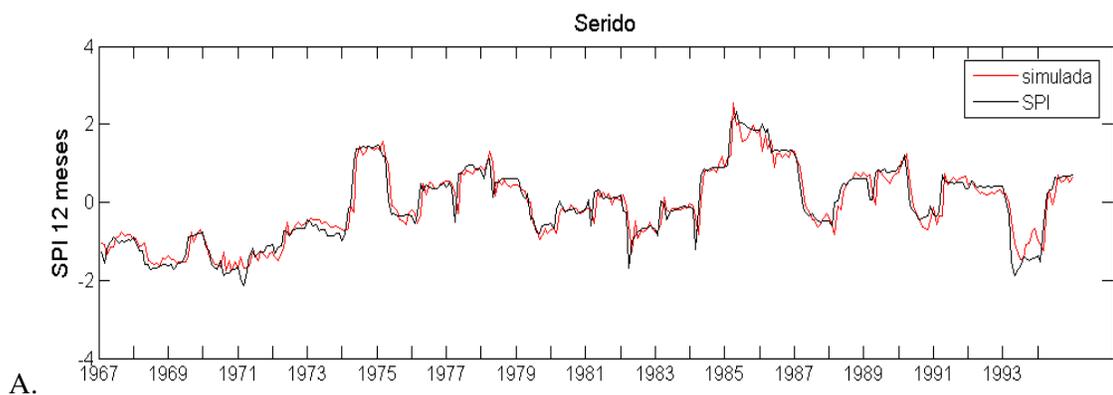
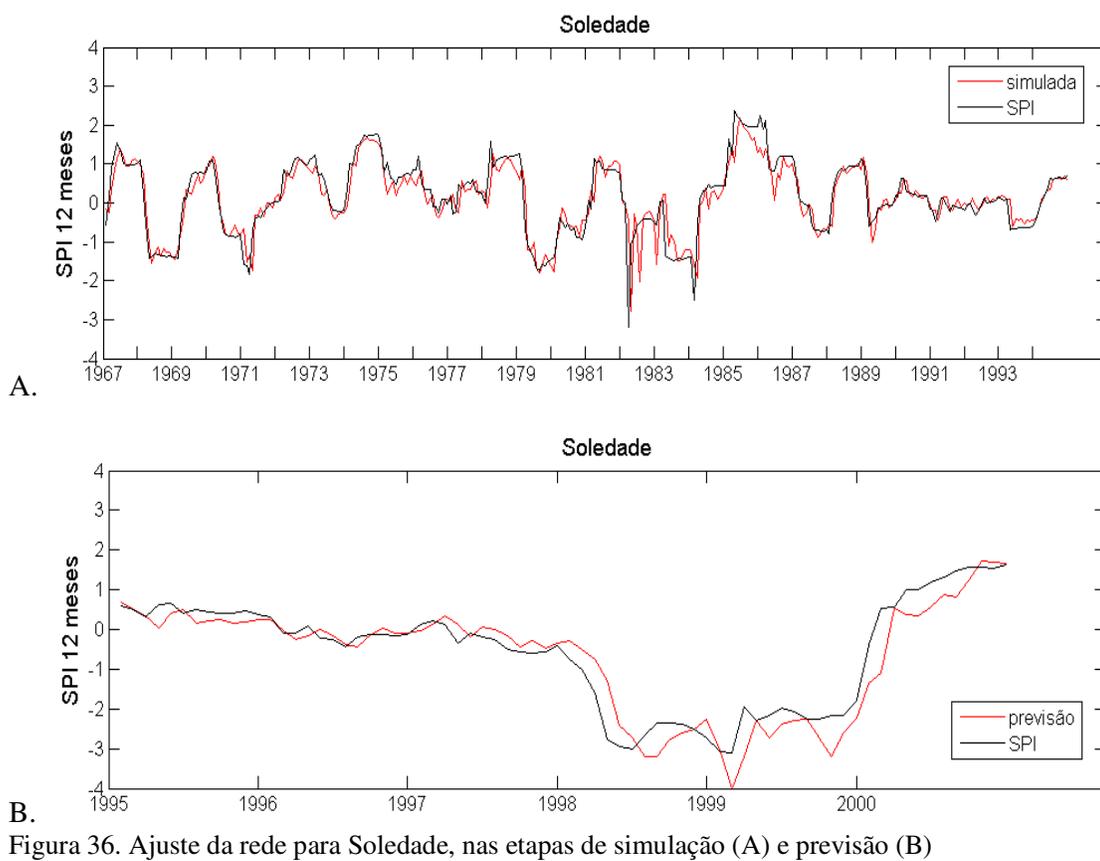
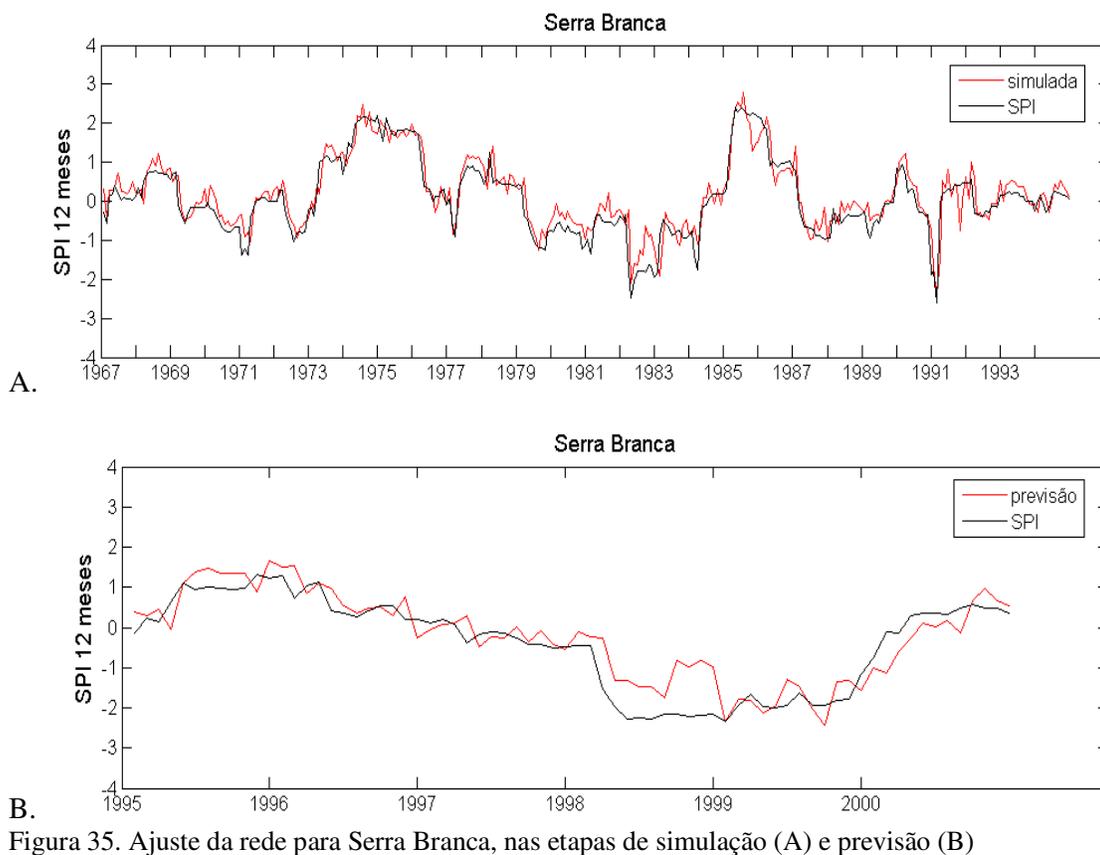


Figura 34. Ajuste da rede para Seridó, nas etapas de simulação (A) e previsão (B)



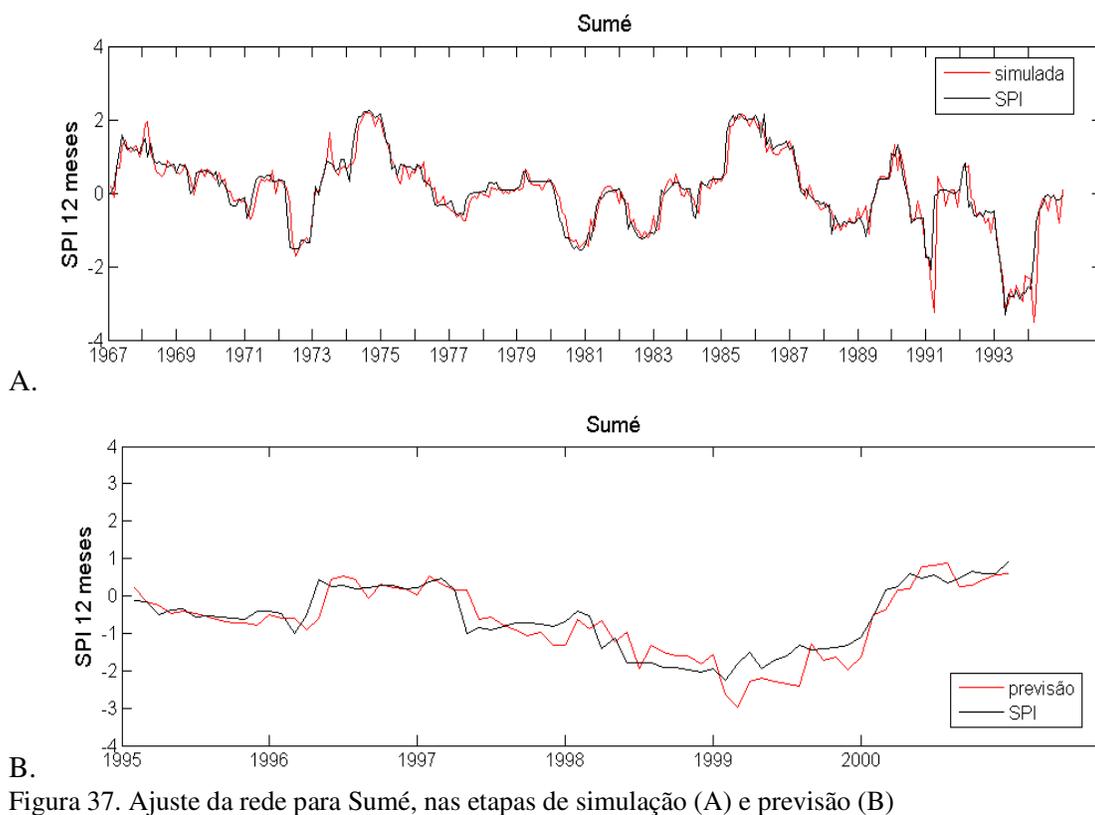


Figura 37. Ajuste da rede para Sumé, nas etapas de simulação (A) e previsão (B)

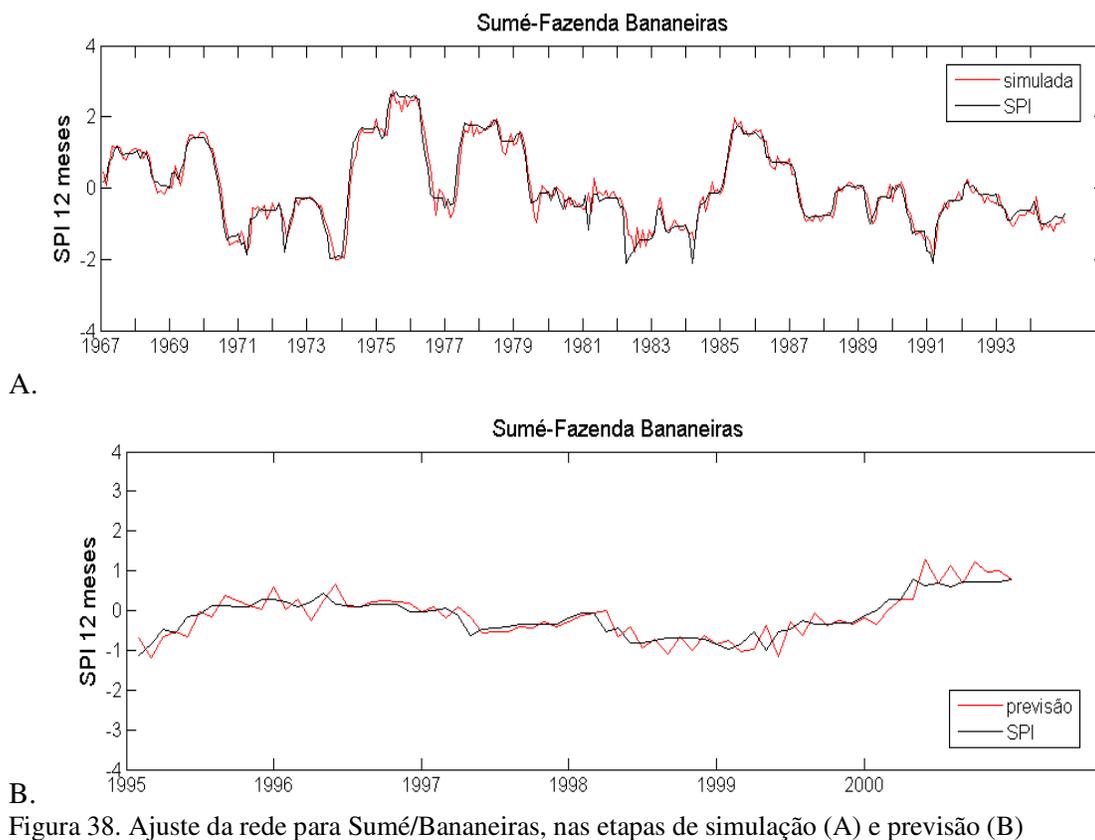


Figura 38. Ajuste da rede para Sumé/Bananeiras, nas etapas de simulação (A) e previsão (B)

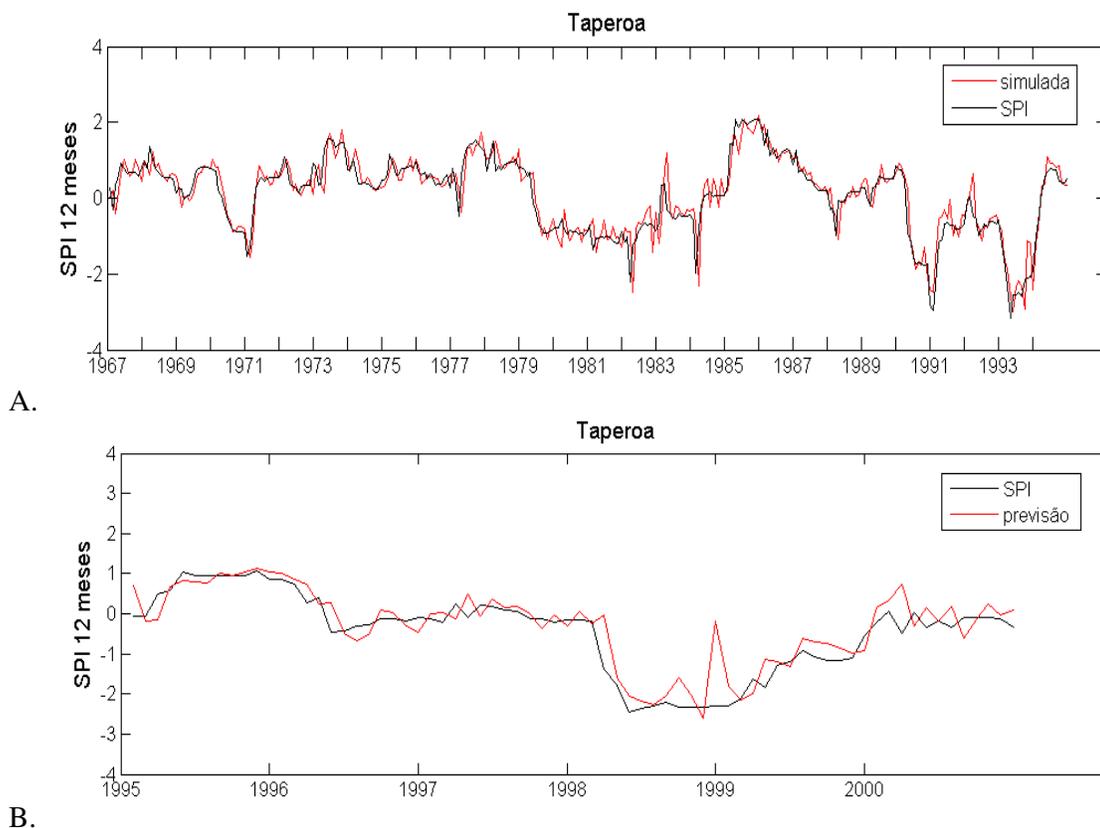


Figura 39. Ajuste da rede para Taperoá, nas etapas de simulação (A) e previsão (B)

## 5.2 PREVISÕES PARA DOIS, QUATRO E SEIS MESES

Adicionalmente, foram escolhidos dois postos pluviométricos para se efetuar as previsões de dois, quatro e seis meses. Um deles situado em uma sub-região com menor precipitação (Soledade) e o outro em outra sub-região com maior precipitação (Camalaú). A Figura 40 mostra a performance da rede em relação a variação do erro em cada fase para a estação de Soledade. As Figuras 41, 42 e 43 exibem os gráficos das regressões para cada uma das fases (treinamento, validação, teste e regressão) do processo de previsão para dois, quatro e seis meses, respectivamente, na estação de Soledade,

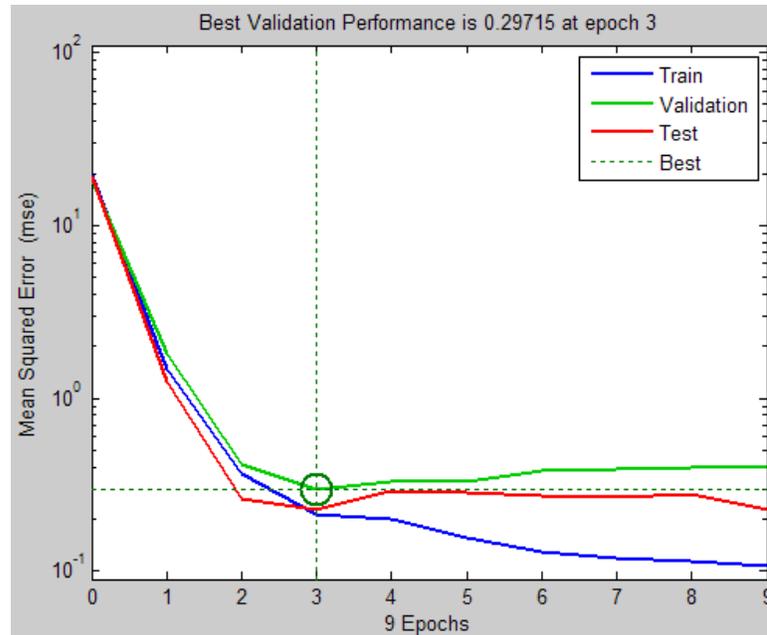


Figura 40. Variação do erro com o número de épocas na previsão de 2 meses para a estação de Soledade

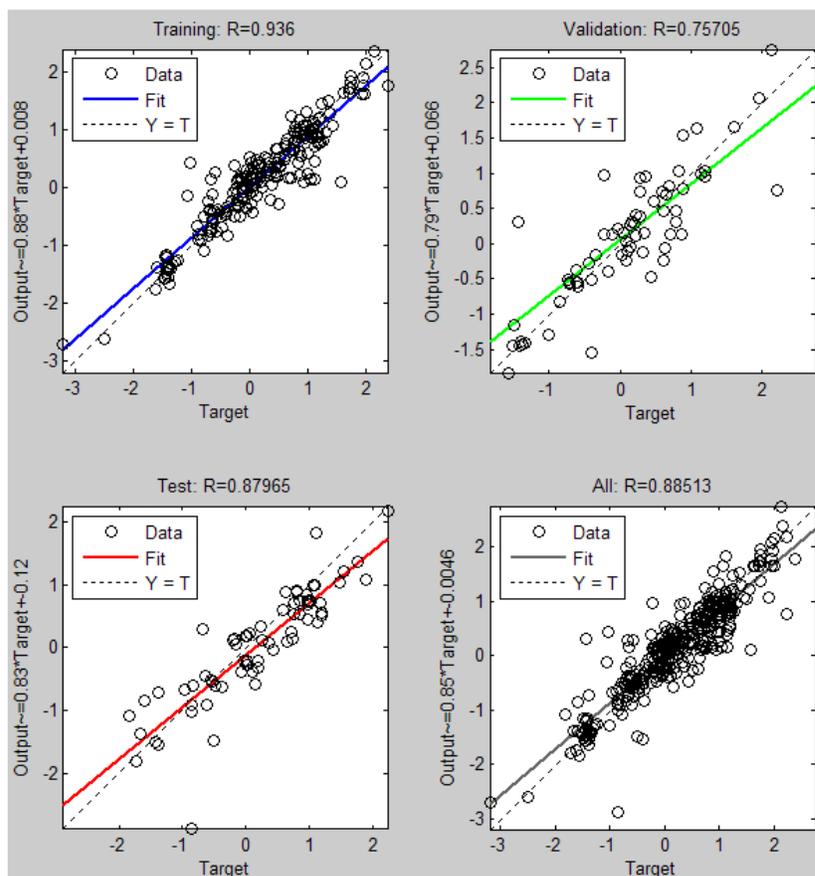


Figura 41. Curvas de regressões para a previsão de dois meses em Soledade

Em todos os casos (Figuras 41, 42 e 43) a rede encontrou maior dificuldade no ajuste dos dados para previsões mais longas. Os melhores valores de regressão foram encontrados para previsão de um mês (Tabela 10), mas à medida que se aumentou a escala temporal, as previsões pioraram significativamente, conforme os valores expostos nas Tabelas 11 e 12. Como visto nas tabelas supracitadas, os menores valores de regressão foram para o horizonte de 6 meses. A qualidade das previsões para dois, quatro e seis meses pode ser vista nas Figuras 44 e 45 para os postos de Soledade e Camalaú, respectivamente. Esses resultados corroboram a metodologia do trabalho: em previsões de longo prazo há redução na eficácia da rede.

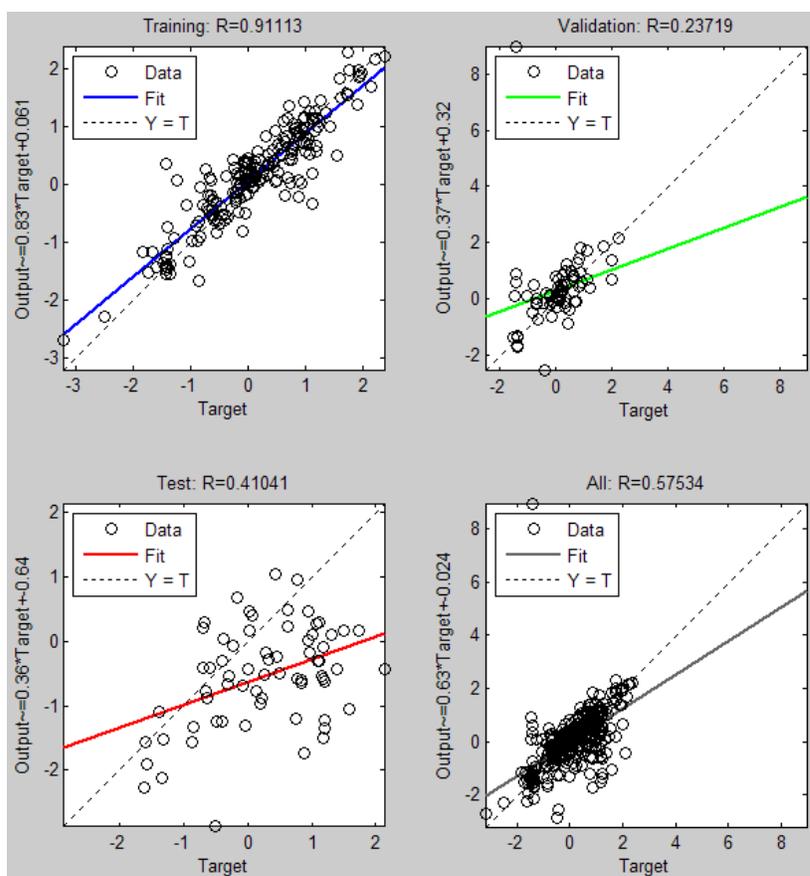


Figura 42. Curvas de regressões para a previsão de quatro meses em Soledade

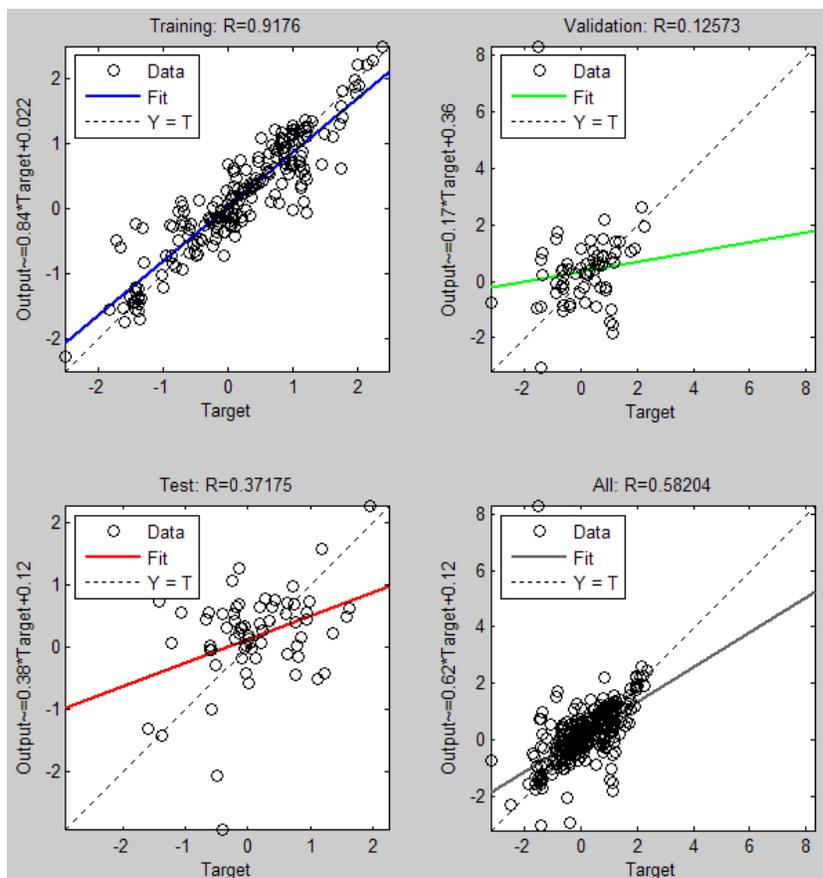


Figura 43. Curvas de regressões para a previsão de seis meses em Soledade

As Tabelas 11 e 12 para Soledade e Camalaú, respectivamente, resumem a evolução da rede para previsões de dois, quatro e seis meses. Embora tenha sido utilizado o algoritmo de retropropagação, é de se esperar, de modo geral, que aumentando o tempo a ser previsto ocorra também aumento no erro de previsão. Os valores da previsão para dois meses são razoáveis, acima disso há progressiva degeneração dos valores previstos.

Note que os valores de regressão durante a fase de treinamento são sempre melhores do que os das fases seguintes, em qualquer escala temporal. Isso demonstra que a rede não encontra problemas para assimilar os dados fornecidos, ajusta-os sempre da melhor forma possível. Ao iniciar o processo de validação, os valores dos ajustes são reduzidos. Isso sugere que a rede precisa de melhorias no processo aprendizagem. Uma das formas de melhorar o processo de aprendizagem seria aumentar a quantidade de dados de entrada da rede e/ou modificar a forma como os dados são apresentados à rede

Tabela 11. Teste da rede para previsões de dois, quatro e seis meses para a estação de Soledade

<b>Soledade</b>	<b>R</b>	<b>R</b>	<b>R</b>	<b>R</b>	<b>Performance</b>	<b>Melhor</b>
	<b>treino</b>	<b>validação</b>	<b>teste</b>	<b>todos</b>	<b>mse</b>	<b>validação</b>
Previsão 2 meses	0.936	0.757	0.879	0.885	0.214	0.297
Previsão 4 meses	0.898	0.645	0.481	0.745	0.303	0.328
Previsão 6 meses	0.895	0.240	0.371	0.582	0.398	1.190

Tabela 12. Teste da rede para previsões de dois, quatro e seis meses para a estação de Camalaú

<b>Camalau</b>	<b>R</b>	<b>R</b>	<b>R</b>	<b>R</b>	<b>Performance</b>	<b>Melhor</b>
	<b>treino</b>	<b>validação</b>	<b>teste</b>	<b>todos</b>	<b>mse</b>	<b>validação</b>
Previsão 2 meses	0.957	0.631	0.902	0.877	0.258	0.271
Previsão 4 meses	0.913	0.602	0.804	0.816	0.275	0.494
Previsão 6 meses	0.911	0.506	0.581	0.747	0.360	0.779

Na análise das Figuras 44 e 45, é nítida a redução no ajuste da série prevista para a série de *SPI* esperada, de forma que os valores apresentados nas Tabelas 11 e 12 se refletem sobre a série prevista. As séries das previsões para dois meses nas duas estações ainda possuem boa eficácia e conseguem acompanhar bem os valores do índice de precipitação. As séries das previsões para quatro e seis meses já mostram maior discrepância para as séries esperadas, e não conseguem acompanhar um padrão.

Entre Soledade e Camalaú, as previsões nas três escalas temporais apresentaram um comportamento um pouco melhor para Camalaú, que é uma estação localizada na área da bacia com maiores valores médios anuais de precipitação. Não é possível afirmar nada acerca da evolução da rede ser influenciada pela climatologia, haja vista que a previsão para um mês foi considerada muito boa em ambos os postos.

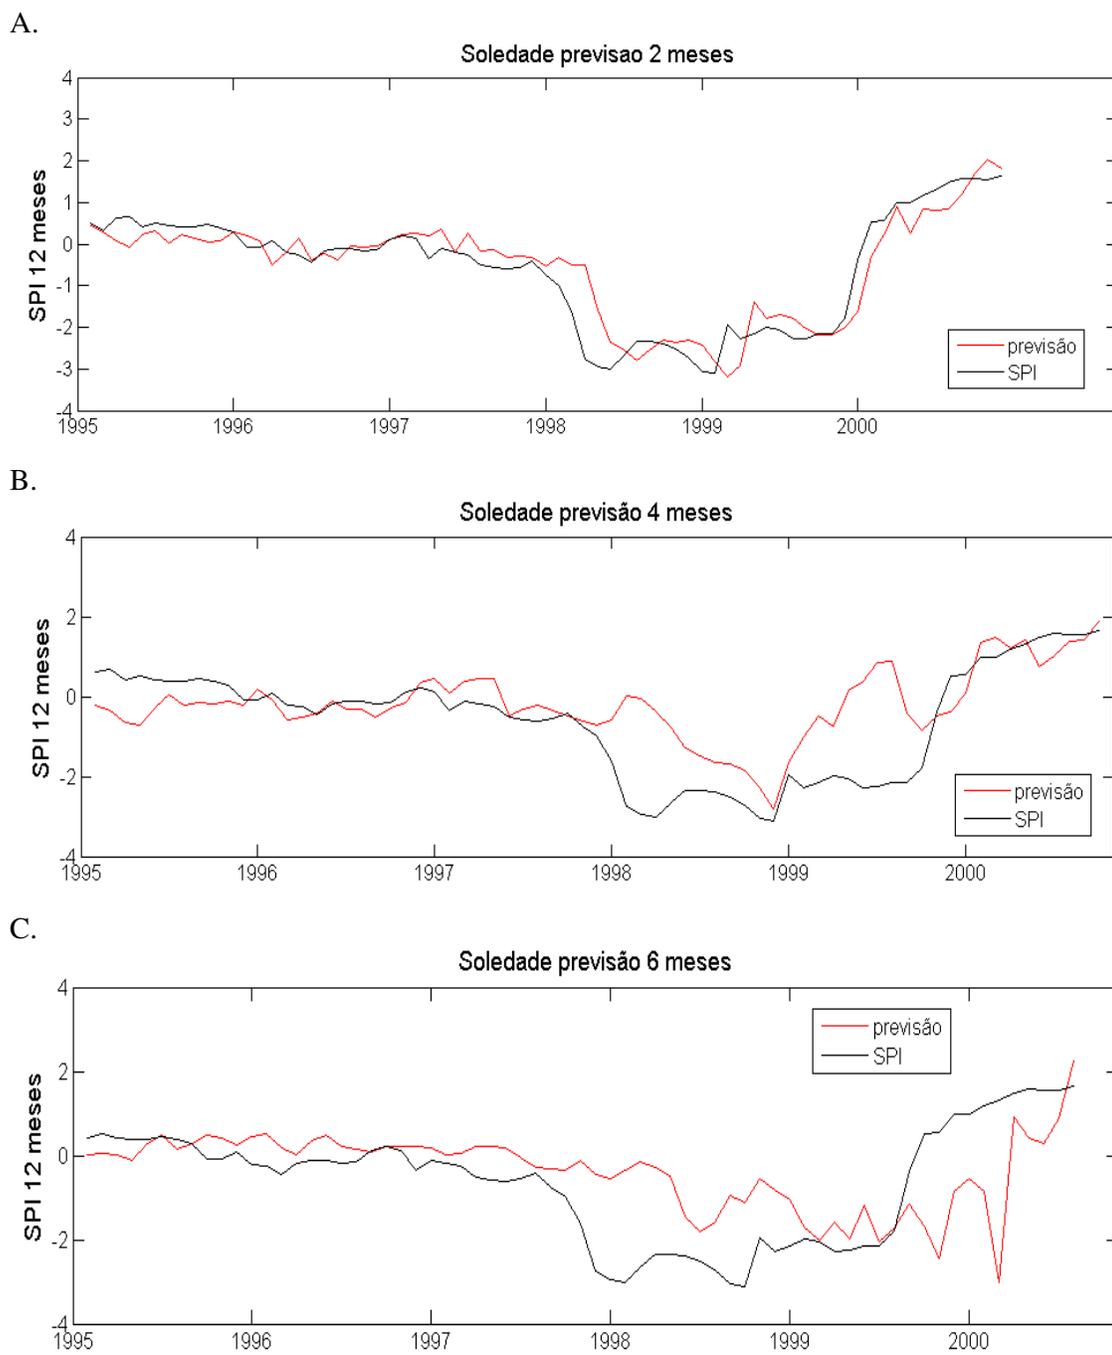
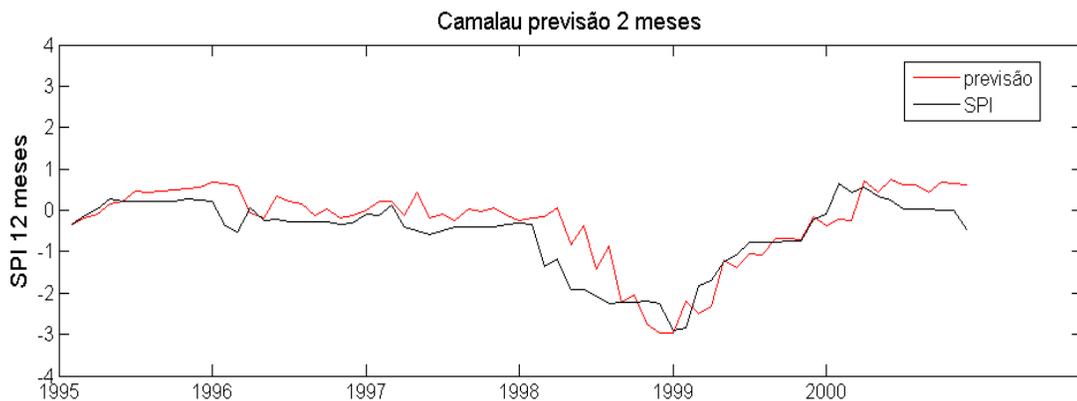
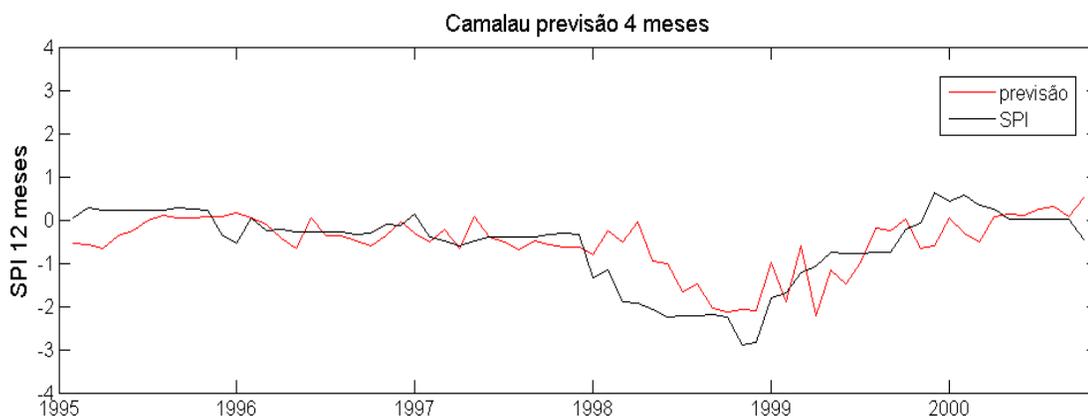


Figura 44. Ajuste da rede para previsões de *SPI* em Soledade: (A) dois meses, (B) quatro meses e (C) seis meses

A.



B.



C.

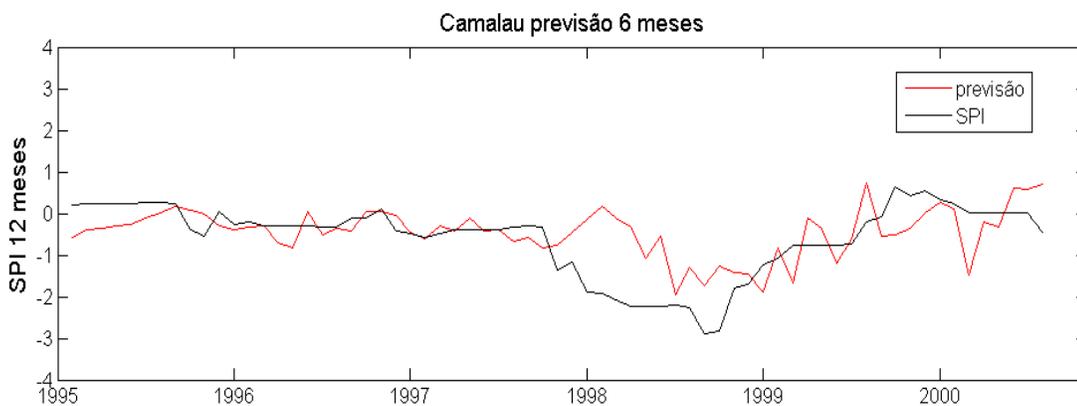


Figura 45. Ajuste da rede para previsões de *SPI* em Camalau: (A) dois meses, (B) quatro meses e (C) seis meses

## 6. CONCLUSÕES E SUGESTÕES

Durante a escolha dos tipos de arquitetura, a rede neural do tipo cascade-forward backpropagation também apresentou bom desempenho no processo de escolha, é possível que ela seja uma boa alternativa para previsão de séries *SPI*, mas é necessário verificar sua eficiência para outros postos pluviométricos.

O preenchimento de falhas dos dados observados pelo valor médio altera o comportamento das séries temporais e afeta os resultados da previsão. Esse fato foi comprovado pelo resultado do posto de Monteiro, único posto em que os dados faltosos foram preenchidos com o valor médio.

O uso das redes do tipo feed-forward apresentou bons resultados para a previsão de *SPI* em todos os postos, para o horizonte de dois meses. Na previsão para um mês, os valores médios de regressões foram iguais a 0,968 na fase de treinamento, 0,883 na validação e 0,915 na fase de teste. Já o MSE médio dos 26 postos foi de 0,0949, considerado um erro médio muito baixo.

A construção das redes mostrou-se extremamente capaz de prever seca, mas ainda é preciso que se aprimore o método, haja vista que sua eficiência é reduzida com o aumento do horizonte de previsão. As previsões para quatro e seis meses mostraram que é preciso melhorias nas técnicas de aprendizagens das redes.

É possível que a escolha de outros algoritmos de propagação e/ou número de neurônios diferentes, ou mesmo, outras funções de transferência possa melhorar a eficiência da previsão. Para melhorar a previsão de longo prazo são necessárias mudanças mais significativas como: nova arquitetura, mudanças na forma de entrada dos dados e criação ou modificação dos algoritmos de aprendizagem.

Em geral, o histórico evolutivo das RNAs mostra que o aprendizado de redes recursivas vem se aperfeiçoando e apresentando inúmeras alternativas para melhorar seu desempenho. Vale ressaltar que neste trabalho, apenas alguns modelos foram testados, e os dados apresentados em forma de índice. Assim, ainda há muito potencial a ser explorado pela aplicação das RNA, principalmente para previsão de prazos mais longos.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- ABRAMOWITZ, M.; STEGUN, I.A. **Handbook of Mathematical Formulas, Graphs, and Mathematical Tables**. Dover Publications, Inc., New York, USA. 1965.
- ACHARYA C.; MOHANTY S.; SUKLA L.B; MISRA V.N. Prediction of sulphur removal with *Acidithiobacillus* sp. using artificial neural networks. **Ecol. Model.** 190, 223–230, 2006.
- AESA – Agência Executiva de Gestão das Águas do Estado da Paraíba. Disponível em <<http://www.aesa.pb.gov.br>>. Acesso em 20. Jan. 2011.
- ALMEIDA, R.; BARBOSA, P.S.F. Previsão de secas hidrológicas com base em um modelo de redes neurais artificiais. In: **VII Simpósio de Recursos Hídricos do Nordeste**. São Luís, MA, 2004.
- ALVES, C. A. M. **Uma ferramenta de extração de regras de redes neurais**. Dissertação do curso de Mestrado em Engenharia Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.
- ANA – Agência Nacional de Águas. Disponível em <<http://hidroweb.ana.gov.br>>. Acesso em 10 Set. 2010.
- ANMALA, J.; ZHANG, B.; GOVINDARAJU, R. S. Comparison of ANNs and empirical approaches for predicting watershed runoff. **Journal of Water Resources Planning and Management**, Reston: ASCE, v. 126. n. 3, p. 156-166, May/June 2000.
- ANTONIC O.; KRIZAN J.; MARKI A.; BUKOVEC D. Spatio-temporal interpolation of climatic variables over large region of complex terrain using neural networks. **Ecol. Model.** 138, 255–263, 2001.
- ARAÚJO, L. E.; BECKER, C. T.; PONTES, A. L. Periodicidade da precipitação pluviométrica no estado da Paraíba. **XIII Congresso Brasileiro de Agrometeorologia**, Santa Maria, Rio Grande do Sul, 2003.
- ARAÚJO, P. C. **Aplicação do modelo GR4J à bacia hidrográfica do Rio Paraíba em Caraúbas**. Dissertação do Curso de Mestrado em Meteorologia, Universidade Federal de Campina Grande, Campina Grande, 2005.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. **Artificial neural networks in hydrology**. I. Preliminary concepts. *J. Hydrol. Eng.* 5 (2), 124–137, 2000a.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. **Artificial neural networks in hydrology**. II. Hydrologic applications. *J. Hydrol. Eng.* 5 (2), 115–123, 2000b.
- BAUGHMAN, D. R.; LIU, Y. A. **Neural Networks in Bioprocessing and Chemical Engineering**. Academy Press, 488p, 1995.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis, Forecasting and Control**. Prentice Hall, Englewood Cliffs, NJ, USA. 1994.
- BUSSAY, A.; SZINELL, C.; SZENTIMERY, T. **Investigation and Measurements of Droughts in Hungary**. Hungarian Meteorological Service, Budapest, Hungary, 1999.

- CALBETE, N. O.; SATYAMURTY, P. Vórtices Ciclônicos em Altos Níveis que Atuaram na Região Nordeste no Período de 1987 a 1995. **Climanálise Especial**. Comemoração dos 10 anos. MCT/INPE/CPTEC. 168-172, 1996.
- CYBENKO, G. Approximation by Superpositions of a Sigmoidal Function. *Math. Control Signals Systems*, 2, p. 303-314, 1989.
- DCA – Departamento de Ciências Atmosféricas, < <http://www.dca.ufcg.edu.br/tsm.htm>>, acesso em 01/02/2011.
- DEMUTH, H.; BEALE, M.; HAGAN, M. **Neural Network Toolbox 5**, User's Guide, MathWorks Inc. 2007.
- EDWARDS, D. C.; MCKEE, T. B. Characteristics of 20th century drought in the United States at multiple timescales. Colorado State University, Fort Collins. **Climatology Report** No. 97-2, CO, USA, 1997.
- ESPINOZA, E. S. **Distúrbios nos ventos de leste no Atlântico tropical**. Dissertação de Mestrado. São José dos Campos, INPE, 1996.
- FLETCHER, D.; GOSS, E. Forecasting with neural networks: an application using bankruptcy data. **Info. Manage.** 24, 159–167, 1993.
- FLOOD, I., KARTAM, N. Neural networks in civil engineering. I. Principles and understanding. **Journal of Computing in Civil Engineering**. ASCE 8 (2), 131–148, 1994a.
- FLOOD, I., KARTAM, N. Neural networks in civil engineering. I. Principles and understanding. **Journal of Computing in Civil Engineering**. ASCE 8 (2), 149–162, 1994b.
- GALVÍNCIO, J. D.; SOUSA, F. A. S.; SHIRINIVASAN, V. S. Balanço hídrico à superfície da bacia hidrográfica do Açude Epitácio Pessoa. **Revista Brasileira de Recursos Hídricos**. Rio Grande do Sul. v. 11, n. 03, p. 135-146. 2006.
- HAYES, M. J.; SVOBODA, M. D.; WILHITE, D. A.; VANYARKHO, O. V. Monitoring the 1996 drought using the standardized precipitation index. *Bull. Am. Meteorol. Soc.* 80, 429–438. 1999.
- HAYKAN, S. **Neural Networks - A comprehensive Foundation**. New York: Macmillan College Publishing Company, 1994.
- HEBB, D. O. **The Organisation of Behaviour**. John Wiley and Sons. 1949.
- HECHT-NIELSEN, R. **Neurocomputing**. Addison-Wesley, Menlo Park, CA, USA, 1990.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feed-forward networks are universal approximators. **Neural Network**. 2, 359–366, 1989.
- HUGHES, B.L.; SAUNDERS, M. A. A drought climatology for Europe. *Int. J. Climatol.* 22, 1571–1592, 2002.
- KOUSKY, V. E. **Frontal influences on northeast Brazil**. *Monthly Weather Review*, 107: 1140-1153. 1979.
- KOUSKY, V. E.; GAN M. A. **Upper tropospheric cyclones vórtices in the tropical south atlantic**. *Tellus*, 33: 538-551. 1981.

- KRÖSE, B. J. A.; SMARGT, P. van der. **An introduction to Neural Networks**. The University of Amsterdam, eighth edition, 1996.
- LANA, X.; SERRA, C.; BURGUENO, A. Patterns of monthly rainfall shortage and excess in terms of the standardized precipitation index. *Int. J. Climatol.* 21, 1669–1691, 2001.
- LIPPMANN, R. P. An introduction to computing with neural nets. *IEEE ASSP Mag.*, 4–22, 1987.
- LOKE, E. **Introduction to Artificial Neural Networks in Urban Hydrology**, MATECH, Institute of Environmental Science and Engineering, Technical University of Denmark, Lyngby pp. 1–47, 1995.
- LORRAI, M; SECHI, G. M. Neural nets for modelling rainfall-runoff, transformations, *Water Resources Manage.* N° 9, p. 299-313, 1995.
- MACHADO, F. W. **Modelagem Chuva-Vazão mensal utilizando redes neurais artificiais**, Dissertação de Mestrado em Engenharia em Recursos Hídricos e Ambiental, Universidade Federal do Paraná, 2005.
- MAIER, H. R.; DANDY, G. C. The use of artificial neural networks for the prediction of water quality parameters. *Water Resources Research.* 32 (4), 1013–1022, 1996.
- MCKEE, T. B.; DOESKEN, N. J.; KLIEST, J. The relationship of drought frequency and duration to time scales. In: **Proceedings of the Eighth Conference on Applied Climatology**, Anaheim, CA, January 17–22. American Meteorological Society, Boston, MA, USA, pp. 179–184, 1993.
- MCCULLOCH, W. S. AND PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biology*, 5:115-133, 1943.
- MEDEIROS, A. M. T. de. **Variabilidade Espaço-Temporal da Precipitação Pluvial Diária Sobre a Bacia Hidrográfica do Açude Epitácio Pessoa**. Dissertação de Mestrado em Meteorologia. Campina Grande, novembro, 2003.
- MELESSE, A. M.; HANLEY, R. Artificial Neural Network Application for Multi-Ecosystem Carbon Flux Simulation, *Ecological Modeling* 189, 305–314, 2005.
- MONTE, E. M. **Estudos de periodicidades: Séries temporais de chuva no Nordeste do Brasil**. 107 f. Tese (Mestrado em Meteorologia). Universidade Federal da Paraíba, Campina Grande, Paraíba, 1986.
- MORAIS, B. S.; LINS, R. O. C.; SILVA, G. B. L. Previsão de seca usando redes neurais artificiais, **IX Simpósio de Recursos Hídricos do Nordeste**, Salvador, Bahia, 2008.
- PASINI, A.; LORE, M.; AMELI, F. Neural network modelling for the analysis of forcings/temperatures relationships at different scales in the climate system. *Ecol. Model.* 191, 58–67, 2006.
- OBASI, G.O.P. WMO's role in the international decade for natural disaster reduction. *Bulletin. American Meteorological Society*, 75 (1), 655–1661, 1994.
- OLIVO, A. A.; SILVA, J. D. S.; VIJAYKUMAR, N. L. Previsão de cheias fluviais usando redes neurais artificiais. **VI Simpósio de Recursos Hídricos do Nordeste**. Maceió/AL, 2002.

- ROSENBLATT, F. **Principles of Neurodynamics**. Spartan Books, New York, 1962.
- RUMELHART, D.E., HILTON, G.E., WILLAMS, R.J. Learning representations by back-propagating errors. *Nature* 323, 533–536, 1986.
- SAHOO, G. B.; RAY, C.; WADE, H. F. Pesticide prediction in ground water in North Carolina domestic wells using artificial neural networks. **Ecol. Model.** 183, 29–46. 2005.
- SALVATORE, L. **Inferência do teor de enxofre em unidades de hidrotratamento de diesel baseada em modelagem heurística**, Dissertação de Mestrado. Escola de Química, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007.
- SANTOS, C. C.; FILHO, A. J. P. Modelagem hidrológica urbana por meio de redes neurais artificiais: uma aplicação para a bacia do rio Tamanduateí em São Paulo, SP. **Revista Brasileira de Meteorologia**, v. 18, n. 2, 149-159, 2003.
- SOUSA, W. S.; SOUSA, F. A. S. Rede Neural Artificial Aplicada à Previsão de Vazões Médias Mensais da Bacia Hidrográfica do Rio Piancó, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 2, p. 173-180, 2010.
- SHAMSELDIN, A. Y. Application of a neural network technique to rainfall-runoff modeling. **Journal of Hydrology** 199, 1997.
- STRANG, D. M. G. D. **Análise climatológica das normais pluviométricas do Nordeste do Brasil**. São José dos Campos, CTA – (IAC – M – 02/72), 29p, 1972.
- SZALAI, S.; SZINELL, C. **Comparison of two drought indices for drought monitoring in Hungary a case study**. In: Vogt, J.V. 2000.
- TANG, Z.; FISHWICK, P. A. **Feed-forward neural nets as models for time series forecasting**. *ORSA J. Comput.* 5 (4), 374–385, 1993.
- THOM, H.C.S., A note on gamma distribution. **Monthly Weather Review**. 86, 117–122. 1958.
- USDA. Major world crop areas and climatic pro.les, World Agricultural Outlook Board, US department of Agriculture, **Agricultural Handbook** No. 664, pp. 157–170. 1994.
- UVO, C. R. B. **A zona de convergência intertropical (ZCIT) e sua relação com a precipitação na região norte e nordeste brasileiro**. Dissertação de Mestrado em Meteorologia. INPE. São José dos Campos, 1989.
- VALENÇA, M. J. S. **Aplicando redes neurais: um guia completo**. Olinda, PE. Ed. Livro Rápido, 284p, 2005.
- WIDROW, B. **Generalization and information in networks of adaline neurons**. In Yovits, J. and Goldstein, editors, *Self-Organizing Systems*, Washington. Spartan Books, 1962.
- WONG, F. S. Time series forecasting using backpropagation neural networks. **Neurocomputing** 2, 147–159, 1991.
- ZHANG, B.L.; DONG, Z.Y. An adaptive neural-wavelet model for short term load forecasting. **Electric Power Syst. Res.** 59, 121–129, 2001.