

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS**

PROGRAMA DE PÓS-GRADUAÇÃO EM

METEOROLOGIA




TESE DE DOUTORADO

Roni Valter de Souza Guedes

**Análise e previsão de eventos críticos de precipitação
com base no SPI e em redes neurais artificiais para o
estado de Pernambuco**

Campina Grande, Março de 2016



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

**ANÁLISE E PREVISÃO DE EVENTOS CRÍTICOS DE PRECIPITAÇÃO COM
BASE NO SPI E EM REDES NEURAS ARTIFICIAIS PARA O ESTADO DE
PERNAMBUCO**

RONI VALTER DE SOUZA GUEDES

ORIENTADOR: Prof. Dr. FRANCISCO DE ASSIS SALVIANO SOUSA

**Campina Grande
Março de 2016**

RONI VALTER DE SOUZA GUEDES

**ANÁLISE E PREVISÃO DE EVENTOS CRÍTICOS DE PRECIPITAÇÃO COM
BASE NO SPI E EM REDES NEURAS ARTIFICIAIS PARA O ESTADO DE
PERNAMBUCO.**

Tese apresentada ao Programa de Pós-graduação em Meteorologia da Universidade Federal de Campina Grande, em cumprimento às exigências para obtenção do título de Doutor em Meteorologia.

Área de concentração: Meteorologia de Meso e Grande Escalas

Subárea: Climatologia Dinâmica

Orientador: Prof. Dr. Francisco de Assis Salviano Sousa

Campina Grande,
Março de 2016

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

- G924a Guedes, Roni Valter de Souza.
Análise e previsão de eventos críticos de precipitação com base no SPI e em redes neurais artificiais para o estado de Pernambuco / Roni Valter de Souza Guedes. – Campina Grande, 2016.
119 f. : il. color.
- Tese (Doutorado em Meteorologia) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, 2016.
"Orientação: Prof. Dr. Francisco de Assis Salviano de Sousa".
Referências.
1. Índices Climáticos. 2. Temperatura de Superfície do Mar. 3. Modelagem. I. Sousa, Francisco de Assis Salviano de. II. Título.


CDU 551.585(043)

RONI VALTER DE SOUZA GUEDES


ANÁLISE E PREVISÃO DE EVENTOS CRÍTICOS DE PRECIPITAÇÃO COM
BASE NO SPI E EM REDES NEURAS ARTIFICIAIS PARA O ESTADO DE
PERNAMBUCO

TESE APROVADA EM 18/12/2015


BANCA EXAMINADORA




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




Prof. Dr. JOSÉ IVALDO BARBOSA DE BRITO
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande



Prof. Dr. BERNARDO BARBOSA DA SILVA
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande



Prof. Dr. EMERSON MARIANO DA SILVA
Departamento de Física
Centro de Ciências e Tecnologia
Universidade Estadual do Ceará



Prof. Dr. RANYERE SILVA NOBREGA
Departamento de Ciências Geográficas
Centro de Filosofia e Ciências Humanas
Universidade Federal de Pernambuco

DEDICATÓRIA

Dedico este trabalho aos meus pais, Dalton Guedes e Fátima Batista, também a minha esposa, Denise Guedes, e aos vários amigos que me apoiaram nesta conquista.

AGRADECIMENTOS

Em primeiro lugar a Deus, por ter me dado toda a energia, saúde e capacidade para realizar este trabalho. Aos meus pais, Dalton e Fátima, que tanto lutaram e acreditaram, dando todo o suporte necessário para que eu pudesse evoluir e me tornar independente. Aos meus três irmãos, Anderson, Dalton e Danila, pelos incentivos e exemplos. Aos amigos da meteorologia que me apoiaram sempre, formando parcerias e estudos ao longo desta jornada, com destaque aos colegas da turma de mestrado e doutorado.

Um agradecimento especial a minha querida esposa, Denise Alves, pela sua compreensão, todo o amor, carinho e confiança de todos os dias.

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

A equipe que compõe a Gerência de Monitoramento e Mudanças Climáticas da APAC, que sempre foram solícitos, atenciosos e companheiros, entre eles, Patrice Oliveira, pelo entusiasmo e apoio.

E ainda, ao Conselho Nacional de Pesquisa e Desenvolvimento Científico e Tecnológico – CNPq, pela ajuda financeira. E a Agência Pernambucana de Águas e Clima – APAC pela liberação e disponibilização dos dados históricos para o estudo.

Aos não citados diretamente, mas que participaram desta caminhada, me ensinando um pouco de cada um, tanto do lado profissional como pessoal, sempre estimulando e animando em todos os momentos. Obrigado a todos por tudo.

*Tente mover o mundo. O primeiro passo
será mover a si mesmo. (Platão)
Mais importante que a vontade de vencer
é a coragem de começar.*

LISTA DE SIGLAS E ABREVIATURAS

APAC – Agência Pernambucana de Águas e Clima
ATSM – Anomalia da Temperatura da Superfície do Mar
DOL – Distúrbio Ondulatório de Leste
ENSO – El Nino Southern Oscillation
IOS – Índice Oscilação Sul
MGRAD – Gradiente Meridional do Atlântico
NOAA – National Oceanic and Atmospheric Administration
ODP – Oscilação Decadal do Pacífico
RNA – Redes Neurais Artificiais
SPI – Standardized Precipitation Index
SRHE – Secretaria de Recursos Hídricos e Energéticos
VCAN – Vórtice Ciclônico dos Altos Níveis
ZCAS – Zona de Convergência do Atlântico Sul
ZCIT – Zona de Convergência Intertropical

LISTA DE FIGURAS

Figura 1. Evolução da utilização de água durante o século XX.....	15
Figura 2. Transformação equiprovável para totais precipitados com duração três meses.	21
Figura 3. Distribuição normal para o SPI, com média 0 e variância de 1.....	22
Figura 4. Função densidade de probabilidade gama com parâmetros alfa=2 e beta=1.....	23
Figura 5. Exemplos de arquiteturas de redes.....	29
Figura 6. Célula de rede neural artificial.....	29
Figura 7. Classificação climática para o estado de Pernambuco.....	36
Figura 8. Espacialização do relevo do estado de Pernambuco.....	38
Figura 9. Regiões pluviometricamente homogêneas do estado de Pernambuco.....	39
Figura 10. Configuração de uma rede neural com três camadas.....	46
Figura 11. Diagrama com o resumo dos procedimentos da metodologia.	46
Figura 12. Distribuição espacial da precipitação média anual.	47
Figura 13. Distribuição espacial dos postos pluviométricos selecionados.....	48
Figura 14. Distribuição da média do SPI-1 de todos os postos.....	50
Figura 15. Distribuição da média do SPI-3 de todos os postos.....	51
Figura 16. Distribuição da média do SPI-6 de todos os postos.....	52
Figura 17. Distribuição da média do SPI-9 de todos os postos.....	52
Figura 18. Distribuição da média do SPI-12 de todos os postos.....	53
Figura 19. Distribuição da média do SPI-24 de todos os postos.....	54
Figura 20. Distribuição temporal de Brejo da Madre de Deus, A: SPI-1 e B: SPI-3.....	55
Figura 21. Distribuição temporal de Brejão, A: SPI-1 e B: SPI-3.	56
Figura 22. Dendrograma pelo método de Ward para o SPI-1.....	60
Figura 23. Dendrograma pelo método de Ward para o SPI-3.....	61
Figura 24. Dendrograma pelo método de Ward para o SPI-6.....	62
Figura 25. Dendrograma pelo método de Ward para o SPI-12.....	63
Figura 26. Dendrograma pelo método de Ward para o SPI-24.....	64
Figura 27. Distribuição espacial para dois grupos do SPI-1.	65
Figura 28. Distribuição espacial para dois grupos do SPI-3.	65
Figura 29. Distribuição espacial para dois grupos do SPI-6.	66
Figura 30. Distribuição espacial para dois grupos do SPI-12.	66
Figura 31. Distribuição espacial para dois grupos do SPI-24.	66

Figura 32. Histograma de frequência dos SPIs para diferentes escalas: (A) Grupo 1 e (B) ...	69
Figura 33. Distribuição temporal do SPI-12 meses: (A) Grupo 1 e (B) Grupo 2.	70
Figura 34. Distribuição temporal do SPI-24 meses: (A) Grupo 1 e (B) Grupo 2.	71
Figura 35. Distribuição temporal do SPI-36 meses: (A) Grupo 1 e (B) Grupo 2.	72
Figura 36. Distribuição temporal do SPI-48 meses: (A) Grupo 1 e (B) Grupo 2.	73
Figura 37. Distribuição temporal do SPI-60 meses: (A) Grupo 1 e (B) Grupo 2.	74
Figura 38. Distribuição espacial para dois grupos do SPI-24.	75
Figura 39. Arquiteturas de redes neurais do tipo “Cascade Forward”, “Feed-Forward” e “Layer Recurrent”, respectivamente.	80
Figura 40. Comparação entre os tipos de rede a) “Cascade-Forward”, b) “Feed-Forward”, c) “Elman backpropagation” e d) “Layer Recurrent”	82
Figura 41. Desempenho da rede com duas camadas, alterando o número de neurônios. (a) 5000 e 2000; (b) 5000 e 100.....	85
Figura 42. Rede “Cascade-Forward” com seis camadas e 7575 neurônios distribuídos de forma decrescente.....	86
Figura 43. Comparação entre os valores estimados pela rede e o objetivo (SPI-3) a ser alcançado. (A) é o Grupo 1 e (B) é o Grupo 2.	87
Figura 44. Coeficientes de regressão para as fases de treinamento, validação e teste.	88
Figura 45. Comparação dos valores estimados pela rede e os SPIs de três meses.....	89
Figura 46. Previsão da rede neural para o SPI-1. (A) é o Grupo 1 e (B) é o Grupo 2.	90
Figura 47. Previsão da rede neural para o do SPI-6. (A) é o Grupo 1 e (B) o Grupo 2.	90

LISTA DE TABELAS

Tabela 1. Funções de transferência	30
Tabela 2. Distribuição mensal da precipitação (mm/mês) por cada região homogênea	40
Tabela 3. Classificação do índice SPI e sua probabilidade de ocorrência.	42
Tabela 4. Relação de postos selecionados e ordenados pela longitude.....	48
Tabela 5. Correlação entre as escalas temporais do SPI.	57
Tabela 6. Identificação dos postos na divisão em dois grupos para cada escala do SPI.....	67
Tabela 7. Duração e intensidade das piores secas de acordo com SPI-12.	68
Tabela 8. Valores de correlação entre os SPIs do grupo 1 e anomalias de TSMs e IOS.	78
Tabela 9. Valores de correlação entre os SPIs do grupo 2 e anomalias de TSMs e IOS.	78
Tabela 10. Resultados de uma simulação com quatro tipos de rede neural.	81
Tabela 11. Teste com diferentes algoritmos de treinamento.....	82
Tabela 12. Classificação dos resultados do teste para os algoritmos mais promissores.	84
Tabela 13. Resultados do treinamento para cada função de transferência.....	84
Tabela 14. Exemplos de configurações aplicadas nos testes.	87

RESUMO

A identificação e classificação de áreas susceptíveis à ocorrência de eventos críticos, chuvosos ou secos, tornaram-se uma necessidade frequente no contexto da variabilidade climática, responsável por muitos desastres naturais em diversos países do mundo. O diagnóstico com base nos impactos meteorológicos, agrícolas e hidrológicos pode ser aferido através de índices climáticos. O Índice de Precipitação Padronizado (SPI) foi desenvolvido para diagnosticar e categorizar a variabilidade da precipitação com base em diferentes escalas temporais. A aplicação da metodologia do SPI para 57 postos distribuídos sobre o estado de Pernambuco, Nordeste do Brasil, com séries de 1963 a 2015, foi capaz de destacar e classificar as principais anomalias das chuvas através da sua intensidade e duração. As escalas menores do SPI (mensal e trimestral) indicaram o início e tendência de cada evento; a escala semestral identificou o comportamento do período chuvoso e as escalas anual e bienal definiram os eventos mais fortes e duradouros. Foram diagnosticados eventos positivos e negativos nas categorias de fraco, moderado, severo e extremo. Foram analisados os eventos que ocorreram de forma mais generalizada e, portanto, mais significativos. Foram destacados os eventos chuvosos críticos de 1963, 1973, 1984 e os eventos secos de 1993, 1998 e 2012. A análise de agrupamento utilizando a métrica de Ward foi aplicada aos SPIs para delimitar dois grupos bem definidos para qualquer escala temporal do SPI. A divisão do estado de Pernambuco ficou assim: Grupo 1, do Litoral ao Agreste e o Grupo 2 representando todo o Sertão. Os valores das anomalias de temperatura da superfície do mar foram correlacionados com cada escala do SPI e usados como entrada nos modelos baseados em Redes Neurais Artificiais (RNA) para prever as variações deste índice na área de estudo. Os resultados mostraram que o modelo apresentou uma boa previsão com o padrão de comportamento da escala trimestral do SPI, e não obteve o mesmo nível de desempenho para as escalas mensais e semestrais, porém, o modelo de RNA conseguiu absorver a tendência dos valores destas escalas e encontrar uma boa associação.

Palavras-chave: Índices Climáticos, Temperatura da Superfície do Mar e Modelagem.

ABSTRACT

The identification and classification of areas susceptible to critical events be it rainy or dry events, has become a frequent need in the current context of climate variability, responsible for natural disasters in several countries in the world. The diagnosis based on meteorological, agricultural and hydrological impacts can be measured by climatic indices. The Standardized Precipitation Index (SPI) was developed to categorize and make the diagnostic the variability of the rainfall based on different temporal scales. The application of SPI methodology to 57 stations distributed about the state of Pernambuco, Northeastern Brazil, for the years 1963 to 2015, was able to highlight and rank the main anomalies of rainfall through its intensity and duration. Smaller scales the SPI (monthly and quarterly) indicated the start and trend of each event, the semiannual scale identified the behavior of rainy period and the annual and biennial scales it defined the strongest and most enduring events. Positive and negative events were diagnosed in the scale categories: low, moderate, severe and extreme. Were analyzed the events that occurred more widely and thus more significant. Were highlighted the critical rainfall events of 1963, 1973, 1984 and the dry events of 1993, 1998, 2012. The cluster analysis using the metric of Ward was applied to SPIs to delimit the two well-defined groups to any timescale of the SPI. The division of Pernambuco state was as follows: Group 1, from Coast to Agreste and Group 2 represents the entire Sertão. The values of the temperature anomalies of the sea surface were correlated with each SPI scale and used as input in models based on Artificial Neural Networks (ANN) to predict the variations of this index in the study area. The results showed that the model had a good forecast with the standard of behavior of the quarterly SPI scale, but did not get the same level of performance for the monthly and semi-annual scales, but the model the ANN was able to absorb the trend of the values of these scales and find a good association.

Keywords: Climate indices, Sea Surface Temperature and modeling.

SUMÁRIO

LISTA DE SIGLAS E ABREVIATURAS	VIII
LISTA DE FIGURAS	IX
LISTA DE TABELAS	XI
RESUMO	XII
ABSTRACT	XIII
INTRODUÇÃO	15
1.1. Objetivo Geral	18
1.2. Objetivos específicos.....	18
1.3 Justificativa.....	19
2. REVISÃO BIBLIOGRAFIA	20
2.1. Índice Padronizado de Precipitação (SPI).....	20
2.1.1 Revisão Bibliográfica do SPI	24
2.1.2 Revisão Bibliográfica da Influência das TSMs sobre a chuva.....	26
2.2. Redes Neurais Artificiais (RNAs).....	28
2.2.1 Neurônio artificial	29
2.2.2 Funções de transferência	30
2.3.3. Características das redes neurais artificiais	31
2.3.4 Revisão Bibliográfica das RNAs.....	32
3. MATERIAL E MÉTODOS	35
3.1. Área de estudo	35
3.1.1. Hidrografia	35
3.1.2. Clima	36
3.1.3. Relevos.....	38
3.1.4. Regiões pluviometricamente homogêneas	39
3.2. Cálculo do Índice de Precipitação Padronizado (SPI)	41
3.3. Análise de Agrupamento (Cluster Analysis).....	43
3.4. Correlação Linear entre os SPIs e TSMs	44
3.5. Concepção da Rede Neural Artificial.....	44
4. RESULTADOS E DISCUSSÃO	47
4.1 SPI médio da região para cada escala	49
4.2. Distribuições da escala anual de cada estação no SPI-12	54
4.3 Correlações entre as médias das escalas do SPI.....	56
4.4. Análise de agrupamento para várias escalas do SPI	57
4.5. Relação entre as variáveis de entrada do modelo.....	75
4.6. Relação das variáveis de entrada do modelo e a saída (SPI)	76
4.7. Montagem e desempenho da Rede Neural Artificial	78
5. CONCLUSÕES E SUGESTÕES	91
REFERÊNCIAS	94
APÊNDICE 1 – Distribuição do SPI-12 para cada posto analisado	101

INTRODUÇÃO

A dependência do controle e aproveitamento dos recursos hídricos para a evolução da sociedade se mostra cada vez maior e importante através do tempo. No início do século XX, cerca de 90% da água doce utilizada era destinada à agricultura, devido à expansão industrial a partir de 1940, e o crescimento urbano e populacional, o uso da água se tornou mais significativo em outros setores, exigindo demandas para além da sobrevivência humana, ou seja, também para o desenvolvimento econômico e em consequência para a melhoria do padrão de vida da sociedade (BISWAS, 1997). A Figura 1 mostra a expansão sobre o uso da água para diversos fins, e indica o aumento acentuado da demanda. Isto reforça a necessidade de estudos sobre o comportamento, variação e distribuição da precipitação para diversas áreas.

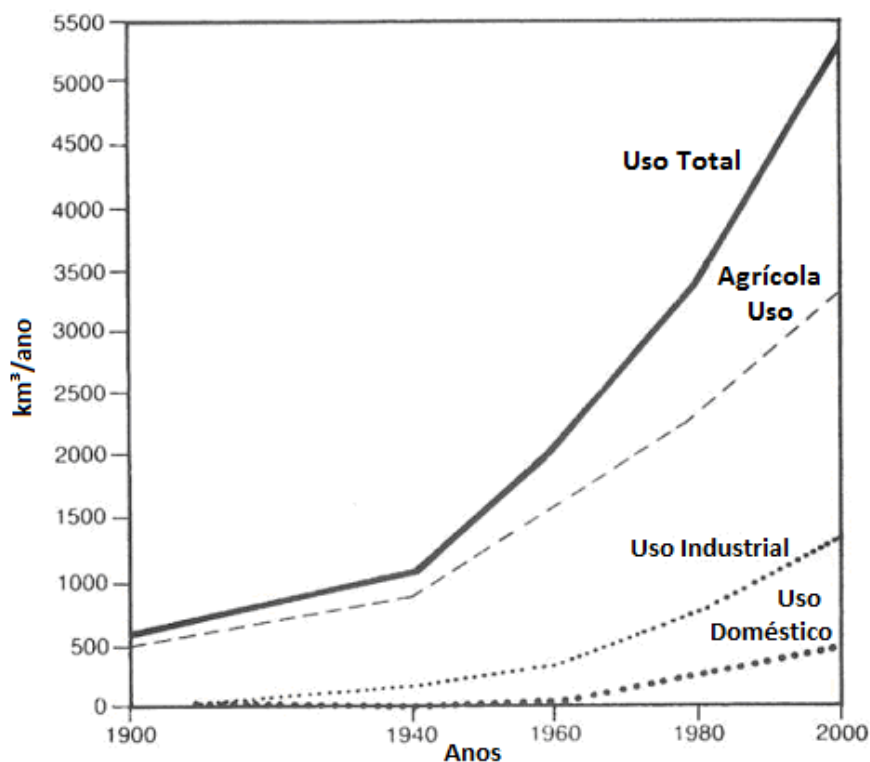


Figura 1. Evolução da utilização de água durante o século XX
Fonte: BISWAS (1997)

A identificação e classificação de áreas susceptíveis à ocorrência de eventos extremos tornaram-se uma necessidade frequente no contexto das mudanças climáticas. Por conta de sua frequência e intensidade, esses eventos extremos vêm provocando catástrofes em diversos países. As alterações climáticas globais indicam que estas mudanças podem gerar um

aumento no número de eventos críticos de precipitação pelo mundo, alguns cenários traçados pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2014) apontam para aumento das chuvas torrenciais.

A seca é um fenômeno que pode ter curta, média ou longa duração. Em casos graves, um evento pode durar anos, com efeitos devastadores sobre a agricultura, o abastecimento de água e a situação sócio-econômica de uma região. Em alguns casos pode ser difícil determinar quando uma seca começa ou termina, mas ela é recorrente e inevitável.

Em todo o Planeta, entre 1967 e 1992, as secas afetaram 50% de 2,8 bilhões das pessoas que sofreram algum tipo de catástrofe natural. Por causa de impactos diretos e indiretos da seca, 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 vulneráveis às secas. Mais importante ainda, quase todas as grandes áreas agrícolas estão localizadas em regiões suscetíveis a ocorrência desse fenômeno que produz uma complexa rede de impactos que abrange muitos setores da economia e atinge locais bem distantes da área física que enfrenta a seca. No Nordeste do Brasil, sua ocorrência é comum, principalmente na região semiárida (USDA, 1994).

Vários tipos de índices são capazes de diagnosticar a deficiência ou excesso hídrico de uma região, mas nem todos têm viabilidade de aplicação devido à escassez de dados históricos e de outras variáveis, além da precipitação. O SPI merece destaque por conta de uma metodologia que facilita a sua utilização haja vista que este índice depende apenas da precipitação pluviométrica e também pode ser aplicado para mais pontos pela facilidade e base de comparação histórica maior que outras variáveis. Além disto, permite classificar de forma pontual a situação hídrica de uma área e também avaliá-la em diferentes escalas temporais e classificar, em cada escala, situações de eventos extremos, severos, moderados e fracos nas faixas de déficit ou de excesso hídrico.

A importância de se avaliar diferentes escalas temporais está principalmente nos efeitos diretos sobre as áreas atingidas. O fenômeno da seca pode ter sua definição diferenciada com base na sua duração ou nos impactos provocados, e pode ser do tipo meteorológica, agrícola e hidrológica, entre outros (PIRES, 2003).

- **A seca meteorológica** é caracterizada pelo déficit da precipitação em relação ao valor normal; caracteriza-se pela falta de água induzida pelo desequilíbrio entre a precipitação e a evaporação, a qual depende de outros elementos como a velocidade do vento, temperatura, umidade do ar e insolação.

- **A seca agrícola** está associada à falta de água causada pelo desequilíbrio entre a água disponível no solo, a necessidade das culturas e a transpiração das plantas. Este tipo de seca está relacionado com as características das culturas, da vegetação natural, ou seja, dos sistemas agrícolas em geral. A seca agrícola manifesta-se após a seca meteorológica, mas antes da seca hidrológica.
- **A seca hidrológica** está relacionada com a redução dos níveis médios de água nos reservatórios de superfície e subterrâneos e com a depleção de água no solo. Este tipo de seca está normalmente defasado da seca meteorológica, haja vista que é necessário um período maior para que as deficiências na precipitação alterem o comportamento do ciclo hidrológico.

O diagnóstico da intensidade da precipitação pode contribuir para o conhecimento de eventos críticos chuvosos e seus efeitos na recomposição dos níveis de reservatórios para diversos fins, além das ocorrências de enchentes, deslizamentos de terra e alagamentos nos centros urbanos. O SPI é eficiente na detecção das intensidades e durações dos eventos extremos para regiões de diferentes características climáticas, inclusive em áreas do Nordeste Brasileiro (MACEDO et al., 2010 e GUEDES et al., 2012) e também a capacidade do SPI em se associar com outras metodologias (HAO e AGHAKOUCHAK, 2013, BELAYNEH et al., 2014, GOCIC e TRAJKOVIC, 2014).

Avaliações podem ser direcionadas para regiões específicas através do agrupamento hierárquico dos índices de chuva, identificando subáreas com diferentes características, que apresentam outras consequências quando sob ocorrência de eventos críticos. Por exemplo, o método de Ward (1963) permite fazer associações entre variáveis e identificar o grau de aproximação entre elas. O uso desse método permite que o pesquisador escolha a quantidade e o tamanho dos grupos que deseja formar de acordo com seu objetivo e área de estudo.

A precipitação depende dos sistemas meteorológicos que atuam na região, do relevo e dos fenômenos climáticos de grande escala que influenciam as variáveis que definem o comportamento e a circulação da atmosfera. No Nordeste brasileiro, além de fatores físicos e geográficos, os eventos críticos estão associados a fenômenos como o El Niño/Oscilação Sul e o Dipolo do Atlântico (aquecimento/esfriamento do Atlântico Norte/Sul) (MELO, 1999; ALVES, 1997).

Vários pesquisadores mostraram que existe relação entre as TSMs (Temperatura da Superfície do Mar) dos oceanos Atlântico e Pacífico com as precipitações no Nordeste do Brasil, mas analisaram períodos específicos, como correlações com a quadra chuvosa de determinada área (FERREIRA et al., 2004) ou considerando os intervalos entre a fase inicial e

de desenvolvimento do ENOS (ANDREOLI & KAYANO, 2007; REPELLI & NOBRE, 2004). Outros defendem, por sua vez, que a influência dos fenômenos ENOS é diferente para cada área e que a intensidade do seu efeito depende das condições de Dipolo do Atlântico (LUCENA et al., 2011 e COSTA, 2012). Já alguns indicaram que o ENSO por si só não caracteriza seca no Nordeste Brasileiro e deve atuar concomitantemente com a configuração desfavorável do Atlântico (NÓBREGA et al., 2014).

A previsão de eventos anômalos de precipitação já foi objeto de estudos de vários cientistas que utilizaram diversos tipos de modelos. Alguns destacaram os modelos baseados em Redes Neurais Artificiais (RNAs) na previsão de índices de seca, devido a sua capacidade de adaptação e identificação de padrões, se saindo melhores que outros modelos (BELAYNEH et al., 2014). Morid et al. (2007) afirmaram que modelos de RNAs para a previsão de índices de precipitação podem ser muito convenientes para fins operacionais e de alertas precoces. A hipótese que norteia este trabalho é a de que é possível diagnosticar e prever eventos críticos de chuva com base em modelos de Rede Neurais Artificiais classificados a partir dos SPIs de diferentes escalas temporais

1.1. Objetivo Geral

O objetivo deste estudo é analisar os eventos críticos de chuvas no estado de Pernambuco com base no Índice de Precipitação Padronizado (*SPI*) em diferentes escalas temporais, e propor um modelo baseado em Redes Neurais Artificiais para a previsão de índices climáticos a partir das anomalias de TSMs no Pacífico e Atlântico Tropical.

1.2. Objetivos específicos

- i – Atualizar e manter registros históricos dos principais eventos críticos no estado de Pernambuco e disponibilizar um sistema para o monitoramento automático dos eventos extremos para subsidiar as análises climáticas da APAC;
- ii – Diagnosticar eventos em várias escalas temporais, possibilitando identificar durações e intensidades, com informações pontuais para os municípios do estado de Pernambuco;
- iii – Aplicar a Análise de Agrupamento nos SPIs e dividir o estado de Pernambuco em grupos climaticamente homogêneos;

iv – Correlacionar as TSMs dos oceanos Pacífico e Atlântico com os SPIs de cada grupo e em várias escalas temporais.

v – Propor um modelo de previsão de SPIs a partir de dados de TSMs dos oceanos Pacífico e Atlântico com base em modelo de Redes Neurais Artificiais.

1.3 Justificativa

O estado de Pernambuco comumente apresenta ocorrências de eventos críticos chuvosos que acentuam a frequência de inundação e/ou alagamento, principalmente em áreas urbanas. Paralelamente, grande parte do estado sofre com eventos críticos de secas repetitivos, principalmente na região semiárida, com baixa disponibilidade hídrica e alta variabilidade temporal. Assim, há uma necessidade de monitoramento e análise contínua destes eventos para quantificar sua intensidade, frequência e duração em cada caso. Este estudo pretende contribuir com ferramentas que possam melhorar o conhecimento, aprimorar o diagnóstico e a previsão dos eventos críticos e subsidiar a tomada de decisão para a gestão dos recursos hídricos.

Este índice de precipitação calculado por município ou por subáreas facilita a análise dos diferentes impactos para áreas específicas e sua atualização sistemática em diversas escalas temporal apresenta um diagnóstico, local ou regional, do início, da intensidade e atual duração de cada evento, e fornece o histórico do comportamento do índice. A comparação do SPI com as TSMs do Pacífico e Atlântico é uma proposta inédita, para o estado de Pernambuco, incorporada neste trabalho e os resultados poderão reforçar o conhecimento da influência deles no SPI do Estado em várias escalas temporal.

Uma vez conhecidas os pesos de cada variável sobre o índice, pode-se identificar uma tendência do comportamento do mesmo no curto e longo prazo, dependendo dos pesos das correlações para cada área. Essas informações podem ser agregadas para previsões em vários tipos de modelos, e neste caso, se propõe um modelo baseado em redes neurais que será usado nas previsões do SPI em diferentes escalas, antecipando-se aos efeitos decorrentes dos eventos críticos. Essa proposta de utilizar dados oceânicos inseridos em modelos de RNAs para a previsão de índice climático é inovadora e fornece uma nova ferramenta de apoio ao monitoramento e desenvolvimento dos recursos hídricos da região.

2. REVISÃO BIBLIOGRAFIA

2.1. Índice Padronizado de Precipitação (SPI)

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) desenvolveram o *SPI* para quantificar déficits de precipitação em múltiplas escalas.

O uso do *SPI* apresenta as seguintes vantagens (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, uma vez que faz comparações pontuais;
- 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 crítico 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.

No cálculo do SPI a probabilidade cumulativa da precipitação de um determinado local x durante o tempo t $H(x,t)$ é então transformada na variável aleatória normalizada $Z(x,t)$ com média 0 e desvio padrão 1, que corresponderá ao valor de SPI. Esta é a transformação equiprobabilística que Panofsky e Brier (1968) definiram como característica essencial para transformar a variável de uma distribuição (*gama*) numa variável com uma distribuição de forma definida (distribuição normal), tal que a probabilidade de ser inferior a um dado valor da variável inicial seja a mesma que a probabilidade de ser inferior ao valor correspondente da variável transformada (DOMINGOS, 2006).

Este método está representado na Figura 2, onde uma quantidade de precipitação total de 3 meses (por exemplo, dezembro a fevereiro) é convertida num valor de SPI, com média 0 e variância 1. Em **a)** a linha quebrada designa o valor atual trimestral da precipitação (Dezembro a Fevereiro) para uma estação na Inglaterra no período de 1901 a 1999. Esta linha

mostra também a distribuição de probabilidade cumulativa empírica para o período considerado. A curva contínua em **a)** mostra a distribuição da probabilidade cumulativa da distribuição gama, ajustada à série de precipitação. No lado **b)** a curva contínua mostra a distribuição de probabilidade cumulativa da variável aleatória normalizada (Z) usando a mesma escala da probabilidade cumulativa da distribuição empírica e da distribuição gama ajustada. Deste modo, obtêm-se os valores do SPI. Assim, por exemplo, para um valor de precipitação de 77 mm, obtêm-se um valor de SPI de +1.1 (DOMINGOS, 2006).




Figura 2. Transformação equiprovável para totais precipitados com duração três meses.
Fonte: Hughes e Saunders (2002).

Visto não ser muito prático produzir este tipo de figuras para todas as estações, em todas as escalas temporais possíveis e para cada mês do ano, o valor de Z ou SPI é obtido computacionalmente.

Conceitualmente, o SPI representa o valor de Z -score, ou seja, o nº de desvios padrão acima ou abaixo que um evento (valor) se encontra em relação à média. Contudo, isto não é totalmente correto para escalas de tempo pequenas, devido a sua maior aleatoriedade, visto que a distribuição original da precipitação é assimétrica.

No entanto a Figura 3 mostra que durante o período base para o qual os parâmetros são estimados, o SPI terá uma distribuição normal com um valor esperado de 0 e uma variância

de 1. Um índice com estas características é desejável de modo a permitir comparações dos valores de cada posto pluviométrico e em diferentes regiões.




Figura 3. Distribuição normal para o SPI, com média 0 e variância de 1.
Fonte: DOMINGOS (2006).

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* se mantém em determinada faixa negativa por um período de tempo, este evento cessa quando o valor do *SPI* aumenta até a faixa normal.

O *SPI* foi desenvolvido de modo a ser um indicador de seca, que reconhece a importância das escalas de tempo que afetam vários tipos de necessidades de água. Deste modo, é calculado considerando séries e períodos médios, selecionados de modo a se determinar séries de escalas de tempo de i meses, $i = 1, 2, 3, \dots, 12, \dots, 24, \dots$ meses. O n° de meses (i) é arbitrário, mas os valores escolhidos representam escalas de tempo de déficit de precipitação importantes (<http://www.drought.unl.edu>).

O *SPI*-1 mês é parecido com o desvio relativo da precipitação, mas o índice é mais exato devido à distribuição ter sido normalizada. O *SPI*-1 deve ter uma interpretação cuidadosa para os meses em que a média é muito baixa, pois, podem ocorrer valores grandes de *SPI* devido a aleatoriedade da precipitação. Por isto, a climatologia da região deve ser levada em consideração para interpretar o significado do valor do índice.

O *SPI*-3 meses faz comparações trimestrais da precipitação acumulada nos mesmos 3 meses para todos os anos da série, sendo uma estimativa sazonal e refletindo as condições de

água no solo a curto prazo. A observação desta escala é importante da identificação de períodos normais no meio de eventos extremos longos detectados em escalas maiores.

O SPI-6 semestral compara a precipitação neste intervalo com a média histórica do mesmo período de 6 meses de todos os anos da série. Nesta escala observa o comportamento da precipitação no início e fim de cada estação do ano, e já está associada às anomalias nos reservatórios e níveis dos rios.

O SPI-9 meses observa as anomalias entre as estações e períodos de transição, englobando todo um período chuvoso, funcionando como indicador para o setor agrícola.

O SPI-12 meses já reflete a situação anual considerada de longo prazo; esta escala atenua eventos de curto espaço, mas detecta tendências prolongadas de déficit hídrico associando a falta de água em reservatórios e queda nos níveis de água subterrânea.

É importante salientar que quanto maior for o período com dados usado para calcular a distribuição dos parâmetros, maior é a probabilidade de se obter melhores resultados (por ex.: 50 anos de informações é melhor que 20 anos). Deste modo, pode-se usar um período de tempo muito longo para calcular os parâmetros da distribuição e depois extrair os valores do SPI apenas para um determinado período de tempo (um ano ou meses). Na Figura 4 encontra-se o comportamento da densidade de probabilidade gama em relação a quantidade de precipitação.




Figura 4. Função densidade de probabilidade gama com parâmetros $\alpha=2$ e $\beta=1$.
Fonte: DOMINGOS, 2006.

2.1.1 Revisão Bibliográfica do SPI

Bussay et al. (1999) e Szalai e Szinell (2000) avaliaram a utilidade do *SPI* para descrever eventos de secas ocorridas 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 escalas maiores, mas a escala de 3 meses já representa impacto quando ocorre no início do crescimento da vegetação.

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 através das cargas fatoriais estabelecendo a classificação do tempo de duração destes eventos. O agrupamento dos pluviômetros sugeriu que os eventos de escassez são mais abrangentes e aumentam notavelmente, enquanto os episódios de excessos de chuva apresentam tendência decrescente na quantidade de pluviômetros atingidos, ou seja, apresentam áreas menores com o tempo.

Hughes e Saunders (2002) estudaram a climatologia das secas na Europa com base em escalas temporais mensais do *SPI* de 3, 6, 9, 12, 18 e 24 meses no período de 1901-1999. O número médio de eventos de seca extrema e moderada com o *SPI*-12 foi de 6 ± 2 eventos, e 27 ± 3 eventos, respectivamente. Enquanto que a duração média foi 27 ± 8 meses para eventos extremos e de 21 ± 3 meses para eventos moderados.

Tsakiris & Vangelis (2004) apresentaram um método de estimativa do índice *SPI* (03, 06 e 12 meses) para uma área geográfica, na parte Este da Ilha de Creta, e sua utilização para caracterização das secas nessa área, observando que o procedimento proposto pode caracterizar uma área de dimensões de mesoescala. Concluíram que o método pode ser usado para estimar a severidade da seca, sua duração e intensidade. Também que o processo adotado é vantajoso pela sua simplicidade, transparência e universalidade.

Tonkaz (2006) estudou o comportamento das secas no sudeste da Turquia, usando o *SPI*. O autor identificou que os eventos de secas atuantes nos anos 1999-2000 influenciaram o decréscimo das atividades agrícolas em comparação com a década anterior.

Blain & Brunini (2007) realizaram análises comparativas entre os índices *SPI*, *PDSI* e *PDSI* adaptado sobre o estado de São Paulo, e concluíram que o *SPI* tem melhor versatilidade devido sua consistência espacial para o cálculo do déficit hídrico com melhor distribuição e em diversas escalas de tempo do que os outros métodos.

Morais et al., (2008) utilizaram o *SPI* com redes neurais para prever eventos de secas da bacia hidrográfica do rio São Francisco. Nesse estudo foi analisado o desempenho de um tipo de rede neural para várias 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 de maior acumulado da precipitação, sendo, portanto, de mais fácil previsão.

Macedo et al. (2010) utilizaram os *SPIs* (12 e 24 meses) para monitorar as secas severas e extremas nas sub-regiões pluviométricas homogêneas do Estado da Paraíba e diagnosticaram que a maioria dos eventos extremos prolongados tiveram correlação com padrões de El Niño.

Guedes et al. (2012) aplicaram a metodologia do *SPI* para o diagnóstico de seca sobre o estado do Piauí. Foram identificadas secas na categoria severa para vários municípios e mostrado que a sua duração depende da escala do *SPI* considerada. A quantidade de secas nas escalas de 3 e 6 meses foi maior que nas escalas de 12 e 24 meses, mas a espacialização das mesmas se manteve em quase todas as regiões.

Hao et al. (2013) propuseram um modelo de índice multivariado (*MSDI*) com base no *SPI* e no *SSI*, que usa a umidade do solo. Os resultados indicaram que o *SPI* domina o início da seca, enquanto que sua persistência ficou mais semelhante ao comportamento do *SSI*. Os autores não pretendem substituir estes índices, mas no futuro com integração de outros índices para que o *MSDI* avalie secas meteorológicas, agrícolas e hidrológicas.

Zhang e Jia (2013) propuseram a detecção remota da seca com multi-sensores que calculam o índice de micro ondas integrado da seca (*MIDI*), composto por outras variáveis estimadas e o correlacionaram com o *SPI*. Os resultados indicaram maior correlação com o *SPI* de 1 mês, diminuindo com o aumento da escala do *SPI*. Portanto, o *MIDI* foi recomendado para seca de curto prazo e em áreas remotas ou com poucas medições meteorológicas.

Gocic e Trajkovic (2014) aplicaram a metodologia do *SPI-12* para ilustrar os anos mais secos na Sérvia e a análise de componentes principais para capturar padrões de seca. Também observaram que além de destacar os anos mais secos ou mais chuvosos, também foi possível identificar percentagem de ocorrência de seca para diferentes grupos da região e dois padrões de comportamento.

Masud et al. (2015) com vista a caracterização de eventos de seca quanto a sua severidade e duração na Bacia do Rio Saskatchewan usaram o índice *SPI* e também o *SPEI* que segue o mesmo princípio do primeiro, porém, utiliza dados de evapotranspiração. Assim,

encontraram áreas associadas a risco de seca mais intensa e áreas com secas mais frequentes e suaves. A comparação entre as saídas do SPI e do SPEI não mostraram muitas diferenças e ambos podem representar a espacialização das secas. No entanto, para cenários climáticos o SPEI deve ser usado por embutir efeito da temperatura na forma de evapotranspiração.

Qin et al. (2015) avaliaram a ocorrência de seca na bacia Haihe da China através dos índices SPI e SMDS que utiliza umidade do solo. Os resultados indicaram que o SPI apresenta secas com menores durações e com áreas afetadas maiores, pois a seca meteorológica difere da hidrológica a depender das condições hídricas da região. Os dois índices têm significativa correlação com o NDVI, mas em termos anuais o SMDS apresenta correlação um pouco maior, embora os valores de umidade do solo fossem estimados.

Wang et al. (2015) avaliaram impactos na mudança da vegetação na China usando o SPI e o NDVI. Com a identificação dos anos e severidades das ocorrências de secas identificadas pelo SPI foi possível observar que ao longo de 30 anos houve influência da seca sobre a vegetação nas partes norte e principalmente noroeste da China. Quando a seca ocorreu durante o período de crescimento tiveram grande impacto negativo sobre o desenvolvimento da vegetação.

Zarch et al. (2015) compararam o SPI com outro índice de seca (RDI) que envolve a evapotranspiração potencial. Eles observaram que os dois índices tiveram maior semelhança para zonas áridas em comparação com zonas úmidas, mas que diferem em zonas de transição, devido alterações da evapotranspiração. Também sugeriram que o SPI não fosse usado em cenários climático futuros de longo prazo por não ter em sua composição outras variáveis atmosféricas.

2.1.2 Revisão Bibliográfica da Influência das TSMs sobre a chuva

Moura et al. (2009) associaram a precipitação de março a julho na faixa leste do Nordeste para um grupo restrito de postos com as anomalias de TSM. Foi encontrada maior correlação para o Oceano Atlântico e também modos zonais e meridionais com a variação de lags, enquanto que o Pacífico Tropical apresentou correlação negativa.

Lucena et al. (2011) mostraram que entre 1948 e 1997, ocorreram 14 El Niños, 13 La Niñas, 10 Dipolos positivos e 9 Dipolos negativos. Concluíram que o Atlântico Tropical parece ter um impacto climático mais consistente sobre o norte do Nordeste do Brasil, enquanto que o ENSO tem papel secundário, com exceção de episódios de El Nino ou La Nina muito forte.

Costa (2012) observou uma maior correlação da TSM do Pacífico e a vazão dos postos do Alto São Francisco, enquanto que a relação da TSM do Atlântico foi maior para a vazão no Médio e Baixo São Francisco.

Gelcera et al. (2013) usaram o índice de seca (ARID) voltado para a agricultura e avaliaram sua relação com ENSO para duas regiões de latitudes médias: Flórida nos Estados Unidos e Rio Grande do Sul, no Brasil. Para ambas as regiões o ENSO teve efeito limitado sobre o padrão espacial do ARID, mas suas fases quente e fria influenciaram os níveis de estresse hídrico. Durante El Niño os valores de ARID diminuíram e no La Niña o índice aumentou. Esta relação é mais evidente no período de novembro a maio.

Nóbrega et al. (2014) utilizaram dados de quatro estações sobre o estado de Pernambuco considerando alguns meses de maior relevância para os fenômenos ENSOS e Dipolo e compararam um índice IAC com as TSMs destes fenômenos. Os resultados indicaram que a ocorrência conjunta do El Niño e Dipolo positivo acentuaram as anomalias de precipitação, enquanto que a ocorrência um fenômeno isoladamente mostrou menor relação. Na última década foi registrada a ocorrência de eventos El Niño nos anos 2002 a 2010, o que não refletiu em períodos secos sobre o NEB, seja por conta da intensidade do evento ou porque o dipolo do Atlântico exerceu maior influência.

Nóbrega et al., (2014), através do programa RCLimindex, calcularam índices extremos de precipitação para a Paraíba e correlacionaram com a TSM dos oceanos tropicais. Foi observado que a região do Sertão teve associação com os oceanos Atlântico e Pacífico, como também, com a OMA. Já as regiões da Borborema e Agreste foram mais correlacionadas com o Atlântico Norte e com a OMA. E, por fim, o Litoral se correlacionou significativamente apenas com o Atlântico Norte.

Machado et al. (2015) associaram dados de precipitação da Colômbia com TSM nos padrões canônico e modoki do El Niño. Os resultados indicaram redução das chuvas nas áreas norte, central e ocidental da Colômbia, enquanto que na parte sudoeste apresenta efeito oposto. A metodologia de decomposição de valores singulares (SVD) indicou que o primeiro modo está associado ao El Niño canônico e o segundo modo ao El Niño modoki. Foi observado que a forma canônica domina as variações na maioria das estações, mas na parte sudoeste é dominada pela forma modoki.

2.2. Redes Neurais Artificiais (RNAs)

Redes Neurais Artificiais (RNAs) é um conceito da computação que visa trabalhar no processamento de dados de modo semelhante ao cérebro humano, ou seja, são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através de experiências (SOUSA, 2008). 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.

Em 1943, a ideia 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). Nos anos 80, John Hopfield utilizou um algoritmo de aprendizado que estabilizava a rede binária simétrica com realimentação. Rumelhart et al. (1986) deram destaque a este campo com a introdução do poderoso método “*backpropagation*” como algoritmo de aprendizado, sendo utilizado até hoje.

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. Podem-se 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), em que se encontram, também, informações sobre os algoritmos de aprendizagem, *Backpropagation*, *Combinatorial* e *Iterativo Multicamadas*. A Figura 5 mostra algumas arquiteturas que apresentam dinâmicas diferentes no fluxo dos dados.

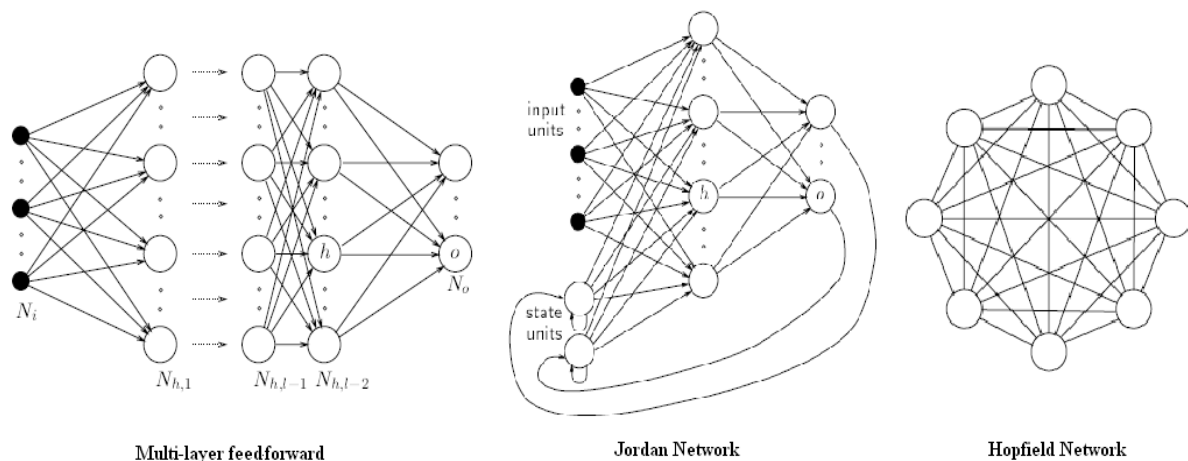


Figura 5. Exemplos de arquiteturas de redes.
 Fonte: Kröse; Smarg, (1996).

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, 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.

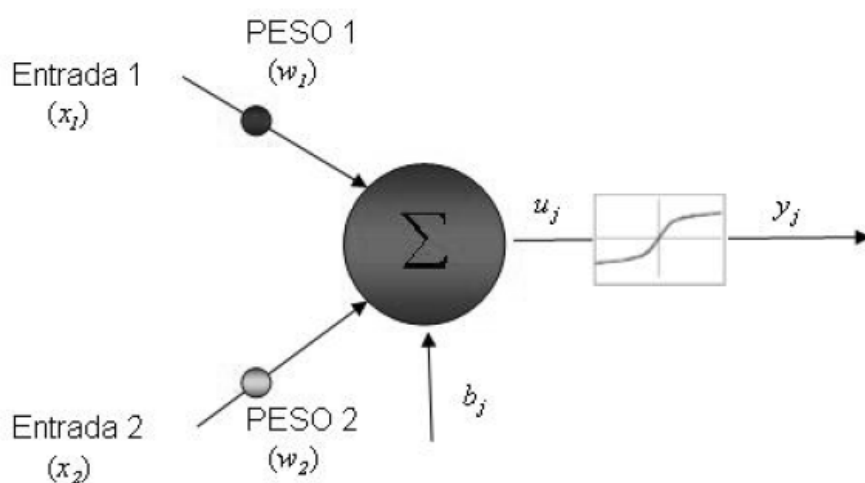


Figura 6. Célula de rede neural artificial.
 Fonte: Machado (2005).

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, sendo que 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: Demuth et al. (2007).

2.3.3. Características das redes neurais artificiais

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, 2000):

- (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.

2.3.4 Revisão Bibliográfica das RNAs

Anmala et al. (2000) utilizaram RNAs feed-forward e RNAs recorrentes com entradas de temperatura e chuva mensal para a previsão da 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.

Almeida e Barbosa (2004) utilizaram RNAs com o objetivo da 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.

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.

Morid et al. (2007) identificaram a capacidade da RNA para a previsão dos índices de precipitação (SPI e EDI) para a província do Teerã no Iran e que devido o padrão de entrada da rede não se modificar com o tempo, estes modelos são adequados para fins operacionais.

Barua et al. (2012) desenvolveram um índice de seca agregada não linear (NADI) para classificar a seca hidrológica dentro de uma bacia. Estes dados serviram de entrada para dois modelos de RNA. No geral, os dois modelos foram capazes de prever seca por até 6 meses, estatisticamente significantes com nível de 1%. Os dois modelos tiveram desempenho melhor que o ARIMA.

Zadeh e Tabari (2012) usaram o tipo de RNA MLP para prever valores de SPI em várias escalas, mas adicionaram na rede neural os índices NAO e SOI com defasagem temporal. Os resultados indicaram no prazo de 1 mês valores de RMSE=0,35 e $R^2=0,92$, e ainda que a previsão do SPI12 e SPI24 tiveram melhores previsões que as demais escalas.

Abarghouei et al. (2013), através do SPI em várias escalas, vistoriaram a previsão de seca com base em modelos de RNAs para uma região árida do Iran. Os testes indicaram que a estrutura da rede com o algoritmo trainingd mostrou mais habilidade que outros. As correlações permaneceram acima de 0,79 e, em alguns casos maiores que 0,9, indicando a capacidade de previsão de seca da RNA.

Belayneh et al. (2014) utilizaram os modelos ARIMA (estocástico), SVR (regressão) e RNA (redes neurais) para a previsão do índice de precipitação padronizado (SPI 12 e SPI 24) dentro da bacia do rio Awash da Etiópia. Eles usaram técnica em ondeletas para processar as entradas dos modelos. Os resultados indicaram que o modelo baseado em RNA foi melhor que os demais por apresentar maior coeficiente de determinação e menores erros médios quadrático e absoluto. Concluíram que mais estudos precisam ser feitos para determinar se

esta técnica para a previsão do SPI de longo prazo é adequada para outros locais com diferentes características físicas e climáticas.

Depiné et al. (2014) usaram RNA para preenchimento de falhas em dados horários de precipitação no estado do Rio Grande do Sul. Foi observado que a rede é capaz de efetuar o preenchimento seguindo os padrões e picos; porém, é necessário cuidado na entrada da rede, separando os dados para uma mesma estação climática.

Yang et al. (2014) fizeram uma abordagem com redes neurais (RNA) para simular a variação de um índice de seca híbrido (HDI). Este método permitiu a construção de cenários de secas futuras, consideraram um aumento de temperatura que aceleraria o degelo e levaria a uma diminuição de 14% das secas nas próximas décadas sobre a região da bacia do rio Tarim na Ásia Central.

3. MATERIAL E MÉTODOS

Foram utilizados neste estudo dados de precipitação pluviométrica mensal de 138 postos disponíveis no histórico da Agência Pernambucana de Águas e Clima (APAC) e que possuem dados atualizados. Dos quais foi possível formatar 57 séries consistentes, bem distribuídas espacialmente, dos anos de 1963 a 2015.

Alguns programas foram necessários no emprego desta metodologia, em que o Microsoft Excel serviu para o tratamento e análise das séries de dados, o SPSS para fazer as correlações estatísticas, o programa de linguagem R para o cálculo do SPI e o Matlab para a aplicação do modelo de Redes Neurais.

3.1. Área de estudo

O estado de Pernambuco está situado no Nordeste do Brasil e possui uma extensão de 98.311,616 km², contando com 185 municípios, em que 122 deles estão contidos no Semiárido, ou seja, 65,95% dos municípios, que correspondem a uma área de 86.710,000 km², num total de 88,20% de sua área (PEREIRA JR, 2007).

3.1.1. Hidrografia

As grandes bacias hidrográficas de Pernambuco possuem duas vertentes: Faz parte da bacia do Atlântico Nordeste Oriental e da Bacia do rio São Francisco. Os rios que escoam para o rio São Francisco formam os chamados rios interiores, cujos rios nascem em municípios limítrofes na divisa de estados da Região Nordeste; os rios que escoam para o Oceano Atlântico constituem os chamados rios litorâneos, fazem parte da bacia hidrográfica do Atlântico Nordeste Oriental, e quase todos nascem no Planalto da Borborema.

Os três maiores reservatórios de água de Pernambuco são: Reservatório Engenheiro Francisco Sabóia em Ibimirim, no sertão, na bacia hidrográfica do rio Moxotó; o Reservatório de Jucazinho, localizado na mesorregião do Agreste próximo ao município de Surubim, bacia do rio Capibaribe e a represa de Itaparica, na bacia do rio São Francisco, com vistas ao aproveitamento hidroelétrico do rio. A usina de Itaparica é uma das maiores usinas

hidrelétricas do Brasil e além desses reservatórios existe um conjunto de reservatórios distribuídos por todo o estado.

Na Região Metropolitana do Recife há poucos lagos e reservatórios, com destaque para os reservatórios de Tapacurá e Pirapama. Além do rio São Francisco, os principais rios de Pernambuco são: Brígida, Pajeú, Moxotó, Ipanema, Capibaribe, Ipojuca, Una e Jaboatão.

3.1.2. Clima

O estado de Pernambuco possui a maior parte do seu território com clima semiárido, com poucas áreas chegando à classificação árida na região do Sertão do São Francisco. Já na parte leste, região do Litoral, o clima varia entre úmido e subúmido. Algumas áreas de transição no Agreste e extremo noroeste do estado apresentam clima subúmido seco. A Figura 7 mostra a classificação espacial do clima segundo Thornthwaite, baseado no índice hídrico (Im).

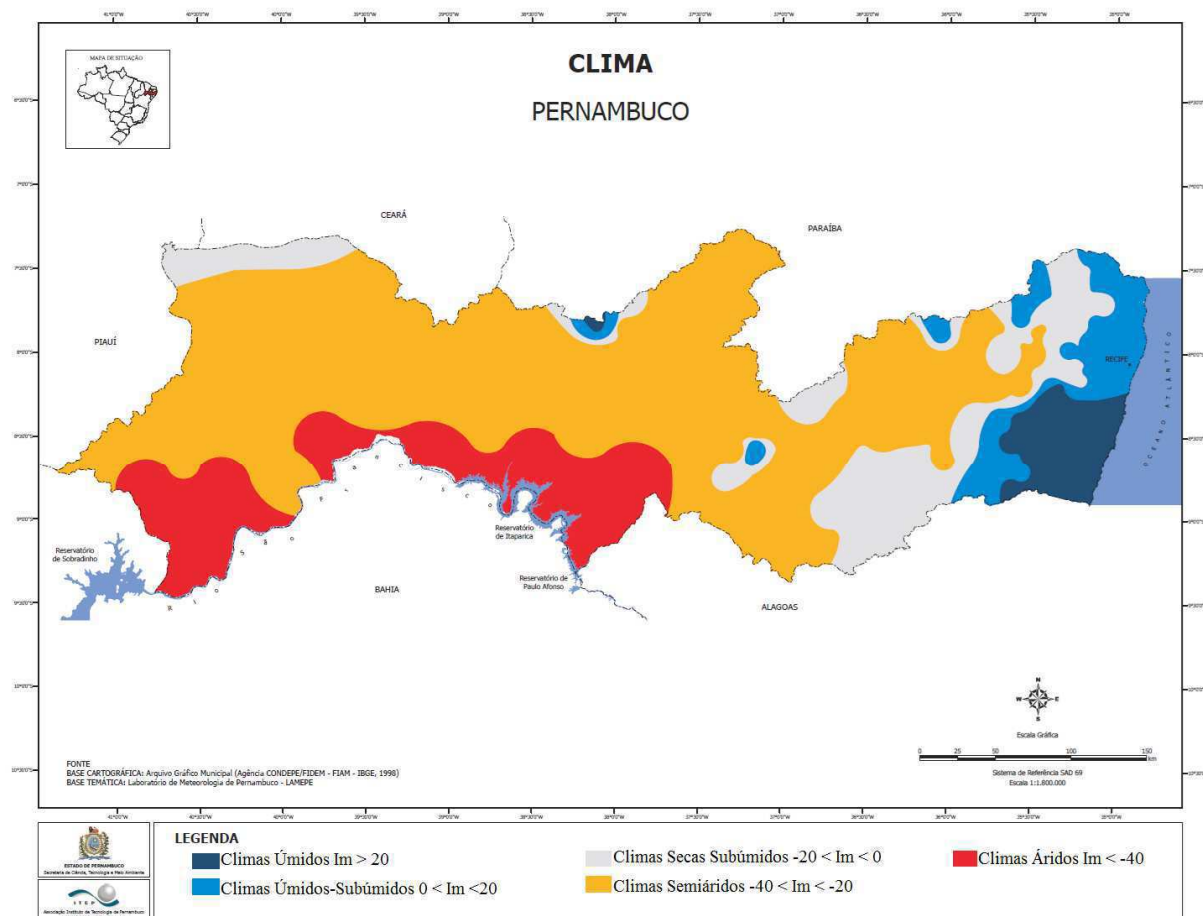


Figura 7. Classificação climática para o estado de Pernambuco.

Fonte: SRHE, Secretaria de Recursos Hídricos e Energéticos de Pernambuco (2013).

O Litoral apresenta baixa amplitude térmica, com temperatura média anual em torno dos 25 °C, no inverno entre 20 °C e 27 °C e no verão de 22 °C a 31 °C. A estação meteorológica do Recife apresenta evaporação anual (Piche) de 1163 mm, variando mensalmente de 64 mm a 130 mm entre inverno e verão, respectivamente. A umidade relativa média compensada varia de 73% a 85%. Com a intensidade média do vento variando de 2,23 m/s em maio a 3,26 m/s em setembro, e direção do vento variando entre 108 e 152 graus. Já as chuvas acima de 1 mm ocorrem em 171 dias por ano em média.

No Agreste existem áreas com orografias mais acentuadas que apresentam características climáticas diferentes, enquanto que na parte meridional as médias das temperaturas mínimas no inverno chegam a 15,6 °C em Garanhuns e na parte setentrional as mínimas médias atingem 18,2 °C em Surubim. Já as temperaturas máximas têm médias variando de 28 °C em Garanhuns a 32 °C em Surubim. A evaporação anual de 1082 mm em Garanhuns (40 a 140 mm mensalmente) e de 1695 mm em Surubim (72 a 205 mm mensalmente). A umidade relativa média compensada varia de 72% a 92% em Garanhuns e de 70% a 85% em Surubim. A intensidade do vento em Garanhuns passa de 3,2 m/s a 4,3 m/s entre abril e novembro, e Surubim registra de 2,8 m/s a 3,7 m/s no mesmo período. Em toda a região nos meses de inverno a direção do vento fica de sudeste (147 graus) e no final da primavera fica de leste (90 graus). Enquanto que o número de dias com chuva acima de 1mm por ano varia de 115 dias em Garanhuns e 80 dias em Surubim.

O Sertão apresenta a maior amplitude térmica com temperaturas mínimas médias em 16 °C e máximas médias em 36 °C, entre inverno e final da primavera, respectivamente. Na estação de Petrolina (extremo sudoeste) a evaporação anual registra mais de 3000 mm (172 a 345 mm mensalmente), umidade média compensada variando 48% a 70%. E registrou em média apenas 43 dias por ano com chuva acima de 1 mm. A intensidade do vento no Sertão varia bastante para cada área, com locais registrando médias mensais abaixo de 1,6 m/s (Petrolândia, Floresta) e outros com médias mensais acima dos 5 m/s (Petrolina). Em todos os casos a direção média é de Sudeste (130 graus).

3.1.3. Relevo

O estado tem altitude crescente entre o Litoral e o Planalto da Borborema, na parte leste, e também do Vale do São Francisco até os limites com a Paraíba e Ceará na parte central e oeste. As três principais áreas são Baixa Litorânea, Planalto da Borborema e Depressão Sertaneja. A Baixa Litorânea tem altitude abaixo dos 200 m, apresentando relevo peneplano (mamelonar), aumentando significativamente na região do Agreste devido à presença do Planalto da Borborema com média regional de 600 m e pontos que ultrapassam os 1.000 m de altitude. A região do Sertão é dominada pela Depressão Sertaneja, com média de 400 m, sendo que esta região tem relevo crescente de sul a norte, por influência da bacia do Rio São Francisco na parte sul e do Planalto da Borborema na parte nordeste (Sertão de Moxotó e Pajeú) e da Chapada do Araripe na parte noroeste. Com ponto máximo na cidade de Triunfo que atinge 1260 m no Pico do Papagaio. A Figura 8 detalha a distribuição espacial da orografia sobre todo o Estado.

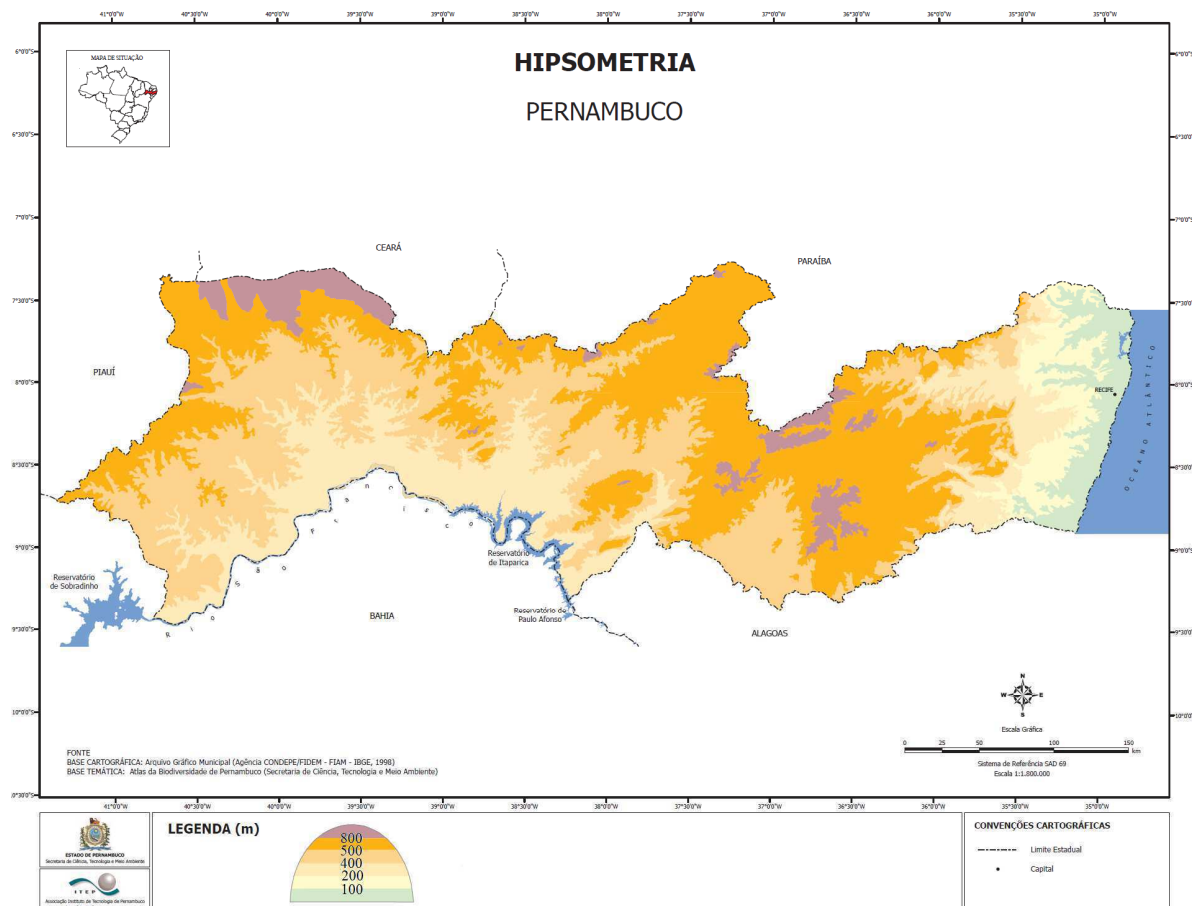


Figura 8. Espacialização do relevo do estado de Pernambuco.

Fonte: SRHE, Secretaria de Recursos Hídricos e Energéticos de Pernambuco (2013).

3.1.4. Regiões pluviometricamente homogêneas

De acordo com os dados de precipitação de 110 postos pluviométricos, Costa (2005) dividiu o estado de Pernambuco em oito mesorregiões com padrão mensal. A Figura 9 apresenta as delimitações de cada área, observa-se que o relevo apresentado na Figura 8 e o distanciamento do oceano Atlântico foram cruciais na definição dessas mesorregiões.

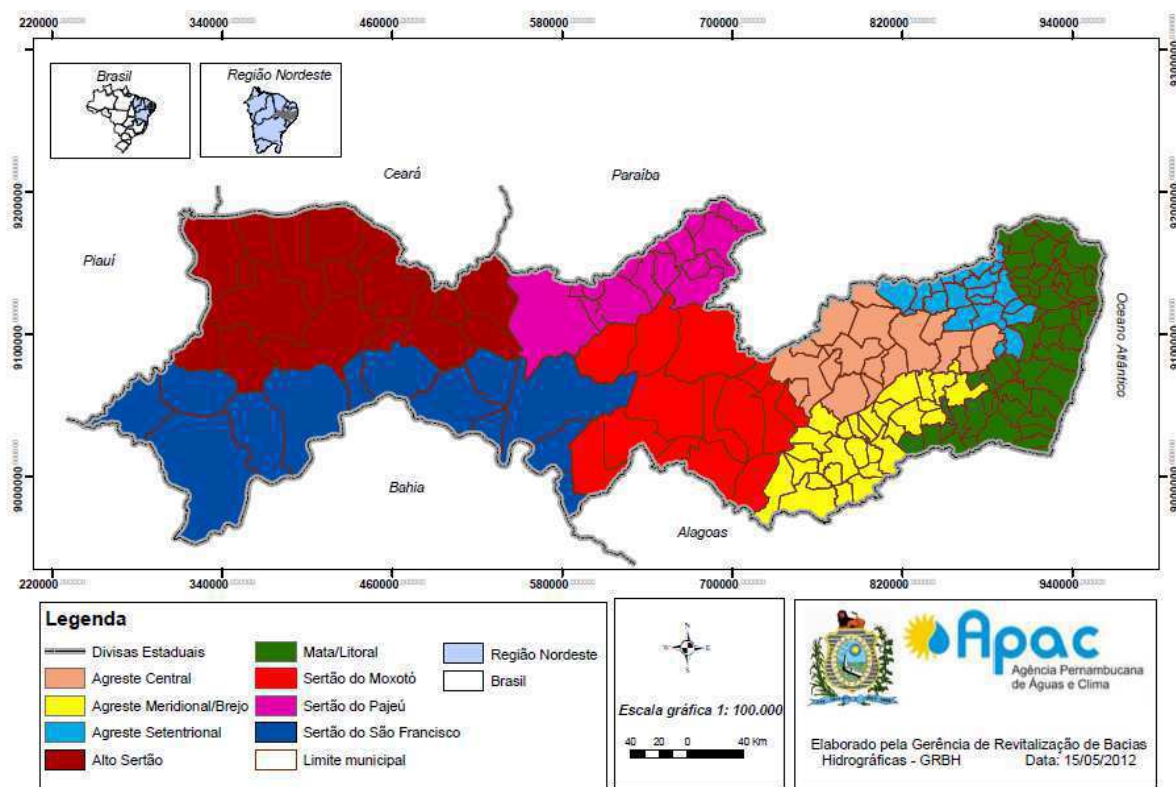


Figura 9. Regiões pluviometricamente homogêneas do estado de Pernambuco.
Fonte: Adaptado de Santos (2011).

No Litoral e Zona da Mata, as áreas de planície e aquelas próximas ao Oceano Atlântico, têm maior disponibilidade de umidade, através de nuvens quentes (baixo nível), canais de umidade, Distúrbios Ondulatórios de Leste (DOL) e pulsos da Zona de Convergência Intertropical (ZCIT), além da influência da Brisa Marítima. Portanto, essas áreas supracitadas possuem o melhor regime pluviométrico do estado, com maiores valores acumulados de chuva com média anual de 1480 mm e distribuição temporal da precipitação mais regular.

O Agreste fica subdividido em três mesorregiões, Agreste Setentrional, Central e Meridional. Esta região recebe os impactos dos mesmos sistemas meteorológicos citados na região anterior, porém de forma menos intensa e menos frequente, haja vista a perda de

massa/energia sobre o continente. O Agreste apresenta orografia acentuada, em algumas áreas ocorrem brisas de vale-montanha e ainda sistemas convectivos locais. Os totais pluviométricos chegam a 800 mm na área Setentrional e Meridional e apenas a 563 mm na área Central do Agreste. Essa redução é justificada principalmente pelas alterações orográficas mais irregulares e avançadas do Planalto da Borborema nesta área.

No Sertão há um aumento gradativo da precipitação de sul para norte. O mesmo ocorre com a orografia (Figura 8), porém, os sistemas meteorológicos são diferentes; a parte norte tem impactos diretos e efetivos da ZCIT, que não atinge com a mesma intensidade todo o Sertão. Já a parte sul tem influência da Zona de Convergência do Atlântico Sul (ZCAS) e resquícios de frentes frias, que ocorrem com menor frequência e intensidade por não se deslocarem mais para norte.

O sistema meteorológico denominado Vórtice Ciclônico de Altos Níveis (VCAN) pode provocar precipitações sobre todas as áreas, a depender da posição e deslocamento da sua borda (periferia), mas ele é fundamental para a região do Sertão, pois, é considerado crucial na definição da qualidade do início da estação chuvosa, uma vez que ocorrência é predominantemente no verão.

Os acumulados da precipitação mensal sobre cada mesorregião, com destaque para a quadra chuvosa estão na Tabela 2, assim como os totais anuais.

Tabela 2. Distribuição mensal da precipitação (mm/mês) por cada região homogênea

	<i>Alto Sertão</i>	<i>Sertão do Pajeú</i>	<i>Sertão do São Francisco</i>	<i>Sertão do Moxotó</i>	<i>Agreste Central</i>	<i>Agreste Meridional</i>	<i>Agreste Setentrional</i>	<i>Zona da Mata e Litoral</i>
Janeiro	98,4	79,4	90,9	59,4	39,4	41,6	40,8	68,7
Fevereiro	105,2	107,4	83,0	71,2	52,9	50,7	54,6	87,4
Março	143,5	153,7	124,3	110,7	92,2	82,3	92,9	149,1
Abril	96,7	132,2	70,8	91,6	86,8	95,9	105,9	185,0
Maio	34,8	70,1	28,0	72,8	63,2	102,6	106,4	201,0
Junho	16,1	39,9	17,3	73,2	72,3	128,2	140,2	244,4
Julho	10,9	30,8	11,5	65,8	64,3	127,1	136,7	233,3
Agosto	3,8	10,0	4,5	31,0	30,3	68,4	67,6	124,2
Setembro	5,4	6,2	5,8	17,3	15,4	42,5	40,7	76,7
Outubro	10,9	8,5	11,4	14,9	11,1	19,5	17,0	35,5
Novembro	28,7	14,7	39,0	19,6	11,3	15,5	15,5	32,5
Dezembro	25,5	35,4	64,4	38,4	24,4	26,4	26,4	42,6
Total								
Anual	579,9	688,3	550,9	665,9	563,6	800,7	844,7	1480,4
Quadra Chuvosa	443,8	472,7	369	348,3	314,5	453,8	489,2	863,7

Fonte: SANTOS (2011).

3.2. Cálculo do Índice de Precipitação Padronizado (SPI)

As equações e o procedimento utilizados para calcular o SPI foram definidos de acordo com os seguintes passos (DOMINGOS, 2006):

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 (para toda 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:

$$g(x) = \frac{1}{b^a \Gamma(a)} x^{a-1} e^{-x/b} \quad [1]$$

em que $a > 0$ é o parâmetro de forma; $b > 0$ é o parâmetro de escala e $x > 0$ é a quantidade de chuva precipitada. A função matemática Gama é dada por:

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

Os parâmetros a e b da função densidade de probabilidade Gama são estimados para cada estação e escala de tempo de interesse. Para estimativa dos parâmetros a e b , utilizam-se as soluções de Máxima Verossimilhança, estimados pela aproximação de Thom (1958), qual seja:

$$\hat{a} = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \quad \text{em que } A = \ln(\bar{x}) - \frac{\sum_i^n x_i}{n}, \quad \text{e, } \hat{b} = \frac{\bar{x}}{\hat{a}}$$

n é o número de observações da amostra e \bar{x} é o valor médio dos dados de chuva.

Os parâmetros resultantes serão utilizados para obtenção da probabilidade de chuva para um determinado mês e para o período de tempo desejado para o posto em estudo. Logo, a função acumulada de probabilidade Gama é dada por:

$$G(x) = \frac{1}{\Gamma(\hat{a})} \int_0^x t^{\hat{a}-1} e^{-t} dt \quad [3]$$

A função Gama $\Gamma(a)$ não é definida para $x = 0$, mas como a amostra dos dados de precipitação pode conter zeros, a probabilidade acumulada mista, $H(x)$ é dada da seguinte forma:

$$H(x) = q + (1 - q)G(x) \quad [4]$$

onde q é a probabilidade de ter um zero na amostra analisada. Se m for o número de zeros numa série de precipitação, Thom (1958) estipulou que q pode ser estimado por m/n .

Usando uma aproximação descrita em Abramowitz and Stegun (1965) que converte a probabilidade cumulativa na variável aleatória normalizada (Z), tem-se:

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

$$Z = SPI = + \left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \quad \text{para } 0,5 < H(x) \leq 1,0 \quad [6]$$

Em que, $c_0 = 2,515$; $c_1 = 0,803$; $c_2 = 0,010$; $d_1 = 1,433$; $d_2 = 0,189$; $d_3 = 0,001$;

$$\text{em que } t = \sqrt{\ln\left(\frac{1}{(H(x))^2}\right)} \quad \text{para } 0 < H(x) \leq 0,5 \quad [7]$$

$$\text{e } t = \sqrt{\ln\left(\frac{1}{(1-H(x))^2}\right)} \quad \text{para } 0,5 < H(x) \leq 1,0 \quad [8]$$

A Tabela 3 apresenta a classificação adotada neste trabalho para a classificação dos períodos secos ou chuvosos do índice SPI com a respectiva probabilidade de ocorrência.

Tabela 3. Classificação do índice SPI e sua probabilidade de ocorrência.

Classificação do SPI		
Valor do SPI	Categoria	Probabilidade %
$\geq 2,00$	Chuva extrema	2,3
1,99 a 1,50	Chuva severa	4,4
1,49 a 1,00	Chuva moderada	9,2
0,99 a 0,50	Chuva fraca	15,0
0,49 a -0,49	Normal	38,0
-0,50 a -0,99	Seca fraca	15,0
- 1,00 a -1,49	Seca moderada	9,2
- 1,50 a -1,99	Seca severa	4,4
$\leq - 2,00$	Seca extrema	2,3

Fonte: Mckee (1993), Hughes & Saunders (2002)

3.3. Análise de Agrupamento (Cluster Analysis)

O agrupamento dos dados foi utilizado com o intuito de identificar áreas homogêneas de impactos dos eventos críticos de forma simultânea e apontar padrões similares relativos aos efeitos das TSMs sobre a região. A técnica de Análise de Agrupamento escolhida foi à hierárquica, em que são produzidas sequências de partições em classes cada vez mais vastas, e a união de dois grupos numa determinada etapa produz um dos agrupamentos da etapa superior, o que caracteriza o processo hierárquico.

Na análise de agrupamento, todos os processos de hierarquização são similares, iniciando-se pela determinação da função de agrupamento. De acordo com Wilks (2006) esta função é usada como critério para medir a distância entre dois pontos x_i e x_j ou para estabelecer o quanto eles são parecidos. Aqui, para medir a dissimilaridade entre dois indivíduos x_i e x_j utilizou-se a distância euclidiana, expressada por:

$$d(x_i, x_j) = |x_i - x_j| = \left[\sum_{k=1}^n P_i (x_{i,k} - x_{j,k})^2 \right]^{1/2} \quad [9]$$

onde, $x_{j,k}$ representa os valores mensais dos locais x_i e x_j e P_i é o peso associado a cada indivíduo.

O método de Ward (1963) procura por partições que minimizem a perda associada a cada agrupamento. Essa perda é quantificada pela diferença entre a soma dos erros quadráticos de cada padrão e a média da partição em que está contido. A soma dos quadrados dos desvios de p indivíduos organizados em k grupos é definida como:

$$SQD = \sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2 \quad [10]$$

onde n é o número total de elementos do agrupamento e x_i é o n -ésimo elemento do agrupamento.

Nos métodos hierárquicos, o dendrograma que é a representação gráfica de uma árvore de classificação, representa a ordem em que os dados foram agrupados. A obtenção dos grupos pode ser feita pelo dendrograma a partir do critério da inércia e conhecimento prévio da região em estudo.

3.4. Correlação Linear entre os SPIs e TSMs

Obteve-se os dados das anomalias de TSMs do Oceano Pacífico Equatorial nas áreas conhecidas denominadas Niño 1+2 (0-10°Sul), (90°Oeste-80°Oeste); Niño 3 (5°Norte-5°Sul), (150°Oeste-90°Oeste); Niño 4 (5°Norte-5°Sul), (160°Leste-150°Oeste); Niño 3.4 (5°Norte-5°Sul), (170-120°Oeste) e do Oceano Atlântico, Tropical Norte – ATN (5-20°Norte, 60-30°Oeste); Tropical Sul - ATS (0-20°Sul, 30°Oeste-10°Leste) e também o Gradiente Meridional do Atlântico – MGRAD, além do IOS, todas do período base de 1950 a 2013.

Utilizou-se o método de correlação de Pearson (r) para fazer a associação linear entre os pares das variáveis. A significância estatística considera até 0,05 foi obtida pelo teste t-Student com N graus de liberdade correspondente aos anos da série histórica dos dados. Foram realizadas correlações entre as próprias as escalas do SPI (1 mês, 3 meses, 6 meses, 9 meses, 12 meses e 24 meses), também entre os SPIs com as TSMs e IOS.

3.5. Concepção da Rede Neural Artificial

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. Assim, serão selecionados quatro tipos de rede e testar seus desempenhos com as mesmas entradas, posteriormente, com o tipo definido, serão feitas novas rodadas com alterações nos algoritmos, seguido pelas funções de ativação e depois modificando a quantidade de camadas e neurônios. Toda a 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*).

A terceira 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, e 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.

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 (θ). 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 cálculo 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). A Figura 10 exemplifica a estrutura de uma rede, com pesos, viés e funções de ativação.

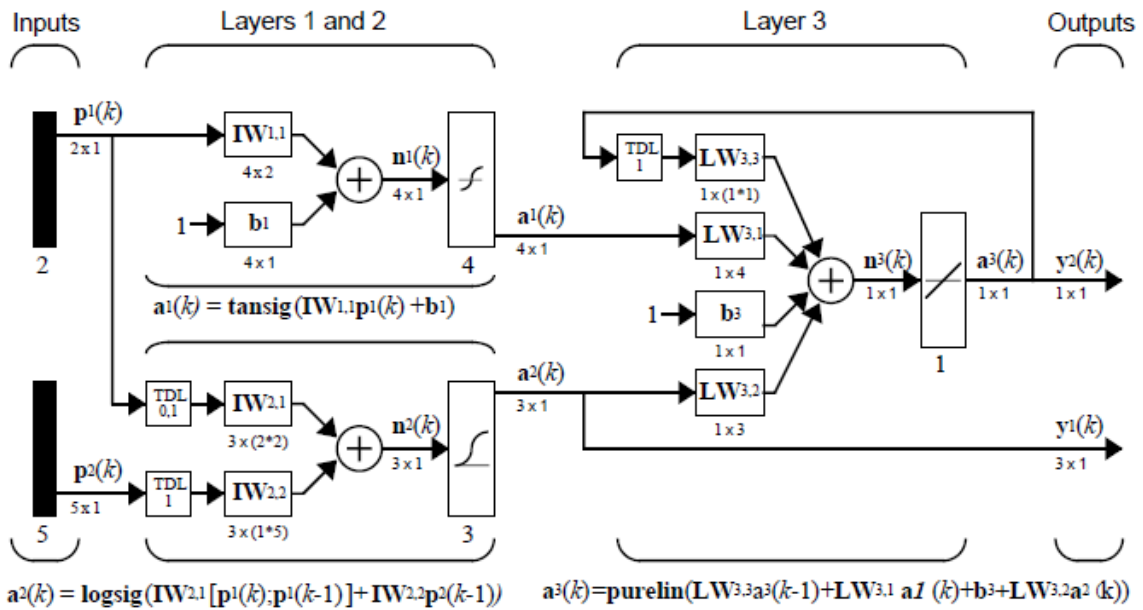


Figura 10. Configuração de uma rede neural com três camadas.
 Fonte: Demuth (2007).

O resumo dos procedimentos executados na metodologia pode ser verificado na Figura 11, em que a primeira caixa tem-se a escolha dos dados e cálculo do SPI e a segunda caixa com os passos da escolha do modelo final da RNA que será usado na previsão.

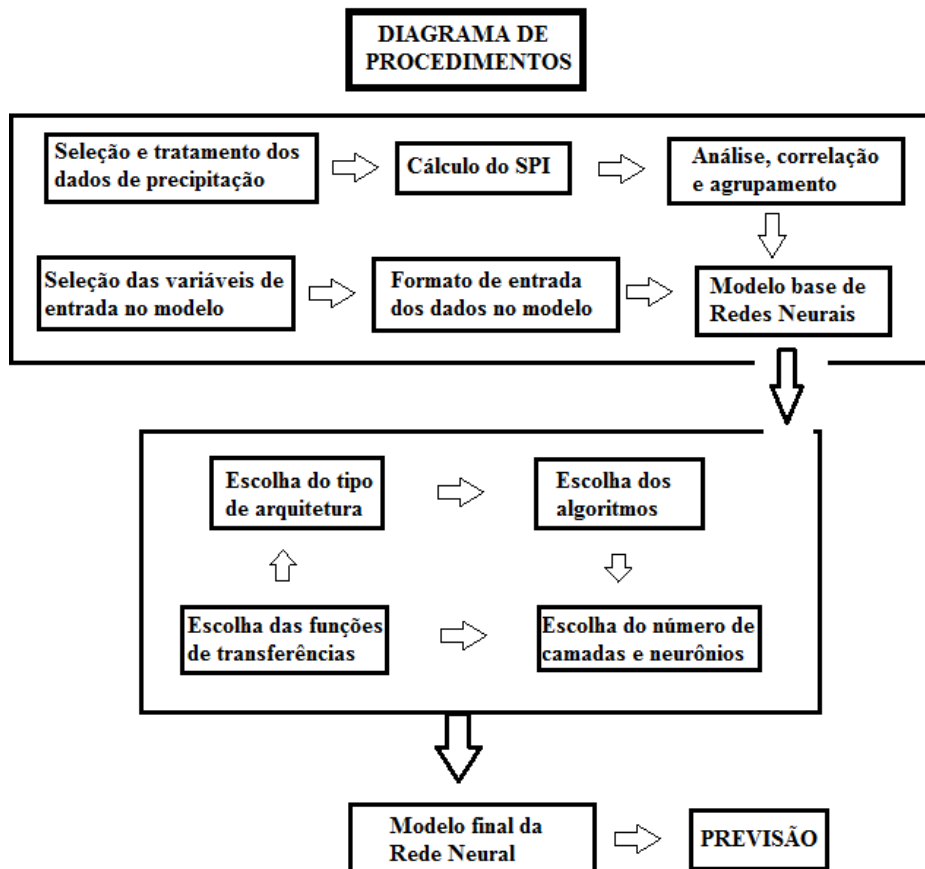


Figura 11. Diagrama com o resumo dos procedimentos da metodologia.

4. RESULTADOS E DISCUSSÃO

A análise espacial do total anual médio da precipitação para os pontos utilizados neste estudo pode ser observada na Figura 12, em que as maiores precipitações ocorrem na faixa leste entre o Litoral e a Zona da Mata, com valores acima dos 1000 mm/ano. No Agreste quase toda esta região está na faixa de 600 a 800 mm/ano, com pequenas áreas com acumulados menores na região homogênea do Agreste Central e outra faixa com acumulado acima dos 800 mm na região homogênea do Agreste Meridional. O Sertão é a região com maior variabilidade pluviométrica com faixas entre 400 e 500 mm/ano na área homogênea do São Francisco e acumulados acima dos 800 mm/ano em pequenas áreas do Alto Sertão e do Sertão do Pajéu.

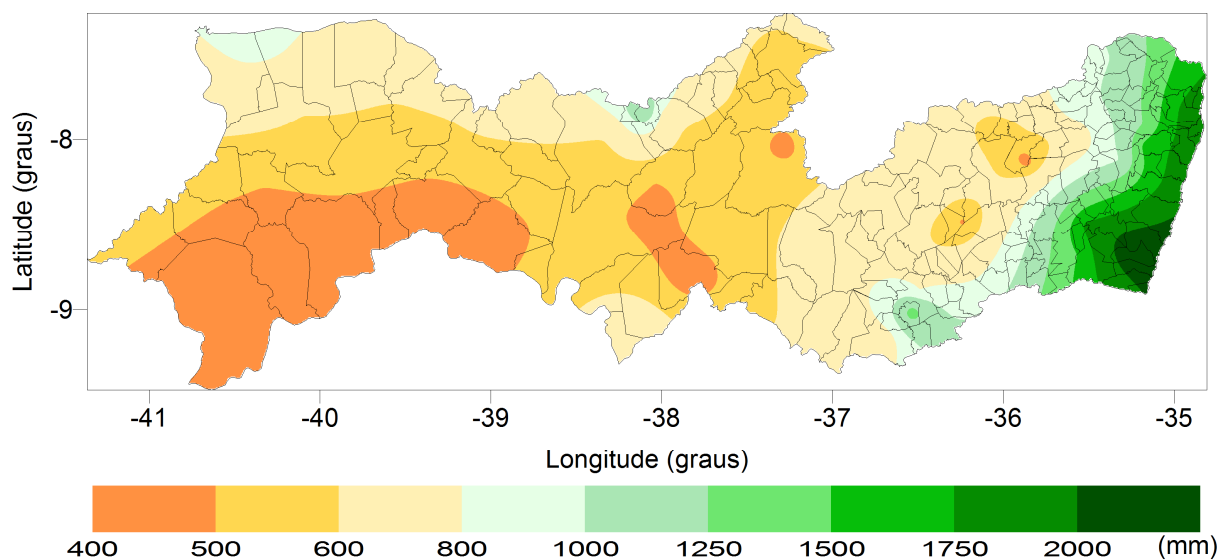


Figura 12. Distribuição espacial da precipitação média anual.

De todos os postos analisados foi possível selecionar 57 postos com dados consistentes, séries longas maiores que 50 anos e que fossem bem distribuídos espacialmente, ainda que algumas possuíssem falhas pontuais e poucos intervalos curtos (2 meses), sendo possível o preenchimento através de aproximação. Ainda assim, estas substituições de poucos meses e de forma pontual tem pouca interferência sobre o valor do SPI baseado em séries longas e com escalas diferenciadas. Na Tabela 4 se encontra a listagem de todos os postos utilizados neste trabalho, já na Figura 13 estão às localizações geográficas sobre o estado de Pernambuco, com numeração crescente a partir da sua posição longitudinal.

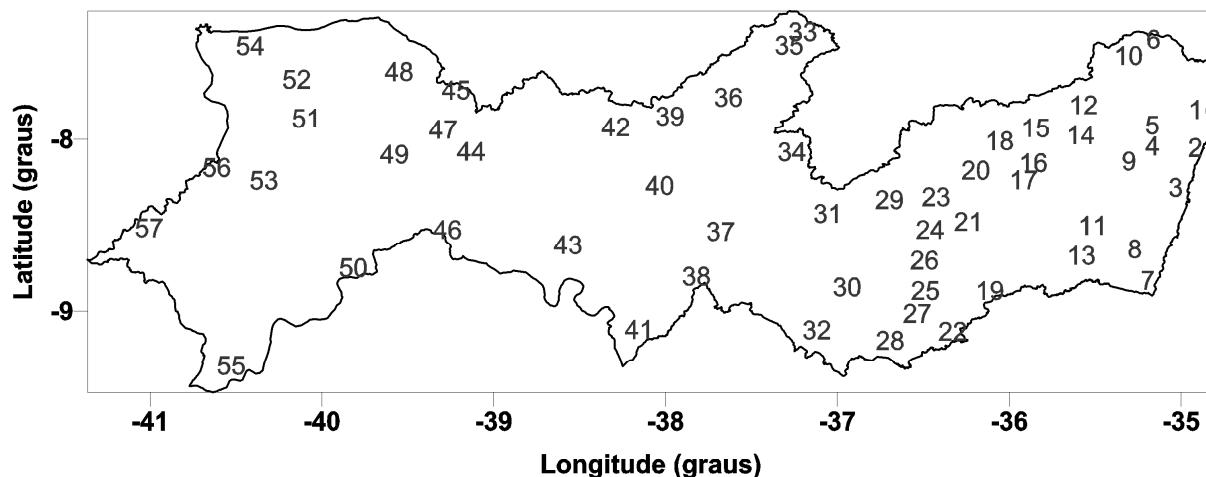


Figura 13. Distribuição espacial dos postos pluviométricos selecionados.

Tabela 4. Relação de postos selecionados e ordenados pela longitude.

Posto	Número	Posto	Número
Pesqueira	29	Pesqueira	29
Igarassu	1	Pedra	30
Recife	2	Arcoverde	31
Cabo	3	Águas Belas	32
São Lourenço da Mata	4	Itapetim	33
Paudalho	5	Sertânia	34
Itambé	6	São José do Egito	35
Barreiros	7	Afogados da Ingazeira	36
Rio Formoso	8	Ibimirim	37
Vitória do Santo Antão	9	Inajá	38
Timbaúba	10	Flores	39
Cortês	11	Betânia	40
Bom Jardim	12	Tacaratu	41
Palmares	13	Serra Talhada	42
Passira	14	Floresta	43
Frei Miguelinho	15	Salgueiro	44
Riacho das Almas	16	Cedro	45
Caruaru	17	Cabrobó	46
Toritama	18	Serrita	47
Canhotinho	19	Moreilândia	48
Brejo da Madre de Deus	20	Parnamirim	49
Cachoeirinha	21	Santa Maria da Boa Vista	50
Correntes	22	Ouricuri	51
Belo Jardim	23	Ipubi	52
São Bento do Uma	24	Santa Cruz da Venerada	53
Garanhuns	25	Araripina	54
Jucati	26	Petrolina	55
Brejão	27	Santa Filomena	56
Bom Conselho	28	Afrânio	57

Observa-se que a precipitação está diretamente relacionada com a posição geográfica e orográfica do estado indicada na Figura 8, o Litoral devido à proximidade do Oceano Atlântico, alta disponibilidade de umidade e também devido à convergência dos ventos alísios com a brisa terrestre, assim possui o regime pluviométrico com maiores acumulados e distribuição temporal regular, enquanto que no Agreste e em pontos isolados do Sertão, apesar da irregularidade, possuem acumulados maiores que o restante da região por influência do relevo acentuado. Por fim, a maior parte da região do Sertão e algumas áreas específicas no Agreste, possuem a maior irregularidade e os menores acumulados devido à ausência de relevo acentuado e suas posições geográficas mais para dentro do continente que reduzem a atuação de sistemas meteorológicos propulsores de precipitação, ficando estas áreas mais dependentes exclusivamente de sistemas de grande escala para o transporte de umidade e instabilidades.

A relação com a classificação climática da Figura 7 também é verificada uma vez que a precipitação é dependente das condições de umidade que são inversamente proporcionais à temperatura do ar, portanto, inferem diretamente no clima.

4.1 SPI médio da região para cada escala

Cada posto pluviométrico apresenta sua peculiaridade e sua alternância entre períodos chuvosos ou secos variando suas intensidades e durações, mas quando um evento é intenso sempre atinge áreas maiores e se for de caráter climático estes eventos são identificados em toda uma região e em qualquer escala temporal. Por isto, foi identificado através do SPI os eventos chuvosos e secos nas escalas temporais de 1 mês, 3 meses, 6 meses, 9 meses, 12 meses, 24 meses, 36 meses, 48 meses e 60 meses, para cada um dos pontos selecionados no estudo.

Verificou-se que o SPI das pequenas escalas de 1 e 3 meses varia rapidamente devido a característica natural das chuvas de alta variabilidade temporal, mas estas escalas podem identificar com maior exatidão o início e o fim dos eventos. Para verificar os eventos mais significativos sobre o Pernambuco, calculou-se o SPI médio de todas as escalas temporais, este valor representa os eventos que ocorreram de forma generalizada sobre a região em estudo, ou seja, os eventos encontrados no SPI médio são mais abrangentes e impactantes.

O SPI médio para a escala de apenas 1 mês está representado na Figura 14, na qual se verifica a alta variabilidade mensal e vários picos positivos e negativos de curta duração, mas também alguns com maior duração mesmo nesta escala temporal, implicando em meses consecutivos de déficit hídrico e indicando o início de eventos mais intensos. Observa-se que os finais dos anos de 1963, 1973 e 1984 tiveram valores positivos seqüenciais, estes eventos chuvosos só aparecerão em escalas maiores posteriormente e seus efeitos também serão sentidos depois e dependerão da duração nas demais escalas. Também é possível identificar eventos curtos, porém intensos, como no início de 2004 um pico de dois meses que é cessado rapidamente, mas que aparecerá em escalas maiores de forma atenuada, indicando efeitos diferentes sobre os recursos hídricos, agricultura e condições climáticas em relação aos outros anos. Do lado negativo pode-se fazer a mesma análise, e se identificar várias secas curtas, mas os principais déficits iniciaram no começo de 1993 e 1998 sendo entendidas nos meses seguintes. E também uma seca em 2012/2013 com dois picos negativos, mas não atenuada nos meses seguintes.




Figura 14. Distribuição da média do SPI-1 de todos os postos.

O aumento da escala temporal do SPI para uma análise trimestral (SPI-3) permitiu visualizar de forma mais clara as observações feitas na escala mensal, verificou-se a permanência dos eventos citados anteriormente e diminuiu a aleatoriedade da escala menor, conforme a Figura 15. O destaque nesta escala de 3 meses é que apontou melhor a intensidade dos eventos, pois ela acumulou valores seguidos de mesmo sinal, o que aumentou os picos destes eventos mais significativos, com valores do SPI-3 chegando aos 1,5 positivos sendo

considerado eventos de chuva severa de acordo com a classificação da Tabela 2. Na ponta negativa com valores de -2,0 considerados eventos de seca extrema, principalmente em 1993, porém, os efeitos sobre a região dependerão da duração e permanência desta intensidade em escalas maiores.




Figura 15. Distribuição da média do SPI-3 de todos os postos.

A análise do índice passou a ser semestral com o SPI-6, esta escala também é interessante por diagnosticar a quadra chuvosa e sua transição, a permanência de um evento crítico nesta escala temporal garante a informação da qualidade hídrica, pois valores significativos indicam que o regime pluviométrico foi comprometido ou favorecido. A Figura 16 indicou atenuação de muitos eventos apontados nas escalas menores devido à aleatoriedade das chuvas, mas os principais eventos citados anteriormente permaneceram e mantiveram sua intensidade, assim eles podem ser considerados eventos críticos. Também se destaca, além dos anteriores, no SPI-6 que alguns eventos classificados nas escalas menores como moderados, passaram para a categoria fraca nesta escala, mas em 1977, 1989 e 2002 ainda permaneceram na categoria de chuva moderada, enquanto que o ano de 1981 ficou identificado com uma seca moderada mais expressiva que os demais eventos positivos.




Figura 16. Distribuição da média do SPI-6 de todos os postos.

O SPI-9 engloba além do regime de precipitação natural, também os períodos de transição da região, porém, esta escala não apontou diferenças significativas em relação à escala semestral, basicamente definiu melhor a oscilação entre períodos positivos e negativos, mantendo os eventos mais críticos citados anteriormente nas categorias extremas, severas e moderadas. Na Figura 17 do SPI-9 o destaque ficou para a elevação de uma seca fraca do SPI-6 no final de 1983 para a categoria de seca moderada no SPI-9 durando até o início de 1984.




Figura 17. Distribuição da média do SPI-9 de todos os postos.

A escala anual indicada através do SPI-12 é a mais completa por englobar todo o regime pluviométrico de qualquer ponto, além dos eventos indicados aqui terem uma duração maior, os seus efeitos tem um impacto mais consistente sobre as áreas atingidas. Eventos

críticos nesta escala a partir da categoria moderada já condicionam o potencial agrícola e hídrico.

Observou-se claramente um atraso na identificação dos eventos através da Figura 18. Então, para esta análise é necessário ter o cuidado que o valor é referente ao acumulado dos 12 meses anteriores, por isto se identifica eventos de chuva moderada em 1964, 1974 em referência aos eventos iniciados em 1963 e 1973 encontradas nos SPIs de escalas menores. O maior evento médio de chuva foi em 1985 atingindo a categoria de chuva severa com intensidade de 1,518. Pelo lado negativo, as secas moderadas permaneceram e foram diagnosticadas no início dos anos de 1982 e 1984 devido ao acúmulo desta escala. Mas o destaque foram os anos de 1993 e 1998 com vários meses na categoria de seca extrema e também 2012 que chegou a categoria extrema durante 2 meses.




Figura 18. Distribuição da média do SPI-12 de todos os postos.

A escala de 2 anos representada pelo SPI-24 meses identifica déficits ou excessos prolongados, a sua base de comparação engloba duas estações chuvosas e duas estações secas. A Figura 19 mostra dois eventos positivos de categoria chuva moderada em 1975 e outro mais forte em 1985/1986. Enquanto que no lado negativo foram três eventos, sendo 1993 com categoria severa de forma menos persistente, 1998 com categoria extrema e persistente e 2013 com categoria severa.




Figura 19. Distribuição da média do SPI-24 de todos os postos.

4.2. Distribuições da escala anual de cada estação no SPI-12

Quando se avalia uma região é imprescindível que se tenha uma boa rede de observação, isto fica evidente na análise de pontos individuais, as características isoladas interferem diretamente na qualidade das chuvas de uma área. No SPI-12 para cada posto pluviométrico é possível observar valores mais intensos para determinados anos, com diferenças entre cada ponto mesmo que próximos um do outro.

De maneira geral nos postos mais a leste, localizados no Litoral, tiveram secas em 2013 menos intensas do que a de 1993, enquanto que em 1998 o evento seca foi a mais forte e prolongado. Destaca-se o posto de São Lourenço da Mata que foi o único em todo o estado a não reportar seca em 1993. A análise ponto a ponto facilita o entendimento da intensidade e classificação para áreas específicas através da evolução de cada escala temporal do SPI para o mesmo ponto.

As classificações anuais de cada posto selecionado, apontando comportamentos distintos entre as áreas e alguns eventos mais localizados, podem ser verificadas com o SPI-12 individualizado por ponto no apêndice deste trabalho.

Os postos pluviométricos de Brejo da Madre de Deus e Brejão chamaram atenção por possuírem vários períodos negativos seguidos na escala SPI-12. O posto de Brejo da Madre de Deus teve uma quantidade maior de secas consecutivas desde 1989 e o posto de Brejão com mais anos com seca a partir de 1981. Esta sequência de ocorrências só ocorreu nestes

dois postos e indicou que estes vêm apresentando déficits anuais de precipitação nas últimas décadas, e apresentarem menor quantidade de eventos chuvosos significativos.

É importante ressaltar que ocorreram precipitações acima da média em alguns meses nestes postos recuperando a situação de seca e retornando a normalidade, mas estas chuvas não foram suficientes para indicar um evento chuvoso nas escalas temporais maiores. As Figuras 20 mostram que ocorreram eventos chuvosos no SPI-1 e no SPI-3 no posto Brejo da Madre de Deus com frequência e intensidades significativas. O mesmo pode ser observado nas Figuras 21 para o posto de Brejão, porém com uma intensidade menor no SPI-3.




Figura 20. Distribuição temporal de Brejo da Madre de Deus, A: SPI-1 e B: SPI-3.

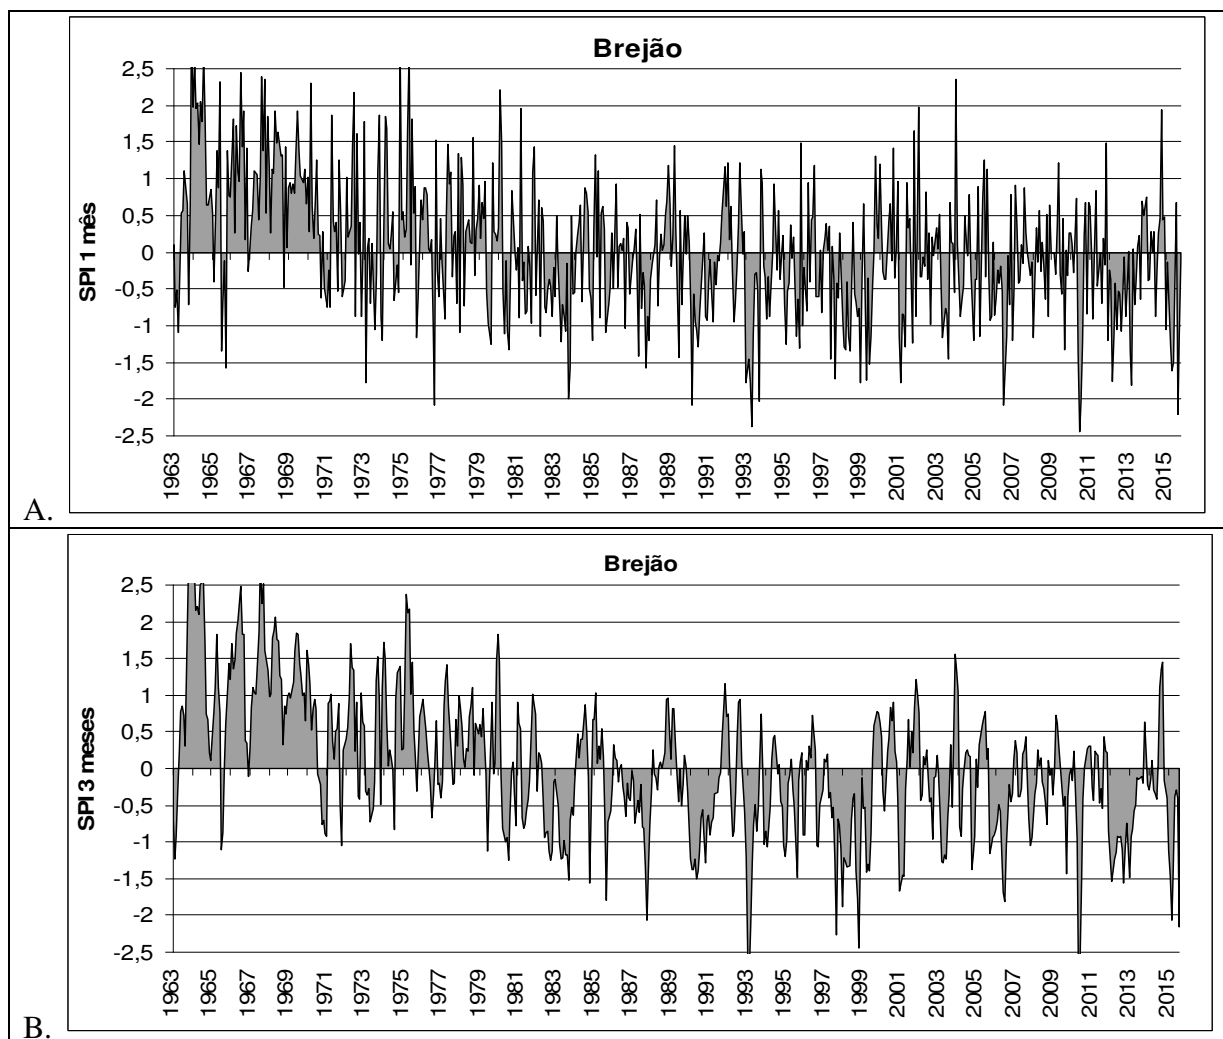


Figura 21. Distribuição temporal de Brejão, A: SPI-1 e B: SPI-3.

Uma observação interessante é perceber que o SPI além da detecção dos eventos extremos em anos ou meses específicos, ele também identifica anomalias nas séries, que podem representar erro de medição, falha no preenchimento dos dados ou até mesmo alterações no microclima destas áreas.

4.3 Correlações entre as médias das escalas do SPI

Como apontado nas análises anteriores, quanto maior a escala do SPI a identificação do evento crítico é adiado de acordo com os meses da escala. Por isto, é natural que escalas pequenas se correlacionem menos com as escalas maiores. Conforme a Tabela 5, feita uma correlação entre as escalas do SPI, verifica-se que a média do SPI-1 tem uma correlação

melhor com o SPI-3 e a pior relação com o SPI-24. Observe que a melhor correlação é sempre com a escala mais próxima e que quanto maiores forem às escalas melhor será a correlação, desta forma, a melhor correlação encontrada foi entre os SPI-9 e SPI-12, depois entre SPI-6 e SPI-9. Enquanto que, a correlação entre os SPI-3 e SPI-6 foi próxima da observada entre SPI-6 e SPI-12. Destaca-se que a escala do SPI-24 teve sua melhor correlação com o SPI-12, porém, com valor abaixo das demais citadas, devido à distância entre as escalas no tempo.

Tabela 5. Correlação entre as escalas temporais do SPI.

Escalas do SPI	Coeficientes de correlação				
	1 com 3	1 com 6	1 com 9	1 com 12	1 com 24
R	0,675	0,531	0,447	0,384	0,262
Escalas do SPI	3 com 6	3 com 9	3 com 12	3 com 24	
R	0,799	0,686	0,610	0,419	
Escalas do SPI	6 com 9	6 com 12	6 com 24		
R	0,881	0,797	0,572		
Escalas do SPI	9 com 12	9 com 24			
R	0,921	0,687			
Escalas do SPI	12 com 24				
R	0,776				

Esta análise mostra o efeito das escalas maiores do SPI sobre a suavização das séries, uma vez que seu comportamento se torna menos aleatório, há uma predisposição maior em encontrar correlações maiores com outros índices e variáveis.

4.4. Análise de agrupamento para várias escalas do SPI

Para entender melhor como se comportam os efeitos dos eventos extremos sobre o estado de Pernambuco e quais as estações que possuem índices semelhantes em cada escala temporal, foi feito o agrupamento de todos os postos através do método de Ward, com as escalas temporais do SPI-1 mês, SPI-3 meses, SPI-6 meses, SPI-12 meses e SPI-24 meses.

É possível identificar quais postos tem as relações mais próximas através da construção de dendrogramas. Quanto mais perto da base, maior o número de grupos e mais estreita é a associação entre os postos pertencente ao mesmo grupo. Assim, os primeiros grupos formados perto da base indicam uma relação direta e pode-se deduzir que aquelas estações têm o mesmo padrão de variação e intensidade dos efeitos climáticos.

As análises de dendrogramas para as escalas com horizonte temporal curto e longo são interessantes para observar se os postos permanecem no mesmo grupo em comparações mensal, trimestral, semestral, anual e até bienal e também indica quais as áreas do estado sobre efeitos semelhantes em eventos chuvosos e secos.

Observou-se o dendrograma de cada escala temporal e as subdivisões formadas para cada nível de homogeneidade entre os postos pluviométricos, considerou-se formatar até 8 grupos na região, mas as áreas só ficaram delineadas até 4 grupos, mas os grupos só ficaram definidos e semelhantes em todas as escalas do SPI, apenas na divisão em dois grupos, por isto, neste trabalho levou-se adiante a divisão em dois grupos para cada escala de tempo para buscar correlações com vários índices oceânicos.

O primeiro dendrograma para a escala mensal, representada pelo SPI-1 na Figura 22, indicou que os postos localizados no Sertão formaram o grupo 2 e o outro grupo 1 com os postos localizados entre o Agreste e o Litoral. Ainda é possível observar que nesta escala mensal os postos do grupo 2 (Sertão) têm maior associação que os do grupo 1, pois, se fossem formados três grupos, o grupo 1 seria dividido, separando a maior parte do Agreste dos postos mais a leste no Litoral. Em uma análise mais detalhada, observa-se que em cinco grupos mais similares, os postos remanescentes do Agreste se separariam da faixa litorânea, e os postos do Sertão central formariam um novo grupo separado de todo o oeste, compondo as áreas do Moxotó e Pajeú como faixa de transição para o grupo do Agreste. Estas novas áreas bem menores já poderiam ser chamadas de microrregiões.

Para os demais dendrogramas, representados nas Figuras 23 (trimestral), Figura 24 (semestral), Figura 25 (anual) e Figura 26 (bienal), comportamento semelhante pode ser observado na divisão de dois grupos. No SPI-3 a divisão até três grupos foi muito parecida com o SPI-1, porém, em cinco grupos já houve uma diferença nos postos do leste, separando a Região Metropolitana do Recife de uma nova área conhecida por Zona da Mata e parte do inicial do Agreste.

No SPI-6, a divisão em três grupos se destacou pelo fato do Sertão ser dividido primeiro, antes do Agreste e do Litoral, mostrando que o efeito de um evento seco ou chuvoso tem maior alternância entre as partes oeste e central do Sertão na escala semestral. Enquanto que no SPI-12, a formação de quatro grupos formaria o Sertão oeste, o Sertão Central, o Agreste e a faixa Litorânea, nesta escala anual o Litoral não se divide igual a semestral, mostrando que embora a parte leste possa sofrer com eventos climáticos em tempos diferentes, o balanço anual deve ter efeito parecido.

No SPI-24, o comportamento bienal indicou que a faixa litorânea sofre efeito parecido com as partes centrais e oeste na divisão de dois grupos, mostrando o Agreste com comportamento diferente do restante do estado. Quando se divide em três grupos o Litoral passa a formar o novo grupo, separado do Agreste e do Sertão, enquanto que a formação de quatro grupos separaria o Sertão Central, mas não ficaria bem definido, como nas escalas temporais menores do SPI.

SPI 1

***** H I E R A R C H I C A L C L U S T E R A N A L Y S I S *****

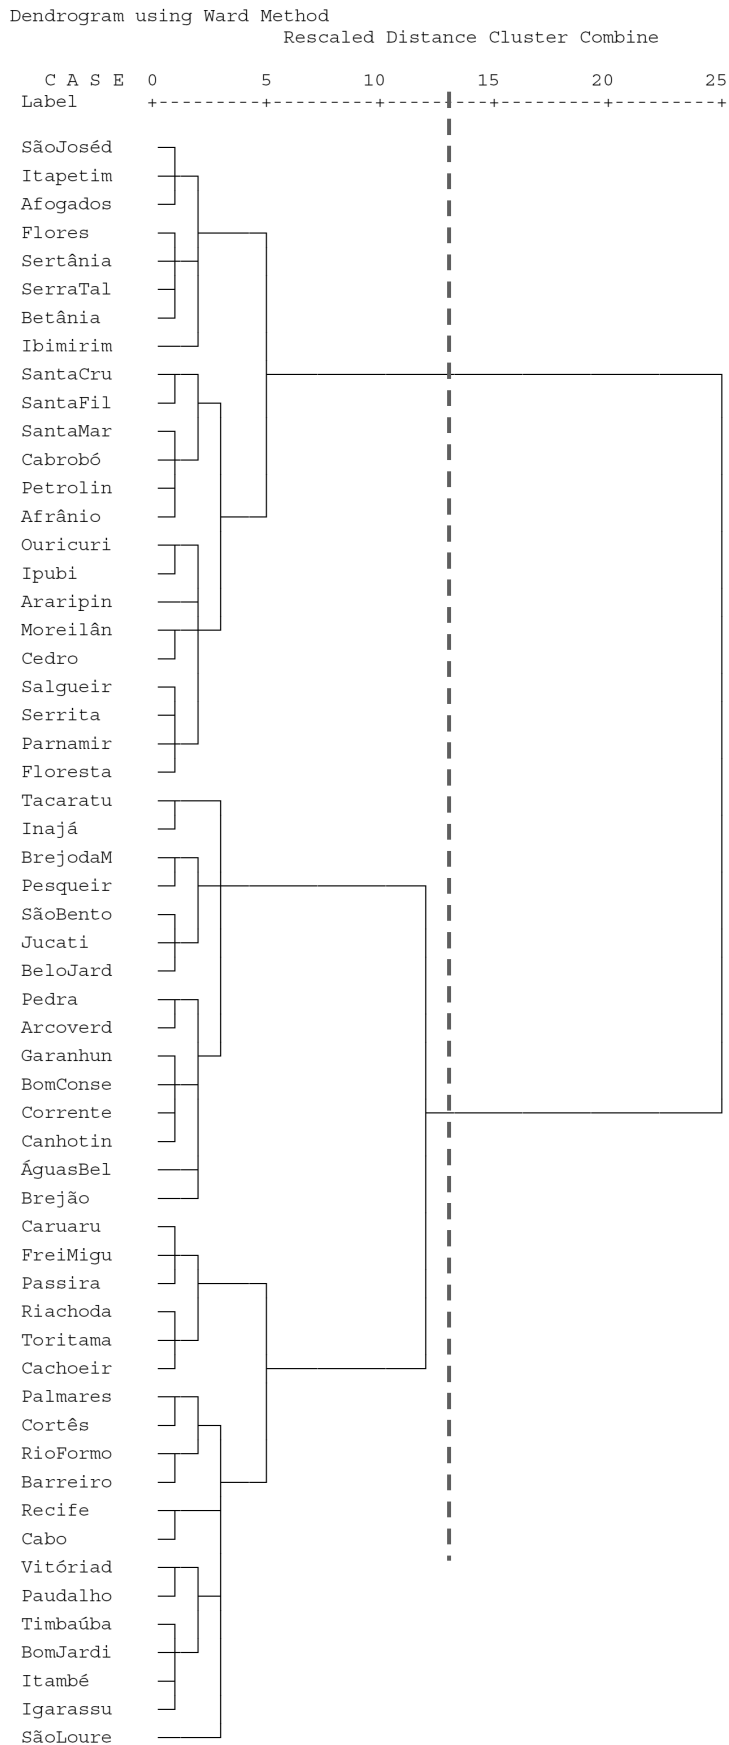


Figura 22. Dendrograma pelo método de Ward para o SPI-1.

SPI 3
 * * * * * H I E R A R C H I C A L C L U S T E R A N A L Y S I S * * * * *

Dendrogram using Ward Method

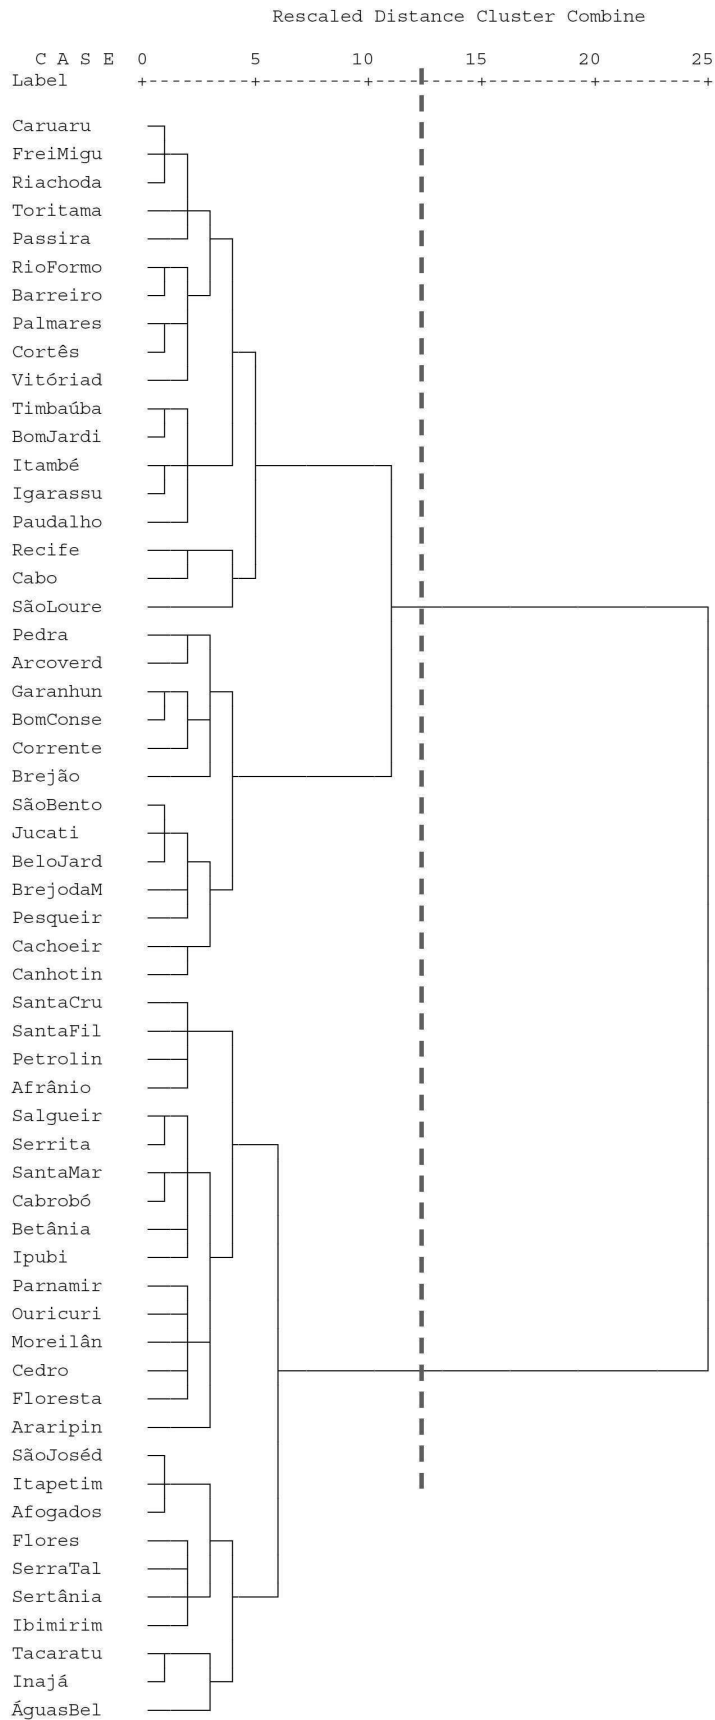


Figura 23. Dendrograma pelo método de Ward para o SPI-3.

SPI 6

***** H I E R A R C H I C A L C L U S T E R A N A L Y S I S *****

Dendrogram using Ward Method

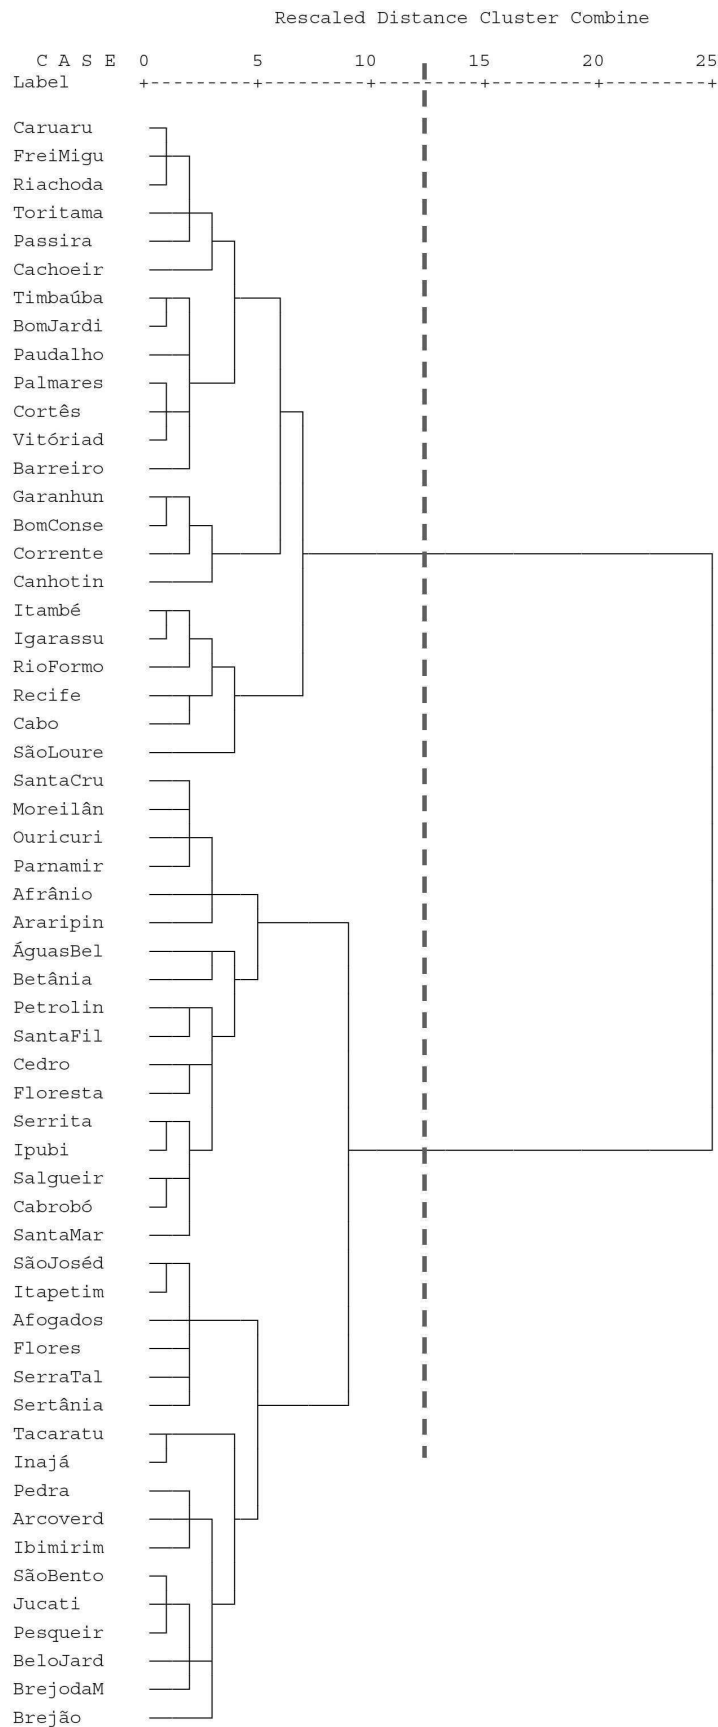


Figura 24. Dendrograma pelo método de Ward para o SPI-6.

SPI 12

***** H I E R A R C H I C A L C L U S T E R A N A L Y S I S *****




Figura 25. Dendrograma pelo método de Ward para o SPI-12.

SPI 24

***** H I E R A R C H I C A L C L U S T E R A N A L Y S I S *****

Dendrogram using Ward Method

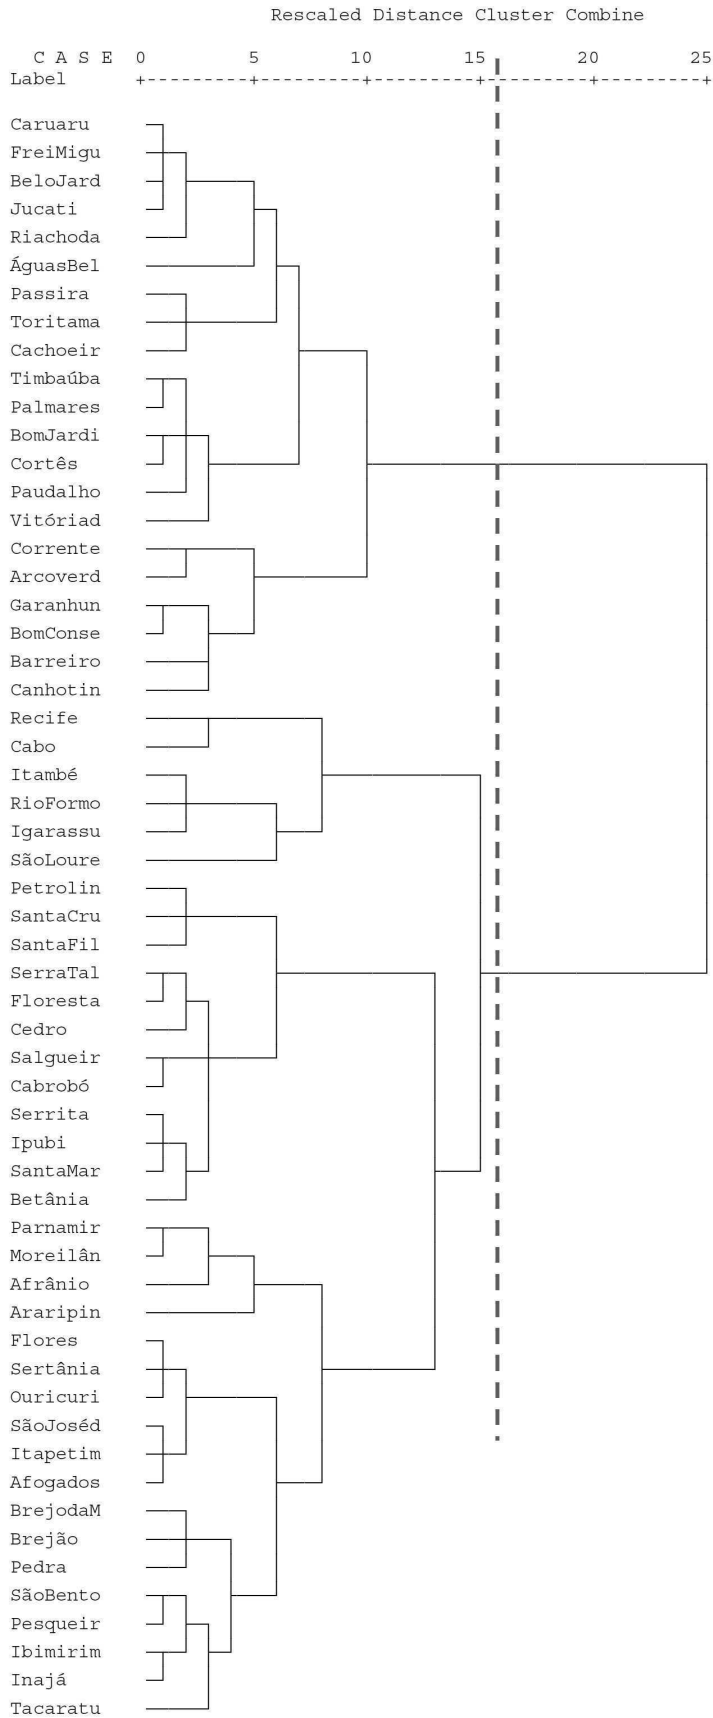


Figura 26. Dendrograma pelo método de Ward para o SPI-24.

As divisões em dois grupos do SPI em Pernambuco indicaram que à medida que a escala temporal fica maior, mais homogêneo se torna a distribuição espacial, conforme se verifica nas Figuras 27 a 31, o grupo 2 vai se espalhando em direção ao Litoral na parte leste. Ou seja, quanto maior a escala de tempo considerada para eventos extremos em uma região tem-se um padrão de comportamento mais generalizado e parecido com o Sertão, devido à suavização dos picos. Neste caso, o SPI-1 mostra alguns postos no início do Sertão com os mesmos efeitos do Agreste, como é o caso de Inajá, Tacaratu e Arcoverde. Mas, quando as escalas se tornam semestrais ou anuais, são postos do Agreste que passam a fazer parte do grupo do Sertão. Muito provavelmente pelas escalas maiores passarem a englobar, no mesmo intervalo de tempo, os períodos chuvosos de outros pontos, e assim o evento crítico passa a ocorrer simultaneamente em outras áreas e assim classificar estes pontos no mesmo grupo.

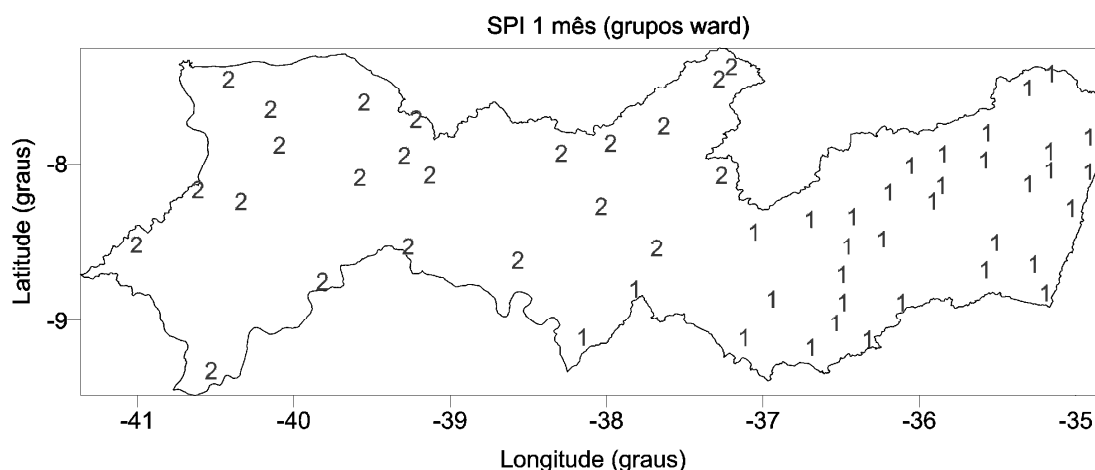


Figura 27. Distribuição espacial para dois grupos do SPI-1.

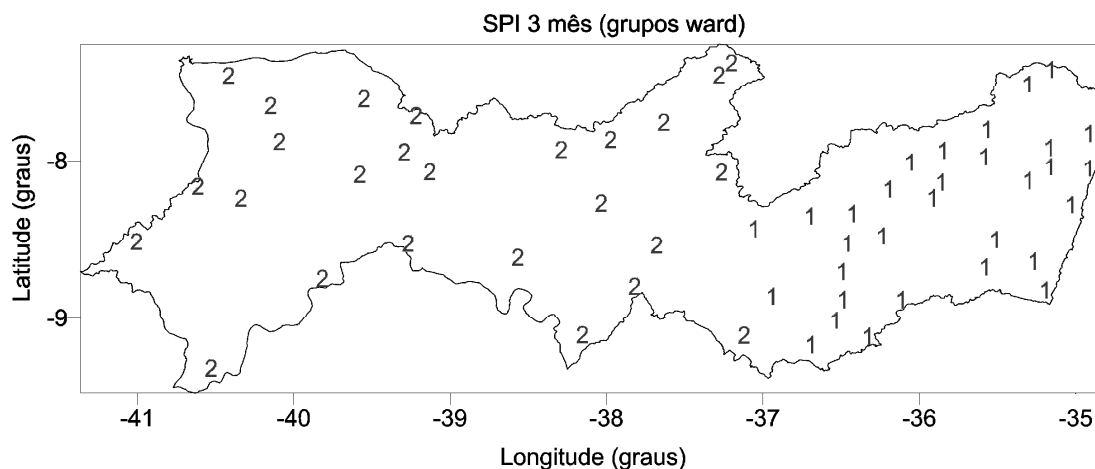


Figura 28. Distribuição espacial para dois grupos do SPI-3.

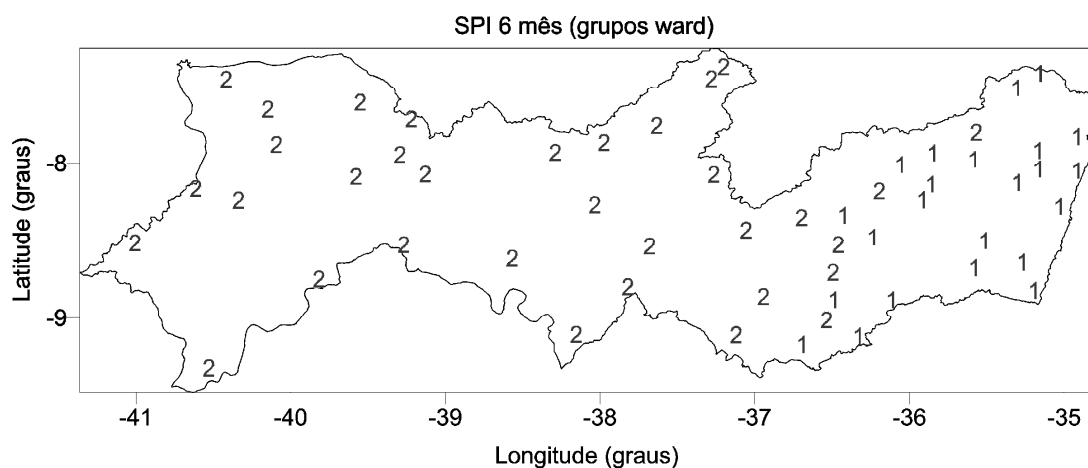


Figura 29. Distribuição espacial para dois grupos do SPI-6.

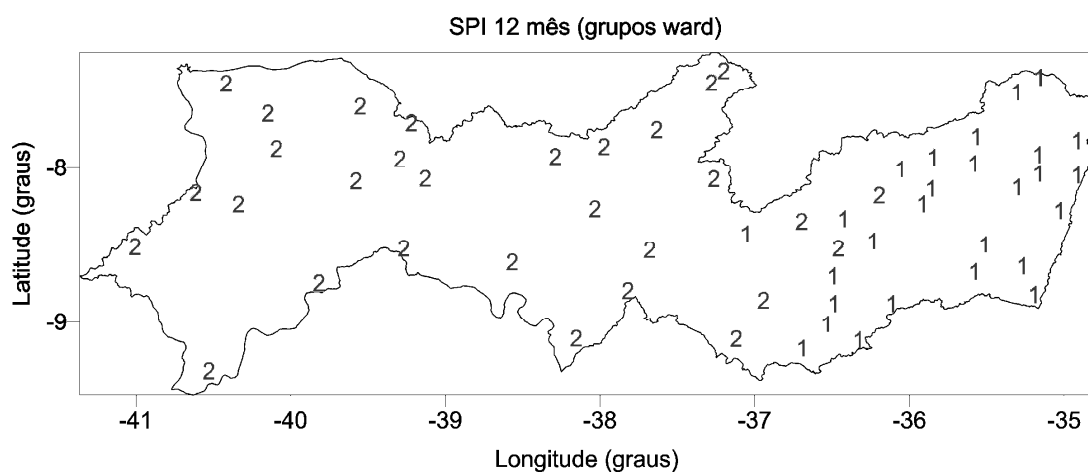


Figura 30. Distribuição espacial para dois grupos do SPI-12.

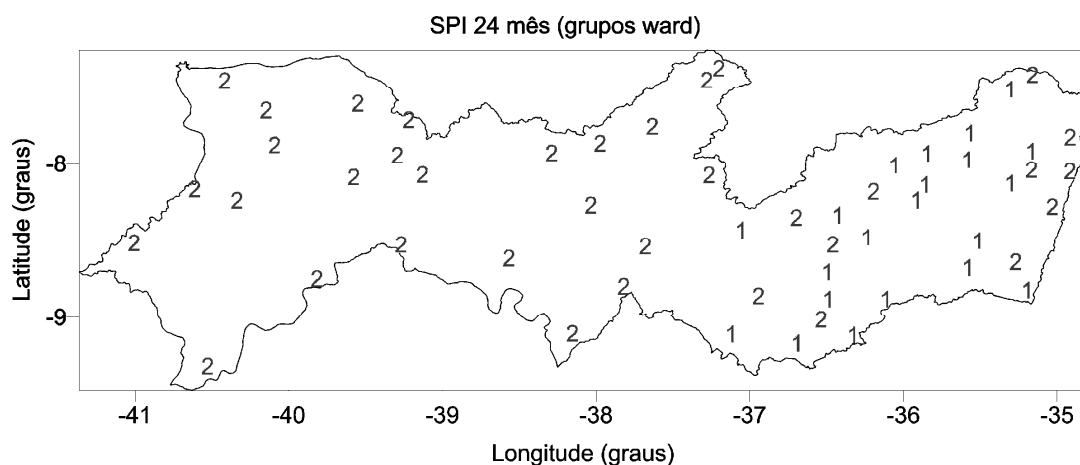


Figura 31. Distribuição espacial para dois grupos do SPI-24.

A identificação dos postos que ficaram nos grupos 1 ou 2 para cada escala temporal do SPI encontra-se no Tabela 6, com os postos ordenados longitudinalmente, assim é possível identificar rapidamente quais os postos mudaram de grupo com o aumento das escalas.

Tabela 6. Identificação dos postos na divisão em dois grupos para cada escala do SPI.

Posto	SPI 1	SPI 3	SPI 6	SPI 12	SPI 24
Igarassu	1	1	1	1	2
Recife	1	1	1	1	2
Cabo	1	1	1	1	2
São Lourenço da Mata	1	1	1	1	2
Paudalho	1	1	1	1	2
Itambé	1	1	1	1	1
Barreiros	1	1	1	1	1
Rio Formoso	1	1	1	1	2
Vitória do Santo Antão	1	1	1	1	1
Timbaúba	1	1	1	1	1
Cortês	1	1	1	1	1
Bom Jardim	1	1	2	1	1
Palmares	1	1	1	1	1
Passira	1	1	1	1	1
Frei Miguelinho	1	1	1	1	1
Riacho das Almas	1	1	1	1	1
Caruaru	1	1	1	1	1
Toritama	1	1	1	1	1
Canhotinho	1	1	1	1	1
Brejo da Madre de Deus	1	1	2	2	2
Cachoeirinha	1	1	1	1	1
Correntes	1	1	1	1	1
Belo Jardim	1	1	1	1	1
São Bento do Uma	1	1	2	2	2
Garanhuns	1	1	1	1	1
Jucati	1	1	2	1	1
Brejão	1	1	2	1	2
Bom Conselho	1	1	1	1	1
Pesqueira	1	1	2	2	2
Pedra	1	1	2	2	2
Arcoverde	1	1	2	1	1
Águas Belas	1	2	2	2	1
Itapetim	2	2	2	2	2
Sertânia	2	2	2	2	2
São José do Egito	2	2	2	2	2
Afogados da Ingazeira	2	2	2	2	2
Ibimirim	2	2	2	2	2
Inajá	1	2	2	2	2
Flores	2	2	2	2	2
Betânia	2	2	2	2	2
Tacaratu	1	2	2	2	2
Serra Talhada	2	2	2	2	2
Floresta	2	2	2	2	2
Salgueiro	2	2	2	2	2
Cedro	2	2	2	2	2
Cabrobó	2	2	2	2	2
Serrita	2	2	2	2	2
Moreilândia	2	2	2	2	2
Parnamirim	2	2	2	2	2
Santa Maria da Boa Vista	2	2	2	2	2
Ouricuri	2	2	2	2	2
Ipubi	2	2	2	2	2
Santa Cruz da Venerada	2	2	2	2	2
Araripina	2	2	2	2	2
Petrolina	2	2	2	2	2
Santa Filomena	2	2	2	2	2
Afrânio	2	2	2	2	2

A análise dos eventos críticos chuvosos ou secos pode ser feita de forma mais detalhada. Seja para um ponto específico ou para um grupo, em que para cada estação verifica-se o pico da intensidade do SPI, o tempo em que o evento permaneceu em cada categoria e sua variação em cada escala temporal. De maneira geral, ao comparar a evolução anual das três últimas grandes secas, ocorridas em Pernambuco para os dois grupos, usando o SPI de 12 meses, constatou-se que no Grupo 1 ocorreu uma seca mais intensa em 1998, com duração de 15 meses na categoria extrema. Por outro lado, as outras duas secas nesse grupo ficaram na categoria severa. No Grupo 2, os três eventos de secas chegaram na categoria extrema. O ano de 1993 apresentou um pico mais forte e quatro meses a mais de duração. A Tabela 7 exhibe as durações e as máximas intensidades ocorridas em cada ano para cada grupo.

Tabela 7. Duração e intensidade das piores secas de acordo com SPI-12.

Grupo 1 – SPI 12	
1993	7 meses na categoria severa, com pico -1,95 e 4 meses na categoria moderada
1998	15 meses na categoria extrema, com pico -2,54 e 6 meses na categoria severa
2012	3 meses na categoria severa, com pico -1,89 e 9 meses na categoria moderada
Grupo 2 – SPI 12	
1993	9 meses na categoria extrema, com pico -2,71 e 4 meses na categoria severa
1998	5 meses na categoria extrema, com pico -2,54 e 9 meses na categoria severa
2012	5 meses na categoria extrema, com pico -2,30 e 9 meses na categoria severa

A Figura 32 exhibe o histograma de frequência dos SPIs, de um a 24 meses. Cada uma das escalas do SPI apresentou variações pouco díspares. O grupo 1 apresentou uma distribuição mais igualitária com duas divisões na classificação normal em torno de 160 ocorrências e outras duas divisões nas categorias fracas com menos de 100 ocorrências. Já no grupo 2 a distribuição é mais desigual, tem uma categoria normal com cerca de 200 observações e uma outra em torno de 140 ocorrências, com um desequilíbrio entre o lado positivo e o negativo. É possível que essa diferença na configuração dos dois grupos seja devido à baixa variabilidade temporal e má distribuição da precipitação no grupo 2 (Sertão) quando comparada ao grupo 1 (Litoral e Agreste)

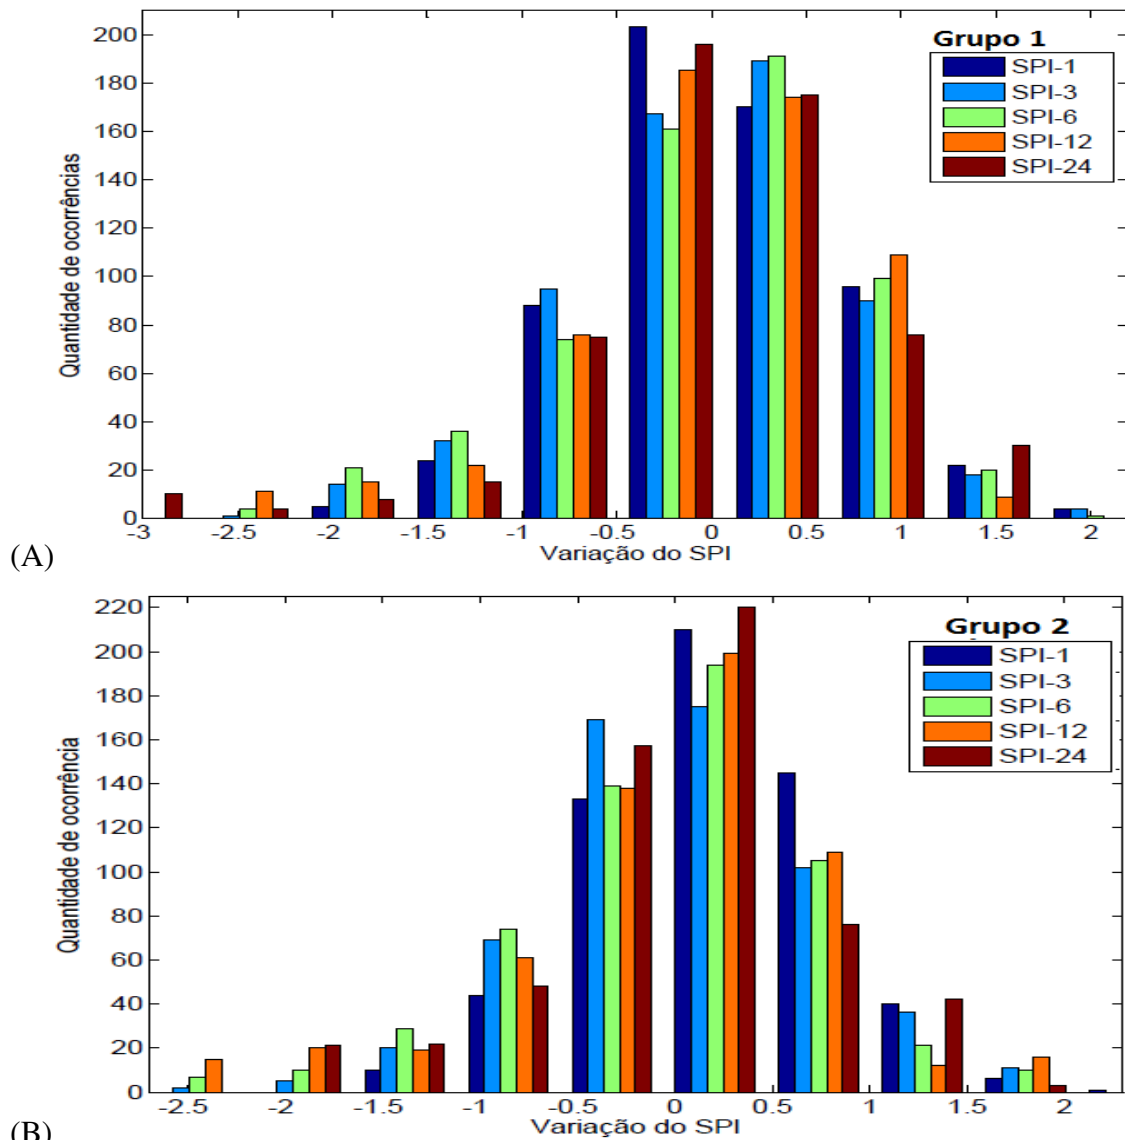


Figura 32. Histograma de frequência dos SPIs para diferentes escalas: (A) Grupo 1 e (B) Grupo 2.

A análise das variações do SPI nas escalas temporais maiores, respeitando a divisão de agrupamento inicial para o grupo 1 (regiões do Agreste e Litoral) e grupo 2 (Sertão), mostra que os eventos se tornam mais prolongados em uma determinada classificação do SPI quanto maior for a escala de tempo, ou seja, os ciclos temporais positivos e negativos ficam mais evidentes nos SPIs 24, 36, 48 e 60 meses. Este fato indica a influência de outros mecanismos mais duradouros sobre a precipitação do estado de Pernambuco, que entre algumas possibilidades está a ODP (Oscilação Decadal do Pacífico).

Em uma comparação generalizada entre os grupos 1 e 2, observa-se que a maioria dos eventos críticos ocorrem nos dois grupos, variando apenas a intensidade. Na Figura 33 para o SPI-12, no grupo 1 foi identificado com mais destaque os eventos chuvosos fracos nos anos

1992, 1994, 2001 e 2002, que ocorreram no grupo 2 como seca fraca. Já os eventos chuvosos de 1974 e 1986 foram mais intensos no grupo 2 atingindo a categoria de chuva severa, enquanto que no grupo 1 ficaram apenas nas categorias de chuva fraca e moderada.




Figura 33. Distribuição temporal do SPI-12 meses: (A) Grupo 1 e (B) Grupo 2.

A escala do SPI-24 meses mostrou, através da Figura 34, que os eventos críticos secos e chuvosos do grupo 2 foram mais intensos que os mesmos eventos na região do grupo 1, com exceção para o evento crítico de seca ocorrido em 1998 que foi mais significativo no grupo 1,

com valor próximo a -3 nesta escala de 24 meses, que significa um índice na categoria de seca extrema.




Figura 34. Distribuição temporal do SPI-24 meses: (A) Grupo 1 e (B) Grupo 2.

Na medida em que se considera uma escala maior do SPI, os eventos sequenciais de eventos positivos ou negativos começam a se unir e formar um único evento de maior duração, e assim deixa mais nítido os períodos de excesso ou déficit dos recursos hídricos de uma determinada área. A escala do SPI-36 meses apresentada na Figura 35 identifica de forma ainda mais clara que a escala de 24 meses, que os eventos de seca ocorrido nos anos de

1993 e 2012 foram mais significativos e impactantes para o grupo 2. E principalmente que o evento de seca iniciado em 2012 tem tido duração maior e se intensificado com o aumento da escala do SPI.

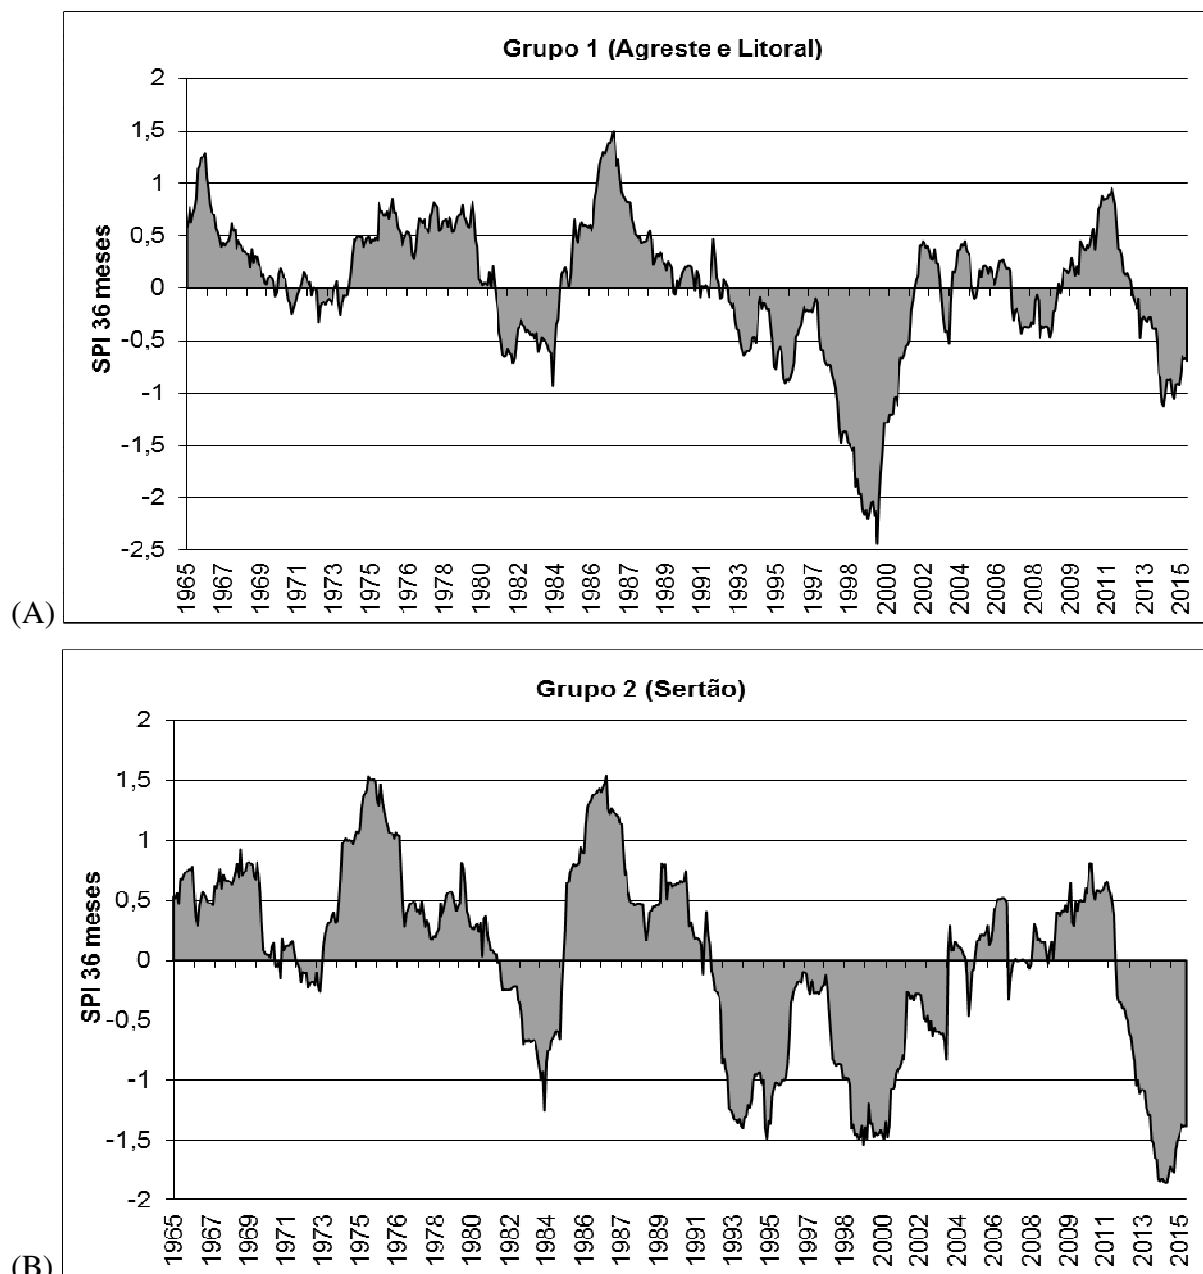


Figura 35. Distribuição temporal do SPI-36 meses: (A) Grupo 1 e (B) Grupo 2.

A escala do SPI-48 meses manteve todos os eventos encontrados nas escalas de 24 e 36 meses, apenas prolongou a duração dos mesmos. Nesta escala representada na Figura 36, a seca de 2012 se destacou mais ainda no grupo 2, enquanto que no grupo 1 esta seca ficou quase inalterada.




Figura 36. Distribuição temporal do SPI-48 meses: (A) Grupo 1 e (B) Grupo 2.

Com a evolução da escala temporal do índice SPI, alguns eventos críticos não sofrem alteração significativa, porém, com observações mais detalhadas identificam-se flutuações em suas intensidades e durações. A Figura 37 para acumulados de cinco anos ou SPI-60 meses unifica as secas de 1993 e 1998 de forma mais evidente que nas escalas anteriores. Em resumo são três grandes eventos chuvosos e três grandes eventos de seca prolongados.




Figura 37. Distribuição temporal do SPI-60 meses: (A) Grupo 1 e (B) Grupo 2.

As divisões pela Análise de Agrupamento apresentaram áreas relativamente definidas até quatro grupos, com exceção de um ou outro posto pluviométrico deslocado dos demais do seu grupo. Apenas o SPI de 24 meses mostrou postos com uma configuração de quatro grupos mais confusa. As divisões em mais grupos apresentaram maior mistura de postos nas áreas. A maior ou menor mistura dependeu da escala do SPI. Assim, as quatro sub-regiões delimitadas estão podem ser vistas na Figura 38. Nessa Figura os Grupos 3 e 4 representam o leste e o

oeste do estado, respectivamente. Por outro lado, que os Grupos 1 e 2 representam áreas de transição entre as regiões do Litoral e do Sertão.

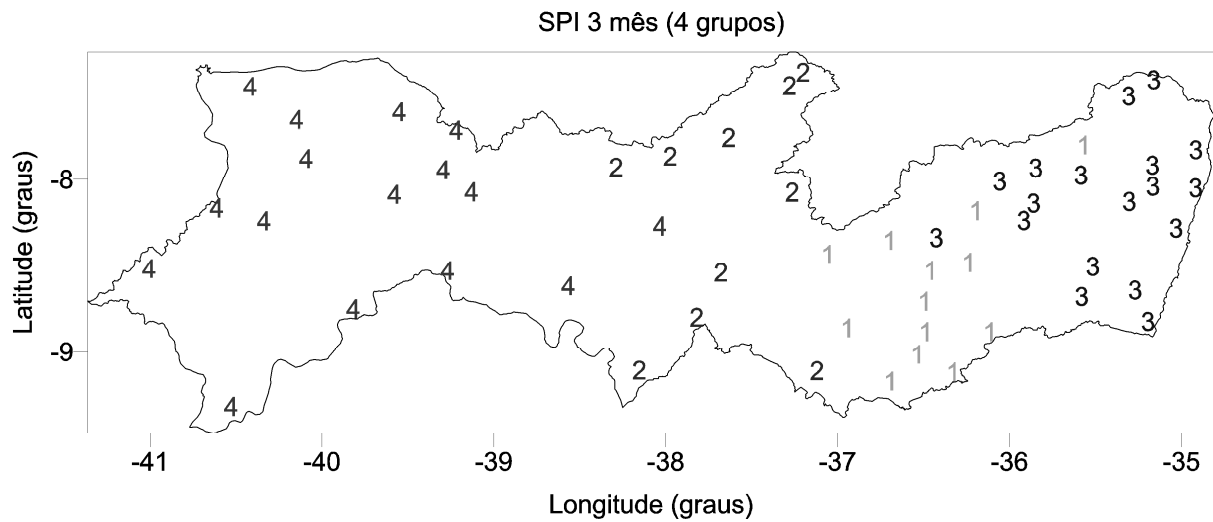


Figura 38. Distribuição espacial para dois grupos do SPI-24.

4.5. Relação entre as variáveis de entrada do modelo

Para verificar se há as relações entre as TSMs do Pacífico e do Atlântico, Mgrad e IOS, foram calculadas as correlações entre essas variáveis, comparando suas médias móveis nas ordens de 1, 3, 6, 12 e 24 meses em associação às escalas do SPI.

IOS (Índice de Oscilação Sul) apresentou forte correlação negativa com as quatro áreas do ENOS (El Nino Oscilação Sul), sendo - 0,65 para os Nino1+2 e Nino 4 e próximo a - 0,8 para os Nino 3 e Nino 3.4. Todos com significância estatística menor que 0,01. Também o IOS apresentou baixa correlação positiva com o oceano Atlântico Sul maior que 0,14, mas as correlações são maiores quanto maior for a média móvel, assim chegou a um $r=0,38$ para a média móvel 24. O destaque é que as correlações do IOS com o oceano Atlântico Norte não tiveram significância estatística, com exceção da média móvel 24, que conseguiu uma correlação baixa de 0,16.

O ENOS (El Nino Oscilação Sul), além das fortes correlações negativas apresentadas em relação ao IOS, verificou-se que o Nino1+2 tem maior correlação com o Nino 3 e menor com o Nino4, esse resultado era esperado devido à distância entre as áreas. O Nino 3 teve uma correlação com Nino 1+2 maior do que com o Niño 4. Esses valores podem ser explicados pela ocorrência dos El Niños Modoki (quando as TSMs da áreas localizadas na

parte tropical mais a leste sobre o Oceano Pacífico ficam mais aquecidas e as demais áreas da parte central do Oceano) em alguns anos e não canônicos (quando o aquecimento do Oceano Pacífico é mais homogêneo e distribuído). O destaque nessa comparação foi que o oceano Atlântico Norte apresentou correlações positivas significativas, embora pequenas, com todas as áreas do ENSO, enquanto que o Atlântico Sul não teve significância. Nessa observação com a parte norte do Atlântico os valores das correlações foram da seguinte ordem, Nino 4 (0,280); Nino 3.4 (0,163); Nino 3 (0,146) e Nino1+2 (0,114).

No Oceano Atlântico, como explicado anteriormente, a parte Norte do Atlântico apresentou baixa correlação positiva com o ENOS, enquanto que a parte Sul do oceano não apresentou correlação significativa. Com IOS foi o contrário, a parte Sul do oceano apresentou baixa correlação positiva e na parte norte a correlação não atingiu o nível de significância de 0,05. Já o Gradiente Meridional (Mgrad – diferença entre as TSMs localizadas no Atlântico Tropical Norte menos as TSMs do Atlântico Tropical Sul) do Atlântico teve maior correlação com Niño 4 em todas as médias móveis, seguido pelo Nino 3.4 e não se correlacionou com Niño 1+2. Muito pouco com o IOS e Niño 3, nas escalas de 6, 12 e 24.

4.6. Relação das variáveis de entrada do modelo e a saída (SPI)

A busca da melhor associação entre as iterações do oceano Atlântico e a situação atmosférica sobre o Nordeste brasileiro, em especial sobre o estado de Pernambuco, foi necessária para se adotar o “Lag” ou “Latency at game”. O Lag é a diferença temporal entre o início de um evento e o momento em que seu efeito é perceptível sobre uma área. Como se sabe, as anomalias de TSMs modulam a circulação da atmosfera, alterando a frequência e intensidade dos sistemas meteorológicos precipitantes. Entretanto, há um espaço de tempo necessário para que as anomalias no Pacífico ou no Atlântico interfiram nos padrões de chuva sobre o Nordeste do Brasil. Por isso, foram usados “Lags” de 0 a 12 meses e considerada apenas valores de correlação com significância estatística de 0,01.

Em um primeiro momento se observou correlações mês a mês, independentemente da escala do SPI ser pequena ou grande. Dessa forma, foi avaliado o impacto da anomalia mensal da TSM sobre o SPI nas escalas mensais, trimestrais, semestrais e anuais. Então, foi possível verificar que alguns “Lags” apresentam valores aproximados de correlação, ou seja,

para cada escala do SPI identificou-se certos números de “Lags” com valores de correlação maiores do que os demais.

Esta primeira análise apontou que as escalas pequenas do SPI tiveram Lags menores, aumentando o Lag com o aumento da escala do SPI, este fato pode ter ocorrido em virtude da metodologia do SPI compor um acúmulo de meses em cada escala do índice. Essa variação do Lag dentro de uma faixa ou intervalo, para cada escala e também de forma diferente a depender da área do oceano em destaque, gerou certa indefinição de quais Lags eram mais adequados.

Para tentar definir os melhores Lags de cada área e suas correlações, em um segundo momento, calculou-se a média móvel das variáveis de entrada para intervalos idênticos aos da variável de saída (SPI) e assim comparar a associação entre os mesmos períodos de tempo. Assim, os Lags ficaram mais definidos (intervalo mais curto e diferenciados) e os valores de correlação foram maiores, mas mantiveram a mesma ordem de relação das variáveis da primeira análise.

Antes de realizar as análises para cada escala do SPI é importante comprovar algumas observações de comportamento já esperadas nas relações entre as variáveis: Todas as anomalias de TSMs do Pacífico apresentaram correlações negativas com todos os SPI de Pernambuco, mostrando os mesmos resultados encontrados na literatura sobre o fenômeno El Niño/La Niña desfavorecer/favorecer o regime de chuvas sobre a área em estudo. Estes resultados corroboram com os trabalhos citados na revisão bibliográfica, tais como Moura et al. (2009) e Nóbrega et al. (2014).

As anomalias de TSMs do Atlântico Norte também foram correlacionadas negativamente com o SPI. Por outro lado, a área do Atlântico Sul apresentou todas as correlações positivas. Desse modo, o gradiente meridional entre as duas áreas (MGRAD) ou Dipolo do Atlântico sempre apresentou correlação negativa. Já o índice IOS apresentou correlações positivas em todas as escalas.

Em vista do exposto acima, a partir das tabelas 8 e 9, se podem elencar as observações específicas das relações entre as variáveis e as escalas do SPI: 1) quanto maior a escala do SPI, maior a correlação com as outras variáveis; 2) para quaisquer escala do SPI e Lags, as áreas do oceano Pacífico apresentaram a sequência de correlação: Niño 1+2, Niño 3, Niño 3.4 e Niño 4; 3) para o Oceano Atlântico as correlações mostraram a seguinte ordem de melhor associação sobre a região: Gradiente Meridional, Atlântico Sul e Atlântico Norte; 4) o grupo 1 (Agreste/Litoral) não se correlacionou consistentemente com os Niño 3.4 e Niño 4 em nenhuma escala do SPI e 5) a sequência de correlação entre os grupos foi a seguinte: grupo 1:

Niño 1+2, Gradiente Meridional, Atlântico Sul, Niño 3, Atlântico Norte, IOS e; grupo 2: Niño 1+2, Gradiente Meridional, Niño 3, Atlântico Sul, Niño 3.4, IOS, Niño 4 e Atlântico Norte.

Conforme a divisão feita pela Análise de Agrupamento os efeitos causados pelos os eventos críticos são diferentes em determinadas áreas do estado de Pernambuco. De forma geral, essas diferenças são bem estabelecidas entre a área leste (grupo 1) e a área oeste (grupo 2) e percebidas em todas as escalas do SPI, por isso, os valores médios do SPI de cada grupo, nas escalas mensal (SPI-1), trimestral (SPI-3), semestral (SPI-6), anual (SPI-12) e bienal (SPI-24), foram correlacionados com cada variável de entrada, e os coeficientes de correlação podem ser vistos nas Tabelas 8 e 9, para os grupos 1 e 2, respectivamente.

Tabela 8. Valores de correlação entre os SPIs do grupo 1 e anomalias de TSMs e IOS.

Grupo 1	SPI-1	SPI-3	SPI-6	SPI-12	SPI-24
Niño 1+2	-0,227	-0,307	-0,352	-0,444	-0,478
Niño 3	-0,137	-0,196	-0,223	-0,306	-0,336
Niño 3.4	-0,108*	-0,160	-0,159	-0,215	-0,275
Niño 4	-0,119*	-0,174**	-0,170**	-0,218	-0,294
Atl Norte	-0,133	-0,180	-0,207	-0,278	-0,351
Atl Sul	0,148	0,210	0,265	0,274	0,131**
Gradiente	-0,197	-0,293	-0,351	-0,416	-0,438
IOS	0,115	0,153	0,187	0,227	0,174

*insignificante até o lag 9, e com r pequeno; **insignificante até o lag6.

Tabela 9. Valores de correlação entre os SPIs do grupo 2 e anomalias de TSMs e IOS.

Grupo 1	SPI-1	SPI-3	SPI-6	SPI-12	SPI-24
Niño 1+2	-0,190	-0,302	-0,373	-0,478	-0,566
Niño 3	-0,154	-0,246	-0,304	-0,400	-0,510
Niño 3.4	-0,136	-0,200	-0,240	-0,303	-0,381
Niño 4	-0,134	-0,174	-0,211	-0,253	-0,311
Atl Norte	-0,118	-0,141	-0,200	-0,263	-0,353
Atl Sul	0,143	0,217	0,257	0,301	0,189
Gradiente	-0,202	-0,278	-0,372	-0,448	-0,483
IOS	0,163	0,190	0,222	0,248	0,226

4.7. Montagem e desempenho da Rede Neural Artificial

Para montar a rede ideal para os dados deste trabalho e em seguida efetuar a simulação foi preciso efetuar inúmeros testes sequenciais com alterações na estrutura da rede, de forma a encontrar o melhor conjunto que pudesse representar as influências existentes entre os dados de entrada e de saída. É muito importante que os dados de entrada facilitem o aprendizado da rede neural, por isso, foram testadas várias opções como entrada.

Para identificar o tempo que as condições físicas sobre oceanos demoram a interferir na ocorrência de chuva sobre o estado de Pernambuco, os dados foram distribuídos com lags, conforme visto na seção anterior de correlações entre as variáveis. Os lags não apresentaram muitas diferenças entre si em termos de correlação e significância, mas existe uma faixa de valores em que eles são melhores definidos. Por isso, se testou o comportamento da rede neural nas seguintes faixas de valores: para o SPI 1 – lags de 0 a 5; para SPI 3 – lags de 1 a 6 e para o SPI 6 – lags de 4 a 9.

Os resultados iniciais considerando a série completa com todos os meses do ano, não conseguiram se ajustar ao padrão dos dados, mesmo fazendo alterações sistemáticas nas quantidades de camadas e de neurônios. Ressalta-se que, alguns algoritmos conseguiram mostrar uma tendência de encontrar o padrão dos dados, mas seria necessário um processamento operacional mais robusto para buscar alguma evolução destes resultados. Essa indefinição ocorreu principalmente pelo fato da região em estudo ter um período chuvoso curto. Isso interfere sobremaneira na variação do SPI e induz alterações fora do padrão nos períodos de estiagem.

Para resolver esse problema do SPI, considerou-se o período chuvoso como entrada para a rede e se definiu os meses de referência para cada grupo de acordo com a Tabela 3 da distribuição das chuvas. A definição ficou assim: grupo 2 de janeiro a maio e o grupo 1 de março a julho. Com estas entradas obteve-se uma significativa melhora nos desempenhos das redes.

Os lags 2 e 3 foram os que receberam mais destaque, aparentemente a região do Atlântico teria um lag 2 (especialmente a área do Atlântico Sul) e a região do Pacífico teria lag 3, mas com a área do Nino 1+2 com lag 2. Mesmo assim, a diferença da performance da rede entre estes dois lags foi muito pequena. Ainda, tentou-se fazer três combinações utilizando o lag 2 para algumas variáveis e o lag 3 para outras, porém, os resultados se mantiveram similares. Portanto, para equiparar as variáveis e tornar a operacionalização mais prática em termos de tempo e predição das condições futuras adotou-se o Lag 3 como entrada para a previsão do SPI1 e SPI3. Estes resultados são semelhantes aos encontrados por Silva et al. (2011) que apontam maiores correlações do Atlântico quanto mais próximo do período chuvoso estiver a defasagem temporal.

Durante a definição de entrada dos dados, outras opções foram testadas, como a exclusão de algumas variáveis, testou-se a entrada com as duas, as quatro e as seis variáveis mais correlacionadas e não houve diferença significativa nos resultados, mesmo alternando os tipos de redes. Outra opção testada foi a entrada de equações com peso nas variáveis que

pudessem apresentar uma correlação melhor com a saída, mas a rede também não mostrou evolução. Nessas opções de entrada se verificou que a rede faz distinção do nível de interferência de cada variável durante a fase de treinamento, tornando sua influência mais ou menos importante. A rede detecta se uma variável foi alterada de forma direta ou inversamente proporcional e mantém o resultado igual ao anterior, mas a rede não detecta quando há alteração no lag de entrada.

Diante do exposto, optou-se por usar como entrada as variáveis do grupo 2, sempre com lag 3. Foram testados quatro tipos de arquiteturas de redes neurais: a primeira sem realimentação dos dados, a segunda com realimentação da entrada inicial em todas as camadas, a terceira com realimentação na saída da rede de forma mais simplificada e a quarta com camada recorrente. Na Figura 39 observam-se três tipos de arquiteturas.

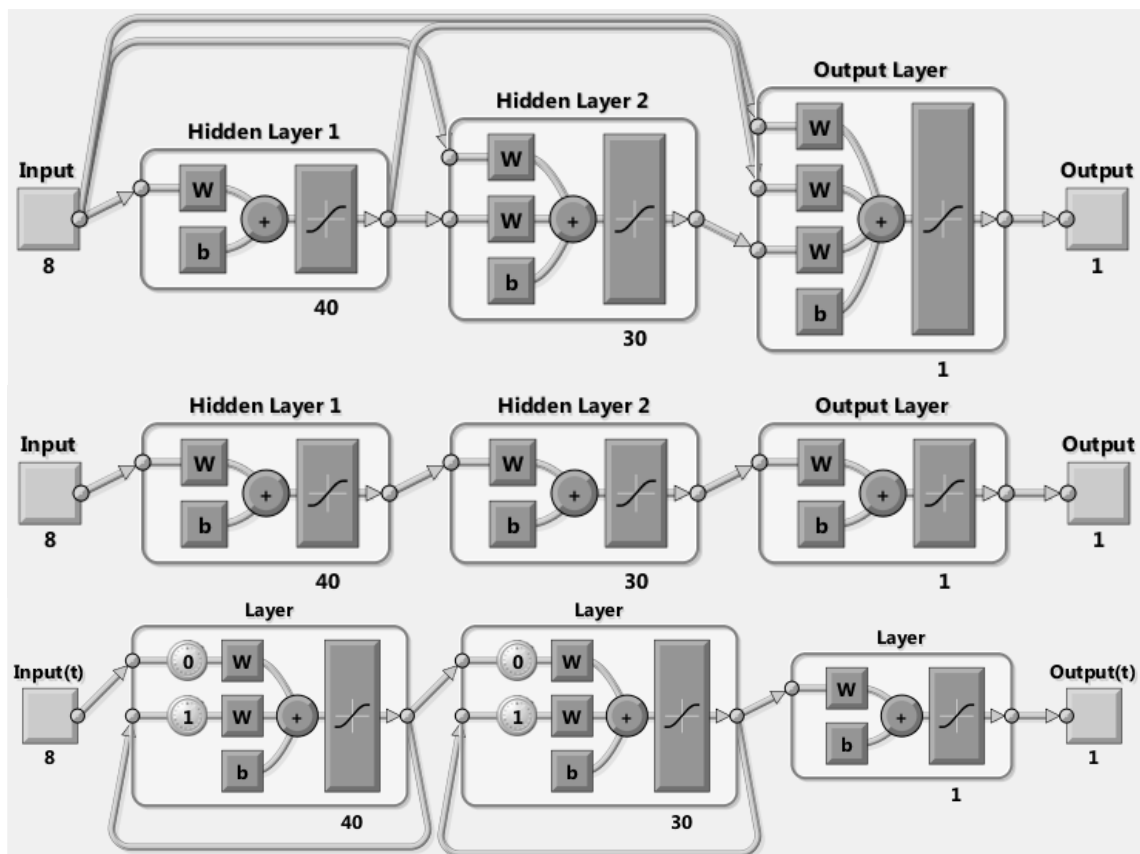


Figura 39. Arquiteturas de redes neurais do tipo “Cascade Forward”, “Feed-Forward” e “Layer Recurrent”, respectivamente.


As arquiteturas do tipo “Elman” e “Layer Recurrent” exigiram mais processamento, além disso, suas saídas foram mais suavizadas e não definiram bem as posições dos picos dos eventos. Já as redes do tipo “Feed” e “Cascade Forward” foram mais rápidas e possibilitou o

aumento do tamanho da rede. Comparando as saídas dessas últimas arquiteturas foi verificado que ambas tiveram desempenhos mais satisfatórios, haja vista que representou melhor os valores extremos positivos e negativos do que as duas primeiras redes. Nessa fase de construção da arquitetura foram efetuados testes com 3, 4 e 5 camadas, alterando o número de neurônios e as funções de ligação. A Tabela 10 mostra o resumo de uma das simulações, neste caso, rede com cinco camadas e os neurônios divididos de forma decrescente a cada camada na sequência 35_30_25_20.

Tabela 10. Resultados de uma simulação com quatro tipos de rede neural.

REDES	Performance MSE	Melhor validação
Feed-forward backpropagation	0,07	0,35
Cascade-forward backpropagation	0,06	0,45
Elman backpropagation	0,14	0,49
Layer Recurrent	0,22	0,51

Na maioria das simulações o desempenho com a rede “Cascade Forward” foi superior às demais, pois, sua saída conseguiu absorver o padrão de variação nos dados e fazer as inflexões em pontos similares ao objetivo final da rede (série do SPI). Assim, esse foi o tipo de rede considerado mais adequado para simular os eventos deste estudo. A diferença média entre a saída, fornecida pela rede neural, e o seu objetivo apresentou os seguintes resultados em uma das simulações: “Cascade-Forward” igual a 0,078; “Feed-Forward” 0,225; “Elman backpropagation” 0,510 e “Layer Recurrent” 0,769. A Figura 40 exibe exemplos de simulações obtidas pelos diferentes tipos de redes neurais, em que a linha sem pontos é a saída fornecida pela rede, e a linha com asteriscos é o objetivo a ser atingido.






Figura 40. Comparação entre os tipos de rede a) “Cascade-Forward”, b) “Feed-Forward”, c) “Elman backpropagation” e d) “Layer Recurrent”

Alguns testes adicionais comparando as redes Feed e Cascade Forward foram realizados, mas os resultados se mantiveram um pouco mais precisos com a arquitetura da rede “Cascade-Forward”, e assim, deu-se prosseguimento ao estudo com a definição do algoritmo de aprendizado. Essa é uma parte importante do estudo. É com nesse algoritmo que a rede tomará suas principais decisões. É a qualidade desse algoritmo que poderá retardar ou acelerar as decisões da rede neural. Foram testados quatorze diferentes algoritmos (Tabela 11) e selecionados os melhores, não apenas em performance no treinamento, mas também na qualidade de suas saídas em comparação com os dados do SPI.

Tabela 11. Teste com diferentes algoritmos de treinamento.

Algoritmos	Performance (MSE)	Melhor validação	r (Teste)	r(validação)
<u>trainbfg</u>	0,189	0,25	0,57	0,39
<u>trainbr</u>	83,2	83,2	Training = 0,49	
<u>traincgb</u>	0,29	0,32	0,64	0,66
<u>traincgf</u>	0,29	0,39	0,42	0,72
<u>traincgp</u>	0,35	0,28	0,40	0,68
<u>traingd</u>	0,64	0,81	0,51	0,38
<u>traingda</u>	0,47	0,43	0,34	0,11
<u>traingdm</u>	1,64	1,26	0,08	0,12
<u>traingdx</u>	0,68	0,83	0,18	0,24
<u>trainlm</u>	0,14	0,37	0,68	0,71
<u>trainoss</u>	0,08	0,64	0,36	0,39
<u>trainr</u>	1,21	1,25	0,21	0,30
<u>trainrp</u>	1,94	2,23	0,21	0,44
<u>trainscg</u>	0,29	0,51	0,46	0,60

em que:

trainbfg - BFGS retropropagação quase-Newton;
trainbr - Regularização Bayesiana;
traincgb - Gradiente conjugado de retropropagação com reiniciação Powell-Beale;
traincgf - Gradiente conjugado de retropropagação com atualizações Fletcher-Reeves;
traincgp - Gradiente conjugado de retropropagação com atualizações Polak-Ribiere;
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 conjugado e escalado de retropropagação.

Dos algoritmos testados, foram selecionados sete (Tabela 12) para efetuar novas simulações com outras configurações de rede. Observou-se que todos os algoritmos baseados no gradiente conjugado de retropropagação assimilaram melhor o comportamento do SPI. As novas simulações foram feitas com rede de 3, 4 e 5 camadas, alterando-se o número de neurônios em cada uma delas. Não houve melhorias nos casos com “trainoss e trainbfg”, e pequenas melhorias nos casos “traincgp e trainscg”. O algoritmo “trainlm” apresentou aperfeiçoamento em duas saídas, mas nas demais não teve bom comportamento, haja vista que esse algoritmo exige maior processamento e, portanto, maior dificuldade para adotar um maior número de neurônios e camadas. Por fim, os dois algoritmos mais consistentes foram “traincgf e traincgb”, por terem treinamentos mais rápidos e possibilitarem o teste de redes maiores. Os resultados destes dois últimos algoritmos foram comparados e constatou-se que a performance do “traincgb” é levemente melhor. Também, suas saídas conseguiram representar melhor as inflexões do SPI. A Tabela 12 exhibe os resultados da simulação da rede, e classificou-se a análise da seguinte maneira: ruim – quando houve perda no sinal dos dados; satisfatório – conseguiu manter o sinal, mas não a amplitude; boa – detectou as alterações do sinal e da amplitude e, por fim, muito boa – quando identificou os picos e os resultados se aproximam da amplitude dos dados.

Tabela 12. Classificação dos resultados do teste para os algoritmos mais promissores.

Algoritmos	Performance (MSE)	Melhor validação	r (Teste)	r(validação)	Análise gráfica
<u>trainbfg</u>	0,25	0,30	0,52	0,36	Boa
<u>traincgb</u>	0,20	0,31	0,52	0,73	muito boa
<u>traincgf</u>	0,30	0,28	0,42	0,63	muito boa
<u>traincgp</u>	0,33	0,57	0,55	0,31	satisfatória
<u>trainlm</u>	0,05	0,35	0,64	0,54	boa
<u>trainoss</u>	0,36	0,51	0,50	0,71	ruim
<u>trainscg</u>	0,33	0,54	0,34	0,22	satisfatória

No decorrer das simulações anteriores foram testados três tipos de funções de transferência, logsig, purelin e tansig. Essas simulações foram feitas alterando apenas as funções nas camadas escondidas e depois nas camadas de saída. No teste com purelin, os resultados sempre extrapolaram os valores extremos do SPI, enquanto que a logsig suavizou e subestimou os valores dos SPI. Utilizaram-se também as funções conjuntamente numa mesma rede, mas não houve resultado mais satisfatório. Portanto, a tansig foi a função de transferência que se saiu melhor nos teste, além de sempre apresentar melhor performance no treinamento. O resumo de uma das simulações pode ser visto na Tabela 13.

Tabela 13. Resultados do treinamento para cada função de transferência.

Funções de transferência	Performance (MSE)	Melhor validação	r(validação)	r (teste)	r (todos)
Purelin	0,69	0,60	0,34	0,34	0,32
Logsig	0,37	0,31	0,49	0,38	0,53
Tansig	0,23	0,22	0,70	0,48	0,69

Por fim, para completar toda a estrutura da rede, definiram-se os números de camadas escondidas e neurônios que seriam suficientes para obter resultados satisfatórios. Inicialmente foi usada uma rede com 5 camadas e 50 neurônios em cada uma e outra com 4 camadas e 300, 200, 100 neurônios em cada uma. O resultado mais satisfatório foi àquele para a rede com mais neurônios, mesmo com menor número de camadas. Para consolidar esse resultado fez-se outro teste com uma rede de três camadas e 250 e 100 neurônios e outra rede com 1000 e 100 neurônios. Novamente a rede com mais neurônios foi a melhor.

Em seguida foram efetuados vários testes, aumentando ao máximo computacional o tamanho da rede, com simulações de até 10.000 neurônios numa única camada, consumindo o tempo de processamento de 10 minutos. Outra rede com a mesma quantidade de neurônios

divididos em duas camadas demorou em torno de 45 minutos para ser processada, já essa rede com quatro camadas consumiu tempo superior a uma hora para ser processada. Esta mesma quantidade de neurônios, com mais camadas travou o processamento da rede. Os resultados obtidos nesse teste indicaram que o aumento excessivo do número de neurônios nas camadas da rede não melhorou a performance.

A simulação de uma rede com poucos neurônios, abaixo de 100 em cada camada, mostrou que apenas uma camada era insuficiente e que com mais camadas era possível acompanhar o padrão de variação do SPI, mas nunca sua amplitude. Assim, decidiu-se construir redes variando o número de neurônios em cada camada, no início ou no final da rede. Dessa forma, os valores de saída da rede se aproximaram mais do objetivo.

Foram realizados dezenas de testes com redes de duas e três camadas, envolvendo neurônios de forma decrescente, assim: 5000 e 3000; 5000 e 2000; 5000 e 1000; 4000 e 2000; 3000 e 2000; 3000 e 1000; 2000 e 1000, respectivamente. Nesses testes, não houve grandes diferenças entre seus resultados, porém, nos casos em que a última camada tinha menos neurônios os resultados apresentaram um melhor padrão. Em seguida foram efetuadas novas simulações com muitos neurônios na primeira e poucos na segunda camada, assim: 5000 e 300; 5000 e 200; 5000 e 100; 3000 e 300; 3000 e 200; 3000 e 30; 3000 e 10; 2000 e 300; 2000 e 200; 2000 e 75; 1000 e 100 dentre outras. Com estes testes, observou-se que a redução de neurônios na segunda camada não prejudicou a rede e algumas vezes apresentaram uma saída mais ajustada. A Figura 41 mostra algumas dessas performances para o SPI-3.




Figura 41. Desempenho da rede com duas camadas, alterando o número de neurônios. (a) 5000 e 2000; (b) 5000 e 100.

Com base nas melhorias encontradas foram aumentados o número de camadas, e testadas redes com 4, 5 e 6 camadas, assim: (5000, 2000 e 100); (3000, 1300 e 555); (3000,

2000 e 200); (2500, 250 e 25); (1800, 1200 e 600); (4000, 2000, 1000, 500 e 75); (1500, 1000, 500, 200 e 100); (100, 80, 60 e 40); (200, 150 e 100). A Figura 42 mostra uma das redes testadas.

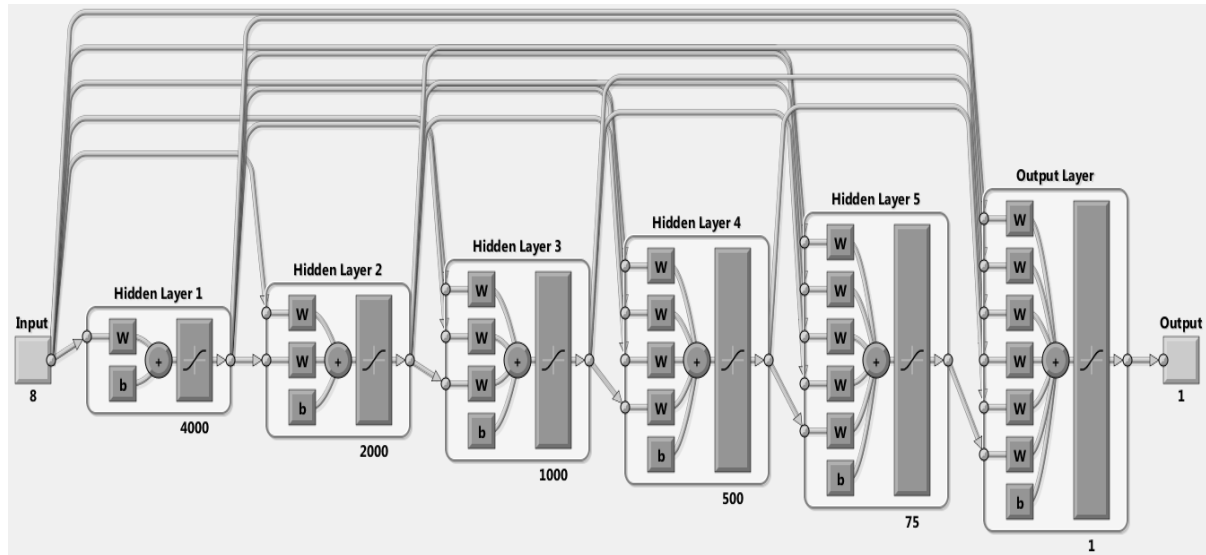


Figura 42. Rede “Cascade-Forward” com seis camadas e 7575 neurônios distribuídos de forma decrescente.

Constatou-se que as quantidades de neurônios e de camadas são menos decisivas na performance do que o tipo da rede, o algoritmo e a função de transferência. A rede neural se mostrou capaz de identificar e acompanhar os padrões com várias combinações de camadas e neurônios, sendo que algumas são mais consistentes do que outras. A decisão desta configuração final vai depender de outros fatores que podem influir no treinamento da rede, para definir esta questão, se utilizou um número de neurônio proporcional ao tamanho da série inserida na entrada, variando de 1 até 20 vezes essa quantidade, sempre dependendo do aumento de camadas.

Para uma entrada com variáveis de aproximadamente 250 observações cada, foram testadas configurações com número de neurônios proporcionais à entrada e aumento do número de camadas, conforme mostrada algumas dessas configurações na Tabela 14. O desempenho da rede foi mais satisfatório para até cinco 5 camadas escondidas, já as redes com mais camadas, além de tornar o processamento muito lento não propiciaram evolução e por vezes apresentou resultados menos consistentes que as redes menores.

Tabela 14. Exemplos de configurações aplicadas nos testes.

Tamanho da arquitetura	Número de neurônios em cada camada
2 camadas escondidas	2500 e 250
2 camadas escondidas	2500 e 500
2 camadas escondidas	250 e 125
2 camadas escondidas	500 e 250
2 camadas escondidas	750 e 500
3 camadas escondidas	500, 250 e 125
3 camadas escondidas	750, 500 e 250
3 camadas escondidas	1000, 750 e 500
4 camadas escondidas	1000, 750, 500 e 250
5 camadas escondidas	1000, 750, 500, 250 e 125
6 camadas escondidas	1000, 750, 500, 250, 125 e 62
6 camadas escondidas	2000, 1000, 750, 500, 250 e 125
7 camadas escondidas	1000, 750, 500, 250, 125, 62 e 31
7 camadas escondidas	2000, 1500, 1000, 750, 500, 250 e 125
7 camadas escondidas	2000, 1750, 1250, 750, 500, 250 e 125
8 camadas escondidas	2500, 2000, 1500, 1000, 750, 500, 250 e 125
9 camadas escondidas	2000, 1750, 1500, 1250, 1000, 750, 500, 250 e 125

Com base nos testes realizados, aparentemente a arquitetura da rede teve maior habilidade para realizar a previsão para o Grupo 1. As várias configurações conseguiram representar o padrão dos SPIs desse Grupo 1. Já para o Grupo 2 o modelo apresentou mais dificuldade para realizar a previsão dos SPIs. Também o número de configurações foi consideravelmente menor. Apesar disso, foi possível obter performances relativamente boas do modelo para ambos os grupos, principalmente para o SPI-3. Essas performances podem ser vistas na Figura 43. Nessa Figura a linha pontilhada é o valor do SPI ocorrido e a linha contínua é a saída prevista pela rede neural.

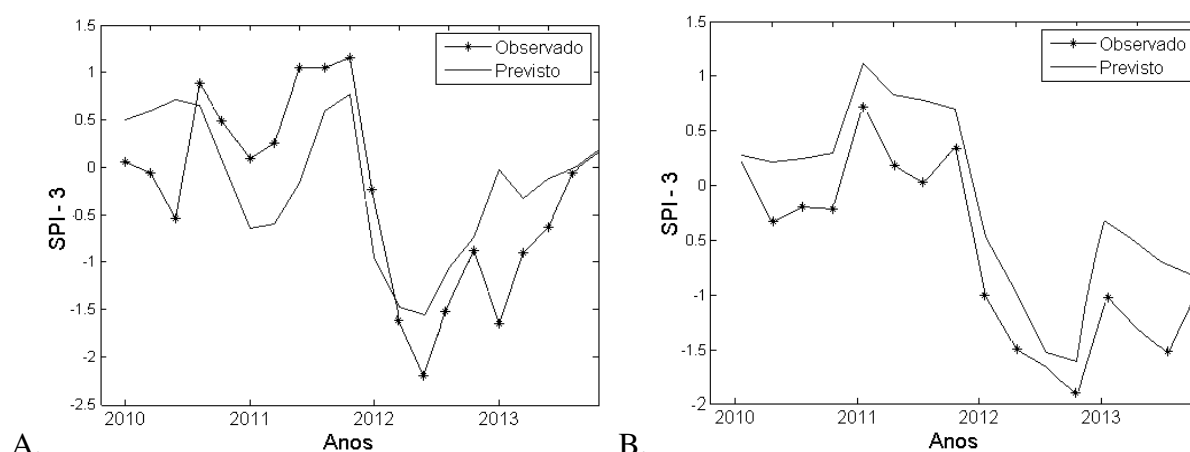


Figura 43. Comparação entre os valores estimados pela rede e o objetivo (SPI-3) a ser alcançado. (A) é o Grupo 1 e (B) é o Grupo 2.

As regressões e os ajustes das estimativas utilizando o modelo de rede neural na fase de treinamento podem ser vistos para cada iteração (Figura 44). Após concluir o treinamento os valores dos coeficientes de regressão para o treinamento, validação e teste são disponibilizados, conforme vistos na Figura 44. Também são fornecidas as estimativas finais para efeito de comparações e análise de erros e para a confecção de outras figuras, como por exemplo, a Figura 45 que exhibe a dispersão entre os valores estimados pela rede neural e os valores do SPI.

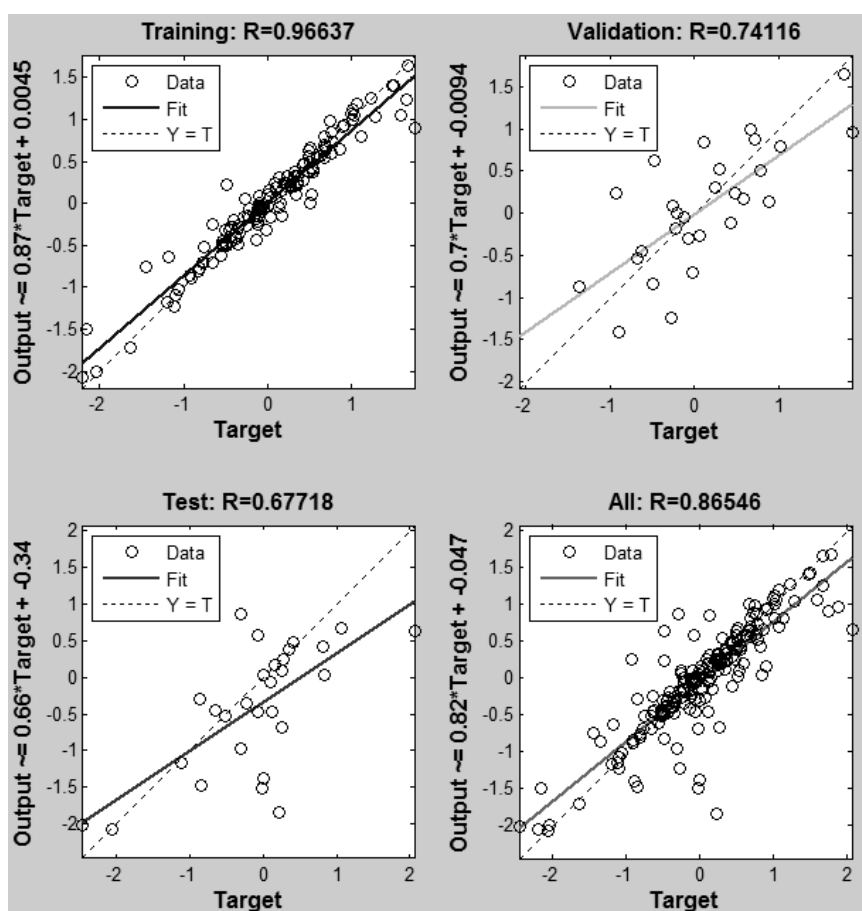


Figura 44. Coeficientes de regressão para as fases de treinamento, validação e teste.




Figura 45. Comparação dos valores estimados pela rede e os SPIs de três meses.

De modo geral, o modelo de rede neural artificial obteve, com os métodos aplicados neste estudo, um ajuste relativamente bom para prever o SPI de escala trimestral. Entretanto, o modelo não apresentou o mesmo desempenho para as escalas mensal e semestral, haja vista que apresentou dificuldades para identificar os valores máximos e mínimos dessas escalas temporais. A justificativa para esse fato é que os valores do SPI de escala mensal apresentam alta variabilidade e são influenciados fortemente pelos fatores geográficos e pela ocorrência de sistemas meteorológicos locais. Já na previsão do SPI na escala semestral foi adotado o lag 6, devido o tamanho da escala do índice e assim aumentou-se o horizonte temporal a ser previsto. Além disto, também foi avaliado os valores do SPI incluindo os meses que antecedem o período chuvoso (novembro a abril, no caso do Grupo 2) e (janeiro a junho no caso do Grupo 1).

Apesar de algumas dificuldades para o ajuste da previsão pelo modelo de redes neurais, o mesmo conseguiu captar a tendência e o sinal dos valores esperados na escala menor (SPI-1), conforme pode ser observado na Figura 46. Já para a escala semestral o modelo de redes neurais apresentou uma previsão do SPI-6 melhor ajustada que na escala menor e acompanhou a variação do índice e suas mudanças inter-anuais. Porém, as RNAs na maioria das configurações testadas não conseguiu acompanhar os valores de amplitudes máximas e mínimas, a melhor performance está representada na Figura 47. Observa-se que o modelo teve mais facilidade em fazer a previsão do SPI da região do grupo 1, também nestas escalas temporais de 1 e 6 meses.

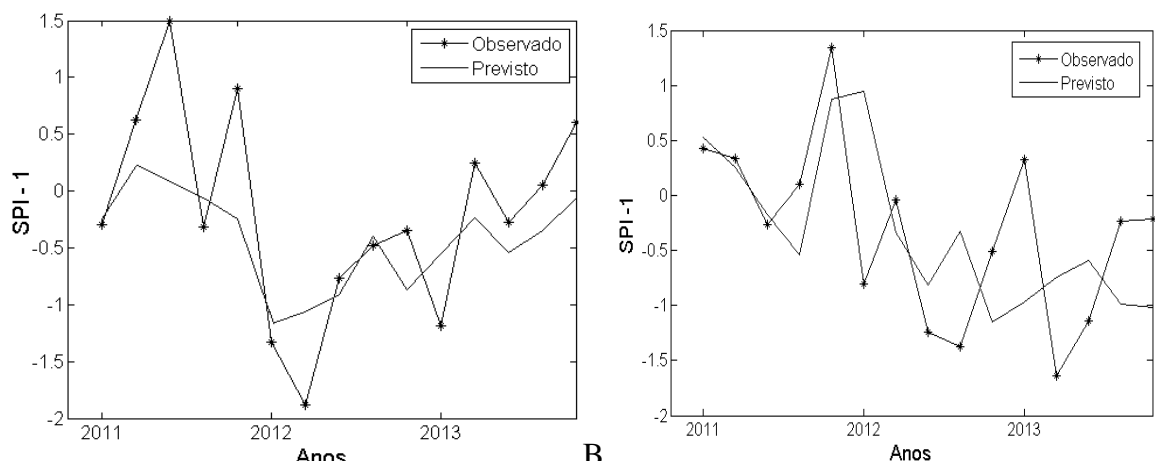


Figura 46. Previsão da rede neural para o SPI-1. (A) é o Grupo 1 e (B) é o Grupo 2.

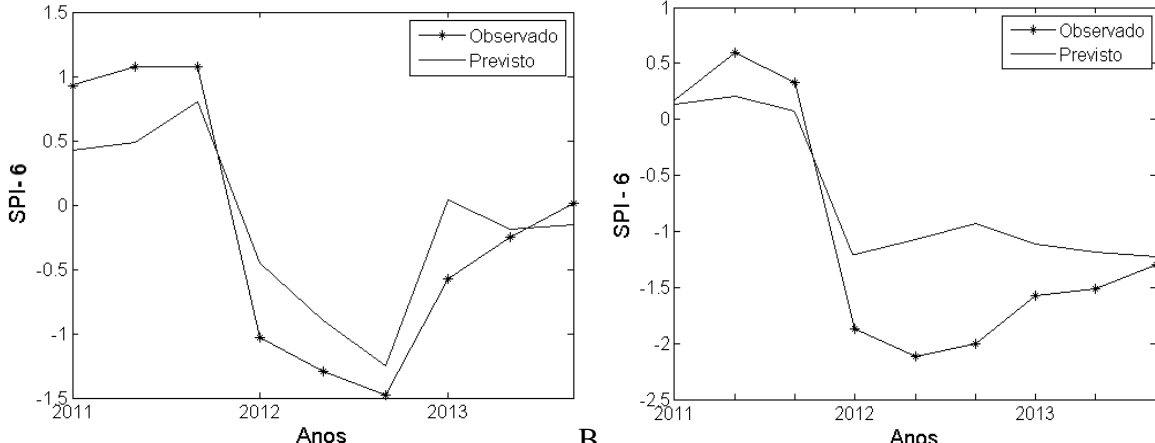


Figura 47. Previsão da rede neural para o do SPI-6. (A) é o Grupo 1 e (B) o Grupo 2.

O desempenho aparentemente melhor do modelo para o conjunto de estações do Grupo 1 pode está relacionado ao fato de o período chuvoso ser maior, mais definido e melhor distribuído, e dessa forma causa menos impactos nas variações dos SPIs. Também, a área desse Grupo 1 é menor e experimenta a ocorrência dos sistemas meteorológicos espaço-temporal. Já no Grupo 2 o período chuvoso é menor e menos definido, haja vista que nas áreas do Sertão do Pajéu e Moxotó esse período se estende até maio e junho, respectivamente. Nas demais áreas do Sertão o período chuvoso se restringe até o mês de abril.

5. CONCLUSÕES E SUGESTÕES

A metodologia do SPI identificou todos os eventos críticos de precipitação, positivos e negativos, ocorridos no estado de Pernambuco em várias escalas temporais e destacou os mais significativos através de suas intensidade e duração. A variação das escalas temporais dos SPIs ajudou a diagnosticar o início dos eventos através de escalas menores, suas intensidade e duração em outras escalas.

O SPI-1 indicou com intensidade maior o início dos eventos que ganharam destaque e também a alta variabilidade da chuva no curto espaço de tempo. É por isso que essa escala não possibilita a identificação do prolongamento de eventos mais significativos. O SPI-3 reduziu um pouco a variabilidade temporal dos eventos e indicou suas persistências, mas não definiu suas significâncias do ponto de vista dos recursos hídricos, haja vista que não considera todo o período chuvoso. O SPI-6 definiu as tendências de eventos positivos e negativos e mostrou que índices maiores nessa escala não decaem rapidamente, esse fato leva o analista a induzir possíveis efeitos sobre a área estudada. O SPI-9 apenas suavizou as oscilações que ainda apareciam nas escalas menores e indicou a permanência e intensidade dos eventos. Desse modo, a escala de nove meses não adicionou novas informações para o estado de Pernambuco.

O SPI-12 quando analisado de forma individualizada indicou que em alguns municípios o evento crítico pode ser mais intenso e durar um pouco mais. De forma geral, os principais eventos ocorreram em todos os postos pluviométricos, mostrando que os efeitos de grande escala são generalizados.

O SPI-12 filtrou a variabilidade de curto prazo e consolidou os eventos críticos, indicando suas intensidade e duração de forma mais clara. Nessa escala estão envolvidos os períodos naturais de chuva e estiagem. O SPI-24 por ser uma série mais suavizada, mascarou os eventos de escalas menores, mas indicou os períodos em que houve excessos e déficits mais prolongados sobre a área do estado. Em escalas ainda maiores com os SPIs de 36, 48 e 60 meses, por envolver vários anos, os eventos diagnosticados foram mais prolongados e indicaram a formação de ciclos positivos e negativos ao longo da série.

O SPI médio espacial classificou todos os eventos significativos que ocorreram no estado de Pernambuco, com exceção dos eventos mais fracos ou que ocorreram de forma isolada, haja vista que esses foram atenuados pela média. Por essa razão, há necessidade em

estimar o SPI pontual para diagnosticar o comportamento local e obter informações mais detalhadas da sua variabilidade.

Os principais eventos críticos que ocorreram no estado de Pernambuco entre os anos de 1963 e 2013 foram diagnosticados, em média, como eventos chuvosos de categoria moderada no ano de 1963 e 1973 e de chuva severa em 1984. Já os eventos secos ocorreram nas categorias extrema em 1993, 1998 e 2012 e com intensidade de seca moderada nos anos de 1981 e 1983.

Alguns municípios apresentaram alterações no comportamento da série temporal de precipitação. Esses dados podem ter sofrido alterações ambientais que afetaram o microclima, ou mesmo alteração no posto de medição (localização ou equipamento). Os destaques são para os postos pluviométricos de Brejão e Brejo da Madre de Deus. Esses postos apresentam uma sequência de eventos positivos nas primeiras décadas e depois uma série de eventos negativos consecutivos nas últimas décadas, na escala anual. Porém, as escalas menores mostraram que esses ocorreram pequenos eventos alternados.

A Análise de Agrupamento delimitou o estado de Pernambuco em dois grupos climáticos: O Grupo 1 (Agreste e Litoral) e o Grupo 2 (Sertão), para todas as escalas temporais estudadas. A proporção que se aumenta a escala temporal do SPI, as localidades do Grupo 2 (Sertão) tende a adentrar as áreas do Grupo 1 (Agreste e Litoral). Isto indica que a área de transição compõe as características do clima semiárido e litorâneo e vice-versa. A Análise de Agrupamento mostrou que o estado tende a experimentar impactos de um evento crítico em áreas de mesmo período chuvoso.

Foi possível identificar que o Litoral, o Agreste, parte Central (Sertões de Moxotó e Pajéu) e a parte Oeste (Sertão de São Francisco e Alto Sertão) possuem a mesma variabilidade climática, de acordo com as escalas do SPI-1 ao SPI-12.

As correlações entre o SPI e as temperaturas da superfície do mar (TSM) das áreas do El Niño 3,4 e 4 apresentaram valores menores do que as correlações das áreas Niño 1+2 e 3, para ambos os grupos, principalmente para o Grupo 1 (Litoral). Por outro lado, no Atlântico o gradiente meridional teve a maior correlação, seguida pela área do Atlântico Sul, sendo que esta última área apresentou correlação positiva.

Neste trabalho, várias arquiteturas de redes neurais foram utilizadas para realizar a previsão dos SPIs nas escalas estudadas. Algumas arquiteturas obtiveram desempenhos satisfatórios, mas a arquitetura considerada mais adequada neste trabalho foi a do tipo Cascade-forward backpropagation, com o algoritmo Gradiente conjugado de retropropagação,

com reinicialização Powell-Beale e a função de transferência tangente sigmóide, sempre variando o número de camadas e neurônios, dependendo das variáveis de entrada.

O modelo de Redes Neurais Artificiais distinguiu a importância relativa de cada uma das variáveis de entrada e apresentou um desempenho satisfatório na associação entre as variáveis oceânicas e os valores dos SPIs sobre o estado de Pernambuco. De modo geral, a previsão para região do grupo 1 foi melhor que para a região do grupo 2.

Na realização da previsão, a escala trimestral destacou-se porque as RNAs tiveram mais facilidade para encontrar suas variações e seu comportamento. Com esta escala o modelo conseguiu se ajustar significativamente para a previsão do SPI, e acompanhou as flutuações e o sinal do índice. Porém, nas escalas mensais e semestrais o modelo apresentou um pouco mais de dificuldade para obter o mesmo ajuste e poucas RNAs foram capazes de acompanhar as variações destas escalas. Ainda assim, com o treinamento adequado o modelo conseguiu fazer previsões de valores dos SPI-1 e SPI-6 capazes de indicar a tendência das variações anuais esperadas.

Acredita-se que haja espaço para melhorias no desempenho da rede neural desde que seja usado um computador com maior capacidade de processamento, redes neurais com arquiteturas maiores e algoritmos mais sofisticados, inserção de funções mais específicas e outros tipos de treinamento..

A adoção dessa metodologia no ambiente operacional de previsão pode ensejar aprimoramentos, seja por alterações no formato dos dados de entrada, seja pela adoção de testes com mais variáveis climáticas ou até mesmo pelo uso metodologias similar, como a Análise de Componentes Principais e Wavelet (ondeletas). Enfim, novas ferramentas que auxiliem na definição das variáveis de entradas do modelo de redes neurais poderá melhorar o desempenho da previsão dos SPIs.

REFERÊNCIAS

- ABARGHOUEI, H. B.; KOUSARI, M. R.; ZARCH, M. A. A. Prediction of drought in dry lands through feedforward artificial neural network abilities. **Arabian Journal of Geosciences**, v. 6, n. 5, p. 1417-1433, 2013.
- ABRAMOWITZ, M.; STEGUN, I.A. **Handbook of Mathematical Formulas, Graphs, and Mathematical Tables**. Dover Publications, Inc., New York, USA. 1965.
- 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, 2000.
- 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.
- ALVES, J. M. B. Aspectos climatológicos do nordeste brasileiro com ênfase a região semi-árida: principais causas da variedade pluviométrica interanual. IN: **1º Simpósio sobre Captação de Água de Chuva no Semi-Árido Brasileiro**, Petrolina, 1997.
- ANDREOLI, R. V.; KAYANO, M. T. A importância relativa do Atlântico Tropical Sul e Pacífico leste na variabilidade de precipitação do Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v.22, n.1, p.63-74. 2007.
- APAC. Agência Pernambucana de Águas e Clima. Gerência de Meteorologia e Mudanças Climáticas. **Monitoramento Pluviométrico**. Disponível em: <<http://www.apac.pe.gov.br/meteorologia/monitoramento-pluvio.php>>. Acesso em 16 abr. 2014.
- BARUA, S.; NG, A.; PERERA, B. Artificial neural network-based drought forecasting using a nonlinear aggregated drought index. **Journal of Hydrologic Engineering**, v. 17, n. 2, p. 1408–1413, 2012.

BAUGHMAN, D. R.; LIU, Y. A. **Neural Networks in Bioprocessing and Chemical Engineering**, Academy Press, 488p, 1995.

BELAYNEH, A.; ADAMOWSKI, J.; KHALIL, B.; OZGA-ZIELINSKI, B. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models. **Journal of Hydrology**, v. 508, p. 418–429, 2014.

BISWAS, A.K. **Water Development and Environment em Water Resources – Environmental Planning, Management and Development** (Biswas, A. (ed)), McGraw-Hill, EUA, ISBN 0-07-005483-5, p. 1-35, 1997.

BLAIN, G. C; BRUNINI, O. Análise Comparativa dos índices de seca de Palmer, Palmer Adaptado e índice padronizado de precipitação no estado de São Paulo. **Revista Brasileira de Meteorologia**, v.22, n.1, p.105-111, 2007.

BUSSAY, A.; SZINELL, C.; SZENTIMERY, T. **Investigation and Measurements of Droughts in Hungary**. Hungarian Meteorological Service, Budapest, Hungary, 1999.

COSTA, D. C.; BRITO, J. I. B.; BRAGA, C. C.. Identificação de Regiões Climáticas no Estado de Pernambuco para Aplicação no Monitoramento da Variabilidade Interanual. In: **XIV Congresso Brasileiro de Agrometeorologia**, 2005. Campinas – SP, 18-21 de julho de 2005.

COSTA, K. M. S. **Variabilidade oceânica associada à variabilidade climática da vazão na Bacia do Rio São Francisco**. 2012. 163f. Dissertação (Mestrado) – Faculdade de Filosofia Letras e Ciências Humanas, Universidade de São Paulo, 2012.

DEPINE, H.; CASTRO, N. M. R.; PINHEIRO, A.; PEDROLLO, O. Preenchimento de falhas de dados horários de precipitação utilizando redes neurais artificiais. **Revista Brasileira de Recursos Hídricos**, v. 19, n. 1, p. 51-63, 2014.

DEMUTH, H.; BEALE, M.; HAGAN, M. **Neural Network Toolbox 5**, User's Guide, MathWorks Inc. 2007.

DOMINGOS, S. I. S. **Análise do índice de seca Standardized Precipitation Index (SPI) em Portugal Continental e sua comparação com o Palmer Drought Severity Index (PDSI)**. Tese de licenciatura (Meteorologia) – Universidade de Lisboa, Lisboa, 2006

FERREIRA, F. F.; ALVES, J. M. B.; COSTA, A. A. Um estudo dos impactos das temperaturas da superfície do mar (TSM) em macrorregiões pluviometricamente homogêneas, no Estado do Ceará. **Revista Brasileira de Agrometeorologia**, v.12, n.1, p. 193-204, 2004.

GELCERA, E.; FRAISSE, C.; DZOTSI, K.; HU, Z.; MENDES, R.; ZOTARELLI, L. Effects of El Niño Southern Oscillation on the space–time variability of Agricultural Reference Index for Drought in midlatitudes. **Agricultural and Forest Meteorology**, v. 174– 175, p. 110–128, 2013.

GOCIC, M.; TRAJKOVIC, S. Spatiotemporal characteristics of drought in Serbia. **Journal of Hydrology**, v. 510, p. 110–123, 2014.

GUEDES, R. V. S.; MACEDO, M. J. H.; SOUSA, F. A. S. Análise espacial de eventos de secas com base no índice padronizado de precipitação e análise de agrupamento. **Revista Brasileira de Ciências Ambientais**, v. 23, p. 55–65, 2012.

HAO, Z.; AGHAKOUCHAK, A. Multivariate Standardized Drought Index: A parametric multi-index model. **Advances in Water Resources**, v. 57, p. 12–18, 2013.

HAYES, M. J.; SVOBODA, M. D.; WILHITE, D. A.; VANYARKHO, O. V. Monitoring the 1996 drought using the standardized precipitation index. *Bull. American Meteorological Society*, v. 80, n. 3, 429–438. 1999.

IPCC. Synthesis Report. Summary for Policymakers. In: IPCC. Climate Change, 2014.

HUGHES, B.L.; SAUNDERS, M. A. A drought climatology for Europe. **International Journal of Climatology**, v. 22, n. 13, p. 1571–1592, 2002.

LANA, X.; SERRA, C.; BURGUEÑO, A. Patterns of monthly rainfall shortage and excess in terms of the standardized precipitation index. **International Journal of Climatology**, v. 21, p. 1669–1691, 2001.

LOKE, E. **Introduction to Artificial Neural Networks in Urban Hydrology**, MATECH, Institute of Environmental Science and Engineering. Technical University of Denmark, Lyngby, p. 1–47, 1995.

- LUCENA, D. B.; SERVAIN, J.; FILHO, M. F. G. Rainfall response in Northeast Brazil from ocean climate variability during the second half of the twentieth century. **Journal of Climate**, v. 24, p. 6174-6184, 2011.
- MACEDO, M. J. H.; GUEDES, R. V. S.; SOUSA, F. A. S.; DANTAS, F. R. C. Análise do índice padronizado de precipitação para o estado da Paraíba, Brasil. **Revista Ambiente & Água**, v.5, n.1, p.204-214, 2010.
- MACHADO, S. C.; LEMUS, R. P.; FORTIS, S. R. G.; DIEZ, Y. C.; PARRA, M. J. E. Assessing the impact of El Niño Modoki on seasonal precipitation in Colombia. **Global and Planetary Change**, v. 124, p. 41–61, 2015.
- MASUD, M.B.; KHALIQ, M.N.; WHEATER, H.S. Analysis of meteorological droughts for the Saskatchewan River Basin using univariate and bivariate approaches. **Journal of Hydrology**, v. 522, p. 452–466, 2015.
- 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, p. 179–184, 1993.
- MELO, J. C. O fenômeno El Niño e as secas no Nordeste do Brasil. **Raízes**, ano XVIII, v. 20, p. 13-21, 1999.
- MOURA, G. B. A; ARAGÃO, J. O. R; MELO, J. S. P; SILVA, A. P. N; GIONGO, P. R; LACERDA, F. F. Relação entre a precipitação do leste do Nordeste do Brasil e a temperatura dos oceanos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, n.4, p.462–469, 2009.
- 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.
- MORID, S.; SMAKHTIN, V.; BAGHERZADEH, K. Drought forecasting using artificial neural networks and time series of drought indices. **International Journal of Climatology**, v. 27, p. 2103–2111, 2007.

NOBREGA, J. N.; SANTOS, C. A. C.; GOMES, O. M.; BEZERRA, B. G.; BRITO, J. I. B. Eventos extremos de precipitação nas mesorregiões da Paraíba e suas relações com a tsm dos oceanos tropicais. **Revista Brasileira de Meteorologia**, v.29, n.2, 197-208, 2014.

NOBREGA, R. S; SANTIAGO, G. A. C. F. Tendência de temperatura na superfície do mar nos Oceanos Atlântico e Pacífico e variabilidade de precipitação em Pernambuco **Revista Mercator**, Fortaleza, v. 13, n. 1, p. 107-118, jan./abr. 2014.

OBASI, G.O.P. WMO's role in the international decade for natural disaster reduction. Bulletin. **American Meteorological Society**, v. 75, p. 655–1661, 1994.

PANOFSKY, H.A.; BRIERG, W. **Some applications of statistics to meteorology**, Pennsylvania: Pennsylvania State University, 1968. 224p.

PASINI, A.; LORE, M.; AMELI, F. Neural network modelling for the analysis of forcings/temperatures relationships at different scales in the climate system. **Ecological Modelling**. v. 191, p. 58–67, 2006.

PEREIRA JR, J. S. (2007). **Nova Delimitação do Semiárido Brasileiro. Biblioteca digital da câmara dos deputados**. Disponível em: < <http://bd.camara.gov.br> >

PIRES, V. **Frequência e Intensidade de Fenômenos meteorológicos extremos associados à precipitação**. Dissertação para a obtenção do grau de Mestre em Ciências e Engenharia da Terra, Lisboa, pp.98, 2003.

QIN, Y.; YANG, D.; LEI, H.; XU, K.; XU, X. Comparative analysis of drought based on precipitation and soil moisture indices in Haihe basin of North China during the period of 1960–2010. **Journal of Hydrology**, v. 526, p. 55-67, 2015.

REPELLI, C. A.; NOBRE, P. Statistical prediction of sea-surface temperature over the tropical Atlantic. **International Journal of Climatology**, v.24, p.45-55. 2004.

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**, v. 323, p. 533–536, 1986.

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.

SANTOS, L. A. **Monitoramento da precipitação em Pernambuco utilizando a técnica dos quantis**. Trabalho de conclusão do curso em Meteorologia, UFCG, Campina Grande, Paraíba, 2011.

SALVATORE, L. **Inferência do teor de enxofre em unidades de hidrotreamento de diesel baseada em modelagem heurística**, Dissertação de Mestrado. Escola de Química, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007.

SILVA, A. P. N., MOURA, G. B. A., GIONGO, P. R., MEDEIROS, S. R. R. Correlação entre as temperaturas da superfície do mar e a quantidade da precipitação na estação chuvosa no nordeste do estado de Pernambuco. **Revista Brasileira de Meteorologia**, v. 26, n.1, 149 – 156, 2011.

SOUZA, W. S. **Rede Neural Artificial Aplicada à Previsão de Vazões Médias Mensais da Bacia Hidrográfica do Rio Piancó**. Dissertação de Mestrado em Meteorologia. Universidade Federal de Campina Grande, Campina Grande, 2008.

SRHE, Secretaria de Recursos Hídricos e Energéticos de Pernambuco, Documentos para downloads **Atlas de Bacias Hidrográficas**. Disponível em: <http://www.srhe.pe.gov.br/index.php?option=com_content&view=article&id=323:mapas-das-bacias-hidrograficas&catid=42:documentos&Itemid=75>. Acesso em: 28 jan. 2015.

SZALAI, S.; SZINELL, C. Comparison of two drought indices for drought monitoring in Hungary a case study, **Springer Netherlands**. Chapter: Drought and Drought Mitigation in Europe of the series Advances in Natural and Technological Hazards Research, v. 14, p. 161-166. 2000.

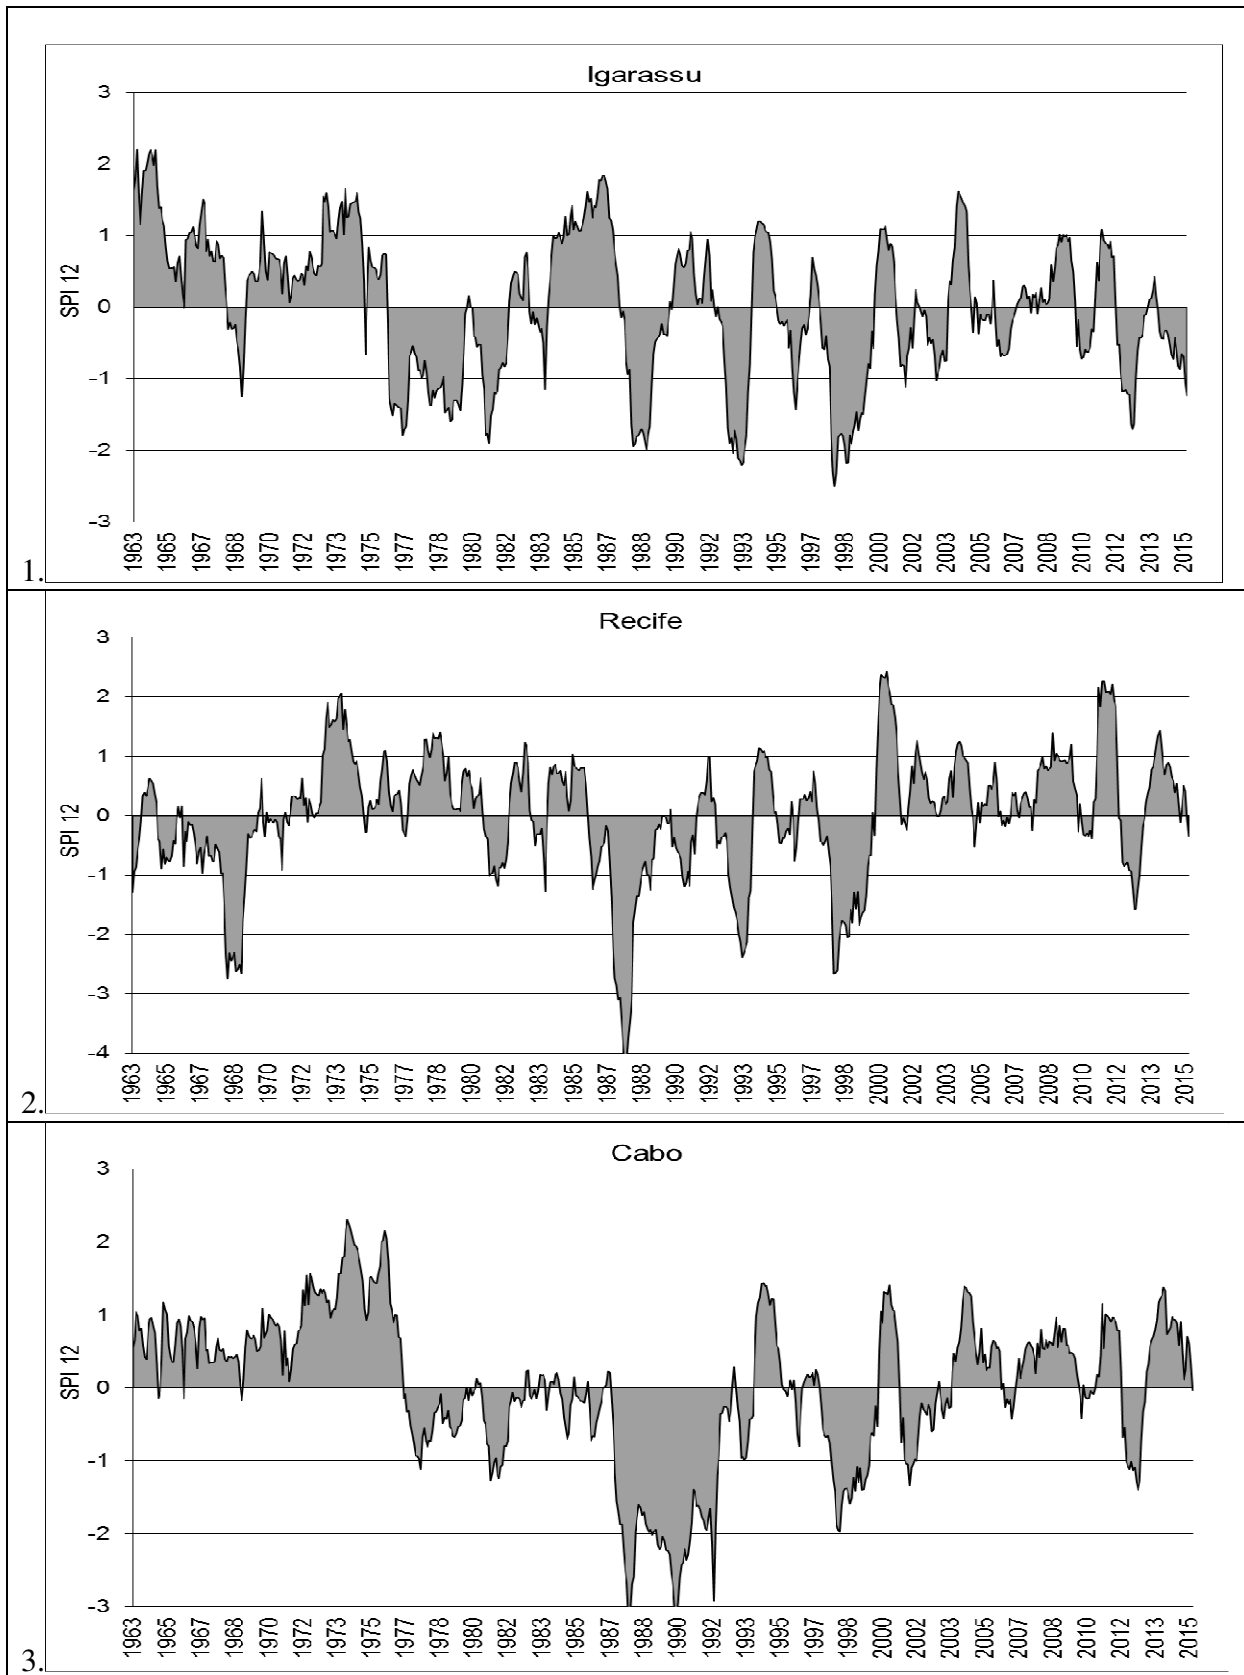
THOM, H.C.S., A note on gamma distribution. **Monthly Weather Review**. v. 86, p. 117-122. 1958.




TONKAZ, T. Spatio-temporal assessment of historical droughts using SPI with GIS in GAP Region, Turkey. **Journal of Applied Sciences**, v.12, n.6, p. 2565-2571, 2006.

TSAKIRIS, G; VANGELIS, H. Towards a Drought Watch System based on Spatial SPI. **Water Resources Management**, v.18, p. 1-12, 2004.


- USDA. Major world crop areas and climatic profiles. World Agricultural Outlook Board, US department of Agriculture, **Agricultural Handbook**, v. 664, p. 157–170. 1994.
- VALENÇA, M. J. S. **Aplicando redes neurais: um guia completo**. Olinda, PE. Ed. Livro Rápido, 284p, 2005.
- WANG, H.; CHEN, A.; WANG, Q.; HE, B. Drought dynamics and impacts on vegetation in China from 1982 to 2011. **Ecological Engineering**, v. 75, p. 303–307, 2015.
- WARD, J. H. Hierarchical grouping of optimize an objective function. **Journal of the American Statistical Association**, v. 58, p. 236-244, 1963.
- WIDROW, B. **Generalization and information in networks of adaline neurons**. In Yovits, J. and Goldstein, editors, *Self-Organizing Systems*, Washington. Spartan Books, 1962.
- WILKS, D. S. **Statistical Methods in the Atmospheric Sciences**. 2. ed. London, Academic Press, 2006. 649p.
- YANG T., ZHOU X., YU Z., KRYSANOVA V., WANG B. Drought projection based on a hybrid drought index using Artificial Neural Networks, **Hydrological Processes**, v. 29, p. 2635-2648, doi: [10.1002/hyp.10394](https://doi.org/10.1002/hyp.10394), 2014.
- ZADEH, M. R.; TABARI, H. MLP-based drought forecasting in different climatic regions. **Theoretical and Applied Climatology**, v. 109, 3-4, p. 407-414, 2012.
- ZARCH, M. A. A.; SIVAKUMAR, B.; SHARMA, A. Droughts in a warming climate: A global assessment of Standardized precipitation index (SPI) and Reconnaissance drought index (RDI). **Journal of Hydrology**, v. 526, p. 183-195, 2015.
- ZHANG, A.; JIA, G. Monitoring meteorological drought in semiarid regions using multi-sensor microwave remote sensing data. **Remote Sensing of Environment**, v. 134, p. 12–23, 2013.

APÊNDICE 1 – Distribuição do SPI-12 para cada posto analisado.







7.









8.






9.












19.




20.




21.




22.




23.




24.




25.









26.




27.









34.




35.




36.




37.






38.




39.







43.






44.




45.







49.




50.




51.




52.




53.




54.



55.



56.



57.

