



Universidade Federal da Paraíba

Centro de Tecnologia

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL

– MESTRADO –

**PREVISÃO ESPAÇO-DEPENDENTE DO ÍNDICE PADRONIZADO
DE PRECIPITAÇÃO UTILIZANDO REDES NEURAI
ARTIFICIAIS NA SUB-BACIA HIDROGRÁFICA DO ALTO SÃO
FRANCISCO**

por

Vanessa Negreiros de Medeiros Miranda

*Dissertação de Mestrado apresentada à Universidade Federal da Paraíba
para obtenção do grau de Mestre*

João Pessoa

Agosto - 2018



Universidade Federal da Paraíba

Centro de Tecnologia

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL

– MESTRADO –

**PREVISÃO ESPAÇO-DEPENDENTE DO ÍNDICE PADRONIZADO
DE PRECIPITAÇÃO UTILIZANDO REDES NEURAIS
ARTIFICIAIS NA SUB-BACIA HIDROGRÁFICA DO ALTO SÃO
FRANCISCO**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal da Paraíba, como parte dos requisitos necessários para a obtenção do título de Mestre.

Vanessa Negreiros de Medeiros Miranda

Orientador: Dr. Celso Augusto Guimarães Santos

João Pessoa

Agosto - 2018

Catálogo na publicação
Seção de Catalogação e Classificação

M672p Miranda, Vanessa Negreiros de Medeiros.

Previsão espaço-dependente do índice padronizado de precipitação utilizando redes neurais artificiais na sub-bacia hidrográfica do Alto São Francisco / Vanessa Negreiros de Medeiros Miranda. - João Pessoa, 2018.
83 f. : il.

Orientação: Celso Augusto Guimarães Santos.
Dissertação (Mestrado) - UFPB/CT/PPGECAM.

1. Previsão. 2. Rna. 3. SPI. 4. Sub-bacia 40. I. Santos, Celso Augusto Guimarães. II. Título.

UFPB/BC

**“PREVISÃO ESPAÇO-DEPENDENTE DO ÍNDICE
PADRONIZADO DE PRECIPITAÇÃO UTILIZANDO REDES
NEURAIS ARTIFICIAIS NA SUB-BACIA HIDROGRÁFICA DO
ALTO SÃO FRANCISCO”**

VANESSA NEGREIROS DE MEDEIROS MIRANDA

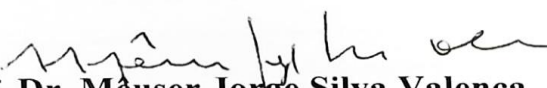
Dissertação aprovada em 17 de agosto de 2018

Período letivo: 2018.2

BANCA EXAMINADORA:


Prof. Dr. Celso Augusto Guimarães Santos
Orientador


Prof. Dr. Gustavo Barbosa Lima Silva
Examinador Interno


Prof. Dr. Meuser Jorge Silva Valença
Examinador Externo

AGRADECIMENTOS

Agradeço a Deus, fonte da Vida e Senhor da História, por me ter criado e amado com predileção.

À minha família, meus pais, irmã e cunhado por todo apoio, compreensão e colaboração.

Gratidão de coração ao meu esposo maravilhoso que não mede esforços em me ver feliz e realizada.

Ao meu pequeno Emanuel por me incentivar a ser cada dia melhor.

Ao meu orientador, o Professor Dr. Celso Augusto Guimarães Santos, exemplo de profissional e ser humano, por sua alegria, exigência e disponibilidade para ensinar. Obrigada por acreditar em mim e me fazer enxergar além.

Ao Professor Dr. Richarde Marques da Silva por todos os ensinamentos, disponibilidade e paciência.

Ao Professor Dr. Gustavo Barbosa Lima Silva e o Professor Dr. Mêuser Jorge Silva Valença, membros da banca examinadores, pelas valorosas contribuições para melhoria do trabalho e participarem dessa etapa tão importante em minha vida.

Ao Prof. Antônio Sobrinho Junior, Coordenador do Curso de Engenharia Civil do Unipê, pela amizade, incentivo, profissionalismo e apoio em todos os momentos deste percurso.

Aos alunos do grupo de pesquisa PPGECAM-LEPPAN, na pessoa de Reginaldo e Paulinha, por todos os ensinamentos, debates, críticas construtivas e presença nos momentos mais difíceis da pesquisa.

A todos que contribuíram para conclusão dessa dissertação, minha gratidão.

RESUMO

Os fenômenos naturais de secas e cheias apresentam significativas repercussões. Para evitar as consequências negativas desses fenômenos, faz-se necessário realizar um eficaz acompanhamento, análise e planejamento. Uma ferramenta que está ganhando destaque na previsão e, conseqüentemente, alerta nas tomadas de decisão são as redes neurais artificiais devido à grande capacidade de modelagem de séries temporais não-lineares e não-estacionárias, características da precipitação. Diante do exposto, o objetivo geral deste trabalho consiste em realizar a previsão espaço-temporal de SPI, parâmetro de quantificação da seca e umidade, na sub-bacia Hidrográfica do Alto São Francisco (sub-bacia 40), através da aplicação de Rede Neural Artificial e avaliar sua eficiência, sendo os objetivos específicos: (a) Analisar o comportamento espaço-temporal dos índices de precipitação padronizado, de curto e longo prazo, ao longo do período de 1998 a 2015; (b) Desenvolver arquitetura das RNAs, realizar a previsão de SPI para curto e longo prazo, avaliar a qualidade dos resultados e definir o melhor Modelo; (d) Analisar a correlação espaço-dependente entre os dados observados e os previstos pelo melhor modelo de previsão; e (e) analisar o efeito estocástico nos resultados previstos pelo melhor modelo de previsão para 30 rodadas. O estudo foi realizado em uma malha espacial de 169 (cento e sessenta e nove) pontos, equidistantes 0.25° , compreendendo a sub-bacia 40, localizada na região central de Minas Gerais. Os dados de precipitação utilizados foram adquiridos do produto 3B42 do satélite TRMM e compreendeu o período de 1 de janeiro 1998 a 31 de dezembro de 2015. Utilizando RNAs multicamadas *feedforward* treinadas pelo algoritmo de Levenberg-Marquardt, foram realizadas as previsões para um ano à frente e o desempenho de cada RNA foi avaliado. A partir dos resultados obtidos, observa-se que as RNAs que apresentaram os melhores desempenhos pertencem ao Modelo 15, com 15 anos de dados de entrada, os anos 2000 a 2014. Os valores de R e kappa, resultantes da previsão utilizando as RNAs do Modelo 15, foram melhores para os SPIs de longo prazo em comparação com os resultados de SPIs de curto prazo. Os valores R variaram de muito baixa ($0 \leq R < -0,1$) a alta (0,7 a 0,9) e muito alta (0,9 a 1), constituindo estes dois últimos na maioria dos valores de previsão. Já o kappa variou de ótima (0,81–0,99) a sofrível (0,20–0,40), sendo estes últimos, resultados pontuais. Dessa forma, a RNA com 15 anos de dados de entrada provou ser uma ferramenta eficaz para previsão de SPI de um ano à frente.

PALAVRAS-CHAVE: Previsão, RNA, SPI, Sub-bacia 40.

ABSTRACT

The natural phenomena of droughts and floods have significant repercussions. To avoid the negative consequences of these phenomena, it is necessary to carry out an effective monitoring, analysis and planning. A tool that is gaining prominence in forecasting and, consequently, alerting in decision making is the artificial neural networks due to the large modeling capacity of non-linear and non-stationary time series, characteristics of precipitation. In view of the above, the general objective of this work is to perform SPI spatiotemporal prediction, parameter of drought and humidity quantification, in the Upper São Francisco river sub-basin (sub-basin 40), through the application of Artificial Neural Network and to evaluate its efficiency, with the specific objectives being: (a) to analyze the spatio-temporal behavior of standardized precipitation indices, in the short- and long-term, from 1998 to 2015; (b) to develop ANN architecture, perform SPI forecast for short- and long-term, evaluate the quality of results and define the best model; (d) to analyze the spatiotemporal correlation between the data observed and those predicted by the best prediction model; and (e) to analyze the stochastic effect on the results predicted by the best prediction model after 30 runs. The study was carried out in a space grid of 169 (one hundred and sixty-nine) points, equidistant 0.25° , comprising sub-basin 40, located in the central region of Minas Gerais. The precipitation data used were obtained from the TRMM 3B42 product and comprised the period from January 1, 1998 to December 31, 2015. Using feedforward multilayer ANNs trained by the Levenberg-Marquardt algorithm, forecasts were made for a year ahead and the performance of each ANN was evaluated. From the obtained results, it is observed that the ANNs that presented the best performances belong to the Model 15, with 15 years of input data, the years 2000 to 2014. The values of R and kappa, resulting from the prediction using the ANNs from Model 15, were better for long-term SPIs compared to short-term SPI results. The R values ranged from very low ($0 \leq R < -0.1$) to high (0.7 to 0.9) and very high (0.9 to 1), the latter two being at most of the forecast values. The kappa varied from optimal (0.81–0.99) to poor (0.20–0.40), the latter being punctual results. Thus, ANN with 15 years of input data proved to be an effective tool for predicting SPI from one year ahead.

KEYWORDS: ANN, forecast, SPI, sub-basin 40.

LISTA DE FIGURAS

Figura 1 – Classificação do SPI e sua relação com a curva normal padrão (SANTOS et al., 2017).....	18
Figura 2 – Neurônio biológico simplificado (FACELI et al., 2011)	22
Figura 3 - Modelo de um neurônio artificial (RAUBER, 2014)	23
Figura 4 – RNA multicamadas (Faceli et al., 2011).....	25
Figura 5 - Grau de conexão entre neurônio de uma RNA multicamadas (Faceli et al., 2011).....	26
Figura 6 – Redes neurais feedforward e recorrente (FACELI et al., 2011)	26
Figura 7 - Funções de Ativação.....	27
Figura 8 – Localização da sub-bacia hidrográfica do Alto São Francisco	31
Figura 9 - Grade de pontos TRMM.....	32
Figura 10 – Esquema do processamento da RNA (Modelo 2) para previsão anual do SPI-1	37
Figura 11 – Exemplo da arquitetura da RNA (Modelo 2).....	38
Figura 12 – SPI a curto prazo do Ponto 1.....	42
Figura 13 – SPI a longo prazo do Ponto 1.....	43
Figura 14 – Representação da organização dos dados para realização das previsões.	44
Figura 15 – Quantidade de neurônios na camada intermediária que geraram os melhores resultados de previsão.	47
Figura 16 – Diagrama de caixa da variação dos dados resultantes das 10 rodadas de previsão.....	48
Figura 17 – Índice de correlação (R) mensal resultante dos 17 Modelos.....	51
Figura 18 – Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 15.	52
Figura 19 – Comparação entre os dados de SPI-24 observados e previstos para o mês de janeiro do ano de 2015 sobre o Alto do São Francisco – Modelo 15.....	54
Figura 20 – Comparação entre as séries de dados de SPI-24 observados e previstos para o mês de janeiro do ano de 2015 sobre o Alto do São Francisco – Modelo 15.	56
Figura 21 – Dados de SPI-24 observados e previstos nas oito faixas de classificação (mês de janeiro de 2015 - Modelo 15).....	57

Figura 22 – Comparação entre os dados de SPI-24 observados e previstos no ano de 2015 sobre o Alto do São Francisco – Modelo 15.	58
Figura 23 - Diagrama de caixa da variação dos dados de kappa resultantes de 30 rodadas de previsão utilizando o Modelo 15.	60
Figura 24 - Diagrama de caixa da variação dos dados de R resultantes de 30 rodadas de previsão utilizando o Modelo 15.	60

LISTA DE TABELAS

Tabela 1 – Classificação do SPI	18
Tabela 2 - Modelos das RNAs e respectivos dados de entrada.	36
Tabela 3 – Escala do coeficiente de correlação de Pearson (R)	40
Tabela 4 – Escala de concordância do kappa de Cohen	41
Tabela 5 – Melhor número de neurônios para previsão de acordo com SPI e dados de entrada.	46
Tabela 6 – Quantidade de neurônios que geraram os melhores resultados de previsão para 10 rodadas respectivas.	47
Tabela 7 – Índice de correlação R geral entre os dados observados e previstos.	49
Tabela 8 - Índice de concordância kappa geral entre os dados observados e previstos.	49
Tabela 9 – Coeficiente de correlação R mensal resultante do Modelo 15.	53
Tabela 10 - Índice de concordância kappa mensal resultantes do Modelo 15.	53
Tabela 11 – Coeficiente de correlação R mensal resultante da previsão do ano de 2014	61
Tabela 12 – Coeficiente de correlação R mensal resultante da previsão do ano de 2013	61

SUMÁRIO

CAPÍTULO 1	12
1. INTRODUÇÃO.....	12
1.1. OBJETIVOS	14
1.1.1. Objetivo Geral:	14
1.1.2. Objetivos Específicos:	14
1.2. ESTRUTURA DA DISSERTAÇÃO	14
CAPÍTULO 2	15
2. FUNDAMENTAÇÃO TEÓRIA	15
2.1. ÍNDICE PADRONIZADO DE PRECIPITAÇÃO – SPI.....	16
2.1.1. VANTAGENS DO USO DO SPI.....	19
2.2. REDES NEURAIS ARTIFICIAIS – RNA	20
2.2.1. HISTÓRICO DAS RNA.....	20
2.2.2. NEURÔNIO BIOLÓGICO.....	21
2.2.3. NEURÔNIO ARTIFICIAL	22
2.2.4. A RNA E SEUS COMPONENTES BÁSICOS	24
2.2.4.1. ARQUITETURA	24
2.2.4.2. TOPOLOGIA.....	25
2.2.4.3. FUNÇÃO DE ATIVAÇÃO	27
2.2.4.4. PROCESSO DE APRENDIZADO.....	27
2.2.5. VANTAGENS	28
CAPÍTULO 3	30
3. METODOLOGIA.....	30
3.1. DESCRIÇÃO DA ÁREA EM ESTUDO.....	30
3.2. DADOS DE PRECIPITAÇÃO TRMM.....	31
3.3. ÍNDICE PADRONIZADO DE PRECIPITAÇÃO – SPI.....	33

3.4. REDES NEURAIS ARTIFICIAS	35
3.4.1. Entrada na RNA.....	35
3.4.2. Arquitetura da RNA.....	37
3.4.3. Aprendizagem da RNA.....	38
3.4.4. Verificação da RNA.....	39
3.4.5. Índices de Desempenho	39
3.4.5.1. Coeficiente De Correlação De Pearson (R).....	40
3.4.5.2. Grau de Concordância De Cohen (kappa)	40
CAPITULO 4	42
4. RESULTADOS	42
4.1. COMPORTAMENTO DOS SPI.....	42
4.2. REDE NEURAL ARTIFICIAL	43
4.2.1. Previsão a partir de 17 modelos de RNAs	43
4.2.2. Definição do número de neurônios na camada escondida.....	45
4.2.3. Desempenho das previsões (R e kappa anual).....	48
4.2.4. Desempenho das previsões (R e kappa mensal)	50
4.2.5. Determinação do modelo de RNAs com melhor desempenho	51
4.2.6. Análise estatística dos resultados de previsão	59
CAPÍTULO 5	63
5. CONCLUSÕES E RECOMENDAÇÕES	63
5.1. CONCLUSÕES.....	63
5.2. RECOMENDAÇÕES	64
REFERÊNCIAS	65
APÊNDICE A	70
APÊNDICE B.....	77

CAPÍTULO 1

Este capítulo mostra uma visão geral acerca da problemática, além dos objetivos e estruturação da dissertação.

1. INTRODUÇÃO

Os fenômenos naturais de secas e cheias, devido a suas inerentes complexidades, apresentam significativas repercussões nos ecossistemas, nas atividades socioeconômicas, culturais e históricas. Dentre suas características, destacam-se o seu desenvolvimento lento, suas longas durações e múltiplas facetas em uma única região, notadamente quanto à escassez hídrica, que tem assolado a maioria dos continentes ao redor do mundo nas últimas três décadas, a afetar a sobrevivência de bilhões de pessoas em todo o planeta (MORID *et al.*, 2007; MISHRA & SINGH, 2010).

Os impactos causados são diretamente influenciados pela intensidade com que acontecem os fenômenos secos e úmidos. Para caracterizá-los e modelá-los de forma adequada, os fenômenos podem ser representados por índices e estes classificados com base em variáveis hidrometeorológicas.

Em 1993, McKee *et al.* (1993) criou um indicador e definidor de seca, o índice de precipitação padronizado SPI (*Standardized Precipitation Index*), para servir como uma ferramenta útil no acompanhamento e análise desses fenômenos. Esse indicador ganhou popularidade mundial entre os pesquisadores pela sua capacidade de melhor quantificar a intensidade e duração de eventos secos e úmidos em diferentes escalas temporais e suas possíveis condições regionais, o que lhe permite descrever importantes condições de seca para uma variedade de aplicações meteorológicas, utilizando apenas a precipitação como variável hidrometeorológica.

Dentre as vantagens, o SPI proporciona facilidade de computação e possibilita a comparação dos valores para diferentes regiões, por ser um índice padronizado (KIM *et al.*, 2006; HAYES *et al.*, 1999). No Brasil, esse índice é um dos métodos recomendados pelo INMET (Instituto Nacional de Meteorologia) para caracterizar anomalias de precipitação.

Os dados de precipitação utilizados para o cálculo dos valores de SPI podem ser provenientes de postos pluviométricos ou medidos por satélites. Essa última opção, de acordo com Soares *et al.* (2016), tem se tornado cada vez mais frequente em vários

estudos hidrológicos devido ao fato dos sensores orbitais fornecerem rapidamente informações, com abrangência espacial e com qualidade crescente.

Dentre os tipos de satélites para esta finalidade, Collischonn (2006) destacou os satélites da série GOES (*Geoestationary Operational Environmental System*) e TRMM (*Tropical Rainfall Measuring Mission*), este último projetado para estudar precipitação e realizar pesquisas climáticas nos trópicos (NASA, 2016).

Neste estudo, para além do acompanhamento e análise dos fenômenos de precipitação por meio dos produtos do satélite TRMM, faz-se necessário realizar o planejamento, cujo sucesso está estritamente relacionado com o número de previsões acerca da problemática.

Desse modo, a modelagem hidrológica surge como uma ferramenta de previsão e, consequentemente, alerta nas tomadas de decisão. Dentre essas ferramentas, as Redes Neurais Artificiais (RNA) têm se destacado pela grande capacidade de modelagem de séries temporais não-lineares e não-estacionárias, provando ser uma ferramenta útil para a previsão de fenômenos naturais (CUTORE *et al.*, 2009; SANTOS *et al.*, 2009).

A área a ser analisada está compreendida na Região Hidrográfica do São Francisco, bacia de fundamental importância devido ao grande volume de água transportada para o semiárido, localizada em região caracterizada por ocorrência de clima semiárido e de ampla importância para o País em termos sociais, econômicos e culturais.

Especificamente, a região estudada é a sub-bacia 40, que corresponde à área de drenagem do reservatório de Três Marias e parte da área de drenagem do Alto São Francisco, constituindo um dos reservatórios mais importantes do Brasil por ocasião da instalação e funcionamento da Usina Hidrelétrica Três Marias.

O estudo proposto será aplicado em uma malha espacial de 169 (cento e sessenta e nove) pontos, equidistantes 0.25° , localizada entre os paralelos 18° e 21° de latitude sul e os meridianos 43.75° e 46.75° de longitude oeste, compreendendo a sub-bacia hidrográfica do Alto São Francisco até Três Marias ou sub-40, localizada na região central de Minas Gerais.

O estudo espera obter significativa previsão a curto e longo prazo dos fenômenos secos e úmidos ao longo da sub-bacia hidrográfica do Alto São Francisco, utilizando o índice de precipitação padronizado, SPI, a partir de dados de precipitação provenientes do satélite TRMM no período de 1998 a 2015.

1.1.OBJETIVOS

1.1.1. Objetivo Geral:

Avaliar o desempenho das Redes Neurais Artificiais na previsão espaço-temporal de SPI, parâmetro de quantificação da seca e umidade, na sub-bacia Hidrográfica do Alto São Francisco (sub-bacia 40).

1.1.2. Objetivos Específicos:

- Analisar o comportamento espaço-temporal dos índices de precipitação padronizado, de curto e longo prazo, ao longo do período de 1998 a 2015;
- Desenvolver arquitetura das RNAs, realizar a previsão de SPI para curto e longo prazo, avaliar a qualidade dos resultados e definir o melhor Modelo;
- Analisar a correlação espaço-temporal entre os dados observados e os previstos pelo melhor Modelo de previsão; e
- Analisar o efeito estocástico nos resultados previstos pelo melhor Modelo de previsão para 30 rodadas.

1.2.ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está dividida da seguinte forma: o capítulo 1 contém uma visão geral acerca do problema, o objetivo geral e específicos e estruturação da dissertação; o capítulo 2 apresenta a fundamentação teórica sobre SPI e RNAs; o capítulo 3 descreve a metodologia adotada; o capítulo 4 apresenta os resultados e discussões acerca dos mesmos; e o capítulo 5 contém as conclusões e recomendações para futuros trabalhos.

CAPÍTULO 2

Neste capítulo é apresentada uma breve revisão bibliográfica que objetivou uma atualização das pesquisas existentes dentro da temática escolhida para essa dissertação, além de serem apresentados alguns conceitos relevantes sobre SPI e RNAs.

2. FUNDAMENTAÇÃO TEÓRIA

O estudo e aplicação do índice de seca, SPI, vem crescendo entre os cientistas que comprovam, cada vez mais, a sua aplicabilidade e eficácia (KURNIK *et al.*, 2011; MORID *et al.*, 2006; NEDEALCOV *et al.*, 2015).

Kurnik *et al.* (2011) ao estudarem a possibilidade de utilizar o SPI para monitorar as condições de seca no Chifre da África, região nordeste do referido continente, calcularam valores de SPI 3, 6, 9 e 12 meses para o período de 1985 a 2008 com dados de precipitação do Centro de Climatologia de Precipitação Global (GPCC) e Centro Europeu de Previsão de Tempo Médio (ECMWF). Ao realizarem teste com os dois conjuntos de dados de SPI diferentes, os primeiros resultados demonstraram a viabilidade de utilizar o SPI para monitoramento de secas em escalas regionais na África.

Morid *et al.* (2006) compararam o desempenho de sete índices para monitoramento da seca na província de Teerã, Irã. Os índices utilizados incluíram o DI, PN, SPI, CZI, MCZI, Z-Score e o EDI. A comparação dos índices foi baseada em casos de seca e classes que foram detectados na província ao longo dos 32 anos de dados. Os resultados mostram que o SPI e EDI apresentaram variação espacial e temporal de seca consistente.

Nedealcov *et al.* (2015) utilizou os índices de seca SPI e SPEI para realizar uma estimativa espaço-temporal regional de seca na República da Moldávia. Mapas digitais foram elaborados para servir como referência na elaboração dos Atlas relativos a um acompanhamento científico de secas sobre a República Moldávia.

Aliado ao uso dos índices de seca, em especial o SPI para o monitoramento de secas, as redes neurais artificiais tem sido largamente utilizadas pelos cientistas para realização de previsões (MISHRA & DESAI, 2006; SANTOS *et al.*, 2015; GUEDES, 2011;).

Mishra & Desai (2006) calcularam as séries de SPI para múltiplas escalas de tempo e realizaram uma comparação entre Redes Neurais Artificiais e Modelos Estocásticos Lineares para previsão de seca utilizando como índice o SPI. Redes neurais recursivas, redes neurais direta e modelos estocásticos lineares (ARIMA / SARIMA), foram aplicadas para a previsão de seca na Bacia do Rio Kansabati, na Índia. Os resultados mostraram que RNA recursiva apresentou melhores resultados para previsão de um 1 mês à frente, a RNA direta teve, sempre, desempenho superior às outras duas quando o tempo de previsão foi acima de 4 meses e o ARIMA apresentou bons resultados quando o tempo de previsão foi de até 2 meses, mas inferior em comparação com a RNA direta. Dessa forma, eles conseguiram demonstrar que, nesse caso, as RNA são superiores aos modelos estocásticos lineares.

Santos *et al.* (2015) fizeram uso das redes neurais artificiais para previsão, em Portugal Continental, do SPI relativo à primavera. Devido o país ter sua agricultura prejudicada pelos eventos de seca, o índice SPI foi calculado à escala temporal de 6 meses, escala mais adequada para representar seca agrícola. Para a realização da previsão, foram avaliados, ainda, a influência de predictores externos, como o índice NAO de inverno e as temperaturas da superfície do mar (SST) relativos também a estação de Inverno. Os resultados permitiram concluir que pode haver uma melhoria da capacidade de previsão dos modelos.

Guedes (2011) utilizou as RNAs para previsão de séries temporais do índice padronizado de precipitação (SPI) na bacia hidrográfica do açude Eptácio Pessoa, município de Boqueirão-PB, e avaliou sua eficiência. Para conseguir um modelo que gerasse os menores erros, ele realizou sucessivas mudanças na configuração da rede. A rede adotada mostrou-se eficiente para previsões de até 3 meses e escalas de SPI maiores. Quando os horizontes temporais foram maiores, houve uma diminuição da qualidade dos resultados, sendo necessário realizar outros testes para melhorar o processo de aprendizagem da rede.

2.1.ÍNDICE PADRONIZADO DE PRECIPITAÇÃO – SPI

O índice padronizado de precipitação (SPI), proposto por McKee, Doesken e Kliest, no ano de 1993, no artigo intitulado *Drought monitoring with multiple time scales*, foi desenvolvido para servir como uma ferramenta versátil no monitoramento e análise de precipitação. Baseado na quantificação do déficit ou excesso de precipitação

em diferentes escalas temporais, ele é capaz de refletir o impacto da seca em regiões de diferentes disponibilidades de água (MCKEE *et al.*, 1995).

Definido por Chen & Yang (2012) como o desvio padrão entre a precipitação medida e a função de distribuição de probabilidade de chuva, o SPI é calculado a partir dos dados de precipitação organizados em uma distribuição de probabilidades e, em seguida, transformados em uma distribuição normal padrão.

As séries de precipitação utilizadas para o cálculo do SPI, de acordo com o *National Drought Mitigation Center* (2017), devem ser compostas por longos períodos. Entretanto, vale evidenciar que quanto mais longas as séries de dados, maiores são as chances de incorporar efeitos de tendência e de não-estacionaridade, como mudanças na média, desvio, variância, etc nos valores de SPI.

Para melhor representar a distribuição dos dados de precipitação, o conjunto de dados históricos é ajustado a uma função de distribuição de probabilidades do tipo Gama, utilizada por McKee *et al.* (1993) na formulação original do SPI, uma vez que é o tipo que melhor se adequa à distribuição de precipitação, e aos parâmetros α e β , que representam a forma de distribuição. Desse modo, estabelecida a função de probabilidade acumulada, torna-se possível o indicativo de eventos secos e úmidos, representados por baixa e alta probabilidade, respectivamente, em relação à função de probabilidade acumulada.

Entretanto, o indicativo de um evento seco e úmido é em relação à média e ao desvio padrão da função de probabilidade acumulada do tipo Gama de uma determinada área. Isto significa que ao mudar a área analisada, as características de precipitação mudam, consequentemente, a média e o desvio padrão, tornando-se impraticável a comparação de eventos de precipitação para áreas diferentes, uma vez que a ocorrência de um evento seco em uma área pode representar um evento úmido em outra.

Para realizar a análise de eventos de precipitação em regiões de diferentes disponibilidades hídricas, faz-se necessário normalizar o valor do SPI. A função de probabilidade cumulativa tipo Gama é transformada na variável Z , função de distribuição normal padrão, com média igual a zero e desvio padrão de unidade. Desse modo, os valores de precipitação da função Gama possuem um correspondente na função Z , sendo este o valor do índice padronizado de precipitação (SPI) para um ponto particular de dados de precipitação.

De acordo com este índice, pode-se determinar o início e fim de um evento de seca, bem como de um evento úmido, através de valores negativos e positivos,

respectivamente. Os valores negativos do SPI indicam que a precipitação foi menor que a precipitação média, já os valores positivos indicam ocorrência de precipitação acima de média. A Tabela 1 apresenta as oito faixas de classificação dos valores do SPI, que variam de $-3,0$ a $3,0$, divididas de acordo com os eventos de precipitação.

Tabela 1 – Classificação do SPI

Valores de SPI	Categoria
$\geq 2,00$	Extremamente úmido
1,50 a 1,99	Severamente úmido
1,0 a 1,49	Moderadamente úmido
$-0,99$ a $0,99$	Próximo do normal
$-1,00$ a $-1,49$	Moderadamente seco
$-1,50$ a $-1,99$	Severamente seco
$\leq -2,00$	Extremamente seco

Fonte: Adaptado de McKee *et al.* (1993).

A Figura 1 representa as probabilidades, distribuição da curva normal padrão, associadas à classificação do SPI, em uma escala que varia do $-3,0$, evento extremamente seco, ao $3,0$, extremamente úmido, e a definição da escala de cores representativa para oito tipos de eventos, onde a classificação próximo ao normal (Tabela 1) foi dividida em *suavemente seco* e *suavemente úmido*. Assim, e de acordo com a Figura 1, a probabilidade acumulada de um evento ter o valor de SPI próximo de 0 é de aproximadamente 50%. Chega-se a este valor somando as porcentagens de probabilidades de -3 a 0 ou de 3 a 0.

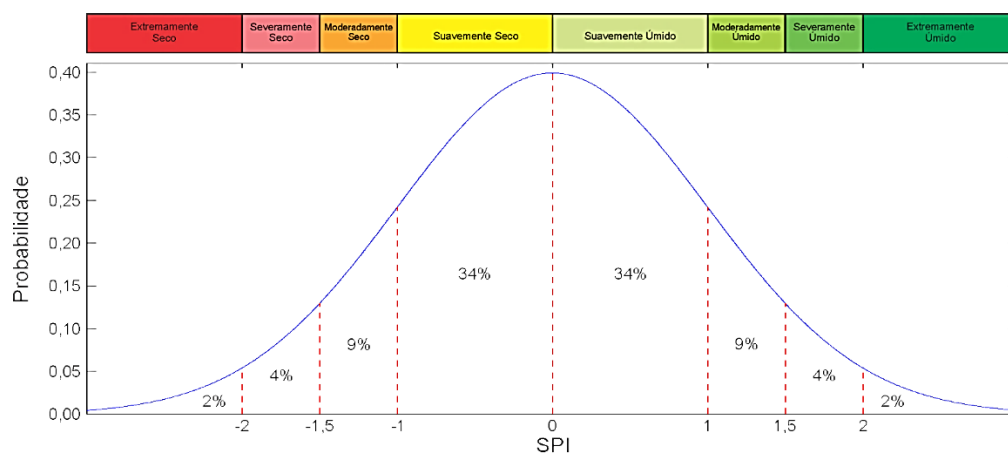


Figura 1 – Classificação do SPI e sua relação com a curva normal padrão (SANTOS et al., 2017)

Os valores SPI são calculados para diferentes escalas temporais, de curto e longo prazo, sendo frequentemente medidas as escalas de 1, 3, 6, e 9 meses, correspondendo a curto prazo, e 12, 24 e 48 meses, longo prazo. Um SPI de t meses compara a precipitação ao longo de um período de t meses, para o ano em análise, com os totais de precipitação do mesmo período de t meses de todos os anos do registro histórico.

Por exemplo, o SPI-9 no final do mês de setembro compara a precipitação acumulada ao longo dos últimos nove meses, ou seja, dos meses de janeiro até setembro, do ano em análise, com as precipitações acumuladas do mês de janeiro até setembro de todos os anos do registro histórico (WMO, 2012).

McKee *et al.* (1993) percebeu que para pequenas escalas de tempo, cada novo mês provoca um impacto relevante, de modo que o SPI pode mover-se rapidamente entre valores secos e úmidos. Entretanto, para escalas de tempo maiores, o índice responde mais lentamente, já que cada novo mês não tem grande impacto sobre o total.

De acordo com a *World Meteorological Organization* (2012) os SPIs de 1 a 3 meses, curto prazo, estão associados a condições de umidade do solo. O SPI-6, por sua vez, está associado a vazões e níveis irregulares de reservatório, e a partir do SPI-9 em diante, a vazões, níveis de reservatórios e níveis de águas subterrâneas.

Em relação aos tipos de seca, Passos (2015), relacionou os SPIs de 1 ou 2 meses para análises de seca meteorológica, os SPIs de 1 a 6 meses para análises de seca agrícola e SPI de 6 meses ou mais para análises de seca hidrológica e aplicações.

A partir da sucessão de valores de SPI, o início, o fim, a duração, a magnitude e a intensidade do evento de seca ou umidade podem ser identificados. A duração de um evento corresponde ao número de meses que decorrem entre o seu início e fim, a magnitude resulta da soma positiva do SPI para todos os meses durante o evento de precipitação e a intensidade equivale ao quociente entre a magnitude e a duração (MCKEE *et al.* 1993, 1995; MORID *et al.*, 2006).

2.1.1. VANTAGENS DO USO DO SPI

O SPI é um dos índices de precipitação mais utilizados pelos pesquisadores para caracterizar eventos secos e úmidos devido aos atributos abaixo:

- Utiliza apenas a precipitação como variável hidrometeorológica para o seu cálculo, indicando a ocorrência de eventos secos ou úmidos;

- É normalizado espacial e temporalmente, o que permite a comparação entre valores de SPI em diferentes regiões, com diferentes estações climáticas e períodos temporais distintos;
- Pode ser calculado para diferentes escalas temporais, cada qual associada a uma ou mais variáveis de recursos hídricos, como, umidade do solo, vazão, níveis de reservatório, águas subterrâneas, neve acumulada.
- É uma ferramenta operacional, pois pode ser calculada em tempo real;

Pelas suas características, o SPI é considerado um instrumento útil, simples e versátil no monitoramento e análise de precipitação, cujos resultados são utilizados em planejamentos estratégicos das bacias hidrográficas.

2.2.REDES NEURAIS ARTIFICIAIS – RNA

2.2.1. HISTÓRICO DAS RNA

Os primeiros estudos acerca do tema foram escritos pelo psiquiatra e neuroanatomista Warren Mcculloch e o matemático Walter Pitts, em 1943, em um artigo intitulado *A logical calculus of the ideas immanent in nervous activity*, no qual sugeriram a construção de uma máquina computacional inspirada no cérebro humano.

Mcculloch e Pitts, ao proporem um modelo de neurônio artificial em que os neurônios executavam funções lógicas simples e cada um podia executar uma função diferente, provaram que a combinação de vários neurônios artificiais em sistemas neurais produz um elevado poder computacional, uma vez que, aparentemente, qualquer função que pudesse ser representada por uma combinação de funções lógicas poderia ser modelada por uma rede formada por esses neurônios (FACELI *et al.*, 2011).

As descobertas Mcculloch e Pitts influenciaram outros pesquisadores e, desse modo, surgiram muitos estudos acerca da temática. Como exemplo de cientistas que provocaram um desenvolvimento significativo das redes neurais, até final da década de 50, estão Hebb e Rosenblatt. Hebb (1949) ao afirmar que a eficiência de uma sinapse variável entre dois neurônios é aumentada pela ativação repetida de um neurônio causada pelo outro neurônio, através daquela sinapse, definiu um algoritmo de adaptação dos pesos. Já Rosenblatt (1958) apresentou o *perceptron*, um sistema de rede neural simples, composta de entradas e uma saída, com fluxo de informação

unidirecional e dotado de um algoritmo de aprendizagem dos pesos que a tornou capaz de resolver problemas de classificação linearmente separáveis.

Entretanto, devido a limitação do *perceptron* em classificar apenas padrões linearmente separáveis, poucos foram os avanços significativos ao longo de décadas. Minsky & Papert (1969) comprovaram matematicamente que o simples problema do “Ou exclusivo” (XOR) não conseguia ser resolvido pelo *perceptron*, fazendo grande parte da comunidade científica abandonar os estudos na área.

Para resolver o problema da não-linearidade, descobriram que ao acrescentar uma camada intermediária entre a camada de entrada e de saída, os problemas cujos padrões eram não-lineares poderiam ser resolvidos. Entretanto, por se tratar de problemas complexos, apenas a adoção de uma rede com multicamadas não era suficiente, era necessário um algoritmo que fosse capaz de treinar os pesos da rede de maneira que realizasse a classificação correta dos problemas (HAYKIN, 2011).

Em 1986, um dos trabalhos que pode ser considerado uma das principais contribuições para a retomada dos estudos sobre RNA, foram propostos por Rumelhart *et al.* (1986), onde um algoritmo de aprendizado capaz de transpor as limitações que haviam na utilização de redes *perceptron* multicamadas e denominado “retropropagação de erro” (error backpropagation) foi apresentado.

A partir do explanado, pode-se perceber que o caminho percorrido pelas redes neurais é longo e complexo. Desde as descobertas apresentadas por McCulloch e Pitts, as RNAs estão sendo aperfeiçoadas de maneira que conseguiram estabelecer-se em múltiplas áreas, como a matemática, engenharia, neurociências, psicologia e ciências físicas (HAYKIN, 2011).

2.2.2. NEURÔNIO BIOLÓGICO

As redes neurais artificiais tiveram a sua inspiração no comportamento inteligente do cérebro humano, capaz de processar e gerar respostas a tarefas complexas com uma aparente facilidade que somente é possível devido a complexa estrutura e funcionamento do sistema nervoso.

Esse sistema consiste em um conjunto complexo de células que determinam o funcionamento e o comportamento dos seres vivos. O cérebro é o elemento principal e possui como sua unidade fundamental, o neurônio, que se diferencia das outras células

pela capacidade de responder a estímulos, possibilitando a transmissão de impulsos nervosos a outros neurônios.

De acordo com Gonçalves (2016) os principais componentes dessa célula nervosa, o neurônio, são os dendritos, o corpo celular e o axônio. Os dendritos são especializados na recepção dos estímulos nervosos provenientes de outros neurônios ou do ambiente. Os referidos estímulos são transmitidos para o corpo celular, que coleta as informações, as combina e processa. Caso a intensidade e frequência desses estímulos sejam significativas, o corpo celular gera um novo estímulo que é recebido pelo axônio, um prolongamento dos neurônios responsável pela condução dos impulsos elétricos produzidos no corpo celular para locais mais distantes, outros neurônios.

Além dos três componentes principais, há as sinapses, unidades que fazem a mediação das interações entre os neurônios e são o contato entre a terminação de um axônio e o dendrito de outro neurônio (FACELI *et al.*, 2011).

Na Figura 2 podem ser visualizados os elementos de um neurônio simplificado.




Figura 2 – Neurônio biológico simplificado (FACELI *et al.*, 2011)

2.2.3. NEURÔNIO ARTIFICIAL

Baseado na estrutura e no funcionamento do neurônio biológico, as unidades de processamento simples, ou neurônios artificiais, foram criados constituindo-se como o elemento básico das redes neurais artificiais e responsáveis por computar funções matemáticas.

Na Figura 3, observa-se a representação de um neurônio matemático proposto por McCulloch & Pitts (1943), onde um neurônio com D terminais de entrada,

recebendo x estímulos, representado na forma de vetor como $x = [x_1, x_2, \dots, x_D]$ e, simulando as sinapses, pesos associados aos terminais de entrada, representados na forma vetorial como $w = [w_1, w_2, \dots, w_D]$, cujos valores podem ser positivos ou negativos, correspondendo às sinapses excitatórias e inibitórias, respectivamente.

A cada entrada está associada um peso, chamado de peso sináptico, que reflete a importância da entrada. O resultado dos produtos das entradas pelos respectivos pesos, correspondem ao processamento realizado pelo corpo celular ou soma, sendo representados como $[x_1w_1 + x_2w_2 + \dots + x_Dw_D]$. A função de ativação recebe o estímulo, resultado do corpo celular, e transfere a resposta do neurônio para a camada adjacente, sendo a função de ativação determinante para o valor de saída do neurônio. O valor limiar de saída do neurônio é igual a 1 ou 0, este último número pode ser substituído por -1 . Quando o valor da combinação linear ultrapassar o limiar estabelecido (μ), o neurônio torna-se ativo, ou seja, o valor é igual a 1, caso contrário, a saída é igual a 0, ou alternativamente, -1 (GALVÃO & VALENÇA, 1999).

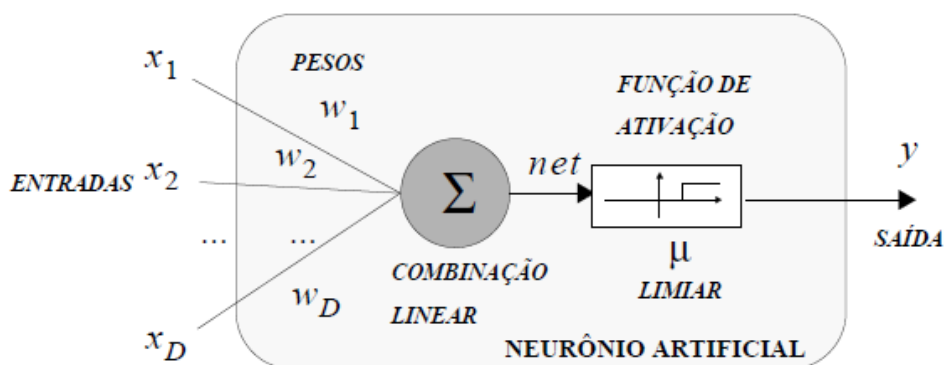


Figura 3 - Modelo de um neurônio artificial (RAUBER, 2014)

Inspirado no comportamento das células neurais biológicas, os neurônios artificiais possuem uma estrutura que simula a forma, o comportamento e as funções de um neurônio biológico.

De acordo com Haykin (2011), uma RNA assemelha-se ao cérebro em dois aspectos: primeiro, o conhecimento adquirido pela rede a partir de seu ambiente é através de um processo de aprendizagem e, segundo, os pesos sinápticos, forças de conexão entre os neurônios, são utilizados para armazenar o conhecimento adquirido.

Comparando as Figuras 2 e 3, percebe-se que há diversas características em comum, tais como:

- (a) Os terminais de entrada simulam os dendritos;
- (b) As sinapses são representadas pelos pesos sinápticos;
- (c) Os estímulos recebidos pela entrada são ponderados e combinados, equivalendo ao corpo celular;
- (d) A função de ativação é responsável pela intensidade das informações processadas aos neurônios adjacentes.

2.2.4. A RNA E SEUS COMPONENTES BÁSICOS

Como afirmado anteriormente, uma rede neural artificial (RNA) pode ser definida como um modelo matemático inspirado na arquitetura e no comportamento neural do cérebro humano. Baseado na rede neural natural, que possui grande capacidade de processamento e armazenamento, as redes artificiais são compostas por milhões de neurônios artificiais interconectados que formam uma rede, estrutura de processamento, onde as informações são processadas por meio de técnicas computacionais.

Os aspectos responsáveis pelo sucesso do desempenho das informações processadas pela rede, de acordo com Freire (2012), consistem na definição da arquitetura da rede e do processo de aprendizado.

2.2.4.1. ARQUITETURA

A definição de uma arquitetura que gere uma rede promissora é geralmente realizada por um processo de tentativa e erro, o que não é uma tarefa simples. Nesse processo, diferentes configurações são treinadas e avaliadas objetivando uma previsão exata para o conjunto de dados em treinamento (FACELI *et al.*, 2011).

A arquitetura engloba a topologia da rede e a função de ativação. A topologia refere-se ao modo como a rede está estruturada, já a função de ativação define o valor de saída de um neurônio em função dos dados de entrada.

2.2.4.2. TOPOLOGIA

Na RNA, os neurônios podem estar dispostos em três camadas, uma camada de entrada, uma camada intermediária e uma camada de saída. Entretanto, há RNA que não possui camada intermediária, exemplo para esse tipo de rede é o *perceptron* proposto por Rosenblatt (1958). Uma RNA com pelo menos um neurônio entre as camadas de entrada e saída, são ditas RNAs multicamadas.

A Figura 4 apresenta um exemplo de RNA multicamada que recebe valores de dois atributos de entrada, possui neurônios na camada intermediária e gera dois valores na camada de saída.




Figura 4 – RNA multicamadas (Faceli *et al.*, 2011)

Nesse tipo de RNA, o grau de conexão entre as unidades de processamento, de acordo com Faceli *et al.* (2011), classifica a rede em três tipos:

- Completamente conectada: os neurônios estão conectados a todos os neurônios da camada anterior e/ou seguinte.
- Parcialmente conectada: os neurônios estão conectados a apenas alguns dos neurônios da camada anterior e/ou seguinte.
- Localmente conectada: redes parcialmente conectadas, onde os neurônios conectados a um neurônio se encontram em uma região bem definida.

Os três padrões são mostrados na Figura 5.




Figura 5 - Grau de conexão entre neurônio de uma RNA multicamadas (Faceli *et al.*, 2011)

Além do número de camadas, número de neurônios por camada e grau de conectividade entre eles, o método como as informações são propagadas na rede constitui-se uma das principais disposições da topologia da rede.

De acordo com Castro & Zuben (1998) as redes são classificadas em redes de propagação para frente (*feedforward*) e redes realimentadas (*recurrent*).

Nas redes de propagação para frente (*feedforward*) o fluxo de informação é unidirecional, ou seja, um neurônio recebe como entrada a saída de um neurônio de camada anterior.

Já no caso das redes realimentadas (*recurrent*) não há restrição entre os neurônios. As conexões de retroprogramação ou retroalimentação permitem que um neurônio receba como entrada a saída de um neurônio da mesma camada ou de uma camada posterior.

A Figura 6 apresenta as duas redes, *feedforward* e recorrente.




Figura 6 – Redes neurais feedforward e recorrente (FACELI *et al.*, 2011)

A figura 6 (a) apresenta uma RNA multicamadas *feedforward*, na qual um neurônio pode receber em seus terminais de entrada valores de saída de neurônios da camada anterior e/ou enviar seu valor de saída para terminais de entrada de neurônios da camada seguinte.

A figura 6 (b) também é uma rede multicamadas, mas com a ocorrência de realimentação, na qual os valores das saídas dos neurônios são aplicados como entrada em neurônios da camada anterior.

2.2.4.3.FUNÇÃO DE ATIVAÇÃO

A função de ativação, aplicada à entrada total, define o valor de saída de um neurônio em função dos dados de entrada e permite a identificação das relações lineares e não lineares entre estes dados (FREIRE, 2012).

Entre as funções mais utilizadas destacam-se a função linear, a função escada e a função sigmoidal. A Figura 7 apresenta as três funções de ativação citadas.




Figura 3 - Funções de Ativação

Figura 7 - Funções de Ativação

A função linear produz uma saída linear contínua, a função de escada, uma saída binária (não-linear discreta), e a função sigmoidal, uma saída não-linear contínua.

2.2.4.4.PROCESSO DE APRENDIZADO

Definida a arquitetura da rede neural, deve-se realizar o treinamento da rede de modo que o desempenho seja satisfatório. Gonçalves (2016) afirma que a principal característica de uma rede neural é a sua capacidade de aprender a partir de um ambiente e de melhorar seu desempenho por meio da aprendizagem.

De acordo com Haykin (2011) o procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem e consiste em ajustar os pesos sinápticos da rede de uma forma ordenada de modo que seja produzido um modelo com bom desempenho. Dentre os algoritmos de treinamento, o mais utilizado é o algoritmo backpropagation, baseado na propagação do erro, proposto por RUMELHART *et al.* (1986).

O processo de aprendizado das redes neurais pode ser realizado por meio dos treinamentos supervisionados e não supervisionados. No primeiro, cada entrada produz uma saída e caso a diferença entre os respectivos valores esteja fora dos limites estabelecidos, ocorre um ajuste dos pesos para diminuir o erro entre os dados. No treinamento não-supervisionado, a RNA processa os dados de entrada, classificando-os, utilizando critérios próprios previamente definidos (MACHADO, 2005).

Os modelos de redes neurais como o perceptron e o perceptron multicamadas, segundo Rauber (2014) são exemplos de modelos com aprendizagem supervisionada que se baseiam no erro entre a resposta desejada e calculada da rede para adaptar os pesos.

Freire (2012) afirma que a definição adequada da topologia de rede, das funções de ativação e algoritmo de aprendizagem garantirá a convergência e a generalização da rede neural. A convergência diz respeito a capacidade de uma rede em aprender todos os padrões do conjunto de treino e a generalização refere-se a capacidade de um modelo de aprendizado de responder corretamente aos exemplos que lhe são apresentados.

De modo a buscar a convergência e a generalização, os tipos de RNAs utilizadas nesse trabalho são do tipo multicamadas *feedforward*, funções de ativação do tipo sigmóide e linear e algoritmo de Levenberg-Marquard.

2.2.5. VANTAGENS

Devido as suas características, as RNAs possuem diversas vantagens, como a capacidade de aprendizagem, auto-organização, tolerância a falhas, obtenção de resultados em tempo real e a flexibilidade em solucionar problemas de diversas áreas, entre elas, o reconhecimento de padrões, processamento de sinais, controle e otimização, problemas de classificação e previsão de séries temporais (ASCE, 2000a; MOMO *et al.*, 2016).

Particularmente, na hidrologia e engenharia de recursos hídricos, as RNAs estão sendo consideradas como uma alternativa aos modelos lineares, visto que estes últimos assumem os dados como sendo estacionários e possuem capacidade limitada em captar não-estacionariedade e não-linearidades nas séries hidrológicas (MISHRA *et al.*, 2007; SANTOS *et al.*, 2015).

Por apresentar grande habilidade em modelagem e previsão não linear de séries temporais não-estacionárias, característica dos processos hidrológicos, as RNAs têm se tornado uma ferramenta útil na modelagem desses processos. Alguns exemplos desse uso são observados na modelagem chuva-vazão, na previsão de vazões, na modelagem de águas subterrâneas, qualidade da água, gestão da água, na previsão de precipitação, em séries temporais, em operações de reservatórios, entre outros (GALVAO e VALENÇA, 1999; ASCE, 2000a, ASCE, 2000b; MISHRA & DESAI, 2006; CUTORE *et al.*, 2009; CARNEIRO & FARIAS, 2013; SANTOS & SILVA, 2014; LE *et al.*, 2015; SANTOS *et al.*, 2018).

CAPÍTULO 3

Neste capítulo é apresentada a metodologia aplicada.

3. METODOLOGIA

3.1.DESCRICÃO DA ÁREA EM ESTUDO

A área em estudo corresponde a sub-bacia 40 ou sub-bacia do Alto São Francisco até Três Marias, compreendida na bacia hidrográfica do rio São Francisco localizada entre as latitudes 7°00' e 21°00' S e longitudes 35°00' e 47°40' W. Abrange os estados de Minas Gerais, Distrito Federal, Goiás, Bahia, Sergipe, Alagoas e Pernambuco e representa a bacia mais importante da região do semiárido brasileiro.

Em decorrência da sua grande extensão e por abranger diferentes regiões, a bacia do rio São Francisco é dividida em Alto, Médio, Submédio e Baixo São Francisco, sendo essas quatro regiões subdivididas em sub-bacias hidrográficas. A sub-40 e sub-41, a sub-42 até sub-47, a sub-48 e a sub-49 correspondem, respectivamente, ao alto, médio, submédio e baixo São Francisco.

A sub-bacia 40, área em estudo, corresponde a área de drenagem do reservatório de Três Marias e parte da área de drenagem do Alto São Francisco, encontrando-se compreendida, mais especificamente, na região central de Minas Gerais. Essa sub-bacia compreende 106 municípios e possui uma área de drenagem de aproximadamente 51.000 km².

A topografia da região é ligeiramente acidentada, formadas por serras e terrenos ondulados e altitudes que variam de 1.600 a 600 m. O Planalto Dissecado do Centro-Sul e Leste de Minas, a Depressão São Franciscana, o Planalto do São Francisco, o Quadrilátero Ferrífero e a Serra do Espinhaço constituem as unidades geomorfológicas existentes (ONS, 2009).

Em relação ao clima, o tropical úmido e temperado são os predominantes nessa região que é marcada por estação chuvosa no verão e seca no inverno, e possui, desse modo, duas estações climáticas bem definidas.

Na Figura 8, a localização da área estudada está representada.

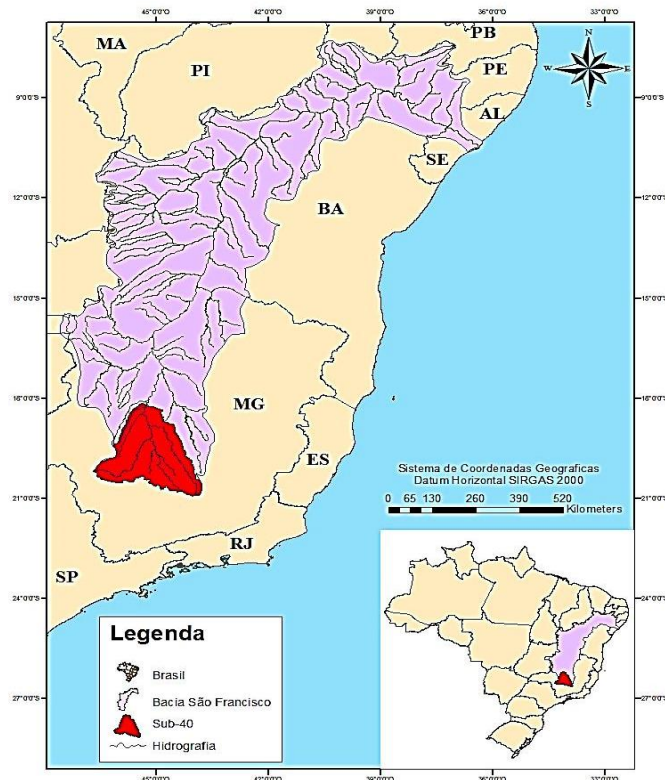


Figura 8 – Localização da sub-bacia hidrográfica do Alto São Francisco

3.2.DADOS DE PRECIPITAÇÃO TRMM

Os dados de precipitação, no período de 1 de janeiro 1998 a 31 de dezembro de 2015, foram adquiridos do produto 3B42 do satélite da missão *Tropical Rainfall Measuring Mission* (TRMM), disponibilizados gratuitamente pelo site da NASA, para uma malha espacial de 169 (cento e sessenta e nove) pontos, equidistantes $0,25^\circ$, localizada entre os paralelos $18,00^\circ$ e $21,00^\circ$ de latitude sul e os meridianos $43,75^\circ$ e $46,75^\circ$ de longitude oeste, constituindo uma área de aproximadamente 130.000 km^2 e cobrindo toda a sub-bacia 40.

A Figura 9 representa a grade de pontos TRMM, contemplando toda a área da sub-40.

CAPÍTULO 3 - METODOLOGIA

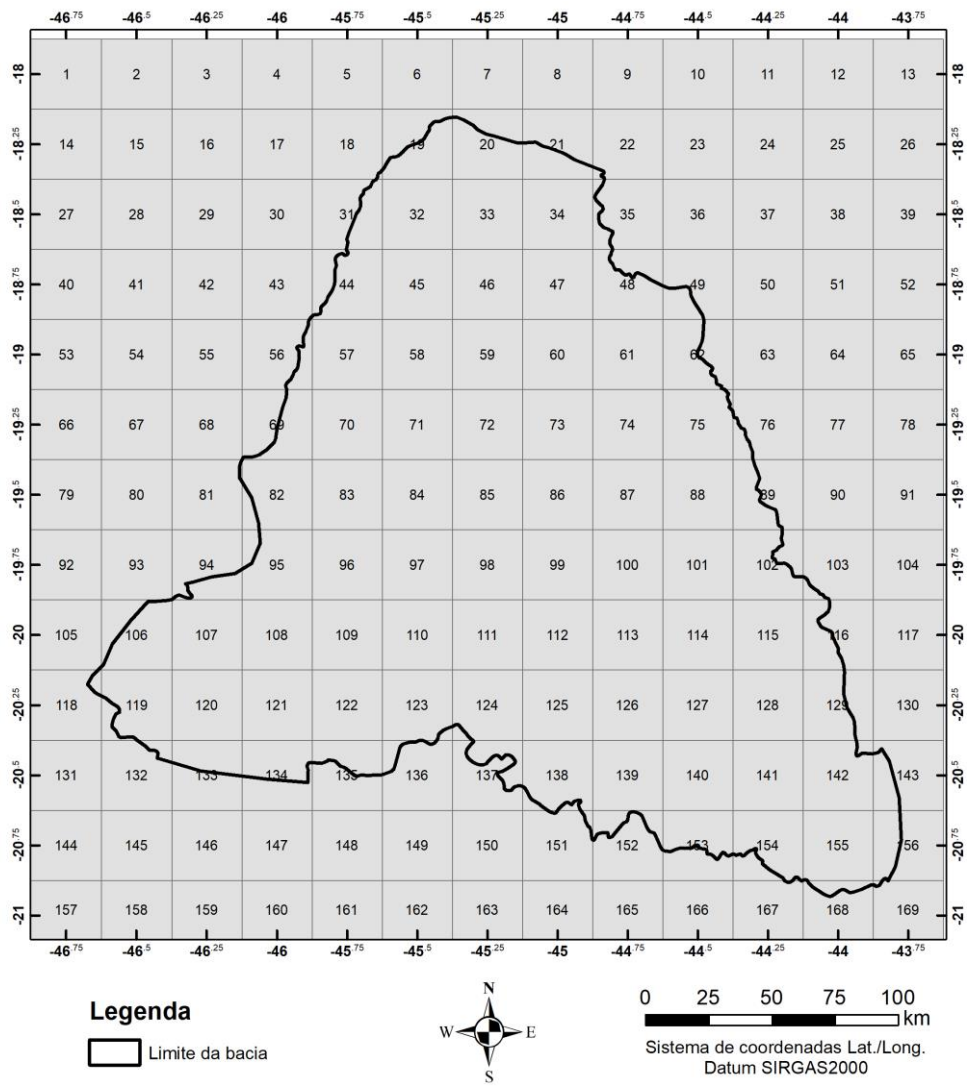


Figura 9 - Grade de pontos TRMM

3.3.ÍNDICE PADRONIZADO DE PRECIPITAÇÃO – SPI

A partir dos dados de precipitação diárias do TRMM, foram calculadas as precipitações acumuladas mensais ao longo dos 18 (dezoito) anos e os valores de SPI para várias escalas temporais.

Essa série histórica de dados de precipitação é considerada relativamente pequena, por outro lado, evita que sejam incorporados efeitos de tendência e de não-estacionaridade nos valores de SPI calculados.

Foram definidas oito escalas temporais (i.e., 1, 3, 6, 9, 12, 18, 24 e 48 meses) para serem analisadas. Assim, o SPI pode ser calculado para uma observação a partir de um mês de precipitação até um total de 48 meses, possibilitando a análise dos eventos de precipitação a curto e longo prazo.

No cálculo do SPI, é realizado o ajuste de uma função de densidade de probabilidade do tipo Gama para uma dada distribuição de frequência de totais de precipitação para uma estação. A função é representada pela fórmula:

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \quad (x>0) \quad (1)$$

onde,

$\alpha > 0$ parâmetro de forma de distribuição;

$\beta > 0$ parâmetro de escala de distribuição;

$x > 0$ quantidade de precipitação;

$\Gamma(\alpha) = \int_0^\infty y^{\alpha-1} e^{-y} dy$ função Gama;

Os parâmetros α (forma) e β (escalar) da função de densidade de probabilidade Gama são estimados por meio de soluções de máxima verossimilhança para cada série temporal (ponto de grade), para cada escala de tempo (1 mês, 3 meses, 9 meses, 24 meses, etc.) e para cada mês do ano, como segue:

$$\hat{\alpha} = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \quad (2)$$

$$\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}} \quad (3)$$

onde,

$$A = \ln(\bar{x}) - \frac{1}{n} \sum_{i=1}^n \ln(x_i) = \text{medida de assimetria de distribuição}$$

n = número de precipitações observadas

\bar{x} = precipitação média ao longo da escala de tempo de interesse

Pela facilidade de cálculo, utilizou-se o software Matlab® para determinação dos parâmetros α e β , buscando as máximas probabilidades.

Já de posse dos parâmetros calculados e das séries de dados, é possível calcular a probabilidade cumulativa Gama dos valores de precipitação. Probabilidade cumulativa é dada por:

$$G(x) = \int_0^x g(x) dx = \frac{1}{\hat{\beta}^{\hat{\alpha}} \Gamma(\hat{\alpha})} \int_0^x x^{\hat{\alpha}-1} e^{-x/\hat{\beta}} dx \quad (4)$$

Esta probabilidade foi calculada no programa Matlab®, através da função `gamcdf(x)`.

Deixando $t = x / \beta$, esta equação torna-se a função Gama incompleta:

$$G(x) = \frac{1}{\Gamma(\hat{\alpha})} \int_0^x t^{\hat{\alpha}-1} e^{-t} dt \quad (5)$$

Uma vez que a função Gama é indefinida para $x = 0$ e admitindo que existe a possibilidade de determinado mês de determinado ano ter precipitação nula, a probabilidade cumulativa torna-se:

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

$$q = \frac{m}{n} \quad (7)$$

onde,

$H(x)$ = probabilidade cumulativa Gama ajustada;

q = probabilidade de precipitação nula;

m = ocorrência de precipitação nula;

n = número total de eventos da série temporal;

$G(x)$ = probabilidade cumulativa Gama normal.

Finalmente, o ajuste de distribuições é realizado, onde a probabilidade cumulativa Gama ajustada ($H(x)$) é transformada na distribuição normal (variável normal padrão Z) do SPI com média 0 e desvio padrão igual a 1. As condições para obtenção do real valor do SPI são:

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

$$Z = SPI = + \left[t - \frac{c_0 + c_1 + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \quad 0,5 < H(x) < 1 \quad (9)$$

onde,

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

$$t = \sqrt{\ln \left(\frac{1}{(1-H(x))^2} \right)} \quad 0,5 < H(x) < 1 \quad (11)$$

$$c_0 = 2,515517, d_1 = 1,432788$$

$$c_1 = 0,802853, d_2 = 0,189269$$

$$c_2 = 0,010328, d_3 = 0,001308$$

Os valores obtidos de SPI para as diferentes séries temporais de precipitação foram utilizados para formarem as séries temporais a serem previstas pelas redes neurais artificiais.

3.4.REDES NEURAS ARTIFICIAS

A metodologia de previsão utilizando RNAs adotada nessa pesquisa teve como principais referências os trabalhos desenvolvidos por (SANTOS et al., 2018; CARNEIRO & FARIAS, 2013; GUEDES, 2011; SOUSA & SOUSA, 2009).

3.4.1. Entrada na RNA

A entrada na RNA foi dada a partir dos dados de SPI de 1 ou mais anos antecedentes, a fim de se obter os valores de SPI de 1 ano a frente. Foram utilizados 18 anos de dados, sendo o ano previsto o de 2015 e os outros 17 anos utilizados como

dados de entrada. Os 17 anos de dados de entrada (ano 2014, anos 2013–2014, anos 2012–2014, ..., anos 1998–2014) foram chamadas de modelos. Cada modelo contém oito redes neurais, correspondendo as oito escalas de tempo de SPI. A Tabela 2 apresenta os 17 modelos utilizados.

Tabela 2 - Modelos das RNAs e respectivos dados de entrada.

RNA	Dados de entrada
Modelo 1	2014
Modelo 2	2013 a 2014
Modelo 3	2012 a 2014
Modelo 4	2011 a 2014
Modelo 5	2010 a 2014
Modelo 6	2009 a 2014
Modelo 7	2008 a 2014
Modelo 8	2007 a 2014
Modelo 9	2006 a 2014
Modelo 10	2005 a 2014
Modelo 11	2004 a 2014
Modelo 12	2003 a 2014
Modelo 13	2002 a 2014
Modelo 14	2001 a 2014
Modelo 15	2000 a 2014
Modelo 16	1999 a 2014
Modelo 17	1998 a 2014

Como visto, cada modelo tem uma quantidade específica de anos de dados de entrada e SPI para a RNA. Por exemplo, o Modelo 1 tem como dados de entrada o ano de 2014 para as oito escalas de tempo de SPI, já os dados de entrada do Modelo 2 são os anos de 2013 e 2014 para oito escalas de SPI. Assim, os anos de 1998 a 2014 constituem os dados de entrada das oito RNAs do Modelo 17, correspondendo cada uma das RNAs às oito escalas de SPI calculadas neste trabalho.

Vale salientar que para o cálculo dos valores de SPI dos anos utilizados como dados de entrada (1998 a 2014), não foram considerados os dados de precipitação do ano de 2015, visto que ele foi o ano previsto.

Para realização da previsão, os dados de entrada nas RNAs foram divididos em três grupos, os quais são os conjuntos de treino, de validação e de teste. Os três conjuntos foram divididos em blocos contínuos, de modo que 70% dos dados foram apresentados à rede neural durante o treinamento, 15% foram utilizados para a validação e 15% para o teste. Durante o treinamento, os dados são apresentados à rede

que é ajustada de acordo com o seu erro. O treinamento é interrompido quando a generalização para de melhorar, indicado por um aumento do erro médio quadrático (MSE) dos dados de validação, ou seja, os dados de validação são utilizados para medir a generalização da rede e interromper o treinamento quando a generalização para de melhorar. Já os dados fornecidos para o teste da rede, estes não têm efeito sobre o treinamento e, portanto, fornecem uma medida independente do desempenho da rede durante e após o treinamento.

Por se tratar de RNAs multicamadas *feedforward*, cuja regra de aprendizado é do tipo supervisionado, foi fornecida a rede o conhecimento prévio do resultado desejado, no caso, os dados de SPI (1, 3, 6, 9, 12, 18, 24 e 48 meses) do ano a ser previsto (2015) para todos os 169 pontos da área estudada.

A Figura 10 representa um exemplo do Modelo 2, na qual se pretende realizar a previsão do ano de 2015, com os dados de SPI-1 dos anos de 2013 e 2014.




Figura 10 – Esquema do processamento da RNA (Modelo 2) para previsão anual do SPI-1

3.4.2. Arquitetura da RNA

A topologia e funções de ativação, constituintes básicos da arquitetura de uma RNA, foram definidas de acordo com processo de tentativa e erro, tendo sido testadas diversas configurações; além disso, foi feita uma revisão de literatura onde se analisou o desempenho da arquitetura de redes que possuíam o mesmo objetivo, isto é, previsão de índices de precipitação.

A Figura 11 ilustra a arquitetura da RNA adotada, apresentando como exemplo a rede neural do Modelo 2, cujos dados de entrada são os anos de 2013 a 2014. Como pode ser observado, consiste em uma RNA multicamadas *feedforward*, com uma camada de entrada, uma camada intermediária/escondida contendo 11 neurônios e uma camada de saída, sendo a função de transferência do tipo sigmoide entre a entrada e a camada intermediária e do tipo linear entre as camadas intermediárias e de saída.




Figura 11 – Exemplo da arquitetura da RNA (Modelo 2).

3.4.3. Aprendizagem da RNA

No processo de aprendizagem, os algoritmos de treinamento realizam os ajustes dos pesos de modo a minimizar o erro entre os valores de saída produzidos e os desejados para cada neurônio da camada de saída.

Há vários algoritmos de treinamento, dentre eles, o mais utilizado é o *back-propagation* (RUMELHART *et al.*, 1986) baseado no método do gradiente descendente, que leva em consideração a magnitude do erro no momento do ajuste dos pesos.

Uma variação muito utilizada do algoritmo *back-propagation* é o Levenberg-Marquardt, algoritmo que constitui uma extensão do método de Newton, e por possuir um ajuste rápido e eficiente no processo de ajuste dos pesos de uma RNA (MATLAB, 2017) foi o escolhido para realizar o treinamento das RNAs.

No algoritmo de Levenberg-Marquardt o ajuste dos pesos é dado pela razão entre o vetor gradiente e a matriz hessiana:

$$\Delta w = - \frac{\nabla \varepsilon(w)}{H \varepsilon(w)} \quad (12)$$

Em que $\varepsilon(w)$ corresponde à função que se deseja ajustar, $\nabla \varepsilon(w)$ é o gradiente e $H \varepsilon(w)$ é a matriz hessiana.

Se a função $\varepsilon(w)$ for quadrática, logo:

$$\varepsilon(w) = \sum_{i=1}^N e_i^2(w) \quad (13)$$

Pode-se demonstrar que:

$$\nabla \varepsilon(w) = J^T(w)e(w) \quad (14)$$

e

$$H\varepsilon(w) = J^T(w)J(w) \quad (15)$$

Em que $J(w)$ equivale a matriz jacobiana.

Substituindo (14) e (15) em (12):

$$\Delta w = -[J^T(w)J(w)]^{-1}J^T(w)e(w) \quad (16)$$

Para que o método de otimização funcione corretamente, é adicionada uma matriz diagonal μI ao termo $[J^T(w)J(w)]^{-1}$ da equação (16), resultando a equação (17) no algoritmo de otimização de Levenberg-Marquardt.

$$\Delta w = -[J^T(w)J(w) + \mu I]^{-1}J^T(w)e(w) \quad (17)$$

Durante o ajuste de pesos, o valor de μ pode ser ajustado de acordo com desempenho da rede. Se os erros são grandes entre as iterações, μ deve ser multiplicado por um fator β , caso contrário, μ é dividido pelo mesmo fator, sendo este previamente determinado.

3.4.4. Verificação da RNA

A verificação foi realizada através do cálculo do erro médio quadrático (*MSE – mean square error*), calculado por:

$$MSE = \frac{1}{N} \sum_{i=1}^N (SPI_i - \widehat{SPI}_i)^2 \quad (18)$$

em que SPI_i é o valor observado do SPI para escala de tempo i e \widehat{SPI}_i é o índice de precipitação calculado/previsto para mesma escala de tempo i .

Os valores do MSE próximos de zero são melhores. O valor zero significa que não há erro.

3.4.5. Índices de Desempenho

Os índices de desempenho utilizados foram os índices estatísticos de grau de concordância de Cohen (kappa) e o coeficiente de correlação de Pearson (R)

3.4.5.1. Coeficiente De Correlação De Pearson (R)

O índice estatístico empregado na avaliação da correlação foi o coeficiente de correlação de Pearson (R), que é uma técnica de avaliação que mede o grau de associação linear entre variáveis.

O coeficiente de correlação de Pearson (R) varia de -1 a 1 , relação negativa e positiva entre as variáveis, respectivamente. Os valores unitários representam uma correlação perfeita, já o valor igual a 0 corresponde a uma relação difusa ou não linear. O coeficiente R é calculado por:

$$R = \frac{N \sum (SPI_i \widehat{SPI}_i) - \sum SPI_i \sum \widehat{SPI}_i}{\sqrt{[N \sum SPI_i^2 - (\sum SPI_i)^2][N \sum \widehat{SPI}_i^2 - (\sum \widehat{SPI}_i)^2]}} \quad (19)$$

em que SPI_i é o valor observado do SPI para escala de tempo i e \widehat{SPI}_i é o índice de precipitação calculado/previsto.

A Tabela 3 apresenta a escala de correlação de R e as respectivas interpretações.

Tabela 3 – Escala do coeficiente de correlação de Pearson (R)

Valores do coeficiente R	Concordância
0,0 a 1,0	Muito baixa
0,1 a 0,3	Baixa
0,3 a 0,5	Moderada
0,5 a 0,7	Alta
0,7 a 0,9	Muito alta
0,9 a 1,0	Quase perfeita

Fonte: Adaptado Hopkins (2000)

3.4.5.2. Grau de Concordância De Cohen (kappa)

Por se tratar de uma análise espacial dos dados, o índice escolhido para verificar o grau de concordância entre os resultados previstos pelas RNAs e os dados observados foi o índice kappa, proposto por Jacob Cohen.

Constituindo um método estatístico de avaliação do nível de concordância entre um conjunto de dados, o kappa varia de 1 a valores próximos ou abaixo 0 , representando uma total concordância e nenhuma concordância, respectivamente.

Os dados previstos e observados foram classificados de acordo com as oito faixas de classificação do SPI e então o grau de concordância, através do kappa, foi verificado.

CAPÍTULO 3 - METODOLOGIA

Os níveis de concordância assumidos e as respectivas interpretações estão dispostos na Tabela 4.

Tabela 4 – Escala de concordância do kappa de Cohen

Valores do coeficiente kappa	Concordância
<0,00	Ruim
0,00 - 0,20	Fraca
0,21 - 0,40	Sofrível
0,41 - 0,60	Regular
0,61 - 0,80	Boa
0,81 - 0,99	Ótima
1	Perfeita

Fonte: Adaptado de Landis & Koch (1977)

CAPITULO 4

Neste capítulo são apresentados os resultados do trabalho e discussões acerca dos mesmos.

4. RESULTADOS

4.1.COMPORTAMENTO DOS SPI

As Figuras 12 e 13 representam um exemplo das curvas dos SPIs a curto e longo prazo, respectivamente, do primeiro ponto (Ponto 1) da malha espacial dos 169 pontos. Constata-se que quanto menores forem as escalas temporais, mais rapidamente as curvas se movem entre valores secos e úmidos. Já para escalas de tempo maiores, o índice responde mais lentamente, pois representam a precipitação acumulada para o mesmo período.

Podemos observar pelas Figuras 12 e 13 que a partir da determinação das séries temporais de SPI para as escalas de 1, 3, 6, 9, 12, 18, 24 e 48 meses, é percebido uma suavização da curva dos valores do índice. Quando as escalas de tempo são curtas, cada novo mês provoca um impacto relevante. Entretanto, para escalas de tempo maiores, cada novo mês não tem grande impacto sobre o total.




Figura 12 – SPI a curto prazo do Ponto 1




Figura 13 – SPI a longo prazo do Ponto 1

Nas Figuras 12 e 13, o atraso no início das séries, a partir do SPI-3, deve-se ao fato da série resultar da precipitação mensal acumulada para o mesmo período.

4.2. REDE NEURAL ARTIFICIAL

4.2.1. Previsão a partir de 17 modelos de RNAs

Após a determinação das séries temporais de SPI para todas as escalas e definição do número de neurônios na camada escondida, foi realizada a previsão anual de 2015 a partir de 17 modelos, cada modelo com oito redes neurais, correspondendo aos respectivos dados de entrada.

A Figura 14 representa o modo como foram organizados os dados de SPI para realização da previsão, tomando como exemplo uma das redes neurais do Modelo 1, cujo dado de entrada corresponde ao SPI-1 do ano de 2014.

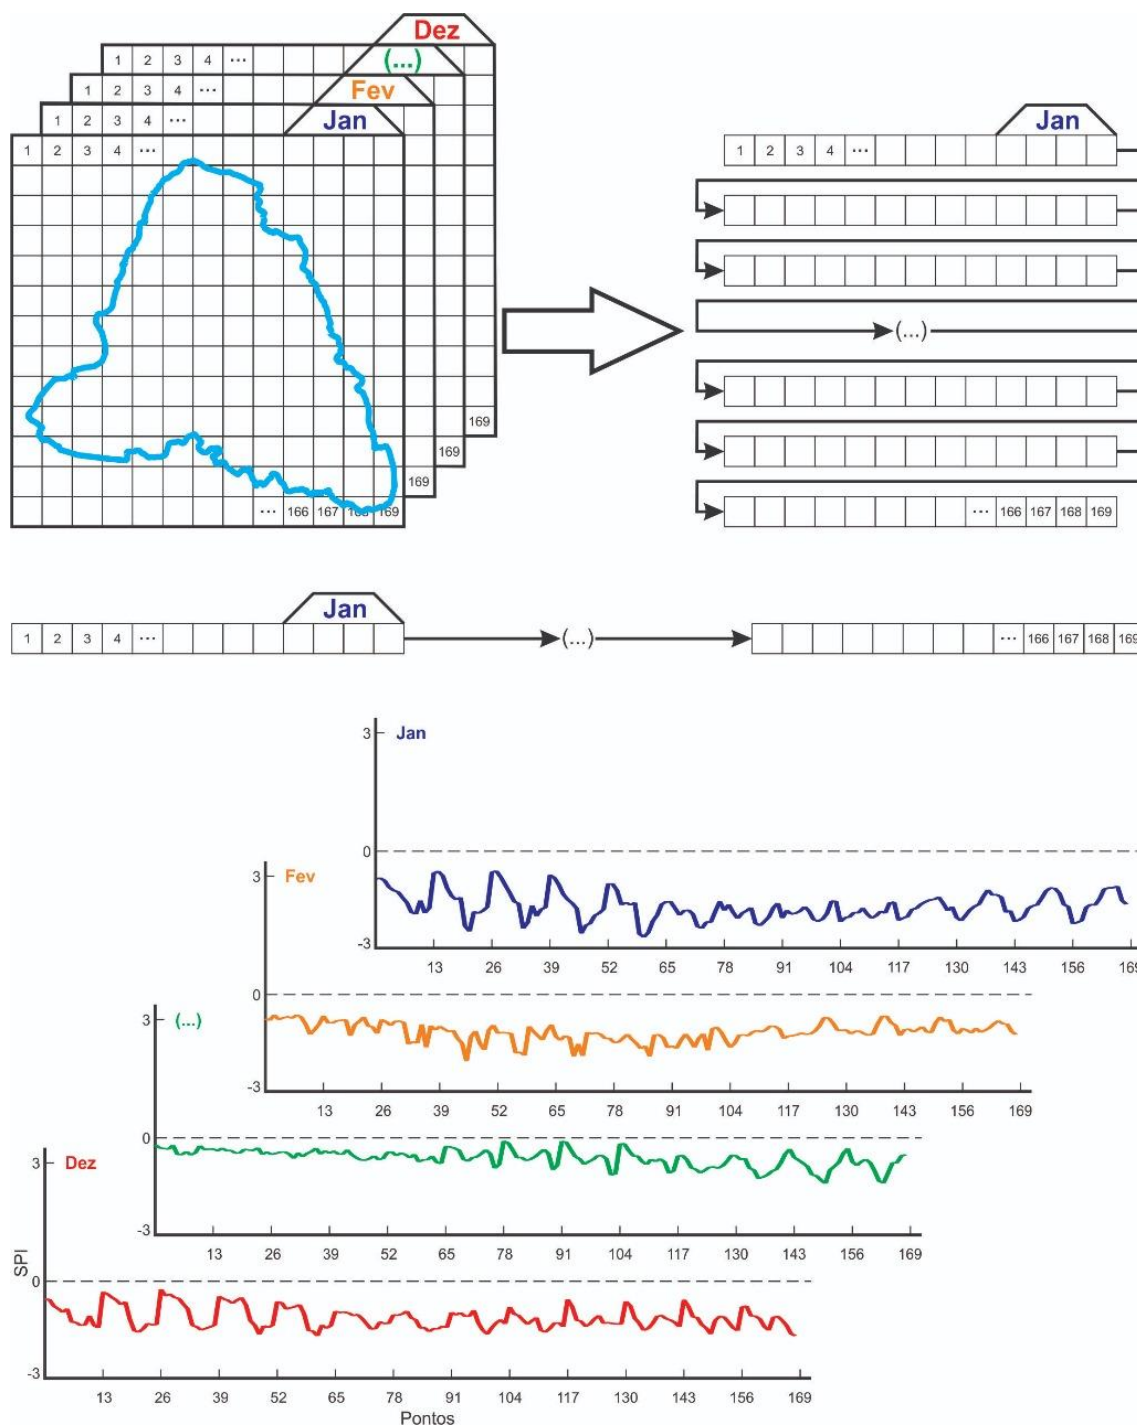


Figura 14 – Representação da organização dos dados para realização das previsões.

Cada ano possui doze matrizes 13×13 , correspondendo aos doze meses do ano, para cada uma das oito escalas de SPI (1, 3, 6, 9, 12, 18, 24 e 48). O exemplo apresentou na Figura 14 os valores de SPI-1 do ano de 2014 representadas nas doze matrizes 13×13 do ano de 2014 com os valores do SPI-1 transformadas em uma série histórica.

A matriz 13×13 com os 169 dados de SPI é transformada em uma série histórica do respectivo mês e ano. No exemplo da Figura 14, as 12 matrizes, com os valores de SPI-1, correspondentes aos 12 meses do ano de 2014 foram transformadas em 12 séries históricas.

Os valores do SPI-1 para os 169 pontos e os 12 meses do ano de 2014 estão representados em 12 matrizes 13×13 , cada matriz correspondendo a um mês do ano de 2014. Com as 12 matrizes exemplificadas transformadas em 12 séries históricas, entrou-se na RNA para prever as séries históricas do ano futuro (2015), cujos 169 valores de SPI-1 previstos para cada mês compõem as 12 matrizes 13×13 previstas para o ano de 2015.

Realizada a previsão por todos os modelos e suas respectivas RNAs, obteve-se as matrizes 13×13 das oito escalas do SPI para os 12 meses do ano previsto (2015). De posse dos dados previstos, realizou-se a comparação entre as matrizes do SPI observado do ano de 2015 versus as matrizes do SPI previsto para 2015.

A análise de desempenho das previsões realizadas para o ano de 2015 foi feita por meio do cálculo dos índices estatísticos (R e kappa) anual e mensais. Os valores de R e kappa anual foram calculados considerando a correlação e o grau de concordância, respectivamente, entre os dados observados e os dados previstos para o ano de 2015 para cada SPI e modelo de previsão. Já os cálculos dos índices estatísticos mensais consideraram a correlação e o grau de concordância entre os dados observados e os dados previstos para os meses do ano previsto (2015) para cada SPI e modelo de previsão.

Nesta etapa, além de terem sido realizadas 16.224 previsões (169 pontos \times 12 meses previstos \times 8 SPIs) para cada modelo, foram realizadas 5.516.160 verificações, correspondendo as 16.224 previsões realizadas para cada um dos 17 modelos multiplicado pela quantidade de neurônios na camada intermediária variando de 1 a 20.

4.2.2. Definição do número de neurônios na camada escondida

Para definição do número de neurônios a ser adotado na arquitetura da RNA, como já mencionado, foram realizadas 5.516.160 verificações, correspondendo aos 169 pontos da área estudada, 12 meses do ano previsto, 17 modelos, oito SPIs e a quantidade de até 20 neurônios na camada intermediária.

CAPÍTULO 4 – RESULTADOS E DISCUSSÕES

De acordo com os valores resultantes dos coeficientes de correlação entre os dados observados e previstos para o ano de 2015, a Tabela 5 apresenta o número de neurônios da camada intermediária que resultou nos melhores valores de previsão. Por exemplo, para a previsão realizada pelo Modelo 1 utilizando os dados de SPI-1, os melhores resultados de previsão foram alcançados utilizando 19 neurônios na camada intermediária.

Tabela 5 – Melhor número de neurônios para previsão de acordo com SPI e dados de entrada.

	SPI-1	SPI-3	SPI-6	SPI-9	SPI-12	SPI-18	SPI-24	SPI-48
2014 a 2014	19	13	16	7	16	19	17	20
2013 a 2014	14	12	8	11	16	15	12	15
2012 a 2014	17	16	16	13	8	18	13	18
2011 a 2014	18	8	7	11	14	6	10	11
2010 a 2014	13	9	18	16	11	10	14	14
2009 a 2014	16	10	4	20	10	5	15	7
2008 a 2014	12	6	13	7	8	13	6	20
2007 a 2014	14	11	13	14	13	16	17	13
2006 a 2014	7	13	5	10	13	17	12	14
2005 a 2014	16	8	15	20	14	11	10	13
2004 a 2014	8	9	18	5	5	14	10	20
2003 a 2014	10	8	5	18	10	6	18	14
2002 a 2014	3	8	6	11	15	12	3	11
2001 a 2014	12	14	19	16	6	11	11	12
2000 a 2014	10	6	9	5	15	9	7	10
1999 a 2014	11	7	10	11	6	11	20	20
1998 a 2014	16	7	4	7	5	13	17	16

A partir da Tabela 5, o gráfico da Figura 15 foi traçado representando o número de vezes que determinado número de neurônios na camada intermediária gerou os melhores resultados de previsão. Por exemplo, pela Figura 15, percebe-se que 11 e 13 neurônios na camada escondida apareceram 13 vezes, respectivamente, como os melhores resultados de previsão, representando, em ambos os casos 9,56%. Já a quantidade de neurônios que 3 e 4 representaram apenas 2,72% em ambos os casos.




Figura 15 – Quantidade de neurônios na camada intermediária que geraram os melhores resultados de previsão.

Entretanto, como a RNA constitui-se em um modelo estocástico, os resultados serão diferentes a cada rodada. Por isso, cada modelo de RNA foi rodado 10 vezes e a partir dos resultados obtidos, foi realizada uma análise estatística dos dados para determinação da melhor quantidade de neurônios para a camada intermediária.

A Tabela 6 apresenta, para cada rodada de previsão, a quantidade de vezes que utilizando determinado neurônio na camada intermediária, o resultado de previsão foi o melhor. Por exemplo, o gráfico da Figura 15 está representado na primeira coluna, intitulada RUN-1. A partir da escala de cores, pode-se perceber que os melhores valores estão entre 10, 11, 12 e 13 neurônios.

Tabela 6 – Quantidade de neurônios que geraram os melhores resultados de previsão para 10 rodadas respectivas.

NEURÔNIOS	RUN-1	RUN-2	RUN-3	RUN-4	RUN-5	RUN-6	RUN-7	RUN-8	RUN-9	RUN-10
1	0	0	0	0	0	0	0	0	0	0
2	0	0	0	1	1	2	2	1	1	0
3	2	4	2	2	3	0	3	1	0	2
4	2	5	2	1	4	0	2	2	4	3
5	7	4	7	10	3	5	4	8	5	4
6	9	6	8	12	9	10	8	6	9	6
7	8	5	9	7	9	10	3	12	12	5
8	8	3	8	8	6	11	7	9	9	11
9	4	7	4	12	12	6	8	7	14	8
10	12	8	12	6	9	8	9	11	4	9
11	12	10	13	13	6	10	14	17	10	6
12	7	11	7	10	6	16	9	8	9	10
13	13	9	13	10	17	6	12	6	5	11
14	10	6	11	12	12	2	8	10	13	13
15	7	11	6	10	6	9	5	8	8	12
16	12	8	12	5	6	7	8	9	5	8
17	6	12	5	7	9	6	11	2	6	10
18	7	10	7	3	7	7	8	5	9	6
19	4	10	3	5	3	15	6	9	5	5
20	6	7	7	2	8	6	9	5	8	7

Analisando estatisticamente os resultados, foram calculados, para cada rodada, a média, moda, mediana, 1º e 3º quartil e os valores mínimos e máximos. Com isso, foi gerado o diagrama de caixa (*Box Plot*), representado na Figura 16, onde é possível realizar uma melhor leitura dos resultados da Tabela 4.




Figura 16 – Diagrama de caixa da variação dos dados resultantes das 10 rodadas de previsão.

A partir da Figura 16, percebe-se que a mediana está em 11 e 13 neurônios. Então, como critério de determinação do número de neurônios a ser utilizado na camada escondida, foram analisados os resultados da média e da moda, ou seja, o valor que apareceu mais vezes. De acordo com os resultados, o número que resultou nos melhores valores de previsão foi 11 neurônios, sendo este o valor escolhido.

4.2.3. Desempenho das previsões (R e kappa anual)

Definido a utilização de 11 neurônios na camada escondida para realização das previsões, os resultados apresentados nas Tabelas 7 e 8, obtidos mediante a correlação (*R*) e o grau de concordância (*kappa*) entre os dados observados e os dados previstos para o ano de 2015 para cada SPI e modelo de previsão, representam o valor anual de *R* e *kappa* de cada SPI e modelo de previsão.

CAPÍTULO 4 – RESULTADOS E DISCUSSÕES

Para uma leitura mais rápida dos resultados, nas Tabelas 7 e 8 foi aplicado um gradiente de cores (vermelho, laranja, amarelo, verde claro e verde escuro) para representar a variação dos resultados. Baseado nos resultados de cada uma das tabelas, os valores mais baixos foram pintados de vermelho, seguido pelo tom laranja, amarelo, verde claro e finalizando com os valores mais altos pintados de verde escuro.

Tabela 7 – Índice de correlação R geral entre os dados observados e previstos.

SPI-1	0,941	0,941	0,933	0,922	0,933	0,881	0,866	0,896	0,927	0,944	0,940	0,916	0,928	0,859	0,897	0,888	0,828
SPI-3	0,951	0,910	0,919	0,961	0,914	0,932	0,953	0,951	0,926	0,943	0,929	0,913	0,889	0,915	0,911	0,913	0,962
SPI-6	0,971	0,980	0,979	0,984	0,972	0,945	0,982	0,957	0,970	0,972	0,972	0,859	0,953	0,963	0,977	0,964	0,961
SPI-9	0,946	0,959	0,960	0,949	0,925	0,962	0,944	0,961	0,923	0,969	0,967	0,954	0,975	0,958	0,850	0,957	0,944
SPI-12	0,916	0,933	0,949	0,796	0,948	0,962	0,920	0,943	0,946	0,956	0,973	0,903	0,942	0,953	0,934	0,927	0,912
SPI-18	0,969	0,965	0,982	0,971	0,984	0,956	0,984	0,942	0,978	0,981	0,906	0,944	0,979	0,985	0,949	0,942	0,948
SPI-24	0,882	0,593	0,947	0,876	0,939	0,931	0,945	0,926	0,908	0,923	0,955	0,939	0,880	0,934	0,950	0,891	0,959
SPI-48	0,941	0,930	0,955	0,949	0,955	0,974	0,956	0,948	0,965	0,953	0,938	0,957	0,935	0,946	0,934	0,936	0,941
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Tabela 8 - Índice de concordância kappa geral entre os dados observados e previstos.

SPI-1	0,456	0,684	0,700	0,381	0,684	0,683	0,780	0,620	0,638	0,386	0,589	0,289	0,595	0,871	0,722	0,681	0,634
SPI-3	0,670	0,827	0,715	0,529	0,805	0,501	0,880	0,820	0,738	0,371	0,670	0,797	0,766	0,601	0,519	0,546	0,584
SPI-6	0,839	0,589	0,722	0,898	0,853	0,854	0,685	0,803	0,772	0,608	0,620	0,736	0,353	0,795	0,648	0,920	0,978
SPI-9	0,869	0,923	0,923	0,532	0,457	0,703	0,946	0,619	0,800	0,908	0,931	0,729	0,977	0,916	0,856	0,817	0,513
SPI-12	0,833	0,912	0,499	0,523	0,833	0,785	0,689	0,976	0,952	0,945	0,921	0,598	0,515	0,764	0,968	0,984	0,324
SPI-18	0,724	0,869	0,899	0,916	0,600	0,917	0,925	0,953	0,778	0,917	0,972	0,824	0,981	0,655	0,944	0,822	0,853
SPI-24	0,869	0,515	0,721	0,612	0,607	0,849	0,871	0,555	0,861	0,851	0,890	0,867	0,924	0,968	0,663	0,957	0,978
SPI-48	0,705	0,853	0,912	0,928	0,552	0,914	0,971	0,971	0,774	0,956	0,915	0,780	0,472	0,718	0,971	0,771	0,971
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Por exemplo, o valor de R (Tabela 7) igual a 0,859, resultante da previsão do Modelo 15 cujos dados de entrada corresponderam aos dados de SPI-1 dos anos de 2000 a 2014, representa o valor de correlação anual entre os dados de SPI-1 de todas as 12 matrizes 13×13 observadas e previstos para o ano de 2015. Do mesmo modo, o valor de kappa (Tabela 8) igual a 0,722, correspondente ao erro de previsão entre os valores de SPI-1 contido nas matrizes 13×13 (169 pontos) observados e previstos para o ano de 2015.

A partir das Tabelas 7 e 8, constata-se que há uma relação entre os valores de R e kappa. Na medida em que os valores de kappa diminuem, os valores de correlação de R acompanham e vice-versa. Entretanto, também é percebido que os resultados de previsão da maioria dos modelos cujos dados de entrada eram o SPI-1, por exemplo, apresentam bons resultados de R , diferindo do índice kappa. Por exemplo, o valor de

kappa igual a 0,386, resultante da concordância anual entre os dados de SPI-1 observados e previstos para o ano de 2015 pelo Modelo 10, foi baixo em relação ao valor de R igual a 0,944 para o mesmo modelo e SPI. Isso demonstra que apesar das séries históricas (matrizes 13×13) previstas e observadas apresentarem o mesmo comportamento linear, favorecendo o valor de R , o grau de concordância entre as séries históricas dos dados dos SPIs observados e previstos para o ano de 2015 foi baixo.

De acordo com a classificação apresentada na metodologia, os valores de correlação R variaram de moderada (0,50–0,70) a muito forte ($> 0,90$), constituindo estes últimos a maioria dos valores de previsão. Já os resultados dos valores de concordância kappa variaram de ótima (0,81–0,99) a sofrível (0,20–0,40), sendo estes últimos, resultados pontuais. A concordância de previsão foi, na sua maioria, ótima (0,81–0,99).

4.2.4. Desempenho das previsões (R e kappa mensal)

Após obtidos os valores de kappa e R anual, apresentados nas Tabelas 7 e 8, foram calculados os valores dos índices estatísticos R e kappa para os respectivos meses do ano de previsto (2015).

Como forma de representar os valores de R obtidos mediante a correlação entre os dados observados e os dados previstos para os 12 meses do ano previsto (2015) para cada SPI (1, 3, 6, 9, 12, 18, 24 e 48) e modelo de previsão (17 Modelos), a Figura 17 apresenta, baseada na escala de cores do coeficiente de correlação (R), os resultados do comportamento linear entre os as séries históricas mensais observadas e previstas para o ano de 2015.

Na Figura 17 estão representados oito quadrados onde dentro de cada um deles estão contidos 204 (12 meses \times 17 modelos) pequenos quadrados, correspondendo aos desempenhos lineares das previsões dos meses de 2015 realizadas pelas oito RNAs contidas em cada um dos 17 Modelos. Por exemplo, a previsão da série histórica (169 pontos) de SPI-9 do mês de fevereiro de 2015 realizada pela RNA cujo dado de entrada corresponde aos dados de SPI-9 dos meses de fevereiro dos anos de 2000 até 2014 (Modelo 15) resultou em um valor de correlação verde claro, significando que o valor de R foi próximo de 0. Já a previsão da série histórica de SPI-6 do mesmo mês de fevereiro de 2015 realizada pela RNA cujo dado de entrada corresponde aos dados de

SPI-6 dos meses de fevereiro dos anos de 2000 até 2014 (Modelo 15) resultou em um valor de correlação verde escuro, significando um alto valor de R , próximo de 1.




Figura 17 – Índice de correlação (R) mensal resultante dos 17 Modelos.

Ainda, ao analisar a Figura 17, percebe-se que as correlações mensais entre os dados observados e previstos para os SPIs de longo prazo apresentaram bons resultados, sendo melhores do que os resultados de correlação para os SPIs de curto prazo, onde houveram valores de R próximos de zero, significando correlação muito baixa.

4.2.5. Determinação do modelo de RNAs com melhor desempenho

Após realizados os cálculos dos índices de estatísticos R e kappa mensal, foi avaliado o desempenho das previsões realizadas pelas RNAs contidas nos 17 Modelos. A partir da análise de dispersão entre os valores de R e kappa mensal, foi observado que o Modelo 15, com 15 anos de dados de entrada, os anos 2000 até 2014, apresentou, no geral, bom desempenho de previsão e os melhores resultados de correlação entre os dados de R e kappa.

Na Figura 18, está representado o gráfico de dispersão com todos os dados (12 meses \times 8 SPIs) de R e kappa resultantes das previsões realizadas pelas RNAs do Modelo 15. Os gráficos dos outros modelos de previsão estão no APÊNDICE A.




Figura 18 – Dispersão entre os valores de R e κ resultantes da previsão do Modelo 15.

Analisando a Figura 18, observa-se que há dois valores em que os coeficientes de correlação R foram fracos, próximos de zero, e o κ superior a 0,70, em ambos os casos, e há um caso em que o κ foi sofrível, mas o coeficiente de correlação foi alta (0,7 a 0,9) e muito alta (0,9 a 1), resultando em uma baixa dispersão. Apesar disso, conforme pode ser verificado na Figura 18, a maior parte dos resultados de R e κ foram classificados como ‘ótimo’ e ‘alto’, respectivamente, sendo o modelo 15 o que apresentou os melhores desempenhos para a maioria das previsões.

Como o Modelo 15 apresentou, no geral, os melhores resultados de previsão, as Tabelas 9 e 10 mostram os valores de R e κ mensais resultantes das previsões realizadas por meio das oito RNAs pertencentes a esse Modelo. Os dados de entrada correspondem aos anos de 2000 até 2014, variando as escalas de SPI, e os dados de saída correspondem a previsão das oito escalas do SPI de um ano à frente (2015). Os resultados de todos os modelos estão em APÊNDICE B.

Por exemplo, o valor de R (Tabela 9) igual a 0,950, resultante da previsão do Modelo 15 cujos dados de entrada corresponderam aos dados de SPI-24 dos anos de 2000 a 2014, representa o valor de correlação mensal entre os dados de SPI-24 das matrizes 13×13 observada e prevista para o mês de janeiro do ano de 2015. Já o valor de κ (Tabela 10) igual a 0,894 correspondente ao erro de previsão entre os valores de SPI-24 contido nas matrizes 13×13 (169 pontos) observado e previsto para o mês de janeiro do ano de 2015.

CAPÍTULO 4 – RESULTADOS E DISCUSSÕES

Para uma leitura mais rápida dos resultados, nas Tabela 9 e 10 foi aplicado um gradiente de cores (vermelho, laranja, amarelo, verde claro e verde escuro) para representar a variação dos resultados. Baseado nos resultados de cada uma das tabelas, os valores mais baixos foram pintados de vermelho, seguido pelo tom laranja, amarelo, verde claro e finalizando com os valores mais altos pintados de verde escuro.

Tabela 9 – Coeficiente de correlação R mensal resultante do Modelo 15.

	SPI-1	SPI-3	SPI-6	SPI-9	SPI-12	SPI-18	SPI-24	SPI-48
Jan	0,326	0,938	0,929	0,448	0,932	0,899	0,950	0,971
Fev	0,578	0,620	0,956	0,028	0,891	0,927	0,982	0,959
Mar	0,922	0,607	0,978	0,784	0,940	0,884	0,948	0,939
Abr	0,748	0,754	0,967	0,744	0,925	0,831	0,929	0,958
Mai	0,743	0,920	0,934	0,823	0,910	0,823	0,933	0,950
Jun	0,759	0,594	0,867	0,459	0,906	0,940	0,931	0,942
Jul	0,555	0,808	0,899	0,542	0,885	0,882	0,939	0,953
Ago	0,621	0,729	0,911	-0,014	0,895	0,888	0,926	0,924
Set	0,457	0,640	0,868	0,527	0,928	0,957	0,939	0,950
Out	0,385	0,783	0,891	0,734	0,919	0,921	0,936	0,956
Nov	0,544	0,886	0,904	0,822	0,911	0,946	0,904	0,948
Dez	0,761	0,825	0,901	0,581	0,915	0,914	0,982	0,889

Tabela 10 - Índice de concordância kappa mensal resultantes do Modelo 15.

	SPI-1	SPI-3	SPI-6	SPI-9	SPI-12	SPI-18	SPI-24	SPI-48
Jan	0,549	0,644	0,592	0,740	0,831	0,920	0,894	0,772
Fev	0,697	0,555	0,809	0,866	0,761	0,872	0,924	0,673
Mar	0,549	0,647	0,632	0,795	0,904	0,696	0,849	0,715
Abr	0,650	0,717	0,583	0,692	0,769	0,815	0,798	0,577
Mai	0,714	0,714	0,553	0,751	0,698	0,659	0,808	0,756
Jun	0,740	0,623	0,499	0,775	0,712	0,630	0,796	0,655
Jul	0,542	0,374	0,541	0,762	0,730	0,800	0,747	0,632
Ago	0,613	0,635	0,576	0,727	0,710	0,712	0,738	0,645
Set	0,687	0,732	0,499	0,633	0,782	0,803	0,774	0,602
Out	0,722	0,660	0,635	0,643	0,842	0,672	0,840	0,720
Nov	0,659	0,646	0,552	0,693	0,752	0,780	0,794	0,690
Dez	0,534	0,669	0,486	0,638	0,872	0,846	0,694	0,727

A partir da Tabela 9, percebe-se que os valores de R para os SPIs de longo prazo foram melhores em comparação com os resultados de SPIs de curto prazo, conforme também representado pela Figura 17. Dentre os SPIs de curto prazo, o SPI-9 apresentou baixa correlação entre os dados observados e previstos para o mês de agosto e fevereiro

de 2015, já o SPI-6 apresentou um dos melhores valores de correlação, com R igual a 0,978. Em relação aos SPIs de longo prazo, todos apresentam bons coeficientes de correlação, destacando-se o SPI-24 do mês de fevereiro e dezembro, com os maiores valores de R (0,982).

Analisando os resultados dos graus de concordância (kappa) (Tabela 10), é possível perceber que, na maioria dos casos, os desempenhos das previsões aumentam à medida que as escalas de tempo do SPI aumentam. Pode-se observar que a efetividade das previsões é menor nos SPI de curto prazo, atingindo os maiores valores de concordância para os SPI de longo prazo. Isto pode ser justificado devido à alta variabilidade temporal da precipitação do SPI a curto prazo, enquanto que para escalas de tempo maior, esta variabilidade é atenuada porque mais dados mensais são utilizados.

Como forma de representar e explicar de maneira mais clara os resultados das Tabelas 9 e 10, é apresentada na Figura 19 a espacialização dos dados de SPI-24 observados e previstos para o mês de janeiro de 2015 pelo Modelo 15.

Na Figura 19, foi aplicado um gradiente de cores (vermelho, laranja, amarelo, verde claro e verde escuro) para representar a variação dos valores de SPI-24, de modo que os valores mais baixos foram novamente pintados de vermelho, seguido pelo tom laranja, amarelo, verde claro e finalizando com os valores mais altos pintados de verde escuro.

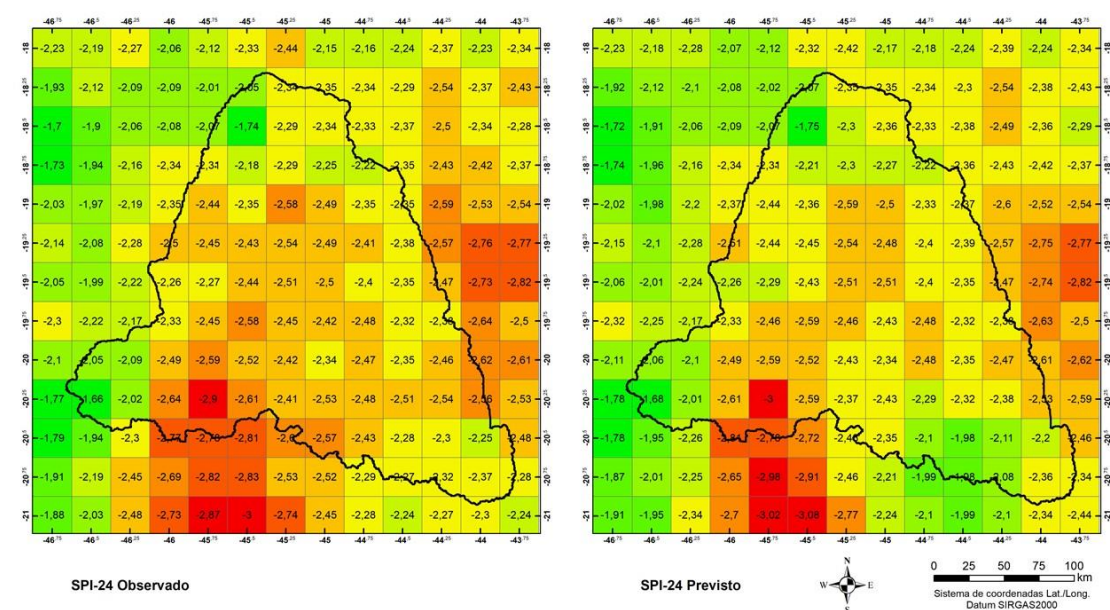


Figura 19 – Comparação entre os dados de SPI-24 observados e previstos para o mês de janeiro do ano de 2015 sobre o Alto do São Francisco – Modelo 15.

Analisando a Figura 19, é possível perceber que para o mês de janeiro, a previsão foi satisfatória, uma vez que todos os 169 pontos previstos apresentaram valores bem próximos ou iguais ao observado. Alinhado a isso, a efetividade da previsão, representado pelo kappa igual a 0,894, foi classificado com grau de concordância ótimo (0,81–0,99).

Os dados de SPI-24 espacializados (matriz 13×13) na Figura 19 representam duas séries históricas que graficamente (Figura 20) representam a comparação entre a série histórica do SPI-24 observado do mês de janeiro de 2015 versus a série histórica do SPI-24 previsto para o mesmo mês do ano de 2015.

De acordo com a Figura 20, há pontos em que os valores do SPI-24 do mês de janeiro observados e os previstos apresentam grau de concordância (kappa) quase perfeito. Nesse exemplo, somente a partir do ponto 123, os valores previstos do SPI-24 para o mês de janeiro apresentaram uma maior diferença, sendo esta, em todos os pontos, menor que 0,5.




Figura 20 – Comparação entre as séries de dados de SPI-24 observados e previstos para o mês de janeiro do ano de 2015 sobre o Alto do São Francisco – Modelo 15.

De acordo com as oito faixas de classificação do SPI, proposta por MCKEE *et al.* (1993) e apresentada na Tabela 1, os valores de SPI de cada ponto foi classificado. A Figura 21 apresenta, como exemplo, a espacialização (matriz 13×13) dos valores de SPI-24 observados e previstos para o mês de janeiro de 2015 pelo Modelo 15 dentro da classificação adotada.

A partir da Figura 21, podemos observar que os valores, nesse exemplo, variaram de extremamente seco ($SPI < -2,00$) a severamente seco ($-1,99 < SPI < -1,50$), ou seja, duas faixas de classificação, representadas pelos números 1 e 2, respectivamente. Além disso, é possível verificar o motivo do valor resultante de kappa ter sido diferente de 1, visto que os resultados previstos nos pontos 80, 140, 152, 153, 158 e 166 (ver Figura 9) apresentaram classificações diferentes dos valores observados nesses mesmos pontos.

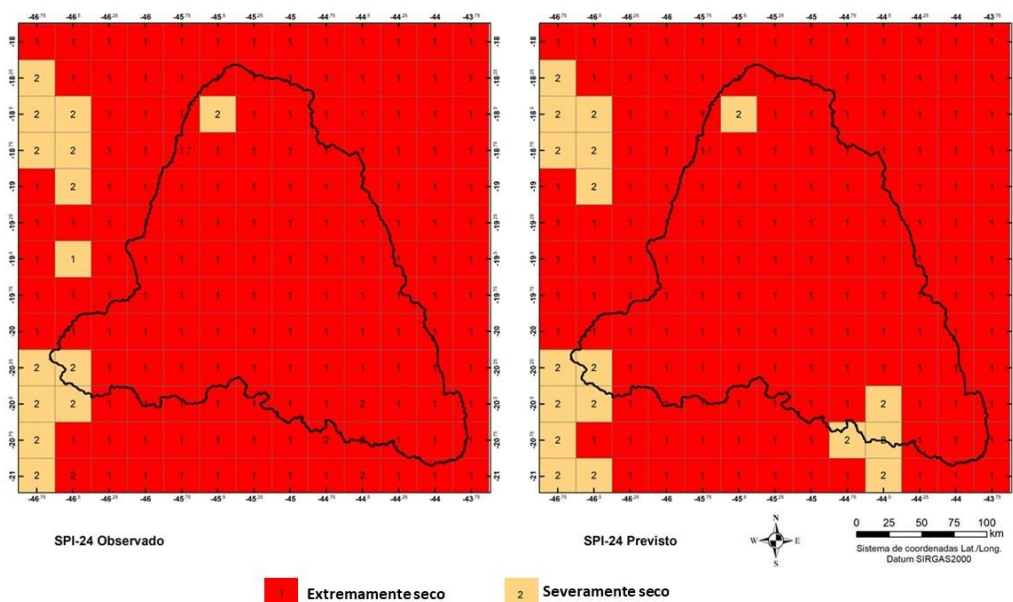


Figura 21 – Dados de SPI-24 observados e previstos nas oito faixas de classificação (mês de janeiro de 2015 - Modelo 15).

Como forma de representar a comparação entre os dados de SPI-24 observados e previstos no ano de 2015 sobre a região que inclui a bacia do Alto do São Francisco, é apresentada na Figura 22 a espacialização entre os dados de SPI-24 observados e previstos para todos os meses do ano 2015. A coluna intitulada ‘SPI-24 observado’ apresenta a espacialização dos valores de SPI-24 observados, enquanto que a coluna ‘SPI-24 previsto’ mostra os dados previstos mediante utilização de uma RNA cujos dados de entrada foram os valores de SPI-24 dos anos de 2000 até 2014. Os gráficos a

direita dos respectivos meses apresentam a dispersão entre os dados observados e previstos, comparando-os com a linha de igualdade, com os respectivos valores obtidos dos coeficientes de correlação (R) e grau de concordância (kappa).

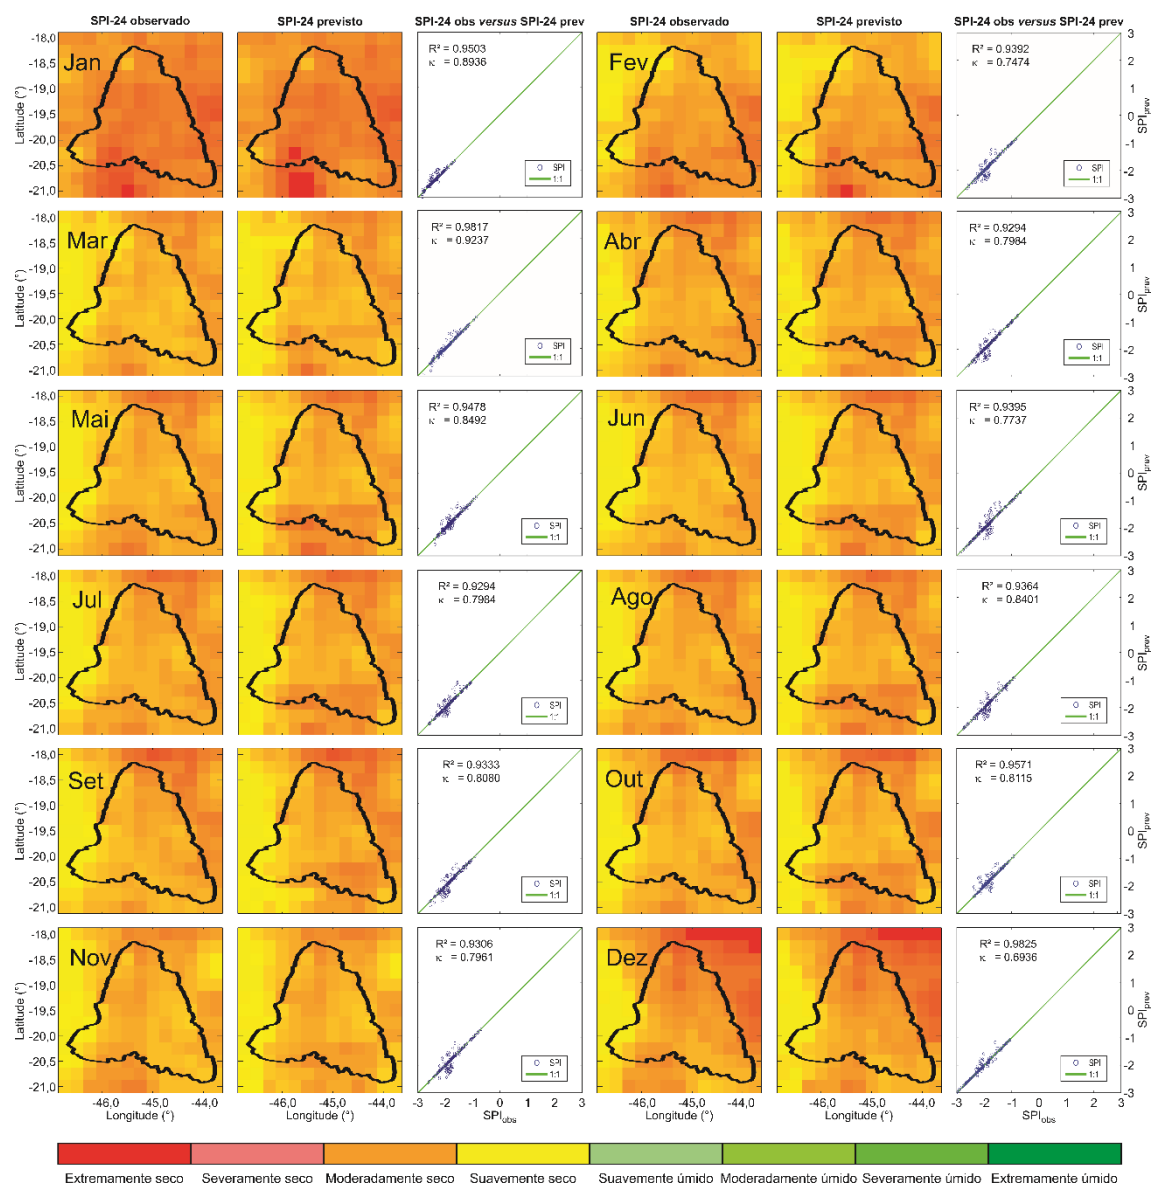


Figura 22 – Comparação entre os dados de SPI-24 observados e previstos no ano de 2015 sobre o Alto do São Francisco – Modelo 15.

Os resultados mostram que o período dos últimos 24 meses (fevereiro de 2013 a janeiro de 2015) foi severamente atingido pela seca em comparação com o mesmo período ao longo dos últimos 18 anos, de modo que todos os eventos que aconteceram

tanto para dados observados, quanto para dados previstos, foram eventos secos, SPI-24 ≤ 0 .

Ainda a respeito da análise da distribuição espacial da seca, percebe-se que de abril a dezembro, as regiões mais afetadas pelas secas foram as regiões leste e nordeste da área de estudo, enquanto a porção oeste foi menos afetada. Toda a região central representou uma zona de alta severidade de seca, apresentando dessa forma valores extremamente secos de SPI-24. Em janeiro e fevereiro, percebe-se que a região sul e sudoeste foram as regiões mais afetadas pela seca, apresentando os maiores valores negativos de SPI-24.

A respeito da correlação entre os dados observados e previstos do SPI-24 para todos os meses do ano de 2015, os valores de R variaram de 0,904, mês de novembro, a 0,982, nos meses de fevereiro e dezembro, já os valores de kappa variam de 0,694 em dezembro até 0,924 em fevereiro, permitindo concluir que as correlações obtidas e a qualidade da previsão foram significativamente altas ao longo de todo ano de 2015 para o SPI-24.

4.2.6. Análise estatística dos resultados de previsão

Por RNA constituir-se um modelo estatístico, cada nova rodada da rede resultados diferentes serão obtidos. Por isso, para verificar a veracidade dos resultados, as RNAs contidas nos 17 modelos foram rodados 30 vezes e a partir dos resultados, foi realizada uma análise estatística dos valores de kappa e R resultantes do grau de concordância e de correlação, respectivamente, entre os dados observados e os dados previstos para o ano de 2015 para cada SPI e modelo de previsão.

Analisando estatisticamente os resultados, foram calculados, para cada rodada, a mediana, 1º e 3º quartil e os valores mínimos e máximos dos coeficientes de correlação (R) e dos graus de concordância (kappa). As Figura 23 e 24 apresentam os diagramas de caixa (*Box Plot*) onde estão representados os valores de kappa e R para cada uma das 30 rodadas do modelo 15.

A partir das Figuras 23 e 24, é possível verificar que as 30 rodadas do modelo 15 apresentaram variação de dados muito parecidas. Conforme pode ser visto, na 1ª rodada, os resultados da mediana de kappa e R foram 0,790 e 0,971, respectivamente. Já na 20ª rodada, os valores da mediana de kappa e R foram respectivamente 0,793 e 0,972.

Em relação aos valores discrepantes, chamados *outliers*, eles estão presentes em todas as rodadas, entretanto, são dados pontuais. Com isso, podemos concluir que existe uma equivalência entre os conjuntos de dados; logo, os resultados de previsão apresentados estão adequados.




Figura 23 - Diagrama de caixa da variação dos dados de kappa resultantes de 30 rodadas de previsão utilizando o Modelo 15.




Figura 24 - Diagrama de caixa da variação dos dados de R resultantes de 30 rodadas de previsão utilizando o Modelo 15.

4.2.7. Verificação das RNA's

Após definidas as redes neurais de melhor desempenho, para fins de verificação, foram realizadas previsões das oito escalas de SPI para os anos de 2013 e 2014.

CAPÍTULO 4 – RESULTADOS E DISCUSSÕES

As Tabelas 11 e 12 mostram os valores de R mensais resultantes das previsões realizadas por meio das oito RNAs para os anos de 2014 e 2013, respectivamente. Na previsão realizada para o ano de 2014, os dados de entrada correspondem aos anos de 1999 até 2013, já para a previsão realizada para o ano de 2013, os dados de entrada correspondem aos anos de 1998 até 2012.

Para uma leitura mais rápida dos resultados, nas Tabela 11 e 12 foi aplicado um gradiente de cores (vermelho, laranja, amarelo, verde claro e verde escuro) para representar a variação dos resultados. Baseado nos resultados de cada uma das tabelas, os valores mais baixos foram pintados de vermelho, seguido pelo tom laranja, amarelo, verde claro e finalizando com os valores mais altos pintados de verde escuro.

Tabela 11 – Coeficiente de correlação R mensal resultante da previsão do ano de 2014.

	SPI-1	SPI-3	SPI-6	SPI-9	SPI-12	SPI-18	SPI-24	SPI-48
Jan	0,139	0,555	0,803	0,353	0,101	0,566	0,655	0,749
Fev	0,017	0,659	0,693	0,125	0,113	0,547	0,647	0,713
Mar	0,309	0,519	0,646	0,163	0,220	0,456	0,602	0,621
Abr	0,162	0,078	0,632	0,480	0,204	0,386	0,496	0,508
Mai	0,299	0,431	0,499	0,517	0,303	0,390	0,397	0,501
Jun	0,189	0,358	0,298	0,155	0,425	0,560	0,454	0,478
Jul	0,231	0,085	0,298	0,076	0,521	0,408	0,432	0,463
Ago	0,121	0,331	0,495	0,511	0,532	0,240	0,472	0,406
Set	0,088	0,003	0,267	0,183	0,522	0,242	0,387	0,504
Out	0,504	0,323	0,240	0,284	0,581	0,474	0,585	0,329
Nov	0,778	0,261	0,690	0,473	0,769	0,337	0,412	0,289
Dez	0,337	0,200	0,365	0,166	0,142	0,248	0,343	0,228

Tabela 12 – Coeficiente de correlação R mensal resultante da previsão do ano de 2013.

	SPI-1	SPI-3	SPI-6	SPI-9	SPI-12	SPI-18	SPI-24	SPI-48
Jan	0,236	0,326	0,691	0,185	0,637	0,430	0,479	0,416
Fev	0,263	0,217	0,001	0,169	0,503	0,460	0,386	0,368
Mar	0,386	0,037	0,271	0,191	0,036	0,511	0,437	0,397
Abr	0,078	0,125	0,392	0,238	0,296	0,532	0,385	0,423
Mai	0,346	0,528	0,111	0,172	0,173	0,513	0,380	0,455
Jun	0,365	0,174	0,167	0,098	0,363	0,494	0,374	0,478
Jul	0,161	0,086	0,048	0,112	0,110	0,410	0,362	0,489
Ago	0,020	0,129	0,042	0,160	0,131	0,336	0,347	0,519
Set	0,142	0,301	0,397	0,129	0,318	0,380	0,405	0,494
Out	0,106	0,252	0,727	0,243	0,346	0,369	0,444	0,337
Nov	0,230	0,319	0,421	0,242	0,031	0,268	0,428	0,163
Dez	0,067	0,418	0,700	0,127	0,661	0,203	0,288	0,039

A partir dos valores de R (Tabela 11 e Tabela 12), é percebido que os SPIs de longo prazo apresentam, na sua maioria, resultados melhores em comparação com os resultados de SPIs de curto prazo, ou seja, na maioria dos casos, os desempenhos das previsões aumentam à medida que as escalas de tempo do SPI aumentam.

Além disso, vale ressaltar que as previsões realizadas para o SPI-6, em ambos os casos, resultaram nos maiores valores de coeficientes de correlação para determinados meses dos respectivos anos previstos.

De acordo com a classificação de R (Tabela 3), percebe-se que os resultados de correlação R resultantes das previsões realizadas pelas oito melhores RNAs, foram classificados, na sua maioria, como alta e moderada para o SPI-6 e os SPI de longo prazo, sendo, portanto, as melhores escalas para realizar previsão.

CAPÍTULO 5

5. CONCLUSÕES E RECOMENDAÇÕES

5.1. CONCLUSÕES

De acordo com os resultados obtidos pode-se concluir que o objetivo proposto por este trabalho foi atingido, uma vez que foi realizada a previsão espaço-temporal de SPI, na sub-bacia Hidrográfica do Alto São Francisco (sub-bacia 40), através da aplicação de Rede Neural Artificial e o desempenho das RNAs aplicadas para realização das previsões foram analisados.

A partir dos resultados, foi possível definir o melhor Modelo de previsão, dentre os 17 modelos propostos. Por meio dos cálculos dos índices estatísticos de desempenho, coeficiente de correlação de Pearson (R) e grau de concordância de Cohen (kappa), entre os dados observados e previstos pelas RNAs, o modelo 15, cujo dado de entrada corresponde aos anos de 2000 até 2014, foi definido como o modelo que contém as RNAs com melhores desempenhos de previsão.

Baseados nas classificações de R e kappa adotadas na metodologia deste trabalho, percebe-se que os resultados de correlação R e de concordância kappa, resultantes das previsões realizadas pelo Modelo 15, variaram de muito baixa ($0 \leq R < -0,1$) a muito alta (0,9 a 1), constituindo este último na maioria dos valores de previsão. A correlação entre os dados observados e previstos, utilizando o Modelo 15, foi, na sua maioria, alta (0,5 a 0,7), muito alta (0,7 a 0,9) e quase perfeita (0,9 a 1). Já os resultados dos valores de concordância kappa variaram de ótima (0,81–0,99) a sofrível (0,20–0,40), sendo estes últimos, resultados pontuais. A concordância de previsão utilizando o Modelo 15 foi, na sua maioria, boa (0,61–0,80) e ótima (0,81–0,99).

Foi percebido também que os SPIs de longo prazo foram melhores em comparação com os resultados de SPIs de curto prazo, ou seja, na maioria dos casos, os desempenhos das previsões aumentam à medida que as escalas de tempo do SPI aumentam. Isto pode ser justificado devido à alta variabilidade temporal da precipitação do SPI a curto prazo, enquanto que para escalas de tempo maior, esta variabilidade é atenuada porque mais dados mensais são utilizados.

Além disso, em decorrência da RNA constituir-se um modelo estatístico, produzindo resultados diferentes a cada previsão, foi verificada a veracidade dos dados previstos realizando, para cada Modelo, 30 rodadas de previsão. Os resultados das 30 rodadas de previsões permitiram concluir que as RNAs contidas no Modelo 15 produzem dados de previsão consistentes visto que os valores previstos não diferem significativamente entre as rodadas, provando ser uma ferramenta eficaz para previsão de SPI de um ano à frente.

Para fins de verificação, foram realizadas previsões para os anos de 2013 e 2014 e, de acordo com a classificação de R (Tabela 3), os resultados de correlação R resultantes das previsões, foram classificados, na sua maioria, como alta e moderada.

5.2.RECOMENDAÇÕES

De acordo com os resultados obtidos, este trabalho pode ser utilizado para encorajar o uso da ferramenta de redes neurais para previsões espaço-temporal do Índice Padronizado de Precipitação (SPI).

Como sugestão de futuros trabalhos estão a previsão de outros índices de precipitação, como SPEI (*Standardized Precipitation and Evapotranspiration Index*) e o PDSI (Índice de Severidade de Seca de Palmer), consideração da influência de índices climáticos como ENSO (*El Niño/La Niña Southern Oscillation*) na previsão dos índices de precipitação pode resultar em dados relevantes, e o tratamento dos ruídos presentes nos dados por meio da utilização de ferramentas como as *wavelets* (ondaletas).

REFERÊNCIAS

- ASCE. Task Committee on Application of Artificial Neural Networks in Hydrology. **Artificial Neural Networks in Hydrology. I: Preliminary Concepts**. Journal Of hydrologic engineering, v. 5, n. March, p. 115–123, 2000a.
- ASCE. Task Committee on Application of Artificial Neural Networks in Hydrology. **Artificial Neural Networks in Hydrology. II: Hydrologic Applications**. Journal Of hydrologic engineering, v. 5, n. April, p. 124–137, 2000b.
- CARNEIRO, T. C., FARIAS, C. A. S. **Otimização Estocástica Implícita e Redes Neurais Artificiais para Auxílio na Operação Mensal dos Reservatórios Coremas - Mãe d'Água**. Revista Brasileira de Recursos Hídricos. v. 18, nº. 4, 2013.
- CASTRO, L. N.; ZUBEN, F. J. V. **Redes Neurais Artificiais**. Notas de aula. Departamento de Engenharia de Computação e Automação Industrial. Unicamp. 1998.
- CHEN, J.; YANG, Y. **SPI-based regional drought prediction using weighted Markov Chain model**. Research Journal of Applied Sciences, Engineering and Technology, v. 4, n. 21, p. 4293–4298, 2012.
- COLLISCHONN, B. **Uso de precipitação estimada pelo satélite TRMM em modelo hidrológico distribuído**. Universidade Federal do Rio Grande do Sul. Instituto de Pesquisas Hidráulicas. Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental (Dissertação). Porto Alegre, 196p., 2006.
- CUTORE, P.; DI MAURO, G.; CANCELLIERE, A. **Forecasting Palmer Index Using Neural Networks and Climatic Indexes**. Journal of Hydrologic Engineering, n. junho, p. 588-595, 2009.
- FACELI, K., LORENA, A. C., GAMA, J., CARVALHO, A. C. P. L. F. **Inteligência Artificial: Uma Abordagem de Aprendizagem de Máquina**. Rio de Janeiro: LTC, 2011.
- FREIRE, P. K. M. M. **O uso da Transformada Wavelet na previsão de vazão**. Universidade Federal da Paraíba. Programa de Pós-graduação em Engenharia Urbana e Ambiental (Dissertação). João Pessoa, 130p., 2012.

- GALVÃO, C. O.; VALENÇA, M. J. S. **Sistemas inteligentes: aplicações a recursos hídricos e sistemas ambientais**. Coleção ABRH de Recursos Hídricos, 7. Ed. Universidade/UFRGS/AHRH. Porto Alegre. 1999.
- GONÇALVES, A. R. **Redes Neurais Artificiais**. Disponível em: < <https://www-users.cs.umn.edu/~agoncalv/arquivos/pdfs/> >. Acesso em: 20 outubro de 2017.
- GUEDES, R. V. S. **Previsão de seca na bacia hidrográfica do Açude Epitácio Pessoa com base em redes neurais artificiais**. Universidade Federal de Campina Grande. Programa de Pós-graduação em Meteorologia (Dissertação). Campina Grande, 72p., 2011.
- HAYES, M. J.; SVOBODA, M. D.; WILHITE D. A.; VANYARKHO, O. V. **Monitoring the 1996 drought using the Standardized Precipitation Index**. Bulletin of the American Meteorological Society, 80, p. 429–438, 1999.
- HAYKIN, S. **Redes Neurais**. 2º ed. Bookman. Porto Alegre, 2011.
- HEBB, D.O. **The Organization of Behavior**. New York: Wiley, 1949.
- HOPKINS, W. G. **Correlation coefficient: a new view of statistics**. 2000. Disponível em: <<http://www.sportsci.org/resource/stats/effectmag.html>>. Acesso em: 30 de março de 2018.
- INMET. Instituto Nacional de Meteorologia. **Índice de Precipitação Padronizada – SPI**. Disponível em: <<http://www.inmet.gov.br/html/clima.php>>. Acesso em: 23 de out de 2016.
- KIM, T. W., VALDÉS, J. B., NIJSSEN, B. & RONCAYOLO, D. **Quantification of linkages between large-scale climatic patterns and precipitation in the Colorado River Basin**. J. Hydrol. 321, p. 173–186, 2006.
- KURNIK, B., BARBOSA, P., VOGT, J. **Testing two different precipitation datasets to compute the standardized precipitation index over the Horn of Africa**. International Journal of Remote Sensing, v. 32, p. 5947–5964, 2011.
- LANDIS, J.R; KOCH, G.G. **The measurement of observer agreement for categorical data**. Biometrics, v.33, p.159-174, 1977.

- LE, M. H., PEREZ, G. C., SOLOMATINE, D., NGUYEN, L. B. **Meteorological drought forecasting based on climate signals using artificial neural network - a case study in Khanhhoa province Vietnam**. Procedia Engineering, Volume 154, p. 1169 – 1175, 2015.
- MACHADO, F. W. **Modelagem Chuva-Vazão Mensal utilizando Redes Neurais Artificiais**. Universidade Federal do Paraná. Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental (Dissertação). Curitiba, 156p., 2005.
- MATLAB. **Levenberg-Marquardt backpropagation**. Disponível em: <<https://www.mathworks.com/help/nnet/ref/trainlm.html>>. Acesso em: 15 de julho de 2017.
- MCCULLOCH W.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biophysics, 5, p. 115–133, 1943.
- MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. **The relationship of drought frequency and duration to time scales**. AMS 8th Conference on Applied Climatology, Boston, Massachusetts, USA, p. 179–184, 1993.
- MCKEE, T. B., DOESKEN, N. J.; KLIEST, J. **Drought monitoring with multiple time scales**. Proc. of the Ninth Conf. on Appl. Climatol. AMS, Dallas, Texas, USA, p. 233-236, 1995.
- MINSKY, M.L.; PAPERT, S. A. **Perceptrons**, MIT Press, Cambridge, Massachusetts, USA, 1969.
- MISHRA, A. K.; SINGH, V. P. **A review of drought concepts**. Journal of Hydrology, 391, p. 202-216, 2010.
- MISHRA, A. K.; DESAI, V. R. **Drought forecasting using feed-forward recursive neural network**. Journal of Hydrology, Volume 198, p. 127-138, 2006.
- MISHRA, A. K.; DESAI, V. R.; SINGH, V. P. **Drought Forecasting Using a Hybrid Stochastic and Neural Network Model**. Journal of Hydrologic Engineering, p. 626-638, 2007.
- MOMO, M. R., ZANCHETT, P. S., ARAÚJO, C. Z., CORREIA, W., ABREU, C. R. C. **RNA Aplicada a Modelagem Hidrológica Alternative Title: Applied ANN To**

Hydrologic Model. XII Simpósio Brasileiro de Sistemas de Informação. Florianópolis-SC, 2016.

MORID, S.; SMAKHTIN, V.; BAGHERZADEH, K. **Drought forecasting using artificial neural networks and time series of drought indices.** International Journal of Climatology, 27, p. 2103–2111, 2007.

MORID, S.; SMAKHTIN, V.; MOGHADDASI, M. **Comparison of seven meteorological indices for drought monitoring in Iran.** International Journal of Climatology, v. 26, n. 7, p. 971–985, 2006.

NASA. Nacional Aeronautics and Space Administration. **Precipitation Measurement Missions.** Disponível em: <<https://pmm.nasa.gov/TRMM>>. Acesso em: 10 de out de 2016.

NEDEALCOV M., RĂILEANU V., SÎRBU R., COJOCARI R. **The Use of Standardized Indicators (SPI and SPEI) in Predicting Droughts Over The Republic of Moldova Territory.** PESD, v. 9, p. 149-157, 2015.

ONS, Operador Nacional do Sistema Elétrico. **Previsão de Vazões Diárias ao Reservatório de Três Marias usando a técnica de Redes Neurais (2009).** Disponível em: <http://www.ons.org.br/operacao/previsao_vazoes.aspx>. Acesso em: 10 de novembro de 2016.

PASSOS, J. S. A. **Variabilidade espaço-temporal da precipitação do Alto São Francisco (sub-40) utilizando dados do sensor PR/TRMM** Universidade Federal da Paraíba. Programa de Pós-graduação em Engenharia Civil e Ambiental (Dissertação). João Pessoa, 106p., 2015.

RAUBER, T. W. **Redes neurais artificiais.** Departamento de Informática. Universidade Federal do Espírito Santo, 2005.

ROSENBLATT, F. **The Perceptron: A probabilistic model for information storage and organization in the brain.** Psychological Review, 65, p. 386–408, 1958.


RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. **Learning internal representations by error propagation, in Parallel Distributed Processing:**

- explorations in the Microstructure of Cognition**, edited by D. E. Rumelhart and J. L. McClelland, 1(8), MIT Press, Cambridge, USA, 1986.
- SANTOS, C.A.G.; BRASIL NETO, R.M.; PASSOS, J.S.A.; SILVA, R.M. **Drought assessment using a TRMM-derived standardized precipitation index for the upper São Francisco River basin, Brazil**. Environmental Monitoring and Assessment, 189(6), p. 250, 2017.
- SANTOS, C. A. G.; FREIRE, P. K. M. M.; SILVA, R. M.; AKRAMI, S. A. **Journal of Hydrologic Engineering Hybrid wavelet neural network approach for daily inflow forecasting using Tropical Rainfall Measuring Mission data**. Journal of Hydrologic Engineering. 2018. (no prelo)
- SANTOS, C. A. G.; MORAIS, B. S.; SILVA, G. B. L. **Drought forecast using an artificial neural network for three hydrological zones in San Francisco River basin, Brazil**. IAHS-AISH Publication, v. 333, p. 302–312, 2009.
- SANTOS, J.F., PORTELA, M.M., PULIDO-CALVO, I. **Previsão de Secas ma Primavera em Portugal Continental com base em Indicadores Climáticos de Larga Escala**. Ingeniería del Agua, p. 211-227, 2015.
- SANTOS, C.A.G.; SILVA, G. B. L. **Daily streamflow forecasting using a wavelet transform and artificial neural network hybrid models**. Hydrological Sciences Journal, 59:2, 312-324, 2014.
- SOARES, A. S. D.; PAZ, A. R. DA P.; PICCILLI, D. G. A. **Avaliação das estimativas de chuva do satélite TRMM no Estado da Paraíba**. Revista Brasileira de Recursos Hídricos, v. 21, n. 2, p. 288–299, 2016.
- SOUSA, W. S.; SOUSA, F. A. S. **Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó**. Revista Brasileira de Engenharia Agrícola e Ambiental. v.14, n.2, p.173–180, 2010.
- WMO. World Meteorological Organization. **Standardized Precipitation Index**. User Guide N° 1090, 16p., 2012.


APÊNDICE

APÊNDICE A


Apêndice A-1: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 1.




Apêndice A-2: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 2.




Apêndice A-3: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 3.




Apêndice A-4: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 4.



Apêndice A-5: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 5.




Apêndice A-6: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 6.




APÊNDICE


Apêndice A-7: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 7.




Apêndice A-8: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 8.




Apêndice A-9: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 9.




Apêndice A-10: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 10.




Apêndice A-11: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 11.




Apêndice A-12: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 12.




Apêndice A-13: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 13.




Apêndice A-14: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 14.



Apêndice A-16: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 16.



Apêndice A-17: Dispersão entre os valores de R e kappa resultantes da previsão do Modelo 17.



APÊNDICE B

APÊNDICE

Apêndice B-1: Coeficiente de determinação R mensal resultantes de todos os Modelos para o SPI-1

	SPI-1																
Jan	0,623	0,770	0,672	0,558	0,720	0,320	0,526	0,111	0,573	0,577	0,741	0,618	0,654	0,269	0,326	0,548	0,720
Fev	0,753	0,646	0,528	0,613	0,354	0,387	0,435	0,489	0,575	0,806	0,365	0,397	0,664	0,136	0,578	0,112	0,476
Mar	0,906	0,900	0,859	0,779	0,786	0,801	0,802	0,842	0,870	0,861	0,883	0,886	0,727	0,524	0,922	0,839	0,723
Abr	0,870	0,801	0,763	0,878	0,805	0,778	0,663	0,888	0,596	0,778	0,830	0,533	0,855	0,461	0,748	0,793	0,354
Mai	0,869	0,908	0,586	0,744	0,684	0,666	0,691	0,516	0,684	0,865	0,754	0,898	0,833	0,042	0,743	0,688	0,756
Jun	0,826	0,710	0,696	0,674	0,674	0,712	0,441	0,561	0,793	0,719	0,778	0,583	0,747	0,544	0,759	0,638	0,414
Jul	0,729	0,526	0,451	0,636	0,696	0,359	0,152	0,486	0,697	0,854	0,515	0,512	0,702	0,313	0,555	0,252	0,444
Ago	0,554	0,656	0,641	0,436	0,693	0,200	0,518	0,020	0,610	0,813	0,591	0,654	0,548	0,342	0,621	0,227	0,622
Set	0,889	0,914	0,838	0,830	0,817	0,779	0,521	0,388	0,706	0,880	0,830	0,879	0,613	0,604	0,457	0,736	0,234
Out	0,695	0,694	0,777	0,691	0,823	0,638	0,503	0,353	0,759	0,724	0,824	0,569	0,854	0,432	0,385	0,749	0,688
Nov	0,451	0,770	0,472	0,517	0,786	0,665	0,152	0,720	0,551	0,696	0,643	0,794	0,590	-0,243	0,544	0,742	0,304
Dez	0,923	0,896	0,845	0,689	0,842	0,712	0,666	0,856	0,826	0,892	0,913	0,835	0,812	0,782	0,761	0,834	0,336
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-2: Índice de concordância kappa mensal resultantes de todos os Modelos para o SPI-1

	SPI-1																
Jan	0,204	0,317	0,452	0,149	0,493	0,298	0,298	0,284	0,352	0,213	0,140	0,124	0,386	0,357	0,549	0,447	0,298
Fev	0,658	0,490	0,416	0,265	0,535	0,566	0,263	0,249	0,626	0,248	0,004	0,349	0,323	0,286	0,697	0,300	0,629
Mar	0,171	0,453	0,475	0,180	0,489	0,300	0,303	0,338	0,604	0,131	0,199	0,233	0,238	0,156	0,549	0,485	0,567
Abr	0,607	0,468	0,554	0,240	0,519	0,316	0,536	0,051	0,634	0,083	0,229	0,282	0,283	0,254	0,650	0,382	0,633
Mai	0,390	0,403	0,381	0,274	0,247	0,435	0,336	0,057	0,639	0,092	0,218	0,173	0,266	0,240	0,714	0,320	0,534
Jun	0,532	0,486	0,464	0,222	0,300	0,424	0,435	0,520	0,545	0,345	0,055	0,169	0,186	0,206	0,740	0,545	0,535
Jul	0,402	0,245	0,418	0,040	0,343	0,208	0,083	-0,069	0,460	0,153	0,253	0,111	-0,041	0,183	0,542	0,178	0,260
Ago	0,257	0,426	0,308	0,178	0,467	0,357	0,276	0,222	0,398	0,142	0,396	-0,036	0,085	0,105	0,613	0,353	0,455
Set	0,375	0,544	0,238	0,160	0,334	0,362	0,566	0,207	0,711	-0,082	0,097	0,504	0,264	0,075	0,687	0,489	0,389
Out	0,539	0,440	0,437	0,095	0,502	0,643	0,466	0,286	0,606	0,255	0,085	0,312	0,224	0,291	0,722	0,411	0,538
Nov	0,428	0,459	0,527	0,234	0,229	0,527	0,365	0,307	0,414	0,056	0,135	0,231	0,372	0,304	0,659	0,368	0,489
Dez	0,477	0,513	0,653	0,282	0,490	0,511	0,573	0,425	0,660	0,093	0,491	0,221	0,350	0,100	0,534	0,539	0,710
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-3: Coeficiente de determinação R mensal resultantes de todos os Modelos para o SPI-3

	SPI-3																
Jan	0,914	0,681	0,905	0,950	0,575	0,901	0,969	0,892	0,721	0,861	0,829	0,828	0,609	0,912	0,938	0,846	0,945
Fev	0,813	0,498	0,631	0,855	0,800	0,822	0,893	0,619	0,723	0,862	0,387	0,669	0,678	0,849	0,620	0,747	0,882
Mar	0,772	0,633	0,198	0,792	0,360	0,809	0,802	0,709	0,317	0,581	0,687	0,640	0,620	0,371	0,607	0,162	0,821
Abr	0,681	0,321	0,724	0,886	0,663	0,821	0,873	0,823	0,509	0,624	0,492	0,488	0,006	0,583	0,754	0,577	0,893
Mai	0,736	0,764	0,873	0,904	0,472	0,864	0,841	0,897	0,295	0,906	0,848	0,763	-0,069	0,509	0,920	0,588	0,873
Jun	0,836	0,359	0,575	0,872	0,542	0,726	0,823	0,504	0,811	0,787	0,751	0,801	0,094	0,818	0,594	0,290	0,469
Jul	0,888	0,399	0,696	0,911	0,235	0,809	0,827	0,847	0,841	0,749	0,598	0,800	0,662	0,699	0,808	0,659	0,856
Ago	0,703	0,296	0,285	0,673	0,362	0,539	0,555	0,757	0,325	0,736	0,607	0,292	0,726	0,655	0,729	0,650	0,786
Set	0,282	0,336	0,673	0,788	0,741	0,540	0,752	0,804	0,733	0,784	0,704	0,490	0,711	0,746	0,640	0,509	0,747
Out	0,846	0,754	0,508	0,841	0,767	0,828	0,903	0,846	0,664	0,732	0,738	0,865	0,716	0,704	0,783	0,883	0,917
Nov	0,775	0,775	0,862	0,829	0,736	0,645	0,882	0,868	0,834	0,853	0,707	0,728	0,051	0,805	0,886	0,730	0,902
Dez	0,835	0,673	0,730	0,861	0,737	0,661	0,877	0,893	0,756	0,928	0,757	0,841	0,632	0,650	0,825	0,773	0,894
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

APÊNDICE

Apêndice B-4: Índice de concordância kappa mensal resultantes de todos os Modelos para o SPI-3

	SPI-3																
Jan	0,739	0,577	0,645	0,802	0,644	0,639	0,295	0,608	0,670	0,696	0,809	0,412	0,690	0,782	0,644	0,744	0,715
Fev	0,565	0,412	0,598	0,770	0,722	0,455	0,277	0,573	0,692	0,573	0,822	0,557	0,437	0,670	0,555	0,705	0,644
Mar	0,470	0,410	0,481	0,602	0,577	0,540	0,233	0,542	0,630	0,499	0,619	0,539	0,362	0,608	0,647	0,638	0,553
Abr	0,573	0,577	0,582	0,586	0,549	0,522	0,201	0,297	0,775	0,650	0,652	0,399	0,656	0,764	0,717	0,637	0,511
Mai	0,584	0,550	0,585	0,642	0,593	0,644	-0,003	0,399	0,700	0,614	0,644	0,491	0,544	0,580	0,714	0,689	0,641
Jun	0,365	0,524	0,514	0,554	0,513	0,607	0,567	0,432	0,660	0,548	0,655	0,432	0,535	0,669	0,623	0,649	0,504
Jul	0,547	0,453	0,589	0,620	0,762	0,528	0,297	0,449	0,510	0,660	0,706	0,436	0,586	0,594	0,374	0,820	0,672
Ago	0,327	0,246	0,333	0,560	0,459	0,408	0,169	0,531	0,589	0,415	0,636	0,379	0,462	0,692	0,635	0,768	0,523
Set	0,643	0,382	0,600	0,760	0,631	0,606	0,170	0,551	0,598	0,621	0,694	0,495	0,607	0,510	0,732	0,673	0,287
Out	0,677	0,623	0,604	0,705	0,631	0,521	0,374	0,487	0,643	0,520	0,692	0,527	0,325	0,727	0,660	0,866	0,308
Nov	0,649	0,674	0,585	0,707	0,626	0,644	0,073	0,640	0,614	0,717	0,757	0,148	0,460	0,632	0,646	0,758	0,511
Dez	0,572	0,543	0,582	0,620	0,455	0,580	0,324	0,423	0,628	0,632	0,687	0,431	0,192	0,692	0,669	0,705	0,622
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-5: Coeficiente de determinação *R* mensal resultantes de todos os Modelos para o SPI-6

	SPI-6																
Jan	0,945	0,889	0,922	0,967	0,952	0,800	0,950	0,946	0,915	0,894	0,953	0,829	0,898	0,875	0,929	0,810	0,926
Fev	0,965	0,970	0,974	0,932	0,949	0,700	0,974	0,928	0,906	0,922	0,976	0,804	0,854	0,812	0,956	0,952	0,955
Mar	0,952	0,975	0,982	0,983	0,841	0,930	0,964	0,939	0,925	0,948	0,978	0,705	0,879	0,924	0,978	0,941	0,881
Abr	0,938	0,966	0,983	0,984	0,936	0,827	0,964	0,900	0,917	0,929	0,922	0,708	0,921	0,939	0,967	0,931	0,780
Mai	0,921	0,947	0,929	0,935	0,888	0,775	0,972	0,866	0,934	0,934	0,879	0,653	0,914	0,869	0,934	0,927	0,947
Jun	0,890	0,863	0,875	0,910	0,899	0,677	0,931	0,792	0,875	0,864	0,857	0,516	0,669	0,552	0,867	0,857	0,896
Jul	0,893	0,885	0,904	0,928	0,885	0,727	0,946	0,778	0,924	0,896	0,879	0,733	0,747	0,862	0,899	0,797	0,907
Ago	0,798	0,903	0,934	0,889	0,852	0,853	0,923	0,834	0,886	0,894	0,925	0,701	0,855	0,822	0,911	0,877	0,844
Set	0,862	0,871	0,882	0,928	0,834	0,716	0,872	0,823	0,761	0,840	0,828	0,569	0,730	0,517	0,868	0,866	0,918
Out	0,927	0,946	0,876	0,943	0,889	0,867	0,952	0,909	0,897	0,916	0,873	0,561	0,912	0,941	0,891	0,819	0,719
Nov	0,800	0,885	0,903	0,895	0,912	0,717	0,846	0,873	0,897	0,925	0,846	0,443	0,582	0,924	0,904	0,896	0,953
Dez	0,746	0,906	0,901	0,932	0,908	0,685	0,853	0,841	0,785	0,854	0,907	0,837	0,893	0,910	0,901	0,890	0,816
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-6: Índice de concordância kappa mensal resultantes de todos os Modelos para o SPI-6

	SPI-6																
Jan	0,832	0,920	0,921	0,910	0,871	0,832	0,797	0,699	0,880	0,663	0,747	0,851	0,674	0,601	0,592	0,756	0,529
Fev	0,693	0,777	0,732	0,809	0,772	0,740	0,730	0,690	0,782	0,584	0,722	0,777	0,462	0,533	0,809	0,818	0,461
Mar	0,612	0,703	0,764	0,661	0,707	0,724	0,371	0,662	0,712	0,598	0,691	0,777	0,579	0,473	0,632	0,863	0,476
Abr	0,650	0,733	0,780	0,684	0,682	0,731	0,478	0,516	0,741	0,595	0,731	0,757	0,612	0,706	0,583	0,832	0,631
Mai	0,425	0,682	0,651	0,730	0,641	0,692	0,547	0,337	0,639	0,611	0,649	0,725	0,459	0,490	0,553	0,822	0,490
Jun	0,306	0,702	0,443	0,562	0,600	0,518	0,491	0,598	0,627	0,502	0,694	0,798	0,640	0,644	0,499	0,694	0,328
Jul	0,500	0,630	0,591	0,594	0,708	0,618	0,645	0,501	0,734	0,394	0,558	0,740	0,433	0,592	0,541	0,678	0,411
Ago	0,412	0,583	0,563	0,596	0,540	0,593	0,490	0,609	0,682	0,491	0,661	0,644	0,357	0,511	0,576	0,632	0,412
Set	0,461	0,685	0,576	0,704	0,747	0,571	0,712	0,610	0,673	0,471	0,675	0,807	0,530	0,622	0,499	0,776	0,389
Out	0,683	0,718	0,743	0,659	0,710	0,768	0,618	0,487	0,731	0,737	0,606	0,680	0,586	0,621	0,635	0,672	0,429
Nov	0,504	0,722	0,757	0,643	0,682	0,716	0,469	0,625	0,784	0,361	0,715	0,768	0,587	0,535	0,552	0,762	0,448
Dez	0,521	0,704	0,730	0,437	0,691	0,685	0,626	0,599	0,779	0,532	0,666	0,740	0,639	0,659	0,486	0,743	0,460
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

APÊNDICE

Apêndice B-7: Coeficiente de determinação R mensal resultantes de todos os Modelos para o SPI-9

	SPI-9																
Jan	0,839	0,904	0,924	0,895	0,800	0,886	0,813	0,919	0,816	0,958	0,922	0,951	0,940	0,942	0,448	0,884	0,917
Fev	0,884	0,890	0,965	0,935	0,773	0,956	0,901	0,941	0,604	0,942	0,917	0,923	0,957	0,940	0,028	0,945	0,852
Mar	0,963	0,920	0,949	0,955	0,884	0,973	0,906	0,939	0,818	0,947	0,961	0,864	0,968	0,928	0,784	0,896	0,929
Abr	0,925	0,907	0,960	0,957	0,767	0,932	0,853	0,880	0,833	0,945	0,915	0,951	0,960	0,900	0,744	0,856	0,904
Mai	0,936	0,942	0,944	0,964	0,794	0,944	0,836	0,893	0,832	0,929	0,919	0,962	0,967	0,921	0,823	0,907	0,928
Jun	0,952	0,931	0,962	0,914	0,837	0,952	0,887	0,910	0,826	0,965	0,945	0,919	0,972	0,879	0,459	0,930	0,905
Jul	0,915	0,893	0,931	0,934	0,874	0,907	0,938	0,917	0,796	0,942	0,960	0,936	0,959	0,898	0,542	0,933	0,951
Ago	0,875	0,878	0,886	0,924	0,820	0,927	0,875	0,875	0,807	0,931	0,868	0,933	0,940	0,893	-0,014	0,914	0,870
Set	0,801	0,808	0,878	0,834	0,749	0,859	0,783	0,850	0,847	0,862	0,928	0,810	0,887	0,909	0,527	0,911	0,808
Out	0,848	0,879	0,888	0,756	0,820	0,871	0,831	0,932	0,865	0,926	0,924	0,911	0,908	0,910	0,734	0,885	0,865
Nov	0,671	0,916	0,755	0,828	0,922	0,888	0,864	0,920	0,933	0,901	0,948	0,851	0,899	0,925	0,822	0,908	0,954
Dez	0,763	0,856	0,817	0,862	0,867	0,895	0,836	0,898	0,832	0,906	0,885	0,647	0,938	0,907	0,581	0,922	0,888
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-8: Índice de concordância kappa mensal resultantes de todos os Modelos para o SPI-9

	SPI-9																
Jan	0,714	0,612	0,694	0,580	0,728	0,751	0,839	0,829	0,695	0,750	0,574	0,657	0,576	0,629	0,740	0,705	0,767
Fev	0,718	0,675	0,706	0,239	0,636	0,698	0,725	0,794	0,496	0,660	0,689	0,736	0,643	0,530	0,866	0,299	0,746
Mar	0,821	0,688	0,773	0,116	0,722	0,780	0,816	0,838	0,610	0,502	0,479	0,737	0,639	0,653	0,795	0,571	0,841
Abr	0,698	0,618	0,728	0,208	0,800	0,694	0,878	0,885	0,555	0,520	0,652	0,668	0,550	0,597	0,692	0,576	0,859
Mai	0,788	0,709	0,731	0,342	0,669	0,662	0,843	0,741	0,541	0,504	0,547	0,697	0,659	0,645	0,751	0,392	0,784
Jun	0,820	0,711	0,780	0,485	0,723	0,702	0,813	0,795	0,489	0,446	0,485	0,574	0,612	0,618	0,775	0,521	0,876
Jul	0,772	0,418	0,704	0,340	0,755	0,714	0,880	0,732	0,554	0,539	0,569	0,754	0,597	0,463	0,762	0,260	0,813
Ago	0,723	0,542	0,681	0,413	0,637	0,700	0,775	0,814	0,181	0,350	0,498	0,510	0,489	0,578	0,727	0,074	0,699
Set	0,565	0,413	0,553	0,366	0,724	0,781	0,704	0,708	0,651	0,455	0,326	0,638	0,595	0,528	0,633	0,223	0,735
Out	0,742	0,547	0,721	0,594	0,707	0,692	0,777	0,716	0,565	0,130	0,478	0,662	0,528	0,606	0,643	0,508	0,750
Nov	0,551	0,584	0,594	0,304	0,762	0,677	0,755	0,678	0,436	0,519	0,327	0,724	0,502	0,537	0,693	0,636	0,808
Dez	0,541	0,589	0,512	0,269	0,623	0,694	0,643	0,703	0,450	0,228	0,455	0,585	0,556	0,684	0,638	0,335	0,672
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-9: Coeficiente de determinação R mensal resultantes de todos os Modelos para o SPI-12

	SPI-12																
Jan	0,927	0,853	0,965	0,883	0,931	0,957	0,932	0,959	0,932	0,946	0,971	0,911	0,812	0,893	0,932	0,900	0,869
Fev	0,915	0,895	0,919	0,757	0,922	0,922	0,907	0,910	0,914	0,975	0,957	0,848	0,970	0,970	0,891	0,866	0,858
Mar	0,933	0,964	0,950	0,892	0,921	0,930	0,950	0,966	0,960	0,958	0,979	0,861	0,930	0,966	0,940	0,884	0,923
Abr	0,851	0,911	0,922	0,771	0,934	0,949	0,900	0,900	0,931	0,924	0,962	0,846	0,884	0,898	0,925	0,824	0,915
Mai	0,874	0,904	0,927	0,860	0,931	0,953	0,892	0,904	0,896	0,914	0,959	0,894	0,947	0,939	0,910	0,907	0,917
Jun	0,885	0,928	0,933	0,731	0,944	0,957	0,902	0,938	0,923	0,918	0,955	0,847	0,933	0,956	0,906	0,924	0,833
Jul	0,889	0,924	0,917	0,825	0,938	0,936	0,881	0,893	0,895	0,916	0,963	0,905	0,879	0,925	0,885	0,915	0,928
Ago	0,893	0,919	0,918	0,710	0,930	0,934	0,865	0,893	0,900	0,932	0,946	0,884	0,884	0,930	0,895	0,955	0,938
Set	0,894	0,947	0,943	0,850	0,947	0,955	0,872	0,935	0,944	0,947	0,978	0,905	0,913	0,948	0,928	0,920	0,925
Out	0,881	0,939	0,946	0,861	0,931	0,974	0,890	0,920	0,944	0,949	0,967	0,914	0,971	0,948	0,919	0,939	0,907
Nov	0,857	0,926	0,926	0,803	0,932	0,959	0,919	0,935	0,951	0,946	0,960	0,819	0,931	0,890	0,911	0,950	0,924
Dez	0,837	0,903	0,913	0,684	0,924	0,955	0,903	0,933	0,925	0,959	0,961	0,903	0,923	0,939	0,915	0,855	0,778
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

APÊNDICE

Apêndice B-10: Índice de concordância kappa mensal resultantes de todos os Modelos para o SPI-12

	SPI-12																
Jan	0,845	0,802	0,831	0,638	0,866	0,846	0,845	0,662	0,777	0,857	0,562	0,737	0,650	0,893	0,831	0,814	0,787
Fev	0,605	0,707	0,692	0,638	0,699	0,664	0,713	0,576	0,560	0,820	0,637	0,644	0,611	0,840	0,761	0,796	0,832
Mar	0,707	0,532	0,808	0,676	0,593	0,810	0,859	0,770	0,659	0,863	0,554	0,648	0,470	0,764	0,904	0,866	0,837
Abr	0,622	0,661	0,661	0,685	0,744	0,673	0,693	0,634	0,586	0,775	0,362	0,588	0,505	0,666	0,769	0,763	0,643
Mai	0,601	0,463	0,627	0,686	0,781	0,725	0,791	0,696	0,538	0,784	0,362	0,448	0,411	0,695	0,698	0,770	0,759
Jun	0,604	0,535	0,715	0,461	0,722	0,697	0,772	0,716	0,632	0,784	0,494	0,441	0,766	0,646	0,712	0,703	0,650
Jul	0,618	0,616	0,750	0,705	0,749	0,763	0,762	0,619	0,614	0,781	0,375	0,452	0,478	0,743	0,730	0,780	0,721
Ago	0,594	0,598	0,731	0,625	0,792	0,744	0,800	0,730	0,589	0,806	0,253	0,538	0,626	0,727	0,710	0,746	0,703
Set	0,667	0,462	0,793	0,701	0,750	0,797	0,790	0,629	0,509	0,872	0,456	0,653	0,519	0,817	0,782	0,740	0,752
Out	0,697	0,613	0,840	0,695	0,756	0,750	0,718	0,556	0,682	0,814	0,600	0,722	0,526	0,808	0,842	0,836	0,700
Nov	0,559	0,654	0,767	0,740	0,683	0,774	0,744	0,637	0,387	0,836	0,611	0,572	0,704	0,721	0,752	0,757	0,736
Dez	0,722	0,553	0,803	0,768	0,737	0,904	0,718	0,802	0,231	0,901	0,640	0,669	0,504	0,907	0,872	0,832	0,879
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-11: Coeficiente de determinação *R* mensal resultantes de todos os Modelos para o SPI-18

	SPI-18																
Jan	0,946	0,951	0,979	0,965	0,976	0,952	0,957	0,894	0,955	0,964	0,650	0,720	0,970	0,959	0,899	0,933	0,823
Fev	0,945	0,914	0,959	0,964	0,974	0,953	0,970	0,877	0,978	0,966	0,724	0,802	0,972	0,925	0,927	0,905	0,935
Mar	0,955	0,950	0,957	0,960	0,978	0,935	0,959	0,912	0,946	0,917	0,938	0,921	0,967	0,960	0,884	0,935	0,831
Abr	0,853	0,875	0,945	0,938	0,939	0,863	0,912	0,935	0,938	0,927	0,832	0,866	0,972	0,967	0,831	0,774	0,884
Mai	0,900	0,845	0,950	0,889	0,902	0,912	0,925	0,776	0,956	0,919	0,869	0,817	0,949	0,924	0,823	0,770	0,861
Jun	0,962	0,923	0,980	0,950	0,970	0,947	0,965	0,825	0,970	0,975	0,905	0,881	0,961	0,989	0,940	0,941	0,927
Jul	0,956	0,916	0,980	0,945	0,973	0,894	0,960	0,906	0,969	0,972	0,958	0,952	0,963	0,985	0,882	0,888	0,922
Ago	0,949	0,882	0,975	0,938	0,965	0,927	0,968	0,875	0,954	0,965	0,837	0,935	0,947	0,978	0,888	0,868	0,935
Set	0,948	0,949	0,982	0,950	0,979	0,960	0,977	0,880	0,964	0,974	0,930	0,949	0,967	0,983	0,957	0,815	0,940
Out	0,942	0,934	0,954	0,924	0,966	0,894	0,970	0,882	0,935	0,957	0,901	0,862	0,938	0,967	0,921	0,928	0,899
Nov	0,931	0,933	0,937	0,924	0,967	0,874	0,967	0,965	0,955	0,958	0,855	0,911	0,963	0,963	0,946	0,925	0,922
Dez	0,933	0,960	0,965	0,960	0,980	0,896	0,977	0,920	0,971	0,973	0,885	0,934	0,972	0,976	0,914	0,942	0,889
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-12: Índice de concordância kappa mensal resultantes de todos os Modelos para o SPI-18

	SPI-18																
Jan	0,851	0,869	0,930	0,385	0,869	1,000	0,615	0,553	0,362	0,869	1,000	0,930	0,930	1,000	0,920	0,930	0,448
Fev	0,910	0,769	0,885	0,764	0,826	0,923	0,732	0,884	0,701	0,708	0,935	0,912	0,822	0,863	0,872	0,863	0,716
Mar	0,741	0,790	0,870	0,696	0,791	0,790	0,664	0,750	0,381	0,769	0,736	0,725	0,696	0,677	0,696	0,716	0,744
Abr	0,696	0,519	0,730	0,354	0,443	0,775	0,578	0,812	0,662	0,700	0,841	0,826	0,810	0,813	0,815	0,741	0,567
Mai	0,802	0,679	0,765	0,556	0,526	0,772	0,473	0,733	0,593	0,702	0,773	0,669	0,643	0,688	0,659	0,670	0,440
Jun	0,791	0,691	0,850	0,744	0,693	0,761	0,571	0,698	0,644	0,694	0,740	0,760	0,750	0,730	0,630	0,706	0,397
Jul	0,684	0,620	0,757	0,649	0,725	0,721	0,592	0,753	0,568	0,704	0,704	0,820	0,713	0,761	0,800	0,750	0,352
Ago	0,806	0,579	0,712	0,615	0,628	0,684	0,584	0,670	0,516	0,728	0,726	0,743	0,796	0,746	0,712	0,700	0,321
Set	0,673	0,625	0,783	0,701	0,636	0,772	0,498	0,679	0,699	0,710	0,728	0,808	0,780	0,747	0,803	0,656	0,403
Out	0,734	0,631	0,745	0,683	0,644	0,719	0,644	0,802	0,491	0,672	0,688	0,789	0,746	0,784	0,672	0,734	0,552
Nov	0,730	0,673	0,819	0,600	0,666	0,781	0,612	0,758	0,597	0,645	0,736	0,784	0,753	0,746	0,780	0,789	0,481
Dez	0,688	0,743	0,806	0,606	0,642	0,844	0,627	0,724	0,519	0,713	0,741	0,764	0,741	0,794	0,846	0,728	0,536
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

APÊNDICE

Apêndice B-13: Coeficiente de determinação R mensal resultantes de todos os Modelos para o SPI-24

	SPI-24																
Jan	0,8923	0,5688	0,953	0,9262	0,959	0,887	0,9535	0,939	0,941	0,885	0,951	0,951	0,942	0,857	0,95	0,825	0,971
Fev	0,881	0,644	0,942	0,930	0,957	0,939	0,965	0,942	0,943	0,914	0,957	0,924	0,884	0,919	0,982	0,869	0,984
Mar	0,870	0,717	0,947	0,907	0,942	0,959	0,921	0,916	0,910	0,917	0,923	0,872	0,896	0,948	0,948	0,919	0,959
Abr	0,823	0,290	0,911	0,824	0,922	0,942	0,935	0,920	0,876	0,917	0,954	0,927	0,934	0,940	0,929	0,850	0,936
Mai	0,823	0,690	0,921	0,783	0,904	0,942	0,922	0,894	0,877	0,888	0,948	0,932	0,893	0,950	0,933	0,929	0,927
Jun	0,840	0,347	0,934	0,881	0,957	0,906	0,940	0,919	0,893	0,903	0,947	0,940	0,929	0,945	0,931	0,946	0,951
Jul	0,853	0,719	0,932	0,802	0,907	0,917	0,946	0,880	0,876	0,867	0,951	0,945	0,930	0,952	0,939	0,912	0,946
Ago	0,835	0,589	0,939	0,901	0,921	0,858	0,938	0,885	0,890	0,944	0,946	0,923	0,901	0,945	0,926	0,942	0,949
Set	0,875	0,794	0,947	0,890	0,953	0,954	0,956	0,935	0,910	0,910	0,966	0,950	0,844	0,960	0,939	0,941	0,972
Out	0,825	0,733	0,920	0,854	0,926	0,938	0,944	0,911	0,885	0,943	0,952	0,925	0,879	0,952	0,936	0,896	0,945
Nov	0,839	0,552	0,913	0,784	0,808	0,821	0,887	0,897	0,826	0,906	0,919	0,907	0,938	0,895	0,904	0,679	0,877
Dez	0,922	0,574	0,966	0,933	0,955	0,969	0,945	0,932	0,903	0,976	0,943	0,942	0,953	0,948	0,982	0,905	0,971
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-14: Índice de concordância kappa mensal resultantes de todos os Modelos para o SPI-24

	SPI-24																
Jan	0,638	0,353	0,707	0,675	0,879	0,446	0,6885	0,5791	0,833	0,6472	0,844	0,7393	0,871	0,752	0,894	0,922	0,871
Fev	0,614	0,437	0,663	0,738	0,747	0,807	0,825	0,762	0,808	0,684	0,867	0,462	0,894	0,905	0,924	0,847	0,933
Mar	0,646	0,398	0,748	0,714	0,767	0,758	0,771	0,808	0,707	0,643	0,858	0,592	0,801	0,850	0,849	0,784	0,781
Abr	0,588	0,415	0,663	0,681	0,686	0,678	0,743	0,699	0,558	0,656	0,750	0,545	0,737	0,745	0,798	0,665	0,741
Mai	0,618	0,484	0,726	0,649	0,747	0,644	0,765	0,730	0,566	0,521	0,761	0,418	0,806	0,805	0,808	0,778	0,777
Jun	0,543	0,432	0,681	0,745	0,762	0,744	0,803	0,757	0,688	0,662	0,817	0,470	0,832	0,818	0,796	0,754	0,787
Jul	0,599	0,360	0,687	0,715	0,723	0,685	0,792	0,817	0,485	0,386	0,775	0,535	0,824	0,783	0,747	0,707	0,701
Ago	0,620	0,392	0,722	0,818	0,811	0,710	0,728	0,774	0,593	0,776	0,764	0,370	0,801	0,743	0,738	0,666	0,716
Set	0,556	0,498	0,645	0,751	0,836	0,737	0,709	0,785	0,602	0,702	0,827	0,572	0,865	0,767	0,774	0,773	0,757
Out	0,573	0,248	0,665	0,816	0,830	0,712	0,820	0,791	0,776	0,696	0,786	0,486	0,822	0,860	0,840	0,761	0,809
Nov	0,676	0,143	0,692	0,693	0,731	0,610	0,711	0,587	0,545	0,239	0,783	0,255	0,763	0,690	0,794	0,692	0,769
Dez	0,681	0,587	0,653	0,708	0,774	0,589	0,702	0,657	0,630	0,550	0,696	0,380	0,772	0,783	0,694	0,647	0,798
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

Apêndice B-15: Coeficiente de determinação R mensal resultantes de todos os Modelos para o SPI-48

	SPI-48																
Jan	0,977	0,973	0,968	0,973	0,979	0,987	0,981	0,957	0,975	0,975	0,935	0,979	0,988	0,950	0,971	0,981	0,972
Fev	0,943	0,955	0,931	0,968	0,956	0,981	0,964	0,970	0,984	0,978	0,938	0,974	0,969	0,952	0,959	0,958	0,971
Mar	0,962	0,948	0,976	0,957	0,960	0,983	0,973	0,931	0,974	0,970	0,944	0,964	0,944	0,950	0,939	0,937	0,963
Abr	0,947	0,925	0,976	0,961	0,955	0,975	0,955	0,967	0,971	0,955	0,960	0,960	0,936	0,948	0,958	0,943	0,939
Mai	0,937	0,926	0,966	0,954	0,963	0,978	0,962	0,950	0,963	0,950	0,962	0,953	0,912	0,946	0,950	0,930	0,926
Jun	0,936	0,916	0,960	0,941	0,959	0,978	0,960	0,961	0,963	0,937	0,955	0,954	0,925	0,954	0,942	0,931	0,931
Jul	0,934	0,910	0,955	0,946	0,959	0,978	0,959	0,941	0,964	0,957	0,943	0,954	0,937	0,948	0,953	0,934	0,951
Ago	0,942	0,919	0,951	0,943	0,960	0,975	0,952	0,918	0,964	0,945	0,933	0,947	0,923	0,932	0,924	0,937	0,932
Set	0,950	0,948	0,961	0,946	0,952	0,986	0,970	0,951	0,967	0,961	0,948	0,965	0,924	0,948	0,950	0,943	0,953
Out	0,948	0,956	0,965	0,953	0,961	0,982	0,955	0,959	0,967	0,945	0,919	0,958	0,941	0,947	0,956	0,937	0,927
Nov	0,951	0,944	0,958	0,940	0,979	0,990	0,975	0,961	0,984	0,946	0,961	0,966	0,934	0,954	0,948	0,943	0,944
Dez	0,841	0,853	0,874	0,896	0,891	0,898	0,877	0,910	0,910	0,896	0,852	0,897	0,873	0,887	0,889	0,839	0,864
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17

APÊNDICE

Apêndice B-16: Índice de concordância kappa mensal resultantes de todos os Modelos para o SPI-48

	SPI-48																
Jan	0,912	0,827	0,949	0,499	0,895	0,821	0,831	0,689	0,855	0,880	0,880	0,676	0,772	0,732	0,772	0,871	0,894
Fev	0,661	0,723	0,769	0,238	0,745	0,702	0,738	0,670	0,860	0,877	0,850	0,761	0,687	0,804	0,673	0,781	0,773
Mar	0,770	0,598	0,786	0,672	0,712	0,834	0,704	0,691	0,744	0,678	0,660	0,682	0,552	0,665	0,715	0,635	0,742
Abr	0,631	0,701	0,627	0,479	0,673	0,719	0,659	0,338	0,790	0,728	0,728	0,713	0,573	0,768	0,577	0,746	0,682
Mai	0,666	0,721	0,723	0,438	0,759	0,816	0,796	0,743	0,830	0,816	0,739	0,790	0,707	0,720	0,756	0,760	0,685
Jun	0,703	0,727	0,740	0,630	0,767	0,809	0,799	0,719	0,808	0,741	0,792	0,627	0,610	0,664	0,655	0,759	0,743
Jul	0,680	0,693	0,728	0,654	0,780	0,755	0,823	0,613	0,855	0,814	0,800	0,806	0,499	0,718	0,632	0,792	0,724
Ago	0,698	0,723	0,723	0,544	0,790	0,761	0,805	0,639	0,823	0,661	0,796	0,723	0,622	0,714	0,645	0,706	0,749
Set	0,697	0,774	0,686	0,608	0,773	0,756	0,782	0,612	0,743	0,698	0,809	0,750	0,628	0,703	0,602	0,760	0,787
Out	0,691	0,779	0,857	0,750	0,794	0,856	0,845	0,679	0,845	0,687	0,837	0,806	0,638	0,825	0,720	0,780	0,769
Nov	0,734	0,826	0,784	0,593	0,867	0,886	0,867	0,626	0,877	0,876	0,858	0,831	0,697	0,821	0,690	0,795	0,841
Dez	0,642	0,695	0,729	0,356	0,837	0,779	0,643	0,496	0,838	0,790	0,832	0,747	0,664	0,720	0,727	0,675	0,758
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10	Modelo 11	Modelo 12	Modelo 13	Modelo 14	Modelo 15	Modelo 16	Modelo 17