

UNIVERSIDADE FEDERAL DO AMAZONAS
FACULDADE DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**ESTUDO COMPARATIVO ENTRE ALGORITMOS DE PREVISÃO DE
CHEIAS SAZONAIS USANDO REDE NEURAL ARTIFICIAL E MÉTODO DE
APRENDIZADO BASEADO EM COMITÊ**

PAULA ARAÚJO MARÃES

MANAUS

2019

UNIVERSIDADE FEDERAL DO AMAZONAS
FACULDADE DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

PAULA ARAÚJO MARÃES

**ESTUDO COMPARATIVO ENTRE ALGORITMOS DE PREVISÃO DE
CHEIAS SAZONAIS USANDO REDE NEURAL ARTIFICIAL E MÉTODO DE
APRENDIZADO BASEADO EM COMITÊ**

Dissertação apresentada ao Curso de Mestrado em Engenharia Elétrica, área de concentração de Controle e Automação de Sistemas do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas.

Orientadora: Prof.^a Dr.^a. Marly Guimarães Fernandes Costa

Coorientador: Prof. Dr. Cícero Ferreira Fernandes Costa Filho.

MANAUS

2019

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

M393e Marães, Paula Araújo
Estudo comparativo entre algoritmos de previsão de cheias sazonais usando Rede Neural Artificial e método de aprendizado baseado em Comitê / Paula Araújo Marães. 2019
88 f.: il. color; 31 cm.

Orientadora: Profª. Drª. Marly Guimarães Fernandes Costa
Coorientador: Prof. Dr. Cícero Ferreira Fernandes Costa Filho
Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Amazonas.

1. Cheias sazonais. 2. Redes Neurais Artificiais. 3. Métodos de aprendizado baseados em Comitê. 4. Categorização das cheias. I. Costa, Profª. Drª. Marly Guimarães Fernandes II. Universidade Federal do Amazonas III. Título

PAULA ARAÚJO MARÃES

ESTUDO COMPARATIVO ENTRE ALGORITMOS DE PREVISÃO DE CHEIAS SAZONAIS USANDO REDE NEURAL ARTIFICIAL E MÉTODO DE APRENDIZADO BASEADO EM COMITÊ

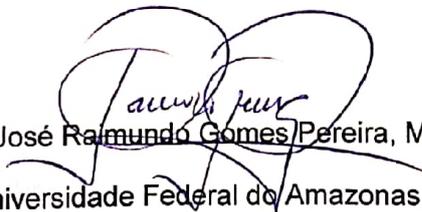
Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica na área de concentração Controle e Automação de Sistemas.

Aprovado em 29 de abril de 2019.

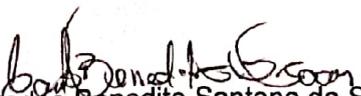
BANCA EXAMINADORA



Prof^a. Dra. Marly Guimarães Fernandes Costa, Presidente
Universidade Federal do Amazonas



Prof. Dr. José Raimundo Gomes Pereira, Membro
Universidade Federal do Amazonas



Prof. Dr. Carlos Benedito Santana da Silva Soares, Membro
Instituto Federal do Amazonas

AGRADECIMENTOS

À minha orientadora Prof.^a Dr.^a Marly Guimarães Fernandes Costa e ao meu coorientador Prof. Dr. Cícero Ferreira Fernandes Costa Filho, pela confiança que depositaram em mim e por contribuir ao meu crescimento profissional;

Ao amigo Prof. M.Sc. Francisco Januário pelo apoio e constante ajuda em minha trajetória;

Aos meus colegas Anne, Adriana, Rodrigo, Patrese e Walmir pela ajuda e incentivo nessa jornada;

À Universidade Federal do Amazonas, em especial ao Centro de Tecnologia Eletrônica e da Informação – CETELI pela concessão de toda infraestrutura para a realização desse trabalho;

À Fundação de Amparo à Pesquisa do Estado do Amazonas – FAPEAM pela concessão da bolsa de estudos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001.

À minha família, em especial aos meus queridos pais pelo amor, dedicação e apoio incondicional que me deram sempre;

Ao meu noivo Adson Seabra por todo carinho e apoio.

RESUMO

A ocorrência das cheias sazonais dos rios afeta, principalmente, a população ribeirinha. Identifica-se em bases de dados bibliográficas a realização de várias pesquisas no tema previsão de ocorrência de cheias. Os resultados dessas pesquisas constituem-se em importantes contribuições para políticas públicas, pois as ferramentas de previsão de cheias podem viabilizar ações preventivas, que minimizam os danos causados às populações ribeirinhas. Neste trabalho foram avaliados métodos capazes de prever o pico da cheia de rios. Os métodos desenvolvidos foram avaliados na previsão de cheias do rio Negro, o maior afluente da margem esquerda do rio Amazonas e o principal rio que passa às margens da cidade de Manaus. Os preditores implementados foram: Redes Neurais Artificiais (RNA) e métodos de Aprendizado baseados em Comitê. Foram utilizados os seguintes dados de entrada, relativos ao período de 1951-2017: índices climáticos e o nível do próprio rio. Esses dados foram, posteriormente, submetidos a um processo de seleção de características. Para o preditor usando RNA foram avaliadas três arquiteturas, diferenciadas pelo número de neurônios nas camadas ocultas, a saber: 6, 8 e 10, as quais foram treinadas utilizando os seguintes métodos de generalização: regularização L^2 e parada antecipada. O período de realização da previsão foi variado de 1 até 4 meses de antecedência da ocorrência do pico máximo da cheia na região. Adicionalmente, foi proposto a previsão das cheias em quatro categorias: alta, média-alta, média-baixa e baixa. Para o preditor usando métodos de Aprendizado baseados em Comitê foram utilizados os algoritmos de *bagging* e *boosting* para criar o comitê de regressão. A eficiência dos preditores foi avaliada através do Coeficiente de Correlação de Pearson (CCP) e pela acurácia da categorização das cheias. O melhor resultado do coeficiente de Pearson para o preditor utilizando RNA com parada antecipada foi $r_p = 0,9592$, ao passo que o melhor resultado com o comitê foi obtido usando o método de *bagging*, $r_p = 0,9374$. A classificação de cheias em categorias apresentou uma acurácia de 85,07% para o preditor RNA (parada antecipada e *bootstrap*) e com o Método baseado em comitê foi de 82,09% (*bagging*).

Palavras-Chave: Cheias Sazonais; Redes Neurais Artificiais; Métodos de Aprendizado baseados em Comitê; Categorização das cheias.

ABSTRACT

The occurrence of seasonal floods of rivers affects, mainly, the riverside population. It is identified in bibliographic databases the accomplishment of several researches in the subject prediction of occurrence of floods. The results of these surveys constitute important contributions to public policies, since flood forecasting tools can enable preventive actions, which minimize the damage caused to the riverine populations. In this work, methods capable of predicting the peak of the river flood were evaluated. The methods developed were evaluated in the flood forecast of the Negro River, the largest tributary of the left bank of the Amazon River and the main river that passes by the city of Manaus. The predictors implemented were: Artificial Neural Networks (ANN) and Learning methods based on Committee. The following input data were used for the period 1951-2017: climatic indexes and the level of the river itself. These data were later subjected to a process of selection of characteristics. For the predictor using ANN, three architectures, differentiated by the number of neurons in the hidden layers, were evaluated: 6, 8 and 10, which were trained using the following generalization methods: L^2 regularization and early stopping. The forecast period was varied from 1 to 4 months in advance of the occurrence of the maximum flood peak in the region. Additionally, it was proposed to predict floods in four categories: high, medium-high, medium-low and low. For the predictor using Committee-Based Learning methods, the bagging and boosting algorithms were used to create the regression committee. The efficiency of the predictors was evaluated through the Pearson Correlation Coefficient (PCC) and the accuracy of the flood categorization. The best Pearson coefficient result for the predictor using ANN with early stop was $r_p = 0,9592$, while the best committee result was obtained using the bagging method, $r_p = 0,9374$. The classification of floods into categories presented an accuracy of 85,07% for the predictor ANN (early stop and bootstrap) and with the Method based on committee was of 82,09% (bagging).

Keywords: Seasonal Floods; Artificial neural networks; Methods of Learning based on Committee; Flood categorization.

LISTA DE ILUSTRAÇÕES

Figura 1: Representação do neurônio artificial. Fonte: Adaptado de (DSA, 2018).....	19
Figura 2: Arquitetura de RNA simples. Fonte: (DSA, 2018)	20
Figura 3: Rede neural de Múltiplas Camadas. Fonte: Adaptado de (DSA, 2018).....	21
Figura 4: Ilustração do Algoritmo de Backpropagation. Fonte: (DSA, 2018).....	22
Figura 5: Arquitetura <i>ensemble methods</i> . Fonte: (Zhou, 2012)	26
Figura 6: Ilustração do método Bootstrap. (Theodoridis, et al., 2003)	30
Figura 7: Modelo NNARX. Fonte: Adaptada de (Anuar, et al., 2017).....	35
Figura 8: Arquitetura do modelo SAE-BP. Fonte: Adaptada de (Liu, et al., 2017).....	36
Figura 9: Diagrama de Previsão. Fonte: Adaptada de (Ruslan, et al., 2014).....	40
Figura 10: Diagrama de implementação dos métodos para previsão de cheias sazonais.	46
Figura 11: Localização El Niño. Fonte: (Climate Prediction Center, 2018).....	48
Figura 12: Ilustração da Metodologia <i>Leave-One-Out</i> . Fonte: Adaptado de (Sonka, et al., 2000)	49
Figura 13: RNA com arquitetura 9-6-6-1.	51
Figura 14: RNA com arquitetura 9-8-8-1.	51
Figura 15: RNA com arquitetura 9-10-10-1.	51
Figura 16: Método <i>bootstrap</i> : Procedimento para geração de um conjunto de treinamento com 100 anos. A escolha dos anos que constituem o lado direito da figura é feita de forma aleatória.	52
Figura 17: Associação das RNAs criadas com os 25 conjuntos gerados.	53
Figura 18: Distribuição dos dados numa distribuição normal. Fonte: (Portal Action, 2018)	56
Figura 19: Redes Neurais utilizadas.	58
Figura 20: Gráfico de convergência para a rede com arquitetura 10-10-1, 8 variáveis de entrada e método de regularização L^2	60
Figura 21: Curva de Correlação obtida com os valores preditos por uma rede com arquitetura 10- 10-1, 8 variáveis de entrada e regularização L^2 . $r = 0,9457$	61
Figura 22: Gráfico de convergência para a rede com arquitetura 10-10-1, 8 variáveis de entrada e método de generalização de parada antecipada.	62
Figura 23: Curva de Correlação obtida com os valores preditos por uma rede com arquitetura 10- 10-1, 8 variáveis de entrada e generalização de parada antecipada. $r = 0,9592$	62
Figura 24: Curva de Correlação para o método de bagging, com 8 variáveis de entrada. $r =$ $0,9374$	69
Figura 25: Curva de Correlação para o método de boosting, com 8 variáveis de entrada. $r = 0,9154$	70

LISTA DE QUADROS

Quadro 1: Algoritmo de Bagging	27
Quadro 2: Algoritmo de Boosting	28

LISTA DE TABELAS

Tabela 1: Comparação dos resultados de diferentes abordagens. Fonte: (Liu, et al., 2017).....	37
Tabela 2: Validação do modelo proposto. Fonte: Adaptada de (Mitra, et al., 2016).....	38
Tabela 3: Índice de desempenho para estimativa de inundação. Fonte: Adaptada de (Shu, et al., 2004).....	41
Tabela 4: Comparação dos artigos usando Redes Neurais e Métodos Convencionais.	43
Tabela 5: Aplicação utilizando métodos de aprendizado baseado em comitê.	45
Tabela 6: Índices Climáticos. Fonte: (Climate Prediction Center, 2018).....	48
Tabela 7: Ordenamento das variáveis usando o método de seleção escalar de características modificado. Fonte: (Rodrigues et al., 2015).....	49
Tabela 8: Faixas e classe de cheias em função da média e desvio padrão dos picos de cheias no período de 1903 a 2017 ($m = 27,87m$ e $\sigma = 1,15$).....	56
Tabela 9: Melhores desempenhos dos experimentos com RNA utilizando regularização L^2	60
Tabela 10: Melhores desempenhos dos experimentos com RNA utilizando Parada Antecipada.	61
Tabela 11: Resultados dos experimentos para as RNAs com 4 meses de antecedência do pico máximo da cheia.	65
Tabela 12: Resultados dos experimentos com 8 e 9 variáveis de entrada para as RNAs.....	66
Tabela 13: Resultado da matriz de confusão para a classificação de faixas.	67
Tabela 14: Resultados de previsão do pico da cheias com 4 meses de antecedência para os métodos de Aprendizado baseado em Comitê em função do número de variáveis de entrada. ..	71
Tabela 15: Melhores resultados de previsão de pico de cheias para 4, 3, 2 e 1 mês de antecedência da ocorrência da cheia obtidos com os métodos de aprendizado baseados em Comitê.	72
Tabela 16: Resultado da matriz de confusão para a classificação de cheias sazonais em faixas.	73
Tabela 17: Comparação de desempenho entre RNA e os métodos de aprendizagem baseados em comitê com 1 mês de antecedência do pico da cheia.	74
Tabela 18: Comparação de desempenho entre o preditor RNA deste trabalho e o implementado por Rodrigues et.al. (2015) para previsão de cheias com 4 meses de antecedência.....	74
Tabela 19: Acurácia da classificação das cheias em faixas de valores a partir dos preditores usados.....	75

LISTA DE ABREVIATURAS E SIGLAS

BP	<i>Backpropagation</i>
DC	<i>Deterministic Coefficient</i>
ENN	<i>Elman Neural Network</i>
ENSO	<i>El Niño – Southern Oscillation</i>
GPRS	<i>General Packet Radio Service</i>
ICP	Índice de Correlação de Pearson
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos
IoT	<i>Internet of Things</i>
LSBoost	<i>Least Square Boosting</i>
MAE	<i>Mean Absolute Error</i>
MLP	<i>Multilayer Perceptron</i>
MSE	Erro Quadrático Médio
NNARX	<i>Neural Network Auto Regressive with Exogenous</i>
PPGEE	Programa de Pós-Graduação em Engenharia Elétrica
PRError	<i>Percentual Relative Error</i>
RBias	<i>Relative Bias</i>
RMSE	<i>Root Mean Square Error</i>
RNA	Redes Neurais Artificiais
RSError	<i>Relative Square Error</i>
SAE	<i>Stacked Autoencoders</i>
SOI	<i>South Oscillation Index</i>
SST	<i>Sea Surface Temperature</i>
SVM	<i>Support Vector Machine</i>
WSN	<i>Wireless Sensor Network</i>

SUMÁRIO

LISTA DE ILUSTRAÇÕES	8
LISTA DE QUADROS	9
LISTA DE TABELAS	10
LISTA DE ABREVIATURAS E SIGLAS	11
SUMÁRIO	12
1 INTRODUÇÃO	14
1.1 Objetivo Geral	15
1.2 Objetivos Específicos	16
1.3 Estrutura do Trabalho	16
2 FUNDAMENTAÇÃO TEÓRICA	18
2.1 Redes Neurais Artificiais (RNA)	18
2.1.1 Aprendizado	21
2.1.2 Algoritmo de Retropropagação (<i>Backpropagation</i>)	22
2.2 Métodos de Aprendizado Baseado em Comitê	25
2.3 Método de Seleção Escalar de Características Modificado	28
2.4 Método <i>Bootstrap</i>	29
2.5 Significância Estatística	30
2.5.1 Teste de significância Qui-quadrado (χ^2)	31
3 REVISÃO BIBLIOGRÁFICA	33
3.1 Métodos Estatísticos Tradicionais	33
3.2 Redes Neurais Artificiais	34
3.3 Métodos de aprendizado baseado em comitê	40
3.4 Resumo	41
4 MATERIAIS E MÉTODOS	46
4.1 Conjunto de dados	47
4.2 Metodologia de Previsão	48
4.3 Configuração e Treinamento das Redes Neurais	50
4.4 Método de generalização <i>Bootstrap</i>	52
4.5 Configuração dos Métodos de Aprendizado Baseado em Comitê	53
4.6 Avaliação do desempenho dos preditores	54
4.6.1 Coeficiente de Correlação de Pearson	54
4.6.2 Índices de Erro	55
4.6.3 Acurácia da categorização da previsão de cheias em faixas	55
5 RESULTADOS	58
5.1 Redes Neurais Artificiais	58

5.1.1	Curvas de Convergência das RNAs para Regularização L^2	59
5.1.2	Curvas de Convergência das RNAs com Parada Antecipada	61
5.1.3	Valores de Coeficiente de Pearson e de Índices de Erro para as RNAs.....	63
5.1.4	Valores da Matriz de Confusão para a classificação de faixas utilizando RNA	67
5.2	Aprendizado baseado em Comitê.....	68
5.2.1	Curva de correlação do <i>Bagging</i>	68
5.2.2	Curva de correlação do <i>Boosting</i>	69
5.2.3	Coeficientes de Pearson e Índices de Erro para os métodos de Aprendizado baseado em Comitê.....	70
5.2.4	Resultados da classificação de cheias em faixas utilizando aprendizado baseado em Comitê.....	72
6	DISCUSSÃO.....	74
7	CONCLUSÃO	76
	REFERÊNCIAS	78
	APÊNDICE I.....	80

1 INTRODUÇÃO

O rio Negro é o maior afluente da margem esquerda do rio Amazonas e o principal rio que passa às margens da cidade de Manaus. É o mais extenso rio de água negra do mundo, e o segundo maior em volume de água, ficando atrás somente do rio Amazonas. O fenômeno das cheias atinge principalmente os municípios que estão nas margens dos rios Solimões, Amazonas, Tapajós, Negro, Juruá, Purus, Japurá e Madeira. A maior cheia já registrada do rio Negro em Manaus ocorreu em 2012 e atingiu a cota de 29,97 metros acima do nível do mar (ANA, 2019). Esse fenômeno de subidas e baixas do rio, que é comandado pelo rios Negro e Solimões, atinge todos os rios da bacia Amazônica (MMA, 2007).

Anualmente, quando inicia a estação chuvosa na região Amazônica, ocorre o fenômeno das cheias. As cheias que ocorrem na orla de Manaus e em seu entorno duram cerca de sete a oito meses, isso ocorre devido ao gigantesco tamanho da bacia hidrográfica e a pequena declividade dos leitos. Esse ciclo sazonal das cheias inicia, geralmente, em fevereiro e a sua máxima é alcançada entre os meses de junho e julho, coincidindo com o chamado verão Amazônico. Em geral em agosto, a água começa a recuar, dando início a estação da seca que fica mais acentuada no mês de outubro, quando a temperatura fica mais elevada. Esse ciclo de cheias tem consequências principalmente sobre a população ribeirinha, que habitam às margens dos rios, prejudicando as atividades de pesca e agricultura e a criação de animais. Outra consequência da cheia dos rios é o comprometimento da segurança e da saúde dos ribeirinhos, tornando as enchentes um problema social e econômico (MMA, 2007). É importante enfatizar que as intervenções humanas (urbanização, construção de moradias às margens dos rios e aos obstáculos que se criam ao escoamento da água) ao longo da bacia hidrográfica, são alguns dos elementos que influenciam na magnitude das enchentes. Assim, quando o homem ultrapassa os limites naturais do meio em que vive ele contribui para que as inundações se tornem um problema social, econômico e ambiental.

Em Manaus, o alerta de cheias é realizado pelo Serviço Geológico do Brasil desde 1989. Esse serviço monitora anualmente os níveis d'água dos rios Solimões, Negro e Amazonas. O monitoramento é divulgado por meio de boletins semanais emitidos em parceria com Sistema de Proteção da Amazônia – SIPAM e tem o objetivo de manter a

população e as autoridades (defesa civil, corpo de bombeiros, governos estadual e municipal) informadas sobre o comportamento das cheias na região, propiciando meios de uma tomada de decisão mais segura. (MMA, 2007).

Em pesquisa bibliográfica foram identificadas algumas propostas de previsão de cheias que visam fornecer informações antecipadas sobre as ocorrências de inundações. A utilização dessas ferramentas, pelos órgãos públicos, permitiria minimizar os danos causados pelas cheias. Dentre esses trabalhos, destacam-se o de Córdoba-Machado *et.al.* (2016), de Schongart *et.al.* (2007) e o de Rodrigues *et.al.* (2015), que mostram a correlação das chuvas e descargas da bacia Amazônica, usando padrões atmosféricos e oceânicos como a Temperatura da Superfície do Mar (do inglês, *Sea Surface Temperature – SST*) e o fenômeno climático ENSO (do inglês, *El Niño South Oscillation*). Os trabalhos referidos e a maioria dos trabalhos identificados na literatura utilizam redes neurais artificiais como mecanismo de previsão da cheia.

Por outro lado, identifica-se na literatura a utilização em diversas tarefas de classificação (Ju, et al., 2017) e predição de métodos de aprendizado baseados em comitê que agregam múltiplos modelos de aprendizado com o objetivo de melhorar a precisão, gerando vários preditores para resolver o mesmo problema (Shu, et al., 2004). Esses métodos ainda são pouco explorados na literatura.

Nesse trabalho, pretendemos explorar novamente a predição da cheia do Rio Negro, procurando trazer para a área as seguintes contribuições: 1) comparar o desempenho de redes neurais com o método de aprendizado baseado em comitê, na previsão do pico da cheia do Rio Negro, através da utilização de índices climáticos e do nível do Rio Negro; 2) avaliar a previsão da cheia com 4, 3, 2 e 1 mês de antecedência; 3) propor uma classificação das cheias em faixas de valores e avaliar os erros cometidos pelos preditores considerando a existência dessas faixas.

1.1 Objetivo Geral

O objetivo geral desse trabalho é realizar um estudo comparativo entre redes neurais artificiais e métodos de aprendizado baseado em comitê para previsão do valor do pico de cheia de rios, com base em cotas da cheia do rio e de índices climáticos registrados em meses anteriores ao mês da ocorrência do pico máximo da cheia.

1.2 Objetivos Específicos

São objetivos específicos deste trabalho:

- Avaliar o desempenho de três arquiteturas de redes neurais artificiais de propagação direta, na previsão da cheia utilizando regularização L^2 , parada antecipada (*Early Stop*) e *Bootstrap*;
- Avaliar o desempenho do aprendizado baseado em comitê na previsão da cheia do rio Negro;
- Comparar o desempenho das RNAs com o desempenho do comitê de classificadores na previsão de cheias do rio Negro;
- Propor uma metodologia para classificação das cheias do rio Negro em categorias em função das faixas de variação de níveis d'água.

1.3 Estrutura do Trabalho

Este trabalho está dividido em sete capítulos. O Capítulo 1 trata da apresentação da motivação desse estudo, caracterizando e contextualizando o problema. Além disso, são descritos os objetivos gerais e específicos desta dissertação.

No Capítulo 2 é apresentado uma revisão bibliográfica de artigos relacionados ao tema de previsões de cheias, analisando e explorando as metodologias utilizadas pelos autores. Os artigos foram obtidos por meio das bases de dados: *IEEE*, *Web of Science* e *Google Scholar*.

O capítulo 3 aborda a fundamentação teórica, com o conteúdo necessário para o desenvolvimento deste trabalho, como os conceitos básicos de redes neurais artificiais, aprendizado baseado em comitê e o método de seleção escalar de características modificado, que foi proposto por um membro desta equipe de pesquisa (Rodrigues, et al., 2015).

No Capítulo 4 são apresentados os materiais utilizados para a implementação da proposta deste trabalho, assim como os algoritmos de redes neurais artificiais e aprendizado baseado em comitê que foram empregados para o desenvolvimento desta pesquisa.

No Capítulo 5 são apresentados os resultados obtidos por meio da realização de experimentos com as RNAs e com os métodos de aprendizado baseado em comitê.

No capítulo 6 são apresentados as discussões dos resultados para ambos os preditores desenvolvidos.

Finalmente, no capítulo 7, as conclusões sobre os resultados obtidos são expostas.

2 FUNDAMENTAÇÃO TEÓRICA

Esse capítulo descreve os principais métodos e ferramentas necessários para o desenvolvimento do trabalho proposto. Primeiramente, aborda-se conceitos relativos a Redes Neurais Artificiais (RNA) para previsões de cheias, empregando o algoritmo de *Backpropagation* juntamente com o método de otimização de *Levenberg-Marquadt* (Yu, et al., 2010). Outro método abordado, mas que ainda é pouco utilizado na literatura, são os métodos de aprendizado baseado em comitê (Zhou, 2012), que podem ser utilizados tanto para classificação quanto para regressão. Em seguida, é descrito o método de Seleção Escalar de Características Modificado (Rodrigues, et al., 2015). Por fim, é descrito o teste de hipótese estatística, Qui-quadrado (X^2), utilizado para avaliar os resultados obtidos no trabalho proposto.

2.1 Redes Neurais Artificiais (RNA)

Uma rede neural é uma máquina que modela a maneira como o cérebro realiza uma tarefa particular. Pode ser definida da seguinte forma:

“Uma RNA é um processador maciço, paralelamente distribuído, constituído de neurônios com uma capacidade natural para armazenar conhecimento e assim torná-lo útil. A RNA possui semelhança com o cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede através de um processo de aprendizagem;
2. As conexões entre neurônios são utilizadas para armazenar o conhecimento obtido.” (Haykin, 2001).

As RNAs são formadas por um conjunto de neurônios artificiais que interagem entre si, à semelhança da estrutura e funcionamento dos neurônios biológicos. O neurônio artificial de uma rede neural é um componente que calcula uma soma ponderada de várias entradas e utiliza uma função de ativação para então produzir uma saída (DSA, 2018).

Dessa maneira, as redes neurais artificiais possuem a capacidade de coletar e armazenar informações baseadas no processo de aprendizagem. Esse processo é realizado a partir da implementação de um algoritmo de aprendizagem, onde os pesos são

modificados até que se obtenha a saída desejada. Para que as RNAs sejam capazes de resolver problemas complexos em diversas aplicações é necessário que um treinamento adequado, com uma quantidade razoável de amostras seja efetuado.

As redes neurais artificiais possuem algumas características importantes, como a não-linearidade, alto paralelismo, robustez, tolerância a falhas, aprendizagem, capacidade de lidar com informações imprecisas e capacidade de generalização (Jain, et al., 1996). Modelos de RNA com estas características são muito desejáveis, pois:

- A não-linearidade permite um melhor ajuste de dados;
- A robustez e tolerância a falhas não afeta substancialmente o desempenho da rede após a eliminação de alguns neurônios;
- A flexibilidade pode ser ajustada a novos ambientes por meio do processo de aprendizagem;
- A capacidade de lidar com informações incertas garante que, mesmo quando a informação é fornecida incompleta ou afetada por ruído, ainda é possível obter um raciocínio correto;
- O paralelismo implica em um processamento rápido;
- A capacidade de generalização da rede permite a aplicação do modelo para dados desconhecidos.

As redes neurais artificiais possuem todas a mesma unidade de processamento: o neurônio artificial, que simula o comportamento do neurônio biológico. O modelo artificial do neurônio é apresentado na Figura 1, em que são mostrados os três elementos básicos de um modelo artificial de neurônio biológico:

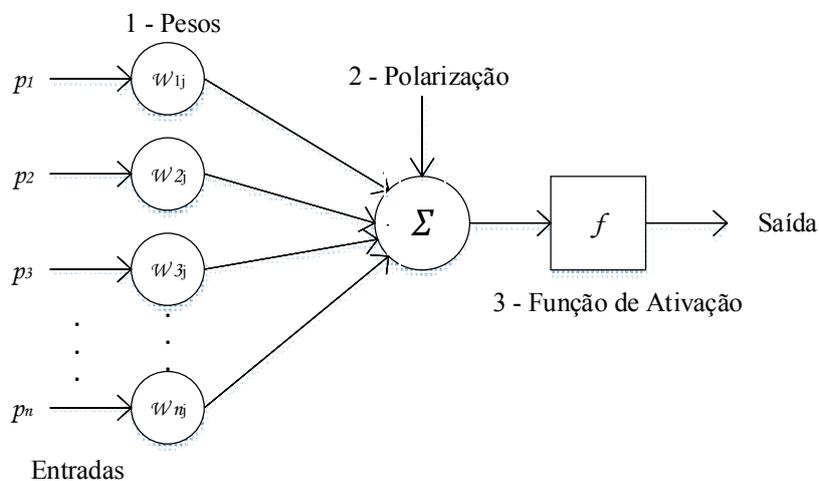


Figura 1: Representação do neurônio artificial. Fonte: Adaptado de (DSA, 2018)

1 – Sinapse ou elos de conexão (pesos): Refere-se ao peso associado à cada entrada da rede. Os índices referem-se a entrada e ao neurônio ao qual o peso se conecta.

2 – Somador (polarização): Realiza a soma ponderada do produto das entradas pelos respectivos pesos;

3 – Função de Ativação: É responsável por restringir a amplitude da saída do neurônio a um valor finito. A polarização que é aplicado externamente, tem a função de aumentar ou diminuir a entrada líquida da função de ativação, possibilitando que o neurônio apresente saída não nula ainda que todas as suas entradas sejam nulas (Haykin, 2001).

A arquitetura de uma rede neural pode assumir diversas formas, dependendo do tipo de aplicação a ser realizada, estando diretamente ligado ao algoritmo de aprendizagem utilizado para treinar a rede. Os seguintes itens definem a arquitetura de uma rede neural: número de camadas intermediárias, a quantidade de neurônios em cada camada e a função de ativação. Para o treinamento de uma rede neural utiliza-se um algoritmo de aprendizagem. A Figura 2 apresenta um exemplo de arquitetura de rede neural simples.

De acordo com a Figura 2, é possível notar que um neurônio pode receber um ou mais sinais de entrada e produzir um único sinal de saída, que pode ser o sinal de saída da rede ou o sinal de entrada para um ou vários outros neurônios da camada posterior, que formam a rede neural artificial (DSA, 2018).

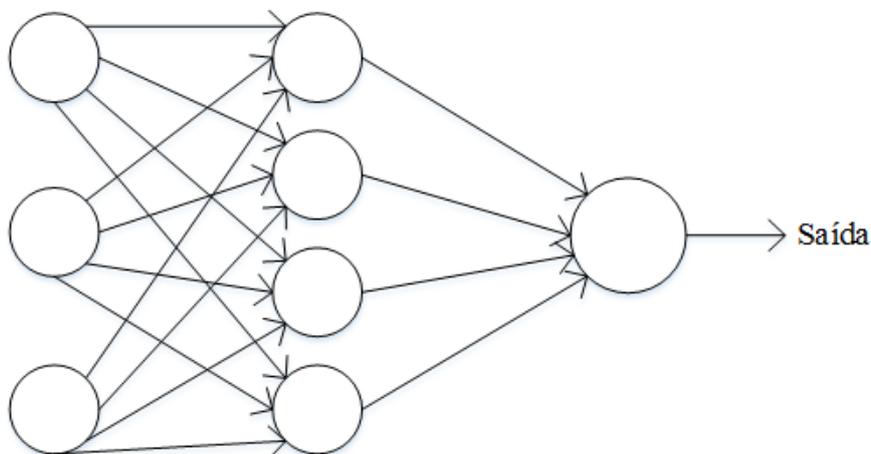


Figura 2: Arquitetura de RNA simples. Fonte: (DSA, 2018)

Na Figura 3 exemplifica-se um MLP (do inglês, *Multilayer Perceptron*) com quatro camadas, sendo que duas são camadas ocultas (DSA, 2018). A camada mais à esquerda é denominada de camada de entrada. A camada mais à direita é a camada de saída e pode conter um ou mais neurônios. A camada do meio é chamada de camada oculta, pois os neurônios nessa camada não se comunicam com o exterior. Algumas redes possuem múltiplas camadas ocultas. Essas redes são denominadas de *Perceptrons* Multicamadas.

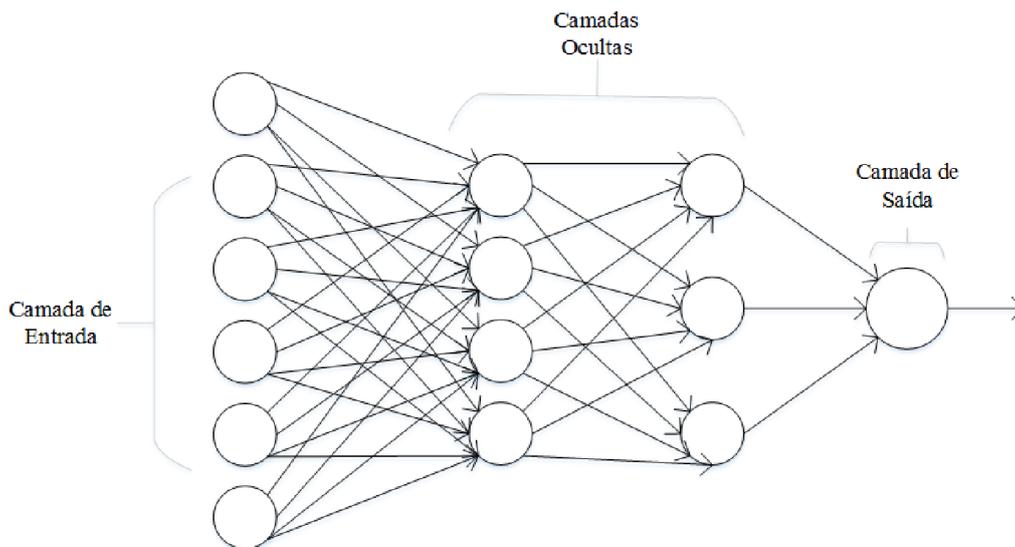


Figura 3: Rede neural de Múltiplas Camadas. Fonte: Adaptado de (DSA, 2018)

2.1.1 Aprendizado

A propriedade mais importante de uma rede neural é a sua capacidade de aprender automaticamente a partir de exemplos, através de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de polarização, que torna a rede mais instruída após cada iteração do processo de aprendizagem (Jain, et al., 1996).

Os métodos de aprendizado das redes neurais podem ser divididos em dois grupos: aprendizado supervisionado e aprendizado não-supervisionado. O aprendizado supervisionado é aquele em que o agente externo confere o quanto a rede está próxima da solução aceitável, adaptando durante o treinamento os pesos entre os neurônios, na tentativa de obter diferenças mínimas entre as saídas desejadas e as saídas obtidas. No aprendizado não supervisionado as saídas da rede não são conhecidas. Normalmente, através de algoritmos de agrupamento, formam-se as classes desejadas (Jain, et al., 1996).

2.1.2 Algoritmo de Retropropagação (*Backpropagation*)

O algoritmo de *Backpropagation* é considerado o mais importante para o treinamento das redes neurais. Esse algoritmo procura, de forma iterativa, a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural (Rumelhart, et al., 1986). Por meio de um mecanismo de correção de erros, realiza o ajuste dos pesos em cada camada da RNA (DSA, 2018).

O algoritmo de *Backpropagation* é um tipo de treinamento supervisionado e consiste em duas fases:

1. O passo para frente (do inglês, *Forward Pass*): essa etapa é também chamada de propagação direta. O sinal se propaga da entrada para a saída da rede, através da multiplicação sucessiva pelos pesos de cada uma das camadas que compõem a rede neural, até obter os valores de saída da rede.
2. O passo para trás (do inglês, *Backward Pass*): essa etapa é também conhecida como retropropagação ou propagação reversa. Utiliza a saída desejada e a saída fornecida pela rede, em conjunto com o método do gradiente descendente, para realizar a atualização dos pesos e conexões.

A Figura 4, ilustra o fluxo de processamento das fases do algoritmo de *Backpropagation* (Matsunaga, 2012).

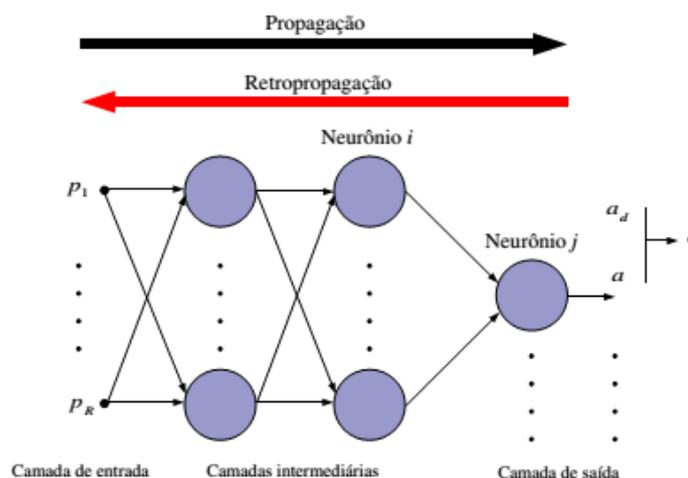


Figura 4: Ilustração do Algoritmo de *Backpropagation*. Fonte: (DSA, 2018)

Para a atualização dos pesos da última camada, o algoritmo de *Backpropagation* simplesmente calcula a derivada do erro em relação aos pesos da última camada e atualiza os mesmos pela regra do gradiente descendente. Para atualização dos pesos das camadas

anteriores, é aplicada a regra da cadeia. Em cada interação, ou seja, uma propagação direta e uma propagação reversa, os pesos sofrem uma atualização. Após um determinado número de interações, definido pelo valor final do erro desejado, diz-se que a rede aprendeu, ou seja, espera-se que tenha havido uma redução do erro cometido na saída da rede. A atualização dos pesos pode ser expressa através da Equação 1 (DSA, 2018).

$$\text{Novo Peso} = \text{Peso Antigo} - \text{Derivada} * \text{Taxa de Aprendizagem} \quad \text{Eq. 1}$$

A taxa de aprendizagem geralmente é definida com uma constante muito pequena, para que o peso seja atualizado de forma lenta e suave, evitando oscilações indesejáveis no processo de convergência da rede. Na RNA, a atualização de pesos é guiada pela força do gradiente descendente sobre o erro. Na literatura existem vários métodos de atualização de pesos, que são conhecidos como otimizadores, que visam acelerar o processo de convergência do algoritmo. Na próxima seção é abordado o método de otimização de Levenberg-Marquardt, que foi utilizado neste trabalho.

2.1.3 Método de Otimização Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt é o método de otimização mais eficaz para acelerar a convergência do algoritmo de *Backpropagation*, mostrando-se mais eficiente do que a técnica convencional do gradiente descendente. É considerado um método de segunda ordem, pois utiliza informações da segunda derivada da função de erro, assim como ocorre também nos métodos do gradiente conjugado e de Gauss-Newton (Silva, et al., 2012).

O método Levenberg-Marquardt é uma extensão do método de Gauss-Newton, que é uma variante do método de Newton. Porém, ele é mais robusto que o algoritmo de Gauss-Newton. Na maioria dos casos ele converge bem, mesmo que a superfície de erro seja muito mais complexa do que uma função quadrática. A ideia básica do algoritmo de Levenberg-Marquardt é que ele executa um processo de treinamento combinado quando uma região possui uma curvatura complexa, operando como um algoritmo do gradiente descendente. Essa mudança ocorre até que a curvatura local seja aproximadamente

quadrática. Nesse ponto, o mesmo opera como um algoritmo de Gauss-Newton, que pode acelerar significativamente a convergência (Yu, et al., 2010).

Segundo Silva *et.al.* (2012), a equação utilizada no algoritmo de Gauss-Newton para atualização dos pesos da RNA (W) e diminuição do valor do Erro Quadrático Médio (EQM) é dada por:

$$W_{i+1} = W_1 - H^{-1}\nabla f(W) \quad \text{Eq. 2}$$

em que:

H^{-1} – Matriz Hessiana invertida

W – Pesos da RNA

O gradiente $\nabla f(W)$ pode ser representado por:

$$\nabla f(W) = J^T e \quad \text{Eq. 3}$$

em que:

e – Vetor de erro representado por:

$$e = \begin{bmatrix} e_{1,1} \\ e_{1,2} \\ \dots \\ e_{1,M} \\ \dots \\ e_{P,1} \\ e_{P,2} \\ \dots \\ e_{P,M} \end{bmatrix} \quad \text{Eq. 4}$$

J – Matriz Jacobiana.

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial x_1} & \frac{\partial e_1}{\partial x_2} & \frac{\partial e_1}{\partial x_n} \\ \frac{\partial e_2}{\partial x_1} & \frac{\partial e_2}{\partial x_2} & \frac{\partial e_2}{\partial x_3} \\ \vdots & \vdots & \vdots \\ \frac{\partial e_n}{\partial x_1} & \frac{\partial e_n}{\partial x_2} & \frac{\partial e_n}{\partial n} \end{bmatrix} \quad \text{Eq. 5}$$

A matriz Hessiana pode ser calculada da seguinte maneira:

$$\nabla^2 f(W) = J^T J + S \quad \text{Eq. 6}$$

Onde x_i é o i -ésimo padrão da RNA e S pode-se supor que é um valor muito pequeno. Dessa forma, a relação entre a matriz Hessiana H e a matriz Jacobiana J pode ser reescrita da seguinte maneira:

$$\nabla^2 f(W) \approx J^T J \quad \text{Eq. 7}$$

Diante disso, a atualização dos pesos por meio do método de Gauss-Newton pode ser expresso por:

$$W_{i+1} = W_i - (J^T J)^{-1} J^T e \quad \text{Eq. 8}$$

Uma limitação do método de Gauss-Newton é que a matriz Hessiana não pode ser invertida. É nesse momento que o algoritmo de Levenberg-Marquardt apresenta uma modificação, sendo a atualização dos pesos efetuada da seguinte maneira:

$$W_{i+1} = W_i - (J^T J + \mu I)^{-1} J^T e, \quad \text{Eq. 9}$$

em que a matriz Identidade (I) e o parâmetro (μ) são responsáveis por tornar a matriz Hessiana definida positiva.

Ou seja, a vantagem do algoritmo de Gauss-Newton sobre o método padrão de Newton, é que o método de Gauss-Newton não utiliza derivada de segunda ordem na função de erro total, introduzindo a matriz Jacobiana J .

Hagan *et.al.* (1994), apresentou de forma resumida da modificação do método de Levenberg-Marquardt para o algoritmo de *Backpropagation*, seguindo o procedimento abaixo:

1. Apresentar todas as entradas para a rede e calcular a saída de rede correspondente;
2. Calcular a matriz Jacobiana J ;
3. Calcular a atualização de pesos de acordo com a Eq. 7 e avaliar o erro, propagando os padrões da RNA;
4. Se o erro aumentou então desfaça a atualização de pesos e reduza μ , senão valide a atualização e incremente μ ;
5. Se o algoritmo convergiu então encerre, senão volte para o passo 1.

2.2 Métodos de Aprendizado Baseado em Comitê

Os métodos de aprendizado baseado em comitê são meta-algoritmos que combinam várias técnicas de aprendizado de máquina em um modelo preditivo para

diminuir a variação e melhorar as previsões, diferente do que ocorre quando é utilizado um método de aprendizado convencional. Enquanto os métodos de aprendizado baseado em comitê tentam construir um conjunto de classificadores e combiná-los, as abordagens de aprendizado comuns tentam construir um único classificador a partir dos dados de treinamento. Esse método também é conhecido como sistemas de múltiplos classificadores (Zhou, 2012).

A Figura 5, apresenta uma arquitetura comum de comitê, mostrando que um comitê é formado pelos chamados classificadores de base. Esses classificadores são gerados a partir do treinamento de um algoritmo de aprendizado que poder ser uma árvore de decisão, uma rede neural, ou outros tipos de classificadores. Nos métodos de aprendizado baseado em comitê, podem ser usados um ou mais tipos de algoritmos de classificadores. Os classificadores de base homogêneos, utilizam classificadores do mesmo tipo, enquanto que os heterogêneos, utilizam classificadores de diferentes tipos. A maioria dos métodos de aprendizado baseado em comitê utiliza somente classificadores de base homogênea (Zhou, 2012).

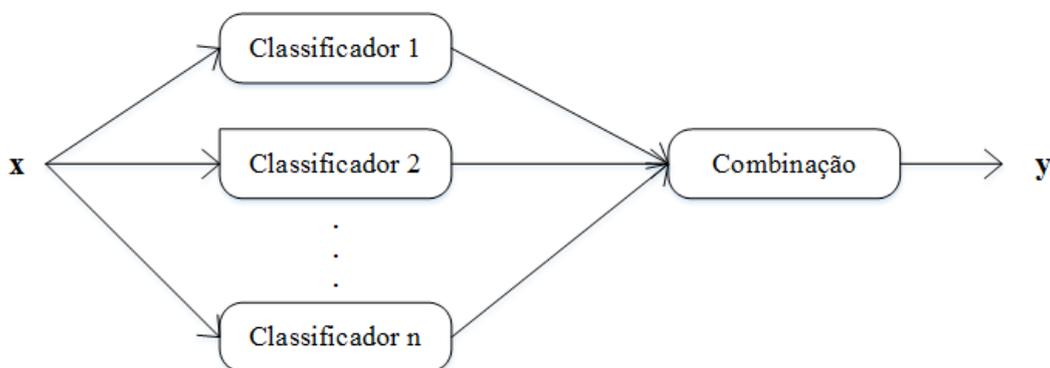


Figura 5: Arquitetura *ensemble methods*. Fonte: (Zhou, 2012)

Em essência, os métodos de aprendizado baseado em comitê apresentam as seguintes características:

1. Constroem modelos múltiplos e diversos, de versões adaptadas dos dados de treinamento (na maioria das vezes reponderados ou reamostrados);
2. Combinam as previsões desses modelos de alguma forma, muitas vezes por média simples ou votação (ponderada possível).

Na literatura, os algoritmos de montagem mais utilizados são o *bagging* e o *boosting* (Flach, 2012). O *bagging* (do inglês, *Bootstrap Aggregating*), utiliza amostragem *bootstrap* para obter um conjunto de dados para que os classificadores de

base sejam treinados. No *bagging*, os resultados dos classificadores de base são agregados por meio da combinação por votos para classificação e da média para regressão.

No *Bagging*, os classificadores são treinados de forma independente por diferentes conjuntos de treinamento. Uma classe comumente usada de algoritmos de comitê são as *Random Forests*. O Quadro 1, fornece o algoritmo básico para o *bagging*, que foi proposto por Breiman (1996). Cada árvore do comitê é construída a partir de uma amostra do conjunto de treinamento desenhada com substituição (ou seja, uma amostra de *bootstrap*), isso é feito na linha 4. Na linha 1 é definida o conjunto de dados a ser utilizado, o tipo de algoritmo de aprendizagem e o tamanho do comitê (Breiman, 1996). Esse algoritmo retorna um comitê de modelos (linha 2), podendo optar por combinar as previsões dos diferentes modelos por votação - a classe prevista pela maioria dos modelos ganha - ou pela média, o que é mais apropriado no caso de modelos regressivos (Flach, 2012).

Algoritmo 1: *Bagging*(D, T, \mathcal{A}) – Treinar um conjunto de modelos de amostras *bootstrap*

- 1 Entrada: **Dataset D ; tamanho do ensemble T ; algoritmo de aprendizagem \mathcal{A} .**
 - 2 Saída: **Conjunto de modelos cujas previsões devem ser combinadas por votação ou média.**
 - 3 For **$t=1$ para T** do
 - 4 **Construir um exemplo de *bootstrap* D_t de D , amostrando pontos de dados $|D|$ com substituição;**
 - 5 **Executar \mathcal{A} em D_t para produzir um modelo M_t ;**
 - 6 end
 - 7 Return **$\{M_t | 1 \leq t \leq T\}$**
-

Quadro 1: Algoritmo de *Bagging*. Fonte: (Flach, 2012)

O método de *boosting* é capaz de converter classificadores fracos, como uma árvore de decisão pequena, para versões ponderadas dos dados, chamados de classificadores fortes. Dessa forma, as previsões são então combinadas através de um voto majoritário ponderado para classificação, ou uma soma ponderada para regressão. A principal diferença em relação ao *bagging*, é que os conjuntos de dados reamostrados são construídos especificamente para gerar classificadores complementares, e a importância do voto é ponderado com base no desempenho de cada modelo, em vez da atribuição de mesmo peso para todos os votos. Esse procedimento permite aumentar o desempenho simplesmente adicionando aprendizes mais fracos (Flach, 2012).

O Quadro 2, apresenta o procedimento geral do método de *boosting*, onde na linha 1 é definido o conjunto de dados a ser utilizado, o tamanho do comitê e o algoritmo de

aprendizagem, na linha 10 são calculados os pesos para então ser realizada a previsão por meio de uma soma ponderada no caso da regressão. A saída (linha 2) é um conjunto ponderado de modelos.

Algoritmo 2: **Boosting(D,T,A)** – Treinar um conjunto de classificadores binários de conjuntos de treinamento reponderado.

```

1  Entrada: Dataset D; tamanho do ensemble T; algoritmo de aprendizagem A.
2  Saída: Conjunto ponderado de modelos.
3   $w_{1i} \leftarrow 1/|D|$  para todo  $x_i \in D$ ;
4  For  $t=1$  para T do
5      Executar A em D com pesos  $w_{ti}$  para produzir um modelo  $M_t$ ;
6      Calcular o erro ponderado  $\epsilon_t$ 
7  if  $\epsilon_t \geq 1/2$  then
8      set  $T \leftarrow t - 1$  and break
9  end
10  $\alpha_t \leftarrow \frac{1}{2} \ln \frac{1-\epsilon_t}{\epsilon_t}$ ;
11  $w_{(t+1)i} \leftarrow \frac{w_{ti}}{2\epsilon_t}$  para instâncias mal classificadas  $x_i \in D$ 
12  $w_{(t+1)j} \leftarrow \frac{w_{tj}}{2(1-\epsilon_t)}$  para instâncias corretamente classificadas  $x_j \in D$ 
13 end
14 Return  $\{M(x) = \sum_{t=1}^T \alpha_t M_t(x)\}$ 

```

Quadro 2: Algoritmo de Boosting. Fonte: (Flach, 2012)

2.3 Método de Seleção Escalar de Características Modificado

No trabalho desenvolvido por Rodrigues *et.al.* (2015), foi proposta a técnica de seleção escalar de características modificado, essa técnica é uma modificação do método original de seleção escalar de características, que é utilizada para selecionar as variáveis que melhor separam um conjunto de amostras com classes distintas. A diferença da técnica original para a que foi proposta no trabalho citado, foi a substituição da Discriminante Linear de Fisher – FDL (do inglês, *Fisher Linear Discriminant*) pelo Índice de Correlação de Pearson (ICP). Essa mudança foi realizada para que fossem selecionadas as melhores características ou variáveis que não possuíssem informações redundantes.

O método de seleção escalar de características modificado segue os seguintes passos (Rodrigues, et al., 2015):

1. Seleciona-se inicialmente o conjunto C de variáveis que apresentam coeficientes de correlação de Pearson com o pico da cheia estatisticamente significantes. Assim, será selecionada a primeira variável x_{s1} , que será a que possuir o maior valor de correlação com o pico da cheia;
2. Para selecionar a segunda variável, x_{s2} , foi utilizado o coeficiente de correlação cruzada entre as variáveis x_i e x_j , conforme a Equação 9.

$$\rho_{ij} = \frac{\sum_{n=1}^N x_{ni}x_{nj}}{\sqrt{\sum_{n=1}^N x_{ni}^2 x_{nj}^2}} \quad \text{Eq. 10}$$

em que N é o número total de anos ($2017 - 1951 + 1 = 66$), e x_{ni} e x_{nj} são os valores da i-ésima e da j-ésima variável do ano n. A segunda variável é aquela que maximiza a Equação 10.

$$\alpha_1 r_{s2} - \alpha_2 |\rho_{s1s2}|, \quad \text{para todo } s2 \neq s1 \quad \text{Eq. 11}$$

sendo que α_1 e α_2 expressam a importância do primeiro e do segundo termo.

3. As outras variáveis selecionadas, x_{sk} , são as que maximizam a Equação 11:

$$\alpha_1 r_{sk} - \frac{\alpha_2}{k-1} \sum_{r=1}^{k-1} |\rho_{srsk}| \quad \text{Eq. 12}$$

2.4 Método *Bootstrap*

O método *bootstrap* consiste na geração de novos conjuntos de dados artificialmente. Esse método é uma maneira de superar o fato de se ter um número limitado de dados de entrada disponíveis e criar mais dados. Dessa forma ao aplicar esse método em um conjunto de dados X de tamanho N, será obtido um novo conjunto de dados, X^* , de tamanho N, formado por amostragem aleatória com reposição do conjunto original de dados (X). Reposição quer dizer que quando uma amostra é copiada para um conjunto genérico, ela não é removida do conjunto original, mas sim reconsiderada na próxima amostragem (Theodoridis, et al., 2003).

Na Figura 6 tem-se a ilustração do método *bootstrap*. Os conjuntos de treinamento *bootstrap* (azuis) contêm, cada um tamanho $N=5$, portanto, possuem o mesmo tamanho do conjunto de dados original (cinza). Foram obtidos pela amostragem com reposição do conjunto de dados original. Isto significa que alguns dados podem não aparecer no conjunto de treinamento *bootstrap* e alguns podem aparecer mais de uma vez em um mesmo conjunto, como mostrado na referida Figura.

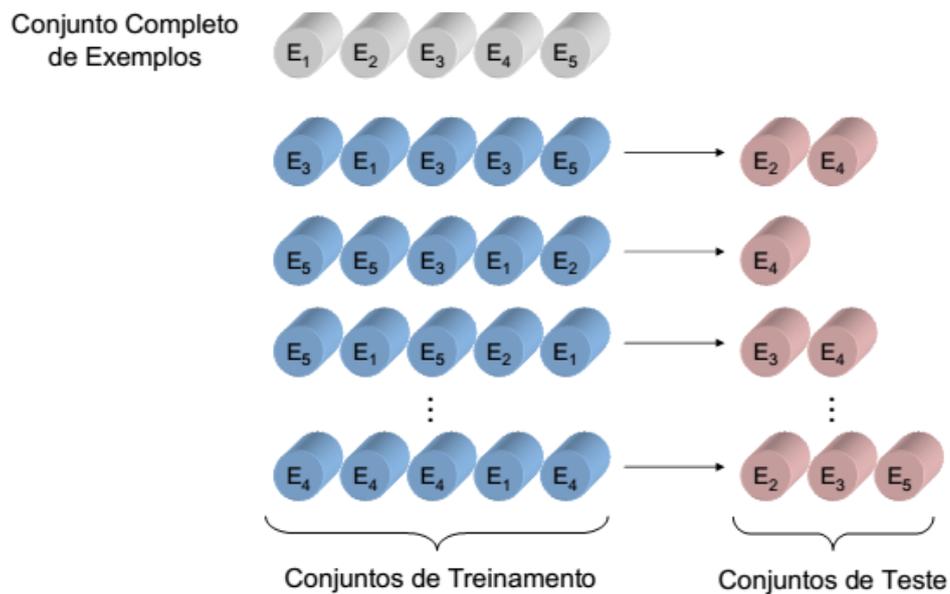


Figura 6: Ilustração do método *Bootstrap*. (Theodoridis, et al., 2003)

2.5 Significância Estatística

Testes de significância, também chamados de teste de hipótese, são procedimentos estatísticos que buscam verificar uma hipótese, no sentido de aceitá-la ou rejeitá-la, com base nos resultados de uma amostra. Dessa forma, a questão da significância de um resultado é abordada usando-se o conceito de hipótese estatística. As hipóteses estatísticas surgem de problemas científicos, existindo dois tipos básicos: hipótese nula (H_0) e hipótese Alternativa (H_A) (Costa Neto, 2002).

A hipótese nula (H_0), assume que um dado resultado estatístico foi obtido por acaso, devido a flutuações probabilísticas dos eventos medidos, e não devido a uma causa real que influencia o resultado. Ou seja, essa hipótese supõe a igualdade dos parâmetros

que estão sendo testados. A hipótese alternativa (H_A), é considerada caso a hipótese nula (H_0) seja rejeitada, e supõe que os parâmetros testados são diferentes.

De modo geral, são definidos cinco passos para a construção de um teste de hipóteses (Piana, et al., 2009):

1. Definir as hipóteses estatísticas: H_0 e H_A ;
2. Fixar o nível de significância α e identificar a estatística do teste;
3. Determinar a região crítica (faixa de rejeição) e a região de aceitação em função do nível de α pelas tabelas estatísticas apropriadas;
4. Baseado na amostra, calcular o valor da estatística do teste;
5. Concluir: se valor estatístico \in região crítica, rejeição, caso contrário aceitação.

Neste trabalho, o teste de significância estatística é utilizado com o objetivo de avaliar se as diferenças entre os resultados de previsão da cheia do Rio Negro, obtidos por diversos classificadores, e expressos através de categorias de valores, são estatisticamente significantes ou não. Para a avaliação da significância estatística, foi o utilizado o teste Qui-quadrado (teste X^2) (Costa Neto, 2002).

2.5.1 Teste de significância Qui-quadrado (X^2)

O teste Qui-quadrado é considerado um teste não-paramétrico, isso quer dizer que não depende de parâmetros populacionais, nem de suas respectivas estimativas. Ou seja, esse teste permite verificar se frequências de categorias observadas estão de acordo com as frequências esperadas (Piana, et al., 2009).

Esse teste foi desenvolvido por Karl Pearson e é baseado em uma estatística Q , que tem distribuição Qui-quadrado com parâmetro ν . É assim definido (Costa Neto, 2002):

$$Q = \sum_{i=1}^k \frac{(X_i - E_i)^2}{E_i} \sim X^2(\nu), \quad \text{Eq. 13}$$

em que

X_i : É a frequência observada da classe i ;

E_i : É a frequência esperada da classe i ;

k : É o número total de classes da variável;

$v = k - 1$: É o número de graus de liberdade ou classes independentes.

Esse teste possui algumas restrições que devem ser observadas quando o mesmo for utilizado, tais como:

- O teste é válido somente para frequências absolutas;
- A distribuição Qui-quadrado é derivada da distribuição normal, sendo assim uma distribuição contínua. Dessa forma, devido ao tipo de dado que for utilizado, deverão ser feitas algumas considerações para que seja obtido uma boa aproximação, como:

- a) Em casos que se trabalha apenas com um grau de liberdade, é necessário utilizar uma correção, chamada de correção de continuidade, dada pela Equação 13;

$$Q = \sum_{i=1}^k \frac{(|X_i - E_i| - 0,5)^2}{E_i} \quad \text{Eq. 14}$$

- b) Quando existirem frequências esperadas menores que cinco, é conveniente que sejam agrupadas.

3 REVISÃO BIBLIOGRÁFICA

Constata-se na literatura que já foram desenvolvidos vários sistemas de previsão de cheias, com o intuito de obter informações antecipadas sobre as ocorrências de inundações, que são grandes causadoras de desastres naturais, afetando principalmente a população ribeirinha. A motivação para esses desenvolvimentos é que, a partir dos sistemas desenvolvidos, medidas preventivas possam ser tomadas antecipadamente pelas autoridades responsáveis, na tentativa de minimizar os danos causados à população (MMA, 2007). As ferramentas mais utilizadas na literatura para realizar a previsão de cheias são os métodos estatísticos tradicionais (como regressão linear) e as Redes Neurais Artificiais (Schongart *et.al.*, 2007; Córdoba-Machado *et.al.*, 2016; Anuar *et.al.*, 2017; Truatmoraka *et.al.*, 2016; Rodrigues *et.al.*, 2015; Mitra *et.al.*, 2016; Liu *et.al.*, 2017 e Ruslan *et.al.*, 2014). Outro método utilizado na predição de cheias, identificado na literatura, é o de aprendizado baseado em comitê (*Ensemble Methods*), também conhecido como aprendizado de sistemas de múltiplos classificadores (Zhou, 2012). Na literatura, foi possível encontrar a aplicação de (Shu, et al., 2004) utilizando esse método.

3.1 Métodos Estatísticos Tradicionais

Um método de previsão de inundação bastante utilizado na literatura é conhecido como correlação estatística. O mesmo fornece o grau de relacionamento linear entre duas variáveis. Com relação aos rios da Bacia Amazônica, foi visto que a variação anual do nível da cheia do rio e as chuvas nesse período têm uma forte correlação com a Temperatura da Superfície do Mar (do inglês, *Sea Surface Temperature – SST*) e com os fenômenos climáticos ENSO (do inglês, *El Niño South Oscillation*). O estudo de Schongart e Junk (2007), utilizou múltiplas correlações e fez uma análise, no período de 1903 à 2004, do nível do rio no porto de Manaus. Foram encontradas altas correlações entre o nível máximo do rio Negro, o Índice de Oscilação Sul (do inglês, *South Oscillation Index –SOI*) e as anomalias SST, com 4 meses de antecedência da ocorrência do pico da cheia, sendo o índice de correlação $r = 0,71$ e o teste de significância estatística *t-student*, $p = 0,0001$. Os resultados obtidos indicaram uma boa congruência entre os valores observados e os previstos para os níveis de cheia do rio Negro, mostrando que as diferenças entre os níveis de inundação observados e previstos são inferiores à 50 cm em

46,5 % dos casos, inferiores à 100 cm em 81,2 % dos casos, e inferiores à 150 cm em 97 % dos casos observados.

O estudo de Córdoba-Machado *et.al.* (2016), utilizou uma análise de correlação móvel de 30 anos para realizar a previsão sazonal do rio Magdalena, usando padrões atmosféricos e oceânicos como a Temperatura da Superfície do Mar (do inglês, *Sea Surface Temperature* – SST), a Precipitação (Pt), a Temperatura sobre a Terra (Tm) e o Índice de Teleconexão. Esse último índice é usado em meteorologia para descrever variações simultâneas entre processos climáticos que ocorrem em diferentes lugares do mundo. Para realizar esse estudo, foram selecionadas três estações ao longo do rio Magdalena, sendo a estação 2 considerada a mais representativa do fluxo do rio, abrangendo o período de 1936 à 2009. O esquema de previsão adotado foi baseado em modelos de regressão linear e utiliza o tempo entre os campos preditores SST, Pt e Tm, e os campos preditivos (Qs). O resultado mostrou correlações significativas e estáveis entre as anomalias Qs e as anomalias SST, Pt e Tm, mostrando correlações significativas. A melhor previsão de Qs foi obtida para o inverno, usando a precipitação (Pt) ocorrida durante o outono como preditor, registrando um erro entre a série de vazões original e prevista de 0,33 e uma correlação de 0,74.

3.2 Redes Neurais Artificiais

As aplicações que utilizam modelos de redes neurais artificiais (RNA) têm apresentado um desempenho significativo quando comparado com métodos estatísticos tradicionais como no trabalho de Rodrigues *et.al.* (2015). Alguns trabalhos de previsões de cheias utilizaram RNA para a emissão de alertas de inundação em intervalos curtos de tempo (Anuar, et al., 2017), (Liu, et al., 2017), (Ruslan, et al., 2014), (Truatmoraka, et al., 2016) e (Mitra, et al., 2016).

Anuar *et.al.* (2017), projetou um sistema de previsão do nível da cheia para o rio Kelantan com base no fluxo do rio Sokor, na Malásia, utilizando RNAs para prever o nível da água com 5 horas de antecedência. Esse estudo teve como objetivo comparar um método convencional de previsão com o Sistema Autorregressivo de rede neural com entrada Exógena (NNARX). Esse último é baseado no modelo autorregressivo linear com entrada exógena (ARX), que é um método comum utilizado em pesquisas de predição.

Os dados usados nesse estudo são de 2009 à 2013, com intervalos de 1 hora. Para o método convencional foi utilizado uma rede neural multi-camadas de propagação direta (do inglês, MLP – *MultiLayer Perceptron*), treinada com o algoritmo de *backpropagation*. Como mostrado na Figura 7, a rede NNARX possui 5 entradas e 1 saída, que corresponde ao nível de água do rio Kelantan.

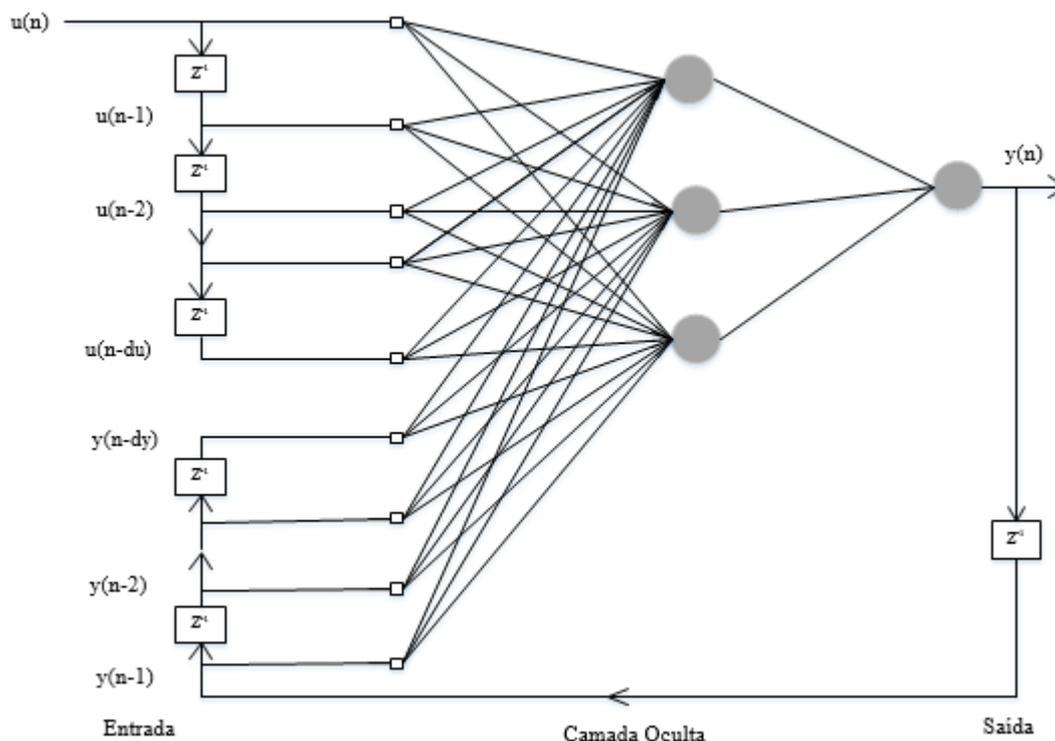


Figura 7: Modelo NNARX. Fonte: Adaptada de (Anuar, et al., 2017)

Para avaliar o desempenho do sistema desenvolvido foi calculado o erro médio quadrático (do inglês, *Mean Square Error*). Para o modelo convencional o MSE obtido foi de 0,2550. Já no modelo NNARX o MSE foi de $1,342 \times 10^{-4}$, o que mostra que o desempenho do modelo NNARX é superior para a previsão da cheia, com 5 horas de antecedência.

No estudo de Liu et.al. (2017) foi projetado um modelo de previsão de inundação baseado no algoritmo de aprendizagem profunda através da integração de autocodificadores empilhados – SAE (do inglês, *Stacked Autoencoders*) e treinados com o algoritmo de *backpropagation* (BP). A previsão é realizada com 6 horas de antecedência, abrangendo o período de cheia de 1998 à 2010. Inicialmente, considerando o desequilíbrio da distribuição de dados, primeiramente foram classificados todos os dados em várias categorias por meio do método de agrupamento *K-Means*. A Figura 8,

apresenta a arquitetura adotada para o algoritmo SAE-BP, mostrando que, após as camadas ocultas terem sido treinadas pelo SAE, a camada oculta da rede profunda é conectada diretamente a rede BP, a qual é responsável por realizar a previsão. Em Liu et.al. (2017) esse método foi comparado com outras abordagens já desenvolvidos na literatura, tendo sido observado que o desempenho do algoritmo baseado em SAE-BP teve um desempenho superior, conforme mostrado na Tabela 1.

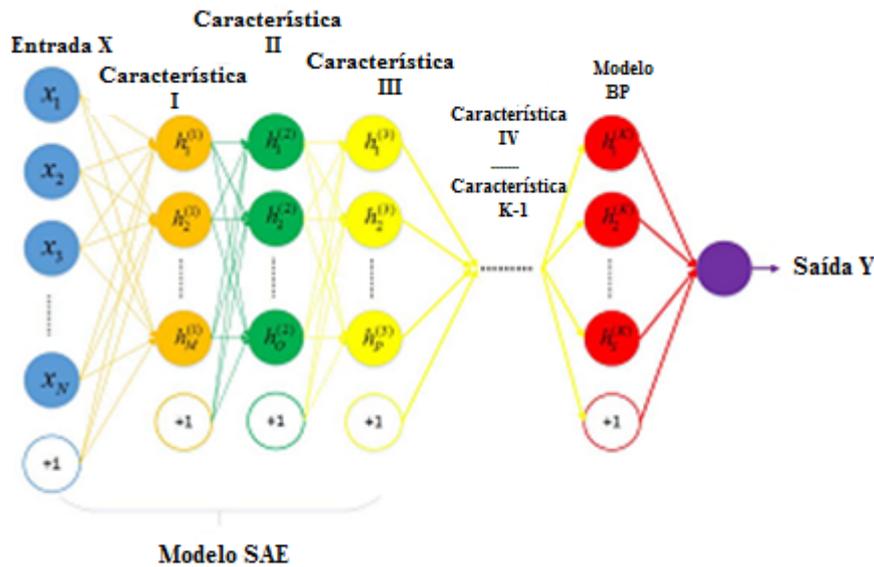


Figura 8: Arquitetura do modelo SAE-BP. Fonte: Adaptada de (Liu, et al., 2017)

A Tabela 1 apresenta o desempenho do algoritmo SAE-BP comparado com os seguintes métodos: rede neural BP, rede neural RBF, máquina de vetor de suporte – SVM (do inglês, *Support Vector Machine*) e máquina de aprendizagem extrema. Essa tabela mostra o erro médio quadrático – MSE (do inglês, *Mean Square Error*) e o coeficiente determinístico – DC (do inglês, *Deterministic Coefficient*) para a melhor configuração de cada método implementado. Os parâmetros MSE e o DC têm uma faixa dinâmica de [0, 1]. Quanto mais próximo de zero for o MSE mais precisa é a previsão e quanto mais próximo de 1 for o DC maior é a precisão da previsão. Observa-se que o modelo SAE-BP+Kmeans alcançou o melhor resultado na realização da previsão da cheia.

Tabela 1: Comparação dos resultados de diferentes abordagens. Fonte: (Liu, et al., 2017)

Model	MSE	DC
SVM	0,4930	0,816
Rede neural BP	0,6999	0,707
Rede neural RBF	0,7295	0,695
Máquina de Aprendizagem Extrema	0,6807	0,715
SAE-BP	0,3644	0,848
SAE-BP+Kmeans	0,2877	0,88

O modelo proposto por Truatmoraka *et.al.* (2016) foi baseado em RNA e tem como objetivo a previsão da cheia para o dia seguinte para a bacia do rio Chao Praya na Tailândia, utilizando três estações de medição. O modelo utilizou variáveis importantes para prever o pico da cheia do rio em um dado instante, como o nível do rio em instantes anteriores, capacidade de descarga de água, escoamento médio da chuva, altura da bacia na estação de medição e a capacidade máxima de descarga da água na estação de medição. Nessa pesquisa foram usadas informações diárias de 2012 a 2015. Devido ao fato de alguns arquivos possuírem dados incompletos ou ausentes, foi utilizada a técnica *data mining* para fazer a calibração dos dados. Esse método substitui os valores ausentes pelos valores médios. Os dados foram divididos em conjunto de treinamento e conjunto de teste, sendo 70% dos dados utilizados para treinamento e 30% utilizados para teste. A estrutura do modelo da RNA foi de 20-10-1, significando que a camada de entrada possui 20 nós, a segunda camada, denominada de camada oculta, possui 10 nós. A última camada é a de saída e possui apenas 1 nó. Para avaliar o desempenho do modelo desenvolvido, foi utilizado o Erro Absoluto Médio - MAE (do inglês, *Mean Absolute Error*) e a Raiz do Erro Absoluto Médio - RMSE (do inglês, *Root Mean Squared Error*) entre o nível real da água e o nível previsto. Para verificar se o modelo desenvolvido teve êxito na previsão da cheia, foram testadas mais duas arquiteturas de RNA, 9-5-1 e 9-7-1. Os resultados mostraram que o modelo 20-10-1 obteve o melhor desempenho, resultando nos menores valores de RMSE na fase de teste, em todas as estações de medição.

Mitra *et.al.* (2016), desenvolveram um sistema embarcado baseado em aprendizagem de máquinas para realizar previsões de inundações em uma bacia hidrográfica, para o período de 2006 à 2014. O modelo é baseado em uma rede de malha modificada, baseada na especificação *ZigBee*. Os dados coletados em tempo real são transferidos por meio de uma rede de sensores sem fio - WSN (do inglês, *Wireless Sensor Network*) e enviados pela internet por meio de um módulo de serviços gerais de rádio por

pacotes - GPRS (do inglês, *General Packet Radio Services*), essa tecnologia tem o objetivo de aumentar as taxas de transferência de dados, facilitando a comunicação e o acesso a redes. Os conjuntos de dados foram avaliados utilizando um modelo de rede neural simples. Para este estudo foram considerados como variáveis de predição: a chuva – RN, o nível de umidade – HM, o fluxo de água – WF, a pressão e o nível da água. Os resultados obtidos, utilizando a abordagem da Internet das Coisas – IoT (do inglês, *Internet of Things*), mostrou-se robusto quando comparado com outros métodos já utilizados na literatura. A Tabela 2 apresenta os resultados da correlação R obtida para um conjunto de modelos. Os modelos A, B e C, que utilizaram apenas uma variável como entrada, RN, HM e WF, respectivamente, apresentaram os piores resultados. Os modelos D, E e F, que utilizaram duas variáveis como entrada, apresentaram uma melhora significativa no desempenho. Mas, como mostrado na Tabela 2, o melhor resultado foi obtido quando foram utilizadas as três variáveis como entrada (RN, HM e WF).

Tabela 2: Validação do modelo proposto. Fonte: Adaptada de (Mitra, et al., 2016)

Modo	Descrição	Correlação (R)
A	Apenas precipitação como entrada (RN)	0,5745
B	Apenas umidade como entrada (HM)	0,2521
C	Apenas fluxo de água como entrada (WF)	0,8512
D	RN + HM	0,9713
E	HM + WF	0,8914
F	RN + WF	0,9891
G	RN + HM + WF	0,9912

O estudo de Rodrigues et.al. (2015), propôs uma metodologia para a previsão do nível da cheia do rio Amazonas, utilizando redes neurais de propagação direta, sendo a entrada da rede composta pelos índices climáticos ENSO (do inglês, *El Niño South Oscillation*), Índice de Oscilação Sul (do inglês, *South Oscillation Index - SOI*) e pelo nível do próprio rio, avaliado nos meses que antecedem o pico da cheia. O modelo foi avaliado com dados obtidos no período entre 1951-2014. O autor desenvolveu uma rede neural de propagação direta, utilizando a metodologia de treinamento e teste *Leave-one-out*: um determinado ano k é removido do conjunto de N anos, dessa forma o treinamento da rede neural é realizado com os dados de N-1 anos e treinada N vezes. As variáveis de entrada foram selecionadas segundo o coeficiente de Pearson (r). Na avaliação das mesmas, foram selecionadas apenas aquelas que apresentaram significância estatística ao nível de 0,1%. As variáveis selecionadas foram ranqueadas conforme o maior valor desse coeficiente. Para o cálculo do nível da cheia foram realizadas 100 simulações com 100

redes iniciadas aleatoriamente. Com isso, o nível da cheia foi determinado como o valor médio desses 100 resultados obtidos. Em seguida, foi mudada a metodologia de ordenamento das variáveis. Ao invés das mesmas serem ordenadas pelo coeficiente de Pearson(r), foi proposto pelo autor o método de seleção escalar de características modificado. Para o treinamento da rede foi usado o algoritmo de *backpropagation* associado ao método de otimização de *Levenberg-Marquardt*. A função de ativação usada na rede neural foi a tangente hiperbólica. Com o objetivo de melhorar a generalização das redes neurais, foi utilizado regularização L^2 e parada antecipada. Os resultados obtidos mostraram que o melhor desempenho alcançado foi utilizando regularização L^2 e selecionando as variáveis de entrada através do método de seleção escalar de características modificado, com a arquitetura de rede neural 6-6-1. Nos resultados obtidos, verificou-se que em 51,56% dos anos estudados, a previsão resultou em um erro menor que 0,5 m. Em 92,19% dos anos observados, a previsão resultou em um erro menor do que 1,0 m. O segundo melhor conjunto de resultados foi obtido a partir do método de parada antecipada. Portanto, o método proposto nesse trabalho mostrou-se eficaz, principalmente quando foi utilizado o método de regularização L^2 .

Ruslan *et.al.* (2014) propuseram um modelo utilizando a rede neural de Elman – ENN (do inglês, *Elman Neural Network*) para realizar a previsão do nível de inundação com 4 horas de antecedência. Esse tipo de rede neural foi desenvolvido para modelagens não-lineares, identificação dinâmica de sistemas, previsão de cargas, entre outros, sendo a aplicação na área hidrológica considerada nova entre os pesquisadores. A Figura 9, mostra os diagramas que representam os sistemas utilizados para a previsão, sendo o modelo ENN alimentado com 4 entradas, onde ST1, ST2 e ST3 correspondem ao nível de 3 rios a montante, que indica a direção de um ponto mais baixo para o mais alto do rio, enquanto que $\delta y / \delta k$ corresponde a diferença do nível de água no local da inundação devido à precipitação. A saída do sistema, \hat{y} , representa o nível de água previsto no local da inundação. No sistema da Figura 9(b) foi utilizado um filtro de correção para atuar como melhorador do modelo e obter o nível de água real no local da inundação. Ou seja, o nível de água previsto, \hat{y} obtido a partir do modelo ENN melhorado foi então comparado com o nível de água real no local de inundação.

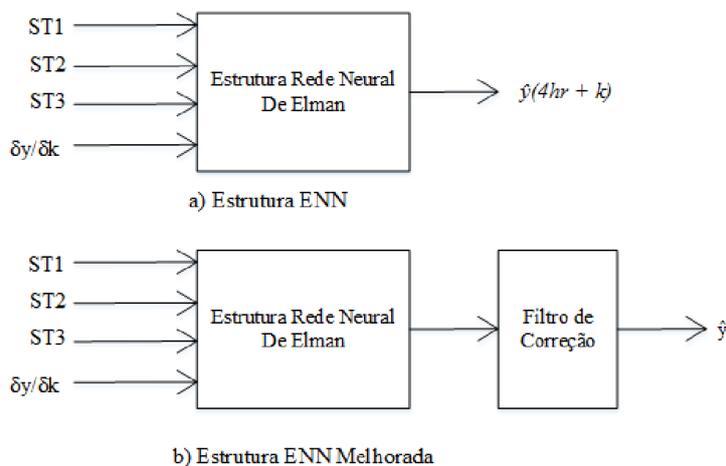


Figura 9: Diagrama de Previsão. Fonte: Adaptada de (Ruslan, et al., 2014)

Para o modelo ENN foi obtido um fraco resultado de predição, sendo baixo o valor de melhor ajuste (do inglês, *best fit*), 12,75%, e alto o valor de RMSE, de 0,5516 m. A ENN melhorada produziu um alto valor de melhor ajuste, de 97,15%, e um baixo valor de RMSE de 0,018 m.

3.3 Métodos de aprendizado baseado em comitê

Além das RNAs, tem sido estudado a utilização de métodos de aprendizado baseado em comitê para a previsão de cheias. Tratam-se de algoritmos que combinam várias técnicas de aprendizado de máquina em um modelo preditivo para diminuir a variação (*Bagging*), polarizar (*Boosting*) ou melhorar as previsões (*Stacking*) (Zhou, 2012).

Shu *et al.* (2004), aplicaram seis abordagens para a criação de conjuntos usando redes neurais artificiais com o objetivo de analisar a frequência de inundação baseada em regressão nas bacias hidrográficas da Inglaterra, Escócia e País de Gales. Os métodos mais usados para combinar RNAs com métodos de aprendizado baseado em comitê são combinação linear e generalização de pilha. A Tabela 3 apresenta as abordagens que foram adotadas: 1. Uma RNA simples; 2. Uma RNA com o método de média simples; 3. Uma RNA com o método de *stacking*; 4. Uma RNA combinando os métodos de *bagging* e média simples; 5. Uma RNA combinando os métodos de *bagging* e *stacking*; 6. Uma RNA combinando os métodos de *boosting* e mediana; e 7. Uma RNA combinando os métodos de *boosting* e *stacking*. A partir dessas combinações foram calculadas as métricas de desempenho: erro quadrado relativo - RSError (do inglês, *Relative Square*

Error), erro relativo percentual – PError (do inglês, *Percentual Relative Error*) e o viés relativo – RBias (do inglês, *Relative Bias*). Para uma melhor visualização dos resultados foram listados a média (**m**) e o desvio padrão (**σ**) de cada critério de desempenho. A melhor capacidade de generalização é indicada pelo valor mais alto do ranking. Observa-se que o desvio padrão para métodos de aprendizado baseado em comitê são geralmente muito menor do que para uma RNA simples.

Tabela 3: Índice de desempenho para estimativa de inundação. Fonte: Adaptada de (Shu, et al., 2004)

Método	RSError		PError		RBias		Ranking
	m	σ	m	σ	m	σ	
RNA_SIMPLES	0,4391	0,0103	29,44	0,2962	0,0729	0,0047	0,25
RNA_MEAN	0,4247	0,0043	28,96	0,1759	0,0722	0,0018	0,50
RNA_BASIC_STACK	0,3826	0,0072	27,83	0,2329	0,0855	0,0031	0,54
RNA_BAG_MEAN	0,4281	0,0070	28,80	0,2985	0,0703	0,0021	0,54
RNA_BAG_STACK	0,3819	0,0050	27,72	0,2278	0,0759	0,0021	0,67
RNA_BOOST_MEDIAN	0,4103	0,0066	28,74	0,2308	0,0600	0,0022	0,71
RNA_BOOST_STACK	0,3663	0,0039	27,48	0,1653	0,0728	0,0028	0,83
REG_OLS	0,4880	...	33,70	...	0,0892	...	0,00
REG_NONLINEAR	0,4378	...	32,71	...	0,0586	...	0,46

Pode-se notar a partir da linha 2 até a linha da 7 da tabela que os modelos propostos no estudo de Shu *et.al.* (2004) são mais precisos na estimativa de inundação e menos sensíveis à escolha de parâmetros iniciais do que no caso de uma única RNA. A maioria dos conjuntos de RNA, principalmente aqueles que utilizam o *stacking*, têm um melhor desempenho que os modelos de regressão. As melhorias obtidas com as RNAs são principalmente provenientes da redução da magnitude do erro de previsão, que geralmente é acompanhado por um aumento na polarização, RBias.

3.4 Resumo

Neste capítulo, foi apresentado o trabalho sobre previsão do nível da cheia para 5 horas à frente baseado em RNA, apresentado por Anuar *et.al.* (2017). Ele utilizou duas abordagens: uma RNA convencional que foi treinada com o algoritmo de aprendizagem *Backpropagation*; e uma rede neural autorregressiva com entrada exógena – NNARX (do inglês, *Neural Network Autoregressive with Exogenous Input*). Esse é um modelo não-linear derivado do modelo Autorregressivo com Entrada Exógena – ARX (do inglês, *Autoregressive with Exogenous Input*). O trabalho de Liu *et.al.* (2017) foi apresentado,

mostrando uma abordagem de aprendizagem profunda, integrando autocodificadores empilhados (do inglês, SAE) e redes neurais de backpropagation – BPNN (do inglês, *Backpropagation Neural Network*) para a previsão do fluxo de inundação. Em seguida, foi apresentado o trabalho de Truatmoraka *et.al.* (2016), que desenvolveu um modelo de previsão de cheias usando RNA para a Bacia do Chao Praya, situada na região central da Tailândia, utilizando 3 estações de Medição. O trabalho de Córdoba-Machado *et.al.* (2016) apresentou um sistema de previsão sazonal antecipada do fluxo do rio Magdalena, com antecipação de uma a quatro temporadas, utilizando regressão linear. Mitra *et.al.* (2016) desenvolveu um modelo de previsão de inundações usando a Internet das coisas e redes neurais artificiais (RNA). Rodrigues *et.al.* (2015) propôs um método para previsão de cheias sazonais utilizando redes neurais artificiais, em uma aplicação ao rio Negro. Em seguida, Ruslan *et.al.* (2014) apresentou um modelo de previsão de inundação com 4 horas de antecedência usando rede neural de Elman – ENN (do inglês, *Elman Neural Network*). Por fim, Schongart *et.al.* (2007) desenvolveu um modelo de previsão do pulso de inundação na Amazônia Central pelos índices ENSO (do inglês, *El Niño South Oscillation*). Finalizando este capítulo, foi apresentado o trabalho de Shu *et.al.* (2004), que propôs a criação de conjuntos usando redes neurais artificiais com o objetivo de analisar a frequência de inundação.

Nas Tabelas 4 e 5 são mostrados de forma resumida os estudos apresentados. Comparando com as outras ferramentas relacionadas neste capítulo, o trabalho proposto é o primeiro a utilizar o método *bootstrap* para realizar a criação dos conjuntos de treinamento para que seja feita a previsão de cheias sazonais, além de desenvolver uma metodologia para classificar as cheias em faixas de valores a partir da média e desvio padrão. Outra contribuição do trabalho proposto é a utilização do método de aprendizagem baseado em comitê para realizar a previsão de cheias e então comparar com as RNAs.

Tabela 4: Comparação dos artigos usando Redes Neurais e Métodos Convencionais.

REFERÊNCIA	APLICAÇÃO	VARIÁVEIS DE ENTRADA	MÉTODOS	RESULTADOS
(Córdoba-Machado, et al., 2016)	Previsão sazonal do rio Magdalena, usando regressão linear para o período de 1936 à 2009.	<ul style="list-style-type: none"> Índice SST, precipitação global, média das temperaturas e índices de teleconexão. 	Regressão Linear	r = 0,74
(Schongart, et al., 2007)	Modelo de previsão de cheia com 4 meses de antecedência do nível máximo, usando regressão linear para o período de 1903 à 2004.	<ul style="list-style-type: none"> Índice de Oscilação Sul (SOI) nível da água em fevereiro 	Regressão Linear	Coefficiente de Correlação r = 0.71, p<0.0001.
(Anuar, et al., 2017)	Modelo de previsão do nível do rio para 5 horas à frente baseado em RNA, para o Rio Kelantan, com informações do ano de 2009 a 2013.	<ul style="list-style-type: none"> O sistema tem como entrada: 3 descargas de água de três rios diferentes e outras 2 são o valor da chuva. Os dados são relativos ao período de 01/01/09 à 01:00 h até 31/12/13 às 24:00 h, com intervalo de 1 hora. 	<ul style="list-style-type: none"> RNA NNARX é um modelo não-linear derivado do modelo Autorregressivo com Entrada Exógena (ARX). 	Modelo RNA: MSE=0,2550; Modelo NNARX: MSE=1,342x10 ⁻⁴ .
(Liu, et al., 2017)	Modelo de previsão de inundação baseado no algoritmo de aprendizagem profunda através da integração de autoencodificadores empilhados com a rede neural BP, para 6 horas de antecedência.	<ul style="list-style-type: none"> Chuva das primeiras 4-7 horas de seis estações a montante e a estação atual. Os escoamentos de 4-7 horas anteriores da estação atual e Os escoamentos de todas as estações nas últimas 4 horas. 	Autocodificadores empilhados (SAE) e redes neurais de propagação reversa (BPNN) para a previsão do fluxo de inundação.	SAE-BP: MSE = 3644 DC = 0,848

REFERÊNCIA	APLICAÇÃO	VARIÁVEIS DE ENTRADA	MÉTODOS	RESULTADOS
(Truatmoraka, et al., 2016)	Modelo de previsão de nível da cheia para o dia seguinte usando RNA, para a Bacia do Chao Praya na região central da Tailândia, utilizando 3 estações de Medição (C13, C3 e C7A).	<ul style="list-style-type: none"> Entrada da estação: média do escoamento da precipitação; altura da bacia na estação de medição de observação; capacidade máxima de descarga de água. 	RNA com Algoritmo de backpropagation (BPNN)	<p>C13: RMSE = 0,3369 e MAE = 0,08;</p> <p>C3: RMSE = 0,0257 e MAE = 0,017;</p> <p>C7A:RMSE = 0,0839 e MAE = 0,0619;</p>
(Ruslan, et al., 2014)	Modelo de previsão de inundação com 4 horas de antecedência usando a estrutura ENN Melhorada para a Estação Kelang River, localizada na Ponte Petaling, em Kuala Lumpur.	<ul style="list-style-type: none"> Conj. de-Treinamento: período de 2/6/2010 a 7/2/2010 em intervalos de 10 min.; Conj. de Validação: os dados de 5/2/2010 a 6/2/2010; Conj.de Teste: Os dados de teste variam de 19/11/2010 a 21/11/2010 	Rede neural de Elman	<p>ENN:</p> <p>Best fit = 12,75%;</p> <p>RMSE = 0,5516.</p> <p>ENN Aprimorado:</p> <p>Best fit = 97,15%;</p> <p>RMSE = 0,018.</p>
(Mitra, et al., 2016)	Modelo de previsão de inundações usando a Internet das coisas e redes neurais artificiais (RNA). Período de 2006-2014	<ul style="list-style-type: none"> Fluxo de água, Nível de umidade, Quantidade de precipitação, Pressão (a montante ou a jusante com base em sua localização relativa) e Nível da água da bacia de Ganges. 	O modelo usa uma conexão de rede de malha modificada sobre ZigBee para o WSN coletar dados e um módulo GPRS para enviar os dados pela Internet	r = 0,9912, quando foram utilizados como entrada do algoritmo a chuva + umidade + fluxo de água.

REFERÊNCIA	APLICAÇÃO	VARIÁVEIS DE ENTRADA	MÉTODOS	RESULTADOS
(Rodrigues, et al., 2015)	Proposta de um Método para Previsão de Cheias Sazonais Utilizando Redes Neurais Artificiais: Uma Aplicação ao Rio Amazonas	<ul style="list-style-type: none"> SST El Niño 1+2, 3, 3+4, 4 e SOI. Dados de 1953 -2014. 	Foram usados 2 algoritmos para a previsão, denominados de: Algoritmo 1 (RNA convencional) e Algoritmo 2 (método da seleção escalar de características).	Índice de correlação de previsão em RNA: rp = 0,755; correlação simples: rp = 0,745

Tabela 5: Aplicação utilizando métodos de aprendizado baseado em comitê.

REFERÊNCIA	APLICAÇÃO	VARIÁVEIS DE ENTRADA	MÉTODOS	RESULTADOS
(Shu, et al., 2004)	Conjuntos de redes neurais artificiais e sua aplicação na análise de frequência de inundação para três bacias hidrográficas.	<ul style="list-style-type: none"> Área de drenagem de captação (AREA). Média anual de precipitação (SAAR). Tipo de drenagem do solo (SPRHOST e BFIHOST). Efeito reservatório ou lago (FARL). 	<ol style="list-style-type: none"> NN_BASIC_MEAN; NN_BASIC_STACK; NN_BAG_MEAN; NN_BAG_STACK; NN_BOOST_MEDIAN; NN_BOOST_MANDIAN; NN_SINGLE; 	Rank Score: 0,83 RSError: Média: 0,3663 Desv. Padrão: 0,0039 PError: Média: 27,48 Desv. Padrão: 0,1653 Rbias: Média: -0,0728 Desv. Padrão: 0,0028

4 MATERIAIS E MÉTODOS

Neste capítulo é apresentada a metodologia proposta para a previsão das cheias sazonais do rio Negro utilizando redes neurais artificiais e métodos de aprendizado baseado em comitê. Para a realização dos experimentos utilizou-se um microcomputador com processador Intel Core i5-3337U, com 1.8 GHz e 8 GB de RAM, operando sob o sistema operacional Microsoft Windows 7, com processador de 64 bits. O software utilizado foi o Matlab®.

O diagrama em bloco da Figura 10 apresenta as etapas da metodologia proposta para realizar o treinamento dos preditores utilizados na previsão de cheias sazonais do rio Negro, redes neurais artificiais e aprendizado baseado em comitê.

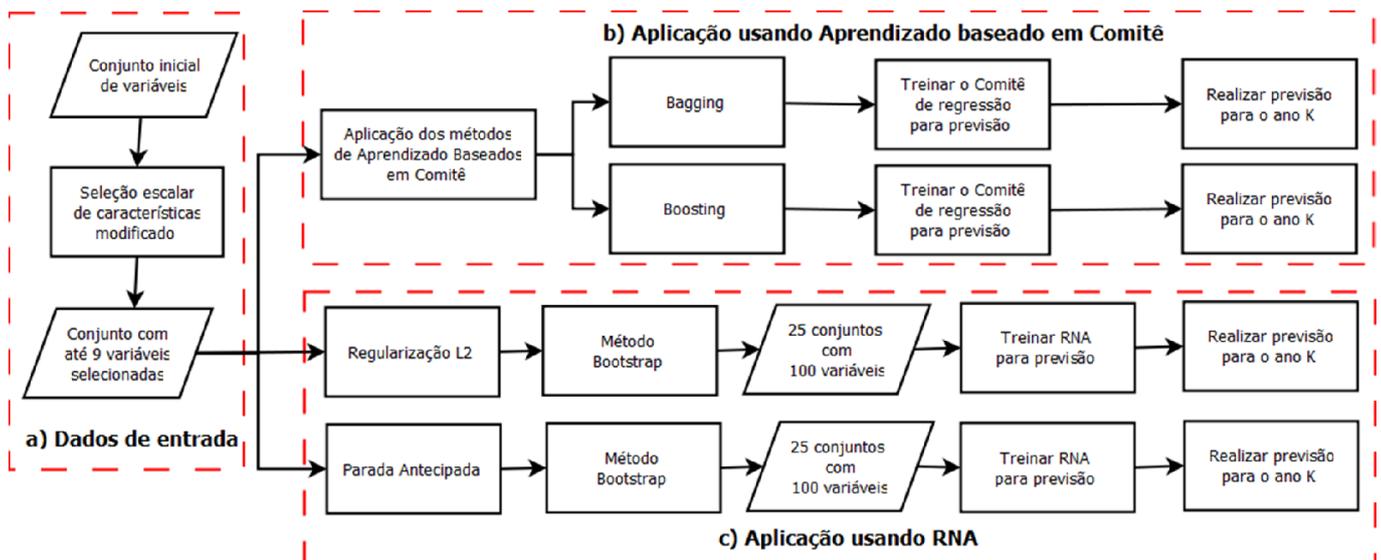


Figura 10: Diagrama de implementação dos métodos para previsão de cheias sazonais.

No bloco (a) da Figura 10, mostra-se a composição do conjunto de dados de entrada, cujo conjunto inicial de variáveis é constituído pelos índices climáticos (ENSO e SOI) e pelos níveis do Rio Negro no período de 1951 – 2017. A partir do conjunto inicial são extraídas e selecionadas as nove melhores variáveis segundo o método de seleção escalar de características modificado (Rodrigues, et al., 2015).

No bloco (b) apresenta-se a metodologia de treinamento para o aprendizado baseado em Comitê, que utiliza técnicas de *bagging* e de *boosting*. O classificador usado para regressão na Máquina de Comitê foi árvore de decisão.

No bloco (c) é apresentada a metodologia de treinamento usando RNA. No treinamento da RNA, o método *bootstrap* foi implementado com 25 conjuntos distintos. Foram implementadas três arquiteturas de RNA, com diferentes números de neurônios na camada oculta.

O uso dessas duas abordagens tem como objetivo verificar o desempenho de ambas as implementações e assim obter um preditor de cheias sazonais mais eficiente.

4.1 Conjunto de dados

Como proposto, neste trabalho, a previsão da cheia será operacionalizada com antecedência de 1 a 4 meses em relação mês em que ocorre o pico máximo da cheia. Portanto, a previsão será realizada com dados dos meses de fevereiro, março, abril e maio, respectivamente. Foram utilizados dois conjuntos de dados, um conjunto de índices climáticos e um conjunto de níveis do rio Negro, obtidos no período de 1951 à 2017, resultando em 67 anos de dados. O segundo conjunto de dados, referentes aos níveis do rio Negro, foram coletados no site da Agência Nacional de Águas – ANA (ANA, 2019) e na página oficial do porto de Manaus (Porto de Manaus, 2018)

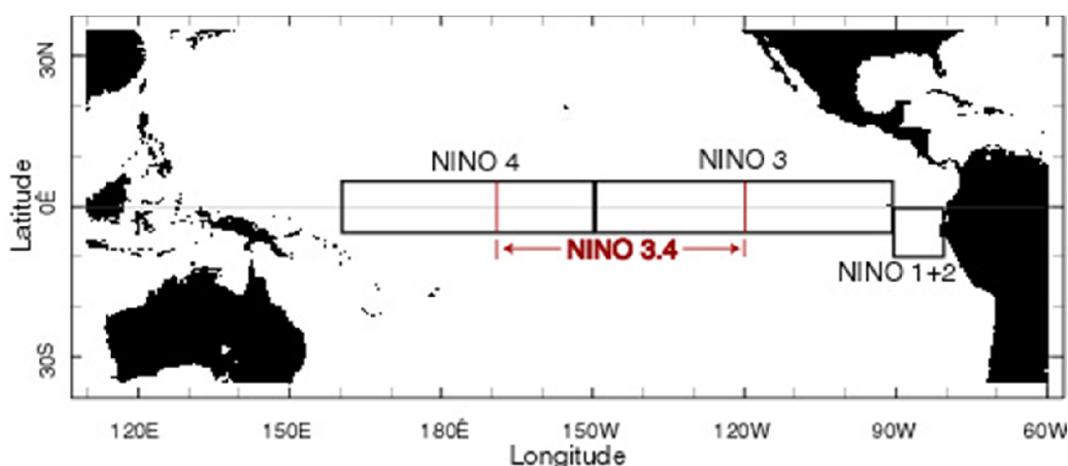
O primeiro conjunto é constituído pelos índices climáticos ENSO (do inglês, *El Niño South Oscillation*) e SOI (do inglês, *South Oscillation Index*). Os índices ENSO são alterações significativas de curta duração, variando de 15 a 18 meses, na distribuição da temperatura da superfície do mar (do inglês, *Sea Surface Temperature – SST*) do Oceano Pacífico devido ao fenômeno *El Niño*. São classificados em: SST, SST *El Niño*₃, SST *El Niño*₃₊₄ e SST. O índice de Oscilação Sul (do inglês, *South Oscillation Index - SOI*) é calculado como a diferença padronizada entre a pressão ao nível do mar média entre o Tahiti (17°S, 149°W) e Darwin, Austrália (13°S, 131°E). Os dados dos índices climáticos foram obtidos na página oficial do *Climate Prediction Center* (Climate Prediction Center, 2018).

No estudo de Rodrigues *et.al.* (2015), esses índices foram escolhidos após analisar trabalhos anteriores e verificar uma forte correlação negativa da descarga do rio com índices SST do pacífico e uma correlação positiva com o índice SOI. Utilizamos o mesmo conjunto de dados para fins de comparação. Na Tabela 6 são apresentados os índices ENSO, a latitude e a longitude do local de coleta e o período em que foi realizada a coleta.

Tabela 6: Índices Climáticos. Fonte: (*Climate Prediction Center, 2018*)

Índice ENSO	Latitude	Longitude	Período
SST <i>El Niño</i> ₁₊₂	0 a 10°S	90 a 80°W	1951-2017
SST <i>El Niño</i> ₃	5°N a 5°S	150 a 90°W	1951-2017
SST <i>El Niño</i> ₃₊₄	5°N a 5°S	170 a 120°W	1951-2017
SST <i>El Niño</i> ₄	5°N a 5°S	160°E a 150°W	1951-2017
SOI	Diferença padronizada entre a pressão ao nível do mar média entre o Tahiti (17°S, 149°W) e Darwin, Austrália (13°S, 131°E).		

A Figura 11 ilustra a localização geográfica das regiões do El Niño no Oceano Pacífico.

**Figura 11:** Localização El Niño. Fonte: (*Climate Prediction Center, 2018*)

4.2 Metodologia de Previsão

Os preditores utilizados neste trabalho são de dois tipos: redes neurais completamente conectadas e métodos de aprendizado baseados em comitê. Os preditores serão utilizados em associação com os conjuntos de dados criados.

O algoritmo para treinamento da rede neural utiliza a metodologia *leave-one-out*. Nessa metodologia, um determinado ano k é removido do conjunto de N anos e o treinamento da rede neural é efetuado com os dados de $N-1$ anos. Depois de treinada, a rede neural é utilizada para realizar a previsão do ano que foi removido (Sonka, et al., 2000). Variando-se o valor de k faz-se a previsão da cheia para todos os anos do conjunto de dados. A metodologia *leave-one-out* é utilizada quando se dispõe de poucas amostras

no conjunto de dados, como é o caso deste trabalho. Na Figura 12 ilustramos a metodologia *leave-one-out*.

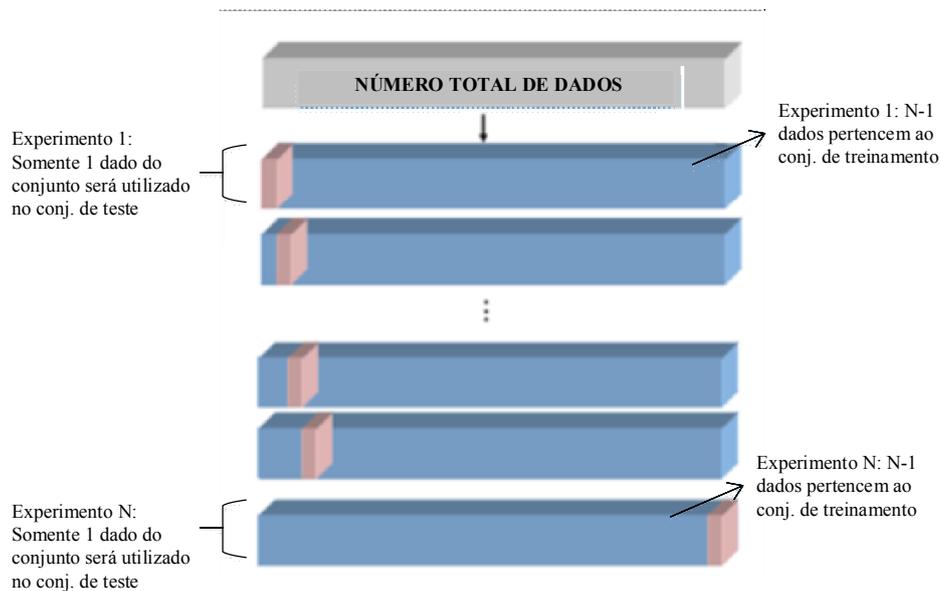


Figura 12: Ilustração da Metodologia *Leave-One-Out*. Fonte: Adaptado de (Sonka, et al., 2000)

Para a seleção dos conjuntos de dados, foi utilizado o método de seleção escalar de características modificado, citado no Capítulo 2. Esse método foi proposto por Rodrigues *et.al.* (2015) e tem como objetivo selecionar as nove melhores características ou variáveis que não tenham informações redundantes. A escolha desse método deveu-se ao fato de ter sido o método de seleção de características que apresentou os melhores resultados no trabalho de Rodrigues *et.al.* (2015). A Tabela 7 mostra o resultado do ordenamento das variáveis após a aplicação do método de Seleção Escalar de Características Modificado, para os meses de fevereiro, março, abril e maio, que são os quatro meses que antecedem o pico da cheia na região Amazônica.

Tabela 7: Ordenamento das variáveis usando o método de seleção escalar de características modificado. Fonte: (Rodrigues et al., 2015)

Ordem	Fevereiro (4 meses de antecedência)	Março (3 meses de antecedência)	Abril (2 meses de antecedência)	Maio (1 mês de antecedência)
	Variável 1	Variável 2	Variável 3	Variável 4
1 ^a	Nível do rio em fevereiro	Nível do rio em março	Nível do rio em abril	Nível do rio em maio
2 ^a	SOI em janeiro	Nível do rio em janeiro	Nível do rio em fevereiro	Nível do rio em março
3 ^a	SOI em setembro	SOI em novembro	SOI em janeiro	Nível do rio em janeiro
4 ^a	Nível do rio em janeiro	Nível do rio em fevereiro	Nível do rio em março	Nível do rio em abril

Ordem	Fevereiro (4 meses de antecedência)	Março (3 meses de antecedência)	Abril (2 meses de antecedência)	Maio (1 mês de antecedência)
	Variável 1	Variável 2	Variável 3	Variável 4
5 ^a	SOI em novembro	SOI em janeiro	Nível do rio em janeiro	Nível do rio em fevereiro
6 ^a	SOI em dezembro	SOI em dezembro	El Niño 3+4 fev	El Niño 3+4 jan
7 ^a	El Niño 3+4 Jan	SOI em setembro	SOI em novembro	SOI em janeiro
8 ^a	El Niño 3+4 Fev	El Niño 3+4 jan	SOI em setembro	SOI em novembro
9 ^a	El Niño 3+4 Dez	El Niño 3+4 fev	El Niño 3+4 jan	SOI em setembro

4.3 Configuração e Treinamento das Redes Neurais

Foram utilizadas três arquiteturas de redes neurais artificiais (RNA), que foram testadas usando 1 à 9 variáveis de entradas e 1 variável de saída, sendo que cada arquitetura possui um número específico de camadas ocultas, com 6, 8 e 10 camadas. A saída da rede corresponde ao resultado da previsão para cada arquitetura de RNA utilizada. As Figuras 13, 14 e 15 ilustram as arquiteturas das três redes neurais desenvolvidas. Utilizou-se o método de otimização *Levenberg-Marquardt* por meio da função *'trainlm'* do Matlab[®]. Na primeira e segunda camadas da rede, foi utilizada a função de ativação *'tansig'*. Essa função é similar a função sigmóide, mas com variação de -1 a 1, em vez de 0 a 1 como na sigmóide. Isso faz com que a *'tansig'* se aproxime mais da identidade e seja uma opção melhor para servir de ativação às camadas ocultas das RNAs (Matsunaga, 2012).

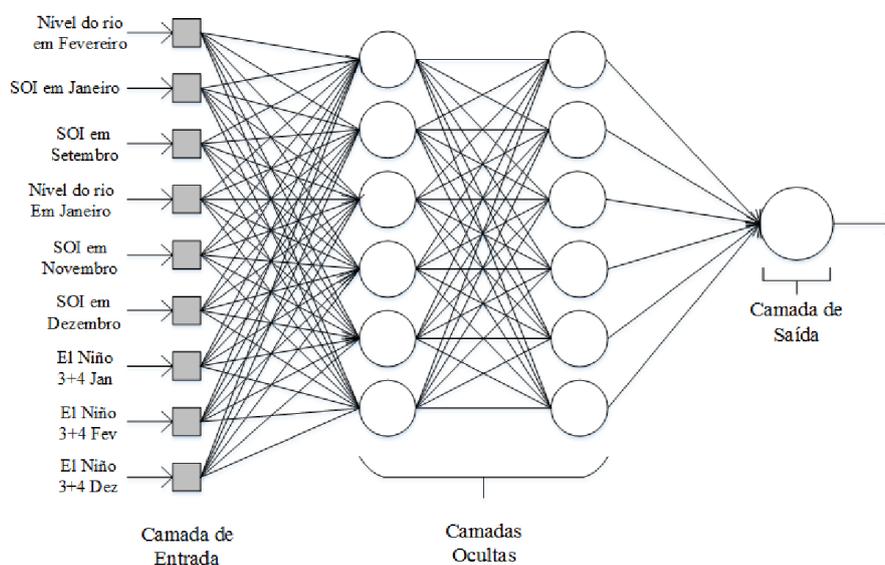


Figura 13: RNA com arquitetura 9-6-6-1.

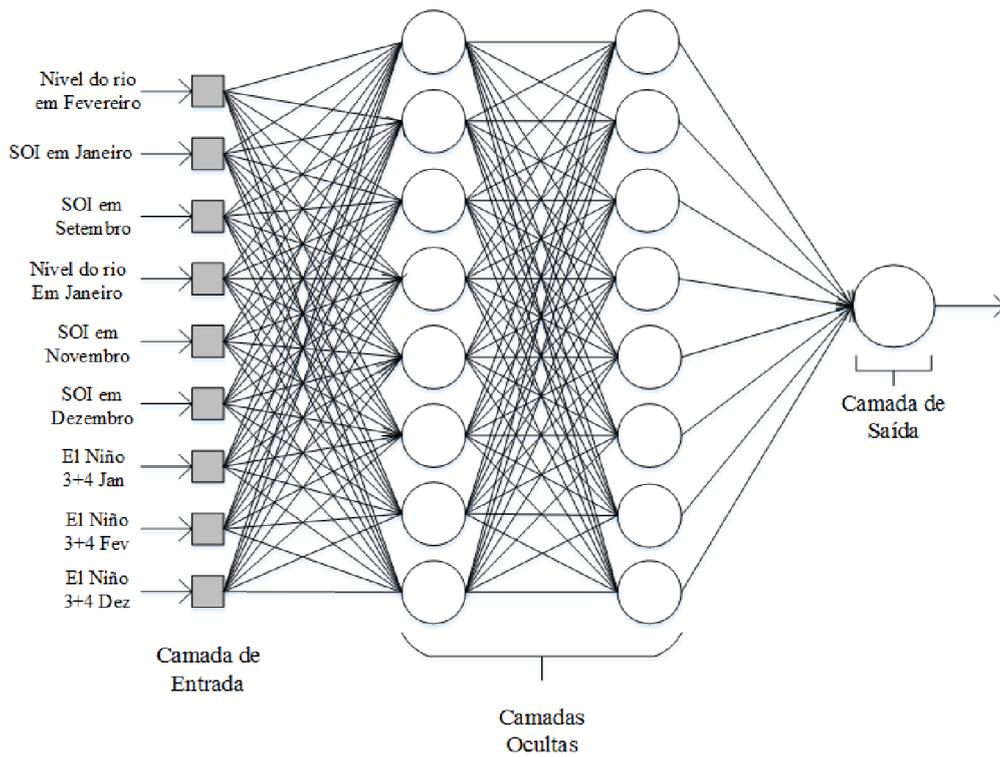


Figura 14: RNA com arquitetura 9-8-8-1.

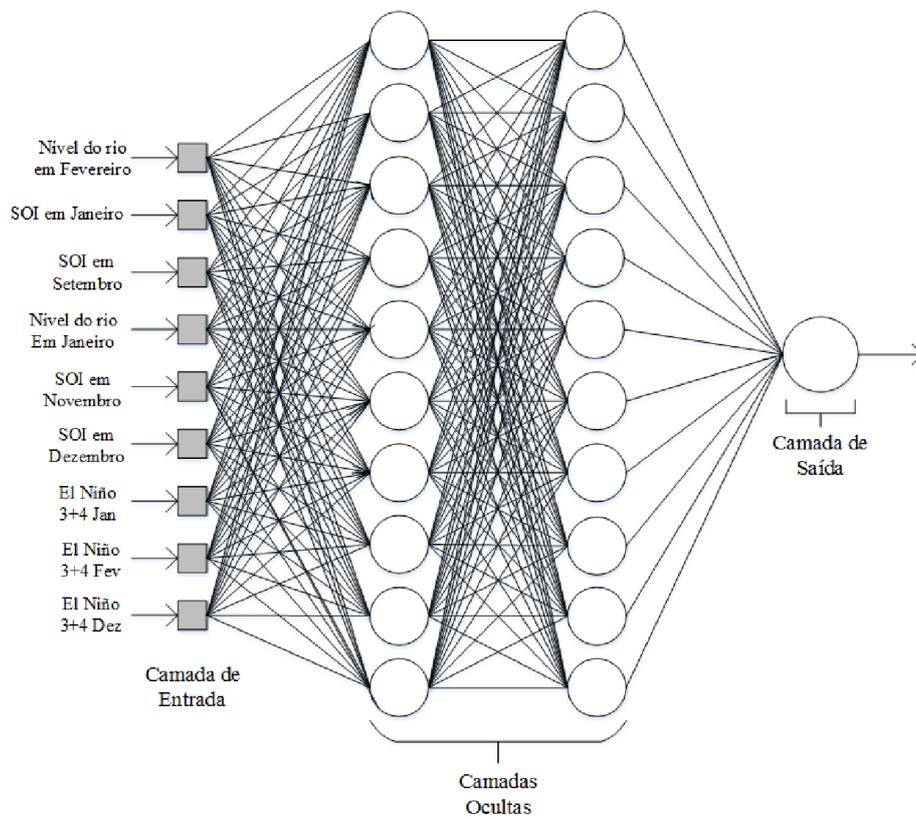


Figura 15: RNA com arquitetura 9-10-10-1.

Cada arquitetura foi treinada utilizando três métodos de generalização: regularização L^2 , parada antecipada (*Early Stop*) e *Bootstrap*.

4.4 Método de generalização *Bootstrap*

O método de generalização *bootstrap* foi implementado através de 25 treinamentos distintos, utilizando, de cada vez, um conjunto de dados diferente. Para cada treinamento com um conjunto de dados diferente, foi realizada uma nova inicialização dos parâmetros da rede (pesos e polarizações). Depois de treinada, a rede é então utilizada para prever o valor da cheia do ano k (ano excluído do conjunto de treinamento). A previsão final para o ano k é obtida calculando-se o valor médio das 25 previsões. No treinamento das redes associou-se o método *bootstrap* ao método de regularização L^2 e ao método de parada antecipada.

Os 25 conjuntos distintos de treinamento contêm, cada um, dados relativos a 100 anos. Como dispomos de apenas 67 anos (1951-2017), sendo um deles retirado para se fazer a previsão (ano k), restam apenas 66 anos para o treinamento. Para se compor um conjunto de treinamento com dados relativos a 100 anos, os dados de alguns anos são repetidos de forma aleatória. A Figura 16, ilustra o procedimento utilizado na geração dos dados de um conjunto de 100 anos. No Matlab[®], foram utilizadas funções que realizam esse procedimento de forma automatizada.

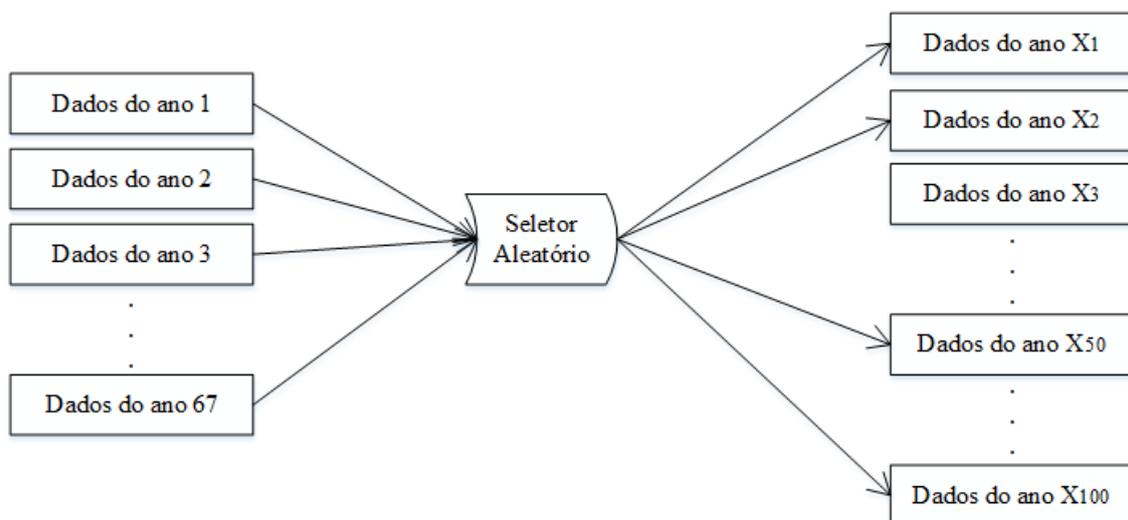


Figura 16: Método *bootstrap*: Procedimento para geração de um conjunto de treinamento com 100 anos. A escolha dos anos que constituem o lado direito da figura é feita de forma aleatória.

Após a criação dos 25 conjuntos de dados, as diferentes arquiteturas das redes neurais são treinadas, de forma distinta, obtendo como resultado 25 valores previstos e um valor médio calculado, conforme ilustrado na Figura 17.

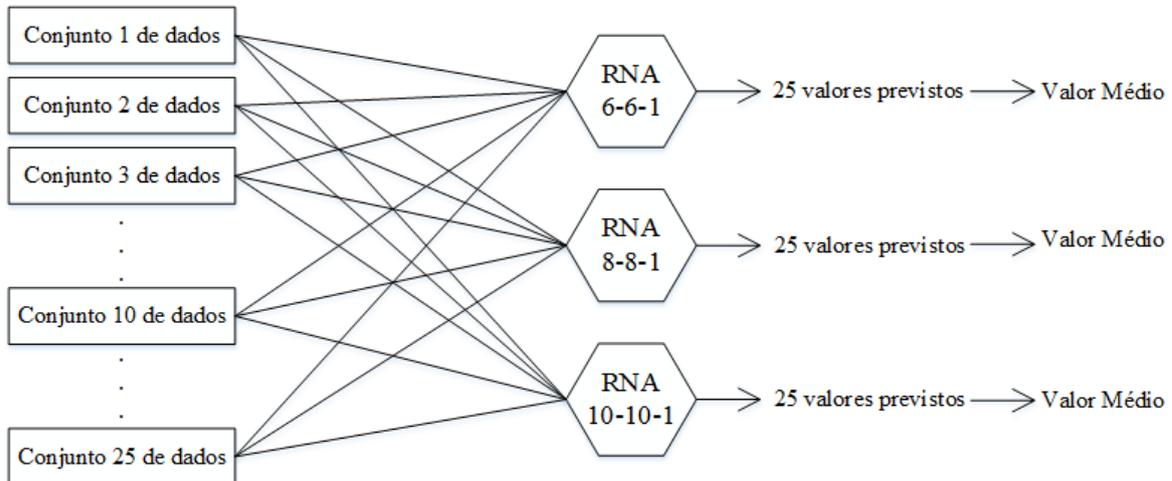


Figura 17: Associação das RNAs criadas com os 25 conjuntos gerados.

4.5 Configuração dos Métodos de Aprendizado Baseado em Comitê

No Matlab[®], um comitê para classificação pode ser criado por meio da função *fitensemble* ($X, Y, Name, Value$) ou por regressão usando *fitrensemble* ($X, Y, Name, Value$). Ambas as funções recebem os mesmos parâmetros. Nesse estudo está sendo utilizado o comitê de regressão para realizar a predição da cheia do rio Negro. Os parâmetros da função *fitrensemble* foram configurados da seguinte maneira (MathWorks, 2018):

- X – é a matriz de dados do preditor;
- Y – é o vetor de respostas e deve ter o mesmo número de linhas de X ;
- $Name$ – É o nome do argumento e $Value$ – é o valor correspondente.

Para o algoritmo desenvolvido foram utilizados os seguintes argumentos:

- '*Method*', '*Bag*' e '*Method*', '*LSBoost*' – que são os algoritmos apropriados para criar comitês de regressão;
- '*NumLearningCycles*', 100 – é o número de ciclos de aprendizado de conjunto. Em cada ciclo de aprendizado, o software treina um aprendiz fraco para cada objeto de modelo em *Learners*;

- *Learners, templateTree ()* – é o tipo de classificador que será usado no comitê.

Neste trabalho, o classificador a ser utilizado é o de árvore de decisão para comitês de regressão, o qual retorna um classificador de árvore de decisão padrão, adequado para conjuntos de treinamento ou modelos multiclasse. Esse classificador é o mais comumente usados em aprendizado baseado em comitê. Nesse estudo, estão sendo utilizados os algoritmos de *bagging* (Bag) e *boosting* (LSBoost) para criar o comitê de regressão, com cem ciclos de aprendizado cada um.

4.6 Avaliação do desempenho dos preditores

O desempenho dos preditores será avaliado através de três métricas:

- Coeficiente de correlação de Pearson
- Índices de erro
- Tabela de Confusão das faixas de enquadramento das cheias

4.6.1 Coeficiente de Correlação de Pearson

O coeficiente de correlação de Pearson será calculado de posse dos valores de cheia preditos para cada ano, através da Equação 14.

$$r = \frac{Cov(X,Y)}{S_X S_Y}, r \in [-1,1] \quad \text{Eq. 15}$$

em que:

X – Valores das cheias reais;

Y – Valores das cheias previstos;

Cov(X, Y) – Covariância amostral das variáveis X e Y;

S_X – Desvio padrão amostral da variável X;

S_Y – Desvio padrão amostral da variável Y.

Na sequência descreveremos os conceitos relativos aos Índices de Erro e de faixa de enquadramento.

4.6.2. Índices de Erro

A terceira maneira utilizada para avaliar o desempenho dos preditores foi através da utilização dos índices de erro propostos por Schongart *et al.* (2007). Os índices de erro, nomeados como Ind_1, Ind_2, Ind_3 e Ind_4, são descritos a seguir:

- **Ind_1:** número de previsões em que o valor absoluto da diferença entre o valor previsto e o real é inferior 0,5m;
- **Ind_2:** número de previsões em que o valor absoluto da diferença entre o valor previsto e o real situa-se entre 0,5m e 1m;
- **Ind_3:** número de previsões em que o valor absoluto da diferença entre o valor previsto e o real é superior a 1m e inferior a 1,5m;
- **Ind_4:** número de previsões em que o valor absoluto da diferença entre o valor previsto e o real é superior a 1,5m;

4.6.3 Acurácia da categorização da previsão de cheias em faixas

Neste trabalho, além da comparação entre métodos de previsão do valor de pico da cheia sazonal, é proposto a classificação das cheias de acordo os critérios apresentados na Tabela 8, em quatro categorias, a saber: Cheia baixa – Faixa 1, Cheia Média Baixa - Faixa 2, Cheia média alta - Faixa 3 e Cheia Alta - Faixa 4. A discriminação dos valores de cota do rio para cada uma dessas faixas, baseou-se na consideração de que a distribuição dos picos de cheias do período de 1903 a 2017 assemelha-se a uma curva normal, cujo valor médio é M e o desvio padrão σ . Uma cheia é considerada média se o seu valor de pico estiver entre $M \pm \sigma$. Assim, 68,26% das cheias são consideradas como cheias médias, conforme a Figura 18. Dentro da classe de cheia média foi criada duas subclasses: média baixa ($M - \sigma$) e média alta ($M + \sigma$). Por fim, se o pico da cheia for $< (M - \sigma)$ é considerada como baixa (15,87% das cheias) e se for $> (M + \sigma)$ é considerada alta (15,87% das cheias).

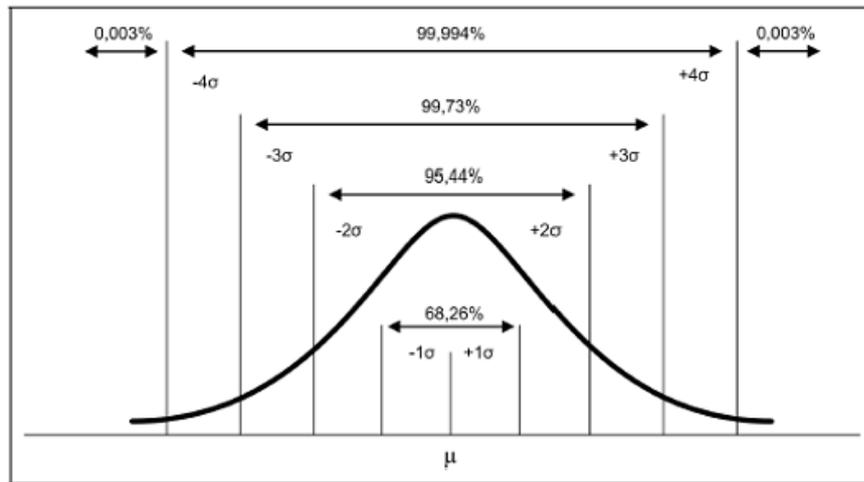


Figura 18: Distribuição dos dados numa distribuição normal. Fonte: (Portal Action, 2018)

Dessa forma, os valores de pico das faixas, apresentados na Tabela 8, são dinâmicos e mudam à medida em que novos registros de cheia estejam disponíveis, posto que mudarão os valores de M e σ . Para os registros de 1903 à 2017, o valor médio é $m = 27,87m$ e o desvio padrão é $\sigma = 1,15$.

Tabela 8: Faixas e classe de cheias em função da média e desvio padrão dos picos de cheias no período de 1903 a 2017 ($m = 27,87m$ e $\sigma = 1,15$)

Faixa	Categoria	Critério de classificação	Valor
1	Baixa	$PC_p < (m - \sigma)$	$PC_p < 26,72m$
2	Média Baixa	$(m - \sigma) < PC_p < m$	$26,72m < PC_p < 27,87m$
3	Média Alta	$m < PC_p < (m + \sigma)$	$27,87m < PC_p < 29,02m$
4	Alta	$PC_p > (m + \sigma)$	$PC_p > 29,02m$

PC_p : Pico da cheia previsto

Baseado nas faixas de classificação mostradas na Tabela 8 será obtida a matriz de confusão para cada preditor, conforme modelo mostrado a seguir.

Valores reais	FAIXAS	Pico da Cheia Previsto (PC_p)			
		1	2	3	4
1		X_{11}	X_{12}	X_{13}	X_{14}
2		X_{21}	X_{22}	X_{23}	X_{24}
3		X_{31}	X_{32}	X_{33}	X_{34}
4		X_{41}	X_{42}	X_{43}	X_{44}

Com base na matriz de confusão acima a acurácia pode ser definida como:

$$Acurácia = \frac{\sum_{i=1}^4 X_{ii}}{(\sum_{i=1}^4 \sum_{j=1}^4 X_{ij})} \quad \text{Eq. 16}$$

X_{ii} – Valores de picos de cheias classificados nas faixas corretas

X_{ij} – Valores de picos de cheias classificados incorretamente em outras faixas.

5 RESULTADOS

Nesta seção são apresentados os resultados para a RNA *Perceptron* de Múltiplas Camadas (MLP) desenvolvida e para a aplicação utilizando métodos de Aprendizado baseado em Comitê. Os algoritmos foram implementados utilizando o software Matlab[®]. As diferenças entre os resultados obtidos com as diversas arquiteturas e métodos de generalização foram avaliadas através do teste de significância Qui-quadrado (χ^2). Apresenta-se também uma comparação entre os resultados obtidos no trabalho proposto e aqueles obtidos no estudo de Rodrigues *et.al.* (2015). Os resultados das simulações realizadas são mostrados a seguir.

5.1 Redes Neurais Artificiais

Foram avaliadas as seguintes arquiteturas: N-6-6-1, N-8-8-1 e N-10-10-1, em que N varia de 1 a 9 variáveis de entrada. Em todas as arquiteturas foram utilizados métodos para melhorar a generalização da rede, como regularização L^2 e parada antecipada. O comando *feedforwardnet* (*hiddenSizes*, *trainFcn*) cria as RNAs no software Matlab[®] conforme mostrado na Figura 19.

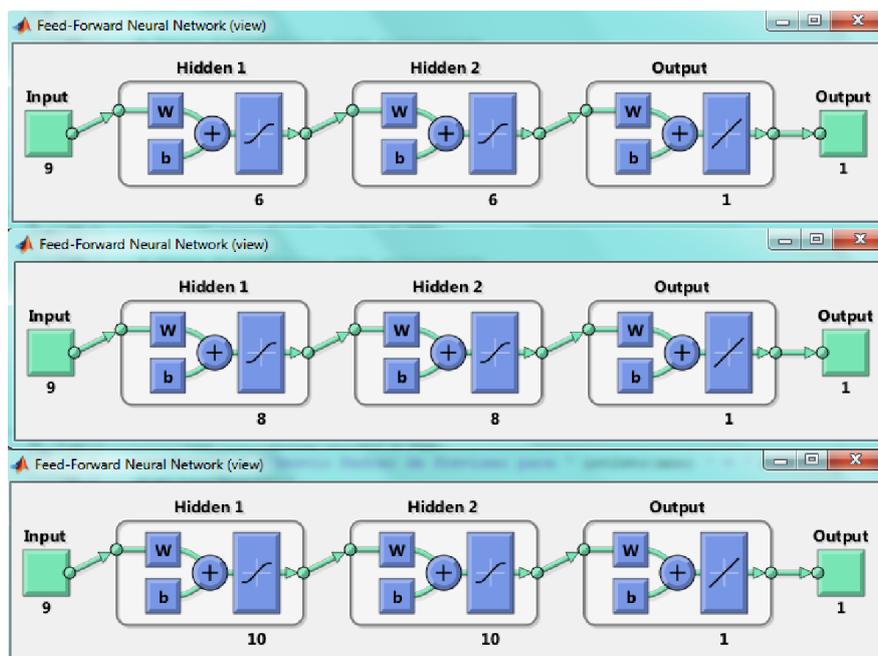


Figura 19: Redes Neurais utilizadas.

Foram realizadas várias simulações variando-se o número de variáveis de entrada do conjunto de 9 entradas (1, 2, 3, 4, 5, 6, 7, 8 e 9), o número de neurônios nas camadas escondidas e o método de generalização. A seguir apresentam-se os resultados dos referidos experimentos.

5.1.1 Curvas de Convergência das RNAs para Regularização L^2

Quando se utiliza o método de regularização L^2 , a função de desempenho, $msereg$, é constituída de dois termos, conforme a Equação 16. O primeiro deles, msw , corresponde à média da soma dos quadrados dos pesos e polarização da rede (Equação 17), enquanto que o segundo, mse , tem como sub-termo a soma dos erros médios quadráticos (Equação 18).

$$msereg = \gamma * msw + (1 - \gamma) * mse \quad \text{Eq. 17}$$

$$msw = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad \text{Eq. 18}$$

$$mse = \frac{1}{n} \sum_{i=1}^n (t_i - \alpha_i)^2 \quad \text{Eq. 19}$$

Em que:

n – número de dados

t_i – Valores observados (reais)

α_i – Valores previstos

w_j – Pesos da RNA

γ – Taxa de desempenho

A especificação de treinamento ‘ $msereg$ ’ no Matlab[®], baseado na Equação 18, implementa a regularização L^2 que força os pesos e polarizações a adotarem valores menores, fazendo com que a rede tenha resposta suave e seja menos tendenciosa ao *overfitting*. Para o critério de parada do treinamento foi utilizado 500 épocas ou um erro

menor do que 0,001. A Tabela 9 apresenta os melhores resultados obtidos quando foi utilizado o método de regularização L^2 para previsões com até 1 mês de antecedência da ocorrência das cheias. Como resultado, a Figura 20 mostra o gráfico de convergência da rede para o método de regularização L^2 , apresentando o ponto de convergência para a rede simulada com 1 (um) mês de antecedência do pico máximo da cheia.

Tabela 9: Melhores desempenhos dos experimentos com RNA utilizando regularização L^2

Antecedência do pico da cheia	Número de variáveis	Arquiteturas	r_p	Ind_1	Ind_2	Ind_3	Ind_4
4 meses	9	6x6x1	0,719	32	26	7	2
3 meses	9	10x10x1	0,8187	41	20	5	1
2 meses	8	6x6x1	0,8859	45	19	3	0
1 mês	8	10x10x1	0,9457	60	7	0	0

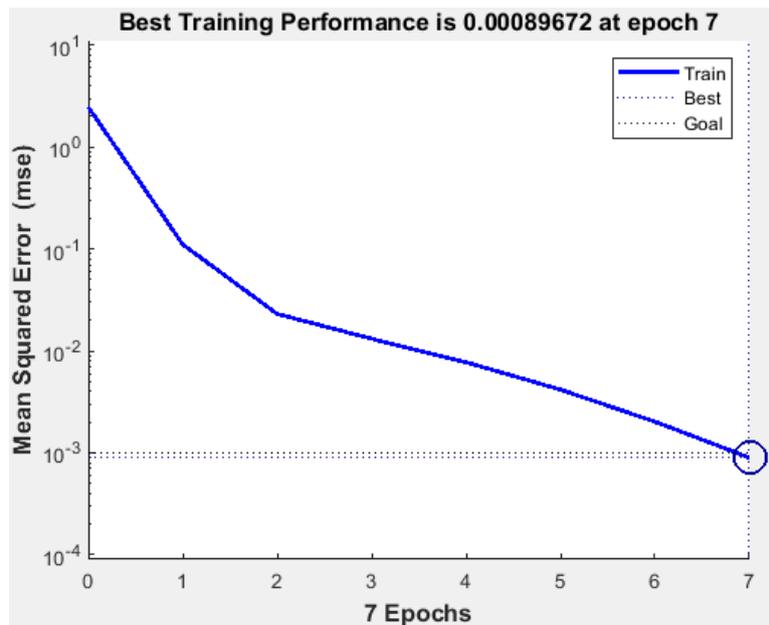


Figura 20: Gráfico de convergência para a rede com arquitetura 10-10-1, 8 variáveis de entrada e método de regularização L^2 .

A Figura 21 apresenta o gráfico da correlação obtida a partir dos valores preditos por uma RNA com arquitetura 10-10-1, 8 variáveis de entrada e com regularização L^2 para 1 mês de antecedência de ocorrência da cheia. O coeficiente de correlação de Pearson para essa curva foi $r = 0,9457$.

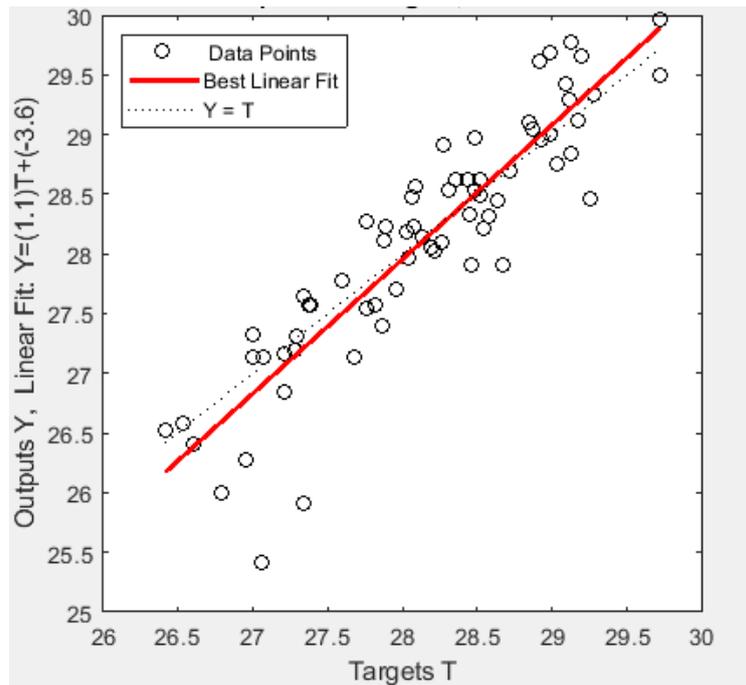


Figura 21: Curva de Correlação obtida com os valores preditos por uma rede com arquitetura 10-10-1, 8 variáveis de entrada e regularização L^2 . $r = 0,9457$.

5.1.2 Curvas de Convergência das RNAs com Parada Antecipada

No método de parada antecipada foi utilizado 60% dos dados para treinamento, 20% para validação e 20% para teste. Assim como no método de regularização L^2 , também foram realizadas previsões com até 1 (um) mês de antecedência da ocorrência de cheias. A Tabela 10 apresenta os melhores resultados obtidos nos experimentos.

Tabela 10: Melhores desempenhos dos experimentos com RNA utilizando Parada Antecipada.

Antecedência do pico da cheia	Número de variáveis	Arquiteturas	r_p	Ind_1	Ind_2	Ind_3	Ind_4
4 meses	8	8x8x1	0,7309	36	26	4	1
3 meses	9	10x10x1	0,8203	42	20	3	2
2 meses	8	6x6x1	0,9238	55	11	1	0
1 mês	8	10x10x1	0,9592	63	4	0	0

A Figura 22 apresenta o gráfico de convergência da rede quando se aplica o método de generalização de parada antecipada. A simulação que apresentou melhor desempenho foi feita para o mês de maio, correspondente a 1 (um) mês de antecedência do pico máximo da cheia, com 8 variáveis de entrada e arquitetura 10-10-1. Nos treinamentos com parada antecipada, o critério de parada do treinamento foi considerado quando o erro no conjunto de validação atingisse mais de 20 interações.

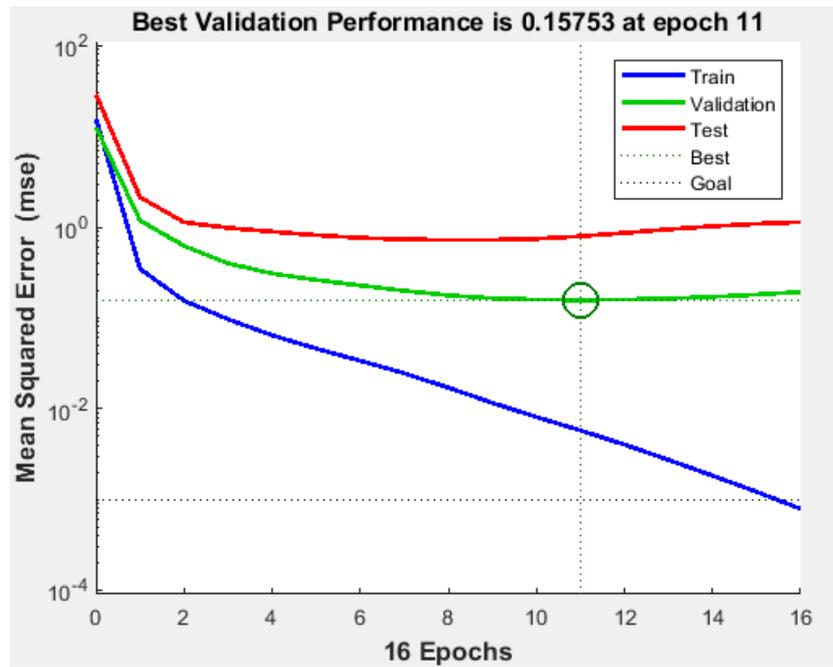


Figura 22: Gráfico de convergência para a rede com arquitetura 10-10-1, 8 variáveis de entrada e método de generalização de parada antecipada.

A Figura 23 apresenta a curva de correlação obtida a partir dos valores preditos por uma RNA com arquitetura 10-10-1, 8 variáveis de entrada e com método de generalização de parada antecipada. O coeficiente de correlação de Pearson para essa curva foi $r_p = 0,9592$.

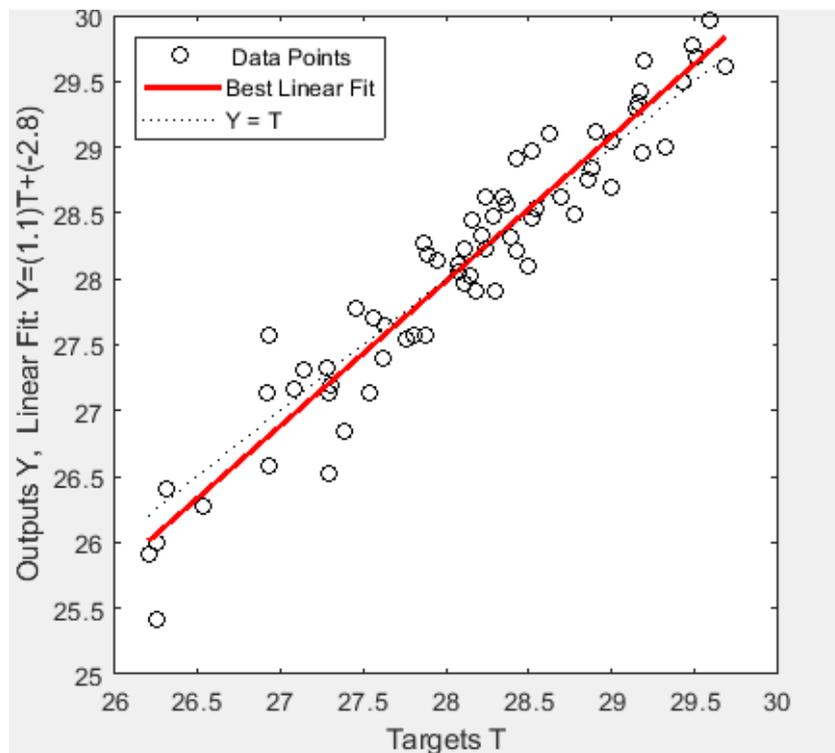


Figura 23: Curva de Correlação obtida com os valores preditos por uma rede com arquitetura 10-10-1, 8 variáveis de entrada e generalização de parada antecipada. $r = 0,9592$.

5.1.3 Valores de Coeficiente de Pearson e de Índices de Erro para as RNAs

Na Tabela 11 são apresentados os valores obtidos para o coeficiente de Pearson e para os índices de erro, considerando as três arquiteturas de redes neurais, apresentados em função do número de variáveis de entrada, dos métodos de generalização para o período de realização da previsão de 4 meses de antecedência da cheia. Observa-se que os melhores resultados foram obtidos utilizando 8 e 9 variáveis na entrada da RNA. A Tabela 12 apresenta os valores obtidos utilizando 8 e 9 variáveis de entrada na RNA para o quatro meses que antecedem o mês de ocorrência do pico máximo da cheia.

A partir dos resultados mostrados na Tabela 11, observa-se que os melhores resultados foram obtidos utilizando RNA com parada antecipada para o coeficiente de correlação de Pearson, $r_p = 0,7309$. Esse valor foi obtido utilizando 8 variáveis de entrada selecionadas pelo método de seleção escalar de características modificado e com uma arquitetura de rede neural 8-8-1. Para essas condições, obteve-se os seguintes valores para os índices de erro: Ind_1 = 36, Ind_2 = 26, Ind_3 = 4 e Ind_4 = 1. Esses resultados mostram que em 53,73% dos anos a previsão possui um erro menor do que 0,5m; em 92,53% dos anos a previsão resultou em um erro menor do que 1 m e em somente um ano (98,51%) a previsão resultou em um erro maior do que 1,5 m.

Na Tabela 12 observou-se que os melhores resultados foram obtidos ao utilizar RNA com o método de generalização de parada antecipada e quando a previsão da cheia foi realizada com 1 mês de antecedência da cheia, isto é, no mês de maio, o coeficiente de correlação de Pearson foi de $r_p = 0,9592$. Neste caso, foram utilizadas 8 variáveis de entrada selecionadas pelo método de seleção escalar de características modificado e com uma arquitetura de RNA 10-10-1. Para essa arquitetura obteve-se os seguintes valores de índices de erro: Ind_1 = 63, Ind_2 = 4, Ind_3 = 0 e Ind_4 = 0, mostrando que em 94,02% dos anos a previsão possui um erro menor do que 0,5 m; em 100% dos anos a previsão resultou em um erro menor do que 1 m.

Dessa forma, com o objetivo de avaliar se havia diferenças, estatisticamente significantes, entre o desempenho das RNAs com os métodos de generalização de regularização L^2 e parada antecipada, aplicou-se o teste Qui-quadrado aos valores dos índices, para cada uma das linhas das Tabelas 11 e 12. As tabelas de contingência utilizadas para o teste Qui-quadrado são tabelas 4x2 (4 índices de erro x dois métodos de

generalização). O nível de significância adotado foi de 0,0001. Verificou-se que existia diferença estatisticamente significativa apenas em alguns poucos casos: Caso 1: Arquitetura 8-8-1, 1 variável de entrada; Caso 2: Arquitetura 10-10-1, 1 variável de entrada; Caso 3: Arquitetura 6-6-1, 2 variáveis de entrada; e Caso 4: Arquitetura 10-10-1, 5 variáveis de entrada. Assim, de uma forma geral, não existem diferenças estatisticamente significantes entre os métodos de generalização de regularização L^2 e parada antecipada.

Tabela 11: Resultados dos experimentos para as RNAs com 4 meses de antecedência do pico máximo da cheia.

Número de variáveis	Arquiteturas	Regularização – L^2					Parada Antecipada – <i>Early Stop</i>				
		r_p	Ind 1	Ind 2	Ind 3	Ind 4	r_p	Ind 1	Ind 2	Ind 3	Ind 4
1	6x6x1	0,5229	19	23	9	16	0,6513	33	21	9	4
	8x8x1	0,3864	23	9	10	25	0,6252	30	27	4	6
	10x10x1	0,5396	25	19	10	13	0,7104	31	28	6	2
2	6x6x1	0,4451	26	13	16	12	0,6845	30	28	6	3
	8x8x1	0,5138	22	21	13	11	0,6696	31	25	9	2
	10x10x1	0,6197	30	17	13	7	0,6285	28	30	4	5
3	6x6x1	0,5337	27	16	14	10	0,7109	28	29	9	1
	8x8x1	0,5609	25	23	12	7	0,6712	26	29	11	1
	10x10x1	0,6044	23	28	13	3	0,6795	30	22	12	3
4	6x6x1	0,5229	30	19	12	6	0,7202	33	26	6	2
	8x8x1	0,5791	23	30	11	3	0,6623	27	31	6	3
	10x10x1	0,6038	26	24	15	2	0,6363	24	32	9	2
5	6x6x1	0,6475	34	20	8	5	0,6737	27	31	7	2
	8x8x1	0,5869	22	26	17	2	0,7038	29	27	10	1
	10x10x1	0,5157	31	15	14	7	0,6773	25	33	8	1
6	6x6x1	0,6223	29	21	15	2	0,6453	28	27	11	1
	8x8x1	0,6347	32	15	16	4	0,6644	27	29	9	2
	10x10x1	0,6652	25	26	15	1	0,6734	30	24	12	1
7	6x6x1	0,6919	32	27	5	3	0,6124	31	23	10	3
	8x8x1	0,7035	32	21	13	1	0,6728	31	26	8	2
	10x10x1	0,6748	31	24	10	2	0,6792	26	32	8	1
8	6x6x1	0,6428	28	24	13	2	0,6632	27	30	9	1
	8x8x1	0,6879	39	17	7	4	0,7309	36	26	4	1
	10x10x1	0,6768	33	23	8	3	0,6942	27	34	5	1
9	6x6x1	0,719	32	26	7	2	0,6857	33	24	9	1
	8x8x1	0,6708	31	25	9	2	0,7171	34	23	9	1
	10x10x1	0,5936	32	19	12	4	0,6953	34	22	10	1

Tabela 12: Resultados dos experimentos com 8 e 9 variáveis de entrada para as RNAs.

Antecedência do pico da cheia	Número de variáveis	Arquiteturas	Regularização - L2				Parada Antecipada – <i>Early Stop</i>					
			r_p	Ind_1	Ind_2	Ind_3	Ind_4	r_p	Ind_1	Ind_2	Ind_3	Ind_4
4 meses	8	6x6x1	0,6428	28	24	13	2	0,6632	27	30	9	1
		8x8x1	0,6879	39	17	7	4	0,7309	36	26	4	1
		10x10x1	0,6768	33	23	8	3	0,6942	27	34	5	1
	9	6x6x1	0,719	32	26	7	2	0,6857	33	24	9	1
		8x8x1	0,6708	31	25	9	2	0,7171	34	23	9	1
		10x10x1	0,5936	32	19	12	4	0,6953	34	22	10	1
3 meses	8	6x6x1	0,7439	35	26	4	2	0,7983	35	28	3	1
		8x8x1	0,71	36	21	9	1	0,7977	38	24	3	2
		10x10x1	0,7135	36	20	9	2	0,7964	34	27	5	1
	9	6x6x1	0,8048	39	19	9	0	0,8036	39	22	6	0
		8x8x1	0,7762	33	28	5	1	0,7944	37	24	6	0
		10x10x1	0,8187	41	20	5	1	0,8203	42	20	3	2
2 meses	8	6x6x1	0,8859	45	19	3	0	0,9238	55	11	1	0
		8x8x1	0,8421	43	21	2	1	0,8938	51	14	1	1
		10x10x1	0,8668	48	16	2	1	0,903	45	21	1	0
	9	6x6x1	0,7772	39	22	3	3	0,8954	49	16	2	0
		8x8x1	0,7937	38	22	5	2	0,9087	52	14	1	0
		10x10x1	0,8664	42	23	2	0	0,8992	53	11	3	0
1 mês	8	6x6x1	0,9127	52	14	1	0	0,9556	64	2	1	0
		8x8x1	0,9223	51	16	0	0	0,958	63	4	0	0
		10x10x1	0,9457	60	7	0	0	0,9592	63	4	0	0
	9	6x6x1	0,9081	51	15	1	0	0,9565	61	6	0	0
		8x8x1	0,9163	49	18	0	0	0,949	59	8	0	0
		10x10x1	0,9274	55	10	2	0	0,9486	58	8	1	0

5.1.4 Valores da Matriz de Confusão para a classificação de faixas utilizando RNA

Na Tabela 13 são apresentados os valores obtidos para a matriz de confusão a partir dos melhores coeficientes de correlação das Tabelas 11 e 12, considerando os métodos de generalização utilizados. Analisando a Tabela 13, observa-se que, utilizando regularização $L^2 + bootstrap$, o sistema previu os seguintes resultados: 3 anos foram corretamente classificados na faixa 1 e 4 anos foram erroneamente classificados como sendo da faixa 2; 13 anos foram corretamente classificados na faixa 2 e 3 anos foram erroneamente classificados como sendo da faixa 3; 27 anos foram corretamente classificados na faixa 3, 3 anos foram erroneamente classificados como sendo da faixa 2 e 2 anos foram erroneamente classificados como sendo da faixa 4; 7 anos foram corretamente classificados na faixa 4 e 5 anos foram erroneamente classificados como sendo da faixa 3. Utilizando parada antecipada + *bootstrap* foram obtidos os seguintes resultados: 4 anos foram corretamente classificados na faixa 1 e 3 anos foram erroneamente classificados como sendo da faixa 2; 15 anos foram corretamente classificados na faixa 2 e 1 ano erroneamente classificado na faixa 3; 29 anos foram corretamente classificados na faixa 3, 2 anos foram erroneamente classificados como sendo da faixa 2 e 1 ano erroneamente classificado como faixa 4; 9 anos foram corretamente classificados na faixa 4 e 3 anos foram erroneamente classificados na faixa 3. Dessa forma, obtivemos uma acurácia de 74,62 % para o método de regularização $L^2+bootstrap$ e uma acurácia de 85,07% para o método de parada antecipada + *bootstrap*.

Tabela 13: Resultado da matriz de confusão para a classificação de faixas.

		Pico da Cheia Previsto (PC_p)			
		Regularização L^2			
Valores reais	Faixas	1	2	3	4
	1	3	4	0	0
	2	0	13	3	0
	3	0	3	27	2
	4	0	0	5	7
		Parada Antecipada			
Faixas	1	2	3	4	
1	4	3	0	0	
2	0	15	1	0	
3	0	2	29	1	
4	0	0	3	9	

A partir dos resultados da Tabela 13 obtivemos uma acurácia de 74,62% para o método de regularização L^2 e uma acurácia de 85,07% para o método de parada antecipada. Assim, na classificação em faixas proposta nesse trabalho, o método de parada antecipada apresentou melhor desempenho. O resultado apresentado na Tabela 13 refere-se a previsão com 4 meses de antecedência da ocorrência do pico máximo de cheia, entretanto, verificou-se a classificação de cheias em faixas, seja com 4 meses, com 3, com 2 ou com 1 mês de antecedência da ocorrência das cheias apresentou o mesmo desempenho.

5.2 Aprendizado baseado em Comitê

Após os experimentos utilizando o preditor RNA, foram realizados experimentos utilizando os métodos de aprendizado baseado em comitê. Como já mencionado, a proposta desse trabalho foi avaliar se a referida abordagem tem desempenho superior aos apresentados em implementações com RNAs na aplicação de previsão de cheias sazonais.

Com isso, foram avaliados os métodos de *bagging* e *boosting* em que utilizamos os mesmos conjuntos de variáveis de entrada, de 1 a 9 variáveis, com o objetivo de determinar qual conjunto e qual método de aprendizado apresentam o melhor desempenho.

5.2.1 Curva de correlação do *Bagging*

O método *Bagging*, que significa agregação de *bootstrap*, é um tipo de aprendizado baseado em comitê. Na implementação do método no ambiente de desenvolvimento Matlab[®], os aprendizes são treinados a partir da reamostragem dos dados do conjunto de variáveis de entrada, por meio do método de *bootstrap*.

Para realizar os experimentos utilizando esse método foi utilizada a função do Matlab[®] *fitrensemble* ($X, Y, Name, Value$), em que o comitê de regressão usado foi o 'Bag'. Para o treinamento do comitê foram usados 100 ciclos de aprendizado, onde o software treina um aprendiz para cada objeto do modelo e o classificador usado para regressão é o de árvores de decisão. Cada árvore do comitê pode selecionar preditores

aleatoriamente para divisão de decisão. Essa seleção aleatória é feita para cada divisão e toda árvore profunda envolve muitas divisões, então, por padrão, esse parâmetro é definido como um terço dos preditores para regressão. Essa técnica é utilizada para melhorar a precisão do *bagging*. A Figura 24 mostra a curva de correlação para o método de *bagging* com 6 variáveis de entrada e informa-se o respectivo coeficiente de correlação. Ressalta-se que, dos experimentos realizados com o número de variáveis de entrada sendo variado de 1 a 9 e o período de realização da previsão sendo de 4 meses, 3 meses, 2 meses e 1 mês de antecedência da ocorrência do pico máximo da cheia, o experimento realizado com 8 variáveis e 1 mês de antecedência foi o que apresentou o maior coeficiente de correlação $r_p = 0,9374$.

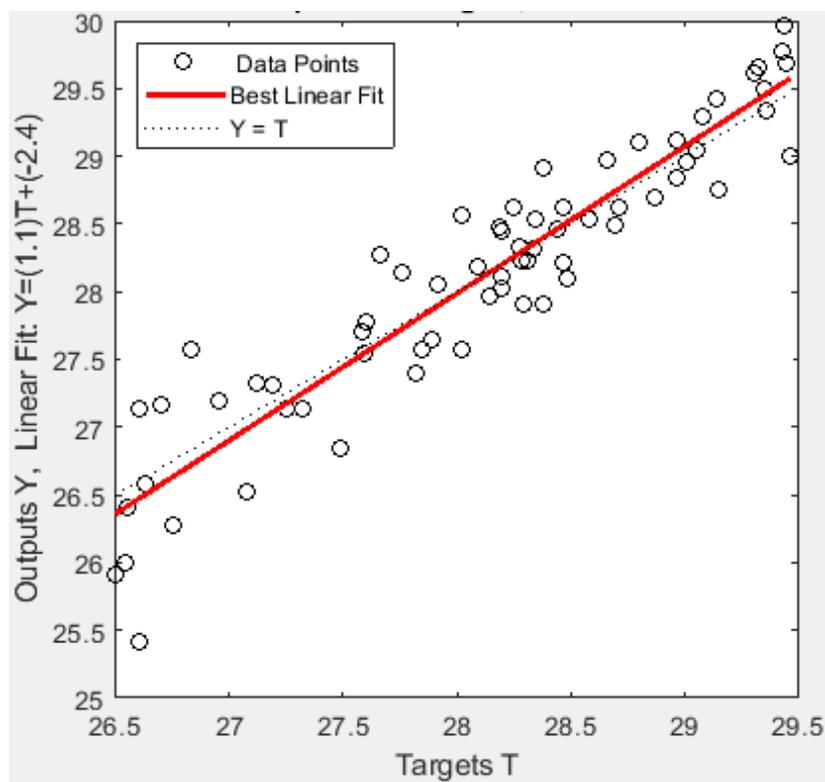


Figura 24: Curva de Correlação para o método de *bagging*, com 8 variáveis de entrada. $r = 0,9374$.

5.2.2 Curva de correlação do *Boosting*

No Matlab[®], a função responsável por implementar o método de *boosting* é o LSBoost (do inglês, *Least Squares Boosting*). O *Boosting*, como fora mencionado, é também um tipo de comitê de regressão. A cada passo do treinamento o comitê ajusta um novo aprendiz a partir da diferença entre a resposta observada e a previsão agregada de

todos os aprendizes que cresceram anteriormente. O uso desse comitê é adequado para minimizar o erro quadrático médio. Fazendo uso dos mesmos parâmetros do experimento anterior, experimentos foram realizados, variando-se o número de variáveis de entrada de 1 a 9. A Figura 25 mostra a curva de correlação para o método de *Boosting* com 8 variáveis de entrada e informa-se o respectivo coeficiente de correlação, r_p . Ressalta-se que, o período da previsão é de 1 mês de antecedência e dos experimentos realizados aquele realizado com 8 variáveis foi o que apresentou o maior coeficiente de correlação $r_p = 0,9154$.

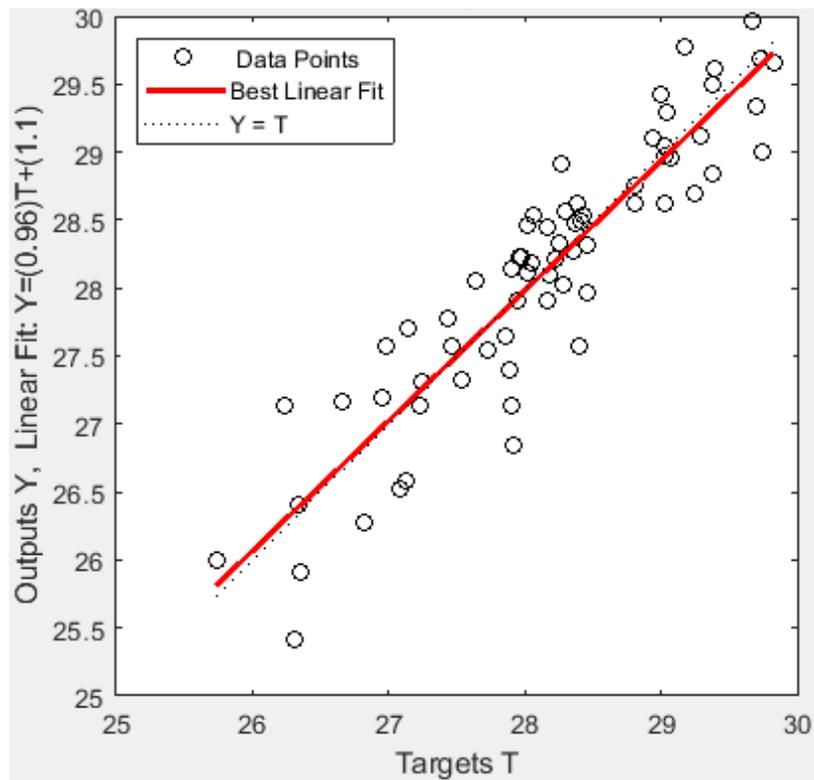


Figura 25: Curva de Correlação para o método de *boosting*, com 8 variáveis de entrada. $r = 0,9154$

5.2.3 Coeficientes de Pearson e Índices de Erro para os métodos de Aprendizado baseado em Comitê

Na Tabela 14 são apresentados os valores obtidos para os coeficientes de Pearson e para os índices de erro, considerando os comitês *bagging* e *boosting* e o número de variáveis de entrada.

Tabela 14: Resultados de previsão do pico da cheias com 4 meses de antecedência para os métodos de Aprendizado baseado em Comitê em função do número de variáveis de entrada.

Número de variáveis	<i>Bagging</i>					<i>Boosting</i>				
	r_p	Ind_1	Ind_2	Ind_3	Ind_4	r_p	Ind_1	Ind_2	Ind_3	Ind_4
1	0,7091	31	26	9	1	0,6158	22	30	11	4
2	0,6867	29	28	8	2	0,6751	30	23	9	5
3	0,6596	29	27	7	4	0,593	19	27	17	4
4	0,6824	27	29	10	1	0,5214	26	20	10	11
5	0,7063	31	27	7	2	0,6021	27	19	14	7
6	0,7145	30	30	6	1	0,5951	25	24	11	7
7	0,7035	28	32	5	2	0,5842	23	20	18	6
8	0,6963	29	29	8	1	0,5589	26	19	13	9
9	0,7058	29	30	6	2	0,6153	22	25	15	5

Observando a Tabela 14, o melhor desempenho, segundo o coeficiente de correlação de Pearson, foi obtido na previsão com 4 meses de antecedência da ocorrência do pico máximo da cheia com o método de comitê *bagging* com 6 variáveis de entrada ($r_p = 0,7145$). Nessas condições, os seguintes valores para os índices de erro foram obtidos: Ind_1 = 30, Ind_2 = 30, Ind_3 = 6 e Ind_4 = 1. Os resultados mostram que em 44,77% dos anos (30 anos) a previsão possui um erro menor do que 0,5m; em 89,55% dos anos (60 anos) a previsão resultou em um erro menor do que 1m; e em 98,51% dos anos a previsão resultou em um erro menor do que 1,5 m.

Na Tabela 15 são apresentados os melhores resultados com 4 meses, 3 meses, 2 meses e 1 mês de antecedência da ocorrência do pico máximo da cheia. Observa-se que os melhores resultados foram obtidos utilizando o método de *bagging*, apresentando $r_p = 0,9374$. Esse valor foi obtido utilizando 8 variáveis de entrada, selecionadas pelo método de seleção escalar de características modificado, a previsão da cheia foi realizada com 1 mês de antecedência do pico máximo, isto é, no mês de maio. Os resultados mostram que em 85,07% dos anos a previsão possui um erro menor do que 0,5m; em 98,51% dos anos a previsão resultou em um erro menor do que 1 m; e em 100% dos anos a previsão resultou em um erro menor do que 1,5 m.

Tabela 15: Melhores resultados de previsão de pico de cheias para 4, 3, 2 e 1 mês de antecedência da ocorrência da cheia obtidos com os métodos de aprendizado baseados em Comitê.

Antecedência	Nº variáveis	<i>Bagging</i>				Nº variáveis	<i>Boosting</i>					
		r_p	Ind_1	Ind_2	Ind_3		Ind_4	r_p	Ind_1	Ind_2	Ind_3	Ind_4
4 meses	1	0,7091	31	26	9	1	0,6158	22	30	11	4	
	6	0,7145	30	30	6	1	2	0,6751	30	23	9	5
3 meses	1	0,8583	45	20	2	0	1	0,8089	35	24	8	0
	6	0,8309	36	27	3	1	7	0,8172	38	24	4	1
2 meses	1	0,9077	49	17	1	0	4	0,904	48	18	1	0
	4	0,9029	49	16	2	0	5	0,9012	50	16	1	0
1 mês	8	0,9374	57	9	1	0	8	0,9154	52	14	1	0
	9	0,9353	57	9	1	0	9	0,9074	50	17	0	0

Com o objetivo de avaliar se haviam diferenças estatisticamente significantes entre os métodos de aprendizagem de *bagging* e *boosting*, aplicou-se o teste Qui-quadrado aos valores dos índices, para cada uma das linhas das Tabelas 14 e 15. As tabelas de contingência utilizadas para o teste Qui-quadrado são tabelas 4x2 (4 índices de erro por dois métodos de generalização). O nível de significância adotado foi de 0.0001. Verificou-se que existia diferença estatisticamente significativa apenas no caso em que foi utilizado 7 variáveis no conjunto de entrada. De forma geral, constatou-se que não existem diferenças estatisticamente significantes entre os métodos de aprendizagem *bagging* e *boosting*.

5.2.4 Resultados da classificação de cheias em faixas utilizando aprendizado baseado em Comitê.

Na Tabela 16 são apresentados os valores obtidos para a matriz de confusão para a classificação de cheias em faixas a partir dos melhores coeficientes de correlação apresentados da Tabela 15 obtidos para os métodos de *bagging* e *boosting*. Analisando a Tabela 16, observa-se que, utilizando *bagging*, obteve-se os seguintes resultados: 5 anos foram corretamente classificados na faixa 1 e 2 anos erroneamente classificado na faixa 2; 13 anos foram corretamente classificados na faixa 2, 1 ano erroneamente classificado na faixa 1 e 2 anos erroneamente classificados na faixa 3; 27 anos foram corretamente classificados na faixa 3, 2 anos erroneamente classificado na faixa 2 e 3 anos erroneamente classificados na faixa 4; 10 anos foram corretamente classificados na faixa 4 e 2 anos erroneamente classificado na faixa 3. Utilizando *boosting* foram obtidos os

seguintes resultados: 4 anos foram corretamente classificados na faixa 1 e 3 anos erroneamente classificados na faixa 2; 10 anos foram corretamente classificados na faixa 2, 2 anos erroneamente classificado na faixa 1 e 4 anos erroneamente classificados na faixa 3; 26 anos foram corretamente classificados na faixa 3, 1 ano erroneamente classificado na faixa 2 e 5 anos erroneamente classificados na faixa 4; 10 anos foram corretamente classificados na faixa 4 e 2 anos erroneamente classificado na faixa 3. Dessa forma, obtivemos uma acurácia de 82,09% para o método de *bagging* e uma acurácia de 74,63% para o método de *boosting*.

Tabela 16: Resultado da matriz de confusão para a classificação de cheias sazonais em faixas.

		Pico da Cheia Previsto (PC_p)			
		<i>Bagging</i>			
Valores reais	Faixas	1	2	3	4
	1	5	2	0	0
	2	1	13	2	0
	3	0	2	27	3
	4	0	0	2	10
		<i>Boosting</i>			
Faixas	1	2	3	4	
1	4	3	0	0	
2	2	10	4	0	
3	0	1	26	5	
4	0	0	2	10	

6 DISCUSSÃO

O estudo comparativo mostrou que os métodos baseados em comitês não conseguiram superar o desempenho dos preditores utilizando redes neurais artificiais. Ainda, os melhores valores de ambos preditores foram na previsão de 1 mês de antecedência, vide Tabela 17.

Tabela 17: Comparação de desempenho entre RNA e os métodos de aprendizagem baseados em comitê com 1 mês de antecedência do pico da cheia.

Erro	RNA	Método de Comitê
Ind_1 (<i>erro</i> ≤ 0,5)	94,02%	85,07%
Ind_1 + Ind_2 (<i>erro</i> ≤ 1)	100%	98,51%
Ind_1 + Ind_2 + Ind_3 (<i>erro</i> ≤ 1,5)	100%	100%
r_p	0,9592	0,9374

O melhor desempenho, segundo o coeficiente de Pearson, $r_p = 0,9592$ foi obtido por uma RNA com arquitetura 10-10-1, parada antecipada como método de regularização L^2 e 8 variáveis de entrada, selecionadas pelo método de seleção escalar de características modificado.

A Tabela 18 apresenta uma comparação de desempenho utilizando os três Índices de Erro para o preditor proposto e o trabalho de Rodrigues *et.al.* (2015). Considerando que Rodrigues *et.al.* (2015) utilizou o mesmo conjunto de dados e realizou a previsão com 4 meses de antecedência. Observa-se que os percentuais de acerto foram levemente superiores àqueles obtidos por Rodrigues *et.al.* (2015).

Tabela 18: Comparação de desempenho entre o preditor RNA deste trabalho e o implementado por Rodrigues *et.al.* (2015) para previsão de cheias com 4 meses de antecedência.

Erro	RNA implementada por Rodrigues <i>et.al.</i> (2015)	RNA implementada nesta dissertação
Ind_1 (<i>erro</i> ≤ 0,5)	51,56%	53,73%
Ind_1 + Ind_2 (<i>erro</i> ≤ 1)	92,18%	92,53%
Ind_1 + Ind_2 + Ind_3 (<i>erro</i> ≤ 1,5)	98,43%	98,51%

Com respeito a proposta de classificação de cheias em faixas de valores, a Tabela 19 apresenta a acurácia dessa classificação para os preditores que obtiveram melhor

desempenho nos experimentos. Dessa forma, a abordagem utilizando RNA com parada antecipada + *bootstrap* apresentou melhor desempenho. Os experimentos foram realizados com 1 mês de antecedência do pico máximo da cheia, período em que os preditores desenvolvidos apresentaram os melhores coeficientes de Pearson.

Tabela 19: Acurácia da classificação das cheias em faixas de valores a partir dos preditores usados.

Preditores	Classificação de faixas (Acurácia)
RNA com Regularização L^2+ <i>Bootstrap</i>	74,62%
RNA com Parada antecipada + <i>Bootstrap</i>	85,07%
Método de Comitê - <i>Bagging</i>	82,09%
Método de Comitê - <i>Boosting</i>	74,63%

7 CONCLUSÃO

Neste trabalho realizou-se um estudo de duas abordagens aplicadas a previsão de cheias sazonais do rio Negro, com antecedência variando de um a quatro meses da ocorrência do pico máximo da cheia na região. Essas duas abordagens utilizaram, respectivamente, preditores implementados através de Redes Neurais Artificiais e preditores implementados através de métodos de aprendizado baseados em Comitê. A primeira abordagem tem estudos prévios presentes na literatura, enquanto que a segunda até o momento da pesquisa bibliográfica do presente trabalho, sem estudos prévios para o problema tema do trabalho. Para realizar a implementação desses métodos foi necessário o uso de outras técnicas como o método de seleção escalar de características modificado, o método *bootstrap*, regularização L^2 , parada antecipada e os métodos de *bagging* e *boosting*. Adicionalmente, nessa dissertação foi proposta uma nova forma de classificação da cheia, a classificação em faixas de valores. Essas faixas foram determinadas em função da média e desvio padrão dos picos máximos dos anos anteriores.

A proposição de avaliar três arquiteturas de redes neurais artificiais utilizando regularização L^2 , parada antecipada e *bootstrap*, foi o primeiro objetivo específico atendido e os resultados foram apresentados nas Tabelas 11 e 12.

Os resultados apresentados na Tabela 14 fez com que o segundo objetivo específico fosse alcançado: “Avaliar o desempenho do Aprendizado baseado em Comitê na previsão da cheia do rio Negro”.

O terceiro objetivo específico deste trabalho foi atendido quando obtivemos os resultados apresentados na Tabela 15, de forma que foi possível comparar o desempenho dos métodos abordados e assim constatar qual o mais eficiente, preditor RNA com parada antecipada.

Na medida em que se propôs uma metodologia para classificação das cheias do rio Negro em faixas de valores, segundo a média e o desvio padrão dos valores das cheias anteriores, atendeu-se ao quarto objetivo específico desse trabalho. Esse objetivo específico foi posto na introdução como: “Propor uma metodologia para classificação das

cheias do rio Negro em faixas de variação d'água, segundo a média e o desvio padrão dos valores das mesmas”.

A comparação com os resultados obtidos por Rodrigues *et.al.* (2015), mostrou que os melhores resultados deste trabalho foram satisfatórios.

Do trabalho realizado, os resultados sugerem que a abordagem de previsão de cheias utilizando o preditor RNA permanece como a abordagem de melhor desempenho quando comparada ao preditor baseado em comitê utilizando *bagging* e *boosting*.

REFERÊNCIAS

- ANA, Agência Nacional de Águas. 2019.** [Online] 2019. [Citado em: 14 de janeiro de 2019.] <http://www3.ana.gov.br/>.
- Anuar, Mohd Azrol Syafiee, et al. 2017.** Early Prediction System Using Neural Network in Kelantan River ,Malaysia. *IEEE 15th Student Conference on Research and Development (SCOReD)*. 2017.
- Breiman, Leo. 1996.** Bagging Predictors. *Boston : Kluwer Academic Publishers*. 1996.
- Climate Prediction Center. 2018.** NOAA Center for Weather and Climate Prediction. *Climate Prediction Center*. [Online] 2018. [Citado em: 14 de Junho de 2018.] <ftp://ftp.cpc.ncep.noaa.gov/wd52dg/data/indices/sstoi.indices>.
- Córdoba-Machado, Samir , et al. 2016.** Seasonal streamflow prediction in Colombia using atmospheric and oceanic patterns. *Journal of Hydrology*. 2016, Vol. 538.
- Costa Neto, Pedro Luiz Oliveira. 2002.** *Estatística*. São Paulo : Edgard Blucher, 2002. 8521203004.
- DSA. 2018.** *Deep Learning Book*. 2018.
- Flach, Peter. 2012.** *Machine Learning: The Art and Science of Algorithms that Make Sense os Data*. New York : Cambridge University Press, 2012. 978-1-107-09639-4.
- Hagan, Martin T. e Menhaj, Mohammad B. 1994.** Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Network* . 6, 1994, Vol. 5.
- Haykin, Simon. 2001.** *Redes Neurais: Princípios e prática*. São Paulo : ARTMED Editora S.A., 2001. 0132733501.
- Jain, Anil K., Mao, Jianchang e Mohiuddin, K. M. 1996.** Artificial Neural Networks: A Tutorial. *IEEE*. 1996.
- Ju , Cheng , Bibaut , Aurélien e van der, Mark J. . 2017.** The Relative Performance of Ensemble Methods with Deep Convolutional Neural Networks for Image Classification. 2017.
- Liu, Fan , Xu, Feng e Yang, Sai . 2017.** A Flood Forecasting Model based on Deep Learning Algorithm via Integrating Stacked Autoencoders with BP Neural Network. *IEEE Third International Conference on Multimedia Big Data*. 2017.
- MathWorks. 2018.** *Framework for Ensemble Learning*. 2018.
- Matsunaga, Victoria Yukie. 2012.** *Curso de Redes Neurais Utilizando o Matlab*. Belém - Pará : s.n., 2012.
- Mitra, Prachatos , et al. 2016.** Flood forecasting using Internet of things and Artificial Neural Network. *IEEE*. 2016.
- MMA. 2007.** *Atlas das Áreas Susceptíveis à Desertificação do Brasil*. Brasília : s.n., 2007.
- Patterson, J. e Gibson, A. 2017.** *Deep Learning: A Practitioner's Approach*. O'Reilly Media. 2017.
- Piana, Clause Fátima Brum, Machado, Amauri Almeida e Selau, Lisiane Priscila Roldão. 2009.** *Estatística Básica*. Pelotas : s.n., 2009.

- Portal Action. 2018.** [Online] 13 de Novembro de 2018. <http://www.portalaction.com.br/probabilidades/62-distribuicao-normal>.
- Porto de Manaus. 2018.** [Online] 2018. [Citado em: 13 de Julho de 2018.] <https://www.portodemanaus.com.br/?pagina=niveis-maximo-minimo-do-rio-negro>.
- Rodrigues, Márcio M., Costa, Marly G. F. e Filho, Cícero F. F. C. 2015.** Proposta de um Método para Previsão de Cheias Sazonais Utilizando Redes Neurais Artificiais: Uma Aplicação ao Rio Amazonas. *Google Scholar*. 2015.
- Rumelhart, David E., Hinton, Geoffrey E. e Williams, Ronald J. 1986.** Learning representations by back-propagating errors. *Nature Research Journal*. 323, 1986.
- Ruslan, Fazlina Ahmat, et al. 2014.** Prediction of 4 Hours Ahead Flood Water Level Using Improved ENN Structure: Case Study Kuala Lumpur. *IEEE International Conference on Control System, Computing and Engineering*. 2014.
- Schongart, Jochen e Junk, Wolfgang J. 2007.** Forecasting the flood-pulse in Central Amazonia by ENSO-indices. *Journal of Hydrology*. 335, 2007.
- Shu, Chang e Burn, H. Donald. 2004.** Artificial neural network ensembles and their application in pooled. *Water Resources Research*. 2004, Vol. 40, W09301, doi: 10.1029/2003WR002816.
- Silva, Renato M., Almeida, Thiago A. e Yamakami, Akebo. 2012.** Análise de desempenho de redes neurais artificiais para classificação automática de web spam. *Revista Brasileira de Computação Aplicada*. 2012, Vol. 4.
- Sonka, Milan e Fitzpatrick, J. Michael. 2000.** *Medical Image Processing and Analysis*. Washington : Spie Press, 2000.
- Theodoridis, Sergios e Koutroumbas, Konstantinos. 2003.** *Pattern Recognition*. San Diego : Academic Press, 2003.
- Truatmoraka, Panjaporn , Waraporn, Narongrit e Suphachotiwatana, Dhanasite. 2016.** Water Level Prediction Model Using Back Propagation Neural Network. *4th International Symposium on Computational and Business Intelligence*. 2016.
- Yu, Hao e Wilamowski, Bogdan M. 2010.** *Levenberg-Marquardt Training*. 2010.
- Zhou, Zhi-Hua. 2012.** *Ensemble Methods: Foundations and Algorithms*. Boca Raton : CRC Press, 2012. 978-1-4398-3005-5 .

Previsão de Cheias Sazonais para o Rio Negro Usando Redes Neurais Artificiais e Método de Aprendizado Baseado em Comitê

Paula A. Marães¹, Marly G. F. Costa¹, Cícero F. F. C. Filho¹

¹Centro de Pesquisa e Desenvolvimento de Tecnologia Eletrônica e da Informação –
Universidade Federal do Amazonas [CETELI/UFAM]
CEP 69077-000 – Manaus – AM – Brazil

paulamaraes14@gmail.com, {mcosta, ccosta}@ufam.edu.br

Abstract. *Seasonal Black River floods affects mainly the riverside population. In this work we present a methodology to predict the flood peak, using two types of predictors: Artificial Neural Networks (ANN) and Decision trees. For the training of the predictors, the variables were selected using a modified characteristic scalar selection technique. The data used corresponds to the period 1951-2017. For improving the neural network generalization, the technique of regularization L^2 and early stop, associated with bootstrap were employed. For improving decision trees performance, committee-based learning method (boosting and bagging) was employed. Additionally, this work proposes classifying the river floods into four ranges of values. The efficiency of the predictors was evaluated using the Pearson correlation coefficient and accuracy in range classification. The predictions were obtained with 4,3,2 months and 1 month before the occurrence of river peak level. The best accuracy obtained in range classification was 85,07%, for one month before the occurrence of peak level.*

Resumo. A ocorrência das cheias sazonais dos rios afeta, principalmente, a população ribeirinha. Neste trabalho foram avaliados métodos capazes de prever o pico da cheia de rios, utilizando dois tipos de preditores: Redes Neurais Artificiais (RNA) e Árvores de Decisão. Para o treinamento dos preditores, as variáveis foram selecionadas através da técnica de seleção escalar de características modificada a partir de um conjunto de dados das cheias do Rio Negro relativo ao período de 1951-2017. Para melhorar a generalização das Redes Neurais foram utilizadas as técnicas de regularização L^2 e parada antecipada, associadas a técnica *bootstrap*. Para melhorar a performance das árvores de decisão, métodos de aprendizado baseado em comitê (*boosting* e *bagging*), foram empregados. Esse artigo propõe ainda a classificação das cheias em faixas de valores. A eficiência dos preditores foi avaliada através do coeficiente de correlação de Pearson e da acurácia da classificação das cheias. As predições foram obtidas com 4,3,2 meses e 1 mês de antecedência em relação a ocorrência do pico da cheia. A melhor acurácia obtida na classificação em faixas foi de 85,07% com um mês de antecedência com relação ao pico da cheia, para o preditor RNA (parada antecipada e *bootstrap*).

1. Introdução

O Rio Negro é o maior afluente da margem esquerda do rio Amazonas, sendo o principal rio que passa às margens da cidade de Manaus, dando origem a uma rede de igarapés na cidade. As cheias sazonais do Rio Negro apresentam um longo tempo de percurso, cerca de sete/oito meses, iniciando em fevereiro. Seu máximo é alcançado entre os meses de junho e julho, coincidindo com o chamado verão Amazônico. Isso ocorre devido ao gigantesco tamanho da bacia hidrográfica e a pequena declividade dos leitos. A maior cheia já registrada do rio Negro, medida na cidade de Manaus, ocorreu em 2012 e atingiu a cota de 29,97 metros acima do nível do mar.

Esse fenômeno de subidas e baixas do rio atinge todos os rios da bacia Amazônica e impacta, principalmente, a população ribeirinha, que habita às margens dos rios, pois prejudica as atividades de pesca, agricultura e a criação de animais, assim como, compromete a própria habitação dessa população.

Em Manaus, o monitoramento do fenômeno de subidas e baixas do rio é feito pelo Serviço Geológico do Brasil em parceria com o Sistema de Proteção da Amazônia – SIPAM. São emitidos boletins semanais que informam sobre a evolução das cheias às autoridades (defesa civil, corpo de bombeiros, governos estadual e municipal) e à população em geral [MMA, 2007].

Através de pesquisa em bases de dados bibliográficas identificou-se algumas publicações científicas que apresentam métodos e/ou sistemas de previsão de cheias, desenvolvidos com o intuito de obter informações antecipadas sobre essas ocorrências. Essas ferramentas podem ser utilizadas pelos órgãos públicos com o fim de minimizar os danos causados pelas cheias, através de uma previsão antecipada do pico das mesmas. Dentre esses trabalhos, destacam-se o de Córdoba-Machado *et. al.* [2016], de Schongart *et. al.* [2007] e o de Rodrigues *et. al.* [2015], que mostram a correlação das descargas da bacia Amazônica com padrões atmosféricos e oceânicos, como: a Temperatura da Superfície do Mar (do inglês, *Sea Surface Temperature – SST*) e o fenômeno climático *El Niño South Oscillation* (ENSO), e com as chuvas que ocorrem na região.

Nesse trabalho, pretendemos explorar novamente a predição da cheia do Rio Negro, procurando trazer para a área as seguintes contribuições: 1) comparar o desempenho de redes neurais com o método de aprendizado baseado em máquina de comitê, na previsão do pico da cheia do Rio Negro, através da utilização de índices climáticos e do nível do Rio Negro; 2) avaliar a previsão da cheia com 4, 3, 2 e 1 mês de antecedência; 3) propor uma classificação das cheias em faixas de valores/categorias e avaliar os erros dos preditores implementados, considerando a existência dessas faixas.

2. Materiais e Métodos

O diagrama em bloco da Figura 1 apresenta as etapas da metodologia proposta para realizar o treinamento dos preditores utilizados na previsão de cheias sazonais do Rio Negro, quais sejam: redes neurais artificiais e árvores de decisão.

No bloco a) da Figura 1, apresenta-se o conjunto de dados de entrada, composto por um conjunto inicial de variáveis: índices climáticos (ENSO e SOI) e os níveis do Rio Negro no período de 1951 – 2017. A partir do conjunto inicial são extraídas e selecionadas as nove melhores variáveis, segundo o método de seleção escalar de características, o qual foi modificado por Rodrigues *et. al.* [2015].

No bloco b) apresenta-se a metodologia de treinamento do comitê de árvores de decisão, que utilizam os métodos de aprendizado: *bagging* e *boosting*.

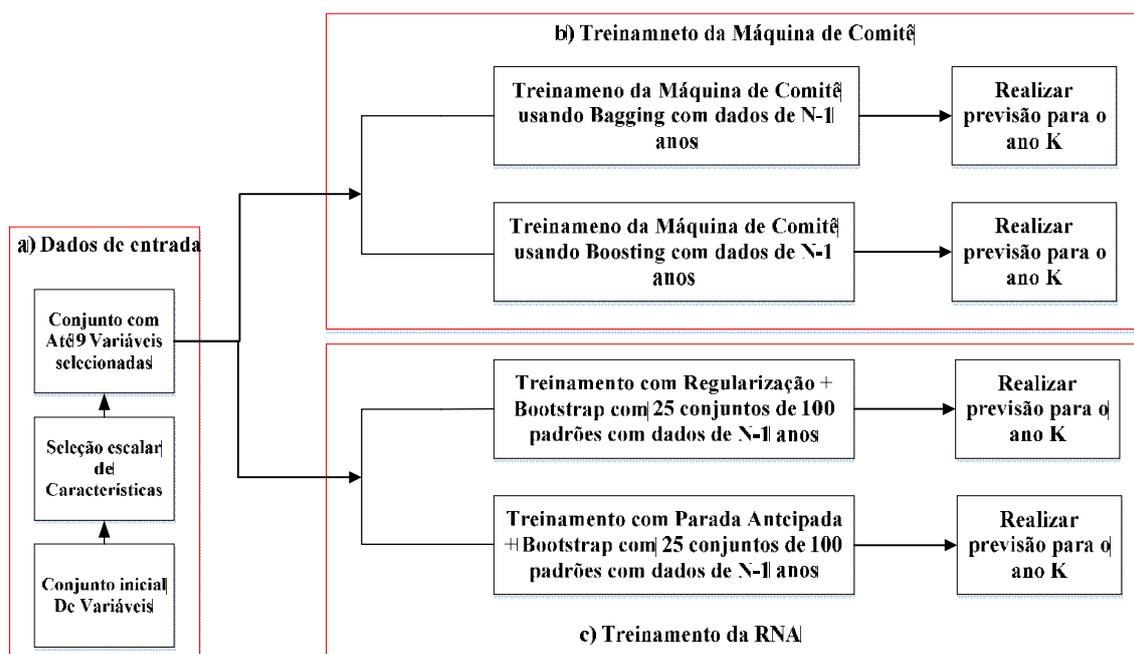


Figura 1. Metodologia utilizada para o treinamento dos preditores.

No bloco c) é apresentada a metodologia de treinamento usando RNA. Foram implementadas três arquiteturas de RNA, com diferentes números de neurônios nas camadas ocultas. No treinamento da RNA, o método *bootstrap* foi implementado com 25 conjuntos distintos.

2.1. Conjunto de dados

As variáveis utilizadas na entrada dos preditores foram índices climáticos e o nível do Rio Negro, obtidos num período de 67 anos ($N=67$), de 1951 à 2017. As cotas do Rio Negro foram coletadas no site da Agência Nacional de Águas – ANA [ANA, 2019] e na página oficial do Porto de Manaus [Porto de Manaus, 2018]. À semelhança dos trabalhos de Schongart *et al.* [2007] e Rodrigues *et al.* [2015] os índices climáticos utilizados foram: SST *El niño*₁₊₂, SST *El niño*₃, SST *El niño*₃₊₄, SST *El niño*₄ e o SOI [do inglês, *South Oscillation Index*]. Os valores dos índices climáticos foram coletados da página oficial do *Climate Prediction Center* [Climate Prediction Center, 2018]. Considerando que o pico das cheias ocorre no mês de junho tem-se que, quando a previsão é feita com 4 meses de antecedência, os valores dessas variáveis são extraídos dos meses de fevereiro, março, abril e maio. Quando a previsão é feita com 3 meses de antecedência, os valores dessas variáveis são extraídos dos meses de março, abril e maio. Quando a previsão é feita com 2 meses de antecedência, os valores dessas variáveis são extraídos dos meses de abril e maio. Quando a previsão é feita com 1 mês de antecedência, os valores dessas variáveis são extraídos do mês de maio.

2.2. Metodologia de previsão

Conforme já mencionado, os preditores utilizados neste trabalho são de dois tipos: redes neurais completamente conectadas e árvores de decisão.

A metodologia *leave-one-out* [Sonka, *et al.*, 2000] foi utilizada no treinamento dos preditores. Nessa metodologia, um determinado ano k , para o qual se deseja fazer a previsão, é removido do conjunto de N anos e o treinamento do preditor é efetuado com

os dados de (N-1) anos. Depois de treinado, o preditor é utilizado para realizar a previsão do ano que foi removido. Variando-se o valor de k faz-se a previsão da cheia para todos os anos do conjunto de dados.

Para a seleção dos conjuntos de variáveis, utilizou-se o método de seleção escalar de características, modificado por Rodrigues *et. al.* [2015]. Dessa forma, seleciona-se as nove (M=9) melhores características ou variáveis, procurando eliminar a redundância entre as mesmas. A Tabela 1 mostra o conjunto de variáveis utilizadas para o treinamento dos preditores em função da antecedência da previsão e ordenadas segundo o método de seleção de características aplicado.

Tabela 1. Conjunto de variáveis utilizadas para o treinamento dos preditores em função da antecedência da previsão e ordenadas pelo método de seleção de características modificado.

Ordem	Variáveis utilizadas para previsão segundo o período de antecedência em meses			
	4 meses	3 meses	2 meses	1 mês
1º	Nível do rio fevereiro	Nível do rio março	Nível do rio abril	Nível do rio maio
2º	SOI em janeiro	Nível do rio janeiro	Nível do rio fevereiro	Nível do rio março
3º	SOI em setembro	SOI em novembro	SOI em janeiro	Nível do rio janeiro
4º	Nível do rio janeiro	Nível do rio fevereiro	Nível do rio março	Nível do rio abril
5º	SOI em novembro	SOI em janeiro	Nível do rio janeiro	Nível do rio fevereiro
6º	Soi em dezembro	El Niño 3+4 dez	El Niño 3+4 fev	El Niño 3+4 jan
7º	El Niño 3+4 Jan	SOI em setembro	SOI em novembro	SOI em janeiro
8º	El Niño 3+4 Fev	El Niño 3+4 jan	SOI em setembro	SOI em novembro
9º	El Niño 3+4 Dez	El Niño 3+4 fev	El Niño 3+4 jan	SOI em setembro

2.3. Configuração e treinamento das redes neurais

Foram utilizadas arquiteturas de redes neurais artificiais (RNA) com 4 camadas. Três arquiteturas distintas foram utilizadas. Elas diferem no número de neurônios das camadas escondidas: M-6-6-1, M-8-8-1 e M-10-10-1. O Método de otimização de *Levenberg-Marquardt* foi empregado no treinamento. Na primeira e na segunda camada das redes, foi utilizada a função de ativação ‘*tansig*’. Essa função se aproxima mais da função identidade e, segundo [Matsunaga, 2012], é considerada uma melhor opção para ativação das camadas escondidas das RNAs. Cada arquitetura foi treinada utilizando duas combinações de métodos para melhoria da generalização: regularização L^2 ,+ *bootstrap* e parada antecipada (*Early Stop*) + *bootstrap*.

2.4. Método de regularização *Bootstrap*

O método de regularização *bootstrap* foi implementado utilizando-se 25 treinamentos distintos. Em cada treinamento, um conjunto de dados diferente é utilizado e uma nova inicialização dos parâmetros da rede (pesos e polarizações) é efetuada. Depois de treinada, a rede é então utilizada para prever o valor da cheia do ano k (ano excluído do conjunto de treinamento). A previsão final para o ano k é obtida calculando-se o valor médio das 25 previsões. No treinamento das redes o método *bootstrap* foi associado ao método de regularização L^2 e ao método de parada antecipada, respectivamente.

Os 25 conjuntos distintos de treinamento contêm, cada um, dados relativos a 100 anos. Como dispomos de apenas 67 anos (1951-2017) e sendo um deles retirado para se fazer a previsão (ano k), restam apenas 66 anos para o treinamento. Para se compor um conjunto de treinamento com dados relativos a 100 anos, os dados de alguns anos são repetidos de forma aleatória. A figura 2 ilustra o método *bootstrap* de treinamento da RNA.

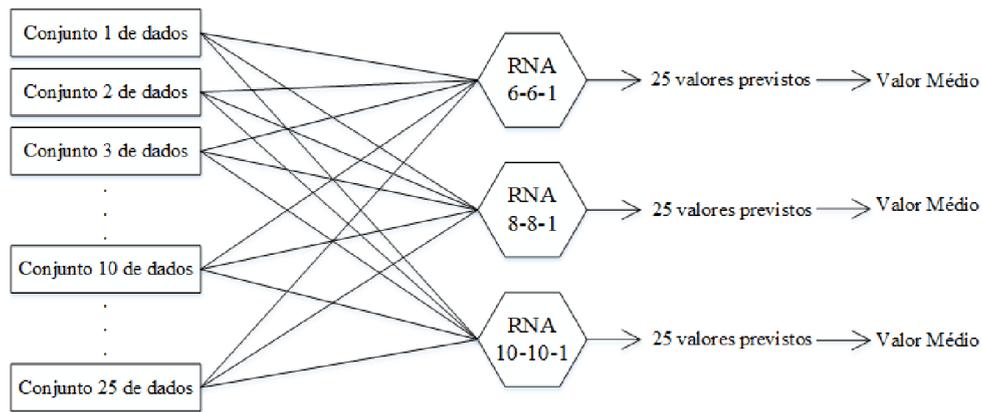


Figura 2. Método bootstrap de treinamento da RNA.

2.5 Métodos de *Bagging* e *Boosting*

Em aprendizado de máquina, tanto na classificação quanto na regressão, o conceito de comitê ou conjunto está associado a ideia de treinar-se múltiplos modelos utilizando o mesmo algoritmo. O objetivo é minimizar os erros devido a ruídos, polarização ou variância. Tanto no método de *bagging* quanto no de *boosting*, os diferentes conjuntos utilizados no treinamento dos modelos são produzidos por amostragem randômica, com reposição. No método *bagging*, qualquer padrão tem a mesma probabilidade de aparecer novamente em um novo conjunto de treinamento. Já no método *boosting*, os valores preditos erroneamente por um modelo anterior, têm maior probabilidade de aparecer novamente em um novo conjunto de treinamento. A ideia é que esse erro de predição possa ser corrigido. Árvores de decisão foram utilizadas com os métodos de *bagging* e *boosting*.

2.6 Avaliação do Desempenho dos preditores

2.6.1 Coeficiente de Correlação de Pearson

A primeira avaliação de desempenho dos preditores implementada foi através da utilização do coeficiente de correlação de Pearson, r_P , definido como o grau de associação entre duas variáveis aleatórias. Esse coeficiente é adimensional, com valores situados ente -1,0 e 1,0, e reflete a intensidade de uma relação linear entre dois conjuntos de dados (valores reais das cheias e valores preditos), com as seguintes condições: para $r_P=1$ significa uma correlação positiva perfeita entre duas variáveis; para $r_P=-1$ significa uma correlação negativa perfeita entre duas variáveis, isto é, se uma aumenta, a outra sempre diminui; para $r_P=0$ significa que as duas variáveis não dependem linearmente uma da outra. No entanto, pode existir uma outra dependência que seja "não linear". Assim, o resultado $r_P=0$ deve ser investigado por outros meios.

2.6.2 Faixas de enquadramento das cheias

É proposto a classificação das cheias de acordo os critérios apresentados na Tabela 2, em quatro categorias, a saber: cheia baixa – faixa 1, cheia média baixa - faixa 2, cheia média alta - faixa 3 e cheia alta - faixa 4. A discriminação dos valores de cota do rio para cada uma dessas faixas, baseou-se na consideração de que a distribuição dos picos de cheias do período de 1903 a 2017 assemelha-se a uma curva normal, cujo valor médio é M e o desvio padrão σ . Uma cheia é considerada média se o seu valor de pico estiver entre $M \pm \sigma$. Assim, 68,26% das cheias são consideradas como cheias médias. Dentro da classe de cheia média foi criada duas subclasses: média baixa ($M - \sigma$) e média alta ($M + \sigma$). Por fim,

se o pico da cheia for $< (M-\sigma)$ é considerada como baixa (15,87% das cheias) e se for $> (M+\sigma)$ é considerada alta (15,87% das cheias). Dessa forma, os valores de pico das faixas, apresentados na Tabela 2, são dinâmicos e mudam à medida em que novos registros de cheia estejam disponíveis, posto que mudarão os valores de M e σ . Para os registros de 1903 à 2017, o valor médio é $M = 27,87\text{m}$ e o desvio padrão é $\sigma=1,15\text{m}$.

Tabela 2. Faixas e classe de cheias em função da média e desvio padrão dos picos de cheias no período de 1903 a 2017 ($M = 27,87\text{m}$ e $\sigma=1,15\text{m}$)

Faixa	Critério de classificação	Valor	Classificação
1	$PC_p < (M-\sigma)$	$PC_p < 26,72\text{m}$	Baixa
2	$(M-\sigma) < PC_p < M$	$26,72\text{m} < PC_p < 27,87\text{m}$	Média Baixa
3	$M < PC_p < (M+\sigma)$	$27,87\text{m} < PC_p < 29,02\text{m}$	Média Alta
4	$PC_p > (M+\sigma)$	$PC_p > 29,02\text{m}$	Alta

PC_p : Pico da cheia previsto

2.6.3 Índices de Erro

A terceira maneira utilizada para avaliar o desempenho dos preditores foi através da utilização dos índices de erro propostos por Schongart *et al.* (2007). Os índices de erro, nomeados como Ind_1, Ind_2, Ind_3 e Ind_4, são descritos a seguir:

- **Ind_1**: número de previsões em que o valor absoluto da diferença entre o valor previsto e o real é inferior 0,5m;
- **Ind_2**: número de previsões em que o valor absoluto da diferença entre o valor previsto e o real situa-se entre 0,5m e 1m;
- **Ind_3**: número de previsões em que o valor absoluto da diferença entre o valor previsto e o real é superior a 1m e inferior a 1,5m;
- **Ind_4**: número de previsões em que o valor absoluto da diferença entre o valor previsto e o real é superior a 1,5m.

3. Resultados

Os algoritmos foram implementados utilizando o software Matlab R2018a. As diferenças entre os resultados obtidos com as diversas arquiteturas e métodos de generalização foram avaliadas através do teste de significância qui-quadrado (χ^2).

3.1. Redes Neurais Artificiais

Foram realizadas várias simulações com o objetivo de determinar qual associação de conjunto de variáveis de entrada [1, 2, 3, 4, 5, 6, 7, 8 e 9], arquitetura e método de generalização apresentam o melhor desempenho.

Na Tabela 3 são apresentados os valores obtidos para o coeficiente de Pearson e para os índices de erro, para as três arquiteturas de redes neurais, em função do número de variáveis de entrada, métodos de generalização e antecedência da previsão. Observa-se que os melhores resultados são obtidos ao utilizar-se RNA com o método de generalização de parada antecipada, com 8 variáveis de entrada, arquitetura 10-10-1 e quando se realizou a previsão da cheia com 1 mês de antecedência do pico máximo, isto é, no mês de maio. O coeficiente de correlação de Pearson, para essa situação, foi de $r_p=0,9592$. Verifica-se que 94,02% dos anos, a previsão possui um erro absoluto inferior a 0,5m e em 100% dos anos a previsão resultou em um erro absoluto menor que 1,5m.

Tabela 3. Resultados das simulações com 8 e 9 variáveis de entrada para as RNAs.

N. de variáveis	Arquit.	Regularização L^2 + Bootstrap					Parada Antecipada + Bootstrap				
		r_p	Ind_1	Ind_2	Ind_3	Ind_4	r_p	Ind_1	Ind_2	Ind_3	Ind_4
4 meses de antecedência											
8	6x6x1	0,6428	28	24	13	2	0,6632	27	30	9	1
	8x8x1	0,6879	39	17	7	4	0,7309	36	26	4	1
	10x10x1	0,6768	33	23	8	3	0,6942	27	34	5	1
9	6x6x1	0,719	32	26	7	2	0,6857	33	24	9	1
	8x8x1	0,6708	31	25	9	2	0,7171	34	23	9	1
	10x10x1	0,5936	32	19	12	4	0,6953	34	22	10	1
3 meses de antecedência											
8	6x6x1	0,7439	35	26	4	2	0,7983	35	28	3	1
	8x8x1	0,71	36	21	9	1	0,7977	38	24	3	2
	10x10x1	0,7135	36	20	9	2	0,7964	34	27	5	1
9	6x6x1	0,8048	39	19	9	0	0,8036	39	22	6	0
	8x8x1	0,7762	33	28	5	1	0,7944	37	24	6	0
	10x10x1	0,8187	41	20	5	1	0,8203	42	20	3	2
2 meses de antecedência											
8	6x6x1	0,8859	45	19	3	0	0,9238	55	11	1	0
	8x8x1	0,8421	43	21	2	1	0,8938	51	14	1	1
	10x10x1	0,8668	48	16	2	1	0,903	45	21	1	0
9	6x6x1	0,7772	39	22	3	3	0,8954	49	16	2	0
	8x8x1	0,7937	38	22	5	2	0,9087	52	14	1	0
	10x10x1	0,8664	42	23	2	0	0,8992	53	11	3	0
1 mês de antecedência											
8	6x6x1	0,9127	52	14	1	0	0,9556	64	2	1	0
	8x8x1	0,9223	51	16	0	0	0,958	63	4	0	0
	10x10x1	0,9457	60	7	0	0	0,9592	63	4	0	0
9	6x6x1	0,9081	51	15	1	0	0,9565	61	6	0	0
	8x8x1	0,9163	49	18	0	0	0,949	59	8	0	0
	10x10x1	0,9274	55	10	2	0	0,9486	58	8	1	0

Na Tabela 4 é apresentada a matriz de confusão para a classificação em faixas, utilizando-se os melhores preditores apresentados na Tabela 3, segundo o coeficiente de Pearson, para os dois métodos de generalização. A partir da Tabela 4, observa-se que, para o método de regularização L^2 , houve 49 acertos (elementos na diagonal principal) e 17 erros. Já, para o método de parada antecipada, houve 57 acertos e 10 erros. Assim, obtém-se uma acurácia de 74,62 % para o método de regularização L^2 e uma acurácia de 85,07% para o método de parada antecipada.

Para avaliar o desempenho das RNAs com os métodos de generalização (regularização L^2 e parada antecipada), aplicou-se o teste χ^2 (qui-quadrado) aos valores obtidos na Tabela 4, considerando o número de acertos e erros de cada método. Assim, o teste é aplicado a uma tabela de contingência com 2 colunas por 2 linhas, ou seja, com um grau de liberdade, $gl = 1$. O nível de significância adotado foi de 95%, com um valor crítico, $t_c = 3,84$. A hipótese nula é que não existe diferenças significativas entre os valores de acertos e erros obtidos com o método de regularização L^2 e de parada antecipada. O valor obtido de $\chi^2 = 5,11$. Como $\chi^2 > t_c$, a hipótese nula deve ser rejeitada, ou seja, existe diferença estatisticamente significativa entre o número de acertos e erros de ambos os métodos. Assim, o método de parada antecipada é superior ao método de regularização L^2 .

Tabela 4. Matriz de confusão para a classificação em faixas usando RNA.

		Regularização + Bootstrap				Parada Antecipada+ Bootstrap			
		Valores previstos				Valores previstos			
Faixas		1	2	3	4	1	2	3	4
Valores reais	1	3	4	0	0	4	3	0	0
	2	0	13	3	0	0	15	1	0
	3	0	3	27	2	0	2	29	1
	4	0	0	5	7	0	0	3	9

3.2. Resultados das Árvores de Decisão com Aprendizado Baseado em Comitê

Na Tabela 5 são apresentados os valores dos coeficientes de Pearson e dos índices de erro, para os métodos de *bagging* e *boosting*, em função do número de variáveis de entrada. Observa-se que os melhores resultados foram obtidos utilizando o método de *bagging*, apresentando $r_p = 0,9374$. Esse valor foi obtido utilizando 8 variáveis de entrada, selecionadas pelo método de seleção escalar de características modificado, a previsão da cheia foi realizada com 1 mês de antecedência do pico máximo, isto é, no mês de maio. Os resultados mostram que em 85,07% dos anos a previsão possui um erro menor do que 0,5m; em 98,51% dos anos a previsão resultou em um erro menor do que 1m; e em 100% dos anos a previsão resultou em um erro menor do que 1,5 m.

Tabela 5. Resultados das simulações para os métodos de Aprendizado usando árvores de decisão e aprendizado baseado em comitê.

N. de variáveis	<i>Bagging</i>				N. de variáveis	<i>Boosting</i>					
	r_p	Ind_1	Ind_2	Ind_3		Ind_4	r_p	Ind_1	Ind_2	Ind_3	Ind_4
4 meses de antecedência											
1	0,7091	31	26	9	1	1	0,6158	22	30	11	4
6	0,7145	30	30	6	1	2	0,6751	30	23	9	5
3 meses de antecedência											
1	0,8583	45	20	2	0	1	0,8089	35	24	8	0
6	0,8309	36	27	3	1	7	0,8172	38	24	4	1
2 meses de antecedência											
1	0,9077	49	17	1	0	4	0,904	48	18	1	0
4	0,9029	49	16	2	0	5	0,9012	50	16	1	0
1 mês de antecedência											
8	0,9374	57	9	1	0	8	0,9154	52	14	1	0
9	0,9353	57	9	1	0	9	0,9074	50	17	0	0

Na Tabela 6 é apresentada a matriz de confusão para a classificação em faixas, utilizando-se os melhores preditores apresentados na Tabela 5, segundo o coeficiente de Pearson, para os métodos *boosting* e *bagging*. A partir da Tabela 6, obtém-se uma acurácia de 82,09% para o método de *bagging* e uma acurácia de 74,63% para o método de *boosting*. Aplicando o teste χ^2 aos dados da Tabela 6, nas mesmas condições em que o mesmo foi aplicado à Tabela 4, calculamos o valor de $\chi^2 = 3,97$. Assim, como $\chi^2 > t_c$, a hipótese nula deve ser rejeitada, ou seja, existe diferença estatisticamente significativa entre o número de acertos e erros de ambos os métodos. Assim, o método de *bagging* é superior ao método de *boosting*, com árvore de decisão.

Tabela 6. Matriz de confusão para a classificação em faixas usando Árvores de Decisão com aprendizado baseado em comitê.

		<i>Bagging</i>				<i>Boosting</i>			
		Valores previstos				Valores previstos			
		Faixas	1	2	3	4	1	2	3
Valores reais	1	5	2	0	0	4	3	0	0
	2	1	13	2	0	2	10	4	0
	3	0	2	27	3	0	1	26	5
	4	0	0	2	10	0	0	2	10

4. Discussão e Conclusão

Inicialmente, destaca-se duas contribuições importantes deste trabalho. A primeira foi a previsão de cheias sazonais do rio Negro com antecedência de um a quatro meses em relação a ocorrência do pico da cheia, utilizando Redes Neurais Artificiais e Árvores de Decisão, com aprendizado baseado em comitê. Em trabalhos anteriores (Rodrigues et al. [2005] e Schongart *et al.* [2007]), essa previsão era feita com apenas 4 meses de antecedência. A segunda foi a classificação das cheias em faixas, através de uma metodologia de enquadramento que considera a média e o desvio padrão dos picos das cheias ocorridas num dado período (neste caso, de 1903 a 2017). Esse enquadramento em faixas possibilita uma nova avaliação do desempenho dos preditores através de matrizes de confusão e permite aos órgãos públicos anunciarem as previsões das cheias de forma mais intuitiva, do que simplesmente anunciando números.

A partir dos resultados apresentados anteriormente, conclui-se que os melhores resultados deste trabalho foram obtidos utilizando-se RNA com o método de generalização de parada antecipada. No entanto, ao se aplicar o teste de χ^2 aos resultados obtidos nas Tabelas 4 e 6, com os métodos de parada antecipada e *bagging* com árvores de decisão, respectivamente, obteve-se um valor de $\chi^2 = 2,03$. Assim, como $\chi^2 < t_c$, a hipótese nula deve ser aceita, ou seja, não existe diferença estatisticamente significativa entre o número de acertos e erros de ambos os métodos. Assim, o método de parada antecipada não é superior ao método de *bagging* com árvores de decisão.

A Tabela 7 apresenta uma comparação entre os três Índices de Erro dos melhores resultados obtidos nesse trabalho utilizando RNA e máquina de comitê, com o melhor resultado obtido por Rodrigues *et al.* [2015], considerando 4 meses de antecedência. Observa-se que os percentuais de acerto foram levemente superiores àqueles obtidos por Rodrigues *et al.* [2015].

Uma característica importante da metodologia empregada é que a mesma faz uso de comitês de preditores, o que confere maior credibilidade aos resultados obtidos.

Uma limitação no desenvolvimento do trabalho é que os dados disponíveis para treinamento, validação e teste dos preditores são bem limitados, referindo-se apenas a um período de 67 anos, que vai de 1903 a 2017. Face a essa limitação, objetivando maximizar o conjunto de treinamento, utilizamos o método *leave-one-out* para o treinamento e teste dos preditores. Nesse contexto, as redes neurais artificiais tiveram um desempenho superior às árvores de decisão.

Tabela 7. Comparação de desempenho entre o preditor RNA deste trabalho e o implementado por Rodrigues et.al. (2015) para previsão de cheias com 4 meses de antecedência.

Erro	RNA implementada por Rodrigues et.al. (2015)	*RNA	*Máquina Comitê
Ind_1 [erro \leq 0,5m]	51,56%	53,73%	44,77%
Ind_1 + Ind_2 [erro \leq 1m]	92,18%	92,53%	89,55%
Ind_1 + Ind_2 + Ind_3 [erro \leq 1,5m]	98,43%	98,51%	98,51%

*preditores implementados nesse trabalho.

Embora esse trabalho dedique-se a previsão de cheias, a abordagem utilizada não fez uso de séries temporais. O treinamento de ambos os métodos empregados, redes neurais e árvores de decisão, fez uso de técnicas supervisionadas, com pares entrada saída [9,1], sendo as 9 variáveis apresentadas paralelamente à entrada da rede, para a previsão do nível da cheia do ano a que as mesmas se referem. Em trabalhos futuros pretende-se utilizar uma abordagem sequencial de entrada de informações nos preditores, através da utilização de redes recorrentes, uni e bidirecionais, e comparar os resultados das previsões das cheias com aqueles ora obtidos.

Agradecimentos

Essa pesquisa foi suportada pela Samsung Eletrônica da Amazônia Ltda, sob os termos da Lei Federal 8.387/91, através de convênio firmado com o CETELI/UFAM.

5. Referências

- Climate Prediction Center. [2018]. “NOAA Center for Weather and Climate Prediction”. Climate Prediction Center. [Online] 2018. [Citado em: 14 de Junho de 2018.] <ftp://ftp.cpc.ncep.noaa.gov/wd52dg/data/indices/sstoi.indices>.
- Córdoba-Machado, Samir , *et.al.* [2016]. “Seasonal streamflow prediction in Colombia using atmospheric and oceanic patterns”. Journal of Hydrology. 2016, Vol. 538.
- Matsunaga, Victoria Yukie. [2012]. “Curso de Redes Neurais Utilizando o Matlab”. Belém - Pará : s.n., 2012.
- MMA [2007] “Atlas das Áreas Susceptíveis à Desertificação do Brasil”, Brasília.
- Porto de Manaus. [2018]. [Online] 2018. [Citado em: 13 de Julho de 2018.] <https://www.portodemanaus.com.br/?pagina=niveis-maximo-minimo-do-rio-negro>.
- Rodrigues, Márcio M., Costa, Marly G. F. e Filho, Cícero F. F. C. [2015]. “Proposta de um Método para Previsão de Cheias Sazonais Utilizando Redes Neurais Artificiais: Uma Aplicação ao Rio Amazonas”. Google Scholar. 2015.
- Schongart, Jochen e Junk, Wolfgang J. [2007]. “Forecasting the flood-pulse in Central Amazonia by ENSO-indices”. Journal of Hydrology. 335, 2007.
- Sonka, Milan e Fitzpatrick, J. Michael. [2000]. “Medical Image Processing and Analysis”. Washington : Spie Press, 2000.
- Zhou, Zhi-Hua. [2012]. “Ensemble Methods: Foundations and Algorithms”. Boca Raton: CRC Press, 2012. 978-1-4398-3005-5.