

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
CAMPUS MACAÉ
CURSO DE GRADUAÇÃO EM ENGENHARIA CIVIL

JULIA DA SILVA GODINHO

PREVISÃO HIDROLÓGICA NA BACIA HIDROGRÁFICA DO RIO MACAÉ COM
REDES NEURAIS

MACAÉ
2021

JULIA DA SILVA GODINHO

PREVISÃO HIDROLÓGICA NA BACIA HIDROGRÁFICA DO RIO MACAÉ COM
REDES NEURAIAS

Trabalho de conclusão de curso de graduação apresentado a Universidade Federal do Rio de Janeiro como parte dos requisitos para obtenção do grau de Bacharel em Engenharia Civil.

Orientador: Profa. Janaina Sant'Anna Gomide Gomes
Co-orientador: Prof. Rafael Malheiro da Silva do Amaral Ferreira

MACAÉ

2021

CIP - Catalogação na Publicação

GG585p Godinho, Julia da Silva
Previsão Hidrológica na Bacia Hidrográfica do Rio
Macaé com Redes Neurais / Julia da Silva Godinho. -
Rio de Janeiro, 2021.
59 f.

Orientadora: Janaina Sant'Anna Gomide Gomes.
Coorientador: Rafael Malheiro da Silva do Amaral
Ferreira.

Trabalho de conclusão de curso (graduação) -
Universidade Federal do Rio de Janeiro, Campus
Macaé Professor Aloísio Teixeira, Bacharel em
Engenharia Civil, 2021.

1. Previsão hidrológica. 2. Recursos Hídricos. 3.
Bacia Hidrográfica do Rio Macaé. 4. Aprendizado de
Máquina. 5. Redes Neurais Artificiais . I. Gomes,
Janaina Sant'Anna Gomide, orient. II. Ferreira,
Rafael Malheiro da Silva do Amaral, coorient. III.
Título.



**ATA DE DEFESA DE TRABALHO DE CONCLUSÃO DE CURSO – TCC
ENGENHARIA CIVIL**

ALUNO: Julia da Silva Godinho

DRE: 115050011

TÍTULO: Previsão Hidrológica da Bacia Hidrográfica do Rio Macaé com Redes Neurais

ORIENTADOR(ES): Janaína Sant'Anna Gomide Gomes e Rafael Malheiro da Silva do Amaral Ferreira

LOCAL DE REALIZAÇÃO: Google Meet <https://meet.google.com/tvc-mfwe-uag>

O professor orientador, na qualidade de Presidente da banca, iniciou os trabalhos às 15 horas, concedendo ao aluno um tempo de 40 minutos para exposição oral de sua monografia. Dando prosseguimento, o aluno foi arguido pelos examinadores. A seguir, o Presidente da banca abriu a palavra à plateia. Ao final, a Banca Examinadora avaliou o trabalho apresentado pelo aluno e atribuiu grau de:

- APROVADO SEM RESTRIÇÕES
 APROVADO COM RESTRIÇÃO (necessária a realização de correções para aprovação, em, no máximo, 30 dias)
 REPROVADO

Macaé, 09 de junho de 2021

BANCA EXAMINADORA:

Orientador: Prof. D.Sc. Janaína Sant'Anna
Gomide Gomes
Universidade do Rio de Janeiro –
UFRJ/Macaé

Co-orientador: Prof. D.Sc. Rafael Malheiro da
Silva do Amaral Ferreira
Universidade do Rio de Janeiro –
UFRJ/Macaé

Prof. M.Sc. Beatriz Rohden Becker
Universidade do Rio de Janeiro –
UFRJ/Macaé

Prof. D.Sc. Laura Emmanuella Oliveira
Universidade Federal do Rio Grande do Norte

AGRADECIMENTOS

A Deus, que me sustentou até este momento e a quem dedico minha vida como forma de gratidão pelo seu favor imerecido.

A minha família, em especial meus pais, Cleide Lúcia e Paulo Roberto, a quem espero um dia retribuir ao menos uma parcela do que dedicaram das suas vidas a mim. Ao Vitor Jesus, que faz parte da família que eu escolhi, por acreditar em mim e por ter feito o trabalho de Estradas I todo sozinho.

Aos amigos da faculdade, com quem compartilho as dificuldades da graduação e quem sem a ajuda deles provavelmente ainda estaria fazendo Física I.

À equipe do Aprenda a Programar Jogando, que será responsável pelas memórias mais carinhosas que levarei da faculdade.

Aos professores da UFRJ Campus-Macaé pelos ensinamentos e pela disponibilidade. Em especial, a minha orientadora Profa. Janaína Gomide, com quem tive minha primeira aula na graduação e com quem tenho o prazer de encerrar o curso sob sua atenciosa orientação.

RESUMO

A previsão hidrológica é uma ferramenta útil para lidar com problemas socioambientais e técnicos, podendo ser utilizada em sistemas de alertas de desastres naturais, gerenciamento de obras hídricas e como auxílio na tomada de decisão de políticas públicas. Baseado nisso, esse trabalho apresenta a aplicação de um modelo hidrológico baseado em Redes Neurais Artificiais do tipo perceptron de múltiplas camadas (MLP), a fim de prever o nível da estação fluviométrica Fazenda Airis situada na bacia hidrográfica do rio Macaé. Para tal, foram utilizados registros diários de estações fluviométricas e pluviométricas, do período de 2010 a 2013, disponibilizados pela Agência Nacional de Águas (ANA) e pelo Sistema de Alerta de Cheias do Instituto Estadual do Ambiente (INEA). A metodologia adotada investiga a influência das variáveis de entrada e arquitetura nas redes no desempenho dos modelos. Os resultados obtidos foram considerados muito satisfatórios e sustentam a proposição do potencial das Redes Neurais Artificiais para previsão hidrológica. Obteve-se que dos 189 modelos criados 42,3% tiveram o coeficiente de determinação R^2 acima de 0,80. A melhor RNA desenvolvida recebeu dados diários de 6 estações pluviométricas e de 1 estação fluviométrica, obtendo para as métricas R^2 , MAE os valores 0,88 e 7,03 cm, respectivamente. Por fim, os resultados ainda foram comparados com modelos desenvolvidos em trabalhos relacionados.

Palavras-chave: Redes Neurais Artificiais. Modelagem hidrológica. Bacia hidrográfica do Rio Macaé.

ABSTRACT

Hydrological forecasting is a valuable tool for dealing with socio-environmental problems, and it can be used in natural disaster alert systems and as assistant aid in making public policies. This work presents an application of a hydrological model based on Artificial Neural Networks (ANN). The variable modeled was the flood stage of the fluviometric station Fazenda Airis, located in the drainage basin of the Macaé River. To this end, were used daily records of flow and rainfall stations between 2010 to 2013, made available by the National Water Agency (ANA) and the INEA Flood Alert System, were used. The adopted methodology investigates the influence of the input variables and ANN architecture on the models' performance. The results obtained were considered very satisfactory and support the proposition of the potential of Artificial Neural Networks for hydrological forecasting. It was found that of the 189 models created, 42.3 % had the coefficient of determination R^2 above 0.80. The best ANN developed received daily data from six rainfall stations and one fluviometric station, obtaining for metrics R^2 , MAE the values of 0.88, 7.03 cm, respectively. Finally, The results were compared with related works.

Keywords: Artificial Neural Networks. Hydrological forecasting. Drainage Basin of the Macaé River.

LISTA DE ILUSTRAÇÕES

Figura 1 – Componentes do ciclo hidrológico	16
Figura 2 – Monitoramento de chuvas: (a) pluviógrafo (b) pluviograma (CARVALHO; SILVA, 2016)	17
Figura 3 – Hidrograma típico resultante da ocorrência de uma precipitação na área contribuinte. Adaptado de (TUCCI et al., 2012)	18
Figura 4 – Neurônio artificial. Adaptado de (HAYKIN, 1999)	21
Figura 5 – Funções de ativação tangente hiperbólica (tanh) e linear retificada (ReLU) (MÜLLER; GUIDO, 2016)	22
Figura 6 – Representação gráfica de uma rede neural do tipo perceptron de múltiplas camadas (MLP)	23
Figura 7 – Ilustração dos processos de <i>overfitting</i> e <i>underfitting</i>	24
Figura 8 – Regularização por parada antecipada. Adaptado de (GÉRON, 2019)	25
Figura 9 – Etapas da elaboração do trabalho	26
Figura 10 – Região hidrográfica VIII - Macaé e Das Ostras	27
Figura 11 – Fluviograma e pluviograma da Fazenda Airis entre 2010 e 2013	28
Figura 12 – Frequência das arquiteturas com coeficiente de determinação R^2 igual ou maior a 0,80 (Tabela 5)	35
Figura 13 – Frequência das alternativas de entrada nos modelos com coeficiente R^2 acima de 0,80 (Tabela 5)	37
Figura 14 – M1C4N10: a) previsão do conjunto de teste b) gráfico de dispersão	39
Figura 15 – M2C1N5: (a) previsão do conjunto de teste (b) gráfico de dispersão	39
Figura 16 – M3C1N20: (a) previsão do conjunto de teste (b) gráfico de dispersão	40
Figura 17 – M4C4N20: (a) previsão do conjunto de teste (b) gráfico de dispersão	41
Figura 18 – M5C2N50: (a) previsão do conjunto de teste (b) gráfico de dispersão	42
Figura 19 – M6C4N20: (a) previsão do conjunto de teste (b) gráfico de dispersão	43
Figura 20 – M7C1N80: (a) previsão do conjunto de teste (b) gráfico de dispersão	44
Figura 21 – M8C1N5: (a) previsão do conjunto de teste (b) gráfico de dispersão	44
Figura 22 – M9C4N100: (a) previsão do conjunto de teste (b) gráfico de dispersão	45

LISTA DE TABELAS

Tabela 1 – Estações Pluviométricas da bacia hidrográfica do rio Macaé selecionadas	27
Tabela 2 – Postos fluviométricos da bacia do rio Macaé selecionadas	28
Tabela 3 – Alternativas de dados de entrada com as variáveis usadas, a defasagem dos dados em dias, intervalo da série histórica e número de registros que cada modelo recebe no treinamento.	30
Tabela 4 – Hiperparâmetros considerados no treinamento das RNAs	31
Tabela 5 – Modelos com coeficiente acima de determinação R^2 igual ou acima de 0,80.	35
Tabela 6 – Melhores modelos para cada alternativa de entrada, usando como referência o coeficiente de determinação R^2 . Onde, M é alternativa de entrada (Tabela 3) e a defasagem dos dados é dada em dias.	36
Tabela 7 – Cinco melhores resultados para a alternativa de entrada 1.	38
Tabela 8 – Cinco melhores modelos para a alternativa de entrada 2	39
Tabela 9 – Cinco melhores modelos para a alternativa de entrada 3	40
Tabela 10 – Cinco melhores modelos para a alternativa de entrada 4	41
Tabela 11 – Cinco melhores modelos para a alternativa de entrada 5	42
Tabela 12 – Cinco melhores modelos para a alternativa de entrada 6	42
Tabela 13 – Cinco melhores modelos para a alternativa de entrada 7	43
Tabela 14 – Cinco melhores modelos para a alternativa de entrada 8	44
Tabela 15 – Cinco melhores modelos para a alternativa de entrada 9	45
Tabela 16 – Estudos de aplicação de Redes Neurais Artificiais para previsão hidrológica, com autores e ano de publicação, variáveis do conjunto de entrada, extensão da série histórica, saída do modelo de previsão e melhores métricas obtidas.	47

LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas
DNOS	Departamento Nacional de Obras e Saneamento
INEA	Instituto Estadual do Ambiente
MAE	Erro Médio Absoluto
MAPE	Média Percentual Absoluta do Erro
ML	Machine Learning, ou Aprendizado de Máquina
MLP	Perceptron de Múltiplas Camadas
NS	Coefficiente de Desempenho Nash-Sutcliffe
ReLU	Função Linear Retificada
RMSE	Raiz do Erro Médio Quadrático
RNA	Redes Neurais Artificiais
RNN	Redes Neurais Recorrentes
r_p	Coefficiente de Correlação de Pearson
TSM	Temperatura na Superfície do Mar

SUMÁRIO

1	INTRODUÇÃO	11
1.1	OBJETIVOS	12
1.2	MOTIVAÇÃO E JUSTIFICATIVA	12
1.3	ESTRUTURA DO TRABALHO	12
2	TRABALHOS RELACIONADOS	14
3	CONCEITOS GERAIS	16
3.1	CICLO HIDROLÓGICO	16
3.1.1	Balanco hídrico	18
3.2	MODELOS HIDROLÓGICOS	19
3.3	APRENDIZADO DE MÁQUINA	20
3.4	REDES NEURAIS ARTIFICIAIS	21
3.4.1	Neurônio Artificial	21
3.4.2	Perceptron de Múltiplas Camadas	22
3.4.2.1	Generalização	24
4	MATERIAIS E MÉTODOS	26
4.1	ESCOLHA DA ÁREA DE ESTUDO	26
4.2	COLETA DOS DADOS	26
4.2.1	Precipitação	27
4.2.2	Vazão e Nível	28
4.3	TRATAMENTO DOS DADOS	29
4.4	DEFINIÇÃO DOS MODELOS DE ENTRADA	29
4.5	TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS	31
4.6	ANÁLISE DE DESEMPENHO	32
4.6.1	Erro Médio Absoluto (MAE)	32
4.6.2	Erro Médio Quadrático (MSE)	33
4.6.3	Coefficiente de Determinação	33
5	RESULTADOS E DISCUSSÕES	34
5.1	ARQUITETURA	34
5.2	CONJUNTO DE DADOS DE ENTRADA	36
5.3	ANÁLISE POR ALTERNATIVA DE ENTRADA	38
5.4	COMPARAÇÃO COM TRABALHOS RELACIONADOS	45
6	CONCLUSÃO	48

REFERÊNCIAS	50
ANEXO A – RESULTADOS DAS REDES NEURAS ARTIFICIAIS	54

1 INTRODUÇÃO

Inundações são fenômenos naturais decorrentes da elevação do nível da água em uma seção fluvial, ocasionada por eventos de chuva extremos, e podem ser intensificados por intervenções humanas. O Rio de Janeiro está entre os seis estados brasileiros com maior número de desastres naturais registrados, onde 65% de todas as ocorrências estão associadas a inundações (IKEMOTO et al., 2015). Esta alta incidência se deve, em parte, ao processo de urbanização e a canalização de rios. Haja vista o processo de urbanização promover o aumento da impermeabilização, escoamento superficial, ocupação do solo e construção de condutos pluviais, ocasionando o aumento dos picos de vazão máxima durante eventos pluviométricos (TUCCI; SILVEIRA, 2001).

A previsão hidrológica de curto prazo é uma das ferramentas empregadas na gestão de risco a desastres, devido a sua capacidade de prever situações futuras com antecedência de poucos dias ou horas. É comumente utilizada no sistema de alerta de desastres naturais e permite ao usuário da informação se antecipar a este evento extremo, além de auxiliar nos processos de tomadas de decisão nas políticas públicas (NETO et al., 2020).

O Centro Nacional de Monitoramento e Alerta de Desastres Naturais (Cemaden), criado em 2011 pelo governo federal, é o órgão responsável pelo monitoramento de eventos meteorológicos e ameaças naturais em municípios brasileiros suscetíveis à ocorrência de desastres naturais, além de realizar pesquisas para a melhoria de seu sistema de alerta antecipado. Observando o potencial das técnicas de inteligência computacional para construção de modelos hidrológicos, o Cemaden possui uma linha de pesquisa de modelagem de dados hidrometeorológicos por meio de técnicas de Aprendizado de Máquina, como Árvore de Decisão (LIMA; SCOFIELD, 2017). No entanto, a maior ênfase é dada aos modelos de Redes Neurais Artificiais (RNA) aplicados à previsão de curto prazo de inundações (SILVA et al., 2016). Como resultado, um modelo baseado em RNA capaz de realizar previsão de nível com 120 minutos de antecedência já se encontra em operação, como suporte no tomada de decisões do Cemaden, conforme relatado em (LIMA et al., 2016).

Os modelos de Redes Neurais Artificiais possuem capacidade de modelar sistemas não-lineares complexos com grande quantidade de dados e com um conjunto reduzido de parâmetros. Sendo particularmente úteis em situações nas quais as relações dos processos físicos não são completamente compreendidas (GÉRON, 2019). Baseado nisso, os modelos de RNAs oferecem um boa alternativa na gestão de riscos e desastres naturais provenientes de fenômenos hidrológicos e têm sido usados com sucesso, apresentando bons resultados na modelagem chuva-vazão (NETO et al., 2020).

1.1 OBJETIVOS

OBJETIVO GERAL

O objetivo deste trabalho é aplicar um modelo baseado em Redes Neurais Artificiais para previsão hidrológica em base diária na bacia hidrográfica do rio Macaé. Isso será possível por meio da combinação de diferentes conjuntos de dados, que abrangem dados pluviométricos e fluviométricos diários e da análise dos hiperparâmetros das RNAs.

OBJETIVOS ESPECÍFICOS

- Demonstrar a aplicação da técnica de RNA para a previsão do nível diário da estação fluviométrica Fazenda Airis, localizada no médio curso da bacia hidrográfica do rio Macaé;
- Avaliar diferentes combinações de variáveis de entrada e analisar sua influência na modelagem hidrológica frente aos resultados obtidos;
- Analisar a influência da arquitetura da RNA no desempenho dos modelos de previsão gerados;
- Confrontar os resultados obtidos com modelos de trabalhos relacionados.

1.2 MOTIVAÇÃO E JUSTIFICATIVA

A motivação para a realização desse trabalho parte das ocorrências de desastres naturais decorrente do aumento dos níveis dos rios e dos benefícios da previsão a eventos futuros para a gestão de recursos hídricos.

O trabalho é relevante do ponto de vista prático, pois explora uma técnica que tem demonstrado bom desempenho em aplicações de previsão hidrológica, utilizando de dados já existentes na rede de monitoramento de recursos hídricos. Proposta ainda não explorada na bacia hidrográfica em questão.

Do ponto de vista acadêmico, o trabalho envolve importantes fundamentos de aprendizado de máquina aplicados a soluções de problemas de Engenharia Civil e gestão de recursos hídricos.

1.3 ESTRUTURA DO TRABALHO

O segundo capítulo desse trabalho refere-se à revisão bibliográfica de trabalhos relacionados que abordam a aplicação de RNAs na modelagem hidrológica.

Com o objetivo de contextualizar o problema proposto, o terceiro capítulo traz um revisão geral sobre os principais conceitos utilizados no presente trabalho. Serão revisados os conceitos de ciclo hidrológico e modelagem hidrológica. Este capítulo apresenta ainda

uma introdução sobre a técnica de Aprendizado de Máquina, as aplicações e classificações. Em destaque, será abordada a técnica de Redes Neurais Artificiais, observando seus parâmetros e como a alteração destes influenciam no desempenho dos modelos.

O quarto capítulo refere-se ao estudo de caso, onde é apresentada a área de estudo, a bacia hidrográfica do rio Macaé, assim como todos os dados utilizados e os tratamentos destes. É feita uma exposição da metodologia adotada, que consiste na investigação dos parâmetros e dos vetores de entrada das RNAs para previsão hidrológica. Esse capítulo traz ainda a descrição dos treinamentos e as métricas utilizadas na avaliação dos modelos.

O quinto capítulo apresenta os resultados obtidos pelas RNAs, analisando a influência da arquitetura e dos vetores de entrada no desempenho das previsões. A aplicabilidades de cada conjunto de variáveis é discutida pela observação gráfica das previsões. Por fim, esse capítulo traz uma análise comparativa, onde o desempenho da melhor RNA produzida é confrontada com os melhores resultados obtidos em trabalhos relacionados.

O último capítulo traz as conclusões obtidas a partir dos resultados dos experimentos e analisa possíveis abordagens para a continuidade desse tema em trabalho futuros.

2 TRABALHOS RELACIONADOS

Nesta seção serão apresentados trabalhos relacionados na implementação de Redes Neurais Artificiais (RNA) na modelagem hidrológica.

Estudos têm avaliado o desempenho de modelos baseados em RNAs na modelagem hidrológica, observando a aplicabilidade da técnica em emissão de alertas e gestão de recursos hídricos (SHAMSELDIN, 2010; LIMA et al., 2016; ROY; GUPTA; GOSWAMI, 2012; LEKKAS et al., 2004; FERREIRA; LIMA, 2018). Nesse contexto, em (DEBASTIANI; SILVA; NETO, 2016) os autores testaram doze tratamentos de dados com combinações de variáveis de precipitação, evapotranspiração e vazão, além de transformações e deslocamentos temporais dessas para a previsão hidrológica em escala diária. Os vetores de entrada foram definidos após uma análise exploratória de correlação entre as variáveis hidroclimáticas. O melhor modelo de previsão com coeficiente de determinação de 0,868 foi obtido pela combinação dos dados de precipitação com tempo de resposta de dois dias e vazão com tempo de resposta de um dia.

De forma semelhante, os autores em (SILVA et al., 2016) investigaram a melhor combinação dos vetores de entrada com dados diários de precipitação e vazão de uma sub-bacia hidrográfica situada no litoral norte de São Paulo, no intervalo de 1985 a 1989. Encontrou-se que o uso simultâneo de dados de precipitação e de vazão resultaram em RNAs melhores, com coeficientes Nash-Sutcliffe de 0,77. Dessa forma, os autores destacaram a necessidade da promoção do monitoramento contínuo das duas variáveis.

Alguns trabalhos utilizam a técnica de RNAs para previsão em escala mensal, como o trabalho apresentado em (MACHADO, 2005), que propõe um modelo hidrológico utilizando dados de precipitação, vazão e evapotranspiração potencial para a previsão de vazão no Rio Jangada, Paraná. As melhores RNAs apresentaram coeficiente de correlação igual a 96,9%. O bom resultado obtido foi associado à metodologia adotada, a qual considerou a influência do número de neurônios na camada de entrada e na camada intermediária, o número de *epochs*, a inicialização e extensão da série de dados. Identificou-se que o número de neurônios de entrada está relacionado com a extensão do conjunto de dados, sugerindo que o aumento dos vetores de entrada deve ser acompanhado pelo aumento da extensão dos dados de treinamento.

Para a previsão hidrológica em curto prazo, em (MATOS; PEDROLLO; CASTRO, 2014) os autores propõem alternativas de controle a montante, onde foram empregados dados diários e horários de precipitação e vazão da Ponte Mística e vazões de sub-bacias localizadas a montante do exutório da Ponte Mística, posto alvo das previsões. A partir desta metodologia, observou-se que a utilização de valores de entrada defasados em um dia resultou na melhora de cinco das oito alternativas de controle a montante treinados. Ainda foi possível concluir que a eficiência das RNAs tende a aumentar com a proporção

da área controlada das sub-bacias usadas no treinamento, que obtiveram coeficientes Nash-Sutcliffe entre 0,89 e 0,97.

A metodologia adotada em (SOUSA; SOUSA, 2010) investiga a arquitetura da RNA, variando os neurônios nas camadas de entrada e intermediária e a função de transferência, utilizando dados de um posto fluviométrico e cinco postos pluviométricos. Encontrou-se que uma RNA com dados de entrada normalizados, 15 neurônios na camada oculta e com função de ativação sigmoide logarítmica é capaz de prever com 77,0% de eficiência a vazão média da bacia hidrográfica do rio Piancó. Outros autores adotaram a abordagem de investigação da arquitetura da RNA e dados de entrada para determinar o melhor modelo de previsão (CELESTE; MENEZES; FONTES, 2014; CRISTALDO et al., 2018; OLIVEIRA; PEDROLLO; CASTRO, 2011; NETO et al., 2020; SILVA; CASTRO; VIEIRA, 2018).

Alguns exemplos comparam outras técnicas de Aprendizado de Máquina com as RNAs. (BATISTA, 2009) implementou modelos de séries temporais de Box & Jenkins e RNAs do tipo perceptron de múltiplas camadas na previsão de vazão do rio Grande, afluente ao reservatório da usina hidrelétrica de Camargos-MG. Identificou-se que as RNAs se adequaram aos dados em questão e encontraram resultados superiores às séries temporais. Ainda considerando a abordagem proposta pelo ML, o trabalho apresentado em (SOUSA; GUEDES; OLIVEIRA, 2018) comparou os algoritmos de Árvores de Decisão, Floresta Aleatórias, Regressão Logística e RNAs para previsão do volume anual de chuva em Manaus. Após o treinamento e testes de mais de 4.000 modelos com parâmetros distintos, foi verificado que as RNAs obtiveram as melhores performances.

Trabalhos recentes também tem apresentado resultados interessantes na área de previsão de séries temporais implementando as Redes Neurais Recorrentes (RNN). As RNNs são redes que possuem realimentação das saídas para as entradas, diferente das RNAs onde há conexões somente com os neurônios da camada seguinte (FREIRE; JR; BARRETO, 2009). Explorando a aplicação de RNN com camadas Long Short-Term Memory (LSTM), o trabalho apresentado em (VASSALLI, 2018) propõe a previsão de vazão em rios da bacia hidrográfica do Paraíba do Sul utilizando dados de precipitação e vazão. Por meio de estudos comparativos com outros modelos de ML e RNNs com diferentes níveis de complexidade, essa técnica se mostrou adequada para previsão de vazão após os resultados satisfatórios obtidos nos experimentos.

Nesse trabalho é proposta a aplicação de modelos de previsão hidrológica em base diária baseado em Redes Neurais Artificiais, sendo uma proposta inédita para a área de estudo escolhida, a bacia hidrográfica do rio Macaé, localizada no litoral do Estado do Rio de Janeiro. Para tal, serão investigadas as variáveis de entrada e os hiperparâmetros das RNAs.

3 CONCEITOS GERAIS

A seguir serão apresentados os principais temas abordados nesse trabalho, de maneira a contextualizar o leitor dos conceitos que envolvem a modelagem hidrológica baseada em técnicas de Aprendizado de Máquina.

3.1 CICLO HIDROLÓGICO

O conceito de ciclo hidrológico está ligado à circulação fechada da água, nos seus diferentes estados físicos, entre a superfície terrestre e a atmosfera (Figura 1).




Figura 1 – Componentes do ciclo hidrológico

Este movimento é impulsionado pelo Sol, que fornece a energia para mudar o estado físico e elevar a água da superfície terrestre para a atmosfera, e à gravidade, que faz com que a água condensada caia e que, uma vez na superfície, circule através de linhas de água que se reúnem em rios até atingir os oceanos ou se infiltre nos solos e nas rochas, através dos seus poros, fissuras e fraturas (CARVALHO; SILVA, 2016).

O ciclo hidrológico pode ser descrito pelas seguintes etapas:

a) Precipitação

O processo de precipitação é definido como sendo toda água proveniente do meio atmosférico que atinge a superfície terrestre na forma de chuva, neve ou granizo.

No caso das chuvas, para que ocorram, é necessário que as gotículas de água cresçam a partir de “núcleos de condensação” até atingirem um peso suficiente capaz de sobrepor as forças de sustentação e se precipitarem (MIRANDA; OLIVEIRA; SILVA, 2010).

A parcela de precipitação que atinge o solo pode infiltrar ou escoar superficialmente, a depender das condições do solo como, umidade e tipo do solo e sua cobertura (TUCCI; CLARKE, 1997).

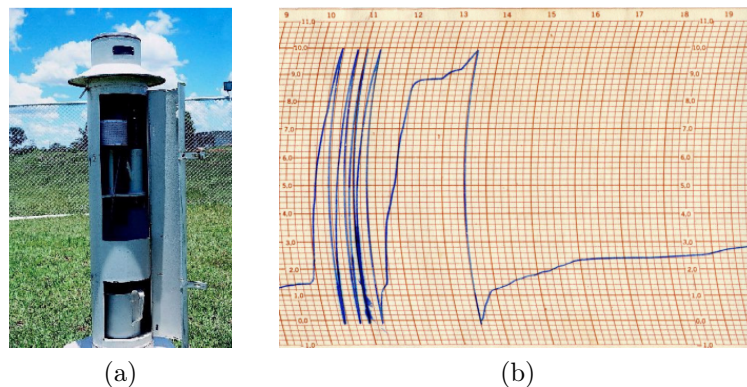


Figura 2 – Monitoramento de chuvas: (a) pluviógrafo (b) pluviograma (CARVALHO; SILVA, 2016)

O monitoramento das chuvas é feito por estações pluviométricas dotadas de instrumentos chamados pluviômetros e pluviógrafos. Pluviômetros são coletores de área conhecida, que medem em milímetros o total precipitado ao final de um intervalo de tempo. Os pluviógrafos (Figura 2a) registram a quantidade de chuva acumulada em 24 horas, o horário e sua intensidade em um diagrama denominado pluviograma, como o mostrado na Figura 2b.

b) Infiltração

Refere-se ao processo de penetração da água na superfície através de vazios do solo, formando seu teor de umidade. Esta etapa do ciclo é responsável para a recarga de aquíferos e influencia diretamente o escoamento superficial (TUCCI et al., 2012).

A infiltração é um processo que depende de fatores como a condição da superfície, cobertura vegetal, tipo e umidade inicial do solo, presença de fissuras e nível de compactação do solo (CARVALHO; SILVA, 2016).

c) Escoamento superficial e subterrâneo

O escoamento superficial é a fase do ciclo que trata do deslocamento da água proveniente das precipitações sobre o solo dos pontos mais altos para os pontos mais baixos pela ação da gravidade. Os volumes chegam até os rios e lagos, causando aumento da vazão ou dos volumes armazenados. A variação de vazão de um rio ao longo do tempo é representada graficamente pelo hidrograma (Figura 3).

Apesar do hidrograma ser bem característico, com a ascensão, pico e recessão da vazão, vários fatores podem alterar na forma em que ele se apresenta. Os principais fatores são o relevo da bacia hidrográfica, cobertura e uso do solo, canalização de rios e intensidade da precipitação.

A estimativa do escoamento superficial pode ser feita por meio da medição do nível de água do canal, realizada em postos fluviométricos. A altura da água é medida diretamente




Figura 3 – Hidrograma típico resultante da ocorrência de uma precipitação na área contribuinte. Adaptado de (TUCCI et al., 2012)

com auxílio das réguas linimétricas ou por meio de linígrafos, capazes de registrar as variações de níveis. A partir das alturas é possível estimar a vazão em uma determinada seção do curso d'água através da curva-chave, que relaciona uma altura do nível do curso d'água a uma vazão (CARVALHO; SILVA, 2016).

Ainda tem-se que a água que percola até os aquíferos pode ser transportada até os rios, criando a descarga de base, a qual oferece condições para manter os rios perenes em períodos de estiagem. Esse processo é denominado escoamento subterrâneo.

d) Evapotranspiração

A evapotranspiração é definida pelo conjunto de processos físicos de evaporação e transpiração vegetal, responsáveis pela transformação da água na superfície terrestre em vapor atmosférico (TUCCI et al., 2012). Os fatores intervenientes no processo de evapotranspiração incluem a radiação solar, temperatura da superfície, temperatura e umidade do ar, vento e aspectos fisiológicos dos vegetais.

3.1.1 Balanço hídrico

O balanço hídrico pode ser entendido como a contabilização das entradas e saídas de água de um determinado espaço em um intervalo de tempo, que relaciona a quantidade de cada componente do ciclo, podendo ser efetuado em diversos níveis, de acordo com o volume de controle.

Tem-se que a principal entrada de água de uma bacia é a precipitação (P). Enquanto que a saída pode ocorrer por evapotranspiração (E_T) e pelo escoamento superficial (Q).

Para longos períodos a equação do balanço hídrico para uma bacia hidrológica pode ser usada como (LEOPOLDO; FRANKEN; SALATI, 1982):

$$P = E_T + Q \quad (3.1)$$

Dentre as variáveis citadas, nesse trabalho serão considerados os componentes de precipitação e vazão para a criação dos modelos hidrológicos.

3.2 MODELOS HIDROLÓGICOS

Sendo o objeto de estudo da maioria dos modelos hidrológicos, a bacia hidrográfica se refere ao conjunto de áreas que captam e despejam água sobre um ou mais canais de escoamento que desembocam em uma única saída, o estuário da bacia.

O modelo hidrológico pode ser definido como uma ferramenta utilizada para representar os processos que ocorrem na bacia hidrográfica e prever as consequências das diferentes ocorrências em relação aos valores observados, facilitando dessa forma, uma análise quantitativa e qualitativa dos processos do ciclo hidrológico (TUCCI et al., 2005).

A grande dificuldade de modelar os processos hidrológicos pode ser atribuída a grande heterogeneidade do sistema, ou seja, a grande variabilidade de fatores envolvidos (TUCCI; CLARKE, 1997). Também deve ser considerada a necessidade de um grande volume de dados, que estejam distribuídos no tempo e no espaço, para garantir a precisão desses modelos.

Os modelos podem ser classificados de acordo com o tipo de variáveis utilizadas (estocásticas ou determinísticas), a relações entre essas variáveis (empíricos ou conceituais) e a existência ou não de relações espaciais (concentrados ou distribuídos) (ALMEIDA; SERRA, 2017):

a) Concentrado ou Distribuído: modelos ditos concentrados não levam em consideração a variabilidade espacial das variáveis hidrológicas envolvidas. No seu desenvolvimento são atribuídos valores médios representativos para toda a área. Já o modelo é dito distribuído quando há a distribuição espacial das variáveis e dos parâmetros, dividindo a área de estudo em unidades consideradas homogêneas (ALMEIDA; SERRA, 2017).

b) Conceitual ou Empírico: os modelos são ditos conceituais quando são baseados em equações que consideram os conceitos físicos relacionados aos vários processos do sistema. Enquanto que os modelos empíricos, ou de “caixa preta”, utilizam funções que ajustam os estímulos as respostas desejadas através de uma equação que não tem relação com os processos físicos que regem o sistema (TUCCI et al., 2005).

c) Estocástico ou Determinístico: quando a chance de ocorrência das variáveis for levada em consideração, e o conceito de probabilidade é introduzido na formulação do modelo, o processo e o modelo são ditos estocásticos. O modelo é dito determinístico

quando não considera a natureza probabilística das variáveis. Ou seja, quando para uma mesma entrada, o modelo produz uma mesma saída, com condições iniciais iguais.

Modelos hidrológicos baseados em Rede Neurais Artificiais são consideradas empíricos e estocásticos. E a depender de como são abordados, podem ser classificados como contínuos ou discretos.

3.3 APRENDIZADO DE MÁQUINA

Aprendizado de Máquina, ou *Machine Learning* (ML), é um ramo da Inteligência Artificial e consiste na técnica de programação de computadores para fins de extração de conhecimento a partir de dados, sem que os computadores sejam explicitamente programados para tal tarefa (MÜLLER; GUIDO, 2016).

As etapas da implementação de um projeto baseado em Aprendizado de Máquina podem ser divididas em: coleta de dados, pré-processamento dos dados, seleção do modelo, implementação do modelo e avaliação do desempenho (GÉRON, 2019).

O aprendizado de um modelo baseado em ML se dá a partir de um processo chamado treinamento. Os algoritmos de ML podem ser classificados de acordo com a quantidade e o tipo de supervisão que recebem durante o treinamento. O termo aprendizado supervisionado refere-se à técnica onde o modelo de ML recebe pares de dados de entrada e saída para o treinamento, ou seja, os dados de treinamento incluem as soluções desejadas, chamadas de rótulo. Há também o aprendizado não supervisionado, onde os dados de treinamento não são rotulados. Alguns exemplos de algoritmos não supervisionados são de agrupamento (*clustering*), algoritmos de visualização, redução de dimensionalidade e detecção de anomalias (MÜLLER; GUIDO, 2016).

Espera-se que após o treinamento o modelo seja capaz de realizar previsões de forma eficiente a partir de dados de entrada ainda não vistos. Esta habilidade é chamada de generalização, que ocorre quando um algoritmo é capaz de generalizar seu aprendizado para novas amostras com as mesmas características dos dados de treinamento.

Modelos de aprendizado supervisionado podem ser divididos em dois tipos de tarefas: regressão e classificação. Em algoritmos de classificação o objetivo é prever uma certa categoria dentro de uma possibilidade de classes pré-definida. Um exemplo de tarefa de classificação aplicada ao contexto de hidrologia, seria prever se para uma dada vazão, o canal está no período de cheia ou estiagem. Por outro lado, algoritmos de regressão utilizam dados de entrada para prever valores numéricos. Tendo como exemplo a previsão da vazão de um canal, o modelo de regressão recebe um conjunto de atributos (i.e. variáveis de entrada), tais como: precipitação e evapotranspiração, e partir destas deve prever a vazão do canal.

Nesse trabalho será abordada a aplicação de algoritmo de Aprendizado de Máquina com aprendizado supervisionado para realizar a tarefa de regressão e estimar o nível

diário na estação fluviométrica Fazenda Airis. O algoritmo que será utilizado é o de Redes Neurais Artificiais.

3.4 REDES NEURAIIS ARTIFICIAIS

Inspirado nos neurônios biológicos, as Redes Neurais Artificiais são sistemas computacionais capazes de reconhecer padrões e realizar previsões por meio do conhecimento adquirido a partir de um conjunto de dados. Temos que a RNA se assemelha ao cérebro humano em dois aspectos (HAYKIN, 1999):

1. Capacidade de extrair conhecimento do ambiente em que está inserida através de um processo de aprendizado.
2. O conhecimento adquirido é armazenado em pesos sinápticos nas conexões entre as unidades da rede.

Dentre as vantagens das RNAs, destaca-se a capacidade de modelar sistemas lineares e não-lineares, além da capacidade de aprender diretamente dos dados.

O processamento das informações nas RNAs ocorre em unidades denominadas neurônios, onde a troca de sinais entre essas unidades ocorre por meio de conexões. O aprendizado de uma RNA se dá pelo ajustes dos pesos sinápticos nas conexões entre os neurônios até que se minimize o erro na saída da RNA.

3.4.1 Neurônio Artificial

Um neurônio artificial é a unidade de processamento e o elemento básico constituinte de uma RNA (Figura 4).

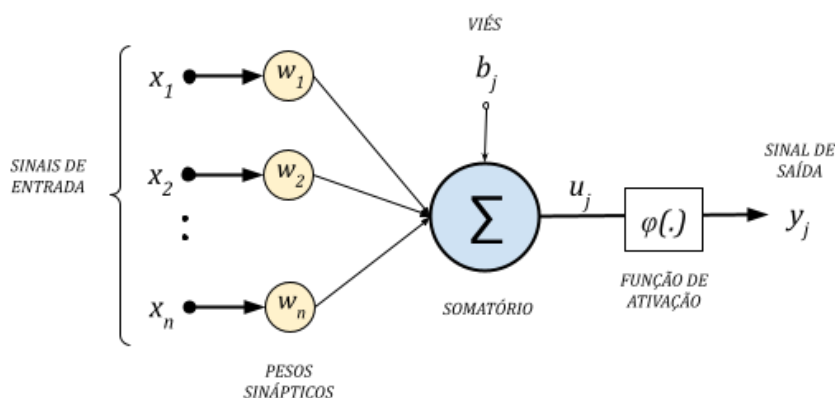


Figura 4 – Neurônio artificial. Adaptado de (HAYKIN, 1999)

A sua estrutura permite o recebimento de dados, o processamento dos estímulos e transmissão de um sinal de saída. O processamento de um dado neurônio j pode ser definido pelas equações abaixo.

$$u_j = \sum_{i=1} x_i w_i \quad (3.2)$$

$$y = \varphi(u_j + b_j) \quad (3.3)$$

Onde, x_i são os valores de entrada e w_i referem-se aos pesos sinápticos das conexões, que atribuem a RNA à capacidade de aprendizado. O peso b_j , chamado de viés ou *bias* assume o valor constante 1 e é adicionado a soma dos produtos u_j . O viés é utilizado para deslocar o resultado da função de ativação para direita ou para esquerda. Funcionamento similar ao da constante b em uma função de primeiro grau: $y = ax + b$. Finalmente, o resultado da soma $\sum x_i w_i$ será processado pela função de ativação $\varphi(\cdot)$, a qual determinará o sinal de saída y_j (HAYKIN, 1999).

A função de ativação permite à RNA identificar relações lineares e não-lineares entre as variáveis de entrada e saída. A Figura 5 mostra o comportamento de duas funções de ativação comumente usadas no treinamento de RNA.




Figura 5 – Funções de ativação tangente hiperbólica (tanh) e linear retificada (ReLU) (MÜLLER; GUIDO, 2016)

A função tangente hiperbólica (tanh) é contínua, com os limites entre -1 e 1 . Enquanto que a função de ativação linear retificada, conhecida como ReLU, garante que todo sinal de saída seja positivo, sendo expressa por:

$$f(a) = \begin{cases} a, & a \geq 0 \\ 0, & a < 0 \end{cases} \quad (3.4)$$

3.4.2 Perceptron de Múltiplas Camadas

Uma RNA do tipo de perceptron multicamadas (MLP) é composta por neurônios dispostos em camadas sequenciais: uma camada de entrada, uma ou mais camadas de

processamento (camadas ocultas) e uma camada de saída (Figura 6). A não ser os neurônios da camada de saída, cada neurônio é conectado com as unidades da camada seguinte. Quando uma RNA possui mais de duas camadas ocultas é considerada uma rede de aprendizado profundo ou *deep learning*.

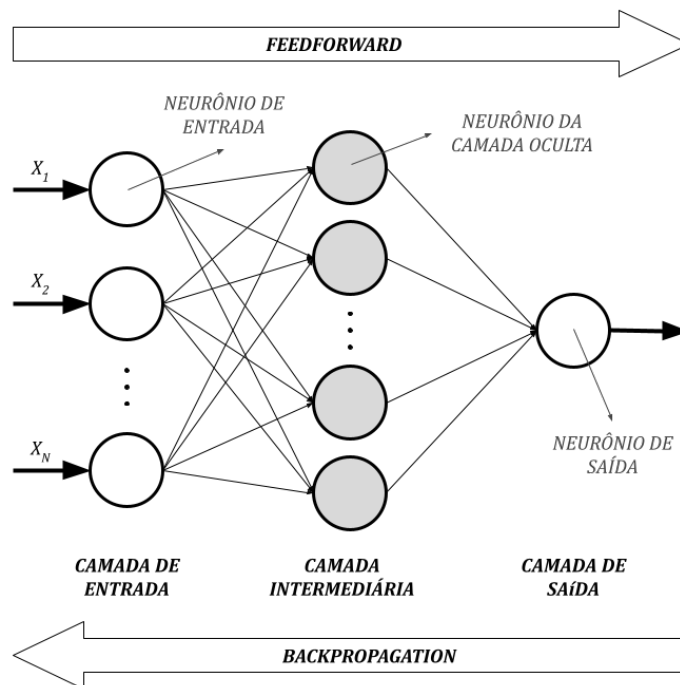


Figura 6 – Representação gráfica de uma rede neural do tipo perceptron de múltiplas camadas (MLP)

A arquitetura da rede neural é definida pelo número de camadas e o número de unidades de processamento em cada camada. A quantidade de neurônios da camada de entrada é definida pelo número de atributos do conjunto de entrada, enquanto que o número de neurônios da camada de saída é definido pela quantidade de variáveis a serem modeladas pelo rede (EVSUKOFF, 2020).

Os dados recebidos na camada de entrada são processados nas camadas ocultas, até que chegue na camada de saída. Portanto, o fluxo das informações é propagada em somente uma direção, sendo assim denominada de RNA *feedforward*.

Para o treinamento de uma RNA do tipo MLP, utiliza-se o algoritmo de retropropagação, ou *backpropagation* (VASILEV et al., 2019). O algoritmo de *backpropagation* corrige os pesos entre cada conexão de forma proporcional ao erro que este esteja causando na saída da RNA. Para cada instância do conjunto de treinamento, o algoritmo de *backpropagation* estima o erro do modelo ao comparar o valor de saída y com o valor real observado. Após, retorna em cada camada medindo a contribuição de cada conexão ao erro encontrado na camada de saída. Após esse processo, os pesos entre as conexões são alterados sutilmente a fim de reduzir o erro final da RNA (GÉRON, 2019).

3.4.2.1 Generalização

Um modelo bem treinado deve ser capaz de generalizar para amostras ainda não vistas, ou seja, para dados desconhecidos. Uma maneira de avaliar a capacidade de generalização é dividir o conjunto de dados em: treinamento, validação e teste. O conjunto de treinamento é utilizado para treinar o modelo e o conjunto de teste para testar o desempenho do mesmo. Ainda é criado um subconjunto dentro conjunto de treinamento, chamado de conjunto de validação, utilizado para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento (MÜLLER; GUIDO, 2016). A taxa de erro em novas amostras é chamada de erro de generalização e ao avaliarmos o modelo treinado com o conjunto de teste, essa estimativa é obtida (MÜLLER; GUIDO, 2016).

Epochs ou épocas indicam o estágio de aprendizado da RNA e representa quantas vezes um conjunto de dados é apresentado à rede durante o treinamento. A medida que o número de *epochs* aumenta durante o treinamento, o erro do conjunto de validação diminui, tornando possível o mapeamento de comportamentos mais complexos.

Porém, quando um modelo se ajusta muito próximo das particularidades de um conjunto de dados de treinamento pode ocorrer o sobreajuste, ou *overfitting*. Quando isso ocorre, a RNA perde a capacidade de generalizar seu aprendizado para novas amostras de dados. Por outro lado, para um baixo número de *epochs* o modelo pode não ser capaz de se ajustar as particularidades dos dados de treinamento nem aos dados de teste. Dessa forma, obtém-se um modelo que sofreu subajuste, ou *underfitting*. A Figura 7 ilustra esses processos.

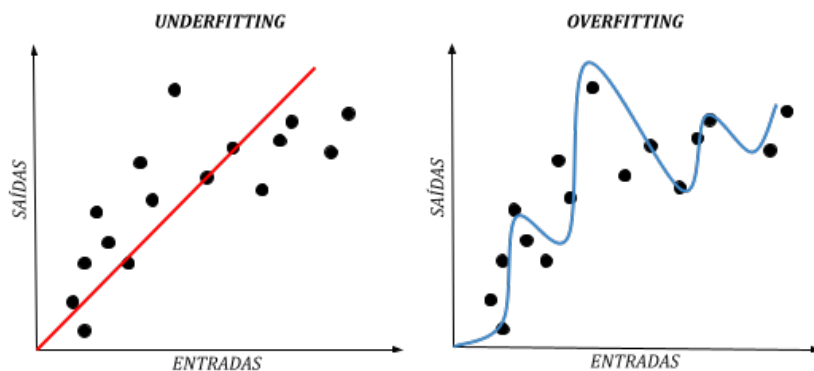


Figura 7 – Ilustração dos processos de *overfitting* e *underfitting*

Uma das técnicas utilizadas para prevenir o *overfitting* na RNA é a regularização. O *overfitting* pode ser identificado pelo erro de previsão do conjunto de validação. No início do treinamento, o erro do conjunto de validação tende a diminuir. Porém, se o modelo começar a se sobreajuste aos dados, o erro de validação aumentará. A técnica de “parada antecipada” pode ser empregada para finalizar o treinamento assim que o erro de validação parar de diminuir por um número determinado de *epochs*, evitando o *overfitting*

(GÉRON, 2019). A Figura 8 mostra como se dá a variação do erro nos conjuntos de treinamento e validação e onde ocorre a parada do modelo.

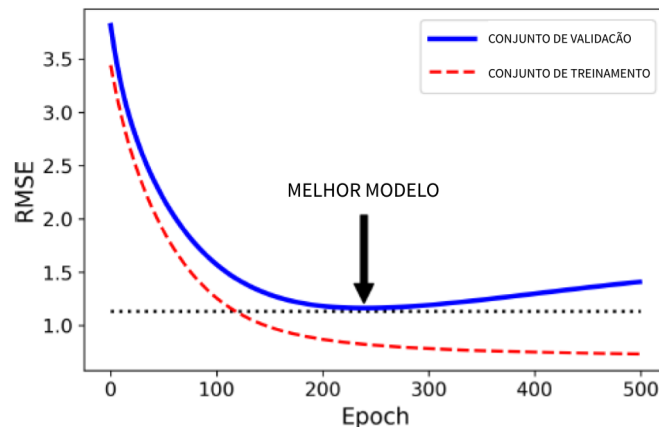


Figura 8 – Regularização por parada antecipada. Adaptado de (GÉRON, 2019)

A regularização ℓ_2 também é uma das técnicas usadas para se evitar ou minimizar o *overfitting*, ao aplicar uma penalidade aos pesos sinápticos da RNA, simplificando o modelo. As restrições tem o objetivo de reduzir a grandeza dos parâmetros da rede (MÜLLER; GUIDO, 2016).

No presente trabalho a técnica de Redes Neurais Artificiais será implementada para a previsão do nível diário no rio Macaé-RJ. As RNAs serão implementadas com a função de ativação ReLU e duas técnicas de regularização para evitar o *overfitting*: parada antecipada e regularização ℓ_2 . A arquitetura das RNAs será objeto de investigação dos experimentos.

4 MATERIAIS E MÉTODOS

A metodologia adotada neste trabalho contém cinco etapas: escolha da área de estudo, coleta dos dados, tratamento dos dados, definição dos modelos de entrada, treinamento das RNAs e análise de desempenho (Figura 9). Cada uma das etapas será detalhada nesta seção.



Figura 9 – Etapas da elaboração do trabalho

4.1 ESCOLHA DA ÁREA DE ESTUDO

A área de estudo deste trabalho é a bacia hidrográfica do rio Macaé, que compõe a Região Hidrográfica VIII do Estado do Rio de Janeiro e se localiza na faixa costeira central-norte do Estado (Figura 10). O rio Macaé é o principal canal da bacia e nasce na Serra Macaé de Cima em Nova Friburgo, percorre cerca de 136 km, desaguando no oceano Atlântico na cidade de Macaé.

A bacia hidrográfica em questão possui uma área de drenagem de aproximadamente 1.765 km² e abrange seis municípios: Nova Friburgo, onde estão localizadas as principais nascentes, Casimiro de Abreu, Rio das Ostras, Conceição de Macabu, Carapebus e Macaé, com inserção de cerca de 1.448 km² (82%) do seu território na bacia (FREITAS et al., 2015).

A bacia do rio Macaé teve cerca de 60 km do canal principal, além de trechos de afluentes retificados pelo extinto Departamento Nacional de Obras e Saneamento (DNOS) na década 1940. Esse tipo intervenção consiste na retirada de curvas e meandros do canal em questão, tornando-o mais retilíneo e íngreme, ocasionando o aumento na velocidade do fluxo d'água e transferindo as cheias para jusante. Na área urbana de Macaé, há registros de cheias frequentes durante o período chuvoso do ano, assim como a ocorrência de eventos extremos que ocasionam em perdas e danos aos moradores próximos do canal fluvial (ASSUMPÇÃO; MARÇAL, 2012).

4.2 COLETA DOS DADOS

Nesse trabalho, os vetores de entrada serão compostos por dados de vazão e nível médio diário. Também serão utilizados dados de precipitação diária, onde ora serão representados pelas estações e ora pela média. Todos os dados foram obtidos através do

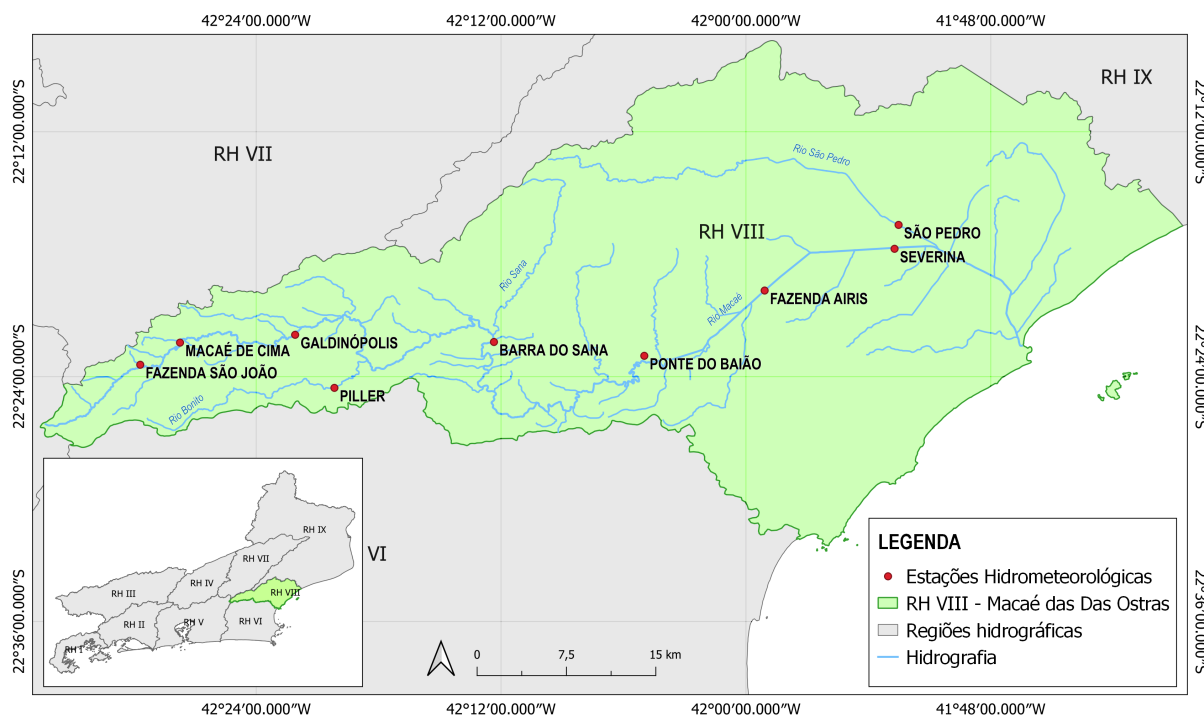


Figura 10 – Região hidrográfica VIII - Macaé e Das Ostras

portal Hidroweb¹ da ANA ou disponibilizados pelo Sistema de Alerta de Cheias do INEA. Os conjuntos de dados utilizados serão detalhados a seguir.

4.2.1 Precipitação

As séries históricas foram obtidas no portal Hidroweb da ANA, do onde foram selecionados 6 postos pluviométricos localizados dentro da área de estudo: Fazenda São João (2241005), Galdinópolis (2242004), Piller (2242003), Ponte Baião (2242145), Fazenda Airis (2241032) e Severina (2241030). O critério de seleção considerou a proximidade com a estação alvo e a extensão da série histórica. A Tabela 1 traz a extensão das séries históricas e a localização de cada posto pluviométrico, que também pode ser observada na Figura 10.

Tabela 1 – Estações Pluviométricas da bacia hidrográfica do rio Macaé selecionadas

Código	Estação	Intervalo	Latitude	Longitude	Município
2241005	Fazenda São João	1967-2020	-22.3903	-42.4947	Nova Friburgo
2242004	Galdinópolis	1950-2020	-22.3631	-42.3808	Nova Friburgo
2242003	Piller	1950-2020	-22.4047	-42.3392	Nova Friburgo
2242145	Ponte Baião	2010-2013	-22.383	-42.083	Macaé
2241032	Fazenda Airis	2011-2013	-22.3281	-41.9825	Macaé
2241030	Severina	2011-2013	-22.2956	-41.8786	Macaé

¹ Hidroweb. Disponível em: <<https://www.snirh.gov.br/hidroweb/serieshistoricas>>

4.2.2 Vazão e Nível

As séries históricas foram obtidas no portal Hidroweb e cedidas pelo Sistema de Alerta de Cheias no INEA. Foram selecionados 6 postos fluviométricos onde são fornecidos dados de vazão ou nível de rios inseridos na bacia do rio Macaé. São estes: Macaé de Cima (59120000), Galdinópolis (59125000), Piller (59135000), Barra do Sana (59134000), Fazenda Airis (59138800) e São Pedro (59143000). A Tabela 2 traz para cada estação a localização e o rio que monitora. A localização dos postos pode ser vista na Figura 10.

Tabela 2 – Postos fluviométricos da bacia do rio Macaé selecionadas

Código	Estação	Intervalo	Latitude	Longitude	Rio monitorado
59120000	Macaé de Cima	1967-2020	-22.3722	-42.4622	Rio Macaé de Cima
59125000	Galdinópolis	1950-2020	-22.3689	-42.3792	Rio Macaé
59135000	Piller	1950-2020	-22.4092	-42.3361	Rio Bonito
59134000	Barra do Sana	2011-2013	-22.3686	-42.2058	Rio Macaé
59138800	Fazenda Airis	2010-2013	-22.3281	-41.9825	Rio Macaé
59143000	São Pedro	2011-2013	-22.2761	-41.8753	Rio São Pedro

A estação Fazenda Airis (59138800) fornece observações de nível, medidos por meio de réguas linimétricas e será o objeto de previsão deste trabalho. A escolha da Fazenda Airis como posto alvo dos modelos de previsão se deu pela localização, próxima à área urbanizada e por se tratar de um trecho retificado do Rio Macaé. As demais estações fluviométricas serão usadas como dados de entrada no treinamento das RNAs. Essas estão localizadas a montante da Fazenda Airis (5913880), com exceção da estação São Pedro (59143000), que monitora o rio de mesmo nome, um dos principais afluentes do rio Macaé.

A Figura 11 apresenta o pluviograma e hidrograma da Fazenda Airis (59138800) entre 2010 e 2013. Por meio deste foi possível verificar graficamente as repostas aos eventos de precipitação no nível da bacia.

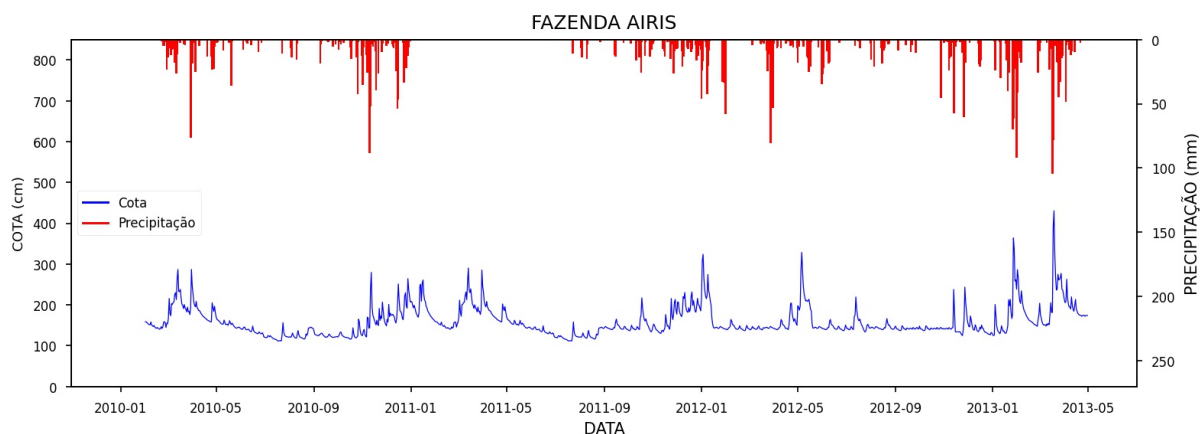


Figura 11 – Fluviograma e pluviograma da Fazenda Airis entre 2010 e 2013

4.3 TRATAMENTO DOS DADOS

As RNAs aprendem a mapear a relação entre os dados de entrada e saída ajustando os pesos sinápticos, baseado na retropropagação dos erros durante o treinamento. Por isso, tem-se que a qualidade dos dados influencia no desempenho do modelo. O pré-processamento inclui a seleção, limpeza e transformação de dados, com o objetivo de preparar o conjunto de treinamento que será utilizado para o ajuste do modelo (EVSU-KOFF, 2020). Neste trabalho o pré-processamento inclui o preenchimento de falhas e normalização.

As falhas das séries históricas foram preenchidas por um algoritmo de regressão linear, conforme apresentado em (MELLO; KOHLS; OLIVEIRA, 2017). Posteriormente, os dados foram divididos em conjuntos de treinamento, validação e teste, com 60%, 20% e 20%, respectivamente

Deve ser considerado que o algoritmo de *backpropagation* usado nas RNAs do tipo MLP são sensíveis a escala dos dados. Baseado nisso, os dados do conjunto de treino foram normalizados no intervalo $[0,1]$, concordando com os limites da função de ativação ReLU escolhida para os experimentos (DAWSON; WILBY, 2001).

A manipulação e análise dos dados foi realizada em linguagem Python, utilizando a biblioteca Pandas² e Scikit-Learn³ para pré-processamento e avaliação dos dados.

4.4 DEFINIÇÃO DOS MODELOS DE ENTRADA

Com a intenção de investigar a influência das variáveis na previsão do nível do canal, foram propostas 9 alternativas de conjunto de entrada. Na Tabela 3 são apresentadas todas as alternativas com as variáveis aplicadas, o intervalo da série histórica e o número de registros contidos. A extensão da série foi definida pelas estações abrangidas por cada alternativa. Para todos os modelos, a variável de saída é a nível diário na estação fluviométrica de Fazenda Airis (59138800).

As combinações de entrada foram escolhidas de forma a possibilitar a análise da contribuição entre dados de precipitação, vazão e nível, para diferentes tempos de resposta. O tempo de resposta de algumas alternativas foi escolhido de forma experimental. Abaixo, temos uma descrição de cada conjunto.

- **Alternativa 1:** Para a previsão de nível no tempo t , essa alternativa de entrada recebe dados diários de precipitação, vazão e nível de todas as estações pluviométricas (Tabela 1) e fluviométricas (Tabela 2) com defasagem de um dia ($t - 1$). Dessa forma, cada variável representa um neurônio da camada de entrada da RNA;

² Pandas. Disponível em: <<https://pandas.pydata.org/docs/index.html>>

³ Scikit-learn. Disponível em: <<https://scikit-learn.org/stable/index.html>>

Tabela 3 – Alternativas de dados de entrada com as variáveis usadas, a defasagem dos dados em dias, intervalo da série histórica e número de registros que cada modelo recebe no treinamento.

N	Variáveis de entrada	Defasagem	Intervalo	Registros
1	$P1, P2, P3, P4, P5, P6, Q1, Q2, Q3, Q4, Q5, Q6$	1	02/05/11 a 30/04/13	9.490
2	$P1, P2, P3, P4, P5, P6, Q1, Q2, Q3, Q4, Q5, Q6$	2	03/05/11 a 30/04/13	18.225
3	$P1, P2, P3, P4, P5, P6$	4	05/05/11 a 30/04/13	18.175
4	\bar{P}	4	01/02/10 a 30/04/13	5.925
5	$\bar{P}, Q1, Q2, Q3, Q4, Q5, Q6$	1	02/01/11 a 30/04/13	6.800
6	$Q1, Q2, Q3, Q4, Q5, Q6$	1	02/01/11 a 30/04/13	5.950
7	$Q5$	1	02/02/10 a 30/04/13	2.368
8	$P1, P2, P3, P4, P5, P6, Q5$	1	02/05/11 a 30/04/13	5.840
9	$Q1, Q2, Q3, Q4, Q6$	1	04/01/11 a 30/04/13	9.339

Nota: Sendo $P1, P2, P3, P4, P5$ e $P6$ os dados de precipitação das estações Fazenda São João, Galdinópolis, Piller, Ponte do Baião, Fazenda Airis e Severina, respectivamente; \bar{P} é a precipitação média das estações pluviométricas citadas. São $Q1, Q2, Q3, Q4, Q5$ e $Q6$ as leituras diárias registradas pelas estações fluviométricas Macaé de Cima, Galdinópolis, Piller, Barra do Sana, Fazenda Airis e São Pedro, respectivamente.

- **Alternativa 2:** Similar à alternativa 1, esse modelo combina dados diários de todas as estações fluviométricas e pluviométricas. Porém, recebe as observações dos últimos 2 dias, sendo o conjunto de dados com mais registros (Tabela 3);
- **Alternativa 3:** Utiliza dados de precipitação diária dos 4 dias anteriores. Dessa forma, espera-se avaliar a eficácia de um modelo de previsão de vazão que recebe somente dados pluviométricos. Sendo um alternativa interessante para estudos em trechos onde ainda não há o monitoramento fluviométrico, haja vista a rede de monitoramento pluviométrico no Brasil é mais ampla que monitoramento fluviométrico, conforme constatado em (SARMENTO, 2021);
- **Alternativa 4:** Recebe somente dados diários de precipitação média com tempo de resposta de 4 dias. Os valores foram estimados pela média aritmética (\bar{P}) das estações pluviométricas da Tabela 1. De maneira que as RNAs treinadas com essa alternativa terão quatro neurônios na camada de entrada, sendo um neurônio para cada um dos quatro dias que antecedem a previsão no tempo t ;
- **Alternativa 5:** Combina dados diários das estações fluviométricas e de precipitação média (\bar{P}) com tempo de resposta de um dia;
- **Alternativa 6:** Recebe dados diários de 6 estações fluviométricas em $(t - 1)$. Com isso, espera-se analisar a viabilidade de um modelo de previsão que não recebe atributos pluviométricos;

- **Alternativa 7:** Utiliza somente os dados de cota diária da Fazenda Airis ($Q5$) em $(t - 1)$, de forma que as RNAs treinadas com esse conjunto terão apenas um neurônio na camada de entrada. Esta alternativa pode ser considerada em bacias com monitoramento hidrológico limitado, pois requer monitoramento de somente uma variável;
- **Alternativa 8:** Combinação de dados de precipitação de todas as estações pluviométricas (Tabela 1) e de nível diário em Fazenda Airis com defasagem ($Q5$) de um dia;
- **Alternativa 9:** Considera somente dados fluviométricos a montante e jusante da Fazenda Airis. Essa combinação avalia o desempenho de um modelo que não recebe como atributo os dados da estação alvo.

4.5 TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS

A generalização de um modelo é definida por três fatores: (1) extensão e representatividade do conjunto de treinamento, (2) a arquitetura da RNA e (3) a complexidade do problema a ser resolvido (HAYKIN, 1999) .

A arquitetura de uma RNA se refere a forma em que as informações fluem entre as unidades de processamento, a quantidade de neurônios e o número de camadas que a compõe. A determinação da arquitetura da RNA é uma das tarefas mais importantes no processo de criação de um modelo, influenciando diretamente no seu desempenho (MAIER; DANDY, 2000).

Baseado nisso, neste trabalho foi adotado o método de variação da quantidade de camadas ocultas e o número de neurônios. De forma que, para cada alternativa de entrada (Tabela 3) serão criadas RNAs com 1, 2 e 4 camadas intermediárias, variando-se também a quantidade de neurônios na camada oculta entre 5, 10, 20, 50, 80, 100 e 120. Logo, cada alternativa de entrada será treinada para 21 arquiteturas diferentes. Ao final dos experimentos teremos 189 modelos de neuroprevisão. A Tabela 4 resume os hiperparâmetros utilizados no treinamento das RNAs.

Tabela 4 – Hiperparâmetros considerados no treinamento das RNAs

Hiperparâmetros das Redes Neurais	
Camadas ocultas	1, 2, 4
Neurônios na camada oculta	5, 10, 20, 50, 80, 100, 120
Função de ativação	ReLU
Regularização	Parada antecipada e regularização ℓ_2
Otimização	Adam

Com o objetivo de melhorar a generalização das RNAs utilizadas, foram implementados dois critérios de regularização: regularização ℓ_2 e parada antecipada (RODRIGUES; COSTA; FILHO, 2015). A técnica “parada antecipada” finaliza o treinamento quando o erro de validação alcança para de diminuir, evitando o superajuste do modelo. Enquanto que a regularização ℓ_2 reduz a magnitude dos pesos das RNAs.

Em todos os modelos foi implementado o algoritmo de otimização “Adam”, utilizado para que a RNA ajuste seus pesos de forma mais rápida e eficiente. Considerando a aleatoriedade das inicializações dos pesos das RNAs, cada modelo foi inicializado e treinado 5 vezes. Os resultados serão apresentados pela média obtida e com seu respectivo desvio padrão.

O processo de criação, treinamento e teste das RNAs foi feito utilizando o pacote *Keras*, um API do *TensorTensorFlow 2* utilizado para soluções de ML⁴. O trecho de código abaixo exemplifica a criação de uma RNA do tipo MLP, definindo-se uma camada de entrada com cinco neurônios, uma camada oculta com dez neurônios e uma camada de saída.

```
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras import layers

model = tf.keras.Sequential()
model.add(tf.keras.layers.InputLayer(5))      # Camada de entrada
model.add(tf.keras.layers.Dense(10))         # Camada oculta
model.add(tf.keras.layers.Dense(1))         # Camada de saída
```

4.6 ANÁLISE DE DESEMPENHO

Para a análise da eficiência do modelo foram combinadas métricas de erro e de ajuste (DAWSON; WILBY, 2001).

4.6.1 Erro Médio Absoluto (MAE)

O Erro Médio Absoluto (MAE) é calculado pela diferença absoluta entre os valores previstos e observados, conforme abaixo:

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.1)$$

Onde, \hat{y}_i são os valores previstos, y_i os valores observados e n é número de amostras.

⁴ Keras API. Disponível em: <<https://keras.io/about/>>

4.6.2 Erro Médio Quadrático (MSE)

Erro Médio Quadrático (MSE) é a medida do quadrado da soma de todas as distâncias entre os valores previstos e medidos, sendo uma métrica do ajuste do modelo para grandes vazões (DAWSON; WILBY, 2001). A equação que o define é:

$$MSE(\hat{y}, y) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.2)$$

4.6.3 Coeficiente de Determinação

O Coeficiente de Determinação (R^2) representa a proporção da variância da variável y , definido como:

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.3)$$

Onde \hat{y}_i são os valores previstos, y_i os valores observados, \bar{y} é a média dos valores observados e n é a quantidade de dados. Esta métrica indica o quão bom o ajuste do modelo e generalização do modelo. Os valor de R^2 podem variar de $-\infty$ a 1, sendo 1 o melhor resultado.

5 RESULTADOS E DISCUSSÕES

Nesta seção iremos analisar os resultados obtidos nos experimentos propostos na seção anterior para a previsão do nível diário da estação fluviométrica Fazenda Airis.

A primeira parte das discussões é direcionada à arquitetura e aos dados de entrada das RNAs. A exposição dos resultados segue com a análise da aplicabilidade das variáveis de entrada na previsão hidrológica, utilizando gráficos de dispersão e comparação entre as cotas previstas e observadas.

Cada alternativa de conjuntos de entrada (Tabela 3) foi treinada para 21 arquiteturas diferentes, conforme os hiperparâmetros mostrados na Tabela 4. Logo, o total de 189 modelos de RNAs foram treinadas e testadas. Cada modelo foi inicializado e treinado 5 vezes e os coeficientes que serão mostrados a seguir representam a média das inicializações acompanhados do desvio padrão.

Dos 189 modelos gerados, 80 foram selecionados para a primeira parte da análise, conforme mostra a Tabela 5. O critério de seleção foi o coeficiente de determinação R^2 do conjunto de teste igual ou maior que 0,80. Todos os resultados obtidos estão disponíveis no Anexo A.

Todas as RNAs serão identificados pela nomenclatura que indica o conjunto de entrada, o número de neurônios e camadas ocultas. O primeiro número após a letra “M” refere-se a alternativa de dados de entrada, conforme a Tabela 3. O número após a letra “C” indica a quantidade de camadas ocultas da RNA, que pode assumir os valores de 1, 2 ou 4 camadas. O número após a letra “N” refere-se a quantidade de neurônios presente em cada camada intermediária, que varia entre 5, 10, 20, 50, 80 100 e 120. Tomando como exemplo, a nomenclatura M3C2N100 refere-se a RNA que recebeu as variáveis de entrada da alternativa 3, possuindo 2 camadas ocultas e 100 neurônios em cada camada oculta.

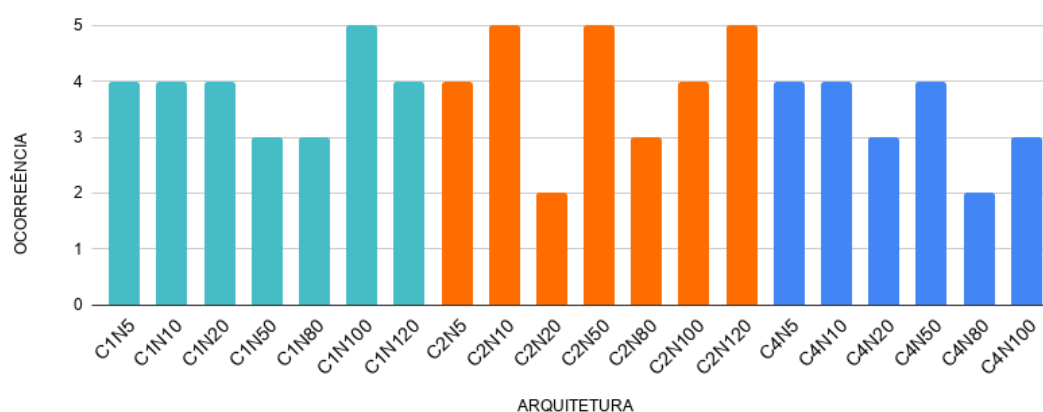
O melhor valor de R^2 obtido foi de 0,88 (0,01) pela RNA M8C1N5, a qual recebeu o conjunto de entrada 8, com uma camada oculta e cinco neurônios na camada oculta. A seguir serão apresentadas discussões sobre os experimentos.

5.1 ARQUITETURA

Das 21 arquiteturas propostas, a Figura 12 mostra a frequência de cada configuração entre os modelos com coeficiente R^2 acima de 0,80, mostrados na Tabela 5. Podemos observar que arquiteturas mais simples (i.e. com menos camadas ocultas e neurônios) foram capazes de realizar previsões tão eficazes quanto as mais complexas. Portanto, não houve ganho significativo no desempenho do modelo ao acrescentar camadas ocultas e neurônios nestas camadas.

Tabela 5 – Modelos com coeficiente acima de determinação R^2 igual ou acima de 0,80.

RNA	R^2	RNA	R^2	RNA	R^2
M8C1N5	0,88 (0,01)	M6C2N50	0,84 (0,03)	M8C1N120	0,82 (0,03)
M1C4N10	0,88 (0,04)	M8C1N50	0,84 (0,03)	M1C4N20	0,82 (0,04)
M1C2N5	0,88 (0,05)	M8C1N10	0,84 (0,04)	M5C1N120	0,82 (0,04)
M1C2N80	0,87 (0,04)	M8C4N50	0,84 (0,04)	M7C2N50	0,82 (0,04)
M8C2N100	0,87 (0,04)	M8C4N100	0,84 (0,04)	M2C1N50	0,82 (0,05)
M2C1N5	0,87 (0,06)	M1C1N20	0,84 (0,05)	M2C1N80	0,82 (0,05)
M8C4N10	0,87 (0,07)	M2C2N120	0,84 (0,05)	M7C2N120	0,82 (0,05)
M8C2N5	0,86 (0,01)	M6C4N120	0,84 (0,05)	M8C2N50	0,82 (0,05)
M6C4N20	0,86 (0,02)	M5C1N100	0,84 (0,06)	M1C1N10	0,82 (0,06)
M5C2N20	0,86 (0,03)	M5C4N50	0,84 (0,06)	M6C1N5	0,82 (0,07)
M2C2N80	0,86 (0,04)	M6C1N20	0,84 (0,06)	M7C1N100	0,82 (0,07)
M8C2N10	0,86 (0,04)	M1C4N5	0,84 (0,07)	M1C1N5	0,82 (0,09)
M8C1N100	0,86 (0,05)	M2C1N10	0,84 (0,07)	M2C1N20	0,82 (0,09)
M1C2N10	0,86 (0,06)	M2C4N50	0,84 (0,07)	M6C2N120	0,81 (0,03)
M5C4N5	0,86 (0,07)	M8C2N20	0,84 (0,09)	M7C2N10	0,81 (0,04)
M1C1N80	0,85 (0,02)	M2C2N5	0,83 (0,03)	M1C1N120	0,81 (0,05)
M5C2N120	0,85 (0,03)	M8C4N80	0,83 (0,03)	M2C1N120	0,81 (0,05)
M1C4N50	0,85 (0,04)	M2C1N100	0,83 (0,05)	M5C1N50	0,81 (0,05)
M5C4N10	0,85 (0,04)	M2C4N5	0,83 (0,05)	M5C2N80	0,81 (0,08)
M8C1N20	0,85 (0,04)	M2C4N10	0,83 (0,05)	M1C4N100	0,80 (0,03)
M8C4N20	0,85 (0,04)	M2C4N120	0,83 (0,05)	M2C2N10	0,80 (0,05)
M1C2N120	0,85 (0,05)	M5C4N100	0,83 (0,05)	M6C2N10	0,80 (0,05)
M2C2N50	0,85 (0,05)	M1C4N80	0,83 (0,07)	M5C1N10	0,80 (0,07)
M1C2N100	0,84 (0,03)	M8C4N5	0,83 (0,09)	M6C2N100	0,80 (0,07)
M1C4N120	0,84 (0,03)	M8C4N120	0,83 (0,1)	M5C2N5	0,80 (0,07)
M2C2N100	0,84 (0,03)	M1C2N50	0,82 (0,03)	M5C4N120	0,80 (0,08)
M7C1N80	0,84 (0,03)	M1C1N100	0,82 (0,03)		

Figura 12 – Frequência das arquiteturas com coeficiente de determinação R^2 igual ou maior a 0,80 (Tabela 5)

As arquiteturas que mais geraram bons modelos foram as C1N100, C2N10, C2N50 e C2N120. E as RNAs com duas camadas ocultas e 20 neurônios em camada camada, C2N20, foram as menos frequentes entre os melhores resultados da Tabela 5.

5.2 CONJUNTO DE DADOS DE ENTRADA

A Tabela 6 apresenta a melhor RNA obtida para cada alternativa de entrada (Tabela 3). A partir da leitura dessa tabela podemos tirar algumas conclusões sobre a contribuição das variáveis na previsão hidrológica na estação Fazenda Airis.

Tabela 6 – Melhores modelos para cada alternativa de entrada, usando como referência o coeficiente de determinação R^2 . Onde, M é alternativa de entrada (Tabela 3) e a defasagem dos dados é dada em dias.

M	Variáveis de Entrada	Defasagem	Modelo	R^2
1	$P1, P2, P3, P4, P5, P6, Q1, Q2, Q3, Q4, Q5, Q6$	1	M1C4N10	0,88 (0,04)
2	$P1, P2, P3, P4, P5, P6, Q1, Q2, Q3, Q4, Q5, Q6$	2	M2C1N5	0,87 (0,06)
3	$P1, P2, P3, P4, P5, P6$	4	M3C1N20	0,49 (0,10)
4	\bar{P}	4	M4C4N20	0,45 (0,07)
5	$\bar{P}, Q1, Q2, Q3, Q4, Q5, Q6$	1	M5C4N5	0,86 (0,07)
6	$Q1, Q2, Q3, Q4, Q5, Q6$	1	M6C4N20	0,86 (0,02)
7	$Q5$	1	M7C1N180	0,84 (0,03)
8	$P1, P2, P3, P4, P5, P6, Q5$	1	M8C1N5	0,88 (0,01)
9	$Q1, Q2, Q3, Q4, Q6$	1	M9C4N100	0,53 (0,22)

Nota: Sendo $P1, P2, P3, P4, P5$ e $P6$ os dados de precipitação das estações Fazenda São João, Galdinópolis, Piller, Ponte do Baião, Fazenda Airis e Severina, respectivamente; \bar{P} é a precipitação média das estações pluviométricas citadas. São $Q1, Q2, Q3, Q4, Q5$ e $Q6$ as leituras diárias registradas pelas estações fluviométricas Macaé de Cima, Galdinópolis, Piller, Barra do Sana, Fazenda Airis e São Pedro, respectivamente.

a) Contribuição dos tipos de dados

Para analisar a contribuição das variáveis podemos observar a rede M7C2N120, que recebeu somente dados de nível da Fazenda Airis e apresentou um bom desempenho com R^2 igual a 0,82 e com desvio padrão de 0,01. Com o acréscimo de dados de chuva média, \bar{P} , obtemos o modelo M5C4N20, que apresentou uma melhora na previsão com R^2 de 0,86 (0,07).

Porém, se os dados pluviométricos foram aplicados de forma que cada estação pluviométrica será uma variável de entrada, obtemos a RNA M8C1N5. Esta RNA que produziu no melhor modelo de previsão, com R^2 igual a 0,88 com desvio padrão de 0,01.

Adicionando os dados das estações fluviométricas a montante e a jusante da Fazenda Airis, obtemos M1C4N10. Esta mudança produziu novamente um bom modelo de previ-

são, com coeficiente R^2 de 0,88 (0,04), porém não representou uma melhora significativa no desempenho.

Podemos observar que a estação Fazenda Airis com defasagem de um dia é o atributo mais importante para a previsão do modelo e que dados fluviométricos de outros pontos não contribuíram significativamente para a eficiência do mesmo.

A Figura 13 mostra a frequência em que modelos de cada alternativa de entrada obteve coeficiente de determinação acima de 0,80. Vemos que as alternativas de entrada 1, 2, 5 e 8, que combinam dados pluviométricos e fluviométricos, são as mais frequentes entre os melhores modelos (Tabela 5). Por outro lado, nenhum dos modelos treinados somente com dados de precipitação obtiveram R^2 acima de 0,80 (alternativas 3 e 4). Portanto, temos desses resultados que a combinação de dados de precipitação e vazão geram modelos de previsão hidrológica mais precisos.

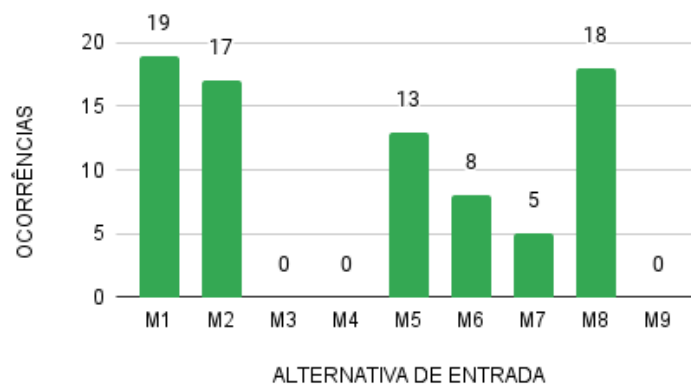


Figura 13 – Frequência das alternativas de entrada nos modelos com coeficiente R^2 acima de 0,80 (Tabela 5)

b) Defasagem dos dados

As alternativas 1 e 2 recebem as mesmas variáveis, com a diferença no tempo de defasagem dos dados. Enquanto que a alternativa 1 recebe dados em $(t - 1)$, o conjunto de entrada da alternativa 2 recebe dados em $(t - 1)$ e $(t - 2)$.

Na Tabela 6 vemos que o acréscimo de informação de chuvas e vazão com dois dias de defasagem não contribuiu para a melhora da previsão, visto que o modelo M1C4N10 obteve maior coeficiente em relação ao M2C1N5.

c) Tratamento dos dados de precipitação

Os modelos de RNA podem receber os dados pluviométricos de diferentes formas. A alternativa 3 recebe os dados de chuva de maneira que cada estação pluviométrica representa um neurônio de entrada. Enquanto que na alternativa 4, a RNA é alimentada pela pluviosidade média, calculada pela média aritmética. Vemos que a RNA M3C1N20

com coeficiente R^2 de 0,49 teve desempenho superior ao M4C4N20, que obteve coeficiente igual a 0,45.

O resultado obtido pode ser explicado pelos pesos atribuídos pelas RNAs a cada variável durante o treinamento. De forma que pela distribuição dos dados pluviométricos da alternativa 3, é possível que o algoritmo retropropagativo atribua os pesos de acordo com a contribuição da estação, gerando melhores previsões. Destaca-se que há outros métodos de obtenção da média pluviométrica e que estes não foram tratados nesse trabalho.

5.3 ANÁLISE POR ALTERNATIVA DE ENTRADA

Foram selecionadas as 5 melhores RNAs para cada conjunto de entrada (Tabela 3) para a análise gráfica. O critério de seleção foi o coeficiente de determinação R^2 no conjunto de teste. Serão mostradas também as métricas de erro médio absoluto (MAE) e erro médio quadrático (MSE) obtidas no conjunto de treinamento, validação e teste.

Alternativa de Entrada 1

A primeira alternativa de dados de entrada reuniu todos as variáveis obtidas estações pluviométricas e fluviométricas com tempo de resposta de um dia.

Na Tabela 7 vemos que M1C4N10 foi o melhor modelo criado, com coeficiente R^2 igual a 0,88 (0,04), MAE igual a 6,34 cm e MSE de 180,78 cm^2 . É possível observar que os demais modelos tiveram desempenhos próximos, apesar da variação de arquitetura.

Portanto, podemos concluir que o uso de dados de nível e vazão a montante em combinação com dados pluviométricos diário com defasagem de tempo de um dia gera modelos capazes de criar bons ajustes. A Figura 14 mostra as previsões do modelo M1C4N10 e o gráfico de dispersão que evidencia a tendência em superestimar as cotas mais altas e subestimar as cotas médias, entre 200 e 250 cm.

Tabela 7 – Cinco melhores resultados para a alternativa de entrada 1.

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M1C4N10	201,41	6,56	255,90	7,09	180,78	6,34	0,88 (0,04)
M1C2N5	239,97	6,91	138,48	6,24	195,16	6,67	0,88 (0,05)
M1C2N80	237,05	6,75	172,85	6,32	171,12	6,77	0,87 (0,04)
M1C2N10	232,62	6,76	184,85	6,19	179,22	6,60	0,86 (0,06)
M1C1N80	221,09	6,60	264,39	7,25	157,33	6,64	0,85 (0,02)

Alternativa de Entrada 2

A alternativa 2 recebeu os dados das estações pluviométricas e fluviométricas com defasagem de um e dois dias, e também apresentou um bom ajuste aos modelos.

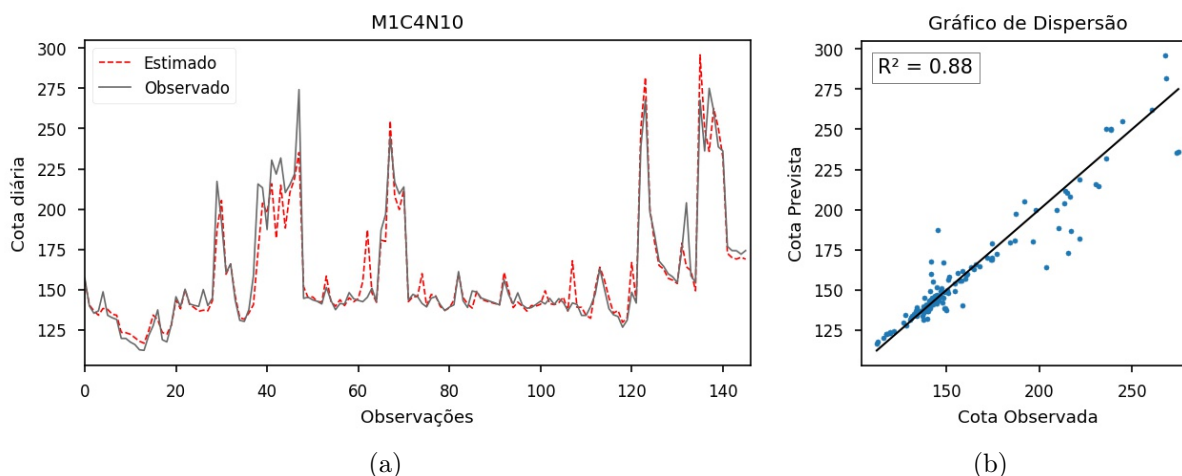


Figura 14 – M1C4N10: a) previsão do conjunto de teste b) gráfico de dispersão

O melhor modelo obtido com esse conjunto de entrada foi o M2C1N5 com coeficiente R^2 igual a 0,87 (0,06). E o MAE e MSE obtidos foram de 6,81 cm e 164,57 cm², respectivamente. A Tabela 8 mostra outros quatro modelos obtidos ordenados pelo coeficiente, onde vemos que não houve grande variação no ajuste dos modelos.

Tabela 8 – Cinco melhores modelos para a alternativa de entrada 2

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M2C1N5	243,38	7,36	326,42	8,56	164,57	6,81	0,87 (0,06)
M2C2N80	230,97	6,61	193,14	6,70	176,75	6,90	0,86 (0,04)
M2C2N50	204,58	6,35	286,75	7,76	195,43	6,67	0,85 (0,05)
M2C1N10	241,26	7,17	264,14	7,80	211,20	7,51	0,84 (0,07)
M2C2N100	209,29	6,40	291,25	7,76	238,63	7,05	0,84 (0,03)




Figura 15 – M2C1N5: (a) previsão do conjunto de teste (b) gráfico de dispersão

Alternativa de Entrada 3

Os modelos treinados com essa combinação de entrada recebem dados de precipitação com tempo de resposta de um a quatro dias. Esses modelos obtiveram desempenho inferior, onde o melhor deles, M3C1N20, resultou no coeficiente R^2 de 0,49 (0,10) e com altos valores para MAE e MSE. No gráfico de dispersão da rede M3C1N20 (Figura 16) vemos que a previsão foi muito subestimada para as cotas mais elevadas e gerou uma previsão mínima próxima de 150 cm.

Tabela 9 – Cinco melhores modelos para a alternativa de entrada 3

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M3C1N20	743,80	17,17	931,01	19,22	746,53	17,19	0,49 (0,10)
M3C1N120	752,50	17,07	879,22	18,20	906,08	18,78	0,45 (0,08)
M3C2N100	653,78	16,06	1.054,75	20,12	849,90	17,72	0,44 (0,23)
M3C4N50	736,47	16,69	738,36	16,77	869,69	18,49	0,44 (0,05)
M3C4N120	623,47	15,34	1.127,68	19,71	853,68	18,26	0,41 (0,13)

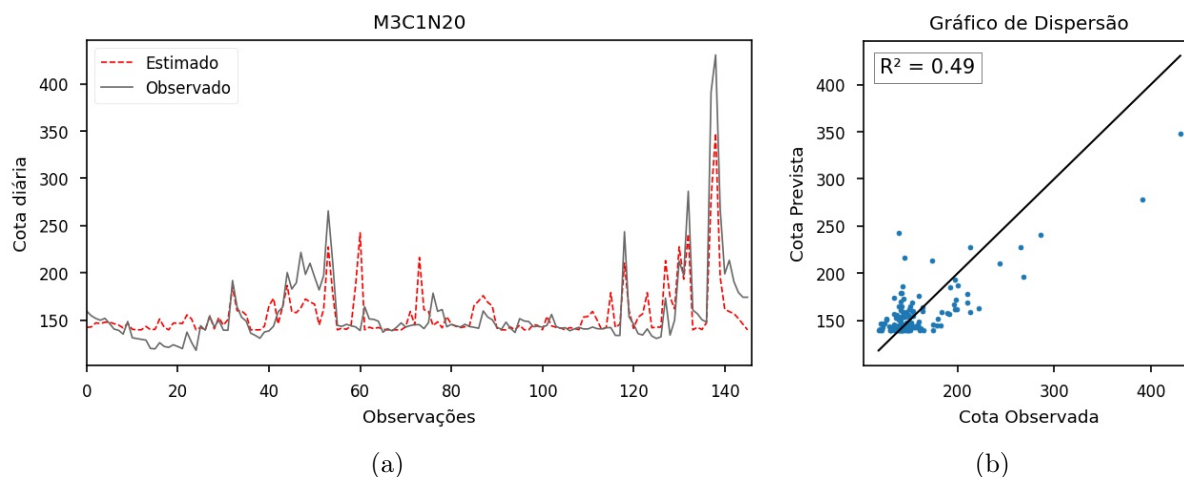


Figura 16 – M3C1N20: (a) previsão do conjunto de teste (b) gráfico de dispersão

Alternativa de Entrada 4

A combinação de entrada 4 considerou dados de pluviosidade média para $(t - 1)$, $(t - 2)$, $(t - 3)$ e $(t - 4)$, onde os valores foram encontrados pela média aritmética.

A melhor RNA produzida por essa combinação foi a M4C4N20, que obteve coeficiente R^2 de 0,45 (0,07), MAE igual a 19,44 cm e MSE de 798,97 cm^2 . Sendo portanto, a alternativa de entrada mais inferior entre as 9 propostas (Tabela 6).

A Figura 17 mostra que similar ao comportamento da do M3C1N20, o M4C4N20 obteve um valor mínimo de previsão próximo ao 150 cm, e tendeu a subestimar níveis mais elevados.

A partir dos resultados, podemos concluir que conjuntos de entrada compostos somente por dados pluviométricos não foram capazes de gerar bons modelos de previsão na Fazenda Airis.

Tabela 10 – Cinco melhores modelos para a alternativa de entrada 4

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M4C4N20	849,09	19,83	877,37	19,72	798,97	19,44	0,45 (0,07)
M4C2N50	855,27	19,94	776,27	19,14	849,32	19,67	0,38 (0,06)
M4C2N80	790,73	19,60	865,82	19,42	929,09	20,19	0,37 (0,13)
M4C1N5	896,20	20,03	978,39	20,55	788,85	19,10	0,34 (0,08)
M4C2N100	902,73	20,17	785,13	19,47	724,06	18,71	0,34 (0,11)

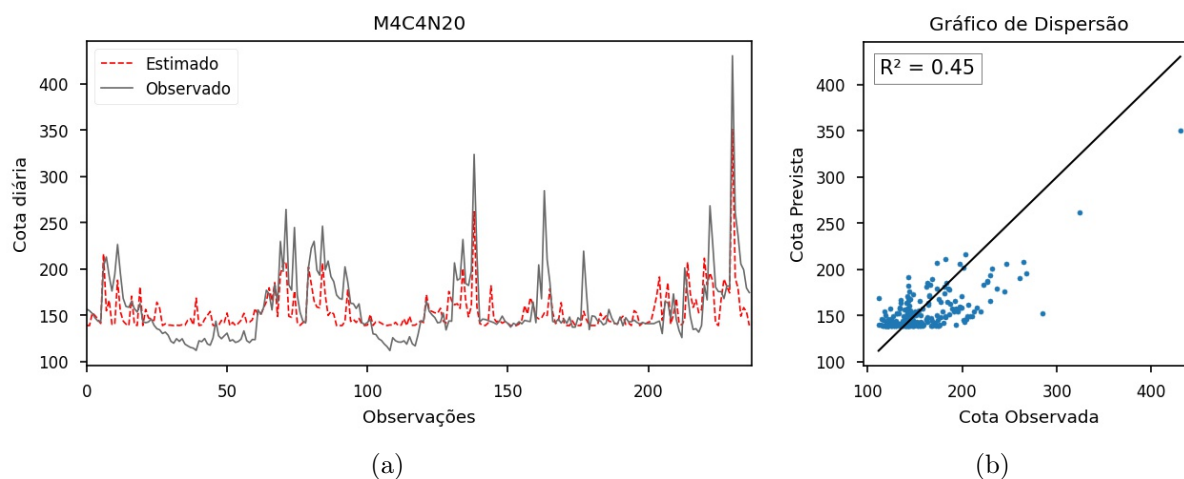


Figura 17 – M4C4N20: (a) previsão do conjunto de teste (b) gráfico de dispersão

Alternativa de entrada 5

Os resultados da Tabela 11 correspondem aos cinco melhores modelos combinaram dados de chuva média \bar{P} com as leituras das estações fluviométricas com tempo de resposta de um dia.

É possível observar que essa combinação gerou bons modelos de previsão, com coeficiente de determinação R^2 de até 0,86 e que as redes mais simples tiveram resultados tão bons quanto as redes mais complexas.

Em relação as previsões da rede M5C250, vemos que esta possui um bom ajuste nos períodos de estiagem e tende a subestimar os períodos de cheia do rio (Figura 18).

Tabela 11 – Cinco melhores modelos para a alternativa de entrada 5

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M5C2N20	252,04	6,92	422,52	8,25	182,60	6,81	0,86 (0,03)
M5C4N5	300,30	7,40	247,63	7,30	203,55	6,88	0,86 (0,07)
M5C2N120	278,12	7,07	350,61	8,38	167,99	6,72	0,85 (0,03)
M5C4N10	273,85	7,29	344,15	7,60	205,93	6,98	0,85 (0,04)
M5C1N100	309,32	7,59	223,44	7,15	210,42	7,25	0,84 (0,06)

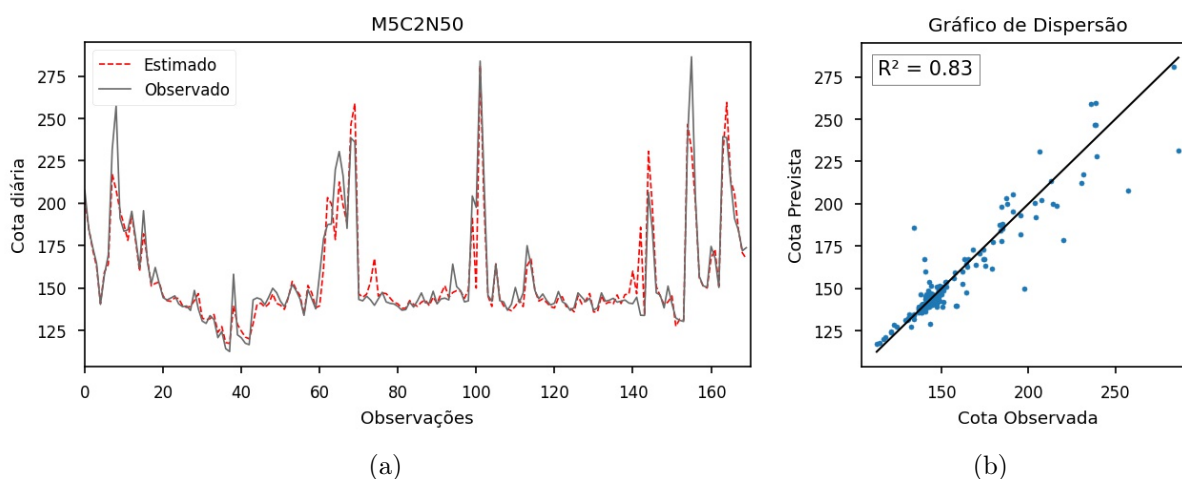


Figura 18 – M5C2N50: (a) previsão do conjunto de teste (b) gráfico de dispersão

Alternativa de Entrada 6

A combinação de entrada com somente dados fluviométricas com defasagem de um dia mostra um bom ajuste, com coeficiente de correlação de até 86%, com baixa variância (Tabela 12).

A Figura 19 mostra a previsão do melhor modelo produzido: M6C4N20. Este obteve para as métricas R^2 , MAE e MSE, os valores 0,86 (0,02), 7,57 cm e 219,29 cm^2 , respectivamente. O gráfico de dispersão do modelo M6C4N20 mostra a tendência em subestimar as previsões e o bom ajuste para cotas mais baixas.

Tabela 12 – Cinco melhores modelos para a alternativa de entrada 6

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M6C4N20	314,46	7,21	264,31	7,19	219,29	7,57	0,86 (0,02)
M6C1N20	279,32	7,35	435,38	8,53	199,44	7,09	0,84 (0,06)
M6C2N50	287,53	7,11	353,40	7,70	203,13	7,14	0,84 (0,03)
M6C4N120	325,97	7,50	238,72	7,08	198,70	6,57	0,84 (0,05)
M6C1N5	350,30	8,28	259,15	7,94	228,79	7,48	0,82 (0,07)

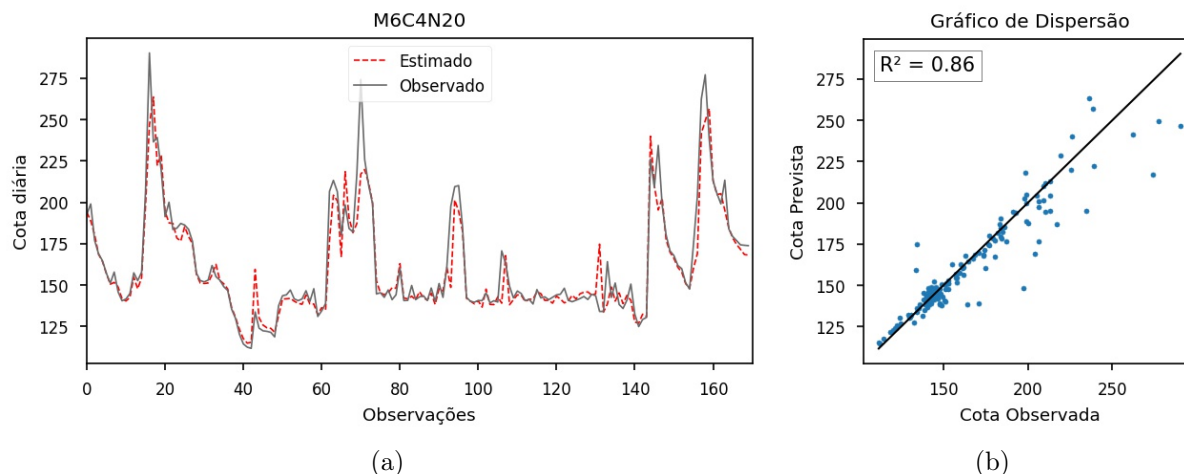


Figura 19 – M6C4N20: (a) previsão do conjunto de teste (b) gráfico de dispersão

Alternativa de Entrada 7

Os modelos treinados com a combinação de entrada 7 receberam somente dados diários de nível da estação Fazenda Airis em $(t - 1)$, para a previsão dessa mesma variável no tempo t . É um conjunto de entrada mais simples que não requer uma ampla rede de monitoramento hidrológico.

A Tabela 13 mostra os cinco melhores modelos gerados, todos com R^2 acima de 80%. Baseado nisso, concluímos que foi possível criar um modelo de previsão hidrológica com ótimo ajuste somente com dados de nível de um período anterior.

O melhor modelo criado com a alternativa de entrada 7 foi o M7C1N80 com R^2 de 0,84 (0,03). A Figura 20 mostra a previsão da rede M7C1N80 para o conjunto de teste.

Tabela 13 – Cinco melhores modelos para a alternativa de entrada 7

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M7C1N80	292,84	7,28	369,07	7,46	190,12	6,94	0,84 (0,03)
M7C2N120	287,20	7,42	340,00	7,61	224,01	7,28	0,82 (0,05)
M7C1N100	302,17	7,68	269,05	6,92	252,64	6,52	0,82 (0,07)
M7C2N50	256,36	7,27	389,42	7,68	270,06	7,44	0,82 (0,04)
M7C2N10	284,52	7,28	315,44	7,78	278,59	7,91	0,81 (0,04)

Alternativa de Entrada 8

Na Tabela 14 vemos que combinação de dados de nível da Fazenda Airis e de precipitação com defasagem de um dia gerou bons modelos de previsão. Do qual, a RNA M8C1N5, produziu as melhores métricas entre as 189 RNAs criadas, com coeficiente R^2 igual 0,88 (0,01), MAE de 7,03 cm e MSE de 178,97 cm^2 .




Figura 20 – M7C1N80: (a) previsão do conjunto de teste (b) gráfico de dispersão

Destaca-se que a arquitetura da RNA M8C1N5 é a mais simples entre as utilizadas nos experimentos, evidenciando que uma RNA do tipo MLP com uma camada oculta é suficiente para uma previsão hidrológica com boa precisão. A Figura 21 mostra o ajuste do M8C1N5 aos dados de conjunto de teste.

Tabela 14 – Cinco melhores modelos para a alternativa de entrada 8

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M8C1N5	239,92	7,00	240,90	7,18	178,97	7,03	0,88 (0,01)
M8C2N100	240,36	6,82	174,92	6,53	167,81	6,34	0,87 (0,04)
M8C4N10	200,51	6,48	266,88	7,63	153,99	6,30	0,87 (0,07)
M8C1N100	208,70	6,75	288,01	7,71	188,10	6,87	0,86 (0,05)
M8C2N5	222,95	6,83	200,87	6,76	205,31	7,27	0,86 (0,01)




Figura 21 – M8C1N5: (a) previsão do conjunto de teste (b) gráfico de dispersão

Alternativa de Entrada 9

Sem utilizar dados de nível da Fazenda Airis, a combinação de entrada 9 não produziu bons modelos, onde o coeficiente R^2 máximo de 0,53 foi obtido pela RNA M9C4N100 (Tabela 15).

Na Figura 22 vemos que o modelo M9C4N100 tende a subestimar os períodos de cheia e superestimar os períodos de estiagem.

Baseado nisso, podemos considerar que o nível da Fazenda Airis é uma das mais importantes variáveis de entrada para eficácia das previsões.

Tabela 15 – Cinco melhores modelos para a alternativa de entrada 9

Modelo	Treinamento		Validação		Teste		
	MSE	MAE	MSE	MAE	MSE	MAE	R^2
M9C4N100	566,72	12,94	839,45	14,96	715,91	13,06	0,53 (0,22)
M9C4N120	613,76	13,63	611,32	13,27	715,20	14,09	0,53 (0,05)
M9C1N5	754,17	16,20	713,57	16,26	627,91	15,66	0,51 (0,12)
M9C2N5	711,38	15,90	522,25	14,34	847,90	16,10	0,49 (0,06)
M9C1N50	677,42	15,43	655,45	15,40	788,18	16,47	0,48 (0,11)

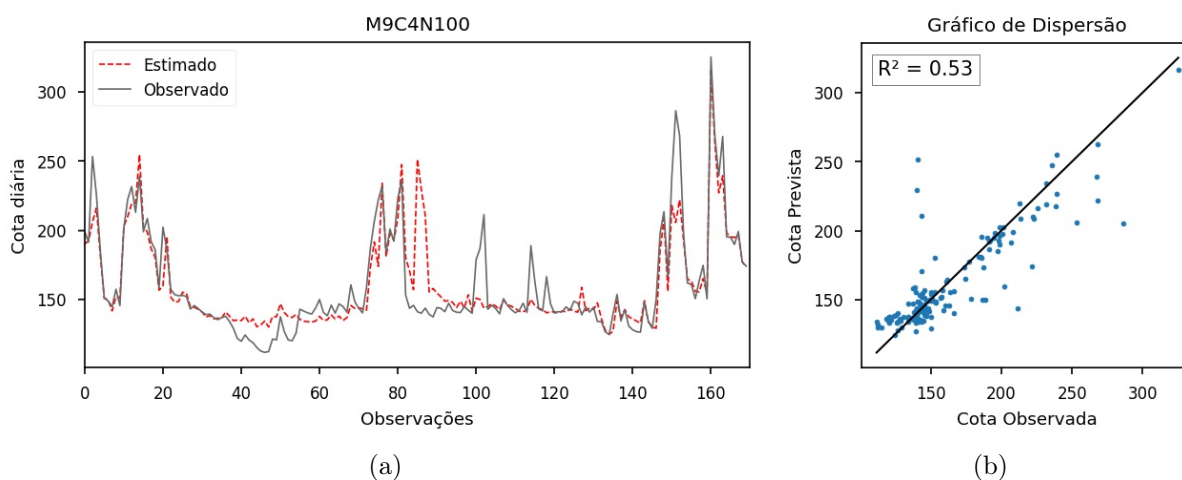


Figura 22 – M9C4N100: (a) previsão do conjunto de teste (b) gráfico de dispersão

5.4 COMPARAÇÃO COM TRABALHOS RELACIONADOS

Nessa seção os resultados obtidos são comparados com trabalhos citados na Revisão Bibliográfica. Foram selecionados trabalhos que aplicaram modelos baseados em Redes Neurais Artificiais para previsão hidrológica no Brasil em diferentes bases temporais.

Para cada trabalho, a Tabela 16 apresenta a extensão da série histórica, as variáveis de entrada e saída, juntamente com as métricas do melhor modelo obtido. Ao final, os dados do presente trabalho foram inseridos para fins de comparação.

Algumas métricas de desempenho escolhidas pelos autores não foram tratadas neste trabalho. Porém, podemos dividi-las entre métricas de ajuste e erro (DAWSON; WILBY, 2001). O coeficiente de determinação R^2 é similar ao coeficiente de desempenho Nash-Sutcliffe (NS) ao analisar o ajuste do modelo, como tratado em (DAWSON; WILBY, 2001). Enquanto que, o coeficiente de correlação de Pearson (r_p) determina o grau de correlação linear entre os valores previstos e observados, podendo variar entre -1 e 1. As demais métricas MAE, MSE, MAPE e RMSE são medidas de erro, onde MAPE refere-se a Média Percentual Absoluta do Erro e RMSE é a Raiz do Erro Médio Quadrático.

Alguns autores investigam a variação dos dados de entrada, como em (MACHADO, 2005; SOUSA; SOUSA, 2010; MATOS; PEDROLLO; CASTRO, 2014; DEBASTIANI; SILVA; NETO, 2016; CELESTE; MENEZES; FONTES, 2014). Mas é possível observar, que em sua maioria, o conjunto de dados das melhores RNA combinam dados pluviométricos e fluviométricos, concordando com as conclusões obtidas nesse trabalho. Em relação a extensão dos dados, este trabalho possui a menor série para previsão em base diária entre os estudos apresentados na Tabela 16.

Ao compararmos os resultados obtidos nesse estudo com os demais trabalhos citados na Tabela 16, vemos que os modelos desenvolvidos tiveram desempenho satisfatório. Porém observamos que é possível gerar modelos com previsões ainda mais eficientes, incentivando a continuidade deste tema.

Tabela 16 – Estudos de aplicação de Redes Neurais Artificiais para previsão hidrológica, com autores e ano de publicação, variáveis do conjunto de entrada, extensão da série histórica, saída do modelo de previsão e melhores métricas obtidas.

Autores e Ano	Variáveis de Entrada	Série Histórica	Saída	Métricas
(MACHADO, 2005)	Precipitação Vazão Evapotranspiração	1976 a 1994	Vazão mensal	$r_p = 0,886$ RMSE = 8,11
(BATISTA, 2009)	Vazão	1990 a 2007	Vazão mensal	MAPE = 0,59 MSE = 779,59
(SOUSA; SOUSA, 2010)	Precipitação Vazão	1964 a 2003	Vazão mensal	$R^2 = 0,92$ NS = 0,77 RMSE = 8,29
(MATOS; PEDROLLO; CASTRO, 2014)	Precipitação Vazão	22/08/89 a 01/06/94	Vazão diária	NS = 0,97
(CELESTE; MENEZES; FONTES, 2014)	Precipitação Vazão	1969 a 1979	Vazão mensal	NS = 0,82 $r_p = 0,95$
(DEBASTIANI; SILVA; NETO, 2016)	Precipitação Vazão	1997 a 1999	Vazão diária	NS = 0,919 $R^2 = 0,868$ RMSE = 14,29
(LIMA et al., 2016)	Precipitação Cota	2013 a 2014	Cota horária	NS = 0,982 RMSE = 1,5 MAE = 0,69
(SILVA et al., 2016)	Precipitação Vazão	05/06/1986 a 15/03/1989	Vazão diária	NS = 0,77 RMSE = 1,09
(CRISTALDO et al., 2018)	Precipitação Cota	1995 a 2014	Cota diária	$r_p = 0,95$ NS = 0,93 MAE = 0,71
(SILVA; CASTRO; VIEIRA, 2018)	Precipitação TSM	1979 a 2016	Cota mensal	MSE = 0,001 $R^2 = 0,999$
(MARAES; COSTA et al., 2019)	Cota Índices climáticos	1951 a 2017	Cota mensal	$r_p = 0,96$
(NETO et al., 2020)	TSM Pressão atmosférica	2011 a 2016	Cota mensal	$R^2 = 0,845$ RMSE = 0,233 NS = 0,834
Presente trabalho	Precipitação Cota	02/05/11 a 30/04/13	Cota diária	$R^2 = 0,88$ MSE = 178,97 MAE = 7,03

Nota: a defasagem dos dados não foi tratada na análise dos atributos.

6 CONCLUSÃO

O objetivo geral deste trabalho foi propor um modelo baseado em Redes Neurais Artificiais para previsão hidrológica em escala diária na bacia hidrográfica do rio Macaé, no litoral no Estado do Rio de Janeiro¹. A base de dados é composta por 6 estações pluviométricas e 6 estações fluviométricas situadas na bacia do rio Macaé. O objeto de previsão foi o nível diário na estação fluviométrica Fazenda Airis e o estudo da influência da arquitetura e do conjunto de treinamento foram objetivos específicos desse trabalho.

Para tal, foram estudadas 9 combinações de variáveis de entrada, diversificando as estações utilizadas e deslocamento temporal das observações. Cada alternativa de entrada foi treinado para 21 arquiteturas, que variavam o número de camadas ocultas em 1, 2 e 4 e os neurônios das camadas ocultas em 5, 10, 20, 50, 80, 100, 120. Duas técnicas de regularização foram implementadas: parada antecipada e regularização ℓ_2 . As configurações implementadas foram apresentadas na Tabela 4.

No total, foram treinadas 189 RNAs, onde 42,3% dos modelos obtiveram o coeficiente de correlação R^2 acima de 80% (Tabela 5). Resultados estes, considerados satisfatórios. A melhor RNA encontrada, M8C1N5, recebeu dados de nível da Fazenda Airis e dados de 6 estações pluviométricas com defasagem de tempo de um dia e R^2 de 0,88 com desvio padrão de 0,01.

No que se refere aos conjuntos de treinamento, observou-se que o desempenho das RNAs foi muito dependente das variáveis de entrada, de modo que as combinações de dados de vazão e precipitação se mostraram mais eficazes, com coeficiente R^2 entre 0,86 e 0,88 e MAE entre 6,34 e 7,04 cm. O uso da precipitação foi feito ora pela média aritmética, ora representado por cada estação. De forma que o uso pontual dos dados pluviométricos mostrou-se mais interessante nos modelos. Contudo, observou-se que modelos treinados somente com dados pluviométricos não obtiveram bons ajustes, com R^2 entre 0,45 e 0,49. A variável que se mostrou mais relevante na previsão foi o nível diário da Fazenda Airis com defasagem de um dia. Tendo somente essa variável de entrada, a RNA M7C1N180 produziu bom ajuste aos dados de teste e obteve R^2 igual a 0,84 (0,03).

Observou-se ainda que as arquiteturas menos complexas (i.e. com menos camada ocultas e neurônios) obtiveram desempenho similar ou superior as arquiteturas mais complexas (i.e. com mais camadas ocultas e neurônios). Um histograma das arquiteturas mais frequentes entre os melhores resultados foi apresentado.

Os resultados obtidos nos experimentos encorajam a utilização da técnica de RNAs na modelagem hidrológica, mesmo em bacias onde monitoramento e a extensão dos dados é limitado, tendo em vista que a série histórica deste trabalho foi inferior a 3 anos. Os resultados reforçam a relevância do investimento no monitoramento concomitante das

¹ O código implementado está disponível em: <https://github.com/JuliaGodinho08/RNA_Macae>.

chuvas e do nível dos rios urbanos e trechos a montante das áreas urbanas, a fim de que sejam desenvolvidas previsões mais efetivas. De forma que tais ferramentas auxiliem nas tomadas de decisão do poder público e no planejamento de recursos hídricos.

Para a continuidade deste tema em trabalhos futuros, recomenda-se implementar a técnica de RNA para modelagem hidrológica em escala mensal e horária, visando o aproveitamento das previsões em outros setores de planejamento hídrico na região. Os resultados obtidos podem ser confrontados com modelos hidrológicos convencionais.

É possível ainda abordar a influência de novas variáveis hidrológicas, como a estimativa de infiltração, umidade do solo, chuva efetiva e evapotranspiração potencial em combinação com a verificação de técnicas de verificação de atributos.

Recomenda-se ainda a investigação de outros algoritmos de otimização e a influência da extensão do conjunto de treinamento, função de ativação e de técnicas de pré-processamento. Por fim, como alternativa as RNAs, explorar a implementação de algoritmos de Redes Neurais Recorrentes, muito utilizadas para dados de séries temporais.

REFERÊNCIAS

- ALMEIDA, L.; SERRA, J. C. V. Modelos hidrológicos, tipos e aplicações mais utilizadas. **Revista da FAE**, v. 20, n. 1, p. 129–137, 2017.
- ASSUMPÇÃO, A. P.; MARÇAL, M. Retificação dos canais fluviais e mudanças geomorfológicas na planície do rio macaé (rj). **Revista de Geografia (UFPE)**, v. 29, n. 3, 2012.
- BATISTA, A. L. F. Modelos de séries temporais e redes neurais artificiais na previsão de vazão. **Mestrado em engenharia de sistemas, Universidade Federal de Lavras, Lavras, Minas Gerais**, 2009.
- CARVALHO, D. F. d.; SILVA, L. D. B. d. Hidrologia. In: UFRRJ. [S.l.], 2016. Notas de Aula.
- CELESTE, A. B.; MENEZES, T.; FONTES, V. Modelagem do processo chuva-vazão pelo tank model e por redes neurais artificiais na bacia do rio Japarutuba, Sergipe. **Scientia Plena**, v. 10, n. 7, 2014.
- CRISTALDO, M. F. et al. Previsão probabilística de enchentes para uma pequena bacia hidrográfica do pantanal. **Revista Ambiente & Água**, SciELO Brasil, v. 13, n. 4, 2018.
- DAWSON, C.; WILBY, R. Hydrological modelling using artificial neural networks. **Progress in physical Geography**, Sage Publications Sage CA: Thousand Oaks, CA, v. 25, n. 1, p. 80–108, 2001.
- DEBASTIANI, A. B.; SILVA, R. D. d.; NETO, S. L. R. Eficácia da arquitetura MLP em modo closed-loop para simulação de um sistema hidrológico. **Revista Brasileira de Recursos Hídricos**, SciELO Brasil, v. 21, n. 4, p. 821–831, 2016.
- EVSUKOFF, G. A. **Inteligência Computacional: Fundamentos e Aplicações**. [S.l.]: e-papers, 2020.
- FERREIRA, C. da C.; LIMA, C. H. R. Previsão de vazões naturais afluentes a um reservatório utilizando a técnica de redes neurais artificiais. **XIV SIMPÓSIO DE RECURSOS HÍDRICOS DO NORDESTE**, 2018.
- FREIRE, A. L.; JR, J. M. P. de M.; BARRETO, G. A. Redes neurais recorrentes para predição recursiva de séries temporais caóticas: um estudo comparativo. **IX Congresso Brasileiro de Redes Neurais**, p. 25–28, 2009.
- FREITAS, L. E. et al. Atlas ambiental da bacia hidrográfica do rio Macaé. Nova Triáde do Brasil Ltda., Rio de Janeiro, n. 1, 2015.
- GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems**. [S.l.]: O'Reilly Media, 2019.
- HAYKIN, S. **Neural networks: a comprehensive foundation**. [S.l.]: Prentice hall, 1999.

IKEMOTO, S. M. et al. Redução de risco de desastres associados a inundações. **Boletim águas Território**, v. 10, 2015.

LEKKAS, D. et al. Application of artificial neural networks for flood forecasting. **Global Nest Journal**, v. 6, n. 3, p. 205–211, 2004.

LEOPOLDO, P. R.; FRANKEN, W.; SALATI, E. Balanço hídrico de pequena bacia hidrográfica em floresta amazônica de terra firme. **Acta Amazônica**, SciELO Brasil, v. 12, n. 2, p. 333–337, 1982.

LIMA, G. R. de et al. An operational dynamical neuro-forecasting model for hydrological disasters. **Modeling Earth Systems and Environment**, Springer, v. 2, n. 2, p. 1–9, 2016.

LIMA, G. R. de; SCOFIELD, G. B. A machine learning-based model to improve shortterm forecasts of flooding in nova friburgo-rj. **Revista Brasileira de Cartografia**, v. 69, n. 1, 2017.

MACHADO, F. W. **Modelagem chuva-vazão mensal utilizando redes neurais artificiais**. Tese (Doutorado) — Dissertação de Mestrado. Universidade Federal do Paraná, 2005.

MAIER, H. R.; DANDY, G. C. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. **Environmental modelling & software**, Elsevier, v. 15, n. 1, p. 101–124, 2000.

MARAES, P.; COSTA, M. et al. Previsão de cheias sazonais para o rio negro usando redes neurais artificiais e árvores de decisão com aprendizado baseado em comitê. In: SBC. **Anais do X Workshop de Computaç ao Aplicada a Gest ao do Meio Ambiente e Recursos Naturais**. [S.l.], 2019. p. 47–56.

MATOS, A.; PEDROLLO, O. C.; CASTRO, N. Efeito do controle de montante de sub-bacias embutidas na previs ao hidrológica de curto prazo com redes neurais: Aplicação à bacia de ponte mística. **Revista Brasileira De Recursos Hídricos**, v. 19, n. 1, p. 87–99, 2014.

MELLO, Y. R. de; KOHLS, W.; OLIVEIRA, T. M. N. de. Uso de diferentes métodos para o preenchimento de falhas em estações pluviométricas. **Boletim de Geografia**, v. 35, n. 1, p. 112–121, 2017.

MIRANDA, R. A. C. de; OLIVEIRA, M. V. S. de; SILVA, D. F. da. Ciclo hidrográfico planetário: abordagens e conceitos. **Geo Uerj**, v. 1, n. 21, p. 109–119, 2010.

MÜLLER, A. C.; GUIDO, S. **Introduction to machine learning with Python: a guide for data scientists**. [S.l.]: "O'Reilly Media, Inc.", 2016.

NETO, L. A. dos S. et al. Modelagem hidroclimatologica utilizando redes neurais multi layer perceptron em bacia hidrográfica no sudoeste da amazônia. **Revista Brasileira de Climatologia**, v. 26, 2020.

OLIVEIRA, G. G. de; PEDROLLO, O. C.; CASTRO, N. M. dos R. Metodologia de análise de sensibilidade e exclusão de variáveis de entrada em simulação hidrológica por redes. **XIX Simpósio Brasileiro de Recursos Hídricos**, 2011.

RODRIGUES, M.; COSTA, M.; FILHO, C. C. Proposta de um método para previsão de cheias sazonais utilizando redes neurais artificiais: Uma aplicação ao rio Amazonas. In: SBC. **Anais do VI Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais**. [S.l.], 2015. p. 1–10.

ROY, J.; GUPTA, D.; GOSWAMI, S. An improved flood warning system using wsn and artificial neural network. In: IEEE. **2012 Annual IEEE India Conference (INDICON)**. [S.l.], 2012. p. 770–774.

SARMENTO, L. Monitoramento hidrometeorológico no Brasil: uma análise sob a ótica da coordenação de políticas públicas. **Revista de Gestão de Água da América Latina**, 2021.

SHAMSELDIN, A. Y. Artificial neural network model for river flow forecasting in a developing country. **Journal of Hydroinformatics**, IWA Publishing, v. 12, n. 1, p. 22–35, 2010.

SILVA, A. G. da; CASTRO, A. R. G.; VIEIRA, A. C. Modelo de previsão hidrológica utilizando redes neurais artificiais: um estudo de caso na bacia do rio Xingu - Altamira-PA. **Revista Brasileira de Computação Aplicada**, v. 10, n. 3, p. 55–62, 2018.

SILVA, M. R. da et al. Utilização de redes neurais artificiais em alertas hidrológicos: Estudo de caso na bacia do rio Claro em Caraguatatuba, estado de São Paulo. **Anuário do Instituto de Geociências**, v. 39, n. 1, p. 23–31, 2016.

SOUSA, R. dos S.; GUEDES, E. B.; OLIVEIRA, M. B. L. de. Previsão anual de precipitações em Manaus, Amazonas: Um comparativo de técnicas de aprendizado de máquina. In: SBC. **Anais do IX Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais**. [S.l.], 2018.

SOUSA, W. d. S.; SOUSA, F. d. A. de. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio Piancó. **Revista Brasileira de Engenharia Agrícola e Ambiental**, SciELO Brasil, v. 14, n. 2, p. 173–180, 2010.

TUCCI, C. E.; CLARKE, R. T. Impacto das mudanças da cobertura vegetal no escoamento: revisão. **Revista Brasileira de Recursos Hídricos**, v. 2, n. 1, p. 135–152, 1997.

TUCCI, C. E. et al. **Modelos hidrológicos**. [S.l.]: Editora da UFRGS Porto Alegre, 2005.

TUCCI, C. E. et al. **Hidrologia: ciência e aplicação**. São Paulo: Editora da, 2012.

TUCCI, C. E.; SILVEIRA, A. Gerenciamento da drenagem urbana. **Porto Alegre**, 2001.

VASILEV, I. et al. **Python Deep Learning: Exploring deep learning techniques and neural network architectures with PyTorch, Keras, and TensorFlow**. [S.l.]: Packt Publishing Ltd, 2019.

VASSALLI, L. C. Aplicação de redes neurais LSTM para a previsão de curto prazo de vazão do rio Paraíba do Sul. 2018.

ANEXOS

ANEXO A – RESULTADOS DAS REDES NEURAIS ARTIFICIAIS

N	Modelo	Treinamento		Validação		Teste		
		MSE	MAE	MSE	MAE	MSE	MAE	R^2
1	M1C1N5	248,68	7,74	252,86	7,52	237,86	7,13	0,82 (0,09)
2	M1C1N10	248,02	7,32	229,24	7,22	209,27	7,26	0,82 (0,06)
3	M1C1N20	206,51	6,68	253,06	7,06	215,36	6,76	0,84 (0,05)
4	M1C1N50	199,51	6,51	196,18	6,45	275,19	7,15	0,79 (0,04)
5	M1C1N80	221,09	6,60	264,39	7,25	157,33	6,64	0,85 (0,02)
6	M1C1N100	200,58	6,59	260,01	7,38	240,98	7,35	0,82 (0,03)
7	M1C1N120	213,55	6,80	270,69	7,28	243,16	7,16	0,81 (0,05)
8	M1C2N5	239,97	6,91	138,48	6,24	195,16	6,67	0,88 (0,05)
9	M1C2N10	232,62	6,76	184,85	6,19	179,22	6,60	0,86 (0,06)
10	M1C2N20	164,69	6,05	308,96	7,49	312,03	7,53	0,78 (0,05)
11	M1C2N50	195,72	6,28	237,77	6,94	234,88	7,13	0,82 (0,03)
12	M1C2N80	237,05	6,75	172,85	6,32	171,12	6,77	0,87 (0,04)
13	M1C2N100	197,54	6,44	264,37	7,04	236,65	6,83	0,84 (0,03)
14	M1C2N120	200,79	6,49	265,51	7,18	195,13	6,41	0,85 (0,05)
15	M1C4N5	191,65	6,31	281,48	7,53	200,13	6,64	0,84 (0,07)
16	M1C4N10	201,41	6,56	255,90	7,09	180,78	6,34	0,88 (0,04)
17	M1C4N20	210,42	6,47	128,78	5,82	271,02	7,37	0,82 (0,04)
18	M1C4N50	187,44	6,11	242,87	7,26	227,30	6,86	0,85 (0,04)
19	M1C4N80	181,26	6,25	224,80	6,86	239,01	6,64	0,83 (0,07)
20	M1C4N100	173,40	6,18	150,12	6,14	265,73	6,80	0,8 (0,03)
21	M1C4N120	184,85	6,27	177,50	6,08	250,85	6,98	0,84 (0,03)
22	M2C1N5	243,38	7,36	326,42	8,56	164,57	6,81	0,87 (0,06)
23	M2C1N10	241,26	7,17	264,14	7,80	211,20	7,51	0,84 (0,07)
24	M2C1N20	242,07	7,05	234,47	7,25	233,59	7,62	0,82 (0,09)
25	M2C1N50	230,31	6,82	303,65	8,07	244,29	7,64	0,82 (0,05)
26	M2C1N80	236,42	6,91	220,09	6,92	227,23	7,29	0,82 (0,05)
27	M2C1N100	231,76	6,79	205,34	6,76	251,11	7,81	0,83 (0,05)
28	M2C1N120	215,47	6,66	243,42	7,18	252,47	7,65	0,81 (0,05)
29	M2C2N5	219,07	6,91	199,39	6,72	253,82	7,10	0,83 (0,03)
30	M2C2N10	198,35	6,63	304,68	7,98	235,34	7,22	0,8 (0,05)
31	M2C2N20	177,57	6,56	291,31	7,63	341,80	8,12	0,75 (0,1)
32	M2C2N50	204,58	6,35	286,75	7,76	195,43	6,67	0,85 (0,05)
33	M2C2N80	230,97	6,61	193,14	6,70	176,75	6,90	0,86 (0,04)
34	M2C2N100	209,29	6,40	291,25	7,76	238,63	7,05	0,84 (0,03)
35	M2C2N120	209,49	6,49	207,87	6,63	261,40	7,39	0,84 (0,05)

Continuação								
N	Modelo	Treinamento		Validação		Teste		
		MSE	MAE	MSE	MAE	MSE	MAE	R^2
36	M2C4N5	201,92	6,50	263,06	7,27	239,28	7,38	0,83 (0,05)
37	M2C4N10	210,90	6,60	225,58	7,40	259,79	7,13	0,83 (0,05)
38	M2C4N20	221,99	6,73	143,25	6,16	230,63	7,06	0,78 (0,04)
39	M2C4N50	206,57	6,20	172,77	6,63	190,21	6,54	0,84 (0,07)
40	M2C4N80	156,26	5,61	279,08	7,60	258,65	7,51	0,79 (0,06)
41	M2C4N100	151,66	5,59	294,28	7,33	286,88	7,77	0,79 (0,07)
42	M2C4N120	174,10	5,85	256,15	6,89	211,38	6,43	0,83 (0,05)
43	M3C1N5	806,45	17,70	782,39	17,68	797,27	17,91	0,28 (0,15)
44	M3C1N10	774,86	17,45	785,57	17,85	900,16	17,94	0,3 (0,12)
45	M3C1N20	743,80	17,17	931,01	19,22	746,53	17,19	0,49 (0,1)
46	M3C1N50	777,77	17,24	841,82	18,38	783,09	18,15	0,37 (0,06)
47	M3C1N80	843,26	17,82	718,56	17,75	745,00	17,65	0,26 (0,2)
48	M3C1N100	744,11	17,09	896,83	18,05	867,01	19,02	0,26 (0,05)
49	M3C1N120	752,50	17,07	879,22	18,20	906,08	18,78	0,45 (0,08)
50	M3C2N5	717,27	17,29	903,39	18,27	800,29	17,61	0,28 (0,13)
51	M3C2N10	712,00	17,07	915,96	18,44	838,95	18,39	0,32 (0,14)
52	M3C2N20	751,38	16,97	792,33	18,18	850,15	18,28	0,4 (0,1)
53	M3C2N50	740,73	17,02	838,03	18,02	772,37	17,49	0,32 (0,22)
54	M3C2N80	700,65	16,38	847,39	18,32	787,98	17,52	0,25 (0,22)
55	M3C2N100	653,78	16,06	1.054,75	20,12	849,90	17,72	0,44 (0,23)
56	M3C2N120	723,93	16,53	739,23	17,69	899,69	18,58	0,36 (0,09)
57	M3C4N5	759,52	17,05	843,94	18,17	741,00	17,86	0,26 (0,18)
58	M3C4N10	734,86	16,94	851,77	18,51	844,58	18,39	0,35 (0,1)
59	M3C4N20	768,76	16,96	645,14	16,52	954,71	19,10	0,31 (0,14)
60	M3C4N50	736,47	16,69	738,36	16,77	869,69	18,49	0,44 (0,05)
61	M3C4N80	703,38	16,45	668,72	16,06	932,32	19,04	0,18 (0,27)
62	M3C4N100	676,57	15,88	844,16	18,05	1.020,71	19,38	0,32 (0,06)
63	M3C4N120	623,47	15,34	1.127,68	19,71	853,68	18,26	0,41 (0,13)
64	M4C1N5	896,20	20,03	978,39	20,55	788,85	19,10	0,34 (0,08)
65	M4C1N10	880,19	19,73	859,52	19,95	986,80	20,81	0,3 (0,05)
66	M4C1N20	926,06	20,17	821,73	19,48	881,91	19,82	0,31 (0,05)
67	M4C1N50	907,75	20,01	857,95	20,04	909,72	19,82	0,25 (0,03)
68	M4C1N80	904,46	20,13	835,37	19,49	850,66	19,45	0,28 (0,05)
69	M4C1N100	848,19	19,58	917,86	20,09	1.021,96	21,06	0,34 (0,06)
70	M4C1N120	855,65	19,60	910,06	19,98	956,42	20,84	0,29 (0,09)
71	M4C2N5	865,12	19,83	800,78	19,64	891,92	19,83	0,34 (0,04)
72	M4C2N10	866,99	19,89	736,07	18,50	952,27	20,79	0,29 (0,12)

Continuação								
N	Modelo	Treinamento		Validação		Teste		
		MSE	MAE	MSE	MAE	MSE	MAE	R^2
73	M4C2N20	838,77	19,69	821,05	19,38	951,96	20,51	0,32 (0,1)
74	M4C2N50	855,27	19,94	776,27	19,14	849,32	19,67	0,38 (0,06)
75	M4C2N80	790,73	19,60	865,82	19,42	929,09	20,19	0,37 (0,13)
76	M4C2N100	902,73	20,17	785,13	19,47	724,06	18,71	0,34 (0,11)
77	M4C2N120	820,08	19,40	830,25	19,79	885,60	20,45	0,3 (0,12)
78	M4C4N5	848,43	19,71	882,29	20,34	876,45	19,72	0,32 (0,12)
79	M4C4N10	854,04	19,70	823,20	19,80	874,47	19,94	0,33 (0,07)
80	M4C4N20	849,09	19,83	877,37	19,72	798,97	19,44	0,45 (0,07)
81	M4C4N50	792,47	19,61	937,88	20,33	898,73	19,66	0,3 (0,07)
82	M4C4N80	840,02	19,64	781,94	19,66	904,64	20,08	0,33 (0,16)
83	M4C4N100	856,21	19,91	780,76	18,80	916,05	20,49	0,33 (0,06)
84	M4C4N120	820,49	19,71	807,55	18,94	928,98	20,46	0,32 (0,13)
85	M5C1N5	271,00	7,66	270,05	7,75	350,96	8,26	0,77 (0,09)
86	M5C1N10	289,82	7,59	255,78	7,54	285,91	7,57	0,8 (0,07)
87	M5C1N20	261,29	7,59	316,40	7,84	346,81	8,19	0,78 (0,07)
88	M5C1N50	281,13	7,16	222,20	7,15	272,77	7,51	0,81 (0,05)
89	M5C1N80	253,22	7,27	279,24	7,57	337,56	7,61	0,79 (0,11)
90	M5C1N100	309,32	7,59	223,44	7,15	210,42	7,25	0,84 (0,06)
91	M5C1N120	224,08	6,78	355,52	7,95	316,55	8,12	0,82 (0,04)
92	M5C2N5	243,01	7,12	320,50	7,39	326,08	8,03	0,8 (0,07)
93	M5C2N10	248,29	7,03	276,68	7,45	341,19	8,20	0,75 (0,09)
94	M5C2N20	252,04	6,92	422,52	8,25	182,60	6,81	0,86 (0,03)
95	M5C2N50	265,43	7,28	220,95	7,07	338,54	7,44	0,78 (0,08)
96	M5C2N80	274,83	7,13	216,05	7,09	310,30	7,81	0,81 (0,08)
97	M5C2N100	260,59	7,25	276,44	7,38	289,89	6,99	0,78 (0,07)
98	M5C2N120	278,12	7,07	350,61	8,38	167,99	6,72	0,85 (0,03)
99	M5C4N5	300,30	7,40	247,63	7,30	203,55	6,88	0,86 (0,07)
100	M5C4N10	273,85	7,29	344,15	7,60	205,93	6,98	0,85 (0,04)
101	M5C4N20	273,28	7,28	235,43	6,92	298,75	7,66	0,79 (0,06)
102	M5C4N50	267,72	7,11	311,80	7,88	212,68	6,60	0,84 (0,06)
103	M5C4N80	262,80	7,13	171,70	6,79	387,77	7,91	0,74 (0,1)
104	M5C4N100	286,40	7,60	251,59	6,94	231,58	6,58	0,83 (0,05)
105	M5C4N120	249,17	6,98	308,20	7,48	271,08	7,36	0,8 (0,08)
106	M6C1N5	350,30	8,28	259,15	7,94	228,79	7,48	0,82 (0,07)
107	M6C1N10	321,87	8,20	283,37	8,27	320,18	7,95	0,76 (0,09)
108	M6C1N20	279,32	7,35	435,38	8,53	199,44	7,09	0,84 (0,06)
109	M6C1N50	289,14	7,41	232,91	7,09	366,24	7,98	0,77 (0,11)

Continuação								
N	Modelo	Treinamento		Validação		Teste		
		MSE	MAE	MSE	MAE	MSE	MAE	R^2
110	M6C1N80	278,19	7,15	331,13	7,80	291,70	7,52	0,79 (0,08)
111	M6C1N100	287,78	7,17	290,83	7,35	302,40	8,03	0,78 (0,06)
112	M6C1N120	317,21	7,52	216,17	6,67	292,32	8,01	0,79 (0,07)
113	M6C2N5	317,58	7,64	204,95	6,87	303,63	7,58	0,76 (0,06)
114	M6C2N10	303,31	7,46	270,03	7,57	267,86	7,15	0,8 (0,05)
115	M6C2N20	281,35	7,20	274,68	7,31	324,78	7,98	0,77 (0,06)
116	M6C2N50	287,53	7,11	353,40	7,70	203,13	7,14	0,84 (0,03)
117	M6C2N80	292,40	7,35	245,00	6,81	301,18	7,38	0,79 (0,07)
118	M6C2N100	306,80	7,29	269,79	7,75	247,47	6,99	0,8 (0,07)
119	M6C2N120	266,84	7,15	411,22	8,07	225,92	7,29	0,81 (0,03)
120	M6C4N5	287,60	7,22	341,34	7,51	239,50	7,97	0,79 (0,06)
121	M6C4N10	246,67	7,09	341,11	7,75	354,04	7,72	0,79 (0,07)
122	M6C4N20	314,46	7,21	264,31	7,19	219,29	7,57	0,86 (0,02)
123	M6C4N50	273,26	7,15	300,32	7,58	314,04	7,48	0,77 (0,08)
124	M6C4N80	296,42	7,38	198,81	7,19	343,65	7,26	0,75 (0,13)
125	M6C4N100	296,62	7,43	238,21	6,97	291,75	7,21	0,78 (0,06)
126	M6C4N120	325,97	7,50	238,72	7,08	198,70	6,57	0,84 (0,05)
127	M7C1N5	289,89	7,71	252,14	7,01	345,86	7,89	0,76 (0,05)
128	M7C1N10	294,97	7,52	213,59	7,39	350,44	7,47	0,75 (0,07)
129	M7C1N20	251,85	7,19	251,47	7,37	446,44	8,77	0,72 (0)
130	M7C1N50	263,08	7,05	311,49	7,43	334,05	7,83	0,75 (0,04)
131	M7C1N80	292,84	7,28	369,07	7,46	190,12	6,94	0,84 (0,03)
132	M7C1N100	302,17	7,68	269,05	6,92	252,64	6,52	0,82 (0,07)
133	M7C1N120	277,78	7,20	268,24	7,28	327,70	7,62	0,76 (0,07)
134	M7C2N5	242,85	7,68	374,05	7,67	349,34	6,93	0,73 (0)
135	M7C2N10	284,52	7,28	315,44	7,78	278,59	7,91	0,81 (0,04)
136	M7C2N20	281,75	7,28	302,74	7,75	294,19	7,80	0,79 (0,05)
137	M7C2N50	256,36	7,27	389,42	7,68	270,06	7,44	0,82 (0,04)
138	M7C2N80	228,44	6,99	377,83	7,71	366,93	8,59	0,75 (0,09)
139	M7C2N100	248,52	7,00	250,43	7,62	428,34	8,21	0,73 (0,07)
140	M7C2N120	287,20	7,42	340,00	7,61	224,01	7,28	0,82 (0,05)
141	M7C4N5	272,02	7,27	308,60	7,50	307,89	7,64	0,79 (0,03)
142	M7C4N10	299,90	7,52	258,71	6,84	277,64	7,68	0,79 (0,04)
143	M7C4N20	271,54	7,36	278,09	7,44	347,52	7,85	0,77 (0,07)
144	M7C4N50	280,85	7,51	294,68	7,78	304,15	7,30	0,78 (0,04)
145	M7C4N80	253,63	7,42	315,50	8,08	358,87	7,11	0,7 (0,13)
146	M7C4N100	270,53	7,39	308,24	7,25	308,67	7,73	0,77 (0,03)

Continuação								
N	Modelo	Treinamento		Validação		Teste		
		MSE	MAE	MSE	MAE	MSE	MAE	R^2
147	M7C4N120	296,85	7,55	246,89	6,87	290,32	7,68	0,79 (0,07)
148	M8C1N5	239,92	7,00	240,90	7,18	178,97	7,03	0,88 (0,01)
149	M8C1N10	209,81	6,82	288,14	6,86	215,67	7,66	0,84 (0,04)
150	M8C1N20	236,93	7,16	222,98	6,99	185,26	6,66	0,85 (0,04)
151	M8C1N50	215,83	7,01	278,59	7,45	186,08	6,57	0,84 (0,03)
152	M8C1N80	199,17	6,55	150,16	6,57	327,14	7,90	0,78 (0,07)
153	M8C1N100	208,70	6,75	288,01	7,71	188,10	6,87	0,86 (0,05)
154	M8C1N120	224,71	6,89	213,56	6,64	273,08	7,33	0,82 (0,03)
155	M8C2N5	222,95	6,83	200,87	6,76	205,31	7,27	0,86 (0,01)
156	M8C2N10	223,51	6,95	199,93	6,54	169,39	6,75	0,86 (0,04)
157	M8C2N20	220,59	6,74	178,71	6,60	217,59	6,80	0,84 (0,09)
158	M8C2N50	206,04	6,72	206,57	6,58	232,89	6,56	0,82 (0,05)
159	M8C2N80	198,15	6,64	161,65	6,35	266,76	6,84	0,78 (0,09)
160	M8C2N100	240,36	6,82	174,92	6,53	167,81	6,34	0,87 (0,04)
161	M8C2N120	178,39	6,34	164,49	6,53	364,98	7,77	0,74 (0,03)
162	M8C4N5	208,68	6,83	209,43	6,61	194,07	6,63	0,83 (0,09)
163	M8C4N10	200,51	6,48	266,88	7,63	153,99	6,30	0,87 (0,07)
164	M8C4N20	191,66	6,68	318,40	7,51	169,63	5,79	0,85 (0,04)
165	M8C4N50	206,66	6,42	186,30	6,77	214,62	6,80	0,84 (0,04)
166	M8C4N80	165,33	6,13	263,36	6,88	238,30	6,92	0,83 (0,03)
167	M8C4N100	178,48	6,20	261,48	7,18	216,02	6,78	0,84 (0,04)
168	M8C4N120	202,95	6,58	177,53	6,41	182,66	6,44	0,83 (0,1)
169	M9C1N5	754,17	16,20	713,57	16,26	627,91	15,66	0,51 (0,12)
170	M9C1N10	711,32	16,01	635,28	16,10	709,40	16,80	0,48 (0,11)
171	M9C1N20	678,88	15,73	687,37	15,94	792,72	16,30	0,39 (0,03)
172	M9C1N50	677,42	15,43	655,45	15,40	788,18	16,47	0,48 (0,11)
173	M9C1N80	672,35	15,88	762,14	15,94	823,37	16,47	0,44 (0,08)
174	M9C1N100	656,22	15,51	788,50	16,19	821,28	16,84	0,35 (0,16)
175	M9C1N120	717,55	16,16	590,81	15,54	736,64	16,11	0,45 (0,07)
176	M9C2N5	711,38	15,90	522,25	14,34	847,90	16,10	0,49 (0,06)
177	M9C2N10	653,22	14,93	711,85	15,67	794,95	16,51	0,45 (0,04)
178	M9C2N20	580,93	14,59	1.047,59	17,42	696,72	16,03	0,48 (0,12)
179	M9C2N50	600,83	14,18	794,65	15,51	846,28	16,28	0,45 (0,08)
180	M9C2N80	658,16	14,74	662,00	15,11	786,94	15,55	0,44 (0,12)
181	M9C2N100	621,08	14,41	804,52	14,97	824,95	15,43	0,36 (0,12)
182	M9C2N120	667,91	14,83	675,69	14,70	952,96	15,82	0,39 (0,07)
183	M9C4N5	581,92	14,75	1.000,71	17,28	793,34	15,15	0,44 (0,07)

Continuação								
N	Modelo	Treinamento		Validação		Teste		
		MSE	MAE	MSE	MAE	MSE	MAE	R^2
184	M9C4N10	710,20	15,47	665,98	14,67	752,19	14,90	0,44 (0,16)
185	M9C4N20	670,61	15,32	681,07	15,01	776,31	15,53	0,42 (0,08)
186	M9C4N50	584,76	13,85	791,22	15,32	1.175,73	16,32	0,27 (0,05)
187	M9C4N80	620,28	13,76	689,29	13,82	773,81	14,73	0,46 (0,11)
188	M9C4N100	566,72	12,94	839,45	14,96	715,91	13,06	0,53 (0,22)
189	M9C4N120	613,76	13,63	611,32	13,27	715,20	14,09	0,53 (0,05)
Fim da Tabela								