

UFPA

PPGEC

Universidade Federal do Pará



EVANICE PINHEIRO GOMES

AVALIAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL HÍBRIDOS NA ESTIMATIVA DE PRECIPITAÇÕES

Instituto de Tecnologia
Programa de Pós-Graduação em Engenharia Civil

Orientador: Prof. Claudio José Cavalcante Blanco, Ph.D.

Belém – Pará – Brasil

2022

Evanice Pinheiro Gomes

**AVALIAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL
HÍBRIDOS NA ESTIMATIVA DE PRECIPITAÇÕES**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil, da Universidade Federal do Pará, como requisito parcial para obtenção do grau de Doutor em Engenharia Civil.

Área de Concentração: Engenharia Hídrica

Orientador: Prof. Claudio José Cavalcante Blanco, Ph.D.

Belém
2022

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a)
autor(a)

- P654a Pinheiro, Evanice Gomes.
Avaliação de Modelos de Inteligência Artificial Híbridos
na Estimativa de Precipitações / Evanice Gomes Pinheiro. —
2022.
110 f. : il. color.
- Orientador(a): Prof. Dr. Claudio José Cavalcante Blanco
Coorientador(a): Prof. Dr. Claudio José Cavalcante
Blanco
Tese (Doutorado) - Universidade Federal do Pará,
Instituto de Tecnologia, Programa de Pós-Graduação em
Engenharia Civil, Belém, 2022.
1. Inteligência Artificial. 2. Redes Neurais. 3.
Decomposição Wavelet de Máxima Sobreposição. 4.
CMORPH. 5. Estimativa de precipitações. I. Título.

CDD 624



AVALIAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL HÍBRIDOS NA ESTIMATIVA DE PRECIPITAÇÕES

AUTORA:

EVANICE PINHEIRO GOMES

TESE SUBMETIDA À BANCA
EXAMINADORA APROVADA PELO
COLEGIADO DO PROGRAMA DE PÓS-
GRADUAÇÃO EM ENGENHARIA CIVIL DO
INSTITUTO DE TECNOLOGIA DA

APROVADO EM: 18 / 03 / 2022.

BANCA EXAMINADORA:

Prof. Claudio José Cavalcante Blanco, Ph.D.
Orientador (UFPA)

Prof. Dr. Gustavo Barbosa Lima da Silva
Membro Externo (UFPB)

Prof. Dr. Francisco Carlos Lira Pessoa
Membro Interno (UFPA)

Prof. Dr. Nelio Moura de Figueiredo
Membro Interno (UFPA)

Visto:

Prof. Dr. Marcelo de Souza Picanço
Coordenador do PPGEC / ITEC / UFPA

Dedico este trabalho ao meu pai Joaquim Barbosa Gomes (in memoriam), que sempre com seu remo em punho, navegou pelos rios da Amazônia e nos ensinou a lutar pela vida, de forma muito alegre e positiva, apesar de muitas tormentas vividas.

AGRADECIMENTOS

À Deus por me guiar e permitir que eu pudesse chegar à conclusão desta etapa em minha vida.

A toda minha família, em especial ao meu pai Joaquim Barbosa Gomes (in memoriam), minha mãe Raimunda Pinheiro dos Passos, aos meus irmãos Benedito Aldemir (in memoriam), Gorete, Lucia, Zózimo, Bielson, Lindeus, Ruth, Ilma e Antônia por sempre me apoiarem e confiarem em mim.

Ao meu companheiro Edson, por toda paciência, compreensão, carinho e amor. Aos meus enteados Evelyn e Eder, e também ao meu afilhado Erick. Obrigado por estar comigo durante toda essa jornada, compartilhando dores, alegrias, tristezas, planos e sonhos.

Ao meu orientador, professor Claudio Blanco, pela oportunidade que me deu de evoluir como pessoa e profissional, acreditando em minha capacidade. Agradeço por todo auxílio, orientação e amizade. O senhor tem a minha admiração!

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de doutorado.

Aos colegas do Grupo de Pesquisa em Água, Energia e Sustentabilidade da Amazônia (GAES) da Universidade Federal do Pará (UFPA) pelo apoio durante a elaboração da tese e pelos momentos de descontração, essenciais para criar laços de amizade que irei levar para vida toda. Em especial a Patrícia da Silva Holanda, pelo grande apoio e incentivo.

À maravilhosa Sanny Assis, por todo suporte durante essa jornada no Programa de Pós-Graduação em Engenharia Civil.

A todos que não foram citados, mas que também contribuíram direta e indiretamente para que eu concluísse o doutorado, o meu mais sincero agradecimento. Muito obrigado!

Estudar as manifestações da natureza é trabalho que agrada a Deus. É o mesmo que rezar, que orar. Procurando conhecer as leis naturais, glorificando o primeiro inventor, o artista do Universo, se aprende a amá-lo, pois que um grande amor a Deus nasce de um grande saber.

(Leonardo da Vinci)

RESUMO

As análises hidrológicas realizadas a partir das precipitações na Amazônia são essenciais devido a sua importância na regulação do clima, na circulação atmosférica regional e global. No entanto, nesta região, existem limitações relacionadas a séries de dados com períodos curtos e muitas falhas, sobretudo na escala diária. Apesar dos avanços significativos em ciência e tecnologia, previsões práticas e precisas tem sido uma grande preocupação, devido a sua complexidade. Portanto, vários modelos conceituais, empíricos ou híbridos vêm sendo testados para estimativas de chuva com maior precisão. Dentre os modelos empíricos, os que incorporam métodos de inteligência artificial (IA) são abordagens potencialmente úteis para simular o processo de precipitação. As Redes Neurais Artificiais (RNA), como modelos de IA, são capazes de estabelecer uma relação entre entradas históricas (chuva, vazão, etc.) e as saídas desejadas, através de função não linear composta de vários fatores que são ajustados aos dados observados, permitindo sua estimativa. Assim, para melhorar as análises de precipitações, foi desenvolvido modelos híbridos, envolvendo Rede Neural Artificial (RNA) do tipo com Retardo de Tempo (TDNN), rede ELMAN, rede de Base Radial (RBF) e Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS), acoplado com Wavelet Discreta de Máxima Sobreposição (MODWT). Adotaram-se 6 estações pluviométricas, que estão localizados em diferentes biomas da região, e dados de satélite (CMORPH). Os dados de chuva foram avaliados por períodos sazonais (chuvoso e menos chuvoso). Os resultados obtidos demonstraram que o modelo MODWT-ANFIS teve a melhor capacidade em simular as precipitações diárias das estações pluviométricas avaliadas, mesmo para períodos menos chuvoso, que são sabidamente mais difíceis de serem simulados em relação aos períodos chuvosos. Nesse caso, as entradas de dados defasadas para 4 dias e 5 dias apresentaram melhor desempenho, com valores de Nash próximos a 1,0 e erros médios quadráticos inferiores a 0,001.

Palavras Chave - Inteligência Artificial, Redes Neurais, Decomposição Wavelet, Entradas com atraso de tempo, CMORPH, Amazônia.

ABSTRACT

The hydrological analyzes carried out from rainfall in the Amazon are essential due to its importance in climate regulation, regional and global atmospheric circulation. However, in this region, there are limitations related to data series with short periods and many flaws, especially in the daily scale. Despite significant advances in science and technology, practical and accurate predictions have been a major concern due to their complexity. Therefore, several conceptual models, empirical or hybrid, have been tested to forecast rain with greater precision. Among empirical models, those that incorporate artificial intelligence (AI) methods are potentially useful approaches to simulate the precipitation process. Artificial Neural Networks (ANN), as AI models, are able to establish a relationship between historical inputs (rain, flow, etc.) and the desired outputs, through a non-linear function composed of several factors that are adjusted to the observed data, allowing your prediction. Thus, to improve the precipitation analysis, hybrid models were developed, involving Artificial Neural Network (ANN) of the type with Time Delay (TDNN), ELMAN network, Radial Base network (RBF) and Adaptive Neuro-Fuzzy Inference System (ANFIS), coupled with Maximum Overlap Discrete Wavelet (MODWT). Six rainfall gauge station were adopted, which are located in different biomes of the region, and satellite data (CMORPH). Rainfall data were evaluated by seasonal periods (rainy and dry). The results obtained demonstrated that the MODWT-ANFIS model had the best capacity to simulate the daily precipitation of the evaluated rainfall gauge station, even for dry periods, which are known to be more difficult to be simulated in relation to the rainy periods. In this case, data entries lagged by 4 days and 5 days performed better, with Nash values close to 1.0 and root mean square errors below 0.001.

Keywords: Artificial Intelligence, Neural Networks, Wavelet Decomposition, Time Delayed Inputs, CMORPH, Amazon.

LISTA DE FIGURAS

FIGURA 1- ÓRBITAS DOS SATÉLITES.....	25
FIGURA 2 - ESQUEMA DE FUNCIONAMENTO DA TÉCNICA CMORPH.	27
FIGURA 3 - WAVELET DAUBECHIES DE ORDEM 1 ATÉ 10.	44
FIGURA 4 - FUNÇÃO WAVELET SYMLET, DO NÍVEL 2 AO NÍVEL 8.....	45
FIGURA 5 - FUNÇÃO WAVELET COIFLET COM MOMENTOS DE 1 A 5.....	45
FIGURA 6 - ÁREAS RELACIONADAS COM IA (ADAPTADO DE MONARD; BARANAUSKAS, 2000).	47
FIGURA 7 - ESQUEMA DE UM NEURÔNIO ARTIFICIAL.	49
FIGURA 8 - FUNÇÕES DE ATIVAÇÃO PARCIALMENTE DIFERENCIÁVEIS.	50
FIGURA 9 - FUNÇÕES DE ATIVAÇÃO TOTALMENTE DIFERENCIÁVEIS.	50
FIGURA 10 - EXEMPLO DE ARQUITETURAS DE RNA (A, B, C, D).	52
FIGURA 11 - TOPOLOGIA DE PMC COM ENTRADAS ATRASADAS NO TEMPO.	54
FIGURA 12 - REPRESENTAÇÃO DE UMA AMOSTRA A SER USADA EM PMC.	55
FIGURA 13 - ESQUEMA DO PROCESSAMENTO DO PMC COM ENTRADAS ATRASADAS.	56
FIGURA 14 - ARQUITETURA DA REDE TDNN COMBINADA COM TRANSFORMADA WAVELET.	57
FIGURA 15 - ARQUITETURA DA REDE ELMAN COMBINADA COM MODWT.	58
FIGURA 16 - ARQUITETURA DA REDE RBF COMBINADA COM MODWT.	60
FIGURA 17 - MODELO HÍBRIDO DE MODWT E RNA COM ARQUITETURA DA REDE ANFIS.	63
FIGURA 18 - ESQUEMA METODOLÓGICO DA PESQUISA.	66
FIGURA 19 - AMAZÔNIA E LOCALIZAÇÃO DAS ESTAÇÕES PLUVIOMÉTRICAS.....	69
FIGURA 20 - VALORES MÉDIOS DE MSE E NASH PARA O MODELO MODWT-TDNN.	75
FIGURA 21 - VALORES MÉDIOS DE MSE E NASH PARA O MODELO MODWT-RBF....	77
FIGURA 22 - VALORES MÉDIOS DE MSE E NASH PARA O MODELO MODWT-ELMAN.	80
FIGURA 23 - DESEMPENHO DOS MODELOS MODWT-RNA.	85

LISTA DE TABELAS

TABELA 1 - TRABALHOS DE MODELAGEM HÍBRIDA COM DW E RNA, INCLUINDO ANO DE PUBLICAÇÃO, AUTORES, MÉTODOS ADOTADOS, VARIÁVEIS HIDROLÓGICAS, ESCALA TEMPORAL E LOCAL.....	32
TABELA 2 - FAMÍLIAS WAVELETS MAIS COMUNS.	43
TABELA 3 - DADOS DAS ESTAÇÕES PLUVIOMÉTRICAS DA ANA E PRECIPITAÇÃO MÉDIA DIÁRIA.	7070
TABELA 4 - VALORES MÉDIOS DE MSE E NASH PARA CADA FILTRO WAVELET DO MODELO MODWT-TDNN.....	74
TABELA 5 - RESULTADO DOS MODELOS MODWT-RNA NA CALIBRAÇÃO.....	766
TABELA 6 - VALORES MÉDIOS DE MSE E NASH PARA CADA FILTRO WAVELET DO MODELO MODWT-RBF.....	77
TABELA 7 - VALORES MÉDIOS DE MSE E NASH PARA CADA FILTRO WAVELET DO MODELO MODWT-ELMAN.....	79
TABELA 8 - PARÂMETROS E RESULTADOS DO MODELO MODWT-ANFIS, NA CALIBRAÇÃO.	82
TABELA 9 - PARÂMETROS ANFIS APÓS TREINAMENTO (CALIBRAÇÃO).....	82
TABELA 10 - DESEMPENHO DOS MODELOS HÍBRIDOS MODWT-RNA NA VALIDAÇÃO PARA OS DADOS DE PRECIPITAÇÃO DA ANA.	89
TABELA 11 - DESEMPENHO DOS MODELOS HÍBRIDOS MODWT-RNA NA VALIDAÇÃO PARA OS DADOS DE PRECIPITAÇÃO DA CMORPH.	90

LISTA DE SIGLAS E ABREVIATURAS

AEM	Aprendizado Extremo de Máquina
AES	Análise de Espectro Singular
AES	Análise do Espectro Singular
AG	Algoritmos Genéticos
ANFIS	Sistema de Inferência Neuro-Fuzzy Adaptativo
AMSR-E	Radiômetro Avançado de Varredura por Microondas
AMSU	Unidade de Sonda de Microondas Avançada
ANA	Agência Nacional de Águas
ANEEL	Agência Nacional de Energia Elétrica
AR	Autoregressivos
ARMA	Modelos Autorregressivos de Médias Móveis
CEMADEN Naturais	Centro Nacional de Monitoramento e Alerta de Desastres
CMORPH	Climate Prediction Center Morphing
CC	Condição de contorno
DB ₂ , db ₂	Função Daubechies de ordem 2
DW	Decomposição Wavelet
GCM	Modelos de Circulação Global
IA	Inteligência artificial
INMET	Instituto Nacional de Meteorologia
IR	Infra Red
LM	Levenberg-Marquardt
MA	Médias móveis
MSE	Erro Médio Quadrático

MW	Micro Wave
MODWT	Transformada Wavelet Discreta de Máxima Sobreposição
N	Nash
NCEP	National Centers for Environmental Prediction
NF	Neuro Fuzzy
NOOA	National Oceanic and Atmospheric Administration NOAA
OMM	Organização Mundial de Meteorologia
PC	Período Chuvoso
PEG	Programação de Expressão Gênica
PERSIANN	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Network.
PGEW	Programação Genética de Wavelet
PMC	Perceptron Múltiplas Camadas
PMD	Precipitação Média Diária
MC	Menos Chuvoso
RHTA	Região Hidrográfica Tocantins Araguaia
RNA	Redes Neurais Artificiais
RNM	Rede Nacional de Monitoramento
RVS	Regressão Vetorial de Suporte
SSMI	Sensor Especial Microondas/Gerador de Imagens
SST	Temperatura na superfície do Oceano Pacífico
TDNN	Time Delay Neural Network
TRMM	Missão de Medição de Precipitação Tropical
VSM	Vetor de Suporte de Máquina
WNF	Wavelet-Neuro-fuzzy

SUMÁRIO

1 INTRODUÇÃO	16
1.1 HIPÓTESE E MOTIVAÇÃO.....	19
1.2 OBJETIVOS.....	19
1.2.1 Geral	19
1.2.2 Específicos	20
2 FUDAMENTAÇÃO TEÓRICA	21
2.1 CONCEITOS GERAIS DE PREVISÃO HIDROLÓGICA.....	21
2.2 MEDIÇÃO DA PRECIPITAÇÃO.....	22
2.2.1 Precipitação Medida por Pluviômetros	23
2.2.2 Precipitação Medida via Satélite	25
2.2.3 Produtos de Precipitação por Satélite – CMORPH	26
2.3 MODELOS HIDROLÓGICOS PARA ESTIMATIVA DE CHUVAS DIÁRIAS.....	28
2.4 MODELOS HÍBRIDOS NA ESTIMATIVA HIDROLÓGICA.....	29
2.5 DECOMPOSIÇÃO WAVELET – DW.....	34
2.6 ANÁLISE MULTIRESSOLUÇÃO.....	37
2.7 TRANSFORMADA DE WAVELET DISCRETA.....	38
2.8 TRANSFORMADA WAVELET DISCRETA DE MÁXIMA SOBREPOSIÇÃO – MODWT.....	39
2.9 FAMÍLIAS WEAVELET.....	42
2.10 REDES NEURAIS ARTIFICIAIS - RNA.....	46
2.10.1 Inteligência Artificial	46
2.10.2 Principais conceitos sobre RNA	47
2.10.3 Arquiteturas das Redes Neurais	51
2.10.4 Processos de Treinamento ou Aprendizado da RNA	52
2.10.5 Perceptron de Múltiplas Camadas (PMC) e Rede TDNN	53
2.10.6 Rede Elman	57
2.10.7 Rede Neural de Base Radial (RBF)	60
2.10.8 Redes ANFIS	62
3 MATERIAL E MÉTODOS	66
3.1 ÁREA DE ESTUDO.....	68
3.2 BASE DE DADOS.....	69
3.3 USO DA MODWT.....	70

3.4 ENTRADAS DEFASADAS NO TEMPO.....	71
3.5 AVALIAÇÃO DA SAZONALIDADE.....	71
3.6 CRITÉRIOS DE DESEMPENHO.....	72
4 RESULTADOS E DISCUSSÕES.....	74
4.1 RESULTADOS DO MODELO MODWT-TDNN.....	74
4.2 RESULTADOS DO MODELO MODWT- RBF.....	77
4.3 RESULTADOS DO MODELO MODWT-ELMAN.....	79
4.4 RESULTADOS DO MODELO MODWT-ANFIS.....	81
4.5 CONSIDERAÇÕES SOBRE OS FILTROS WAVELET.....	83
4.6 VALIDAÇÃO DOS MODELOS MODWT-RNA.....	84
5 CONCLUSÃO.....	91
6 SUGESTÕES PARA TRABALHOS FUTUROS.....	93
REFERÊNCIAS.....	94
APÊNDICE A - PRECIPITAÇÃO OBSERVADA E SIMULADA EM CADA ESTAÇÃO.....	107
APÊNDICE B - PARÂMETROS ADOTAS NAS REDES NEURAIIS.....	110
APÊNDICE C - ARTIGO PUBLICADO COMO PARTE DE UM DOS PRODUTOS DE PESQUISA DA TESE.....	111
APÊNDICE D - ARTIGO PUBLICADO COMO PARTE DE UM DOS PRODUTOS DE PESQUISA DA TESE	112

1 INTRODUÇÃO

As análises realizadas a partir das precipitações podem encontrar entraves relacionados à qualidade dos dados, ao tamanho da série histórica e ao número de estações pluviométricas disponíveis (Michot et al. 2019). Apesar dos avanços significativos em ciência e tecnologia, previsões práticas e precisas são preocupantes, devido à escala de sua complexidade. Assim, há uma variedade de técnicas usadas para fazer estimativa de chuva com maior precisão, incluindo vários modelos conceituais e empíricos ou combinados (Davolio et al. 2008).

Os modelos conceituais são baseados em equações que representam os processos físicos e a evolução dos fenômenos atmosféricos que compõem o sistema climático e podem incluir a atmosfera, hidrosfera, biosfera e geosfera. Os modelos de circulação global, por exemplo, são modelos conceituais (Cuo et al., 2011; Golding, 2014). Modelos empíricos fazem ajustes matemáticos de valores calculados aos dados observados, através de funções que não consideram os processos físicos envolvidos (Siad et al., 2019). Exemplos desses modelos são modelos autorregressivos (ARs), médias móveis (MMs), médias móveis autoregressivas (ARMAs), redes neurais artificiais (ANNs), suporte regressão vetorial (RVS), etc.

Dentre os modelos empíricos, os que incorporam métodos de inteligência artificial (IA) são abordagens potencialmente úteis para simular o processo de precipitação (Fahimi et al., 2017; Nourani et al., 2014). De acordo com Sulaiman et al. (2018), esta utilidade deve-se à notável flexibilidade dos métodos de IA na modelagem de sistemas altamente não lineares e padrões estocásticos, e esses métodos não requerem conhecimento prévio do comportamento dos processos de medição. Na verdade, esses métodos dependem principalmente de informações derivadas de conjuntos de séries hidrológicas e meteorológicas existentes e usam uma abordagem de “caixa preta” para simular processos subjacentes. Além disso, segundo Shoaib et al. (2016), os métodos de IA, como as Redes Neurais Artificiais (RNA), são capazes de estabelecer uma relação entre entradas históricas (chuva, vazão, etc.) e as saídas desejadas, através de função não linear composta de vários fatores que são ajustados aos dados observados, permitindo sua estimativa.

Essa relação da RNA com as variáveis hidrológicas tem sido aplicada em diversos estudos na área de modelagem hidrológica, como por exemplo, Partal e Kiss (2007), Partal e Cigizoglu (2009), Kisi e Shiri (2011), Nourani et al. (2009), Chau e Wu (2010), Jimenez e Collischonn (2015), Soares dos Santos et al. (2016), Nourani et al. 2017, Shouab et al. (2018) e Honorato et al. (2018).

As RNAs são métodos muito utilizados na estimativa de variáveis hidrológicas, contudo um único modelo de RNA pode não ser capaz de lidar com comportamento não estacionário de séries temporais se a entrada não for pré-processada (Islam e Sivakumar 2002; Cannas et al. 2006; Hu et al. 2018). Nesse sentido, a Transformação Wavelet (TW) é uma metodologia de pré-processamento, capaz de filtrar e corrigir as informações contidas na série temporal de dados de entrada. Segundo Nourani et al. (2014), essa correção nas entradas favorece consideravelmente a eficiência dos modelos de RNA na estimativa das variáveis hidrológicas.

Ramana et al. (2013) integraram a TW e RNA via Perceptron Múltiplas Camadas (PMC), obtendo bom desempenho para estimativa de chuvas. A metodologia foi aplicada aos dados mensais da estação Darjeeling, na Índia. He et al. (2015) combinaram a TW e RNA do tipo feed forward backpropagation para estimativa da precipitação mensal no território australiano, concluindo que o modelo combinado teve um desempenho melhor na estimativa, quando comparado com o modelo único de RNA e de Regressão Linear Múltipla (RLM). Partal et al. (2015) obtiveram bons resultados combinando a TW com três tipos de RNA (feedback propagation, função de base radial e rede neural de regressão generalizada) para estimativa de precipitação diária, usando variáveis meteorológicas como entradas aos modelos. Nourani et al. (2014) destacaram muito bem as vantagens dos modelos combinados (TW e RNA), bem como a trajetória e o futuro potencial de sua aplicação na hidrologia.

É possível desenvolver esses modelos de estimativa baseados em RNA e combinar ferramentas de pré-processamento, utilizando uma série de variáveis, como temperatura, radiação e umidade como entradas. Contudo, poucas estações estão equipadas com recursos para medir essas variáveis, especialmente em países em desenvolvimento, por razões econômicas e técnicas (Altunkaynak et al., 2015). Logo, é aconselhável desenvolver um modelo que possa prever a precipitação diária com base em registros

anteriores de sua série histórica. Além disso, a quantidade de dados mínimos de entradas, que funcionam como uma memória nos modelos de RNA e atuam no aprendizado da rede, ainda é um motivo de preocupação. Assim, Shouaib et al (2016) avaliaram o potencial de RNA recorrentes com atraso no tempo acoplada a TW para estimativa de escoamento. Duong e Bui (2018) propõem um modelo de memória de curto e longo prazo (LSTM) com RNA para prever mensalmente a precipitação na estação meteorológica de Ca Mau, no Vietnã. Os autores verificaram que o modelo LSTM conseguiu simular satisfatoriamente a não estacionaridade e não linearidade da precipitação.

Assim, os modelos propostos neste estudo, tem como contribuição, demonstrar práticas que poderão ser adotadas na introdução de camadas de atraso de tempo e pré-processadas por Wavelet Discreta de Máxima Sobreposição (MODWT), modeladas por redes neurais. O uso da MODWT ao invés da DW traz como principal novidade, níveis de decomposições wavelet corrigidos por limites e em coeficientes de escala a partir de dados de séries temporais, superando as Condições de Contorno (CC), que afetam as previsões de modelos baseados em Wavelet, as quais não se adotam na tradicional DW.

A análise comparativa entre os modelos híbridos, considerando o uso de MODWT e RNA, adotou quatro tipos de RNA (Rede Neural de Atraso de Tempo, Base Radial, Neuro-Fuzzy, Rede Elman), na Região Amazônica. A Amazônia foi selecionada por se destacar como uma importante bacia hidrográfica que depende da precipitação para sustentar diversas atividades econômicas e por ser uma grande reguladora do clima, na circulação atmosférica regional e global. Além disso, bases diferentes de dados de precipitação serão adotadas, tais como as observadas pontualmente pela Agência Nacional de Águas – ANA e as de Satélite do Climate Prediction Center Morphing – CMORPH, permitindo que os modelos sejam aplicados, mesmo na ausência de monitoramento por estações pluviométricas pontuais, já que os dados do CMORPH apresentam a vantagem de obter informações espacializadas e pontuais da precipitação.

1.1 HIPÓTESE E MOTIVAÇÃO

No contexto apresentado, são abordadas as seguintes hipóteses:

- Dentre os tipos de Redes Neurais adotadas, existe alguma que seja mais eficiente para estimativa de chuva diária, considerando seu uso combinado com Wavelet Discreta de Máxima Sobreposição (MODWT)?

- Modelos hidrológicos Híbridos, desenvolvidos com Inteligência Artificial, poderão estimar, de forma satisfatória, precipitações diárias na Região Amazônica?

- Existe alguma vantagem em se usar dados obtidos in situ, ou obtidos por satélite na modelagem de precipitação diária?

O emprego de modelos para estimar variáveis climáticas como a precipitação, nas bacias hidrográficas, é fundamental, pois ela influencia nas atividades econômicas, no abastecimento doméstico, turismo, meio ambiente, além de colaborar em situações de variações climáticas. Dessa forma, a estimativa adequada da precipitação, é interessante para a gestão de bacias, visto que a região amazônica apresenta flutuações hídricas (inundações e estiagens), em diferentes biomas (Cerrado, Amazônia e Pantanal), que compõem seu território. Desta forma, este estudo poderá contribuir no fornecimento de estimativas diárias de chuva para melhorar o uso da água na região, evitando desperdícios e possíveis impactos, dando suporte aos tomadores de decisão para promoverem o planejamento mais eficiente dos recursos hídricos.

Além disso, este trabalho poderá contribuir em estudos de modelagem hidrológica que envolvam o uso da MODWT e RNA, fornecendo informações específicas e critérios que poderão ser adotados na escolha da RNA, para estimativas de precipitações diárias.

1.2 OBJETIVOS

1.2.1 Geral

Definir entre os modelos híbridos adotados (MODWT-RNA), qual é o mais vantajoso para estimativa de precipitações diárias, adotando diferentes bases de dados de precipitação.

1.2.2 Específicos

- Avaliar as séries de precipitações diárias registradas pela *ANA* e pelo *CMORPH*;
- Desenvolver a filtragem de sinais por meio da Decomposição Wavelet de Máxima Sobreposição para decomposição da série de precipitação diária com diferentes (filtros) Wavelet mãe.
- Obter a combinação MODWT e *RNA* para formar modelos híbridos;
- Aplicar e avaliar os modelos de Inteligência Artificial às séries de precipitação;
- Estimar precipitações diárias em diferentes locais da região Amazônica.

2 FUDAMENTAÇÃO TEÓRICA

2.1 CONCEITOS GERAIS DE PREVISÃO HIDROLÓGICA

A Previsão hidrológica é a estimativa das ocorrências futuras de uma ou mais variáveis hidrológicas para um determinado intervalo de tempo (SENE 2010). Geralmente, as variáveis hidrológicas mais analisadas são as vazões, níveis dos rios e precipitações. Segundo Sene (2010) a previsão ou estimativa hidrológica é requerida para um tempo de antecedência determinado, que pode ser de horas ou menos quando o risco de perda de vida ou da propriedade é alto, em anos ou décadas para planejamento estratégico de longo prazo, e frequentemente aplicado nas seguintes abordagens:

- tomada de decisão: em termos de tática e emergência. Podem incluir os sistemas de alerta de cheias, programação de irrigação, operação de abastecimento de água e controle de sistemas de drenagem urbana;

- sazonal ou interanual: incluem a estimativa de estiagem, manejo dos recursos hídricos, estimativa do degelo anual, entre outros;

- estratégica: inclui manejo de bacias, avaliação dos impactos às mudanças climáticas na operação de reservatórios, sistemas de aquíferos, entre outros.

A previsão hidrológica pode ser realizada em curto prazo: com antecedência de poucas horas até 14 dias, e em longo prazo: com antecedência de até nove meses (Georgakakos e Krzysztofowicz 2001). A previsão de curto prazo, usualmente tem sido adotada para controle de inundações, previsão de níveis para navegação, disponibilidade hídrica para irrigação, abastecimento de água e operação energética, e neste caso podemos incluir a estimativa da precipitação diária como exemplo.

A estimativa da precipitação é geralmente realizada nas escalas, anuais, mensais, diárias e horárias, dependendo da finalidade do estudo. No entanto, na escala diária, ela tem sido muito requisitada, devido ao seu vasto uso, principalmente em previsões meteorológicas. No entanto, segundo Osborn et al. 2016, a física associada à sua análise é complexa e as escalas de tempo e espaço envolvidas, dificultam a obtenção de resultados satisfatórios pelos modelos hidrológicos.

A baixa densidade dos postos pluviométricos em tempo real, e a baixa disponibilidade de radares meteorológicos, é um dos principais problemas existentes no Brasil, quanto ao uso de modelos hidrológicos para estimativa de variáveis hidrológicas. Isso afeta a estimativa da precipitação na escala espacial e temporal dentro de uma bacia hidrográfica. Uma alternativa, nesse caso, pode ser a utilização de estimativas de precipitação por satélite. Pesquisas recentes têm avaliado positivamente as estimativas de precipitação por satélite na área de hidrologia (Clarck et al.; 2013; Salem Nashwan et al. 2019). Com o desenvolvimento de novos sensores a bordo de satélites meteorológicos, as estimativas de precipitação por satélite podem estar disponíveis em poucas horas. Assim, as medições de precipitações disponíveis atualmente, para serem utilizadas em modelos hidrológicos, são obtidas por instrumentos meteorológicos, por radares ou por satélites.

2.2 MEDIÇÃO DA PRECIPITAÇÃO

A água encontra-se em estado de fluxo contínuo, em que o vapor de água é introduzido na atmosfera por meio da evaporação e evapotranspiração. Esse vapor d'água é elevado e distribuído vertical e horizontalmente por correntes de ar formando nuvens. A água na nuvem segue um mecanismo interno e complexo de processos de colisão, agregação e expansão das partículas de gelo até a condensação; no caso da precipitação líquida, formam-se gotículas de água que, pela gravidade, atingem o solo (SHUTTLEWORTH, 2012).

Uma vez que a precipitação chega à superfície da Terra, esta é usualmente expressa em milímetros ou em polegadas de coluna de água e quantificada sobre um período de tempo. A precipitação sobre a superfície da Terra não é homogênea, sendo que a topografia e a direção dos ventos são alguns fatores locais e regionais que definem o comportamento da chuva em todo o planeta (COLLISCHONN e DORNELES, 2013). As formas de medir o volume de água que precipita em determinada região, depende da técnica disponível para cada situação. Neste estudo, foram consideradas as precipitações obtidas por instrumentos conhecidos como pluviômetros e por satélite.

2.2.1 Precipitação Medida por Pluviômetros

O principal instrumento utilizado para quantificar a precipitação é o pluviômetro, definido como um recipiente instalado a superfície terrestre, com dimensões padronizadas, que acumulam a água, e necessitam do registro de leituras, em intervalos de tempos definidos. A forma convencional de medir a chuva é por leitura da proveta graduada que contém o volume de água captada (SANTOS, 2001).

Os pluviógrafos, assim como os pluviômetros, possuem um recipiente padronizado, permitindo um monitoramento contínuo. Originalmente eram mecânicos, utilizavam uma balança para quantificar a água e um papel para registrar o total precipitado. Hoje, o modelo mais utilizado no Brasil é o de sifão, o qual é conectado ao recipiente que verte toda a água armazenada quando o volume retido equivale a 10 cm de chuva.

A tecnologia para aquisição e registro de precipitação evoluiu, e assim surgiram os registradores eletrônicos, também conhecidos como “dataloggers”. A aquisição do datalogger deu origem aos pluviômetros digitais, que geralmente são compostos por um funil, que faz a captura da chuva e leva a água coletada para um mecanismo basculante, semelhante a um pequeno recipiente basculante duplo. Ao acumular certo volume de água, o mecanismo se desequilibra, tombando para o lado, despejando a água coletada e emitindo um pulso eletrônico que será registrado no “datalogger” (TAPIADOR et al., 2012). Aparelhos como esses podem registrar, armazenar e transmitir os dados via satélite ou via sinal de internet para uma fonte receptora, dispensando um observador diário, agilizando o monitoramento hidrológico.

Outros aparelhos de qualidade são montados com tecnologia de relógios mecânicos, e sua precisão é razoável para chuvas de pequena intensidade. Entretanto, mesmo no caso dos melhores aparelhos, é sabido que o desempenho desses equipamentos pode apresentar tendência à submedição em casos da ocorrência de chuvas mais intensas. Além desses problemas mencionados na medição, existem erros associados à perda de calibração dos aparelhos pelo pouso de aves, ventos fortes e sujeira, entre outros.

No Brasil, grande parte do monitoramento ocorre em estações pluviométricas, pertencentes à Rede Nacional de Monitoramento (RNM),

gerenciadas pela Agência Nacional de Águas (ANA) que operam diretamente 4.610 estações, sendo: 2.760 pluviométricas, distribuídas nas 12 regiões hidrográficas brasileiras, registradas no ano de 2017 (ANA, 2018). Além da ANA, existem outras instituições e empresas que mantêm pluviômetros, como a Agência Nacional de Energia Elétrica (ANEEL), Centro Nacional de Monitoramento e Alerta de Desastres Naturais (CEMADEN), o Instituto Nacional de Meteorologia (INMET), empresas de geração de energia hidrelétrica e empresas de pesquisas agropecuárias.

Os pluviômetros registram a quantidade de precipitação em um ponto, sendo limitado a representar a variabilidade espacial da precipitação em uma maior região. A Organização Mundial de Meteorologia (OMM) recomenda que a densidade seja função de cada tipo de relevo: um pluviômetro em 900 km² em regiões costeiras; 250 km² por pluviômetro em áreas montanhosas; 575 km² por pluviômetro em regiões com morros e colinas no interior; e 20 km² por pluviômetro em áreas urbanas (OMM, 2008).

Diferentemente dos pluviômetros, os radares meteorológicos permitem estimar a precipitação de forma razoavelmente contínua no tempo e no espaço. Em alguns casos, esses dados podem complementar a informação dos pluviômetros. Porém, a estimativa de precipitação por radar é baseada em medições indiretas, e têm diversas fontes de incerteza, como a calibração manual dos equipamentos, a orientação apropriada da antena de controle de radar, a atenuação devido à umidade ou neve, os ruídos não meteorológicos e a estimativa dos parâmetros da função Z-R, que relaciona a refletividade e a intensidade da precipitação (EINFALT E MICHAELIDES, 2008).

A descoberta do uso da rede de comunicação celular comercial para obter intensidades da precipitação em tempo real, publicada por Chwala et al. (2012) e Overeem et al. (2016), é uma nova maneira de medir também a quantidade de chuva. Funciona, a partir dos dados de atenuação dos sinais de micro ondas, fazendo uso do fato de que as gotas de chuva consideráveis, absorvem e dispersam a radiação eletromagnética correspondente às frequências entre 1 GHz e 100 GHz. Porém, essa metodologia vem sendo testada ainda para áreas de bacias de pequeno porte com alcance de sinais de onda da rede de comunicação celular.

2.2.2 Precipitação Medida via Satélite

Os registros de precipitação através de satélites, consiste em observações realizadas no espaço, através de sensores a bordo de satélites que orbitam de duas formas: a órbita geossíncrona e órbita polar (heliosíncrona), representada na Figura 1.

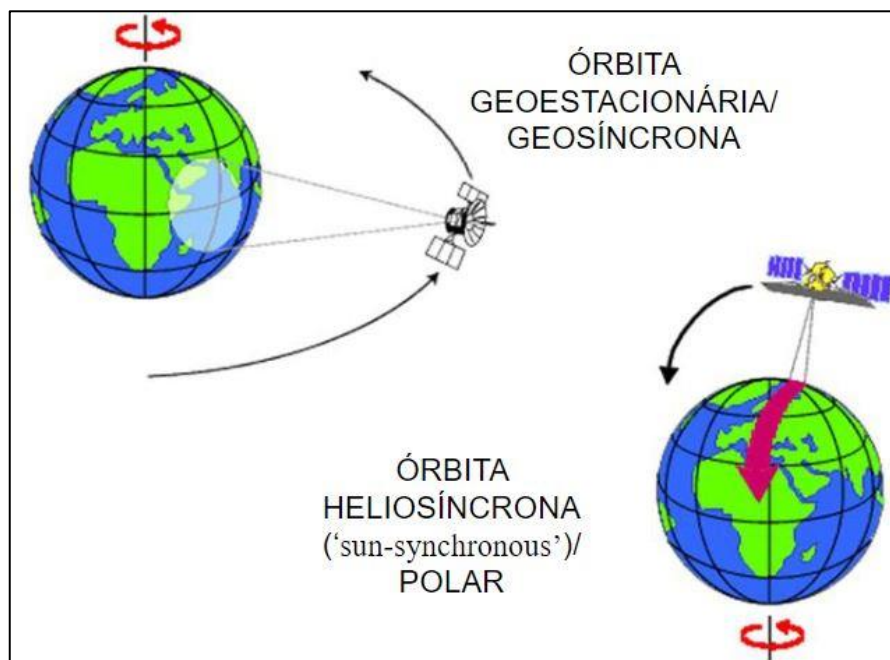


Figura 1- Órbitas dos Satélites.

Os satélites geoestacionários posicionam-se a uma altura aproximada de 36.000 km, circulando em torno da Terra em uma órbita geossíncrona, à mesma velocidade angular da Terra sobre a linha equatorial. Essa característica da órbita permite que satélites geoestacionários continuamente observem uma mesma região da Terra, obtendo informação mais detalhada, a qual é de interesse quando são desejados dados em curtos intervalos de tempo, por exemplo, de 15 em 15 minutos. Já os satélites em órbita polar circulam constantemente a Terra numa órbita próxima da direção norte-sul (Figura 1). Os satélites nessa órbita estão posicionados a uma altura aproximada de 900 km, mais próximo da Terra podendo visitar uma mesma região mais de uma vez ao dia (KIDD, 2001).

A radiação que trafega através da atmosfera interage com as moléculas suspensas por meio dos processos de reflexão, espalhamento e absorção. A energia desses processos é detectada pelos sensores que interpretam a

energia, nas bandas espectrais nas faixas de visível infravermelho e micro-onda. A interpretação individual em cada uma dessas bandas espectrais tem permitido estimar a precipitação por meio de algoritmos matemáticos (TAPIADOR et al., 2012).

Com o passar dos anos, as formas quantitativas de obter precipitação desde o espaço têm evoluído para métodos mais diretos com interpretação mais física do processo de precipitação, dando origem a diversos algoritmos de medição de chuva, que utilizam as bandas individuais como visível, infravermelho (do inglês Infra Red - IR) e micro-onda (do inglês Micro Wave - MW), permitindo uma melhor estimativa da precipitação.

As técnicas de estimativa de precipitação que usam o espectro do visível infravermelho ocorrem de forma indireta, uma vez que as gotas de chuva não são diretamente observadas pelo sensor do satélite. Assim, elas são realizadas por algoritmos que relacionam a taxa de chuva de nuvens precipitantes à espessura e/ou temperatura de brilho das nuvens (KIDD, 2001).

A medição da precipitação, a partir da radiação passiva de micro-onda, (MW), é baseada na radiação emitida da superfície da terra (superfícies oceânicas e continentais). Esta radiação identifica os processos de absorção, emissão ou espalhamento das nuvens, e dependendo da frequência, podem ser inferidas propriedades físicas da nuvem, permitindo identificar partículas precipitáveis como água, gelo ou neve (TAPIADOR et al., 2012).

2.2.3 Produtos de Precipitação por Satélite – CMORPH

Na estimativa de precipitação por satélite, os dados de diversos sensores são ajustados através de algoritmos. Esses algoritmos são formulados com base na observação multiespectral de diversos satélites de diferentes órbitas. Podem ser citados, como exemplos, os produtos Climate Prediction Center Morphing - CMORPH (JOYCE et al., 2004); TRMM Multisatellite Precipitation Analysis - TMPA TRMM (HUFFMAN et al., 2007) e Precipitation Estimation from Remotely Sensed Information using Artificial Neural Network - PERSIANN (Hong et al., 2004).

O CMORPH é um algoritmo que produz estimativas de precipitação globais a partir da medição de micro-ondas (MW) e infravermelhas (IR), em alta

resolução, via satélite geostacionário. Em essência, imagens IR sucessivas são deslocadas espacialmente uma em relação à outra em todas as direções possíveis, e a mudança que produz a maior correlação forma a base do campo de vetores de movimento, que será processada pelo algoritmo (Figura 2). No entanto, como a distribuição espacial das temperaturas e precipitações no topo da nuvem não é a mesma, os vetores de movimento de precipitação são refinados por meio de um modelo estatístico que relaciona os vetores de movimento das nuvens à advecção de chuvas por radar (JANOWIAK et al. 2001).

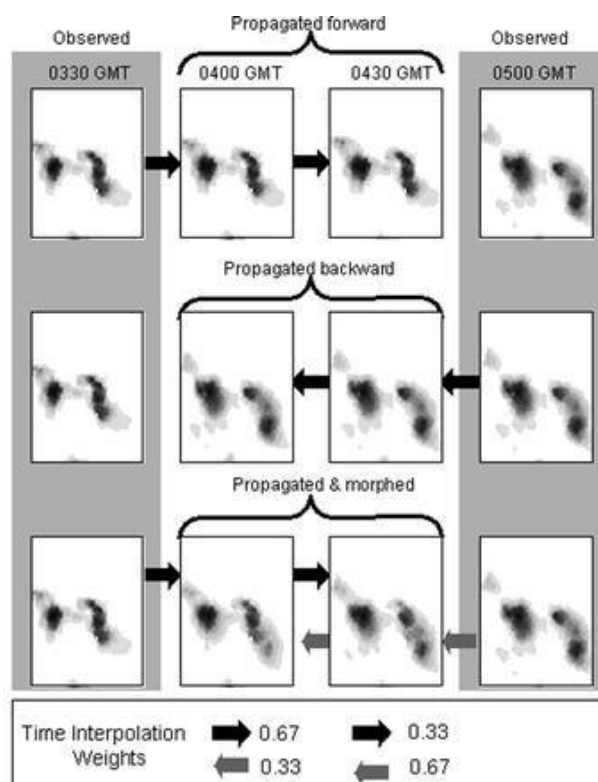


Figura 2 - Esquema de funcionamento da técnica CMORPH.

Fonte: Joyce, et al. (2004)

O processo de propagação das chuvas começa, então, com a propagação de campos de estimativas de precipitação derivadas de MW de 8 km e meia hora instantaneamente no tempo, usando os vetores de movimento de precipitação derivados de IR. Assim, a técnica CMORPH recebe, lê, combina e produz os resultados da precipitação (JOICE et al. 2004).

De acordo com Joyce et al. (2004) e Pereira Filho et al. (2010), a técnica de CPC Morphing, fornece excelente resolução espacial (de $0,07^\circ \times 0,07^\circ$ latitude/longitude, que é de cerca de 8 km no equador) e frequentes análises temporais da precipitação globalmente, a partir de 60°N e 60°S . Este método combina estimações de precipitação que são geradas por algoritmos que recebem informações de instrumentos, como o Sensor Especial Microondas/Gerador de Imagens (SSM/I), o Radiômetro Avançado de Varredura por Microondas (AMSR-E), pela Unidade de Sonda de Microondas Avançada (AMSU) e pelo imageador de micro-ondas (Missão de Medição de Precipitação Tropical - TRMM). Contudo, como esses instrumentos estão em órbita terrestre baixa, a frequência de amostragem pode gerar falha. O CMORPH atenua essa deficiência de amostragem, usando dados de infravermelho “geossíncronos” como um mecanismo para interpolar e “transformar” as estimativas de precipitação derivadas de combinações das informações de micro-ondas passiva, produzindo informação da precipitação a cada meia hora.

Uma característica importante desse produto é a sua flexibilidade, em incorporar fontes de informação do tipo micro-ondas, de qualquer satélite em órbita. Diversos estudos, adotaram os dados de precipitação do CMORPH, para análise do comportamento hidrológico, em diversas bacias brasileiras, como por exemplo em Pereira Filho et al. (2010), Clark e Buark (2013), Jimenez et al. (2013) e Falck et al. (2016), os quais apresentaram bons resultados.

2.3 MODELOS HIDROLÓGICOS PARA ESTIMATIVA DE CHUVAS DIÁRIAS

Modelo Hidrológico pode ser considerado como um instrumento que serve para representar o desempenho de um fenômeno em um determinado sistema. Na hidrologia, sua aplicação serve para entender e simular o comportamento das variáveis hidrológicas da bacia hidrográfica (COLLISCHONN e DORNELES, 2013).

Na literatura, os modelos de estimativas futuras de variáveis hidrológicas podem ser classificados em conceituais e empíricos. Destacam-se entre os modelos conceituais, aqueles baseados na modelagem numérica da precipitação, por exemplo, os Modelos de Circulação Global (GCM). Estes

modelos são baseados em equações representativas dos processos físicos e evolução de fenômenos atmosféricos que compõem o sistema climático, que pode incluir a atmosfera, a hidrosfera, a biosfera e a geosfera, como nos estudos propostos por McGuffie e Henderson-Sellers, 1997; Cuo et al., 2011 e Golding, 2014.

Os modelos empíricos realizam ajustes de valores calculados aos observados, e estas analogias matemáticas não possuem relação com o comportamento físico dos processos hidrológicos (SIAD et al. 2019). Como exemplo destes modelos, temos os Autoregressivos (AR), Médias Móveis (MM), Auto-regressivos de Médias Móveis (autoregressive-moving-average ou ARMA, na sigla em inglês), Redes Neurais Artificiais (RNA), Regressão Vetorial de Suporte (RVS) etc. Modelar as precipitações diárias, não é simples, devido a sua particularidade de não acumular valores, como em séries mensais e anuais. Assim, os modelos não paramétricos apresentam a vantagem de dependerem somente das informações que são obtidas do conjunto de séries hidrológicas existentes e usam uma abordagem de “caixa preta” para simular os processos subjacentes (SULAIMAN et al. 2018).

Devido à complexidade que envolve a estimativa de variáveis hidrológicas, os modelos que possuem flexibilidade na modelagem de sistemas altamente não-lineares e padrões estocásticos, e não exigem conhecimento prévio do comportamento de outras variáveis associadas a ela, são interessantes, principalmente porque não requerem conhecimento prévio dos fenômenos envolvidos. Contudo, nem sempre o modelo poderá ser suficiente adotando como análise, apenas a série histórica. Às vezes trabalhar com a série da variável que se deseja estimar e suas possíveis variáveis influenciadoras pode ser benéfico. O único agravo é a falta da disponibilidade de determinadas variáveis hidrológicas, necessárias a um determinado estudo.

2.4 MODELOS HÍBRIDOS NA ESTIMATIVA HIDROLÓGICA

Os modelos híbridos são constituídos da combinação de modelos conceituais e ou empíricos, com o objetivo de estimar a variável de interesse (DEVIA et al., 2015). Essa concepção é adotada na tentativa de melhorar a estimativa de dados hidrológicos, e tem se mostrado muito vantajosa. Muitos

autores têm adotado modelos híbridos, incorporando métodos que envolvem principalmente Redes Neurais Artificiais (RNA), Decomposição Wavelet (DW), Análise do Espectro Singular (AES), Regressão Vetorial de Suporte (RVS), Neuro Fuzzy (NF), Algoritmos Genéticos (AG), Aprendizagem de Máquina (AM), Vetor de Suporte de Máquina (VSM) e Programação de Expressão Gênica (PEG). No entanto, a abordagem sobre qual critério usar para escolha da RNA associada à DW não foi explorado. A maioria dos estudos cerca-se de informações sobre a aplicação do modelo em si e seu desempenho para estimar alguma variável hidrológica.

Nas últimas décadas podemos destacar alguns trabalhos desenvolvidos, em vários lugares do mundo, utilizando a modelagem híbrida que impulsionaram os estudos na estimativa de variáveis hidrológicas, adotando preferencialmente DW e RNA mostrados adiante.

Partal e Kissi (2007) propuseram o método DW e NF para prever os valores de precipitação diária. Como a escolha de entradas de modelo apropriadas é uma das etapas mais críticas na construção de um modelo de previsão, o DW foi usado para apresentar o sinal de precipitação original sob diferentes intervalos de resolução. Posteriormente, os coeficientes de correlação entre as subséries (média, máxima, desvio padrão, assimetria) e as séries de precipitação originais forneceram as entradas para o método NF. Seu modelo obteve um bom ajuste com os dados observados, especialmente para séries temporais que tiveram precipitação zero, nos meses de verão, bem como para os picos no período de teste.

Partal e Cigizoglu (2009) propuseram o uso de DW e RNA do tipo feed-forward e backpropagation, para estimativa da precipitação diária. Adotaram como dados de entrada, variáveis meteorológicas, como temperatura, umidade, evaporação e precipitação. A DW foi usada para decompor o sinal de entrada em dez níveis, corrigindo os ruídos da série, e depois, esses dados foram alimentar o método RNA. O ponto chave deste modelo Wavelet-RNA é a decomposição da série temporal e a utilização da DW como entradas do modelo ANN. Os resultados indicam que as estimativas do modelo Wavelet-RNA são significativamente superiores às obtidas por um modelo convencional de RNA ou por um modelo de regressão multilinear.

Kisi e Shiri (2011) compararam as habilidades de modelos híbridos de Programação Genética de Wavelets (WGEP) e modelos de Wavelet-Neuro-fuzzy (WNF) para estimativa diária de precipitação. Os resultados mostraram que modelo híbrido WGEP são mais eficazes na estimativa da precipitação diária que o modelo WNF, o qual foi incapaz de aprender muito bem o processo não linear de precipitação.

Kuo et al. (2010) investigaram a previsibilidade sazonal das chuvas pela abordagem Wavelet-AI. A análise da Wavelet foi empregada em dados sazonais de chuva e Temperatura do Oceano Pacífico (SST) e os resultados revelaram alta coerência de Wavelet entre o SST selecionado e a precipitação sazonal. Eles passaram a usar um modelo RNA-AG para prever a precipitação sazonal com um tempo de execução de uma estação, usando o modelo AG para calibrar os parâmetros da RNA. Como resultado, os parâmetros e coeficientes do modelo para as diferentes camadas foram otimizados, minimizando uma função objetivo que, por sua vez, maximizou a correlação entre os valores simulados, obtendo uma forte relação entre anomalias sazonais de temperatura do Pacífico e precipitação sazonal no local estudado.

Kissi e Cimen (2012) usaram um modelo DW-VSM para a estimativa de precipitação diária e descobriram que o método híbrido poderia aumentar a precisão da estimativa da precipitação de um dia antes do que um único VSM e modelos de RNA. Na literatura podem ser encontrados outros trabalhos, bastante interessantes que envolvem modelagem híbrida de variáveis hidrológicas, demonstrando sua promissora aplicação na hidrologia, na climatologia, hidrogeologia e em diversas áreas da ciência (Nourani et al. 2009; Adamowski e Sun 2010; Ren et al. 2011; Wei et al. 2012; Nayak et al. 2013; Yassen et al. 2016; Nourani et al. 2017). Além desses, Nourani et al. 2014 publicaram um estudo que discute e apresenta diversas aplicações do uso da DW com diversos modelos de inteligência artificial para estimativa de variáveis hidrológicas. Na Tabela 1 estão resumidos alguns estudos de modelagem híbrida com DW e RNA, a qual é o assunto de interesse nesta pesquisa, indicando o tipo de metodologia, a variável hidrológica e a escala de tempo adotada.

Tabela 1 - Trabalhos de modelagem híbrida com DW e RNA, incluindo ano de publicação, autores, métodos adotados, variáveis hidrológicas, escala temporal e local

Autor/ano	Metodologia	Variável	Escala	Local
Mwale et al. (2007)	DW, RNA e AG.	Precipitação	Mensal	Alpes/Europa
Partal e Kisi (2007)	DW e NF	Precipitação	Diária	Oeste da Turquia
Nourani et al. (2009)	DW e RNA	Precipitação	Mensal	Bacia Ligvanchai/Irã
Partal e Cigizoglu (2009)	DW e RNA	Precipitação	Diária	Turquia
Kuo et al. (2009)	DW, RNA e AG	Precipitação	Sazonal	Taiwan
Chau e Wu (2010)	AES, RVS, RNA e Fuzzy	Precipitação	Diária	China
Kisi e Shiri (2011).	DW, GEP e NF	Precipitação	Diária	Turquia
Kisi e Cimen (2012)	DW e SVM	Precipitação	Diária	Turquia
Ramana et al. (2013)	DW e RNA	Precipitação	Mensal	Himalaia
Guimarães Santos e Silva (2014)	DW e RNA	Vazão	Diária	Rio São Francisco/Brasil
He et al. (2015)	DW e RNA	Precipitação	Mensal	Austrália
Yassen et al. (2016)	SVR e RNA	Vazão	Mensal	Rio Tigres/Iraque
Nourani et al. (2017)	DW, ELM e SVM	Vazão	Diário	Bacia Snoqualmie/EUA
Honorato et al. (2019)	DW e RNA	Vazão	Mensal	Lago de Sobradinho/Brasil
Santos et al. (2019)	DW e RNA	Vazão	Diário	Bacia do Alto São Francisco/Brasil
Hammad et al. (2021)	DW e RNA	Precipitação	Diária	Bacia do rio Indo/Paquistão

No estudo de Nourani et al. 2014 são feitos alguns questionamentos a respeito do uso da DW com RNA, que são relevantes e devem ser vistos como informações essenciais no uso da modelagem híbrida, envolvendo essas duas técnicas. O primeiro refere-se ao valor médio das chuvas pontuais medidas sobre uma bacia hidrográfica, que geralmente é atribuído a toda a área da bacia, e subsequentemente isso pode gerar incertezas no uso de estimativas de problemas do mundo real. Também, embora o processo de pré-processamento de dados pela transformação Wavelet possa melhorar o desempenho da modelagem de precipitação em diferentes escalas de tempo, essa melhoria é maior para grandes escalas, como dados mensais ou sazonais, comparados a horários, diários ou semanais.

Shouaib et al. (2016) explanaram como o potencial de RNA recorrentes com atraso no tempo, acoplada a diferentes famílias Wavelet, para estimativa de chuva e escoamento em bacias hidrográficas, influenciam no desempenho do modelo de RNA. Hu et al. (2018) inseriram modelos LSTM com RNA para simular o processo chuva-vazão com base em eventos de inundação de 1971 a 2013 na bacia chinesa do Rio Fen, obtendo resultados satisfatórios com o uso da LSTM. Salman et al. (2018) construíram modelo LSTM com RNA para prever variáveis meteorológicas, no aeroporto de Hang Nadim, na Indonésia, demonstrando que várias camadas de entrada com diferentes atrasos de tempo, melhoram a estimativa das variáveis observadas. Hammad et al. 2021 desenvolveram um novo modelo de RNA com Retardo de Tempo de Múltipla Ordem (WMTLNN) acoplado a Wavelet para estimativa de chuvas, em bacias do Indu, no Paquistão. Os autores constataram que as diferentes entradas com atrasos no tempo e o pré-processamento da Wavelet melhoraram a estimativa da precipitação nas bacias avaliadas.

Apesar do uso enorme da DW e RNA acopladas, percebe-se que as principais vantagens para usar a DW, nos vários estudos mencionados, estão associadas à remoção de ruído nos dados de entrada, decompostos em vários níveis, que melhoram as entradas no modelo RNA proposto. No entanto, nenhum dos estudos mencionados considerou as condições de limite da DW, e estudos anteriores raramente usaram a DW do tipo MODWT, que considera as condições de contorno e reduz o erro nas estimativas. Apesar de gerar bons resultados, ainda há uma lacuna em relação ao uso de funções Wavelet e os

níveis de decomposição. A maioria das pesquisas não se preocupa em examinar diferentes famílias disponíveis de Wavelets, que podem melhorar a decomposição da série temporal adotada. Além disso, a avaliação de diferentes camadas de atraso de tempo na RNA é uma proposta que pode melhorar as estimativas de precipitação no modelo híbrido MODWT-RNA.

2.5 DECOMPOSIÇÃO WAVELET

A Transformada Wavelet ou Decomposição Wavelet (DW) é uma ferramenta pertencente ao campo da Análise Wavelet (ondeletas), a qual surgiu como uma abordagem alternativa para o processamento de sinais, cobrindo a deficiência da transformada de *Fourier* por permitir que tanto informações sobre a frequência quanto sobre o tempo, estejam presentes, na decomposição de sinais (TAPANI e KOZAKEVICIUS, 2012).

A DW amplia intervalos de dados separando-os em diferentes componentes de frequência e escala, permitindo a análise de cada componente em sua escala correspondente. A ideia de aproximação, mediante a superposição de funções, tem sua origem nos trabalhos de Joseph Fourier que, no século XIX, descobriu que poderia utilizar senos e cossenos para representar outras funções (MISITI et al., 1997; RAIMUNDO, 2018).

Segundo Torrence & Compo (1998), a novidade da DW em relação ao trabalho de Fourier é que a base das funções de Fourier é dependente da frequência, mas não do tempo, ou seja, pequenas alterações no domínio da frequência produzem alterações em todo o domínio do tempo. A DW depende de ambos os domínios, da frequência, via dilatação, e do tempo, via translação, o que é uma vantagem em diversos casos. Para Lima 2003, esta é a razão pela qual elas podem distinguir as características locais de um sinal em diferentes escalas e, por translações, elas cobrem toda a região na qual o sinal é estudado.

Tanto na análise de Fourier, quanto na análise de wavelet, a ideia é aproximar uma função pela combinação linear de senos e cossenos ou wavelet, respectivamente (MORETTIN, 1999). Contudo, na análise de Fourier, a função periódica tem período 2π , de quadrado integrável, $L^2(0, 2\pi)$, gerada pela superposição de exponenciais complexas, $W_n(t) = e^{int}$, $n = 0, \pm 1, \dots$, obtidas

por dilatação da função $W(t) = e^{int}$. Na análise wavelet, este conceito foi estendido para $L^2(\mathbb{R})$, em outras palavras, esse espaço é criado a partir de uma única função ψ , chamada de wavelet mãe, gerado por dilatações e translações de ψ , produzindo uma família de funções $\psi_{a,b}$ (VETTERLI, 1995):

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), \quad a > 0, -\infty < b < \infty \quad (1)$$

Em que $a, b \in \mathbb{R}$ e $a \neq 0$.

O parâmetro a , de escala, ajusta-se a dilatação da wavelet e b determina a localização da wavelet. A wavelet mãe pode ser considerada como uma onda de curta duração que cresce e decai em um período limitado, e isso é crucial para o bom desempenho da transformação, dependendo da wavelet escolhida, o método filtra informações específicas durante o processo, revelando informações dos dados originais, como tendências, pontos de desintegração e descontinuidades, que o sinal bruto não expõe (HOLDEFER e SEVERO 2015).

Quando se trata de sinais discretos, frequentemente usam-se valores particulares para a e b , $a = 2^j$ e $b = k2^j$, com $k, j \in \mathbb{Z}$ (Equação 2):

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k) \quad (2)$$

Em que $k, j \in \mathbb{Z}$, sendo que $\psi_{j,k}(t)$ é obtida de $\psi(t)$ por dilatação de 2^{-j} e uma translação $k2^j$.

As funções $\{\psi_{j,k}(t), j, k \in \mathbb{Z}\}$ constituem uma base que obrigatoriamente não precisa ser ortogonal, todavia, empregando-se bases ortogonais é possível a reconstrução congênere do sinal original por meio dos coeficientes da transformada. Ponderando a base ortogonal gerada por ψ , $\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k)$, com $j, k \in \mathbb{Z}$, de maneira que qualquer $f(t) \in L^2(\mathbb{R})$ é formulado, conforme a Equação 3 (MORETTIN, 1999):

$$f(t) = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} C_{j,k} \psi_{j,k}(t) \quad (3)$$

em que $f(t)$ é uma série de wavelets com coeficientes (Equação 4):

$$C_{j,k} = \langle f, \psi_{j,k} \rangle = \int_{-\infty}^{\infty} f(t) \psi_{j,k}(t) dt \quad (4)$$

Existem diferentes tipos de wavelets ortogonais e algumas possuem atributos mais apropriados para determinadas aplicações. Um modo para geração de wavelets ortogonais é pela função escala ou wavelet formulado, conforme a Equação 5 (MORETTIN, 1999):

$$\phi(t) = \sqrt{2} \sum_k h_k \phi(2t - k) \quad (5)$$

Segundo Morettin, (1999) e Daubechies, (1992), essa formulação possibilita gerar uma família ortogonal de $L^2(\mathbb{R})$:

$$\phi_{j,k}(t) = 2^{-j/2} \phi(2^{-j} t - K) \quad (6)$$

em que $j, k \in \mathbb{Z}$. Então nessas condições, ψ pode ser computado por:

$$\psi(t) = \sqrt{2} \sum_k g_k \phi(2t - k) \quad (7)$$

Em que $g_k = (-1)^k h_{1-k}$. Chamadas equações de dilatação, g_k e h_k são coeficientes de filtros passa-baixa e passa-alta usados para calcular a Transformada de Wavelet Discreta (DWT), conforme Equações 8 e 9:

$$h_k = \sqrt{2} \int_{-\infty}^{\infty} \phi(t) \phi(2t - k) dt \quad (8)$$

e

$$g_k = \sqrt{2} \int_{-\infty}^{\infty} \psi(t) \phi(2t - k) dt \quad (9)$$

Considerando o sistema ortogonal $\{\phi_{j,k}(t), \psi_{j,k}(t), j, k \in \mathbb{Z}\}$, pode-se formular $f(t) \in L^2(\mathbb{R})$, seguindo a Equação 10:

$$f(t) = \sum_k c_{j,k} \phi_{j,k}(t) + \sum_{j \leq j} \sum_k d_{j,k} \psi_{j,k}(t) \quad (10)$$

Em que:

$$C_{j,k} = \langle f(t), \phi_{j,k}(t) \rangle = \int_{-\infty}^{\infty} f(t) \psi_{j,k}(t) dt \quad (11)$$

e

$$d_{j,k} = \langle f(t), \psi_{j,k}(t) \rangle = \int_{-\infty}^{\infty} f(t) \psi_{j,k}(t) dt \quad (12)$$

2.6 ANÁLISE MULTIRESPOLUÇÃO

A Análise Multiresolução introduzida por Mallat (1999) constitui-se de uma sequência de subespaços fechados V_j , onde $V_j \subset L^2(\mathfrak{R})$, em que cada V_j usa diferentes resoluções, daí o nome Análise Multiresolução, atendendo as propriedades abaixo, de acordo com Jawerth & Sweldens (1994):

- MR1) $V_2 \subset V_1 \subset V_0 \subset V_{-1} \subset V_{-2} \subset$;
- MR2) $\overline{\bigcup_{j \in \mathbb{Z}} V_j} = L^2(\mathfrak{R})$;
- MR3) $\overline{\bigcap_{j \in \mathbb{Z}} V_j} = \lim_{j \rightarrow +\infty} V_j = \{0\}$;
- MR4) $f(t) \in V_j \subset L^2(\mathfrak{R}) \Leftrightarrow f(2t) \in V_{j-1}, j \in \mathbb{Z}$ (*Invariância em escala*)
- MR5) $f(t) \in V_j \Leftrightarrow f(t - 2^j k) \in V_j, (j, k) \in \mathbb{Z}^2$ (*Invariância em translações*)
- MR6) *Existência de uma função ϕ , função escala, em que $\{\phi_{j,k}; j \in \mathbb{Z}\}$*

é uma base ortogonal em V_j onde $\phi_{j,k}(t)$ é formada pela equação 6.

Considerando uma série de tempo $f(t) \in L^2(\mathfrak{R})$, da qual se quer obter aproximações em vários níveis de resolução, cada subespaço V_j é formado por aproximações de funções, em que a melhor aproximação é alcançada, tendo em vista a projeção ortogonal (P_j) de f sobre cada V_j , assim:

$$\forall g(t) \in V_j, \|g(t) - f(t)\| \geq \|P_j(t) - f(t)\| \quad (13)$$

Conforme $V_j \subset V_{j-1}$ significa dizer que ao passar do nível de resolução j , escala 2^j , para o nível $j-1$, ganha-se informação.

À medida que a resolução 2^{-j} aumenta, $j \rightarrow -\infty$, a função de aproximação converge para a função original, $P_j f \rightarrow f$, ou melhor, contém mais

informações sobre f e obtém-se (MR2). De outra forma, quando a resolução 2^{-j} decresce para zero, (MR3) provoca a perda de todas as informações de f (MALLAT, 1999).

A propriedade (MR4) está concernente com a (MR1), já que à medida que j decresce, refinando a escala, a resolução em frequência aumenta. Conseqüentemente, detalhes que aparecem em uma escala 2^j também devem estar presentes na escala 2^{j-1} . A propriedade (MR5) sugere que V_j é invariante a qualquer translação proporcional a escala 2^j (OLIVEIRA, 2007).

A informação que é perdida quando se passa de V_{j-1} para V_j pode ser caracterizada pelo subespaço W_j , complemento ortogonal de V_j em V_{j-1} , conforme a Equação 14:

$$V_j \oplus W_j = V_{j-1}, W_j \perp V_j \quad (14)$$

Em que \oplus indica a soma direta. Sucede que $V_j = \bigoplus_{k=1}^{j=+\infty} W_k$.

A função $\psi(t)$, determinada pela equação 7, em que $\{\psi_{j,k}; k \in Z\}$ forma uma base ortogonal para W_j , de maneira que $\forall f \in L^2(\mathfrak{R})$, pode-se formular f como na equação 10. Assim, a Análise Multiresolução conduz a um método hierárquico rápido para o cálculo dos coeficientes wavelet de uma dada função (RAIMUNDO, 2018).

2.7 TRANSFORMADA DE WAVELET DISCRETA

Existem duas formas principais de transformada wavelet: a contínua (TWC) e a discreta (TWD). Segundo Bolzan (2004), as TWC são comumente usadas para visualizar, em diagrama tridimensional, a relação existente entre as componentes de diferentes frequências, em função da escala temporal do sinal estudado. Já as TWD são adotadas para a decomposição e filtragem de qualquer série temporal, apresentando certa habilidade de não provocar redundância de coeficientes entre as escalas.

Como os dados hidrometeorológicos são geralmente registrados em intervalos de tempo discretos, a TWD é preferencialmente adotada na

decomposição hidrológica de séries temporais (Merh et al. 2013; Ramana et al. 2013).

Para a formulação da Transformada de Wavelet Discreta (TWD) e com o propósito de se trabalhar com séries temporais, assume-se $\psi_{a,b}$ como definida pela Equação 2. De acordo com Von Sachs et al. (1997), os coeficientes wavelet da DWT podem ser representados pela Equação 15:

$$d_{j,k,n} = \sum_{t=0}^{n-1} x_t \psi_{j,k}(t) \quad (15)$$

em que $J = 0, 1, 2, \dots, J, K = 0, 1, 2, \dots, 2^j, X = (x_0, x_1, \dots, x_{n-1})^T, J$ inteiro representando a escala mais grossa ou suave, perfazendo n coeficientes d , e $n = 2^j$ observações de um processo estocástico ou uma série temporal.

Considerando que uma série de tempo $f(t) \in L^2(\mathfrak{R})$ possa ser representada em relação a uma base de wavelet como na Equação 10, valendo-se da equação de escala ϕ (Equação 5) e da definição de wavelet ψ (Equação 6) pode-se calcular os coeficientes $d_{j,k}$ e $c_{j,k}$, conforme Von Sachs et al. (1997) (Equações 16-19):

$$d_{k,j} = \langle f, \psi_{j,k} \rangle_{L^2} = \sum_{n \in \mathbb{Z}} g_n \langle f, \phi_{j-1,2k+n} \rangle, \quad (16)$$

$$d_{j,k} = \sum_{n \in \mathbb{Z}} \overline{g_{n-2k}} c_{j-1,n} \quad (17)$$

$$c_{j,k} = \langle f, \phi_{j,k} \rangle_{L^2} = \sum_{n \in \mathbb{Z}} h_n \langle f, \phi_{j-1,2k+n} \rangle \quad (18)$$

$$c_{j,k} = \sum_{n \in \mathbb{Z}} \overline{h_{n-2k}} c_{j-1,n} \quad (19)$$

Sabe-se que h_g e g_k são formulados pelas Equações 8 e 9.

2.8 TRANSFORMADA WAVELET DISCRETA DE MÁXIMA SOBREPÓSICÃO

Segundo Zhu et al. (2014), a Transformada Wavelet Discreta de Máxima Sobreposição (MODWT), é uma adaptação da TWD. A MODWT permite a

utilização da Análise Multiresolução para resolver a limitação da TWD, que requer $N = 2^j$ em que J é um inteiro positivo.

A definição da MODWT advém da TWD. Seja $(h_{j,k})$ o filtro da TWD e $(g_{j,k})$ o filtro de escala, sendo $k = 1, \dots, L$ representando (L) o comprimento do filtro, com j níveis de decomposição. O filtro wavelet MODWT $(\hat{h}_{j,k})$ e o filtro de escala MODWT $(\hat{g}_{j,k})$ são definidos como $\tilde{h}_{j,k} = h_{j,k}/2^{j/2}$ e $\tilde{g}_{j,k} = g_{j,k}/2^{j/2}$. Assim os coeficientes da wevelet MODWT de nível j são definidos como a convolução da série de tempo (X_t) e os filtros MODWT são obtidos pelas Equações (20) e (21):

$$\tilde{W}_{j,t} = \sum_{k=0}^{K_j-1} \tilde{h}_{j,k} X_{t-k \bmod N} \quad (20)$$

$$\tilde{V}_{j,t} = \sum_{k=0}^{K_j-1} \tilde{g}_{j,k} X_{t-k \bmod N} \quad (21)$$

Em que $\tilde{W}_{j,t}$ representa o coeficiente wavelet; $\tilde{V}_{j,t}$ é o coeficiente de escala; $\bmod N$ denota o modulo de operação, tratando a série histórica como periódica, com período igual a N , e se pode obter o número de coeficientes de wavelet e de escalas afetados pelas Condições de Contorno (CC) através da Equação 22:

$$K_j = (2^j - 1) (K - 1) + 1 \quad (22)$$

O valor de K_j representa o número de coeficientes de wavelet e de escalas afetados pelas Condições de Contorno, para o nível de decomposição J e um nível de comprimento do filtro wavelet K . Assim, por meio desta equação é possível obter os coeficientes de wavelet e de escala “corrigidos pelos limites”, ou seja, aqueles que evitam adicionar incerteza às wavelets e aos coeficientes de escala devido ao problema dos “dados futuros” (Percival e Walden, 2000, Quilty & Adamowski, 2018 e Basta, 2014).

A MODWT usa um filtro passa alto (\tilde{h}) para calcular seus coeficientes wavelets e aplica uma construção iterativa das séries temporais (X_t) , as quais podem ser reconstruídas utilizando-se a Equação 23:

$$X_t = \tilde{W}_{j,t} + \tilde{V}_{j,t} \quad (23)$$

A principal diferença entre a TWD e a MODWT envolve a dizimação, pois a TWD apresenta coeficientes de escala a um determinado nível j e têm 2^j menos coeficientes do que na escala $j-1$. A dizimação da TWD causa problemas na aplicação de dados reais porque requer que a série cronológica seja um número inteiro múltiplo de 2^j , seja invariável e sensível a acrescentar novos pontos de dados (Maheswaran e Khosa, 2012 Percival e Walden, 2000).

Os inconvenientes da TWD podem ser superados pelo uso da MODWT, através do simples redimensionamento da wavelet e os filtros de escala, utilizados pelo TWD. O redimensionamento dos filtros TWD conserva a energia e evita a necessidade de subamostragem na MODWT, ou seja, a subamostragem diádica é evitada resultando em wavelet e coeficientes de escala que têm a mesma duração que a série cronológica original (Walden, 2001).

A MODWT vem ganhando destaque no uso de decomposições de séries temporais devido ao seu potencial de considerar as Condições de Contorno (CC), que envolvem a decomposição de dados, evitando erros que podem ser introduzidos em todo o desenvolvimento do modelo de estimativa proposto. Nos trabalhos de Percival e Walden (2000), Basta (2014), Du et al (2017) e Quilty e Adamowsky (2018) são demonstrados como as CC influenciam na decomposição da série temporal e como podem produzir previsões incorretas, se não forem tratadas adequadamente.

De maneira geral, segundo Percival e Walden (2000) e Quilty e Adamowsky (2018), há três problemas relacionados as CC que podem comprometer a decomposição feita por TWD, sendo eles:

a) “dados futuros” – ocorre quando a TW adotada requer observações de séries temporais futuras para realizar a decomposição no presente, tornando a decomposição inviável se os dados não estiverem disponíveis. Em outras palavras, dados do futuro da série temporal são essenciais para calcular uma wavelet ou os coeficientes de escala no presente. Logo se deve evitar a TW que use dados futuros (caso da TWD);

b) seleção inadequada dos níveis de decomposição – devido a ocorrência de erros que são introduzidos nas wavelet e nos coeficientes de escala no início da série temporal decomposta (Basta 2014 e Percival e Walden, 2000), deve-se identifica-los e retirá-los, para deixá-los livre de incertezas relacionadas às CC. O número de coeficientes afetados é obtido pela Equação 22. Quando se seleciona um filtro de wavelet muito longo e um nível de decomposição muito alto, deixando poucos coeficientes de escala e wavelets, para calibrar o modelo de previsão, pode-se dizer que se tem uma seleção inadequada dos níveis de decomposição.

c) particionamento do conjunto de calibração e validação – ocorre quando os registros de séries temporais usados na calibração e validação do modelo não são suficientes para permitir um treinamento adequado do modelo. Neste caso é conveniente que após a decomposição da série de dados pela MODWT, com níveis e filtros adequados, removam-se os primeiros coeficientes de wavelet e escala, resultando em valores corrigidos pelos limites. Assim, pode-se definir o particionamento do conjunto de dados de forma adequada, garantindo um número suficiente para calibração e validação.

2.9 FAMÍLIAS WAVELET

A seleção da família wavelet, segundo Misiti et al. (2015), é determinada pelas características do sinal (ou da imagem) e pela natureza da aplicação. Podem ainda, modificam-se em termos de várias propriedades importantes, tais como:

- Suporte da wavelet no tempo, frequência e taxa de decaimento.
- Simetria ou antissimetria da wavelet. Os filtros de reconstrução perfeita que acompanham têm fase linear.
- Número de momentos de fuga. Wavelets com números crescentes de momentos de fuga resultam em representações esparsas para uma grande classe de sinais e imagens.
- Regularidade da wavelet. Ondas mais suaves fornecem resolução de frequência mais nítida. Além disso, algoritmos iterativos para construção de wavelet convergem mais rapidamente.
- Existência de uma função de escalonamento, φ .

A escolha da wavelet mãe adequada é a principal tarefa em todas as análises de wavelets, pois os resultados da decomposição de séries temporais são sensíveis às wavelets usadas. Existe um grande número de wavelets disponíveis para análise de séries temporais, no entanto, as wavelets mãe podem ser divididas em dois tipos: ortogonais ou não ortogonais. O uso de uma wavelet ortogonal implica o uso da TWD, enquanto que uma wavelet não ortogonal pode ser usada com a TWC (TORRENCE E COMPO 1998). Para Torrence e Compo (1998), existem sete famílias wavelets mãe ortogonal e três não ortogonal, consideradas as mais comuns e usuais na decomposição wavelet, as quais são apresentadas na Tabela 2.

A wavelet mãe Daubechies pertence a família de wavelets ortogonais que definem uma *TDW* e são caracterizadas por um número máximo de momentos de desaparecimento para um determinado suporte. Elas não têm expressão explícita e nem são simétricas. O índice que as acompanham (db_n), indica a ordem, que em teoria pode variar de 1 ao infinito (Misiti, 2000). A Figura 3 mostra as wavelets Daubechies de ordem 1 até 10.

Tabela 2 - Famílias Wavelets mais comuns.

Tipo	Família Wavelet	Abreviação
Ortogonal	Haar	Haar
	Daubechies	Db
	Coiflets	Coif
	Symlets	Sym
	BiorSplines	BiorM.N
	Reverse Biortogonal	Rbio
	Discrete Meyer	Dmey
Não ortogonal	Morlet	Morl
	Mexicano	Marr
	Gaussian	Gaus

Fonte: Adaptado de Torrence e Compo (1998).




Figura 3 - Wavelet Daubechies de ordem 1 até 10.

As famílias de funções wavelets são geralmente apresentadas pela abreviação do pesquisador que as desenvolveram (“coif” para Coifman ou “db” para Daubechies) ou de alguma denominação dada (“sym” para Symlets), seguido por um número que costuma apresentar uma característica da função. Como característica geral, observa-se que todas as funções decaem rapidamente para zero. As funções wavelet oscilam mais que suas escalonadoras associadas. A wavelet $coif_2$ exibe alguns pontos angulares. As wavelet db_6 e sym_6 são bastante suaves. Outro aspecto importante é o comprimento das funções wavelet e escalonadora, bem como de sua transformada. O suporte compacto das funções wavelet assinala a velocidade com que as funções convergem a zero, no domínio do tempo ou da frequência, quantificando a localização temporal e de frequência da transformação. A simetria é outro aspecto relevante devido às aplicações em processamento, especialmente de imagens, nas quais se deseja evitar a perda de fase de sinal analisado (MALLAT, 1999).

As wavelet mãe menos assimétrico de Daubechies (la_{14}) são mais simétricos do que as wavelets da fase extrema. São conhecidas pela abreviação Sym_n , em que n é o número de momentos de fuga. A Figura 4 apresenta a configuração da wavelet symlets.




Figura 4 - Função Wavelet Symlet, do nível 2 ao nível 8.

As funções de dimensionamento Coiflet (Figura 5), também exibem momentos de fuga. Em coif_N , N é o número de momentos de fuga para ambas as funções wavelet e escala. Esses filtros também são referidos na literatura pelo número de coeficientes de filtro, que é $3N$.




Figura 5 - Função Wavelet Coiflet com momentos de 1 a 5.

No presente estudo foram adotadas as wavelet daubechies de ordem 4 (db4), a menos assimétrica de daubechies (la14) e a Coiflet (c6), por apresentarem bom desempenho em análises de séries de dados (Guimarães Santos e Silva, 2014; Maheswaran e Khosa, 2012; Sang, 2012; Santos et al. 2019).

2.10 REDES NEURAIS ARTIFICIAIS – RNA

2.10.1 Inteligência Artificial

Segundo Monard & Baranauskas (2000), há mais de 2.000 anos, iniciaram-se os estudos sobre inteligência. Primeiramente com filósofos que procuravam entender como eram realizados os processos de visão, aprendizado, lembranças e raciocínio. Desde então, várias tentativas para mecanizar a inteligência foram efetuadas, sendo que muitas dessas tentativas precedem as ideias dos computadores digitais e das tecnologias mais avançadas.

Somente no pós-guerra (anos 50), que a área de Inteligência Artificial (IA), começou a ser estudada. Pesquisadores da área da computação começaram a utilizar computadores no desenvolvimento de programas simbólicos com o objetivo de resolver problemas mais complexos (MONARD; BARANAUSKAS, 2000).

O termo Inteligência Artificial foi usado pela primeira vez na década dos anos 50, na tentativa de formalizar o eterno sonho da criação de um “cérebro eletrônico”. Caldeira et al. (2007) definem a IA como o ramo da computação preocupada com a automação de comportamento inteligente, ao passo que, Winston (1992) entende IA como o estudo da computação que torna possível perceber, raciocinar e agir, concluindo que, IA é o estudo das ideias que permitem aos computadores serem inteligentes.

Para Rezende (2005), IA é a capacidade da ciência da computação voltada à execução das funções que são desempenhadas pelo seres humanos, isto é, imitar a inteligência na compreensão da linguagem e da visão, aprendizado, raciocínio lógico, resolução de problemas simples ou complexos, dentre outros. A IA está interligada as mais diversas áreas como: redes neurais, psicologia, linguística, filosofia, biologia, matemática, engenharia, entre outras áreas científicas, sendo uma área extensa de aplicações (Figura 6).

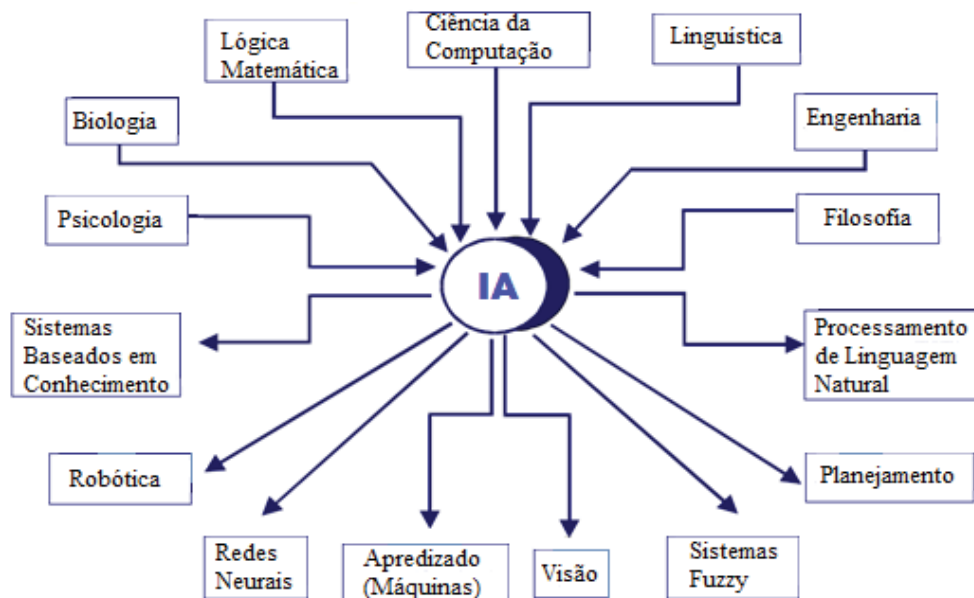


Figura 6 - Áreas relacionadas com IA (adaptado de MONARD; BARANAUSKAS, 2000).

2.10.2 Principais conceitos sobre RNA

As pesquisas sobre sistemas inteligentes evoluíram por várias décadas, com origem nas pesquisas sobre Inteligência Artificial, exatamente com o interesse de se entender o cérebro humano ou de criar uma máquina que imitasse suas funções (MINE, 2010). Os primeiros registros de RNA surgiram em 1943, com McCulloch e Water Pitts, que conceberam o primeiro modelo de neurônio artificial que se baseia em uma modelagem matemática do neurônio biológico. Estes estudiosos uniram seus conhecimentos em áreas distintas e publicaram um trabalho, apresentando o modelo matemático que descrevia o comportamento de neurônios. Anos depois, iniciou-se uma pesquisa relacionada com o aprendizado de redes e o primeiro trabalho publicado foi em 1949 por Donald Hebb, que sugeriu em seu livro “Organization of Behavior” um modo de proporcionar capacidade de aprendizado às redes neurais devido à variação dos pesos de entrada dos neurônios (SILVA et al., 2003).

Nos últimos anos, o estudo de modelos de RNA tem despertado grande interesse, pois eles são aproximadores da função universal capaz de mapear qualquer função linear ou não linear e têm sido aplicados em diversas áreas de pesquisa, sendo cada vez mais utilizados para a estimativa e classificação, principalmente em áreas onde tradicionalmente se usam modelos estatísticos (SACHINDRA e KANAE, 2019).

Segundo Haykin (2010), uma RNA pode ser considerada como um processador maciçamente e paralelamente distribuído, constituídos de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e o torna disponível para o uso. Ela assemelha-se ao cérebro humano sobre dois aspectos:

- O conhecimento é adquirido pela rede a partir de seu ambiente, através de um processo de aprendizagem (treinamento).
- Forças de conexões entre neurônios, conhecidos como pesos sinápticos, que são utilizados para armazenar o conhecimento adquirido.

A RNA pode ser definida como um sistema constituído por elementos de processamento interconectados chamados de neurônios, dos quais estão dispostos em camadas (uma camada de entrada, uma ou várias intermediárias e uma de saída) e são responsáveis pela não linearidade da rede, através do processamento de certas funções matemáticas. As Redes Neurais possuem alguma forma de regra de aprendizagem, que é responsável pela modificação dos pesos sinápticos a cada ciclo de iteração, de acordo com os exemplos que lhes são apresentados. Assim, pode se dizer que a *RNA* aprende por exemplos (HAYKIN, 2010).

Segundo Silva et al. (2010), existem vários tipos de *RNA*, cuja finalidade é o treinamento do comportamento de determinada variável. A principal diferença entre elas está no tipo de arquitetura da rede e nas suas características de processamento de aprendizagem. As mais conhecidas são: Perceptron (P), Perceptron Múltiplas Camadas (PMC), Adaline (A), Rede de Base Radial (RBR) e Rede Neuro Fuzzy, entre outras, que em termos matemáticos podem ser expressas pelas Equações 24 e 25.

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (24)$$

$$y = g(u) \quad (25)$$

Em que w_i é o peso (ponderação) associado à i -ésima entrada; x_i são as entradas da rede; θ é o limiar de ativação; u é o resultado da diferença obtida entre o combinador linear e o limiar de ativação; $g(u)$ é a função de ativação e y consiste no valor final produzido pelo neurônio, a partir de um conjunto de sinais de entrada.

O modelo de neurônio mais simples e que engloba as principais características de uma rede neural biológica, isto é, paralelismo e alta conectividade, foi proposto por McCulloch e Pitts (1943), mostrado na Figura 7, o qual é composto por entradas (X_1, X_2, \dots, X_n), por pesos sinápticos (W_1, W_2, \dots, W_n), função de combinação ou combinador linear (Σ), limiar de ativação (θ), função de ativação (g) e sinal de saída (y).




Figura 7 - Esquema de um Neurônio Artificial.

De acordo com McClelland (1986), os modelos de redes neurais, de maneira geral, apresentam algumas componentes, que definem suas principais características, a saber:

- a) Elementos de processamento - neurônios: é a unidade de processamento de informação que é fundamental para a operação de uma rede neural (Figura 7).
- b) Estado de Ativação: cada neurônio em uma rede neural, tem associado um estado de ativação, cujos elementos estabelecem a ativação de todos as unidades em um dado grupo, através de um vetor. A escolha do estado de ativação a ser utilizado para o neurônio é em função do que se procura representar com o modelo.
- c) Função de Ativação: função utilizada para calcular um novo estado de ativação do neurônio. Podem ser divididas em dois grupos principais, isto é, funções parcialmente diferenciáveis e funções totalmente diferenciáveis, considerando-se para tanto todo o seu domínio de definição. As funções de ativação parcialmente diferenciáveis são aquelas que possuem pontos cujas derivadas de primeira ordem são inexistentes. As principais funções desse grupo são a função degrau, função degrau bipolar e função rampa simétrica (Figura 8).




Figura 8 - Funções de Ativação parcialmente diferenciáveis.

Funções de ativação totalmente diferenciáveis são aquelas cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio de definição. As quatro principais funções pertencentes a este grupo, e que podem ser empregadas em redes neurais artificiais são a função logística, a tangente hiperbólica, a gaussiana (Figura 9) e a função linear.




Figura 9 - Funções de Ativação totalmente diferenciáveis.

d) Padrão de Interconexão entre os elementos de processamento: essa representação é feita através de uma matriz de pesos e define o conhecimento do sistema. As conexões com pesos positivos representam conexões excitatórias (reforço na ativação do neurônio) e as com pesos negativos, conexões inibitórias (inibição na ativação do neurônio). Os pesos das conexões, chamadas de pesos sinápticos, representam matematicamente, a importância de cada informação com relação a um dado neurônio. O principal propósito é, pois, determinar o melhor conjunto de pesos capaz de representar um dado problema.

e) Regra de Propagação: Trata-se de uma regra que combina os valores de entrada de um neurônio, com os respectivos valores da matriz de pesos para produzir uma entrada líquida. Uma das regras de propagação mais simples é

aquela, na qual o sinal líquido é uma soma ponderada de cada entrada que chega a um dado estado de propagação pelo respectivo peso.

f) Função de Saída: os neurônios ativados produziram um sinal de saída que está relacionado com sua ativação por uma função de transferência conhecida como função de saída. Ela pode ser uma função identidade (sinal de saída igual ao estado de ativação) ou uma função do tipo ponteira (patamar, limiar) em que a emissão do sinal só ocorre quando a ativação é superior a um dado limite.

2.10.3 Arquiteturas das Redes Neurais

Segundo Silva et al (2010), as principais arquiteturas de redes neurais artificiais, considerando a disposição de seus neurônios, assim como suas formas de interligação entre eles e a constituição de suas camadas podem ser divididas em:

a) Rede feedforward de camada simples: para esse tipo de arquitetura de redes neurais artificiais, tem-se apenas uma camada de entrada e uma única camada de neurônios, que é a própria camada de saída. A Figura 10a ilustra uma rede feedforward de camada simples compostas de n entradas e m saídas. Essas redes, geralmente são treinadas em problemas envolvendo classificação de padrões e filtragem linear.

b) Arquitetura feedforward de camada múltiplas: são constituídas pela presença de uma ou mais camadas escondidas de neurônios (Figura 10b). São empregadas na solução de diversos tipos de problemas, tais como aqueles relacionadas à aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, etc.

c) Arquitetura recorrente ou realimentada: são redes em que as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios (Figura 10c). A característica da realimentação quantifica tais redes para processamento dinâmico de informações, isto é, estas podem ser utilizadas em sistemas variantes em relação ao tempo, como estimativa de séries temporais, otimização e identificação de sistemas, controle de processos, etc.

d) Arquitetura em estrutura reticulada: as principais características destas redes estão na disposição espacial dos neurônios, visando propósitos de extração de

características, ou seja, a localização espacial dos neurônios está diretamente relacionada com o processo de ajuste de seus pesos e limiares (Figura 10d). Suas aplicações são bem diversificadas, tais como em problemas de agrupamento (clustering), reconhecimento de padrões, otimização de sistemas, gráficos, etc.

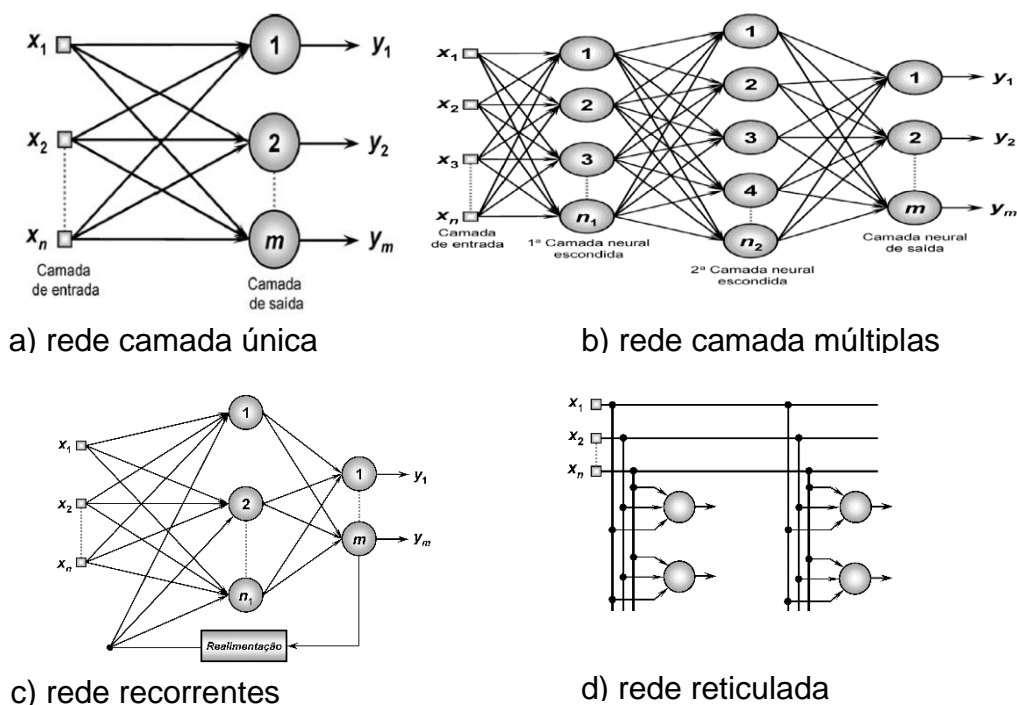


Figura 10 - Exemplo de Arquiteturas de RNA (a, b, c, d).
Fonte: Adaptado de Silva et al. (2010)

2.10.4 Processos de Treinamento ou Aprendizado da RNA

Uma das características bastante relevantes das redes neurais artificiais é o processo de treinamento (tipo de aprendizagem), que consiste da aplicação de passos ordenados, que sejam necessários para sintonização dos pesos sinápticos e limiares de seus neurônios, tendo-se como objetivo final a generalização de soluções a serem produzidas pelas suas saídas. Existem três tipos mais utilizados para o aprendizado de uma RNA: método de aprendizado supervisionado, método de aprendizado não supervisionado e o aprendizado com reforço.

O método de aprendizado supervisionado consiste em se ter disponível, considerando cada amostra dos sinais de entrada, as respectivas saídas

desejadas, ou seja, cada amostra de treinamento é composta pelos sinais de entradas e suas correspondentes saídas. Os pesos sinápticos e limiares são então continuamente ajustados mediante aplicação de ações comparativas, executadas pelo algoritmo de aprendizagem, que supervisionam a defasagem entre as respostas produzidas pela rede em relação às desejadas. A rede estará treinada quando tal defasagem estiver dentro de valores aceitáveis (KARTALOPOLOS, 1996; SANTOS et al, 2010).

No treinamento não supervisionado a própria rede é capaz de ajustar o seu funcionamento extraindo regularidades e padrões existentes nos estímulos de entrada, inexistindo as respectivas saídas desejadas. Conseqüentemente, a própria rede deve se auto organizar em relação às partículas existentes entre os elementos componentes do conjunto total de amostras, identificando subconjuntos (clusters) que contenham similaridades. Os pesos sinápticos e limiares dos neurônios da rede são então ajustados pelo algoritmo de aprendizado de forma a refletir esta representação internamente dentro da própria rede (HAYKIN, 2001).

Os métodos baseados em treinamento com reforço têm sido considerados uma variação das técnicas que utilizam treinamento supervisionado, as quais avaliam constantemente a defasagem de valor entre a resposta produzida pela rede em relação à respectiva saída desejada. Os algoritmos de aprendizado, utilizados neste método, ajustam os parâmetros internos dos neurônios baseando-se em quaisquer informações quantitativas ou qualitativas, advindas da interação com o sistema (ambiente) que está sendo mapeado, as quais são então utilizadas para medir o desempenho do aprendizado (SUTTON & BARTO, 2018).

2.10.5 Perceptron de Múltiplas Camadas (PMC) e Rede TDNN

A rede PMC é caracterizada pela presença de pelo menos uma camada escondida de neurônios, situada entre a camada de entrada e a respectiva camada de saída. Essas redes são bastante versáteis, podendo ser aplicadas nas áreas de reconhecimento de padrões, identificação e controle de processos, otimização de sistemas e estimativa de séries temporais.

Uma das *RNA* utilizada neste trabalho é voltada para estimativa de séries temporais, e se refere à *PMC* de entradas atrasadas no tempo. Esta rede foi idealizada por Lang e Hinton (1988) e se enquadra na arquitetura feedforward (sem realimentação das saídas de neurônios às primeiras camadas), em que a estimativa de valores posteriores a partir do instante t , associados ao comportamento do processo, é computada em função do conhecimento de seus valores anteriores (Equação 26).

$$x(t) = f(x(t-1), x(t-2), \dots, x(t-n_p)) \quad (26)$$

Em que n_p é a ordem do preditor, ou seja, a quantidade de medidas (amostras) passadas que serão necessárias para a estimação do valor $x(t)$. Esse tipo de arranjo (Figura 11) é chamado de TDNN (Time Delay Neural Network) com configuração focada. Este tipo de rede é estimulada através de uma memória de curto prazo. Segundo Haykin (2001), especificamente, dado um sinal de entrada consistindo em um valor presente $x(n)$ e de p valores passados $x(n-1), \dots, x(n-p)$, armazenados em linhas de atraso de ordem p , por exemplo, os parâmetros livres da rede neural são ajustados para minimizar o erro médio quadrado entre a saída da rede, $y(n)$, e a resposta desejada $d(n)$.




Figura 11 - Topologia de PMC com entradas atrasadas no tempo.

A partir da Ilustração da Figura 11, verifica-se que a rede recebe as n_p entradas $\{x(t-1), x(t-2), \dots, x(t-n_p)\}$, as quais estão representando o comportamento do processo, e predizem como resposta o respectivo valor esperado para $x(t)$, cujo resultado é explicado pelo valor $y(t)$ fornecido pelo seu

neurônio de saída. Assim, durante o processo de treinamento, a rede tentará ajustar as suas matrizes de pesos visando minimizar o erro produzido pela diferença entre $x(t)$ e $y(t)$, conforme Equação 27.

$$E(t) = x(t) - y(t), \text{ em que } (n_p + 1) \leq t \leq N \dots\dots\dots (27)$$

O valor de N representa a quantidade total de medidas (amostras) disponíveis e que foram sequencialmente coletadas ao longo do tempo.

Segundo Silva et al. (2010), o treinamento da rede PMC com entradas atrasadas no tempo é similar ao PMC convencional, contudo os cuidados que ora devem ser levados em conta estão associados com a amostragem do conjunto de treinamento da rede. Para elucidar tal mecanismo, considera-se que para um determinado sistema dinâmico foram escolhidas oito medidas ($N=8$), ao longo do tempo (Figura 12).

$$x(t) = \begin{bmatrix} t = 1 & t = 2 & t = 3 & t = 4 & t = 5 & t = 6 & t = 7 & t = 8 \\ 0,11 & 0,32 & 0,53 & 0,17 & 0,98 & 0,67 & 0,83 & 0,79 \\ x(1) & x(2) & x(3) & x(4) & x(5) & x(6) & x(7) & x(8) \end{bmatrix}^T$$

Figura 12 - Representação de uma amostra a ser usada em PMC.

Fonte: Silva et al (2010)

Para o processamento, a ser mapeado com uma ordem de predição igual a três $\{n_p = 3\}$, por exemplo, tem-se, para o PMC, com entradas atrasadas no tempo, um conjunto de treinamento composto por um total de cinco amostras, pois o parâmetro t varia de quatro até oito (Equação 27), como demonstrado no esquema da Figura 13.

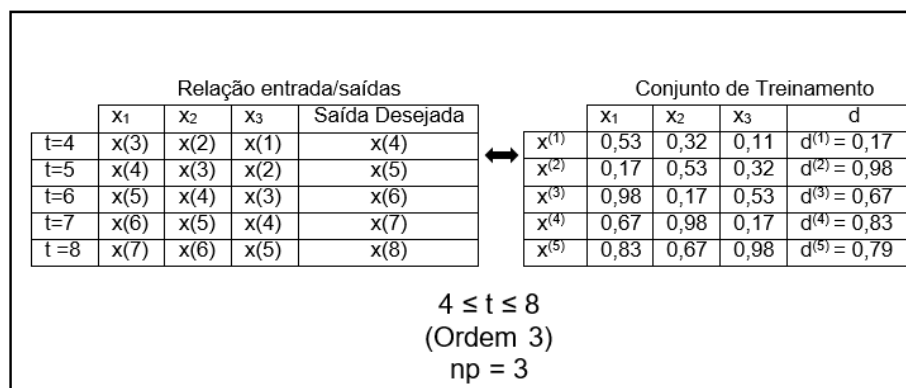


Figura 13 - Esquema do processamento do PMC com entradas atrasadas.

Fonte: Silva et al. (2010)

Esse processamento do PMC de entradas atrasadas consiste em uma operação de janelas deslizantes de largura n_p , movimentando-se a mesma unidade para a direita em cada iteração de tempo. Assim, após o treinamento da rede, basta realizar a inserção de amostras anteriores da série a fim de executar a predição de seus valores futuros.

A rede *TDNN* adotada foi estruturada em quatro camadas e possuem as seguintes configurações: *TDNN* (a, b, c, d), com uma camada oculta, em que a é o número de neurônios na camada de entrada, b representa o número de valores usados como memória da rede, c número de neurônios na camada oculta e d é o número de neurônios na camada de saída, em que as entradas, são formadas pelos valores de precipitações diárias.

A determinação dos pesos da *RNA* é feita através de treinamento, no qual vários exemplos de entrada-saída são apresentados à *RNA* e seus pesos são iterativamente modificados até que a *RNA* atinja uma capacidade de mapeamento aceitável, que é definida pelo usuário.

O treinamento das redes *PMC*, incluindo a *TDNN*, é realizada pelo algoritmo de retropropagação (backpropagation), os quais permitem que os pesos e os neurônios ajustem-se automaticamente a cada iteração, resultando na diminuição dos erros produzidos pelas respostas da rede. O algoritmo mais utilizado e conhecido é o Levenberg-Marquardt (LM). O algoritmo de *LM* foi utilizado para o treinamento do *PMC*, devido seu uso ser consolidado em diversas aplicações. O algoritmo *LM* é uma modificação do algoritmo clássico de Newton, usado como uma solução ótima para problemas de minimização de

função. Ele foi projetado para abordar a velocidade e a precisão do treinamento de segunda ordem sem precisar calcular a matriz Hessiana. As técnicas de otimização não linear de segunda ordem são geralmente mais rápidas e confiáveis. Atualmente, o algoritmo *LM* é, reconhecidamente, o mais rápido para treinar uma *RNA* de tamanho moderado, apesar de exigir uma quantidade superior de memória em comparação com outros algoritmos. (DALIAKOPOULOS et al. 2005).

No presente estudo, foram definidos os seguintes parâmetros a serem adotados na rede *TDNN*:

- a) uma camada oculta;
- b) critério de parada pelo número máximo de 1.000 iterações;
- c) taxa de aprendizado, variando de 0,025 a 1,0;
- d) algoritmo de aprendizado: Levenberg-Marquardt;
- e) função de transferência na camada oculta (log sigmoide); e
- e) função de saída linear.

O esquema da estrutura da rede *TDNN* combinada com a decomposição wavelet é demonstrada na Figura 14, abaixo.

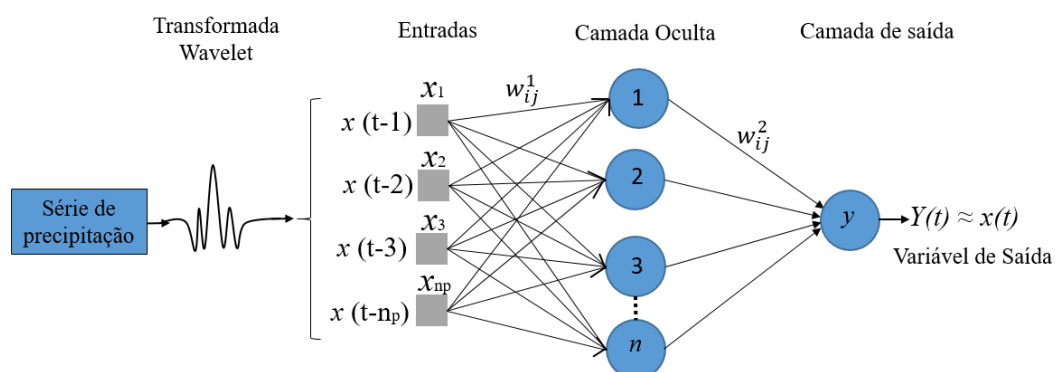


Figura 14 - Arquitetura da rede TDNN combinada com transformada wavelet.

2.10.6 Rede Elman

As redes Elman, assim denominadas devido ao seu criador, Jeffrey Elman (1991), são conhecidas como redes recorrentes simples e são aperfeiçoamentos das redes feedforward. Segundo Silva et al. (2010), as redes

recorrentes são aquelas em que as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios. Esta realimentação oferece a rede uma memória de eventos imediatos anteriores, afetando as atualizações dos pesos em cada uma das camadas da rede. Além disso, a realimentação qualifica este tipo de rede para processamento dinâmico de informações, podendo ser utilizadas em sistemas variantes em relação ao tempo, como estimativa de séries temporais, otimização e identificação de sistemas, etc.

A rede Elman contém conexões recorrentes dos neurônios ocultos para uma camada de unidades de contexto que consiste de atrasos unitários. Estas unidades de contexto armazenam as saídas dos neurônios ocultos por um passo de tempo, e então as realimenta de volta para a camada de entrada. Os neurônios ocultos têm assim um registro das suas ativações passadas, o que capacita a rede a realizar tarefas de aprendizagem que se estendem no tempo (HAIKYN, 2021).

Elman (1991) descreve que nessas redes, além das unidades de entrada, intermediárias e de saída, há também unidades de contexto, como nas redes parcialmente recorrentes em geral (Figura 15). As unidades de entrada e saída interagem com o ambiente externo, enquanto as unidades intermediárias e de contexto não o fazem. As unidades de entrada são apenas unidades de armazenamento que passam os sinais sem modificá-los. As unidades de saída são unidades lineares que somam os sinais que recebem. As unidades intermediárias podem ter funções de ativação lineares ou não lineares, e as unidades de contexto são usadas apenas para memorizar as ativações anteriores das unidades intermediárias e podem ser consideradas como atraso no tempo em um passo.

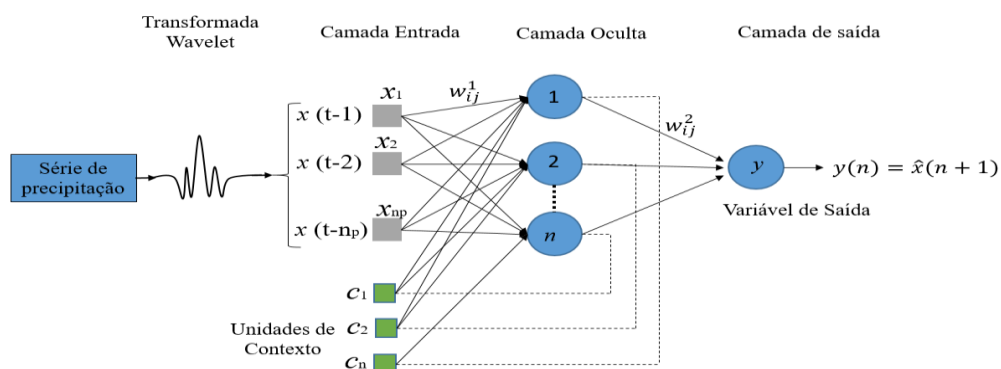


Figura 15 - Arquitetura da rede Elman combinada com MODWT.

Schatz (2014) esclarece que a rede Elman funciona da seguinte maneira: no instante t (inicial), o sinal é propagado pela rede e as unidades de contexto, inicializadas com a saída da camada escondida com o valor zero. Nesta primeira iteração, a rede comporta-se como uma rede feedforward e os neurônios escondidos ativam os neurônios da camada de contexto e esses armazenam a saída desta iteração, sendo utilizada no próximo ciclo. Em seguida, a saída produzida é comparada com as respostas desejadas e os erros são calculados e utilizados para ajustar os pesos de todos os neurônios. No instante $(t + 1)$ o processo é repetido. A diferença é que a partir de agora os neurônios escondidos serão ativados pelas unidades de entrada e pelas unidades de contexto que possuem o valor de saída dos neurônios escondidos no instante (t) .

Como as unidades de contexto de uma rede Elman são tratadas como entradas, os mesmos também têm pesos sinápticos associados a rede e podem ser ajustados pelo algoritmo backpropagation, que se caracteriza pelo treinamento de propagação adiante das entradas até a saída, e pela propagação reversa, onde os erros e os pesos sinápticos das saídas iniciais são utilizados e ajustados em todos os neurônios da rede, realizados sucessivamente.

A realimentação, que ocorre na rede Elman, vai da saída da camada escondida para todos os demais neurônios da rede. A saída de um neurônio k da camada oculta de uma rede Elman no instante t é dado pela Equação 28 (Silva et al. 2010).

$$y_k(t) = \varphi([\sum_{i=1}^n x_i(t) w_{ki}] + [\sum_{i=1}^n y_k(t-1)w_{ki}^*] + b_k) \quad (28)$$

Em que $y_k(t)$ é a saída do neurônio k da camada oculta no instante t , $x_i(t)$ é a entrada i da rede no instante t , w_{ki} é o peso da entrada i no neurônio k da camada oculta, n é a quantidade de neurônios da camada oculta, w_{ki}^* é o peso da unidade de contexto i do neurônio k da camada oculta e b_k é o erro (bias).

Na aplicação da Rede Elman, os parâmetros adotados foram:

- a) Valor de atraso que variou de 2 a 5;
- b) Número de neurônios na camada oculta igual a 10;

- c) A função de treinamento foi Levenberg-Marquardt;
- d) A função de ativação na camada oculta foi a tangente sigmoide e na camada de saída foi a linear; e
- e) O desempenho da rede foi avaliado pelo erro médio quadrado (mse) e o valor de Nash.

Esses parâmetros foram adotados conforme o resultado do treinamento da rede, buscando os menores erros na estimativa da série de precipitação.

2.10.7 Rede Neural de Base Radial (RBF)

As redes de funções de base radial, conhecidas como RBF pertencem a arquitetura feedforward de camadas múltiplas, cujo treinamento é efetivado de forma supervisionada (as entradas e as saídas desejadas são informadas no treinamento), e são compostas por três camadas, uma contendo a camada de entrada, uma única camada oculta, na qual as funções de ativação são de base radial, e uma camada de saída. Geralmente os neurônios da camada oculta utilizam a função gaussiana como função de ativação (SILVA et al., 2010). A Figura 16 representa o esquema da arquitetura de rede RBF adotada.

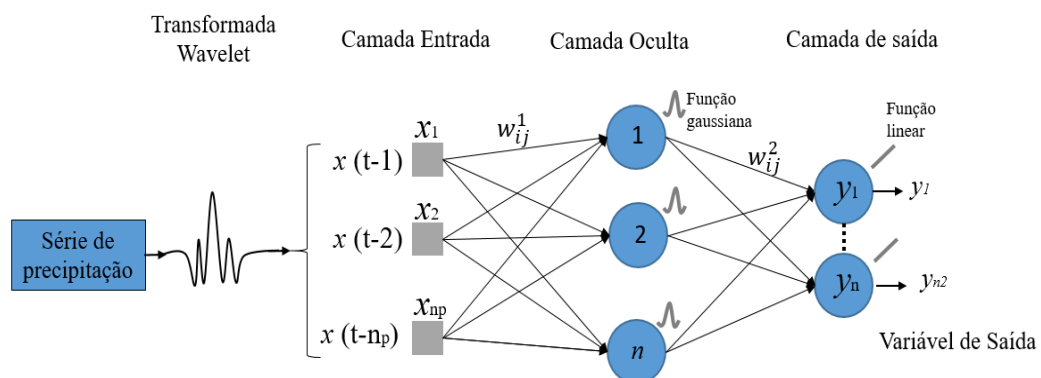


Figura 16 - Arquitetura da rede RBF combinada com MODWT.

As três camadas que formam a rede Elman possui funções específicas. A camada de entrada é constituída por nós de fonte que conectam a rede ao seu ambiente. A segunda camada, a única camada oculta da rede, aplica uma transformação não linear do espaço de entrada para o espaço oculto; na maioria das aplicações, o espaço oculto é de alta dimensionalidade. A camada

de saída é linear, fornecendo a resposta da rede ao padrão (sinal) de ativação aplicada à camada de entrada (HAIKYN, 2001).

O treinamento da RBF é constituído de dois estágios. O primeiro refere-se aos ajustes de peso dos neurônios da camada intermediária, nos quais se efetua a determinação dos parâmetros dos neurônios RBF, ou seja, o centro dos neurônios e a largura da função gaussiana (Equação 29). O segundo estágio está vinculado aos ajustes dos pesos dos neurônios da camada de saída, então, realiza-se o cálculo dos pesos entre a camada escondida e a camada de saída, de acordo com a Equação 30 (Russel e Norvig, 2014).

$$\varphi_i = \exp\left(-\frac{\|x-u_i\|^2}{2\sigma_i^2}\right) \quad (29)$$

$$y = \sum_{i=1}^n w_i \varphi_i(x) \quad (30)$$

Segundo Braga et al. (2011), cada neurônio da camada intermediária possui um vetor associado, chamado de centro do neurônio, o qual define o centro do campo receptivo daquele neurônio, exercendo forte influência sobre o desempenho da rede.

Para a execução da rede, é necessário definir alguns parâmetros, os quais devem ser avaliados para ajustar os melhores resultados da estimativa da rede. Neste trabalho foram adotadas como parâmetros, conforme sugerido em MATLAB R2019 (Beale et al. 1992):

- a) mesmo número de entradas para o número de neurônios da camada oculta;
- b) a constante de propagação variou de 0,1 a 2,0;
- c) o tipo de treinamento foi Levenberg-Marquardt;
- d) o erro mínimo foi de 0; e
- e) a função de ativação na camada oculta foi a gaussiana e na camada de saída a linear.

A cada iteração da rede, o vetor de entrada que resulta na redução do erro da simulação, foi usado para criar um neurônio RBF. O erro foi verificado e se baixo o suficiente, o treinamento da rede foi concluído, caso contrário, o

próximo neurônio é adicionado, até que a meta do erro mínimo seja atingida ou o número máximo de iterações seja alcançado.

2.10.8 Redes ANFIS

O Sistema de Inferência Neuro-Fuzzy Adaptativo (Adaptive Neuro-Fuzzy Inference System - ANFIS) é uma rede neural que combina o Sistema de Inferência Fuzzy (FIS) com a RNA. O ANFIS, é considerado um sistema de inferência fuzzy organizado na forma de uma rede adaptativa, capaz de fazer o mapeamento dos dados de entrada e saída com base no conhecimento de um especialista. A Rede adaptativa é uma rede multicamadas, com arquitetura feedforward disposta por nós interligados por conexões unidirecionais e aprendizado supervisionado (JANG, 1993).

Uma rede Neuro-Fuzzy é, geralmente, formada por três camadas. A primeira camada (fuzzificação) representa as regras fuzzy, ou seja, os termos antecedentes da regra. A segunda camada (intermediária) representa as regras fuzzy e a terceira camada (defuzzificação) representa as variáveis de saída, ou seja, o termo consequente da regra. Contudo podem existir vários tipos de FIS em uma rede ANFIS, que podem variar dependendo do raciocínio e das regras aplicadas. O FIS Takagi-Sugeno (1985), adotado neste estudo, representa um sistema que associa um conjunto de regras linguísticas no antecedente (parte “se”) com proposições fuzzy, e no consequente (parte “então”) apresentadas por expressões do tipo $y=f(x)$, das variáveis linguísticas do antecedente. Por intermédio deste sistema (Takagi-Sugeno) e a partir de um conjunto de dados para treinamento (pares de entrada e saída) é possível fazer previsões de determinada variável, usando uma arquitetura ANFIS, conforme a Figura 17. Esta arquitetura é composta por cinco camadas, cada uma com finalidades específicas (JANG, 1993).

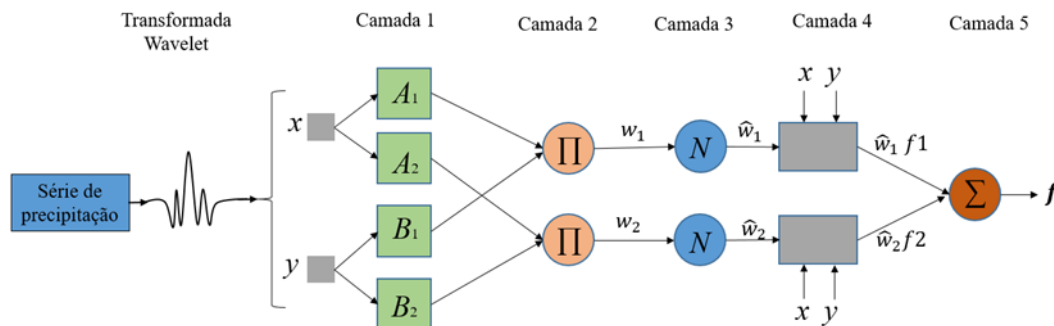


Figura 17 - Modelo híbrido de MODWT e RNA com arquitetura da rede ANFIS.

Na primeira camada, calcula-se o grau de pertinência das entradas x e y , de acordo com o tipo de Função de Pertinência (MF) escolhida nestes nós (A_1 , A_2 , B_1 , B_2). As funções de pertinência (MF) podem ser definidas como sendo uma representação gráfica (diferentes formas) da magnitude de participação de cada entrada e resposta de saída, dependendo do conceito que se deseja representar e do contexto aplicado. Ela associa um peso para cada valor de entrada processada, definindo, assim, uma superposição funcional entre as entradas e determinando uma resposta para a saída. Essa função pode ser linear (triangular, trapezoidal) ou não linear (gaussiana, sino, sigmóide) em função da complexidade do problema e podendo ser também usadas de acordo com a preferência, experiência do especialista, além de depender das características do fenômeno (CALDEIRA, 2007; MALANGE, 2010).

Na segunda camada, os neurônios executam as regras fuzzy como o produto algébrico (neurônio Π), a partir da Equação 31, considerando a MF (μ) e os termos linguísticos (A_i , B_i).

$$w_i = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1, 2 \dots \quad (31)$$

Na terceira camada, as funções de pertinência são normalizadas, através dos pesos (w) dos neurônios N , conforme Equação 32.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1, 2 \quad (32)$$

Na quarta camada as saídas dos neurônios são calculadas pelo produto entre os níveis de disparo normalizado e o valor das regras do consequente. Seus parâmetros correspondem aos coeficientes das expressões afins e a função de ativação dos neurônios que formam a quarta camada, são definidas pela Equação 33, em que p_i, q_i, r_i são os parâmetros associados aos consequentes das regras.

$$z_{4,1} = \bar{w}_i f_i = \bar{w}_i (p_i + q_i y + r_i) \quad (33)$$

Na quinta camada é calculada a saída do sistema f , e, juntamente com os nós da terceira e quarta camada, promovem a defuzificação ou soma total de todos os sinais de entrada, podendo ser representada pela Equação 34.

$$f = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (34)$$

Para aplicação da ANFIS na estimativa da precipitação, foram adotados como parâmetros iniciais duas MFs para cada variável de entrada. O tipo de função de pertinência é escolhido pelo melhor desempenho da rede, variando entre a triangular, trapezoidal, gaussiana, sino generalizada e senoidal. A função de saída foi testada pelo tipo constante e linear e como parâmetro para o treinamento, foi escolhido o método de treinamento híbrido, que consiste pela combinação do método backpropagation e o dos mínimos quadrados, sendo o primeiro associado às estimativas dos parâmetros das funções de pertinência de entrada, e o segundo, associado às estimativas dos parâmetros de saída das funções de pertinência. Outros parâmetros que foram usados são: tolerância de erro mais próximo a zero e o número inicial de épocas igual a 2. Para Misit (2000), o número de épocas refere-se à quantificação de apresentação de todo o conjunto de padrões de treinamento durante o processamento da RNA. Geralmente são necessárias algumas épocas para que uma rede esteja treinada e pronta para produzir resultados. O número de épocas pode aumentar ou diminuir de acordo com o sistema a ser implementado. Lembrando que sempre se deve tomar cuidado com o super treinamento (Overfitting).

O super treinamento é um fenômeno conhecido como o excesso de ajuste do treinamento. Quando este acontece, a rede pode perder a habilidade de generalizar entre padrões de entrada e saída similares. Segundo Haikyn (2001), a generalização pode ser influenciada pelo aumento indiscriminado de neurônios, assim como o incremento de camadas intermediárias, as quais podem ser inapropriadas para as redes em relação às amostras pertencentes aos conjuntos de teste.

Nas circunstâncias de “overfitting”, o erro quadrático durante a fase de aprendizagem tende a ser baixo, contudo, durante a fase de generalização frente aos subconjuntos de teste, o erro quadrático tende a assumir valores bem elevados, fato que denota a condição de “overfitting”.

Para evitar o “overfitting”, o arranjo da arquitetura das redes, bem como seus parâmetros podem ser ajustados, começando com pequenas camadas e adicionando neurônio na camada oculta. Introdução de diferentes parâmetros a rede, também devem ser avaliados, de maneira que o erro quadrático mantenha-se próximo nas etapas de treinamento e teste da rede (SANTOS, et al. 2010). No presente estudo foi adotado tais procedimentos para se evitar o super treinamento.

3 MATERIAL E MÉTODOS

A metodologia adota neste estudo consiste nas seguintes etapas:

- Obtenção, organização e padronização dos dados de precipitação;
- Divisão da série histórica em períodos sazonais (Período Chuvoso - PC e Menos Chuvoso - MC);
- Decomposição da série dos períodos sazonais por MODWT com filtros Wavelet;
- Calibração dos modelos através do treinamento da MODWT-RNA por meio de ajustes dos parâmetros da rede, do tipo de entrada e filtros Wavelet (75% da série histórica);
- Validação do modelo, adotando os parâmetros ótimos, obtidos na calibração (25% da série histórica) por meio dos critérios de desempenho.

Na Figura 18 observa-se o esquema das etapas metodológicas para a realização deste trabalho com destaque nas caixas azuis para o tratamento e organização dos dados, nas caixas verdes a realização da decomposição MODWT e as caixas vermelhas para a aplicação do modelo MODWT-RNA, juntamente com a calibração e validação.

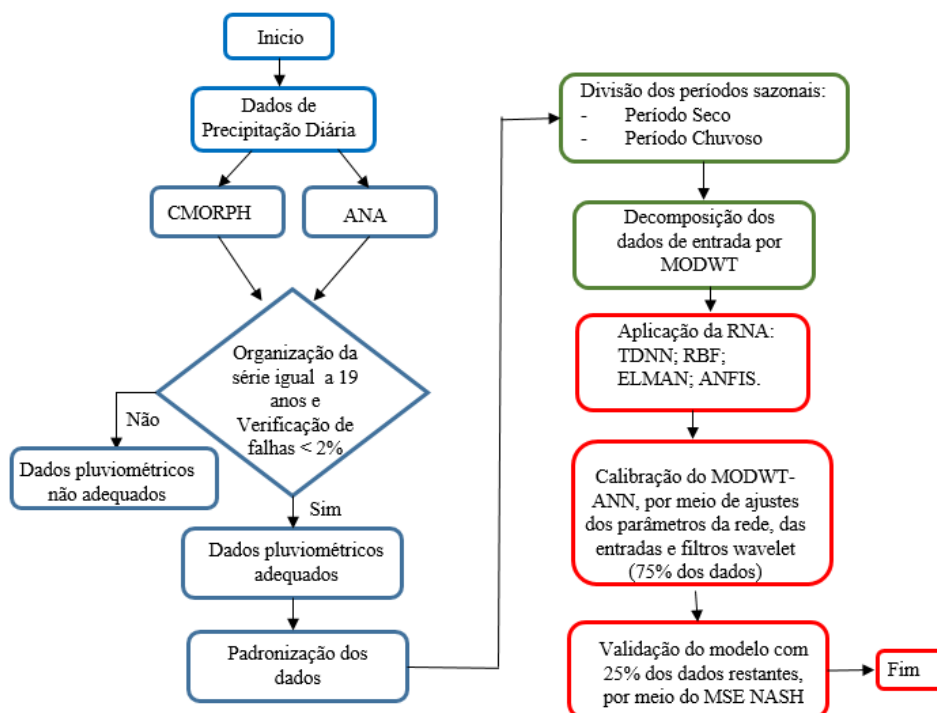


Figura 18 - Esquema Metodológico da Pesquisa.

Os modelos combinados da MODWT-RNA foram avaliados inicialmente pelo tipo de filtro wavelet e número de entradas atrasadas no tempo (delay). A MODWT foi usada para decompor a série de precipitação e gerar os coeficientes de wavelet e de escala “corrigidos por limite”. Para tanto, foram adotados três tipos de famílias wavelet: daubechies (db), menos assimétrico de daubechies (db4), wavelet coiflet (c6) e três níveis de decomposição j (4, 6, 8). O comprimento do filtro variou, conforme a família wavelet adotada e pode ser consultado com mais detalhe em Basta (2014). O nível máximo de decomposição foi de oito ($J_{\text{máx}}=8$) e o comprimento dos filtros (K) de wavelet foram de 4 para db4, de 14 para la14 e de 6 para c6. Assim, usando um nível máximo de decomposição igual a oito e um K igual a 4, temos que $K_j = (2^8 - 1)(4 - 1) + 1$, logo K_j é igual a 766 coeficientes afetados pelo limite de j (essa prática foi adotada também, para $j = 4$ e 6, e para $K= 6$ e 14). Assim, foram definidos os coeficientes de wavelets corrigidos por limite e os coeficientes de escala, antes de selecionar as variáveis de entrada para calibração e validação do modelo com o uso da RNA. Os menores erros e o melhor valor de Nash resultantes da validação do uso da RNA indicaram a melhor estrutura MODWT-RNA para estimativa da precipitação diária.

Os dados de entrada, já transformados pela MODWT, usando seis filtros (db-j6, db-j8, la14-j4, la14-j6, c6-j4 e c6-j6), para cada estação, foram organizados em uma matriz de dados contendo os valores da decomposição, de 2, 3, 4 e 5 dias atrasados e do valor esperado no dia desejado. Assim, cada matriz, com atrasos diferentes, foi treinada pelas redes neurais. Os resultados contendo os valores simulados, na validação, são usados para comparar o valor médio do MSE e Nash, em períodos diferentes (Chuvoso e Menos Chuvoso), indicando qual a melhor entrada e filtro. A seleção dos parâmetros apropriados para o melhor desempenho das redes neurais, como o número de neurônios na camada oculta e na camada de saída, foi definida pelo método das aproximações sucessivas. Isso é realizado treinando a rede e avaliando o seu desempenho em uma faixa de diferentes valores crescente do número de neurônios, a fim de obter eficiência quase máxima com o mínimo de neurônios necessários (Hammerstron, 1993). No modelo envolvendo a rede ANFIS, o número de MF foi definido de forma iterativa, pois não há uma regra básica

para encontrar a MF. Contudo segundo Jang (1993), um número de MF muito grande, deve ser evitado para diminuir o tempo e o esforço computacional.

As observações diárias decompostas pela MODWT, na fase de calibração dos modelos de RNA (75% da série histórica), foram ainda divididos em três partes: conjunto de treinamento (50%), conjunto de validação (25%) e teste (25%). Esta divisão é realizada automaticamente no momento do processamento das RNA, de acordo com o tamanho da matriz de dados de entrada, garantindo um melhor treinamento e verificação do erro médio quadrático gerado.

No processo de validação dos modelos MODWT-RNA foram usadas as melhores famílias wavelet com seus respectivos níveis e os melhores parâmetros das RNA, definidos na calibração do modelo. Contudo nesta fase, adotaram-se os 25% da série de dados, que não foram usadas na calibração. A divisão da série histórica em períodos sazonais foi detalhada no item 3.5.

3.1 ÁREA DE ESTUDO

A área da Amazônia é de aproximadamente 5.217.423 km², correspondendo a 61% do território brasileiro (IBGE, 2010). A região possui uma extensa e densa rede hidrográfica formada pelo maior rio do mundo, o Amazonas, com uma extensão de 6.400 km, dos quais cerca de 3.220 km estão dentro do Brasil. Incluindo as descargas de seus vários afluentes, o rio Amazonas é responsável por 60% da disponibilidade hídrica do Brasil e cerca de 20% da vazão de toda água doce do mundo (Davidson et al. 2012). Segundo dados do Mapbiomas (2016), a Amazônia apresenta três biomas característicos, o Bioma Amazônico (BA) que é o mais representativo ocupando 83,86% da região, o Bioma Cerrado (BC) situado a leste e sudeste, corresponde a 14,32%, e o Bioma Pantanal (BA) localizado a sudoeste representando apenas 1,82% da área total (Figura 4). Além disso, nestes biomas existem as áreas de transição: o Ecótono Amazônia-Cerrado (EAC) é o de maior em extensão com aproximadamente 6.240 km², estendendo-se de sudeste a sudoeste da região, e os Ecótonos Amazônia-Pantanal (EAP) e Amazônia-Pantanal-Cerrado (EAPC) situados no estado do Mato Grosso (Figura 19).

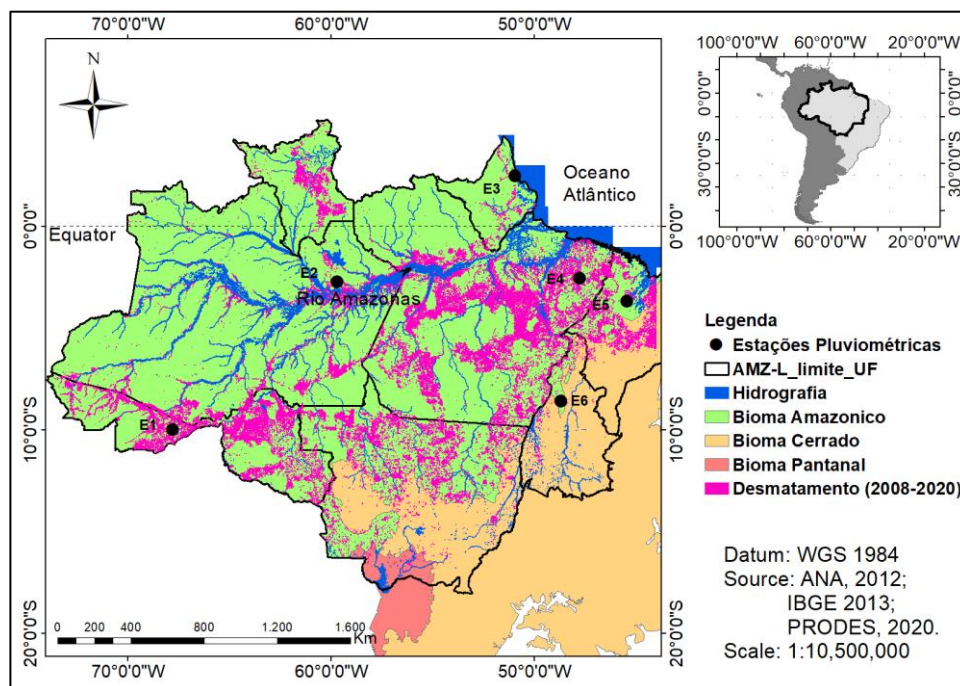


Figura 19 - Amazônia e Localização das Estações Pluviométricas.

No contexto da circulação regional, a floresta desempenha papel importante como fonte de geração de umidade para outras regiões do Brasil (Centro-oeste, Sudeste e Sul) e para o continente sul-americano (Silveira et al. 2017; Ciemer et al. 2018). Segundo dados do Projeto de Monitoramento do Desmatamento na Amazônia por Satélites - PRODES (2021), a área desmatada na AMZ-L até 2020 é de 16% da área total, concentrando-se nas bordas sul e leste da região, conhecida como “arco do desmatamento” (Figura 19). Este processo de desmatamento é causado principalmente, segundo Vale et al. 2019 e Lima et al. 2019, pela substituição da cobertura florestal por atividades de pecuária, agrícola e agroindustrial.

3.2 BASE DE DADOS

Para esta pesquisa, adotou-se a série histórica de seis estações pluviométricas (Tabela 3) monitoradas pela Agência Nacional de Águas (ANA), disponível em (<http://www.snirh.gov.br>), localizadas na região da AMZ-L (Figura 4). Os dados de precipitação diária do produto CMORPH foram obtidos para cada localização da estação da ANA. A escolha das estações priorizou séries

com falhas mínimas (média de 0,2% no total dos dados observados) e o período de observações diárias foi de 19 anos, de 1998 a 2016. A precipitação estimada do satélite é proveniente do produto CMORPH, que está disponível no site (<https://www.ncei.noaa.gov/products/climate-data-records/precipitation-cmorph>) da Administração Oceânica e Atmosférica Nacional (NOAA). A precipitação registrada pela ANA é pontual e registrada a cada 24 horas. As informações produzidas pelo CMORPH têm resolução espacial de 8 km (no equador) e são registradas a cada 30 minutos. Essas diferenças motivaram a utilização dos dois bancos de dados, além da possibilidade de substituição de dados, na ausência de monitoramento pontual, comum em alguns locais da Amazônia.

Tabela 3 - Dados das estações pluviométricas da ANA e precipitação média diária.

ID	Estações	Latitude	Longitude	Falhas (%)	MD ANA	MD CMORPH	Período
E1	Rio Branco	-9,98	-67,80	0,1	5,4	4,2	1998-2016
E2	Rio Preto da Eva	-2,70	-59,70	0,0	6,1	5,8	
E3	Calçoene	2,50	-50,95	0,0	12,4	8,2	
E4	Badajós	-2,51	-47,77	0,0	6,3	5,5	
E5	Pindaré Mirim	-3,66	-45,44	0,0	5,2	4,0	
E6	Itaporã do Tocantins	-8,57	-48,69	0,0	5,1	4,3	

ID = Identificação das estações Pluviométricas da ANA; MD = Média diária de precipitação.

3.3 USO DA MODWT

Na prática a decomposição MODWT é realizada em uma série de dados, onde são selecionados o tipo de filtro (wavelet), o nível de decomposição e o limite, este último, podendo ser periódico ou de reflexão. Se periódico, os coeficientes de wavelet e de escala resultantes são calculados sem fazer duplicações na série original, tratando (X_t) como se fosse circular. Se for de reflexão uma nova série é refletida com o dobro do comprimento da série original. No presente estudo adotou-se o limite periódico, três tipos de famílias

wavelets, Daubechies (db4) de nível 6 e 8 (db4-j6 e db4-j8), menos assimétrico ou Symlet (la14) de nível 4 e 6 (la14-j4 e la14-j6) e coiflet (c6) de nível 4 e 6 (c6-j4 e c6-j6), selecionadas com base nas mais usuais em séries de dados hidrológicos (Maheswaran e Khosa, 2012; Santos et al. 2019) e por realizarem decomposições diversificadas.

A decomposição dos dados por MODWT através dos filtros wavelet ($\hat{h}_{j,k}$) de posição e ($\hat{g}_{j,k}$) escala, são reconstruídos pela Equação 22. Neste caso, os coeficientes de escala e posição são somados e através da equação 20 são definidas as quantidades de coeficientes da série gerada que devem ser retirados para formar os dados de entrada nas redes neurais.

3.4 ENTRADAS DEFASADAS NO TEMPO

Em problemas envolvendo a estimativa de séries temporais, as redes neurais são utilizadas como um bom artifício, principalmente na camada de entrada, onde a incorporação de uma memória na entrada da rede permite o fortalecimento do aprendizado do comportamento das séries temporais. Podendo ser, intuitivamente, anexada as demais camadas da rede, melhorando os resultados. Assim, a combinação de entradas com base nos tempos antecedentes é sugerida neste trabalho. Quatro combinações foram adotadas, considerando a precipitação de dois, três, quatro e cinco dias antecedentes (t-2, t-3, t-4 e t-5) para estimativa do dia atual. Em previsões de variáveis hidrológicas, o intervalo de tempo para esse atraso, não está bem definido, contudo, Shoab et al. 2018; Kim et al. 2020; e Hammad et al. 2021, consideram que até cinco atrasos é um número aceitável, sendo adotado neste estudo. Além disso, incorporar outras variáveis climáticas (temperatura, radiação solar, etc.) na estimativa da precipitação, podem gerar erros devido à incerteza das reais influencias que tais variáveis podem exercer na precipitação.

3.5 AVALIAÇÃO DA SAZONALIDADE

Os dados de precipitação diária foram organizados de duas maneiras, sendo: 1) período chuvoso, que é formado por 3444 precipitações diárias dos meses de novembro-abril do ano de 1998-2016, divididos em 2584 valores

para a calibração (01/01/1998-16/02/2012) e 860 valores para a validação (17/02/2012-31/12/2016); 2) período menos chuvoso, formado por 3496 precipitações dos meses de maio-outubro de 1998-2016, divididos em 2624 valores para a calibração (01/05/1998-17/06/2012) e 872 para a validação (18/06/2012-31/10/2016). Essa divisão visa avaliar a influência da sazonalidade na resposta do modelo. No processamento da rede, os dados foram padronizados (Equação 35) e divididos para a calibração (75%) e para a validação (25%).

$$P_{pad} = \frac{P_i - P_{min}}{P_{max} - P_{min}} \quad (35)$$

Na qual P_{pad} é a precipitação padronizada, P_i é precipitação a ser padronizada, P_{min} e P_{max} são, respectivamente, o menor e o maior valor observado nas séries de precipitações. A padronização implica em escalonar as amostras para a faixa de variação dinâmica das funções de ativação das camadas escondidas, tipicamente representadas pela função logística ou tangente hiperbólica, com o intuito de evitar a saturação dos neurônios, assim como adotado por (Nourani et al. 2017).

3.6 CRITÉRIOS DE DESEMPENHO

O desempenho dos modelos foi avaliado através de parâmetros estatísticos, que são usados para quantificar a concordância entre os dados observados e estimados. Neste estudo foram utilizados três critérios clássicos, o erro médio quadrático (MSE) e o coeficiente de Nash (N) e o coeficiente de correlação representados pelas Equações (36), (37) e (38) respectivamente, além de estatísticas como média, desvio padrão e valores extremos dos dados.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{obs} - Y_{est})^2 \quad (36)$$

$$Nash = 1 - \frac{\sum (Y_{obs} - Y_{est})^2}{\sum (Y_{obs} - \bar{X})^2} \quad (37)$$

$$r = \frac{\sum_{i=1}^n y_{obs} y_{est} - \sum_{i=1}^n y_{obs} \sum_{i=1}^n y_{est}}{\sqrt{[n \sum_{i=1}^n y_{obs}^2 - (\sum_{i=1}^n y_{obs})^2]} * \sqrt{[n \sum_{i=1}^n y_{est}^2 - (\sum_{i=1}^n y_{est})^2]}} \quad (38)$$

Em que n é o número de amostras, Y_{obs} é a precipitação observada, Y_{est} é a precipitação estimada. Os modelos com melhores desempenhos são aqueles que apresentaram baixos valores de MSE e N próximos a 1 (Chai e Draxler, 2014; Nash e Sutcliffe, 1970). A categoria empregada para o nível de correlação foi baseada em Ayres (2012), em que os valores para uma forte correlação estão mais próximos a 1.

4 RESULTADOS E DISCUSSÃO

4.1 RESULTADOS DO MODELO MODWT-TDNN

Na fase de calibração com a rede TDNN, realizaram-se diversas simulações para definir os valores ótimos da rede, por meio do método das aproximações sucessivas. Neste sentido, foi definido uma estrutura de rede neural (a, b, c), indicando o número ótimo para os neurônios na camada de entrada (a), o atraso da rede (b) e o número de neurônios na camada oculta (c). Inicialmente, foi realizado treinamento em cada estação, nos períodos chuvosos e menos chuvosos, nos dados da ANA e CMORPH, e os valores médios obtidos do MSE e Nash foram organizados na Tabela 4 e no gráfico da Figura 20, que indicam qual o melhor atraso da rede e o filtro wavelet mais favorável. A taxa de aprendizagem que melhor se adaptou aos dados de chuva diária foi o valor de 0,035, pois os menores erros aconteceram quando este valor foi adotado. O número de neurônios na camada de entrada e na camada oculta que resultaram em melhores ajustes foram 2 e 20 respectivamente, definindo a melhor rede TDNN com configuração de 2,2,20. Estes resultados enquadram-se com os intervalos sugeridos por Gomes e Blanco (2021) para as redes TDNN que realizam estimativas de chuvas diárias.

Tabela 2 - Valores médios de MSE e Nash para cada filtro wavelet do modelo MODWT-TDNN (calibração).

Período Chuvoso - PC												
Atraso	db4-j6		db4-j8		la14-j4		la14-j6		c6-j4		c6-j6	
	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash
2	0,147	0,95	0,056	0,98	0,163	0,93	0,237	0,86	0,097	0,95	0,132	0,94
3	0,258	0,91	0,087	0,91	0,148	0,88	0,274	0,85	0,257	0,91	0,276	0,92
4	0,284	0,86	0,123	0,87	0,257	0,85	0,326	0,85	0,384	0,87	0,384	0,80
5	0,793	0,76	0,258	0,82	0,456	0,82	0,412	0,84	0,489	0,76	0,396	0,80
Período Menos Chuvoso - MC												
Atraso	db4-j6		db4-j8		la14-j4		la14-j6		c6-j4		c6-j6	
	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash
2	0,469	0,89	0,235	0,92	0,314	0,9	0,211	0,92	0,494	0,92	0,682	0,9
3	0,327	0,93	0,164	0,91	0,325	0,87	0,248	0,91	0,527	0,93	0,324	0,89
4	0,088	0,93	0,123	0,92	0,148	0,93	0,231	0,9	0,206	0,92	0,416	0,92
5	0,052	0,95	0,050	0,97	0,0742	0,94	0,284	0,94	0,108	0,94	0,119	0,95

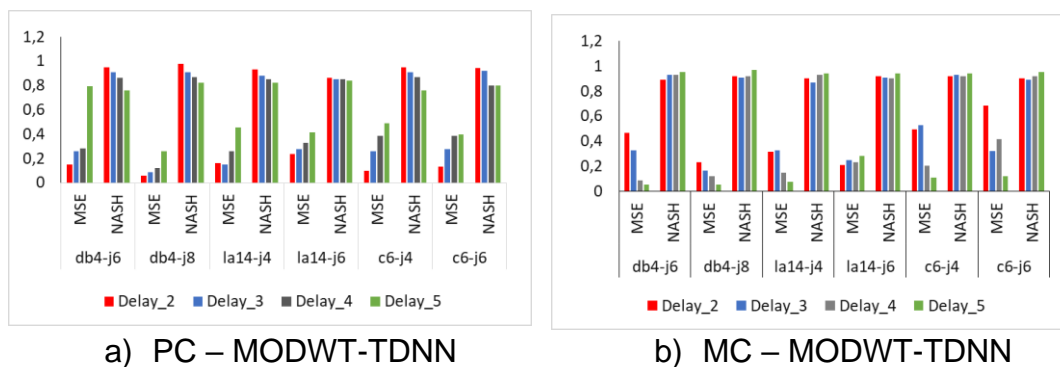


Figura 20 - Valores médios de MSE e Nash para o modelo MODWT-TDNN.

O filtro wavelet db4-j8 demonstrou ser melhor, pois seus valores de MSE e Nash foram bem melhores que os demais filtros. No período chuvoso, o atraso com dois dias apresentou menores MSE, de 0,056 a 0,237, e Nash maiores variando de 0,86 a 0,98, quando comparados com os demais atrasos (Tabela 4). Já para o MC, os atrasos de cinco dias, ajustaram-se bem, com valores de MSE entre 0,050 e 0,284, e maiores Nash variando de 0,94 e 0,97. Assim, observa-se que para se obter um desempenho melhor na estimação, em relação ao número de dias de atraso (b), ou seja, a memória na entrada da rede, o período menos chuvoso exigiu uma memória maior que as da série do período chuvoso. Isso pode estar relacionado com a variação interanual da precipitação, uma vez que a sequência de dias sem chuvas precisa de muito mais informações de dias anteriores do que os dias chuvosos (Wilks, 1999).

Após a definição das melhores defasagens de entradas, dos filtros wavelet e dos melhores parâmetros da rede TDNN, avaliou-se o desempenho do modelo MODWT-TDNN para cada estação, nos diferentes períodos sazonais e para os dados da ANA e CMORPH. Na tabela 5 encontram-se tais resultados, os quais foram avaliados para cada modelo MODWT-RNA adotado.

Avaliando os dados do CMORPH com os dados da ANA na estimativa da precipitação diária, adotando a rede TDNN (2,2,20), nos diferentes períodos sazonais, percebeu-se que o filtro wavelet db4-j8 apresentou melhores ajustes em relação ao MSE, para todas as estações tanto do período menos chuvoso como do chuvoso para os dados da ANA. Já na série de dados do CMORPH, os filtros db4-j8 e la14-j6 foram mais adequados para o período chuvoso, enquanto o filtro db4-j8 foi melhor para o período MC (Tabela 5).

Tabela 3 - Resultado dos Modelos MODWT-RNA na calibração.

Período Chuvoso											Período Menos Chuvoso								
Modelo	Estações	ANA					CMORPH				ANA					CMORPH			
		Atraso	Filtro	Nível(j)	MSE	Nash	Filtro	Nível(j)	MSE	Nash	Atraso	Filtro	Nível(j)	MSE	Nash	Filtro	Nível(j)	MSE	Nash
MODWT-TDNN	E1		db4	8	0,083	0,98	la14	6	0,188	0,98		db4	8	0,186	0,98	la14	8	0,361	0,98
	E2		db4	8	0,099	0,98	la14	6	0,124	0,98		db4	8	0,16	0,98	db4	8	0,052	0,98
	E3	(t-2)	db4	8	0,057	0,89	la14	6	0,36	0,97	(t-5)	db4	8	0,167	0,97	db4	8	0,218	0,98
	E4		db4	8	0,103	0,98	la14	6	0,231	0,96		db4	8	0,255	0,95	db4	8	0,126	0,95
	E5		db4	8	0,094	0,95	db4	8	0,128	0,97		db4	8	0,218	0,97	db4	8	0,131	0,95
	E6		db4	8	0,069	0,96	db4	8	0,09	0,97		db4	8	0,292	0,98	db4	8	0,232	0,98
MODWT-RBF	E1		c6	6	0,0005	0,98	db4	8	0,008	0,98		db4	8	0,002	0,98	la14	6	0,003	0,92
	E2		c6	6	0,001	0,98	c6	6	0,047	0,97		db4	6	0,0001	0,96	db4	8	0,124	0,97
	E3	(t-5)	c6	4	0,059	0,98	db4	8	0,061	0,97	(t-5)	db4	8	0,215	0,98	la14	6	0,103	0,97
	E4		db4	8	0,124	0,98	db4	8	0,002	0,96		la14	6	0,147	0,97	la14	6	0,141	0,98
	E5		db4	8	0,152	0,98	db4	8	0,515	0,96		db4	8	0,075	0,97	db4	8	0,236	0,96
	E6		db4	8	0,028	0,96	db4	8	0,028	0,97		db4	8	0,085	0,98	db4	8	0,019	0,98
MODWT-ELMAN	E1		c6	4	0,0112	0,98	db4	8	0,0018	0,76		db4	8	0,0166	0,95	la14	4	0,0086	0,65
	E2		db4	8	0,0129	0,96	la14	4	0,0106	0,69		db4	6	0,0131	0,96	c6	6	0,0126	0,87
	E3	(t-5)	c6	4	0,059	0,98	db4	8	0,022	0,72	(t-5)	db4	8	0,0083	0,97	c6	6	0,0296	0,92
	E4		db4	6	0,0124	0,97	la14	4	0,0047	0,8		db4	8	0,0068	0,97	db4	8	0,0134	0,74
	E5		c6	4	0,0139	0,98	db4	8	0,515	0,96		la14	4	0,00116	0,98	la14	4	0,0255	0,84
	E6		la14	4	0,0181	0,96	la14	4	0,0665	0,83		db4	8	0,0344	0,97	la14	6	0,0615	0,97
MODWT-ANFIS	E1		db4	6	0,001	0,98	db4	6	0,009	0,74		db4	8	0,0031	0,8	db4	6	0,0015	0,98
	E2		db4	6	0,0054	0,92	db4	8	0,0036	0,7		c6	6	0,004	0,94	c6	6	0,0039	0,96
	E3	(t-4)	db4	6	0,0018	0,98	c6	6	0,0024	0,98	(t-4)	db4	6	0,0024	0,98	db4	6	0,001	0,98
	E4		c6	6	0,0017	0,98	db4	6	0,0023	0,98		c6	6	0,0024	0,98	db4	6	0,002	0,98
	E5		c6	6	0,0014	0,98	c6	6	0,0029	0,98		c6	6	0,0026	0,98	la14	6	0,0012	0,98
	E6		db4	6	0,0054	0,94	db4	6	0,0049	0,68		db4	8	0,0012	0,95	db4	6	0,0009	0,98


4.2 RESULTADOS DO MODELO MODWT-RBF

Após obter os testes com as entradas defasadas (2, 3, 4 e 5 dias), para as seis estações envolvidas, em cada período sazonal, nos seis diferentes filtros (db-j6, db-j8, la14-j4, la14-j6, c6-j4 e c6-j6), verificou-se que a rede RBF teve bom desempenho com o filtro db4-j8, e exigiu mais dias de atraso para gerar resultados com MSE menores e um Nash mais favorável, tanto no PC como no MC. Isso pode ser observado na Tabela 6 e na Figura 21, em que os menores valores médios de MSE e maiores valores médios de Nash ocorrem para as simulações com 5 dias de atraso. Esse resultado pode estar relacionado com o fato da RBF formar os centros e as distâncias euclidianas, através das funções gaussianas por regra de competição, que geram melhores resultados quanto maior o número de elementos, ou seja maior número de entradas (Luo e Unbehauen, 1998).


Tabela 4 - Valores médios de MSE e Nash para cada filtro wavelet do modelo MODWT-RBF.

Período Chuvoso - PC												
Atras	db4-j6		db4-j8		la14-j4		la14-j6		c6-j4		c6-j6	
	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nas
2	0,35	0,92	0,02	0,94	0,985	0,88	0,75	0,93	0,65	0,96	0,74	0,87
3	0,27	0,94	0,05	0,97	0,452	0,87	0,49	0,9	0,44	0,95	0,58	0,95
4	0,02	0,96	0,01	0,96	0,098	0,91	0,41	0,92	0,26	0,94	0,08	0,92
5	0,00	0,96	0,00	0,98	0,013	0,95	0,00	0,98	0,01	0,97	0,02	0,97

Período Menos Chuvoso - MC												
Atras	db4-j6		db4-j8		la14-j4		la14-j6		c6-j4		c6-j6	
	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nash	MSE	Nas
2	0,07	0,94	0,54	0,92	0,102	0,91	0,75	0,87	0,02	0,9	0,14	0,94
3	0,23	0,91	0,18	0,88	0,099	0,93	0,29	0,92	0,71	0,87	0,67	0,86
4	0,08	0,95	0,02	0,9	0,241	0,88	0,26	0,92	0,32	0,91	0,24	0,92
5	0,00	0,96	0,00	0,97	0,087	0,96	0,12	0,96	0,06	0,95	0,01	0,95



a) PC – MODWT-RBF



b) MC – MODWT-RBF

Figura 21 - Valores médios de MSE e Nash para o modelo MODWT-RBF.

No processo de treinamento da rede RBF, o número de neurônios de base radial é igual ao número de vetores de entrada, porque essa rede cria iterativamente um neurônio por vez para cada vetor de entrada (Braga et al., 2011). Foi definido como número máximo de neurônio na camada oculta (MN), o mesmo valor de entradas, conforme indicado por Beale et al. 1992. As precipitações selecionadas previamente pela MODWT são apresentadas em forma de vetores, correspondente às entradas de dados. A constante de propagação (*sp*) da base radial que melhor se ajustou as simulações, corresponde a 0,2, pois apresentou menores erros para o MSE. Para Fausett (2006), é importante que a constante de propagação seja um valor suficiente para que os neurônios da camada escondida respondam a regiões sobrepostas do espaço de entrada, porém não deve ser tão grande, evitando que todos os neurônios respondam essencialmente da mesma maneira. Neste estudo essa constante foi avaliada no intervalo de 0,1 a 1, como sugerido por Beale et al. (1992).

As entradas filtradas e defasadas de 5 dias dos dados da ANA e do CMORPH, de cada estação foram treinadas com a rede RBF, usando a constante de propagação igual a 0,2, número de neurônios da camada oculta (MN) igual aos vetores de entrada e o mínimo erro médio quadrado de 0,001. Tais parâmetros apresentaram bons resultados durante a calibração. Os resultados destes testes revelam que no PC, adotando os dados da ANA, o filtro db4-j8 apresentou menores MSE para as estações (E4, E5, E6), exceto para as estações E1, E2 e E3 em que o filtro c6-j6 foi o mais apropriado, com menores MSE e Nash mais próximos a 1. No MC, somente a estação E4 apresentou menor MSE com o filtro la14-j6, todas as demais estações (E1, E2, E3, E5 e E6), tiveram menores MSE e melhores Nash com o filtro db4-j8. Com os dados do CMORPH, o filtro db4-j8 foi o que apresentou melhor desempenho na simulação para as estações do PC e do MC, exceto E2, no PC, onde o menor MSE ocorreu para o filtro c6-j6. Para as estações E1, E3 e E4, no MC, o menor MSE incidiu com filtro la14-j6 (Tabela 5).

Pelos resultados obtidos, o filtro db4-j8 destacou-se na simulação da precipitação diária com a rede RBF, seu bom desempenho já foi observado em outros trabalhos de estimativa de variáveis hidrológicas (Shouaib, et al. 2018, Maheswaran e Khosa, 2012). A estimativa foi satisfatória tanto para os dados

da ANA como os do CMORPH e apesar do filtro db-j8 ter se destacado, os demais filtros também apresentaram pequenos MSE e Nash relativamente bons.


4.3 RESULTADOS DO MODELO MODWT-ELMAN

Nos testes com a rede Elman, as entradas defasadas, o número de neurônios na camada oculta, foram inicialmente avaliados para cada estação, em períodos diferentes (PC e MC). O resultado do desempenho foi obtido pelas médias do MSE e Nash em cada período, para cada atraso da rede (Tabela 7 e Figura 22). No processo de calibração da rede, observa-se que o atraso de cinco dias apresentou menores MSE e maiores Nash, tanto no PC como no MC. Esse resultado indica que quanto mais dados para treinar a rede Elman, melhores serão seus resultados.

Em relação aos números de neurônios na camada oculta, variou-se de 5 a 40 com defasagem de 5. Observou-se que 10 neurônios é um valor aceitável, pois garante neurônios suficientes a ponto de não comprometer o treinamento da rede, deixando muito extenso e aumentando o tempo de processamento. Segundo Jang (1997), um número de neurônios muito grande pode deixar o treinamento da rede mais longo e as vezes não traz melhorias as simulações. A melhor configuração da rede Elman foi então de 5 atrasos na camada de entrada e 10 neurônios na camada oculta (1:5;10). O tipo de filtro com as menores médias do MSE e maiores Nash, foi o c6-j4 para o PC e o db4-j8 para o MC, para as simulações com o modelo MODWT-ELMAN (Tabela 7).

Tabela 5 - Valores médios de MSE e Nash para cada filtro wavelet do modelo MODWT-ELMAN.

Período Chuvoso - PC													
		db4-j6		db4-j8		la14-j4		la14-j6		c6-j4		c6-j6	
Rede	Atras	MSE	Nas	MSE	Nas	MSE	Nash	MSE	Nas	MS	Nash	MSE	Nas
1:2,1	2	0,042	0,67	0,068	0,58	0,021	0,64	0,031	0,66	0,053	0,74	0,067	0,78
1:3,5	3	0,057	0,56	0,042	0,62	0,047	0,62	0,047	0,57	0,042	0,6	0,045	0,64
1:4,5	4	0,038	0,62	0,009	0,6	0,027	0,6	0,035	0,62	0,033	0,4	0,042	0,72
1:5,1	5	0,022	0,75	0,020	0,78	0,019	0,69	0,018	0,79	0,003	0,89	0,028	0,81
Período Menos Chuvoso - MC													
		db4-j6		db4-j8		la14-j4		la14-j6		c6-j4		c6-j6	
Rede	Atras	MSE	Nas	MSE	Nas	MSE	Nash	MSE	Nas	MSE	Nas	MSE	Nas
1:2,1	2	0,009	0,58	0,039	0,52	0,081	0,56	0,064	0,64	0,095	0,61	0,049	0,65
1:3,3	3	0,074	0,67	0,014	0,63	0,008	0,6	0,053	0,63	0,074	0,64	0,009	0,7
1:4,2	4	0,052	0,68	0,033	0,68	0,032	0,58	0,081	0,58	0,032	0,65	0,051	0,67
1:5,1	5	0,002	0,69	0,002	0,74	0,012	0,68	0,030	0,68	0,003	0,71	0,003	0,72



a) PC – MODWT-ELMAN

b) MC – MODWT-ELMAN

Figura 22 - Valores médios de MSE e Nash para o modelo MODWT-ELMAN.

Após seleção dos melhores parâmetros para a rede ELMAN, as estações com dados da ANA e do CMORPH foram treinadas em cada período e com diferentes filtros, adotando as entradas defasadas de cinco dias. Assim, pelos resultados obtidos da calibração, observa-se que para os dados da ANA, no período chuvoso, o filtro c6-j4 apresentou menores MSE para as estações E1, E3, e E5. Enquanto que para as estações E2, E4, e E6, os filtros com menores MSE foram respectivamente db4-j8, db4-j6, la14-j4 e c6-j6. No MC, com os dados da ANA, o filtro db4-j8 apresentou menores MSE para as estações E1, E3, E4 e E6. Para a estação E2, os menores MSE aconteceram com o filtro db4-j6 e na E5 com o filtro la14-j4 (Tabela 5).

Para os dados do CMORPH, no PC, o filtro db4-j8 foi melhor para as estações E1, E3 e E5. O filtro la14-j4 foi melhor para as estações E2, E4 e E6. Em relação ao período MC, o filtro la14-j4 foi mais adequado para as estações E1 e E6, enquanto que o filtro c6-j6 foi melhor para as estações E2 e E3. Para as estações E4 e E5, os melhores filtros foram respectivamente db4-j8 e la14-j4 (Tabela 5). O uso da rede 1:5,10, adotando as entradas filtradas com diferentes filtros wavelets mostrou-se uma estratégia eficaz para mostrar que não há uma predominância de um único filtro como aconteceu nas redes anteriores (TDNN e RBF). Isso reforça a ideia de que cada tipo de entrada e cada tipo de rede pode resultar em um treinamento específico para diferentes estações pluviométricas.

Tanto no PC como MC, os valores médios do Nash foram maiores para os dados da ANA, em torno de 0,69 a 0,98, no PC, e no MC, na faixa de 0,65 a 0,98. Em relação ao erro, a média do MSE foi menor para os dados da ANA, na

faixa de 0,01 a 0,059. Isso indica que as precipitações diárias estimadas através do modelo MODWT-ELMAN, simularam melhor os dados da ANA do que os do CMORPH, apresentando erros bem menores e Nash próximos a 1 (Tabela 5).

4.4 RESULTADOS DO MODELO MODWT-ANFIS

Na calibração da rede ANFIS, foram inicialmente realizados testes para definir os parâmetros mais favoráveis. Após as simulações em cada estação, com diferentes filtros e níveis adotados, foram obtidos os melhores parâmetros, em relação as entradas defasadas, quanto ao número de funções de pertinência (NMF), tipo da função de pertinência (MF) e número de épocas. O NMF de 2 para cada entrada e a MF do tipo sino (gbellmf) foram as que apresentaram menores erros para treinamento, teste, validação e o FIS da rede (0,01570, 0,01656, 0,01601, 0,01542), com entradas defasadas de 4 dias (Tabela 8). A função de saída selecionada foi a constante e o método de treinamento foi o híbrido. Assim, após o treinamento, a ferramenta computacional apresenta os parâmetros otimizados da rede ANFIS (Tabela 9).

Durante o treinamento da ANFIS, verificou-se que o aumento no número de funções de pertinência e na defasagem da entrada, acarretou em um aumento no tempo e esforço computacional e não resultou em ganho para a rede, pois os erros (MSE) não diminuíram. Portanto, neste caso, aumentar o número de entradas e NMF não é aconselhável para este tipo de estimativa da precipitação. Este fato pode estar relacionado com o grande empenho que a rede ANFIS precisa realizar com cada MF e em cada variável de entrada, exigindo maior esforço do processamento da ANFIS. Desta forma, as entradas com cinco dias de atraso, foram realizadas somente com 4 NMF para agilizar e tornar o treinamento mais eficiente. Em relação ao número de épocas, foram adotados valores de 2 a 100 épocas, contudo trinta épocas foi o valor que apresentou menores MSE, e acima deste valor os erros ficaram sem diminuição significativa, logo este foi escolhido (Tabela 8).

Tabela 6 - Parâmetros e Resultados do modelo MODWT-ANFIS, na calibração.

2 atrasos de Entrada						
NMF	MF	Épocas	Erro treino	Erro teste	Erro check	Erro FIS
2 2	trimp	30	0,01886	0,01962	0,02031	0,0189
3 3	gbellmf	30	0,01879	0,02161	0,02053	0,0189
4 4	gbellmf	30	0,01840	0,01957	0,01986	0,0181
5 5	gbellmf	30	0,01868	0,03141	0,02137	0,0187
6 6	gaussmf	30	0,01846	0,02705	0,02483	0,0184
7 7	trapmf	30	0,01848	0,02402	0,02112	0,0185
8 8	trapmf	30	0,01861	0,024151	0,020959	0,0186
3 atrasos de entrada						
2 2 2	gbellmf	30	0,01881	0,08131	0,08131	0,01881
3 3 3	trimp	30	0,01828	0,02051	0,02449	0,01828
4 4 4	gbellmf	30	0,01705	0,01961	0,02034	0,01720
5 5 5	gbellmf	30	0,01763	0,03991	0,11176	0,01763
6 6 6	gaussmf	30	0,01741	0,05599	0,19521	0,01741
7 7 7	gbellmf	30	0,01790	0,15160	0,25428	0,01790
4 atrasos de entrada						
2 2 2 2	gbellmf	30	0,01570	0,01656	0,01601	0,01542
3 3 3 3	gauss2mf	30	0,01780	0,02365	0,02612	0,01780
4 4 4 4	gaussmf	30	0,01733	0,43885	0,12759	0,01743
5 5 5 5	gaussmf	30	0,01648	0,12007	0,19133	0,01648
6 6 6 6	gaussmf	30	0,01847	0,18319	0,17287	0,01847
5 atrasos de entrada						
2 2 2 2 2	gaussmf	30	0,028261	0,098502	0,20054	0,028264
3 3 3 3 3	trimp	30	0,027264	0,036274	0,12092	0,027193
4 4 4 4 4	gaussmf	30	0,056044	0,22155	0,081788	0,056044

Tabela 7 - Parâmetros ANFIS após treinamento (calibração).

Tipo do parâmetro ANFIS	Valor
Funções de pertinência (MF)	gbellmf
Função de Saída (defuzificação)	Constante
Número de nós	55
Número de regras fuzzy	16
Número de parâmetros lineares	16
Número de parâmetros não lineares	24
Total de parâmetros	40
Número de pares de treinamento	1308-1736
Número de pares de validação	656 - 870

A partir da escolha dos vetores de entrada, dos parâmetros da ANFIS e as entradas defasadas de quatro dias de precipitação ($t-4$), cada estação foi avaliada quanto ao seu desempenho pelo modelo MODWT-ANFIS, considerando o tipo de filtro mais adequado. Assim, as entradas já filtradas foram treinadas e analisadas quanto ao MSE e NASH.

Nos resultados com o modelo MODWT-ANFIS, houve predominância do filtro db4-j6 no ajuste às estimativas, tanto para o PC como o MC. Logo, identifica-se que tal filtro prevaleceu satisfatório também para os dados da ANA e CMORPH (Tabela 5). Em relação às séries de dados da ANA, no PC, os valores de Nash obtidos foram aceitáveis, na faixa de 0,92 a 0,98 e erros (MSE) variando de 0,001 a 0,0054. Já no MC, os valores de Nash obtidos foram de 0,8 a 0,98 e erros entre 0,0012 a 0,004. Considerando as séries de precipitações do CMORPH, no PC, os valores de Nash alcançados foram de 0,7 a 0,98 e erros de 0,002 a 0,009. Já para o período MC, Nash foi de 0,96 a 0,98 e MSE entre 0,001 a 0,0039 (Tabela 5).

4.5 CONSIDERAÇÕES SOBRE OS FILTROS WAVELET

A wavelet Daubechies (db4) foi capaz de decompor o elemento de sazonalidade da série temporal de forma mais eficiente, seus resultados para os níveis 6 e 8 e comprimento (L) 4, apresentaram pequenos erros e valores de Nash próximos ao ideal. Segundo Maheswaran e Khosa (2012), seu bom desempenho, deve-se ao seu suporte mais amplo em séries temporais sazonais, pela capacidade de suavizar o sinal e boa localização de tempo e frequência, que são necessários a série de precipitação, que apresenta intercorrência temporal. A wavelet menos assimétrica (la14) e a coiflet (c6), combinada com a RNA também apresentaram bons resultados, com pequenos erros e Nash elevados. Porém seu desempenho em relação à db4 não foi muito diferente. Isso mostra que o aumento do comprimento (L) do filtro (6 e 14), para este caso, não trouxe melhoras significativas, e que o filtro db4 com comprimento (L) de 4 já seria suficiente para uma boa decomposição do sinal.

A escolha do melhor filtro, segundo Zang et al. (2016), deve ser aquele com decomposição mais semelhante as características da série estudada. Contudo, quando se escolhe um filtro, outros parâmetros estão associados a

ele. Assim, pelos testes realizados aqui, o fator que mais influenciou nas simulações foi o nível de decomposição e o comprimento da wavelet, pois o ajuste do melhor modelo, com nível 8 e comprimento 4, conferiram um ajuste moderado e admissível à decomposição dos dados de precipitação.

O uso de um comprimento maior de wavelet (6 e 14) não apresentou maior qualidade às estimativas, e poderia ainda, retirar um número bem maior de coeficientes wavelet ajustados pelas CC, comprometendo a quantidade de dados de entrada na simulação do modelo com RNA.

Para evitar erros e contornar a CC, é necessário escolher wavelet adequados e dados de entrada suficientes para treinamento e estimativa (Ramírez-Hernández et al., 2016; Du et al., 2017; e Quilty e Adamowski, 2018). Assim, na seleção da série de precipitação, esta questão foi adotada testando três filtros wavelet e três níveis de decomposição, retirando os valores que interferem nos coeficientes afetados pelo limite de j , e também pela divisão ajustada do número de dados usados na calibração e validação. Dos 3444 dias do período chuvoso, 766 foram retirados, restando 2678, os quais foram divididos em 2009 para a calibração e 669 para a validação. No período menos chuvoso foram 3496 dias (menos 766), divididos em 2048 (calibração) e 682 (validação). Com isso foi possível filtrar a série de dados, deixando-as livres de incertezas relacionados a CC e ainda ajustar números adequados de dados de entrada para treinamento e validação das redes neurais.

4.6 VALIDAÇÃO DOS MODELOS MODWT-RNA

Na validação dos modelos, foram realizados testes com 25% da série histórica, os quais não foram adotados na calibração, correspondendo ao período sazonal (PC e MC) de 2012 a 2016. Pelos resultados obtidos, o modelo MODWT-ANFIS foi o melhor na simulação da chuva diária para todas as estações e em todos os períodos estudados (PC e MC). Conforme pode ser observado na Figura 23 e Tabelas 10 e 11, há evidências de que o modelo MODWT-ANFIS apresentou melhor desempenho, especialmente para o PC, pois o coeficiente de correlação (r), o valor de Nash, a média diária de precipitação (μ) e o desvio padrão (dp) entre os valores observados e simulados foram mais ajustados para este modelo, com Nash acima de 0,72

(Tabela 10). Os dados da ANA e do CMORPH analisados mostraram-se satisfatórios, contudo as precipitações dos dados de satélite apresentam valores menores que os observados de forma pontual (ANA), ver Tabelas 10 e 11; e Apêndice A, o qual são adotados os dados de chuvas despadronezados.

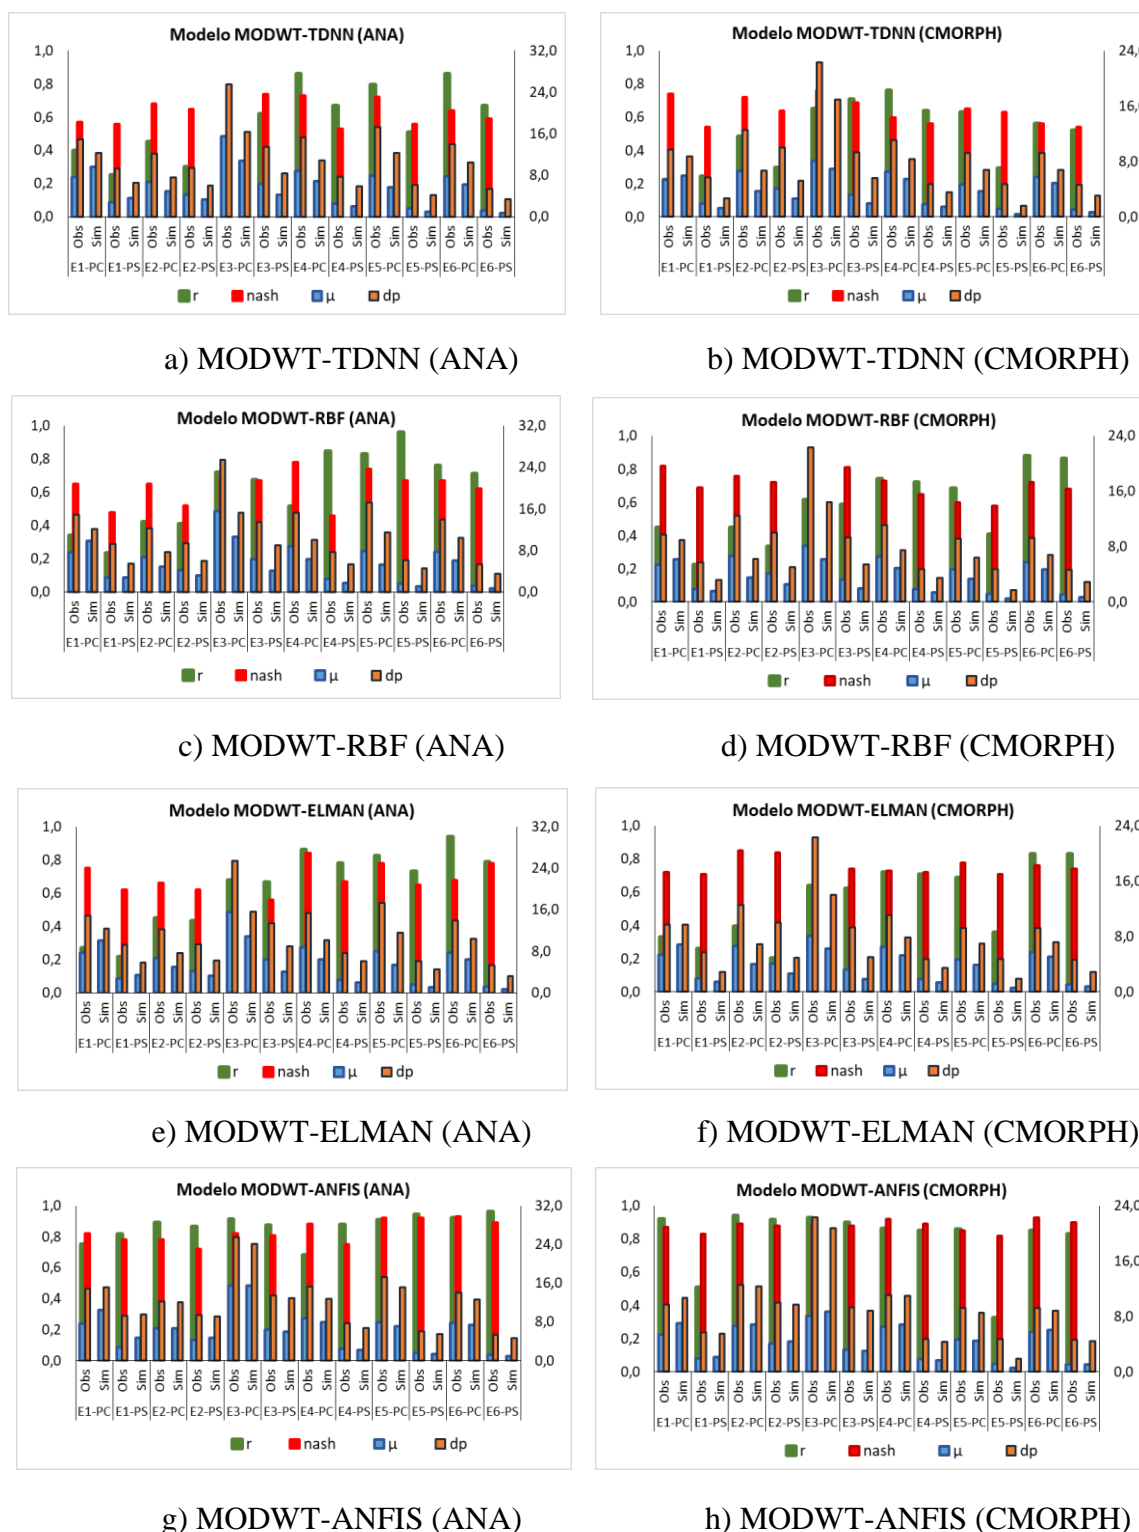


Figura 23 - Desempenho dos Modelos MODWT-RNA.

A melhor eficácia do modelo ANFIS pode ser explicado pela sua capacidade de incorporar as regras fuzzy para auxiliar nas previsões, sendo sensível a conjuntos de dados de aprendizagem, podendo aprender muito mais durante o período de treinamento e melhorar as previsões na fase de teste (Seera et al., 2012, Roy e Singh, 2020). Choubin et al. 2016, Ali et al. 2018 e Ebrahimi-Khusfi et al. 2021, por exemplo, verificaram que o modelo ANFIS combinado a outras técnicas pode reduzir incertezas e aumentar a precisão na estimativa de precipitação.

Os modelos de RNA possuem particularidades, que influenciam na modelagem, refletindo em suas estimativas. A rede TDNN, por exemplo, necessitou de mais neurônio na camada oculta e dois dias de atraso para prever bem os dados. Por outro lado, seu tempo de processamento é bem mais rápido que a rede RBF, ELMAN e ANFIS, as quais demandam mais tempo de processamento, devido ao número de parâmetros a serem determinados.

Já nos estudos de Zang et al (1998), que realizaram profundo estudo em redes neurais, foi identificado que a seleção dos parâmetros adotados para uma RNA, depende do problema em si envolvido, da série de dados e do tipo de rede empregada. Apesar de existirem alguns métodos para definir certos parâmetros como o número de neurônios da camada oculta e a taxa de aprendizagem em alguns modelos de RNA (TONGYU et al 2012; LIU et al 2019), não há um método definido a ser usado no treinamento de redes neurais, principalmente em estimativas de dados hidrológicos. Portanto, o método de escolha dos parâmetros usados na RNA, adotados neste trabalho através de iterações sucessivas, conforme sugerido também por Bergstra e Bengio 2012 e Mao et al. 2021, é válido na aplicação do modelo híbrido MODWT-RNA.

Todos os parâmetros utilizados neste estudo, foram selecionados com base no melhor resultado em termos do MSE, Nash e coeficiente de correlação entre os dados observados e simulados, os quais estão resumidos no Apêndice B.

De acordo com a estimativa dos modelos na validação, é possível verificar que eles são capazes de simular, satisfatoriamente, as precipitações das estações E1, E2, E3 e E4 (Figura 4), com alto índice pluviométrico, localizada no bioma amazônico; e as precipitações das estações E5 e E6

(Figura 4), com baixo índice pluviométrico, localizadas em região de transição e no cerrado. Ou seja, o modelo não teve problemas em reproduzir as precipitações decorrentes da variabilidade climática da Amazônia. Entretanto, outros modelos mostraram problemas para essa reprodução (Wilks, 1999; Detzel e Mine, 2011; Liu et al., 2011; Ng et al., 2017).

A entrada de dados do modelo MODWT-ANFIS com pequenos atrasos de tempo mostrou-se eficaz, pois o desempenho obtido pelo Nash foi superior a 0,72 na estimativa da precipitação diária. Esse pequeno número de entradas pode ser considerado uma grande vantagem do modelo aqui proposto, pois permite contornar o problema de períodos menos chuvosos, observados por Suhaila et al. 2011 e Costa et al. 2015, que exigem mais informações de dias anteriores para prever os dias futuros. Além disso, segundo Nerantzaki and Papalexiou (2019), a previsibilidade de eventos de precipitação, ainda é um desafio na literatura e necessitam de métodos específicos para sua modelagem.

Em relação às estimativas de precipitação diária, em geral, o período chuvoso foi melhor estimado pelo modelo híbrido (Tabelas 10 e 11). Esse resultado pode estar relacionado ao maior número de dados com valor zero no período de estiagem. Esses dados indicam informações escassas nas amostras, o que pode fazer com que sejam insuficientes para o aprendizado da rede neural e, conseqüentemente, insuficientes para simular dados futuros. Essa questão também pode estar relacionada à variação interanual da precipitação, pois as sequências de dias sem chuva requerem muito mais informações dos dias anteriores do que as sequências de dias chuvosos (Wilks, 1999). Além disso, Hellassa e Souag-Gamane (2019) demonstraram que a remoção de ruído na série de precipitação por meio da decomposição de wavelet induz uma melhora significativa nas estimativas diárias de chuva e, dependendo da função wavelet adotada, períodos chuvosos podem ter uma resposta melhor do que períodos sem chuva. Assim, enquanto o método wavelet decompõe o sinal e incorpora as características sazonais da série pluviométrica, longos períodos de dias sem chuva precisam de mais atenção na modelagem diária. Apesar disso, e considerando os resultados, os modelos híbridos desenvolvidos estimaram bem a precipitação diária nos locais avaliados, mas em alguns dias a precipitação foi subestimada pelo modelo,

conforme evidenciado nos gráficos de comparação entre os valores de precipitação observados e estimados (APÊNDICE A) para os dados da ANA e do CMORPH (dados já despadronizados).

A variabilidade da precipitação na região amazônica é bastante dinâmica e, de acordo com Wang et al. (2018), que avaliaram o comportamento da precipitação na América do Sul no período chuvoso (de dezembro a maio), a precipitação total pode variar muito. Reichle et al. (2017) indicaram que o viés de precipitação é forte em muitas áreas tropicais e subtropicais, especialmente na América do Sul, durante dezembro, janeiro e fevereiro (DJF). Além disso, nos estudos de Gloor et al. (2013), Espinoza et al. (2016) e Latrubesse et al. (2017), há tendências crescentes para a ocorrência de estiagens sazonais extremas e inundações nesta região. Portanto, o trabalho atual, pode auxiliar nas estimativas futuras de estiagens prolongadas e chuvas intensas. Essas estimativas são importantes para atividades como agronegócio, abastecimento, geração de energia, etc.

Tabela 8 - Desempenho dos Modelos Híbridos MODWT-RNA na validação para os dados de precipitação da ANA.

		MODWT-TDNN					MODWT-RBF					MODWT-ELMAN					MODWT-ANFIS				
	Período	μ	dp	r	mse	nash	μ	dp	r	mse	nash	μ	dp	r	mse	nash	μ	dp	r	mse	nash
E1-Chuvoso	Obs	7,7	14,9	0,40	0,0001	0,57	7,7	14,9	0,34	0,0001	0,65	7,7	14,9	0,27	0,00009	0,75	7,7	14,9	0,75	0,00014	0,82
	Sim	9,6	12,3				9,9	12,1				10,1	12,4				10,5	15,2			
E1-Menos chuvoso	Obs	2,8	9,3	0,25	0,0001	0,56	2,8	9,3	0,24	0,0002	0,48	2,8	9,3		0,00015	0,62	2,8	9,3	0,82	0,00024	0,78
	Sim	3,6	6,5				2,7	5,5				3,4	5,9	0,22			4,7	9,6			
E2-Chuvoso	Obs	6,7	12,2	0,45	0,0001	0,68	6,7	12,2	0,42	0,0001	0,65	6,7	12,2	0,45	0,00012	0,66	6,7	12,2	0,89	0,00027	0,78
	Sim	5,0	7,6				4,9	7,7				5,0	7,7				6,7	12,1			
E2-Menos chuvoso	Obs	4,3	9,4	0,30	0,0002	0,65	4,3	9,4	0,41	0,0002	0,52	4,3	9,4	0,43	0,00017	0,62	4,3	9,4	0,87	0,00030	0,72
	Sim	3,3	6,0				3,3	6,0				3,3	6,3				4,7	9,2			
E3-Chuvoso	Obs	15,6	25,5				15,6	25,5				15,6	25,5				15,6	25,5			
	Sim	10,8	16,4	0,46	0,0001	0,77	10,6	15,2	0,72	0,0001	0,69	10,9	15,6	0,68	0,00006	0,64	15,5	24,1	0,91	0,00014	0,82
E3-Menos chuvoso	Obs	6,4	13,4				6,4	13,4				6,4	13,4				6,4	13,4			
	Sim	4,3	8,4	0,62	0,0001	0,74	4,1	9,1	0,68	0,0001	0,67	4,0	8,9	0,67	0,00014	0,56	6,0	12,9	0,87	0,00022	0,81
E4-Chuvoso	Obs	8,8	15,3				8,8	15,3				8,8	15,3				8,8	15,3			
	Sim	6,8	10,9	0,86	0,0001	0,73	6,3	10,1	0,51	0,0001	0,78	6,5	10,1	0,86	0,00011	0,84	7,9	12,7	0,68	0,00013	0,88
E4-Menos chuvoso	Obs	2,6	7,7				2,6	7,7				2,6	7,7				2,6	7,7			
	Sim	2,0	5,9	0,67	0,0004	0,53	1,8	5,4	0,85	0,0003	0,46	2,0	6,1	0,78	0,00042	0,67	2,3	6,8	0,88	0,00041	0,75
E5-Chuvoso	Obs	7,9	17,3				7,9	17,3				7,9	17,3				7,9	17,3			
	Sim	5,7	12,3	0,80	0,0001	0,72	5,3	11,4	0,83	0,0001	0,74	5,4	11,5	0,83	0,00014	0,78	7,0	15,2	0,91	0,00021	0,92
E5-Menos chuvoso	Obs	1,6	6,1				1,6	6,1				1,6	6,1				1,6	6,1			
	Sim	1,0	4,2	0,51	0,0005	0,56	1,1	4,5	0,96	0,0006	0,67	1,0	4,5	0,73	0,00054	0,65	1,4	5,5	0,95	0,00072	0,92
E6-Chuvoso	Obs	7,8	14,0				7,8	14,0				7,8	14,0				7,8	14,0			
	Sim	6,2	10,5	0,86	0,0001	0,64	6,1	10,5	0,76	0,0001	0,67	6,4	10,4	0,94	0,00012	0,68	7,4	12,6	0,92	0,00011	0,93
E6-Menos chuvoso	Obs	1,2	5,3				1,2	5,3				1,2	5,3				1,2	5,3			
	Sim	0,7	3,5	0,67	0,0006	0,59	0,8	3,6	0,71	0,0006	0,62	0,7	3,2	0,79	0,00056	0,78	1,0	4,7	0,96	0,00012	0,89
Média				0,57	0,00021	0,65			0,62	0,00023	0,63			0,64	0,00022	0,69			0,87	0,00025	0,84

Tabela 9 - Desempenho dos Modelos Híbridos MODWT-RNA na validação para os dados de precipitação da CMORPH.

Estação	Período	MODWT-TDNN					MODWT-RBF					MODWT-ELMAN					MODWT-ANFIS				
		μ	dp	r	mse	nash	μ	dp	r	mse	nash	μ	dp	r	mse	nash	μ	dp	r	mse	nash
E1-Chuvoso	Obs	5,4	9,7	0,22	0,0001	0,74	5,4	9,7	0,45	0,00041	0,82	5,4	9,7	0,33	0,00012	0,72	5,4	9,7	0,92	0,0001	0,87
	Sim	5,9	8,7				6,2	9,0				6,8	9,7				7,0	10,7			
E1-Menos chuvoso	Obs	1,9	5,7	0,24	0,0003	0,54	1,9	5,7	0,23	0,00026	0,69	1,9	5,7	0,26	0,00026	0,71	1,9	5,7	0,51	0,0006	0,83
	Sim	1,3	2,7				1,6	3,1				1,4	2,9				2,2	5,5			
E2-Chuvoso	Obs	6,6	12,5				6,6	12,5				6,6	12,5				6,6	12,5			
	Sim	3,7	6,7	0,49	0,0001	0,72	3,6	6,2	0,45	0,00013	0,76	4,0	6,8	0,40	0,00013	0,85	6,9	12,3	0,94	0,0004	0,89
E2-Menos chuvoso	Obs	4,1	10,0				4,1	10,0				4,1	10,0				4,1	10,0			
	Sim	2,7	5,2	0,30	0,0001	0,64	2,6	5,0	0,33	0,00015	0,72	2,6	5,0	0,20	0,00014	0,84	4,4	9,7	0,92	0,0004	0,88
E3-Chuvoso	Obs	8,1	22,3				8,1	22,3				8,1	22,3				8,1	22,3			
	Sim	6,9	16,9	0,65	0,0001	0,76	6,2	14,4	0,61	0,00009	0,88	6,3	14,0	0,64	0,00008	0,79	8,7	20,8	0,93	0,0001	0,89
E3-Menos chuvoso	Obs	3,2	9,3				3,2	9,3				3,2	9,3				3,2	9,3			
	Sim	2,0	5,6	0,71	0,0002	0,69	2,0	5,4	0,59	0,00020	0,81	1,8	5,0	0,62	0,00020	0,74	3,0	8,9	0,90	0,0004	0,88
E4-Chuvoso	Obs	6,6	11,1				6,6	11,1				6,6	11,1				6,6	11,1			
	Sim	5,5	8,3	0,76	0,0001	0,6	4,9	7,4	0,74	0,00015	0,73	5,3	7,8	0,72	0,00016	0,73	6,9	11,0	0,87	0,0003	0,92
E4-Menos chuvoso	Obs	1,8	4,7				1,8	4,7				1,8	4,7				1,8	4,7			
	Sim	1,4	3,6	0,64	0,0005	0,56	1,3	3,4	0,72	0,00056	0,65	1,3	3,5	0,71	0,00064	0,72	1,7	4,3	0,85	0,0009	0,89
E5-Chuvoso	Obs	4,7	9,2				4,7	9,2				4,7	9,2				4,7	9,2			
	Sim	3,7	6,7	0,63	0,0002	0,65	3,4	6,4	0,68	0,00022	0,6	3,9	7,0	0,69	0,00022	0,78	4,5	8,6	0,86	0,0003	0,85
E5-Menos chuvoso	Obs	1,1	4,8				1,1	4,8				1,1	4,8				1,1	4,8			
	Sim	0,4	1,6	0,29	0,0003	0,63	0,5	1,8	0,41	0,00034	0,58	0,5	1,9	0,36	0,00033	0,71	0,5	1,9	0,32	0,0003	0,82
E6-Chuvoso	Obs	5,8	9,3				5,8	9,3				5,8	9,3				5,8	9,3			
	Sim	4,9	6,8	0,56	0,0002	0,56	4,7	6,8	0,88	0,00019	0,72	5,1	7,2	0,83	0,00018	0,76	6,0	8,8	0,85	0,0002	0,93
E6-Menos chuvoso	Obs	1,1	4,7				1,1	4,7				1,1	4,7				1,1	4,7			
	Sim	0,7	3,0	0,52	0,0005	0,54	0,7	2,9	0,86	0,00056	0,68	0,7	2,9	0,83	0,00054	0,74	1,0	4,4	0,83	0,0001	0,90
Média				0,50	0,00024	0,64			0,58	0,00027	0,72			0,55	0,00025	0,76			0,81	0,00036	0,88

5 CONCLUSÃO

Os modelos híbridos combinando MODWT e RNA mostraram-se satisfatórios para estimativas de precipitação diária nas estações avaliadas da região Amazônica. Contudo, é necessário destacar que para o uso de tais modelos, medidas devem ser adotadas, como verificação das condições de contorno na utilização da MODWT, que se não forem adotadas podem gerar estimativas incorretas. Além disso, é importante a verificação dos parâmetros mais adequados para cada RNA.

O modelo MODWT-TDNN exigiu mais neurônios na camada oculta, menos tempo de defasagem e seu tempo de processamento foi maior. Além disso, a taxa de aprendizagem deve ser extensivamente testada, por não haver um valor adequado definido. Contudo, este modelo pode ser eficiente nas estimativas de precipitações diárias para defasagens curtas de até dois dias de atraso. Já no modelo MODWT-RBF pode ser empregada a defasagem curta de até 5 dias de atraso, uma constante de propagação de 0,2 e o número de neurônios na camada oculta igual ao número de entradas. Tais parâmetros são os mais significativos a serem estabelecidos na rede RBF.

O modelo MODWT-ELMAN gera melhores resultados com no máximo 10 neurônios na camada oculta. Entradas atrasadas de até cinco dias, de precipitação diária, podem ser bem estimadas por este modelo. Contudo, o aumento de neurônios na camada de entrada aumenta o tempo de processamento da rede. O aumento do número de funções de pertinência e maiores entradas defasadas, não são aconselháveis na estimativa de chuvas diárias, para o modelo MODWT-ANFIS, devido ao aumento do esforço e processamento da rede, as quais não geraram benefícios aos resultados. A função de pertinência indicada para o uso deste modelo é a do tipo sino (gbellmf) que pode ser empregada na estimativa de precipitação diária com eficácia.

Dentre os modelos de Redes Neurais adotados, a rede neural ANFIS foi a mais eficiente considerando o uso combinado com a MODWT, nas estimativas de precipitação diária. Suas vantagens estão relacionadas com a possibilidade de adotar apenas quatro dias de atraso, a sensibilidade à aprendizagem da série de dados e incorporação das regras fuzzy para auxiliar

nas estimativas. O pequeno número de entradas de dados do modelo com pequenos atrasos de tempo mostrou-se eficaz, sendo considerada uma grande vantagem do modelo, pois permite contornar o problema de períodos menos chuvosos, que exigem mais informações de dias anteriores para simular os dias futuros. O pré-processamento de dados realizados pelo MODWT foi essencial para retirar ruídos da série histórica original e corrigir as condições de contorno, que podem prejudicar as simulações do modelo. Essa etapa no desenvolvimento dos modelos, juntamente com as entradas defasadas no tempo, configuram uma das grandes vantagens dos modelos híbridos, como o modelo analisado.

Para a aplicação dos modelos híbridos, MODWT-RNA, podem ser adotados dados de precipitação advindos de estações pluviométricas e de satélites, como as do CMORPH, pois ambos foram bem simuladas para as chuvas diárias. Isso representa uma vantagem na aplicação do modelo, pois grande parte da região amazônica não é completamente monitorada com estações pluviométricas convencionais.

Os resultados gerados podem auxiliar futuros trabalhos para o melhor entendimento da modelagem da precipitação diária e de seu comportamento na região amazônica, que vem sofrendo com queimadas e desmatamentos, impactando o ciclo hidrológico da região e afetando diversas atividades, como por exemplo, abastecimento humano, saneamento, agronegócio, produção hidrelétrica e transporte hidroviário. Esse cenário de aumento do desmatamento da floresta amazônica afeta outras regiões do país (centro-oeste, sudeste e sul), que dependem da evapotranspiração advinda da Amazônia para a produção de chuva, que é importante, também, para os usos de água citados anteriormente.

6 SUGESTÕES PARA TRABALHOS FUTUROS

Os bons resultados desta abordagem híbrida estimulam o desenvolvimento de novas pesquisas sobre o assunto. Por exemplo, uma maneira de melhorar os resultados alcançados é testar outros tipos de modelos de Inteligência artificial, além de incorporar séries com maior registro de dados, além dos 19 anos analisados. Além disso, outras variáveis como temperatura e umidade podem ser introduzidas no modelo desenvolvido. Essas variáveis também influenciam a produção de chuvas e não foram analisadas no presente estudo.

A estimativa de chuvas nos períodos mais críticos de estiagens ou cheias pode ainda ser avaliada conjuntamente com os fenômenos climáticos El Niño e La Niña, por exemplo, os quais influenciam na ocorrência de chuva na região. Essas análises podem ser interessantes, principalmente, em escalas sazonais ou anuais.

Sugere-se, ainda, aplicar os modelos híbridos em sub-bacias da Amazônia, principalmente, nos locais sem monitoramento convencional, para aprimoramento e validação dos modelos híbridos nas pequenas bacias, onde há maior escassez de medição de precipitação.

REFERÊNCIAS

ADDISON, Paul S.; MURRAY, Kevin B.; WATSON, James N. Wavelet transform analysis of open channel wake flows. *Journal of engineering mechanics*, v. 127, n. 1, p. 58-70, 2001.

ALI, Mumtaz et al. An ensemble-ANFIS based uncertainty assessment model for forecasting multi-scalar standardized precipitation index. *Atmospheric Research*, v. 207, p. 155-180, 2018.

ALTUNKAYNAK, Abdusselam; NIGUSSIE, Tewodros Assefa. Prediction of daily rainfall by a hybrid wavelet-season-neuro technique. **Journal of Hydrology**, v. 529, p. 287-301, 2015.

ANA - Agência Nacional de Águas (Brasil). Conjuntura dos recursos hídricos no Brasil 2018: informe anual / Agência Nacional de Águas. -- Brasília: ANA, 2018. Disponível em: <http://conjuntura.ana.gov.br/>. Acessado em junho de 2018.

AYRES, M. Elementos de Bioestatística. Universidade Federal do Pará. 2ª edição. Belém, 2012.

BAŠTA, Milan et al. Additive decomposition and boundary conditions in wavelet-based forecasting approaches. **Acta Oeconomica Pragensia**, v. 22, n. 2, p. 48-70, 2014.

Braga, A. P.; Carvalho, A. P. L. F.; Ludermir, T. B., 2011. Redes neurais artificiais: teoria e aplicações. 2. ed. Rio de Janeiro: LTC, 226p.

BENNETT, Bree et al. A comprehensive and systematic evaluation framework for a parsimonious daily rainfall field model. **Journal of hydrology**, v. 556, p. 1123-1138, 2018.

BERGSTRA, James; BENGIO, Yoshua. Random search for hyper-parameter optimization. **Journal of machine learning research**, v. 13, n. 2, 2012.

BOLZAN, Maurício José Alves. Análise da transformada em ondeletas aplicada em sinal geofísico. **Revista Brasileira de Ensino de Física**, v. 26, p. 37-41, 2004.

CALDEIRA, A.M.; MACHADO, M.A.S.; SOUZA, R.C.; TANSCHKEIT, R. OLIVEIRA JUNIOR, A.H (Coord.). **Inteligência computacional aplicada à administração, economia e engenharia em Matlab**. São Paulo: Tomson Learning, 2007.

CANNAS, Barbara et al. Data preprocessing for river flow forecasting using neural networks: wavelet transforms and data partitioning. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 31, n. 18, p. 1164-1171, 2006.

CIEMER, Catrin et al. Temporal evolution of the spatial covariability of rainfall in South America. **Climate dynamics**, v. 51, n. 1, p. 371-382, 2018.

CHAI, Tianfeng; DRAXLER, Roland R. Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. **Geoscientific model development**, v. 7, n. 3, p. 1247-1250, 2014.

CHAU, Kwok Wing; WU, C. L. A hybrid model coupled with singular spectrum analysis for daily rainfall prediction. **Journal of Hydroinformatics**, v. 12, n. 4, p. 458-473, 2010.

CLARKE, Robin T.; BUARQUE, Diogo C. Statistically combining rainfall characteristics estimated from remote-sensed and rain gauge data sets in the Brazilian Amazon-Tocantins Basins. **Journal of Geophysical Research: Atmospheres**, v. 118, n. 14, p. 7467-7480, 2013.

CHOUBIN, Bahram et al. Multiple linear regression, multi-layer perceptron network and adaptive neuro-fuzzy inference system for forecasting precipitation based on large-scale climate signals. **Hydrological sciences journal**, v. 61, n. 6, p. 1001-1009, 2016.

COLLISCHONN, Walter; DORNELLES, Fernando. Hidrologia para engenharia e ciências ambientais. **Porto Alegre: Associação Brasileira de Recursos Hídricos**, v. 1, p. 336, 2013.

COSTA, Veber; FERNANDES, Wilson; NAGHETTINI, Mauro. A Bayesian model for stochastic generation of daily precipitation using an upper-bounded distribution function. **Stochastic environmental research and risk assessment**, v. 29, n. 2, p. 563-576, 2015.

CUO, Lan; PAGANO, Thomas C.; WANG, Q. J. A review of quantitative precipitation forecasts and their use in short-to medium-range streamflow forecasting. **Journal of hydrometeorology**, v. 12, n. 5, p. 713-728, 2011.

DALIAKOPOULOS, Ioannis N.; COULIBALY, Paulin; TSANIS, Ioannis K. Groundwater level forecasting using artificial neural networks. **Journal of hydrology**, v. 309, n. 1-4, p. 229-240, 2005.

DA SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes neurais artificiais para engenharia e ciências aplicadas-curso prático. **São Paulo: Artliber**, 2010.

DAUBECHIES, Ingrid. **Ten lectures on wavelets**. Society for industrial and applied mathematics, 1992.

DAVIDSON, Eric A. et al. The Amazon basin in transition. **Nature**, v. 481, n. 7381, p. 321-328, 2012.

DAVOLIO, S. et al. A meteo-hydrological prediction system based on a multi-model approach for precipitation forecasting. **Natural hazards and earth system sciences**, v. 8, n. 1, p. 143-159, 2008.

DETZEL, D. H. M.; MINE, M. R. M. Generation of daily synthetic precipitation series: analyses and application in La Plata river Basin. **The Open Hydrology Journal**, v. 5, n. 1, 2011.

DEVIA, Gayathri K.; GANASRI, B. Pa; DWARAKISH, G. Sa. A review on hydrological models. **Aquatic procedia**, v. 4, p. 1001-1007, 2015.

DU, Kongchang; ZHAO, Ying; LEI, Jiaqiang. The incorrect usage of singular spectral analysis and discrete wavelet transform in hybrid models to predict hydrological time series. **Journal of Hydrology**, v. 552, p. 44-51, 2017

DUONG, T. A.; BUI, M. D.; RUTSCHMANN, P. Long Short Term Memory for monthly rainfall prediction in Camau. 2018.

EBRAHIMI-KHUSFI, Zohre; TAGHIZADEH-MEHRJARDI, Ruhollah; NAFARZADEGAN, Ali Reza. Accuracy, uncertainty, and interpretability assessments of ANFIS models to predict dust concentration in semi-arid regions. *Environmental Science and Pollution Research*, v. 28, n. 6, p. 6796-6810, 2021. <https://doi.org/10.1007/s11356-020-10957-z>

EINFALT, Thomas; MICHAELIDES, Silas. Quality control of precipitation data. In: **Precipitation: Advances in measurement, estimation and prediction**. Springer, Berlin, Heidelberg, 2008. p. 101-126.

ELMAN, Jeffrey L. Distributed representations, simple recurrent networks, and grammatical structure. **Machine learning**, v. 7, n. 2, p. 195-225, 1991.

FAHIMI, Farzad; YASEEN, Zaher Mundher; EL-SHAFIE, Ahmed. Application of soft computing based hybrid models in hydrological variables modeling: a comprehensive review. **Theoretical and applied climatology**, v. 128, n. 3-4, p. 875-903, 2017.

FALCK, Aline S. et al. Propagation of satellite precipitation uncertainties through a distributed hydrologic model: A case study in the Tocantins–Araguaia basin in Brazil. **Journal of Hydrology**, v. 527, p. 943-957, 2015.

FAUSETT, Laurene V. **Fundamentals of neural networks: architectures, algorithms and applications**. Pearson Education India, 2006.

GEORGAKAKOS, Konstantine P.; KRZYSZTOFOWICZ, Roman. Probabilistic and ensemble forecasting. 2001.

GEORGE, Jany; LETHA, J.; JAIRAJ, P. G. Daily rainfall prediction using generalized linear bivariate model—A case study. **Procedia Technology**, v. 24, p. 31-38, 2016.

GERMANO, Michell Fontenelle et al. Analysis of the breeze circulations in Eastern Amazon: an observational study. **Atmospheric Science Letters**, v. 18, n. 2, p. 67-75, 2017.

GOLDING, B. W. (2014). "Regional Prediction Models". Em: North, G. R.; Pyle, J. A.; Zhang, F. (2014). "Encyclopedia of Atmospheric Sciences". Academic Press, 2nd Edition, 2008.

GOMES, Evanice Pinheiro; BLANCO, Claudio José Cavalcante; PESSOA, Francisco Carlos Lira. Regionalization of precipitation with determination of homogeneous regions via fuzzy c-means. **RBRH**, v. 23, 2018.

GOMES, Evanice Pinheiro; BLANCO, Claudio José Cavalcante. Daily rainfall estimates considering seasonality from a MODWT-ANN hybrid model. **Journal of Hydrology and Hydromechanics**, v. 69, n. 1, p. 13-28, 2021.

GONÇALVES, Mariane Furtado et al. Homogenous regions and rainfall probability models considering El Niño and La Niña in the State of Pará in the Amazon. **Acta Scientiarum. Technology**, v. 40, 2018.

GUIMARÃES SANTOS, C. A.; SILVA, G. B. L. da. Daily streamflow forecasting using a wavelet transform and artificial neural network hybrid models. **Hydrological Sciences Journal**, v. 59, n. 2, p. 312-324, 2014.

GUMINDOGA, Webster et al. Performance of bias-correction schemes for CMORPH rainfall estimates in the Zambezi River basin. **Hydrology and earth system sciences**, v. 23, n. 7, p. 2915-2938, 2019.

HAMMAD, Muhammad et al. Rainfall forecasting in upper Indus basin using various artificial intelligence techniques. **Stochastic Environmental Research and Risk Assessment**, p. 1-23, 2021.

HAYKIN, Simon. **Neural networks and learning machines**, 3/E. Pearson Education India, 2010.

HE, Xinguang; GUAN, Huade; QIN, Jianxin. A hybrid wavelet neural network model with mutual information and particle swarm optimization for forecasting monthly rainfall. **Journal of Hydrology**, v. 527, p. 88-100, 2015.

HELLASSA, Sarah; SOUAG-GAMANE, Doudja. Improving a stochastic multi-site generation model of daily rainfall using discrete wavelet de-noising: a case study to a semi-arid region. **Arabian Journal of Geosciences**, v. 12, n. 2, p. 53, 2019.

HOLDEFER, Antonio Eliseu; SEVERO, Dirceu Luis. Análise por ondaletas sobre níveis de rios submetidos à influência de maré. **Revista Brasileira de Recursos Hídricos**, v. 20, n. 1, p. 192-201, 2015.

HONG, Yang et al. Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system. **Journal of Applied Meteorology**, v. 43, n. 12, p. 1834-1853, 2004.

HONORATO, André Gustavo da Silva Melo; SILVA, Gustavo Barbosa Lima da; GUIMARAES SANTOS, Celso Augusto. Monthly streamflow forecasting using neuro-wavelet techniques and input analysis. **Hydrological Sciences Journal**, v. 63, n. 15-16, p. 2060-2075, 2018.

HU, Caihong et al. Deep learning with a long short-term memory networks approach for rainfall-runoff simulation. **Water**, v. 10, n. 11, p. 1543, 2018.

HUFFMAN, George J. et al. The TRMM multi-satellite precipitation analysis (TMPA). In: **Satellite rainfall applications for surface hydrology**. Springer, Dordrecht, 2010. p. 3-22.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Cobertura do uso da terra do Brasil (Land use coverage in Brazil). Rio de Janeiro: IBGE, 2014. Available from: <https://www.ibge.gov.br/geocienciasnovoportal/informacoes-ambientais/cobertura-e-uso-da-terra> (accessed in 13 Sept. 2017).

ISLAM, M. N.; SIVAKUMAR, B. Characterization and prediction of runoff dynamics: a nonlinear dynamical view. **Advances in water resources**, v. 25, n. 2, p. 179-190, 2002.

JANG, J.-SR. ANFIS: adaptive-network-based fuzzy inference system. **IEEE transactions on systems, man, and cybernetics**, v. 23, n. 3, p. 665-685, 1993.

JANG, Jyh-Shing Roger; SUN, Chuen-Tsai; MIZUTANI, Eiji. Neuro-fuzzy and soft computing-a computational approach to learning and machine intelligence [Book Review]. **IEEE Transactions on automatic control**, v. 42, n. 10, p. 1482-1484, 1997.

JANOWIAK, John E.; JOYCE, Robert J.; YAROSH, Yelena. A real-time global half-hourly pixel-resolution infrared dataset and its applications. **Bulletin of the American Meteorological Society**, v. 82, n. 2, p. 205-218, 2001.

JAWERTH, Björn; SWELDENS, Wim. An overview of wavelet based multiresolution analyses. **SIAM review**, v. 36, n. 3, p. 377-412, 1994.

JIMÉNEZ, Karena Quiroz; COLLISCHONN, Walter. Método de combinação de dados de precipitação estimados por satélite e medidos em pluviômetros para a modelagem hidrológica. **Revista Brasileira de Recursos Hídricos**, v. 20, n. 1, p. 202-217, 2015.

JIMÉNEZ, Karena Quiroz; DE MELO, Tirzah Moreira; LOUZADA, José Antônio. Uso de dados de precipitação obtidos por sensoriamento remoto em um modelo agro-hidrológico. **Irriga**, v. 18, n. 3, p. 496-508, 2013.

JOYCE, Robert J. et al. CMORPH: A “morphing” approach for high resolution precipitation product generation. In: **Satellite rainfall applications for surface hydrology**. Springer, Dordrecht, 2010. p. 23-37.

KASABOV, N. K.; SONG, Q. Denfis: Dynamic evolving neural-fuzzy inference system and its application for time-series prediction. *IEEE Transactions on Fuzzy Systems*, v. 10, n. 2, p. 144–154, 2002.

KIDD, Chris. Satellite rainfall climatology: A review. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 21, n. 9, p. 1041-1066, 2001.

KIM, Sungwon et al. Bayesian model averaging: A unique model enhancing forecasting accuracy for daily streamflow based on different antecedent time series. **Sustainability**, v. 12, n. 22, p. 9720, 2020.

KIŞI, Özgür. Neural networks and wavelet conjunction model for intermittent streamflow forecasting. **Journal of Hydrologic Engineering**, v. 14, n. 8, p. 773-782, 2009.

KISI, Ozgur; SHIRI, Jalal. Precipitation forecasting using wavelet-genetic programming and wavelet-neuro-fuzzy conjunction models. **Water resources management**, v. 25, n. 13, p. 3135-3152, 2011.

KISI, Ozgur; CIMEN, Mesut. A wavelet-support vector machine conjunction model for monthly streamflow forecasting. **Journal of Hydrology**, v. 399, n. 1-2, p. 132-140, 2011.

KUO, Chun-Chao; GAN, Thian Yew; YU, Pao-Shan. Wavelet analysis on the variability, teleconnectivity, and predictability of the seasonal rainfall of Taiwan. **Monthly Weather Review**, v. 138, n. 1, p. 162-175, 2010.

LANG, K. J. The development of the time-delay neural network architecture for speech recognition. **Technical Report CMU-CS-88-152**, 1988.

LEVY, Morgan C. et al. Addressing rainfall data selection uncertainty using connections between rainfall and streamflow. **Scientific reports**, v. 7, n. 1, p. 219, 2017.

LIMA, Mendelson et al. Demystifying sustainable soy in Brazil. **Land Use Policy**, v. 82, p. 349-352, 2019.

DE LIMA, Paulo Cupertino. **Wavelets: uma introdução**. Matemática Universitária, v. 33, p. 13-44, 2003.

LIU, Yonghe et al. A comparison of four precipitation distribution models used in daily stochastic models. **Advances in Atmospheric Sciences**, v. 28, n. 4, p. 809-820, 2011.

LIU, Yang et al. Short-term rainfall forecast model based on the improved Bp–nn algorithm. **Scientific reports**, v. 9, n. 1, p. 1-12, 2019.

MAHESWARAN, Rathinasamy; KHOSA, Rakesh. Comparative study of different wavelets for hydrologic forecasting. **Computers & Geosciences**, v. 46, p. 284-295, 2012.

MALANGE, F.C.V. Rede Neuro Fuzzy Wavelet para Detecção e Classificação de Anomalias de Tensão em Sistemas Elétricos de Potência. 128 p (Tese de Doutorado). Universidade Estadual Paulista “Júlio de Mesquita Filho”. Campus de Ilha Solteira: SP, Abril, 2010.

MALLAT, Stéphane. A wavelet tour of signal processing. Elsevier, 1999.

MALLAT, Stephane G. A theory for multiresolution signal decomposition: the wavelet representation. IEEE transactions on pattern analysis and machine intelligence, v. 11, n. 7, p. 674-693, 1989.

MAO, Ganquan et al. Comprehensive comparison of artificial neural networks and long short-term memory networks for rainfall-runoff simulation. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 123, p. 103026, 2021.

Mapbiomas. Mapa de Limite dos Biomas 1:1.000.000, 2016. Disponível em: https://mapbiomas.org/pages/database/reference_maps

MEHR, Ali Danandeh et al. Successive-station monthly streamflow prediction using neuro-wavelet technique. **Earth Science Informatics**, v. 7, n. 4, p. 217-229, 2014.

MONARD, M.C.; BARANAUSKAS, J.A.. **Aplicação de Inteligência Artificial: Uma Visão Geral**. Instituto de Ciências Matemáticas e de Computação de São Carlos. São Carlos: Universidade São Paulo, 2000.

MICHOT, Véronique et al. Validation and reconstruction of rain gauge–based daily time series for the entire Amazon basin. **Theoretical and Applied Climatology**, v. 138, n. 1, p. 759-775, 2019.

MINE, Otávio Massashi. Previsão de demanda de autopeças com redes neurais. 2010. Dissertação de Mestrado. Universidade Federal do Espírito Santo.

MISITI, Michel et al. Wavelet Toolbox Getting Started Guide. The Mathworks, 1997.

MISITI, Michel. **Wavelet Toolbox for Use with MATLAB: User's Guide; Version 2; Computation, Visualization, Programming**. MathWorks Incorporated, 2000.

MORETTIN, P. A. Ondas e Ondaletas: da Análise de Fourier a Análise de Ondaletas (in Portuguese). [Wave and wavelets: from Fourier analysis to wavelets]. Sao Paulo: Edusp, 1999.

MWALE, Davison; GAN, Thian Yew. Wavelet analysis of variability, teleconnectivity, and predictability of the September–November East African rainfall. *Journal of Applied Meteorology*, v. 44, n. 2, p. 256-269, 2005.

MWALE, Davison et al. Wavelet empirical orthogonal functions of space-time-frequency regimes and predictability of southern Africa summer rainfall. *Journal of Hydrologic Engineering*, v. 12, n. 5, p. 513-523, 2007.

NASH, J. Eamonn; SUTCLIFFE, Jonh V. River flow forecasting through conceptual models part I—A discussion of principles. **Journal of hydrology**, v. 10, n. 3, p. 282-290, 1970.

NASHWAN, Mohamed Salem; SHAHID, Shamsuddin; WANG, Xiaojun. Assessment of satellite-based precipitation measurement products over the hot desert climate of Egypt. **Remote sensing**, v. 11, n. 5, p. 555, 2019.

NERANTZAKI, Sofia D.; PAPALEXIOU, Simon Michael. Tails of extremes: Advancing a graphical method and harnessing big data to assess precipitation extremes. **Advances in Water Resources**, v. 134, p. 103448, 2019.

NG, Jing Lin et al. Generation of a stochastic precipitation model for the tropical climate. **Theoretical and applied climatology**, v. 133, n. 1, p. 489-509, 2018.

NOURANI, Vahid; ALAMI, Mohammad T.; AMINFAR, Mohammad H. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. **Engineering Applications of Artificial Intelligence**, v. 22, n. 3, p. 466-472, 2009.

NOURANI, Vahid et al. Applications of hybrid wavelet–artificial intelligence models in hydrology: a review. **Journal of Hydrology**, v. 514, p. 358-377, 2014.

NOURANI, Vahid; ANDALIB, Gholamreza; SADIKOGLU, Fahreddin. Multi-station streamflow forecasting using wavelet denoising and artificial intelligence models. **Procedia computer science**, v. 120, p. 617-624, 2017.

OLIVEIRA, Hélio Magalhaes. Análise de Sinais para Engenheiros: Uma abordagem via WAVELETS. Rio de Janeiro: Brasport, 2007.

OLIVEIRA-JÚNIOR, José Francisco de et al. Cluster analysis identified rainfall homogeneous regions in Tocantins State, Brazil. **Biosci. j.(Online)**, v. 33, n. 2, p. 333-340, 2017.

OSBORN, Timothy J. et al. Pattern scaling using ClimGen: monthly-resolution future climate scenarios including changes in the variability of precipitation. **Climatic Change**, v. 134, n. 3, p. 353-369, 2016.

OLSON, Branden; KLEIBER, William. Approximate Bayesian computation methods for daily spatiotemporal precipitation occurrence simulation. **Water Resources Research**, v. 53, n. 4, p. 3352-3372, 2017.

PARTAL, Turgay; KIŞI, Özgür. Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. **Journal of Hydrology**, v. 342, n. 1-2, p. 199-212, 2007.

PARTAL, Turgay; CIGIZOGLU, H. Kerem. Prediction of daily precipitation using wavelet—neural networks. **Hydrological sciences journal**, v. 54, n. 2, p. 234-246, 2009.

PARTAL, Turgay; CIGIZOGLU, H. Kerem; KAHYA, Ercan. Daily precipitation predictions using three different wavelet neural network algorithms by meteorological data. **Stochastic environmental research and risk assessment**, v. 29, n. 5, p. 1317-1329, 2015.

PERCIVAL, Donald B.; WALDEN, Andrew T. **Wavelet methods for time series analysis**. Cambridge university press, 2000.

PEREIRA FILHO, Augusto J. et al. Satellite Rainfall Estimates Over South America—Possible Applicability to the Water Management of Large Watersheds 1. **JAWRA Journal of the American Water Resources Association**, v. 46, n. 2, p. 344-360, 2010.

PEREIRA FILHO, Augusto José et al. A Step towards Integrating CMORPH Precipitation Estimation with Rain Gauge Measurements. **Advances in Meteorology**, v. 2018, 2018.

PRODES, Projeto de Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite. Disponível em: <http://www.dpi.inpe.br/prodesdigital/prodesmunicipal.php>. Acesso em 13 de fevereiro de 2022.

QUILTY, John et al. Bootstrap rank-ordered conditional mutual information (broCMI): A nonlinear input variable selection method for water resources modeling. **Water Resources Research**, v. 52, n. 3, p. 2299-2326, 2016.

RAIMUNDO, Milton Saulo. Desenvolvimento de um modelo adaptativo baseado em um sistema SVR-Wavelet híbrido para previsão de séries temporais financeiras. 2018. Tese de Doutorado. Universidade de São Paulo.

RAMANA, R. VENKATA et al. Monthly rainfall prediction using wavelet neural network analysis. **Water resources management**, v. 27, n. 10, p. 3697-3711, 2013.

RAMÍREZ-HERNÁNDEZ, Jorge et al. La influencia del efecto de borde en el pronóstico de precipitaciones utilizando DWT diádica, MODWT, ANN y ANFIS. **Tecnología y ciencias del agua**, v. 7, n. 3, p. 93-113, 2016.

REZENDE, S.O. Sistemas inteligentes: fundamentos e aplicações. Baueri/SP: Manole, 2005.

RIVERA, Diego et al. Forecasting monthly precipitation in Central Chile: a self-organizing map approach using filtered sea surface temperature. **Theoretical and applied climatology**, v. 107, n. 1-2, p. 1-13, 2012.

ROY, Bishwajit; SINGH, Maheshwari Prasad. An empirical-based rainfall-runoff modelling using optimization technique. **International journal of river basin management**, v. 18, n. 1, p. 49-67, 2020.

RUSSELL, Stuart; NORVIG, Peter. Artificial Intelligence: A Modern Approach, Global Edition. **Pearson**, 2016.

SACHINDRA, D. A.; KANAE, S. Machine learning for downscaling: the use of parallel multiple populations in genetic programming. **Stochastic Environmental Research and Risk Assessment**, v. 33, n. 8, p. 1497-1533, 2019.

SALMAN, Afan Galih et al. Single layer & multi-layer long short-term memory (LSTM) model with intermediate variables for weather forecasting. **Procedia Computer Science**, v. 135, p. 89-98, 2018.

SANG, Y. F. et al. Improved continuous wavelet analysis on the variation of hydrologic time series' dominant period. **Hydrol. Sci. J**, v. 58, n. 1, p. 118-132, 2013.

SANG, Yan-Fang. A practical guide to discrete wavelet decomposition of hydrologic time series. **Water resources management**, v. 26, n. 11, p. 3345-3365, 2012.

SANTOS, I. dos et al. Hidrometria aplicada. **Curitiba: Instituto de Tecnologia para o desenvolvimento**, 2001.

SANTOS, Celso AG et al. Hybrid wavelet neural network approach for daily inflow forecasting using tropical rainfall measuring mission data. **Journal of Hydrologic Engineering**, v. 24, n. 2, p. 04018062, 2019.

SCHAEFLI, Bettina; MARAUN, Douglas; HOLSCHNEIDER, M. What drives high flow events in the Swiss Alps? Recent developments in wavelet spectral analysis and their application to hydrology. **Advances in Water Resources**, v. 30, n. 12, p. 2511-2525, 2007.

SCHATZ, C.H.V; Sistema Inteligente Para Monitoramento e Predição do Estado Clínico de Pacientes Baseado em Lógica Fuzzy e Redes Neurais. (Dourado), PósGraduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica do Paraná; Curitiba, 2014.

SEERA, Manjeevan et al. Fault detection and diagnosis of induction motors using motor current signature analysis and a hybrid FMM–CART model. **IEEE transactions on neural networks and learning systems**, v. 23, n. 1, p. 97-108, 2011.

SENE, K. Hydrometeorology: forecasting and applications. 1. ed. United Kingdom: Springer, 2010.

SHOAIB, Muhammad et al. A comparative study of various hybrid wavelet feedforward neural network models for runoff forecasting. **Water resources management**, v. 32, n. 1, p. 83-103, 2018.

SHOAIB, Muhammad et al. A comparison between wavelet based static and dynamic neural network approaches for runoff prediction. **Journal of Hydrology**, v. 535, p. 211-225, 2016.

SILVEIRA, Luiz Gustavo Teixeira da et al. Reciclagem de precipitação e desflorestamento na Amazônia: um estudo de modelagem numérica. **Revista Brasileira de Meteorologia**, v. 32, p. 417-432, 2017.

SIAD, Si Mokrane et al. A review of coupled hydrologic and crop growth models. **Agricultural Water Management**, v. 224, p. 105746, 2019.

SOARES DOS SANTOS, T.; MENDES, David; RODRIGUES TORRES, R. Artificial neural networks and multiple linear regression model using principal components to estimate rainfall over South America. **Nonlinear Processes in Geophysics**, v. 23, n. 1, p. 13-20, 2016.

SOUZA, E. B. GrADS-Grid Analysis and Display System Fundamentos e programação Básica. Universidade Federal do Pará, 2004.

SUHAILA, Jamaludin et al. Introducing the mixed distribution in fitting rainfall data. **Open Journal of Modern Hydrology**, v. 1, n. 02, p. 11, 2011.

SULAIMAN, Sadeq Oleiwi et al. Precipitation pattern modeling using cross-station perception: regional investigation. **Environmental Earth Sciences**, v. 77, n. 19, p. 1-11, 2018.

SUTTON, Richard S.; BARTO, Andrew G. **Reinforcement learning: An introduction**. MIT press, 2018.

TAKAGI, Tomohiro; SUGENO, Michio. Fuzzy identification of systems and its applications to modeling and control. **IEEE transactions on systems, man, and cybernetics**, n. 1, p. 116-132, 1985.

TAPANI, S.; KOZAKEVICIUS, A. Wavelet change-point analysis for non-stationary time series. **Journal of Wavelet Theory and Applications**, v. 5, n. 1, p. 29-44, 2012.

TAPIADOR, Francisco J. et al. Global precipitation measurement: Methods, datasets and applications. **Atmospheric Research**, v. 104, p. 70-97, 2012.

TEALAB, Ahmed; HEFNY, Hesham; BADR, Amr. Forecasting of nonlinear time series using ANN. **Future Computing and Informatics Journal**, v. 2, n. 1, p. 39-47, 2017.

TEODORO, Paulo Eduardo et al. Cluster analysis applied to the spatial and temporal variability of monthly rainfall in Mato Grosso do Sul State, Brazil. **Meteorology and Atmospheric Physics**, v. 128, n. 2, p. 197-209, 2016.

TIAN, Yudong et al. Component analysis of errors in satellite-based precipitation estimates. **Journal of Geophysical Research: Atmospheres**, v. 114, n. D24, 2009.

TORRENCE, Christopher; COMPO, Gilbert P. A practical guide to wavelet analysis. **Bulletin of the American Meteorological society**, v. 79, n. 1, p. 61-78, 1998.

TONGYU, Xu. PENG S., QIN Z. Transient power quality recognition based on BP neural network theory. *Energy Procedia*, v. 16, p. 1386-1392, 2012.

VALE, Petterson et al. The expansion of intensive beef farming to the Brazilian Amazon. **Global Environmental Change**, v. 57, p. 101922, 2019.

VON SACHS, Rainer; NASON, Guy P.; KROISANDT, Gerald. **Adaptive estimation of the evolutionary wavelet spectrum**. University of Kaiserslautern, Germany, and University of Bristol, UK, 1997.

WILKS, Daniel S. Interannual variability and extreme-value characteristics of several stochastic daily precipitation models. **Agricultural and forest meteorology**, v. 93, n. 3, p. 153-169, 1999.

WMO - WORLD METEOROLOGICAL ORGANIZATION. Methods of observation. In: *Guide to Hydrological Practices: hydrology from measurement to hydrological information*. 6. ed. Geneva, Switzerland, 2008. v. 1, cap. 2, p. 24-27. (WMO - n. 168). Disponível em: Acesso em: junho 2018.

YASEEN, Zaher Mundher et al. Stream-flow forecasting using extreme learning machines: A case study in a semi-arid region in Iraq. **Journal of Hydrology**, v. 542, p. 603-614, 2016.

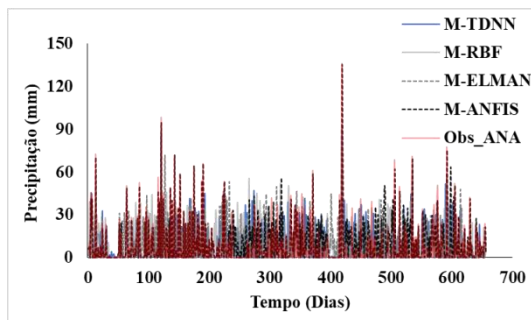
ZHANG, Xiaoli et al. Are hybrid models integrated with data preprocessing techniques suitable for monthly streamflow forecasting? Some experiment evidences. **Journal of Hydrology**, v. 530, p. 137-152, 2015.

ZHANG, Guoqiang; PATUWO, B. Eddy; HU, Michael Y. Forecasting with artificial neural networks: The state of the art. **International journal of forecasting**, v. 14, n. 1, p. 35-62, 1998.

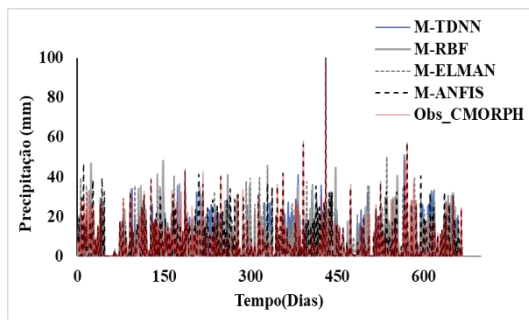
ZERY, Marcelo et al. Exposure assessment of rainfall to interannual variability using the wavelet transform. **International Journal of Climatology**, v. 39, n. 1, p. 568-578, 2019.

ZHU, Li; WANG, Yanxin; FAN, Qibin. MODWT-ARMA model for time series prediction. **Applied Mathematical Modelling**, v. 38, n. 5-6, p. 1859-1865, 2014.


APÊNDICE A – PRECIPITAÇÃO OBSERVADA E SIMULADA EM CADA ESTAÇÃO (DADOS DA VALIDAÇÃO).




a) Período Chuvoso (ANA)



b) Período Chuvoso (CMORPH)




c) Período Menos chuvoso (ANA)

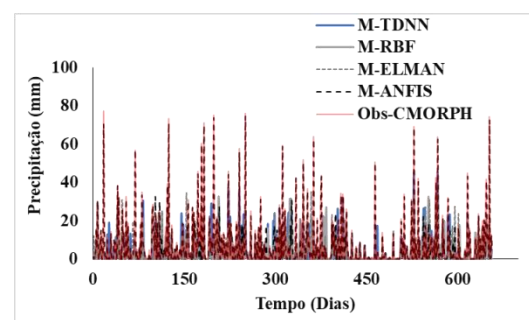


d) Período Menos chuvoso (CMORPH)

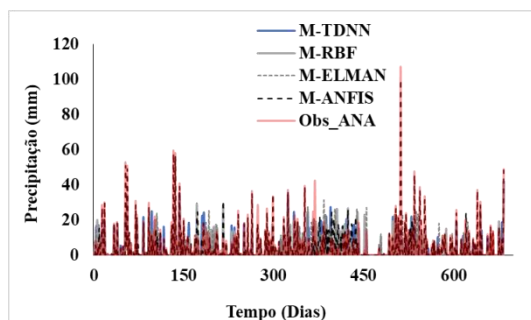
E1 – Estação Rio Branco




a) Período Chuvoso (ANA)



b) Período Chuvoso (CMORPH)



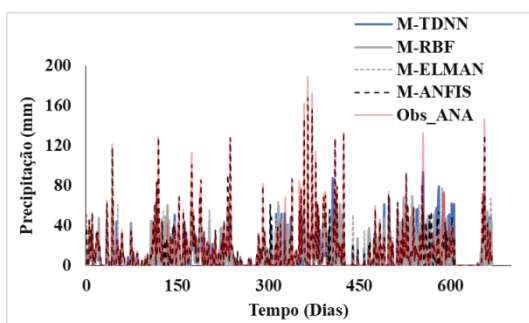
c) Período Menos chuvoso (ANA)




d) Período Menos chuvoso (CMORPH)

E2 – Estação Rio Preto da Eva


Continua APÊNDICE A




a) Período Chuvoso (ANA)



b) Período Chuvoso (CMORPH)




c) Período Menos chuvoso (ANA)




d) Período Menos chuvoso (CMORPH)


E3 – Estação Calçoene




a) Período Chuvoso (ANA)



b) Período Chuvoso (CMORPH)




c) Período Menos chuvoso (ANA)




d) Período Menos chuvoso (CMORPH)

E4 – Estação Badajós


Continua APÊNDICE A




a) Período Chuvoso (ANA)



b) Período Chuvoso (CMORPH)




c) Período Menos chuvoso (ANA)




d) Período Menos chuvoso (CMORPH)


E5 – Estação Pindaré Mirim




a) Período Chuvoso (ANA)



b) Período Chuvoso (CMORPH)



c) Período Menos chuvoso (ANA)



d) Período Menos chuvoso (CMORPH)

E6 – Estação Itaporã do Tocantins

APÊNDICE B – PARÂMETROS ADOTAS NAS REDES NEURAIS.

Parâmetros	ELMAN	TDNN	RBF	ANFIS
Número de Neurônios na camada de entrada	2 - 5	2 - 20	Iguais as entradas de dados (x)	-
Número de neurônios na camada oculta	2-20, (10)	2 - 20 (10)	Iguais as entradas de dados (x)	-
Número de iterações	máx. 1000	máx. 1000	máx. 1000	máx. 1000
Critério de Parada (erro mínimo)	0,001	0,001	0,001	0,001
Taxa de Aprendizagem	-	0,035	-	-
Algoritmo de Aprendizagem	Levenberg-Marquardt	Levenberg-Marquardt	Levenberg-Marquardt	Híbrido
Número de Épocas	180	até 1000	até 1000	30
Função de transferência na camada oculta	tangente sigmóide	log sigmóide	Gaussiana	gbell sino generalizada
Função de Saída	Linear	Linear	Linear	Constante
Constante de Propagação	-	-	0,2	-
Função de Pertinência (MF)	-	-	-	gbellmf (sino generalizada)
Número de função de pertinência (NMF)	-	-	-	2
Sistema de Inferência Fuzzy (FIS)	-	-	-	Takagi-Sugeno

APÊNDICE C – ARTIGO PUBLICADO COMO PARTE DE UM DOS PRODUTOS DE PESQUISA DA TESE.

J. Hydrol. Hydromech., 69, 2021, 1, 13–28
 DOI: 10.2478/johh-2020-0043
 ISSN 1338-4333

©2021. This is an open access article distributed under the Creative Commons Attribution NonCommercial-NoDerivatives 4.0 License



Daily rainfall estimates considering seasonality from a MODWT-ANN hybrid model

Evanice Pinheiro Gomes¹, Claudio José Cavalcante Blanco^{2*}

¹ Civil Engineering Graduate Program, Federal University of Pará – PPGEC/ITEC/UFPA, Av. Augusto Corrêa, 01, 66075-110, Belém, Brazil.

² School of Environmental and Sanitary Engineering, Federal University of Pará – FAESA/ITEC/UFPA, Av. Augusto Corrêa, 01, 66075-110, Belém, Brazil.

* Corresponding author. Tel.: +55 91 3201-8859. E-mail: blanco@ufpa.br

Abstract: Analyses based on precipitation data may be limited by the quality of the data, the size of the available historical series and the efficiency of the adopted methodologies; these factors are especially limiting when conducting analyses at the daily scale. Thus, methodologies are sought to overcome these barriers. The objective of this work is to develop a hybrid model through the maximum overlap discrete wavelet transform (MODWT) to estimate daily rainfall in homogeneous regions of the Tocantins-Araguaia Hydrographic Region (TAHR) in the Amazon (Brazil). Data series from the Climate Prediction Center morphing (CMORPH) satellite products and rainfall data from the National Water Agency (ANA) were divided into seasonal periods (dry and rainy), which were adopted to train the model and for model forecasting. The results show that the hybrid model had a good performance when forecasting daily rainfall using both databases, indicated by the Nash–Sutcliffe efficiency coefficients (0.81–0.95), thus, the hybrid model is considered to be potentially useful for modelling daily rainfall.

Keywords: Artificial Intelligence; Climate Prediction Center morphing; Dry and rainy periods; Amazon.

INTRODUCTION

Analyses based on available precipitation data may be limited by the quality of the data, the size of the available historical series and the efficiency of the adopted methodologies. An alternative used to overcome these limitations can be obtained by daily precipitation forecasting models. Models used for forecasting variables, such as precipitation, can be classified as conceptual or empirical. Conceptual models are based on equations representing the physical processes and evolution of atmospheric phenomena that make up the climate system and may include the atmosphere, hydrosphere, biosphere and geosphere, for example, global circulation models are conceptual models (Cuo et al., 2011; Golding, 2014). Empirical models make mathematical adjustments of calculated values to observed values without relating the physical behaviour of hydrological processes (Siad et al., 2019). Examples of these models are autoregressive models (ARs), moving averages (MAs), autoregressive moving averages (ARMA), artificial neural networks (ANNs), decomposition wavelets (DWs), support vector regression (RVS), etc.

The implementation of these daily precipitation forecasting models presents difficulties due to the large number of variables (climatic and geomorphological) that influence precipitation trends and the lack of understanding about the role of precipitation trends in controlling the distribution of the variables (Frumau et al., 2011; Gupta et al., 2017; Osborn et al., 2016). Therefore, due to the complexity of this problem, models incorporating artificial intelligence (AI) methods are potentially useful approaches for simulating the precipitation process (Fahimi et al., 2017; Nourani et al., 2014). According to Sulaiman et al. (2018), this utility is due to the remarkable flexibility of AI methods in modelling highly nonlinear systems and stochastic patterns, and these methods do not require prior

knowledge of the behaviour of measurement processes. In fact, these methods rely primarily on information that is derived from existing hydrological and weather series sets and use a “black box” approach to simulate underlying processes.

According to Tealab et al. (2017), the dynamic behaviour of most time series and their autoregressive moving averages create the challenge of predicting nonlinear time series that contain inherited moving average terms using AI methodologies such as neural networks. They also emphasized the importance of formulating new neural network models with deep learning and hybrid methodologies. In attempts to improve the prediction of data, such as precipitation data, the combination of models has been proven to be very advantageous. For example, the use of DWs to filter ANN-input data is a good example of this combination. One of the first studies on this modelling technique was carried out by Partal and Kisi (2007). They established a predictive model integrating DWs and neuro-fuzzy techniques with daily precipitation data in the Mediterranean region; this hybrid is considered a solid basis for modelling precipitation processes in the region. Kuo et al. (2010) investigated the seasonal predictability of rainfall using the DW-ANN approach, using seasonal data on rainfall and Pacific Ocean sea surface temperatures (SSTs) and revealing a high coherence of DWs and ANNs in predicting the variables studied.

There are several studies in the literature on the application of hybrid models to forecast daily precipitation. Partal and Cigizoglu (2009) decomposed time series of meteorological variables using DWs and combined them with ANNs (feed-forward back-propagation, FFBP). The authors estimated daily rainfall at various points in Turkey. They achieved the best results with the combination of DWs and ANNs when using ten levels of decomposition. Kisi and Shiri (2011) adopted genetic programming (GP) and neuro-fuzzy (NF) techniques, isolated and combined with DWs, without informing the adopted

APÊNDICE D – ARTIGO PUBLICADO COMO PARTE DE UM DOS PRODUTOS DE PESQUISA DA TESE.

Environ Monit Assess (2022) 194:296
<https://doi.org/10.1007/s10661-022-09939-0>



MODWT-ANN hybrid models for daily precipitation estimates with time-delayed entries in Amazon region

Evanice Pinheiro Gomes · Claudio José Cavalcante Blanco ·
 Patrícia da Silva Holanda · José Francisco de Oliveira Júnior

Received: 25 November 2021 / Accepted: 12 March 2022
 © The Author(s), under exclusive licence to Springer Nature Switzerland AG 2022

Abstract Hydrological analyses based on precipitation records in the Amazon are essential due to their importance in climate regulation and regional and global atmospheric circulation. However, there are limitations related to data series with short periods and many gaps and failures at the daily scale. Thus, a hybrid model was developed based on an artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS) coupled with the

maximum overlap discrete wavelet (MODWT) method to obtain precipitation estimates. Six rainfall gauge stations located in different biomes within the studied region were adopted, and satellite data (CMORPH) were used. The interval of data that was have used is 1998–2016. The precipitation data were evaluated by seasonal (wet and dry) periods. The results obtained demonstrated the good capacity of the MODWT-ANFIS model to simulate the daily precipitation. In this case, data entries lagged by 4 days and 5 days performed better, with *Nash* values close to 1.0 and mean square errors (*MSE*) below 0.1.

E. P. Gomes
 Graduate Program of Civil Engineering, Federal University of Pará-PPGEC/ITEC, UFPA, Av. Augusto Corrêa, 01, Belém 66075-110, Brazil
 e-mail: gomesevanice@ufpa.br

C. J. C. Blanco (✉)
 School of Environmental and Sanitary Engineering, Universidade Federal do Pará – FAESA/ITEC/UFPA, Av. Augusto Corrêa, 01, Belém 66075-110, Brazil
 e-mail: blanco@ufpa.br

P. da Silva Holanda
 Graduate Program in Natural Resource Engineering in the Amazon of the Federal University of Pará-PRODERNA/ITEC/UFPA, Av. Augusto Corrêa 01, Belém 66075-110, Brazil
 e-mail: pholanda@ufpa.br

J. F. de Oliveira Júnior
 Applied Meteorology and Environment Laboratory (LAMMA), Institute of Atmospheric Sciences (ICAT), Federal University of Alagoas – LAMMA/ICAT/UFAL, Av. Lourival Melo Mota, S/N, Maceió, Alagoas 57072-970, Brazil

Keywords Artificial intelligence · Time-delayed inputs · CMORPH · Amazon

Introduction

Precipitation estimates are essential for the management of water resources, as well as for creating sustainability strategies for these resources for extremely varied applications, such as agriculture, industry, water supply, energy production (hydroelectricity) and waterway transport, especially in extreme weather conditions. However, according to Michot et al. (2019), practical and accurate forecasts may encounter barriers related to the quality of the data (gaps and failures), size of the historical series and availability of the number of rainfall stations. Thus, the use of effective methods for estimating precipitation