

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CÂMPUS DE ILHA SOLTEIRA**

PRISCILA BORGES ALVES OLIVEIRA

**Previsão de Ondas de Impacto utilizando a Rede Neural Artificial
ARTMAP FUZZY, um exercício multidisciplinar de Engenharia e Ciências
Ambientais**

Ilha Solteira
2021

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CÂMPUS DE ILHA SOLTEIRA**

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

PRISCILA BORGES ALVES OLIVEIRA

**Previsão de Ondas de Impacto utilizando a Rede Neural Artificial
ARTMAP FUZZY, um exercício multidisciplinar de Engenharia e Ciências
Ambientais**

Tese apresentada à Faculdade de Engenharia -
UNESP – Campus de Ilha Solteira, para
obtenção do título de Doutora em Engenharia
Elétrica.

Área de Conhecimento: Automação

Profa. Dra. Anna Diva Lotufo
Orientador

Ilha Solteira
2021

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

O48p Oliveira, Priscila Borges Alves.
Previsão de ondas de impacto utilizando a rede neural artificial ARTMAP FUZZY, um exercício multidisciplinar de engenharia e ciências ambientais / Priscila Borges Alves Oliveira. -- Ilha Solteira: [s.n.], 2021
269 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2021

Orientador: Anna Diva Lotufo
Inclui bibliografia

1. ARTMAP FUZZY. 2. Ondas de impacto. 3. Normalização. 4. *Roll waves*. 5. Previsão de ondas de impacto. 6. Classificação de ondas de impacto.


Raiane da Silva Santos
Supervisora Técnica de Seção
Seção Técnica de Referência, Atendimento ao usuário e Documentação
Diretoria Técnica de Biblioteca e Documentação
CSB-9 - 9999



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Previsão de Ondas de Impacto utilizando a Rede Neural Artificial ARTMAP FUZZY, um exercício multidisciplinar de Engenharia e Ciências Ambientais

AUTORA: PRISCILA BORGES ALVES OLIVEIRA

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovada como parte das exigências para obtenção do Título de Doutora em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:

Prof.^a. Dr.^a. ANNA DIVA PLASENCIA LOTUFO (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. GERALDO DE FREITAS MACIEL (Participação Virtual)
Departamento de Engenharia Civil / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof.^a. Dr.^a. MARA LÚCIA MARTINS LOPES (Participação Virtual)
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. CLAUDIO FREITAS NEVES (Participação Virtual)
Programa de Engenharia Oceânica / Universidade Federal do Rio de Janeiro - UFRJ

Prof. Dr. TIAGO ZENKER GIRELI (Participação Virtual)
Departamento de Recursos Hídricos / Universidade Estadual de Campinas - UNICAMP

Ilha Solteira, 13 de julho de 2021

Dedico este trabalho em primeiro lugar a Deus, sem o qual nada disso seria possível. Também dedico aos meus pais e meu marido, pelo incentivo, compreensão e auxílio.

AGRADECIMENTOS

Agradeço a Deus por todo auxílio nos diversos momentos de minha vida, por me guiar pelo caminho, me ajudar na superação dos obstáculos e dificuldades, me mostrar que nada é impossível para aquele que tem fé, agradeço-O por mais esta conquista.

Agradeço à minha família, em especial aos meus pais por todo amparo e auxílio nesta etapa, ao meu marido por todo amor, paciência, compreensão e incentivo e aos meus irmãos por estarem sempre ao meu lado.

Agradeço a todos os professores que me auxiliaram durante este trabalho, dedicando seu tempo, aconselhando, compartilhando seus conhecimentos e orientando em diversos momentos. Em especial a minha orientadora a Professora Anna Diva, por todo carinho, auxílio, dedicação, conhecimento e amparo, a Professora Mara por seus conselhos e por estar sempre disposta a me auxiliar nos diversos momentos e ao Professor Geraldo por todos conhecimentos compartilhados.

Agradeço a todos os alunos do SINTEL e do LH2, em especial a Tânia, Monara e Tatiana por estarem sempre ao meu lado quando precisei e pelos cafézinhos, ao Carlos por seu auxílio durante as primeiras etapas da programação, ao Evandro e ao André pela compreensão e ensinamentos durante os primeiros estudos sobre ondas de impacto e *roll waves* e a todos que direta ou indiretamente contribuíram para que este trabalho tivesse êxito.

Agradeço ao Instituto Federal de São Paulo que proporcionou esta oportunidade e a FEIS por toda infraestrutura e pela oportunidade para realização deste trabalho.

Agradeço a todos os meus amigos pela paciência e compreensão nos diversos momentos e pelo suporte quando precisei.

*“Nada te perturbe, nada te espante,
tudo passa. Deus não muda. A
paciência tudo alcança. Quem a
Deus tem nada lhe falta. Só Deus
basta!”*

Santa Tereza de Ávila

RESUMO

Um dos fenômenos mais devastadores do mundo, as ondas de impacto destroem cidades inteiras e removem da história diversas pessoas. As ondas de impacto se tornaram foco de diversos estudos que buscam sua reprodução em laboratório, sua modelagem matemática e a criação de sistemas de alerta, na busca pela redução dos danos causados. A aplicação das redes neurais as ondas de impacto ainda é um campo pouco ou quase nada explorado, assim, neste trabalho, é proposto à utilização da rede neural artificial ARTMAP Fuzzy para previsão dos parâmetros relativos às ondas de impacto, sendo eles: evolução das alturas máximas, comprimentos e períodos relativos, bem como a classificação das ondas segundo seus tipos. Em conjunto também é proposto um estudo sobre a influência da normalização nas previsões realizadas, bem como a utilização da metodologia proposta a um banco de dados de *roll waves*. Para validação da metodologia foram realizadas comparações entre as previsões fornecidas pela rede e os dados medidos experimentalmente, estes que se encontram na literatura. Os resultados demonstraram a capacidade da rede em prever as ondas de impacto, bem como a influência que a normalização tem nos resultados apresentados pela rede, além da capacidade de classificar as ondas segundo seus tipos. Os resultados ainda comprovaram a existência de um parâmetro suficiente para previsão das ondas de impacto validando o observado na literatura. Também se verificou a capacidade da rede em trabalhar com um banco de dados de *roll waves*, conseguindo prever os parâmetros solicitados. Assim, este estudo contribui para a evolução do estado da arte no que tange a utilização da rede neural ARTMAP Fuzzy para previsão das ondas de impacto servindo de auxiliador para criação de sistemas de alerta.

Palavras-chave: ARTMAP Fuzzy; ondas de impacto; *roll waves*; normalização.

ABSTRACT

Impact waves are the most devastated phenomenon in the world destroying entire cities and removing people from history. These waves are studied and reproduced in laboratories with mathematical modeling and creation of alert systems, seeking to reduce damages. The application of Artificial Neural Networks in impact waves is still few explored and therefore this work proposes to use the Fuzzy ARTMAP Neural Network to predict the parameters related to impact waves such as, evolution of maximum heights, lengths and relative periods, as well as the classification of the waves according to the type. Besides, a study is proposed to evaluate the normalization in predicting such parameters and the use of the proposal to a roll waves dataset. To validate the methodology, comparisons were effectuated with the experimental data and those obtained with the neural network. Results show the capacity of the neural network in predicting the impact waves as well as the study of the normalizations proposed evaluates the influence in the predictions, besides the capacity in classifying the waves according to their types. Furthermore, the results prove the existence of an enough parameter to predict impact waves validating the observed in literature. The capacity of the neural network with the roll waves dataset is also adequate predicting the requested parameters. Thus, this study contributes to the evolution of Fuzzy ARTMAP neural network in predicting impact waves and aiding to create an alert system.

Keywords: Fuzzy ARTMAP; impact waves; roll waves; normalization.

SUMÁRIO

1	INTRODUÇÃO	12
1.1	CONSIDERAÇÕES INICIAIS	12
1.2	IMPORTÂNCIA DO TEMA	12
1.3	OBJETIVO GERAL.....	13
1.4	OBJETIVOS ESPECÍFICOS	13
1.5	APRESENTAÇÃO DO TRABALHO	13
2	ONDAS DE IMPACTO	15
2.1	FENÔMENOS ENVOLVENDO ONDAS DE IMPACTO	15
5.1.1	Baía de Lituya	16
2.1.2	Pontesei	19
2.1.3	Vajont	20
2.1.4	Furnas	23
2.2	CARACTERIZAÇÃO DO FENÔMENO.....	26
2.3	HISTÓRICO DE PESQUISA AO LONGO DOS ANOS.....	33
2.4	CAMPOS DE PESQUISA	36
3	REDES NEURAIS ARTIFICIAIS	40
3.1	BREVE HISTÓRICO.....	40
3.2	ARTMAP Fuzzy.....	42
3.3	APLICAÇÃO DAS RNA A ONDAS	47
3.4	APLICAÇÃO DAS RNA ARTMAP FUZZY A ONDA DE IMPACTO	49
4	METODOLOGIA	50
4.1	PARÂMETROS GOVERNANTES.....	50
4.1.1	Seleção de dados	52
4.2	ELABORAÇÕES DAS MATRIZES DE ENTRADA E SAÍDA.....	54
4.3	CRITÉRIOS DE AVALIAÇÃO DA METODOLOGIA	57
4.4	FILTRAGEM DOS DADOS	60
4.5	ALTERAÇÕES NA COMPOSIÇÃO DA MATRIZ DE ENTRADA	60
5	PREVISÃO – ARTMAP FUZZY	62
5.1	TESTES ESTUDADOS	62
5.2	EVOLUÇÃO DAS ALTURAS.....	63
5.3	COMPRIMENTOS RELATIVOS	68
5.4	PERÍODOS RELATIVOS	72

5.5	CONSIDERAÇÕES.....	76
6	NORMALIZAÇÃO - ARTMAP FUZZY	78
6.1	NORMALIZAÇÕES.....	78
6.2	TIPOS DE NORMALIZAÇÕES UTILIZADAS.....	81
6.3	CRITÉRIO DE ESCOLHA.....	86
6.4	BANCO DE DADOS PARA OS TESTES DE NORMALIZAÇÃO	87
6.5	BANCO DE DADOS DE <i>ROLL WAVES</i>	89
6.5.1	<i>Roll Waves</i>	89
6.5.2	Banco de Dados.....	90
6.6	RESULTADOS DOS TESTES DE NORMALIZAÇÃO	92
6.6.1	Resultados dos testes de normalização para a evolução das alturas máximas relativas.....	92
6.6.2	Resultados dos testes de normalização para os comprimentos relativos.....	98
6.6.3	Resultados dos testes de normalização para os períodos relativos.....	104
6.6.4	Resultados dos testes de normalização aplicados a um banco de dados numérico de <i>roll waves</i>	110
6.7	ANÁLISE DA INFLUÊNCIA DAS NORMALIZAÇÕES NOS COMPORTAMENTOS DOS DADOS REFERENTES ÀS ONDAS DE IMPACTO	113
6.8	ANÁLISE DA INFLUÊNCIA DA NORMALIZAÇÃO NA DETERMINAÇÃO DAS ALTURAS MÁXIMAS NA SITUAÇÃO PADRÃO E MODIFICADA PARA $H=0,12$ METROS.....	119
7	CLASSIFICAÇÃO DAS ONDAS.....	122
7.1	CLASSIFICAÇÃO DAS ONDAS	122
8	CONCLUSÃO	126
9	SUGESTÕES PARA TRABALHOS FUTUROS.....	131
	REFERÊNCIAS	132
	ANEXO A – HISTÓRICOS DO FENÔMENO AO REDOR DO MUNDO	147
1.	Lago Genebra	147
2.	Goldau	150
3.	Lago Davos.....	154
4.	Mühlehorn	155
5.	Alpnachersee	157
6.	Quinten	159

7.	Visão geral.....	161
ANEXO B – REDES NEURAIS.....		164
1.	Breve histórico	164
2.	Neurônio biológico x neurônio artificial	166
ANEXO C – TABELAS DO TRABALHO DE ANDREAS HUBER		172
APÊNDICE A – ALGORITMO DA RNA		189
APÊNDICE B – PREVISÃO		192
1	EVOLUÇÃO DAS ALTURAS MÁXIMAS	192
1.1.1	Previsão das curvas das alturas máximas relativas para $h=0,12$	192
1.1.2	Previsão das curvas das alturas máximas relativas para $h=0,18$	199
1.1.3	Previsão das curvas das alturas máximas relativas para $h=0,27$	204
1.1.4	Previsão das curvas das alturas máximas relativas para $h=0,36$	210
2	PREVISÃO DOS COMPRIMENTOS.....	215
2.1.1	Previsão dos comprimentos de onda para $h=0,12$ m	215
2.1.2	Previsão dos comprimentos de ondas relativos para $h=0,18$	220
2.1.3	Previsão dos comprimentos de ondas relativos para $h=0,27$	224
2.1.4	Previsão dos comprimentos de ondas relativos para $h=0,36$	228
3	PREVISÃO DOS PERÍODOS DE ONDA	232
3.1.1	Previsão dos períodos de onda relativos para $h=0,12$	232
3.1.2	Previsão dos períodos de onda relativos para $h=0,18$	236
3.1.3	Previsão dos períodos de onda relativos para $h=0,27$	240
3.1.4	Previsão dos períodos de onda relativos para $h=0,36$	244
APÊNDICE C - NORMALIZAÇÃO		249
1	Normalização pelo máximo da matriz de entrada e matriz de saída sem normalização.....	249
2	Normalização pelo máximo da matriz de entrada e matriz de saída por Carpenter .	250
3	Normalização pelo máximo da matriz de entrada e pelo máximo da matriz de saída.....	250
4	Normalização da matriz de entrada pelo valor máximo da coluna e matriz de saída sem normalização	251
5	Normalização da matriz de entrada pelo valor máximo da coluna e matriz de saída normalizada por Carpenter	252
6	Normalização da matriz de entrada pelo valor máximo da coluna e matriz de saída normalizada pelo máximo da coluna	253

7	Normalização da matriz de entrada pelo máximo da linha e matriz de saída sem normalização.....	254
8	Normalização da matriz de entrada pelo máximo da linha e matriz de saída normalizada por Carpenter	255
9	Normalização da matriz de entrada pelo máximo da linha e matriz de saída normalizada pelo máximo da linha.....	256
10	Normalização da matriz de entrada pelo somatório da coluna e matriz de saída sem normalização.....	257
11	Normalização da matriz de entrada pelo somatório da coluna e matriz de saída normalizada por Carpenter	258
12	Normalização da matriz de entrada pelo somatório da coluna e matriz de saída pelo somatório da coluna.....	259
13	Normalização da matriz de entrada por Carpenter e matriz de saída sem normalização.....	261
14	Normalização da matriz de entrada por Carpenter e matriz de saída por Carpenter	261
15	Normalização da matriz de entrada pelo min-máx e matriz de saída pelo min-máx	262
16	Normalização da matriz de entrada pelo min-máx e matriz de saída por Carpenter	263
17	Normalização da matriz de entrada pelo min-máx e matriz de saída sem normalização.....	264
18	Normalização da matriz de entrada pelo máx-min e matriz de saída pelo máx-min	264
19	Normalização da matriz de entrada pelo máx-máx e matriz de saída por Carpenter	265
20	Normalização da matriz de entrada pelo máx-min e matriz de saída sem normalização.....	266
21	Normalização da matriz de entrada por Carpenter e matriz de saída pelo máximo da coluna.....	267
22	Normalização da matriz de entrada por Carpenter e matriz de saída pelo máx-min	267
23	Normalização da matriz de entrada por Carpenter e matriz de saída pelo min-máx	268
24	Normalização da matriz de entrada por Carpenter e matriz de saída pelo somatório da coluna.....	269

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

As ondas de impacto ou de submersão são um fenômeno de difícil modelação e compreensão, sendo foco de diversos estudos. O registro dessas ondas na literatura indica um grande poder destrutivo causando perdas materiais e de vidas humanas. Devido às catástrofes oriundas das ondas de impacto é de grande importância à criação de sistemas de alerta para tentar evitar ou prever a ocorrência desses eventos. Na mesma direção, ondas pulsantes (de rolo ou roll waves) também é um fenômeno que quando gerado na superfície livre, vem geralmente potencializar acidentes naturais, como corrida de detritos, de deslizamentos e de lama.

1.2 IMPORTÂNCIA DO TEMA

O uso das redes neurais artificiais tem-se mostrado de grande valia para tratamento de problemas de engenharia, muitos dos quais apresentaram bons resultados ao se utilizar essa ferramenta. Assim entende-se que a aplicação de uma RNA para tratamento das ondas de superfície, como tratadas neste trabalho, seria de grande importância, pois podem gerar respostas em curto prazo e auxiliaria no entendimento desses fenômenos, bem como na criação de um sistema de alerta que possibilite evitar a perda de vidas humanas e mitigar a perda de bens materiais.

Observou-se que a utilização das redes neurais ao estudo das ondas de impacto é um tema pouco explorado, possuindo pouca ou nenhuma referência, apesar dos estudos relativos às ondas de impacto ser abordadas desde a década de 50, a utilização das redes neurais contribui para o avanço do estado da arte neste assunto.

1.3 OBJETIVO GERAL

A proposta desse trabalho é utilizar as redes neurais artificiais, mais precisamente a RNA ARTMAP Fuzzy, para previsão das características das ondas de impacto: evolução das alturas máximas, períodos, comprimento e classificação.

1.4 OBJETIVOS ESPECÍFICOS

Podemos destacar como objetivos específicos do trabalho:

1. Utilizar a RNA ARTMAP FUZZY para previsão dos parâmetros fundamentais das ondas de impacto;
2. Utilizar a RNA ARTMAP FUZZY para classificação das ondas de impacto;
3. Verificar a influência da normalização na previsão dos parâmetros relativos às ondas de impacto;
4. Verificar a influência dos parâmetros da RNA ARTMAP Fuzzy na previsão dos parâmetros relativos às ondas de impacto;
5. Utilizar a RNA ARTMAP Fuzzy para previsão dos parâmetros relativos às *roll waves* e verificar a influência da normalização nesta previsão;

1.5 APRESENTAÇÃO DO TRABALHO

Esta pesquisa foi dividida em cinco estudos, sendo o primeiro referente à utilização da rede neural artificial ARTMAP Fuzzy para previsão das ondas de impacto, o segundo referente aos estudos da influência da normalização, o terceiro referente à influência dos parâmetros de treinamento, o quarto referente à classificação das ondas e o quinto referente à utilização da rede neural artificial ARTMAP Fuzzy para previsão dos parâmetros relativos à *roll waves*.

Este trabalho constitui-se de uma pesquisa multidisciplinar e, portanto foi necessária a criação de duas introduções, uma relativa às ondas de impacto e uma segunda relativa às redes neurais artificiais mais especificamente a ARTMAP Fuzzy, constituindo-se os capítulos 2 e 3 deste trabalho.

Devido à extensão de ambos os assuntos foram criados dois anexos, um referente ao histórico do fenômeno das ondas de impacto pelo mundo, anexo A e outro referente ao histórico das redes neurais artificiais, anexo B.

A metodologia utilizada no trabalho é apresentada no capítulo 4, juntamente com os parâmetros governantes das ondas de impacto, a seleção dos dados para utilização no trabalho, as matrizes de entrada e saída da rede neural artificial, bem como suas alterações e a avaliação da metodologia.

No capítulo 5 são apresentados os resultados das previsões da evolução das alturas, comprimentos e períodos relativos, enquanto no capítulo 6 é apresentado todo estudo de normalização, bem como o estudo referente ao banco de dados de *roll waves* e uma breve revisão bibliográfica das *roll waves* e apresentação dos parâmetros que compõem o banco de dados numérico.

Por fim no capítulo 7 são apresentados os resultados da classificação realizada pela rede neural. No capítulo 8 as conclusões deste trabalho e no capítulo 9 as sugestões para trabalhos futuros.

Adicionalmente no anexo C são apresentadas todas as tabelas do trabalho de Andreas Huber utilizadas para compor o banco de dados de ondas de impacto, o apêndice A que apresenta o algoritmo da rede neural artificial ARTMAP Fuzzy, o apêndice B que apresenta todos os resultados da previsão dos parâmetros das ondas de impacto e o apêndice C que apresenta todos os resultados dos testes de influência da normalização.

2 ONDAS DE IMPACTO

As ondas de impacto são um dos fenômenos mais devastadores enfrentados pela humanidade, sendo capazes de desaparecer com cidades inteiras e ceifar milhares de vidas, seus efeitos moveram os olhares do mundo para necessidade da criação de sistemas de alerta e monitoramento constante das regiões mais vulneráveis.

Segundo Huber (1980) a densa povoação da Suíça e a necessidade de recreação levaram a uma crescente ocupação das margens dos lagos por edifícios, instalações para esportes aquáticos e locais de descanso, com isto a atenção do público voltou-se para as rochas instáveis que podem cair no lago abaixo e gerar ondas destrutivas.

Ainda segundo Huber (1980) um desastre iminente pode ser evitado ou pelo menos reduzido com a detecção no momento oportuno, porém isto requer previsões dos efeitos das quedas que consistem em estimar o tamanho e o curso da queda da rocha e prever a onda gerada por essa queda.

Entende-se que a criação de sistemas de alerta cada vez mais avançados é de suma importância, a capacidade dos sistemas em prevê-las e alertar a população pode ser decisivo quanto à preservação de vidas humanas.

Como disposto na apresentação deste trabalho, o foco principal é a previsão das ondas de impacto utilizando a rede neural ARTMAP Fuzzy, podendo ressaltar que foi realizado a previsão das ondas pulsantes (roll waves) em segundo plano, tal a complexidade que ambos os tópicos possuem, optou-se a destinar a estudos futuros um aprofundamento nas ondas roll waves.

Sendo assim, neste capítulo são apresentados alguns dos maiores acidentes envolvendo ondas de impacto e a caracterização do fenômeno.

2.1 FENÔMENOS ENVOLVENDO ONDAS DE IMPACTO

A seguir são apresentados quatro eventos envolvendo as ondas de impacto, outros eventos semelhantes se encontram no Anexo A.

2.1.1 Baía de Lituya

A Baía de Lituya fica situada na costa sudeste do estado do Alasca, Estados Unidos. Segundo Fritz (2001) no dia 08 de julho de 1958 ocorreu um deslizamento de rochas subaéreas em Gilbert Inlet, ocasionado por um terremoto de magnitude 8,3 ao longo da falha Fairweather, o volume estimado do deslizamento foi de $30,69 \times 10^6 \text{ m}^3$ (MILLER, 1960).

Na Figura 1 é possível visualizar a falha, as regiões de geleira, a linha de corte da área de floresta atingida, o lago de pesca, a ilha Cenotaph, e a entrada de Gilbert e Crillion. O deslizamento de terra impactou a água em alta velocidade, gerando um tsunami gigante e a onda mais alta da história (FRITZ; MOHAMMED; YOO, 2009).

Segundo Fritz (2001) esse deslizamento provocou uma onda não linear gigante que correu até 524 metros de altura e a maior onda de subida registrada até então, destruindo uma área de floresta de 10 km^2 nas margens da Baía de Lituya (Figura 2). Esta onda destruiu dois dos três barcos de pesca ancorados na baía, e matou duas pessoas (MILLER, 1960).

Segundo Miller (1960) pelo menos quatro vezes em torno de um século, ondas gigantescas surgiram da cabeceira da baía, destruindo a floresta das margens e deixando linhas de corte semelhantes às formadas pelas geleiras.

O surgimento dessas ondas é atribuído ao efeito combinado de encostas íngremes rochas altamente fraturadas e águas profundas em uma zona de falha ativa, chuvas fortes, congelamento e descongelamento frequentes (FRITZ, 2001).


Segundo Miller (1960) as ondas de 27 de outubro 1936 e 09 de julho de 1958 possuem registros confirmados, entre o período de 1854 a 1916 possivelmente uma ou duas ondas também atingiram a baía, informação baseada em fotos de 1894 e 1929, e possivelmente uma onda em 1853 ou 1854 também atingiu a baía, baseada em análises dos anéis de árvores, com idades iguais, que foram examinadas.

Figura 1 – Baía de Lituya



Fonte: Weiss, Fritz e Wünnemann (2009).

Figura 2 - Dimensões do deslizamento de rochas




Fonte: Mohammed e Fritz (2011) adaptado de Fritz, Hager e Minor (2001).

Na Figura 3 são apresentadas fotos da destruição que causada pela onda de 1958, extraídas do trabalho de Miller (1960): a vista oeste de Coal Creek (Figura 3 (a)), cuja linha de corte na margem esquerda está a uma altura de 50 metros, aproximadamente, e a 300 metros da costa da maré alta. Também é possível ver um tronco de Abeto em Harbor Point (Figura 3 (b)), o chapéu apresentado na foto tem diâmetro de 30 centímetros. O canal de

floresta cortado na ilha de Cenotaph (Figura 3 (c)), além da destruição da área de floresta que se estendia até a margem (Figura 3 (d)). A altura atingida, destruindo árvores a até 524 metros, aproximadamente (Figura 3 (e)) e o pico sudoeste de Gilbert Inlet cuja altura, do canto inferior esquerdo, baía, em relação ao canto superior direito, é de 365 metros, aproximadamente.

Figura 3 – Coletânea de fotos da destruição causada pela onda de 1958



Fonte: Adaptado de Miller (1960).

Segundo Miller (1960) o problema da causa das ondas, após este incidente, tornou-se da noite para o dia, uma questão de interesse público geral, onde até então era principalmente de interesse científico.


2.1.2 Pontesei

O Lago de Pontesei fica situado na província de Belluno, Vêneto, Itália. Segundo Caratto, Semenza e Turrini (2002) no dia 22 de março de 1959 às 7 horas da manhã ocorreu um deslizamento de terra na margem esquerda do reservatório de Pontesei e uma testemunha ocular que estava no lado oposto ao deslizamento informou que o evento não durou mais que 10 a 15 minutos.

Segundo Panizzo *et al.* (2005) o deslizamento possuía um volume de 5 milhões de metros cúbicos, que adentraram no reservatório e alteraram sua capacidade de 9,09 milhões para 5,8 milhões de metros cúbicos.

Na Figura 4 é possível ver a região do deslizamento mais a esquerda e como o lago ficou após o evento.

Figura 4 – Lago Pontesei e Barragem de Pontesei



Fonte: Elaboração do próprio autor no programa Google Earth Pro.


Segundo Caratto, Semenza e Turrini (2002) a ruptura final do deslizamento ocorreu dois anos depois do início de sua ruptura, a superfície de ruptura foi formada em decorrência

de uma ruptura progressiva da área não argilosa e a falha final ocorreu após o desaparecimento da camada de gelo deixando a encosta saturada de água.

Observa-se que este acidente poderia ser o prelúdio do que viria a ser um dos eventos mais conhecidos, referentes a deslizamentos em reservatórios de barragens gerando ondas de impacto, o deslizamento de terra ocorrido na barragem Vajont.

Na Figura 5 é apresentada a região de localização da barragem de Vajont e da barragem de Pontesei, ambas distam-se aproximadamente 22 quilômetros.

Figura 5 – Barragem de Pontesei e Barragem de Vajont



Fonte: Adaptado de Panizzo (2004).

2.1.3 Vajont

A barragem do Vajont está localizada no vale do rio Vajont ao lado do Monte Toc, 100 km ao norte de Veneza na Itália (Figura 6). Segundo Semenza e Ghirotti (2000) houve dois deslizamentos na barragem do Vajont, o primeiro no dia 04 de novembro de 1960 com um volume de 700 mil m³ (SCHNITTER, 1972; PANIZZO, 2004) (Figura 7), o segundo no dia 09 de outubro de 1963, às 22h39, no com volume aproximado entre 270 a 300 milhões de metros cúbicos (HUBER, 1980) (Figura 8).

Figura 6 – Barragem do Vajont e proximidades



Fonte: Elaboração do próprio autor no programa Google Earth Pro.

Figura 7 – Primeiro deslizamento – 700 mil metros cúbicos



Fonte: Schnitter (1972).


Figura 8 – Segundo deslizamento com volume entre 270 a 300 milhões de metros cúbicos



Fonte: SEGUÍ [2005?].

Segundo Hendron Jr e Patton (1985) a onda resultante propagou-se tanto a montante quanto a jusante, erodiu árvores a 935 m (235 m acima do reservatório), varreu a barragem a mais de 100 m acima de sua crista (435 m acima da base a jusante), desceu até o rio Piave, onde tinha altura de 70 m destruindo a maior parte de Longarone e outras cidades no vale do Piave (Figura 9).

Figura 9 – Corte longitudinal do vale do Vajont com as alturas em metros



Fonte: Adaptado de Hendron Jr e Patton (1985)

Nota: a – nível do lago na hora do deslizamento, elevação 700,4 m; b – altura máxima atingida pela onda; c – detritos do deslizamento.

Ainda segundo Hendron Jr e Patton (1985) aproximadamente 2043 pessoas na região perderam a vida e mais quarenta e cinco homens, entre engenheiros, técnicos e operários que viviam nos quartéis situados na crista da barragem, também perderam a vida. A barragem e o

reservatório foram desativados. Na Figura 10 é possível ver a única estrutura que sobreviveu após a onda atingir Longarone. Muitos outros trabalhos relatam o ocorrido neste fatídico dia como os trabalhos de: Belloni e Stefani (1987), Müller (1999), Paronuzzi e Bolla (2012), Francese *et al.* (2013), Ghirotti *et al.* (2013), Bistacchi *et al.* (2013), Bosa e Petti (2013), Manenti *et al.* (2016), Vasquez (2018) e Manenti *et al.* (2018).

Figura 10 – Torre do sino de Pirago em Longarone após a onda



Fonte: Il Gazzettino (2015)

2.1.4 Furnas

Situada em Minas Gerais, no Rio Grande, entre os municípios de São José da Barra e São João Batista do Glória, a usina hidrelétrica de Furnas (Figura 11) é uma das barragens que merece atenção na região de seu reservatório, devido a possíveis quedas de blocos.

Figura 11 - Usina Hidrelétrica de Furnas – MG



Fonte: Elaboração do próprio autor no programa Google Earth Pro.

Segundo Szpilman e Ren (1976) citado por Carvalho *et al.* (1991), no Córrego dos Cabritos situado na margem esquerda do reservatório de Furnas, foram constatados escorregamentos como o ocorrido em janeiro de 1969, na encosta da margem direita do lago. O bloco deslizante fragmentou-se e transformou-se numa corrida de detritos, em grande parte com diâmetros de 5 e 15 centímetros.

Ainda segundo Carvalho *et al.* (1991) esse deslizamento causou pequenos danos, mas sua proximidade com a Barragem alertou para a necessidade de estudos visando a possibilidade de novos deslizamentos futuros e de maior intensidade.

Segundo Szpilman e Ren, 1976 citado por Comissão internacional de Grandes Barragens (ICOLD) Boletim 124 (2002, p.155): “uma queda de rocha chamou a atenção para grandes blocos instáveis de quartzito intemperizado dentro do reservatório.” Ainda, segundo ICOLD Boletim 124 (2002), esses blocos eram de tamanho suficiente para gerarem ondas de impacto, estas que poderiam ultrapassar a barragem causando sérios danos.


Segundo Miguez de Mello (1985 citado por ICOLD Boletim 124, 2002) esses blocos instáveis foram posteriormente escavados.

Segundo Huber *et al.* (1982) em barragens, as ondas gigantes são um perigo, especialmente quando o reservatório está cheio. Seu transbordamento pode danificar o topo do aterro e causar um “tsunami” no vale abaixo, em um caso extremo. E mesmo que a barragem não se rompa, se houver deslocamento suficiente de água, pode ocasionar um “maremoto” devastador no vale, como ocorrido em Vajont em 1963.

Se o potencial de uma onda de impulso for identificado durante a fase de planejamento de um reservatório pode-se designar um estudo de um modelo físico para garantir a segurança da instalação, afirma Fuchs (2013).

Silva e Sandroni (1985) citado por Carvalho *et al.* (1991) relata que realizaram um estudo, através da COPPE - Coordenação de Programas de Pós-Graduação em Engenharia/UFRJ, para estimar as alturas de onda na Barragem para diversas hipóteses de escorregamento. Seu estudo apontou a necessidade de modelos físicos tridimensionais para mensurar as alturas das ondas e possíveis danos à barragem. Na Figura 12 é apresentada a planta do modelo de Furnas e no Quadro 1 são apresentados alguns dos modelos físicos para estudo de barragens existentes.

Figura 12 – Planta do modelo Furnas, local das sondas de medição de ondas e da encosta instável.



Fonte: Carvalho *et al.* (1991).

Quadro 1 - modelos físicos para estudos de barragens no Brasil

Escala	Hidrelétrica	Referência
1:75	Furnas	Carvalho et. al (1991)
1:70	Foz do Rio Claro	Sousa; Almeida; Neto (2018)
1:80	Teles Pires	Sousa; Almeida; Neto (2018)
1:80	Santo Antônio	Revista Furnas (Dez. 2010/ Jan. 2011)
1:110	Jirau	Revista Furnas (2005); Revista FURNAS (2009)


Fonte: Elaboração do próprio autor.

2.2 CARACTERIZAÇÃO DO FENÔMENO

Segundo Fuchs (2013) e Fritz (2002) as ondas de impacto são ondas gravitacionais geradas, em oceanos, lagos ou reservatórios artificiais, devido a deslizamentos de terra, deslizamentos de rochas, quedas de rochas, avalanches de neve, quebras de geleiras, terremotos, erupções vulcânicas, explosões subaquáticas ou até mesmo impactos de asteroides.

Na Figura 13 são ilustradas algumas das principais causas para geração das ondas de impacto segundo Müller (1995).


Figura 13 – Principais causas geradoras das ondas de impacto



Fonte: Adaptado de Müller (1995).

Essas ondas são geradas pela transferência da quantidade de movimento para o corpo d'água, (Figura 14) possuindo três processos de geração de ondas dependendo da posição inicial da massa deslizante (EVERS, 2017).

Figura 14 – Mecanismo de geração de onda



Fonte: Adaptado de Heller (2007).

Segundo Heller (2007) o deslizamento de terra subaerial gera ondas de impulso envolvendo um fenômeno trifásico de sólido, água e ar. A frente do trem de ondas começa

normalmente com uma elevação da superfície da água. Como exemplo o deslizamento da Baía de Lituya no Alasca, Estados Unidos.

Ainda segundo Heller (2007) o deslizamento parcialmente submerso é mais lento em comparação com o subaerial, mas ainda pode causar um fluxo de mistura trifásico. Como exemplo o deslizamento em Vajont na Itália.

O deslizamento submerso, submarinos ou subaquáticos, segundo Heller (2007) envolve apenas duas fases, estando a fase do ar ausente. As ondas de deslizamento subaquático começam normalmente com uma depressão da superfície da água.

Na Figura 15 são apresentadas as três fases principais das ondas de impulso, sendo a primeira referente ao processo de geração das ondas com o impacto do deslizamento e o escoamento ao longo do leito do corpo d'água, o deslocamento da água e a formação das ondas (FRITZ, 2002). Esse impacto gera um trem de ondas com várias cristas e vales (EVERS, 2017).

A segunda fase se refere à propagação do trem de ondas sobre o corpo d'água, incluindo a propagação e dispersão lateral (FRITZ, 2002). Inclui-se a propagação da onda radial e transversal, o desprendimento do ar, a dispersão da frequência da onda e a transformação da onda (HELLER, 2007).

A terceira fase, segundo Fritz (2002) e Heller (2007), é caracterizada pela subida das ondas ao longo da costa e inclui a transformação das ondas com a diminuição da profundidade da água, o aumento da onda ao longo de uma linha costeira ou de uma barragem e um possível galgamento da barragem.

Segundo Fritz (2002) nos casos de lagos ou reservatórios alpinos estreitos, a subida das ondas pode iniciar antes que o deslizamento tenha terminado, pulando assim a segunda fase.


Figura 15 – Fases das ondas de impulso



Fonte: Heller (2007).


As Figuras 16 e 17 representam uma onda gravitacional gerada pelo deslizamento de um material e seus parâmetros principais, sendo eles: Velocidade de impacto do material deslizante (V_s); Volume de massa do material deslizante (V_s); espessura do material deslizante (s); densidade do material deslizante (ρ_s); porosidade do material deslizante (n); ângulo de impacto do material deslizante (α); profundidade da água parada (h); amplitude da onda (a); altura da onda (H); ângulo de subida da margem oposta (β); altura máxima da onda (H_M); amplitude máxima da onda (a_M).

Figura 16 – Parâmetros reguladores no início do canal



Fonte: Adaptado de Heller, Hager e Minor (2009).


Figura 17 - Parâmetros reguladores ao final do canal



Fonte: Adaptado de Heller, Hager e Minor (2009).

Na Figura 18 são apresentados alguns termos característicos das ondas de impulso para maior compreensão e os cinco tipos básicos de ondas, sendo elas: (a) onda sinusoidal, (b) Stokes ondas, (c) onda cnoidal, (d) onda solitária e (e) macaréu.

Figura 18 – Tipos básicos de ondas




Fonte: Heller e Hager (2011). Legenda: L – Comprimento; T – Período; a – amplitude; H – altura; h – profundidade;

As ondas gravitacionais podem ser divididas em vários tipos segundo Evers *et al.* (2019), sendo eles: ondas oscilatórias ou translatórias; ondas de águas rasas, intermediárias ou profundas; ondas periódicas ou não periódicas; ondas lineares ou não lineares.

A Figura 19 ilustra um exemplo de uma onda oscilatória, periódica e linear, esta onda apenas transporta energia que movimenta as partículas de água e não transporta massa fluída, possui periodicidade, uma vez que se constitui em um grupo de várias ondas e possui curva senoidal Evers *et al.* (2019). Podem-se observar na Figura 19 outros três parâmetros principais, sendo eles: O período (T), o comprimento (L) e a velocidade de propagação da onda (c), além disso, a onda é linear se $H/h < 0,03$ e $H/L < 0,006$ (EVERS *et al.*, 2019).

Figura 19 - Parâmetros da onda principal apresentados em uma onda senoidal idealizada




Fonte: Evers *et al.* (2019).

A Figura 20 ilustra um exemplo de uma onda oscilatória ocorrendo em três situações: a) água rasa; b) águas intermediárias; c) águas profundas. O critério para distinção dessas ondas é dado pela relação entre o comprimento de onda (L) e a profundidade da água parada (h) (EVERS *et al.*, 2019).

Segundo Evers *et al.* (2019), no primeiro caso as partículas de água se movem de forma elíptica até se tornarem paralelas ao fundo, um exemplo seria um tsunami causado pelo movimento das placas tectônicas. Enquanto o terceiro caso, segundo Evers *et al.* (2019), é o oposto, as partículas de água se movem em órbitas circulares diminuindo até que não possam mais ser detectadas no fundo, em outras palavras, não são afetadas pelo lago ou fundo do mar, exemplo as ondas de vento em águas abertas.

Ainda segundo Evers *et al.* (2019), o segundo caso ocorre entre os dois anteriores, neste caso o fundo do oceano ou lago influi parcialmente.

Figura 20 - Movimento de partículas de água de uma onda oscilatória em águas rasas, intermediárias e profundas.



Fonte: Evers *et al.* (2019).

Para o caso das ondas translatórias, estas, segundo Evers *et al.* (2019), são o oposto das ondas oscilatórias, pois as partículas de água se movem horizontalmente na direção da

propagação da onda e há transporte de massa de fluido e de energia. E para o caso das ondas não periódicas, estas ocorrem como uma única onda.

Segundo Evers *et al.* (2019), para ondas não lineares quanto maior o grau de não linearidade mais o perfil desvia do perfil senoidal ideal, assim a condição de onda linear para ondas senoidais, onde a altura é igual a duas vezes a amplitude da onda, não se aplica mais.

No caso das ondas de impacto geradas por deslizamento de terra, estas, segundo Evers *et al.* (2019), são ondas não periódicas e normalmente fortemente não lineares, sendo difíceis de analisar matematicamente, podendo ter pouco à considerável transporte de massa de fluido e podendo conter características translatórias e oscilatórias. Devido a estas e outras razões, as previsões precisas das ondas de impacto são um desafio (EVERS, 2019).

Observa-se que todas as ondas de impacto geradas por deslizamento de terra podem ser alocadas em quatro grupos diferentes, sendo eles: Onda de Stokes, Onda Cnoidal, Onda Solitária e macaréu (HELLER; HAGER; MINOR, 2009).

No Quadro 2 são apresentados alguns critérios para classificação do tipo de onda segundo Heller; Hager (2011).

Quadro 2 – Classificação dos tipos de onda

Stokes	Cnoidal	Solitária	Macaréu
Perfil de onda simétrico (para ambos os eixos)	Perfil de onda simétrico (ao eixo vertical)	Perfil de onda simétrico (ao eixo vertical)	Perfil de onda irregular (para ambos os eixos)
Cava idêntica ao longo da crista; Múltiplas cristas equivalentes (pelo menos duas) ($a \approx a_t$)	Cava mais longa que a crista; Múltiplas cristas (pelo menos duas)	Uma crista dominante; Cava quase ausente ($a_t < a/4$)	Frente de onda íngreme, costas ligeiramente inclinadas; Uma crista dominante
Águas profundas a intermediárias ($a_M < h/2$); Leve transporte de massa fluida	Águas intermediárias ou rasas ($a_M < h$); Transporte de massa fluida	Águas rasas; Grande transporte de massa de fluido	Águas intermediárias a rasas; Transporte de grande massa de fluido
Exemplo: Ondas de vento	Exemplo: Ondas de vento em águas rasas	Exemplo: Tsunamis	Exemplo: Rebentação das ondas

Nota: a_t = distância da superfície da água parada até a onda

Fonte: Adaptado de Evers (2019) e Heller e Hager (2011).

Assim, as ondas de impacto geradas por deslizamentos de terra são ondas não periódicas e normalmente fortemente não lineares (EVERS, 2019).

2.3 HISTÓRICO DE PESQUISA AO LONGO DOS ANOS

Ao longo de séculos as ondas de impacto vem sendo alvo de diversos estudos, segundo Heller (2007) os experimentos de John Scott Russell em 1837 podem ser considerados como a origem da pesquisa de ondas de impulso geradas por deslizamentos.

Porém o primeiro a tentar uma teoria das ondas de água foi Isaac Newton em 1687 como é relatado por Craik (2004). Uma revisão histórica acerca da teoria de ondas gravitacionais é realizada no trabalho publicado por Craik (2004), contendo as pesquisas: antes de 1800 com Newton, Laplace e Lagrange; de 1800 a 1830 com: Gerstner, Cauchy, Poisson, e os irmãos Weber; a mecânica dos fluídos britânicos antes de 1838; de 1838 a 1844 com: Russell, Green, Kelland, Airy, e Earnshaw; o artigo de 1840 de Kelland; ondas solitárias de Earnshaw; o artigo sobre mares com ondas de Airy em 1841.

Stokes estava iniciando seus trabalhos com ondas quando o artigo de Airy foi publicado e este e outros trabalhos foram os estímulos para Stokes realizar seu grande trabalho sobre ondas, conforme relatado por Craik (2004).

Segundo U. S. Army Coastal Engineering Research Center (1977), o comportamento das ondas, cuja profundidade local em relação ao comprimento da onda não é muito pequena, é mais bem previsto com as teorias de Airy publicada em 1845 e de Stokes publicada em 1880, enquanto a teoria de ondas cnoidais fornece uma aproximação aceitável para águas rasas e para as zonas de quebra mar a teoria de ondas solitárias melhor se aplica.

Muitas outras teorias e trabalhos são encontrados na literatura e fornecem um maior aprofundamento no assunto, como exemplos:

O trabalho publicado por Kamphuis; Bowering (1970) intitulado: Ondas de impacto geradas por deslizamentos. Seu trabalho investigou as ondas de impacto geradas por deslizamentos originados inteiramente acima da superfície da água. Foi realizada uma tentativa para determinar a relação entre as ondas de impacto geradas e os vários parâmetros do material deslizante e do corpo de água receptor.

O trabalho de Huber (1980) intitulado: Ondas repentinas em lagos como resultado de quedas de rochas. Os resultados de seu trabalho foram baseados em uma série de testes de modelo que foram realizados parcialmente em uma calha e parcialmente em um tanque. As massas do material deslizante consistiam de uma mistura de componentes de granulação fina

e grossa. Com os resultados, números característicos para ondas de impacto, geradas por deslizamentos de rochas em lagos, podem ser calculados e previstos.

O trabalho de Müller (1995) sobre: Acúmulo e transbordamento de ondas de impacto em barragens. Seu trabalho trata dos run-up e galgamentos em barragens devido às ondas de impacto utilizando modelos físicos e observações de incidentes naturais.

O trabalho publicado por De Freitas Maciel e Do Nascimento (2002): Modelagem Numérica de Ondas de Submersão Utilizando o Modelo de Serre. O objetivo de seu estudo era ressaltar a adaptabilidade e domínios de validade de código de cálculo com base nas equações da “classe Boussinesq” (Sistema Serre) no estudo de ondas de submersão.

O trabalho de Fritz (2002): Fase inicial de ondas de impacto geradas por deslizamentos. Seu estudo visava compreender a fase inicial das ondas de impacto geradas por impactos de deslizamentos subaeriais e realizou a medição do campo de velocidades.

O trabalho de Fritz, Hager e Minor (2004): Características de campo próximo de ondas de impacto geradas por deslizamentos. Seu estudo criou um modelo físico bidimensional que estudava o processo de geração de ondas, o deslocamento de água e as características das ondas, utilizando como modelo de comparação as ondas de impacto geradas por rochas que atingiram a Baía de Lituya, no Alasca, em 1958.

O trabalho publicado por Panizzo, De Girolamo e Petaccia (2005) intitulado: Previsão de ondas de impacto geradas por deslizamentos subaeriais. Seu trabalho experimental teve como objetivo definir formulações empíricas capazes de prever as principais características das ondas geradas em um corpo d'água tridimensional, estas foram caracterizadas usando uma abordagem de análise de wavelet e novas formulações de previsão foram definidas com base no estudo experimental e testadas usando um modelo de rede neural artificial.

O trabalho de Zweifel, Zuccalà e Gatti (2007): Comparação entre Ondas de Impacto Computadas e Geradas Experimentalmente. Em seu trabalho foram realizados testes experimentais com ondas de impacto em um canal para determinadas faixas de profundidades, volumes de deslizamento de terra e velocidades de impacto. Seu estudo, produzido em laboratório, também realizou previsões dos perfis de ondas utilizando métodos numéricos, realizando uma comparação entre os ensaios experimentais e modelo numérico, concluindo que as diferenças médias quadráticas entre os picos de onda medidos e calculados não ultrapassaram 20%, o que ele considerou como desempenho satisfatório do software do ponto de vista da engenharia.

O trabalho de Heller (2007): Ondas de impacto geradas por deslizamentos: Previsão de características de campo próximo. Seu trabalho investigou a geração de ondas de impacto

geradas por deslizamentos subaéreos com um modelo hidráulico não distorcido baseado na semelhança de Froude, num total de 211 experimentos conduzidos. Sua pesquisa continuou o trabalho realizado por Fritz (2002) e continuado por Zweifel, Zuccalà e Gatti (2007).

O trabalho de Souza (2007): Métodos analíticos, numéricos e experimentais para o cálculo de ondas de impacto em meios líquidos. Seu estudo visava validar o modelo numérico, baseado nas equações de Serre, desenvolvido por Maciel (1991) e aprimorado por Nascimento (2001), para o caso de materiais granulares.

O trabalho publicado de Fritz, Mohammed e Yoo (2009) intitulado: 50º aniversário do Mega Tsunami gerado pelo Impacto do Deslizamento de Lituya Bay. Seu estudo reproduziu em um modelo físico tridimensional na escala 1: 400 o deslizamento de terra da Baía de Lituya, utilizando o PIV (velocimetria de imagem de partícula) para medição das velocidades de superfície do escorregamento.

O trabalho de Heller, Hager e Minor (2009): Tipos de ondas de impacto geradas por deslizamentos de terra. Seu estudo investigou ondas de impulso geradas por deslizamento de terra subaerial em um canal de ondas de geometria prismática, com variação de sete parâmetros sendo eles: a profundidade da água parada, velocidade de impacto de deslizamento, espessura de deslizamento, volume de deslizamento em massa, densidade de deslizamento em massa, ângulo de impacto de deslizamento e diâmetro de grão.

O trabalho de Fuchs (2013): Onda de impacto solitária de subida e fluxo terrestre. Seu trabalho estudou os efeitos da onda de impacto durante as fases de subida e escoamento superficial na costa oposta à geração da onda, investigando a interação onda-costa variando a altura relativa da onda, a altura relativa da costa e a inclinação da costa.

O trabalho de Yavari-Ramshe e Ataie-Ashtiani (2017): Ondas Subaerial Geradas por Deslizamento: Simulações Numéricas e de Laboratório. Em seu artigo realizou uma breve revisão dos estudos físicos e numéricos sobre Ondas subaerial geradas por deslizamentos de terra (SALGWs).

O trabalho de Ponziani e Gardoni (2017): Ondas geradas por deslizamentos em reservatórios de barragens. Seu estudo teve como objetivo principal usar o modelo em escala no laboratório de hidráulica da NTNU, a fim de investigar o efeito das ondas geradas por deslizamentos em barragens de aterro. O foco de sua pesquisa foi a observação da amplitude e propagação das ondas de impacto geradas no reservatório, altura da água na crista da barragem e volume total de água de galgamento.

As ondas de impacto constituem um campo amplo de pesquisas e diversos outros trabalhos podem ser encontrados na literatura, sendo que estes que foram apresentados constituem apenas uma pequena parcela do que se encontra disponível.


2.4 CAMPOS DE PESQUISA

Na literatura são encontrados diversos estudos que reproduzem em laboratório os deslizamentos que geram ondas de impacto, entre esses estudos podemos encontrar:

Modelos unidimensionais (Figura 21): Os trabalhos de Pérez, García-Navarr e Vázquez-Cendón (2006) e Silva Jr (2013).

Segundo Pérez, García-Navarro e Vázquez-Cendón (2006), a simplificação para o modelo unidimensional é possível nos casos em que a escala de fluxo longitudinal é maior que as dimensões transversais, assim o problema é aproximado apenas como variável na direção do fluxo principal.

Figura 21 - Fluxo unidimensional ao longo da direção x , deslizamento longitudinal (a) e transversal (b).




Fonte: Adaptado de Pérez, García-Navarro e Vázquez-Cendón (2006)

Nota: *P: Perímetro molhado; L: Comprimento do canal.

Modelos bidimensionais (Figura 22): Os trabalhos de Huber (1980), Evers (2017), Fritz, Hager e Minor (2004, 2008), Sælevik, Jensen e Pedersen (2009), Fuchs, Heller e Hager (2010) e Evers e Hager (2015).

Figura 22 - Modelo bidimensional



Fonte: Adaptado de Fritz (2002).

Modelos tridimensionais (Figura 23): Os trabalhos de Huber (1980), Evers (2017), Panizzo, De Girolamo e Petaccia (2005), Liu *et al.* (2005), Mohammed e Fritz (2012), Lindstrøm *et al.* (2014), Jamin *et al.* (2015), Wang *et al.* (2016), McFall e Fritz (2017).

Figura 23 – Modelo Tridimensional



Fonte: Evers (2017).

Além da reprodução das ondas de impacto em laboratórios, as pesquisas também utilizam destes dados para testar hipóteses, desenvolver sistemas de previsão e/ou realizar

comparações com métodos numéricos ou desenvolvê-los. Dentre os trabalhos presentes na literatura podemos citar:

A pesquisa realizada por Serrano-Pacheco, Murillo e García-Navarro (2009) desenvolveu um método de volume finito para a simulação das ondas geradas por deslizamentos de terra e aplicaram a uma série de casos de teste com dados de laboratório e também a um caso prático de tamanho real.

O trabalho de Biscarini (2010) descreveu a aplicação de dinâmica de fluidos computacional (CFD) detalhada para simular a formação e propagação de ondas geradas pelo impacto do material deslizante com a água. Seus resultados foram comparados com dados experimentais relatados na literatura e o modelo aplicado para simular o evento do Tsunami na baía de Lituya em 1958.

O trabalho de Fuchs, Heller e Hager (2010) pretendeu fornecer uma base de dados detalhada para modelagem numérica de ondas de impulso envolvendo características de ondas relativamente simples e topografia de modo que os efeitos principais possam ser calibrados e validados.

A pesquisa realizada por Cremonesi, Frangi e Perego (2011) investigou a aplicação de um método de elementos finitos Lagrangeano para simular ondas de água não lineares devido a deslizamentos de terra, validando o método através de comparação com dados experimentais.

O estudo realizado por Tinti *et al.* (2011) se concentrou na simulação numérica do tsunami gerado por um deslizamento de terra catastrófico passado na ilha vulcânica de Ischia, Itália.

O movimento do deslizamento de terra e o consequente tsunami foram calculados usando os códigos numéricos UBO-BLOCK1 e UBO-TSUFE, respectivamente, concebidos especificamente para evolução do deslizamento e propagação do tsunami, que foram desenvolvidos pela equipe de pesquisa de tsunami da Universidade de Bolonha (TINTI *et al.*, 2011, p. 289).

O trabalho de Bosa e Petti (2011) estuda um modelo numérico hidráulico da bacia de Vajont para reproduzir como a onda foi gerada e sua propagação dentro da bacia.

O estudo realizado por Najafi-Jilani e Ataie-Ashtiani (2012) teve por objetivo fornecer um método empírico aplicável com base em laboratório para previsão do aumento das ondas causadas por deslizamentos submarinos, com foco especial em reservatórios de barragens.

O trabalho de Vasco (2014) desenvolveu um software utilizando a técnica SPH (Hidrodinâmica de Partículas Suavizadas) na geração de ondas de submersão, estimando a

altura da onda solitária gerada a partir do impacto de uma massa deslizante, de duas formas distintas: bloco indeformável, modelado como corpo rígido em um meio fluido ideal.

A pesquisa de Shi *et al.* (2016) estudou a simulação numérica de ondas geradas por deslizamentos usando um modelo hidrodinâmico de partículas suavizadas de acoplamento solo-água (SPH), seu modelo inclui um modelo constitutivo elasto-plástico para solo, um modelo baseado na equação de Navier-Stokes para água e um modelo de acoplamento bilateral na interface. Segundo Shi *et al.* (2016) uma boa concordância foi obtida entre os resultados da simulação e os dados experimentais.

O trabalho de Huang, Wang e Zhao (2017) desenvolveu um modelo gerador de tsunamis com um programa FORTRAN para geradores de tsunamis iniciais induzidos por deslizamentos de terra em reservatórios adicionado a parte do código-fonte aberto FUNWAVE, em que se baseou.

3 REDES NEURAIIS ARTIFICIAIS

Um breve histórico sobre as redes neurais é apresentado no anexo B, enquanto neste capítulo será apresentado de maneira breve um histórico sobre a teoria da ressonância adaptativa, as redes da família ART, em especial a ARTMAP Fuzzy que foi utilizada neste trabalho, bem como as aplicações das redes neurais no estudo de ondas de tsunami, ondas costeiras e ondas de impacto.

3.1 BREVE HISTÓRICO

A teoria da ressonância adaptativa teve início nos trabalhos de Stephen Grossberg intitulados: “*Adaptive pattern classification and universal recoding: I. Parallel development and coding of neural feature detectors*” (GROSSBERG, 1976a), e o complementar: “*Adaptive pattern classification and universal recoding: II. Feedback, expectation, olfaction, illusions*” (GROSSBERG, 1976b).

O trabalho conjunto de Stephen Grossberg e Gail Carpenter em meados dos anos de 1980 desenvolveu as redes neurais da família ART. Estas redes possuem como principais propriedades:

- A plasticidade: segundo Carpenter; Grossberg (1987a) é a capacidade de cada sistema gerar códigos de reconhecimento de forma adaptativa em resposta a uma série de entradas ambientais;
- A estabilidade: é a capacidade da rede sempre convergir, ou seja, apresentar uma resposta;
- O dilema estabilidade-plasticidade: observa-se que um sistema adequado deve ser capaz de transitar do estado estável para o plástico e vice-versa de forma adaptativa, ou seja, ser plástico frente a novas informações e estável frente às informações irrelevantes ou repetidas (CARPENTER; GROSSBERG, 1987a).
- Papel do sistema de atenção na aprendizagem: Nos sistemas ART, os mecanismos de atenção possuem papel importante para auto estabilização da aprendizagem, possuindo quatro tipos: priming atencional (como um estímulo influi na resposta de um estímulo subsequente); controle de ganho de atenção (escolha do que prestar atenção); vigilância atencional (tempo que se presta atenção); competição intermodal (concorrência) (CARPENTER; GROSSBERG, 1987a).
- Complexidade: Segundo Carpenter; Grossberg (1987a): devido à capacidade de reorganização dinâmica dos códigos de reconhecimento para preservar o

equilíbrio enquanto as representações internas se tornam mais complexas e diferenciadas por meio do aprendizado.

Assim, Carpenter e Grossberg (1987a) em seu trabalho: “*A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine*”, caracterizam redes neurais capazes de auto estabilizar a auto-organização de seus códigos de reconhecimento como resposta a um complexo padrão de entrada conciliando os requisitos de plasticidade, estabilidade e complexidade.

Desta teoria foram desenvolvidas diversas redes que são conhecidas como redes da família ART, algumas destas redes são apresentadas no Quadro 3 juntamente com suas referências.

Quadro 3 – Redes da família ART

Redes neurais	Referência
ART	Grossberg (1988)
ART 2	Carpenter; Grossberg (1987b, 1988)
ART 2-A	Carpenter; Grossberg; Rosen (1991)
ART 3	Carpenter; Grossberg (1990)
ARTMAP ou Predictive ART	Carpenter; Grossberg; Reynolds (1991)
Fuzzy ART	Carpenter; Grossberg; Rosen (1991)
Fuzzy ARTMAP	Carpenter <i>et al.</i> (1992)
Simplified Fuzzy ARTMAP (SFAM)	Vakil-Baghmisheh; Pavešić (2003)
Gaussian ART e Gaussian ARTMAP	Williamson (1996)
Fusion ART	Asfour <i>et al.</i> (1993)
ART-EMAP	Carpenter; Ross (1995)
TopoART	Tscherepanow (2010)
Hypersphere ART e Hypersphere ARTMAP	Anagnostopoulos; Georgiopoulos (2000)
LAPART	https://lapartpython.readthedocs.io/en/latest/index.html#lapart-python-documentation Acessado em: 16 mar. 2021

Fonte: Elaboração do próprio autor.

Existem muitas outras redes da família ART e algumas são apresentadas no trabalho de Grossberg (2013) e Carpenter e Grossberg (2016) como exemplo: ARTSCAN; LAMINART; SMART; START; MOTIVATOR; TELOS; LIST PARSE; ARTSCENE; cARTWORD e ARTSTREAM.

Cada uma destas redes possui suas diferenciações em relação às demais, porém o foco deste estudo se faz na ARTMAP Fuzzy e esta será detalhada com mais atenção no subitem a seguir.

3.2 ARTMAP Fuzzy

Segundo Carpenter e Grossberg (1992) a rede neural ARTMAP Fuzzy possui uma arquitetura capaz de aprendizado de reconhecimento on-line rápido, estável, teste de hipóteses e nomenclatura adaptativa em resposta a fluxos arbitrários de padrões de entrada, seja eles analógicos ou binários.

Ainda segundo Carpenter e Grossberg (1992) esta rede pode aprender, reconhecer e fazer previsões de forma autônoma sobre eventos raros, grandes bancos de dados não estacionários, entre outros. Esta arquitetura é capaz de ajustar automaticamente sua escala de generalização para coincidir com a variabilidade morfológica dos dados.

A rede neural ARTMAP Fuzzy minimiza o erro preditivo e maximiza a generalização usando apenas as informações disponíveis localmente, uma vez que incorpora a regra de aprendizado minmax (CARPENTER; GROSSBERG, 1992).


Esta rede assim como outras pode ter sua arquitetura modificada como exemplo o trabalho de Pourpanah, Lim e Saleh (2016) com um modelo híbrido de ARTMAP Fuzzy e algoritmo genético para classificação de dados e extração de regras.

Outra forma de variação da ARTMAP é a ARTMAP Euclidiana utilizada nos trabalhos de Marchiori *et al.* (2011) aplicada a sistemas de energia elétrica, e Barros *et al.* (2015) modificada com treinamento contínuo para detecção e classificação de distúrbios de tensão em sistemas de energia elétrica.

Segundo Carpenter *et al.* (1992) a rede ARTMAP Fuzzy possui treinamento supervisionado, pois é fornecido um conjunto de padrões de entrada e saída para o sistema, é composta por dois módulos ART denominados ARTa e ARTb, ligados pelo módulo inter-

ART (Figura 24), e seus cálculos são fundamentados na lógica nebulosa, possuindo como principais características sua plasticidade, maleabilidade e estabilidade.

Figura 24 – Arquitetura da rede neural ARTMAP Fuzzy



Fonte: Adaptado de Carpenter *et al.* (1992).

Quanto a seu funcionamento, este é composto de duas fases, a primeira envolve o treinamento e a segunda a previsão. Na primeira etapa são apresentados os padrões de entrada e saída para a rede, seguindo para o processo de normalização da entrada e saída. Após é inicializado as matrizes de pesos, configura-se os parâmetros de treinamento da rede descritos a seguir.

Parâmetro de escolha α ($\alpha > 0$), segundo Carpenter; Grossberg (1992) este parâmetro controla o quão profundo a busca prossegue antes de um nó não confirmado ser escolhido, então à medida que a aprendizagem de uma categoria se auto estabiliza suas entradas codificadas são as que melhor correspondem globalmente ao padrão de entrada e saída.

Ainda segundo Carpenter e Grossberg (1992), a aprendizagem segue de forma estável, com as estradas familiares ativando suas categorias, enquanto as novas entradas desencadeiam buscas adaptativas por melhores categorias até que toda capacidade da rede seja utilizada.

Em seu trabalho intitulado: “*Order of Search in Fuzzy ART and Fuzzy ARTMAP: Effect of the Choice Parameter*”, Georgiopoulos (1996) investigou os efeitos dos parâmetros de escolha, de forma a compreender o porquê e em que ordem às categorias são escolhidas para várias faixas do parâmetro de escolha do módulo Fuzzy ART.

Parâmetro de vigilância ρ ($\rho \in [0,1]$), segundo Carpenter; Grossberg (1992) este parâmetro define o critério de correspondência aceitável, calibrando o quão próximo os padrões de entrada devem estar dos pesos para que ocorra ressonância.

Ainda segundo Carpenter; Grossberg (1992) a baixa vigilância leva a ampla generalização, poucas categorias, e uma vigilância muito elevada leva a baixa generalização e criação de várias categorias (aprendizagem exemplar). Exemplificando, um único sistema ART pode reconhecer categorias abstratas de rostos e cães, bem como rostos e cães individuais (CARPENTER; GROSSBERG, 1992).

Taxa de treinamento β , segundo Granger *et al.* (1996) a taxa de treinamento pode ser configurada para treinamento lento ($0 < \beta < 1$) ou para treinamento rápido ($\beta = 1$). Este parâmetro controla a velocidade de adaptação dos pesos, quando β é igual a 1 não há alteração da matriz de peso depois de cada item de um conjunto de entrada ser apresentado uma vez (CARPENTER *et al.*, 1992).

Incremento do parâmetro de vigilância ε , este incremento ocorre durante uma falha no *match tracking*, quando a categoria buscada não é encontrada é acrescido ao parâmetro de vigilância o valor do incremento de forma a evitar que a mesma categoria seja selecionada novamente. A busca segue até a escolha de uma categoria que satisfaça o *match tracking*. (CARPENTER *et al.*, 1992; CARPENTER; GROSSBERG, 1998; LOPES, 2005).

Codificação do complemento: Segundo Carpenter *et al.* (1992) na ART Fuzzy os pesos adaptativos são monotonicamente não crescentes, o que leva a convergência do aprendizado, mas sem a codificação pode haver a proliferação de categorias, pois muitos pesos adaptativos convergem para zero. Assim a codificação evita a proliferação, normalizando os vetores de entrada e preservando as amplitudes das ativações de recursos individuais. Ainda segundo (82) com a codificação de complemento, o grau de ausência e presença de recursos é representado pelo vetor de peso da categoria.


Segundo Carpenter; Grossberg (1998) este processo dobra o número de componentes de entrada, apresentando as características originais e o complemento do vetor, utilizando informações dentro (recursos consistentemente presentes) e fora (recursos consistentemente ausentes) das células para representar um padrão de entrada.

Após as configurações iniciais da rede ARTMAP Fuzzy descritas nos itens anteriores segue-se o fluxograma apresentado na Figura 25 que ilustra toda a etapa referente ao treinamento e apresenta o equacionamento correspondente a cada uma, enquanto no anexo B é apresentado o algoritmo da rede neural ARTMAP Fuzzy utilizado neste trabalho.

Finalizado o treinamento a rede segue para a etapa de diagnóstico, neste caso realiza-se a classificação ou previsão dos novos vetores de entrada apresentados à rede dependendo de suas programações internas.


Na Figura 26 é apresentado o fluxograma da fase de diagnóstico e o equacionamento correspondente a cada etapa, no item X do apêndice A é apresentado o algoritmo da etapa de diagnóstico.

Figura 25 - Fluxograma ARTMAP Fuzzy



Fonte: Adaptado de Lopes (2005).

Figura 26 – Fluxograma da Fase de Diagnóstico da ARTMAP Fuzzy



Fonte: Elaboração do próprio autor.

Assim, todos os processos resumidamente citados anteriormente compõe a rede ARTMAP Fuzzy e exemplificam as etapas de treinamento e diagnóstico.

3.3 APLICAÇÃO DAS RNA A ONDAS

As aplicações das RNA são as mais diversas e podem ser aplicadas as mais variadas áreas de pesquisa, dentre elas as relacionadas a ondas de impacto, podem-se citar alguns trabalhos que envolvem o uso de redes neurais, dentre eles:

O trabalho de Agrawal e Deo (2004) utilizou rede neural do tipo backpropagation e correlação em cascata para estimar os parâmetros de ondas.

O estudo de Panizzo, De Girolamo e Petaccia (2005) realizou um trabalho experimental com o objetivo de definir formulações empíricas capazes de prever as principais características das ondas geradas por deslizamentos subaeriais. Estas ondas foram caracterizadas usando uma abordagem de análise de wavelet. As novas formulações de

previsão definidas com base no estudo experimental foram testadas usando um modelo de rede neural artificial.

No trabalho de Romano *et al.* (2009) foi utilizado uma rede neural de propagação reversa, com duas camadas escondidas, para previsão das alturas máximas de tsunami. Segundo Romano *et al.* (2009) com base em cenários de tsunami pré-computados como conjuntos de dados de treinamento, a Rede Neural Artificial (RNA) foi usada para a construção de modelos de previsão baseados em valores espaciais de alturas máximas de tsunami e tempos de chegada de tsunami, calculados com o modelo TUNAMI-N2-NUS. Ainda segundo Romano *et al.* (2009): “os testes de validação demonstraram que, com um determinado tamanho e localização do terremoto, o método ANN fornece uma previsão precisa e quase instantânea das alturas máximas do tsunami e dos tempos de chegada para todo o domínio computacional”.

O trabalho de Wei, Wang e Liu (2010) utilizou uma rede backpropagation com uma camada oculta, esta rede foi adotada e modificada com o método de momentum adicional e o fator de aprendizagem auto ajustável para o cálculo da aceleração da onda solitária.

Também o trabalho de Li *et al.* (2014) usa uma rede backpropagation, esta rede foi usada para previsão da destruição de bancos por deslizamentos acumulativos na região do reservatório de três Gargantas, China.

No trabalho de Lopez *et al.* (2014) foi realizado um estudo com o uso de uma rede backpropagation para determinar a altura significativa de ondas longas no Porto Exterior de Ferrol, Espanha.

O estudo de Prahlada; Deka (2015) trabalho com um modelo híbrido wavelet e rede neural artificial de Levenberg Marquardt, com dois métodos diferentes, para prever alturas de onda significativas de séries temporais para lead times de até 48 h. A partir do resultado, verificou-se que o segundo método no modelo wavelet-ANN teve um desempenho melhor do que o primeiro método.

O trabalho de Savitha *et al.* (2017) utilizou a Rede de Alocação de Recursos Mínimos e a Rede de Função Radial de Crescimento e Poda para previsão da altura das ondas do oceano usando dados coletados de 13 estações em três regiões geograficamente distintas, o Golfo do México, a região da Coreia e a região do Reino Unido.

No trabalho de Santos *et al.* (2016) foi utilizado a rede neural artificial ARTMAP Fuzzy para prever o regime de ondas tanto no interior como na entrada do Porto de Sines (Portugal). Seu trabalho é um dos poucos a utilizar a RNA ARTMAP Fuzzy, visto que a maioria dos trabalhos faz utilização da rede neural backpropagation.

A pesquisa de Sánchez *et al.* (2018) realizou um estudo com um modelo matemático que utiliza redes neurais artificiais para a avaliação do potencial de energia das ondas, com base em dados registrados por instrumentação de monitoramento de ondas.

Dentre todos os trabalhos pesquisados pode-se dizer que nenhum destes cobre a lacuna que este trabalho propõe, e o que utiliza a rede ARTMAP Fuzzy, trabalho de Santo *et al.* (2016), aplica a um tipo de onda completamente diferente.

Assim, o uso da rede ARTMAP Fuzzy aplicada à previsão da evolução das alturas máximas, períodos e comprimentos relativos das ondas de impacto, bem como todas as hipóteses influenciadoras do processo de previsão aqui abordadas, se constitui num dos estudos pioneiros nesta área.

3.4 APLICAÇÃO DAS RNA ARTMAP FUZZY A ONDA DE IMPACTO

Para este trabalho foi proposto e utilizado a RNA ARTMAP Fuzzy para previsão dos parâmetros fundamentais das ondas de impacto e a classificação das ondas de impacto segundo seus tipos.

As etapas preliminares contaram com um pré-processamento que envolveu o cálculo dos parâmetros adimensionais e a filtragem dos dados utilizados. Seguindo-se para análise dos parâmetros de treinamento da rede e definição dos vetores de entrada e saída. Na fase de diagnóstico realizou-se a previsão dos parâmetros relativos às ondas de impacto e num segundo momento a classificação das ondas segundo seus tipos. Enquanto a avaliação da metodologia contou com uso do MAPE e do RMSE para identificação da melhor previsão.

Todas as etapas aqui citadas são explicadas em maiores detalhes no capítulo 4 e seus resultados são apresentados no capítulo 5, 6 e 7.

4 METODOLOGIA

Neste capítulo são apresentadas as etapas preliminares a entrada dos dados na rede neural e as etapas subsequentes, compondo a elaboração das matrizes de entrada e saída, bem como seleção dos dados extraídos do trabalho de Huber (1980) (anexo C), a evolução da metodologia de avaliação dos resultados gerados, a filtragem do banco de dados, a seleção dos parâmetros de treinamento e diagnóstico da rede neural e por fim o processo de normalização inicial que gerou a investigação realizada no capítulo cinco.

4.1 PARÂMETROS GOVERNANTES

Segundo Huber (1980) os parâmetros governantes para geração e formação das ondas de impacto são:

- Massa de queda: m
- Composição e formato da queda
- Velocidade de imersão da frente do material deslizando: V_e
- Declive do material deslizando: α
- Profundidade: h
- Caminho de propagação de onda: r, x'
- Direção de propagação de onda: γ
- Declive oposto: β
- Largura do material deslizando no ponto de imersão: b
- Aceleração da gravidade: g
- Densidade da água: ρ
- Densidade do material de queda: ρ_s

Esses parâmetros possuem a seguinte relação segundo Huber (1980):

$$\phi_i(m/b, V_e, \alpha, h, r, \gamma, \beta, g, \rho, \rho_s) = 0 \quad (1)$$

Ainda segundo Huber (1980), estes dez parâmetros apresentados na equação (1) podem ser reduzidos a sete parâmetros adimensionais independentes que resultam nas seguintes relações apresentadas na Figura 27.

Figura 27 – sete parâmetros adimensionais independentes

$\pi_1 = \frac{m}{\rho_s \cdot b \cdot h^2} = \frac{V}{b \cdot h^2} = M$	Volume do material deslizando adimensional
$\pi_2 = \frac{v_E}{\sqrt{g \cdot h}} = F$	Velocidade de imersão adimensional (número de Froude da queda)
$\pi_3 = \alpha$	Declive do ponto de imersão
$\pi_4 = \frac{r}{h}$	Caminho de propagação relativo (Parâmetros de posição do ponto de medição do eixo)
$\pi_5 = \gamma$	Direção de propagação da onda
$\pi_6 = \beta$	Inclinação do banco oposto
$\pi_7 = \frac{\rho_s}{\rho}$	Razão de densidade de material de queda / água

Fonte: Adaptado de Huber (1980).

Para Huber (1980) esses parâmetros estão correlacionados (Figura 28) e podem ser reduzidos a cinco parâmetros (Figura 29), ao se considerar que as rochas possuem densidade praticamente inalterável e a onda se propaga apenas na direção x, como exemplo um canal.

Figura 28 – Correlação dos parâmetros

$$\Phi_i (\pi_1, \pi_2, \pi_3, \pi_4, \pi_5, \pi_6, \pi_7) = 0$$

$$\Phi_i (M, F, \alpha, \frac{r}{h}, \gamma, \beta, \frac{\rho_s}{\rho}) = 0$$

Fonte: Huber (1980).

Figura 29 – Cinco parâmetros finais

$$\Phi_i (M, F, \alpha, \frac{x'}{h}, \beta) = 0$$

Fonte: Huber (1980).

Outros parâmetros para avaliar uma onda, segundo Huber (1980), são:

- Altura relativa de onda (H_i / h);
- Comprimento de onda relativo (λ / h);
- Inclinação da onda (H_i / λ);


- Número Ursell ($U = \lambda^2 H / h^3$);
- Velocidade de propagação da onda adimensional ($F_w = c_a / \sqrt{gh}$) (Froude da onda);
- Altura relativa da onda inicial (H_a / h)
- Período da onda ($T = T_i \sqrt{g/h}$)

Onde:

λ : Comprimento de onda;

O canal experimental consistia de um canal horizontal de alvenaria conforme a Figura 30 cujas dimensões eram 30,33m x 0,50 m x 0,50 m. A rampa tinha declividade variável entre 28° a 60° e o banco oposto tinha declividade de 1:12 a 1:0, com sensores capacitivos nas posições x'/h : 5, 10, 15 e 20.

Figura 30 – Canal de medição, seção longitudinal e transversal com faixa e margem oposta



Fonte: Adaptado de Huber (1980).

4.1.1 Seleção de dados

O trabalho de Huber (1980) realizou diversos testes e os catalogou em tabelas conforme o tipo de dados coletado (anexo B), destas tabelas é extraído os dados deste

trabalho. Nas tabelas no anexo B, que fornecem os dados da altura relativa também são apresentados às informações sobre a profundidade, a velocidade de imersão, a massa do bloco, a inclinação do banco oposto e a inclinação do material deslizante, estas tabelas estão separadas de acordo com a distância relativa (x'/h).

Também são apresentadas tabelas no anexo B os dados referentes ao período relativo ($T\sqrt{g/h}$) e ao comprimento relativo (λ/h), bem como a classificação das ondas de acordo com quatro tipos: grupo de ondas sinusoidais (A), grupo de ondas de caráter disperso, uma onda sinusoidal a cnoidal domina a frente de propagação (B), uma onda mais rápida e mais alta que a seguinte, com forma cnoidal ou de onda solitária (C), uma onda solitária (D).

No trabalho de Huber (1980) também é possível encontrar informações referentes à influência do volume de deslocamento, inclinação de onda, tipo de onda pelo número de Ursell, velocidade de propagação da onda, correlação entre a velocidade de propagação e a altura relativa, bem como diagramas para classificar os tipos de ondas de acordo com suas características.

Ainda no trabalho de Huber (1980) existem dados relativos ao experimento tridimensional, porém este trabalho se atentou aos dados bidimensionais.

Os ensaios de Huber (1980) foram executados com as seguintes variações:

- Massa do material deslizante: 5 kg; 15 kg; 30 kg e 50 kg
- Declividade da rampa do material deslizante: 28°; 30°; 35°; 40°; 45°; 60°
- Declividade do banco oposto: 1:0; 1:4; 1:8; 1:12
- Velocidade de impacto: 1 m/s; 2 m/s; 3 m/s e 4 m/s
- Profundidade: 0,12 cm; 0,18 cm; 0,27 cm e 0,36 cm

Assim foram utilizados os dados referentes à evolução das alturas, períodos, comprimentos relativos e classificação das ondas. Após a extração dos dados das tabelas, foram calculados: o volume adimensional (M) e o número de Froude de impacto (F) conforme as equações (2) e (3).

$$M = \frac{\text{massa}}{(\rho_s) \cdot b \cdot h^2} \quad (2)$$

Em que:

ρ_s = densidade do material de suporte;

b = largura do canal;

h = altura da lâmina d'água no canal;

$$F = \frac{V_e}{\sqrt{g*h}} \quad (3)$$

Em que:

V_e = Velocidade de imersão;

g = aceleração da gravidade;

h = altura da lâmina d'água no canal;

Observa-se que a inclinação da trajetória (α) foi apresentada a rede em função do seu seno em radianos ao invés de apresenta-la em graus.

4.2 ELABORAÇÕES DAS MATRIZES DE ENTRADA E SAÍDA

Para determinação de como os dados deveriam ser apresentados à rede neural foram realizadas análises preliminares da seguinte forma:

- I- Apresentou-se toda coletânea de dados extraídos de Huber (1980);
- II- Apresentaram-se apenas os dados referentes a uma das quatro alturas de lâmina d'água do canal;

Porém independente do caso, a rede não conseguia realizar a previsão, necessitando ainda de ajustes na forma de apresentação dos dados, foi observado que isto indicou a grande importância que compreender o funcionamento da rede e sua forma de interpretação dos fenômenos tiveram frente à resposta fornecida pela rede. As primeiras tentativas contemplavam os dados isoladamente e não como uma evolução ao longo do canal, tal qual o fenômeno físico, assim tal abordagem não apresentou êxito. As primeiras tentativas se deveram a forma como os dados estavam apresentados no trabalho de Huber (1980).

Após estudos mais aprofundados e maior entendimento do problema em questão, chegou-se a conclusão que os dados deveriam ser apresentados em sua totalidade, ou seja, todos os dados referentes a um ensaio eram apresentados à rede conforme explanado a seguir.

A entrada dos dados na rede foi feita de maneira matricial, sendo cada ensaio representado por um vetor e o mesmo foi feito para a saída da rede. Assim foram divididas as análises em etapas, a primeira fazendo referência a apenas os dados relativos à evolução das ondas de impacto, a segunda fazendo referência aos dados de períodos e a terceira referente aos dados de comprimentos das ondas de impacto.

Assim entende-se que a matriz de entrada possui um conjunto de N vetores que possui valor igual à quantidade de ensaios considerados, formando uma matriz de N linhas por me

colunas, onde me representa o numero de parâmetros de ensaio considerados para compor cada um dos vetores, resultando na matriz apresentada pela equação (4).

$$\text{Matriz de entrada } N_{xme} = [X_1; X_2; X_3; \dots; X_N]; \quad (4)$$

Em que:

X_i : matriz de entrada; $X \in R^{N_{xme}}$;

N: número de ensaios das ondas de impacto;

me: número parâmetros considerados das ondas de impacto ;

De maneira análoga o mesmo ocorre para a matriz de saída, porém está é composta de N linhas e ms colunas, onde ms é igual ao número de pontos de medição ao longo do canal fixado em 5, assim a matriz de saída é representada pela equação (5).

$$\text{Matriz de saída } N_{xms} = [Y_1; Y_2; Y_3; \dots; Y_N]; \quad (5)$$

Em que:

Y_i : matriz de saída; $Y \in R^{N_{xms}}$;

N: número de ensaios das ondas de impacto;

ms: número de pontos de medição ao longo do canal (ms = 5);

Assim os vetores da matriz de entrada foram divididos conforme as equações (6, 16,17 e 18) enquanto as matrizes de saída foram divididas segundo as equações (7, 8 e 9) apresentadas nos itens a seguir:

I- Para o caso da evolução das alturas de onda, temos:

$$X_i = [h, F, M, \alpha, \beta]; \quad i \in [1; N]; \quad (6)$$

Em que:

h: altura da lâmina d'água do canal;

F: número de Froude;

M: volume adimensional;

α : ângulo de inclinação da trajetória;

β : ângulo de inclinação da praia;

N: número de ensaios das ondas de impacto;

$$Y_i = [H/h_1, H/h_2, H/h_3, H/h_4, H/h_5]; \quad i \in [1; N]; \quad (7)$$

Em que:

H/h_i : altura de onda relativa;

- II- Para o caso dos períodos relativos de onda, a matriz de saída sofre alteração, assim temos:

$$Y_i = [T_1\sqrt{(g/h_1)}, T_2\sqrt{(g/h_2)}, T_3\sqrt{(g/h_3)}, T_4\sqrt{(g/h_4)}, T_5\sqrt{(g/h_5)}]; \quad i \in [1; N]; \quad (8)$$

Em que:

$T_i\sqrt{(g/h_i)}$: período de onda relativo;

g : aceleração da gravidade;

- III- Para o caso dos comprimentos relativos de onda, a matriz de saída sofre alteração, assim temos:

$$Y_i = [\lambda_1/h_1, \lambda_2/h_2, \lambda_3/h_3, \lambda_4/h_4, \lambda_5/h_5] \quad i \in [1; N]; \quad (9)$$

Em que:

λ_i/h_i : comprimento relativo de onda;

As matrizes acima foram criadas para cada uma das quatro alturas de lâmina d'água do canal: $h=0,12$ metros; $h=0,18$ metros; $h=0,27$ metros e $h=0,36$ metros.

Após essas etapas de tratamento dos dados, foram realizados novos testes e verificado a capacidade da rede ARTMAP Fuzzy de prever os parâmetros discutidos anteriormente.

Neste momento a RNA já apresentou um grande salto, os resultados que antes divergiam do esperado, agora se apresentavam próximos ao fenômeno físico observado por Huber (1980). Desde ponto em diante foram realizadas análises para melhorar a previsão.

No início foi utilizado apenas o valor do MAPE para avaliação da previsão. Observou-se que a RNA ainda precisava de alguns ajustes para fornecer valores mais precisos, nesse caso um processo de repetição do algoritmo da RNA e um critério de seleção, na busca pelas melhores previsões, era necessário.

Introduziu-se o processo de randomização das linhas das matrizes de entrada e de saída, pois se entende que a entrada dos vetores de maneira sequencial é apenas uma das possíveis formas de apresentação dos dados a RNA e randomizar o processo leva a uma gama praticamente infinita de resultados.

Foram repetidos todos os testes 500 vezes, ou seja, foram testadas 500 ordenações diferentes de apresentação dos vetores de entrada e saída. Dentre as 500 buscou-se a melhor previsão com base na avaliação do menor MAPE, neste ponto a rede indicou a necessidade de um melhor critério de seleção, pois ao se analisar as previsões pode-se observar que um menor valor de MAPE não estava necessariamente associado a uma melhor previsão. Assim criou-se um critério de avaliação da metodologia conforme explanado a seguir.

4.3 CRITÉRIOS DE AVALIAÇÃO DA METODOLOGIA

Para avaliação da metodologia na busca pelo critério de seleção ideal foram realizadas análises com MAPE e acrescentaram-se análises com o RMSE, uma vez que apenas o MAPE não era suficiente para a seleção da melhor previsão.

Neste ponto cabe uma observação de que para fins de comparação foram separados parte dos dados fornecidos a rede, assim apresentava-se uma porcentagem para o treinamento e outra para o diagnóstico, para fins de cálculo do MAPE e do RMSE conforme as equações (10) e (11):

Cálculo do MAPE e do RMSE de cada ensaio:

$$MAPE_{nd} = [(\sum_{i=1}^{ms} |SR_i - SP_i| / SR_i) / ms] * 100 \quad (10)$$

$$RMSE_{nd} = [\sum_{i=1}^{ms} (SR_i - SP_i)^2 / ms]^{1/2} \quad (11)$$

Em que:

nd: número de entradas apresentadas para a fase de diagnóstico, $nd \in [1; 15]$;

SR: Valor obtido no experimento;

SP: Valor obtido na previsão;

Assim, para seleção da melhor previsão, foram realizadas diversas análises isoladas, utilizando-se os seguintes critérios:

I- O menor MAPE entre os ensaios;

II- O menor MAPE médio dos ensaios;

III- O menor RMSE entre os ensaios

IV- O menor RMSE médio dos ensaios.

Em nenhuma das análises isoladas foi obtida uma previsão satisfatória, pois apesar dos valores do MAPE e do RMSE serem baixos, em alguns casos, graficamente se observou que parte das previsões divergia da resposta esperada.

Quando se utilizou o menor MAPE entre os ensaios, observou que mesmo que o valor do MAPE fosse baixo, não representava a melhor previsão da rede, tal fato foi observado graficamente e numericamente.

Alterando o critério para o menor MAPE médio dos ensaios, observou-se que o mesmo ocorria, um menor MAPE médio não representava a melhor previsão.

Modificando novamente o critério de escolha para o menor valor do RMSE entre os ensaios, observou-se que as curvas de previsão correspondiam em termos comportamentais às curvas reais, porém não estavam sobrepostas, indicando que mesmo com um valor baixo de RMSE não era critério suficiente para escolha da melhor previsão.

Numa nova tentativa, modificou-se o critério de escolha para o menor RMSE médio dos ensaios, porém a mesma situação se repetiu.

Assim para avaliar da melhor forma a resposta fornecida pela rede optou-se por associar o MAPE médio e o RMSE médio. A utilização do termo “médio” refere-se à média entre todos os MAPEs ou RMSEs obtidos, exemplificando: Se forem realizadas 50 previsões de comprimentos, estas 50 serão comparadas com a resposta esperada, no caso obtido pelos ensaios de (1), e calculados os valores de MAPE e RMSE para cada uma das 50 previsões e então calculados os valores do MAPEs ou os valores dos RMSEs médios conforme equação (12) e (13).

$$MAPE_{médio} = (\sum_{i=1}^{nd} MAPE_{nd})/nd \quad (12)$$

$$RMSE_{médio} = (\sum_{i=1}^{nd} RMSE_{nd})/nd \quad (13)$$

Em que:

nd: 50 (para este exemplo em questão)

Tal processo é para apenas uma execução do algoritmo da rede neural, repetindo-se mais 500 vezes a execução da rede, devido à randomização dos vetores de entrada e saída conjuntamente, na busca de uma melhor previsão.

As análises isoladas davam indicativos da possibilidade de existir uma previsão melhor entre os 500 testes, assim criou-se um segundo critério de avaliação, agora entre cada uma das execuções do algoritmo da rede neural. Este novo critério é a análise do conjunto entre o MAPE e o RMSE médios conforme equação (14).

$$\text{Melhor previsão} = \min \text{MAPE médio} \& \min \text{RMSE médio} \quad (14)$$


Observa-se que para realização da seleção da melhor previsão é armazenado, a cada execução, o menor valor de MAPE médio e RMSE médio em conjunto, entre a atual e a anterior já armazenada. No momento inicial a melhor previsão é a primeira execução, ou seja, na primeira análise a melhor previsão é igual a inicial e a partir da segunda análise, a melhor previsão obedece à equação (15).

$$\text{Melhor previsão}_{\text{armazenada}} = \text{menor}(\text{Melhor previsão}_{i-1} \& \text{Melhor previsão}_i) \quad (15)$$

Foram analisados casos maiores que 500 execuções, mas devido ao tempo de processamento e considerando a robustez da rede, 500 repetições mostraram-se suficientes.

Na Figura 31 é apresentado resumidamente o processo de avaliação da metodologia.

Figura 31 – Etapas de avaliação da metodologia



Fonte: Adaptado de Oliveira *et al.* (2020).

4.4 FILTRAGEM DOS DADOS

O banco de dados de Huber (1980) é composto de 636 ensaios considerando as quatro alturas de lâmina d'água (h), sendo 108 ensaios para $h=0,12$ m, 176 ensaios para $h=0,18$ m, 176 ensaios para $h=0,27$ m e 176 ensaios para $h=0,36$ m. Entre esses ensaios observou-se que em alguns não foi observado a formação da onda de impacto e em outros casos havia dificuldade de verificar o número no manuscrito, nesses casos optou-se pela remoção dos ensaios do banco. Posterior às análises iniciais houve indícios de dados com comportamentos muito atípicos, devido à dificuldade para comprovação das razões, optou-se pela retirada dos mesmos. O comportamento atípico desses dados foi verificado graficamente, seguido de uma análise geral de todos os parâmetros. Uma última filtragem foi realizada com a retirada de informações que tivessem apenas dados de altura relativa ou que não tivessem todas as medições, tanto de altura relativa, quanto de período e comprimento. Com o processo de filtragem dos dados, o banco foi reduzido para **532** ensaios contendo a evolução das alturas; períodos relativos e comprimentos de onda, dos quais uma porcentagem foi utilizada para treinamento e outra para previsão.

4.5 ALTERAÇÕES NA COMPOSIÇÃO DA MATRIZ DE ENTRADA

A matriz de entrada é dada pela equação (4) que por sua vez tem as suas linhas formadas por vetores dados pela equação (6). Para início dos testes foi utilizada a matriz de entrada sem alteração no tamanho dos vetores de entrada e considerando apenas a altura da lâmina d'água do canal igual a 0,12 metros. Após essa etapa inicial, foram realizados estudos alterando a quantidade de informação apresentado a rede neural, da seguinte forma:

No segundo teste, o vetor de entrada era dado conforme a equação (16):

$$X_i = [F, M, \alpha, \beta]; \quad i \in [1; N]; \quad (16)$$

No terceiro teste, o vetor de entrada era dado conforme a equação (17):

$$X_i = [F]; \quad i \in [1; N]; \quad (17)$$

No quarto teste, o vetor de entrada era dado conforme a equação (18):

$$X_i = [M]; \quad i \in [1; N]; \quad (18)$$

Observa-se que foram realizados também mais dois testes com os vetores de entrada compostos conforme as equações (19) e (20):

$$X_i = [\alpha]; \quad i \in [1; N]; \quad (19)$$

$$X_i = [\beta]; \quad i \in [1; N]; \quad (20)$$

Porém não se obteve bons resultados nestes dois últimos casos, devido ao fato da informação ser insuficiente para a rede, por isso não estão apresentados os resultados dessas análises nesse trabalho.

Com relação aos parâmetros de treinamento da ARTMAP Fuzzy foram utilizados os valores presentes na Tabela 1, valores estes escolhidos após sequencias de testes, observando que além da rede apresentar bons resultados estes valores permitiram maior maleabilidade a rede ao invés de aumentar o grau de exigência. Valores abaixo destes causavam pequenas divergências e acima foi feito um estudo separado com os ensaios referentes à altura de lamina d'água $h=0,12$ m a fim de verificar a influência dos parâmetros de treinamento na previsão da rede neural.

Tabela 1 – Parâmetros de treinamento da RNA

Parâmetro	Valor
α	0,10
β	1,00
ρ_a	0,50
ρ_b	1,00
ρ_{ab}	1,00
ρ_d	0,50
ε	0,05

Fonte: Oliveira *et al.* (2020).

Acrescentou-se ao estudo a influência que o processo de normalização provocava na previsão realizada pela rede, sua metodologia, resultados e discussões são apresentados no capítulo 6. Os resultados e discussões referentes à previsão dos parâmetros das ondas de impacto são apresentados no capítulo 5 a seguir.

5 PREVISÃO – ARTMAP FUZZY

Num primeiro momento foram realizadas as programações da rede ARTMAP Fuzzy, para analisar as características das ondas de impacto, evolução das alturas máximas, período e comprimentos. Num segundo momento, após comprovação da capacidade da RNA de prever os parâmetros característicos das ondas de impacto, foram realizados testes de normalizações, para verificar a influência das mesmas no processo de previsão, descritas no capítulo 6. Em conjunto com a análise da influência da normalização foi aplicado a mesma metodologia para previsão dos parâmetros relativos a *roll waves*, compondo um segundo estudo dentro deste. E num terceiro momento foram realizados testes de classificação das ondas, descritas no capítulo 7.

5.1 TESTES ESTUDADOS

Para as três situações, evoluções das alturas máximas, períodos e comprimentos relativos, foram realizados previsões separadamente por altura de lâmina d'água, da seguinte forma:

- $h=0,12$ m foram utilizados 158 dados sem filtragem e 75 dados filtrados;
- $h=0,18$ m foram utilizados 144 dados filtrados;
- $h=0,27$ m foram utilizados 155 dados filtrados;
- $h=0,36$ m foram utilizados 158 dados filtrados;

Para este teste foram utilizados 50% dos dados para treinamento e 50% para previsão, os parâmetros de treinamento da rede foram mantidos conforme Tabela 1 e a matriz de entrada foi variada conforme subitem 4.2 do Capítulo 4 e equações (6), (16), (17) e (18). Cada um dos testes foi realizado com 500 repetições e a matriz de saída variou conforme as equações (7), (8) e (9), enquanto a normalização utilizada foi a norma segundo Carpenter *et al.* (1992).

Desta forma tem-se um total de 17 conjuntos de testes, variando entrada e saída e os resultados referentes a cada uma destas variações, bem como os MAPEs e RMSEs obtidos são apresentados a seguir.

Nas Tabelas de 2 a 4 são apresentados os MAPEs obtidos na melhor previsão bem como seus RMSEs e nas Figuras de 32 e 43 apresentam-se dois casos para cada um dos três parâmetros: evolução das alturas, períodos e comprimentos relativos.

No Apêndice B são apresentados os resultados obtidos pela rede, referentes ao maior e menor MAPEs e seus respectivos RMSEs, com os dados tabelados e ilustrados graficamente, para a melhor previsão selecionada pelo critério apresentado no item 4.3, bem como uma explicação mais detalhada de cada um dos casos utilizados nas previsões.

5.2 EVOLUÇÃO DAS ALTURAS

No caso da altura de lâmina d'água $h=0,12$ m, foram utilizadas 4 matrizes de entradas com os dados filtrados e realizado um teste sem a filtragem dos dados cuja matriz de entrada é dada pela equação (6), totalizando 5 testes, repetidos 500 vezes.

Para as demais alturas de lâmina d'água, $h=0,18$ m, $h=0,27$ m e $h=0,36$ m, foram utilizadas 4 matrizes de entrada com os dados filtrados, também foram repetidos os testes 500 vezes. A combinação das matrizes de entrada e saída totalizou 12 conjuntos de testes.

Assim têm-se as seguintes condições:

- Sem filtragem dos dados (S/F.) – vetores da matriz de entrada dada pela equação (6) e da matriz de saída dada pela equação (7);
- Com filtragem dos dados (C.F.) – vetores da matriz de entrada dada pela equação (6) e da matriz de saída dada pela equação (7);
- Com filtragem sem o valor da altura de lâmina d'água (C.F. s/h) – vetores da matriz de entrada dada pela equação (16) e matriz de saída dada pela equação (7);
- Com filtragem e apenas o volume adimensional (C.F. M) – vetores da matriz de entrada dada pela equação (18) e da matriz de saída dada pela equação (7);
- Com filtragem e apenas o número de Froude (C.F. Fr) – vetores da matriz de entrada dada pela equação (17) e da matriz de saída dada pela equação (7);

Quando esta sequência estava completa os vetores da matriz de saída eram substituídos segundo equação (8) referente ao período relativo e depois segundo a equação (9) referente ao comprimento relativo.

Após o primeiro resultado sem filtragem para $h=0,12$ m, foi observado que existiam dados conflitantes ou que poderiam conter erro de preenchimento dentro do banco de dados, assim após análise de cada um dos vetores foram removidos aqueles que indicavam algum problema na informação. Da mesma forma foi realizado esta análise para as demais alturas de lâmina d'água, de forma que do total de 636 dados reduziu-se para 532 dados.

Na Tabela 2 são apresentados os resultados da melhor previsão de cada um dos 17 testes com a matriz de saída referente a evolução das alturas máximas, seus respectivos MAPEs e RMSEs.

Tabela 2 – MAPEs e RMSEs relativos à melhor previsão para evolução das alturas máximas relativas


Altura do canal	Evolução das alturas máx.	MAPE mín.	RMSE	MAPE médio	MAPE máx.	RMSE
h=0,12m	S/ F.	0,3297	0,0016	6,55	36,75	0,1313
	C.F.	0,3294	0,002	5,39	20,59	0,0405
	C.F. s/h	0,6087	0,0037	5,29	16,04	0,0484
	C.F. M	0,2494	0,0006	5,12	16,20	0,0554
	C.F. Fr	0,6530	0,0023	7,70	17,41	0,1036
h=0,18m	C.F.	0,0912	0,0003	6,24	18,49	0,0553
	C.F. s/h	0,3017	0,0003	6,27	19,20	0,0745
	C.F. M	0,3511	0,0008	9,74	33,38	0,0575
	C.F. Fr	0,1204	0,0001	9,77	41,77	0,0602
h=0,27m	C.F.	0,1306	0,0003	8,59	28,71	0,0217
	C.F. s/h	0,1397	0,0005	9,06	49,52	0,0421
	C.F. M	0,1405	0,0002	10,18	47,66	0,0403
	C.F. Fr	1,5743	0,0026	11,20	41,51	0,0352
h=0,36m	C.F.	0,2885	0,0003	9,50	37,08	0,0193
	C.F. s/h	0	0	8,83	37,08	0,0193
	C.F. M	0	0	8,53	32,26	0,0310
	C.F. Fr	0,6383	0,0007	11,14	74,89	0,0445

Fonte: Elaboração do próprio autor.

Da Tabela 2 observa-se que no caso de h=0,12 m o melhor resultado, ao se analisar os MAPEs máximos, médios e mínimos, bem como seus respectivos RMSE, é o referente a matriz de entrada composta apenas pelos dados do volume adimensional, este resultado é apresentado na Figura 32 (a) e (b).

Pode-se observar na Figura 32 (a) que a rede realiza uma boa previsão tendo MAPE mínimo com valor de 0,2494% e o RMSE próximo a zero. Na Figura 32 (b) referente ao maior valor obtido pela rede, em termos de MAPE, com valor de 16,20% pode-se observar que a rede subestima os dois primeiros pontos e superestima os três finais, porém entende o comportamento dos dados, neste caso o RMSE ficou mais próximo de 0,1.

Figura 32 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F.M




Fonte: Elaboração do próprio autor.

Quando se analisa da mesma forma a altura de lâmina d'água $h=0,18$ m, a melhor resposta foi obtida para a matriz de entrada com todos os dados, dada pela equação (6). Na Figura 33 (a) e (b) é apresentado este resultado.

Observando a Figura 33 (a) verifica-se que a rede prevê com sucesso os valores referentes a evolução das alturas máximas, tendo MAPE mínimo de 0,0912% e seu RMSE próximo a zero, enquanto na situação apresentada na Figura 33 (b) o MAPE máximo foi de 18,49% e o RMSE se aproximou de 0,1. Neste caso a rede superestimou os dois primeiros pontos e subestimou os três últimos.

Figura 33 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F.



Fonte: Elaboração do próprio autor.


Para a altura de lâmina d'água $h=0,27$ m, a melhor resposta também foi obtida para a matriz de entrada com todos os dados, dada pela equação (6). Na Figura 34 (a) e (b) é apresentado este resultado.

Na Figura 34 (a) pode-se observar, novamente, que a rede prevê com sucesso os dados referentes a evolução das alturas máximas, tendo MAPE de 0,1306% e RMSE próximo a zero, enquanto na Figura 34 (b) se observa o caso do maior MAPE obtido na previsão, com valor de 28,71% e RMSE de 0,0217.

Cabe observar que devido ao comportamento dos dados experimentais o valor do MAPE máximo ficou mais elevado que nos demais casos, uma vez que ao se observar o gráfico pode-se compreender que este valor deve-se a divergência no terceiro ponto na profundidade relativa de 20.

Nos demais a rede se aproximou muito dos dados experimentais, reforçado pelo valor do RMSE que ao invés de 0,05, como os dois anteriores, é de 0,02, ou seja, a previsão se aproximou mais dos dados experimentais. Observa-se que esta análise não seria possível caso fosse considerado apenas o valor do MAPE.

Figura 34 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F.




Fonte: Elaboração do próprio autor.

Por fim para o caso com a altura de lâmina d'água $h=0,36$ m, a melhor resposta foi obtida para a matriz de entrada composta apenas pelos dados do volume adimensional, dada pela equação (18). Na Figura 35 (a) e (b) é apresentado este resultado.

Na Figura 35 (a) é apresentado o caso do menor MAPE obtido nesta previsão, com valor de 0% e RMSE também zero, ou seja, a previsão da rede e os dados experimentais coincidiram em todos os pontos. No caso do maior MAPE, com valor de 32,26% e RMSE de 0,0310, a rede subestimou os dois primeiros e superestimou os dois últimos, porém ela compreende o comportamento dos dados e ao analisar o MAPE médio de 8,53% observa-se que a maioria das previsões se aproximou do MAPE mínimo, ou seja, a rede realizou boas previsões.

Figura 35 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F. M



Fonte: Elaboração do próprio autor.

Os resultados mostraram a capacidade da rede em interpretar as informações a ela fornecidas, bem como sua capacidade em fornecer boas previsões da curva da evolução das alturas máximas em cada uma das situações a ela apresentada.

Seguiu-se para os testes com a matriz de saída composta pelos dados referentes ao comprimento relativo.

5.3 COMPRIMENTOS RELATIVOS

Para cada uma das alturas de lâmina d'água, $h=0,12\text{m}$, $h=0,18\text{ m}$, $h=0,27\text{m}$ e $h=0,36\text{ m}$, foram utilizadas 3 matrizes de entrada com os dados filtrados, sendo que cada um dos testes foi repetido 500 vezes.

Para análise dos comprimentos de ondas optou-se por não realizar os testes sem filtragem, por já se saber que a existência de dados divergentes modifica sensivelmente a rede.

Optou-se por não realizar a análise com todos os parâmetros menos a altura da lâmina d'água, conforme equação (16), isto se deve ao fato de já se concluir, por meio das análises anteriores, que a presença dessa informação ou não, não modificava significativamente os resultados, isto nos casos de análise separada conforme os estudos deste capítulo, já no caso em que se faz uso de todas as informações é necessário fornecer a rede o valor da lamina d'água de cada ensaio, como ocorre no capítulo 6.

Apenas para efeitos comparativos foram realizados os testes também com a matriz de entrada com todos os dados de ensaio, dada pela equação (16).

Na Tabela 3 são apresentados os resultados da melhor previsão de cada um dos 12 testes com a matriz de saída referente ao comprimento relativo, seus respectivos MAPEs e RMSEs.

Tabela 3 – MAPEs e RMSEs relativos à melhor previsão para o comprimento relativo

Altura do canal	Comprimento relativo	MAPE mín.	RMSE	MAPE médio	MAPE máx.	RMSE
h=0,12m	C.F.	0,3004	0,0315	5,36	21,86	3,1205
	C.F. M	0,3384	0,0405	5,45	15,62	1,5591
	C.F. Fr	0,2822	0,0286	5,98	18,67	3,4456
h=0,18m	C.F.	0,2378	0,0406	5,81	26,28	2,9438
	C.F. M	0,5082	0,0657	6,71	25,17	3,7403
	C.F. Fr	0,2673	0,0456	6,49	21,30	2,7636
h=0,27m	C.F.	0	0	4,22	17,53	1,9945
	C.F. M	0,1623	0,0264	3,79	13,44	1,6765
	C.F. Fr	0,1140	0,0148	3,87	15,04	2,9059
h=0,36m	C.F.	0,1805	0,0223	4,85	21,49	2,2561
	C.F. M	0,1665	0,0218	3,62	14,43	2,3819
	C.F. Fr	0,1625	0,0254	3,92	14,87	2,3154

Fonte: Elaboração do próprio autor.


Quando se analisa os três MAPEs e os RMSEs da Tabela 3 pode-se observar que para h=0,12 m o melhor resultado é o referente a matriz de entrada apenas com os dados referentes ao volume adimensional, visto que possuem menores valores de MAPE máximo e RMSE, enquanto MAPE médio e mínimo são muito semelhantes.

Na Figura 36 (a) é apresentado o resultado referente ao menor MAPE obtido nesta previsão, com valor de 0,3384% e RMSE próximo a 0,1, neste caso observa-se que a rede prevê com sucesso os dados experimentais.

Na Figura 36 (b) é apresentado o resultado referente ao maior MAPE com valor de 15,62% e RMSE 1,559, neste caso a rede subestima os três primeiros pontos e subestima os dois últimos. Com relação ao RMSE a faixa de valores varia, antes era entre zero e 0,1, situação da evolução das alturas máximas, e agora entre 0,1 e 4,0, comprimento relativo. Assim para correta análise deve-se observar a nova faixa de valores.

Nesta previsão o MAPE médio ficou em 5,45% indicando que, novamente, as previsões da rede se aproximam mais do MAPE mínimo que do máximo.

Figura 36 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F. M




Fonte: Elaboração do próprio autor.

Analisando os três MAPEs e os RMSE para $h=0,18$ m, a matriz, com os dados filtrados, dada pela equação (16) é a que apresenta a melhor resposta, quando se compara MAPE médio e mínimo, esta normalização se sobressai. Na Figura 37 (a) e (b) é apresentado este resultado.

Na Figura 37 (a), referente ao menor MAPE com valor de 0,2378% e RMSE próximo de 0,1, observa-se que a rede prevê com sucesso os dados experimentais referentes ao comprimento relativo. Na Figura 37 (b), referente ao maior MAPE com valor de 26,28% e RMSE próximo a 3, pode-se observar que a rede superestimou os três primeiros pontos e subestimou os dois últimos, neste caso os dados experimentais estavam mais próximos a uma reta que a uma curva, podendo explicar a divergência.

Analisando o MAPE médio, com valor de 5,81%, pode-se observar que a maioria das previsões da rede se aproximou do MAPE mínimo, ou seja, se aproximaram dos dados experimentais, indicando que esta previsão foi muito boa.

Figura 37 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F.




Fonte: Elaboração do próprio autor.

Para o caso $h=0,27$ m a melhor resposta é referente a matriz de entrada com apenas os dados do volume adimensional, sobressaindo em termos de MAPE médio e máximo, bem como o RMSE respectivo ao MAPE máximo. Na Figura 38 (a) é apresentada a melhor previsão da rede para o comprimento relativo, com valor de MAPE de 0,1623% e RMSE próximo a 0,1. Na Figura 38 (b) é apresentado o resultado referente ao maior MAPE com valor de 13,44% e RMSE próximo a 1,5. A rede subestimou os três primeiros pontos e superestimou os dois últimos, porém ela compreende o comportamento dos dados.

Analisando o MAPE médio com valor de 3,79% pode-se compreender que a maioria das previsões realizadas pela rede se aproxima da melhor previsão, ou seja, da referente ao MAPE mínimo, indicando que este conjunto de previsões foi muito bom.

Figura 38 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F. M




Fonte: Elaboração do próprio autor.

Por fim para o caso $h=0,36$ m, a melhor resposta também é a referente a matriz de entrada com apenas os dados do volume adimensional, sobressaindo em todos os três MAPEs. Na Figura 39 (a) é apresentada a melhor previsão da rede para o comprimento relativo, com valor de MAPE de 0,1665% e RMSE próximo a 0,1. Na Figura 39 (b) é apresentado o resultado referente a previsão onde a rede mais divergiu, com MAPE com valor de 14,43% e RMSE próximo a 2,5. A rede, como no caso anterior, subestimou os três primeiros pontos e superestimou os dois últimos, porém ela compreende o comportamento dos dados.

Analisando o MAPE médio com valor de 3,62% pode-se compreender que a maioria das previsões realizadas pela rede se aproxima da melhor previsão, ou seja, da referente ao MAPE mínimo, indicando que este conjunto de previsões foi muito bom.

Figura 39 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F. M



Fonte: Elaboração do próprio autor.

5.4 PERÍODOS RELATIVOS

Seguiu-se para a última bateria de testes, agora relativos à previsão dos períodos de onda, foram analisadas as três matrizes de entrada, dadas pelas equações (6), (17) e (18), com todos os dados, com apenas o volume adimensional e com apenas o número de Froude na matriz de entrada, respectivamente. Seguiu-se a mesma sequência de testes realizados anteriormente com a evolução das alturas e com o comprimento relativo de onda.

Na Tabela 4 são apresentados os resultados da melhor previsão de cada um dos 12 testes com a matriz de saída referente ao período relativo, seus respectivos MAPEs e RMSEs.

Tabela 4 – MAPEs e RMSEs relativos à melhor previsão para o período relativo

Altura do canal	Período relativo	MAPE mín.	RMSE	MAPE médio	MAPE máx.	RMSE
h=0,12m	C.F.	0,6123	0,0735	5,45	17,75	3,0429
	C.F. M	0,3570	0,0538	5,15	14,66	2,3312
	C.F. Fr	0,2109	0,0190	5,05	15,13	2,4926
h=0,18m	C.F.	0,1823	0,0210	5,14	14,73	1,8600
	C.F. M	0,2139	0,0285	6,19	25,45	3,3089
	C.F. Fr	0,2427	0,0344	6,52	24,72	2,5776
h=0,27m	C.F.	0,0273	0,0032	3,72	17,46	1,9118
	C.F. M	0,0889	0,0129	3,78	13,55	1,6634
	C.F. Fr	0,1702	0,0264	3,97	16,16	2,6390
h=0,36m	C.F.	0,0990	0,0095	4,41	17,68	2,3982
	C.F. M	0,1205	0,0106	3,46	16,14	2,7580
	C.F. Fr	0,0332	0,0028	3,81	14,78	1,9391


Fonte: Elaboração do próprio autor.

Da análise da Tabela 4 para h=0,12 m tem-se duas situações semelhantes, para matriz de entrada apenas com o volume adimensional e apenas com o número de Froude possuem boas respostas, sendo que para o segundo caso, os resultados são ligeiramente melhores, quando se analisa o MAPE mínimo e médio.

Na Figura 40 (a) é apresentado o resultado do menor MAPE da melhor previsão referente ao período relativo, com valor de 0,2109% e RMSE próximo a zero, podendo-se observar que a previsão da rede coincide com os dados experimentais.

Na Figura 40 (b) é apresentado o resultado referente ao maior valor de MAPE na melhor previsão, com valor de 15,13% e RMSE próximo a 2,5. Neste caso a previsão da rede subestima os três primeiros pontos e superestima os dois últimos, possivelmente a variação do ultimo ponto foi o que resultou num valor mais elevado do RMSE, mas mesmo assim a rede conseguiu compreender o comportamento dos dados experimentais.

Figura 40 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F. Fr




Fonte: Elaboração do próprio autor.

Para o caso de $h=0,18$ m ao se analisar os três MAPEs o melhor resultado se apresenta para a matriz de entrada com todos os dados, dada pela equação (16). Este resultado é apresentado na Figura 41 (a) e (b).

Na Figura 41 (a) pode-se observar o menor valor de MAPE obtido nesta previsão, com valor de 0,1823% e RMSE de 0,0210, assim como no caso anterior a rede prevê com sucesso a curva referente ao período relativo.

Na Figura 41 (b) é apresentado o resultado do maior valor de MAPE obtido, com valor de 14,73% e RMSE próximo a 2, assim como no caso anterior a rede compreende o comportamento dos dados experimentais e apesar de divergir, subestimando e superestimando os pontos, a rede obteve uma boa previsão. Fato reforçado ao se analisar o MAPE médio com valor de 5,14%, indicando que a maioria das previsões se aproxima do caso apresentado na Figura 41(a) relativa ao menor MAPE.

Figura 41 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F.




Fonte: Elaboração do próprio autor.

Para $h=0,27$ m, após análise dos valores dos MAPEs e RMSEs, o melhor resultado foi obtido com apenas o volume adimensional como elemento da matriz de entrada. Na Figura 42 (a) é apresentado o menor valor de MAPE, com valor de 0,0889%, e RMSE próximo a zero, enquanto na Figura 42 (b) é apresentado o maior valor de MAPE, com valor de 13,55% e RMSE próximo a 1,5. Assim como na análise anterior compreende-se que a rede é capaz de prever com sucesso os dados experimentais e entender o comportamento destes.

Em termos de MAPE médio esta previsão teve valor de 3,78%, indicando que as previsões se aproximam muito mais do menor MAPE do que do maior MAPE e esta previsão possui um dos menores valores de MAPE médio.

Figura 42 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F. M




Fonte: Elaboração do próprio autor.

Para o caso de $h=0,36$ m existem duas situações que são semelhantes, com apenas o volume adimensional na matriz de entrada e com apenas o número de Froude na matriz de entrada, neste caso optou-se por apresentar os resultados referentes a primeira situação, sendo o MAPE médio menor em comparação (Figura 43 (a) e (b)).

Na Figura 43 (a) é apresentado o menor valor de MAPE desta previsão, com valor de 0,1205% e RMSE próximo a zero e na Figura 43 (b) é apresentado o maior valor de MAPE desta previsão, com valor de 16,14% e RMSE próximo a 3,0.

No segundo caso pode-se observar que a rede entende o comportamento, mas a superestimação do ultimo ponto e subestimação do primeiro podem justificar o valor mais alto do RMSE, mas mesmo assim esta foi uma boa previsão, pois ao se analisar o MAPE médio com valor de 3,46% entende-se que a maioria das respostas da rede se aproxima do caso do menor MAPE.

Figura 43 – Menor (a) e Maior (b) MAPE obtidos para a matriz de entrada C.F. M



Fonte: Elaboração do próprio autor.

5.5 CONSIDERAÇÕES

Analizando cada uma dos casos, referente as três diferentes matrizes de saída e a cada uma das matrizes de entrada, observou-se que apenas o volume adimensional seria parâmetro suficiente para obter boas previsões em todos os casos, mesmo não se sobressaindo em alguns.

Com base nas previsões realizadas pela rede, a mesma mostrou-se capaz de realizar as previsões em diversas situações, convergindo em diversos casos com os dados experimentais,

e nos caso onde havia alguma divergência a rede compreendia o comportamento e realizava previsões aproximadas.

Observa-se que a apresentação do menor e maior valores de MAPEs obtidos pela rede é de grande importância para a avaliação correta da previsão, uma vez que apenas o menor não reflete todo o estudo, da mesma forma que apenas o maior também não reflete, mas sim o conjunto dos dois.

Assim os estudos aqui apresentados verificaram os extremos apresentados pela rede para se realizar uma boa avaliação da resposta da mesma e que o uso do RMSE complementa as análises, sendo o indicador da quão próxima a previsão da rede está dos dados experimentais.

A seguir são apresentados os estudos referentes a influência da normalização nas previsões, verificando se a alteração da normalização teria ou não impacto direto nas previsões.

6 NORMALIZAÇÃO - ARTMAP FUZZY

No decorrer dos testes anteriores foi levantada a questão da influência da normalização no processo de treinamento e diagnóstico da RNA, uma vez que foi apenas utilizada a normalização segundo Carpenter *et al.* (1992) nos testes do capítulo cinco, seria de interesse investigar tal influência.

Na literatura são encontradas diversas normalizações, mas estas, em sua maioria, aplicadas a rede neural backpropagation, sendo a normalização segundo Carpenter *et al.* (1992) a mais comumente utilizada nos trabalhos envolvendo a RNA ARTMAP FUZZY.

6.1 NORMALIZAÇÕES

Dentre as normalizações encontradas na literatura podemos citar a normalização pelo min-máx, segundo Priddy e Keller (2005) esta normalização é dada pela equação (21), cujos valores são redimensionados para ficarem dentro do intervalo de 0 a 1 ou de -1 a 1.

$$x_i' = (\max_{target} - \min_{target}) * \left[\frac{(x_i - \min_{value})}{(\max_{value} - \min_{value})} \right] + \min_{target} \quad (21)$$

Em que:
 $(\max_{value} - \min_{value}) \neq 0$

Observa-se que assim como existe a min-máx, pode-se analisar o máx-min, cujo foco não é a maximização, mas sim a minimização, ou seja, seu extremo tem máximo em 0 e o mínimo em 1, sua formula é dada pela equação (22).

$$x_i' = (\min_{target} - \max_{target}) * \left[\frac{(\max_{value} - x_i)}{(\max_{value} - \min_{value})} \right] + \max_{target} \quad (22)$$

Em que:
 $(\max_{value} - \min_{value}) \neq 0$

Outra normalização é a estatística ou z-score, segundo Priddy; Keller (2005) é dada pela equação (23).

$$x_i' = [(x_i - \mu_i)/\sigma_i] \quad (23)$$

Em que:

μ : média

σ : desvio padrão

Pode-se encontrar também a normalização Sigmoidal ou Softmax, segundo Priddy; Keller (2005) ela é dada pelas equações (24) e (25), cuja diferença está que no primeiro caso utiliza um sigmoidal logístico e coloca os dados normalizados em um intervalo de 0 a 1 e no segundo caso, é utilizada uma tangente hiperbólica que coloca os dados normalizados em um intervalo de -1 a 1. Aplica-se nos casos que se deseja reduzir a influência de valores extremos ou discrepantes nos dados sem removê-los do conjunto de dados.

$$x'_i \equiv [1/(1 + e^{-(x_i - \mu_i)/\sigma_i})] \quad (24)$$

$$x'_i \equiv [(1 - e^{-(x_i - \mu_i)/\sigma_i})/(1 + e^{-(x_i - \mu_i)/\sigma_i})] \quad (25)$$

Outra normalização, segundo Priddy e Keller (2005), é a normalização energética, dada pela equação (26), que usa qualquer norma de Minkowski desejada, sendo as mais comuns à normalização pela norma L1 (n=1) ou taxicab e a norma L2 (n=2) ou euclidiana, o vetor normalizado é dado pela divisão de cada vetor por seu comprimento, norma L1 ou L2, conforme equação (27).

$$M_n(x) = \sqrt[n]{\sum_{i=1}^N |x_i|^n} \quad (26)$$

$$x'_i = x_i / \left(\sqrt[n]{\sum_{i=1}^N |x_i|^n} \right) \quad (27)$$

Tem-se também a normalização decimal, dada pela equação (28) segundo Al Shalabi e Shaaban (2006):

$$v' = (v/10^j) \quad (28)$$

Em que:

j: é o menor número inteiro de modo que $Max(|v'|) < 1$.

Pode-se encontrar também a normalização Median-Mad (desvio absoluto mediano) dada pela equação (29) e (30) conforme Christophe Leys *et al.* (2013) citado por Eesa e Arabo (2017).

$$nv = f(v) = (v - median(v))/MAD(v) \quad (29)$$

Em que:

$$MAD = \frac{1}{n} \sum_{i=1}^n |x_i - median(x)| \quad (30)$$

Outra variação da normalização anterior utiliza no lugar da mediana a média, assim a normalização Mean-Mad é dada pela equação (31) e (32) segundo Pham-Gia (2011) citado por Eesa e Arabo (2017).

$$nv = f(v) = (v - mean(v))/MAD(v) \quad (31)$$

Em que:

$$MAD = \frac{1}{n} \sum_{i=1}^n |x_i - mean(x)| \quad (32)$$

Existe também a normalização pela Mediana, segundo Jayalakshmi e Santhakumaran (2011), sua utilidade ocorre quando houver a necessidade de calcular a proporção entre duas amostras hibridizadas, esta normalização é dada pela equação (33).

$$x' = x_i / median(a_i) \quad (33)$$

Enquanto a normalização estatística da coluna, ainda segundo Jayalakshmi e Santhakumaran (2011), é dada pela equação (34).

$$x' = (x_i - n(c_a)/n(c_a)) * 0.1 \quad (34)$$

Por fim, tem-se a normalização pela norma segundo Eesa e Arabo (2017), a normalização pela norma é dada pela equação (35).

$$nv = f(v) = v / \|y\| \quad (35)$$

Em que:

y: distancia Euclidiana

Porém boa parte das normalizações anteriores não foram utilizadas neste trabalho, este fato deve-se a dificuldade no processo de desnormalização dos dados pós-fase de diagnóstico, sendo assim foram elaboradas novas normalizações e utilizadas em conjunto com as normalizações pelo máx-min, min-máx e por Carpenter *et al.* (1992). Essas normalizações são apresentadas no tópico a seguir.

6.2 TIPOS DE NORMALIZAÇÕES UTILIZADAS

Como explicado anteriormente, ao se normalizar o dados para treinamento é necessário, após o processo de diagnóstico, realizar a desnormalização dos dados, voltando-os ao que eram anteriormente. Este processo pode ser tão complexo quanto à normalização escolhida, assim, para este trabalho foram utilizadas as normalizações apresentadas nas equações de (36) a (59).

- 1- Normalização pelo máximo da matriz de entrada sem normalização da matriz de saída;

$$\bar{I}_a = I_a / \max |I_a| \quad \bar{I}_b = I_b \quad (36)$$

- 2- Normalização pelo máximo da matriz de entrada com normalização da matriz de saída por Carpenter;

$$\bar{I}_a = I_a / \max |I_a| \quad \bar{I}_b = I_b / \sum_i |I_{b_i}| \quad (37)$$

- 3- Normalização pelo máximo da matriz de entrada e máximo da matriz de saída;

$$\bar{I}_a = I_a / \max |I_a| \quad \bar{I}_b = I_b / \max |I_b| \quad (38)$$

- 4- Normalização pelo máximo da coluna sem normalização da matriz de saída;

$$\bar{I}_a = I_a / \max |I_{a_j}| \quad \bar{I}_b = I_b \quad (39)$$

- 5- Normalização pelo máximo da coluna com normalização da matriz de saída por Carpenter;

$$\bar{I}_a = I_a / \max |I_{a_j}| \quad \bar{I}_b = I_b / \sum_i |I_{b_i}| \quad (40)$$

- 6- Normalização pelo máximo da coluna com normalização da matriz de saída pelo máximo da coluna;

$$\bar{I}_a = I_a / \max |I_{a_j}| \quad \bar{I}_b = I_b / \max |I_{b_j}| \quad (41)$$

- 7- Normalização pelo máximo da linha sem normalização da matriz de saída;

$$\bar{I}_a = I_a / \max |I_{a_i}| \quad \bar{I}_b = I_b \quad (42)$$

8- Normalização pelo máximo da linha com normalização da matriz de saída por Carpenter;

$$\bar{I}_a = I_a / \max |I_{a_i}| \quad \bar{I}_b = I_b / \sum_i |I_{b_i}| \quad (43)$$

9- Normalização pelo máximo da linha da matriz de entrada e da matriz de saída;

$$\bar{I}_a = I_a / \max |I_{a_i}| \quad \bar{I}_b = I_b / \max |I_{b_i}| \quad (44)$$

10- Normalização pelo somatório da coluna da matriz de entrada sem normalização da matriz;

$$\bar{I}_a = I_a / \sum_j |I_{a_j}| \quad \bar{I}_b = I_b \quad (45)$$

11- Normalização pelo somatório da coluna da matriz de entrada e com normalização da matriz de saída por Carpenter;

$$\bar{I}_a = I_a / \sum_j |I_{a_j}| \quad \bar{I}_b = I_b / \sum_i |I_{b_i}| \quad (46)$$

12- Normalização pelo somatório da coluna da matriz de entrada e pelo somatório da coluna da matriz de saída;

$$\bar{I}_a = I_a / \sum_j |I_{a_j}| \quad \bar{I}_b = I_b / \sum_j |I_{b_j}| \quad (47)$$

13- Normalização da matriz de entrada por Carpenter sem normalização da matriz de saída;

$$\bar{I}_a = I_a / \sum_i |I_{a_i}| \quad \bar{I}_b = I_b \quad (48)$$

14- Normalização por Carpenter da matriz de entrada e de saída;

$$\bar{I}_a = I_a / \sum_i |I_{a_i}| \quad \bar{I}_b = I_b / \sum_i |I_{b_i}| \quad (49)$$

15- Normalização (pelo min-máx) por maximização da matriz de entrada e da matriz de saída;

$$\bar{I}_{a_i} = (I_{a_i} - I_{amin}) / (I_{amax} - I_{amin}) \quad \bar{I}_{b_i} = (I_{b_i} - I_{bmin}) / (I_{bmax} - I_{bmin}) \quad (50)$$

16- Normalização (pelo min-máx) por maximização da matriz de entrada e matriz de saída por Carpenter;

$$\bar{I}_{a_i} = (I_{a_i} - I_{amin}) / (I_{amax} - I_{amin}) \quad \bar{I}_b = I_b / \sum_i |I_{b_i}| \quad (51)$$

17- Normalização (pelo min-máx) por maximização da matriz de entrada e sem normalização da matriz de saída;

$$\bar{I}_{a_i} = (I_{a_i} - I_{amin}) / (I_{amax} - I_{amin}) \quad \bar{I}_b = I_b \quad (52)$$

18- Normalização (pelo máx-min) por minimização da matriz de entrada e da matriz de saída;

$$\bar{I}_{a_i} = (I_{amax} - I_{a_i}) / (I_{amax} - I_{amin}) \quad \bar{I}_{b_i} = (I_{bmax} - I_{b_i}) / (I_{bmax} - I_{bmin}) \quad (53)$$

19- Normalização (pelo máx-min) por minimização da matriz de entrada e matriz de saída Carpenter;

$$\bar{I}_{a_i} = (I_{amax} - I_{a_i}) / (I_{amax} - I_{amin}) \quad \bar{I}_b = I_b / \sum_i |I_{b_i}| \quad (54)$$

20- Normalização (pelo máx-min) por minimização da matriz de entrada e sem normalização da matriz de saída;

$$\bar{I}_{a_i} = (I_{amax} - I_{a_i}) / (I_{amax} - I_{amin}) \quad \bar{I}_b = I_b \quad (55)$$

21- Normalização da matriz de entrada por Carpenter e pelo máximo da matriz de saída;

$$\bar{I}_a = I_a / \sum_i |I_{a_i}| \quad \bar{I}_b = I_b / \max |I_{b_i}| \quad (56)$$

22- Normalização da matriz de entrada por Carpenter e normalização da matriz de saída por maximização (pelo máx-min);

$$\bar{I}_a = I_a / \sum_i |I_{a_i}| \quad \bar{I}_{b_i} = (I_{bmax} - I_{b_i}) / (I_{bmax} - I_{bmin}) \quad (57)$$

23- Normalização da matriz de entrada por Carpenter e normalização da matriz de saída por minimização (pelo min-máx);

$$\bar{I}_a = I_a / \sum_i |I_{a_i}| \quad \bar{I}_{b_i} = (I_{bmax} - I_{b_i}) / (I_{bmax} - I_{bmin}) \quad (58)$$

24- Normalização da matriz de entrada por Carpenter e normalização da matriz de saída pelo somatório da coluna;

$$\bar{I}_a = I_a / \sum_i |I_{a_i}| \quad \bar{I}_b = I_b / \sum_j |I_{b_j}| \quad (59)$$

Em que:

Ia: matriz de entrada;

Ib: matriz de saída;

i: número de linhas da matriz I;

j: número de colunas da matriz I;

Observa-se que este estudo decorreu durante o processo de desenvolvimento do primeiro artigo intitulado: “*Impact Waves Prediction by Fuzzy ARTMAP Neural Network*” (OLIVEIRA *et al.*, 2020) já publicado, que analisava apenas os dados referentes à altura de lâmina d’água $h=0,12$ metros e cinco das normalizações apresentadas anteriormente, que são reapresentadas nas equações de (60) a (64).

1- Normalização pela norma (CARPENTER *et al.*, 1992):

$$\bar{I} = I / \sum_i |I| \quad (60)$$

2- Normalização pelo máximo valor de cada coluna:

$$\bar{I} = I / \max |I_j| \quad (61)$$

3- Normalização pelo máximo da matriz:

$$\bar{I} = I / \max |I| \quad (62)$$

4- Normalização pelo máximo da somatória de cada coluna:

$$\bar{I} = I / \sum_j |I_j| \quad (63)$$

5- Normalização pelo máximo da linha:

$$\bar{I} = I / \max |I_i| \quad (64)$$

Em que:

I: matriz de entrada ou saída;

i: número de linhas da matriz I;

j: número de colunas da matriz I;

Foi observado que existia uma grande influência da normalização nas previsões, assim para continuação do estudo foram utilizados todos os 532 dados experimentais do trabalho de Huber (1980) após serem filtrados conforme apresentado no capítulo quatro.

Como segunda comprovação da hipótese levantada, de que a normalização influi nas previsões, foi estudada a influência da normalização num banco de dados de *roll waves*, gerado pelo método numérico e fornecido pelo Laboratório de Hidrologia e Hidrometria da UNESP de Ilha Solteira. Este banco de dados possui um total de 31 mil dados cujos parâmetros que o compõe serão apresentados posteriormente em conjunto com uma breve revisão sobre *roll waves*.

Este estudo gerou o segundo artigo intitulado: Análise da influência da normalização na predição de parâmetros característicos das ondas de impacto (OLIVEIRA *et al.* [2020?]), submetido a periódico e em fase de avaliação, que se constitui num resumo de parte deste capítulo.

Assim, este estudo abordou sete normalizações diferentes:

- 1- Normalização pelo máximo da matriz;
- 2- Normalização segundo Carpenter (CARPENTER *et al.*, 1992);
- 3- Normalização pelo máximo da coluna;
- 4- Normalização pelo máximo da linha;
- 5- Normalização pelo somatório da coluna;
- 6- Normalização por minimização (min-máx);
- 7- Normalização por maximização (máx-min).

A combinação das normalizações anteriores aplicadas a matriz de entrada e de saída, incluindo as situações em que era possível não realizar a normalização, resultou nos vinte quatro casos apresentados anteriormente.

Destes, apenas nove puderam ser usados para estudos da influência da normalização nos períodos e comprimentos, pois os valores dos dados estavam fora do intervalo de zero a um, situação diferente do caso da evolução das alturas, em que os dados já se encontravam dentro deste intervalo.

Exemplificando, dentro das vinte quatro normalizações testadas, houve casos em que a matriz de saída não foi normalizada, tendo em vista que os dados já se encontravam no intervalo de zero a um. Observa-se que as situações sem normalização da saída foram investigadas para averiguar-se quando a matriz de dados já se encontra dentro do intervalo requerido não há necessidade de normaliza-la.

Na realização dos testes foi considerado um aumento de 20%, tanto na normalização da entrada quanto na normalização da saída, o que permite a rede ter uma maior maleabilidade, podendo trabalhar com situações mais adversas do que as apresentadas para o treinamento.

6.3 CRITÉRIO DE ESCOLHA

Assim como foi realizado no capítulo cinco, foi necessário criar um critério de avaliação das normalizações para determinar qual ou quais as normalizações ideais para o conjunto de dados selecionado. Para esta análise foram considerados os MAPES máximos, mínimos e médios segundo as equações (65) a (67):

$$\text{MAPE máximo} = \max (\text{MAPE}_i), i \in [1; N]; \quad (65)$$

$$\text{MAPE mínimo} = \min (\text{MAPE}_i), i \in [1; N]; \quad (66)$$

$$\text{MAPE médio} = \text{média} (\sum_n^i \text{MAPE}_i / N), i \in [1; N]; \quad (67)$$

Em que:

N: número de linhas da matriz de saída;

Além dos MAPES foi realizada uma análise estatística por intervalo de confiança, considerando dois níveis de confiança, um de 95% e outro de 99%.

Foi também investigado o comportamento dos dados pós-normalização, buscando uma maior compreensão da influência que esta tem em seu comportamento.

6.4 BANCO DE DADOS PARA OS TESTES DE NORMALIZAÇÃO

Para os testes de normalização, diferente do que aconteceu nos testes iniciais de previsão, ao invés de utilizar os dados separados por altura de lâmina d'água foram utilizados todos os 636 dados de ensaio de Huber (1980). Dentro desses dados, alguns não geraram ondas e estavam sem preenchimento, outros foram de difícil leitura como se pode visualizar nas tabelas do Anexo B, e outros tinham comportamentos atípicos, estes comportamentos foram visualizados em análises gráficas, desta forma esses dados foram removidos do banco resultando em 532 dados pós-filtragem.

Foram apresentadas à rede neural quatro matrizes de entrada e três matrizes de saída diferentes, combinadas de forma a se ter um total de 12 combinações de entrada e saída a serem analisadas.

A primeira matriz de entrada apresentada a rede era composta pela altura da lâmina d'água do canal (h), volume adimensional (M), número de Froude (F), inclinação da vertente (rampa de deslizamento) (α) e inclinação da praia a jusante (β) conforme equação (68).

$$\text{Matriz 1: } I_a = (h, M, F, \alpha, \beta) \quad (68)$$

Em que:

h : altura da lâmina d'água;

M : Volume adimensional;

F : Número de Froude de Impacto;

α : Inclinação da vertente;

β : Inclinação da praia a jusante;

A segunda matriz de entrada possuía todos os parâmetros anteriores exceto os referentes à inclinação da vertente e da praia a jusante, por não serem impactantes nas previsões da evolução das alturas relativas, períodos e comprimentos, a equação (69) apresenta a segunda matriz de entrada.

$$\text{Matriz 2: } I_a = (h, M, F) \quad (69)$$

Em que:

h : altura da lâmina d'água;

M : Volume adimensional;

F : Número de Froude de Impacto;

A terceira matriz de entrada foi composta pela altura de lâmina d'água e pelo número de Froude e é dada pela equação (70), pois foi uma das matrizes testadas no capítulo cinco.

$$\text{Matriz 3: } I_a = (h, F) \quad (70)$$

Em que:

h : altura da lâmina d'água;

F : Número de Froude de Impacto;

A quarta matriz de entrada foi composta pela altura de lâmina d'água e pelo volume adimensional, dada pela equação (71) e também faz parte das matrizes anteriormente testadas.

$$\text{Matriz 4: } I_a = (h, M) \quad (71)$$

Em que:

h : altura da lâmina d'água;

M : Volume adimensional;

A primeira matriz de saída foi composta pelos valores referentes às alturas máximas de ondas relativas (H/h) ao longo do canal e segue a equação (72).

$$\text{Matriz 5: } I_b = (H_1/h_1, H_2/h_2, H_3/h_3, H_4/h_4, H_5/h_5) \quad (72)$$

Em que:

H/h : Altura máxima de onda relativa ao longo do canal;

A segunda matriz de saída é dada pela equação (73) e é composta pelos dados relativos ao comprimento das ondas de impacto.

$$\text{Matriz 6: } I_b = (\lambda_1/h_1, \lambda_2/h_2, \lambda_3/h_3, \lambda_4/h_4, \lambda_5/h_5) \quad (73)$$

Em que:

λ/h : Comprimento relativo de onda ao longo do canal;

A terceira e última matriz de saída é composta pelos dados referentes ao período relativo das ondas de impacto de acordo com a equação (74).

$$\text{Matriz 7: } I_b = (T_1/h_1, T_2/h_2, T_3/h_3, T_4/h_4, T_5/h_5) \quad (74)$$

Em que:

T: Período relativo de onda ao longo do canal;

Foram então combinadas as matrizes de entrada e saída de forma a obter as 12 análises, exemplificando:

- 1- Matriz 1 e Matriz 5;
- 2- Matriz 2 e Matriz 5;
- 3- Matriz 3 e Matriz 5;
- 4- Matriz 4 e Matriz 5;

Depois dos quatro testes acima foi substituída a matriz de saída pela matriz 6 e depois de mais quatro testes foi realizado a última substituição da matriz de saída pela matriz 7, finalizando 12 testes para cada uma das normalizações propostas.


6.5 BANCO DE DADOS DE *ROLL WAVES*

6.5.1 *Roll Waves*

Segundo Boutounet, Noble e Vila (2012) as roll waves são distúrbios hidrodinâmicos que ocorrem, devido à competição entre a gravidade e o atrito, em fluxos de superfície livre com inclinação.

Conforme De Freitas Maciel (2013) estas ondas costumam ocorrer, por exemplo, em deslizamentos de terra, fluxos de lava e avalanches. Segundo De Freitas Maciel (2013) sua previsão e detecção são úteis para prevenir riscos naturais. Um exemplo de roll waves é apresentado na Figura 44.

Figura 44 – *Roll waves*



Fonte: Adaptado de De Freitas Maciel (2013) e Maciel *et al.* (2017) .

Na literatura é possível encontrar diversos trabalhos que abordam o tema sobre roll waves, seja em laboratório buscando sua reprodução e medição, seja por modelagem numérica ou seja no desenvolvimento de equacionamentos para sua descrição, podendo citar alguns trabalhos como os de: Di Cristo *et al.* (2009), Boutounet, Noble e Vila (2012), De Freitas Maciel (2013), Razis *et al.* (2014), Ostapenko e Bartashevich (2015), Fiorot *et al.* (2015), Campomaggiore *et al.* (2016), Maciel *et al.* (2017), Nakoryakov *et al.* (2017).


6.5.2 Banco de Dados

O banco de dados numérico foi composto por um total de 31 mil dados referentes a *roll waves* e para as análises não foi necessária a filtragem ou conversão para parâmetros adimensionais.

A matriz de entrada foi composta por quatro parâmetros, sendo eles: o índice de escoamento do fluido (n), a tensão limite de escoamento (C), o número de Froude do escoamento (Fr), e a lâmina baixa (h_1). A equação (75) apresenta a matriz de entrada e a Figura 75 ilustra alguns dos parâmetros das *roll waves*.

$$\text{Matriz 8: } I_a = (n, C, Fr, h_1) \quad (75)$$

Figura 75 - Parâmetros das roll waves



Fonte: Cunha (2013)

Nota: θ inclinação do canal; h profundidade do escoamento; l largura do canal;

A matriz de saída, matriz 9, é composta de seis parâmetros, a lâmina alta (h_2), a amplitude de onda (dH), o comprimento de onda (λ), a velocidade de onda (U), o período de onda (T) e a vazão unitária do escoamento (q) e é representada pela equação (76).

$$\text{Matriz 9: } I_b = (h_2; dH; \lambda; U, T, q) \quad (76)$$

Optou-se por realizar uma alteração na quantidade de componentes da matriz de entrada 8, da mesma forma que o escolhido para o tratamento do banco de dados de Huber (1980), nesse momento optou-se por retirar da matriz de entrada os valores referentes ao índice de escoamento e a tensão limite de escoamento, gerando a matriz de entrada 10 representada pela equação (77), enquanto a matriz de saída permaneceu inalterada. Da mesma forma, a alteração surgiu para verificar alterações nas normalizações.

$$\text{Matriz 10: } I_a = (Fr, h_1) \quad (77)$$

Em que:

Fr: Número de Froude;

h_1 : Lâmina baixa (*roll wave*);

Nessa etapa foram realizados os testes primeiro com a matriz de entrada 8 e a matriz de saída 9 e após com a matriz de entrada 10 e a matriz de saída 9, totalizando dois conjuntos de análise.

6.6 RESULTADOS DOS TESTES DE NORMALIZAÇÃO

A seguir são apresentados os resultados dos testes referentes à influência da normalização para os três casos, evolução das alturas máximas, períodos e comprimentos relativos. Os parâmetros de treinamento e diagnósticos utilizados nas baterias de testes foram os mesmos apresentados pela Tabela 1.

6.6.1 Resultados dos testes de normalização para a evolução das alturas máximas relativas

Foi realizado um total de 96 testes para a evolução das alturas máximas, observando que cada um dos testes foi repetido 500 vezes para obter a melhor previsão seguindo o critério apresentado no capítulo quatro.

Assim, na Tabela 5 são apresentados todos os resultados dos valores dos MAPES máximos, mínimos e médios de cada uma das 24 normalizações, referentes à primeira bateria de testes utilizando a matriz de saída 5 e as quatro matrizes de entrada dadas pelas equações (68) a (71) num total de 96 testes para a evolução das alturas máximas.

Tabela 5 – MAPEs máximos, mínimos e médios de cada normalização dos dados referentes à evolução das alturas de ondas para as 4 matrizes de entrada (continua).

Matriz de entrada	1			2			3			4		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização												
1	129,37	0,00	26,11	234,06	1,58	27,85	231,05	2,19	48,08	160,14	0,06	30,89
2	186,05	0,00	8,55	48,08	0,14	9,28	140,18	0,23	14,64	179,34	0,66	8,91
3	171,24	0,05	27,03	191,60	1,16	29,04	228,21	2,93	52,52	200,28	1,79	27,42
4	249,43	0,00	33,29	278,13	1,84	28,78	214,61	1,04	50,07	207,85	0,82	28,84
5	63,59	0,00	8,86	45,62	0,46	9,36	79,75	0,06	13,40	38,47	0,16	8,58
6	241,83	0,00	32,21	163,72	1,72	26,45	287,45	1,03	52,60	211,68	1,95	28,78
7	173,33	0,00	26,61	176,40	1,85	29,02	300,31	1,84	50,45	192,53	1,61	29,88
8	75,97	0,09	8,49	149,63	0,06	9,40	73,87	0,30	13,26	40,55	0,11	8,37
9	50,15	0,00	12,81	70,41	0,30	14,01	158,30	0,14	21,41	84,35	0,25	11,63
10	163,20	0,05	22,65	223,17	0,86	28,44	296,13	3,60	57,29	250,12	0,00	27,40
11	56,06	0,00	8,20	186,05	0,06	9,67	58,68	0,44	13,26	181,46	0,28	8,68
12	168,83	0,00	21,17	229,60	1,03	28,98	218,16	3,46	49,78	189,78	1,99	31,30
13	242,05	0,05	27,12	278,13	1,58	28,83	323,67	1,99	47,51	194,17	1,88	31,02
14	56,06	0,14	8,98	44,84	0,09	9,14	162,01	0,29	12,99	39,15	0,00	8,89

Fonte: Elaboração do próprio autor.

Tabela 5 – MAPEs máximos, mínimos e médios de cada normalização dos dados referentes à evolução das alturas de ondas para as 4 matrizes de entrada (conclusão).

Matriz de entrada	1			2			3			4		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização												
15	211,68	0,00	25,38	228,96	0,05	28,19	218,39	1,03	46,16	197,47	0,81	28,23
16	186,05	0,00	8,55	72,69	0,27	9,72	140,18	0,06	13,21	194,98	0,11	8,67
17	165,91	0,05	26,65	227,51	0,86	28,11	277,51	0,05	53,24	207,13	1,79	28,29
18	165,91	1,16	27,15	250,12	0,86	27,74	308,44	1,03	52,14	278,13	0,86	29,04
19	51,58	0,09	8,28	54,80	0,29	9,05	140,18	0,44	13,92	50,42	0,14	8,00
20	198,33	0,00	26,37	163,49	2,33	27,00	218,39	3,65	48,49	180,53	3,22	27,76
21	229,60	1,16	26,63	200,34	0,92	29,29	246,70	0,93	52,57	303,31	1,71	27,51
22	149,19	0,00	27,26	157,80	0,86	26,35	257,21	1,58	50,02	202,08	1,35	30,37
23	242,05	0,00	27,72	163,49	1,88	27,03	268,27	2,42	47,44	166,34	0,69	29,28
24	168,83	0,05	27,01	278,13	1,85	28,85	317,20	2,40	53,01	217,25	0,05	28,90

Fonte: Elaboração do próprio autor.


Analisando a Tabela 5, pode-se observar que o MAPE máximo atingiu valores entre 51% e 250%, enquanto MAPE mínimo teve valores entre 0% e 1,2% e o MAPE médio oscilou entre 8,2% a 33,3%.

Dentre as normalizações apresentadas, observando MAPE médio, as normalizações 2, 5, 8, 11, 14, 16, e 19, apresentaram os melhores resultados, enquanto ao se observar o MAPE mínimo todas as normalizações tiveram bons resultados e por fim, observando o MAPE máximo as normalizações 11, 14 e 19 aparecem com valores em torno de 54%, mais baixo que as demais.

Cabe observar que mesmo a normalização 9 tendo um bom resultado em termos de máximos e mínimos, porém teve MAPE médio de 12,81%, bem acima das normalizações em destaque.


Na Figura 44 e 45 pode-se observar o resultado para os testes de intervalo de confiança de 0,95 e 0,99, respectivamente. No primeiro teste as normalizações 8, 11 e 19 apresentam melhor resultado, enquanto no segundo teste as normalizações 11 e 19 apresentam maior destaque. Neste momento pode-se concluir que a normalização 11 e 19 para ambos os testes são as mais recomendadas para matriz 1.

Figura 44 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 45 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.

Retomando a análise dos resultados da Tabela 5 pode-se observar, para matriz 2, que os MAPES máximos variaram de 44,84% a 278,13%, enquanto os MAPES mínimos variaram de 0,06% a 2,33% e os MAPES médios variaram de 9,05% a 29,29%.


Buscando as normalizações com melhores resultados, pode-se observar que as normalizações 2, 5, 8, 11, 14, 16, e 19 aparecem em destaque, ao se comparar os resultados

dos MAPES máximos as normalizações 2, 5 e 14 ganham maior destaque, enquanto para MAPE mínimo e médio todas as sete possuem valores considerados próximos.

Analisando as respostas pelo intervalo de confiança, pode-se observar na Figura 46 que as normalizações 14 e 19 estão com melhor comportamento que as demais, enquanto na Figura 47 a normalização 14 se destaca das demais.


Neste momento as normalizações 14 e 19 apresentam-se como as mais adequadas para a matriz 2.

Figura 46 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 47 – Intervalo de confiança 0,99




Fonte: Elaboração do próprio autor.

Seguindo a análise da Tabela 5, pode-se observar que os MAPES máximos variaram de 58,68% a 323,27%, enquanto os MAPES mínimos variaram de 0,06% a 2,93% e os MAPES médios variaram de 12,99% a 57,29%.

Dentre as 24 normalizações analisadas, para caso da matriz 3 as normalizações 2, 5, 8, 11, 14, 16, e 19, apresentam as melhores respostas, sendo que ao analisar o MAPE máximo as normalizações 5, 8 e 11 têm os menores valores e a normalização 11 possui o menor entre eles, com valor de 58,68%. Analisando o MAPE mínimo pode-se considerar que seus valores são muito próximos, considerando apenas as sete melhores normalizações e para o MAPE médio as mesmas sete tem destaque, sendo a normalização 14 com menor valor entre elas.


Analisando pelo intervalo de confiança, no primeiro caso Figura 48 as normalizações 5, 8, 11 e 16 possuem melhor comportamento que as demais. No segundo caso, Figura 49 as mesmas normalizações possuem os melhores comportamentos. Para matriz 3 pode-se observar que a normalização 11 parece ser a mais recomendada.

Figura 48 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 49 – Intervalo de confiança 0,99




Fonte: Elaboração do próprio autor.

Analisando a Tabela 5, para a matriz 4, os MAPES máximos variaram de 38,47% a 303,31%, os MAPES mínimos variaram de 0,05 a 3,65%, enquanto os MAPES médios variaram de 8,00% a 31,30%. Pode-se observar que as sete normalizações 2, 5, 8, 11, 14, 16, e 19, apresentam melhores resultados.

Realizando uma análise dos valores dos MAPES, para o MAPE máximo as normalizações 5, 8, 14 e 19 possuem os menores valores sendo a normalização 5 com o menor entre eles, com valor de 38,47%, enquanto para o MAPE mínimo as sete normalizações possuem valores próximos o mesmo ocorre para os valores do MAPE médio.


Analisando as sete normalizações pelo intervalo de confiança, pode-se observar pela Figura 50 que as normalizações 5, 8 e 19 possuem os melhores comportamentos, sendo a normalização 19 ligeiramente melhor, o mesmo se pode concluir da análise da Figura 51. Pode-se concluir que a normalização 5 e 19 seriam as mais recomendadas para a matriz 4.

Figura 50 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 51 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.

6.6.2 Resultados dos testes de normalização para os comprimentos relativos

Foi realizado um total de 68 testes para os comprimentos relativos, observando que cada um dos testes foi repetido 500 vezes para obter a melhor previsão seguindo o critério apresentado no capítulo quatro.

Assim, na Tabela 6 são apresentados todos os resultados dos valores dos MAPES máximos, mínimos e médios de cada uma das 17 normalizações, referentes à segunda bateria de testes utilizando a matriz de saída 6 e as quatro matrizes de entrada dadas pelas equações (68) a (71) num total de 68 testes para o comprimento relativo.

Tabela 6 – MAPES máximos, mínimos e médios de cada normalização dos dados referentes ao comprimento relativo de onda para as 4 matrizes de entrada (continua).

Matriz de entrada	1			2			3			4		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização												
1												
2	21,50	0,18	5,45	30,35	0,17	5,66	27,62	0,18	6,34	57,15	0,14	5,33
3	74,76	0,40	11,94	106,42	0,73	13,98	64,47	1,23	15,76	128,84	0,60	14,57
4												
5	26,29	0,18	5,10	52,80	0,18	5,78	47,33	0,22	6,14	44,04	0,08	5,32
6	63,70	0,15	11,54	78,98	0,77	12,98	46,64	0,00	15,33	76,94	0,59	13,01
7												
8	44,04	0,00	5,41	39,97	0,11	5,44	29,61	0,15	6,72	50,13	0,18	5,41
9	36,02	0,17	7,83	45,96	0,20	8,09	43,47	0,15	9,54	46,19	0,14	6,78
10												
11	19,64	0,07	5,43	45,40	0,17	5,58	43,05	0,21	6,64	23,28	0,20	5,08
12	67,48	0,97	12,25	104,55	0,40	12,95	61,08	1,23	15,74	104,55	0,21	14,49
13												
14	44,04	0,11	5,46	32,33	0,11	5,51	47,33	0,13	6,74	38,55	0,00	5,22

Fonte: Elaboração do próprio autor.

Tabela 6 – MAPES máximos, mínimos e médios de cada normalização dos dados referentes ao comprimento relativo de onda para as 4 matrizes de entrada (conclusão).

Matriz de entrada	1			2			3			4		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização												
15	106,11	0,15	11,78	109,25	0,36	13,18	76,04	1,04	14,58	55,98	0,00	13,46
16	35,76	0,00	5,18	23,50	0,15	5,45	44,04	0,00	6,46	44,28	0,14	4,96
17												
18	118,88	0,00	12,17	46,38	0,11	12,76	112,29	0,36	15,49	65,12	0,48	13,50
19	44,28	0,09	5,45	39,99	0,17	5,61	35,84	0,20	6,43	50,13	0,13	4,94
20												
21	86,90	0,40	12,35	73,46	0,87	13,59	67,28	0,99	15,19	75,51	0,00	13,17
22	66,19	0,40	11,83	106,42	0,11	13,90	59,31	0,88	14,21	86,59	0,94	13,41
23	67,48	0,61	12,61	76,69	0,87	13,03	76,04	1,24	15,03	72,35	0,00	12,81
24	74,97	0,40	11,73	115,94	0,36	13,82	77,48	0,98	15,43	112,37	0,76	12,51


Fonte: Elaboração do próprio autor.

Da análise da Tabela 6 pode-se observar, para matriz 1, que o MAPE máximo variou de 19,64% a 118,88%, enquanto MAPE mínimo variou de 0,00% a 0,97% e o MAPE médio variou de 5,10% a 12,61%.

Ao se comparar os valores dos MAPES máximos as normalizações 2, 5, 11 e 16 aparecem com melhores resultados, sendo que a normalização 11 possui o menor valor dentre elas, com MAPE máximo de 19,64%. Em termos de MAPE mínimo foi considerado que todos os valores eram bem próximos, o mesmo ocorre quando se analisa os valores do MAPE médio.


Ao se realizar o teste do intervalo de confiança, pode-se observar na Figura 52 que as normalizações 5 e 16 possuem os melhores comportamentos, o mesmo ocorre ao se analisar a Figura 53. Do conjunto de análises pode-se concluir que a normalização 5 seria a mais recomendada para matriz 1.

Figura 52 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 53 – Intervalo de confiança 0,99




Fonte: Elaboração do próprio autor.

Analisando a Tabela 6 pode-se observar, para matriz 2, que o MAPE máximo variou de 23,50% a 115,94%, enquanto MAPE mínimo de 0,11% a 0,87% e o MAPE médio variou de 5,44% a 13,98%.

Comparando-se os valores dos MAPES máximos as normalizações 2, 14 e 16 aparecem com os melhores resultados, sendo a normalização 16 a que possui o menor valor entre elas, com MAPE máximo de 23,50%. Ao se comparar o MAPE mínimo e médio existe pouca variação entre as normalizações 2, 5, 8, 11, 14, 16 e 19 que são as que se destacam em relação às demais.


Da análise da Figura 54 para intervalo de confiança de 0,95, pode-se observar que as normalizações 8, 14 e 16 aparecem com maiores destaques e o mesmo ocorre quando se analisa a Figura 55 com intervalo de confiança de 0,99. Das observações anteriores pode-se concluir que a normalização 16 seria a mais recomendada para matriz 2.

Figura 54 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 55 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.


Analizando novamente a Tabela 6, observando os resultados referentes à matriz 3, pode-se observar que os MAPES máximos variaram de 27,61% a 112,29%, enquanto MAPE mínimo varia de 0 a 1,24% e o MAPE médio varia de 6,14% a 15,76%.

Comparando-se as respostas obtidas, considerando o MAPE máximo, as normalizações 2, 8 e 19 aparecem em destaque, sendo a normalização 2 a com menor valor entre elas, com MAPE máximo de 27,61%. Quando se analisa o MAPE mínimo e médio as normalizações 2, 5, 8, 11, 14, 16 e 19 aparecem com os menores valores, sendo que no MAPE mínimo a normalização 16 se destaca e no MAPE médio a normalização 5, possuindo os menores valores em cada caso respectivamente.

Analizando os intervalos de confiança, no primeiro caso, Figura 56, as normalizações 2, 5, 16 e 19 aparecem com os melhores comportamentos e a normalização número 5 aparece com a menor variação entre elas, o mesmo ocorre ao se observar o segundo caso, Figura 57.


Para o caso da matriz 3, pode-se considerar que as normalizações 2 e 5 seriam as mais recomendadas após as análises anteriores.

Figura 56 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 57 – Intervalo de confiança 0,99




Fonte: Elaboração do próprio autor.

Por fim, analisando a Tabelas 6 para a matriz 4, pode-se observar que o MAPE máximo variou de 23,28% a 128,84%, enquanto o MAPE mínimo variou de 0,00% a 0,94% e o MAPE médio variou de 4,94% a 14,57%.

Comparando-se os valores do MAPE máximo as normalizações 11 e 14 aparecem com os menores valores, sendo a normalização 11 a com menor valor entre as duas, com MAPE máximo de 23,28%. No caso do MAPE mínimo e médio as normalizações 2, 5, 8, 11, 14, 16 e 19 aparecem com os menores valores, sendo que a normalização 14 possui o menor valor de MAPE mínimo e a normalização 19 possui o menor valor de MAPE médio.


Da análise da Figura 58 com intervalo de confiança de 0,95 e da Figura 59 com intervalo de confiança de 0,99 pode-se observar que as normalizações 11, 16 e 19 aparecem com o melhor comportamento. No caso da matriz 4 pode-se recomendar a normalização 11 após as análises anteriores.

Figura 58 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 59 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.

6.6.3 Resultados dos testes de normalização para os períodos relativos

Foi realizado um total de 68 testes para os períodos relativos, observando que cada um dos testes foi repetido 500 vezes para obter a melhor previsão seguindo o critério apresentado no capítulo quatro.

Assim, na Tabela 7 são apresentados todos os resultados dos valores dos MAPES máximos, mínimos e médios de cada uma das 17 normalizações, referentes à terceira bateria de testes utilizando a matriz de saída 7 e as quatro matrizes de entrada dadas pelas equações (68) a (71) num total de 68 testes para o período relativo.

Tabela 7 – MAPEs máximos, mínimos e médios de cada normalização dos dados referentes ao período relativo de onda para as 4 matrizes de entrada (continua).

Matriz de entrada	1			2			3			4		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização												
1												
2	22,23	0,14	5,11	30,70	0,14	5,67	51,55	0,10	6,36	44,27	0,02	5,35
3	47,54	0,38	11,39	84,16	0,79	12,70	43,87	0,25	14,13	157,76	0,11	12,25
4												
5	22,82	0,03	5,33	26,27	0,13	5,54	43,04	0,23	6,82	28,50	0,08	5,23
6	128,63	0,18	10,80	108,22	0,47	12,71	91,21	0,33	14,49	51,31	0,87	12,28
7												
8	43,14	0,08	5,39	43,20	0,09	5,55	40,00	0,02	6,53	44,18	0,09	5,23
9	37,69	0,13	7,87	45,93	0,13	7,83	55,43	0,29	9,79	50,78	0,06	7,34
10												
11	33,85	0,14	5,26	24,92	0,14	5,42	40,19	0,09	6,40	44,27	0,20	5,30
12	67,32	0,90	11,73	108,00	0,48	12,18	74,01	0,97	14,24	54,53	0,91	11,91
13												
14	36,07	0,09	5,54	44,18	0,09	5,60	35,69	0,10	6,62	22,10	0,10	5,20

Fonte: Elaboração do próprio autor.

Tabela 7 – MAPEs máximos, mínimos e médios de cada normalização dos dados referentes ao período relativo de onda para as 4 matrizes de entrada (conclusão).

Matriz de entrada	1			2			3			4		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização												
15	58,21	0,33	11,00	84,16	0,33	12,11	74,01	0,88	13,53	59,19	0,53	12,07
16	23,88	0,14	5,28	23,73	0,13	5,38	35,85	0,15	6,10	37,26	0,13	5,16
17												
18	106,96	0,18	11,21	59,84	0,25	12,43	72,83	0,38	13,52	57,38	0,46	12,92
19	43,14	0,03	5,20	21,29	0,03	5,36	44,11	0,23	6,40	21,32	0,02	5,27
20												
21	58,21	0,33	11,37	59,84	0,87	12,02	77,55	0,68	13,53	52,41	0,37	12,52
22	45,81	0,18	10,73	57,87	0,76	12,19	114,32	1,75	14,23	107,94	0,41	11,87
23	58,98	0,18	11,03	59,84	0,70	12,09	66,98	0,94	13,42	72,45	0,18	11,44
24	57,61	1,39	10,64	71,22	0,70	12,32	46,59	0,78	13,34	51,79	0,55	12,08

Fonte: Elaboração do próprio autor.

Observando a Tabela 7 pode-se observar que, para o caso da matriz 1, o MAPE máximo variou de 22,23% a 128,63%, enquanto o MAPE mínimo variou de 0,03% a 1,39% e o MAPE médio variou de 5,11% a 11,73%.


Dentre as normalizações estudadas as que apresentaram as melhores respostas em termos do MAPE máximo foram 2, 5, 8, 11, 14, 16 e 19, o mesmo pode ser observado ao se analisar os MAPES mínimos e médios.

Porém cabe destacar que as normalizações 2, 5 e 16 possuem os menores valores de MAPE máximo, enquanto as normalizações 5 e 19 os menores valores de MAPE mínimo e as normalizações 2 e 19 os menores valores de MAPE médio.

Realizando as análises pelos intervalos de confiança, na Figura 60, referente ao intervalo de confiança de 0,95, pode-se observar que as normalizações 2, 5, 11, 16 e 19 apresentam os melhores resultados e a normalização 2 apresenta a melhor resposta entre elas. Da análise da Figura 61, referente ao intervalo de confiança de 0,99, pode-se observar que a normalização 2 teve melhor resposta em comparação às demais.


Comparando as análises realizadas pode-se concluir que, para a matriz 1, as normalizações 2 e 5 seriam as mais recomendadas, dando maior destaque a normalização 2.

Figura 60 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 61 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.

Analisando a Tabela 7 pode-se observa que, para a matriz 2, as mesmas sete normalizações anteriores, 2, 5, 8, 11, 16 e 19, aparecem em destaque. Observou-se que o MAPE máximo variou de 21,29% a 108,22%, sendo que as normalizações 5, 11, 16 e 19 possuem os menores valores e a normalização 19 aparece com o menor valor, com MAPE máximo de 21,29%.


Ainda analisando a Tabela 7 observou-se que o MAPE mínimo variou de 0,03% a 0,87%, sendo que as normalizações 8, 14 e 19 aparecem com menores valores e a normalização 19 possui o menor valor entre elas, com MAPE mínimo de 0,03%.

Por fim analisando o MAPE médio, pode-se observar na Tabela 7 que este variou de 5,36% a 12,71%, sendo que as sete normalizações, 2, 5, 8, 11, 16 e 19 aparecem com os menores valores e com valores bem próximos, porém a normalização 19 se destaca com o menor valor entre elas, com MAPE médio de 5,36%.

Quando se realizam as análises por intervalo de confiança, pode-se observar na Figura 62, intervalo de confiança de 0,95, que as normalizações 11, 16 e 19 apresentam os melhores resultados e a normalização 19 o melhor entre elas. Quando se analisa a Figura 63, intervalo de confiança de 0,99, pode-se observar que, novamente, as normalizações 11, 16 e 19 apresentam os melhores resultados e a normalização 19 se destaca ligeiramente em relação à normalização 16.


Dentre as normalizações testadas, pode-se concluir, para a matriz 2, que a normalização 19 seria a mais recomendada.

Figura 62 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 63 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.

Analisando a Tabelas 7 para a matriz 3, pode-se observar que os valores do MAPE máximo variaram entre 35,85% e 114,32%, enquanto os valores do MAPE mínimo variaram de 0,02% a 1,75% e os valores do MAPE médio variaram de 6,1% a 14,49%.

Observando os valores do MAPE máximo, pode-se notar que as normalizações 2, 3, 5, 8, 10, 14, 16, 19 e 24 aparecem com os menores valores e as normalizações 14, com 35,69%, e 16, com 35,85%, apresentam os menores valores entre elas.


Quando se observam os valores do MAPE mínimo as normalizações 2, 5, 8, 11, 14, 16 e 19 aparecem, sendo a normalização 8 a que possui o menor valor entre elas, com MAPE mínimo de 0,02%.

Por fim ao se observar os valores do MAPE médio as sete normalizações anteriores se destacam novamente, sendo a normalização 16 com menor valor entre elas, com MAPE médio de 6,10%.

Ao se realizar os testes pelo intervalo de confiança de 0,95 e 0,99 pode-se observar nas Figuras 64 e 65 que as normalizações 2, 11 e 16 aparecem com os melhores resultados e dentre elas a normalização 16 possui o melhor resultado.


Das análises anteriores pode-se concluir para a matriz 3 que a normalização 16 seria a mais recomendada.

Figura 64 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 65 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.

Realizando a análise para a matriz 4, pode-se observar na Tabelas 7 que os valores do MAPE máximo variaram de 21,32% a 157,76%, enquanto os valores do MAPE mínimo variaram de 0,02% a 0,91% e os valores do MAPE médio variaram de 5,16% a 12,92%.

Ao se observar o MAPE máximo as normalizações 2, 5, 8, 11, 14, 16 e 19 se destacam, sendo que as normalizações 14, com 22,10% e 19, com 21,32%, possuem os menores valores dentre elas.


Observando os valores do MAPE mínimo as mesmas sete normalizações anteriores apresentam os melhores resultados, sendo as normalizações 2 e 19 com os menores valores, com MAPE mínimo de 0,02%.

Analisando os valores do MAPE médio novamente as mesmas sete normalizações aparecem em destaque, sendo as normalizações 14, com 5,20%, e a 16, com 5,16%, com os menores valores dentre elas.

Realizando a análise pelo intervalo de confiança, pode-se observar na Figura 66, intervalo de confiança de 0,95, e na Figura 67, intervalo de confiança de 0,99, que as normalizações 14 e 16 apresentam os melhores resultados dentre as sete em destaque.


Assim, pode-se concluir, com base nas análises anteriores, que para a matriz 4, a normalização 14 seria a mais recomendada.

Figura 66 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 67 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.

6.6.4 Resultados dos testes de normalização aplicados a um banco de dados numérico de *roll waves*

Na Tabela 8 são apresentados os resultados de cada uma das normalizações aplicadas ao banco de dados numérico referente ao fenômeno de *roll waves*, observa-se que as normalizações em que a saída não era normalizada não puderam ser testadas, uma vez que os dados não se encontravam no intervalo de zero a um como no caso dos dados extraídos do trabalho de Huber (1980).

Pode-se observar que as normalizações que aparecem com os menores valores de MAPE médio são as normalizações 5, 8, 9, 11, 14, 21, 22 e 23, para a Matriz 8, com valores em torno de 0,76%. Podendo-se considerar também as normalizações 2, 3, 15, 16, 18 e 19, que também possuem valores bem baixos no MAPE médio, em torno de 1,7%.

Em termos de MAPE máximo, as normalizações 2, 3, 8, 14, 15, 16, 18, 19, 21, 22 e 23 possuem os menores valores, em torno de 23,5%. Enquanto para MAPE mínimo todas aparecem com valores bem próximos, exceto a normalização 6, 12 e 24.

Para a Matriz 10 ocorre quase uma inversão das normalizações selecionadas para a Matriz 8, observa-se que as normalizações 2, 3, 5, 11, 15, 16 18 e 19 aparecem entre as com os menores valores de MAPE médio, com valores em torno de 2,7%.

Em termos de MAPE máximo, as normalizações 5,16 e 19 aparecem com os menores valores, em torno de 23,4%. Enquanto o MAPE mínimo de todas é próximo à zero, exceto para as normalizações 6, 12 e 24.

Tabela 8 – MAPEs máximos, mínimos e médios de cada normalização dos dados numéricos para as 3 matrizes de entrada (continua).

Matriz	8			10		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização						
1						
2	15,38	0,04	1,68	31,47	0,06	2,79
3	26,95	0,05	1,80	35,88	0,09	2,55
4						
5	44,75	0,04	0,96	23,95	0,03	2,80
6	41,63	14,07	14,94	40,83	14,06	16,31
7						
8	24,62	0,04	0,61	91,90	0,12	14,14
9	31,07	0,05	0,76	158,83	0,11	17,75
10						
11	51,69	0,04	0,98	32,95	0,03	2,83
12	38,25	16,71	17,53	52,20	16,71	18,95
13						
14	25,98	0,04	0,68	89,86	0,12	14,05
15	26,36	0,05	1,77	32,27	0,09	2,53
16	20,67	0,03	1,68	25,11	0,04	2,77
17						
18	26,88	0,05	1,79	42,43	0,10	2,56

Fonte: Elaboração do próprio autor.


Tabela 8 – MAPEs máximos, mínimos e médios de cada normalização dos dados numéricos para as 3 matrizes de entrada (conclusão).

Matriz	8			10		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização						
19	28,64	0,04	1,68	21,15	0,06	2,78
20						
21	22,33	0,05	0,71	108,50	0,08	15,18
22	20,35	0,05	0,69	121,63	0,11	15,06
23	20,35	0,05	0,71	118,07	0,11	15,03
24	33,65	16,71	17,28	123,05	16,77	29,53

Fonte: Elaboração do próprio autor.


Quando se analisa o intervalo de confiança, para Matriz 8, de todas as normalizações que apresentaram os melhores resultados, Figura 68 e 69, pode-se observar que as normalizações 8, 9, 14, 21, 22 e 23 aparecem com os menores valores, tanto para o valor de confiança de 0,95, quanto para o valor de 0,99.

Figura 68 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 69 – Intervalo de confiança 0,99




Fonte: Elaboração do próprio autor.

Para a Matriz 10, quando se analisa o intervalo de confiança de todas as normalizações que apresentaram os melhores resultados, Figura 70 e 71, pode-se observar que as normalizações 3, 15 e 18 aparecem com os menores valores, tanto para o valor de confiança


de 0,95, quanto para o valor de 0,99. Observa-se que as normalizações 2, 5, 11, 16 e 19 possuem valores ligeiramente maiores que as três referenciadas anteriormente.

Figura 70 – Intervalo de confiança 0,95



Fonte: Elaboração do próprio autor.

Figura 71 – Intervalo de confiança 0,99



Fonte: Elaboração do próprio autor.

6.7 ANÁLISE DA INFLUÊNCIA DAS NORMALIZAÇÕES NOS COMPORTAMENTOS DOS DADOS REFERENTES ÀS ONDAS DE IMPACTO

Após observar os resultados frente a cada uma das normalizações, era de interesse compreender como cada normalização afetava o banco de dados apresentado à rede. Devido ao tamanho do banco não era possível fazer uma análise de todos os vetores de dados, sendo assim foi selecionado apenas um para esta etapa de análise.


Optou-se por selecionar um vetor da matriz 1, que possuía as informações referentes à altura da lâmina d'água do canal (h), volume adimensional (M), número de Froude (F), inclinação da vertente (rampa de deslizamento) (α) e inclinação da praia a jusante (β) conforme equação (68). E optou-se por analisar o comportamento da saída referente à evolução das alturas máximas de onda dado pela equação (72).

Observou-se o comportamento dos dados graficamente realizando uma análise comparativa entre o antes e depois de cada normalização. Desta forma, poder-se-ia compreender melhor as razões de certas normalizações se destacarem das demais.

Nas Figuras de 72 a 87 são apresentadas todas as variações sofridas pelos dados após cada um dos tipos de normalização, tanto para matriz de entrada (ME), quanto para matriz de saída (MS). No apêndice C é apresentada uma análise mais pontual, apresentado cada uma das normalizações e as variações sofridas nos dados.


Na Figura 72 é apresentada a matriz de entrada normalizada pelo seu máximo e na Figura 73 a matriz de saída normalizada pelo seu máximo. Pode-se observar que no caso da matriz de entrada a uma redução nos valores dos dados que compõe o vetor de entrada, mas não há alteração comportamental dos dados. Na matriz de saída, após sua normalização pode-se observar que há um pequeno aumento nos valores dos dados, porém, assim como no caso da matriz de entrada, não há alteração comportamental dos dados.

Figura 72 – Máximo de ME



Fonte: Elaboração do próprio autor.


Figura 73 – Máximo de MS



Fonte: Elaboração do próprio autor.


Nas Figuras 74 e 75 pode-se observar a alteração sofrida após normalizar a matriz de entrada pelo máximo de suas colunas e a matriz de saída pelo máximo de suas colunas. Neste caso quando se observa o dado da matriz de entrada pode-se notar que há um pequeno aumento no valor referente à altura da lâmina d'água, há uma redução no valor do volume adimensional bem como no valor do número de Froude, enquanto os ângulos de inclinação permanecem com pequena redução de valores, neste caso pode-se observar uma alteração de comportamento. Quando se analisa a matriz de saída observa-se um aumento nos valores dos dados quando comparados com a situação sem normalização e que a uma leve alteração no comportamento dos dados.

Figura 74 – Máximo da coluna de ME



Fonte: Elaboração do próprio autor.


Figura 75 – Máximo da coluna de MS



Fonte: Elaboração do próprio autor.


Nas Figuras 76 e 77 observa-se a alteração sofrida após normalizar a matriz de entrada pelo máximo de suas linhas e a matriz de saída pelo máximo de suas linhas. Observa-se que neste caso há pequena redução dos valores dos dados, quando se analisa a matriz de entrada e não se observa alteração comportamental. Quando se verifica a matriz de saída após normalização, pode-se ver que há uma pequena alteração comportamental e um aumento nos valores dos dados.

Figura 76 – Máximo da linha de ME



Fonte: Elaboração do próprio autor.

Figura 77 – Máximo da linha de MS




Fonte: Elaboração do próprio autor.

Nas Figuras 78 a 81 são apresentadas as alterações sofridas nos dados de entrada e saída após serem normalizados pela somatória de suas colunas. Observa-se que em ambos os casos há redução significativa nos valores dos dados e que para o caso da matriz de entrada, diferente do caso da matriz de saída, existe uma alteração comportamental. Pode-se observar na Figura 80 que o número de Froude muda seu comportamento em relação à situação sem


normalização, diferente do caso da matriz de saída (Figura 81) onde o comportamento se mantém.

Figura 78 – Somatório da coluna de ME




Fonte: Elaboração do próprio autor.

Figura 80 – Ampliação da parte inferior da Figura 78




Fonte: Elaboração do próprio autor.

Figura 79 – Somatório da coluna de MS



Fonte: Elaboração do próprio autor.


Figura 81 – Ampliação da parte inferior da Figura 79




Fonte: Elaboração do próprio autor.

Nas Figuras 82 e 83 é apresentada a normalização da matriz de entrada e de saída por Carpenter et al. (1992). Neste caso a análise é semelhante à feita para o máximo da matriz de entrada e máximo da matriz de saída, ou seja, o comportamento é semelhante.

Figura 82 – ME por Carpenter et al. (1992) Figura 83 – MS por Carpenter et al. (1992)




Fonte: Elaboração do próprio autor.



Fonte: Elaboração do próprio autor.


Nas Figuras 84 e 85 é apresentado o comportamento dos dados após a normalização da matriz de entrada pelo Min-máx e da matriz de saída pelo Min-máx. Observa-se que para a matriz de entrada o comportamento é semelhante ao caso pelo máximo da matriz de entrada e por Carpenter et al. (1992), enquanto que para matriz de saída a pouquíssima alteração nos valores dos dados.

Figura 84 – ME pelo Min-máx



Fonte: Elaboração do próprio autor.


Figura 85 – MS pelo Min-máx



Fonte: Elaboração do próprio autor.


Por fim, nas Figuras 86 e 87 são apresentadas as alterações após a normalização da matriz de entrada pelo Máx-min e da matriz de saída pelo Máx-min. Neste caso os dados de entrada tem um comportamento espelhado em comparação a normalização pelo máximo da entrada, por Carpenter et al. (1992) e pelo Min-máx. Enquanto para a matriz de saída os dados tem um espelhamento em relação a situação sem normalização.

Figura 86 – ME pelo Máx-min



Fonte: Elaboração do próprio autor.

Figura 87 – MS pelo Máx-min



Fonte: Elaboração do próprio autor.

Com base no apresentado é possível compreender quais e porque as 7 normalizações apresentadas no Capítulo 6 subitem 6.6 apresentam-se como as melhores entre as 24 normalizações testadas, sendo possível observar a semelhança no comportamento dos dados após normalização entre as 7 melhores.

No Quadro 4 fica mais claro quais foram as normalizações que se sobressaíram e sua semelhança.

Quadro 4 – Melhores normalizações conforme Cap. 5

Normalização	
2	ME – Máx de ME ; MS - Carpenter
5	ME – Máx da Coluna; MS - Carpenter
8	ME – Máx da Linha; MS - Carpenter
11	ME – Somatório da Coluna; MS - Carpenter
14	ME – Carpenter; MS - Carpenter
16	ME – Min-máx; MS - Carpenter
19	ME – Máx-min; MS - Carpenter

Fonte: Elaboração do próprio autor.

Observou-se que existe uma relação entre a normalização da entrada e da saída de forma que algumas combinações se sobressaíram em relação a outras, sendo que aquelas cuja normalização da saída era segundo Carpenter et al. (1992) apresentavam melhores resultados que as demais.

Ainda foi possível observar que aquelas cuja matriz de entrada tinha comportamentos semelhantes, como é o caso do Máximo da matriz de entrada, Carpenter et al. (1992), Min-máx e Máx-min, possuíam os melhores resultados, fato que fica mais evidente quando se analisa os resultados das normalizações e a análise gráfica.

6.8 ANÁLISE DA INFLUÊNCIA DA NORMALIZAÇÃO NA DETERMINAÇÃO DAS ALTURAS MÁXIMAS NA SITUAÇÃO PADRÃO E MODIFICADA PARA H= 0,12 METROS

Foi realizado um pequeno estudo da influência da modificação dos valores dos parâmetros de treinamento nos resultados apresentados pelas normalizações, como forma de complementar o estudo anterior.

Foram exploradas apenas as 14 primeiras normalizações em duas situações: padrão e modificada. A situação padrão refere-se à utilizada em todo trabalho e a situação alterada refere-se à utilizada neste momento do estudo. Os valores dos parâmetros investigados são apresentados na Tabela 9.

Observa-se que este estudo complementa o estudo publicado no artigo: “*Impact Waves Prediction by Fuzzy ARTMAP Neural Network*” (Oliveira *et al.*, 2020).

Tabela 9 - Parâmetros utilizados para o treinamento da RNA

Parâmetros	Padrão	Alterada
α	0,1	0,1
β	1,0	1,0
ρ_a	0,5	0,97
ρ_b	1,0	1,0
ρ_{ab}	1,0	1,0
ρ_d	0,5	0,8
ε	0,05	0,05

Fonte: Oliveira *et al.* (2020).

Na situação padrão o treinamento era realizado com 50% dos dados referentes à altura da lâmina d’água $h=0,12$ metros e os outros 50% eram para previsão, enquanto na situação alterada o treinamento recebia 80% dos dados e a previsão os 20% restantes.

Observa-se que os dados utilizados já foram filtrados segundo os critérios apresentados no capítulo 4 subitem 4.4, todas as demais condições para treinamento e diagnóstico da rede foram mantidas (quantidades de repetições e normalizações).

Na Tabela 10 são apresentados os valores dos MAPEs máximos, mínimos e médios obtidos em cada uma das 14 normalizações e nas duas situações, padrão e alterada.

Tabela 10 – Resultados dos MAPEs na situação padrão e alterada

	Padrão			Alterada		
MAPE	Máximo	Mínimo	Médio	Máximo	Mínimo	Médio
Normalização						
1	78,98	1,78	16,25	35,05	1,79	11,29
2	14,42	0,32	4,32	6,53	0,32	3,84
3	95,10	1,15	16,21	33,35	1,79	12,35
4	63,98	1,79	13,73	18,56	0,00	8,89
5	12,60	0,31	4,79	12,84	0,00	3,68
6	45,72	0,00	15,41	33,35	1,79	9,11
7	61,64	1,15	15,83	22,53	2,04	4,22
8	17,41	0,63	5,13	10,18	0,32	1,31
9	16,86	0,70	6,97	11,09	0,70	2,33
10	34,89	0,00	12,75	22,79	1,85	10,08
11	20,59	0,31	4,23	8,00	0,90	3,74
12	127,61	0,00	14,90	16,81	1,79	7,72
13	75,05	1,15	17,65	22,63	1,79	4,54
14	20,59	0,32	5,39	8,95	0,32	3,82

Fonte: Elaboração do próprio autor.

Neste caso, em que apenas os dados referentes à $h = 0,12$ metros foram utilizados, pode-se observar que as normalizações 2, 5, 8, 9, 11 e 14 aparecem em destaque, com os menores valores.

Analisando apenas o MAPE médio, na situação padrão, as normalizações 2, 5 e 11 tem os melhores resultados e na situação alterada as normalizações 8 e 9.

Observou-se que ao se trabalhar apenas com os dados de evolução das alturas máximas, os valores dos MAPEs são muito melhores que na situação onde se utilizou todos os dados. Também se observou que na situação alterada há uma melhora significativa na resposta da rede.

Entretanto deve-se observar que para a criação de um sistema de alerta, quanto mais informações a rede possui, maior é sua capacidade de analisar a situação em que se encontra e ser capaz de gerar um alerta corretamente, não sendo este pequeno estudo norteador do trabalho, mas sim um indicativo de que existe muito mais a ser explorado.

7 CLASSIFICAÇÃO DAS ONDAS

7.1 CLASSIFICAÇÃO DAS ONDAS


Nas etapas anteriores foram estudadas as previsões da rede e a influência da normalização no processo de previsão, nesta etapa estudou-se a capacidade da rede de realizar a classificação das ondas de impacto segundo as informações apresentadas por Huber (1980).

As ondas de impacto foram classificadas segundo os seguintes tipos por Huber (1980):

- “Onda Tipo A: Um grupo de ondas em forma de seno com caráter disperso, a maior onda está dentro do grupo” (HUBER, 1980);
- “Onda Tipo B: Grupo de onda com caráter disperso, domina uma onda senoidal a cnoidal na frente da expansão” (HUBER, 1980);
- “Onda Tipo C: A onda anterior é muito mais alta e mais rápida do que a seguinte, tem uma forma de cnoidal para onda solitária” (HUBER, 1980);
- “Onda Tipo D: O movimento da água mostra-se em uma onda solitária, as perturbações subsequentes não são importantes”(HUBER, 1980).

Na Figura 88 são apresentados os quatro tipos de ondas, porém existem casos onde foram observadas ondas que possuíam características de mais de um tipo, Tabela 23 do anexo C.

Figura 88 – Ondas tipo A, B, C e D respectivamente.



Fonte: Adaptado de Huber (1980).

Para os testes de classificação foram utilizadas das normalizações anteriores, sendo escolhidas as normalizações 2, 5, 8, 11 e 14, todos os parâmetros padrões e os dados já filtrados anteriormente foram mantidos.

Após algumas análises observou-se que a resposta foi à mesma, a rede classificou com sucesso todos os tipos de ondas, não havendo erro na classificação, independente do número de repetições e da normalização escolhida.

Observa-se que apenas os dados referentes a altura $h = 0,12$ m são apresentados a seguir, para os demais casos não se verificou a necessidade de apresentação, uma vez que a RNA teve sucesso em todos. Assim, nas Tabelas 11 e 12 são apresentados os resultados para a normalização 14, visto que para este caso se observou que não há influência da normalização.

Na Tabela 11 é apresentada a classificação da rede, para a altura $h = 0,12$ m, na forma numérica, devido há necessidade de conversão para a notação utilizada por Huber (1980) optou-se por refazer a classificação trocando os números por letras, o resultado é apresentado na Tabela 12.

Tabela 11 - Classificação da rede para altura $h = 0,12$ metros

Experimento	Classif.	Experimento	Classif.	Experimento	Classif.	Experimento	Classif.
0,111	0,111	0,1	0,1	0,111	0,111	0,1	0,1
0,111	0,111	0,01	0,01	0,1	0,1	0,111	0,111
0,011	0,011	0,111	0,111	0,111	0,111	0,1	0,1
0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1
0,11	0,11	0,01	0,01	0,1	0,1	0,1	0,1
0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1
0,111	0,111	0,01	0,01	0,1	0,1	0,111	0,111
0,011	0,011	0,1	0,1	0,1	0,1	0,11	0,11
0,111	0,111	0,111	0,111	0,1	0,1	0,111	0,111
0,1	0,1	0,01	0,01	0,11	0,11		
0,1	0,1	0,111	0,111	0,011	0,011		
0,011	0,011	0,01	0,01	0,1	0,1		
0,1	0,1	0,111	0,111	0,111	0,111		
0,111	0,111	0,1	0,1	0,111	0,111		
0,111	0,111	0,1	0,1	0,111	0,111		
0,111	0,111	0,11	0,11	0,1	0,1		
0,111	0,111	0,011	0,011	0,1	0,1		
0,1	0,1	0,011	0,011	0,111	0,111		
0,1	0,1	0,111	0,111	0,111	0,111		
0,1	0,1	0,1	0,1	0,001	0,001		
0,111	0,111	0,01	0,01	0,1	0,1		
0,1	0,1	0,1	0,1	0,1	0,1		
0,1	0,1	0,1	0,1	0,1	0,1		
0,01	0,01	0,1	0,1	0,01	0,01		

Fonte: Elaboração do próprio autor.

Nota: 0,001 – A; 0,010 – B; 0,011 – C; D – 0,100; A/B – 0,101; B/C – 0,110; C/D – 0,111. Classif. – Classificação.

Tabela 12 - Classificação da rede para altura h=0,12 metros

Experiment o	Classif .	Experiment o	Classif .	Experiment o	Classif .	Experiment o	Classif .
B	B	D	D	C/D	C/D	D	D
D	D	D	D	D	D	D	D
C/D	C/D	D	D	C/D	C/D	C	C
C/D	C/D	C	C	C/D	C/D	C/D	C/D
D	D	C/D	C/D	D	D	D	D
D	D	D	D	C	C	D	D
B/C	B/C	C/D	C/D	B	B	C	C
B	B	C	C	B	B	C/D	C/D
D	D	D	D	B/C	B/C	C/D	C/D
C/D	C/D	C	C	C/D	C/D		
B/C	B/C	C/D	C/D	D	D		
C	C	C/D	C/D	B/C	B/C		
C/D	C/D	C/D	C/D	B/C	B/C		
C/D	C/D	B/C	B/C	D	D		
C	C	D	D	D	D		
C/D	C/D	D	D	C/D	C/D		
D	D	B	B	D	D		
B	B	C	C	B/C	B/C		
D	D	C/D	C/D	A	A		
C/D	C/D	C/D	C/D	C/D	C/D		
D	D	C	C	D	D		
D	D	C/D	C/D	B	B		
D	D	D	D	C/D	C/D		
C/D	C/D	C	C	C	C		

Fonte: Elaboração do próprio autor.

Nota: Legenda: Classif. – Classificação.

Observa-se diferença de resultado entre as tabelas devido à entrada da RNA ser de maneira randômica, como explicado na metodologia, porém pode-se visualizar que não há diferença entre o resultado experimental observado por Huber (1980) e a classificação dada pela RNA.

Conclui-se que a rede neural é capaz de classificar com sucesso os tipos de ondas de acordo com o banco de dados fornecido.

8 CONCLUSÃO

Neste estudo foi utilizada a rede ARTMAP Fuzzy para previsão das alturas, períodos e comprimentos relativos das ondas de impacto, para realização deste estudo foram extraídas as informações presentes no trabalho de Huber, A. (1980), cujas planilhas estão apresentadas no Anexo C. Após a extração foi criado o banco de dados de ondas de impacto, sendo necessária a conversão dos dados presentes nas planilhas para números adimensionais.

O banco de dados de ondas de impacto foi composto pelo número de Froude, Volume adimensional, ângulo de inclinação da rampa de deslizamento e ângulo de inclinação da margem oposta, foi acrescentado ao banco de dados os dados referentes às alturas da lâmina d'água, este dado sendo dimensional. As seguintes faixas de valores foram utilizadas neste estudo:

- h : 0,12 m; 0,18 m; 0,27 m e 0,36 m;
- $0,53 < Fr < 3,69$;
- $0,028 < M < 2,58$;
- $0,46 < \alpha < 0,87$;
- $0,083 < \beta < 1$;

Após a elaboração do banco de dados foi necessário o estudo dos mesmos de forma a compreender como deveriam ser apresentados a rede, sendo esta etapa uma das mais importantes para o sucesso do estudo, assim foi possível iniciar os estudos com a rede neural ARTMAP Fuzzy.

O segundo ponto importante identificado na etapa preliminar deste trabalho foi a elaboração das matrizes de entrada e saída da rede, etapa que era dependente da anterior, referente a compreensão do banco de dados.

Num primeiro momento foi utilizada apenas a normalização segundo Carpenter *et al.* (1992), foram testados vários valores para os parâmetros de treinamento até que se chegar a os valores apresentados na Tabela (1). Também foi utilizada a apresentação dos dados de maneira randômica, o que permitiu o desenvolvimento das métricas utilizadas para avaliação da metodologia.

As métricas utilizadas neste trabalho foram o MAPE médio e o RMSE médio em conjunto. Estas métricas foram selecionadas após diversos estudos com análises isoladas, foram utilizados MAPE mínimo, MAPE médio, RMSE mínimo, RMSE médio e em nenhum

caso se obteve os resultados esperados, desta forma foi utilizado então o MAPE médio conforme explicado subitem 4.3 do Capítulo 4.

Os testes foram repetidos 500 vezes e foi selecionada a melhor previsão conforme critério de seleção. Foi observada a capacidade da rede neural ARTMAP FUZZY em realizar as previsões da evolução das alturas máximas, comprimentos e períodos relativos das ondas de impacto.

Com base neste estudo foram realizados modificações na matriz de entrada, removendo parte dos dados, conforme apresentado no subitem 4.5 do Capítulo 4. Deste estudo compreendeu-se que apenas o volume adimensional era suficiente para a realização de boas previsões, semelhante ao constatado por Huber, A. (1980).

Assim, observou-se que o volume adimensional é o parâmetro que faz a conexão entre o modelo experimental, a rede e situações reais, sendo de grande interesse em estudos futuros, com este parâmetro pode-se gerar outras simulações que contribuíram para o desenvolvimento dos sistemas de alerta para evitar novas catástrofes.

A rede neural ARTMAP Fuzzy utiliza como base a normalização segundo Carpenter *et al.* (1992), foi então questionado se a mesma seria ideal para o problema abordado de forma que o segundo grande estudo deste trabalho foi a verificação da influência da normalização na previsão da rede neural ARTMAP Fuzzy e para este estudo foram testadas 24 normalizações conforme apresentado no Capítulo 6. Verificou-se a influência que a normalização teria no banco de dados experimental, relativo a ondas de impacto, e em um banco de dados numérico, relativo a *roll waves*.

Para a avaliação do estudo proposto foi criado uma segunda métrica, utilizou-se o MAPE mínimo, médio e máximo, bem como a análise pelo intervalo de confiança de 95% e 99%, ou seja, a avaliação de todos estes valores permitia selecionar quais as melhores normalizações para o problema.

Após este estudo constatou-se, para o banco de dados experimental, que as normalizações 2, 5, 8, 11, 14, 16 e 19 eram as que possuíam as melhores previsões. Observando que neste estudo também se variou a matriz de entrada de quatro formas conforme apresentado no Capítulo 6.

De maneira mais pontual, após as avaliações conforme a métrica selecionada:

- Para o caso da matriz de saída referente a evolução das alturas máximas, e cada uma das matrizes de entrada: para a matriz 1 as melhores normalizações foram a 11 e 19, para a matriz 2 foram as normalizações 14 e 19, para a matriz 3 foi a normalização 11, e para a matriz 4 foram as normalizações 5 e 19.

- Para o caso da matriz de saída referente ao comprimento relativo, e cada uma das matrizes de entrada: para a matriz 1 a melhor normalização foi a 5, para a matriz 2 foi a normalização 16, para a matriz 3 foram as normalizações 2 e 5, e para a matriz 4 foi a normalização 11.
- Para o caso da matriz de saída referente ao período relativo, e cada uma das matrizes de entrada: para a matriz 1 as melhores normalizações foram a 2 e 5, para a matriz 2 foi a normalização 19, para a matriz 3 foi a normalização 16, e para a matriz 4 foi a normalização 14.

Quando foram analisados os MAPEs e dos intervalos de confiança de maneira geral, para o caso do banco de dados de ondas de impacto, as normalizações mais recomendadas e que apresentaram melhores resultados foram às normalizações 5, 11 e 16, também podendo incluir a normalização 19.

No caso do banco de dados numérico relativo a *roll waves*, houve boas respostas em diversas normalizações, sendo estas: 2, 3, 5, 8, 9, 11, 12, 15, 16, 18, 19, 21, 22 e 23, as que tiveram melhores resultados entre as 17 testadas, sendo que as normalizações 1, 4, 7, 10, 13, 17, 20 não puderam ser testadas por não normalizarem a saída. E após as análises dos MAPEs e dos intervalos de confiança apresentados no Capítulo 6, as normalizações 2, 3, 5, 15, 16 e 19 aparecem com mais destaque e destas as normalizações 16 e 19 seriam as mais recomendadas para o banco numérico.

Quando se observou o resultado apresentado para cada normalização estudada em cada um dos bancos de dados, ondas de impacto e *roll waves*, verificou-se que as normalizações 16, que é a normalização da matriz de entrada pelo min-máx e da matriz de saída por Carpenter *et al.* (1992), e a normalização 19, que é a normalização da matriz de entrada pelo máx-min e normalização da matriz de saída por Carpenter *et al.* (1992), foram as que apresentaram uma melhor previsão.

Outro fator que ficou evidente foi que as melhores normalizações estavam associadas com a normalização da matriz de saída por Carpenter *et al.* (1992), porém o mesmo não ocorria quando se invertia as normalizações, ou seja, quando se normalizava a matriz de entrada por Carpenter *et al.* (1992) e a matriz de saída pelas demais normalizações.

Ressalta-se então que a normalização é um processo importante na fase de pré-processamento dos dados e que dentre as normalizações testadas observou-se que o processo de normalização que reduz a informação, porém mantinha o seu comportamento é o que apresentou o melhor desempenho.

Além disto, foi observado que mesmo a matriz de saída sendo composta de valores dentro do intervalo de zero a um, condição requerida pela rede neural ARTMAP Fuzzy, a sua normalização pode ser necessária. Tal afirmação ficou evidente após o estudo da influência da normalização, uma vez que, as situações onde a matriz de saída era normalizada apresentaram melhores resultados quando comparada com a situação sem normalização.

Com base no que foi observado deste estudo compreendeu-se que nem sempre a normalização recomendada pela literatura será a ideal ao problema proposto, sendo, portanto, necessária uma pré-etapa de análise antes da definição da normalização.

Outro ponto que foi observado durante as análises da influência das normalizações graficamente foi que uma grande alteração nos valores dos dados nem sempre impossibilita uma boa previsão e que aquelas que tinham comportamento mais similar a normalização por Carpenter *et al.* (1992) obtiveram as melhores previsões e ainda que a normalização da saída possuía um maior peso nos resultados apresentados pela RNA do que a normalização da entrada.

O ultimo fato anterior ficou ainda mais evidente nos casos onde se utilizava a normalização 14 na matriz de saída, nestes casos os resultados eram muito melhores do que nos demais, todas as sete normalizações que se destacaram utilizavam a normalização 14 na matriz de saída. Porém ressalta-se que seriam necessárias investigações mais aprofundadas para maior compreensão disto.

O terceiro estudo foi as variações nos parâmetros de treinamento da rede neural, para um pequeno caso, com apenas os dados relativos a $h = 0,12$ m, neste estudo foram comparadas duas situações, padrão e modificada, sendo que na modificada a rede era mais seletiva. Foi observado que para os parâmetros padrões as normalizações 2, 5 e 11 aparecem com os melhores resultados e na situação alterada as normalizações 8 e 9 se destacavam, observando que não foram analisadas as normalizações de 15 a 24.

Este estudo mostrou que apesar das alterações nos valores dos parâmetros de treinamento e diagnóstico, bem como na quantidade de informação apresentada à rede, referente as porcentagens de treinamento e diagnóstico, as normalizações em destaque se mantinham. Observa-se que para este terceiro estudo há a necessidade de um maior aprofundamento, verificando a reposta para os demais dados do banco experimental de ondas de impacto e do banco de dados referente a *roll waves*.

E o quarto e último estudo refere-se a classificação das ondas de impacto segundo os tipos de onda, pode-se observar que a RNA conseguiu classificar sem dificuldade da normalização utilizada.

A rede neural ARTMAP Fuzzy é uma poderosa ferramenta capaz de realizar com sucesso a previsão e classificação das ondas de impacto, bem como previsão das *roll waves* e pode ser utilizada para criação sistemas de alerta.

9 SUGESTÕES PARA TRABALHOS FUTUROS

Com base em todo estudo já realizado propõe-se que seja criado um algoritmo de análise inicial da normalização recomendada ao problema proposto a rede neural artificial, como etapa de pré-análise.

Também a criação de um algoritmo capaz de realizar a previsão, ao mesmo tempo, de todos os parâmetros relativos as ondas de impacto e sua classificação e não mais de maneira isolada como neste estudo.

Outra sugestão é a criação de uma rede inversa, capaz de prever ao invés dos parâmetros de onda, os parâmetros de ensaio, permitindo escolher o tipo de onda que se deseja observar em laboratório, servindo de auxílio na observação do fenômeno em uma escala reduzida.

Propõe-se também a modificação da arquitetura da rede de forma a permitir alimentações com outros parâmetros não abordados no estudo, criando um sistema composto por diversas análises, capaz de identificar todos os casos existentes relativos as ondas de impacto.

Também se sugere um estudo com o volume adimensional de situações reais realizando uma comparação entre o caso real, a rede, o experimental e o numérico.

Por fim, também se sugere uma análise gráfica diferenciada, trazendo as alturas de ondas previstas pela RNA, as medidas experimentalmente e as resultantes de simulações numéricas (modelos numéricos), para efeitos comparativos.

REFERÊNCIAS

AL SHALABI, Luai; SHAABAN, Ziad. Normalization as a preprocessing engine for data mining and the approach of preference matrix. In: INTERNATIONAL CONFERENCE ON DEPENDABILITY OF COMPUTER SYSTEMS, 2006. **Proceedings** [...] New York: IEEE, 2006. p. 207-214.

AGRAWAL, J. D.; DEO, M. C. Wave parameter estimation using neural networks. **Marine structures**, Barking, v. 17, n. 7, p. 536-550, 2004.

AGGARWAL, Charu C.; CLUSTERING, C. K **Reddy data**. algorithms and applications. 2014. Boca Raton: CRC, 2014.

ANAGNOSTOPOULOS, Georgios C.; GEORGIOPULOS, M. Hypersphere ART and ARTMAP for unsupervised and supervised, incremental learning. In: **Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium**. New York: IEEE, 2000. p. 59-64.

ASFOUR, Yousif R. *et al.* Fusion ARTMAP: An adaptive fuzzy network for multi-channel classification. In: **Third International Conference on Industrial Fuzzy Control and Intelligent Systems**. New York: IEEE, 1993. p. 155-160.

BARROS, Ana Claudia *et al.* Detection and classification of voltage disturbances in electrical power systems using a modified Euclidean ARTMAP neural network with continuous training. **Electric Power Components and Systems**, Philadelphia, v. 43, n. 19, p. 2178-2188, 2015.

BELLONI, L. G.; STEFANI, R. The Vajont slide: instrumentation—past experience and the modern approach. **Engineering Geology**, Amsterdam, v. 24, n. 1-4, p. 445-474, 1987.

BENGIO, Yoshua *et al.* Greedy layer-wise training of deep networks. **Advances in neural information processing systems**, San Mateo, v. 19, p. 153, 2007.

Bergsturz Museum. Disponível em: <https://www.arth-online.ch/bergsturz/ausstellung/> Acessado em: 13/11/2020.

BISCARINI, Chiara. Computational fluid dynamics modelling of landslide generated water waves. **Landslides**, v. 7, n. 2, p. 117-124, 2010.

BISTACCHI, ANDREA *et al.* A 3D geological model of the 1963 Vajont landslide. **Italian Journal of Engineering Geology and Environment**, Roma, v. 6, p. 531-539, 2013.

BONNEY, Thomas George. **The Alpine regions of Switzerland and the neighbouring countries: a pedestrian's notes on their physical features, scenery, and natural history**. Deighton, Bell and Company, 1868.

BOSA, Silvia; PETTI, Marco. A numerical model of the wave that overtopped the Vajont dam in 1963. **Water resources management**, [s. l.], v. 27, n. 6, p. 1763-1779, 2013.

BOSA, Silvia; PETTI, Marco. Shallow water numerical model of the wave generated by the Vajont landslide. **Environmental Modelling & Software**, Oxford , v. 26, n. 4, p. 406-418, 2011.

BOURLARD, Hervé; KAMP, Yves. Auto-association by multilayer perceptrons and singular value decomposition. **Biological cybernetics**, New York, v. 59, n. 4, p. 291-294, 1988.

BOURLARD, Hervé. Auto-association by multilayer perceptrons and singular value decomposition. **IDIAP**, Martigny, 2000.

BOUTOUNET, Marc; NOBLE, Pascal; VILA, Jean-Paul. Roll-waves in bi-layer flows. **Mathematical Models and Methods in Applied Sciences**, Singapore, v. 22, n. 06, p. 1250006, 2012.

BUSSMANN, Felix; ANSELMETTI, Flavio S. Rossberg landslide history and flood chronology as recorded in Lake Lauerz sediments (Central Switzerland). **Swiss Journal of geosciences**, [s. l.], v. 103, n. 1, p. 43-59, 2010. <https://doi.org/10.1007/s00015-010-0001-9>.

BOZINOVSKI, Stevo. Modeling Mechanisms of Cognition-emotion Interaction in Artificial Neural Networks, since 1981. **Procedia Computer Science**, [s. l.], v. 41, p. 255-263, 2014.

BROOMHEAD, David S.; LOWE, David. **Radial basis functions, multi-variable functional interpolation and adaptive networks**. Royal Signals and Radar Establishment Malvern (United Kingdom), 1988.

CAMPOMAGGIORE, Francesca *et al.* Inlet effects on roll-wave development in shallow turbulent open-channel flows. **Journal of Hydrology and Hydromechanics**, Varsóvia, v. 64, n. 1, p. 45-55, 2016.

CARATTO, M.; SEMENZA, E.; TURRINI, Maria Chiara. Study of bank instability of the Pontesei hydraulic reservoir (Belluno Province – N.E. Italy.), in: **Proceedings of the first European Conference on Landslides**, Prague, 2002. p. 529-533.

CARPENTER, Gail A.; GROSSBERG, Stephen. A massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer vision, graphics, and image processing**, [s. l.], v. 37, n. 1, p. 54-115, 1987a.

CARPENTER, Gail A.; GROSSBERG, Stephen. ART 2: Self-organization of stable category recognition codes for analog input patterns. **Applied optics**, New York, v. 26, n. 23, p. 4919-4930, 1987b.

CARPENTER, Gail A. ; GROSSBERG, Stephen. The ART of adaptive pattern recognition by a self-organizing neural network. **Computer**, New York: IEEE, v. 21, n. 3, p. 77-88, 1988.

CARPENTER, Gail A.; GROSSBERG, Stephen. ART 3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. **Neural networks**, New York, v. 3, n. 2, p. 129-152, 1990.

CARPENTER, Gail A.; GROSSBERG, Stephen; REYNOLDS, John H. ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. **Neural networks**, New York, v. 4, n. 5, p. 565-588, 1991.

CARPENTER, Gail A.; GROSSBERG, Stephen; ROSEN, David B. ART 2-A: An adaptive resonance algorithm for rapid category learning and recognition. **Neural networks**, New York, v. 4, n. 4, p. 493-504, 1991.

CARPENTER, Gail A.; GROSSBERG, Stephen; ROSEN, David B. Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural networks**, New York, v. 4, n. 6, p. 759-771, 1991.

CARPENTER, Gail A.; GROSSBERG, Stephen. A self-organizing neural network for supervised learning, recognition, and prediction. **IEEE Communications Magazine**, New York, v. 30, n. 9, p. 38-49, 1992.

CARPENTER, Gail A.; GROSSBERG, Stephen; IIZUKA, Kunihiko. **Comparative performance measures of fuzzy ARTMAP, learned vector quantization, and back propagation for handwritten character recognition**. Boston University, Center for Adaptive Systems and Department of Cognitive and Neural Systems, 1992. v. 1, pp. 794-799.

Carpenter, Gail A. Grossberg, S., Markuzon, N., Reynolds, J. H., & Rosen, D. B.. Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on neural networks**, New York, v. 3, n. 5, p. 698-713, 1992.

CARPENTER, Gail A.; ROSS, William D. ART-EMAP: A neural network architecture for object recognition by evidence accumulation. **IEEE Transactions on Neural Networks**, New York, v. 6, n. 4, p. 805-818, 1995.

CARPENTER, Gail; GROSSBERG, Stephen. **Adaptive Resonance Theory**. Boston University Center for Adaptive Systems and Department of Cognitive and Neural Systems, 1998.

CARPENTER, Gail A.; GROSSBERG, Stephen. Adaptive Resonance Theory. 2016. © Springer Science+Business Media New York 2016, C. Sammut, G.I. Webb (eds.), **Encyclopedia of Machine Learning and Data Mining**, DOI 10.1007/978-1-4899-7502-7 6-1

CARVALHO, E. *et al.* DESLIZAMENTO DE ENCOSTA NO RESERVATORIO DA USINA DE FURNAS - ESTUDOS HIDRAULICOS EXPERIMENTAIS. In: SEMINARIO NACIONAL DE GRANDES BARRAGENS, 19, 1991. [S. l.: s. n.], p. 99-108.

CHUNG, Junyoung *et al.* Empirical evaluation of gated recurrent neural networks on sequence modeling. **arXiv preprint arXiv:1412.3555**, 2014.

Contrée de Busingen Lauwerz Rothen e du Rossberg avant la terrible catastrophe du 2e Septembre 1806. Disponível em: https://www.britishmuseum.org/collection/object/P_1958-0712-2243 Acessado em: 13/11/2020.

CUNHA, Evandro Fernandes da. Implementação de aparato experimental para medição de instabilidades tipo Roll Waves em fluidos não-newtonianos. 2013. 107. Dissertação (mestrado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Engenharia, 2013. Disponível em: <<http://hdl.handle.net/11449/124473>>.

CRAIK, Alex DD. The origins of water wave theory. *Annual Review of Fluid Mechanics*, Palo Alto, v. 36, p. 1-28, 2004.

CREMONESI, M.; FRANGI, A.; PEREGO, U. A Lagrangian finite element approach for the simulation of water-waves induced by landslides. **Computers & structures**, Elmsford, v. 89, n. 11-12, p. 1086-1093, 2011.

DE FREITAS MACIEL, Geraldo; DO NASCIMENTO, Maria Francisca. Modelagem Numérica de Ondas de Submersão Utilizando o Modelo de Serre. In: **RBRH**, Porto Alegre, v.7, n.3, 19-24, 2002.

DE FREITAS MACIEL, Geraldo; DE OLIVEIRA FERREIRA, Fabiana; FIOROT, Guilherme Henrique. Control of instabilities in non-Newtonian free surface fluid flows. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Rio de Janeiro, v. 35, n. 3, p. 217-229, 2013.

DI CRISTO, Cristiana *et al.* Roll-waves prediction in dense granular flows. **Journal of Hydrology**, Amsterdam, v. 377, n. 1-2, p. 50-58, 2009.

DOMINIC, Stephen *et al.* Genetic reinforcement learning for neural networks. In: **IJCNN-91-Seattle International Joint Conference on Neural Networks**. Seattle, IEEE, 1991. p. 71-76. vol.2, doi: 10.1109/IJCNN.1991.155315.

EESA, Adel S.; ARABO, Wahab Kh. A normalization methods for backpropagation: a comparative study. **Science Journal of University of Zakho**, Zakho, v. 5, n. 4, p. 319-323, 2017.

ELMAN, Jeffrey L. Finding structure in time. **Cognitive science**, Norwood, v. 14, n. 2, p. 179-211, 1990.

EVERS, Frederic M.; HAGER, Willi H. Impulse wave generation: Comparison of free granular with mesh-packed slides. **Journal of marine science and engineering**, [s. l.], v. 3, n. 1, p. 100-110, 2015.

EVERS, Frederic. **Spatial propagation of landslide generated impulse waves**. 2017. Tese de Doutorado. ETH Zurich. <https://doi.org/10.3929/ethz-b-000209471>

EVERS, Frederic *et al.* Landslide-generated Impulse Waves in Reservoirs: Basics and Computation. **VAW-Mitteilungen**, [s. l.], v. 254, 2019. <https://doi.org/10.3929/ethz-b-000413216>

FIOROT, G. H. *et al.* Experimental setup for measuring roll waves on laminar open channel flows. **Flow Measurement and Instrumentation**, Guilford, v. 41, p. 149-157, 2015.

FRANCESE, ROBERTO *et al.* 3D Geophysical imaging of the Vajont landslide and of its surroundings. **Italian Journal of Engineering Geology and Environment**, Roma, p. 555-565, 2013.

FRITZ, Hermann M. Lituya Bay case rockslide impact and wave run-up. **Science of tsunami Hazards**, Ispra, v. 19, n. 1, p. 3-22, 2001.

FRITZ, Hermann M. **Initial phase of landslide generated impulse waves**. 2002. Tese de Doutorado. ETH Zurich. <https://doi.org/10.3929/ethz-a-004443906>

FRITZ, Hermann M.; HAGER, Willi H.; MINOR, H.-E. Near field characteristics of landslide generated impulse waves. **Journal of waterway, port, coastal, and ocean engineering**, [s. l.], v. 130, n. 6, p. 287-302, 2004.

FRITZ, Hermann M.; MOHAMMED, Fahad; YOO, Jeseon. Lituya bay landslide impact generated mega-tsunami 50 th anniversary. In: **Tsunami Science Four Years after the 2004 Indian Ocean Tsunami**. Birkhäuser Basel, 2009. p. 153-175.

FUCHS, Helge; HELLER, Valentin; HAGER, Willi H. Impulse wave run-over: experimental benchmark study for numerical modelling. **Experiments in fluids**, Berlin, v. 49, n. 5, p. 985-1004, 2010.

FUCHS, Helge. **Solitary impulse wave run-up and overland flow**. Swiss Federal Institute of Technology ETH, 2013. <https://doi.org/10.3929/ethz-a-009787661>

GEORGIOPOULOS, Michael *et al.* Order of search in Fuzzy ART and Fuzzy ARTMAP: Effect of the choice parameter. **Neural Networks**, New York, v. 9, n. 9, p. 1541-1559, 1996.

GHIROTTI, MONICA *et al.* The 1963 Vajont landslide (northeast alps, Italy): post-conference field trip (October 10th, 2013). In: **International Conference on Vajont-1963-2013: thoughts and analyses after**. Padua, 2013. p. 635-646.

GOODFELLOW, Ian J. *et al.* Generative adversarial networks. **arXiv preprint arXiv:1406.2661**, 2014.

GRANGER, Eric *et al.* Match tracking strategies for fuzzy ARTMAP neural networks. In: **Handbook Of Pattern Recognition And Computer Vision**. [s. l.]: World Scientific, 2010. p. 73-100.

GRAVES, Alex; WAYNE, Greg; DANIHELKA, Ivo. Neural turing machines. **arXiv preprint arXiv:1410.5401**, 2014.

GRAVES, Alex *et al.* Hybrid computing using a neural network with dynamic external memory. **Nature**, [s. l.], v. 538, n. 7626, p. 471-476, 2016.

GROSSBERG, Stephen. Nonlinear difference-differential equations in prediction and learning theory. **Proceedings of the National Academy of Sciences of the United States of America**, Washington, v. 58, n. 4, p. 1329, 1967.

GROSSBERG, Stephen. Adaptive pattern classification and universal recoding: I. Parallel development and coding of neural feature detectors. **Biological cybernetics**, New York, v. 23, n. 3, p. 121-134, 1976a.

GROSSBERG, Stephen. Adaptive pattern classification and universal recoding: II. Feedback, expectation, olfaction, illusions. **Biological cybernetics**, New York, v. 23, n. 4, p. 187-202, 1976b.

GROSSBERG, Stephen. On the development of feature detectors in the visual cortex with applications to learning and reaction-diffusion systems. **Biological Cybernetics**, New York, v. 21, n. 3, p. 145-159, 1976c.

GROSSBERG, Stephen. Nonlinear neural networks: Principles, mechanisms, and architectures. **Neural networks**, New York, v. 1, n. 1, p. 17-61, 1988.

GROSSBERG, Stephen; SEIDMAN, Don. Neural dynamics of autistic behaviors: cognitive, emotional, and timing substrates. **Psychological review**, Washington, v. 113, n. 3, p. 483, 2006. <https://doi.org/10.1037/0033-295X.113.3.483>

GROSSBERG, Stephen. Adaptive Resonance Theory: How a brain learns to consciously attend, learn, and recognize a changing world. **Neural networks**, New York, v. 37, p. 1-47, 2013.

HAYES, Brian *et al.* First links in the Markov chain. **American Scientist**, New Haven, v. 101, n. 2, p. 252, 2013.

HE, Kaiming *et al.* Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas, 2016. p. 770-778.

HEBB, Donald Olding. The organization of behavior; a neuropsychological theory. **A Wiley Book in Clinical Psychology**, London: Psychology Press, v. 62, p. 78, 1949.

HELLER, Valentin. **Landslide generated impulse waves: Prediction of near field characteristics**. 2007. Tese de Doutorado. Eth Zurich. <https://doi.org/10.3929/ethz-a-005512384>

HELLER, Valentin; HAGER, Willi H.; MINOR, Hans-Erwin. Scale effects in subaerial landslide generated impulse waves. **Experiments in Fluids**, Berlin, v. 44, n. 5, p. 691-703, 2008.

HELLER, Valentin; HAGER, Willi H.; MINOR, Hans-Erwin. Landslide generated impulse waves in reservoirs: Basics and computation. **VAW-Mitteilungen**, [s. l.], v. 211, 2009.

HELLER, V.; HAGER, Willi H. Wave types of landslide generated impulse waves. **Ocean Engineering**, Elmsford, v. 38, n. 4, p. 630-640, 2011.

HENDRON JR, A. J.; PATTON, Franklin D. **The vaiont slide. A geotechnical analysis based on new geologic observations of the failure surface**. Volume 1. Main text. ARMY ENGINEER WATERWAYS EXPERIMENT STATION VICKSBURG MS GEOTECHNICAL LAB, 1985.

HINTON, Geoffrey E. *et al.* Learning and relearning in Boltzmann machines. **Parallel distributed processing: Explorations in the microstructure of cognition**, [s. l.], v. 1, n. 282-317, p. 2, 1986.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural computation**, Cambridge, v. 9, n. 8, p. 1735-1780, 1997.

HOPFIELD, John J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the national academy of sciences**, Washington, v. 79, n. 8, p. 2554-2558, 1982.

HOSKINS, J. C.; HIMMELBLAU, D. M. Process control via artificial neural networks and reinforcement learning. **Computers & chemical engineering**, New York, v. 16, n. 4, p. 241-251, 1992.

HUANG, Guang-Bin; ZHU, Qin-Yu; SIEW, Chee-Kheong. Extreme learning machine: theory and applications. **Neurocomputing**, [s. l.], v. 70, n. 1-3, p. 489-501, 2006.

HUANG, Bolin; WANG, S. C.; ZHAO, Y. B. Impulse waves in reservoirs generated by landslides into shallow water. **Coastal Engineering**, Amsterdam, v. 123, p. 52-61, 2017.

HUBER, Andreas. **Schwallwellen in Seen als Folge von Felsstürzen**. 1980. Tese de Doutorado. ETH Zurich.

HUBER, Andreas *et al.* FELSBEWEGUNGEN UND UFERABBRUECHE AN SCHWEIZER SEEN, IHRE URSACHEN UND AUSWINKUNGEN. 1982. (<http://dx.doi.org/10.5169/seals-165242>)

ICOLD Bulletin 124 - Reservoir landslides: investigation and management – guidelines and case histories, [s. l.], 2002. p. 243

Ilustração de um modelo de neurônio biológico. Disponível em: <https://guildadocodigo.atelie.software/intelig%C3%A2ncia-artificial-parte-i-ebd62adb10> . Acessado em: 03 de março de 2021.

Ilustração de um Neurônio Artificial. Disponível em: <https://medium.com/@avinicius.adorno/redes-neurais-artificiais-418a34ea1a39> . Acessado em: 03 de março de 2021.

Interface entre Modelo Hidráulico Reduzido e Projeto em Vertedouros de Usinas Hidrelétricas. R. F. Sousa; F. M. Almeida; E. F. Trierweiler Neto. Ed. FURNAS. Goiânia, FURNAS, 2018.

IVAKHNENKO, Alekseï Grigor'evich; LAPA, Valentin Grigor'evich. Cybernetics and forecasting techniques. American Elsevier Publishing Company, [s. l.], 1967 - 168 páginas.

IVAKHNENKO, A. G. Heuristic self-organization in problems of engineering cybernetics. **Automatica**, Elmsford, v. 6, n. 2, p. 207-219, 1970.

IVANOVA, Kseniya A. *et al.* Formation and coarsening of roll-waves in shear shallow water flows down an inclined rectangular channel. **Computers & Fluids**, New York, v. 159, p. 189-203, 2017.

JADERBERG, Max *et al.* Spatial transformer networks. **arXiv preprint arXiv:1506.02025**, 2015.

JAEGER, Herbert; HAAS, Harald. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication. **Science**, Washington, v. 304, n. 5667, p. 78-80, 2004.

JAMIN, Timothée *et al.* Experiments on generation of surface waves by an underwater moving bottom. **Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences**, London, v. 471, n. 2178, p. 20150069, 2015.

JAYALAKSHMI, T.; SANTHAKUMARAN, A. Statistical normalization and back propagation for classification. **International Journal of Computer Theory and Engineering**, [s. l.], v. 3, n. 1, p. 1793-8201, 2011.

KAMPHUIS, J. W.; BOWERING, R. J. Impulse waves generated by landslides. In: **Coastal Engineering 1970**. Amsterdam, 1970. p. 575-588.

KINGMA, Diederik P.; WELLING, Max. Auto-encoding variational bayes. **arXiv preprint arXiv:1312.6114**, 2013.

KOHONEN, Teuvo. Self-organized formation of topologically correct feature maps. **Biological cybernetics**, New York, v. 43, n. 1, p. 59-69, 1982.

KREMER, Katrina; SIMPSON, Guy; GIRARDCLOS, Stéphanie. Giant Lake Geneva tsunami in ad 563. **Nature Geoscience**, London, v. 5, n. 11, p. 756-757, 2012. Disponível em: <https://doi.org/10.1038/ngeo1618>.

KROSE, B. and SMAGT, P. V. "An introduction to neural networks," Online Book, University of Amsterdam, Eighth Edition, 1996. Disponível em: <https://www.infor.uva.es/~teodoro/neuro-intro.pdf> . Acessado em: 03 de março de 2021.

KULKARNI, Tejas D. *et al.* Deep convolutional inverse graphics network. **arXiv preprint arXiv:1503.03167**, 2015.

LAMBERT, André. **Über die klastische Sedimentation im Walensee**. 1976. Tese de Doutorado. ETH Zurich.

Laterally Primed Adaptive Resonance Theor (LAPART). Disponível em: <https://lapart-python.readthedocs.io/en/latest/index.html#lapart-python-documentation>. Acessado em: 16-03-2021.

LECUN, Yann *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, New York, v. 86, n. 11, p. 2278-2324, 1998.

LI, Changdong *et al.* Application of back-propagation neural network on bank destruction forecasting for accumulative landslides in the three Gorges Reservoir Region, China. **Stochastic environmental research and risk assessment**, Berlin, v. 28, n. 6, p. 1465-1477, 2014.

LIU, PL-F. *et al.* Runup and rundown generated by three-dimensional sliding masses. **Journal of fluid Mechanics**, Cambridge, v. 536, n. 1, p. 107-144, 2005.

LINDSTRØM, Erika Kristina *et al.* Experiments on slide generated waves in a 1: 500 scale fjord model. **Coastal engineering**, Amsterdam, v. 92, p. 12-23, 2014.

LOPES, Mara Lúcia Martins. Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica. 2005. xviii, 149 f. Tese de Doutorado - Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, 2005. Disponível em: <<http://hdl.handle.net/11449/100374>>.

LOPEZ, Mario *et al.* LONG WAVES AND ARTIFICIAL NEURAL NETWORKS. **Coastal Engineering Proceedings**, [s. l.], n. 34, p. 31-31, 2014.

MAASS, Wolfgang; NATSCHLÄGER, Thomas; MARKRAM, Henry. Real-time computing without stable states: A new framework for neural computation based on perturbations. **Neural computation**, Cambridge, v. 14, n. 11, p. 2531-2560, 2002.

MACIEL, G. F. **Contribution expérimentale et théorique à l'étude des ondes produites par des glissements solides dans des retenues de barrages**. 1991. 168 f. Tese de Doutorado. Faculdade de Engenharia, Université Joseph Fourier, Grenoble, 1991.

MACIEL, G. de F. *et al.* Experimental apparatus for roll-wave measurements and comparison with a 1D mathematical model. **Journal of Hydraulic Engineering**, New York, v. 143, n. 11, p. 04017046, 2017.

MANENTI, S. *et al.* Vajont disaster: Smoothed particle hydrodynamics modeling of the postevent 2D experiments. **Journal of Hydraulic Engineering**, New York, v. 142, n. 4, p. 05015007, 2016.

MARCHIORI, S. C.; DA SILVEIRA, M. d. CG, Lotufo, ADP, Minussi, CR, and Lopes, MLM,“. **Neural network based on adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems,**” **Applied Soft Computing**, [s. l.], v. 11, n. 1, p. 706-715, 2011.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, [s. l.], v. 5, n. 4, p. 115-133, 1943.

MCFALL, Brian C.; FRITZ, Hermann M. Runup of granular landslide-generated tsunamis on planar coasts and conical islands. **Journal of Geophysical Research: Oceans**, Hoboken, v. 122, n. 8, p. 6901-6922, 2017.

MILLER, D. J. **Giant waves in lituya bay, Alaska**. Geological Survey Professional Paper 354-C. US Government Printing Office, Washington DC, 1960.

MOHAMMED, Fahad; MCFALL, Brian C.; FRITZ, Hermann M. Tsunami generation by 3D deformable granular landslides. In: **Solutions to Coastal Disasters 2011**. Anchorage, 2011. p. 310-320.

MOHAMMED, Fahad; FRITZ, Hermann M. Physical modeling of tsunamis generated by three-dimensional deformable granular landslides. **Journal of Geophysical Research: Oceans**, Hoboken, v. 117, n. C11, 2012.

Moor, Robert. Der Uferbruch am Davosersee. Schweizerische Bauzeitung v. 81/82, 1923. Disponível em: <http://doi.org/10.5169/seals-38950> ou <https://www.e-periodica.ch/digbib/view?pid=sbz-002:1923:81::424#2439> Acessado em: 06-01-2021.

Mühlehorn. Disponível em: <https://www.glarus-nord.ch/> ou <https://www.glarus-nord.ch/portraet/ortschaften/muehlehorn.html/2088> . Acessado em: 06/01/2021.

MÜLLER, Dieter Rainer. **Auflaufen und Überschwappen von Impulswellen an Talsperren**. 1995. Tese de Doutorado. ETH Zurich. (in German)

MÜLLER, H. W. B. SCHW AIGHOFER. 1999. Disponível em: https://boku.ac.at/fileadmin/data/H03000/H87000/H87200/3Arbeitsgruppen/Veroeffentlichungen/Mitt_IAG_Boku_05.pdf Acessado em: 25-02-2021.

MÜLLER, Marcos Ricardo. Análise de desempenho da rede neural artificial ARTMAP fuzzy aplicada para previsão multi-step de cargas elétricas em diferentes níveis de agregação. 2018. Disponível em: <<http://hdl.handle.net/11449/153671>>.

NAKORYAKOV, V. E.; OSTAPENKO, V. V.; BARTASHEVICH, M. V. Rolling waves on the surface of a thin layer of viscous liquid at phase transition. **International Journal of Heat and Mass Transfer**, Oxford, v. 89, p. 846-855, 2015.

NAJAFI-JILANI, A.; ATAIE-ASHTIANI, B. Laboratory investigation of wave run-up caused by landslides in dam reservoirs. **Quarterly Journal of Engineering Geology and Hydrogeology**, Bath, v. 45, n. 1, p. 89-98, 2012.

NASCIMENTO, M. F. **Aproximação das equações da classe Boussinesq no processo de geração da onda na interface sólido-líquido: uma abordagem numérico-experimental com compromissos de engenharia**. 2001. 110f. Dissertação de Mestrado - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2001.

New Navy Device Learns By Doing. Artigo original no The New York Times. Disponível em: <https://mpatacchiola.github.io/blog/2018/12/28/dissecting-reinforcement-learning-8.html> . Acessado em 05 de março de 2021.

OJHA, Varun Kumar; ABRAHAM, Ajith; SNÁŠEL, Václav. Metaheuristic design of feedforward neural networks: A review of two decades of research. **Engineering Applications of Artificial Intelligence**, [s. l.], v. 60, p. 97-116, 2017.

OLIVEIRA, P. B. A. *et al.* Impact wave predictions by a Fuzzy ARTMAP neural network. **Ocean Engineering**, Elmsford, v. 202, p. 107165, 2020.

OLIVEIRA, P. B. A *et al.* Análise da influência da normalização na previsão dos parâmetros característicos das ondas de impacto. (No Prelo).

PANIZZO, Andrea. Physical and numerical modelling of subaerial landslide generated waves. **Doctoral TKHVLV/\$ TXLOD Italy: Universita degli Studi di L'Aquila**, 2004.

PANIZZO, A. *et al.* Great landslide events in Italian artificial reservoirs. **Natural Hazards and Earth System Sciences**, [s. l.], v. 5, n. 5, p. 733-740, <https://doi.org/10.5194/nhess-5-733-2005>, 2005.

PANIZZO, A.; DE GIROLAMO, P.; PETACCIA, A. Forecasting impulse waves generated by subaerial landslides. **Journal of Geophysical Research: Oceans**, Hoboken, v. 110, n. C12, 2005.

PARONUZZI, Paolo; BOLLA, Alberto. The prehistoric Vajont rockslide: an updated geological model. **Geomorphology**, Amsterdam, v. 169, p. 165-191, 2012.

PEARLMUTTER, Barak A. Dynamic recurrent neural networks. 1990. Disponível em: <http://mural.maynoothuniversity.ie/5505/> . Acessado em: 03 de março de 2021.

PÉREZ, G.; GARCÍA-NAVARRO, P.; VÁZQUEZ-CENDÓN, M. E. One-dimensional model of shallow water surface waves generated by landslides. **Journal of Hydraulic Engineering**, New York, v. 132, n. 5, p. 462-473, 2006. DOI: 10.1061/(ASCE)0733-9429(2006)132:5(462).

PHELPS, Creighton H. Neural plasticity in aging and Alzheimer's disease: some selected comments. **Progress in brain research**, Amsterdam, v. 86, p. 3-9, 1990.

PRAHLADA, R.; DEKA, Paresh Chandra. Forecasting of time series significant wave height using wavelet decomposed neural network. **Aquatic Procedia**, [s. l.], v. 4, p. 540-547, 2015.

PRIDDY, Kevin L.; KELLER, Paul E. **Artificial neural networks: an introduction**. SPIE press, 2005.

PONZIANI, Lorenza; GARDONI, Martina. **Landslide generated waves in dam reservoirs- Experimental investigation on a physical hydraulic model**. 2017. Dissertação de Mestrado. NTNU.

POURPANAH, Farhad; LIM, Chee Peng; SALEH, Junita Mohamad. A hybrid model of fuzzy ARTMAP and genetic algorithm for data classification and rule extraction. **Expert Systems with Applications**, New York, v. 49, p. 74-85, 2016.

RANZATO, Marc *et al.* Efficient learning of sparse representations with an energy-based model. **Advances in neural information processing systems**, San Mateo, v. 19, p. 1137, 2007.

RAZIS, D. *et al.* Arrested coarsening of granular roll waves. **Physics of Fluids**, New York, v. 26, n. 12, p. 123305, 2014.

Revista FURNAS. Ano XXXVI, nº376, Dez. 2010/Jan. 2011. Disponível em: https://www.furnas.com.br/arqtrab/ddppg/revistaonline/linhadireta/RF376_de.pdf. Acessado em: 05 fev. 2021.

Revista FURNAS. ANO XXXI, nº319, Abril 2005. Disponível em: https://www.furnas.com.br/arqtrab/ddppg/revistaonline/linhadireta/RF363_modelo.pdf. Acessado em: 05 fev. 2021.

Revista FURNAS. Ano XXXV, nº363, Abril 2009. Disponível em: https://www.furnas.com.br/arqtrab/ddppg/revistaonline/linhadireta/rf319_jirau.pdf. Acessado em: 05 fev. 2021.

ROBERTS, Nicholas J. *et al.* Preliminary global catalogue of displacement waves from subaerial landslides. In: **Landslide science for a safer geoenvironment**. Springer, Cham, 2014. p. 687-692.

ROMANO, Michele *et al.* Artificial neural network for tsunami forecasting. **Journal of Asian Earth Sciences**, [s. l.], v. 36, n. 1, p. 29-37, 2009.

ROSENBLATT, Frank. "**The Perceptron: A Perceiving and Recognizing Automaton (Project PARA)**". Relatório (85-460-1). Cornell Aeronautical Laboratory, Inc, 1957.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, Washington, v. 65, n. 6, p. 386, 1958.

ROSENBLATT, Frank. **Principles of neurodynamics. perceptrons and the theory of brain mechanisms**. Cornell Aeronautical Lab Inc Buffalo, Nova York, 1961.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. **Learning internal representations by error propagation**. California Univ San Diego La Jolla Inst for Cognitive Science, 1985.

SABOUR, Sara; FROSST, Nicholas; HINTON, Geoffrey E. Dynamic routing between capsules. **arXiv preprint arXiv:1710.09829**, 2017.

SÆLEVIK, G.; JENSEN, A.; PEDERSEN, G. Experimental investigation of impact generated tsunami; related to a potential rock slide, Western Norway. **Coastal Engineering**, Amsterdam, v. 56, n. 9, p. 897-906, 2009.

SÁNCHEZ, Antonio Santos *et al.* Wave resource characterization through in-situ measurement followed by artificial neural networks' modeling. **Renewable Energy**, Oxford, v. 115, p. 1055-1066, 2018.

SANTOS, Francisco L. *et al.* Performance of a fuzzy ARTMAP artificial neural network in characterizing the wave regime at the Port of Sines (Portugal). **Journal of Coastal Research**, Fort Lauderdale, v. 32, n. 6, p. 1362-1373, 2016.

SAVITHA, R. *et al.* Regional ocean wave height prediction using sequential learning neural networks. **Ocean Engineering**, Elmsford, v. 129, p. 605-612, 2017.

SCHMIDHUBER, Jürgen. Deep learning in neural networks: An overview. **Neural networks**, New York, v. 61, p. 85-117, 2015.

SCHNELLMANN, Michael *et al.* 15,000 Years of mass-movement history in Lake Lucerne: Implications for seismic and tsunami hazards. **Eclogae Geologicae Helvetiae**, Basel, v. 99, n. 3, p. 409-428, 2006.

SCHNITTER, Gerald. **Das Unglück am Vajont: Folgerungen aus der Praxis des beratenden Ingenieurs in strafrechtlicher Hinsicht**. Ein Dienst der ETH-Bibliothek ETH Zürich, Rämistrasse 101, 8092 Zürich, Schweiz, 1972. www.library.ethz.ch. Disponível em: <http://www.e-periodica.ch> <http://doi.org/10.5169/seals-85316>. Acessado dia 25-02-2021.

SCHUSTER, Mike; PALIWAL, Kuldip K. **Bidirectional recurrent neural networks**. IEEE transactions on Signal Processing, New York, v. 45, n. 11, p. 2673-2681, 1997.

SEGUÍ, Carolina. Vajon Dam Aerial Schematic (IMAGE). DUKE UNIVERSITY. <https://www.eurekalert.org/multimedia/pub/234783.php>. Acessado em: 25-02-2021.

SEMENZA, E.; GHIROTTI, Monica. History of the 1963 Vaiont slide: the importance of geological factors. **Bulletin of Engineering Geology and the Environment**, Heidelberg, v. 59, n. 2, p. 87-97, 2000.

SERRANO-PACHECO, A.; MURILLO, J.; GARCÍA-NAVARRO, P. A finite volume method for the simulation of the waves generated by landslides. **Journal of hydrology**, Amsterdam, v. 373, n. 3-4, p. 273-289, 2009.

SHI, Chuanqi *et al.* Numerical simulation of landslide-generated waves using a soil–water coupling smoothed particle hydrodynamics model. **Advances in water resources**, Southampton, v. 92, p. 130-141, 2016.

SILVA JÚNIOR, José Carlos Guedes da. **Estudo Comparativo entre Modelos Unidimensional e Pseudo Bidimensional para Simulação da Propagação de Ondas Provocadas Pela Ruptura de Barragens**. Dissertação de Mestrado, Rio de Janeiro: UFRJ/COPPE/Programa de Engenharia Civil, 2013.

SMOLENSKY, Paul. **Information processing in dynamical systems: Foundations of harmony theory**. Colorado Univ at Boulder Dept of Computer Science, 1986a.

SMOLENSKY, Paul. Information processing in dynamical systems: Foundations of harmony theory (No. CU-CS-321-86). **Colorado Univ at Boulder Dept of Computer Science**, 1986b.

SOUZA, André Luís de Oliveira. Métodos analíticos, numéricos e experimentais para o cálculo de ondas de impacto em meios líquidos. 2007.

THURO, K.; BERNER, Ch; EBERHARDT, E. Der Bergsturz von Goldau 1806–Versagensmechanismen in wechsellagernden Konglomeraten und Mergeln. **Veröffentlichungen von der**, Erlangen: Springer Spektrum, v. 15, p. 303-308, 2005.

THURO, Kurosch; HATEM, Majd. The 1806 Goldau landslide event—analysis of a large rock slide. In: **Geologically active: proceedings of the 11th IAEG Congress, Auckland, New Zealand**. 2010. v. 510, p. 3693-3700.

TINTI, Stefano *et al.* Numerical simulation of the tsunami generated by a past catastrophic landslide on the volcanic island of Ischia, Italy. **Marine Geophysical Research**, Dordrecht, v. 32, n. 1-2, p. 287-297, 2011.

Torre do Sino de Pirago em Longarone.
https://www.ilgazzettino.it/fotogallery/italia/vajont_1963_le_foto_epoca_zanfron-62333.html#&gid=62333&pid=2 Acessado em: 25-02-2021.

TSCHEREPANOW, Marko. TopoART: A topology learning hierarchical ART network. In: **International Conference on Artificial Neural Networks**. Springer, Berlin, Heidelberg, 2010. p. 157-167.

U. S. ARMY COASTAL ENGINEERING RESEARCH CENTER. Shore Protection Manual. 3 ed. Washington: [s.n.], 1977. 253p.

VAKIL-BAGHMISHEH, Mohammad-Taghi; PAVEŠIĆ, Nikola. A fast simplified fuzzy ARTMAP network. **Neural processing letters**, v. 17, n. 3, p. 273-316, 2003
<https://doi.org/10.1023/A:1026004816362> .

Van Veen, F. & Leijnen, S.. Illustration: A mostly complete chart of Neural Networks. The Neural Network Zoo. Disponível em: <https://www.asimovinstitute.org/neural-network-zoo> . Acessado em: 04 de março de 2021

VASCO, Joel Roberto Guimarães. Desenvolvimento de software utilizando a técnica sph (smoothed particle hydrodynamics) na geração de ondas de submersão. 2014.

VASQUEZ, Jose A. Assessing the Stability of Dams Impacted by Landslide-Generated Waves Using CFD Modelling. In: **Twenty-Sixth International Congress on Large Dams: Vingt-Sixième Congrès International des Grands Barrages**. CRC Press, Vienna, 2018. p. 415-430.

VINCENT, Pascal *et al.* Extracting and composing robust features with denoising autoencoders. In: **Proceedings of the 25th international conference on Machine learning**. Barcelona, 2008. p. 1096-1103.

Vue du vallon entre le Rossberg e le Rigi apres la terrible catastrophe du 2e Septembre 1806. Disponível em: https://www.britishmuseum.org/collection/object/P_1958-0712-2241 Acessado em: 13/11/2020.

WANG, Wei *et al.* Modeling of landslide generated impulsive waves considering complex topography in reservoir area. **Environmental Earth Sciences**, Heidelberg, v. 75, n. 5, p. 372, 2016.

WEI, You-xing; WANG, Deng-ting; LIU, Qing-jun. Application of artificial neural network to calculation of solitary wave run-up. **Water Science and Engineering**, Oxford, v. 3, n. 3, p. 304-312, 2010.

WEISS, Robert; FRITZ, Hermann M.; WÜNNEMANN, Kai. Hybrid modeling of the megatsunami runup in Lituya Bay after half a century. **Geophysical Research Letters**, Washington, v. 36, n. 9, 2009.

WERBOS, Paul John. **The roots of backpropagation: from ordered derivatives to neural networks and political forecasting**. John Wiley & Sons, New York: A Bradford Book, 1994. ISBN 0-471-59897-6.

WIDROW, Bernard; LEHR, Michael A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. **Proceedings of the IEEE**, New York, v. 78, n. 9, p. 1415-1442, 1990, doi: 10.1109/5.58323.

WILLIAMSON, James R. Gaussian ARTMAP: A neural network for fast incremental learning of noisy multidimensional maps. **Neural networks**, New York, v. 9, n. 5, p. 881-897, 1996.

WYDER, Margrit. Die Glocken von Goldau: Eine akustisch orientierte Nachlese zum Goldauer Bergsturz. **Schweizerisches Archiv für Volkskunde**, v. 103, n. 1, p. 61-82, 2007.

YAVARI-RAMSHE, Saeedeh; ATAIE-ASHTIANI, Behzad. Subaerial landslide-generated waves: Numerical and laboratory simulations. In: **Workshop on World Landslide Forum**. Springer, Cham, 2017. p. 51-73.

ZAY, Carl I. **Goldau und seine Gegend, wie sie war und was sie geworden in Zeichnungen und Beschreibungen**. Orell, 1807. Disponível em: <https://archive.org/details/goldauundseineg00zaygoog/page/n40/mode/2up> Acessado em: 13/11/2020.

ZEILER, Matthew D. *et al.* Deconvolutional networks. In: **2010 IEEE Computer Society Conference on computer vision and pattern recognition**. IEEE, San Francisco, 2010. p. 2528-2535.

ZWEIFEL, A.; ZUCCALÀ, D.; GATTI, D. Comparison between computed and experimentally generated impulse waves. **Journal of hydraulic engineering**, New York, v. 133, n. 2, p. 208-216, 2007.

ANEXO A – HISTÓRICOS DO FENÔMENO AO REDOR DO MUNDO

A seguir são apresentados outros desastres envolvendo ondas de impacto e suas consequências para os locais onde ocorreram bem como uma visão geral de um estudo realizado por alguns autores.

1. Lago Genebra

As ondas de impacto geradas por deslizamentos de terra têm assolado a humanidade há muitos séculos, um dos acidentes mais antigos que se tem relato é o deslizamento de terra nas montanhas de Valais que atingiu o Delta do Ródano no Lago Genebra em 563 D.C. (Figura 89).

Figura 89 - Lago Genebra




Fonte: Elaboração do próprio autor no programa Google Earth Pro.

O bispo de Lausanne, Marius, relatou em sua crônica, presente no sétimo volume do livro *Conseveateur Suisse*, o seguinte texto traduzido por Bonney (1868) que o publicou em seu livro:

“No consulado de Basílio... a grande montanha de Tauretunum, no território do Valais, caiu tão repentinamente que cobriu um castelo em sua vizinhança, e algumas aldeias, com seus habitantes; agitou tanto o lago por 60 milhas de comprimento e 20 de largura, que transbordou ambas as margens; destruiu aldeias muito antigas, com homens e gado; sepultou vários lugares santos, com os religiosos que lhes pertenciam. Arrasou com fúria a Ponte de Genebra, as fábricas e os homens; e, fluindo para a cidade de Genebra, causou a perda de várias vidas.”(BONNEY, 1868. p. 130-131)


No ano de 2012 foi publicado na revista *Nature Geoscience* um estudo conduzido por Kremer; Simpson; Girardclos (2012) que correlaciona os depósitos de sedimentos encontrados no lago Genebra com os eventos relatados em 563. Segundo Kremer; Simpson; Girardclos (2012) um deslizamento de terra pode ter levado ao colapso dos sedimentos encontrados na região do Delta do Ródano (Figura 90) e levado à formação de ondas que atingiram toda região (Figura 91) chegando à cidade de Genebra.

Figura 90 – Resumo dos eventos de 563



Fonte: Kremer; Simpson; Girardclos (2012) Legenda: “Esboço do processo geológico e limnogeológico descrevendo as principais fases do evento 563 AD semelhante ao cenário que foi proposto anteriormente, da queda de rochas aéreas no vale do Ródano (1) ao colapso sublacustrino do delta do Ródano, seguido por turbulência e fluxo de detritos propagação com geração de ondas (2), terminando com ondas de água passando sobre as antigas muralhas da cidade de Genebra da Borgonha (3)”(KREMER; SIMPSON; GIRARDCLOS, 2012).

Figura 91 – Simulação da altura e propagação da onda do “tsunami” no Lago Genebra



Fonte: Kremer; Simpson; Girardclos (2012) Legenda: “Em 563 DC , um tsunami foi desencadeado por um movimento catastrófico de massa de sedimentos, após uma queda de rochas na parte oriental do lago na área sublacustre do delta do Ródano (linha tracejada preta). A amplitude da primeira onda registrada variou ao longo da costa (números pretos, em metros), conforme a onda se propagava (contornos vermelhos; números vermelhos indicam o tempo após o evento em minutos). A profundidade da água é indicada em tons de cinza (intervalos de 100 m). O depósito de movimento de massa (contorno preto) está localizado na parte mais profunda do lago” (KREMER; SIMPSON; GIRARDCLOS, 2012). O termo tsunami segue a literatura abrangente, no entanto se entende ondas de impacto ou submersão.

Ainda Kremer; Simpson; Girardclos (2012) o tsunami atingiu a região de Lausanne com uma altura de onda de 13 metros, 15 minutos após início, e 70 minutos depois atingiu Genebra com uma altura de onda de 8 metros.

Para Kremer; Simpson; Girardclos (2012) os tsunamis, com amplitudes de 3 a 13 metros e tempos de chegada menores que 70 minutos, representam uma ameaça direta e eram amplamente ignorados por aproximadamente um milhão de pessoas que vivia no lago. Destaca-se segundo Kremer; Simpson; Girardclos (2012) que Genebra é vulnerável a tais eventos devido a sua baixa elevação em relação ao nível atual do lago e por sua localização estar na ponta em forma de funil, que amplifica as amplitudes das ondas.

2. Goldau

Os deslizamentos de terra ou quedas de blocos de rochas que atingem lagos criam ondas de alta energia e deslocam parte do volume do lago, em alguns segundos um lago calmo pode se transformar em uma corrente violenta Huber (1980). Um deslizamento de terra na montanha de Rossberg, causado por fortes chuvas, com um volume aproximando de 40 milhões de metros cúbicos destruiu a vila suíça de Goldau (THURO; BERNER; EBERHARDT, 2005) bem como as três aldeias adjacentes Buosingen, Röthen e Lauerz (Figura 92) (WYDER, 2007).

Segundo Thuro; Hatem (2010) este incidente custou 457 vidas, 111 casas, 2 igrejas e 220 prédios agrícolas foram perdidos, além de 6,5 km² de pastagens, que foram cobertos por escombros do deslizamento. Ainda segundo Thuro; Hatem (2010), testemunhas relataram um tsunami de 20 metros de altura no lago Lauerz, demolindo edifícios e uma capela na ilha de Schwanau.

Figura 92 – Região de Goldau, Arth, Suíça



Fonte: Elaboração do próprio autor no programa Google Earth Pro.

Segundo Thuro; Hatem (2010) além dos planos deslizantes do deslizamento de rocha de 1806 na área superior, vários outros planos são visíveis na encosta de Rossberg (Figura 93) incluindo um possível deslizamento futuro.

Figura 93 - Série escalonada de planos deslizantes em Rossberg



Fonte: Thuro; Hatem (2010). Legenda: “Plano (1) deslizamento pré-histórico, (2) deslizamento de 1222 Röthen, (3) deslizamento de rochas de 1806, (4) deslizamento de rochas Gnipen de 2002, (5) deslizamento de rochas de Gribsch 2005 – fluxo de detrito, (6) sinais de movimento de declive (evento futuro?). Material de entulho e aldeia atual de Goldau e Oberarth” (THURO; HATEM, 2010).

Alguns artistas da época eternizaram o desastre em suas obras, entre eles Gaspar Rahn, com duas pinturas, antes e depois do deslizamento, intituladas *Contrée de Busingen Lauwerz Rothen e du Rossberg avant la terrible catastrophe du 2 Septembre 1806* (Figura 94) e *Vue du vallon entre le Rossberg et le Rigi apres la terrible catastrophe du 2 Septembre 1806* (Figura 95), respectivamente, ambas se encontram no Museu Britânico.

Figura 94 – Pintura da Vila de Goldau antes do deslizamento



Fonte: https://www.britishmuseum.org/collection/object/P_1958-0712-2243 Acessado em: 13 nov. 2020.

Figura 95 – Pintura da Vila de Goldau depois do deslizamento



Fonte: https://www.britishmuseum.org/collection/object/P_1958-0712-2241 Acessado em: 13 nov. 2020.

Também é possível encontrar objetos, iconografias, livros e registros históricos deste acidente no Museu do deslizamento de terra de Goldau, dentre esses objetos, o sino da igreja (Figura 96) que foi desenterrado bem como o famoso livro “Goldau e sua região, como era e no que se tornou” conhecido como o “Livro do entulho” escrito pelo médico Dr. Karl Zay (ZAY, 1807), considerado uma das maiores fontes históricas sobre o evento.

Figura 96 – Sino da Igreja



Fonte: <https://www.arth-online.ch/bergsturz/ausstellung/>

Acessado em: 13 nov. 2020.

Segundo Bussmann; Anselmetti (2010) o núcleo de 10 metros da bacia distal do lago Lauerz possui uma história de sedimentação de aproximadamente 2000 anos, possuindo uma camada cuja origem provável é o evento histórico conhecido por Röthener Bergsturz que destruiu a vila de Röthen datado de 810 ± 70 DC.

Em seus estudos Bussmann; Anselmetti (2010) identificaram três períodos históricos com maior ocorrência de turbitos de inundação datados de 580–850 DC, 990 –1420 DC e 1630-1940 DC. Também detectaram 6 camadas de inundação que provavelmente marcam eventos de chuvas mais intensas datados aproximadamente de 610, 1160, 1290, 1660, 1850 e 1876 DC, sendo o ultimo o relacionado à chuva mais intensa já registrada.

Seu trabalho, como destacam, tem a capacidade de usar sedimentos de lagos para reconstruir atividades de deslizamentos anteriores, observando que perfurações adicionais poderiam ser a chave para estabelecer a cronologia dos eventos de destruição em massa de Rossberg.

O estudo de Bussmann; Anselmetti (2010) contradiz as sugestões da onda de impulso ser causada pelo impacto direto da massa deslizante no lago Lauerz, pois encontraram indícios de que ela foi fruto de um deslocamento lateral repentino induzido por uma propagação da gravidade de uma quantidade considerável dos depósitos na bacia do lago, o que implica nos processos de avaliação de risco de ondas de impulso.

3. Lago Davos

No dia 7 de fevereiro de 1923, às 5h da manhã, a parte frontal do delta Todtalpach se desprende tendo 330 m de largura por aproximadamente 90 m de profundidade, com uma massa de aproximadamente 900 mil m³, destas 280 mil m³ mergulharam abaixo do nível rebaixado do lago Davos (Figura 97), causando uma onda violenta que se elevou até a altura de 3 metros, arrancando o sistema de bombeamento flutuante (Figura 98) e matando um dos dois mecânicos que estava de plantão (HUBER, 1980; MOOR, 1923).

A causa foi a redução artificial do nível normal do lago em cerca de 12 metros (Figura 99) usando um sistema de bombeamento flutuante, cuja medida foi necessária para criar a captação de água do lago para o nível da usina Davos-Klosters (HUBER, 1980).

Figura 97 – Lago Davos




Fonte: Elaboração do próprio autor no programa Google Earth Pro.

Figura 98 - A estação flutuante de bombeamento (23. XII. 1922)



Fonte: Moor (1923).

Figura 99 - Representação gráfica do rebaixamento do lago



Fonte: Moor (1923).

4. Mühlehorn

Mühlehorn (Figura 100) era uma importante localização de moinhos operados em Meerenbach, que possui uma das forjas de martelo mais antigas, datada do século 18 e ainda em operação. Na região do Mültal era extraída a marga para fabricação do cimento, porém a usina precisou ser fechada após o deslizamento de terra ocorrido em 1924, que soterrou a ferrovia e a usina (<https://www.glarus-nord.ch/> Acessado em: 06 jan. 2021).

Segundo SCHARDT (1924) citado por Lambert (1976) no dia 08 de novembro de 1924 ocorreu um deslizamento de terra em Mühlehorn com volume de 100 mil metros cúbicos que atingiram a linha férrea e afundaram no lago.

Segundo Lambert (1976) em 22 de maio de 1947 um volume de 350 mil metros cúbicos de rocha caíram de uma pedreira na margem norte do lago e desencadearam uma onda de 5 metros de altura causando um acidente fatal.

Para Lambert (1976) não é possível rastrear com precisão esses eventos devido às perfurações não se encontrarem no caminho da queda ou devido às camadas de sedimentos serem muito finas e não se destacarem das demais.

Figura 100 - Mühlehorn



Fonte: Elaboração do próprio autor no programa Google Earth Pro.

Segundo Huber (1980), o deslizamento de terra de 8 de novembro 1924, que enterrou a linha férrea Zurique-Chur, ocorreu cerca de 700 metros a oeste de Mühlehorn em um comprimento de aproximadamente 120 m e parte da massa, que atingiu o lago, foi estimada em 30 mil metros cúbicos (Figura 101).

Figura 101 - Queda de rocha perto de Mühlehorn de 8 de novembro de 1924



Fonte: Huber (1980).

Ainda segundo Huber (1980) suspeita-se de uma combinação de várias causas que tenham levado ao deslizamento, dentre elas o período chuvoso, o terremoto ocorrido um dia antes com epicentro próximo e o intenso sistema de tuneis de exploração de rocha para produção de cimento.

Em seu trabalho Huber (1980) relata que três dias após o primeiro deslizamento uma segunda massa maior perdeu equilíbrio e caiu, levando o forno de cimento com ela e aumentando a base da lâmina para 180 m. As ondas geradas varreram a plataforma provisória de Mühletal e as vias férreas estavam a 8 metros acima do nível do lago, o trabalho de limpeza e reparo levou várias semanas (Figura 102).

Figura 102 - Deslizamento de rocha perto de Mühletal no Lago Walen em 1924: massa total dos dois deslizamentos: 200.000 - 300.000 m³




Fonte: Huber (1980).

5. **Alpnachersee**

Segundo Bendel L. (1931), Bendel L. (1933) e Neue Zürcher Zeitung (1931) citado por Huber (1980), no dia 21 de março de 1931, uma camada de 4 mil metros cúbicos de Schrattenkalk (formação geológica Barremiana a Aptiana, época do Cretáceo inferior) deslizou acima do local de mineração de uma pedreira, localizada na região da confluência do Sarner Aa no Alpnachersee, na base da cordilheira Mueterschwandenberg.

Segundo Huber (1980) na manhã seguinte houve um segundo deslizamento com volume de 30 mil metros cúbicos, destruindo completamente a pedreira e criando uma onda com altura inicial de 3,5 metros e possuindo ainda 1 metro de altura a 2,5 km do ponto de imersão (Figura 103). Cabanas foram destruídas e um navio de 60 toneladas foi seriamente danificado, enquanto a rota Brünigstrasse, que liga Stansstad a Alpnach, na margem oposta, foi inundada em vários locais, tendo inclusive peixes das profundezas do lago sendo jogados na via (Figura 104).

Figura 103 - Queda de rocha no Alpachersee volume 30.000 m³



Fonte: Huber (1980).

Figura 104 – Alpnachersee e entorno



Fonte: Elaboração do próprio autor no programa Google Earth Pro.

6. Quinten

Segundo Zeitung, N. Z.(1946) citado por Huber (1980), no dia 03 de setembro de 1946 em Quinten (Figura 105) ocorreu um deslizamento de 300 mil metros cúbicos que atingiu o Lago Walen e uma pedreira perto de Quinten foi totalmente soterrada, também foi arrancada uma faixa de floresta com a queda.

Ainda segundo Huber (1980) a onda resultante causou estragos na margem oposta e teve altura de subida de 5 a 6 metros, todos os navios ancorados na rota Mühlital-Mühlehorn-Tiefenwinkel foram arrancados e 15 foram destruídos (Figura 106), o limnógrafo em Murg registrou os movimentos de balanço do nível do lago, estes duraram de 4 a 5 horas (Figura 107).

Figura 105 – Quinten




Fonte: Elaboração do próprio autor no programa Google Earth Pro.

Figura 106 - Barcos quebrados perto de Mühlehorn como resultado da queda de rocha perto de Quinten em 1946



Fonte: Huber, A. (1980)

Figura 107 - Limnigrama da estação de medição Murg



Fonte: Federal Office for Water Management citado por Huber (1980).


Segundo Huber (1980): “as deflexões registradas são reduzidas devido ao efeito de amortecimento do limnógrafo em comparação com a altura da onda. Observe o período de oscilação horária do Walensee”.

7. Visão geral

Esses são alguns dos eventos envolvendo as ondas de impacto, Roberts *et al.* (2014) ilustrou 254 eventos de ondas de impacto desde século XIV DC até 2012 em um mapa global (Figura 108). Segundo Roberts *et al.* (2014), destes 156 ocorreram na região da Noruega, 18 no Pacífico Noroeste da América do Norte e 12 nos Alpes europeus.

No mapa são apresentados os deslizamentos de terra não vulcânicos marcados com círculos rosa; os deslizamentos de terra de vulcões marcados com círculos vermelhos; limites da placa convergente em vermelho; limites da placa divergente em amarelo; e transformação dos limites da placa em laranja (ROBERTS *et al.*, 2014).


Figura 108 - Mapa global de ondas de deslocamento geradas por deslizamentos



Fonte: Roberts *et al.* (2014).

Em seu trabalho Roberts *et al.* (2014) organizou os eventos por décadas desde o século 17 e o resultado é apresentado na Figura 109 onde os eventos fora da Noruega são apresentados em rosa e os na Noruega em roxo.


Figura 109 – Eventos de ondas de deslocamento por décadas



Fonte: Adaptado de Roberts *et al.* (2014).

O trabalho de Roberts *et al.* (2014) também organizou o total de fatalidades relacionadas que é apresentado na Figura 110, observando que todas as décadas que excederam 100 mortes foram denominadas por um único evento de alta fatalidade, com exceção da década de 1930 que possui os eventos de Loen e Tajord. Houve também a exclusão de oito eventos na Noruega, sendo três no século 16, três no século 18 e dois no século 19, excluídos segundo Roberts *et al.* (2014) por suas décadas de ocorrência serem desconhecidas.

Figura 110 – Total de Fatalidades por décadas



Fonte: Adaptado de Roberts *et al.* (2014).

Outro trabalho semelhante é o de Schnellmann *et al.* (2006) que construiu um catalogo cronológico de 15000 anos cobrindo todos os movimentos de massa no Lago Lucerna, que através de exemplos históricos indicam que poderiam induzir a formação de ondas de tsunami consideráveis no lago.

Pode-se entender do disposto nos subitens acima a grande importância dos estudos sobre as ondas de impacto, devido não somente aos danos materiais, com destruição de cidades e estruturas, mas principalmente pela perda de vidas humanas.

ANEXO B – REDES NEURAIS

Neste anexo é apresentado um breve histórico da evolução no campo de pesquisa das redes neurais e uma breve explanação sobre os tipos de redes, não fazendo parte do escopo deste trabalho um aprofundamento em cada tipo, mas apenas uma apresentação de parte do que pode ser encontrado na literatura.

1. Breve histórico

As redes neurais artificiais baseiam-se no neurônio biológico, proposto pela primeira vez por Warren McCulloch e Walter Pitts em 1943 cujo trabalho propôs o primeiro modelo matemático de uma rede neural, seu trabalho foi intitulado: Um cálculo lógico das ideias imanentes na atividade nervosa (MCCULLOCH; PITTS, 1943).

Outra contribuição para evolução das redes neurais foi o trabalho publicado por Donald Hebb, em 1949 cujo título era: “*The Organization of Behavior: a neuropsychological theory*” (HEBB, 1949), definia a plasticidade neural conhecida posteriormente como aprendizagem Hebbiniana.

Segundo Phelps (1990) a plasticidade por ser definida como mudanças adaptativas na estrutura e na função do sistema nervoso em todos os estágios de desenvolvimento, ocasionadas por experiências ou lesões.

Frank Rosenblatt criou a rede perceptron, em 1957 publicou um relatório intitulado: “*The Perceptron: a perceiving and recognizing automaton*” no Cornell Aeronautical Laboratory (ROSENBLATT, 1957). Na Figura 111 é apresentado seu artigo ao *The New York Times* onde apresentava a rede.

Frank Rosenblatt também publicou diversos trabalhos e um livro intitulado: “*Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*” (ROSENBLATT, 1961). E em 1969 Marvin Minsky e Seymour Papert publicaram um livro intitulado “*Perceptrons*” que apresentava as limitações da rede.

Figura 111 – Artigo original da apresentação da rede perceptron publicado no *The New York Times*



Fonte: <https://mpatacchiola.github.io/blog/2018/12/28/dissecting-reinforcementlearning-8.html>. Acessado em: 05 mar. 2021.

Em 1967 Ivakhnenko e Lapa apresentaram um algoritmo de aprendizagem funcional para perceptrons multicamadas, feedforward, profundo e supervisionado (IVAKHNENKO; LAPA, 1967). E em 1970 Ivakhnenko apresentou uma rede profunda com oito camadas de treinamento pelo método de grupo de tratamento de dados (GMDH), (IVAKHNENKO, 1970).

Em 1974 Werbos propõe o algoritmo de retro propagação cujo trabalho foi republicado em sua íntegra no livro *“The Roots of Backpropagation: From Ordered Derivatives to Neural Networks and Political Forecasting”* em 1994 (WERBOS, 1994).

Diversos trabalhos surgiram a partir deste momento e as redes neurais se expandiram, dentre eles podemos citar:

Stephen Grossberg ganhador do prêmio Norman Anderson em 2015 pelo conjunto de sua obra, seus trabalhos iniciaram na década de 60 com sistemas de equações diferenciais não lineares para modelar a memória de curto (STM) ou ativação neuronal, médio prazo (MTM) ou habituação dependente de atividade, e longo prazo (LTM) ou aprendizado neuronal, continuando a contribuir nesse campo de pesquisa, bem como introduziu e auxiliou no

desenvolvimento de diversos modelos de redes neurais (GROSSBERG, 1967; 1976^a; 1976b; 1976c).

Gail Carpenter juntamente com Stephen Grossberg desenvolveram a teoria da ressonância adaptativa (ART) desde os anos de 1980, dentre as redes desenvolvidas podemos citar as redes ART 1, ART 2, ART 2-A, ART 3 (WIDROW; LEHR, 1990).

John Hopfield em 1982 com a rede Hopfield uma forma de rede neural recorrente, publicada no trabalho “*Neural networks and physical systems with emergent collective computational abilities*” (HOPFIELD, 1982).

Teuvo Kohonen em 1982 com a rede neural Kohonen, capaz de organizar dados complexos em grupos (KOHONEN, 1982).


David Rumelhart, Geoffrey E. Hinton, Ronald J. Williams em 1986 com trabalho sobre as redes neurais recorrentes (RUMELHART; HINTON; WILLIAMS, 1985).

Em seu trabalho Schmidhuber (2015) reuniu uma coletânea das diversas contribuições para a aprendizagem profunda ao longo dos anos, permitindo observar os diversos estudos que se sucederam neste vasto campo de pesquisa.

2. Neurônio biológico x neurônio artificial


De maneira simplificada o neurônio tem o terminal de recepção que é representado pelos padrões de entrada na rede neural artificial (RNA), o terminal de transmissão que é representado pelos padrões de saída na RNA e as sinapses que são representadas pelos pesos, cuja definição pela Oxford Languages é: “o local de contato entre os neurônios, onde ocorre a transmissão de impulsos nervosos de uma célula para outra” (Figura 112 e 113).

Figura 112 – Neurônio biológico



Fonte: <https://guildadocodigo.atelie.software/intelig%C3%A2ncia-artificial-parte-i-ebd62adb10>. Acessado em: 03 mar. 2021.

Figura 113 – Representação de um neurônio



Fonte: Adaptado de <https://medium.com/@avinicius.adorno/redes-neurais-artificiais-418a34ea1a39>.
Acessado em: 03 mar. 2021.

Segundo Aggarwal; Clustering (2014) existem diversas funções de ativação e varias derivações de unidades neurais, sendo que suas combinações dependem da topologia adotada e da justificativa teórica. As mais amplamente utilizadas são apresentadas no Quadro 5.

Quadro 5 - Tipo de unidades amplamente utilizadas nas redes neurais

Tipo de unidade	Função da rede	Função de ativação
unidade de limite linear	soma ponderada	função de passo ou sinal
unidade linear	soma ponderada	linear ou linear por partes
unidade sigmoidal	soma ponderada	sigmoide ou tanh
unidade de distância	distância	linear ou linear por partes
unidade gaussiana	distância	Gaussiano kernel

Fonte: Aggarwal; Clustering (2014).

Existem diversas arquiteturas de redes neurais baseadas na forma como os neurônios são conectados, podendo-se dividir as arquiteturas em dois grupos: *feedforward* e recorrentes, diferindo basicamente devido à direção da informação, sendo apenas num sentido nas feedfoward (KROSE; SMAGT, 1996) e em ciclos no caso das recorrentes, também chamadas de *feedback* (PEARLMUTTER, 1990).

E quanto à aprendizagem podem das seguintes formas: supervisionada, como exemplo: perceptron, Madaline, e backpropagation (WIDROW; LEHR, 1990); não supervisionada, como exemplo: Hopfield e Kohonen (HOPFIELD, 1982; KOHONEN, 1982); e por reforço (DOMINIC *et al.*, 1991; HOSKINS; HIMMELBLAU, 1992); existindo também

a autoaprendizagem (BOZINOVSKI, 2014); entre outros algoritmos, como exemplo: métodos evolutivos, programação de expressão genética, otimização por enxame de partículas, entre outras (OJHA; ABRAHAM; SNÁŠEL, 2017).

Algumas das arquiteturas existentes foram reunidas no trabalho de Van Veen; Leijnen [2020?] e são apresentadas no Quadro 6 e Figura 114, observando que os nomes das redes neurais foram mantidos em inglês conforme originalmente criadas.

Quadro 6 - Diferentes arquiteturas de redes neurais (continua).

Rede Neural	Referência
Feed forward (FF ou FFNN) e Perceptrons (P)	Rosenblatt, 1958.
Radial basis Network (RBF)	Broomhead; Lowe, 1988.
Recurrent neural networks (RNN)	Elman, 1990.
Long / short term memory (LSTM)	Hochreiter; Schmidhuber, 1997.
Gated recurrent units (GRU)	Chung <i>et al.</i> , 2014.
Bidirectional recurrent neural networks, bidirectional long / short term memory networks and bidirectional gated recurrent units (BiRNN, BiLSTM e BiGRU respectivamente)	Schuster; Paliwal, 1997.
Auto encoders (AE)	Bourlard, 1988; 2000.
Variational auto encoders (VAE)	Kingma, 2013.
Denoising auto encoders (DAE)	Vincent <i>et al.</i> , 2008.
Sparse auto encoders (SAE)	Ranzato <i>et al.</i> , 2007.
Markov chains (MC or discrete time Markov Chain, DTMC)	Hayes <i>et. al.</i> , 2013.
Hopfield network (HN)	Hopfield, 1982.
Boltzmann machines (BM)	Hinton; Sejnowski, 1986.
Restricted Boltzmann machines (RBM)	Smolensky, 1986a; 1986b.
Deep belief networks (DBN)	Bengio <i>et al.</i> , 2007.
Convolutional neural networks (CNN or deep convolutional neural networks, DCNN)	LeCun <i>et al.</i> , 1998.


Fonte: Adaptado de Van Veen; Leijnen [2020?].

Quadro 6 - Diferentes arquiteturas de redes neurais (conclusão).

Rede Neural	Referência
Deconvolutional networks (DN)	Zeiler <i>et al.</i> , 2010.
Deep convolutional inverse graphics networks (DCIGN)	Kulkarni <i>et al.</i> , 2015.
Generative adversarial networks (GAN)	Goodfellow <i>et al.</i> , 2014.
Liquid state machines (LSM)	Maass; Natschläger; Markram, 2002.
Extreme learning machines (ELM)	Huang; Zhu; Siew, 2006.
Echo state networks (ESN)	Jaeger; Haas, 2004.
Deep residual networks (DRN)	He <i>et al.</i> , 2016.
Neural Turing machines (NTM)	Graves; Wayne; Danihelka, 2014.
Differentiable Neural Computers (DNC)	Graves <i>et al.</i> , 2016.
Capsule Networks (CapsNet)	Sabour; Frosst; Hinton, 2017.
Kohonen networks (KN, also self organising (feature) map, SOM, SOFM)	Kohonen, 1982.
Attention networks (AN)	Jaderberg <i>et al.</i> , 2015.

Fonte: Adaptado de Van Veen; Leijnen [2020?].

Figura 114 – Diferentes redes neurais e suas arquiteturas



Fonte: Van Veen; Leijnen [2020?].

Como se pode observar o campo de pesquisa sobre redes neurais avançou muito e suas aplicações são as mais diversas possíveis, desde pesquisas para compreensão do autismo, como trabalho de Grossberg; Seidman (2006): “*Neural dynamics of autistic behaviors: Cognitive, emotional, and timing substrates*” a trabalhos com previsão de cargas, como o trabalho de Lopes (2005): “Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica”.

ANEXO C – TABELAS DO TRABALHO DE ANDREAS HUBER

Tabelas de 13 a 17 – Alturas relativas de onda

Tabelas de 18 a 22 – Comprimentos relativos de onda

Tabelas 23 – Classificação das ondas

Tabelas 24 a 28 – Períodos relativos de onda

Tabela 13 – Altura relativa de onda para $x'/h=5$

h m	v _f m/s	G kg	α																			
			28°				30°				35°		60°		45°				60°			
			β	1:0	1:4	1:6	1:4	1:8	1:12	1:0	1:4	1:0	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12		
0,12	1	5	0,280	0,370	0,212	0,380	0,450	0,385	0,389	0,332	0,361	0,337	0,381	0,406	0,426	0,443	0,440	0,470	0,470			
		15	0,355	0,452	0,352	0,418	0,540	0,530	0,649	0,575	0,593	0,627	0,750	0,645	0,593	0,626	0,620	0,660	0,660			
		30	0,470	0,540	0,465	0,508	0,585	0,680	0,827	0,721	0,730	0,782	0,940	0,805	0,730	0,782	0,770	0,820	0,820			
		50	0,555	0,555	0,515	0,588	0,700	0,680	0,927	0,845	0,840	0,900	1,080	0,945	0,840	0,900	0,890	0,960	0,960			
	2	5	0,240	0,600	0,282	0,600	0,670	0,625	0,376	0,305	0,387	0,338	0,440	0,434	0,432	0,526	0,625	0,625	0,625			
		15	0,325	0,405	0,352	0,448	0,560	0,560	0,699	0,621	0,630	0,682	0,840	0,721	0,630	0,682	0,670	0,720	0,720			
		30	0,330	0,418	0,392	0,475	0,660	0,590	0,861	0,670	0,680	0,732	0,900	0,751	0,680	0,732	0,720	0,770	0,770			
		50	0,440	0,475	0,515	0,570	0,690	0,621	0,927	0,845	0,840	0,900	1,080	0,945	0,840	0,900	0,890	0,960	0,960			
	3	5	0,206	0,375	0,296	0,420	0,475	0,458	0,421	0,440	0,404	0,289	0,480	0,344	0,353	0,496	0,685	0,685	0,685			
		15	0,290	0,418	0,302	0,470	0,620	0,635	0,528	0,514	0,500	0,539	0,710	0,521	0,520	0,590	0,770	0,770	0,770			
		30	0,372	0,375	0,366	0,520	0,460	0,720	0,536	0,480	0,460	0,539	0,710	0,480	0,460	0,539	0,710	0,710	0,710			
		50	0,560	0,486	0,465	0,575	0,720	0,700	0,581	0,727	0,494	0,670	0,780	0,670	0,670	0,780	0,780	0,780	0,780			
	4	5	—	—	—	—	0,520	0,520	0,464	0,480	0,567	0,689	0,689	0,642	0,736	0,722	0,730	0,730	0,730			
		15	—	—	—	—	0,660	0,660	0,624	0,642	0,736	0,858	0,858	0,811	0,905	0,885	0,890	0,890	0,890			
		30	—	—	—	—	0,760	0,760	0,745	0,760	0,858	0,980	0,980	0,933	1,027	1,007	1,010	1,010	1,010			
		50	—	—	—	—	0,840	0,840	0,821	0,840	0,933	1,055	1,055	1,007	1,101	1,081	1,080	1,080	1,080			
0,18	1	5	0,162	0,170	0,160	0,235	0,375	0,295	0,274	0,300	0,294	0,214	0,315	0,465	0,439	0,428	0,618	0,618	0,618			
		15	0,292	0,288	0,202	0,306	0,460	0,380	0,427	0,564	0,615	0,570	0,685	0,817	0,894	0,813	0,720	0,720	0,720			
		30	0,380	0,372	0,386	0,420	0,520	0,455	0,433	0,617	0,616	0,613	0,720	0,817	0,894	0,813	0,720	0,720	0,720			
		50	0,460	0,490	0,428	0,448	0,610	0,560	0,380	0,817	0,894	0,813	0,720	0,817	0,894	0,813	0,720	0,720	0,720			
	2	5	0,190	0,245	0,166	0,266	0,345	0,310	0,298	0,281	0,214	0,235	0,352	0,417	0,389	0,401	0,610	0,610	0,610			
		15	0,221	0,258	0,215	0,325	0,420	0,385	0,412	0,545	0,615	0,514	0,615	0,617	0,615	0,615	0,615	0,615	0,615			
		30	0,272	0,312	0,282	0,345	0,505	0,455	0,424	0,545	0,615	0,514	0,615	0,617	0,615	0,615	0,615	0,615	0,615			
		50	0,350	0,390	0,402	0,420	0,520	0,420	0,445	0,545	0,615	0,514	0,615	0,617	0,615	0,615	0,615	0,615	0,615			
	3	5	0,221	0,194	0,163	0,290	0,395	0,295	0,313	0,297	0,243	0,268	0,352	0,363	0,388	0,437	0,610	0,610	0,610			
		15	0,142	0,215	0,268	0,330	0,470	0,390	0,461	0,447	0,467	0,587	0,650	0,547	0,467	0,587	0,650	0,650	0,650			
		30	0,180	0,285	0,270	0,340	0,540	0,520	0,445	0,547	0,467	0,587	0,650	0,547	0,467	0,587	0,650	0,650	0,650			
		50	0,250	0,338	0,295	0,410	0,475	0,505	0,413	0,559	0,520	0,569	0,700	0,626	0,529	0,627	0,740	0,740	0,740			
	4	5	—	—	—	—	0,430	0,295	0,311	0,326	0,259	0,273	0,380	0,479	0,431	0,479	0,610	0,610	0,610			
		15	—	—	—	—	0,335	0,520	0,499	0,479	0,431	0,479	0,610	0,565	0,528	0,580	0,650	0,650	0,650			
		30	—	—	—	—	0,350	0,630	0,635	0,565	0,528	0,580	0,650	0,622	0,528	0,686	0,740	0,740	0,740			
		50	—	—	—	—	0,380	0,470	0,406	0,422	0,528	0,686	0,740	0,622	0,528	0,686	0,740	0,740	0,740			
0,27	1	5	0,055	0,130	0,111	0,250	0,169	0,190	0,183	0,193	0,167	0,150	0,220	0,296	0,255	0,222	0,350	0,350	0,350			
		15	0,110	0,198	0,173	0,260	0,270	0,350	0,308	0,384	0,371	0,390	0,450	0,509	0,484	0,418	0,540	0,540	0,540			
		30	0,177	0,170	0,246	0,263	0,320	0,430	0,363	0,474	0,385	0,475	0,500	0,474	0,385	0,475	0,500	0,500	0,500			
		50	0,290	0,290	0,320	0,365	0,375	0,450	0,322	0,509	0,484	0,418	0,540	0,509	0,484	0,418	0,540	0,540	0,540			
	2	5	0,073	0,130	0,111	0,245	0,200	0,205	0,200	0,229	0,130	0,134	0,220	0,279	0,214	0,280	0,350	0,350	0,350			
		15	0,091	0,160	0,141	0,275	0,272	0,355	0,262	0,359	0,291	0,364	0,420	0,474	0,385	0,475	0,500	0,500	0,500			
		30	0,146	0,201	0,190	0,300	0,320	0,430	0,364	0,474	0,385	0,475	0,500	0,474	0,385	0,475	0,500	0,500	0,500			
		50	0,202	0,260	0,211	0,287	0,367	0,430	0,380	0,474	0,385	0,475	0,500	0,474	0,385	0,475	0,500	0,500	0,500			
	3	5	0,110	0,130	0,127	0,231	0,224	0,235	0,185	0,286	0,131	0,172	0,200	0,271	0,223	0,288	0,340	0,340	0,340			
		15	0,077	0,146	0,146	0,285	0,285	0,360	0,287	0,416	0,355	0,371	0,430	0,416	0,355	0,371	0,430	0,430	0,430			
		30	0,146	0,146	0,149	0,300	0,312	0,430	0,358	0,416	0,355	0,371	0,430	0,416	0,355	0,371	0,430	0,430	0,430			
		50	0,150	0,170	0,218	0,324	0,360	0,375	0,288	0,294	0,221	0,216	0,290	0,294	0,221	0,216	0,290	0,290	0,290			
	4	5	—	—	—	—	0,224	0,235	0,216	0,284	0,255	0,306	0,399	0,284	0,255	0,306	0,399	0,399	0,399			
		15	—	—	—	—	0,310	0,425	0,294	0,367	0,363	0,341	0,485	0,367	0,363	0,341	0,485	0,485	0,485			
		30	—	—	—	—	0,367	0,430	0,417	0,505	0,487	0,435	0,550	0,505	0,487	0,435	0,550	0,550	0,550			
		50	—	—	—	—	0,425	0,430	0,425	0,505	0,487	0,435	0,550	0,505	0,487	0,435	0,550	0,550	0,550			
0,36	1	5	0,035	0,082	0,069	0,115	0,110	0,180	0,091	0,124	0,107	0,117	0,148	0,248	0,237	0,245	0,290	0,290	0,290			
		15	0,058	0,117	0,100	0,180	0,203	0,300	0,207	0,248	0,237	0,245	0,290	0,248	0,237	0,245	0,290	0,290	0,290			
		30	0,112	0,185	0,143	0,230	0,315	0,380	0,298	0,391	0,384	0,387	0,440	0,391	0,384	0,387	0,440	0,440	0,440			
		50	0,190	0,226	0,061	0,295	0,330	0,450	0,356	0,391	0,384	0,387	0,440	0,391	0,384	0,387	0,440	0,440	0,440			
	2	5	0,052	0,107	0,089	0,177	0,129	0,205	0,133	0,117	0,167	0,168	0,148	0,269	0,224	0,172	0,230	0,230	0,230			
		15	0,072	0,138	0,106	0,192	0,220	0,310	0,231	0,273	0,224	0,248	0,298	0,273	0,224	0,248	0,298	0,298	0,298			
		30	0,108	0,150	0,142	0,233	0,270	0,350	0,288	0,375	0,286	0,330	0,362	0,375	0,286	0,330	0,362	0,362	0,362			
		50	0,162	0,156	0,159	0,245	0,338	0,365	0,314	0,375	0,286	0,330	0,362	0,375	0,286	0,330	0,362	0,362	0,362			
	3	5	0,071	0,092	0,090	0,145	0,162	0,225	0,150	0,095	0,147	0,132	0,182	0,199	0,220	0,228	0,230	0,230	0,230			
		15	0,080	0,140	0,133	0,200	0,223	0,300	0,220	0,229	0,225	0,295	0,340	0,229	0,225	0,295	0,340	0,340	0,340			
		30	0,100	0,116	0,094	0,233	0,295	0,380	0,296	0,389	0,270	0,331	0,392	0,389	0,270	0,331	0,392	0,392	0,392			
		50	0,140	0,199	0,174	0,260	0,355	0,470	0,376	0,489	0,370	0,431	0,492	0,489	0,370	0,431	0,492	0,492	0,492			
	4	5	—	—	—	—	0,162	0,238	0,154	0,137	0,141	0,162	0,190	0,215	0,225	0,270	0,300	0,300	0,300			
		15	—	—	—	—	0,245	0,335	0,219	0,215	0,225	0,276	0,300	0,316	0,317	0,276	0,300	0,300	0,300			
		30	—	—	—	—	0,360	0,380	0,318	0,316	0,317	0,276	0,300	0,316	0,317	0,276	0,300	0,300	0,300			
		50	—	—	—	—	0,370	0,475	0,366	0												

Tabela 14 – Altura relativa de onda para $x'/h = 10$

H/h	β	H/h	α																			
			28°				30°				35°		40°		45°				50°			
			1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12		
0,12	1	5	0,200		0,259		0,163		0,265		0,322		0,263		0,296		0,264	0,288				
		15	0,260		0,322		0,290		0,354		0,440		0,405		0,519		0,534	0,550				
		30	0,366		0,440		0,395		0,440		0,510		0,570		0,574		0,544	0,680				
		50	0,450		0,485		0,440		0,520		0,670		0,580		0,445		0,602	0,705				
	2	5	0,162		0,190		0,220		0,290		0,330		0,290		0,298		0,251	0,328				
		15	0,236		0,318		0,290		0,380		0,460		0,450		0,442		0,566	0,538				
		30	0,225		0,325		0,310		0,408		0,560		0,485		0,436		0,622	0,690				
		50	0,140		0,322		0,440		0,500		0,615		0,660		0,591		0,622	0,680				
	3	5	0,138		0,280		0,232		0,310		0,370		0,352		0,377		0,359	0,370				
		15	0,212		0,325		0,240		0,350		0,490		0,530		0,483		0,542	0,585				
		30	0,275		0,322		0,300		0,450		0,610		0,580		0,505		0,501	0,625				
		50	0,455		0,472		0,195		0,505		0,660		0,580		0,575		0,279	0,660				
	4	5	—		—		—		—		0,420		0,395		0,389		0,388	0,375				
		15	—		—		—		0,390		0,615		0,580		0,578		0,587	0,650				
		30	—		—		—		0,480		0,680		0,550		0,582		0,491	0,735				
		50	—		—		—		0,450		0,655		0,570		0,651		0,642	0,750				
0,18	1	5	0,102		0,120		0,118		0,153		0,235		0,180		0,186		0,205	0,200				
		15	0,201		0,206		0,161		0,232		0,340		0,295		0,331		0,361	0,420				
		30	0,284		0,285		0,308		0,341		0,390		0,370		0,371		0,489	0,555				
		50	0,352		0,380		0,358		0,380		0,475		0,468		0,355		0,570	0,620				
	2	5	0,129		0,170		0,126		0,180		0,212		0,190		0,208		0,198	0,220				
		15	0,153		0,192		0,188		0,255		0,345		0,295		0,330		0,337	0,420				
		30	0,192		0,239		0,232		0,290		0,390		0,370		0,377		0,477	0,500				
		50	0,260		0,303		0,325		0,350		0,410		0,338		0,407		0,557	0,570				
	3	5	0,153		0,166		0,126		0,200		0,250		0,212		0,224		0,194	0,220				
		15	0,107		0,175		0,212		0,265		0,365		0,300		0,371		0,293	0,420				
		30	0,134		0,218		0,225		0,285		0,410		0,425		0,394		0,385	0,515				
		50	0,190		0,262		0,241		0,340		0,415		0,425		0,405		0,519	0,585				
	4	5	—		—		—		—		0,270		0,230		0,249		0,225	0,250				
		15	—		—		—		0,275		0,390		0,388		0,406		0,381	0,430				
		30	—		—		—		0,295		0,500		0,510		0,434		0,502	0,530				
		50	—		—		—		0,310		0,555		0,555		0,402		0,579	0,640				
0,27	1	5	0,044		0,095		0,081		0,126		0,133		0,096		0,110		0,123	0,098				
		15	0,082		0,150		0,130		0,188		0,194		0,185		0,212		0,208	0,215				
		30	0,131		0,142		0,186		0,225		0,275		0,275		0,281		0,297	0,322				
		50	0,222		0,236		0,248		0,270		0,308		0,360		0,264		0,409	0,422				
	2	5	0,057		0,095		0,081		0,122		0,128		0,118		0,130		0,142	0,120				
		15	0,073		0,125		0,110		0,180		0,198		0,205		0,196		0,204	0,215				
		30	0,108		0,165		0,141		0,225		0,275		0,275		0,280		0,287	0,295				
		50	0,155		0,199		0,172		0,244		0,285		0,325		0,311		0,395	0,375				
	3	5	0,082		0,095		0,096		0,160		0,143		0,125		0,127		0,175	0,118				
		15	0,067		0,120		0,121		0,200		0,210		0,262		0,217		0,200	0,220				
		30	0,108		0,120		0,124		0,235		0,270		0,275		0,287		0,318	0,302				
		50	0,133		0,142		0,189		0,252		0,301		0,295		0,330		0,237	0,400				
	4	5	—		—		—		—		0,143		0,138		0,143		0,102	0,169				
		15	—		—		—		—		0,240		0,245		0,230		0,218	0,256				
		30	—		—		—		—		0,285		0,320		0,332		0,298	0,360				
		50	—		—		—		—		0,365		0,290		0,361		0,415	0,430				
0,36	1	5	0,028		0,049		0,045		0,070		0,074		0,076		0,083		0,080	0,088				
		15	0,045		0,087		0,075		0,122		0,146		0,150		0,160		0,159	0,162				
		30	0,086		0,136		0,111		0,196		0,200		0,195		0,214		0,205	0,210				
		50	0,140		0,171		0,069		0,220		0,220		0,280		0,270		0,301	0,300				
	2	5	0,036		0,073		0,070		0,076		0,086		0,084		0,087		0,078	0,117				
		15	0,056		0,099		0,082		0,130		0,148		0,155		0,155		0,170	0,130				
		30	0,081		0,115		0,111		0,160		0,189		0,202		0,209		0,201	0,192				
		50	0,122		0,126		0,125		0,185		0,242		0,238		0,258		0,280	0,255				
	3	5	0,056		0,067		0,065		0,092		0,104		0,090		0,094		0,058	0,087				
		15	0,063		0,107		0,095		0,132		0,151		0,150		0,152		0,135	0,151				
		30	0,076		0,093		0,079		0,165		0,205		0,195		0,216		0,180	0,161				
		50	0,102		0,150		0,149		0,200		0,260		0,288		0,283		0,283	0,204				
	4	5	—		—		—		—		0,104		0,104		0,099		0,088	0,086				
		15	—		—		—		—		0,171		0,173		0,159		0,154	0,154				
		30	—		—		—		—		0,230		0,195		0,241		0,215	0,215				
		50	—		—		—		—		0,278		0,305		0,287		0,286	0,290				

Tabelle 9b Relative Wellenhöhen H_1/h in Abhängigkeit der Versuchsparameter, $x'/h = 10$

Fonte: Huber (1980).

Tabela 15 – Altura relativa de onda para $x'/h = 20$

h m	η_E m	Gr kg	β															
			28°				30°				35°				45°			
			1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12
0,12	1	5	0,146		1,181		1,129		0,190		0,226		0,186		0,210	0,221	0,215	0,218
		15	0,200		0,250		0,250		0,296		0,370		0,320		0,471	0,473	0,472	0,470
		30	0,292		0,370		0,340		0,388		0,452		0,470		0,515	0,517	0,513	0,515
		50	0,379		0,435		0,380		0,470		0,560		0,515		0,561	0,516	0,439	0,630
	2	5	0,115		0,215		0,170		0,212		0,240		0,206		0,206	0,208	0,235	0,245
		15	0,177		0,250		0,240		0,328		0,390		0,372		0,505	0,474	0,428	0,460
		30	0,170		0,260		0,268		0,358		0,480		0,410		0,575	0,650	0,532	0,630
		50	0,270		0,280		0,380		0,448		0,550				0,578	0,585	0,413	0,580
	3	5	0,097		0,215		0,185		0,260		0,290		0,271		0,263	0,253	0,216	0,290
		15	0,160		0,240		0,200		0,290		0,395		0,450		0,340	0,449	0,432	0,505
		30	0,211		0,280		0,255		0,395		0,345		0,480		0,470	0,631	0,485	0,555
		50	0,386		0,375		0,348		0,450		0,600		0,480		0,399	0,317	0,314	0,580
	4	5	—		—		—		—		0,340		0,300		0,315	0,343	0,318	0,305
		15	—		—		—		0,335		0,550		0,480		0,534	0,575	0,580	0,580
		30	—		—		—		0,425		0,630		0,520		0,471	0,474	0,523	0,665
		50	—		—		—		0,430		0,580		0,480		0,578	0,451	0,581	0,685
0,18	1	5	0,073		0,088		0,066		0,104		0,148		0,112		0,140	0,122	0,108	0,124
		15	0,144		0,155		0,131		0,181		0,245		0,225		0,280	0,269	0,259	0,294
		30	0,218		0,229		0,250		0,280		0,308		0,310		0,423	0,445	0,431	0,450
		50	0,280		0,305		0,300		0,330		0,380		0,390		0,526	0,528	0,509	0,540
	2	5	0,091		0,125		0,097		0,124		0,138		0,115		0,139	0,118	0,129	0,142
		15	0,110		0,151		0,151		0,200		0,250		0,230		0,273	0,265	0,259	0,294
		30	0,140		0,191		0,192		0,245		0,315		0,310		0,417	0,357	0,294	0,395
		50	0,200		0,250		0,265		0,288		0,330		0,380		0,512	0,451	0,338	0,480
	3	5	0,110		0,114		0,098		0,140		0,163		0,155		0,126	0,128	0,151	0,142
		15	0,085		0,150		0,171		0,115		0,275		0,230		0,236	0,246	0,262	0,294
		30	0,104		0,175		0,188		0,245		0,345		0,350		0,331	0,381	0,417	0,418
		50	0,148		0,218		0,204		0,285		0,370		0,370		0,472	0,458	0,495	0,500
	4	5	—		—		—		—		0,180		0,156		0,155	0,141	0,147	0,168
		15	—		—		—		0,232		0,308		0,320		0,303	0,283	0,323	0,302
		30	—		—		—		0,262		0,410		0,440		0,446	0,406	0,443	0,440
		50	—		—		—		0,290		0,293		0,482		0,538	0,467	0,559	0,565
0,27	1	5	0,036		0,070		0,040		0,066		0,080		0,054		0,078	0,065	0,064	0,069
		15	0,062		0,112		0,097		0,130		0,139		0,145		0,147	0,133	0,118	0,140
		30	0,100		0,123		0,142		0,168		0,200		0,190		0,229	0,225	0,227	0,240
		50	0,175		0,192		0,145		0,218		0,252		0,190		0,329	0,328	0,282	0,338
	2	5	0,046		0,070		0,040		0,066		0,084		0,041		0,088	0,056	0,065	0,069
		15	0,064		0,098		0,085		0,121		0,142		0,152		0,150	0,122	0,146	0,140
		30	0,082		0,134		0,110		0,172		0,200		0,190		0,229	0,193	0,217	0,216
		50	0,140		0,152		0,141		0,200		0,235		0,252		0,329	0,276	0,310	0,298
	3	5	0,062		0,070		0,073		0,099		0,094		0,070		0,107	0,066	0,080	0,076
		15	0,058		0,100		0,101		0,144		0,156		0,135		0,147	0,128	0,153	0,150
		30	0,082		0,100		0,103		0,185		0,220		0,190		0,243	0,223	0,232	0,226
		50	0,102		0,123		0,164		0,200		0,252		0,240		0,390	0,280	0,238	0,314
	4	5	—		—		—		—		0,094		0,078		0,072	0,092	0,086	0,102
		15	—		—		—		—		0,188		0,158		0,168	0,154	0,167	0,173
		30	—		—		—		—		0,235		0,244		0,246	0,238	0,243	0,274
		50	—		—		—		—		0,312		0,210		0,342	0,229	0,328	0,348
0,36	1	5	0,023		0,031		0,033		0,043		0,049		0,037		0,052	0,043	0,046	0,039
		15	0,035		0,065		0,057		0,086		0,100		0,089		0,102	0,098	0,094	0,097
		30	0,062		0,102		0,086		0,123		0,146		0,135		0,150	0,139	0,143	0,140
		50	0,104		0,135		0,040		0,167		0,170		0,190		0,237	0,239	0,218	0,216
	2	5	0,030		0,053		0,050		0,050		0,058		0,041		0,052	0,082	0,040	0,042
		15	0,044		0,070		0,064		0,090		0,100		0,083		0,107	0,125	0,083	0,083
		30	0,084		0,089		0,087		0,115		0,136		0,126		0,148	0,125	0,129	0,135
		50	0,092		0,102		0,098		0,143		0,170		0,165		0,212	0,174	0,188	0,190
	3	5	0,044		0,049		0,047		0,059		0,063		0,042		0,035	0,052	0,054	0,052
		15	0,050		0,082		0,082		0,091		0,100		0,086		0,091	0,099	0,107	0,095
		30	0,059		0,075		0,066		0,120		0,148		0,135		0,141	0,116	0,161	0,160
		50	0,075		0,113		0,128		0,155		0,198		0,192		0,206	0,154	0,207	0,208
	4	5	—		—		—		—		0,065		0,054		0,057	0,053	0,056	0,050
		15	—		—		—		—		0,115		0,094		0,110	0,105	0,112	0,107
		30	—		—		—		—		0,162		0,135		0,170	0,163	0,162	0,162
		50	—		—		—		—		0,212		0,212		0,219	0,216	0,224	0,215

Tabelle 9c Relative Wellenhöhen H_1/h in Abhängigkeit der Versuchsparemeter, $x'/h = 20$

Fonte: Huber (1980).

Tabela 16 – Altura relativa de onda para $x'/h = 50$

h m	α_E m/s	G kg	α																			
			25°				30°				35°		40°		45°				60°			
			β	1:0	1:4		1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	
0,12	1	5	0,102			0,123		0,095		0,130		0,150	0,125		0,163		0,155	0,162	0,149	0,152		
		15	0,149			0,190		0,190		0,240		0,298	0,250		0,309		0,399	0,393	0,387	0,380		
		30	0,230			0,295		0,282		0,338		0,400	0,375		0,467		0,478	0,471	0,494	0,530		
		50	0,315			0,385		0,328		0,422		0,500	0,455		0,580		0,512	0,483	0,449	0,565		
	2	5	0,081			0,150		0,125		0,145		0,165	0,139		0,173		0,159	0,168	0,178	0,167		
		15	0,129			0,192		0,190		0,275		0,318	0,305		0,332		0,434	0,392	0,373	0,378		
		30	0,125			0,214		0,242		0,315		0,400	0,360		0,379		0,520	0,577	0,496	0,530		
		50	0,213			0,240		0,328		0,400		0,480	0,520		0,527		0,524	0,502	0,418	0,495		
	3	5	0,069			0,161		0,140		0,159		0,210	0,191		0,226		0,175	0,185	0,176	0,205		
		15	0,120			0,214		0,162		0,230		0,295	0,365		0,391		0,338	0,391	0,395	0,415		
		30	0,162			0,240		0,212		0,350		0,322	0,405		0,440		0,432	0,540	0,452	0,470		
		50	0,325			0,326		0,393		0,420		0,550	0,395		0,519		0,354	0,368	0,470	0,495		
	4	5	—			—		—		—		0,250	0,220		0,258		0,238	0,246	0,240	0,188		
		15	—			—		—		0,288		0,480	0,405		0,462		0,471	0,488	0,502	0,446		
		30	—			—		—		0,375		0,570	0,490		0,560		0,446	0,455	0,486	0,505		
		50	—			—		—		0,385		0,525	0,410		0,514		0,501	0,431	0,528	0,490		
0,18	1	5	0,050			0,059		0,059		0,064		0,082	0,064		0,076		0,085	0,075	0,069	0,071		
		15	0,099			0,115		0,101		0,134		0,170	0,160		0,186		0,200	0,195	0,186	0,196		
		30	0,162			0,179		0,193		0,220		0,234	0,243		0,260		0,349	0,359	0,331	0,340		
		50	0,220			0,242		0,245		0,281		0,310	0,327		0,302		0,471	0,290	0,450	0,465		
	2	5	0,063			0,082		0,070		0,075		0,082	0,071		0,090		0,087	0,079	0,087	0,090		
		15	0,078			0,118		0,117		0,150		0,182	0,170		0,196		0,106	0,180	0,194	0,196		
		30	0,099			0,150		0,153		0,202		0,252	0,243		0,272		0,149	0,295	0,282	0,308		
		50	0,156			0,202		0,205		0,250		0,278	0,228		0,330		0,479	0,409	0,329	0,395		
	3	5	0,078			0,083		0,073		0,090		0,098	0,095		0,104		0,072	0,084	0,104	0,090		
		15	0,070			0,126		0,131		0,165		0,208	0,188		0,224		0,178	0,182	0,211	0,196		
		30	0,081			0,140		0,150		0,200		0,278	0,288		0,298		0,272	0,332	0,360	0,330		
		50	0,115			0,181		0,165		0,250		0,330	0,320		0,345		0,422	0,422	0,451	0,425		
	4	5	—			—		—		—		0,111	0,110		0,128		0,095	0,094	0,098	0,103		
		15	—			—		—		0,190		0,234	0,237		0,252		0,024	0,215	0,249	0,236		
		30	—			—		—		0,238		0,330	0,378		0,356		0,382	0,361	0,371	0,370		
		50	—			—		—		0,274		0,260	0,420		0,381		0,439	0,431	0,488	0,500		
0,27	1	5	0,027			0,048		0,041		0,032		0,054	0,034		0,044		0,043	0,039	0,036	0,038		
		15	0,044			0,078		0,068		0,086		0,094	0,079		0,089		0,092	0,087	0,076	0,090		
		30	0,073			0,104		0,102		0,121		0,132	0,140		0,154		0,163	0,161	0,159	0,172		
		50	0,132			0,149		0,145		0,168		0,196	0,198		0,168		0,247	0,254	0,216	0,265		
	2	5	0,035			0,048		0,041		0,035		0,055	0,043		0,049		0,047	0,036	0,040	0,038		
		15	0,049			0,072		0,061		0,079		0,093	0,083		0,099		0,099	0,084	0,095	0,090		
		30	0,059			0,104		0,081		0,126		0,152	0,140		0,152		0,171	0,148	0,154	0,159		
		50	0,089			0,110		0,108		0,160		0,185	0,195		0,196		0,258	0,217	0,234	0,236		
	3	5	0,044			0,048		0,050		0,056		0,058	0,038		0,054		0,056	0,042	0,048	0,049		
		15	0,048			0,078		0,079		0,099		0,109	0,088		0,113		0,098	0,088	0,106	0,106		
		30	0,058			0,078		0,081		0,138		0,167	0,140		0,172		0,170	0,164	0,170	0,172		
		50	0,079			0,104		0,136		0,160		0,206	0,205		0,225		0,143	0,217	0,186	0,244		
	4	5	—			—		—		—		0,058	0,043		0,055		0,045	0,052	0,047	0,055		
		15	—			—		—		—		0,135	0,110		0,128		0,118	0,111	0,132	0,112		
		30	—			—		—		—		0,185	0,181		0,195		0,190	0,180	0,195	0,203		
		50	—			—		—		—		0,255	0,155		0,246		0,264	0,254	0,272	0,276		
0,36	1	5	0,017			0,020		0,021		0,025		0,029	0,025		0,027		0,029	0,023	0,025	0,020		
		15	0,025			0,047		0,039		0,057		0,067	0,048		0,057		0,056	0,055	0,050	0,054		
		30	0,044			0,073		0,061		0,077		0,095	0,091		0,099		0,096	0,094	0,093	0,095		
		50	0,075			0,103		0,050		0,125		0,128	0,130		0,142		0,165	0,151	0,149	0,159		
	2	5	0,021			0,036		0,032		0,030		0,037	0,020		0,033		0,031	0,052	0,021	0,025		
		15	0,032			0,050		0,046		0,059		0,060	0,043		0,062		0,058	0,085	0,051	0,056		
		30	0,047			0,067		0,063		0,078		0,094	0,078		0,099		0,095	0,085	0,084	0,093		
		50	0,068			0,086		0,071		0,105		0,130	0,122		0,142		0,145	0,125	0,139	0,140		
	3	5	0,032			0,054		0,031		0,037		0,038	0,021		0,031		0,018	0,026	0,030	0,034		
		15	0,038			0,060		0,058		0,059		0,065	0,054		0,065		0,055	0,056	0,066	0,043		
		30	0,042			0,059		0,053		0,082		0,102	0,091		0,104		0,102	0,074	0,108	0,110		
		50	0,052			0,087		0,104		0,116		0,143	0,133		0,147		0,135	0,106	0,147	0,154		
	4	5	—			—		—		—		0,038	0,031		0,035		0,032	0,027	0,028	0,034		
		15	—			—		—		—		0,072	0,061		0,076		0,071	0,064	0,062	0,066		
		30	—			—		—		—		0,118	0,091		0,128		0,114	0,105	0,114	0,117		
		50	—			—		—		—		0,160	0,156		0,162		0,156	0,147	0,160	0,250		

Tabelle 9d Relative Wellenhöhen H_1/h in Abhängigkeit der Versuchsparameter, $x'/h = 50$

Fonte: Huber (1980).

Tabela 17 – Altura relativa de onda para $x'/h = 100$

H ₁	x _E	G	β																				
			28°				30°				35°		40°		45°				60°				
			1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12			
0,12	1	5	0,084		0,096		0,076		0,102		0,112		0,100		0,124		0,123		0,128		0,112		0,120
		15	0,110		0,162		0,208		0,258		0,268		0,228		0,247		0,332		0,341		0,314		0,315
		30	0,202		0,260		0,248		0,308		0,370		0,350		0,427		0,452		0,440		0,460		0,485
		50	0,292		0,362		0,296		0,398		0,470		0,440		0,555		0,477		0,460		0,456		0,495
	2	5	0,069		0,118		0,100		0,123		0,131		0,108		0,137		0,131		0,143		0,145		0,121
		15	0,108		0,168		0,161		0,230		0,277		0,270		0,294		0,388		0,340		0,336		0,321
		30	0,110		0,200		0,218		0,300		0,360		0,363		0,357		0,481		0,526		0,470		0,440
		50	0,198		0,221		0,296		0,388		0,445		0,470		0,501		0,487		0,448		0,422		0,440
	3	5	0,060		0,137		0,114		0,137		0,170		0,147		0,181		0,128		0,146		0,154		0,160
		15	0,106		0,200		0,140		0,270		0,265		0,310		0,357		0,136		0,152		0,169		0,155
		30	0,146		0,221		0,187		0,325		0,300		0,375		0,415		0,485		0,480		0,428		0,415
		50	0,300		0,305		0,263		0,390		0,520		0,443		0,450		0,383		0,372		0,419		0,440
	4	5	—		—		—		—		0,199		0,178		0,217		0,191		0,192		0,193		0,188
		15	—		—		—		0,270		0,445		0,375		0,420		0,428		0,411		0,450		0,440
		30	—		—		—		0,352		0,530		0,480		0,457		0,478		0,441		0,460		0,505
		50	—		—		—		0,370		0,490		0,390		0,465		0,454		0,416		0,491		0,490
0,18	1	5	0,041		0,044		0,045		0,045		0,058		0,043		0,052		0,058		0,051		0,049		0,050
		15	0,082		0,092		0,084		0,108		0,129		0,125		0,145		0,155		0,152		0,145		0,153
		30	0,141		0,151		0,160		0,186		0,203		0,208		0,223		0,202		0,206		0,201		0,185
		50	0,192		0,210		0,210		0,252		0,280		0,305		0,282		0,437		0,265		0,410		0,435
	2	5	0,053		0,061		0,055		0,051		0,061		0,060		0,063		0,062		0,059		0,063		0,068
		15	0,066		0,101		0,096		0,120		0,148		0,140		0,157		0,167		0,162		0,156		0,151
		30	0,085		0,130		0,131		0,178		0,226		0,208		0,234		0,305		0,255		0,273		0,272
		50	0,141		0,176		0,172		0,233		0,260		0,205		0,302		0,449		0,381		0,324		0,352
	3	5	0,066		0,067		0,059		0,065		0,070		0,066		0,074		0,047		0,061		0,078		0,068
		15	0,070		0,111		0,108		0,135		0,170		0,168		0,180		0,144		0,145		0,164		0,153
		30	0,075		0,125		0,128		0,180		0,240		0,260		0,284		0,234		0,300		0,311		0,290
		50	0,104		0,165		0,143		0,235		0,315		0,302		0,323		0,387		0,386		0,420		0,390
	4	5	—		—		—		—		0,084		0,086		0,096		0,066		0,069		0,072		0,076
		15	—		—		—		0,165		0,203		0,222		0,203		0,178		0,177		0,204		0,196
		30	—		—		—		0,228		0,300		0,340		0,320		0,339		0,299		0,322		0,340
		50	—		—		—		0,267		0,260		0,400		0,355		0,454		0,405		0,440		0,470
0,27	1	5	0,022		0,036		0,031		0,023		0,046		0,030		0,028		0,027		0,027		0,024		0,028
		15	0,036		0,059		0,052		0,070		0,063		0,070		0,061		0,085		0,083		0,055		0,073
		30	0,060		0,091		0,081		0,101		0,114		0,130		0,119		0,126		0,125		0,121		0,147
		50	0,110		0,121		0,118		0,148		0,160		0,160		0,138		0,199		0,209		0,179		0,236
	2	5	0,030		0,036		0,031		0,030		0,038		0,030		0,032		0,029		0,028		0,028		0,028
		15	0,043		0,056		0,047		0,066		0,069		0,072		0,074		0,073		0,063		0,069		0,073
		30	0,048		0,085		0,066		0,106		0,114		0,120		0,117		0,136		0,110		0,119		0,140
		50	0,073		0,085		0,088		0,140		0,155		0,163		0,163		0,215		0,182		0,190		0,215
	3	5	0,036		0,036		0,038		0,042		0,042		0,028		0,037		0,024		0,029		0,033		0,051
		15	0,042		0,065		0,066		0,081		0,085		0,073		0,085		0,072		0,067		0,080		0,153
		30	0,048		0,065		0,086		0,113		0,128		0,130		0,118		0,130		0,130		0,133		0,165
		50	0,066		0,090		0,118		0,138		0,176		0,200		0,191		0,215		0,179		0,154		0,308
	4	5	—		—		—		—		0,042		0,030		0,036		0,032		0,033		0,030		0,051
		15	—		—		—		—		0,106		0,100		0,094		0,091		0,086		0,083		0,152
		30	—		—		—		—		0,155		0,155		0,156		0,157		0,158		0,163		0,305
		50	—		—		—		—		0,220		0,160		0,208		0,212		0,209		0,237		0,308
0,36	1	5	0,014		0,017		0,015		0,018		0,020		0,022		0,018		0,018		0,013		0,018		0,014
		15	0,020		0,034		0,029		0,045		0,045		0,035		0,039		0,046		0,035		0,031		0,040
		30	0,034		0,060		0,048		0,062		0,064		0,082		0,071		0,072		0,070		0,067		0,082
		50	0,063		0,089		0,074		0,110		0,113		0,115		0,107		0,122		0,124		0,112		0,143
	2	5	0,016		0,028		0,023		0,022		0,025		0,015		0,027		0,020		0,036		0,033		0,020
		15	0,024		0,039		0,036		0,046		0,043		0,029		0,042		0,048		0,064		0,036		0,030
		30	0,037		0,058		0,050		0,063		0,074		0,063		0,072		0,073		0,064		0,060		0,080
		50	0,056		0,075		0,054		0,088		0,110		0,115		0,110		0,109		0,098		0,098		0,130
	3	5	0,026		0,026		0,022		0,024		0,026		0,016		0,019		0,011		0,015		0,019		0,029
		15	0,031		0,050		0,045		0,046		0,046		0,048		0,045		0,037		0,037		0,045		0,057
		30	0,034		0,050		0,044		0,067		0,081		0,082		0,076		0,080		0,053		0,080		0,095
		50	0,042		0,080		0,089		0,099		0,120		0,125		0,111		0,098		0,080		0,113		0,135
	4	5	—		—		—		—		0,026		0,026		0,023		0,020		0,017		0,016		0,024
		15	—		—		—		—		0,056		0,051		0,055		0,051		0,043		0,040		0,054
		30	—		—		—		—		0,094		0,082		0,097		0,084		0,076		0,087		0,098
		50	—		—		—		—		0,138		0,145		0,127		0,012		0,110		0,123		0,127

Tabelle 9e Relative Wellenhöhen H_1/h in Abhängigkeit der Versuchsparameter, $x'/h = 100$

Fonte: Huber (1980).

Tabela 18 – Comprimento relativo de onda para $x'/h=5$

h m	v _E m/s	G kg	λ																			
			28°				30°				35°		40°		45°				60°			
			β	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12			
0,12	1	5	5,9		6,0		6,4		9,5		6,5		5,1		6,1		6,0	6,3	5,9	7,7		
		15	5,0		5,1		5,2		8,1		7,2		—		8,4		5,8	5,6	6,0	8,6		
		30	4,6		—		4,9		8,1		—		—		8,1		—	—	—	—		
		50	—		—		—		6,8		—		—		—		—	—	1,5	—		
	2	5	7,3		6,3		7,6		9,3		7,1		—		6,1		6,2	5,3	5,3	5,7		
		15	4,9		4,9		5,0		10,7		—		6,8		6,0		6,1	6,1	10,1	6,1		
		30	4,9		—		—		6,3		—		—		—		—	6,8	—	—		
		50	—		—		—		11,6		—		—		—		—	3,6	0,6	—		
	3	5	—		6,9		8,5		8,0		6,6		—		6,3		5,1	3,4	5,0	5,5		
		15	—		—		—		6,3		9,3		—		7,3		6,8	6,3	8,3	6,2		
		30	—		—		—		—		—		—		—		1,2	7,3	—	—		
		50	—		—		—		—		—		—		—		1,1	2,2	—	—		
	4	5	—		—		—		—		6,8		7,2		6,5		5,6	5,6	5,6	9,4		
		15	—		—		—		0,7		—		—		8,6		7,3	7,6	7,7	—		
		30	—		—		—		11,2		—		—		—		16,8	—	—	—		
		50	—		—		—		10,6		—		—		—		—	12,5	—	—		
0,18	1	5	7,2		6,2		7,0		7,3		6,7		6,5		5,8		6,2	5,6		7,0		
		15	4,2		5,5		6,0		8,6		7,0		7,3		6,5		6,1	6,2	6,6	7,5		
		30	5,3		5,4		6,2		8,4		4,4		—		5,6		6,5	6,2	6,4	8,6		
		50	5,4		5,5		5,6		6,7		7,3		—		—		5,9	—	5,7	—		
	2	5	6,8		6,3		6,2		8,9		6,7		6,4		6,1		5,8	6,2	8,1	5,2		
		15	5,7		5,5		6,1		8,7		8,6		7,2		6,6		6,1	7,3		5,9		
		30	5,4		5,2		5,7		7,9		8,2		6,6		5,6		6,3	6,6	6,1	6,7		
		50	5,3		5,2		5,2		7,5		5,2		—		5,2		6,3	7,0	5,4	6,0		
	3	5	8,4		7,4		8,1		9,8		6,9		6,7		5,9		6,8	6,7	8,5	5,3		
		15	4,7		4,8		4,4		10,1		8,6		7,0		7,0		5,8	6,6	5,8	6,2		
		30	5,4		5,2		5,1		10,6		8,3		8,5		7,0		6,7	7,8	6,6	7,3		
		50	5,1		5,2		5,7		—		—		—		4,4		6,5	7,8	6,7	6,9		
	4	5	—		—		—		—		6,3		5,8		5,8		6,0	6,2	6,0	7,5		
		15	—		—		—		11,4		7,1		7,9		6,9		6,5	6,2	6,5	7,9		
		30	—		—		—		14,1		8,7		—		7,6		7,1	6,8	7,1	9,5		
		50	—		—		—		—		8,3		—		5,6		8,3	8,5	7,6	—		
0,27	1	5	7,1		6,0		5,2		7,7		6,3		5,3		5,6		6,1	6,3	6,8	6,6		
		15	5,0		6,0		6,0		6,7		7,4		6,1		6,1		5,8	5,9	6,2	6,9		
		30	4,8		6,2		5,6		8,3		7,4		6,6		6,5		6,5	6,8	6,4	7,6		
		50	5,9		5,9		5,9		7,8		6,0		7,4		6,2		6,5	7,1	6,8	5,8		
	2	5	6,5		5,9		5,9		7,4		8,0		6,4		5,7		6,0	6,1	6,4	6,2		
		15	4,8		6,0		5,6		7,3		6,3		6,6		7,1		5,8	6,6	6,7	6,4		
		30	4,8		6,0		5,5		8,2		6,2		7,6		7,5		6,4	6,6	6,8	5,9		
		50	5,8		5,5		5,9		9,5		6,4		6,3		7,7		6,6	6,6	6,7	6,3		
	3	5	6,6		6,2		7,3		8,8		5,1		5,1		7,4		7,1	5,9	5,4	6,1		
		15	5,7		7,6		8,0		10,2		5,8		6,1		7,6		5,8	6,3	6,4	6,2		
		30	5,5		5,1		5,7		11,3		6,8		1,2		7,7		5,8	6,8	6,5	6,0		
		50	5,7		4,9		5,5		11,5		7,4		7,2		8,8		6,4	8,7	6,9	6,3		
	4	5	—		—		—		—		7,4		5,4		7,3		6,3	6,4	6,6	7,4		
		15	—		—		—		—		6,3		6,6		6,9		7,7	6,9	6,5	8,3		
		30	—		—		—		—		7,0		7,0		8,1		7,1	6,3	6,5	8,0		
		50	—		—		—		—		7,7		8,2		9,2		6,8	6,6	8,6	7,9		
0,36	1	5	5,7		5,8		6,1		6,3		6,0		5,9		6,4		5,4	5,5	6,4	6,2		
		15	5,4		5,6		5,9		6,6		7,6		6,2		9,4		5,8	5,9	6,6	6,6		
		30	6,4		5,8		5,0		7,5		6,4		6,2		7,9		6,4	6,4	7,2	7,8		
		50	5,7		5,8		5,7		8,2		6,4		6,8		7,5		6,7	6,6	8,6	8,1		
	2	5	6,2		5,5		5,5		5,1		6,8		5,8		6,0		5,5	5,6	6,1	7,7		
		15	5,6		5,8		5,5		10,3		7,5		6,0		7,4		9,6	5,8	5,7	5,5		
		30	5,8		5,8		5,5		10,6		7,3		6,0		7,5		6,5	5,8	6,1	5,4		
		50	5,5		5,5		5,5		11,8		6,4		5,9		8,2		6,6	5,8	6,9	6,6		
	3	5	7,1		6,9		6,1		8,1		6,1		5,4		6,9		5,6	6,0	6,3	6,5		
		15	5,7		5,2		7,1		10,0		5,8		5,7		7,3		5,4	6,1	7,2	5,5		
		30	5,3		5,1		5,1		9,8		7,9		5,8		8,0		5,4	5,4	8,6	5,4		
		50	5,7		5,5		5,4		10,7		6,7		7,0		8,1		6,4	6,6	7,8	5,2		
	4	5	—		—		—		—		5,8		5,5		6,7		1,3	5,5	6,0	6,2		
		15	—		—		—		—		5,8		6,2		8,1		5,5	5,9	7,0	7,1		
		30	—		—		—		—		6,7		6,7		7,8		5,7	5,9	8,0	7,8		
		50	—		—		—		—		7,5		6,3		7,3		6,3	6,6	7,8	7,7		

Tabelle 10a Relative Wellenlängen λ/h in Abhängigkeit der Versuchsparameter, $x'/h = 5$

Fonte: Huber (1980).

Tabela 19 – Comprimento relativo de onda para $x'/h = 10$

H m	$\frac{x'}{h}$ m/h	β k.g	α															
			28°				30°				35°				45°			
			1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12
0,12	1	5	7,7		7,8	8,2	11,8	8,7	7,0	8,1	8,0	8,3	7,9	9,9	8,7	8,7	8,9	12,2
		15	7,0		7,2	7,3	11,0	—	—	11,7	—	—	—	—	—	—	—	—
		30	6,8		—	7,2	11,6	—	—	12,0	—	—	—	—	—	—	—	—
		50	—		—	—	10,3	—	—	—	—	—	—	—	—	—	2,6	—
	2	5	9,2		8,3	9,6	11,8	9,3	—	8,2	8,3	7,4	7,4	7,7	9,5	9,1	14,7	9,1
		15	8,8		8,9	7,0	14,1	—	9,8	8,7	—	—	—	—	—	10,6	—	—
		30	8,5		—	—	9,4	—	—	—	—	—	—	—	—	—	—	—
		50	—		—	—	16,2	—	—	—	—	—	—	—	—	5,2	1,13	—
	3	5	—		9,2	10,6	10,8	9,0	—	8,7	7,5	7,7	7,2	7,7	10,0	9,5	11,6	9,4
		15	—		—	—	12,6	12,9	—	10,6	—	—	—	—	—	—	—	—
		30	—		—	—	—	—	—	—	—	—	—	—	—	2,2	11,3	—
		50	—		—	—	—	—	—	—	—	—	—	—	—	2,0	3,4	—
	4	5	—		—	—	—	9,5	10,1	9,0	8,0	8,0	8,2	12,3	11,1	11,4	11,4	—
		15	—		—	—	9,2	—	—	—	—	—	—	—	—	—	—	—
		30	—		—	—	11,1	—	—	—	—	—	—	—	—	—	—	—
		50	—		—	—	10,7	—	—	—	—	—	—	—	—	12,1	—	—
0,18	1	5	8,7		7,8	8,6	9,3	8,6	8,2	7,5	8,0	7,4	—	9,0	8,5	8,4	8,7	9,9
		15	8,0		7,4	7,8	10,9	9,3	9,5	—	—	—	—	—	—	—	—	—
		30	7,3		7,5	8,3	11,0	6,7	—	8,1	9,3	9,0	9,2	11,8	9,1	—	—	—
		50	7,8		7,8	8,0	9,7	10,2	—	—	—	—	—	—	—	—	—	—
	2	5	8,5		8,1	8,0	11,0	8,5	8,3	7,9	7,6	8,0	9,0	6,9	8,3	9,4	8,2	—
		15	7,3		7,4	8,0	11,3	10,9	9,5	9,0	9,2	9,5	8,8	9,5	9,2	9,5	8,8	9,5
		30	7,0		7,1	7,6	10,6	10,9	9,3	8,1	9,6	10,8	9,8	9,2	9,6	10,3	8,4	9,2
		50	7,2		7,3	7,3	10,4	7,5	—	7,8	—	—	—	—	—	—	—	—
	3	5	10,1		9,0	10,1	11,9	8,9	8,7	7,8	8,4	8,3	9,8	7,3	8,0	8,8	8,0	8,6
		15	8,4		8,7	8,6	12,9	11,0	9,6	9,4	9,6	10,8	9,8	10,3	9,8	11,2	10,2	10,3
		30	8,9		6,8	6,9	13,3	11,1	11,3	9,7	—	—	—	—	—	—	—	—
		50	8,7		6,8	7,3	—	—	—	6,9	—	—	—	—	—	—	—	—
	4	5	—		—	—	—	8,1	7,9	7,8	7,8	8,0	7,8	9,7	8,9	8,6	9,1	10,7
		15	—		—	—	14,4	9,7	10,7	9,5	10,3	9,9	10,2	13,0	10,3	9,9	10,2	13,0
		30	—		—	—	17,3	12,0	—	10,7	—	—	—	—	—	—	—	—
		50	—		—	—	—	11,3	—	8,5	—	—	—	—	—	—	—	—
0,27	1	5	8,6		7,4	7,1	9,2	8,0	7,0	7,2	7,8	8,0	8,3	8,2	7,6	7,7	7,9	8,9
		15	7,2		7,7	7,7	8,5	9,3	8,1	8,1	8,5	8,8	8,5	10,0	8,5	8,8	8,5	10,0
		30	6,6		8,1	7,4	10,6	9,5	8,7	8,6	9,0	9,5	9,1	7,8	9,0	9,5	9,1	7,8
		50	7,7		7,4	7,9	10,1	8,0	9,8	8,5	—	—	—	—	—	—	—	—
	2	5	7,9		7,5	7,6	9,1	9,4	7,8	7,3	7,6	8,0	8,0	7,7	7,6	8,8	8,4	8,0
		15	6,6		7,7	7,6	9,3	8,0	8,6	8,9	8,5	8,6	8,8	8,0	8,5	8,6	8,8	8,0
		30	6,8		7,7	7,3	10,4	8,2	9,7	9,2	9,3	9,0	9,2	7,7	9,3	9,0	9,2	7,7
		50	7,4		7,3	7,6	11,8	8,5	8,7	10,1	—	—	—	—	—	—	—	—
	3	5	8,5		8,0	8,9	10,6	7,0	6,8	8,9	9,1	7,6	7,1	8,8	7,7	8,1	8,2	8,4
		15	7,3		9,4	9,7	12,5	8,5	8,0	9,7	7,7	8,1	8,2	8,4	7,9	8,9	8,5	8,0
		30	6,9		6,7	7,5	13,5	8,9	9,4	10,0	8,8	9,1	9,0	7,7	8,8	9,1	9,0	7,7
		50	7,1		6,5	7,2	14,0	9,6	9,6	11,1	—	—	—	—	—	—	—	—
	4	5	—		—	—	—	9,6	7,1	9,0	8,1	8,2	8,3	9,5	9,4	8,7	8,2	10,4
		15	—		—	—	—	8,4	8,7	8,9	9,4	8,6	8,7	11,5	9,4	8,6	8,7	11,5
		30	—		—	—	—	9,2	9,3	10,6	9,6	9,3	11,4	10,8	9,6	9,3	11,4	10,8
		50	—		—	—	—	10,3	10,9	11,8	—	—	—	—	—	—	—	—
0,36	1	5	7,2		7,9	7,6	8,2	7,2	7,4	7,6	7,2	7,2	8,0	8,0	7,7	7,6	8,3	8,6
		15	7,0		7,4	7,6	8,5	9,0	7,7	10,9	8,2	8,2	9,2	9,9	8,2	8,2	9,2	9,9
		30	7,8		7,9	7,1	9,4	8,2	8,0	9,8	8,7	8,6	10,8	10,1	8,7	8,6	10,8	10,1
		50	7,4		7,9	7,6	10,1	9,2	8,8	9,5	—	—	—	—	—	—	—	—
	2	5	7,6		7,2	7,2	9,8	8,4	7,1	7,5	7,3	7,3	7,4	9,0	7,3	7,3	7,4	7,2
		15	7,2		7,9	7,5	12,1	9,1	7,7	9,4	8,7	7,4	7,8	7,5	8,7	7,5	7,8	7,5
		30	7,4		7,6	7,3	12,3	9,2	7,4	8,5	8,2	8,0	10,4	8,5	8,5	7,8	8,8	8,5
		50	7,2		7,3	7,2	13,6	8,2	8,0	10,4	—	—	—	—	—	—	—	—
	3	5	8,6		8,0	7,8	9,7	7,6	7,0	8,3	7,2	7,9	7,8	8,9	7,4	7,8	9,0	7,2
		15	7,5		7,1	8,9	11,7	7,7	7,6	9,0	7,2	7,4	10,6	7,5	7,2	7,4	10,6	7,5
		30	7,1		6,9	7,0	12,0	9,9	7,7	9,9	8,2	8,6	10,2	8,6	8,2	8,6	10,0	8,6
		50	7,2		7,3	7,3	13,0	8,7	8,1	10,2	—	—	—	—	—	—	—	—
	4	5	—		—	—	—	7,4	7,0	8,2	1,5	7,0	7,6	7,7	8,4	7,8	8,8	9,1
		15	—		—	—	—	7,7	8,0	9,6	7,7	7,9	10,2	9,9	7,7	7,9	10,2	9,9
		30	—		—	—	—	8,7	8,8	10,0	8,4	8,7	10,1	10,0	8,4	8,7	10,1	10,0
		50	—		—	—	—	9,3	8,6	9,6	—	—	—	—	—	—	—	—

Tabelle 10b Relative Wellenlängen λ/h in Abhängigkeit der Versuchsparameter, $x'/h = 10$

Fonte: Huber (1980).

Tabela 20 – Comprimento relativo de onda para $x'/h=20$

h	m	m/s	kg	α																			
				28°				30°				35°		40°		45°				60°			
				β	1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12		
0,12	1	5	10,1			10,2		10,4		14,8		11,8		9,3		10,8		10,7	10,7	10,5	12,8		
		15	9,6			10,2		10,1		19,0		13,8		—		16,2		13,1	13,1	13,2	17,0		
		30	10,0			—		10,1		16,3		—		—		17,5		—	—	—	—		
		50	—			—		—		15,8		—		—		—		—	4,6	—	—		
	2	5	11,4			11,0		12,1		14,9		12,3		—		11,0		11,0	10,4	10,3	10,5		
		15	8,7			8,7		9,8		18,6		—		14,1		12,7		10,3	13,6	16,3	13,3		
		30	8,5			—		—		13,2		—		—		—		—	16,3	—	—		
		50	—			—		—		22,7		—		—		—		—	7,4	2,4	—		
	3	5	—			12,4		12,4		14,6		12,3		—		11,9		10,6	10,2	10,3	10,9		
		15	—			—		—		17,1		12,7		—		13,4		14,8	14,3	15,4	14,2		
		30	—			—		—		—		—		—		—		—	4,1	17,7	—		
		50	—			—		—		—		—		—		—		—	3,5	9,3	—		
	4	5	—			—		—		—		13,1		14,0		12,7		11,5	11,4	11,5	16,0		
		15	—			—		—		9,8		—		—		17,7		16,5	17,2	16,9	—		
		30	—			—		—		11,1		—		—		—		21,8	—	—	—		
		50	—			—		—		10,8		—		—		—		—	11,8	—	—		
0,18	1	5	10,6			9,8		10,6		11,4		11,0		10,4		9,6		10,2	9,7		11,6		
		15	8,5			9,9		10,1		13,7		12,2		12,4		11,4		11,4	11,4	11,6	13,1		
		30	10,0			10,3		11,2		14,4		10,2		—		11,5		13,4	13,7	13,3	16,1		
		50	10,8			11,1		11,3		14,9		14,4		—		16,0		—	13,7	—	—		
	2	5	10,5			10,1		10,1		13,8		10,8		10,7		10,1		10,0	10,1	10,3	9,2		
		15	9,4			9,9		10,3		14,7		12,8		12,7		11,9		11,4	11,9		11,1		
		30	9,2			9,6		10,6		14,4		14,3		14,9		11,4		13,4	13,4	14,7	13,5		
		50	9,7			10,3		10,1		14,5		10,5		—		11,8		14,7	13,0	13,1	14,9		
	3	5	12,2			11,2		12,4		14,3		11,8		11,2		10,1		10,5	10,9	11,4	9,9		
		15	8,3			8,3		9,2		16,4		14,0		13,0		12,6		11,1	11,8	11,2	11,8		
		30	8,8			8,0		9,4		17,2		13,2		13,6		13,5		13,6	15,0	14,3	14,8		
		50	8,7			8,0		9,3		—		—		—		10,8		14,7	16,0	15,4	15,4		
	4	5	—			—		—		—		10,5		10,6		10,4		10,1	10,4	10,3	12,5		
		15	—			—		—		18,1		13,4		14,8		13,1		12,4	11,9	12,8	14,5		
		30	—			—		—		21,3		16,4		—		15,1		14,9	14,5	14,7	17,8		
		50	—			—		—		—		13,4		—		12,8		17,8	18,9	16,9	—		
0,27	1	5	10,7			9,3		9,8		11,1		10,1		9,2		9,3		9,9	10,0	10,2	10,1		
		15	9,2			9,9		9,9		10,4		12,8		10,6		10,3		9,9	10,1	10,1	11,5		
		30	9,0			10,4		9,8		13,5		12,3		11,4		11,2		11,2	11,4	11,3	13,0		
		50	10,2			6,3		10,6		13,1		10,6		12,9		11,5		12,3	12,9	12,3	10,4		
	2	5	9,3			9,6		9,8		11,2		11,0		9,5		9,3		9,8	10,2	10,0	9,8		
		15	9,1			9,9		10,2		11,9		10,1		11,1		11,3		9,9	11,2	10,8	10,7		
		30	8,9			9,9		9,7		12,2		10,9		12,2		12,8		11,2	11,3	11,6	11,9		
		50	9,5			9,8		9,9		14,6		11,2		11,8		13,2		14,4	12,3	12,5	9,7		
	3	5	10,8			10,2		10,8		12,8		9,2		9,0		10,7		10,8	9,8	9,3	12,7		
		15	9,4			11,5		11,6		13,2		10,9		10,4		12,3		10,2	10,5	10,6	11,1		
		30	8,9			9,0		9,7		16,1		11,6		12,3		12,9		10,8	11,7	11,4	10,3		
		50	9,0			8,7		9,3		13,1		12,6		12,7		14,3		12,0	12,3	12,5	9,7		
	4	5	—			—		—		—		12,8		9,4		11,1		10,2	10,4	10,3	12,0		
		15	—			—		—		—		12,0		11,6		11,5		11,6	11,0	10,8	11,1		
		30	—			—		—		—		12,7		12,4		13,7		12,7	11,4	11,7	14,7		
		50	—			—		—		—		14,0		14,6		15,3		13,7	13,0	13,2	14,7		
0,36	1	5	9,2			10,0		9,3		10,8		8,6		9,2		9,2		9,8	9,3	10,0	10,2		
		15	9,2			9,2		9,8		10,0		10,6		9,6		12,8		10,2	9,9	10,6	11,1		
		30	9,6			10,0		9,9		11,7		10,6		10,1		12,1		10,4	10,5	11,8	12,5		
		50	9,5			10,0		10,1		12,4		10,6		11,1		12,1		11,2	11,2	11,6	13,1		
	2	5	9,4			9,4		9,3		8,3		10,4		8,6		9,4		9,2	9,8	9,0	9,3		
		15	9,3			10,0		10,1		14,2		11,0		10,0		12,0		10,9	9,6	9,5	9,8		
		30	9,3			10,0		9,6		14,3		11,7		10,3		12,2		10,4	9,8	10,1	10,1		
		50	9,4			9,6		9,4		15,3		10,6		10,7		13,1		11,1	10,8	11,2	10,8		
	3	5	10,4			9,8		10,0		11,7		9,1		9,0		10,0		9,0	9,3	9,6	9,0		
		15	9,8			9,8		11,2		13,6		10,1		10,2		11,2		8,7	10,1	11,4	9,0		
		30	9,4			9,4		9,1		14,0		12,5		10,4		12,2		10,5	10,1	12,9	10,1		
		50	9,2			9,6		9,8		15,7		11,2		11,7		12,8		10,7	11,2	12,8	11,3		
	4	5	—			—		—		—		9,3		8,8		10,1		1,8	9,0	9,2	9,0		
		15	—			—		—		—		10,1		10,4		11,4		10,8	10,1	11,1	11,8		
		30	—			—		—		—		11,7		11,2		12,7		10,5	10,6	12,8	12,3		
		50	—			—		—		—		12,0		11,7		12,7		11,2	11,5	13,0	13,2		

Tabelle 10c Relative Wellenlängen λ/h in Abhängigkeit der Versuchsparameter, $x'/h = 20$

Fonte: Huber (1980).

Tabela 21 – Comprimento relativo de onda para $x'/h = 50$

°	′	″	°																			
			24°				30°				35°		40°		45°				60°			
			1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12		
0,12	1	5	14,3		14,5		14,6		19,5		17,2		14,5		15,7		15,7	13,2	15,4	18,0		
		15	14,7		16,2		15,8		22,5		21,1		24,9		22,5		22,5	22,3	22,4	31,2		
		30	16,6		—		18,0		26,5		—		29,1		—		—	—	—	—		
		50	—		—		—		27,6		—		—		—		—	—	9,6	—		
	2	5	15,1		16,0		16,6		20,4		17,2		—		16,2		16,1	16,2	16,1	15,1		
		15	17,8		15,2		15,4		26,7		—		22,9		21,1		20,4	23,1	23,9	23,1		
		30	12,7		—		—		28,1		—		—		—		—	29,8	—	—		
		50	—		—		—		35,4		—		—		—		—	11,8	6,5	—		
	3	5	—		18,2		18,1		21,6		18,6		—		16,1		16,8	17,0	16,5	17,2		
		15	—		—		—		26,3		27,0		—		25,2		24,8	24,7	25,6	24,8		
		30	—		—		—		—		—		—		—		9,3	31,8	—	—		
		50	—		—		—		—		—		—		—		7,5	9,6	—	—		
4	5	—		—		—		—		20,2		21,5		19,7		18,6	18,1	18,2	22,7			
	15	—		—		—		19,6		—		—		28,5		27,8	29,4	28,6	—			
	30	—		—		—		11,0		—		—		—		18,0	—	—	—			
	50	—		—		—		10,9		—		—		—		—	11,3	—	—			
0,18	1	5	13,6		13,4		12,9		15,1		15,3		14,2		13,4		14,1	13,8	20,6	18,2		
		15	13,6		14,4		14,2		18,7		17,6		16,6		16,6		17,0	16,9	16,8	18,8		
		30	15,1		15,8		16,7		20,7		18,0		—		16,5		21,7	21,7	21,5	24,1		
		50	17,2		17,7		17,9		22,8		22,4		—		—		24,7	27,4	24,3	—		
	2	5	14,1		14,4		15,3		18,5		15,0		14,9		14,1		14,3	14,4	13,0	13,5		
		15	13,0		15,4		15,1		20,8		19,0		18,5		17,3		17,3	16,5	25,3	17,0		
		30	13,1		15,0		14,9		21,5		21,0		20,2		18,7		21,9	21,0	20,8	21,5		
		50	14,5		15,9		15,6		22,3		22,1		—		20,3		25,6	24,7	23,5	24,1		
	3	5	13,6		14,8		16,4		18,6		16,3		15,7		14,4		13,9	15,2	13,7	14,9		
		15	12,6		14,8		15,1		22,4		19,3		19,5		18,6		17,1	17,4	17,4	18,3		
		30	12,2		13,1		14,1		23,7		22,4		23,3		21,0		21,7	23,1	23,4	23,8		
		50	12,2		13,2		12,9		—		—		—		19,5		25,0	25,9	26,7	26,2		
4	5	—		—		—		—		14,8		15,5		15,3		14,2	14,6	14,7	17,4			
	15	—		—		—		24,8		20,3		21,9		19,9		19,0	18,3	19,9	21,5			
	30	—		—		—		28,1		25,0		—		21,6		24,3	24,1	23,9	26,9			
	50	—		—		—		—		23,3		—		21,9		29,4	31,9	28,3	—			
0,22	1	5	13,1		12,3		14,4		14,0		13,8		13,1		13,0		13,6	13,5	13,3	13,4		
		15	12,8		13,7		14,0		15,1		16,2		15,3		14,2		14,2	14,3	13,9	16,2		
		30	13,7		14,5		14,3		18,5		17,2		16,4		16,1		16,0	16,1	16,4	18,3		
		50	14,6		12,6		15,6		18,9		15,5		18,7		17,3		18,7	19,2	18,2	15,7		
	2	5	12,3		13,3		13,8		14,8		14,8		12,3		13,0		13,1	13,4	13,4	12,6		
		15	11,7		13,7		15,0		16,5		13,8		15,7		15,3		14,2	14,8	14,4	13,9		
		30	13,4		13,7		14,2		18,1		15,9		16,9		17,9		16,3	16,1	16,1	16,0		
		50	13,3		14,5		13,8		19,5		17,8		17,8		18,8		24,4	18,5	18,8	13,2		
	3	5	15,0		14,0		13,9		16,3		13,2		13,7		15,7		13,6	13,2	13,4	19,0		
		15	13,1		14,6		14,8		19,8		15,2		14,8		17,0		14,9	14,1	14,8	16,9		
		30	12,6		13,2		13,7		20,3		16,6		17,6		18,2		16,3	16,8	16,9	14,4		
		50	12,3		12,6		13,6		22,2		17,8		18,6		20,0		18,1	18,5	19,3	13,2		
4	5	—		—		—		—		17,8		13,5		14,5		14,2	14,4	13,7	16,6			
	15	—		—		—		—		16,0		17,0		16,2		15,2	14,9	15,4	17,6			
	30	—		—		—		—		18,6		18,0		19,3		17,7	17,8	17,3	20,3			
	50	—		—		—		—		20,6		21,4		21,4		20,5	20,2	22,3	22,1			
0,36	1	5	12,5		14,9		12,7		15,4		10,5		12,3		11,7		14,1	13,1	13,4	14,2		
		15	13,0		13,9		13,9		15,1		13,9		12,9		15,7		14,9	13,9	14,4	15,6		
		30	12,7		14,5		15,3		15,7		13,0		14,4		16,1		14,3	14,6	16,4	17,0		
		50	13,4		14,5		14,8		16,3		13,0		15,9		18,6		15,7	15,9	18,4	13,9		
	2	5	12,4		13,5		13,7		7,7		13,8		11,1		12,6		14,0	12,8	11,7	12,7		
		15	13,0		14,3		15,1		17,6		14,3		14,1		16,5		13,5	13,6	13,7	14,2		
		30	12,6		14,4		13,8		17,3		16,0		14,3		16,8		14,2	13,5	14,2	13,0		
		50	13,3		14,0		13,7		18,9		15,0		15,9		17,8		19,7	15,8	15,3	15,0		
	3	5	13,5		12,8		13,7		14,9		12,2		12,6		12,8		11,6	12,8	12,6	13,0		
		15	14,2		14,3		15,3		16,6		14,3		14,9		14,8		13,3	14,1	15,4	14,2		
		30	13,7		14,1		13,0		18,9		17,0		15,3		16,1		15,3	15,4	16,8	15,0		
		50	12,6		14,0		14,6		20,2		15,9		16,4		17,3		15,0	15,8	17,6	16,2		
4	5	—		—		—		—		13,0		12,0		13,2		2,3	12,8	13,2	12,8			
	15	—		—		—		—		14,5		14,6		14,1		15,1	14,5	14,9	16,4			
	30	—		—		—		—		15,9		15,7		17,6		15,8	15,7	17,4	17,0			
	50	—		—		—		—		16,7		17,6		18,2		16,4	15,7	18,2	19,0			

Tabelle 10d Relative Wellenlängen λ/h in Abhängigkeit der Versuchsparameter, $x'/h = 50$

Fonte: Huber (1980).

Tabela 22 – Comprimento relativo de onda para $x'/h = 100$

R	β	Q	λ																			
			28°				30°				35°		40°		45°				60°			
			β	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12			
0,12	1	5	18,6	19,0	18,3	24,2	23,0	19,9	20,9	21,0	19,8	20,6	21,0	33,9	33,5	33,3	37,0	—	—			
		15	20,2	—	26,6	37,8	—	—	42,8	—	—	—	—	—	—	—	—	—	—			
		30	24,5	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—			
		50	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—			
	2	5	18,7	21,2	21,0	25,9	22,6	—	21,7	21,5	22,7	22,6	21,4	36,6	34,5	33,1	34,0	—	—			
		15	17,0	21,2	21,6	33,2	—	33,0	30,8	—	46,7	—	—	—	—	—	—	—	—			
		30	19,0	—	—	49,6	—	—	—	—	—	—	—	—	—	—	—	—	—			
		50	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—			
	3	5	—	24,2	22,7	29,1	25,5	—	24,8	23,6	24,0	23,7	24,3	36,9	37,3	35,9	37,0	—	—			
		15	—	—	—	35,6	37,5	—	36,6	—	—	—	—	17,5	49,7	—	—	—	—			
		30	—	—	—	—	—	—	—	—	—	—	—	33,4	15,1	—	—	—	—			
		50	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—			
4	5	—	—	—	—	28,0	29,9	27,6	26,8	26,0	25,6	29,5	41,5	44,1	42,5	—	—	—				
	15	—	—	—	11,3	—	—	46,9	—	—	—	—	54,0	—	—	—	—	—				
	30	—	—	—	10,9	—	—	—	—	—	—	—	—	—	—	—	—	—				
	50	—	—	—	11,0	—	—	—	—	—	—	—	—	—	—	—	—	—				
0,18	1	5	18,3	17,0	17,1	18,6	19,8	17,9	17,2	18,0	18,1	16,9	20,6	22,9	22,8	22,4	25,0	—	—			
		15	19,1	19,4	18,4	23,6	23,0	22,9	22,0	—	26,5	—	—	31,5	31,7	30,9	33,0	—	—			
		30	20,8	22,0	22,6	27,1	27,3	—	—	—	—	—	—	28,1	34,4	37,5	—	—	—			
		50	24,4	13,1	25,4	32,9	31,2	—	—	—	—	—	—	—	—	—	—	—	—			
	2	5	17,5	18,5	18,3	23,1	19,0	19,3	18,1	18,7	18,6	16,6	18,0	23,6	21,0	26,3	22,1	—	—			
		15	16,6	19,6	19,8	27,1	24,0	24,6	22,9	31,8	29,5	30,0	30,8	—	—	—	—	—	—			
		30	17,2	20,1	20,1	29,1	27,6	28,2	26,9	—	—	—	—	18,9	36,1	36,5	37,0	—	—			
		50	19,6	22,1	21,6	31,0	25,0	—	30,5	—	—	—	—	—	—	—	—	—	—			
	3	5	18,8	18,5	20,2	22,2	20,8	20,2	18,8	17,3	19,4	15,9	20,2	23,7	23,3	24,3	25,2	—	—			
		15	16,9	20,6	21,9	28,9	24,6	26,6	24,8	30,8	32,1	34,0	33,8	—	—	—	—	—	—			
		30	19,6	17,2	19,1	30,1	30,3	31,6	29,2	—	—	—	—	37,5	37,1	40,5	39,2	—	—			
		50	19,9	17,2	16,8	—	—	—	30,6	—	—	—	—	—	—	—	—	—	—			
4	5	—	—	—	—	19,1	20,8	20,5	18,4	18,9	19,2	22,2	26,2	25,3	27,9	29,0	—	—				
	15	—	—	—	31,0	28,0	29,7	27,3	35,2	35,2	34,4	36,2	—	—	—	—	—	—				
	30	—	—	—	34,6	32,0	—	33,8	43,1	47,5	41,8	—	—	—	—	—	—	—				
	50	—	—	—	—	—	—	32,9	—	—	—	—	—	—	—	—	—	—				
0,23	1	5	15,7	15,2	15,5	16,8	17,2	17,2	16,8	17,4	17,0	16,3	16,6	18,6	18,7	17,6	21,0	—	—			
		15	16,4	17,5	16,0	19,3	20,5	20,1	18,2	21,1	20,9	21,7	24,0	25,7	25,8	24,5	20,1	—	—			
		30	18,7	18,7	19,0	23,6	22,4	21,5	21,1	—	—	—	—	—	—	—	—	—	—			
		50	19,3	15,9	21,0	24,8	20,5	24,8	23,6	—	—	—	—	—	—	—	—	—	—			
	2	5	14,8	17,0	17,8	18,2	16,2	14,9	16,6	16,6	16,1	14,8	15,6	18,5	17,9	18,2	17,5	—	—			
		15	18,7	17,5	20,1	21,1	17,2	20,3	18,3	21,6	21,1	20,9	21,5	23,1	23,2	25,6	26,3	—	—			
		30	18,7	17,5	19,0	23,0	21,1	21,6	23,1	—	—	—	—	33,1	33,2	25,6	26,3	—	—			
		50	16,7	19,5	17,9	24,1	27,0	24,2	24,7	—	—	—	—	—	—	—	—	—	—			
	3	5	19,1	17,9	16,4	16,7	17,2	17,7	16,5	16,2	16,8	17,6	16,6	19,9	19,0	19,1	18,5	—	—			
		15	16,4	18,6	17,9	24,1	19,6	18,7	21,6	22,2	22,1	22,8	22,9	24,8	25,0	26,8	26,1	—	—			
		30	16,4	17,8	17,6	24,3	21,7	23,0	23,5	—	—	—	—	—	—	—	—	—	—			
		50	19,3	16,8	17,9	27,0	23,0	24,8	25,9	—	—	—	—	—	—	—	—	—	—			
4	5	—	—	—	—	23,0	24,8	25,9	18,1	18,4	17,0	21,2	23,2	24,2	23,1	26,1	—	—				
	15	—	—	—	—	21,0	22,7	21,0	18,7	18,8	20,1	22,0	23,2	24,2	23,1	26,1	—	—				
	30	—	—	—	—	23,2	23,9	24,9	28,4	28,2	29,7	30,0	—	—	—	—	—	—				
	50	—	—	—	—	27,5	28,6	27,5	—	—	—	—	—	—	—	—	—	—				
0,36	1	5	15,8	19,0	15,9	20,1	12,9	15,3	14,1	18,8	16,9	16,7	18,0	19,8	18,1	18,3	20,7	—	—			
		15	16,9	18,0	18,0	19,4	16,0	16,0	18,3	18,2	16,7	21,0	21,5	20,2	20,8	23,1	22,8	—	—			
		30	15,6	19,0	21,8	19,5	19,3	18,6	19,9	—	—	—	—	—	—	—	—	—	—			
		50	17,4	19,0	19,9	20,0	19,3	20,4	21,0	—	—	—	—	—	—	—	—	—	—			
	2	5	15,9	17,6	18,0	8,7	17,2	13,5	15,7	18,5	15,6	14,2	15,5	17,7	17,6	17,0	18,4	—	—			
		15	16,9	19,5	20,5	20,6	17,4	18,2	20,9	17,9	17,5	18,4	20,2	20,4	21,4	19,4	19,4	—	—			
		30	16,0	19,0	18,2	20,4	20,0	18,9	21,4	—	—	—	—	—	—	—	—	—	—			
		50	17,6	18,3	17,2	21,8	19,3	21,4	22,5	—	—	—	—	—	—	—	—	—	—			
	3	5	16,4	15,9	17,5	17,9	15,1	16,5	15,4	13,8	18,1	15,5	17,7	16,6	18,2	14,4	18,8	—	—			
		15	18,4	20,0	18,9	19,3	19,0	19,9	18,4	20,0	21,1	20,5	20,7	20,4	21,4	19,4	19,4	—	—			
		30	18,2	19,3	17,1	23,1	21,3	20,5	19,9	—	—	—	—	—	—	—	—	—	—			
		50	15,9	18,3	19,7	24,5	20,3	21,2	21,8	—	—	—	—	—	—	—	—	—	—			
4	5	—	—	—	—	16,6	15,1	16,2	18,5	18,2	16,8	16,0	19,4	18,9	18,7	21,7	—	—				
	15	—	—	—	—	19,0	18,9	16,7	21,5	21,1	22,0	21,5	21,5	21,1	22,0	21,5	—	—				
	30	—	—	—	—	20,3	20,3	22,5	23,8	23,8	23,5	25,5	—	—	—	—	—	—				
	50	—	—	—	—	20,3	23,8	24,0	—	—	—	—	—	—	—	—	—	—				

Tabelle 10e Relative Wellenlängen λ/h in Abhängigkeit der Versuchsparameter, $x'/h = 100$

Fonte: Huber (1980).

Tabela 23 – Classificação de ondas

h m	η_E m/s	G kg	β																			
			28°				30°				35°		40°		45°				60°			
			B	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12			
0,12	1	5	B	B	B	B	B	B	B	B	B	B	B/C	B	B	B	B/C	B	B	B/C	B	
		15	B/C	B	C	C	C	B/C	B/C	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	B/C	B/C	
		30	C/D	C/D	C/D	C/D	C/D	C	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	
		50	D	C/D	C/D	C/D	C/D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	
	2	5	B/C	B/C	B/C	B/C	B	B	B	B	B	A	C	C	B	B	C	C	B	C	B	
		15	B/C	C/D	C/D	C/D	C/D	C/D	C/D	C	C	C	C	C	C/D	C/D	C	C	C	C	C	
		30	C	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	C/D	C/D	
		50	C/D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	
	3	5	C	C/D	C	C	B	B	B/C	B	B	B/C	B	B/C	B/C	C	C	C	B	C	B	
		15	D	D	C/D	C/D	C/D	C/D	C	C/D	C	C	C/D	C	D	C/D	C	C	C	C	C	
		30	D	D	C/D	C/D	D	D	D	D	D	D	D	D	D	D	D	D	C/D	C/D	C/D	
		50	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	C/D	C/D	D	
	4	5	—	—	—	—	—	—	—	—	B/C	B/C	C	C	C	C	C	C	B/C	B/C	B/C	
		15	—	—	—	—	—	C/D	C/D	C/D	C/D	C/D	C	C	C/D	D	D	D	C/D	C/D	C/D	
		30	—	—	—	—	—	D	D	D	D	D	D	D	D	D	D	D	C/D	C/D	C/D	
		50	—	—	—	—	—	D	D	D	D	D	C/D	C/D	C/D	C/D	D	D	D	D	D	
0,18	1	5	B	B	B	B	B	B	B	A	B	A/B	A/B	A/B	A/B	A/B	A/B	A/B	A/B	A		
		15	B	B	B	B	B	B	B	B	B	B/C	B/C	C	C	B	B/C	B	B/C	B/C		
		30	B/C	C	B/C	B/C	C	C	C	C	C	C	C	C	C	C	C/D	C/D	C/D	C	C	
		50	C	C	C	C	C/D	C/D	C	C	C	C	C	C	C/D	C/D	C/D	C/D	C/D	C/D	C/D	
	2	5	B/C	B	B	B	A/B	A	B	A	A/B	B	B	B	A/B	B	B	C	B	A/B	A/B	
		15	B/C	B	B	B	B	B	B	B	B	B/C	B/C	C	C	B	C	C	B	B	B	
		30	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	C	C/D	C	C	C	B/C	B/C	B/C	
		50	C	B/C	C	C	C	C/D	C/D	C	C	C	C	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	
	3	5	B/C	B	B	B	A/B	A	A/B	A	A/B	B	B	B	B	B	B	B	B	B	B	
		15	C	C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	C	C	C/D	C/D	C/D	C/D	C/D	C/D	
		30	C/D	C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	C	C	C/D	C/D	C/D	C/D	C/D	C/D	
		50	C/D	C/D	C	C	C/D	C/D	C	C	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	C/D	
	4	5	—	—	—	—	—	—	—	—	B	A/B	B/C	B	B	B	B	B	B	A/B	A/B	
		15	—	—	—	—	—	B/C	B/C	C	C	C	C	C	C	C/D	C/D	C/D	C	C	C	
		30	—	—	—	—	—	C	C	C	C	C	C	C	C	C/D	C/D	C/D	C/D	C/D	C/D	
		50	—	—	—	—	—	C/D	D	D	D	D	C/D	C/D	C/D	C/D	D	D	D	D	D	
0,27	1	5	B	A	A/B	A/B	A	A	A	A	A	A	A	A/B	A/B	A	A	A	A	A		
		15	B	B	B	B	A/B	A/B	B	B	B	B	B	A/B	A/B	B	B	A/B	A/B	A/B		
		30	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
		50	B/C	B	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	B/C	C	C	B/C	B	B/C	B/C	B/C	B/C	
	2	5	B/C	A/B	A	A	A	A	A	A	A	A	A	A	A	A/B	A	A	A	A	A	
		15	B/C	B	B	B	A/B	A/B	B	B	B	B	B	B	A/B	B	B	B	B	B	B	
		30	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
		50	B	B/C	B	B	B	C	B	B	B	B	B	B	B	B	C	C	B/C	B/C	B/C	
	3	5	B	A/B	A/B	A/B	A	A	A	A	A	A	A	A	A/B	A/B	A/B	A/B	A/B	A/B	A/B	
		15	B/C	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
		30	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
		50	B	B	B	B	B	B/C	B/C	B/C	B/C	B/C	B/C	B/C	C	B/C	B/C	B/C	B/C	B/C	B/C	
	4	5	—	—	—	—	—	—	—	—	A	A	A	A	A	A	A	A	A	A	A	
		15	—	—	—	—	—	—	—	—	B	B	B	B	B	B	B	B	B	B	B	
		30	—	—	—	—	—	—	—	—	B	B	B	B	B	B	B	B	B	B	B	
		50	—	—	—	—	—	—	—	—	B	B/C	C	C	C	B/C	C	B/C	C	B/C	B/C	
0,36	1	5	B	A/B	A/B	A/B	A	A	A	A	A	A	A	A	A	A	A	A	A	A		
		15	B	B	B	B	A/B	A/B	B	B	B	B	B	A/B	A/B	B	B	A/B	A/B	A/B		
		30	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
		50	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
	2	5	B	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	
		15	B	A/B	A/B	A/B	A/B	A/B	B	B	B	B	B	B	B	B	B	B	B	B	B	
		30	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
		50	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
	3	5	A/B	A/B	A/B	A/B	A	A	A	A	A	A	A	A	A/B	A	A	A	A	A	A	
		15	B	A/B	A/B	A/B	A/B	A/B	B	B	B	B	B	B	A/B	A	A/B	A/B	A/B	A/B	A/B	
		30	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
		50	B	B/C	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	
	4	5	—	—	—	—	—	—	—	—	A	A	A	A	A	A	A	A	A	A	A	
		15	—	—	—	—	—	—	—	—	A	A/B	B	B	B	B	B	B	B	B	B	
		30	—	—	—	—	—	—	—	—	B	B	B	B	B	B	B	B	B	B	B	
		50	—	—	—	—	—	—	—	—	B	B	B	B	B	B	B	B	B	B/C	B/C	

Tabelle 12 Wellentypen in Abhängigkeit der Versuchsparameter

Fonte: Huber (1980).

Tabela 24 – Períodos relativos de onda para $x'/h = 5$

n	V _E m/s	G kg	α															
			28°				30°				35°				45°			
			β		1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:4	1:0	1:4	1:8	1:12
0,12	1	5		3,78			3,88		6,31		9,00		6,22		4,90		5,86	
		15		4,78			4,82		5,10		7,43		6,34		—		7,50	
		30		4,26					4,36		7,07		—		—		6,82	
		50		—					—		5,68		—		—		—	
	2	5		7,38			6,13		7,31		8,87		6,82		—		5,86	
		15		4,70			4,64		4,83		9,61		—		6,05		5,45	
		30		4,66					—		5,47		—		—		—	
		50		—					—		9,75		—		—		—	
	3	5		—			6,62		8,21		7,48		6,25		—		5,99	
		15		—					—		8,27		—		—		6,40	
		30		—					—		—		—		—		—	
		50		—					—		—		—		—		—	
	4	5		—			—		—		—		6,32		6,68		6,08	
		15		—			—		—		7,48		—		—		7,34	
		30		—			—		—		9,27		—		—		—	
		50		—			—		—		8,62		—		—		—	
0,18	1	5		7,14			6,14		6,92		7,32		6,43		6,37		5,70	
		15		4,06			5,34		5,85		8,11		6,56		6,86		6,18	
		30		5,04			5,12		5,82		7,72		4,03		—		5,13	
		50		5,02			5,08		5,16		5,85		6,47		—		—	
	2	5		6,73			6,18		6,11		8,51		6,57		6,23		6,00	
		15		3,62			5,34		5,89		8,09		8,11		6,74		6,47	
		30		3,21			5,23		5,41		7,08		7,43		5,96		5,12	
		50		4,75			4,85		4,88		6,53		4,61		—		4,39	
	3	5		8,26			7,10		7,87		9,47		6,67		6,50		5,79	
		15		4,59			4,63		4,16		9,28		8,03		6,51		6,61	
		30		5,20			4,97		4,79		9,65		7,47		7,51		6,34	
		50		4,83			4,83		5,34		—		—		—		3,79	
	4	5		—			—		—		—		6,15		5,70		5,64	
		15		—			—		—		10,53		6,58		7,21		6,43	
		30		—			—		—		12,84		7,74		—		6,75	
		50		—			—		—		—		7,33		—		4,81	
0,27	1	5		7,10			6,00		5,02		7,63		6,20		5,21		5,52	
		15		5,53			5,96		5,85		6,45		7,07		5,83		6,15	
		30		4,84			6,06		3,42		7,73		6,98		6,23		6,19	
		50		3,70			5,65		3,84		7,20		5,57		6,86		5,81	
	2	5		6,81			5,79		5,78		7,17		7,94		6,46		5,61	
		15		4,68			5,84		5,42		6,98		6,22		6,34		6,87	
		30		4,70			5,78		5,34		7,67		5,98		7,17		7,05	
		50		5,65			5,37		5,76		8,77		6,06		5,86		7,14	
	3	5		6,42			6,09		7,21		8,52		5,26		4,99		7,38	
		15		3,65			7,45		7,87		9,65		6,41		5,93		7,30	
		30		5,19			4,97		5,62		10,66		6,47		6,73		7,27	
		50		5,56			4,74		5,31		10,62		6,97		6,55		7,87	
	4	5		—			—		—		—		7,28		5,28		7,22	
		15		—			—		—		—		6,08		6,26		6,62	
		30		—			—		—		—		6,65		6,55		7,38	
		50		—			—		—		—		7,09		7,47		8,42	
0,36	1	5		5,69			5,60		6,08		6,02		6,14		5,82		6,41	
		15		5,36			5,47		5,82		6,38		7,49		6,20		6,69	
		30		6,36			5,65		4,59		7,21		6,07		5,97		7,59	
		50		5,58			5,63		5,55		7,84		6,17		6,52		7,09	
	2	5		6,26			5,38		5,37		5,12		6,61		5,86		5,99	
		15		5,58			5,64		5,28		9,77		7,33		5,86		7,13	
		30		5,81			5,66		5,46		10,25		6,86		5,80		7,06	
		50		5,29			5,38		5,45		11,25		6,18		5,67		7,70	
	3	5		7,03			6,87		5,98		7,91		6,10		5,34		6,87	
		15		5,61			5,08		6,80		9,67		5,85		5,51		7,10	
		30		5,21			5,01		5,29		9,21		7,42		5,61		7,74	
		50		5,84			5,39		5,22		10,15		6,45		6,64		7,61	
	4	5		—			—		—		—		5,74		5,47		6,64	
		15		—			—		—		—		5,67		6,06		8,06	
		30		—			—		—		—		6,51		6,41		7,40	
		50		—			—		—		—		7,20		5,91		6,89	

Tabelle 15a Dimensionslose Wellenperioden $T_1\sqrt{g/h}$ in Abhängigkeit der Versuchsparameter, $x'/h = 5$

Fonte: Huber (1980).

Tabela 25 – Períodos relativos de onda para $x'/h = 10$

h	v _E	G	Q																			
			28°				30°				35°		40°		45°				60°			
			β	1:0	1:4		1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12
0,12	1	5	7,54		7,64		8,04		11,18		8,33		6,72		7,79		7,68	7,99	7,56	9,30		
		15	6,69		6,80		7,14		10,08		9,09				10,45		7,63	7,68	7,81	10,69		
		30	6,29				6,46		10,13						10,11							
		50							8,60													
	2	5	9,05		8,07		9,26		11,26		8,93				7,88		7,27	7,02	7,04	7,35		
		15	6,16		6,53		6,49		12,66				8,72		7,90		8,21	7,98	13,25	7,97		
		30	6,21						8,16									8,48				
		50							13,62									4,17				
	3	5	—		8,82		10,31		10,10		8,52				8,27		7,11	7,26	6,82	7,27		
		15	—						11,21		11,33				9,30		8,67	8,18	10,05	8,13		
		30	—														1,74	9,08				
		50	—														1,56	2,70				
4	5	—		—		—				8,84		9,37		8,41		7,50	7,57	7,73	11,55			
	15	—		—		—		7,91						10,49		6,33	9,64	9,63				
	30	—		—		—		9,18								13,50						
	50	—		—		—		8,70									9,53					
0,18	1	5	8,62		7,73		8,49		9,08		8,23		8,04		7,36		7,85	7,26	—	8,75		
		15	5,80		7,18		7,59		10,28		8,71		8,93		8,18		8,04	7,95	8,31	9,28		
		30	6,94		7,11		7,86		10,11		6,14				7,42		8,29	8,01	8,21	10,43		
		50	7,06		7,20		7,32		8,47		9,04						7,72	12,89	7,53	—		
	2	5	8,41		7,95		7,84		10,52		8,33		8,08		7,77		7,47	7,87	8,82	6,73		
		15	7,19		7,19		7,73		10,51		10,28		8,90		8,57		7,82	7,90	21,69	7,75		
		30	6,75		6,76		7,25		9,50		9,88		8,40		7,41		8,17	8,04	7,89	8,51		
		50	9,05		6,80		6,77		9,05		6,65				6,89		8,02	8,67	7,16	7,78		
	3	5	9,93		8,88		9,70		11,49		8,60		8,44		7,65		8,24	8,29	9,38	6,92		
		15	6,25		6,46		6,06		11,85		10,27		8,93		8,88		7,44	8,38	7,55	7,88		
		30	6,65		6,50		6,53		12,29		9,99		10,16		8,78		8,44	9,70	7,80	9,23		
		50	6,34		6,32		6,84								5,95		8,24	9,47	8,50	8,58		
	4	5	—		—		—				7,90		7,63		7,58		7,66	7,83	7,56	9,34		
		15	—		—		—		13,30		8,99		9,77		8,85		8,32	8,02	8,43	9,92		
		30	—		—		—		15,51		10,68				9,50		8,91	8,67	8,97	11,40		
		50	—		—		—				9,98				7,29		10,02	10,41	9,55	—		
0,27	1	5	8,60		7,40		6,81		9,12		7,87		6,88		7,09		7,68	7,87	8,19	8,10		
		15	7,11		7,64		7,56		8,18		8,88		7,74		7,90		7,34	7,47	7,75	8,58		
		30	6,38		7,32		7,19		9,87		8,96		8,21		8,20		8,11	8,40	8,04	9,36		
		50	7,44		7,08		7,57		9,33		7,42		9,09		7,96		8,29	8,70	8,49	6,98		
	2	5	8,03		7,36		7,46		8,82		9,33		7,87		7,19		7,54	7,97	7,92	7,63		
		15	6,44		7,49		7,26		8,89		7,90		8,26		8,67		7,41	8,37	8,25	7,88		
		30	6,46		7,42		7,11		9,73		7,91		9,13		9,11		8,09	8,24	8,40	7,64		
		50	7,21		7,00		7,43		10,90		8,04		8,10		9,37		11,14	8,40	8,43	7,06		
	3	5	8,27		7,86		9,61		10,26		6,94		6,66		8,87		9,04	7,49	6,94	8,69		
		15	7,24		9,22		9,55		11,83		8,26		7,77		9,31		7,43	7,96	7,97	8,24		
		30	6,76		6,54		7,39		12,74		8,46		8,79		9,44		7,52	8,47	8,07	7,55		
		50	6,93		6,29		6,95		12,93		9,04		8,88		10,16		8,12	8,35	8,24	8,77		
	4	5	—		—		—				9,45		6,92		8,90		7,89	7,92	8,26	9,20		
		15	—		—		—				8,11		8,25		8,54		9,14	8,46	7,97	9,94		
		30	—		—		—				8,74		8,70		9,92		8,78	8,07	8,27	10,53		
		50	—		—		—				9,49		9,93		10,80		8,67	8,41	10,34	6,75		
0,36	1	5	7,19		6,95		7,61		7,84		7,37		7,29		7,71		6,92	7,13	7,89	7,82		
		15	6,94		7,23		7,54		8,22		8,87		7,70		10,14		7,36	7,41	8,14	8,24		
		30	7,75		7,20		6,44		9,04		7,78		7,70		9,19		8,03	7,92	8,82	9,54		
		50	7,24		7,47		7,42		9,66		7,91		8,43		9,00		8,17	8,20	10,13	9,63		
	2	5	7,67		7,04		7,07		9,82		8,17		7,17		7,47		7,01	7,44	7,41	9,00		
		15	7,18		7,68		7,35		11,48		8,89		7,52		9,09		9,92	7,29	7,43	6,98		
		30	7,42		7,42		7,18		11,89		8,64		7,54		9,01		8,09	7,30	7,65	7,27		
		50	7,06		7,14		7,09		12,96		7,93		7,69		9,27		8,13	7,30	8,44	8,16		
	3	5	8,52		7,96		7,63		9,48		7,60		6,93		8,27		7,24	7,86	7,76	6,87		
		15	7,38		6,94		6,53		11,32		7,50		7,35		8,75		7,19	7,66	8,75	7,03		
		30	6,98		6,78		6,93		11,27		9,30		7,44		9,58		7,32	7,00	10,01	7,23		
		50	7,12		7,16		7,04		12,33		8,38		8,63		9,58		7,89	8,20	9,47	8,27		
	4	5	—		—		—				7,32		6,97		8,13		5,55	6,98	7,54	7,70		
		15	—		—		—				7,53		7,82		9,56		8,11	7,53	8,58	8,70		
		30	—		—		—				8,45		8,23		9,44		7,40	7,54	9,83	9,49		
		50	—		—		—				9,12		8,07		9,06		7,96	8,25	9,44	9,39		

Tabelle 15b

Dimensionslose Wellenperioden $T_i\sqrt{g/h}$ in Abhängigkeit der Versuchsparameter, $x'/h = 10$

Fonte: Huber (1980).

Tabela 26 – Períodos relativos de onda para $x'/h = 20$

n	α_E	G	τ																			
			28°				30°				35°		40°		45°				60°			
			β	1:0	1:4		1:0	1:4	1:8	1:12	1:0	1:4	1:0		1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12
0.12	1	5	9.89				9.59		10.24		13.86		11.30		9.12		10.38		10.22	10.30	10.05	12.28
		15	9.17				9.53		9.97		13.75		12.34				10.47		11.49	11.58	14.89	
		30	9.23						9.56		14.41						10.47					
		50									13.20											
	2	5	11.21				10.70		11.72		14.21		11.42				10.57		9.63	9.82	9.85	10.03
		15	8.35				9.19		9.13		10.70				12.54		11.53		12.36	11.92	15.09	11.82
		30	8.12								11.98									13.21		
		50																				
	3	5					11.89		12.94		13.66		11.44				11.32		10.03	10.21	9.76	10.29
		15									15.39		15.35				13.21		12.83	12.36	14.11	12.28
		30																		14.18		
		50																				
	4	5											12.18		12.98		11.87		10.79	10.79	10.85	15.02
		15															15.10		9.19	14.41	14.31	
		30																	19.12			
		50																		9.26		
0.18	1	5	10.52				9.71		10.42		11.13		10.56		10.19		9.43		10.01	9.52		14.28
		15	8.22				9.63		9.89		12.92		11.43		11.65		10.84		10.78	10.79	11.06	12.26
		30	9.50				9.76		10.61		13.24		9.25				10.54		11.99	11.74	11.96	14.72
		50	10.03				10.24		10.37		12.23		12.77						11.87	16.27	11.60	
	2	5	10.39				9.91		10.06		13.20		10.59		10.41		9.93		9.83	10.11	11.05	8.97
		15	9.26				9.62		10.16		13.67		13.01		11.89		11.33		10.74	10.08	22.59	10.68
		30	8.88				9.14		10.13		12.91		12.96		11.66		10.62		11.90	11.30	11.43	12.09
		50	10.93				9.60		9.40		12.62		9.31				10.43		12.38	12.67	11.32	11.84
	3	5	12.00				11.05		11.97		13.81		11.21		10.86		9.91		10.19	10.63	11.05	9.52
		15	8.30				8.96		8.81		15.07		13.07		12.09		11.08		10.35	11.23	10.53	10.81
		30	8.48				8.61		8.87		15.66		12.59		12.78		12.22		12.01	13.46	12.63	13.01
		50	8.23				8.36		8.73								9.31		12.35	13.61	12.90	12.83
	4	5											10.13		10.24		10.11		9.91	10.11	9.98	12.04
		15											12.47		12.33		12.21		11.51	11.09	11.96	13.44
		30											14.60				13.40		12.91	12.72	12.92	13.61
		50											13.61				10.98		12.67	15.38	14.00	
0.27	1	5	10.31				9.30		9.23		11.00		9.94		9.04		9.04		9.73	9.84	10.07	9.98
		15	9.08				9.83		9.78		10.49		12.23		10.13		10.03		9.56	9.80	9.91	11.09
		30	8.70				10.16		9.55		12.53		11.61		10.76		10.67		10.69	10.88	10.59	12.16
		50	9.85				8.90		10.16		12.28		9.93		11.98		10.78		11.33	11.82	11.47	9.31
	2	5	9.66				9.43		9.65		10.85		10.32		9.58		9.16		9.53	10.07	9.89	9.51
		15	8.88				9.63		9.73		11.37		9.58		10.66		10.93		9.63	10.67	10.38	10.03
		30	8.71				9.54		9.47		12.35		10.52		11.61		11.84		10.66	10.79	10.91	10.98
		50	9.26				9.39		9.60		13.46		10.60		10.98		12.25		15.10	11.44	11.49	8.90
	3	5	10.31				10.02		10.10		12.19		9.12		8.81		10.67		10.74	9.92	9.12	12.04
		15	9.32				11.28		11.42		14.38		10.59		10.11		11.81		9.88	10.29	10.28	11.08
		30	8.72						9.56		13.19		11.03		11.20		12.17		10.27	11.11	10.86	9.77
		50	8.78				8.42		9.17				11.96		11.73		11.09		11.10	11.32	11.44	8.86
	4	5											12.40		9.16		10.97		10.06	10.12	10.25	11.62
		15											11.58		11.00		11.04		11.23	10.67	10.49	11.52
		30											11.60		11.60		12.82		11.53	11.03	11.33	13.66
		50											12.90		11.30		12.60		11.04	11.74	13.79	13.28
0.36	1	5	9.19				9.66		9.31		10.52		8.80		9.07		9.28		9.29	9.21	9.83	9.97
		15	9.13				9.47		9.76		10.56		10.44		9.60		11.84		9.73	9.63	10.31	10.64
		30	9.53				9.75		9.04		11.35		10.06		9.92		11.62		10.18	10.14	11.31	12.04
		50	9.29				9.71		9.93		11.86		10.12		10.83		11.44		10.73	10.67	12.73	12.24
	2	5	9.49				9.20		9.30		10.52		10.11		8.68		9.32		9.32	9.50	9.02	9.50
		15	9.27				9.72		9.69		13.47		10.75		9.76		11.56		10.70	9.43	9.38	9.31
		30	9.32				9.76		9.45		13.82		10.99		9.86		11.50		10.13	9.43	9.90	9.79
		50	9.22				9.40		9.21		14.96		10.25		10.28		12.31		10.62	9.88	10.72	10.37
	3	5	10.30				9.76		9.74		11.43		9.30		8.91		9.96		9.90	9.30	9.56	8.96
		15	9.74				9.58		10.71		13.13		9.84		9.86		10.89		9.43	9.88	11.01	9.38
		30	9.24				9.23		9.09		13.72		11.74		10.05		11.81		10.00	9.61	12.23	9.73
		50	9.10				9.41		9.30		14.89		10.78		11.10		12.03		10.22	10.68	12.10	10.87
	4	5											8.40		8.76		10.01		4.25	8.99	9.57	8.63
		15											9.88		10.16		11.35		10.44	9.85	10.78	13.36
		30											10.88		10.71		12.05		10.08	10.12	12.35	11.96
		50											11.53		10.97		11.99		10.66	10.87	12.18	12.40

Tabelle 15c Dimensionslose Wellenperioden $T_1\sqrt{g/h}$ in Abhängigkeit der Versuchsparameter, $\alpha'/h = 20$

Fonte: Huber (1980).

Tabela 27 – Períodos relativos de onda para $x'/h = 50$

h m	θ_E min	G kg	α																			
			28°				30°				35°		40°		45°				60°			
			β	1:0	1:4	1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12		
0,12	1	5	14,01			14,20		14,10		18,48		16,47		13,92		15,09		15,07	14,63	14,74	17,27	
		15	14,05			15,30		15,51		20,63		19,17		—		22,24		19,74	19,68	19,65	27,33	
		30	15,36			—		16,05		23,14		—		—		24,52		—	—	—	—	
		50	—			—		—		23,06		—		—		—		—	—	—	—	
	2	5	14,85			15,56		15,99		19,66		16,32		—		15,57		14,09	15,32	15,38	14,99	
		15	12,29			14,39		14,32		23,97		—		20,37		19,15		21,09	22,28	20,63	20,13	
		30	11,65			—		—		20,05		—		—		—		—	23,97	—	—	
		50	—			—		—		29,76		—		—		—		—	—	—	—	
	3	5	—			17,46		17,48		20,20		17,51		—		17,21		15,83	16,10	15,69	16,25	
		15	—			—		—		23,21		23,72		—		22,10		21,53	21,31	22,08	21,45	
		30	—			—		—		—		—		—		—		—	25,52	—	—	
		50	—			—		—		—		—		—		—		—	—	—	—	
	4	5	—			—		—		—		18,79		19,94		18,42		17,42	17,24	17,17	21,31	
		15	—			—		—		9,11		—		—		26,31		13,95	24,71	26,21	—	
		30	—			—		—		9,10		—		—		—		20,53	—	—	—	
		50	—			—		—		8,86		—		—		—		—	8,87	—	—	
0,18	1	5	13,49			13,28		13,68		14,74		14,68		13,92		13,16		13,83	13,55	13,27	15,76	
		15	13,15			13,97		13,89		17,63		16,48		16,54		15,78		16,07	16,00	16,04	17,62	
		30	14,35			14,97		15,78		19,03		14,49		—		16,95		19,35	19,30	19,18	21,29	
		50	15,98			16,34		16,46		19,92		19,86		—		—		20,44	22,07	20,57	—	
	2	5	13,95			14,13		13,98		17,70		14,73		14,50		13,87		14,06	14,15	12,63	13,17	
		15	12,81			13,99		14,35		19,34		17,91		17,33		16,46		16,30	13,92	23,82	16,06	
		30	12,64			14,28		14,22		19,28		19,04		18,25		17,11		19,44	17,74	18,64	19,26	
		50	12,99			14,82		14,50		19,40		15,17		—		17,94		21,38	20,91	19,91	20,39	
	3	5	15,34			14,60		15,80		17,77		15,56		15,23		14,13		13,62	14,74	13,35	14,33	
		15	12,31			14,26		14,42		20,58		18,01		18,14		17,57		15,94	16,52	16,36	16,76	
		30	11,76			12,53		13,31		21,57		20,16		20,58		19,01		19,13	20,78	20,64	20,92	
		50	11,54			12,26		12,12		—		—		—		16,81		21,08	21,96	22,35	21,83	
	4	5	—			—		—		—		14,44		14,98		14,87		12,94	14,23	14,24	16,76	
		15	—			—		—		22,71		18,82		20,00		18,54		17,67	17,02	18,44	19,92	
		30	—			—		—		25,19		22,25		—		21,22		21,08	21,10	21,01	23,58	
		50	—			—		—		—		20,59		—		18,79		24,28	26,19	23,51	—	
0,27	1	5	13,11			12,30		13,79		13,88		13,58		12,88		12,81		13,39	13,29	13,12	13,24	
		15	12,64			12,60		13,72		14,54		15,47		14,62		13,85		13,71	13,88	13,64	15,62	
		30	13,24			14,17		13,90		17,23		16,23		15,48		15,34		15,27	15,36	15,50	17,12	
		50	14,10			12,06		13,00		17,45		14,28		17,34		16,21		17,23	17,59	16,98	13,61	
	2	5	12,51			13,06		13,54		14,34		14,69		12,41		12,80		13,00	13,12	13,28	12,49	
		15	13,36			13,33		14,38		15,77		13,63		15,07		14,88		13,84	14,09	14,12	13,70	
		30	13,11			13,21		13,83		16,93		15,34		15,95		16,82		15,52	15,41	15,40	15,28	
		50	12,77			13,89		13,64		18,00		16,84		16,57		17,44		22,47	17,20	17,30	12,11	
	3	5	14,60			13,75		13,77		15,77		13,09		12,93		13,66		13,50	13,08	13,07	18,76	
		15	12,98			14,32		14,57		18,73		14,77		14,38		16,32		14,40	14,41	14,39	16,57	
		30	12,34			12,88		13,51		19,16		15,78		16,46		17,17		15,48	15,89	16,06	13,59	
		50	11,80			12,19		13,12		—		16,76		17,17		18,30		16,78	16,96	17,66	12,06	
	4	5	—			—		—		—		17,51		13,16		14,34		13,87	13,98	13,83	16,07	
		15	—			—		—		—		15,45		16,31		15,55		14,74	14,50	14,96	16,82	
		30	—			—		—		—		17,68		16,84		18,06		16,53	16,65	16,45	18,59	
		50	—			—		—		—		18,58		19,49		19,58		18,60	18,27	20,22	19,96	
0,36	1	5	12,48			14,01		12,77		14,72		10,74		12,13		11,84		13,64	12,98	13,15	13,88	
		15	12,90			13,57		13,73		14,60		13,70		13,91		14,34		14,25	13,55	14,09	14,95	
		30	12,81			14,12		14,14		15,10		14,23		12,86		15,40		16,00	14,10	15,72	16,37	
		50	13,11			14,08		14,38		15,58		14,46		15,24		15,71		15,10	15,13	17,23	16,73	
	2	5	12,51			13,21		13,36		7,72		13,51		11,21		12,49		13,45	12,62	11,71	13,21	
		15	12,96			14,10		14,46		16,70		13,98		13,77		15,92		13,26	13,26	13,09	13,77	
		30	12,63			14,06		13,58		16,92		13,03		14,02		15,86		13,84	13,25	13,92	14,54	
		50	13,24			13,70		13,03		18,01		14,51		15,28		16,72		15,02	14,73	14,72	14,41	
	3	5	13,37			12,74		13,45		14,55		12,20		12,47		12,75		11,80	12,78	12,59	12,94	
		15	11,96			13,98		14,45		16,06		14,13		14,40		14,39		12,95	13,83	14,92	13,87	
		30	13,47			13,85		12,99		17,76		15,96		14,79		15,58		14,54	14,60	15,93	14,45	
		50	12,46			13,73		14,13		19,16		15,31		15,56		16,25		14,38	13,15	16,72	15,58	
	4	5	—			—		—		—		12,87		11,94		13,08		5,41	12,54	13,10	12,87	
		15	—			—		—		—		14,18		14,27		14,04		14,56	14,05	14,51	15,79	
		30	—			—		—		—		15,45		15,02		16,63		15,16	14,94	16,55	16,29	
		50	—			—		—		—		15,56		16,51		17,18		15,57	15,66	17,07	17,85	

Tabela 28 – Períodos relativos de onda para $x'/h = 100$

m	v _E m/s	G kg	α																					
			28°				30°				35°		40°		45°				60°					
			β	1:0	1:4		1:0	1:4	1:8	1:12	1:0	1:4	1:0	1:0	1:4	1:8	1:12	1:0	1:4	1:8	1:12			
0,12	1	5	18,22				18,60			17,95			22,94			22,02	19,10		20,09		20,16	19,06	19,71	22,07
		15	19,30				21,72			21,86			28,05			26,72	—		30,91		29,74	29,56	29,21	32,41
		30	22,67							23,75			33,01			—	—		36,06		—	—	—	—
		50	—							—			35,25			—	—		—		—	—	—	—
	2	5	18,39				20,62			20,24			24,71			21,70	—		20,85		18,82	21,44	21,54	20,43
		15	16,32				20,08			20,14			31,60			—	29,35		27,95		31,64	30,29	29,85	29,76
		30	15,28							—			29,50			—	—		—		—	37,49	—	—
		50	—							—			41,70			—	—		—		—	—	—	—
	3	5	—				23,21			21,95			27,22			24,14			23,58		22,34	22,70	22,46	22,95
		15	—							—			31,66			32,94			32,10		31,85	32,17	30,98	32,00
		30	—							—			—			—	—		—		—	39,82	—	—
		50	—							—			—			—	—		—		—	—	—	—
	4	5	—				—			—			—			26,04	27,73		25,80		25,02	24,58	24,15	27,69
		15	—				—			—			9,71			—	—		34,89		23,50	37,11	35,98	—
		30	—				—			—			9,02			—	—		—		43,39	—	—	—
		50	—				—			—			8,95			—	—		—		—	8,60	—	—
0,18	1	5	16,37				16,85			16,79			18,16			19,00	17,54		16,89		17,66	17,77	—	20,04
		15	18,67				19,21			18,01			22,25			21,54	21,52		20,92		21,65	21,58	21,39	23,44
		30	19,76				20,84			21,31			26,92			25,10	—		24,28		27,92	28,20	27,56	29,16
		50	22,66				13,94			23,34			28,74			27,66	—		—		32,30	27,71	31,74	—
	2	5	17,31				17,95			17,93			22,10			18,62	18,78		17,80		18,38	18,21	16,18	17,56
		15	16,36				19,24			19,10			25,19			22,63	23,04		21,79		22,23	17,77	24,79	21,07
		30	16,60				19,11			19,00			26,09			25,02	25,48		24,62		28,23	24,94	26,98	27,59
		50	17,36				20,60			20,13			26,92			22,18	—		26,95		32,48	30,54	30,94	31,30
	3	5	18,49				18,26			19,31			21,46			20,11	19,59		18,44		16,96	18,89	15,42	19,43
		15	16,51				19,85			20,93			26,18			22,96	24,74		23,42		22,09	22,13	22,83	23,08
		30	15,03				18,45			18,08			27,40			27,27	27,91		26,44		27,21	28,84	29,46	29,71
		50	15,04				15,98			15,52			—			—	—		26,39		31,58	31,53	33,87	32,66
	4	5	—				—			—			—			18,64	20,10		19,92		18,04	18,40	18,60	21,38
		15	—				—			—			28,62			25,95	27,12		25,44		24,44	23,52	23,86	26,88
		30	—				—			—			31,02			30,27	—		30,00		30,53	30,95	30,24	31,74
		50	—				—			—			—			28,27	—		28,22		35,55	38,98	34,72	—
0,27	1	5	15,71				15,20			16,69			16,65			16,92	16,91		16,55		17,13	16,73	16,08	16,40
		15	16,19				17,37			17,72			18,58			19,58	19,21		17,75		17,96	18,15	17,27	20,24
		30	18,07				18,28			18,47			21,98			21,14	20,29		20,11		20,14	19,95	20,51	22,46
		50	18,64				15,22			20,14			22,90			19,02	23,00		22,11		23,68	23,46	22,86	17,99
	2	5	15,05				16,69			17,49			17,64			16,08	15,03		16,35		16,48	19,95	16,40	15,46
		15	18,24				17,03			19,30			20,16			16,99	19,49		16,76		18,04	17,04	17,79	17,24
		30	17,90				16,87			18,47			21,51			20,36	20,38		21,89		20,57	20,18	19,98	20,54
		50	16,27				18,69			17,35			22,25			25,55	22,53		22,91		30,48	23,42	23,58	24,13
	3	5	18,59				17,58			16,74			19,06			17,06	17,33		16,45		16,05	16,63	17,18	16,39
		15	16,75				18,24			17,62			22,80			19,05	18,66		20,74		19,15	18,60	18,56	18,14
		30	16,07				17,36			17,55			22,93			20,42	21,51		22,38		21,13	20,99	21,61	21,61
		50	14,92				16,26			17,27			21,66			22,90	23,70		23,70		22,94	23,00	24,52	24,02
	4	5	—				—			—			—			22,63	17,35		17,70		17,69	17,86	16,92	20,52
		15	—				—			—			—			20,27	21,52		20,15		18,12	18,30	19,53	21,02
		30	—				—			—			—			22,05	22,36		23,30		21,71	22,72	21,97	23,90
		50	—				—			—			—			25,34	26,05		25,17		25,82	25,52	26,94	27,09
0,36	1	5	15,78				18,36			15,96			19,21			17,20	15,08		14,24		18,19	16,74	16,18	17,59
		15	16,77				17,57			17,79			18,76			15,77	16,01		16,97		18,93	17,64	17,86	19,36
		30	15,49				18,52			19,84			18,76			18,31	17,91		19,06		17,82	18,06	20,17	20,71
		50	17,02				18,45			19,51			19,12			18,61	18,55		19,97		19,43	19,82	21,63	21,31
	2	5	15,44				17,22			17,58			8,73			16,72	13,62		15,59		17,78	15,38	14,26	15,51
		15	16,83				18,96			19,58			19,54			17,00	17,77		20,26		17,38	17,17	16,83	18,25
		30	16,04				18,35			17,87			19,72			18,79	18,27		20,24		17,44	17,14	18,00	19,57
		50	17,26				17,91			16,93			20,78			18,67	20,56		21,14		19,51	19,93	18,70	18,63
	3	5	16,24				15,83			17,16			17,49			15,10	16,13		15,34		13,82	19,26	15,50	17,11
		15	18,49				19,56			18,12			18,67			18,52	16,24		17,89		16,20	17,83	18,78	18,36
		30	17,90				18,95			17,02			21,70			20,00	19,86		19,26		18,93	20,04	19,45	19,46
		50	15,72				17,94			19,08			23,23			19,54	20,11		20,48		16,62	19,73	21,37	20,49
	4	5	—				—			—			—			16,43	15,03		16,06		16,58	16,14	16,62	16,09
		15	—				—			—			—			18,58	18,47		16,43		18,74	18,39	18,19	20,41
		30	—				—			—			—			19,73	19,42		21,19		20,62	20,85	20,89	20,60
		50	—				—			—			—			19,50	22,32		22,66		20,79	20,65	22,04	23,49

Tabelle 15e Dimensionslose Wellenperioden $T_1 \sqrt{g/h}$ in Abhängigkeit der Versuchsparameter, $x'/h = 100$

Fonte: Huber (1980).

APÊNDICE A – ALGORITMO DA RNA

O Algoritmo da RNA ARTMAP FUZZY apresentado a seguir, tem como base os trabalhos de Carpenter *et al.* (1982); Carpenter; Ross (1995); Carpenter; Grossberg; Iizuka (1992) e Müller (2018).

Etapas do algoritmo da RNA ARTMAP Fuzzy:

I. Escolha dos parâmetros:

Parâmetro de escolha da rede ($\alpha > 0$): α ;

Taxa de treinamento $[0, 1]$: β ;

Parâmetros de vigilância dos módulos ARTa, ARTb, InterART e Previsão, respectivamente $(0, 1]$:

$\rho_a, \rho_b, \rho_{ab}$ e ρ_d ;

Incremento do parâmetro de vigilância: ε .

II. Tratamento dos dados de entrada

Leitura dos vetores de entrada e saída, respectivamente:

$I_a = [a_1, a_2, a_3, \dots, a_n]$ e $I_b = [b_1, b_2, b_3, \dots, b_n]$.

Normalização dos vetores de entrada e saída, respectivamente:

$\bar{I}_a = I_a / |I_a|$ e $\bar{I}_b = I_b / |I_b|$

Onde: $|I_a| = \sum_i |I_{ai}|$ e $|I_b| = \sum_i |I_{bi}|$

III. Inicialização dos pesos

$w_j^a = 1$; $w_k^b = 1$ e $w_j^{ab} = 1$

Valor igual a 1 indica que não existe nenhuma categoria ativa.

IV. Complementação dos vetores de entrada e saída, já normalizados, respectivamente:

$I_a = [\bar{a} \ \bar{a}^c]$ e $I_b = [\bar{b} \ \bar{b}^c]$

V. Módulo ARTb

Escolha da categoria (K):

$T_k^b = |I_b \wedge w_k^b| / (\alpha + |w_k^b|)$

$T_K^b = \max\{T_k^b : k = 1, \dots, N_b\}$

Teste de vigilância:

$|x_b| = |I_b \wedge w_K^b| / |I_b| \geq \rho_b$

Se não atende ao critério de vigilância ocorre o Reset: $T_K^b = 0$

Se atender, teve ressonância e faz-se a adaptação do peso e o cálculo do vetor de atividade em F2:

$$w_K^{\text{ovo}} = \beta(I_b \wedge w_K^{\text{velho}}) + (1 - \beta)w_K^{\text{velho}}$$

$$y_{Kk}^b = 1; y_{Kk}^b = 0 \text{ } k \neq K$$

Segue-se para o módulo Inter – ART

VI. Módulo ARTa:

Escolha da categoria (J):

$$T_j^a = |I_a \wedge w_j^a| / (\alpha + |w_j^a|)$$

$$T_j^a = \max\{T_j^a: j = 1, \dots, N_a\}$$

Teste de vigilância:

$$|x_a| = |I_a \wedge w_j^a| / |I_a| \geq \rho_a$$

Se não atende ao critério de vigilância ocorre o Reset: $T_j^a = 0$

Se atender, teve ressonância e cálculo o vetor de atividade em F2:

$$y_{jj}^a = 1; y_{jj}^a = 0 \text{ } j \neq J$$

Segue-se para o módulo Inter – ART

VII. Módulo Inter - ART

Teste de vigilância – Match Tracking

$$|x_{ab}| = |y^b \wedge w_j^{ab}| / |y^b| \geq \rho_{ab}$$

Se não atende ao critério de vigilância ocorre o Reset e o incremento do parâmetro de vigilância, respectivamente:

$$T_j^a = 0$$

$$\rho_a = |I_a \wedge w_j^a| / |I_a| + \varepsilon$$

Se atender, teve ressonância e faz-se a adaptação dos pesos do módulo ARTa e do

Inter – ART, respectivamente:

$$w_j^{\text{ovo}} = \beta(I_a \wedge w_j^{\text{velho}}) + (1 - \beta)w_j^{\text{velho}}$$

$$w_{jk}^{ab} = 1 \text{ } w_{jk}^{ab} = 0 \text{ se } j \neq J \text{ e } k \neq K$$

VIII. Final do treinamento

Se todos os pares de treinamento foram processados, o treinamento é encerrado e segue-se para Previsão, caso contrário:

$$\rho_a = \rho_a^{\text{original}}$$

Voltar aos módulos ART e continuar o processamento.

IX. Previsão

Leitura dos vetores de entrada

$$I_d = [d_1, d_2, d_3, \dots, d_n]$$

Normalização dos vetores de entrada

$$\bar{I}_d = I_d / |I_d|$$

Em que: $|I_d| = \sum_i |I_{di}|$

Escolha da categoria (L):

$$T_l^d = |I_d \wedge w_l^a| / (\alpha + |w_l^a|)$$

$$T_L^d = \max\{T_l^d : l = 1, \dots, N_d\}$$

Teste de vigilância:

$$|x_d| = |I_d \wedge w_L^a| / |I_d| \geq \rho_d$$

Se não atende ao critério de vigilância ocorre o Reset: $T_L^d = 0$

Se atender, teve ressonância e cálculo o vetor de atividade em F2:

$$y_{Li}^d = 1; y_{Li}^d = 0 \text{ } l \neq L$$

Cálculo do vetor de ativação y^b e determinação da categoria ativa (K):

$$y^b = y^d * w^{ab}$$

$$K = \max\{y_i^b : i = 1, \dots, N_b\}$$

Determinação do padrão de saída relacionado ao vetor de entrada I_d :

$$S_d = w_K^b \text{ (sem o complemento)}$$

APÊNDICE B – PREVISÃO

Neste apêndice são apresentados os resultados obtidos pela rede ARTMAP Fuzzy, utilizando os dados experimentais do trabalho de Huber (1980). Todos os resultados apresentados nas tabelas e nos gráficos são referentes ao menor e maior MAPE obtido, da melhor previsão selecionada pelo critério de seleção em uma bateria de 500 repetições.

1 EVOLUÇÃO DAS ALTURAS MÁXIMAS

1.1.1 Previsão das curvas das alturas máximas relativas para $h=0,12$

1.1.1.1 Resultado da RNA ARTMAP Fuzzy sem filtragem dos dados


Para este teste foram utilizados os 158 ensaios, sendo 50% para treinamento e 50% para previsão, os parâmetros de treinamento da rede foram mantidos conforme Tabela 1 e as linhas da matriz de entrada dadas pela equação (6). Na Tabela 29 são apresentados os resultados do menor e o maior MAPE observados na melhor previsão, entre as 500 repetições, selecionadas pela rede.

Tabela 29 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,438	0,435173	0,251	0,44408
0,354	0,354586	0,279	0,367952
0,296	0,298174	0,309	0,304512
0,240	0,240151	0,354	0,250588
0,208	0,207916	0,393	0,218868
MAPE	RMSE	MAPE	RMSE
0,329729	0,001618	36,756	0,131323

Fonte: Elaboração do próprio autor.

Figura 115 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Observou-se que apesar da rede ter conseguido prever uma parcela das respostas, também foram geradas algumas previsões inconsistentes. Isso se deve a alguns dados atípicos, pois é esperado que as curvas das alturas máximas relativas apresentassem comportamento decrescente, Figura 115(a), em outras palavras, à medida que a onda de impacto segue pelo canal, os picos das alturas da onda tendem a diminuir, não sendo esperando um aumento de seu valor como ocorrido na Figura 115(b).

A rede apresentou MAPE máximo de 36,7%, mínimo de 0,329% e médio de 6,55%, indicando a necessidade de uma filtragem nos dados de entrada. Ao analisar o RMSE, na melhor resposta temos um valor próximo à zero, ressaltando que a rede conseguiu prever o comportamento dos dados, porém quando ela diverge o valor do RMSE se aproxima a 0,13.

1.1.1.2 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


Foi realizado novo teste após o processo de filtragem, analisando um total de 74 ensaios, sendo 50% para treinamento e 50% para a previsão, tanto a matriz quanto os parâmetros de treinamento da rede foram mantidos. Os resultados referentes ao menor e maior MAPE observados são apresentados na Tabela 30.

Tabela 30 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,540	0,54351	0,310	0,240571
0,440	0,43927	0,225	0,206638
0,370	0,3673	0,170	0,181315
0,298	0,29781	0,125	0,159537
0,258	0,2581	0,110	0,15194
MAPE	RMSE	MAPE	RMSE
0,32944	0,00201	20,59386	0,04058

Fonte: Elaboração do próprio autor.

Figura 116 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Realizando uma análise comparativa entre esse teste e o anterior, foi observada uma redução no MAPE máximo, de 36,75% para 20,59%, e uma redução no médio de 6,55% para 5,39%, essa queda no valor do MAPE médio indicou que mais dados se aproximaram do esperado do que no caso anterior. Em relação ao RMSE, pode-se observar que as previsões realizadas pela RNA se aproximaram do comportamento dos dados experimentais, conforme a Figura 116 (a) e (b).

1.1.1.3 Resultado da RNA ARTMAP Fuzzy com filtragem e sem a entrada da altura de lâmina d'água (h)


Para esse teste foi mantido os 74 ensaios, sendo 50% para treinamento e 50% para previsão, mas foi alterada a composição da matriz de entrada seguindo a equação (16) eliminando a coluna referente à h. Foi retirado esse parâmetro numa tentativa de verificar os parâmetros de ensaios que mais influenciavam as previsões e como a RNA se comportaria. Os resultados referentes ao menor e maior MAPE são apresentados na Tabela 31.

Tabela 31 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,634	0,62784	0,480	0,399766
0,576	0,574331	0,370	0,345818
0,524	0,524389	0,290	0,298787
0,462	0,464935	0,205	0,247606
0,420	0,424505	0,160	0,213024
MAPE	RMSE	MAPE	RMSE
0,608709	0,003736135	16,04086	0,048427905

Fonte: Elaboração do próprio autor.

Figura 117 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

As previsões obtiveram MAPE máximo de 16,0%, mínimo de 0,60% e médio de 5,29%, uma pequena melhora em relação às análises anteriores. Em termos comportamentais, o valor do RMSE foi próximo à zero no menor MAPE, conforme pode ser visto na Figura 117 (a), mas mais próximo de 0,1 no maior MAPE conforme Figura 117 (b). Com base nessas informações pode-se observar que o parâmetro h não tinha grande influência no processo.

Foram realizados outros testes com a retirada dos parâmetros referentes aos ângulos de inclinação da entrada do material e da praia, não apresentando influência significativa nas previsões, não sendo estes considerados parâmetros essenciais para as análises.

1.1.1.4 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


Como penúltima busca pelo parâmetro adimensional que seria suficiente para obtenção da previsão, foi realizado um teste com apenas o volume adimensional. A matriz de entrada foi modificada para uma matriz com 74 linhas e uma coluna, conforme equação (18). Foi mantida a mesma porcentagem para treinamento e para previsão que os testes anteriores e os mesmos parâmetros de treinamento da RNA, os dados do menor e maior MAPE são apresentados na Tabela 32.

Tabela 32 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,404	0,403121	0,470	0,373328
0,320	0,319495	0,366	0,341771
0,253	0,253023	0,292	0,312595
0,185	0,185479	0,230	0,278061
0,146	0,146882	0,202	0,254244
MAPE	RMSE	MAPE	RMSE
0,249439	0,000637898	16,20025	0,055490495

Fonte: Elaboração do próprio autor.

Figura 118 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

A RNA apresentou MAPE máximo de 16,2%, mínimo de 0,249% e médio de 5,12%, uma pequena melhora em comparação com os testes anteriores. Em relação ao comportamento das curvas, observou-se que a RNA teve dois casos, um com valor do RMSE próximo à zero, Figura 118 (a) e outro com o valor próximo a 0,1, Figura 118 (b), situação semelhante a anterior.

1.1.1.5 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Foi verificado se apenas o número de Froude de impacto era suficiente para a RNA prever as alturas máximas, assim a matriz de entrada foi modificada segundo equação (17). A RNA apresentou valores de MAPE máximo de 17,41%, mínimo de 0,65% e médio de 7,70%, bastante próximos do resultado com apenas o volume adimensional, porém em uma análise geral utilizar apenas o volume adimensional apresentou melhores resultados. Na Tabela 33 são apresentados os resultados referentes ao menor e maior MAPE obtidos na melhor previsão da rede neural.

Tabela 33 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,520	0,522695	0,627	0,7920
0,42	0,418378	0,574	0,633979
0,34	0,336256	0,525	0,509538
0,25	0,250805	0,467	0,38051
0,199	0,200866	0,427	0,30477
MAPE	RMSE	MAPE	RMSE
0,653037	0,002368	17,41095	0,103611

Fonte: Elaboração do próprio autor.

Figura 119 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Pode-se observar na Figura 119 (a) referente ao menor MAPE que a previsão foi assertiva enquanto que no caso do maior MAPE, Figura 119 (b) a previsão divergiu do experimental, superestimando 2 pontos iniciais e subestimando os 2 pontos finais, porém a rede mostrou que entendeu o comportamento do fenômeno. Isso se pode observar também numericamente ao se analisar o valor do RMSE, no melhor caso se aproximando a zero e no caso mais extremo se aproximando a 0,1.

1.1.2 Previsão das curvas das alturas máximas relativas para $h=0,18$

Após a realização dos testes referentes à altura de lâmina d'água $h=0,12\text{m}$ seguiu-se para os testes com $h=0,18\text{ m}$. Manteve-se a mesma porcentagem para o treinamento e o diagnóstico, manteve-se os mesmos parâmetros de treinamento da rede neural e repetiram-se todas as etapas anteriores, a fim de verificar a metodologia novamente.

1.1.2.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


Num primeiro momento foi realizada a filtragem dos dados segundo os critérios explicados no capítulo 4 subitem 4.4 e seguindo-se para elaboração da matriz de entrada e saída conforme apresentado no subitem 4.2 do capítulo 4. A matriz de entrada tem a composição conforme a equação (6) e na Tabela 34 são apresentados dois dos resultados da melhor previsão, sendo um referente ao de maior valor de MAPE e o outro referente ao de menor valor de MAPE.

Tabela 34 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,428	0,427316	0,417	0,512907
0,333	0,333247	0,337	0,361408
0,259	0,259192	0,273	0,253716
0,186	0,186138	0,206	0,158801
0,145	0,145107	0,167	0,113168
MAPE	RMSE	MAPE	RMSE
0,091208	0,000345	18,49059	0,055302

Fonte: Elaboração do próprio autor.

Figura 120 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Como se pode observar ao visualizar os gráficos referentes aos resultados obtidos, na Figura 120 (a) a rede neural conseguiu prever com bastante precisão a curva de evolução das alturas, possuindo MAPE de 0,09% e um valor de RMSE próximo à zero. Já para o caso onde houve maior divergência na previsão, Figura 120 (b), o valor do MAPE foi de 18,49%, sendo que a rede superestimou os dois primeiros pontos e subestimou os demais, mas conseguiu prever o comportamento da curva, tendo um valor de RMSE de 0,05. Calculando o valor do MAPE médio obteve-se 6,24%, valor considerando baixo em comparação a outros testes.

1.1.2.2 Resultado da RNA ARTMAP Fuzzy com filtragem e sem a entrada da altura de lâmina d'água (h)


Realizaram-se os testes com a matriz de entrada composta de acordo com a equação (16), mantendo-se a filtragem dos dados, mas removendo a informação referente à altura de lâmina d'água do canal, de forma a se repetir os ensaios realizados com $h=0,12$ m, mas agora para os ensaios referentes à $h=0,18$ m. Na Tabela 8 são apresentados os resultados referentes ao menor e maior MAPE com os respectivos RMSE obtidos na melhor previsão.

Tabela 35 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,214	0,214225	0,351	0,472367
0,159	0,158617	0,344	0,384642
0,118	0,117596	0,338	0,323909
0,079	0,079309	0,329	0,26655
0,059	0,059254	0,323	0,237533
MAPE	RMSE	MAPE	RMSE
0,301779	0,000322	19,20061	0,074545

Fonte: Elaboração do próprio autor.

Figura 121 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 121 (a) pode-se observar que a rede previu com sucesso a curva de evolução das alturas obtendo MAPE de 0,30% com RMSE próximo a zero, porém no caso mais divergente, Figura 121 (b) a rede não previu com sucesso o comportamento da curva, obtendo um MAPE de 19,20% e um RMSE próximo a 0,1. Neste caso o MAPE médio foi de 6,27%, considerado baixo e numa análise pontual pode-se observar que apesar do MAPE máximo ter sido relativamente alto, a maioria das previsões ficaram próximos ao mínimo.

1.1.2.3 Resultado da rede ARTMAP Fuzzy com dados filtrados e apenas o volume adimensional (M)


Seguindo a cronologia dos ensaios, repetiram-se os testes agora com a matriz de entrada composta conforme a equação (18), analisando o comportamento da rede frente ao fornecimento apenas do valor do volume adimensional para determinar a curva de evolução das alturas. Na Tabela 36 são apresentados os resultados referentes ao MAPE máximo e mínimo, bem como o RMSE respectivo, da melhor previsão obtida da bateria de 500 testes.

Tabela 36 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,235	0,233973	0,395	0,290162
0,188	0,187887	0,25	0,233009
0,151	0,152437	0,163	0,189045
0,117	0,116986	0,098	0,145081
0,096	0,095716	0,07	0,118703
MAPE	RMSE	MAPE	RMSE
0,351141	0,000802	33,38668	0,057527

Fonte: Elaboração do próprio autor.

Figura 122 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Pode-se observar que novamente a rede conseguiu prever a curva de evolução das alturas, porém existiu dentre os casos analisados um com valor de MAPE máximo de 33,38%, Figura 122 (b), considerado alto em comparação aos casos anteriores e seu RMSE ficou próximo a 0,06, mostrando que a rede não previu com sucesso o comportamento da curva. Enquanto no caso mínimo, Figura 122 (a), o valor do MAPE foi de 0,35%, considerado baixo e o RMSE próximo à zero, indicando que a rede compreendeu este ensaio.

Quando analisamos o MAPE médio o valor ficou em 9,74%, mais alto que o anterior, indicando que os MAPES das previsões do melhor teste estavam um pouco mais distantes do mínimo, assim apesar da rede prever as curvas, ainda não atingiu o esperado.

1.1.2.4 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


A fim de verificar a critério comparativo, qual o parâmetro suficiente para realizar a previsão da curva de evolução das alturas, foi realizada uma análise com a matriz de entrada composta conforme a equação (17), fornecendo apenas o número de Froude como dado de entrada da rede. Na Tabela 37 são apresentados os resultados do maior e menor MAPE, com seus respectivos RMSE, da melhor previsão.

Tabela 37 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,202	0,202077	0,375	0,267254
0,161	0,161243	0,235	0,213249
0,131	0,130879	0,148	0,173092
0,101	0,101039	0,082	0,133627
0,084	0,083763	0,058	0,110779
MAPE	RMSE	MAPE	RMSE
0,120459	0,000166	41,77986	0,060271

Fonte: Elaboração do próprio autor.

Figura 123 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 123 (a) observa-se que a rede teve sucesso em prever a curva de evolução das alturas, tendo valor de MAPE de 0,12% com RMSE próximo a zero, enquanto no caso da Figura 123 (b) a rede neural divergiu da curva, possuindo MAPE máximo de 41,77% e RMSE de 0,06. Em termos de MAPE médio a melhor previsão teve valor de 9,77%, em comparação com o teste anterior se observa que a resposta da rede utilizando apenas o volume adimensional foi melhor que a resposta com o número de Froude.

Porém ao se comparar com a resposta fornecida ao se utilizar a matriz de entrada completa, com composição conforme a equação (6), ou comparando com a matriz sem a informação da altura de lamina d'água, equação (16), a rede teve melhor desempenho nestas que no caso com apenas o volume adimensional ou apenas o número de Froude.

1.1.3 Previsão das curvas das alturas máximas relativas para $h=0,27$

Como continuação das análises seguiu-se para os dados referentes à altura de lâmina d'água $h=0,27\text{m}$, realizando quatro testes, o primeiro com matriz de entrada completa composta conforme a equação (6), o segundo com a matriz de entrada composta conforme a equação (16), o terceiro com a matriz de entrada composta conforme a equação (18) e o quarto com a matriz de entrada composta conforme a equação (17). Foram apresentados 155 ensaios para a rede, sendo 50% diagnóstico e 50% para previsão.

1.1.3.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


Na Tabela 38 são apresentados os resultados referentes à melhor previsão obtida da bateria de 500 testes, são apresentados dois extremos da previsão, o menor e o maior MAPE com seus respectivos RMSE.

Tabela 38 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,218	0,2175	0,205	0,18099
0,189	0,189	0,138	0,115834
0,164	0,164	0,041	0,076016
0,136	0,136	0,043	0,049772
0,118	0,1185	0,03	0,034388
MAPE	RMSE	MAPE	RMSE
0,130617	0,000316	28,71115	0,021721

Fonte: Elaboração do próprio autor.

Figura 124 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 124 (a) refere-se ao menor valor de MAPE encontrado na melhor previsão, seu valor foi de 0,13% bastante baixo e seu RMSE foi próximo à zero, indicando que a rede entendeu o comportamento deste dado. Ao se analisar a Figura 124 (b) pode-se observar que o valor do MAPE sobe para 28,71% e o RMSE para 0,02, neste caso a rede se aproximou do

comportamento dos dados, mas divergiu muito no ponto $x'/h = 20$, o que levou a esse aumento no valor do MAPE e do RMSE. Em termos de MAPE médio o valor ficou em 8,59% considerado bom.

1.1.3.2 Resultado da RNA ARTMAP Fuzzy com filtragem e sem a entrada da altura de lâmina d'água (h)


Na Tabela 39 são apresentados os dados referentes à análise realizada com a matriz de entrada composta pela equação (16), a matriz de entrada foi rerepresentada à rede, mas sem a informação da altura de lâmina d'água. Foram selecionados o maior e menor MAPE das previsões realizadas de 78 ensaios, que corresponde aos 50% apresentados.

Tabela 39 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,418	0,418397	0,255	0,17588
0,344	0,343033	0,138	0,130887
0,282	0,281963	0,078	0,099802
0,218	0,218294	0,043	0,074033
0,179	0,179313	0,03	0,063398
MAPE	RMSE	MAPE	RMSE
0,139734	0,000505	49,52614	0,042106

Fonte: Elaboração do próprio autor.

Figura 125 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 125 (a) é apresentada a melhor resposta da rede, tendo valor de MAPE de 0,13% com RMSE próximo a zero, enquanto na Figura 125 (b) é apresentado o resultado referente à resposta mais divergente da rede, com MAPE de 49,52%. Pode-se observar que no primeiro caso a rede previu corretamente a curva de evolução das alturas e entendeu seu comportamento, porém no segundo caso a rede subestimou os dois primeiro pontos e superestimou os três últimos pontos. Quando se analisa o MAPE médio temos 9,06% indicando que a maioria dos valores estava mais próximo ao MAPE mínimo obtido.

1.1.3.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


Seguindo a sequência de ensaios, apresentou-se a rede a matriz de entrada seguindo a equação (18), onde apenas o volume adimensional era apresentado. Na Tabela 40 são apresentados os dois resultados extremos, mínimo e o máximo MAPE obtidos nas previsões.

Tabela 40 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,296	0,295795	0,235	0,157588
0,23	0,229974	0,125	0,122521
0,178	0,178428	0,07	0,09506
0,128	0,127675	0,038	0,06802
0,099	0,099127	0,028	0,052811
MAPE	RMSE	MAPE	RMSE
0,140581	0,000264	47,66707	0,040357

Fonte: Elaboração do próprio autor.

Figura 126 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 126 (a) é apresentado o resultado da melhor previsão realizada pela rede com MAPE de 0,14% e RMSE próximo a zero, enquanto na Figura 126 (b) é apresentada a resposta mais divergente com MAPE de 47,66% e RMSE próximo a 0,05. Observa-se que a situação é semelhante à ocorrida no teste anterior, porém neste caso houve uma pequena melhora do MAPE máximo. Porém ao olhar o MAPE médio de 10,18% indicou que as previsões tiveram um pequeno aumento no valor de seus MAPEs, o que fez o MAPE médio subir em relação ao anterior.

1.1.3.4 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Para realizar uma comparação se o volume adimensional seria o suficiente para realizar a previsão das curvas de evolução das alturas, realizou-se o teste com apenas o número de Froude na matriz de entrada, conforme equação (17). Na Tabela 41 são apresentados os resultados extremos das previsões realizadas.

Tabela 41 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,223	0,227663	0,235	0,16729
0,169	0,167751	0,125	0,123266
0,128	0,124615	0,07	0,091569
0,088	0,087071	0,038	0,063981
0,067	0,067899	0,028	0,049893
MAPE	RMSE	MAPE	RMSE
1,574397	0,002699	41,51504	0,035234

Fonte: Elaboração do próprio autor.

Figura 127 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Observando a Figura 127 (a) referente à melhor previsão da rede, novamente ela compreendeu o comportamento dos dados, tendo MAPE de 1,57% e RMSE próximo à zero. Ao se observar a Figura 127 (b) referente ao maior MAPE com valor de 41,51% e RMSE próximo a 0,04%, pode-se observar que novamente a rede divergiu para menos nos dois primeiros pontos e para mais nos três últimos. Em relação ao MAPE médio a rede obteve 11,2%, tendo um aumento em relação aos dois testes anteriores, indicando que apesar do MAPE máximo terem diminuído novamente, as previsões tiveram um aumento no valor de seus MAPEs.

1.1.4 Previsão das curvas das alturas máximas relativas para $h=0,36$

Como último teste para a evolução das alturas utilizou-se os dados referentes à altura de lâmina d'água $h=0,36$ m. Foram realizados quatro testes referentes às quatro variações da matriz de entrada, dadas pelas equações (6) e (16-18). Apresentaram-se à rede 158 dados, sendo 50% para previsão e 50% para diagnóstico. Observa-se que foram feitos todos os testes com os valores de h em separado para se poder avaliar corretamente o desempenho da rede em cada situação e depois analisar todos os dados em conjunto.

1.1.4.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


Na Tabela 42 são apresentadas as duas previsões referentes ao MAPE mínimo e máximo obtidos na melhor previsão selecionada pelo critério apresentado na seção 4.3. Neste teste foi utilizada a matriz de entrada segundo a equação (6).

Tabela 42 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,159	0,159554	0,148	0,110099
0,125	0,124722	0,073	0,076222
0,098	0,097755	0,039	0,053235
0,071	0,070788	0,02	0,032667
0,056	0,056181	0,014	0,021778
MAPE	RMSE	MAPE	RMSE
0,28855	0,000323	37,08215	0,019341

Fonte: Elaboração do próprio autor.

Figura 128 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Pode-se observar pela Figura 128 (a) que a rede conseguiu prever o comportamento e o valor dos dados, tendo MAPE de 0,28% e RMSE próximo à zero, porém ao se analisar a Figura 128 (b) a rede teve MAPE de 37,08% e RMSE próximo a 0,01, neste caso a rede subestimou o ponto inicial e superestimou os demais. Em termos de MAPE médio a rede atingiu o valor de 9,5%, considerado baixo e indicando que apesar do MAPE máximo de 37,08% a rede teve a maioria dos valores próximos ao mínimo.

1.1.4.2 Resultado da RNA ARTMAP Fuzzy com filtragem e sem a entrada da altura de lâmina d'água (h)


Realizando o segundo teste, com matriz de entrada composta segundo a equação (16) sem o valor de h , pode-se observar na Tabela 43, que apresenta os dois extremos dos valores do MAPE da melhor previsão, que a rede teve um caso de previsão perfeita, acertando todos os pontos previstos, algo que ainda não tinha sido observado nos testes anteriores.

Tabela 43 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,224	0,224	0,148	0,110099
0,167	0,167	0,073	0,076222
0,125	0,125	0,039	0,053235
0,085	0,085	0,02	0,032667
0,064	0,064	0,014	0,021778
MAPE	RMSE	MAPE	RMSE
0	0	37,08215	0,019341

Fonte: Elaboração do próprio autor.

Figura 129 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 129 (a) é apresentada a melhor resposta entre as 79 apresentadas para previsão, com MAPE de valor zero e RMSE de valor zero, enquanto no caso mais divergente, Figura 129 (b) a rede obteve MAPE de 37,08% com RMSE próximo a 0,02, novamente a rede apresentou o mesmo comportamento do teste anterior, subestimando o primeiro ponto e superestimando os demais. Analisando o MAPE médio de 8,83% indicou que a rede teve uma melhora nos valores dos MAPEs, ou seja, as previsões se aproximaram mais do esperado do que em relação ao teste anterior.

1.1.4.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


Seguindo a cronologia dos ensaios, realizou-se o teste com a matriz de entrada segundo a equação (18), apresentando apenas o valor do volume adimensional, novamente a rede teve uma previsão perfeita, com valor de MAPE de zero, conforme se pode ver na Tabela 44, que também apresenta o maior valor de MAPE obtido.

Tabela 44 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,162	0,162	0,269	0,213333
0,104	0,104	0,17	0,16
0,065	0,065	0,107	0,118095
0,038	0,038	0,058	0,08381
0,026	0,026	0,036	0,064762
MAPE	RMSE	MAPE	RMSE
0	0	32,2678	0,031033

Fonte: Elaboração do próprio autor.

Figura 130 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Realizando uma análise gráfica dos resultados, pode-se ver na Figura 130 (a) que a rede entendeu completamente o comportamento e previu com sucesso os valores da curva de

evolução das alturas, tendo MAPE de zero e RMSE de zero. Enquanto no caso mais extremo, Figura 130 (b) a rede obteve MAPE de 32,2% e RMSE de 0,03, tendo o mesmo comportamento dos testes anteriores. Em relação ao MAPE médio seu valor ficou próximo ao teste anterior, ficando em 8,53%.

1.1.4.4 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Como último teste para a evolução das alturas, foi realizado o teste com apenas o número de Froude na matriz de entrada conforme equação (17), de forma a verificar se ocorria o mesmo para $h=0,36$ m como nos casos anteriores, comprovando que apenas o volume adimensional era parâmetro suficiente para realizar as previsões. Na Tabela 45 são apresentados os dois extremos obtidos na melhor previsão.

Tabela 45 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
0,219	0,217627	0,225	0,137192
0,159	0,158767	0,09	0,100087
0,116	0,116171	0,042	0,073234
0,076	0,076673	0,021	0,048335
0,055	0,055762	0,016	0,035152
MAPE	RMSE	MAPE	RMSE
0,638363	0,000775	74,89352	0,044501

Fonte: Elaboração do próprio autor.

Figura 131 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 131 (a) pode-se observar que a rede conseguiu prever novamente a curva de evolução das alturas, obtendo MAPE de 0,63% com RMSE próximo a zero, enquanto no caso extremo, Figura 131 (b) a rede subestimou o primeiro valor e superestimou os demais, tendo MAPE de 74,8% e RMSE próximo a 0,05. Avaliando o MAPE médio de 11,14%, pode-se observar que apenas o número de Froude não foi suficiente em comparação com o teste com o volume adimensional.

Assim pode-se concluir que para o caso da evolução das alturas de ondas, após todas as análises, os casos com melhores respostas são os com a matriz de entrada dada pela equação (16) e (18).

2 PREVISÃO DOS COMPRIMENTOS

2.1.1 Previsão dos comprimentos de onda para $h=0,12$ m

Para $h=0,12$ m, mantiveram-se os mesmos 75 ensaios já pré-selecionados após filtragem, realizou-se todas as análises anteriores, menos a que possui a matriz de entrada conforme a equação (16), seguindo assim uma análise cronológica e complementar. Num primeiro momento foi verificada a resposta da rede à apresentação de todos os parâmetros relativos aos ensaios das ondas de impacto, equação (6), para servirem de base comparativa para a segunda análise, com apenas o volume adimensional na matriz de entrada, equação (18), e terceira análise, com apenas o número de Froude na matriz de entrada, equação (17).

2.1.1.1 Resultado da RNA ARTMAP Fuzzy com filtragem


Nessa análise foram usados os mesmo parâmetros da RNA e as mesmas porcentagens para treinamento e diagnóstico que os testes anteriores e na Tabela 1. Na Tabela 46 são apresentados os dados do menor e maior MAPE obtidos após o critério de seleção.

Tabela 46 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,40	5,431746	7,60	4,809804
7,70	7,679365	9,60	7,121008
10,80	10,76984	12,10	10,55658
17,00	17,04444	16,60	17,86499
24,00	23,9746	21,00	26,54762
MAPE	RMSE	MAPE	RMSE
0,300476	0,031507	21,86582	3,120544

Fonte: Elaboração do próprio autor.

Figura 132 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

A rede obteve respostas satisfatórias, com MAPE máximo de 21,1%, mínimo de 0,29% e médio de 5,36%. Analisando o RMSE, pode-se observar que no segundo caso, Figura 132 (b), ele atingiu um valor de 3,12, mostrando que a rede teve certa dificuldade em

prever o comportamento dos dados, enquanto no primeiro caso, menor MAPE, Figura 132 (a), a RNA conseguiu prever de maneira satisfatória o comportamento da curva de comprimento de onda, tendo um RMSE de 0,03.

2.1.1.2 Resultado da RNA ARTMAP Fuzzy com filtragem e apenas o volume adimensional (M) como parâmetro de entrada


Para esse teste a matriz de entrada era apenas composta pelo volume adimensional e as porcentagens para o treinamento e diagnóstico, bem como os parâmetros da RNA foram mantidos. Tal análise foi realizada para verificar se o volume adimensional era suficiente para a RNA realizar a previsão como realizado no teste das alturas máximas. Os resultados referentes ao maior e menor MAPE são apresentados na Tabela 47.

Tabela 47 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
4,60	4,623288	4,90	3,558082
6,80	6,849315	6,50	5,271233
10,00	9,988584	8,50	7,687215
16,60	16,60959	12,20	12,78274
24,50	24,42922	16,00	18,80073
MAPE	RMSE	MAPE	RMSE
0,338456	0,040511	15,6267	1,559160

Fonte: Elaboração do próprio autor.

Figura 133 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

A RNA apresentou MAPE máximo de 15,62%, mínimo de 0,33% e médio de 5,45%, em comparação com os MAPES anteriores houve uma redução no MAPE máximo. Com relação ao comportamento da curva, o valor do RMSE na Figura 133 (a) apresentou valor de 0,04, apesar do valor não ser mais baixo que no caso anterior, ainda sim foi considerado satisfatório. A curva referente ao MAPE máximo teve uma melhor aproximação entre a prevista pela RNA e a experimental, Figura 133 (b), em comparação com a resposta anterior, com MAPE de 21,86 e RMSE de 3,12. Indicando uma melhora no desempenho da RNA ao se apresentar apenas um parâmetro na matriz de entrada.

2.1.1.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Para confirmação de que o volume adimensional era suficiente para determinação da curva de evolução do comprimento relativo de onda, foi realizado um teste com a matriz de entrada dada pela equação (17), apresentando apenas o número de Froude como elemento da matriz de entrada. Assim como foi feito com os testes anteriores, na Tabela 48 é apresentado o resultado referente aos dois extremos da melhor previsão da rede.

Tabela 48 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,3	5,337748	6,8	9,504636
7,4	7,390728	10,6	13,16026
10,4	10,42914	16,5	18,5706
16,2	16,17748	29,8	28,80636
22,7	22,6649	46,7	40,35815
MAPE	RMSE	MAPE	RMSE
0,282264	0,028632	18,67818	3,445688

Fonte: Elaboração do próprio autor.

Figura 134 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 134 (a) é apresentado o melhor resultado da rede dentro da melhor previsão selecionada, tendo MAPE de 0,28% e RMSE próximo a 0,02, enquanto na Figura 134 (b) mostra o outro extremo, onde a rede mais divergiu da resposta esperada, com MAPE de 18,67% e RMSE de 3,44, um dos maiores valores de RMSE até então. Neste caso o MAPE médio ficou em 5,98% próximo ao MAPE médio do teste anterior, numa análise comparativa, ambos os testes, com apenas o volume adimensional e apenas o número de Froude, foram bastante similares.

2.1.2 Previsão dos comprimentos de ondas relativos para $h=0,18$

Os testes anteriores foram refeitos agora para $h=0,18$ metros, foram consideradas as mesmas três matrizes de entrada dadas pelas equações de (6), (17) e (18), utilizou-se os mesmos parâmetros de treinamento e diagnósticos fornecidos pela Tabela 1 e as mesmas porcentagens de treinamento e diagnóstico, 50% para cada um.

2.1.2.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


No primeiro teste foram considerados todos os dados de ensaio, já filtrados, referentes à lâmina d'água $h=0,18$ metros, os resultados referentes a este ensaio são apresentados na Tabela 23 que apresenta o menor e maior MAPE obtidos na melhor previsão.

Tabela 49 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6,5	6,500151	4,4	6,876471
8,6	8,568381	6,7	9,004902
11,4	11,42451	10,2	11,78824
16,6	16,54584	18	16,94559
22	22,06112	27,5	22,1848
MAPE	RMSE	MAPE	RMSE
0,237811	0,040668	26,28834	2,943843

Fonte: Elaboração do próprio autor.

Figura 135 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Neste ensaio foi obtido o MAPE médio de 5,81%, enquanto o maior MAPE foi de 26,28% e o menor foi de 0,23%, as curvas relativas a esses dois MAPES são representadas respectivamente pelas Figuras 135 (b) e 135 (a). Pode-se observar que no primeiro caso a curva divergiu em relação a experimental e teve RMSE de 2,93, neste caso os três primeiros pontos foram superestimados e os dois últimos subestimados. Já no segundo caso o RMSE foi de 0,04 e a previsão praticamente coincidiu.

2.1.2.2 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


O segundo teste foi apenas o volume adimensional como dado da matriz de entrada, continuando a busca da confirmação de que ele seria o parâmetro suficiente para as previsões. Na Tabela 24 são apresentados dois dos resultados referentes à melhor previsão.

Tabela 50 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,8	5,889394	5,7	8,873485
7,8	7,814773	8,9	11,77443
10,4	10,4197	13,7	15,69924
15,3	15,28977	24,3	23,03693
20,5	20,38636	37,5	30,71591
MAPE	RMSE	MAPE	RMSE
0,508246	0,06575	25,17078	3,740309

Fonte: Elaboração do próprio autor.

Figura 136 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 136 (a) é apresentado o melhor resultado dentro da melhor previsão com MAPE de 0,50% e RMSE de 0,06, mostrando que a rede conseguiu realizar uma boa previsão apenas com o volume adimensional, porém no segundo caso, Figura 136 (b) o valor do MAPE sobe para 25,17% e o RMSE para 3,74, neste caso, apesar da rede entender o comportamento, ela novamente superestimou os três primeiros pontos e subestimou os dois últimos. Ao se analisar o MAPE médio de 6,71% considerado baixo ainda, indicando que apesar da rede possuir um MAPE mais elevado dentre os resultados obtidos, em sua maioria os resultados ainda estão mais próximos do MAPE mínimo.

2.1.2.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Como última análise, foi realizado o teste com apenas o valor do número de Froude na matriz de entrada, conforme equação (17). Na Tabela 25 é apresentado o valor do menor e maior MAPE obtidos com seus respectivos RMSE, para a melhor previsão selecionada pelo critério apresentado na seção 4.

Tabela 51 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6,2	6,195159	8,5	5,651891
8,3	8,358548	9,8	7,625567
11,2	11,21029	11,4	10,22723
16,7	16,7171	13,7	15,25113
22,6	22,51891	15,9	20,54418
MAPE	RMSE	MAPE	RMSE
0,2673	0,045661	21,3027	2,763681

Fonte: Elaboração do próprio autor.

Figura 137 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Pode-se observar pela Tabela 51 ilustrada pelas Figuras 137 (a) e 137 (b), os dois extremos obtidos pela rede, no primeiro caso o valor do MAPE foi de 0,26% e o RMSE de

0,04, mostrando o casamento da curva experimental e da previsão, enquanto no segundo caso ocorre uma divergência, com MAPE de 21,3% e RMSE de 2,76, porém neste caso a rede subestimou os três primeiros pontos e superestimaram os dois últimos, possivelmente esta previsão entrou numa categoria inadequada e isto pode ter causado este valor de MAPE mais elevado. Em termos de MAPE médio o valor foi de 6,49%, indicando que apesar de possuir um valor de MAPE mais alto, no geral a rede teve bons resultados e isto permitiu que o valor do MAPE médio continuasse baixo.

Comparando os dois últimos testes, com volume adimensional e com número de Froude, os resultados foram bastante similares.

2.1.3 Previsão dos comprimentos de ondas relativos para $h=0,27$

Seguindo a sequência cronológica dos testes, seguiu-se para os dados de ensaio relativos à altura de lâmina d'água $h=0,27$ metros, apresentando à rede a matriz de entrada conforme equação (6), (17) e (18), para se realizar uma análise comparativa.

2.1.3.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


Na Tabela 52 é apresentado o menor e maior MAPE obtidos no primeiro teste relativos à melhor previsão obtida pela RNA.

Tabela 52 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6	6	5,8	7,847561
7,7	7,7	7,7	9,27439
9,9	9,9	10,2	11,00697
13,7	13,7	14,9	13,86063
17,5	17,5	19,9	16,51045
MAPE	RMSE	MAPE	RMSE
0	0	17,53388	1,994579

Fonte: Elaboração do próprio autor.

Figura 138 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Analisando a Tabela 52 e as Figuras 138 (a) e (b), pode-se observar que no primeiro caso o valor do MAPE foi zero e o RMSE também, indicando que a rede previu com precisão o valor dos dados experimentais relativos ao comprimento, enquanto no segundo caso, MAPE 17,53% e RMSE 1,99 a rede divergiu dos dados experimentais, superestimando os três primeiros pontos e subestimando os dois últimos, seguindo mesmo comportamento de testes anteriores. Em termo de MAPE médio a rede obteve valor de 4,22%, novamente indicando que a rede possuía mais valores próximos ao mínimo que próximos ao máximo, ou seja, a rede conseguiu obter uma boa previsão dos dados experimentais.

2.1.3.2 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


O segundo teste para $h=0,18$ m foi com a matriz de entrada dada pela equação (18), apresentando apenas o volume adimensional na matriz de entrada, os resultados extremos da melhor previsão são apresentados na Tabela 53.

Tabela 53 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE


Experimental	Previsão	Experimental	Previsão
5,8	5,798255	7,1	5,932617
7,6	7,605503	9,1	7,781745
9,9	9,939866	10,8	10,1702
14,2	14,15678	13,6	14,48483
18,6	18,5996	16,2	19,0306
MAPE	RMSE	MAPE	RMSE
0,162345	0,026423	13,44996	1,676504

Fonte: Elaboração do próprio autor.

Figura 139 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



(a)



(b)

Fonte: Elaboração do próprio autor.

Ao se analisar a Tabela 53 e as Figuras 139 (a) e (b) pode-se observar que no melhor caso a rede neural previu com boa precisão o valor dos dados relativos ao comprimento de onda, com MAPE de 0,16% e RMSE de 0,02, enquanto no segundo caso relativo ao maior MAPE à rede subestimou os três primeiros pontos e superestimou os dois últimos, possuindo MAPE de 13,44% e RMSE de 1,67. Ao se analisar o MAPE médio de 3,79%, com matriz de entrada dada pela equação (6), indica neste caso, uma melhora na previsão em relação ao teste anterior.

2.1.3.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Por fim foi realizado o teste com apenas o número de Froude na matriz de entrada, para seguir a cronologia e realizar uma análise comparativa. Na Tabela 28 é apresentado o resultado do menor e maior MAPE obtidos na melhor previsão selecionada pela rede.

Tabela 54 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6,8	6,795971	6,3	6,49554
8,9	8,872518	7,7	8,480288
11,6	11,60978	9,2	11,09655
16,6	16,61237	13,2	15,87799
21,7	21,70935	26,3	20,74964
MAPE	RMSE	MAPE	RMSE
0,114004	0,014885	15,04877	2,905928

Fonte: Elaboração do próprio autor.

Figura 140 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Ao se analisar a Figura 140 (a) e a Tabela 54, pode-se observar que a rede compreendeu novamente o comportamento dos dados e obteve uma boa previsão, com MAPE de 0,11 e RMSE de 0,01. Enquanto no segundo caso, Figura 140 (b) a rede teve dificuldades

em compreender o comportamento deste ensaio, obtendo MAPE de 15,04% e RMSE 2,90, superestimando quatro valores e subestimando o último. Ao se analisar o MAPE médio de 3,87% entende-se que a rede realizou uma boa previsão e se aproximou dos dados experimentais em sua maioria, em comparação ao teste anterior existe grande similaridade, ainda não se podendo afirmar qual parâmetro seria o ideal entre o volume adimensional e o número de Froude.

2.1.4 Previsão dos comprimentos de ondas relativos para $h=0,36$

Como última bateria de testes relativos ao comprimento de onda, realizaram-se os testes com os dados de ensaio referentes à $h=0,36$ m, utilizando as três matrizes de entrada e todos os parâmetros e porcentagens anteriores.

2.1.4.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


Na Tabela 55 são apresentados os dados do menor e maior MAPE obtidos na melhor previsão com os dados já filtrados previamente e com a matriz de entrada dada pela equação (6).

Tabela 55 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6,7	6,724684	5,5	7,890709
8,7	8,702532	7,3	9,094377
11,2	11,17484	9,6	10,49866
15,7	15,72389	14	12,63851
20,2	20,17405	18,3	14,57775
MAPE	RMSE	MAPE	RMSE
0,180556	0,022329	21,49481	2,256176

Fonte: Elaboração do próprio autor.

Figura 141 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Analisando a Tabela 55 e as Figuras 141 (a) e (b), pode-se observar que no primeiro caso o MAPE foi de 0,18% e RMSE de 0,02 enquanto a curva coincidiu com a dos dados experimentais. Porém no segundo caso não ocorre o mesmo, o MAPE sobe para 21,49% e o RMSE para 2,25, enquanto a curva diverge para mais nos três primeiros pontos e para menos nos dois últimos pontos. O MAPE médio desse ensaio ficou em 4,85% e novamente se observou que a maioria das previsões se aproximou dos dados experimentais, pois o valor do MAPE médio foi baixo.

2.1.4.2 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


Realizou-se o teste com apenas o volume adimensional na matriz de entrada e na Tabela 30 são apresentados o menor e o maior MAPE e seus respectivos RMSE obtidos na melhor previsão de uma bateria de 500 testes conforme realizado em todos os outros anteriores.

Tabela 56 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE


Experimental	Previsão	Experimental	Previsão
6,1	6,082936	10,6	8,087692
7,6	7,60367	12,3	10,39846
9,5	9,504587	14,3	13,43135
12,7	12,73615	17,5	18,775
15,9	15,87266	20,4	24,4075
MAPE	RMSE	MAPE	RMSE
0,166576	0,021816	14,4331	2,381923

Fonte: Elaboração do próprio autor.

Figura 142 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



(a)



(b)

Fonte: Elaboração do próprio autor.

Da análise da Figura 142 (a) e (b) e da Tabela 56 observa-se que a rede previu com sucesso no primeiro caso tendo MAPE de 0,16% e RMSE de 0,02, os valores dos dados de comprimento foram aproximadamente iguais ao experimental. A rede divergiu no segundo caso, com MAPE de 14,43 e RMSE de 2,38, neste caso os três primeiros valores ficaram abaixo do experimental e os dois últimos acima, o que justifica o valor do MAPE e do RMSE. Porém apesar de alguns dados divergirem, ao se observar o MAPE médio de 3,62% compreende-se que a maioria das previsões deste teste estava próxima dos dados experimentais esperados.

2.1.4.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Como último teste para o comprimento e para $h=0,36$ m, realizou-se o teste com apenas o número de Froude na matriz de entrada, conforme a equação (17). Na Tabela 57 é apresentado o resultado do menor e maior MAPE obtidos na melhor previsão e seus respectivos RMSE.

Tabela 57 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6,4	6,39382	10	7,6
8,3	8,300749	11,7	9,866667
10,7	10,65637	13,6	12,66667
15	15,03109	16,6	17,86667
19,5	19,51798	19,3	23,2
MAPE	RMSE	MAPE	RMSE
0,16256	0,025425	14,87401	2,315455

Fonte: Elaboração do próprio autor.

Figura 143 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Na Figura 143 (a) é apresentada a previsão que obteve o menor valor de MAPE de 0,16% e RMSE de 0,02, mostrando mais uma vez a capacidade da rede de prever os dados de

comprimento relativos de onda. Na Figura 143 (b) é apresentada a previsão com maior valor de MAPE de 14,87% e RMSE de 2,31, mais uma vez a rede subestimou os três primeiros pontos e superestimou os dois últimos pontos. Porém, assim como ocorre no teste anterior, ao se observar o MAPE médio de 3,92% pode-se compreender que a rede previu com sucesso os dados experimentais e por isso o valor baixo do MAPE médio. Neste caso, assim como ocorreu com os demais, não ficou claro qual o melhor parâmetro entre o volume adimensional e o número de Froude.

3 PREVISÃO DOS PERÍODOS DE ONDA

3.1.1 Previsão dos períodos de onda relativos para $h=0,12$

Para os testes com altura de lâmina d'água $h=0,12$ metros mantiveram-se os mesmos parâmetros de treinamento e diagnóstico, as mesmas porcentagens de treinamento e diagnóstico e a mesma sequência cronológica anterior.

3.1.1.1 Resultado da rede ARTMAP Fuzzy com filtragem


Foi realizado um teste com a matriz de entrada dada pela equação (6), tendo os 74 ensaios pré-filtrados, sendo 50% para o treinamento da RNA e 50% para a previsão. Na Tabela 58 são apresentados os resultados referentes ao maior e menor MAPE obtidos na melhor previsão selecionada pelo critério de seleção.

Tabela 58 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,65	5,711545	9,14	6,659933
7,56	7,592652	13,25	9,653848
10,05	10,11704	15,09	14,08973
14,74	14,70772	20,63	23,40142
19,71	19,58105	29,85	34,15507
MAPE	RMSE	MAPE	RMSE
0,6123	0,07351	17,75199	3,042958

Fonte: Elaboração do próprio autor.

Figura 144 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

A previsão foi considerada boa como se observa a Figura 144 (a) que retrata o MAPE mínimo de 0,08%, enquanto a Figura 144 (b), que retrata o MAPE máximo de 17,9%, mostra uma divergência de valores entre previsão e experimental. Quanto ao comportamento das curvas a rede teve duas situações diversas, com RMSE próximo a 0.1 e próximo a 3.0, indicando que a rede encontrou certa dificuldade em entender o segundo comportamento, apesar disso o MAPE médio foi de 5,45%, considerado baixo.

3.1.1.2 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M) como parâmetro de entrada


No segundo teste foi alterada a matriz de entrada para uma matriz com apenas um parâmetro, volume adimensional, dada pela equação (18), mantendo-se os mesmos parâmetros da RNA e as mesmas porcentagens de testes anteriores. Na Tabela 33 é apresentado o menor e maior MAPE obtidos na melhor previsão.

Tabela 59 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE


Experimental	Previsão	Experimental	Previsão
5,86	5,87100	5,82	7,606534
7,88	7,86261	9,08	10,89875
10,57	10,66597	14,18	15,50356
15,57	15,54589	25,52	24,89607
20,85	20,78449	39,82	35,51509
MAPE	RMSE	MAPE	RMSE
0,357076	0,05386	14,66331	2,33122

Fonte: Elaboração do próprio autor.

Figura 145 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



(a)



(b)

Fonte: Elaboração do próprio autor.

Neste teste foi obtido MAPE máximo de 14,6%, mínimo de 0,35% e médio de 5,15%, os valores são próximos aos anteriores, apesar do mínimo apresentar um pequeno aumento. A

RNA teve uma melhora na previsão do comportamento das curvas referentes ao período da onda, pois os valores do RMSE nas duas situações diminuíram de valor, indicando uma maior aproximação entre a curva prevista e a experimental, o que fica claro ao se observar as Figuras 145 (a) e 145 (b).

3.1.1.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Realizou-se o terceiro teste com apenas o número de Froude na matriz de entrada seguindo a equação (17). Na Tabela 60 são apresentados o menor e maior MAPE obtidos na melhor previsão da bateria de 500 testes.

Tabela 60 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,19	5,164211	8,87	6,544669
7,27	7,29971	11,26	9,251013
10,29	10,29762	14,21	13,0503
16,25	16,25238	19,46	20,59684
22,95	22,93608	24,71	29,06718
MAPE	RMSE	MAPE	RMSE
0,210985	0,019002	15,13876	2,492608

Fonte: Elaboração do próprio autor.

Figura 146 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Da análise da Tabela 60 e das Figuras 146 (a) e (b) pode-se observar que, assim como para o caso anterior com apenas o volume adimensional, a RNA conseguiu realizar uma boa previsão, no primeiro caso obteve MAPE de 0,21% e RMSE de 0,01, com a curva da previsão casando com a curva experimental. Enquanto no segundo caso, em que há uma maior divergência, com MAPE de 15,13% e RMSE de 2,49, a RNA entendeu o comportamento, mas subestimou os primeiros três pontos e superestimou os dois últimos. Porém o MAPE médio também foi baixo, no valor de 5,05% semelhante ao caso anterior.

3.1.2 Previsão dos períodos de onda relativos para $h=0,18$

Assim como feito anteriormente foram realizados os três testes com as três diferentes matrizes de entrada dadas pelas equações (6), (17) e (18) para se realizar uma comparação. Observa-se que foram mantidos todos os parâmetros e porcentagens anteriores para o treinamento e diagnóstico.

3.1.2.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


No primeiro teste foi analisada a matriz de entrada com todos os parâmetros de ensaio (h , M , F , α , β) e com todos os dados de ensaio referentes à $h=0,18$ m. Na Tabela 61 são apresentados dois resultados da melhor previsão, o primeiro referente ao menor MAPE obtido e o segundo referente ao maior MAPE.

Tabela 61 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6,47	6,448716	8,3	6,304489
8,29	8,274621	9,58	8,089557
10,63	10,61769	11,05	10,38022
14,74	14,755	13,35	14,425
18,89	18,92397	15,42	18,50073
MAPE	RMSE	MAPE	RMSE
0,18238	0,021073	14,73855	1,860034

Fonte: Elaboração do próprio autor.

Figura 147 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Analisando a Tabela 61 e as Figuras 147 (a) e (b), observa-se que a RNA no primeiro caso conseguiu uma boa previsão dos dados de período com MAPE de 0,18% e RMSE de 0,02, enquanto no segundo caso a rede divergiu da resposta, subestimando os três primeiros pontos e superestimando os dois últimos pontos. Porém analisando MAPE médio de 5,14% conclui-se que a rede realizou boas previsões dos dados experimentais.

3.1.2.2 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


Seguindo a sequência de testes foi analisada a resposta da rede com a matriz de entrada dada pela equação (18), que apresenta apenas o volume adimensional na matriz de entrada. Duas das previsões realizadas pela rede são apresentadas na Tabela 62, estas previsões fazem parte da melhor resposta que a RNA apresentou.

Tabela 62 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6,47	6,451561	5	7,770426
8,57	8,539444	7,72	10,28513
11,33	11,31633	11,87	13,62968
16,46	16,4734	20,94	19,84099
21,79	21,83926	32,3	26,30377
MAPE	RMSE	MAPE	RMSE
0,213941	0,02852	25,45454	3,301944

Fonte: Elaboração do próprio autor.

Figura 148 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Observando a Tabela 62 e as Figuras 148 (a) e (b) verifica-se que a rede conseguiu realizar uma boa previsão no primeiro caso com MAPE de 0,21% e RMSE de 0,02, porém no

segundo caso a rede divergiu da resposta esperada obtendo MAPE de 25,45% e RMSE de 3,3, devendo-se isto ao fato da rede ter superestimado os três primeiros pontos e subestimados os dois últimos. Observando o MAPE médio de 6,19% compreende-se que a RNA atingiu uma boa previsão dos dados experimentais.

3.1.2.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Por fim foi analisada a matriz de entrada com apenas o número de Froude para comparação com a situação anterior. Na Tabela 63 é apresentando o menor e maior MAPE obtido na melhor previsão selecionada pela RNA.

Tabela 63 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
4,97	4,962509	4,03	6,191504
6,5	6,493386	6,14	8,101512
8,61	8,589353	9,35	10,71656
12,53	12,59635	16,49	15,71591
16,45	16,4184	25,2	20,48452
MAPE	RMSE	MAPE	RMSE
0,242772	0,034428	24,72078	2,577677

Fonte: Elaboração do próprio autor.

Figura 149 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Ao se analisar as Figuras 149 (a) e (b) e a Tabela 63 pode-se notar que a RNA teve comportamento semelhante ao teste anterior, no primeiro caso a RNA previu com sucesso os dados experimentais tendo MAPE de 0,24% e RMSE de 0,03. Enquanto no segundo caso a RNA divergiu da resposta, tendo MAPE de 24,7% e RMSE de 2,57. Da mesma forma que o caso anterior, ao olhar o MAPE médio de 6,52% entende-se que a RNA conseguiu uma boa previsão dos dados experimentais.

3.1.3 Previsão dos períodos de onda relativos para $h=0,27$

Continuando a sequência de testes foram realizadas as previsões com os dados experimentais relativos à altura de lâmina d'água $h=0,27$ metros e utilizado as três matrizes de entrada dadas pelas equações (6), (17) e (18). Foram selecionados 78 ensaios experimentais para treinamento e 77 para diagnóstico, com total de 155 ensaios experimentais considerados.

3.1.3.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


Na Tabela 64 são apresentados os dois extremos da melhor previsão relativos ao menor e maior MAPE obtidos para o caso da matriz de entrada dada pela equação (6).

Tabela 64 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,78	5,785236	5,59	7,544512
7,42	7,419764	7,43	8,962206
9,54	9,539696	9,88	10,64758
13,21	13,205	14,4	13,38383
16,87	16,8703	19,15	15,91188
MAPE	RMSE	MAPE	RMSE
0,027323	0,003245	17,46426	1,911804

Fonte: Elaboração do próprio autor.

Figura 150 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Analisando a Tabela 64 e as Figuras 150 (a) e (b) nota-se que no primeiro caso a RNA previu com sucesso os dados de período relativo, com MAPE de 0,027% e RMSE próximo a zero, porém no segundo caso houve certa divergência por superestimar os três primeiros pontos e subestimar os dois últimos, obtendo MAPE de 17,4% e RMSE de 1,91. Apesar disto o MAPE médio ficou em 3,72% indicando que a rede, em sua maioria, realizou previsões ótimas.

3.1.3.2 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


Seguindo a sequência, foram realizados os testes com a matriz de entrada dada pela equação (18) e as duas previsões, com menor e maior MAPE, da melhor previsão são apresentadas na Tabela 65.

Tabela 65 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
6,3	6,308534	7,61	5,896387
8,24	8,239526	9,04	7,701225
10,79	10,77981	10,74	10,07555
15,41	15,42919	13,5	14,42118
20,18	20,16294	16,05	18,84566
MAPE	RMSE	MAPE	RMSE
0,088945	0,012933	13,55121	1,663404

Fonte: Elaboração do próprio autor.

Figura 151 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Observando a Tabela 65 e as Figuras 151 (a) e (b) pode-se observar que a RNA manteve uma boa previsão, quando se compara, o menor MAPE 0,08% e RMSE 0,012 e o maior MAPE 13,55% e RMSE 1,66, os resultados com o teste anterior. O mesmo é válido

para caso do MAPE médio de 3,78% em comparação ao anterior. Assim compreende-se que apenas o volume adimensional foi suficiente para a RNA realizar uma boa previsão.

3.1.3.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Para efeito comparativo foi realizada a previsão com a matriz de entrada contendo apenas a informação do número de Froude em cada ensaio. Os dados do menor e maior MAPE obtidos na melhor previsão são apresentados na Tabela 40.

Tabela 66 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE


Experimental	Previsão	Experimental	Previsão
7,87	7,855657	5,76	6,390242
10,16	10,13469	8,77	8,244137
13,09	13,10125	8,86	10,65731
18,3	18,34684	12,06	14,92437
23,7	23,68156	24,03	19,26394
MAPE	RMSE	MAPE	RMSE
0,170218	0,026485	16,16167	2,639092

Fonte: Elaboração do próprio autor.

Figura 152 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



(a)



(b)

Fonte: Elaboração do próprio autor.

Analisando a Tabela 66 e as Figuras 152 (a) e (b) pode-se observar um leve aumento nos valores do MAPE mínimo e máximo obtidos, no primeiro caso tem-se MAPE de 0,17% com RMSE de 0,02, em comparação com o MAPE anterior de 0,08% e RMSE de 0,012. O mesmo ocorre com o segundo caso, com MAPE de 16,16% e RMSE 2,63, em comparação com o caso anterior com MAPE de 13,55% e RMSE de 1,66. Em relação ao médio também há um pequeno aumento de 3,78% para 3,97%. Porém apesar desses pequenos aumentos nas porcentagens dos valores dos MAPES, este teste é considerado tão bom quanto o anterior.

3.1.4 Previsão dos períodos de onda relativos para $h=0,36$

Por último foram realizados os testes com a altura de lâmina d'água $h=0,36$ metros e novamente com as três matrizes de entrada dadas pelas equações (6), (17) e (18). Todos os parâmetros da rede se mantiveram os mesmos e dos 158 ensaios, 78 foram para treinamento e 78 para diagnóstico, mantendo as porcentagens de 50% para treinamento e 50% para diagnóstico.

3.1.4.1 Resultado da RNA ARTMAP Fuzzy com filtragem dos dados


No primeiro teste foi utilizada a matriz de entrada dada pela equação (6), apresentando todos os parâmetros de ensaio (h , F , M , α , β) relativos à $h=0,36$ m. O menor e maior MAPE obtidos na melhor previsão selecionada são apresentados na Tabela 67.

Tabela 67 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,65	5,639978	9,43	6,074742
7,3	7,288148	9,92	8,049894
9,43	9,431721	10,7	10,70257
13,25	13,26157	13,26	15,44523
17,14	17,14858	17,38	20,41756
MAPE	RMSE	MAPE	RMSE
0,099076	0,009502	17,68276	2,398211

Fonte: Elaboração do próprio autor.

Figura 153 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Da análise da Tabela 67 e das Figuras 153 (a) e (b) pode-se observar que no primeiro caso a RNA conseguiu prever com sucesso todos os cinco valores do período relativo de onda, tendo MAPE de 0,099% e RMSE próximo à zero, enquanto no segundo caso devido ao comportamento dos dados experimentais a RNA ficou distante do esperado, tendo MAPE de 17,68% e RMSE 2,39. Porém ao se analisar o MAPE médio de 4,41% entende-se que a maioria das previsões ficou dentro do esperado.

3.1.4.2 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o volume adimensional (M)


Seguindo a sequência de testes foi realizado o teste com apenas o volume adimensional na matriz de entrada, das previsões realizadas pela RNA, a que teve menor e maior MAPE dentro da melhor previsão são apresentadas na Tabela 68.

Tabela 68 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,62	5,604208	11,25	8,279402
7,29	7,306752	12,96	10,79466
9,43	9,434932	14,96	13,93874
13,26	13,25679	18,01	19,58498
17,17	17,16732	20,78	25,36222
MAPE	RMSE	MAPE	RMSE
0,120584	0,010694	16,14718	2,758021

Fonte: Elaboração do próprio autor.

Figura 154 – Comparativo entre experimental e previsão relativo ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Analisando as Figuras 154 (a) e (b) e a Tabela 68 observa-se que a RNA teve um bom desempenho, no primeiro caso a previsão foi assertiva e teve MAPE de 0,12% e RMSE de 0,01, enquanto no segundo caso, que teve maior divergência, a RNA obteve MAPE de 16,14% e RMSE de 2,75, e o MAPE médio ficou em 3,46%. Comparando os dois testes, a resposta da rede foi similar e indica que apenas este parâmetro poderia ser suficiente para realizar a previsão dos períodos de onda relativos.

3.1.4.3 Resultado da rede ARTMAP Fuzzy com utilização de filtros e apenas o número de Froude (F)


Como último teste da bateria de testes de previsões individuais, ou seja, com dados separados de altura de lâmina d'água, foi realizada a análise da resposta da rede a apresentação da matriz de entrada contendo apenas o valor do número de Froude. O resultado do menor e maior MAPE, dentro da melhor previsão, é apresentado na Tabela 69.

Tabela 69 – Previsão relativa ao menor (esquerda) e maior (direita) MAPE

Experimental	Previsão	Experimental	Previsão
5,43	5,425692	9,43	6,575185
6,98	6,984502	9,92	8,464246
8,99	8,991147	10,7	10,89602
12,54	12,53938	13,26	15,19598
16,14	16,13928	17,38	19,55857
MAPE	RMSE	MAPE	RMSE
0,033202	0,002865	14,78315	1,939164

Fonte: Elaboração do próprio autor.

Figura 155 – Comparativo entre experimental e previsão relativa ao menor (a) e o maior (b) MAPE



Fonte: Elaboração do próprio autor.

Observando a Tabela 69 e as Figuras 155 (a) e (b) conclui-se que a RNA conseguiu prever novamente os valores do período de onda relativo. No primeiro caso obteve MAPE de

0,03% e RMSE próximo a zero e no segundo caso com MAPE de 14,78% e RMSE de 1,98, enquanto o MAPE médio ficou em 3,81%. Este teste é similar ao anterior e indicou que ainda não se pode afirmar que somente o volume adimensional é parâmetro suficiente, precisando de mais alguns testes.

APÊNDICE C - NORMALIZAÇÃO

A seguir são apresentadas, graficamente, todas as normalizações utilizadas e sua influência nos dados conforme apresentado no subitem 6.7 do capítulo 6, bem como uma explicação mais detalhada de cada normalização.


1 Normalização pelo máximo da matriz de entrada e matriz de saída sem normalização

Pode-se observar na Figura 156 que ao se dividir a matriz de entrada pelo seu máximo há uma redução nos valores extremos, suavizando as diferenças entre os cinco valores dos parâmetros de ensaio no vetor selecionado.

Na Figura 157 apresenta-se um vetor da matriz de saída sem alteração nos cinco pontos selecionados.


A normalização 1 não apareceu entre as melhores normalizações, compreendendo que apenas a suavização dos extremos não pareceu suficiente para melhorar os resultados das previsões.

Figura156 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 157 – Dados de saída



Fonte: Elaboração do próprio autor.


2 Normalização pelo máximo da matriz de entrada e matriz de saída por Carpenter

A diferença entre esta normalização e a anterior ficou a cargo da matriz de saída que foi normalizada por Carpenter *et al.* (1992), podendo-se observar na Figura 158 que a matriz de saída teve seus valores ligeiramente aumentados em relação à situação sem normalização, observando que seu comportamento não foi afetado.

Na Figura 159 é apresentada a mesma matriz de entrada anterior normalizada pelo máximo da matriz.


Observou-se que a normalização 2 apareceu em destaque por diversas vezes e levantou a hipótese que existe uma relação entre a normalização da entrada e da saída que influencia os resultados das previsões.

Figura 158 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 159 – Dados de saída



Fonte: Elaboração do próprio autor.


3 Normalização pelo máximo da matriz de entrada e pelo máximo da matriz de saída

Diferente da situação anterior optou-se por normalizar a matriz de saída também pelo seu máximo e verificar o comportamento, assim a normalização 3 difere das normalizações anteriores ao se normalizar a saída pelo máximo da matriz de saída.

Na Figura 160 é apresentada a mesma matriz de entrada anterior e na Figura 161 é apresentada a matriz de saída após a normalização.


Apesar de os dados de saída terem um comportamento parecido com a normalização 2 em que existe um pequeno aumento dos valores dos dados de saída após normalização, esta não apareceu entre as melhores normalizações, possivelmente devido a leve alteração no comportamento da curva de evolução das alturas máximas.

Figura 160 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 161 – Dados de saída



Fonte: Elaboração do próprio autor.

4 Normalização da matriz de entrada pelo valor máximo da coluna e matriz de saída sem normalização


Neste momento volta-se a normalizar a matriz de entrada e não normalizar a matriz de saída, situação semelhante à normalização 1, com a diferença que a matriz de entrada foi normalizada pelo valor máximo da coluna, normalização 4.

Pode-se observar na Figura 162 uma alteração significativa no comportamento dos dados, diferente do primeiro caso, normalização 1, ao se dividir pelo máximo de cada coluna o primeiro ponto referente à altura de lâmina d'água teve seu valor aumentado, o segundo ponto referente ao volume adimensional teve uma redução significativa de seu valor, o terceiro ponto referente ao número de Froude também teve redução de valor, o quarto ponto referente ao ângulo de inclinação da vertente não teve quase alteração de valor e o quinto ponto referente ao ângulo de inclinação da praia a jusante teve pouca redução de valor.

Entende-se que isto se deve a natureza de cada um dos parâmetros de ensaio, porém esta normalização alterou o comportamento destes e isto pode explicar a razão desta normalização não aparecer entre as sete melhores.


Na Figura 163 é apresentada a matriz de saída sem alteração nos valores, para ilustração.

Figura 162 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 163 – Dados de saída



Fonte: Elaboração do próprio autor.

5 Normalização da matriz de entrada pelo valor máximo da coluna e matriz de saída normalizada por Carpenter


A normalização número 5 diferencia da anterior pois a saída foi normalizada por Carpenter *et al.* (1992) enquanto a anterior a saída não era normalizada.

A Figura 164 ilustra a matriz de entrada igual a anterior e a Figura 165 ilustra a matriz de saída normalizada por Carpenter *et al.* (1992) como ocorre na normalização 2.

Assim como na normalização 2, a normalização 5 não altera o comportamento da matriz de saída, porém a matriz de entrada muda significativamente seu comportamento, conforme explicado no item anterior.


Observou-se que apesar da matriz de entrada ter seu comportamento alterado, quando se normaliza a matriz de saída por Carpenter *et al.* (1992) existe uma relação mais forte entre os dados de entrada e saída, de tal maneira que mesmo com os dados de entrada com comportamentos diferentes a rede entende o processo e consegue realizar uma boa previsão, tanto que esta normalização aparece entre as sete melhores.

Figura 164 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 165 – Dados de saída



Fonte: Elaboração do próprio autor.


6 Normalização da matriz de entrada pelo valor máximo da coluna e matriz de saída normalizada pelo máximo da coluna

A normalização 6 difere da normalização 5 por normalizar a matriz de saída da mesma forma que a matriz de entrada, ou seja, normaliza cada elemento pelo máximo de sua coluna.

Na Figura 166 é apresentada mais uma vez a matriz de entrada normalizada pelo máximo da coluna e na Figura 167 é apresentada a matriz de saída também normalizada pelo máximo da coluna, podendo-se observar que há uma ligeira mudança no comportamento da curva e um aumento nos valores dos dados da saída.


Neste caso, assim como o que ocorre nas normalizações em que a entrada e a saída são normalizadas da mesma forma, a rede não realiza boas previsões, sendo que esta normalização não aparece entre as sete melhores.

Figura 166 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 167 – Dados de saída



Fonte: Elaboração do próprio autor.

7 Normalização da matriz de entrada pelo máximo da linha e matriz de saída sem normalização


Na normalização 7 altera-se a forma de normalizar a matriz de entrada, agora normalizando pelo máximo da linha, enquanto a matriz de saída volta a não ser normalizada.

Na Figura 168 pode-se observar a alteração nos dados de entrada, diferente do que ocorreu nos casos anteriores, neste há apenas uma redução no valor dos dados de entrada sem alteração de comportamento. A Figura 169 apresenta os dados da matriz de saída.

Era esperado que se os dados de entrada tivessem pouca alteração, a previsão realizada pela rede seria boa também, porém não é o que ocorre, levantando a hipótese de que há uma relação mais forte com a forma de normalizar a saída, do que a normalização da entrada, nos resultados da rede neural.


Da mesma forma que ocorreu com a normalização 1, 3, 4 e 6 a normalização 7 também não aparece entre as melhores, dando indícios de que a normalização da saída pode ser o maior influenciador do processo.

Figura 168 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 169 – Dados de saída



Fonte: Elaboração do próprio autor.

8 Normalização da matriz de entrada pelo máximo da linha e matriz de saída normalizada por Carpenter


Assim como nos casos anteriores, seguindo a sequência de estudo, normalizou-se a saída por Carpenter *et al.* (1992) e verificou-se a influência no comportamento dos dados.

Na Figura 170 apresenta-se a matriz de entrada normalizada pelo máximo da linha e na Figura 171 apresenta-se a matriz de saída normalizada por Carpenter *et al.* (1992).

Os dados da matriz de entrada possuem a mesma interpretação do caso anterior e a matriz de saída possui a mesma interpretação da normalização 2 e 5.


Podendo-se observar novamente que ao se normalizar a matriz de saída por Carpenter *et al.* (1992) a normalização 8 entrou para as sete melhores, indicando mais uma vez que normalizar a saída desta forma pode ser o ideal para o problema estudado.

Figura 170 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 171 – Dados de saída



Fonte: Elaboração do próprio autor.

9 Normalização da matriz de entrada pelo máximo da linha e matriz de saída normalizada pelo máximo da linha


Assim como em estudos anteriores, optou-se por normalizar a entrada e saída pelo máximo de suas linhas.

Na Figura 172 é apresentada a matriz de entrada normalizada pelo máximo da linha e na Figura 173 é apresentada a matriz de saída normalizada pelo máximo da linha.

Pode-se observar que a matriz de saída tem alteração no comportamento da curva e um grande aumento nos valores dos dados.


Como resultado, a normalização 9, matriz de entrada e saída pelo máximo da linha, não apareceu entre as melhores normalizações.

Figura 172 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 173 – Dados de saída



Fonte: Elaboração do próprio autor.


10 Normalização da matriz de entrada pelo somatório da coluna e matriz de saída sem normalização

Na normalização 10 a matriz de entrada é normalizada pelo somatório da coluna e a matriz de saída não é normalizada.

Nas Figuras 174 e 176 pode-se observar a alteração que os dados de entrada sofrerão após a normalização pelo somatório da coluna, os dados da altura da lâmina d'água foram significativamente reduzidos, e pode-se observar uma alteração no comportamento do gráfico em relação à situação sem normalização. Na Figura 175 é apresentada a matriz de saída sem normalização.


Foi necessária uma ampliação dos dados da matriz de entrada após normalização por terem sido reduzidos a valores na casa de 10^{-3} . Também se observou que um dos pontos extremos, ponto 2, teve grande redução de valor, enquanto ponto 5, apesar da redução de valor, foi menor em comparação. A normalização 10 também não apareceu entre as sete melhores.

Figura 174 – Dados de entrada




Fonte: Elaboração do próprio autor.

Figura 175 – Dados de saída



Fonte: Elaboração do próprio autor.

Figura 176 – Ampliação da parte inferior da Figura 174




Fonte: Elaboração do próprio autor.

11 Normalização da matriz de entrada pelo somatório da coluna e matriz de saída normalizada por Carpenter

Na normalização 11 a matriz de entrada se mantém normalizada pelo somatório da coluna, Figuras 177 e 179, com mesma análise que a normalização 10, porém a matriz de saída foi normalizada por Carpenter *et al.* (1992) e o comportamento dos dados antes e depois da normalização é ilustrado na Figura 178, cuja análise é a mesma das normalizações 2, 5 e 8.


Pode-se observar que, apesar da matriz de entrada ter alteração de comportamento e redução significativa dos valores, ao se normalizar a matriz de saída por Carpenter *et al.* (1992), a normalização 11 apareceu entre as sete melhores, novamente indicando que a saída normalizada desta forma pode ser o ideal para este problema.

Figura 177 – Dados de entrada




Fonte: Elaboração do próprio autor.

Figura 178 – Dados de saída



Fonte: Elaboração do próprio autor.

Figura 179 – Ampliação da parte inferior da Figura 177



Fonte: Elaboração do próprio autor.


12 Normalização da matriz de entrada pelo somatório da coluna e matriz de saída pelo somatório da coluna

Seguindo a sequência de estudo, normalizou-se a entrada e saída pelo somatório da coluna, normalização número 12, a fim de continuar a verificar a influência nos dados apresentados a rede.

Nas Figuras 180 e 182 é apresentada a matriz de entrada na situação antes e depois da normalização pela somatória da coluna, cujas análises segue a mesma da normalização 11 e 10.


Nas Figuras 181 e 183 é apresentado a matriz de saída antes e depois da normalização, assim como ocorreu com a matriz de entrada, houve a necessidade de ampliar os dados após a normalização, pois os valores foram reduzidos significativamente, tendo valores na casa de 10^{-3} . Em termos comportamentais a curva dos dados de saída se manteve, apesar disto a normalização número 12 não aparece entre as melhores.

Figura 180 – Dados de entrada




Fonte: Elaboração do próprio autor.

Figura 182 – Ampliação da parte inferior da Figura 180




Fonte: Elaboração do próprio autor.

Figura 181 – Dados de saída



Fonte: Elaboração do próprio autor.

Figura 183 – Ampliação da parte inferior da Figura 181



Fonte: Elaboração do próprio autor.

13 Normalização da matriz de entrada por Carpenter e matriz de saída sem normalização


Como verificado nas análises anteriores e nos resultados dos testes de normalização, foi de interesse verificar como seria o comportamento dos dados quando a matriz de entrada fosse normalizada por Carpenter.

Na normalização 13 a matriz de entrada é normalizada por Carpenter e a matriz de saída permanece inalterada.

Pode-se observar na Figura 184 que assim como ocorre nas normalizações 2 e 3, pelo máximo da matriz de entrada, os dados tem seus extremos amenizados, existe uma pequena alteração comportamental. A Figura 185 ilustra os dados da matriz de saída sem normalização.


Era esperado que, assim como quando a matriz de saída era normalizada por Carpenter *et al.* (1992), a matriz de entrada sendo normalizada desta maneira resultaria que ela se encontraria junto das sete melhores, mas isto não ocorreu.

Figura 184 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 185 – Dados de saída



Fonte: Elaboração do próprio autor.

14 Normalização da matriz de entrada por Carpenter e matriz de saída por Carpenter


Após realizar o estudo sem a normalização da matriz de saída, foi observada a influência da normalização desta pela normalização por Carpenter *et al.* (1992).

Nas Figuras 186 e 187 pode-se observar a influência da normalização 14 nos dados de entrada e saída respectivamente.

Assim como observado nas normalizações anteriores, ao se normalizar a saída por Carpenter *et al.* (1992) a normalização passa a fazer parte das com os melhores resultados.


As análises da matriz de entrada segue a mesma da normalização 13 e a da saída às mesmas das normalizações 2, 5, 8 e 11.

Figura 186 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 187 – Dados de saída



Fonte: Elaboração do próprio autor.


15 Normalização da matriz de entrada pelo min-máx e matriz de saída pelo min-máx

Na normalização 15 os dados da matriz de entrada são normalizados pelo min-máx e os dados da matriz de saída também são normalizados da mesma forma.

Na Figura 188 pode-se observar o comportamento dos dados antes e após a normalização estudada, neste caso o comportamento é bastante semelhante ao que ocorre quando se normaliza por Carpenter *et al.* (1992).


Na Figura 189 pode-se observar que, diferente do que ocorre com a matriz de entrada, a matriz de saída não se comporta como se fosse normalizada por Carpenter *et al.* (1992), os dados possuem pouca alteração de valores e observa-se uma pequena mudança na inclinação da curva. Assim como era esperado a normalização 15 não apareceu entre as sete melhores.

Figura 188 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 189 – Dados de saída



Fonte: Elaboração do próprio autor.


16 Normalização da matriz de entrada pelo min-máx e matriz de saída por Carpenter

Seguindo a sequência do estudo, a matriz de saída foi normalizada por Carpenter *et al.* (1992) e era esperado que a normalização 16 estivesse entre as sete melhores.

Nas Figuras 190 e 191 pode-se observar o comportamento dos dados, de entrada e saída, antes e depois de serem normalizados. As análises da entrada segue a mesma da normalização 15 e da matriz de saída segue a mesma das normalizações 2, 5, 8, 11 e 14.


Da mesma forma que as normalizações 2, 5, 8, 11 e 14, cuja saída é normalizada por (82), a normalização 16 aparece entre as com os melhores resultados.

Figura 190 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 191 – Dados de saída




Fonte: Elaboração do próprio autor.

17 Normalização da matriz de entrada pelo min-máx e matriz de saída sem normalização


A normalização 17 difere da anterior, pois a matriz de saída não é normalizada, em termos de comportamento, como verificado nas Figuras 192 e 193, não ocorre diferença das anteriores, a matriz 17 também não aparece entre as melhores.

Figura 192 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 193 – Dados de saída



Fonte: Elaboração do próprio autor.

18 Normalização da matriz de entrada pelo máx-min e matriz de saída pelo máx-min

Seguindo as análises, a normalização 18 possui os dados de entrada normalizados pelo máx-min e os dados de saída também pelo máx-min.


Nas Figuras 194 e 195 são apresentados os dados antes e depois de serem normalizados pelo máx-min, em ambos os casos observou-se que os dados tiveram um espelhamento após a normalização.

No caso da entrada, os dados são um espelho da normalização min-máx, porém neste caso os pontos 1, 3 e 4 tiveram aumento em seus valores e os pontos extremos, 2 e 5, tiveram redução em seus valores.

Para os dados de saída o comportamento foi diferente, após normalização os dados tiveram aumento dos valores e alteração na inclinação da curva.


Tal comportamento pode explicar porque a normalização 18 não aparece entre as sete melhores.

Figura 194 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 195 – Dados de saída



Fonte: Elaboração do próprio autor.


19 Normalização da matriz de entrada pelo máx-máx e matriz de saída por Carpenter

Da mesma forma que nos estudos anteriores, a matriz de saída foi normalizada por (82) enquanto a matriz de entrada foi normalizada pelo máx-min.

Na Figura 196 é apresentado um vetor da matriz de saída que segue as mesmas observações da normalização 18, enquanto na Figura 197 é apresentado um vetor da matriz de saída, cujo comportamento é o mesmo das normalizações 2, 5, 8, 11, 14 e 16.


Novamente foi observado que ao se normalizar a matriz de saída por Carpenter *et al.* (1992) os resultados das previsões melhoram em relação às outras normalizações, e a normalização 19 aparece entre as sete melhores.

Figura 196 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 197 – Dados de saída




Fonte: Elaboração do próprio autor.

20 Normalização da matriz de entrada pelo máx-min e matriz de saída sem normalização

A normalização 20 segue a sequência do estudo e normaliza a matriz de entrada pelo máx-min, mas não realiza a normalização da matriz de saída.


Nas Figuras 198 e 199 são apresentados os dados de entrada e saída, antes e depois da normalização, cujas análises seguem as relatadas anteriormente. Novamente, como ocorre com as outras normalizações semelhantes, a normalização 18 não aparece entre as sete melhores.

Figura 198 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 199 – Dados de saída




Fonte: Elaboração do próprio autor.

21 Normalização da matriz de entrada por Carpenter e matriz de saída pelo máximo da coluna

A normalização 21 possui os dados de entrada normalizados por Carpenter *et al.* (1992) e os dados de saída normalizados pelo máximo da coluna. Nas Figuras 200 e 201 são apresentados os comportamentos dos dados de entrada e saída, antes e depois de serem normalizados.


Como esperado a normalização 21 também não aparece entre as sete melhores, ressaltando novamente que, diferente do que ocorre com a matriz de saída, normalizar a entrada por Carpenter *et al.* (1992) não garante bons resultados para este problema.

Figura 200 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 201 – Dados de saída




Fonte: Elaboração do próprio autor.

22 Normalização da matriz de entrada por Carpenter e matriz de saída pelo máx-min


Diferente da normalização 21, a normalização 22 possui os dados de entrada normalizados pelo máx-min, da mesma forma que a normalização 18. Nas Figuras 202 e 203 são apresentados os comportamentos dos dados de entrada e saída, antes e depois de serem normalizados. Esta normalização também não aparece entre as sete melhores.

Figura 202 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 203 – Dados de saída




Fonte: Elaboração do próprio autor.

23 Normalização da matriz de entrada por Carpenter e matriz de saída pelo min-máx


A normalização 23 difere das normalizações 21 e 22, pois os dados da matriz de saída são normalizados pelo min-máx. Nas Figuras 204 e 205 são apresentados os comportamentos dos dados de entrada e saída, antes e depois de serem normalizados. Novamente como esperado, esta normalização não aparece entre as sete melhores.

Figura 204 – Dados de entrada



Fonte: Elaboração do próprio autor.

Figura 205 – Dados de saída




Fonte: Elaboração do próprio autor.

24 Normalização da matriz de entrada por Carpenter e matriz de saída pelo somatório da coluna

A última normalização possui a matriz de entrada normalizada por Carpenter *et al.* (1992) e a matriz de saída normalizada pelo somatório da coluna. Nas Figuras 206, 207 e 208 são apresentados os comportamentos dos dados de entrada e saída, antes e depois de serem normalizados.


As observações da matriz de saída seguem as mesmas da normalização número 12 e assim como ela a normalização 24 não aparece entre as sete melhores.

Figura 206 – Dados de entrada




Fonte: Elaboração do próprio autor.

Figura 207 – Dados de saída



Fonte: Elaboração do próprio autor.

Figura 208 – Ampliação da parte inferior da Figura 207



Fonte: Elaboração do próprio autor.