



INSTITUTO SUPERIOR TÉCNICO  
Universidade Técnica de Lisboa



## **Identificação e Controlo de um Conversor de Energia das Ondas usando Modelos Fuzzy e Redes Neurais**

**João José Alves Casanova Fernandes**

Dissertação para obtenção do Grau de Mestre em  
**Engenharia Mecânica**

**Júri**

PRESIDENTE: PAS-Ag. (DEM-IST) João Rogério Caldas Pinto

ORIENTAÇÃO: (Eq. INV. AUXILIAR) Duarte Pedro Mata de Oliveira Valério

VOGAL: PROF-ADJ. (ISEL) Mário José Gonçalves Cavaco Mendes

**Novembro, 2011**

Página deixada intencionalmente em branco.



## Introdução

O forte crescimento da procura energética e os limitados recursos, cada vez mais diminutos, das energias fósseis existentes no planeta, vulgo convencionais, obrigam a encarar esta demanda mundial segundo perspectivas diferentes e inovadoras, traduzindo-se numa forte motivação no seio da comunidade científica, em especial, para encontrar soluções capazes de responder aos novos paradigmas energéticos exigidos pelo estilo de vida da sociedade actual. *“Cada vez mais somos confrontados com a exigência de encontrar nas energias renováveis uma alternativa real e fiável às formas convencionais de produção de energia eléctrica, responsáveis por sérias ameaças ao meio ambiente.”* [1]

## **Agradecimentos**

Este trabalho só foi possível graças ao esforço prévio de várias pessoas, que abraçaram a causa da “energia limpa”, e, em particular, a da energia das ondas, com enorme determinação, cientes da importância cada vez mais preponderante que esta área representa em face dos moldes actuais do estilo de vida da sociedade.

O autor, que partilha, igualmente, deste interesse, quer vincar e endereçar, no entanto, um enorme agradecimento ao seu orientador, o Doutor Duarte Valério, pelo seu espírito crítico, dedicação e permanente disponibilidade; à Doutora Susana Vieira, ao Professor Doutor Mário Mendes e ao Professor Doutor Pedro Beirão pelas sugestões e observações pontuais; para além da sua mulher e filha, pelo seu imenso amor e enorme paciência.

## Resumo

Este trabalho baseia-se no modelo matemático, simplificado, de um dispositivo de extracção de energia das ondas, desenvolvido pelo Centro de Energia das Ondas, e tem como objectivo a respectiva modelação através de modelos obtidos com recurso a duas tecnologias alternativas, Redes Neurais e Lógica Fuzzy, pretendendo, simultaneamente, fazer a comparação entre os índices de desempenho respectivos.

O conhecimento mais pormenorizado das características do aparelho, bem como do seu comportamento funcional, permitem realizar acções de controlo específicas com o intuito de otimizar o seu desempenho, reflectindo-se na optimização da quantidade e da qualidade da extracção da energia das ondas. Uma das principais premissas deste trabalho é a obtenção de modelos directos e inversos, com a melhor qualidade possível, para viabilizar o projecto de um controlador do tipo IMC (*Internal Model Control*).

O intenso percurso de pesquisa, assente numa forte componente computacional, desenvolvido ao longo deste projecto não foi, no entanto, plenamente conseguido, uma vez que não se conseguiram encontrar os modelos inversos, conforme se dá conta no capítulo respectivo. Contudo, a qualidade e a robustez conseguida pelos modelos directos, principalmente dos modelos Fuzzy, independentemente de terem sido obtidos para condições mais favoráveis do nível energético das ondas, viabiliza a opção por um mecanismo de controlo do tipo preditivo, que seria interessante explorar.

**Palavras-chave:** Conversão de Energia das Ondas; Coluna de Água Oscilante; Turbinas Wells; Simulação; Redes Neurais; Lógica Fuzzy.

## **Abstract**

This work is based on the, simplified, mathematical model, of a device designed for extracting energy from waves, which was developed by the Wave Energy Centre, and its goal is the modeling of this device through the models obtained by two alternative technologies, Neural Networks and Fuzzy Logic, with the intended purpose, simultaneously, of making the comparison between the respective levels of performance.

The more detailed knowledge of the characteristics of the device, as well as its performance, allows to perform specific control operations in order to optimize its performance, reflected in the optimization of the quantity and quality of the extraction of wave energy. A major premise of this work is to obtain direct and inverse models, with the best quality possible, to enable the design of a controller of the IMC (Internal Model Control) type.

The intense and hard research, with a strong computational component, developed during this project was not fully achieved, however, since an inverse model was not successfully achieved. However, the quality and robustness evidenced by direct models, especially by fuzzy models, makes it possibility to opt for a control mechanism of the predictive type, a solution that would be interesting to explore.

**Keywords:** Wave Energy Converter; Oscillating Water Column; Wells Turbine; Simulation; Neural Networks; Fuzzy Logic.

# Índice

Introdução.....	I
Agradecimentos.....	II
Resumo.....	III
Abstract .....	IV
Índice.....	V
Lista de Figuras .....	IX
Lista de Tabelas.....	XII
Lista de abreviações .....	XIII
Prefácio.....	XIV
Contribuições .....	XV
1. Objectivo .....	1
1.1 Energia das ondas .....	1
1.1.1 Caracterização da energia das ondas .....	2
1.2 Classificação dos sistemas de extracção .....	3
1.2.1 Exemplos de aparelhos mais desenvolvidos .....	4
1.2.2 Outros modelos em fase de implementação.....	6
1.3 Considerações sobre a viabilização económica dos projectos .....	8
2. Estado da arte .....	9
2.1 Redes Neurais .....	9
2.2 Lógica Fuzzy.....	13
3. Descrição do aparelho .....	17
3.1 Esquema das dimensões físicas.....	17
3.2 Turbinas Wells.....	18
3.3 Modelo matemático .....	20
3.3.1 Considerações adicionais.....	20
3.3.2 Análise de forças .....	20
3.3.3 Forças de radiação .....	21
3.3.4 Forças de excitação.....	21
3.3.5 Constantes físicas .....	22

3.3.6	Dimensões físicas do aparelho.....	22
3.3.7	Dimensões compostas.....	23
3.3.7.1	Definição de outras variáveis.....	24
3.4	Forças actuantes nos dois corpos .....	25
3.4.1	Forças aplicadas no aparelho .....	25
3.4.1.1	Condições de repouso .....	25
3.4.1.2	Forças de radiação .....	26
3.4.1.3	Força de impulsão.....	27
3.4.1.4	Peso do aparelho .....	27
3.4.1.5	Forças devidas à turbina.....	27
3.4.1.6	Potência pneumática disponível para a turbina.....	28
3.4.1.7	Forças devidas à resistência viscosa hidrodinâmica .....	29
3.4.1.8	Força viscosa hidrodinâmica externa.....	30
3.4.1.9	Força viscosa hidrodinâmica interna.....	30
3.4.1.10	Força provocada pela pressão interna .....	30
3.4.1.11	Força provocada pela água no interior do aparelho .....	30
3.4.2	Forças aplicadas no volume de água.....	32
3.4.2.1	Restrições de equilíbrio .....	32
3.4.2.2	Força de radiação .....	32
3.4.2.3	Força de impulsão.....	34
3.4.2.4	Força de resistência da viscosidade hidrodinâmica .....	34
3.4.2.5	Força provocada pela pressão interna .....	34
3.4.2.6	Peso e massa do volume de água .....	34
3.4.3	Modelação do ar no interior do aparelho .....	35
3.5	Condições e variáveis do simulador.....	36
4.	Pesquisa de modelos.....	39
4.1	Modelos <i>NARX</i> , directos, em Redes Neurais .....	43
4.1.1	Modelos para $\zeta$ , com uma velocidade da turbina de 79 rad/s .....	43
4.1.2	Modelos para $h$ , com uma velocidade da turbina de 79 rad/s .....	44
4.1.3	Modelos para $\zeta$ , com uma velocidade da turbina de 100 rad/s .....	45

4.1.4	Modelos para $h$ , com uma velocidade da turbina de 100 rad/s .....	46
4.1.5	Modelos para $\zeta$ , com uma velocidade da turbina de 157 rad/s .....	47
4.1.6	Modelos para $h$ , com uma velocidade da turbina de 157 rad/s .....	48
4.1.7	Observações aos modelos em Redes Neurais .....	49
4.2	Modelos <i>NARX</i> , inversos, em Redes Neurais .....	50
4.3	Modelos <i>NARX</i> , directos, utilizando lógica Fuzzy.....	52
4.3.1	Modelos para $\zeta$ , com uma velocidade da turbina de 79 rad/s .....	52
4.3.2	Modelos para $h$ , com uma velocidade da turbina de 79 rad/s .....	53
4.3.3	Modelos para $\zeta$ , com uma velocidade da turbina de 100 rad/s .....	54
4.3.4	Modelos para $h$ , com uma velocidade da turbina de 100 rad/s .....	55
4.3.5	Modelos para $\zeta$ , com uma velocidade da turbina de 157 rad/s .....	56
4.3.6	Modelos para $h$ , com uma velocidade da turbina de 157 rad/s .....	57
4.3.7	Observações aos modelos em lógica Fuzzy.....	57
4.4	Modelos <i>NARX</i> , inversos, utilizando lógica Fuzzy .....	58
4.5	Interpolação com modelos directos.....	63
4.5.1	Gráficos das interpolações dos sistemas de redes neuronais .....	65
4.5.1.1	Valores gerados com uma velocidade da turbina de 90 rad/s .....	65
4.5.1.2	Valores gerados com uma velocidade da turbina de 115 rad/s .....	66
4.5.1.3	Valores gerados com uma velocidade da turbina de 131 rad/s .....	67
4.5.1.4	Valores gerados com uma velocidade da turbina de 145 rad/s .....	68
4.5.2	Gráficos das interpolações dos sistemas Fuzzy .....	69
4.5.2.1	Valores gerados com uma velocidade da turbina de 90 rad/s .....	69
4.5.2.2	Valores gerados com uma velocidade da turbina de 115 rad/s .....	70
4.5.2.3	Valores gerados com uma velocidade da turbina de 131 rad/s .....	71
4.5.2.4	Valores gerados com uma velocidade da turbina de 145 rad/s .....	72
4.5.3	Observações aos resultados das interpolações.....	73
4.5.3.1	Comparação entre os dois métodos para os modelos de redes neuronais .....	73
4.5.3.2	Comparação entre os dois métodos para os modelos de lógica Fuzzy.....	74
4.5.3.3	Comparação directa das interpolações entre as duas tecnologias .....	74
4.5.4	Interpolações para condições de Inverno.....	75

4.5.4.1	Gráficos das interpolações da primeira simulação .....	76
4.5.4.2	Gráficos das interpolações da segunda simulação .....	77
4.5.4.3	Gráficos das interpolações da terceira simulação .....	78
4.5.4.4	Observações aos resultados das interpolações para condições de Inverno .....	79
5.	Conclusões.....	81
6.	Bibliografia.....	83
Anexo I.....		85
I	Lista de modelos directos (Redes Neurais).....	85
II	Lista de modelos inversos (Redes Neurais).....	86
III	Lista de modelos directos (Lógica Fuzzy) .....	87
IV	Lista de modelos inversos (Lógica Fuzzy).....	88
Anexo II.....		91
	Diagrama do aparelho [2], em repouso, com as respectivas variáveis .....	91
Anexo III .....		93
	Rotina para modelos neuronais.....	93
	Rotina para modelos Fuzzy .....	96

## Lista de Figuras

Figura 1.1 Ilha do Pico, Açores (www.pico-owc.net) .....	4
Figura 1.2 Dispositivo em fase de imersão (Archimedes Wave Swing) .....	5
Figura 1.3 Dispositivo desenvolvido pela Ocean Power Delivery .....	5
Figura 1.4 Projecto em testes na costa da Dinamarca (Earth Vision).....	6
Figura 1.5 <i>PowerBuoy</i> (Ocean Power Technologies).....	6
Figura 1.6 <i>AquaBuoy</i> (Finavera Wind Energy) .....	7
Figura 1.7 <i>Oyster</i> (Aquamarine Power) .....	7
Figura 2.1 Esquema de uma rede neuronal [3] .....	9
Figura 2.2 Rede neuronal com entradas recorrentes ( <i>view(net2)</i> ) [3].....	10
Figura 2.3 Diagrama do algoritmo de aprendizagem [3].....	11
Figura 2.4 Rede neuronal com uma entrada igual à saída pretendida ( <i>view(net)</i> ) [3].....	12
Figura 2.5 Rede <i>Elman</i> ( <i>view(net)</i> ) [3].....	12
Figura 3.1 Dimensões do aparelho [2].....	17
Figura 3.2 Turbina Wells com posicionamento vertical [2] .....	18
Figura 3.3 $U$ : velocidade e direcção do fluxo de ar; $N$ : velocidade de rotação da turbina; $F_x$ : força axial; $F_\theta$ : força tangencial; $\alpha$ : ângulo de ataque do fluxo de ar; $W$ : velocidade relativa do fluxo de ar; $L$ : força de sustentação [2].....	19
Figura 3.4 Gráficos da força de radiação relativos à componente devida à interacção do aparelho consigo próprio .....	26
Figura 3.5 Gráficos da força de radiação relativos à componente devida à interacção do aparelho com a água do mar .....	26
Figura 3.6 Esquema das forças de pressão no interior [2] .....	31
Figura 3.7 Força de mola negativa [2].....	31
Figura 3.8 Identificação de modelo com um zero pelo método de Levy.....	33
Figura 3.9 Diagrama de Bode e diagrama de pólos e zeros.....	34
Figura 3.10 Valor das constantes físicas do aparelho .....	36
Figura 3.11 Valor das constantes físicas da turbina e das do mecanismo de transformação de energia.....	36
Figura 3.12 Valor das variáveis de ambiente.....	37
Figura 3.13 Valor dos parâmetros utilizados para gerar os perfis das ondas .....	37
Figura 3.14 Valor dos parâmetros de simulação .....	38

Figura 4.1 Modelo 28 (Neuronal): 6 atrasos na entrada, 2 atrasos na saída e 11 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente. ....	41
Figura 4.2 Modelo 28 (Neuronal): 4 atrasos na entrada, 7 atrasos na saída e 12 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente. ....	43
Figura 4.3 Modelo 29 (Neuronal): 3 atrasos na entrada, 5 atrasos na saída e 10 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente. ....	44
Figura 4.4 Modelo 22V4 (Neuronal): 1 atrasos na entrada, 6 atrasos na saída e 14 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente. ....	45
Figura 4.5 Modelo 25 (Neuronal): 2 atrasos na entrada, 2 atrasos na saída e 12 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente. ....	46
Figura 4.6 Modelo 26V3 (Neuronal): 5 atrasos na entrada, 2 atrasos na saída e 11 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente. ....	47
Figura 4.7 Modelo 27 (Neuronal): 7 atrasos na entrada, 6 atrasos na saída e 19 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente. ....	49
Figura 4.8 Modelo 50V3 (Fuzzy): 5 atrasos na entrada, 3 atrasos na saída, 0 atrasos puros e 2 <i>clusters</i> ....	52
Figura 4.9 Modelo 51 (Fuzzy): 1 atraso na entrada, 4 atrasos na saída, 0 atrasos puros e 4 <i>clusters</i> . ....	53
Figura 4.10 Modelo 48 (Fuzzy): 4 atraso na entrada, 3 atrasos na saída, 4 atrasos puros e 1 <i>cluster</i> .....	54
Figura 4.11 Modelo 49 (Fuzzy): 5 atrasos na entrada, 2 atrasos na saída, 0 atrasos puros e 3 <i>clusters</i> .....	55
Figura 4.12 Modelo 52 (Fuzzy): 4 atrasos na entrada, 3 atrasos na saída, 3 atrasos puros e 2 <i>clusters</i> .....	56
Figura 4.13 Modelo 53 (Fuzzy): 4 atrasos na entrada, 2 atrasos na saída, 4 atrasos puros e 4 <i>clusters</i> .....	57
Figura 4.14 Modelo 62 (Fuzzy): o perfil de velocidade varia entre 79 e 157 rad/s, com uma frequência entre 0,1 e 1 Hz (sinal do tipo <i>chirp</i> ) .....	59
Figura 4.15 Modelo 62 (Fuzzy): ampliação da imagem anterior entre os instantes 1000 e 1500 (devido ao período de amostragem de 0,05 s, equivalem a 50 s e 75 s, respectivamente). ....	59
Figura 4.16 Modelo 83 (Fuzzy): 2 atrasos na entrada, 3 atrasos na saída, 0 atrasos puros e 4 <i>clusters</i> .....	62
Figura 4.17 Diagrama do mecanismo de interpolação. A variável $h$ é obtida com o valor interpolado de $\zeta$ . ....	64
Figura 4.18 Diagrama do mecanismo de interpolação. A variável $h$ é obtida com os valores base de $\zeta$ ....	64
Figura 4.19 (Neuronal) Resultados do 1º método (N = 90 rad/s). ....	65
Figura 4.20 (Neuronal) Resultados do 2º método (N = 90 rad/s). ....	65
Figura 4.21 (Neuronal) Resultados do 1º método (N = 115 rad/s). ....	66
Figura 4.22 (Neuronal) Resultados do 2º método (N = 115 rad/s). ....	66
Figura 4.23 (Neuronal) Resultados do 1º método (N = 131 rad/s). ....	67

Figura 4.24 (Neuronal) Resultados do 2º método (N = 131 rad/s).	67
Figura 4.25 (Neuronal) Resultados do 1º método (N = 145 rad/s).	68
Figura 4.26 (Neuronal) Resultados do 2º método (N = 145 rad/s).	68
Figura 4.27 (Fuzzy) Resultados do 1º método (N = 90 rad/s).	69
Figura 4.28 (Fuzzy) Resultados do 2º método (N = 90 rad/s).	69
Figura 4.29 (Fuzzy) Resultados do 1º método (N = 115 rad/s).	70
Figura 4.30 (Fuzzy) Resultados do 2º método (N = 115 rad/s).	70
Figura 4.31 (Fuzzy) Resultados do 1º método (N = 131 rad/s).	71
Figura 4.32 (Fuzzy) Resultados do 2º método (N = 131 rad/s).	71
Figura 4.33 (Fuzzy) Resultados do 1º método (N = 145 rad/s).	72
Figura 4.34 (Fuzzy) Resultados do 2º método (N = 145 rad/s).	72
Figura 4.35 Interpolação com Redes Neurais para $H_s = 3,2$ m	76
Figura 4.36 Interpolação com Lógica Fuzzy para $H_s = 3,2$ m	76
Figura 4.37 Interpolação com Redes Neurais para $H_s = 3,2$ m	77
Figura 4.38 Interpolação com Lógica Fuzzy para $H_s = 3,2$ m	77
Figura 4.39 Interpolação com Redes Neurais para $H_s = 3,2$ m	78
Figura 4.40 Interpolação com Lógica Fuzzy para $H_s = 3,2$ m	78

## Lista de Tabelas

Tabela 4.1 Modelo 28 (Neuronal) .....	43
Tabela 4.2 Modelo 29 (Neuronal) .....	44
Tabela 4.3 Modelo 22V4 (Neuronal) .....	45
Tabela 4.4 Modelo 25 (Neuronal) .....	46
Tabela 4.5 Modelo 26V3 (Neuronal) .....	47
Tabela 4.6 Modelo 27 (Neuronal) .....	48
Tabela 4.7 Modelo 50V3 (Fuzzy).....	52
Tabela 4.8 Modelo 51 (Fuzzy) .....	53
Tabela 4.9 Modelo 48 (Fuzzy) .....	54
Tabela 4.10 Modelo 49 (Fuzzy) .....	55
Tabela 4.11 Modelo 52 (Fuzzy) .....	56
Tabela 4.12 Modelo 53 (Fuzzy): 4 atrasos na entrada, 2 atrasos na saída, 4 atrasos puros e 4 <i>clusters</i> . ....	57
Tabela 4.13 Valor do melhor desempenho, respectivamente, do conjunto de modelos entre o 68 e o 75..	60
Tabela 4.14 Modelo 83 (Fuzzy) .....	62
Tabela 4.15 Comparativo dos resultados das interpolações .....	73
Tabela 4.16 Desempenho dos modelos de base com dados de validação.....	73
Tabela 4.17 Comparativo dos resultados das interpolações .....	74
Tabela 4.18 Desempenho dos modelos de base com dados de validação.....	74
Tabela 4.19 Comparação entre as duas tecnologias .....	74
Tabela 4.20 Valores obtidos por uma bóia colocada ao largo de Leixões.....	75
Tabela 4.21 Comparação de resultados das interpolações (N = 131 rad/s, Hs = 3,2 m).....	79

## Lista de abreviações

AWS (*Archimedes Wave Swing*)

CAO (*Coluna de Água Oscilante*)

FFT (*Fast Fourier Transform*)

(iFFT) (*inverse Fast Fourier Transform*)

ID (*Input Delay*)

IMC (*Internal Model Control*)

LF (*Lógica Fuzzy*)

MSE (*Mean Square Error*)

NACA (*National Advisory Committee for Aeronautics*)

NaN (*Not a Number*)

NARX (*Nonlinear AutoRegressive network with eXogenous inputs*)

NN (*Neural Network*)

OD (*Output Delay*)

OWC (*Oscillating Water Column*)

PTO (*Power Take-off*)

TS (*Takagi-Sugeno*)

VAF (*Variance Accounted For*)

WavEC (*Wave Energy Centre*)

## **Prefácio**

Com o objectivo de desenvolver um controlador de um aparelho específico para extracção de energia das ondas, através de modelos alcançados com recurso a duas tecnologias alternativas, Redes Neurais e Lógica Fuzzy, o presente trabalho segue a estrutura seguinte:

**Capítulo 1:** Apresenta os objectivos do trabalho, bem como a energia associada às ondas e alguns dos diversos modelos existentes e o respectivo tipo de classificação.

**Capítulo 2:** Refere o estado da arte, relativamente às duas tecnologias utilizadas para a pesquisa de modelos, fazendo uma apresentação genérica dos respectivos princípios de funcionamento e de algumas das técnicas de aprendizagem.

**Capítulo 3:** Apresenta a descrição do aparelho, com medidas específicas e o respectivo modelo matemático, assente na análise das forças envolvidas, responsável pelos consequentes conjuntos de valores obtidos por simulação e que servem de ponto de partida para a pesquisa de modelos.

**Capítulo 4:** Apresenta as rotinas desenvolvidas para a modelação do aparelho, com as várias fases associadas, tanto para os modelos directos como para os inversos. Reporta o bom desempenho alcançado pelos modelos directos, bem como o contrário, relativamente aos modelos inversos, para cada uma das tecnologias. Mostra os resultados e os respectivos gráficos do sistema de interpolação desenvolvido com base em modelos obtidos para velocidades fixas da turbina, fazendo-se a comparação entre os índices de desempenho relativos a cada uma das tecnologias.

**Capítulo 5:** Conclusões sobre o trabalho desenvolvido e observações em relação ao trabalho futuro.

**Anexo I:** Apresenta sequencialmente, em forma tabelar, as características das diversas tentativas realizadas ao longo deste trabalho, assentes, essencialmente, nas características da velocidade da turbina.

**Anexo II:** Diagrama do aparelho com as variáveis respectivas.

**Anexo III:** Código de programação em Matlab de duas rotinas desenvolvidas para pesquisa de modelos com Redes Neurais e Lógica Fuzzy; o código refere-se a modelos com entradas compostas.

## Contribuições

O autor espera que este trabalho contribua de forma construtiva para o estudo do controlo deste aparelho, através da modelação desenvolvida com base nas tecnologias de Redes Neurais e Lógica Fuzzy que, de resto, representa uma abordagem pioneira na caracterização deste dispositivo. Aliás, o autor está convicto, tanto quanto é do seu conhecimento, que a Lógica Fuzzy foi utilizada pela primeira vez na modelação de um conversor de energia das ondas.

Partindo de uma premissa que pretendia utilizar uma estratégia de controlo do tipo IMC, que assenta no conhecimento dos modelos directos e inversos, será de esperar que as tentativas exaustivas realizadas sejam determinantes para validar a impossibilidade de alcançar uma estratégia de controlo deste tipo, uma vez que não se conseguiram obter modelos inversos do aparelho, com base nas variáveis escolhidas, conforme se refere ao longo do texto.

Alternativamente, face à elevada qualidade evidenciada pelos modelos directos, será de esperar uma enorme probabilidade de sucesso através de uma estratégia de controlo preditivo. No entanto, devido à considerável morosidade do processo de pesquisa (quase 40.000 modelos e cerca de 23 Gb de espaço em disco, no total) e à inexorabilidade do prazo de entrega, o autor lamenta que estas circunstâncias o tenham condicionado ao ponto de inviabilizar o desenvolvimento desta estratégia.



# 1. Objectivo

Contrariamente ao que se verifica na área da extracção de energia eólica, onde existe uma consolidação tecnológica à volta de um único modelo, na área da energia das ondas observa-se uma miríade considerável de projectos, alguns mais conseguidos e viáveis, que pretende responder eficazmente às condições mais adversas do meio ambiente. Refira-se, a propósito, que este projecto representa mais um dos casos, dado que é uma das soluções em estudo que o Centro de Energia das Ondas pretende patentear.

Seguindo os trilhos desenvolvidos em trabalhos anteriores, pioneiros na área da extracção de energia das ondas, o presente trabalho baseia-se no modelo matemático de um conversor de energia das ondas, do tipo de absorção pontual, desenvolvido pelo *Wave Energy Center*, tal como apresentado na tese *Modelling and Control of a Wave Energy Converter* [2], do meu colega Guilherme Nunes, e pretende explorar a vertente de controlo do dispositivo, através de técnicas inteligentes e não convencionais, de forma a minimizar as variações da produção de energia a injectar na rede pública de abastecimento eléctrico, incidindo no comando da velocidade de rotação da turbina através de um esquema de controlo do tipo IMC (*Internal Model Control*). Com este propósito, realizaram-se várias tentativas de modo a encontrar modelos de caracterização do aparelho recorrendo às técnicas de identificação proporcionadas pelas ferramentas de *Redes Neurais* [3] e de *Lógica Fuzzy* [4] existentes no ambiente do programa *Matlab*.

## 1.1 Energia das ondas

O potencial energético contido nos oceanos é, de há muito, bem conhecido, embora tenha sido o primeiro choque petrolífero, ocorrido em meados de 1970 [5], o principal responsável pelo despertar da consciencialização global sobre a importância primordial do papel que esta fonte de energia poderia desempenhar na sustentação do nível de vida da sociedade actual, com a vantagem acrescida de ser um tipo de energia limpa; este último aspecto é, igualmente, de extrema importância em termos de impacte ambiental e na preservação ecológica do nosso planeta.

As ondas devem-se, essencialmente, às interferências provocadas na superfície do mar pelo vento, o qual, por sua vez, é originado pelo sol, através do aquecimento das massas de ar. Devido a um fenómeno de capilaridade, que se traduz numa força de coesão entre as moléculas da água, a superfície do mar oferece uma certa resistência ao vento que actua sobre ela, provocando um arrastamento e uma subida simultânea, que origina a formação das ondas. Por sua vez, quanto maior for a elevação, maior é a superfície de exposição das ondas ao vento e maior será o seu desenvolvimento. Este efeito progressivo, no entanto, termina no momento em que a razão entre a altura e o comprimento de onda ultrapassa o valor 1:7, uma vez que a onda colapsa, por efeito da gravidade.

Estima-se que o potencial energético das ondas em todo o planeta seja de 10 TW, sensivelmente, embora se considere viável, apenas, o aproveitamento de 2 TW; a magnitude deste valor é de tal modo significativa que dava para providenciar as actuais exigências globais de energia eléctrica de todo o

mundo. Sabe-se que a potência energética de uma onda é proporcional ao seu período e ao quadrado da sua amplitude. Ondas de amplitude considerável, na ordem dos 2 m, com períodos entre os 7 e os 10 s, excedem, normalmente, os 50 kW por metro de frente de onda [1]. Segundo estudos realizados sobre o perfil das ondas ao longo da costa portuguesa, a média anual de 40 kW é um valor deveras significativo em termos de balanço custo/benefício, tornando o aproveitamento e a exploração deste tipo de energia no nosso país, que dispõe de uma apreciável extensão de costa, uma solução particularmente atractiva, sem contar com os recursos, igualmente benéficos, das nossas ilhas; por outro lado, para o caso das ilhas, especificamente, este tipo de sistemas de aproveitamento de energia poderá representar uma forma de contornar as dificuldades e os custos energéticos acrescidos causados pela insularidade, tornando o balanço custo/benefício ainda mais favorável. Desde muito cedo, Portugal tem sido um dos países pioneiros na abordagem deste potencial energético, traduzindo-se num dos principais e mais activos fomentadores do desenvolvimento tecnológico específico [6]. A quantidade apreciável de teses de mestrado e doutoramento, bem como de artigos científicos, reflectem sobremaneira o interesse que esta via energética desperta num país com uma enorme orla costeira, tornando-se premente o desenvolvimento de soluções tecnológicas robustas e suficientemente amadurecidas, de modo a promoverem e viabilizarem a sua sustentação económica.

### 1.1.1 Caracterização da energia das ondas

Na tentativa de simplificar o estudo, as ondas são apresentadas como sinusoidais puras, caracterizadas pela amplitude,  $A$ , pelo período,  $T$ , e pela sua superfície livre,  $\eta$  [5].

$$\eta = A \cos(\omega t - kx) \quad (1.1)$$

$\omega = 2\pi/T$ , é a frequência da onda;  $t$  é o tempo;  $x$  é o ponto do espaço na direcção de propagação da onda;  $k=2\pi/L$  é o número de onda ( $L$  é o comprimento da onda), relacionado com a frequência e a profundidade da água no local,  $h$ , pela seguinte expressão:

$$k = \frac{\omega^2}{g} \coth(kh) \quad (1.2)$$

$g$  é a aceleração da gravidade.

As ondas reais, no entanto, não são sinusoidais puras, embora se possam considerar como a soma de um número infinito de sinusóides, com amplitude infinitesimal e frequência correspondente a um certo espectro de onda, que permite obter a quantidade de energia transportada pelas ondas.

Qualquer problema de engenharia, entre outros, que envolva a aplicação de cálculos sobre o perfil das ondas, assenta em observações e dados estatísticos, nomeadamente o espectro de Pierson-Moskowitz, por exemplo. Estes dois investigadores realizaram imensas observações em variadíssimos pontos do planeta e conseguiram determinar um dos espectros mais simples, dependente, apenas, da altura significativa,  $H_s$  [7], conforme se explica a seguir.

$$S(\omega) = \frac{\alpha g^2}{\omega^5} \exp\left(-\beta \left(\frac{\omega_0}{\omega}\right)^4\right) \quad (1.3)$$

$\alpha=8,1 \times 10^{-3}$ ;  $\beta=0,74$ ;  $\omega_0=g/U_{19,5}$ ;  $U_{19,5}$  é a velocidade do vento a uma altura de 19,5 m acima da superfície do mar.

$$S(\omega) = 8,1 \times 10^{-3} g^2 \omega^{-5} \exp\left(\frac{-3,11}{H_s^2} \omega^{-4}\right) \quad (1.4)$$

Este espectro foi introduzido em 1964 e manteve-se como referência por muito tempo, embora seja particularmente significativo para condições de mar desenvolvido, ou seja, sempre que o vento sopra durante bastante tempo sobre uma área considerável de modo a que exista um certo equilíbrio entre o vento e o mar. Nestas condições,  $H_s$  representa a altura média, desde a garganta até à crista, de 1/3 das ondas que apresentaram maior altura; em 120 medições, por exemplo, faz-se a média das 40 ondas com maior altura.

Existem, actualmente, outros espectros capazes de simular o estado do mar sujeito a condições de vento mais agrestes, nomeadamente o espectro de Goda, que depende de dois parâmetros,  $H_s$  e  $T_e$  (período de energia), mas neste trabalho, especificamente, foram utilizados apenas dados gerados para condições de ondas irregulares com base no espectro de Pierson-Moskowitz.

Ao propagar-se, a onda transporta consigo um fluxo de energia que é proporcional ao período da onda e ao quadrado da sua amplitude; a altura da onda, isto é, do pico à cava, é igual ao dobro da sua amplitude,  $H=2A$ . Os sistemas de extracção de energia das ondas, devido à sua natureza dinâmica, são muito sensíveis ao período da onda e a sua eficiência máxima ocorre quando a onda incidente apresenta uma frequência igual à da sua própria velocidade de oscilação [8]. Da relação existente entre a frequência e o comprimento de onda, enunciada em (1.2), pode inferir-se, igualmente, uma relação entre o comprimento de onda e a dimensão do próprio sistema para uma extracção de energia eficiente; quanto maior for o afastamento da frequência, e do comprimento de onda, em relação ao valor óptimo, menor será a eficiência da extracção de energia. A direcção de propagação da onda, relativamente ao dispositivo, também se repercute na eficiência, sendo evidente a vantagem, nesta perspectiva, dos sistemas que apresentem simetria axial, como é o caso do aparelho analisado neste trabalho.

## 1.2 Classificação dos sistemas de extracção

Com incidência, predominantemente, nas últimas décadas, a ideia do aproveitamento da energia das ondas tem conduzido ao aparecimento de um variadíssimo leque de soluções, que se apresentam, respectivamente, com maior ou menor grau, em diferentes patamares de desenvolvimento. Para a sua classificação, os critérios apresentados pela *Wavenet*, em 2003, com base no local de instalação, têm sido os que conseguiram melhor aceitação. Assim, é vulgar a seguinte designação: dispositivos sobre a costa, ou de primeira geração; dispositivos próximos da costa, ancorados em locais com profundidades entre os 10 e os 25 m, ou de segunda geração; dispositivos ao largo, ancorados em locais com profundidades na

ordem dos 50 m, ou de terceira geração. A terminologia inglesa é, respectivamente, *onshore*, *nearshore* e *offshore*.

Qualquer um destes sistemas apresenta vantagens e desvantagens específicas que concorrem para a sua empregabilidade. Os sistemas costeiros apresentam vantagens significativas em termos de implantação, manutenção, acessibilidade e ausência de amarras, embora tenham algumas restrições quanto à localização, ao maior impacte ambiental e uma potência mais fraca, devido aos fenómenos dissipativos que ocorrem na rebentação e pelo atrito presente entre a água e o fundo do mar; dos vários sistemas conhecidos, o de *Coluna de Água Oscilante (CAO)* é o mais investigado e utilizado [9], porque, em grande medida, beneficia do estudo hidrodinâmico desenvolvido para o comportamento de navios na ondulação do mar, que é muito similar [10]. Os outros dois tipos de sistemas, embora com um nível de potência mais elevado, apresentam maiores custos de implementação/exploração e levantam alguns transtornos em termos de navegabilidade. Há, no entanto, um factor extremamente benéfico, comum a todos eles, que se traduz no “combustível”, natural e gratuito, que impulsiona estes mecanismos.

Existem, no entanto, outros processos de classificação dos dispositivos, nomeadamente, segundo o mecanismo de captura de energia das ondas [11]. As seguintes classificações são representativas da maior parte dos dispositivos existentes, actualmente: atenuador (posicionamento paralelo à direcção das ondas), terminador (posicionamento perpendicular à direcção das ondas), absorvedor pontual (dimensões desprezáveis face ao comprimento de frente das ondas), diferencial de pressão submersa e aparelho de galgamento.

### 1.2.1 Exemplos de aparelhos mais desenvolvidos



**Figura 1.1 Ilha do Pico, Açores**  
([www.pico-owc.net](http://www.pico-owc.net))

As colunas de água oscilante (em inglês, *oscillating water column [OWC]*), são dispositivos do tipo absorvedor pontual que estão parcialmente submersos e dispõem de uma abertura inferior para o mar, destinada a admitir os fluxos de água reversíveis, originados pelo movimento oscilatório das ondas, que transmitem, por sua vez, o seu movimento cíclico a uma coluna de ar existente numa câmara colocada na parte superior e que tem acoplada, geralmente, uma turbina do tipo Wells [12], a qual, por sua vez, se encontra ligada a um gerador eléctrico. Este tipo de dispositivo pode funcionar em instalações sobre a costa ou ao largo, como é o caso do aparelho flutuante de simetria cilíndrica que é objecto de estudo no presente trabalho. Em termos de captura de energia, no primeiro estágio, este tipo de dispositivo converte o movimento das ondas, através da interface água/ar, em energia pneumática dentro da câmara-de-ar. Estudos mais recentes, têm sugerido a utilização de mais do que uma turbina, com dimensões mais reduzidas, colocadas axialmente em cascata, de modo a otimizar a eficiência dos dispositivos. Por outro lado, embora seja possível utilizar uma interface hidráulica no PTO (*Power Take-off*), a maior parte dos dispositivos deste género utilizam a pneumática.

A título de curiosidade, a instalação existente na ilha do Pico foi uma das pioneiras e é uma das poucas a funcionar em condições reais, conseguindo injectar energia na rede eléctrica local.



**Figura 1.2 Dispositivo em fase de imersão (Archimedes Wave Swing)**

O *Archimedes Wave Swing (AWS)*, é um dispositivo de absorção pontual assente no fundo do mar. Fica completamente submerso e funciona através da pressão exercida pela coluna de água, com altura variável, que se forma devido à passagem das ondas sobre o aparelho. A campânula envolvente, actua tipo êmbolo, igualmente, sobre uma câmara-de-ar, que se vai comprimindo e descomprimindo, dando origem a um movimento vertical. É a partir deste movimento, que se consegue extrair a energia eléctrica, através de um mecanismo hidráulico ou electromecânico.

A figura apresenta a versão original do dispositivo, no momento em que era feita a colocação no local de funcionamento. Este modelo, em particular, passou por algumas dificuldades de instalação e, hoje em dia, deu lugar a uma versão bastante melhorada.



**Figura 1.3 Dispositivo desenvolvido pela Ocean Power Delivery**

O *Pelamis* é um dispositivo flutuante articulado, do tipo atenuador, composto por vários módulos longitudinais, que fica semi-submerso e com um alinhamento perpendicular em relação à frente de progressão da onda. A energia mecânica é obtida nas articulações, devido à passagem da onda que vai sendo acompanhada sucessivamente pelos vários módulos, originando um movimento desfasado entre eles. O movimento relativo da junta entre dois elementos seguidos é aproveitado, por elementos hidráulicos, geralmente, para converter a oscilação em energia mecânica, a qual, por sua vez, é convertida em energia eléctrica através de um motor hidráulico. A primeira fase de captura de energia deve-se ao princípio de flutuação dos corpos para dar origem à transmissão do movimento realizado pelos cilindros hidráulicos instalados nas articulações. Como a quantidade de energia captada está relacionada com a inclinação dos cilindros e do movimento relativo entre os elementos, cada projecto pode ser optimizado em função do nível energético médio do local da instalação.



**Figura 1.4 Projecto em testes na costa da Dinamarca (Earth Vision)**

conversor da energia das ondas é semelhante ao utilizado pelas centrais de produção hídrica convencionais. A título de curiosidade, refira-se que foi o primeiro dispositivo *offshore* do mundo, para extracção de energia das ondas em funcionamento real, conseguindo injectar energia na rede eléctrica.

Os braços situados lateralmente, em relação à plataforma central, destinam-se a acondicionar e dirigir o caudal de água, optimizando as condições de galgamento. Numa primeira fase de captura de energia encontra-se este mecanismo de conversão de energia cinética em energia potencial, que depois é transformada no movimento mecânico da turbina hidráulica. Verificou-se que a utilização de várias turbinas, em vez de uma, apenas, traz enormes vantagens segundo diversos aspectos, nomeadamente, ao nível do rendimento e da própria manutenção. Embora esteja relacionado com a capacidade e a potência pretendidas para o projecto, fizeram-se estudos experimentais em que se utilizaram várias turbinas mais pequenas, do tipo Kaplan, ligadas directamente a geradores do tipo PMG (*Permanent Magnet Generator*), de modo a minimizar a percentagem de perdas na transformação de energia [13].

O *Wave Dragon* pertence à classe dos dispositivos de galgamento (em inglês, *overtopping devices*). Estes aparelhos, fixos ou flutuantes, recolhem a água do mar num reservatório situado num nível superior, de modo a aumentar a energia potencial associada à sua massa, despejando-a depois para o mar, através de um canal com uma turbina de baixa queda, do tipo Pelton; o princípio de funcionamento deste tipo de

## 1.2.2 Outros modelos em fase de implementação



**Figura 1.5 PowerBuoy (Ocean Power Technologies)**

pelo recente furacão *Irene*, que tantos danos e prejuízos causou à sua passagem.

*PowerBuoy*, dispositivo flutuante do tipo absorvedor pontual, específico para trabalhar ao largo da costa. O princípio base de funcionamento é muito próximo do aparelho em estudo, devido ao movimento vertical de uma bóia, que oscila livremente, e é convertido em energia eléctrica. O processo utiliza um cabo submarino para transporte da energia para terra. A título de curiosidade, a empresa Ocean Power Technologies, responsável pelo desenvolvimento do aparelho, ficou deveras satisfeita pelo facto do exemplar que colocou em funcionamento na costa de New Jersey, em Abril de 2011, ter conseguido suportar as condições extremamente adversas provocadas



**Figura 1.6 AquaBuoy**  
(Finavera Wind Energy)

*AquaBuoy*, um aparelho de características muito idênticas ao anterior. Consiste numa bóia circular de movimento vertical com um tubo vertical submerso, designado por tubo de aceleração. O movimento relativo entre a bóia e a massa de água contida no tubo é transferido para um sistema de conversão, localizado na parte superior, através de um cilindro existente no tubo.



**Figura 1.7 Oyster**  
(Aquamarine Power)

O *Oyster*, na classe *Oscillating Wave Surge Converter*, é um dos aparelhos para extracção de energia das ondas de maiores dimensões. Utilizado a pequenas profundidades, na ordem dos 10 m, é colocado de frente para o sentido das ondas de modo a funcionar como uma barreira, que gira sobre um eixo charneira na parte inferior e que actua sobre um êmbolo de água através de uma conduta de alta pressão, canalizada até à costa. Os componentes com movimento mecânico são mínimos e a parte eléctrica encontra-se toda em terra, garantindo uma boa robustez ao aparelho, para além de viabilizar o projecto economicamente face à redução de custos de manutenção.

### 1.3 Considerações sobre a viabilização económica dos projectos

Em termos de optimização e viabilização dos projectos, o mecanismo de captura de energia com a consequente transformação em energia eléctrica, passando pela fase de entrega final na rede eléctrica, também tem uma percentagem determinante [14, 15]. A utilização de componentes hidráulicos, bem como de turbinas, é particularmente interessante no campo da conversão de energia das ondas, dado que se trata da recuperação dos altos níveis energéticos contidos nas ondas, mas com velocidades relativamente baixas, na ordem de 1 m/s, que precisam de ser aumentadas para uma ordem de grandeza dos 100 m/s, que é um valor característico dos geradores eléctricos.

Por outro lado, face às variações significativas observadas nos estados energéticos do mar, por vezes quase instantâneas e pontuais [10], uma das formas de otimizar os mecanismos de extracção/conversão da energia é através do recurso a acumuladores mecânicos, de gás, químicos ou eléctricos, entre outras possibilidades, de modo a garantir um funcionamento mais regular, mesmo que seja por períodos curtos de tempo; neste aspecto, tem-se registado um ligeiro ascendente no desempenho do aparelho *Wave Dragon*, pelo simples facto de utilizar um acumulador energético que representa o próprio princípio de funcionamento, garantindo-lhe um funcionamento mais regular e com uma possibilidade de controlo mais simples.

Em relação ao aspecto de controlo, consegue-se uma melhoria considerável, de uma ordem de grandeza acima, através deste recurso, embora esta área ainda não esteja completamente explorada e represente, precisamente, uma das que regista maior interesse e actividade. A simplificação e linearização dos modelos matemáticos, que se verifica apenas para estados energéticos do mar mais fracos, com alturas significativas de ondas mais baixas [16], assim como a modelação das próprias turbinas, que apresentam um regime linear apenas com velocidades mais baixas, levanta algumas dificuldades à sua realização e estudo.

Se considerarmos, ainda, a adição do sistema final de rectificação, necessário para disponibilizar a energia eléctrica na rede de consumo, facilmente se percebe a importância do mecanismo de PTO na implementação do projecto, para além do tipo de solução que se considere.

## 2. Estado da arte

### 2.1 Redes Neurais

As redes neuronais são uma das mais recentes e promissoras tecnologias, entre outras, na área do controlo de sistemas, inspirando-se no comportamento biológico do sistema nervoso e que tenta simulá-lo através de uma representação matemática, composta por um conjunto de elementos com funcionamento em paralelo e ligados entre si por factores de peso, podendo apresentar uma gama variada de arquitecturas, consoante o tipo de problema em estudo, conseguindo oferecer resultados plenamente satisfatórios em diversas áreas, incluindo aquelas em que o uso das ferramentas tradicionais se revela de difícil implementação ou impossível de todo [17, 18]. A sua enorme versatilidade e eficácia no modo de ultrapassar as imprecisões da informação e as não linearidades dos processos, através de uma aprendizagem cuidada, concorrem para que esta tecnologia se apresente como uma solução extremamente interessante de equacionar nas modernas vertentes do controlo [19]. A figura seguinte esquematiza a estrutura de uma rede neuronal com uma camada e  $S$  neurónios. A entrada, representada por  $p_i$ , é formada por  $R$  vectores com os valores para os quais se quer determinar a resposta da rede;  $w$  é uma matriz destinada a guardar os pesos que vão afectar o valor das entradas determinando o desempenho da rede;  $b$  é um valor de sintonia fina, *bias*, que otimiza o desempenho da rede, através de um peso ajustável que se multiplica por esta entrada, geralmente unitária;  $f$  representa uma função de activação da camada em que se encontra e apresenta variadas formas, consoante o propósito da rede e a posição que ocupa dentro dela;  $a_i$  simboliza a saída da rede, o valor que se pretende estimar e que é o objectivo da rede.

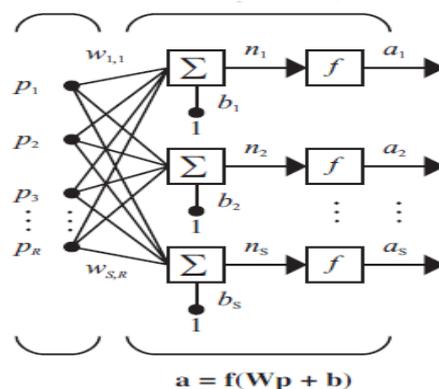
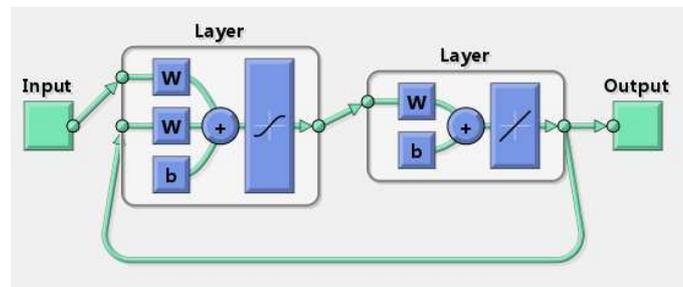


Figura 2.1 Esquema de uma rede neuronal [3]

As redes neuronais conseguem responder de forma eficaz a problemas de grande complexidade e a uma ampla variedade de situações, contemplando áreas como a identificação, a classificação ou o reconhecimento de padrões. O sucesso da sua aplicação passa, essencialmente, pela arquitectura da

estrutura escolhida, que engloba o dimensionamento do número de neurónios e de camadas a utilizar, da escolha criteriosa das variáveis envolvidas e da qualidade do treino a que se sujeita a rede. O ajustamento dos pesos entre as ligações dos neurónios, através de funções de activação específicas, obtido na fase de aprendizagem do modelo para o tipo de arquitectura escolhida, é a premissa fulcral e determinante para o tipo de resposta que a rede vai devolver e do nível qualitativo dos resultados, em função das entradas a que for sujeita.

Existem dois tipos básicos de estruturas de redes neuronais: estáticas e dinâmicas. O segundo tipo, o que importa para o presente trabalho, assenta, essencialmente, na utilização de variáveis de entrada sequenciais, isto é, que caracterizam eventos ou ocorrências sucessivas no tempo, podendo, inclusivamente, haver um certo número de atrasos, tanto das variáveis de entrada como da saída, em que a saída actual é calculada através de entradas anteriores e da própria saída calculada em instantes passados (*feedback*). Esta situação é visível na figura seguinte (obtida com o comando *view(net2)* do Matlab):



**Figura 2.2** Rede neuronal com entradas recorrentes (*view(net2)*) [3]

Facilmente se percebe que a saída actual, calculada pela rede, é reintroduzida na entrada para calcular a saída num instante posterior, que passa a ser, nessa altura, a saída actual e assim sucessivamente até ao fim dos dados; este tipo de funcionamento da rede pode ser utilizado em metodologias que envolvam acções de controlo preditivo, pois permite estimar a saída do dispositivo em instantes posteriores pré-determinados. O facto da função de activação da camada exterior ser linear garante que a saída não seja limitada e possa tomar um valor qualquer, ao passo que a função não linear da camada interna permite que a rede reconheça as relações lineares ou não lineares existentes entre as variáveis de entrada e de saída. A imagem apresenta uma realimentação da última camada para a primeira, mas pode haver, também, configurações de redes com realimentações de camadas internas para a primeira camada; além do mais, pode, inclusivamente, dar-se o caso em que a realimentação é feita com atraso, ou seja, utilizando valores de um ou mais instantes anteriores, como é característico das redes com dinâmica.

O treino da rede é de extrema importância, uma vez que permite criar uma cadeia de pesos e uma malha de relações que, no final, permanecerá fixa e que terá, idealmente, a capacidade de recriar a saída o mais correctamente possível, independentemente da diversidade das entradas (conceito de generalização da rede). É importante sujeitar o treino da rede a um conjunto significativo de dados, que especifique uma amostra credível do universo possível, pois só assim se conseguirá garantir um bom desempenho da rede.

O processo de treino está esquematizado, em abstracto, na figura seguinte

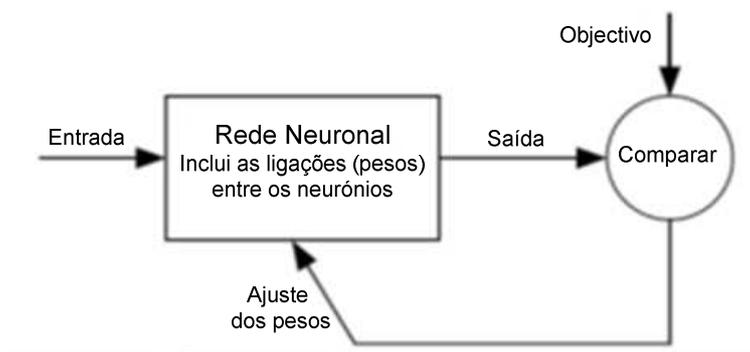


Figura 2.3 Diagrama do algoritmo de aprendizagem [3]

O algoritmo de treino está dependente da forma como este se desencadeia, incremental ou em conjunto (*batch*). No primeiro caso, os pesos são calculados e recalculados por cada valor da entrada, enquanto no segundo, apenas são calculados no final do conjunto de dados e recalculados no final de um novo ciclo (*época*) com os dados de treino, até que se atinja um limite de épocas ou um critério de paragem estabelecido, assente num processo de gradiente descendente (*backpropagation*). Para o tipo de redes dinâmicas, usa-se, habitualmente, o treino em *batch*, com o algoritmo de Levenberg-Marquardt, por ser o mais rápido, no qual o critério de desempenho da rede se baseia na média do quadrado do erro, *MSE*, sendo este a diferença entre a saída real e a calculada.

$$MSE = \frac{1}{N} \times \sum_{i=0}^{i=N} (y_i - \hat{y})^2 \quad (2.1)$$

A estrutura das redes neuronais admite uma versatilidade apreciável, com vista ao tipo de problema que se pretenda resolver, mas passa, essencialmente, pela existência de uma ou mais camadas internas, consoante a complexidade do problema, e uma externa ou de saída. No entanto, atendendo ao que se refere em [3] ou ao conhecimento da comunidade científica, obtido através da realização de diversos estudos, uma rede neuronal com uma camada interna e uma externa pode ser treinada para obter, com grande sucesso, qualquer tipo de função com um número finito de discontinuidades, pressupondo que existe um número suficiente de neurónios na camada interior.

A abordagem ao estudo e identificação do presente dispositivo baseou-se numa *aprendizagem supervisionada*, uma vez que se dispunha do modelo matemático do aparelho, com as respectivas equações físicas que o caracterizam, e dos valores das variáveis de entrada e de saída envolvidas. Este tipo de treino assume-se como uma técnica de optimização da aprendizagem, dado que permite que a rede se ajuste de modo a que os resultados que produz sejam confrontados com os valores reais produzidos pelo dispositivo. Esta configuração, que se designa por *série-paralela*, uma vez que a saída é dada como entrada, pode ser visualizada na Figura 4. No final da fase de aprendizagem, a rede é transformada numa configuração paralela que mantém a estrutura de pesos obtida durante o treino.

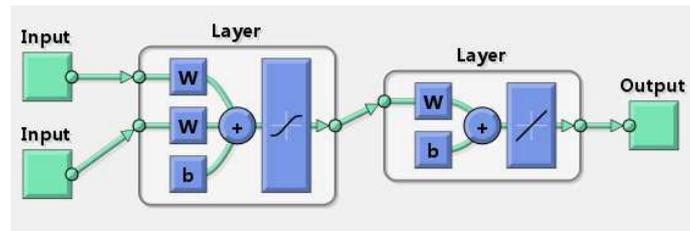


Figura 2.4 Rede neuronal com uma entrada igual à saída pretendida (*view(net)*) [3]

Das várias técnicas possíveis, dado que se está na presença de um dispositivo com memória, ou dinâmica, em que é preciso saber qual o estado das variáveis e também a evolução dos seus valores anteriores, ou passado, a pesquisa baseou-se no desenvolvimento de modelos construídos com funções *NARX* (*nonlinear autoregressive network with exogenous inputs*), definidos pela equação

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)) \quad (2.2)$$

A saída actual,  $y(t)$ , é calculada por regressão dos próprios valores passados e de uma sucessão de valores de uma entrada independente, exógena,  $u(t)$ .

As redes do tipo *Elman* também se adaptam particularmente bem à modelação do dispositivo em estudo e foram pontualmente utilizadas, mas os resultados obtidos não evidenciaram qualquer vantagem em relação às redes *NARX*, bem pelo contrário, uma vez que o desempenho da rede foi sempre inferior e o tempo de computação foi sistemática e significativamente superior. Esta característica das redes *Elman* está relacionada com o facto de utilizar, recorrentemente, como uma das entradas o valor estimado na camada interior e não o valor real, previamente conhecido, que se obteria à saída da rede, conforme se pode observar na Figura 2.5.

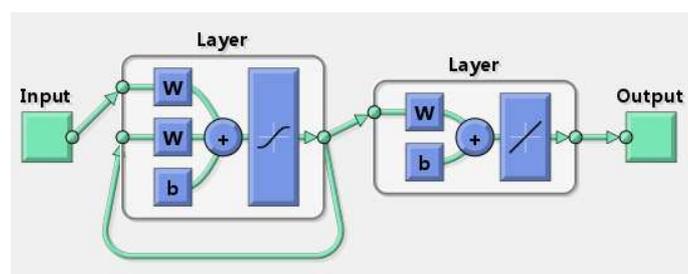


Figura 2.5 Rede *Elman* (*view(net)*) [3]

No entanto, esta característica das redes *Elman*, que para um treino *off-line*, com dados previamente conhecidos, degrada a qualidade dos resultados, concorre sobremaneira para um desempenho mais optimizado em situações de controlo preditivo ao guardar nos parâmetros da rede informação sobre a evolução dos estados anteriores do processo.

## 2.2 Lógica Fuzzy

A lógica Fuzzy, à semelhança das redes neuronais, tem granjeado uma enorme atenção por parte da comunidade científica, em geral, e da indústria, em particular, pela forma simples e eficiente com que permite estabelecer um conjunto de declarações, designadas por regras, baseando-se na linguagem humana comum e no conhecimento empírico, para a definição dos mais variados problemas [20, 21]. Partindo de um leque de declarações do tipo “*se-então*” constrói relações com um certo grau de incerteza entre as variáveis envolvidas no processo, capazes de caracterizar qualitativamente o modelo a estudar; no fundo, trata de fazer a correspondência entre um espaço de entradas para um espaço de saídas, através de declarações relacionadas com as variáveis do processo e um conjunto de adjectivos complementar que estabelece e caracteriza as grandezas respectivas. As variáveis de entrada e as regras que as caracterizam formam o conjunto de *antecedentes*, enquanto para a saída, por paralelismo, tem-se o conjunto de *consequentes*.

Conseguindo dar resposta a um leque amplo de problemas, a mais-valia da lógica Fuzzy prende-se com o nível de imprecisão e a facilidade de interpretação das directivas, antecedentes/consequentes, envolvidas na definição do problema e do objectivo a alcançar; os limites não são taxativos, nem existe o conceito redutor e intransigível do “verdadeiro” ou “falso”, abrindo espaço ao critério do “parcialmente verdadeiro”, com um certo grau de pertença a cada um dos estados possíveis. Inserindo-se numa abordagem mais ampla, que constitui a moderna computação da Inteligência Artificial, os modelos Fuzzy conseguem responder com boa precisão nos sistemas em que o controlo convencional não permite alcançar resultados tão bem sucedidos, como no caso de processos com elevados níveis de imprecisão, por falta de conhecimento das suas características ou pelo seu apreciável nível de complexidade, por serem de difícil caracterização ou apresentarem um elevado grau de não linearidades. A forma simples, através da linguagem corrente, com que as variáveis são qualitativamente caracterizadas concorre, sobremaneira, para uma desejada transparência na interpretação do modelo, e promove uma abordagem mais inteligível entre o conjunto de regras e a informação numérica produzida pelo processo [20], enfatizando a preponderância da informação *versus* precisão.

A essência da lógica Fuzzy assenta na utilização de variáveis para representar palavras, como os adjectivos da linguagem comum, em vez de números; de certa forma, acaba por ser uma metodologia de computação através de variáveis linguísticas, que a torna mais próxima do sentido intuitivo humano [4]. Este conceito, em termos de simbologia matemática, pode ser expresso por (2.3).

$$\mathcal{R}_i: \text{If } x_1 \text{ is } A_{i,1} \text{ and } \dots \text{ and } x_n \text{ is } A_{i,n} \text{ then } y \text{ is } B_i, \quad i = 1, 2, \dots, k \quad (2.3)$$

Nesta expressão,  $A_{i,i}$  e  $B_i$  representam o conjunto de termos do universo linguístico, adjectivos, que definem as variáveis de entrada,  $x_i$ , e saída,  $y$ , respectivamente.

Jogando com a noção básica de conjunto, normalmente associado a um conceito matemático muito preciso, em que um elemento pertence, exclusivamente, a um conjunto ou ao seu complementar, a lógica Fuzzy faz uma extrapolação desta definição para um conceito não tão rigoroso, em que um elemento apresenta um certo grau de pertença a um determinado conjunto, permitindo uma definição mais vaga e

tolerante das fronteiras, que comporta uma maior abrangência e versatilidade na caracterização das variáveis; esta característica, por outro lado, acaba por se traduzir numa maior economia, graças à maior simplicidade permitida na manufacturação dos controladores. Segundo Lotfi Zadeh, considerado o inventor da *Lógica Fuzzy*, “em praticamente todas as situações poderá construir-se o mesmo produto sem recorrer a esta tecnologia, mas com ela será mais rápido e barato. (*sic*)”

Para processos com fraco conhecimento empírico, que se tornam de difícil caracterização ou dos quais se conhecem, apenas, algumas séries numéricas, com valores de entrada e de saída, respectivamente, os desenvolvimentos mais recentes da lógica Fuzzy visam, precisamente, a obtenção automática de modelos através de medições numéricas, recorrendo a técnicas de agrupamento (*clustering*), em que se agrupa a informação em blocos que apresentem um comportamento linear e similar. Depois, com base neste leque de partições, consegue-se modelar um processo multivariável, que poderá ser linear ou não, através de directivas simples e lineares, do tipo Takagi-Sugeno (TS). Os modelos deste tipo têm a particularidade de apresentarem, segundo um conjunto de funções-membro consequentes, resultados numéricos, que podem ser uma função, linear ou não-linear, das entradas do sistema; as regras TS apresentam a forma de (2.4) [22]:

$$\mathcal{R}_i: \text{If } x \text{ is } A_i \text{ then } y_i = f_i(x), \quad i = 1, 2, \dots, k \quad (2.4)$$

Contrariamente ao modelo linguístico (Mamdani), neste caso a entrada  $x$  representa uma variável com valores numéricos precisos e as funções  $f_i$  são, por norma, da mesma natureza.

$$\mathcal{R}_i: \text{If } x \text{ is } A_i \text{ then } y_i = a_i^T x + b_i, \quad i = 1, 2, \dots, k \quad (2.5)$$

Nesta representação,  $a_i$  é um vector de parâmetros numéricos e  $b_i$  é um deslocamento escalar. Depois de se terem definido as directivas do processo, ou de as ter construído com base num conjunto de valores submetido a um algoritmo de treino, a resposta pretendida é calculada através de um mecanismo de inferência que estabelece um critério com base na ponderação dos vários graus de pertença envolvidos.

De certo modo, a lógica Fuzzy questiona e torna pertinente a questão de quão longe se deve levar a importância da precisão quando uma resposta simples e imprecisa for suficiente. Embora com raízes comuns à área da Inteligência Artificial, esta abordagem, através do conhecimento empírico e do bom senso, tem despertado algumas paixões no seio da comunidade científica, catapultando esta área do controlo para uma aceitação e utilização cada vez maiores, graças à simbiose existente entre a vertente científica e o conhecimento adquirido através da observação, do raciocínio e do entendimento humano dos acontecimentos.

Para os modelos TS, o resultado do sistema de inferência é obtido através da fórmula (2.6) [22], ou seja, pelo cálculo dos centros dos vários blocos, *clusters*, e do nível de influência de cada um deles.

$$y = \frac{\sum_{i=1}^K \beta_i y_i}{\sum_{i=1}^K \beta_i} = \frac{\sum_{i=1}^K \beta_i (a_i^T x + b_i)}{\sum_{i=1}^K \beta_i} \quad (2.6)$$

Nesta fórmula,  $\beta_i$  representa o grau de pertença da variável às relações que caracterizam o processo.

Os modelos do tipo TS são uma forma de modelar processos dinâmicos não-lineares através de modelos locais mais simples e lineares que, quando combinados, conseguem representar sistemas de grande complexidade e de ordens elevadas com um nível qualitativo muito apreciável. O desempenho destes modelos costuma avaliar-se pelo valor, em percentagem, da variância (*VAF, Variance Accounted For*), que é dada pela expressão (2.7); *var* representa a variância.

$$VAF(\%) = \left( 1 - \frac{\text{var}(E - \hat{E})}{\text{var } E} \right) \times 100 \quad (2.7)$$

Quanto mais próximo estiver o resultado dos 100%, melhor será a qualidade do modelo.



### 3. Descrição do aparelho

Como referido anteriormente, o presente trabalho insere-se numa abordagem complementar de controlo do dispositivo estudado e apresentado em [2]. Nesta perspectiva, a descrição que se segue, visa, essencialmente, a sua contextualização de modo a facilitar a percepção do estudo, traduzindo-se numa transposição quase rigorosa da original.

Para além das características físicas do aparelho, apresentam-se, igualmente, as equações do modelo matemático desenvolvido para realização de testes e optimização do aparelho.

#### 3.1 Esquema das dimensões físicas

O esquema do aparelho representado na Figura 3.1 serve o propósito de oferecer uma ideia das suas dimensões, razão pela qual se apresenta a figura de uma pessoa para melhor perceber, por analogia, a sua envergadura.

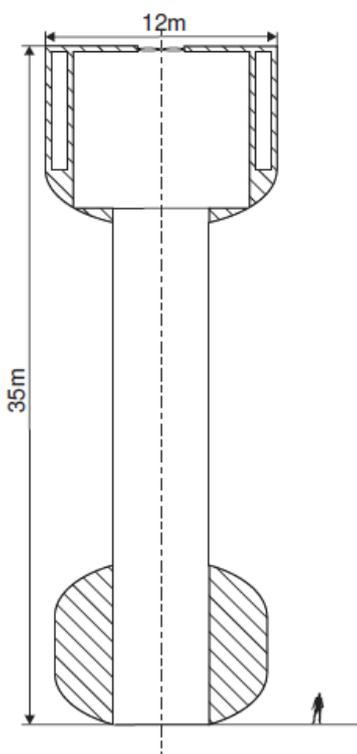
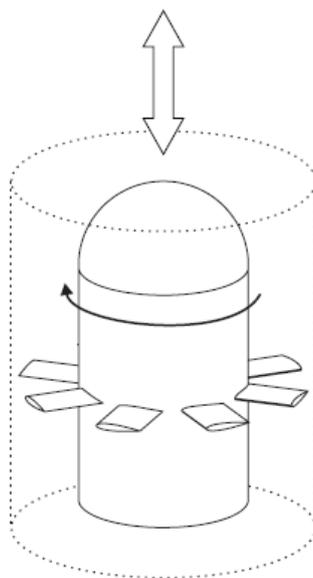


Figura 3.1 Dimensões do aparelho [2]

Desenvolvido pelo *Wave Energy Centre (WavEC)*, este dispositivo, que ainda não foi baptizado, apresenta-se como uma solução inovadora no universo de aparatos desenvolvidos para a extracção de energia através das ondas do mar. Com uma estrutura principal de betão, de modo a contornar as

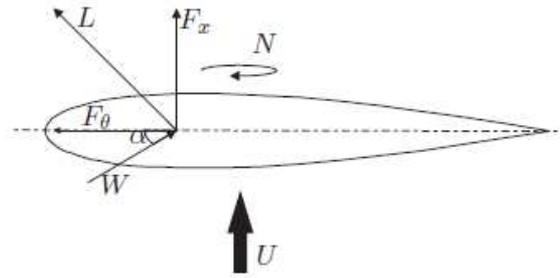
adversidades do meio ambiente e resistir à sua agressividade, este aparelho foi projectado para funcionar ao largo da costa (*offshore*), como as suas dimensões permitem inferir, em zonas com uma profundidade apreciável e suficiente que lhe permita boiar sem que atinja o fundo do mar, de modo a salvaguardar a integridade física da sua estrutura. Classificado como um dispositivo pontual de absorção, apresenta um corpo tubular que admite incursões verticais de água no interior, formando uma coluna de água oscilatória que actua como um êmbolo sobre a câmara-de-ar existente na parte superior, forçando a passagem do ar através da turbina Wells existente no topo; este tipo de turbina, projectado para um funcionamento em regimes de baixa pressão, distingue-se pela característica de dispor de pás com um perfil simétrico que permitem uma rotação contínua no mesmo sentido, independentemente do sentido do fluxo: ascendente ou descendente, neste caso particular, como se pode observar na Figura 3.2.



**Figura 3.2 Turbina Wells com posicionamento vertical [2]**

### **3.2 Turbinas Wells**

As turbinas Wells apresentam características muito interessantes para este fim, sendo, inclusivamente, o tipo de turbina mais utilizado em dispositivos do tipo de coluna de água oscilante (*CAO*). Inventado pelo Dr. Alan Wells, na década de 1970, este tipo de turbina apresenta pás com um perfil simétrico, que implica um aumento do coeficiente de resistência,  $C_d$ , e, conseqüentemente, um menor rendimento. No entanto, o facto de serem auto-rectificadoras proporciona uma facilidade acrescida de utilização, tornando a instalação mais simples e barata, dado que dispensa o recurso a válvulas rectificadoras por causa da inversão do sentido do fluxo de ar [23].



**Figura 3.3**  $U$ : velocidade e direcção do fluxo de ar;  $N$ : velocidade de rotação da turbina;  $F_x$ : força axial;  $F_\theta$ : força tangencial;  $\alpha$ : ângulo de ataque do fluxo de ar;  $W$ : velocidade relativa do fluxo de ar;  $L$ : força de sustentação [2]

A oscilação da coluna de água, que, por simplificação, se assume ser exclusivamente vertical, é causada pela contínua e natural ondulação do mar, embora o seu movimento, devido à inércia do aparelho, não se realize em consonância, ou em fase, com a frequência das ondas; aliás, este é precisamente um dos aspectos sobre os quais se pretende actuar em termos de controlo, de modo a otimizar os níveis da qualidade e estabilidade da energia extraída. Assumindo, também, que o dispositivo nunca fique totalmente submerso— pois de contrário entrará em paragem forçada, designada por *modo de sobrevivência*— a subida da coluna de água origina um aumento de pressão dentro da câmara-de-ar obrigando o ar a passar pela turbina, enquanto a descida, respectivamente, provoca uma depressão no interior da câmara-de-ar, relativamente à pressão atmosférica exterior, que puxa o ar para o interior através da turbina. Embora dependente das condições atmosféricas globais, que tornam a disponibilidade bastante irregular, é este movimento cíclico, precisamente, que se pretende aproveitar para a extracção da energia.

A rotação da turbina está dependente da componente tangencial da força de sustentação,  $F_\theta$ . A potência desenvolvida pela turbina, calculada por (3.1), está directamente relacionada com o coeficiente de força tangencial,  $C_\theta(\alpha)$ , facilmente calculável para perfis NACA normalizados, que depende, por sua vez, do ângulo de incidência do fluxo de ar,  $\alpha$ .

$$P = \frac{1}{2} N C_\theta \rho W^2 A_b U \quad (3.1)$$

Significado das variáveis envolvidas na expressão:  $N$  velocidade de rotação da turbina;  $C_\theta$  coeficiente de força tangencial;  $\rho$  densidade da água do mar;  $W$  velocidade relativa do fluxo de ar;  $A_b$  área projectada da pá;  $U$  velocidade do fluxo de ar.

Este tipo de turbina apresenta uma relação quase linear entre a queda de pressão e o caudal mássico de ar.

$$\dot{m}(t) = K_t(t) \Delta p(t) \quad (3.2)$$

$K_t$  é o coeficiente de proporcionalidade da turbina.

### 3.3 Modelo matemático

O modelo matemático foi obtido, a partir de aproximações lineares, com base na segunda lei de Newton:

$$\sum \vec{F}(t) = \frac{d(m\vec{v}(t))}{dt} \quad (3.3)$$

$\sum F(t)$  somatório de todas as forças envolvidas;  $m$  massa do aparelho;  $v(t)$  velocidade do aparelho.

O dispositivo e a coluna de água existente no interior são considerados dois corpos separados. Enquanto o primeiro engloba toda a parte estrutural, com características constantes, o segundo contempla uma massa de água de valor variável, devido às variações do nível da superfície livre no interior da câmara-de-ar. Os dois corpos encontram-se acoplados através da pressão de ar existente na câmara, sendo regulada pela passagem de ar através da turbina. Esta formulação, partindo do pressuposto que o aparelho está restringido, exclusivamente, a um movimento vertical, estabelece dois graus de liberdade: a altura do aparelho,  $\zeta$ , relativamente ao nível de repouso, e a altura da coluna de água,  $h$ , medida desde o fundo do aparelho até à superfície livre.

O *Anexo II* apresenta o diagrama do aparelho com as respectivas variáveis.

#### 3.3.1 Considerações adicionais

Para além do movimento vertical, consideraram-se, ainda, as seguintes condições:

1. O movimento elevatório é restringido na sua amplitude de modo a que os níveis da água, interno e externo, apenas toquem a superfície das paredes da câmara-de-ar.
2. A espessura dos componentes metálicos, existentes na câmara, é negligenciável.
3. A temperatura do aparelho é constante e igual à da água do mar.
4. A água e o fluxo de ar são irrotacionais.
5. A superfície livre da coluna de água é vista como um pistão de massa negligenciável.
6. A tensão superficial é desprezável.
7. O ar existente na câmara-de-ar é considerado como um gás ideal, tornando o movimento oscilatório num processo isentrópico.

#### 3.3.2 Análise de forças

Existem dois tipos de forças a actuar sobre os dois corpos considerados: hidrostáticas e hidrodinâmicas. As primeiras reportam-se a corpos flutuantes em repouso, em que a força de sustentação é igual ao peso do fluido deslocado pelo corpo e este, por sua vez, desloca uma quantidade de fluido igual ao seu peso. As forças hidrodinâmicas, para corpos em interacção com fluidos, contemplam dois tipos: de radiação e excitação. Segundo a apresentação em [2], estas forças foram calculadas através de um *software* específico, *AquaDyn*, pelo *Wave Energy Centre*; estes cálculos foram obtidos para dimensões específicas do aparelho, impossibilitando a sua alteração, sob pena de invalidação dos resultados, e para um conjunto

de ondas dentro da gama de frequências entre os 0,1 e os 1,275 rad/s, que é aquela onde se concentra maior quantidade de energia.

### 3.3.3 Forças de radiação

São as forças que é preciso aplicar a um corpo imerso ou flutuante de modo a provocar a sua oscilação na ausência de ondas incidentes; no caso específico, acabam por ser as forças criadas pelas ondas radiadas pelo próprio aparelho, de sentido inverso ao das forças de excitação provocadas pelas ondas incidentes. Como estamos na presença de dois corpos, há ainda a considerar as forças internas provocadas pela coluna de água sobre o aparelho, que originam um efeito cruzado.

Para um corpo oscilante, a força de radiação pode ser calculada pela convolução entre uma função linear de resposta a um impulso,  $h_r$ , e a velocidade vertical do corpo,  $\dot{\zeta}$ , mais um termo proporcional à aceleração do corpo, sendo a constante de proporcionalidade a massa adicionada a uma frequência infinita; esta constante é a componente da força que está em fase com a aceleração (sendo a outra ortogonal) e equivale ao efeito que teria um aumento da massa do corpo que se move.

$$f_{rad}(t) = -(-h(t) * \dot{\zeta}(t) - \ddot{\zeta}(t)m_{\infty}) \quad (3.4)$$

O resultado dos cálculos realizados pelo *AquaDyn* contém informação sobre a frequência das componentes da força de radiação, fornecendo a magnitude e a fase de cada componente para uma certa frequência através de um número complexo. A partir do valor absoluto da força,  $F$ , é possível calcular a magnitude em dB,  $20 \log_{10} F$ , e a fase, de modo a obter os diagramas de Bode e aplicar um método de identificação em frequência que permita encontrar a função de transferência de cada componente da força de radiação tornando possível o uso de (3.4) para simulações no domínio do tempo.

Em [2], o autor recorreu a dois métodos de identificação conhecidos: CRONE e Levy; no entanto, foi através do método de Levy que se conseguiram os resultados melhores e mais consistentes. O princípio do algoritmo deste método baseia-se na estimação dos parâmetros da função de transferência que minimizam a média do erro quadrático, embora seja preciso indicar a ordem tanto do numerador como do denominador. Através deste método foi possível encontrar uma função de transferência causal estável, apresentada mais adiante em 0, que se revelou uma boa aproximação aos dados originais.

### 3.3.4 Forças de excitação

Esta força é provocada pela onda no aparelho, considerando que este se encontra numa posição de repouso. Assim, como a força de radiação, esta também foi calculada através do programa *AquaDyn*, seguindo o mesmo procedimento. Enquanto as forças de radiação estão dependentes do movimento do dispositivo, as de excitação dependem unicamente da onda incidente, tornando possível o seu cálculo para o período de simulação, dado que o perfil da onda já foi previamente gerado. Esta circunstância reveste-se de especial importância uma vez que a sua identificação envolve, sempre, modelos não-causais. Para contornar este comportamento, o cálculo é feito no domínio da frequência, com os dados fornecidos pelo simulador.

Para calcular a força de excitação a onda gerada pelo simulador é convertida para o domínio da frequência, através de uma transformada de Fourier (*FFT*), sendo depois multiplicada pela força de excitação e, em seguida, pela inversa da transformada de Fourier (*iFFT*), obter-se a força de excitação no domínio do tempo.

### 3.3.5 Constantes físicas

As constantes físicas envolvidas no processo são:

$g$  aceleração da gravidade, considerada positiva;

$\rho_w$  densidade da água do mar;

$R_{ar}$  constante do ar;

$p_{am}$  pressão atmosférica;

$T$  temperatura da água do mar e do próprio aparelho.

### 3.3.6 Dimensões físicas do aparelho

As dimensões físicas do aparelho são:

$r_{top}$  raio externo da parte superior ;

$r_{topin}$  raio interno da parte superior;

$r_{neck}$  raio interno da coluna;

$r_{bottom}$  raio da parte inferior;

$h_{top}$  altura da parte superior;

$h_{topin}$  altura do cilindro dentro da parte superior;

$h_{bottom}$  altura da parte inferior;

$h_{neck}$  altura da coluna;

$h_{tube}$  altura total do tubo;

$h_{device}$  altura total do aparelho;

$h_{straighttop}$  altura da superfície plana exterior da parte superior;

$c_{topellips}$  raio mínimo do topo elipsoidal;

$c_{bottomellips}$  raio mínimo do fundo elipsoidal;

$h_{straightbottom}$  altura do cilindro que liga as duas metades elipsoidais na parte inferior;

$\varepsilon$  espessura dos componentes metálicos.

### 3.3.7 Dimensões compostas

$$h_{device} = h_{top} + h_{neck} + h_{bottom} = h_{top} + h_{tube} \quad (3.5)$$

As partes elipsóides são do tipo achatado, uma vez que a relação dos seus raios é:  $a = b > c$ , sendo  $a = r_{top}$ ,  $b = r_{top}$ ,  $c = c_{topellips}$ .

Volume do aparelho,  $V_{outside}$ , considerando-o como um sólido:

$$V_{outside} = V_{top} + V_{neck} + V_{bottom} \quad (3.6)$$

$$V_{top} = \pi r^2 h_{straighttop} + \frac{4}{6} \pi r_{top}^2 c_{topellips} \quad (3.7)$$

$$V_{neck} = \pi r_{neck}^2 h_{neck} \quad (3.8)$$

$$V_{bottom} = \pi r_{bottom}^2 h_{straightbottom} + \frac{4}{3} \pi r_{bottom}^2 c_{bottomellips} \quad (3.9)$$

Considerando que o aparelho é oco, o volume total deste espaço é dado por:

$$V_{hollow} = V_{tophollow} + V_{neckhollow} + V_{bottomhollow} \quad (3.10)$$

$$V_{tophollow} = V_{topcylinderhollow} + V_{topellipshollow} \quad (3.11)$$

$$V_{topcylinderhollow} = \pi (r_{top}^2 - r_{r_{topin}}^2) h_{straighttop} \quad (3.12)$$

$$V_{topellipshollow} = \frac{4}{6} \pi r_{top}^2 c_{topellips} - \pi r_{topin}^2 (h_{topin} - h_{straighttop}) - \pi r_{neck}^2 h_{ne} \quad (3.13)$$

$h_{ne}$  é a altura do espaço oco cilíndrico dentro do topo elipsoidal com raio  $r_{neck}$ ; por uma questão de simplicidade pode ser desprezado.

$$V_{neckhollow} = \pi (r_{neck}^2 - (r_{neck} - \varepsilon)^2) h_{neck} \quad (3.14)$$

$$V_{bottomhollow} = \pi r_{bottom}^2 h_{straightbottom} + \frac{4}{3} \pi r_{bottom}^2 c_{bottomellips} - \pi r_{neck}^2 h_{bottom} \quad (3.15)$$

Definição de variáveis do aparelho:

$h_{emerged}$  altura da parte não submersa do aparelho;

$h_{immersed}$  altura da parte submersa;

$\zeta$  posição vertical em relação ao ponto de repouso;

$\eta$  elevação da onda;

$h$  altura da água no interior, medida desde o fundo do aparelho.

Assim,

$$h_{emerged}(t) + h_{immersed}(t) = h_{device} \quad (3.16)$$

Atendendo à consideração 1,

$$h_{emerged}(t) \in [0, h_{straighttop}], \forall t \quad (3.17)$$

$$\overline{h_{immersed}} = h_{device} - \overline{h_{emerged}} \quad (3.18)$$

$\overline{h_{immersed}}$  é um valor médio que permanecerá constante, na medida em que os coeficientes das forças de radiação e de excitação dependem dele.

$$h(t) \in [h_{tube}, h_{device}], \forall t \quad (3.19)$$

### 3.3.7.1 Definição de outras variáveis

$V_{topin}$  é o volume da parte oca superior:

$$V_{topin} = \pi r_{topin}^2 h_{topin} \quad (3.20)$$

$V_{inside}$  é o volume total da parte oca, preenchido parcialmente com ar e água:

$$V_{inside} = V_{topin} + \pi r_{neck}^2 h_{tube} \quad (3.21)$$

$V_{immersed}$  representa o volume da parte submersa:

$$V_{immersed}(t) = V_{outside} - \pi r_{top}^2 h_{emerged}(t) \quad (3.22)$$

$V_{air}$  volume de ar interior, considerando um estado de repouso:

$$\overline{V_{air}} = \pi r_{topin}^2 \overline{h_{emerged}} \quad (3.23)$$

O seu valor momentâneo é dado por:

$$V_{air}(t) = \pi r_{topin}^2 (h_{device} - h(t)) \quad (3.24)$$

### 3.4 Forças actuantes nos dois corpos

A análise seguinte baseia-se em dois corpos em contacto. Um é o próprio aparelho e o segundo é o volume de água no seu interior.

#### 3.4.1 Forças aplicadas no aparelho

Segundo a lei de Newton, tem-se:

$$\begin{aligned} f_{excb}(t) - f_{radbb}(t) + f_{radwb}(t) + f_{impb}(t) + w_b + f_{turb}(t) + f_{vb}(t) + f_{pib}(t) \\ + f_{inwater}(t) = m_b \ddot{\xi}(t) \end{aligned} \quad (3.25)$$

$f_{excb}$  força de excitação;

$f_{radbb}$  força de radiação sobre si próprio;

$f_{radwb}$  força de radiação da água sobre o aparelho;

$f_{impb}$  força de impulsão;

$w_b$  peso do aparelho;

$f_{turb}$  força exercida pela turbina;

$f_{vb}$  força viscosa hidrodinâmica;

$f_{pib}$  força provocada pela pressão interna;

$f_{inwater}$  força provocada pela água no interior;

$m_b$  massa do aparelho.

Integrando duas vezes a equação do movimento do aparelho, a partir de uma posição inicial, obtém-se  $\xi$ .

##### 3.4.1.1 Condições de repouso

Em condições de repouso, dado que não existe movimento, todas as forças da equação (3.25) são nulas, à excepção das hidrostáticas,  $f_{impb}$  e  $w_b$ . Assim, esta equação reduz-se a:

$$w_b + f_{impb} = 0 \quad (3.26)$$

Que pode ser expandida sob a forma:

$$\rho_w g \overline{V_{displaced}} = m_b g \quad (3.27)$$

### 3.4.1.2 Forças de radiação

Como referido anteriormente, estas forças têm duas componentes: uma devida à interacção do aparelho consigo próprio e outra com a água. O método de identificação de Levy, à semelhança da sua utilização nas forças de excitação, permitiu obter alguns bons modelos de estimação, embora fossem modelos causais de pequena ordem. A função de transferência obtida é:

$$H_{bb}(s) = \frac{[2,7259s^3 + 3,9825s^2 + 4,5174s - 0,0185] \times 10^5}{0,0021s^3 + 0,7409s^2 + 1,1879s + 1} \quad (3.28)$$

$$H_{wb}(s) = \frac{[3,864s^3 + 3,174s^2 + 2,453s - 0,005327] \times 10^4}{0,01191s^3 + 2,043s^2 + 1,924s + 1} \quad (3.29)$$

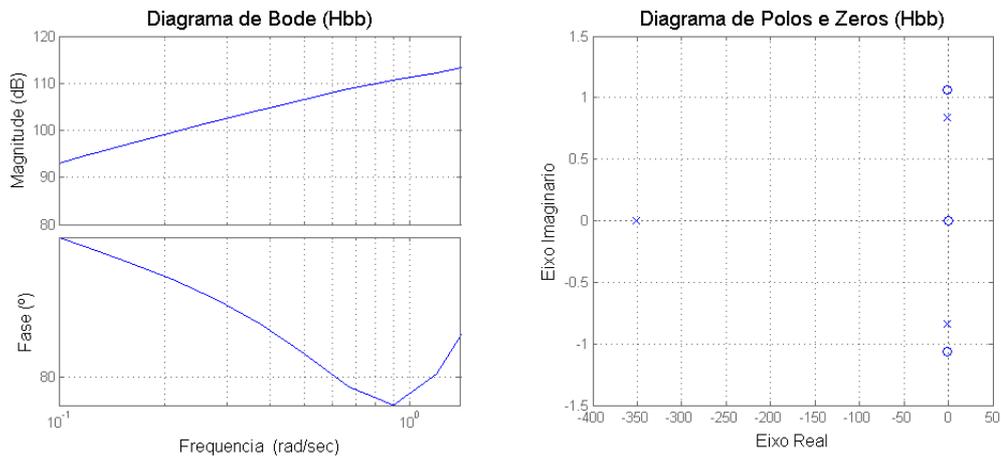


Figura 3.4 Gráficos da força de radiação relativos à componente devida à interacção do aparelho consigo próprio

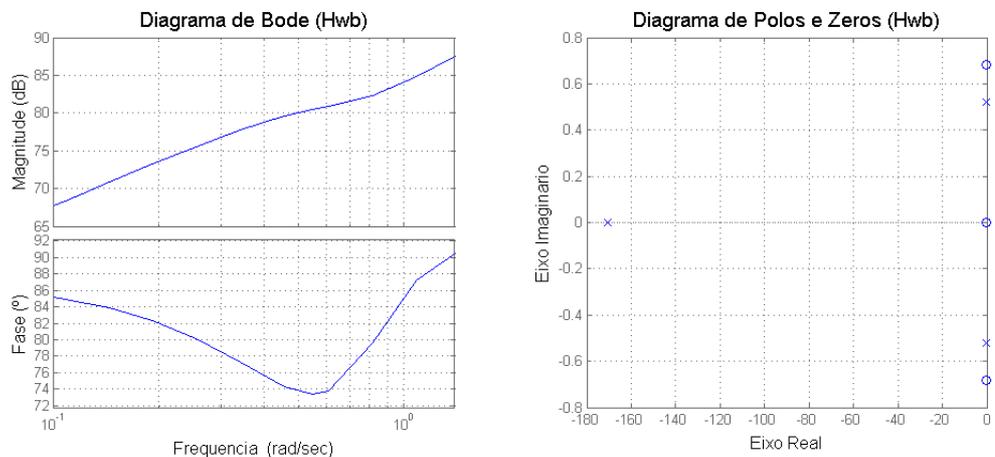


Figura 3.5 Gráficos da força de radiação relativos à componente devida à interacção do aparelho com a água do mar

### 3.4.1.3 Força de impulsão

A força de impulsão ou força de flutuação é dada pela lei de Arquimedes:

$$f_{impb}(t) = \rho_w g V_{displaced}(t) \quad (3.30)$$

Desprezando o pequeno impacto na força de impulsão do movimento ondulante da superfície livre da água no interior,  $h$ , pela teoria da linearidade considera-se apenas a variação de  $\zeta$ . Nestas condições, o volume de água preenchido é dado por:

$$V_{displaced}(t) = V_{bottomhollow} + V_{topellipshollow} + \pi(r_{top}^2 - r_{topin}^2)(h_{straighttop} - \overline{h_{emerged}} - \xi(t)) \quad (3.31)$$

Para efeitos meramente experimentais, considerou-se, também, um tubo que se eleva desde o pescoço até ao topo do aparelho. Quando este tubo se encontrar nessa posição, o volume da parte oca aumenta (é necessário bombear a água para o exterior), assim como a força de impulsão. Nestas condições,  $r_{topin}$  é igual a  $r_{neck}$  e o volume deslocado será:

$$V_{displaced}(t) = V_{bottomhollow} + V_{topellipshollow} + \pi(r_{top}^2 - r_{neck}^2)(h_{straighttop} - \overline{h_{emerged}} - \xi(t)) \quad (3.32)$$

### 3.4.1.4 Peso do aparelho

Assumindo, para efeitos de simulação, que o volume imerso do aparelho tem uma densidade média igual à da água do mar, de modo a obter um estado de equilíbrio, então o peso será calculado pela expressão:

$$w_b = -\rho_w g \overline{V_{displaced}} \quad (3.33)$$

Isto é, em condições de equilíbrio, o peso do aparelho deve ser igual à força de impulsão.

### 3.4.1.5 Forças devidas à turbina

A pressão existente no interior do aparelho, ou seja, na câmara-de-ar, exerce uma força variável nas pás da turbina, alterando a sua velocidade de rotação, que acaba por se reflectir no comportamento do aparelho; é possível controlar esta força dentro de um certo limite e, idealmente, seria desejável ter uma acção de controlo tal que permitisse que a velocidade de oscilação do aparelho estivesse em fase com as ondas incidentes. A força tem a direcção axial da turbina e o mesmo sentido do fluxo de ar.

Considerando o aparelho com a água e o ar interiores como sendo o volume de controlo, haverá transferência de massa de ar e de água através da sua fronteira, embora, para efeitos de cálculo da força axial da turbina, apenas se contabilize a transferência da massa de ar. Assumindo um fluxo em condições quase-estáticas e estabelecendo um balanço do momento linear, o resultado será quase nulo, devido às

pequenas diferenças de velocidade existentes entre a entrada e a saída do ar, bem como das variações de densidade do ar.

Nestas condições, a força da turbina será dada por:

$$F_{turb}(t) = p_{inside}(t)A_{turb} \quad (3.34)$$

$p_{inside}$  pressão relativa do ar dentro do aparelho;

$A_{turb} = \pi(r_{turb})^2$  área ocupada pela turbina.

### 3.4.1.6 Potência pneumática disponível para a turbina

A potência pneumática instantânea disponível para a turbina é dada pela expressão:

$$P(t) = p_{inside}(t)Q(t) \quad (3.35)$$

$Q(t)$  fluxo volumétrico de ar.

Esta aproximação apresenta-se como razoável na medida em que ainda não existe um modelo de turbina específico para o projecto; neste trabalho, por questões de simplicidade, desprezam-se as não-linearidades da turbina. Assim, a energia absorvida pelo dispositivo, durante um certo período de tempo, pode ser calculada através da expressão seguinte:

$$E(t) = \int_0^t p_{inside}(t)Q(t)dt \quad (3.36)$$

Os dois coeficientes adimensionais, que se apresentam a seguir, podem ser utilizados para calcular o fluxo mássico de ar que passa na turbina.

$$\Phi(t) = \frac{\dot{m}_{inside}(t)}{\rho_{air}(t)N(t)r_{turb}^3} \quad (3.37)$$

$$\Psi(t) = \frac{p_{atm} - p_{absin}(t)}{\rho_{air}(t)N^2(t)r_{turb}^2} \quad (3.38)$$

$\Phi$  coeficiente de massa;

$\Psi$  coeficiente de pressão;

$N$  velocidade de rotação da turbina.

O fluxo mássico que passa pela turbina pode ser calculado através da seguinte relação não-linear:

$$\Phi(t) = \varphi_{\psi} \Psi(t) \Leftrightarrow \frac{\dot{m}_{inside}(t)}{\rho_{air}(t)N(t)r_{turb}^3} = \varphi_{\psi} \frac{p_{atm} - p_{absin}(t)}{\rho_{air}(t)N^2(t)r_{turb}^2} \Leftrightarrow \quad (3.39)$$

$$\dot{m}_{inside}(t) = \frac{\varphi_{\psi} r_{turb}}{N(t)} (p_{atm} - p_{absin}(t))$$

A razão do volume de ar é dada por:

$$Q(t) = \frac{\varphi_{\psi} r_{turb}}{\rho_{air}(t)N(t)} (p_{atm} - p_{absin}(t)) \quad (3.40)$$

Uma vez que o primeiro termo da expressão (3.40) é constituído, essencialmente, por constantes, podem-se agrupar num único coeficiente de proporcionalidade da turbina,  $K_t$ , tornando mais simples a sua utilização no processo de optimização do modelo de turbina a utilizar no projecto para as condições do mar no local em que se vier a implementar. Assim,

$$Q(t) = \frac{K_t(t)}{\rho_{air}(t)} p_{inside}(t) \quad (3.41)$$

### 3.4.1.7 Forças devidas à resistência viscosa hidrodinâmica

A força viscosa hidrodinâmica calcula-se através da seguinte equação:

$$f_{vb}(t) = f_{vbe}(t) + f_{vbi}(t) \quad (3.42)$$

$f_{vbe}$  força viscosa hidrodinâmica externa;

$f_{vbi}$  força viscosa hidrodinâmica interna.

Estas duas forças são obtidas a partir de uma expressão relativa ao cálculo da fricção existente num fluxo laminar paralelo a uma parede plana; a sua aplicação às condições do projecto implica a simplificação de considerar que a curvatura do cilindro é negligenciável. Assim, a força por unidade de largura, resistência  $D$ , é dada pela expressão:

$$\frac{2D}{\rho U^2 L} = \frac{1,328}{\sqrt{\frac{LU}{\nu}}} \quad (3.43)$$

$U$  velocidade do fluido;

$L$  comprimento da parede plana;

$\nu$  coeficiente de viscosidade cinemática do fluido.

O denominador do segundo membro representa o número de Reynolds. A força de resistência,  $F_D$ , será:

$$F_D = W \frac{1,328}{\sqrt{\frac{LU}{\nu}}} \rho U^2 L \frac{1}{2} = \frac{1,328}{2} \rho U^{\frac{3}{2}} L^{\frac{1}{2}} \nu^{\frac{1}{2}} W \quad (3.44)$$

$W$  largura da parede plana.

A expressão (3.44) é uma aproximação grosseira, uma vez que a maior fonte de dissipação de energia será a turbulência gerada nas zonas onde o diâmetro do aparelho se altera. Esta circunstância será desprezada, igualmente, nas próximas equações.

### 3.4.1.8 Força viscosa hidrodinâmica externa

A utilização da expressão (3.44) considera três áreas distintas: parte superior, cilindro central e parte inferior.

$$f_{ve}(t) = -sign\left(\dot{\xi}(t) - \dot{\eta}(t)\right) \frac{1,328}{2} \rho_w \nu^{\frac{1}{2}} \left| \dot{\xi}(t) - \dot{\eta}(t) \right|^{\frac{3}{2}} \times \left\{ 2\pi r_{top} \left( h_{top} - \overline{h_{emerged}} - \xi(t) + \eta(t) \right)^{\frac{1}{2}} + \left( 2\pi r_{neck} h_{neck}^{\frac{1}{2}} \right) + \left( 2\pi r_{bottom} h_{bottom}^{\frac{1}{2}} \right) \right\} \quad (3.45)$$

O sinal menos aplicado à função significa que, quando o aparelho se desloca para cima, relativamente à onda, a força aponta para baixo e vice-versa.

### 3.4.1.9 Força viscosa hidrodinâmica interna

Esta força é calculada através da seguinte expressão:

$$f_{vi}(t) = sign\left(\dot{h}(t)\right) \frac{1,328}{2} \rho_w \nu^{\frac{1}{2}} \left\{ \left| \dot{h}(t) \right|^{\frac{3}{2}} 2\pi r_{topin} \left( h(t) - h_{tube} \right)^{\frac{1}{2}} + \left| \dot{h}(t) \frac{r_{topin}^2}{r_{neck}^2} \right|^{\frac{3}{2}} 2\pi r_{neck} h_{tube}^{\frac{1}{2}} \right\} \quad (3.46)$$

Neste caso, quando a água sobe, a força tem o sentido para cima e vice-versa.

### 3.4.1.10 Força provocada pela pressão interna

A força provocada pela pressão interna, devido à simetria do aparelho, não tem nenhuma componente radial e a vertical existe caso o raio da turbina seja diferente do raio da coluna vertical, como se pode observar na Figura 3.6.

Esta força pode ser calculada através da seguinte expressão:

$$f_{pib}(t) = p_{inside}(t) \pi (r_{neck}^2 - r_{turb}^2) \quad (3.47)$$

### 3.4.1.11 Força provocada pela água no interior do aparelho

A massa de água dentro da câmara superior, quando o aparelho não está numa posição de repouso, induz uma força vertical; em situação de repouso, a pressão hidrostática interior é igual à existente no lado de fora, criando uma situação de equilíbrio. Quando a posição relativa de  $\zeta$  e  $h$  é diferente de zero, o volume de água em excesso ou em falta actua como uma mola em sentido negativo, como se pode observar na Figura 3.7.

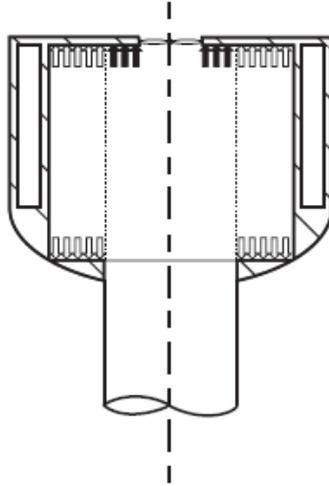


Figura 3.6 Esquema das forças de pressão no interior [2]

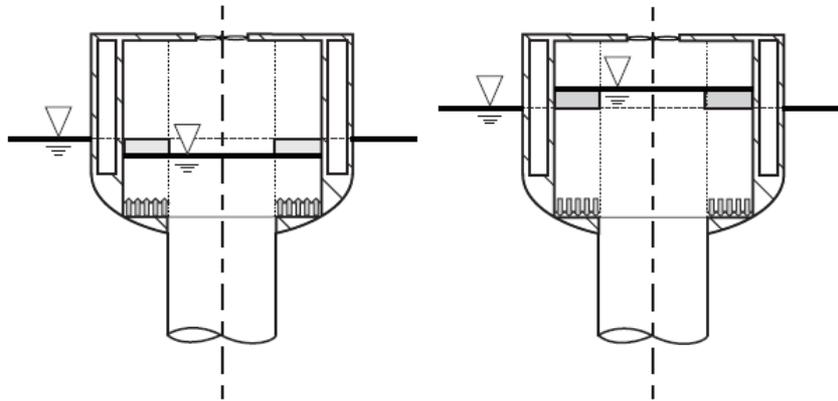


Figura 3.7 Força de mola negativa [2]

O conceito de mola negativa significa que, quando comprimida, a força da mola tem a mesma direcção e sentido do movimento, sendo, gradualmente, mais fácil de comprimir; este modo de funcionamento é precisamente o oposto do evidenciado pelas molas convencionais. Este comportamento pode ser expresso pela lei de Hooke, embora com uma constante de proporcionalidade negativa. Assim, facilmente se percebe que, quanto maior for o volume de água no interior, maior é a facilidade com que o aparelho se movimentará para baixo e vice-versa. Esta característica deve-se às posições relativas de  $\zeta$  e  $h$ , embora a força actue, apenas, na superfície horizontal do aparelho abaixo da linha de água, como se mostra na Figura 3.7.

$$f_{inwater}(t) = -\rho_w g \left( \pi (r_{topin}^2 - r_{neck}^2) \left( h(t) - \overline{h_{immersed}} - \xi(t) \right) \right) \quad (3.48)$$

### 3.4.2 Forças aplicadas no volume de água

A aproximação utilizada anteriormente pode ser aplicada, igualmente, ao segundo corpo. No entanto, a massa e o volume são variáveis no tempo, obrigando a contemplar a derivada da massa em relação ao tempo.

$$\begin{aligned} f_{excw}(t) - f_{radww}(t) + f_{radbw}(t) + f_{impw}(t) + w_w(t) + f_{vw}(t) + f_{piw}(t) \\ = m_w(t)\dot{h}(t) + \dot{m}_w(t)h_w(t) \end{aligned} \quad (3.49)$$

$f_{excw}$  força de excitação aplicada na água;

$f_{radww}$  força de radiação causada pela água em si própria;

$f_{radbw}$  força de radiação provocada pelo aparelho;

$f_{impw}$  força de impulsão;

$w_w$  peso do volume de água considerado;

$f_{vw}$  força de atrito hidrodinâmica;

$f_{piw}$  força de pressão interna aplicada na superfície livre da água;

$m_w$  massa de água no interior do aparelho.

#### 3.4.2.1 Restrições de equilíbrio

As condições de equilíbrio implicam que a pressão de ar interior,  $f_{piw}$ , seja causada, exclusivamente, pela pressão atmosférica. Sendo esta pressão relativa, em condições de equilíbrio, o seu valor será nulo.

A massa de água será dada pela expressão seguinte:

$$\bar{m}_w = \rho_w \left( \pi r_{neck}^2 h_{tube} + \pi r_{topin}^2 (h_{topin} - \overline{h_{emerged}}) \right) \quad (3.50)$$

O peso e a força de impulsão contrabalançam-se, implicando uma resultante nula.

#### 3.4.2.2 Força de radiação

A formulação matemática desta força actuante sobre o volume de água interior é idêntica à da força que actua no aparelho, com duas componentes, e o método de a obter é semelhante.

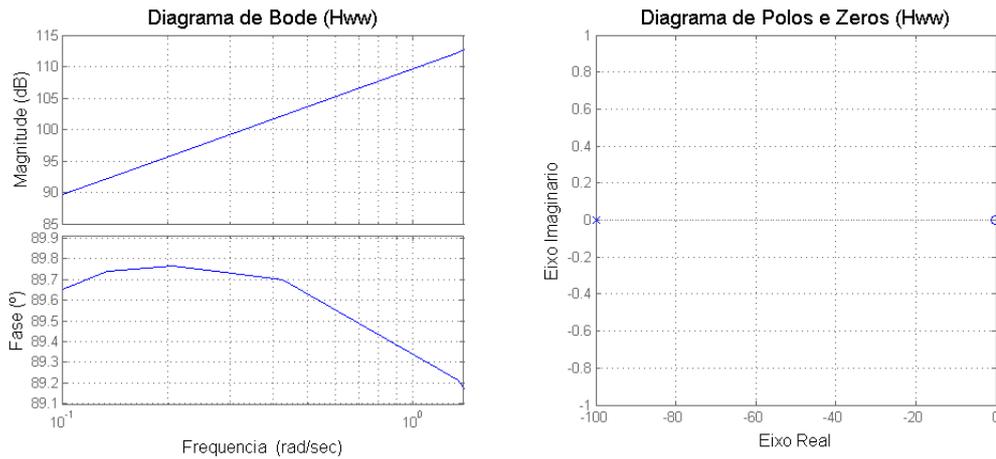
Os dados recolhidos do simulador apresentam-se na Figura 3.8. Como se pode observar, para  $H_{ww}$  o diagrama de Bode é semelhante ao do diferenciador, devido à evolução de 20 dB/dec e a fase perto dos 90°. O método de Levy, para a estimação de um modelo com um zero, conduziu à identificação que se apresenta na referida figura.

Embora o resultado seja satisfatório, o diferenciador levanta outros problemas, dado que actua como um filtro passa-alto que torna o sistema não causal, sendo impossível de simular. Para contornar esta situação, adicionou-se, criteriosamente, um pólo de modo a que a sua influência fosse desprezável dentro da gama

de frequências de interesse para este projecto, -100, onde o corte de frequência não tem nenhum impacto. O diagrama de Bode apresentado permite observar a pequena influência provocada pela adição do referido pólo.

A função de transferência estimada é:

$$H_{ww}(s) = \frac{3,055 \times 10^7 s + 13000}{s + 100} \quad (3.51)$$



**Figura 3.8 Identificação de modelo com um zero pelo método de Levy**

Por último, o método de Levy foi utilizado para encontrar a função de transferência da força de radiação devida ao aparelho sobre a água. Embora o único bom modelo estimado seja de um grau elevado, cinco zeros e cinco pólos, a sua complexidade reduz-se devido ao cancelamento entre pólos e zeros, reduzindo a ordem do modelo para três pólos e três zeros. A Figura 3.9 apresenta os diagramas de Bode respectivos.

O modelo final apresenta um comportamento mais suave, especialmente a sua fase, devido à dificuldade em obter um modelo linear através da informação disponível, em particular para as altas frequências.

A função de transferência estimada é:

$$H_{bw}(s) = \frac{9,698 + 10^4 s^3 + 4,492 \times 10^4 s^2 + 6,13 \times 10^4 s + 399,3}{s^3 + 8,605 s^2 + 6,125 s + 4,182} \quad (3.52)$$

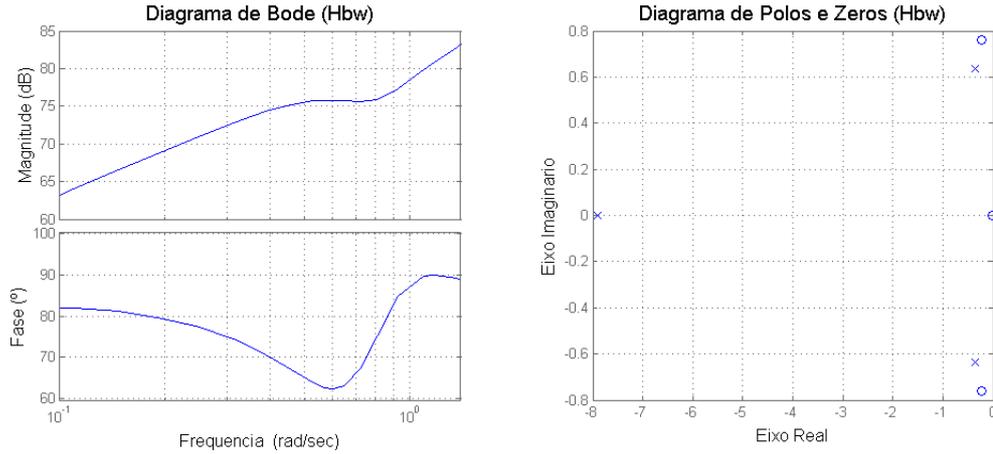


Figura 3.9 Diagrama de Bode e diagrama de pólos e zeros

### 3.4.2.3 Força de impulsão

Esta força depende da posição do aparelho.

$$f_{impw}(t) = \rho_w g \left( \pi r_{neck}^2 h_{tube} + \pi r_{topin}^2 \left( h_{straighttop} - \overline{h_{emerged}} - \xi(t) \right) \right) \quad (3.53)$$

### 3.4.2.4 Força de resistência da viscosidade hidrodinâmica

A força provocada pela resistência da viscosidade hidrodinâmica é simétrica à força interna de resistência da viscosidade hidrodinâmica, anteriormente referida.

### 3.4.2.5 Força provocada pela pressão interna

Força causada pela pressão interna na superfície da água.

$$f_{piw}(t) = p_{inside}(t) \pi r_{topin}^2 \quad (3.54)$$

### 3.4.2.6 Peso e massa do volume de água

A massa de água é variável, dependendo do nível da superfície livre da água no interior do aparelho,  $h(t)$ .

$$m_w(t) = \rho_w \left( \pi r_{neck}^2 h_{tube} + \pi r_{topin}^2 (h(t) - h_{tube}) \right) \quad (3.55)$$

Peso do volume de água:

$$w_w(t) = -g m_w(t) \quad (3.56)$$

### 3.4.3 Modelação do ar no interior do aparelho

Como referido, em condições de equilíbrio, a pressão interior é igual à atmosférica. No entanto, a pressão atmosférica não é utilizada na formulação que se segue, mas sim a pressão relativa.

A superfície livre da água, no interior do aparelho, é tratada como um pistão de massa e espessura desprezáveis, que se encontra sempre numa posição horizontal; as forças que lhe são aplicadas dão origem a um movimento vertical oscilante. Devido às restrições impostas pela turbina à passagem do ar, a pressão interna varia com o tempo.

Fluxo mássico que passa pela turbina:

$$m_{inside}(t) = \rho_{air}(t)V_{air}(t) \quad (3.57)$$

$$\dot{m}_{inside}(t) = V_{air}(t) \frac{d\rho_{air}}{dt} + \frac{dV_{air}}{dt} \rho_{air}(t) \quad (3.58)$$

$\rho_{air}$  densidade do ar ( $m_{inside}/V_{air}$ );  $V_{air}$  volume de ar no interior do aparelho.

Em câmaras com uma grandeza na ordem dos vários metros a compressibilidade do ar não deve ser desprezada. Nestas condições, a sua compressibilidade apresenta um efeito de mola que é particularmente significativo. Para obter  $m_{inside}$  integra-se a expressão (3.39) no tempo, em condições de equilíbrio.

$$m_{inside_0} = \pi r_{top}^2 \rho_{atm} \overline{h_{emerged}} \quad (3.59)$$

Quando o fluxo de ar passa pela turbina no sentido do exterior, a pressão relativa no interior é positiva e o fluxo de ar negativo. Considerando que se trata de um processo reversível, pode-se caracterizá-lo como sendo isentrópico, embora a sua entropia específica não seja constante. Com esta simplificação, pode-se utilizar uma relação isentrópica.

$$\frac{d\rho_{air}}{dt} = \frac{1}{\gamma R_{air} T} \frac{d\rho_{inside}}{dt} \quad (3.60)$$

$\gamma$  é a constante do calor específico. Substituindo (3.60) em (3.58), obtém-se:

$$\dot{m}_{inside}(t) = V_{air} \left( \frac{1}{\gamma R_{air} T} \frac{d\rho_{inside}}{dt} \right) + \frac{dV_{air}}{dt} \rho_{air} \quad (3.61)$$

A pressão pode ser obtida através da integração da expressão seguinte, sabendo que a condição inicial é nula.

$$\frac{d\rho_{inside}}{dt} = \left( \dot{m}_{inside}(t) - \rho_{air}(t) \frac{dV_{air}}{dt} \right) \frac{\gamma R_{air} T}{V_{air}(t)} \quad (3.62)$$

$R_{air}$  é constante e T assume-se como sendo constante, também.

### 3.5 Condições e variáveis do simulador

Os diversos valores, obtidos através do simulador *ipsneck*, para os vários perfis de velocidade da turbina, N, foram gerados com as seguintes definições dos parâmetros utilizados.

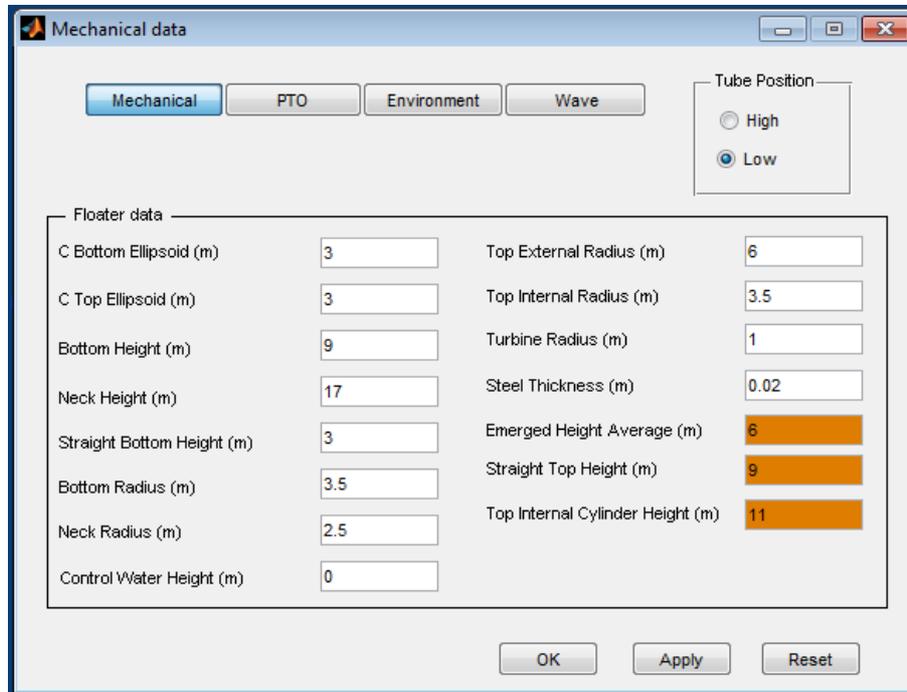


Figura 3.10 Valor das constantes físicas do aparelho

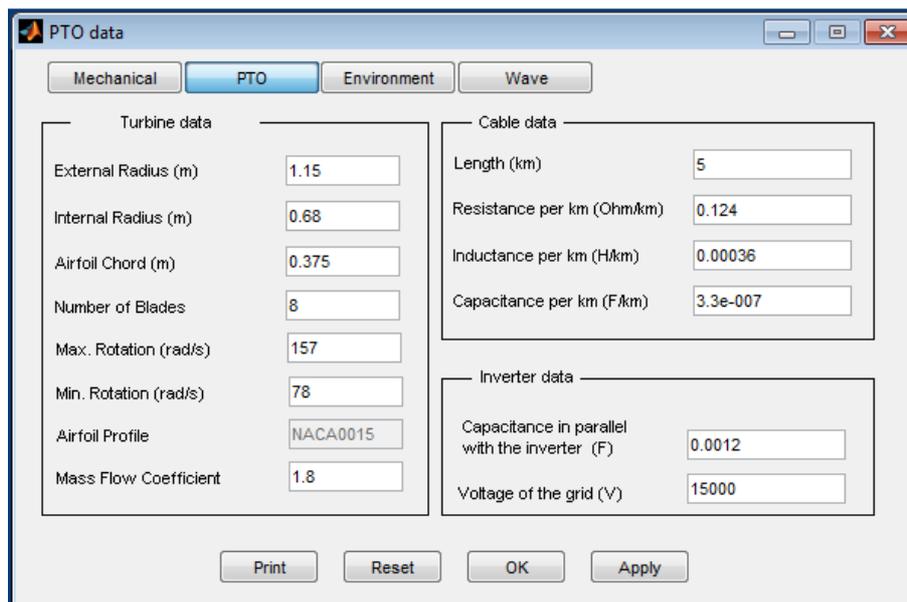


Figura 3.11 Valor das constantes físicas da turbina e das do mecanismo de transformação de energia

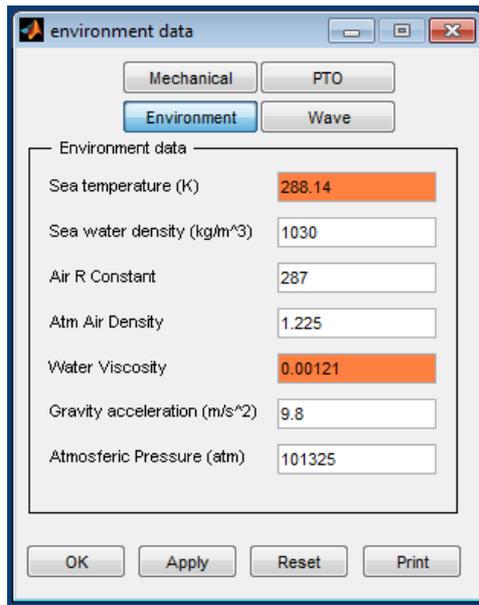


Figura 3.12 Valor das variáveis de ambiente

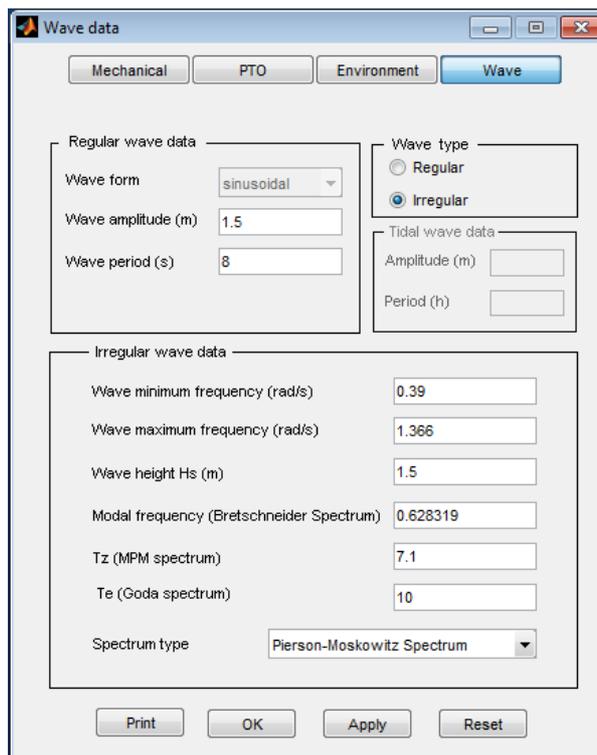
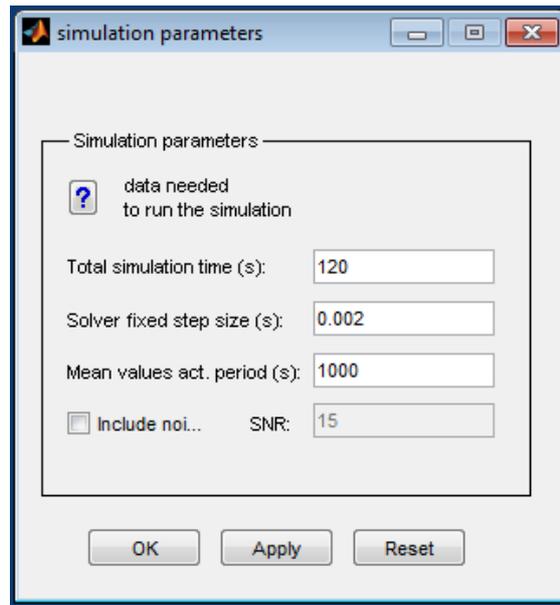


Figura 3.13 Valor dos parâmetros utilizados para gerar os perfis das ondas



**Figura 3.14 Valor dos parâmetros de simulação**

O tipo de *solver* utilizado pelo Simulink (ambiente gráfico do Matlab) foi o *ode3*, que é o utilizado por defeito, devido ao bom nível de precisão que consegue com um esforço moderado de computação. Neste *solver*, de passo fixo, é utilizada a fórmula de integração de Bogacki-Shampine, que é uma versão simplificada de terceiro grau da fórmula de Runge-Kutta. O passo de 0,002 s é um valor suficientemente baixo para garantir um bom nível de precisão dos resultados do simulador. Devido ao desenvolvimento do modelo, o passo não pode ser alterado; sempre que se pretendeu actuar no tamanho do passo obteve-se um erro de implementação do modelo no Matlab.

O modelo, que foi apresentado ao longo deste capítulo, gera uma série de valores com base num perfil de onda obtido de uma forma pseudo-aleatória; se não houver mudança da semente, são gerados os mesmos resultados. No início, começou-se com tempos de simulação de 1 minuto e depois acabou por se utilizar um tempo de 2 minutos, de modo a obter vectores de maior dimensão que permitissem fazer o *resampling* das amostras, com um período de 0,05 s, e ficarem, ainda, com um tamanho significativo e suficiente para a optimização do processo de aprendizagem que os modelos de Redes Neurais e de Lógica Fuzzy utilizam.

O modelo matemático deste projecto, implementado em Simulink, em particular, a parte referente ao sistema de geração das ondas, teve como base a modelação desenvolvida pelo Professor Pedro Beirão, na tese de doutoramento [24], para o AWS.

## 4. Pesquisa de modelos

O objectivo do presente trabalho prende-se com a tentativa de controlar o aparelho descrito no capítulo 3, de modo a otimizar a qualidade de extracção da energia das ondas, e pretende-se obter modelos dinâmicos, com uma ou mais entradas, para as saídas  $\zeta$  (elevação do aparelho) e  $h$  (altura da coluna de água), separadamente. Com esse propósito, pela análise do problema segundo uma perspectiva de raciocínio lógico, presumiu-se que a força de excitação provocada pela incidência das ondas no aparelho,  $F_{exc\_w}$ , e a força de excitação provocada pelo deslocamento do próprio aparelho na coluna de água interior,  $F_{exc\_b}$ , seriam, em simultâneo, as variáveis candidatas mais apropriadas a utilizar como entradas dos modelos. Os valores destas forças, assim como os referentes às próprias saídas, foram obtidos, repetidamente, pela simulação do modelo *ipsneck* durante 60 s, com um período de amostragem de 0,002 s, proporcionando vectores com uma dimensão apreciável de trinta mil pontos, capazes de descrever o comportamento do aparelho num ciclo completo de funcionamento característico.

Dado que o treino das redes do tipo *NARX* é mais eficiente se for adicionada à entrada o vector da própria saída que se pretende estimar, criando uma configuração série-paralela, e que estes valores são temporalmente sequenciais, começou-se por agrupar e manipular estes vectores no formato desejado e, depois, procedeu-se à criação e ao treino da rede. Na fase seguinte, a rede é convertida em paralela e faz-se uma nova simulação em que a entrada é constituída apenas pelas duas forças escolhidas. No final, para validação, é feita uma segunda simulação, com novos valores, para avaliar o desempenho da rede.

Embora este processo seja dos mais expeditos para treino de uma rede neuronal, e que foi utilizado rotineiramente ao longo deste trabalho, também perspectiva a possibilidade de uma aprendizagem demasiado específica relativamente aos dados de treino, ajustando-se particularmente bem a eles mas fortemente penalizadora em termos de generalização [25], o que torna impraticável a utilização da rede para um conjunto mais amplo e abrangente dos vários estados possíveis do aparelho, nomeadamente a enorme diversidade das condições climatéricas e os respectivos perfis de ondulação do mar; este efeito descreve, normalmente, uma rede viciada nos dados de treino, a que se dá o nome técnico, em inglês, de *overfitting*.

Embora a abordagem efectuada tenha sido sistemática e ponderada, com algoritmos de pesquisa adequados aos objectivos pretendidos, em termos práticos, não se estava a alcançar nenhum resultado satisfatório. O desempenho da rede na fase de treino, graças à configuração série-paralela, era excelente mas nas simulações seguintes, já com a configuração paralela da rede, era extremamente decepcionante; inclusivamente, e estranhamente, na simulação com os mesmos valores utilizados no treino da rede, contrariando a existência de *overfitting*. Realizaram-se repetidos ciclos de testes, com variações de 1 a 8 nos atrasos de entrada e de saída, para além das variações de 2 a 20 no número de neurónios na camada interior, por se considerarem gamas de valores mais do que razoáveis para os modelos pretendidos, mas os resultados foram sistematicamente desapontadores.

Das diversas abordagens utilizadas no decorrer desta fase [25, 26, 3], algumas concorrentes, recorreu-se ao limite de 1000 épocas para o treino da rede neuronal e utilizaram-se vários valores como critério de

paragem, tentaram-se arquitecturas com 40 neurónios na camada interior [27], estendeu-se a fase de treino à rede com configuração paralela e realizaram-se, também, várias tentativas a treinar redes apenas com esta configuração, reconstruíram-se os vectores de entrada e de saída com novos períodos de amostragem e, mesmo assim, nunca se obtiveram quaisquer resultados satisfatórios. Este período extremamente exigente e desgastante, que contou com algumas centenas de horas de computação e uma dose considerável de estudo e pesquisa, teve como único mérito o aspecto didáctico de evidenciar a importância da escolha judiciosa dos parâmetros e das variáveis a utilizar na criação das redes neuronais.

A procura de modelos, para a saída  $\zeta$ , acabaria por chegar a bom porto ao adicionar o vector com a elevação da onda, *wave\_elevation*, ao conjunto de entradas; inclusivamente, acabou por se verificar que este vector era, por si só, suficiente para estimar convenientemente a saída pretendida. No entanto, seguindo a mesma metodologia, o modelo para a estimação da saída *h* acabou por não apresentar um grande desempenho com esta configuração e tornou-se evidente que precisaria de uma entrada composta por uma combinação de variáveis. A escolha, que se revelaria acertada, acabou por recair na selecção dos vectores  $\zeta$  e *wave\_elevation*.

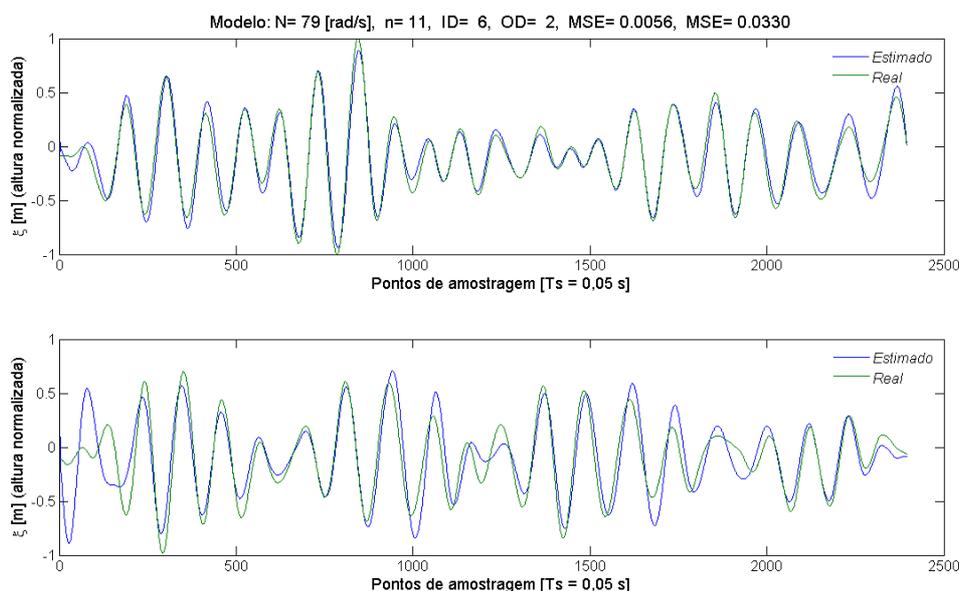
A partir desse momento, em que se conseguiram modelos com elevado desempenho, a finalidade da procura resumia-se a determinar um espaço de soluções conciso e resumido, em termos de parâmetros da rede, no meio da nuvem dos bons resultados alcançados, que fosse capaz de verificar e estender, igualmente, a sua validade e consistência a todo o conjunto de regimes de funcionamento do aparelho, à excepção do modo de sobrevivência. Conhecidas, agora, as variáveis correctas para a entrada dos modelos, relativamente às saídas a estimar, respectivamente, tornou-se imperioso determinar as arquitecturas das redes neuronais do tipo *NARX*, relativamente aos seguintes parâmetros: número de atrasos envolvidos, tanto na entrada como na saída, e o número de neurónios a utilizar na camada interior. Para o efeito, seguindo uma abordagem sistemática, recolheram-se três conjuntos de vectores provenientes do modelo em *Simulink*, relativos a cada um dos três valores da velocidade de rotação da turbina, *N*: 79, 157 (limites inferior e superior, respectivamente) e 100 rad/s; estes valores são representativos da gama de velocidades pretendida para o funcionamento da turbina. A simulação do modelo *ipsneck* foi estendida para um período de dois minutos e produziu conjuntos de vectores com um tamanho de sessenta mil pontos, que foram, posteriormente, reconstruídos com um período de amostragem de 0,05 s; este valor revelou-se bastante eficiente, tanto na redução do tempo de processamento computacional como no de evitar o fenómeno de aprendizagem excessiva e específica, relativamente aos dados de treino (*overfitting*).

Para determinar a zona mais conveniente do espaço de soluções, que proporcionasse encontrar o modelo mais simples e robusto, atendeu-se ao desempenho dos vários modelos de redes neuronais através do parâmetro *MSE (Mean Square Error)*, que permitiu especificar um valor de filtragem, de modo a obter uma nuvem de resultados com os modelos mais consistentes. No entanto, este critério levanta a questão de saber, com alguma exactidão, qual é o valor que define a fronteira entre os modelos considerados bons ou maus. Ao longo deste trabalho, através de uma abordagem visual, pela análise aturada de inúmeros gráficos, observou-se que não existe um valor específico que defina rigorosamente este limite, embora se consiga afirmar, sem que se cometa um erro demasiado grosseiro, que esse valor é da ordem das três

centésimas; para validar os modelos através de critérios mais rigorosos seria preciso utilizá-los numa estratégia qualquer de controlo e avaliar o impacto do seu desempenho. De modo a entender melhor o critério desta avaliação visual, apresentam-se, na Figura 4.1, dois gráficos exemplificativos.

Esta figura é relativa a um modelo com 6 atrasos na entrada, 2 atrasos na saída e 11 neurónios na camada interior, para uma velocidade da turbina de 79 rad/s. O gráfico superior representa a saída real (verde) e estimada (azul), respectivamente, do valor de  $\zeta$ , obtido já na configuração paralela da rede, enquanto o gráfico inferior é relativo a dados novos para validação da rede; dispensou-se a representação gráfica da saída  $\zeta$  (real e estimada), obtida na fase de treino com a configuração série-paralela da rede, por serem, praticamente, duas linhas justapostas. Repare-se que no primeiro, a *performance* da rede apresenta um valor de  $5,627 \times 10^{-3}$  (*MSE*), enquanto no segundo é de  $3,300 \times 10^{-2}$  (*MSE*). Ou seja, embora ainda se possa considerar um modelo bastante aceitável, principalmente no que toca ao gráfico superior, em que é visível uma maior justaposição entre os gráficos dos valores reais e estimados, pelo critério estabelecido das três centésimas este modelo já não é considerado aceitável para o conjunto de avaliação; uma análise mais abrangente permite concluir, com algum rigor, que até às quatro centésimas ainda se encontram modelos consideravelmente bons, mas este intervalo de uma décima acaba por representar uma margem razoável de tolerância, que concorre para uma desejável robustez do modelo a encontrar.

Nos gráficos seguintes, bem como todos os que forem apresentados ao longo do texto, a legenda apresentada refere, a azul (*Estimado*), o gráfico obtido pelo modelo neuronal ou Fuzzy, consoante o caso, e, a verde (*Real*), o valor obtido pelo simulador *ipsneck*. No título dos gráficos, *ID* representa o número de atrasos na entrada (*Input Delays*) e *OD* o número de atrasos na saída (*Output Delays*).



**Figura 4.1 Modelo 28 (Neuronal): 6 atrasos na entrada, 2 atrasos na saída e 11 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente.**

As rotinas de pesquisa desenvolvidas foram reajustadas com base em critérios de otimização do esforço e do tempo de computação necessária, através de um balanceamento da informação e ponderação do problema, de modo a simplificar os modelos sem prejudicar o nível de qualidade ou questionar a sua validade. Assim, por cada rotina de pesquisa, em que se estabilizou a busca na variação de 2 a 7 atrasos na entrada, de 1 a 7 atrasos na saída e de 10 a 20 o número de neurónios a utilizar na camada interior, produziam-se 462 modelos, aos quais se aplicou um filtro para seleccionar apenas os que obedeciam ao critério de desempenho com *MSE* inferior a três centésimas tanto para os dados de treino como para a validação com novos valores, simultaneamente.

Na secção “Anexos” encontra-se uma lista dos modelos que são referenciados nas tabelas que se apresentam a seguir. Aqui, “modelo” refere-se a uma tentativa de pesquisa, implementada por uma rotina de programação no ambiente do Matlab, de modo a conseguir a combinação de parâmetros da rede neuronal que oferecesse os melhores resultados na estimação da respectiva saída. A lista apresenta, também, os modelos referentes a outras tentativas realizadas, conforme se dará conta.

Nas secções seguintes, apresenta-se um conjunto de tabelas com os valores mais conseguidos, relativamente aos três níveis de velocidade da turbina (79, 100 e 157 rad/s), dos modelos para  $\zeta$  e  $h$ , respectivamente. Para cada uma das saídas, em cada um dos patamares de velocidade, escolheu-se o modelo com o melhor desempenho (linha da tabela assinalada com fundo azul) e apresentam-se os gráficos respectivos, obtidos com dois conjuntos de dados distintos: o primeiro utiliza os dados de treino e o segundo, muito mais indicativo da qualidade do modelo, representa o comportamento do modelo perante um conjunto de dados completamente novo, obtido por uma nova simulação do modelo *ipsneck*, com o mesmo perfil de parâmetros; um pouco estranhamente, houve situações em que se conseguiram melhores resultados com estes conjuntos de dados, podendo ser um factor indicativo da qualidade do modelo obtido e da metodologia utilizada na abordagem do problema.

O critério prevalente da selecção dos modelos foi o desempenho, embora se tenha ponderado entre o nível qualitativo e factores como a simplicidade, a robustez, a rapidez de processamento e o preço de implementação do controlador, como no *modelo 29*, em que se optou pelo menor número de neurónios.

## 4.1 Modelos NARX, directos, em Redes Neurais

### 4.1.1 Modelos para $\xi$ , com uma velocidade da turbina de 79 rad/s

Modelos para $\xi$ (79 rad/s)					
Atrasos Entrada	Atrasos Saída	Desempenho Treino	Desempenho Validação	Desempenho Novos Valores	Número Neurónios
1	2	2,22E-08	0,00984	0,025674	18
5	2	4,27E-08	0,01938	0,018251	11
1	3	3,54E-08	0,008594	0,01327	13
3	3	3,61E-07	0,021988	0,023549	12
3	3	1,86E-07	0,026458	0,02961	17
4	3	3,60E-08	0,008966	0,024329	16
4	3	3,46E-08	0,005246	0,017092	19
7	3	4,29E-08	0,005569	0,011909	13
1	4	1,52E-07	0,014781	0,022428	10
2	4	9,21E-07	0,024509	0,01823	10
7	4	9,95E-07	0,019713	0,02967	17
1	5	2,22E-07	0,009857	0,013651	16
2	6	9,98E-07	0,01129	0,028045	11
4	7	5,37E-07	0,007612	0,008145	12

Tabela 4.1 Modelo 28 (Neuronal)

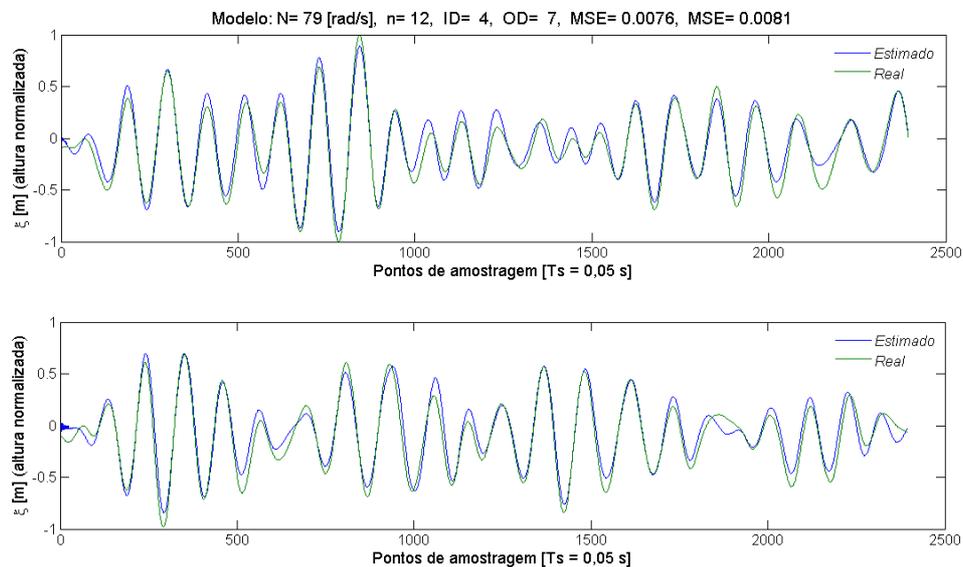


Figura 4.2 Modelo 28 (Neuronal): 4 atrasos na entrada, 7 atrasos na saída e 12 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente.

#### 4.1.2 Modelos para $h$ , com uma velocidade da turbina de 79 rad/s

Modelos para $h$ (79 rad/s)					
Atrasos Entrada	Atrasos Saída	Desempenho Treino	Desempenho Validação	Desempenho Novos Valores	Número Neurónios
3	3	4,50E-09	0,002817	0,004699	20
6	3	2,70E-08	0,027733	0,023174	18
3	5	1,72E-08	0,002647	0,004957	10
3	5	6,09E-08	0,007052	0,00828	17
4	5	8,53E-09	0,004236	0,004596	20
6	5	1,41E-07	0,017296	0,02045	17
7	5	4,67E-09	0,00276	0,009301	11
3	6	4,95E-08	0,013775	0,016342	11
7	6	2,10E-07	0,013521	0,024817	14
7	6	2,63E-07	0,018825	0,023887	18
1	7	3,30E-09	0,002799	0,006175	18
3	7	2,63E-07	0,008272	0,02055	13
3	7	2,74E-07	0,016137	0,020716	19
4	7	3,95E-07	0,012056	0,014067	12
4	7	2,99E-07	0,010453	0,013682	19
5	7	4,31E-07	0,012358	0,015861	17
6	7	3,09E-07	0,011141	0,015537	14
6	7	1,68E-07	0,008326	0,013851	17
6	7	4,72E-07	0,010362	0,011775	19
7	7	2,54E-07	0,01045	0,026933	11

Tabela 4.2 Modelo 29 (Neuronal)

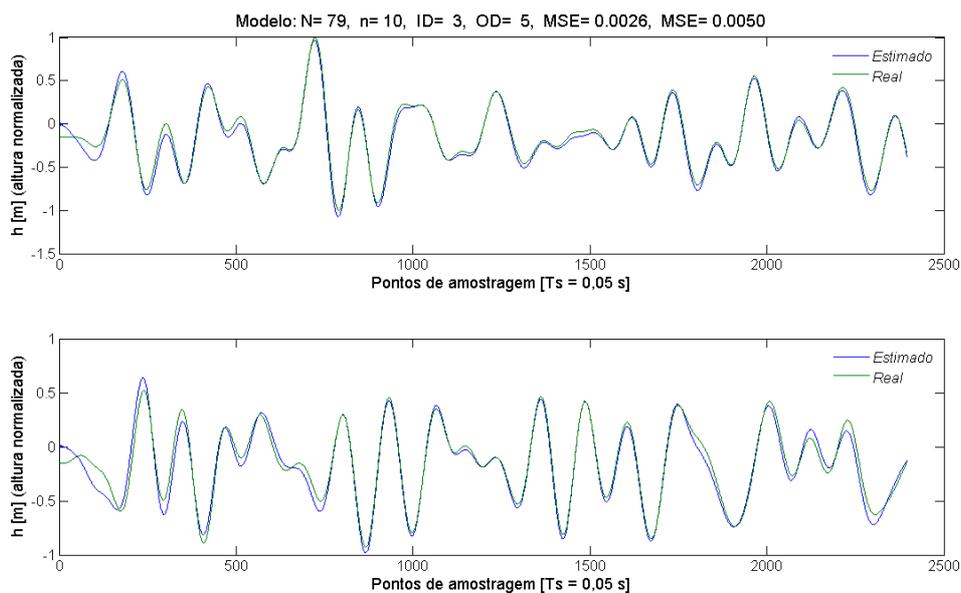


Figura 4.3 Modelo 29 (Neuronal): 3 atrasos na entrada, 5 atrasos na saída e 10 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente.

#### 4.1.3 Modelos para $\xi$ , com uma velocidade da turbina de 100 rad/s

Modelos para $\xi$ (100 rad/s)					
Atrasos Entrada	Atrasos Saída	Desempenho Treino	Desempenho Validação	Desempenho Novos Valores	Número Neurónios
1	2	2,40E-08	0,005552	0,009254	14
1	3	1,60E-07	0,015588	0,029672	14
2	5	2,59E-07	0,006633	0,009102	12
4	5	4,95E-07	0,015567	0,02252	18
6	5	1,33E-07	0,006828	0,011693	11
1	6	5,78E-07	0,004261	0,008634	14

Tabela 4.3 Modelo 22V4 (Neuronal)

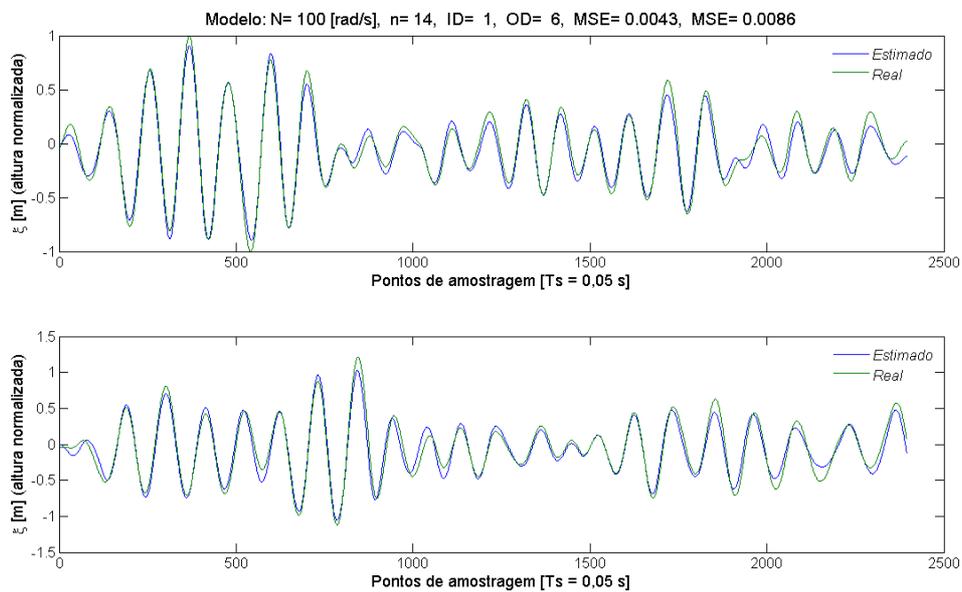


Figura 4.4 Modelo 22V4 (Neuronal): 1 atrasos na entrada, 6 atrasos na saída e 14 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente.

#### 4.1.4 Modelos para $h$ , com uma velocidade da turbina de 100 rad/s

Modelos para $h$ (100 rad/s)					
Atrasos Entrada	Atrasos Saída	Desempenho Treino	Desempenho Validação	Desempenho Novos Valores	Número Neurónios
2	2	7,24E-11	0,001375	0,027045	12
3	2	6,36E-08	0,072694	0,092606	14
4	2	9,86E-08	0,044216	0,096753	12
4	2	3,33E-08	0,068666	0,074023	19
5	2	5,24E-10	0,042728	0,023562	19
6	2	1,95E-08	0,044604	0,080029	10
6	3	7,43E-08	0,047582	0,090149	13
7	3	1,32E-08	0,064939	0,047313	19
1	4	6,63E-08	0,021824	0,053337	12
2	4	6,36E-09	0,082274	0,068735	14
2	5	3,35E-08	0,023435	0,031234	16
5	5	2,90E-08	0,059405	0,033792	12
5	5	9,03E-09	0,014278	0,078626	13
7	6	3,97E-09	0,035925	0,054032	16
4	7	9,37E-08	0,030351	0,094757	12

Tabela 4.4 Modelo 25 (Neuronal)

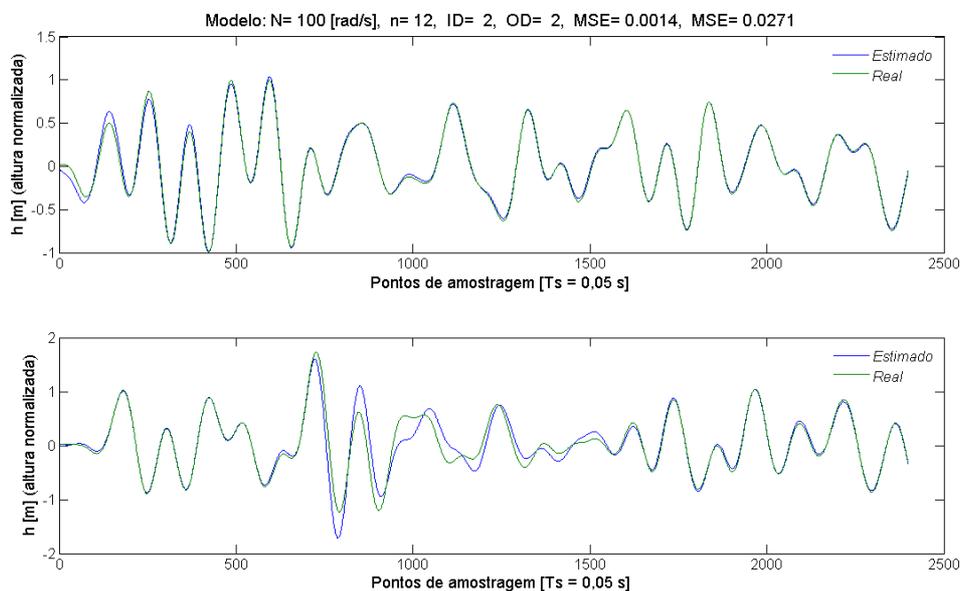


Figura 4.5 Modelo 25 (Neuronal): 2 atrasos na entrada, 2 atrasos na saída e 12 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente.

#### 4.1.5 Modelos para $\xi$ , com uma velocidade da turbina de 157 rad/s

Modelos para $\xi$ (157 rad/s)					
Atrasos Entrada	Atrasos Saída	Desempenho Treino	Desempenho Validação	Desempenho Novos Valores	Número Neurónios
3	2	1,21E-08	0,00386	0,019835	15
4	2	3,55E-08	0,01078	0,022172	18
5	2	1,22E-07	0,016801	0,025883	10
5	2	2,00E-08	0,004033	0,009726	11
6	2	7,69E-08	0,021766	0,020409	16
2	3	2,93E-08	0,004087	0,014377	13
4	3	3,51E-08	0,008376	0,023499	16
5	3	3,19E-08	0,005183	0,022705	12
5	3	5,65E-08	0,004303	0,020312	13
1	4	5,69E-07	0,008453	0,023133	10
1	5	9,63E-08	0,00567	0,019951	11
4	5	1,31E-07	0,008992	0,022073	16
5	6	5,54E-07	0,006947	0,015683	12
4	7	6,81E-07	0,005387	0,026817	12
4	7	4,57E-07	0,011071	0,028145	13

Tabela 4.5 Modelo 26V3 (Neuronal)

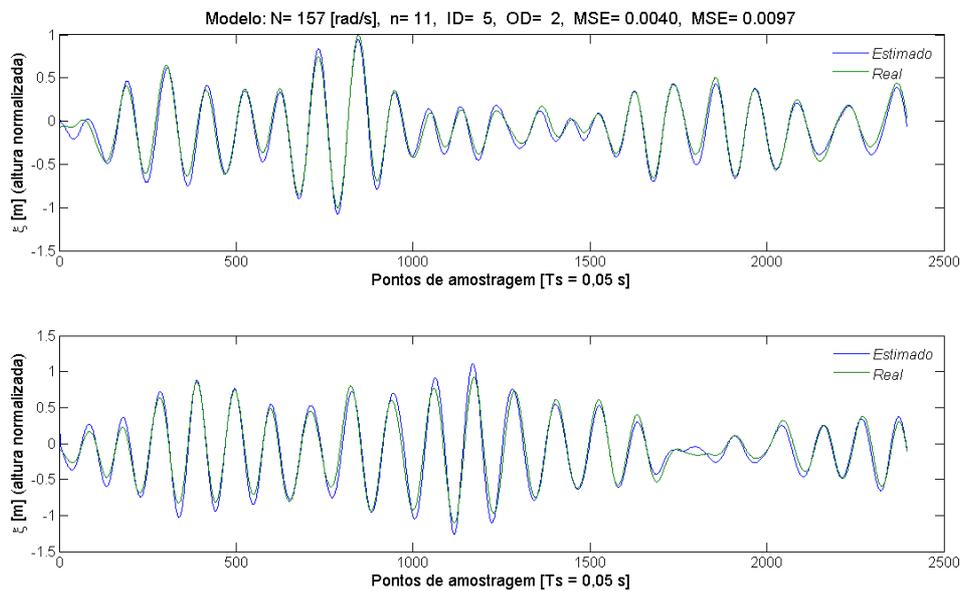
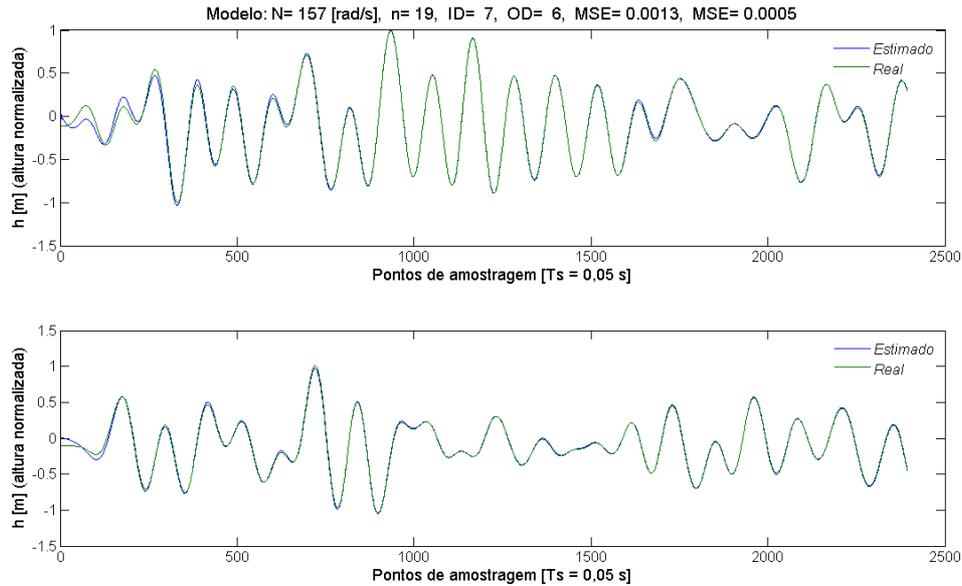


Figura 4.6 Modelo 26V3 (Neuronal): 5 atrasos na entrada, 2 atrasos na saída e 11 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente.

#### 4.1.6 Modelos para $h$ , com uma velocidade da turbina de 157 rad/s

Modelos para $h$ (157 rad/s)					
Atrasos Entrada	Atrasos Saída	Desempenho Treino	Desempenho Validação	Desempenho Novos Valores	Número Neurónios
1	3	1,01E-08	0,005735	0,005748	19
4	3	1,84E-08	0,010574	0,006705	10
6	3	7,84E-09	0,005826	0,004901	15
5	4	1,14E-07	0,023794	0,018874	19
1	5	2,01E-07	0,023603	0,029529	11
1	5	2,52E-07	0,028782	0,024523	16
1	5	2,01E-07	0,012777	0,01949	20
3	5	1,59E-07	0,008802	0,007706	17
4	5	1,81E-07	0,013963	0,009401	19
7	5	3,28E-07	0,016345	0,016994	17
7	5	2,05E-07	0,023766	0,027527	20
2	6	3,90E-07	0,016471	0,014087	14
2	6	1,98E-07	0,006135	0,004014	16
3	6	2,10E-07	0,021571	0,022591	11
3	6	3,79E-07	0,01487	0,026804	19
7	6	4,61E-07	0,023611	0,028179	10
7	6	1,58E-07	0,01165	0,008842	18
7	6	5,20E-10	0,001317	0,000537	19
1	7	4,52E-07	0,012247	0,009437	14
3	7	9,86E-07	0,026196	0,013523	11
3	7	2,85E-07	0,013623	0,013872	13
3	7	8,00E-07	0,018127	0,017674	14
3	7	3,95E-07	0,02491	0,02438	18
4	7	5,53E-07	0,019127	0,022742	15
4	7	1,58E-07	0,004922	0,004006	18
5	7	2,22E-09	0,001221	0,002457	20
6	7	4,31E-07	0,015732	0,011066	20

Tabela 4.6 Modelo 27 (Neuronal)



**Figura 4.7 Modelo 27 (Neuronal): 7 atrasos na entrada, 6 atrasos na saída e 19 neurónios. Os gráficos, superior e inferior, são relativos aos dados de treino e de validação, respectivamente.**

#### 4.1.7 Observações aos modelos em Redes Neurais

No ponto 4.1.2, relativo à saída  $h$  para uma velocidade de 79 rad/s, foram assinalados, excepcionalmente, dois modelos por serem representativos do critério: qualidade *versus* simplicidade. Repare-se que o desempenho é muito semelhante em ambos, assim como as suas arquitecturas da rede neuronal em termos de atrasos, mas apresentam uma diferença significativa na quantidade de neurónios, 10, utilizados na camada interna.

À excepção do modelo 25, relativo à saída  $h$ , para uma velocidade da turbina de 100 rad/s, todos os outros modelos conseguiram obter resultados num segundo filtro, mais apertado, que estipulava um critério de desempenho com  $MSE$  inferior a uma centésima.

## 4.2 Modelos NARX, inversos, em Redes Neurais

A perspectiva de controlo subjacente a este trabalho assentava, inicialmente, numa estratégia IMC (*Internal Model Control*), actuando na velocidade da turbina, variável manipulada, de modo a estabelecer uma sintonia entre a frequência natural de ressonância do dispositivo e a frequência das ondas incidentes, otimizando o potencial máximo de extracção possível da energia das ondas. Para a implementação desta estratégia é forçoso determinar a estrutura dos modelos inversos, capazes de estimar a velocidade de rotação da turbina,  $N$ , na saída da rede neuronal para uma entrada, simples ou composta, com a elevação da onda e/ou da elevação do aparelho.

Esta estratégia acabou por não ser implementada porque foi impossível encontrar, em tempo útil e com uma enorme diversidade de abordagens, modelos minimamente aceitáveis, com as variáveis pretendidas. Para além dos valores das variáveis obtidos com uma configuração estática da velocidade da turbina, recorreu-se a configurações com perfis de velocidade variável: quatro patamares regulares consecutivos, em períodos de um quarto do tempo de simulação, 750 – 1000 – 1250 – 1500 r.p.m (78 – 104,6 – 130,8 – 157 rad/s); sinal variável, do tipo *chirp*, entre os valores mínimo e máximo pretendidos: 750 e 1500 r.p.m. Este tipo de sinal varia entre os valores limite com uma frequência variável, entre 0,1 e 1 Hz, ao longo do tempo de simulação. As tentativas realizadas utilizando um perfil de velocidade por patamares estenderam-se do *Modelo 30* ao *Modelo 39*. Na parte final do texto, na secção dos “Anexos”, apresentam-se, em forma de tabela, as configurações dos modelos enunciados a seguir.

O modelo 30 usa o vector *wave\_elevation* como entrada e estima, na saída, o valor de  $\zeta$ . É uma arquitectura para um modelo directo e conseguiu 8 combinações com um bom desempenho,  $MSE < 0,03$ , tanto nos dados de treino como nos de validação.

O modelo 31 usa o vector *wave\_elevation* como entrada e estima, na saída, o valor de  $h$ . É uma arquitectura para um modelo directo mas o desempenho não foi muito interessante. Para os dados de validação o melhor resultado foi:  $MSE < 0.1466$ .

Nos modelos 32, 33, 35 e 36 (por lapso, saltou-se o 34 na numeração) utilizaram-se entradas compostas, com o vector de velocidade da turbina,  $N$ , mas os resultados não foram interessantes.

O modelo 37, com uma arquitectura parcialmente inversa, usa os vectores *wave\_elevation* +  $h$  na entrada para estimar, na saída,  $N + \zeta$ . O desempenho não foi muito conseguido, o melhor resultado alcançado, com os dados de validação, foi:  $MSE < 0.7102$

O modelo 38, com uma arquitectura inversa, utiliza o vector *wave\_elevation*, na entrada, para estimar  $N$ , na saída. O desempenho, embora superior ao anterior, não foi muito conseguido, o melhor resultado alcançado, com os dados de validação, foi:  $MSE < 0.2244$ .

O modelo 39, com uma arquitectura inversa, utiliza o vector  $h$ , na entrada, para estimar  $N$ , na saída. O desempenho não foi muito conseguido, o melhor resultado alcançado, com os dados de validação, foi:  $MSE < 0.2180$ .

Na sequência destes resultados pouco animadores, passou-se à tentativa de conseguir modelos inversos através de dados obtidos com uma configuração do modelo *ipsneck* em que a velocidade da turbina é variável, com um perfil do tipo *chirp*.

O modelo 40, com uma arquitectura inversa, utiliza o vector *wave\_elevation*, na entrada, para estimar  $N$ , na saída. O desempenho não foi muito conseguido, o melhor resultado alcançado, com os dados de validação, foi:  $MSE < 0.5029$ .

O modelo 40V2 é uma ligeira variação do anterior, em que se tentou um novo limite do erro,  $1 \times 10^{-7}$ , no critério de paragem da fase de treino, em vez do valor  $1 \times 10^{-6}$ , utilizado nas outras tentativas. A alteração do valor das épocas ou do erro é uma das técnicas possíveis para otimizar a qualidade dos modelos pretendidos. A diminuição do valor do erro pode implicar um treino demasiado específico para os dados utilizados nessa fase, culminando na penalização de uma desejada generalização da rede neuronal. Não foi o caso, mas esta alteração também não se mostrou muito influente, pois o melhor resultado alcançado, com os dados de validação, foi:  $MSE < 0.5179$ .

O modelo 41, voltou a utilizar o mesmo valor de  $1 \times 10^{-6}$  no critério de paragem mas substituiu a variável de entrada por *pinside*. O desempenho foi desastroso, o melhor resultado alcançado, com os dados de validação, foi:  $MSE < 10$ ; com os dados de treino:  $MSE < 0.6616$ .

Como uma das premissas deste trabalho estipulava a análise e obtenção de resultados através do recurso a duas tecnologias distintas, Redes Neurais e Lógica Fuzzy, que permitisse a comparação dos resultados alcançados e uma vez que todas as tentativas realizadas no sentido de encontrar modelos para a estimação da velocidade da turbina,  $N$ , não tinham sido bem sucedidas, optou-se por se passar a uma tecnologia alternativa, a Lógica Fuzzy, na expectativa de se conseguir ultrapassar o impasse criado pela falta dos modelos inversos. Para além das ferramentas disponíveis no Matlab, utilizou-se, igualmente, uma *toolbox* externa, desenvolvida pelo Prof. Robert Babuska, e começou-se por encontrar os modelos directos, num procedimento paralelo, como convinha, ao que foi utilizado no caso das redes neuronais, de modo a permitir a comparação de resultados.

Apresentam-se, de seguida, as tabelas de resultados e os gráficos respectivos, relativos aos melhores modelos conseguidos. Devido ao modo de funcionamento da *toolbox* utilizada, referida no parágrafo anterior, apresenta-se apenas o gráfico relativo aos dados de validação, diferentes dos que são utilizados na fase de treino; esta abordagem é semelhante à utilizada nos testes realizados para os modelos com redes neuronais.

### 4.3 Modelos NARX, directos, utilizando lógica Fuzzy

#### 4.3.1 Modelos para $\xi$ , com uma velocidade da turbina de 79 rad/s

Modelos para $\xi$ (79 rad/s)				
Atrasos Entrada	Atrasos Saída	Atrasos Puros	Número Clusters	VAF
5	3	0	2	96,91051
5	3	1	2	96,8519
5	3	2	2	96,8062
5	3	3	2	96,75877
5	3	4	2	96,68569
5	4	1	2	96,63061

Tabela 4.7 Modelo 50V3 (Fuzzy)

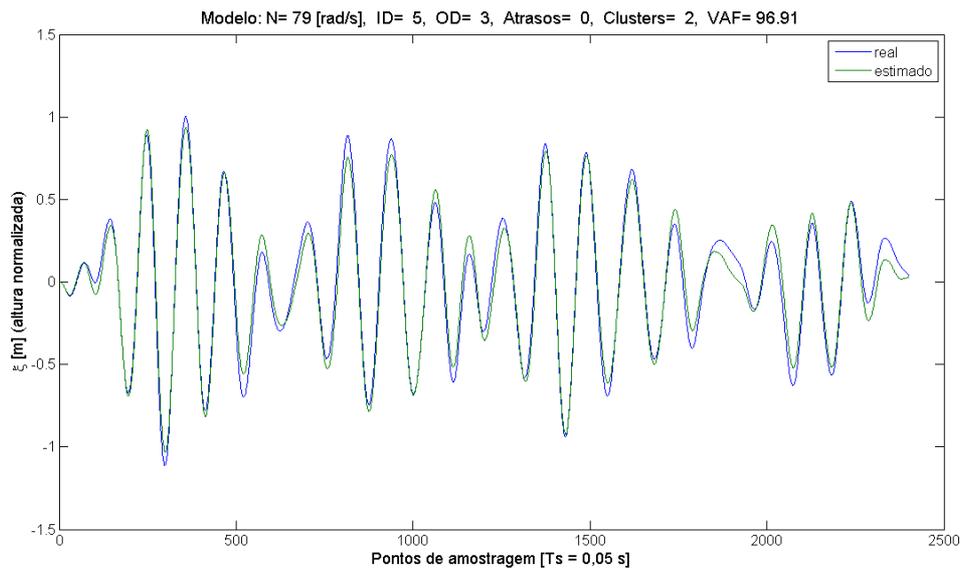


Figura 4.8 Modelo 50V3 (Fuzzy): 5 atrasos na entrada, 3 atrasos na saída, 0 atrasos puros e 2 clusters.

#### 4.3.2 Modelos para $h$ , com uma velocidade da turbina de 79 rad/s

Modelos para $h$ (79 rad/s)				
Atrasos Entrada	Atrasos Saída	Atrasos Puros	Número Clusters	VAF
3	2	4	1	99,60135
3	2	5	1	99,60282
2	3	4	3	99,63253
2	3	5	3	99,66838
1	4	0	3	99,68389
1	4	0	4	99,70812
1	4	1	4	99,65053
1	4	2	4	99,66422
2	4	1	1	99,60915

Tabela 4.8 Modelo 51 (Fuzzy)

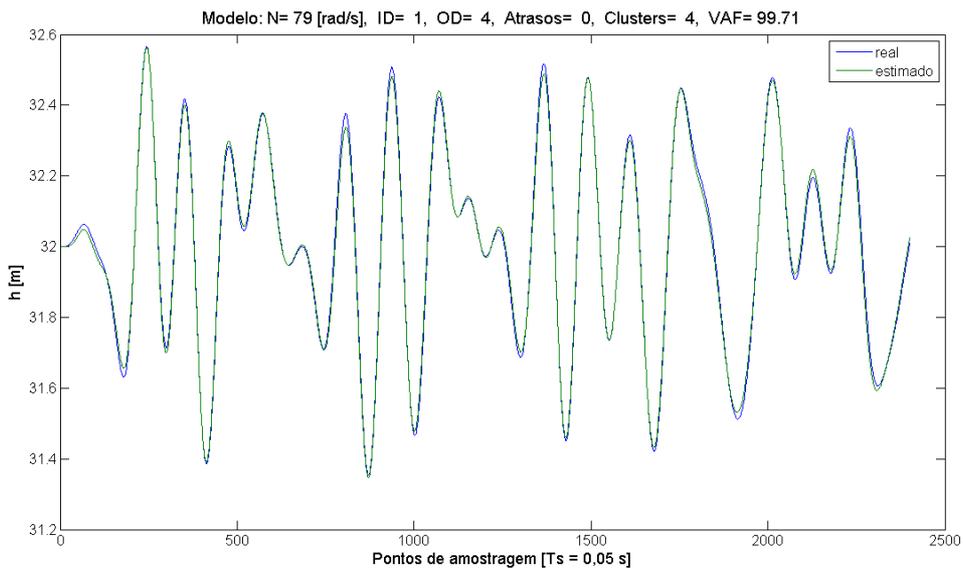


Figura 4.9 Modelo 51 (Fuzzy): 1 atraso na entrada, 4 atrasos na saída, 0 atrasos puros e 4 clusters.

### 4.3.3 Modelos para $\xi$ , com uma velocidade da turbina de 100 rad/s

Modelos para $\xi$ (100 rad/s)				
Atrasos Entrada	Atrasos Saída	Atrasos Puros	Número Clusters	VAF
2	3	1	1	96,56070
4	3	1	1	96,56484
4	3	2	1	96,62526
4	3	3	1	96,68323
4	3	4	1	96,76884
4	3	4	2	96,67505
5	3	0	1	96,55282
5	3	1	1	96,58491
5	3	2	1	96,59156
5	3	3	1	96,59073
5	3	4	1	96,58514
5	3	5	1	96,57411
3	4	0	1	96,60214

Tabela 4.9 Modelo 48 (Fuzzy)

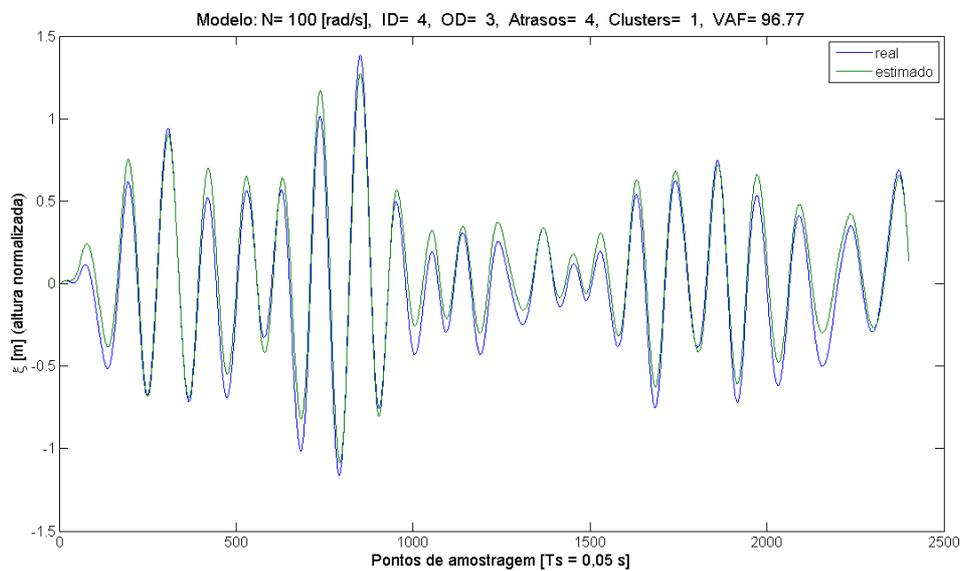


Figura 4.10 Modelo 48 (Fuzzy): 4 atraso na entrada, 3 atrasos na saída, 4 atrasos puros e 1 cluster.

#### 4.3.4 Modelos para $h$ , com uma velocidade da turbina de 100 rad/s

Modelos para $h$ (100 rad/s)				
Atrasos Entrada	Atrasos Saída	Atrasos Puros	Número Clusters	VAF
3	2	0	3	99,75828
3	2	0	4	99,76508
3	2	1	3	99,75356
3	2	1	4	99,7628
3	2	2	4	99,75996
3	2	3	4	99,75641
3	2	4	4	99,75211
3	2	5	4	99,75136
5	2	0	3	99,77593
5	2	1	3	99,77551
5	2	2	3	99,77259
5	2	2	4	99,75718
5	2	3	3	99,77559
5	2	3	4	99,7651
5	2	4	3	99,77711
5	2	4	4	99,76639
5	2	5	3	99,77437
5	2	5	4	99,75648

Tabela 4.10 Modelo 49 (Fuzzy)

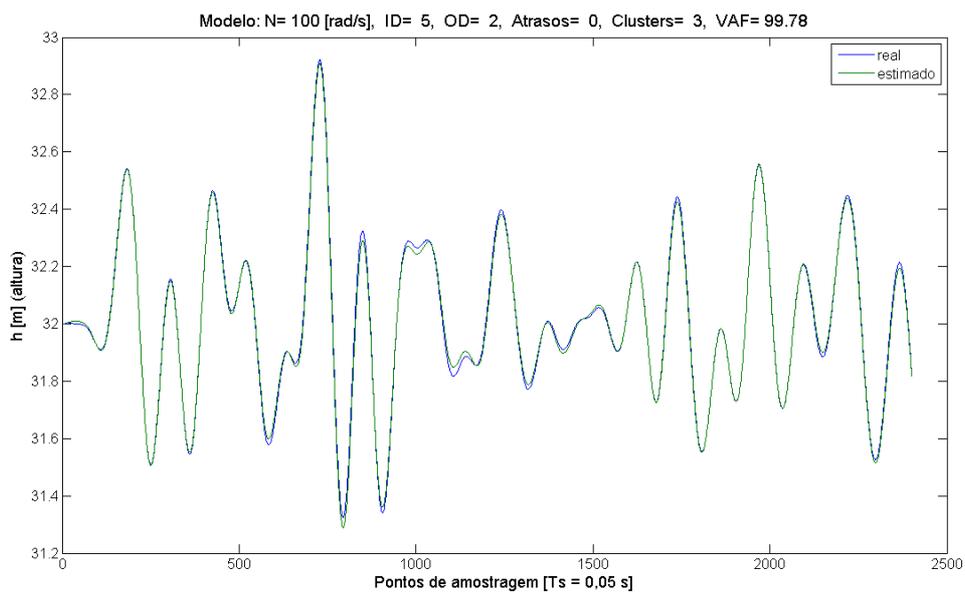


Figura 4.11 Modelo 49 (Fuzzy): 5 atrasos na entrada, 2 atrasos na saída, 0 atrasos puros e 3 clusters.

#### 4.3.5 Modelos para $\xi$ , com uma velocidade da turbina de 157 rad/s

Modelos para $\xi$ (157 rad/s)				
Atrasos Entrada	Atrasos Saída	Atrasos Puros	Número Clusters	VAF
2	3	0	1	97,03882
3	3	0	1	97,0513
3	3	2	2	97,13276
4	3	0	1	97,09411
4	3	1	1	97,19036
4	3	1	2	97,05609
4	3	2	1	97,23195
4	3	2	2	97,40492
4	3	3	1	97,35429
4	3	3	2	97,58729
4	3	4	1	97,54221
5	3	0	1	97,22677
5	3	0	2	97,03468
5	3	1	1	97,22872
5	3	1	2	97,06038
5	3	2	1	97,21867
5	3	2	2	97,06334
5	3	3	1	97,20337
5	3	3	2	97,05578
5	3	4	1	97,18258
5	3	4	2	97,04094
5	3	5	1	97,15345
5	3	5	2	97,00597
3	4	0	1	97,31544

Tabela 4.11 Modelo 52 (Fuzzy)

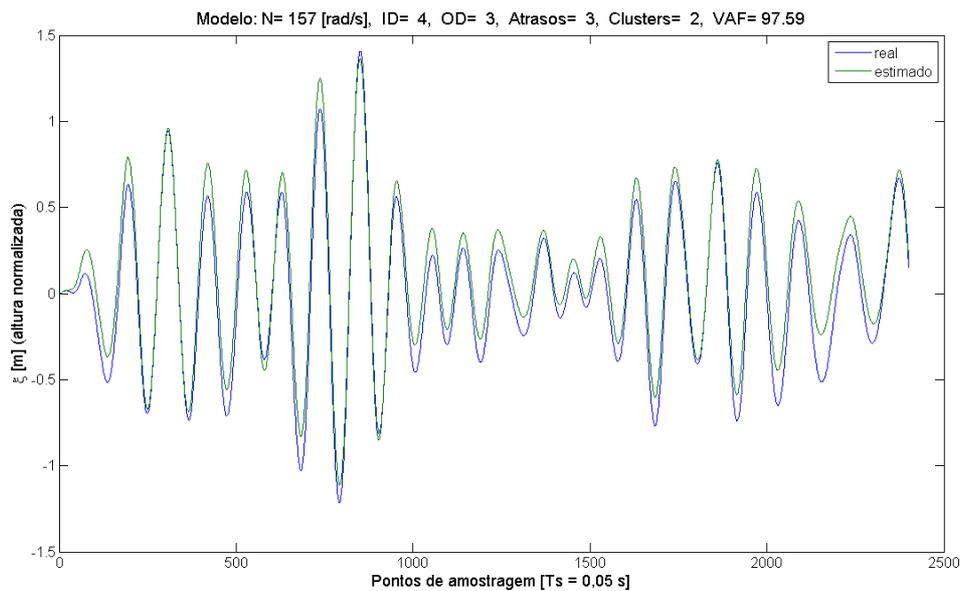


Figura 4.12 Modelo 52 (Fuzzy): 4 atrasos na entrada, 3 atrasos na saída, 3 atrasos puros e 2 clusters.

#### 4.3.6 Modelos para $h$ , com uma velocidade da turbina de 157 rad/s

Modelos para $h$ (157 rad/s)				
Atrasos Entrada	Atrasos Saída	Atrasos Puros	Número Clusters	VAF
3	2	0	3	99,83339
3	2	1	3	99,83162
4	2	0	3	99,83589
4	2	0	4	99,84077
4	2	1	3	99,83707
4	2	1	4	99,84193
4	2	2	3	99,83616
4	2	2	4	99,84232
4	2	3	3	99,83932
4	2	3	4	99,84238
4	2	4	3	99,84061
4	2	4	4	99,84329
4	2	5	3	99,83039
4	2	5	4	99,84143

Tabela 4.12 Modelo 53 (Fuzzy): 4 atrasos na entrada, 2 atrasos na saída, 4 atrasos puros e 4 clusters.

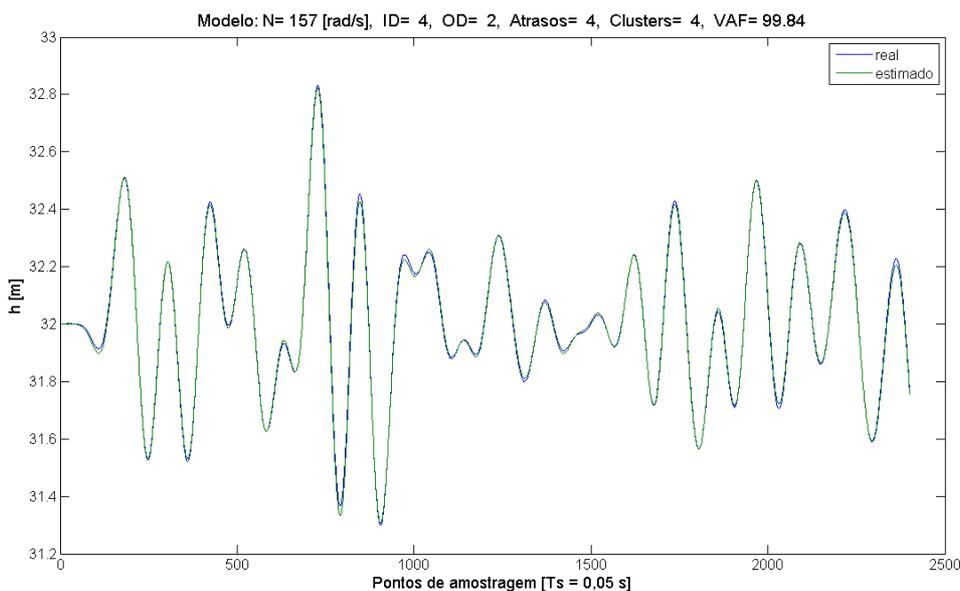


Figura 4.13 Modelo 53 (Fuzzy): 4 atrasos na entrada, 2 atrasos na saída, 4 atrasos puros e 4 clusters.

#### 4.3.7 Observações aos modelos em lógica Fuzzy

Antes de mais, torna-se evidente a quase constante e superior qualidade dos modelos relativos à estimação da altura da coluna de água,  $h$ , independentemente da tecnologia utilizada: redes neuronais ou lógica Fuzzy; basta uma simples inspeção visual para observar a maior justaposição dos gráficos respectivos. O melhor desempenho dos modelos para a variável  $\zeta$  apresenta um VAF na ordem dos 96%,

enquanto para os relativos à saída  $h$  é da ordem dos 99%. É de salientar, igualmente, que para a primeira variável se tenham conseguido arquitecturas com 1 (modelos lineares ou afins) ou 2 *clusters*, ao passo que para a segunda se obtiveram, salvo raras excepções, sempre modelos com 3 e 4 *clusters*.

A lógica Fuzzy acabou por conseguir resultados muito próximos dos que foram obtidos com as redes neuronais, embora com algumas vicissitudes específicas, nomeadamente em termos do tempo de computação, que foi superior, e em termos de estabilidade das rotinas desenvolvidas, que passaram por alguns problemas de convergência, exigindo medidas adicionais ao nível do código, de modo a ultrapassar estados de indefinição dos resultados do tipo *NaN* (*Not a Number*), relativos aos valores próprios (*eigenvalues*) das matrizes utilizadas no algoritmo da rotina *fmsim*, inserida na *toolbox FMID*, que bloqueavam o regular processamento computacional; a referência *NaN* é atribuída aos resultados com valores considerados infinitos. A forma de ultrapassar a ocorrência de resultados não numéricos foi através da instrução “*try – catch*”, embora não tenha sido suficiente para ultrapassar todas as situações de indefinição.

Enquanto as rotinas desenvolvidas para a pesquisa de modelos através das redes neuronais conseguiram realizar, sempre, as 462 tentativas, com a lógica Fuzzy o comportamento foi bastante diferente e mais imprevisível. A maior parte das rotinas não conseguiu realizar os 480 ciclos das tentativas possíveis.

#### 4.4 Modelos *NARX*, inversos, utilizando lógica Fuzzy

Depois de encontrados os modelos directos, os quais foram apresentados nas tabelas anteriores e nos respectivos gráficos, para o melhor dos modelos em cada um dos patamares de velocidade da turbina, tentou-se encontrar os modelos inversos, através de variadíssimas abordagens, conforme se dá conta de seguida, mas sempre sem sucesso. O processo foi muito idêntico ao utilizado anteriormente com as redes neuronais.

O modelo 55 utilizou as entradas:  $wave\_elevation + \zeta + h$ , para estimar a saída:  $N$ ; para estas tentativas utilizaram-se vectores de dados obtidos com um perfil de velocidade variável, do tipo *chirp*, na simulação do modelo *ipsneck*; os limites, mínimo e máximo, foram as já referidas 750 e 1500 r.p.m., respectivamente. O *VAF* obtido nestas tentativas foi sempre negativo.

O modelo 55V2, com os mesmos parâmetros, utilizou apenas um conjunto de dados, em que os vectores foram divididos ao meio para teste e validação, respectivamente. Não foi muito melhor sucedido que o anterior, pois o resultado também foi sempre  $VAF < 0$ .

Para o mesmo perfil de velocidade, tentaram-se as seguintes combinações nas variáveis de entrada:

Modelo 56 – Entradas:  $wave\_elevation + \zeta$ , saída:  $N$ ;  $VAF < 0$ .

Modelo 57 – Entradas:  $wave\_elevation + h$ , saída:  $N$ ;  $VAF < 0$ .

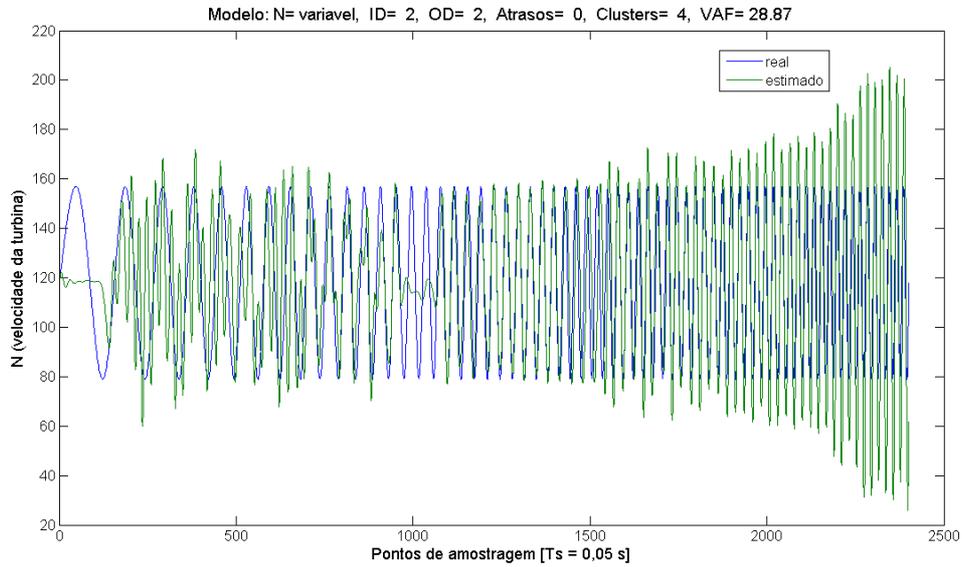
Modelo 58 – Entradas:  $\zeta + h$ , saída:  $N$ ;  $VAF < 0$ .

Modelo 59 – Entrada:  $wave\_elevation$ , saída:  $N$ ;  $VAF \leq 0.42$ .

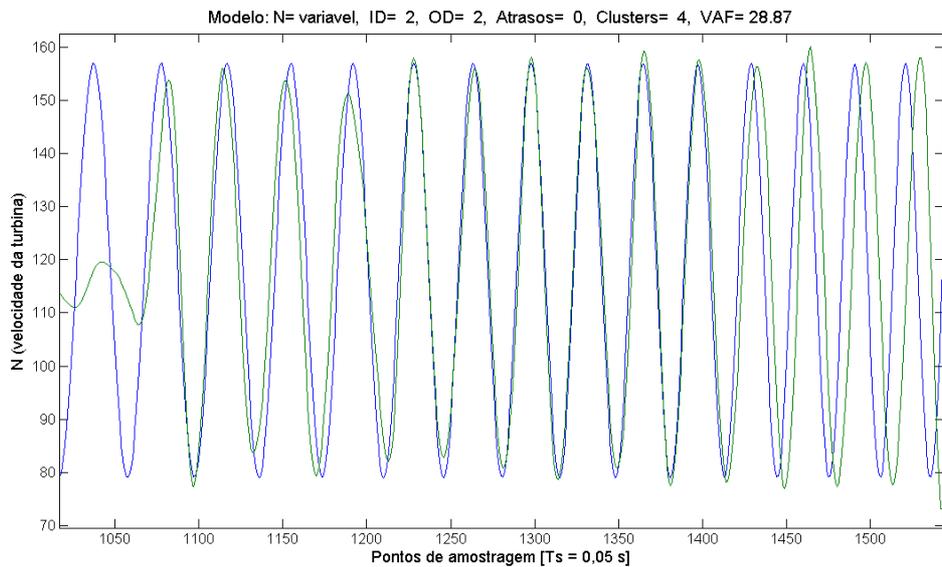
Modelo 60 – Entrada:  $\zeta$ , saída:  $N$ ;  $VAF < 0$ .

Modelo 61– Entrada:  $h$ , saída:  $N$ ;  $VAF < 0$ .

No modelo 62 utilizou-se uma nova combinação de variáveis na entrada:  $F_{turb} + h$ . O resultado não foi muito conseguido, embora se tivesse obtido uma saída muito credível numa faixa de frequências muito pequena para o perfil de variação da velocidade, conforme se apresenta nas figuras seguintes.



**Figura 4.14 Modelo 62 (Fuzzy): o perfil de velocidade varia entre 79 e 157 rad/s, com uma frequência entre 0,1 e 1 Hz (sinal do tipo *chirp*)**



**Figura 4.15 Modelo 62 (Fuzzy): ampliação da imagem anterior entre os instantes 1000 e 1500 (devido ao período de amostragem de 0,05 s, equivalem a 50 s e 75 s, respectivamente).**

Este resultado, apesar de ser único no universo das 480 tentativas realizadas com esta combinação de entradas, acabou por representar um vislumbre de possibilidade na obtenção dos modelos inversos. A tentativa seguinte passou pela recolha de um conjunto de dados novos, gerado a partir de uma configuração com o perfil da velocidade do tipo *chirp*, mas variando, apenas, numa gama de frequências limitada ao intervalo entre 0,34 e 0,68 Hz. Esta tentativa, um pouco estranhamente, não conseguiu nenhum desempenho superior ao obtido anteriormente; por lapso, os resultados não foram gravados e teve que se repetir a experiência, posteriormente, conforme se dará conta mais à frente, quando se apresentar o modelo 76.

O modelo 63 utilizou uma entrada de uma única variável, *Fturb*, com o perfil da velocidade do tipo *chirp* normal, mas não conseguiu nenhum bom resultado;  $VAF \leq 0,4438$ .

O modelo 64 utilizou uma entrada combinada e diferente das utilizadas, anteriormente, *Pinside + h*, com um perfil do tipo *chirp* a variar entre as frequências 12 e 25 Hz, mas não obteve qualquer resultado significativo;  $VAF \leq 1,3589$ .

O modelo 65 utilizou as mesmas variáveis *Pinside + h*, mas obtidas numa nova simulação do modelo *ipsneck* com o perfil da velocidade da turbina do tipo *chirp*, a variar entre as frequências 0,34 e 0,68 Hz, por causa do resultado alcançado com o modelo 62. Os resultados não foram satisfatórios, com o melhor modelo a apresentar um desempenho com  $VAF = 9.1754$ .

O modelo 66 foi em tudo idêntico ao anterior, à exceção da variável *Pinside*, que foi utilizada com o módulo do seu valor. O melhor resultado conseguiu um  $VAF = 15.7109$ .

O modelo 67 utilizou as mesmas variáveis,  $|Pinside| + h$ , mas os valores foram obtidos numa simulação do modelo *ipsneck* com perfil de velocidade gerado por ruído branco. O melhor resultado conseguido obteve um desempenho com  $VAF = 0.4440$ .

Do modelo 68 ao 75, inclusive, todos utilizaram os valores das variáveis obtidos para o modelo anterior, embora tenha havido, em cada um deles, modificações no número e na combinação das variáveis de entrada, conforme se pode observar na lista de modelos apresentada na tabela seguinte, na qual se apresenta a variável *wave\_elevation* pelo símbolo  $\eta$ .

Modelos			
Referência do modelo	Variáveis de entrada	Número de tentativas	Melhor VAF
68	$\eta, \xi, h$	240	0.2253
69	<i>Fturb, h</i>	480	0.0166
70	$\eta, h$	480	-0.0630
71	$\eta, \xi$	480	-0.0259
72	$\xi, h$	480	0.0926
73	$\eta$	480	0.1475
74	$\xi$	480	0.3193
75	<i>h</i>	480	0.2807

**Tabela 4.13** Valor do melhor desempenho, respectivamente, do conjunto de modelos entre o 68 e o 75.

O modelo 76, conforme a chamada de atenção anterior, referida aquando do modelo 62, utiliza as variáveis  $F_{turb} + h$ , obtidas com uma simulação em que a velocidade da turbina apresentou um perfil do tipo *chirp*, a variar entre as frequências 0,34 e 0,68 Hz. O melhor resultado conseguiu um  $VAF = 16.0135$ , ligeiramente inferior ao do modelo 62.

O modelo 77 tem a mesma configuração do anterior mas apresenta estimativas para o simétrico do valor da velocidade,  $-N$ , porque da observação dos muitos gráficos dos modelos anteriores, ressaltou a impressão, por vezes, de que as linhas estavam em “contra-ciclo”. No entanto, o resultado não foi positivo, literalmente, já que o melhor  $VAF = -157.7551$ .

O modelo 77V2 foi uma ligeira variação do anterior, como o próprio nome sugere, dado que se utilizou o valor simétrico da velocidade apenas no vector usado para a fase de treino; o desempenho não variou nada,  $VAF = -157.7551$ .

O modelo 78 variou, relativamente aos anteriores, pela utilização, exclusiva, dos valores positivos de  $F_{turb}$ , na fase de treino;  $VAF = -0.2207$ .

O modelo 78V2 utilizou os valores positivos de  $F_{turb}$  também para a fase de validação;  $VAF = 0.9069$ .

O modelo 79 voltou a utilizar uma combinação diferente de variáveis na entrada, tendo-se substituído o valor da altura  $h$  pelo da respectiva derivada ( $dh$ ):  $wave\_elevation + \zeta + dh$ . O perfil *chirp* da velocidade da turbina voltou a variar no intervalo de frequências entre 0,1 e 1 Hz;  $VAF < 0$ .

O modelo 80 é idêntico ao anterior mas com as entradas:  $F_{turb} + h + dh$ ;  $VAF < 0$ .

O modelo 81, idem, com as entradas:  $F_{turb} + dh$ ;  $VAF < 0$ .

O modelo 82, com as entradas:  $F_{turb} + h$ , é idêntico ao modelo 62, embora utilize um novo conjunto de valores, obtido nas mesmas condições. Foi uma tentativa realizada com o objectivo de validar a consistência dos resultados obtidos anteriormente, os quais acabariam por se verificar, pela proximidade dos valores relativos ao respectivo melhor desempenho,  $VAF = 20.9$ ; curiosamente, este valor foi obtido pelo modelo com uma arquitectura idêntica: 2 atrasos na entrada, 2 atrasos na saída, 0 atrasos puros e 4 *clusters*. O gráfico do modelo 62 era mais interessante, mas o desempenho,  $VAF = 28,87$ , também era um pouco superior.

Depois de todas as variantes das tentativas realizadas para modelar a velocidade da turbina,  $N$ , o modelo 83 faz uma abordagem diferente, através da potência da turbina, que pode ser uma forma indirecta de chegar à velocidade. As condições de realização destas tentativas são idênticas às dos modelos anteriores, bem como os próprios dados utilizados. A entrada combinada,  $F_{turb} + h$ , é igual, também, à do modelo anterior e a única diferença está na saída, que utiliza  $P_{turb}$ . O desempenho foi muito mais conseguido, tendo-se obtido 3 valores superiores a 60%, conforme os resultados apresentados na Tabela 4.14 e no gráfico relativo ao modelo com o melhor desempenho.

Modelos para $P_{turb}$ ( $N$ variável)				
Atrasos Entrada	Atrasos Saída	Atrasos Puros	Número Clusters	VAF
2	3	0	4	64,36823
2	3	1	4	60,97405
3	3	2	3	62,59348

Tabela 4.14 Modelo 83 (Fuzzy)

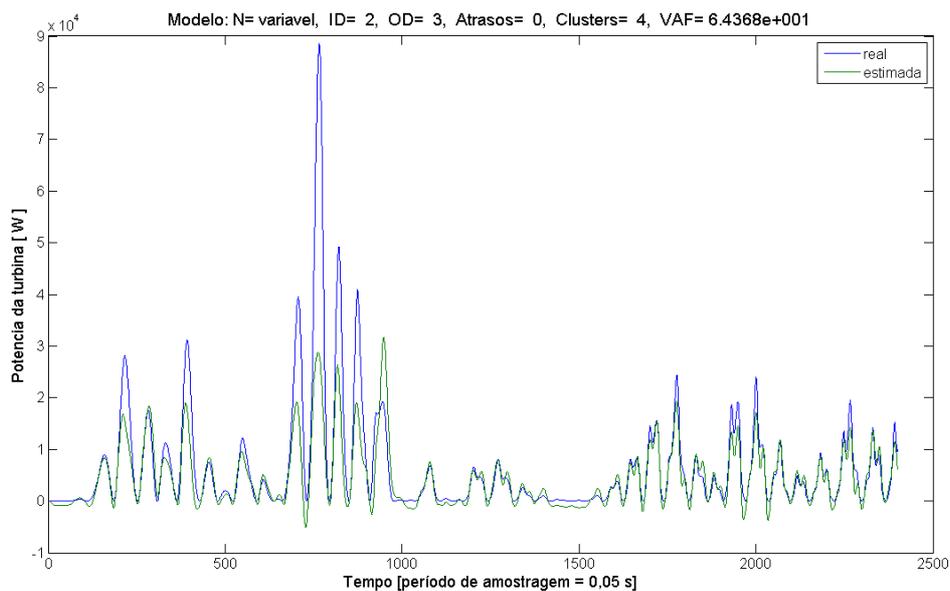


Figura 4.16 Modelo 83 (Fuzzy): 2 atrasos na entrada, 3 atrasos na saída, 0 atrasos puros e 4 clusters.

## 4.5 Interpolação com modelos directos

A estratégia de controlo pretendida, IMC, presume o conhecimento dos modelos directo e inverso do processo em causa. No entanto, como referido, para as duas tecnologias em causa, não se conseguiu determinar nenhum modelo inverso capaz de oferecer um desempenho adequado e com o nível de qualidade dos modelos directos; esta circunstância acaba por evidenciar uma fraca dependência do aparelho ou, no mínimo, das variáveis em causa, relativamente à velocidade da turbina.

Para ultrapassar esta dificuldade, uma das estratégias possíveis seria a adopção da técnica de controlo preditivo, que assenta no conhecimento dos modelos directos. Assim, nos pontos anteriores deste capítulo, apresentaram-se os resultados e os modelos obtidos, respectivamente, tanto com o recurso a Redes Neurais como a Lógica Fuzzy, para velocidades fixas da turbina, nomeadamente,  $N = 79$ ,  $N = 100$  e  $N = 157$ . Estes modelos, dentro de cada uma das respectivas tecnologias envolvidas, servem de alicerce à construção de um mecanismo de interpolação capaz de devolver o valor das variáveis  $\zeta$  e  $h$ , em função da altura da onda, para uma velocidade específica da turbina dentro da gama de funcionamento considerada no projecto: 79 a 157 rad/s; o facto de esta gama não estar dividida em duas partes iguais foi uma opção assumida de modo a avaliar o desempenho e a robustez do sistema de interpolação.

Desenvolveram-se duas rotinas, conforme o esquema apresentado na Figura 4.17 e na Figura 4.18. Na primeira versão, mediante a verificação da velocidade da turbina, que desvia o processamento para o ramo respectivo da decisão, o valor da onda é submetido em dois sistemas neuronais ou Fuzzy, obtidos para duas velocidades fixas, respectivamente, e devolvem o valor de  $\zeta$  que é posteriormente interpolado para ser submetido, também ele, em conjunto com o valor da onda, aos sistemas respectivos para a variável  $h$ . Na segunda, versão, o procedimento é idêntico mas utiliza os valores de  $\zeta$ , obtidos directamente nos sistemas de base para as velocidades fixas da turbina. Tanto quanto se pode observar, pelos resultados obtidos, conforme se apresentará a seguir, as diferenças são mínimas.

Os sistemas alcançados para a variável  $h$ , nas duas variantes, neuronal e fuzzy, não contemplaram uma rotina idêntica, dado que foram obtidos recorrendo aos vectores de valores de  $\zeta$  fornecidos pelo simulador.

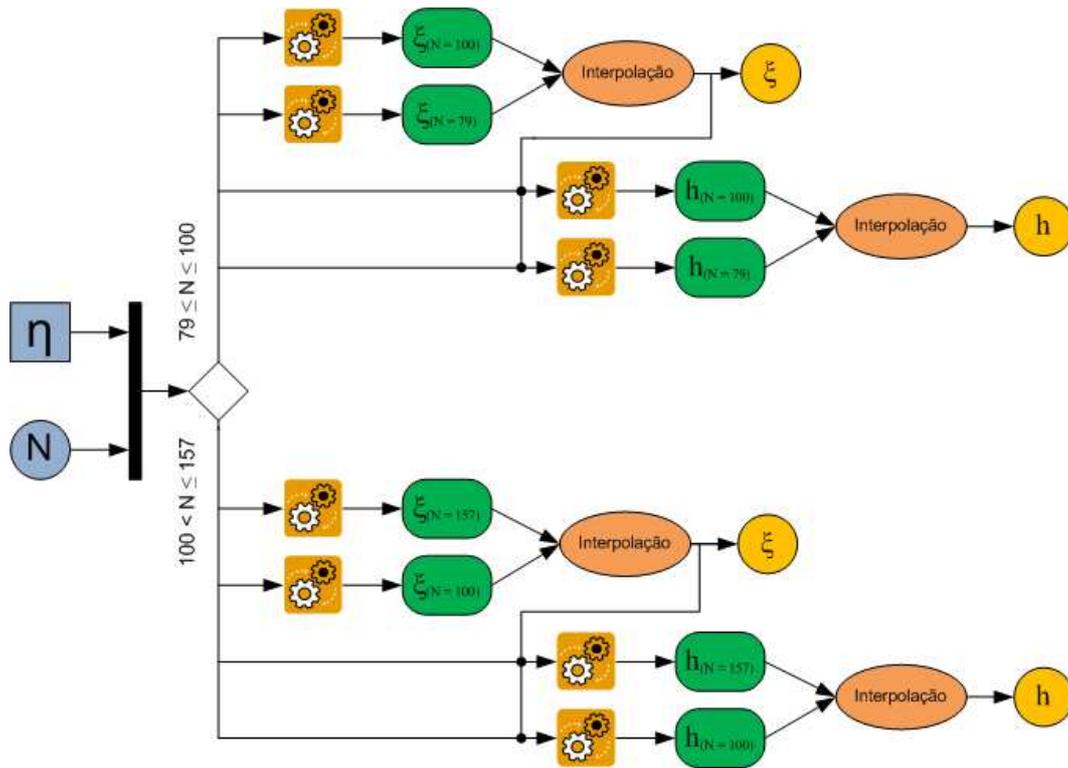


Figura 4.17 Diagrama do mecanismo de interpolação. A variável  $h$  é obtida com o valor interpolado de  $\xi$ .

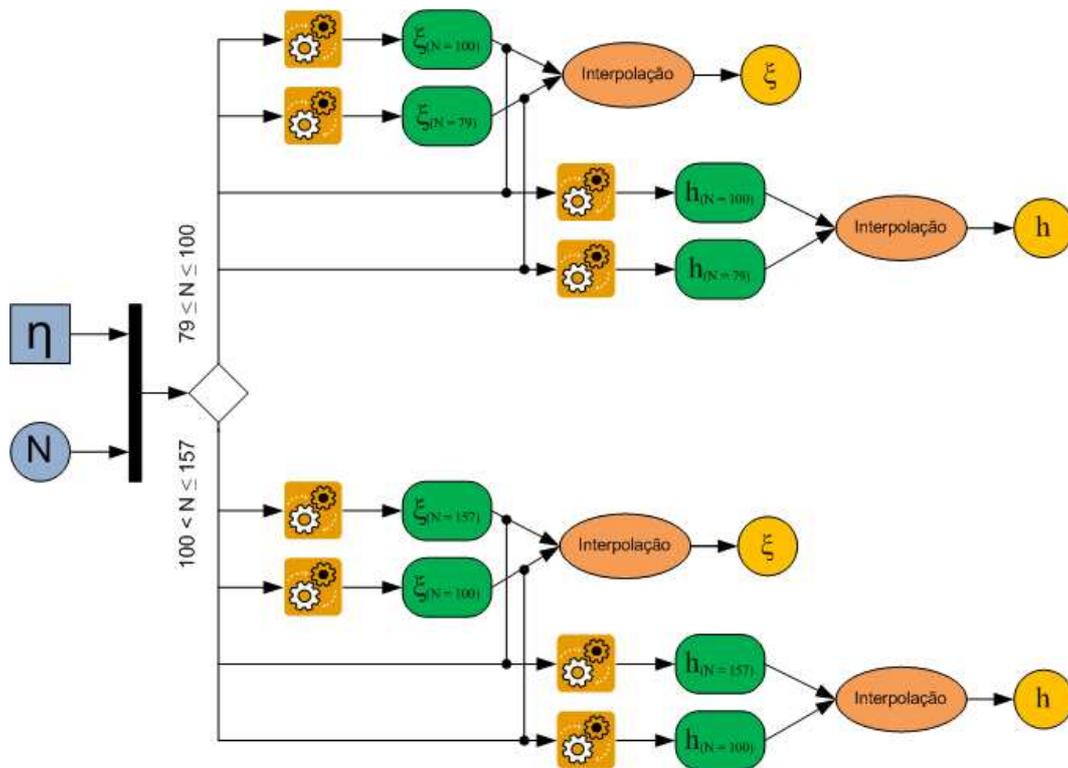


Figura 4.18 Diagrama do mecanismo de interpolação. A variável  $h$  é obtida com os valores base de  $\xi$ .

#### 4.5.1 Gráficos das interpolações dos sistemas de redes neuronais

##### 4.5.1.1 Valores gerados com uma velocidade da turbina de 90 rad/s

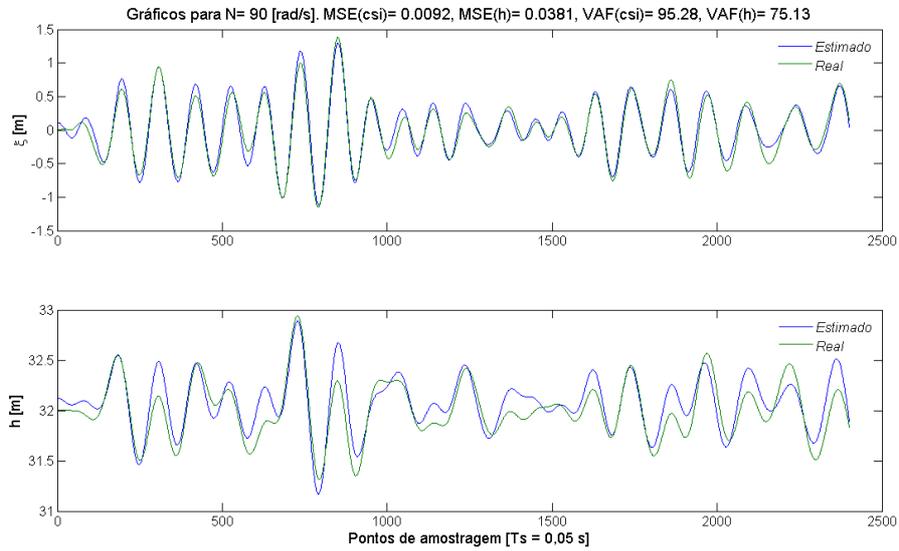


Figura 4.19 (Neuronal) Resultados do 1º método (N = 90 rad/s).

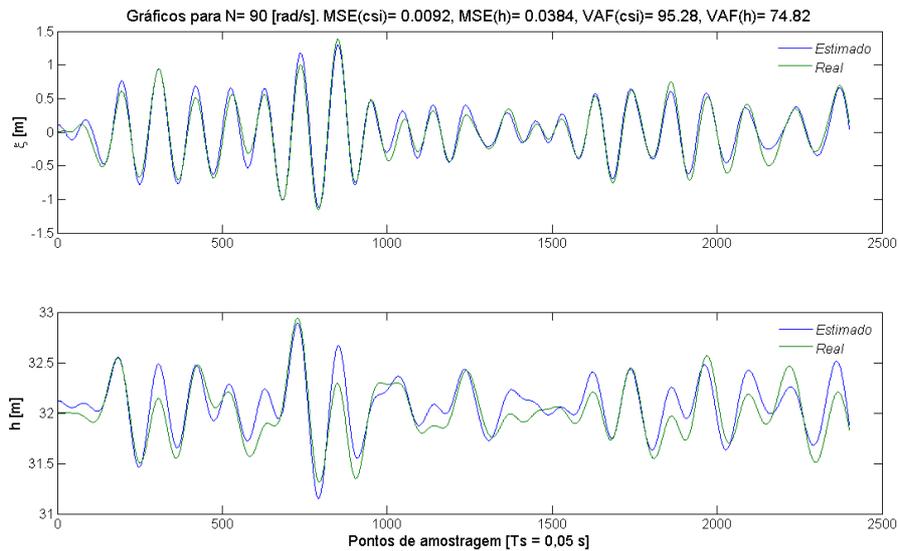


Figura 4.20 (Neuronal) Resultados do 2º método (N = 90 rad/s).

#### 4.5.1.2 Valores gerados com uma velocidade da turbina de 115 rad/s

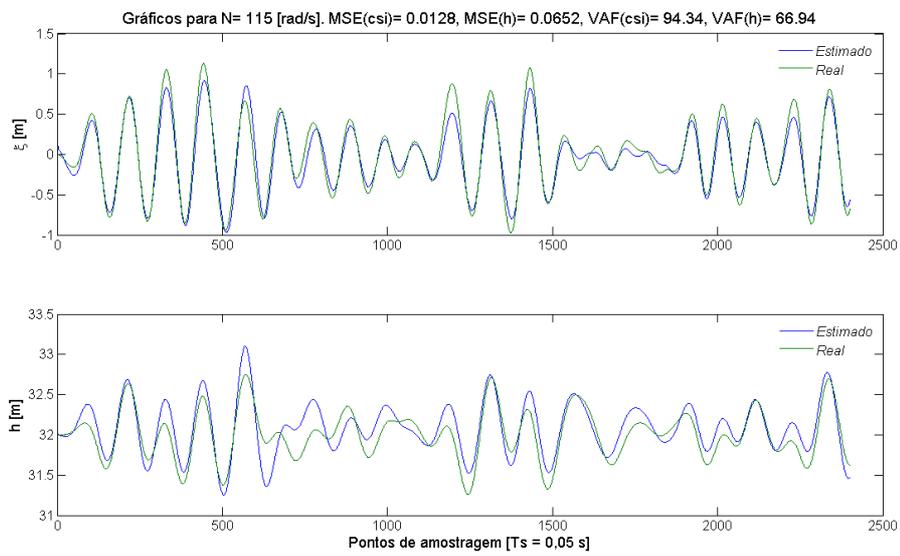


Figura 4.21 (Neuronal) Resultados do 1º método (N = 115 rad/s).

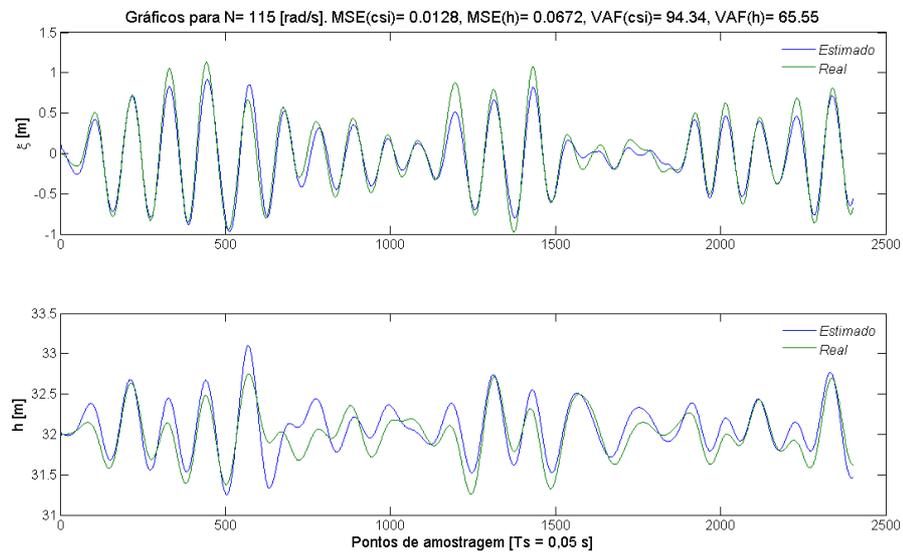


Figura 4.22 (Neuronal) Resultados do 2º método (N = 115 rad/s).

#### 4.5.1.3 Valores gerados com uma velocidade da turbina de 131 rad/s

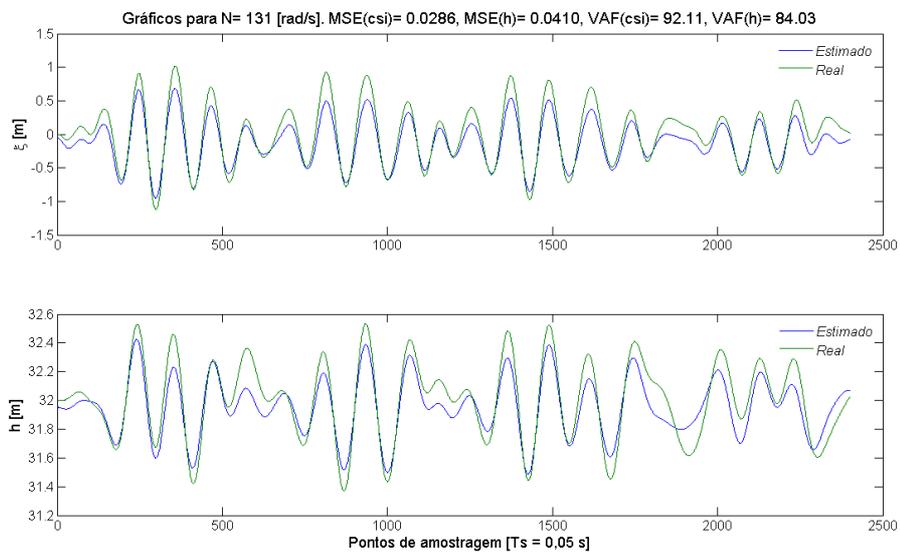


Figura 4.23 (Neuronal) Resultados do 1º método (N = 131 rad/s).

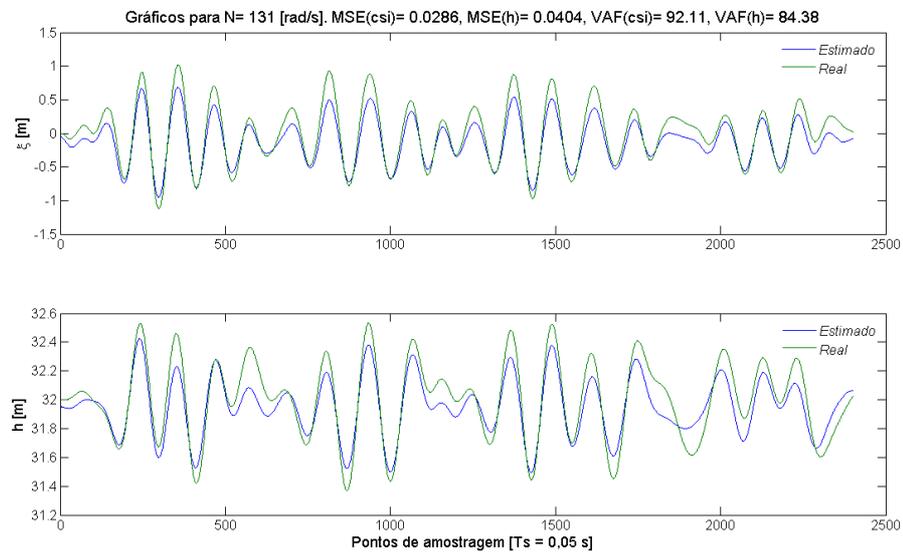


Figura 4.24 (Neuronal) Resultados do 2º método (N = 131 rad/s).

#### 4.5.1.4 Valores gerados com uma velocidade da turbina de 145 rad/s

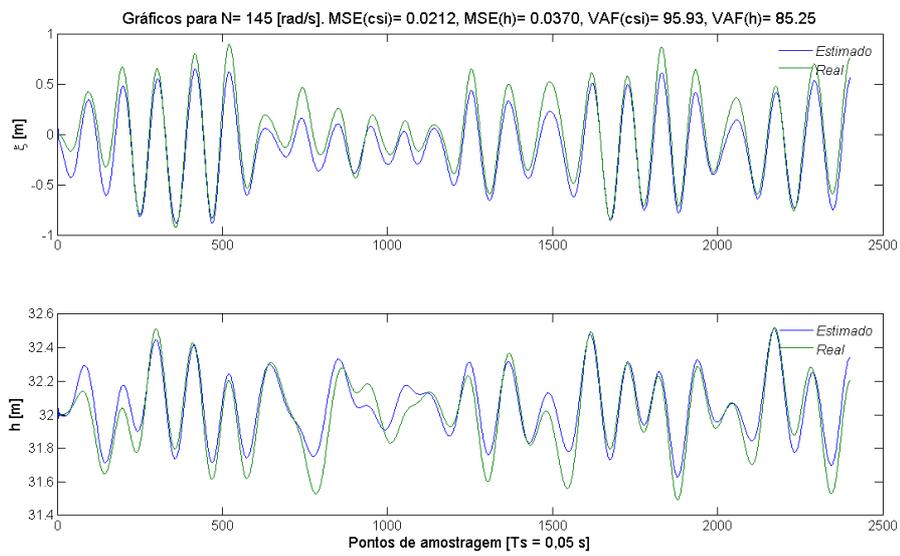


Figura 4.25 (Neuronal) Resultados do 1º método (N = 145 rad/s).

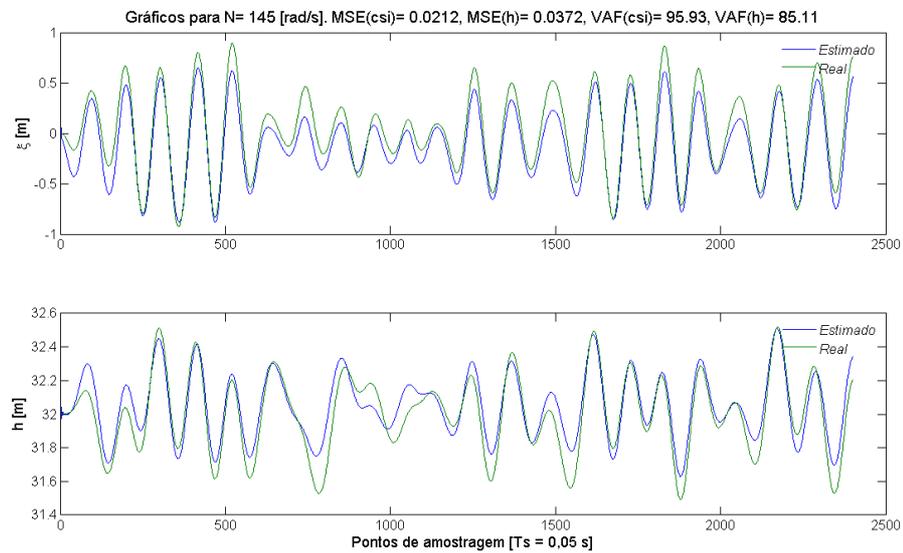


Figura 4.26 (Neuronal) Resultados do 2º método (N = 145 rad/s).

## 4.5.2 Gráficos das interpolações dos sistemas Fuzzy

### 4.5.2.1 Valores gerados com uma velocidade da turbina de 90 rad/s

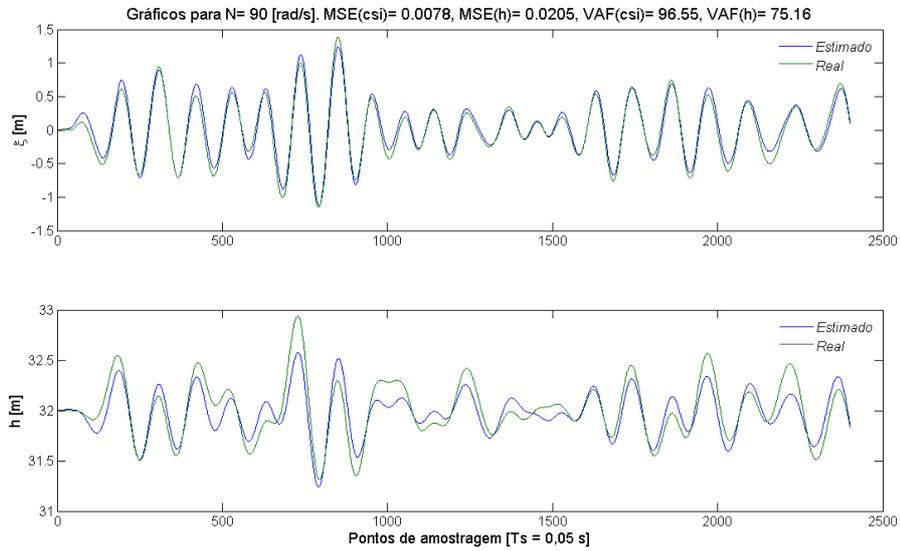


Figura 4.27 (Fuzzy) Resultados do 1º método (N = 90 rad/s).

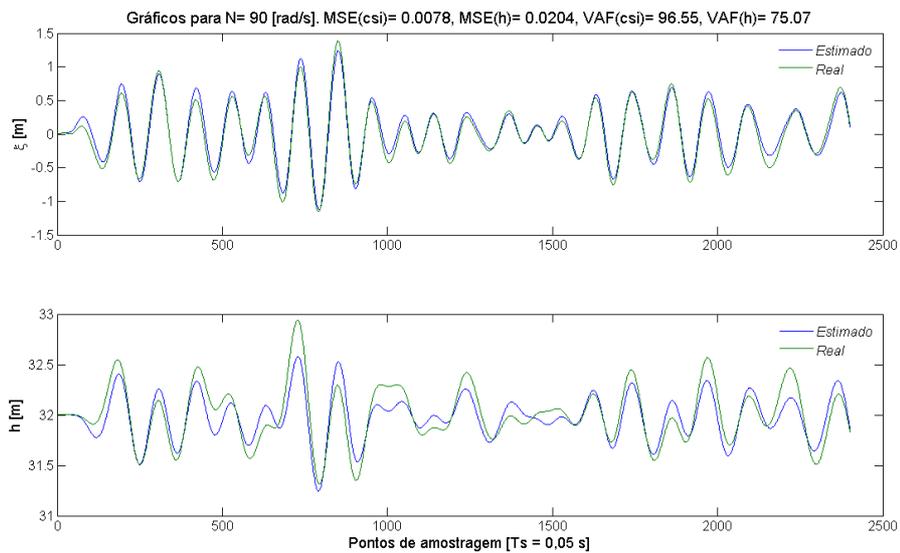


Figura 4.28 (Fuzzy) Resultados do 2º método (N = 90 rad/s).

#### 4.5.2.2 Valores gerados com uma velocidade da turbina de 115 rad/s

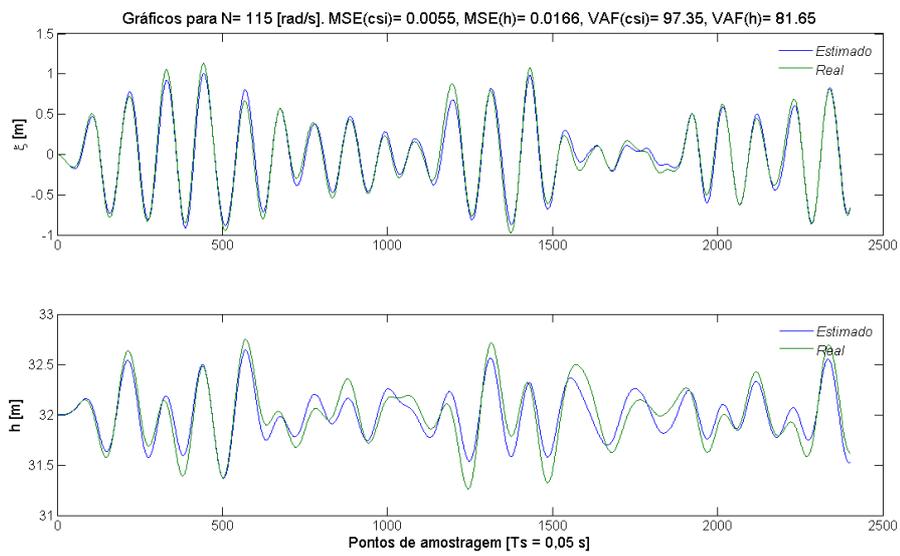


Figura 4.29 (Fuzzy) Resultados do 1º método (N = 115 rad/s).

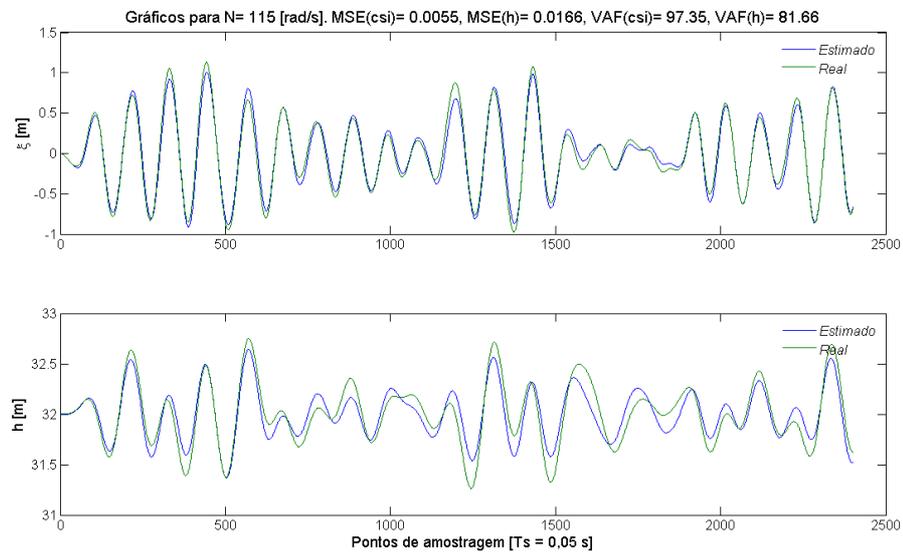


Figura 4.30 (Fuzzy) Resultados do 2º método (N = 115 rad/s).

#### 4.5.2.3 Valores gerados com uma velocidade da turbina de 131 rad/s

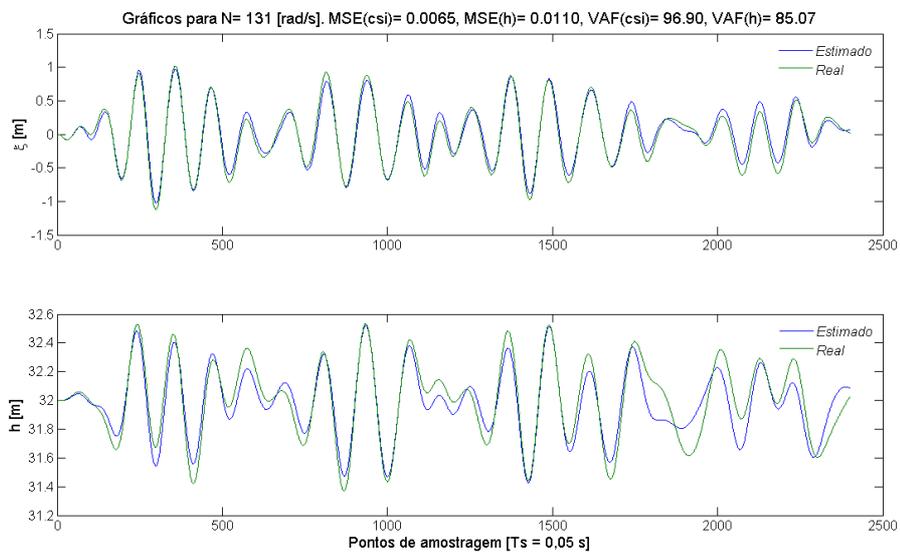


Figura 4.31 (Fuzzy) Resultados do 1º método (N = 131 rad/s).

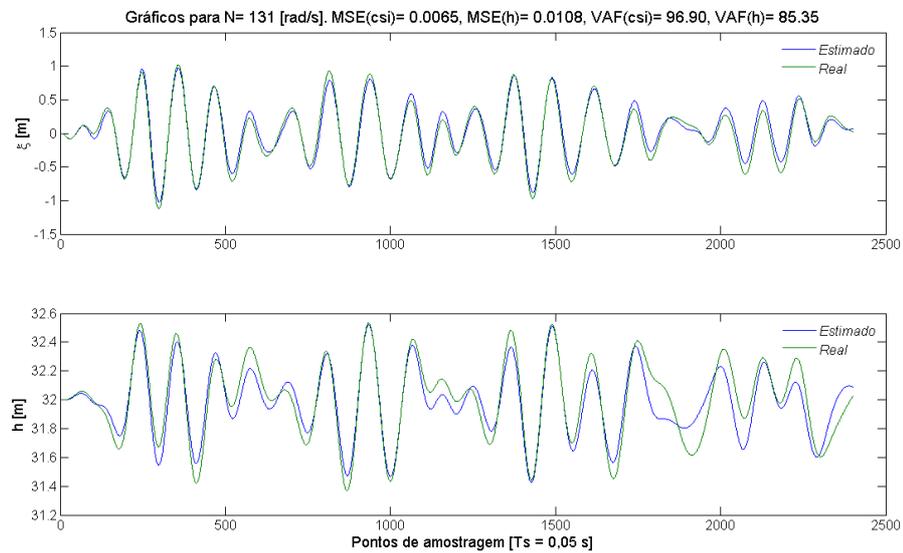


Figura 4.32 (Fuzzy) Resultados do 2º método (N = 131 rad/s).

#### 4.5.2.4 Valores gerados com uma velocidade da turbina de 145 rad/s

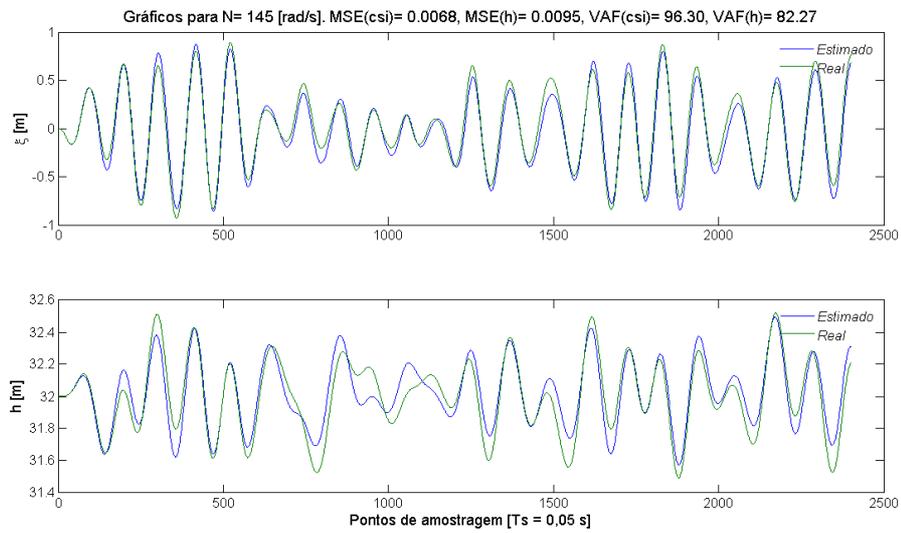


Figura 4.33 (Fuzzy) Resultados do 1º método (N = 145 rad/s).

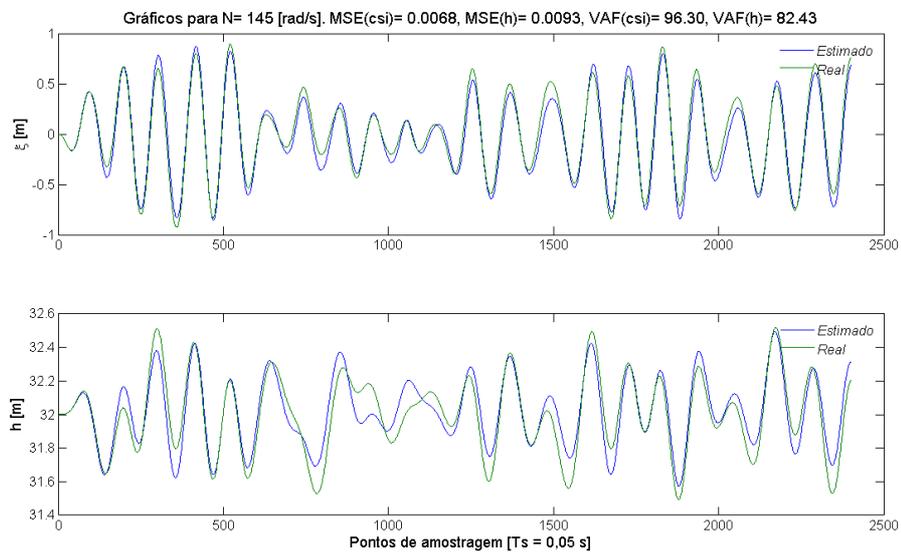


Figura 4.34 (Fuzzy) Resultados do 2º método (N = 145 rad/s).

### 4.5.3 Observações aos resultados das interpolações

Por uma questão de facilidade, na apresentação gráfica destes resultados optou-se por referir o desempenho dos modelos através dos dois indicadores,  $MSE$  e  $VAF$ , contrariamente ao esquema que foi utilizado para os modelos de base. Este facto deve-se, essencialmente, ao uso generalizado destes indicadores para aferir o desempenho dos modelos em Redes Neurais e em Lógica Fuzzy, respectivamente, embora se possa utilizar qualquer um deles, indiferenciadamente; por manifesta falta de tempo, optou-se por não repetir o cálculo destes indicadores relativos aos vários modelos: 28, 29, 22V4, 25, 26V3, 27, 50V3, 51, 48, 49, 52, 53, 62 e 83. Este motivo é igualmente válido para a diferença existente na apresentação dos gráficos referentes aos modelos de base em Redes Neurais, uma vez que os valores obtidos estão normalizados, ao passo que nos relativos às interpolações se mostram os valores reais, isto é, sem qualquer normalização.

#### 4.5.3.1 Comparação entre os dois métodos para os modelos de redes neuronais

Resultados das interpolações dos modelos de redes neuronais					
Velocidade	Método	MSE( $\xi$ )	MSE( $h$ )	VAF( $\xi$ )	VAF( $h$ )
90	1	0.0092	0.0381	95.28	75.13
90	2	0.0092	0.0384	95.28	74.72
115	1	0.0128	0.0652	94.34	66.94
115	2	0.0128	0.0672	94.34	65.55
131	1	0.0286	0.0410	92.11	84.03
131	2	0.0286	0.0404	92.11	84.38
145	1	0.0212	0.0370	95.93	85.25
145	2	0.0212	0.0372	95.93	85.11

Tabela 4.15 Comparativo dos resultados das interpolações

Resultados dos modelos base de redes neuronais			
Modelo	Velocidade	MSE( $\xi$ )	MSE( $h$ )
28	79	0.0081	–
29	79	–	0.0050
22V4	100	0.0086	–
25	100	–	0.0271
26V3	157	0.0097	–
27	157	–	0.0005

Tabela 4.16 Desempenho dos modelos de base com dados de validação

Devido ao facto da tabela anterior apresentar os valores, relativos ao desempenho dos modelos, com os dados normalizados não se consegue inferir correctamente a relação entre eles. No entanto, permite constatar que os resultados referentes à estimação de  $\xi$  são da mesma ordem de grandeza, enquanto os relativos à variável  $h$  serem francamente piores no caso da interpolação. Esta circunstância deve-se ao facto de  $h$  ser estimada com o vector de  $\xi$  entretanto calculado, em vez do vector conseguido com o simulador, que é utilizado nas rotinas dos modelos de base; o  $\xi$  obtido em tempo real já inclui, ele próprio, um erro associado.

#### 4.5.3.2 Comparação entre os dois métodos para os modelos de lógica Fuzzy

Resultados das interpolações dos modelos de lógica Fuzzy					
Velocidade	Método	MSE( $\xi$ )	MSE(h)	VAF( $\xi$ )	VAF(h)
90	1	0.0078	0.0205	96.55	75.16
90	2	0.0078	0.0204	96.55	75.07
115	1	0.0055	0.0166	97.35	81.65
115	2	0.0055	0.0166	97.35	81.66
131	1	0.0065	0.0110	96.90	85.07
131	2	0.0065	0.0108	96.90	85.35
145	1	0.0068	0.0068	96.30	82.27
145	2	0.0068	0.0093	96.30	82.43

Tabela 4.17 Comparativo dos resultados das interpolações

Resultados dos modelos base de lógica Fuzzy			
Modelo	Velocidade	VAF( $\xi$ )	VAF(h)
50V3	79	96.91	–
51	79	–	99.71
48	100	96.77	–
49	100	–	99.78
52	157	97.59	–
53	157	–	99.84

Tabela 4.18 Desempenho dos modelos de base com dados de validação

Enquanto nas interpolações dos modelos de redes neuronais o 1º método apresenta, quase sempre, um desempenho superior, nas dos modelos de lógica Fuzzy é precisamente o contrário. No entanto, em qualquer um dos casos, as diferenças são mínimas e não parecem ser suficientemente significativas para justificar, no caso da lógica Fuzzy, a computação adicional de construir dois vectores distintos para calcular  $h$ .

A degradação do desempenho na estimação de  $h$  é também notória neste caso, pelos mesmos motivos referidos anteriormente. No entanto, no caso dos modelos de base, para as duas tecnologias, observa-se, quase sempre, uma melhoria significativa no desempenho da estimação de  $h$ , que deverá estar relacionada, em grande medida, com o facto de se utilizarem duas variáveis, permitindo uma maior facilidade de aprendizagem.

#### 4.5.3.3 Comparação directa das interpolações entre as duas tecnologias

Comparação das interpolações					
Velocidade	Método	NN-VAF( $\xi$ )	LF-VAF( $\xi$ )	NN-VAF(h)	LF-VAF(h)
90	1	95.28	96.55	75.13	75.16
90	2	95.28	96.55	74.72	75.07
115	1	94.34	97.35	66.94	81.65
115	2	94.34	97.35	65.55	81.66
131	1	92.11	96.90	84.03	85.07
131	2	92.11	96.90	84.38	85.35
145	1	95.93	96.30	85.25	82.27
145	2	95.93	96.30	85.11	82.43

Tabela 4.19 Comparação entre as duas tecnologias

Por uma questão de simplicidade, utiliza-se apenas um dos indicadores do desempenho dos modelos obtidos com cada uma das tecnologias envolvidas, embora qualquer um dos indicadores seja perfeitamente válido para esta análise. No entanto, a escolha do *VAF* parece ser mais adequada por ser um indicador mais intuitivo e de melhor percepção.

A terceira e quarta coluna referem-se ao desempenho dos modelos para a estimação de  $\zeta$  através de modelos em redes neuronais (NN) e lógica Fuzzy (LF), respectivamente. A quinta e a sexta coluna apresentam os resultados referentes à estimação de  $h$ , pela mesma disposição.

À exceção do resultado conseguido com o modelo de redes neuronais para uma velocidade de 145 rad/s, os modelos em lógica Fuzzy apresentam um desempenho superior na estimação nas duas variáveis. Para melhorar estes resultados, relativamente à variável  $h$ , seria preciso voltar a estimar novos modelos em que se utilizaria o valor estimado de  $\zeta$  e não o valor obtido através do simulador *ipsneck*, fornecendo umas condições de aprendizagem mais próximas do modelo final pretendido, que era o de utilizar, em tempo real, o valor da elevação do aparelho,  $\zeta$ .

#### 4.5.4 Interpolações para condições de Inverno

Devido à morosidade computacional envolvida na modelação do aparelho, bem como ao imenso tempo gasto na pesquisa dos modelos inversos, os modelos directos, encontrados para valores fixos da velocidade da turbina, foram obtidos com base nos valores dos parâmetros do simulador apresentados na secção 3.5, com uma altura significativa da onda,  $H_s$ , de 1,5 m. Este valor, por sinal, equivale ao valor médio mais baixo do ano, representando umas condições ambientais mais favoráveis ao funcionamento do aparelho, uma vez que a energia envolvida não chega a ser muito intensa. Assim, na impossibilidade de encontrar modelos para condições mais adversas, por limitações de tempo, optou-se por gerar 3 séries de valores com uma altura  $H_s = 3,2$  m, precisamente o valor mais alto, registado, normalmente, no mês de Janeiro, conforme se pode observar pela Tabela 4.20, referente a valores recolhidos por uma bóia de aquisição de dados situada ao largo de Leixões; todos os outros parâmetros mantiveram-se inalterados. A velocidade da turbina utilizada nas simulações foi fixada em 131 rad/s.

Com base nos valores das três simulações, apresentam-se, a seguir, os gráficos, respectivos, oferecidos pelos sistemas de interpolação, apenas do primeiro método, de cada uma das duas tecnologias: Redes Neuronais e Lógica Fuzzy.

Valores médios significativos												
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
$H_s$ [m]	3,2	3	2,6	2,5	1,8	1,7	1,5	1,6	1,9	1,3	2,8	3,1
$T_e$ min [s]	5,8	5,8	5,2	5,5	5,0	4,7	4,6	5,0	5,2	5,3	5,5	5,3
$T_e$ máx [s]	16,1	14,5	13,7	14,8	12,2	9,7	11,1	10,5	12,0	12,6	13,3	14,2

Tabela 4.20 Valores obtidos por uma bóia colocada ao largo de Leixões

#### 4.5.4.1 Gráficos das interpolações da primeira simulação

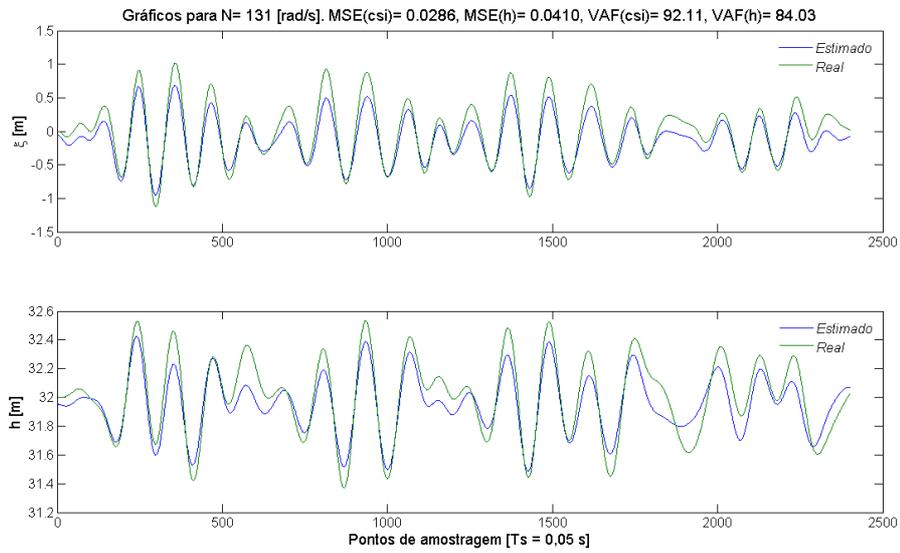


Figura 4.35 Interpolação com Redes Neurais para  $H_s = 3,2$  m

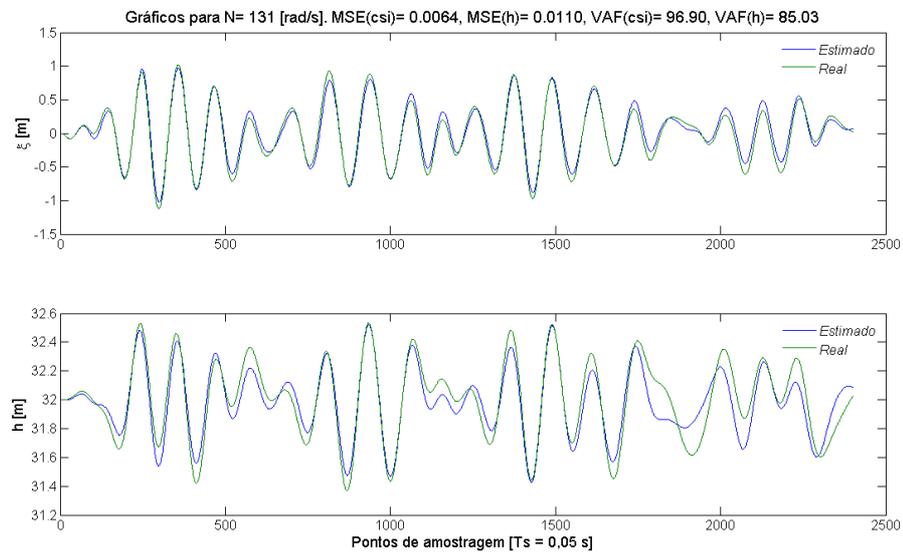


Figura 4.36 Interpolação com Lógica Fuzzy para  $H_s = 3,2$  m

#### 4.5.4.2 Gráficos das interpolações da segunda simulação

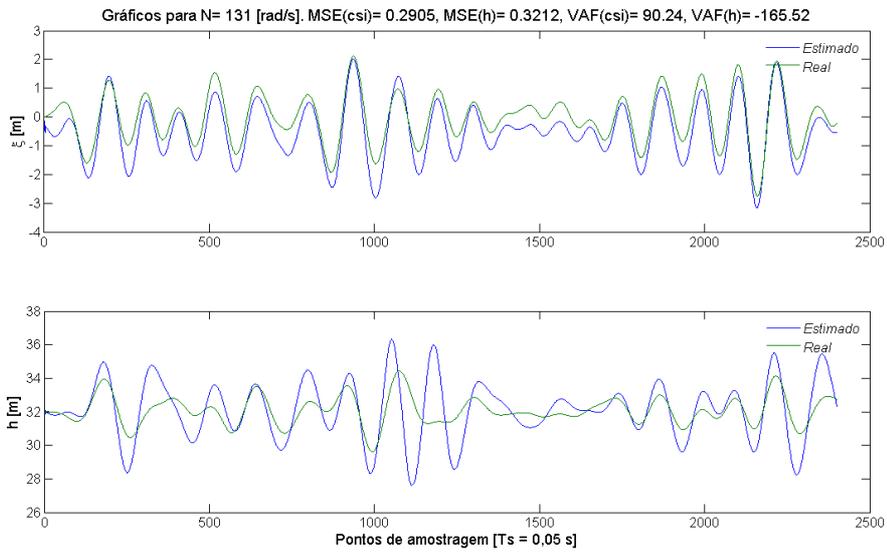


Figura 4.37 Interpolação com Redes Neurais para  $H_s = 3,2$  m

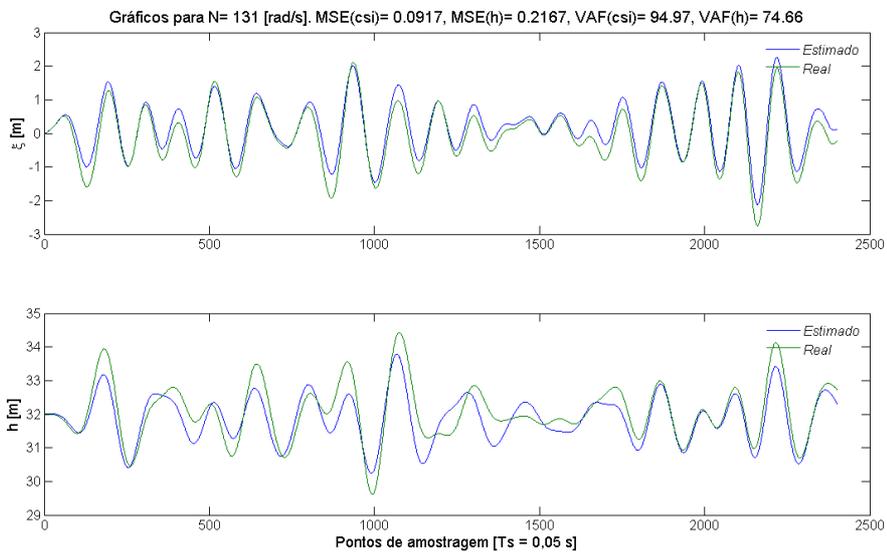


Figura 4.38 Interpolação com Lógica Fuzzy para  $H_s = 3,2$  m

#### 4.5.4.3 Gráficos das interpolações da terceira simulação

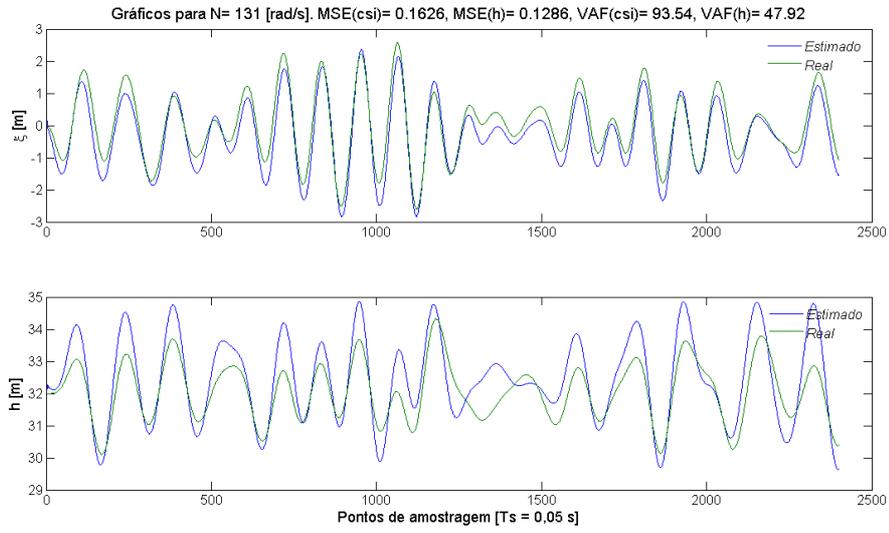


Figura 4.39 Interpolação com Redes Neurais para  $H_s = 3,2$  m

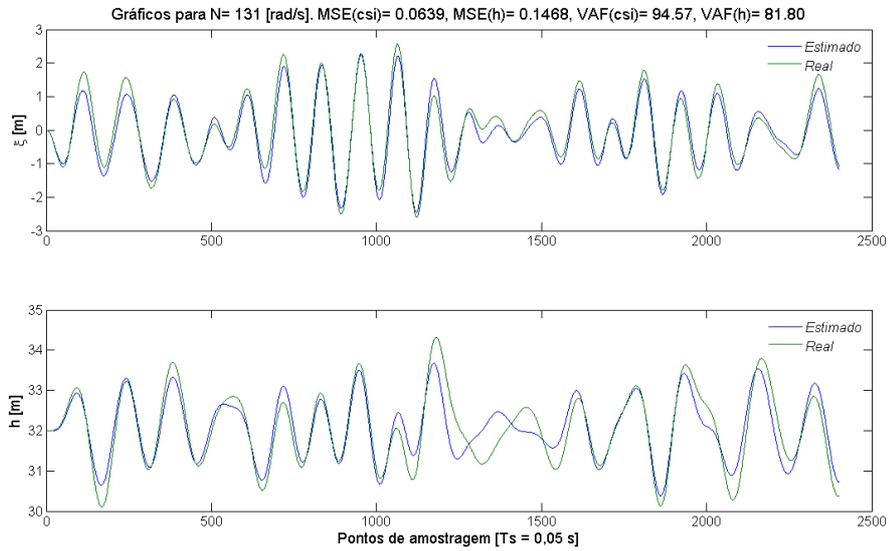


Figura 4.40 Interpolação com Lógica Fuzzy para  $H_s = 3,2$  m

#### 4.5.4.4 Observações aos resultados das interpolações para condições de Inverno

Comparação das interpolações					
Velocidade	Simulação	NN-VAF( $\xi$ )	LF-VAF( $\xi$ )	NN-VAF( $h$ )	LF-VAF( $h$ )
131	1	92,11	96,9	84,03	85,03
131	2	90,24	94,97	-165,52	74,66
131	3	93,54	94,57	47,92	81,80

Tabela 4.21 Comparação de resultados das interpolações (N = 131 rad/s, Hs = 3,2 m)

Considerando os resultados conseguidos nas três experiências, pode-se inferir, à semelhança do que já se tinha verificado anteriormente, que o sistema de interpolação com base em modelos de Lógica Fuzzy volta a apresentar uma capacidade superior de estimação das variáveis em causa:  $\xi$  e  $h$ . De um modo geral, as duas tecnologias apresentam um bom desempenho na estimação de  $\xi$ , sendo significativo sobre a robustez dos modelos conseguidos, embora a estimação de  $h$  levante maiores dificuldades para os modelos de Redes Neurais, que colapsou, inclusivamente, para uma das experiências. Como se referiu anteriormente, é provável que uma estratégia de aprendizagem com base nos valores estimados de  $\xi$  consiga oferecer um desempenho superior, para qualquer uma das tecnologias.

A repetição sistemática das experiências, como as 3 deste caso, foi uma constante ao longo de todo o trabalho, como forma de garantir uma base mais ampla e sólida dos resultados, face à aleatoriedade do sistema de geração das ondas, embora nem sempre se tenham apresentado os resultados, de modo a não sobrecarregar o texto.



## 5. Conclusões

A morosidade computacional das diversas rotinas desenvolvidas para cada uma das tecnologias, associada às dificuldades encontradas na pesquisa dos modelos inversos, que absorveu uma fracção demasiado significativa do tempo disponível, acabaram por subverter, em boa medida, os propósitos deste trabalho, relativamente à parte do controlo. Para um aparelho deste género, absorvedor pontual, dado que as suas dimensões são relativamente reduzidas face às verificadas nas ondas incidentes, é de extrema importância para a optimização da quantidade e qualidade da energia a extrair das ondas, que se faça o controlo da sua velocidade de oscilação segundo as características manifestadas, no momento, pelas ondas incidentes.

As dificuldades verificadas na concretização de modelos inversos evidenciam, em grande medida, a fraca relação ou dependência existente entre o estado de oscilação do aparelho e a velocidade da turbina. O nível de agitação do mar, para além de ser o “combustível”, é, de longe, o fenómeno mais influente no processo. Devido às características bastante irregulares do perfil das ondas torna-se imperioso encontrar um modelo de controlo capaz de responder de forma eficaz a estas condições [28], motivo pelo qual se tentou a abordagem através de técnicas não lineares oferecidas pelas mais recentes áreas de controlo: Redes Neurais e Lógica Fuzzy.

A circunstância de não se terem conseguido encontrar modelos inversos de qualidade, torna impraticável a estratégia de controlo do tipo IMC, mas é irrelevante para outras abordagens, nomeadamente a de controlo preditivo, dado que se baseia, unicamente, no conhecimento dos modelos directos do processo. Assim, como trabalho futuro, propõe-se o estudo mais exaustivo dos modelos directos, através de condições mais alargadas para os estados do mar, que sejam representativas dos níveis energéticos observados ao longo o ano, especialmente para o caso das Redes Neurais, que foi a menos conseguida. Por outro lado, seria interessante observar até que ponto a fase de aprendizagem, para os modelos de estimação de  $h$ , em ambas as tecnologias, baseada nos valores estimados de  $\zeta$ , em vez dos obtidos pelo simulador, influenciaria o nível de desempenho dos modelos respectivos; pode-se dar o caso de tornar estes modelos mais abrangentes e robustos, permitindo-lhes oferecer melhores resultados.



## 6. Bibliografia

- [1] João Cruz, António Sarmento, *Energia das Ondas: Introdução aos Aspectos Tecnológicos, Económicos e Ambientais*, Lisboa: Instituto do Ambiente, 2004.
- [2] G. F. d. S. Nunes, “Modelling and Control of a Wave Energy Converter”, Tese de Mestrado, Dep. Eng<sup>a</sup> Mecânica, Instituto Superior Técnico, Lisboa, 2009.
- [3] Howard Demuth, Mark Beale, Martin Hagan, *Neural Network Toolbox 6 User's Guide*.
- [4] I. The MathWorks, *Fuzzy Logic Toolbox 2 User's Guide*, The MathWorks, Inc..
- [5] Wave Energy Centre, *Potencial e estratégia de desenvolvimento da energia das ondas em Portugal*, Lisboa, 2004.
- [6] Jorge Fernandes Cunha, Roxana Onofrei, “Energia Oceânica”, Instituto Nacional de Propriedade Industrial.
- [7] R. H. Stewart, *Introduction to Physical Oceanography*, 2008.
- [8] A. F. d. O. Falcão, “Wave energy utilization: A review of the technologies”, *Renew Sustain Energy Rev*, p. 20, 22 October 2009.
- [9] Elisabetta Tedeschi, Marta Molinas, Matteo Carraro, Paolo Mattavelli, “Analysis of Power Extraction from Irregular Waves by All-Electric Power Take Off”, IEEE, 2010.
- [10] A. F. d. O. Falcão, *The history of and progress in wave energy conversion devices*, Florence, 2006.
- [11] Dara O'Sullivan, Darren Mollaghan, Anne Blavette and Raymond Alcorn, *Dynamic Characteristics of wave and tidal energy converters & a recommended structure for development of a generic model for grid connection*, vol. Document No: T0321, Ocean Energy Systems, 2010.
- [12] T. Setoguchi, M. Takao, K. Kaneko, “Hysteresis on Wells Turbine Characteristics in Reciprocating Flow”, *International Journal of Rotating Machinery*, 1998.
- [13] Jens Peter Kofoed, Peter Frigaard, Wilfried Knapp & Erik Friis-Madsen, *Description of the Power Take-off System on board the Wave Dragon Prototype*, 2th CA-OE Workshop, 2005.
- [14] R. Henderson, “Design, simulation, and testing of a novel hydraulic power take-off system for the Pelamis wave energy converter”, *Renewable Energy* 31, pp. 271-283, 29 September 2006.
- [15] “Workshop II, Component Technology and Power Take-off”, Uppsala University, 2005.
- [16] J. Falnes, *Ocean Waves and Oscillating Systems*, C. U. Press, Ed., 2004.
- [17] Duarte Valério, Mário J. G. C. Mendes, Pedro Beirão, José Sá da Costa, “Identification and control of the AWS using neural network models”, *Applied Ocean Research* 30, pp. 178-188, 16 December 2008.

- [18] Duarte Valério, Pedro Beirão, Mário J. G. C. Mendes, José Sá da Costa, “Comparison of control strategies performance for a Wave Energy Converter”, *Mediterranean Conference on Control and Automation*, Ajaccio, 2008.
- [19] J. Fernandez de Canete, S. Gonzalez-Perez, P. del Saz-Orozco, “Software Tools for System Identification and Control using Neural Networks in Process Engineering”, World Academy of Science, Engineering and Technology, 2008.
- [20] R. Babuska, *Fuzzy Modeling and Identification Toolbox User's Guide*, 1998.
- [21] Jyh-Shin Roger Jang, Chuen-Tsai Sun, Eiji Mizutani, *Neuro-Fuzzy and Soft Computing*, Prentice Hall, 1997.
- [22] R. Babuska, *Knowledge-based control systems*, Delft: Delft University of Technology.
- [23] M. Torresi, S. M. Camporeale, P. D. Strippoli, G. Pascazio, “Accurate numerical simulation of a high solidity Wells turbine”, 1 March 2007. [Online]. Available: [www.elsevier.com/locate/renene](http://www.elsevier.com/locate/renene). [Acedido em 8 June 2007].
- [24] P. J. B. F. N. Beirão, “Modelling and Control of a Wave Energy Converter: Archimedes Wave Swing”, *Dissertação de Doutoramento, Dep. Eng<sup>a</sup> Mecânica, Instituto Superior Técnico, Lisboa*, 2007.
- [25] Devin Sabo, Xiao-Hua Yu, “A New Pruning Algorithm for Neural Network Dimension Analysis”, IEEE, 2008.
- [26] Bouzerdoun, Abdesselam; Phung, Son Lam; Yang, Jie, “A neural network prunning approach based on compressive sampling”, *Research Online*, 2009.
- [27] Christian Endisch, Christoph Hackl, Dierk Schroder, “System Identification with General Dynamic Neural Networks and Network Pruning”, World Academy of Science, 2008.
- [28] S H Dalter, J R M Taylor, N J Caldwell, “Power conversion mechanisms for wave energy”, *IMEchE*, 2002.

## Anexo I

### I Lista de modelos directos (Redes Neuronais)

A lista de modelos que se segue é a agregação dos cabeçalhos das respectivas *m-files* utilizadas ao longo deste trabalho, indicando o número do modelo, o tempo de amostragem, o critério de paragem do algoritmo de aprendizagem, as entradas e saídas envolvidas e os parâmetros variáveis de optimização dos modelos: número de atrasos, tanto na entrada como na saída, e número de neurónios, para os modelos de Redes Neuronais. As linhas de asteriscos destinam-se a enfatizar a diferenciação entre os modelos devidas ao tipo de tecnologia utilizada: *Redes Neuronais* ou *Lógica Fuzzy*, e ao regime de velocidade da turbina utilizado para a recolha de valores das variáveis envolvidas: *constante*, *variável por patamares* ou *ciclicamente variável*.

Modelos NARX para N = 100 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Critérios de paragem	Número de neurónios (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
22	1 a 12	1 a 12	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	—
22V2	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	—
22V3	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	Repetição com os mesmos valores
22V4	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	Novos valores; Modelo escolhido
23	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	h	—
23V2	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	h	Repetição com os mesmos valores
23V3	1 a 7	2 a 7	1000 épocas; Erro = $10^{-7}$	10 a 20	$\eta$	h	Novos valores; Novo limite do erro
24	1 a 12	8 a 12	1000 épocas; Erro = $10^{-8}$	10 a 20	$\eta$	h	Repetição com os mesmos valores; Novo limite do erro
25	1 a 7	2 a 7	1000 épocas; Erro = $10^{-7}$	10 a 20	$\eta, \xi$	h	Repetição com os mesmos valores; Novo limite do erro; Modelo escolhido
25V2	1 a 7	2 a 7	1000 épocas; Erro = $10^{-7}$	10 a 20	$\eta, \xi$	h	Repetição com os mesmos valores

Modelos NARX para N = 157 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Critérios de paragem	Número de neurónios (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
26	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	—
26V2	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	Repetição com os mesmos valores
26V3	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	Novos valores; Modelo escolhido
27	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, \xi$	h	Modelo escolhido
27V2	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, \xi$	h	Repetição com os mesmos valores
27V3	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, \xi$	h	Novos valores

Modelos NARX para $N = 79$ rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Crítérios de paragem	Número de neurónios (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
28	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	Modelo escolhido
28V2	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	Repetição com os mesmos valores
28V3	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	Novos valores
29	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, \xi$	h	Modelo escolhido
29V2	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, \xi$	h	Repetição com os mesmos valores
29V3	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, \xi$	h	Novos valores

Modelos NARX para $N = [78 - 104,6 - 130,8 - 157]$ rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Crítérios de paragem	Número de neurónios (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
30	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	$\xi$	Velocidade da turbina com 4 patamares; Simulação de 120 s
31	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	h	<i>idem</i>
32	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, N$	$\xi$	<i>idem</i>
33	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, N$	h- $\xi$	<i>idem</i>
35	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, \xi, N$	h	<i>idem</i>
36	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, N$	h, $\xi$	<i>idem</i>

## II Lista de modelos inversos (Redes Neurais)

Modelos Inversos NARX para $N = [78 - 104,6 - 130,8 - 157]$ rad/s ( $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Crítérios de paragem	Número de neurónios (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
37	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta, h$	N, $\xi$	<i>idem</i> ; Modelo inverso
38	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	N	<i>idem</i> ; Modelo inverso
39	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	h	N	<i>idem</i> ; Modelo inverso

Modelos Inversos NARX para N variável entre 79 e 157 rad/s ( $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Crítérios de paragem	Número de neurónios (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
40	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$\eta$	N	Velocidade da turbina variável (sinal tipo <i>chirp</i> ); Simulação de 120 s; Modelo inverso
40V2	1 a 7	2 a 7	1000 épocas; Erro = $10^{-7}$	10 a 20	$\eta$	N	<i>idem</i> ; Modelo inverso; Novo limite do erro
41	1 a 7	2 a 7	1000 épocas; Erro = $10^{-6}$	10 a 20	$P_{inside}$	N	<i>idem</i> ; Modelo inverso; Nova variável entrada

### III Lista de modelos directos (Lógica Fuzzy)

Modelos Fuzzy para N = 100 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Número de atrasos puros (ciclo)	Número de <i>clusters</i> (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
48	1 a 7	2 a 7	0 a 5	1 a 4	$\eta$	$\xi$	Modelo escolhido
49	1 a 7	2 a 7	0 a 5	1 a 4	$\eta, \xi$	h	Duas variáveis de entrada; Modelo escolhido

Modelos Fuzzy para N = 79 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Número de atrasos puros (ciclo)	Número de <i>clusters</i> (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
50	1 a 5	2 a 5	0 a 5	1 a 4	$\eta$	$\xi$	-
50V2	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, N$	$\xi$	Duas variáveis de entrada
50V3	1 a 5	2 a 5	0 a 5	1 a 4	$\eta$	$\xi$	Novos valores; Modelo escolhido
51	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, \xi$	h	Duas variáveis de entrada; Modelo escolhido

Modelos Fuzzy para N = 157 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Número de atrasos puros (ciclo)	Número de <i>clusters</i> (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
52	1 a 5	2 a 5	0 a 5	1 a 4	$\eta$	$\xi$	Modelo escolhido
53	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, \xi$	h	Duas variáveis de entrada; Modelo escolhido

#### IV Lista de modelos inversos (Lógica Fuzzy)

Modelos Fuzzy para N variável entre 79 e 157 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Número de atrasos puros (ciclo)	Número de <i>clusters</i> (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
55	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, \xi, h$	N	Velocidade da turbina variável (sinal tipo <i>chirp</i> ); Três variáveis de entrada; Modelo inverso
55V2	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, \xi, h$	N	<i>idem</i> ; Modelo inverso; Um único vector de teste e validação
56	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, \xi$	N	Velocidade da turbina variável (sinal tipo <i>chirp</i> ); Modelo inverso
57	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, h$	N	<i>idem</i> ; Modelo inverso
58	1 a 5	2 a 5	0 a 5	1 a 4	$\xi, h$	N	<i>idem</i> ; Modelo inverso
59	1 a 5	2 a 5	0 a 5	1 a 4	$\eta$	N	<i>idem</i> ; Modelo inverso
60	1 a 5	2 a 5	0 a 5	1 a 4	$\xi$	N	<i>idem</i> ; Modelo inverso
61	1 a 5	2 a 5	0 a 5	1 a 4	$h$	N	<i>idem</i> ; Modelo inverso
62	1 a 5	2 a 5	0 a 5	1 a 4	$F_{turb}, h$	N	<i>idem</i> ; Modelo inverso; Nova variável de entrada
63	1 a 5	2 a 5	0 a 5	1 a 4	$F_{turb}$	N	<i>idem</i> ; Modelo inverso

Modelos Fuzzy para N = 157 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Número de atrasos puros (ciclo)	Número de <i>clusters</i> (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
64	1 a 5	2 a 5	0 a 5	1 a 4	$p_{inside}, h$	N	<i>idem</i> ; Modelo inverso; Sinal alterado entre 12 e 25 Hz
65	1 a 5	2 a 5	0 a 5	1 a 4	$p_{inside}, h$	N	<i>idem</i> ; Modelo inverso; Sinal alterado entre 0,34 e 0,68 Hz
66	1 a 5	2 a 5	0 a 5	1 a 4	$p_{inside}, h$	N	<i>idem</i> ; Modelo inverso; Sinal alterado entre 0,34 e 0,68 Hz; Pinside em módulo

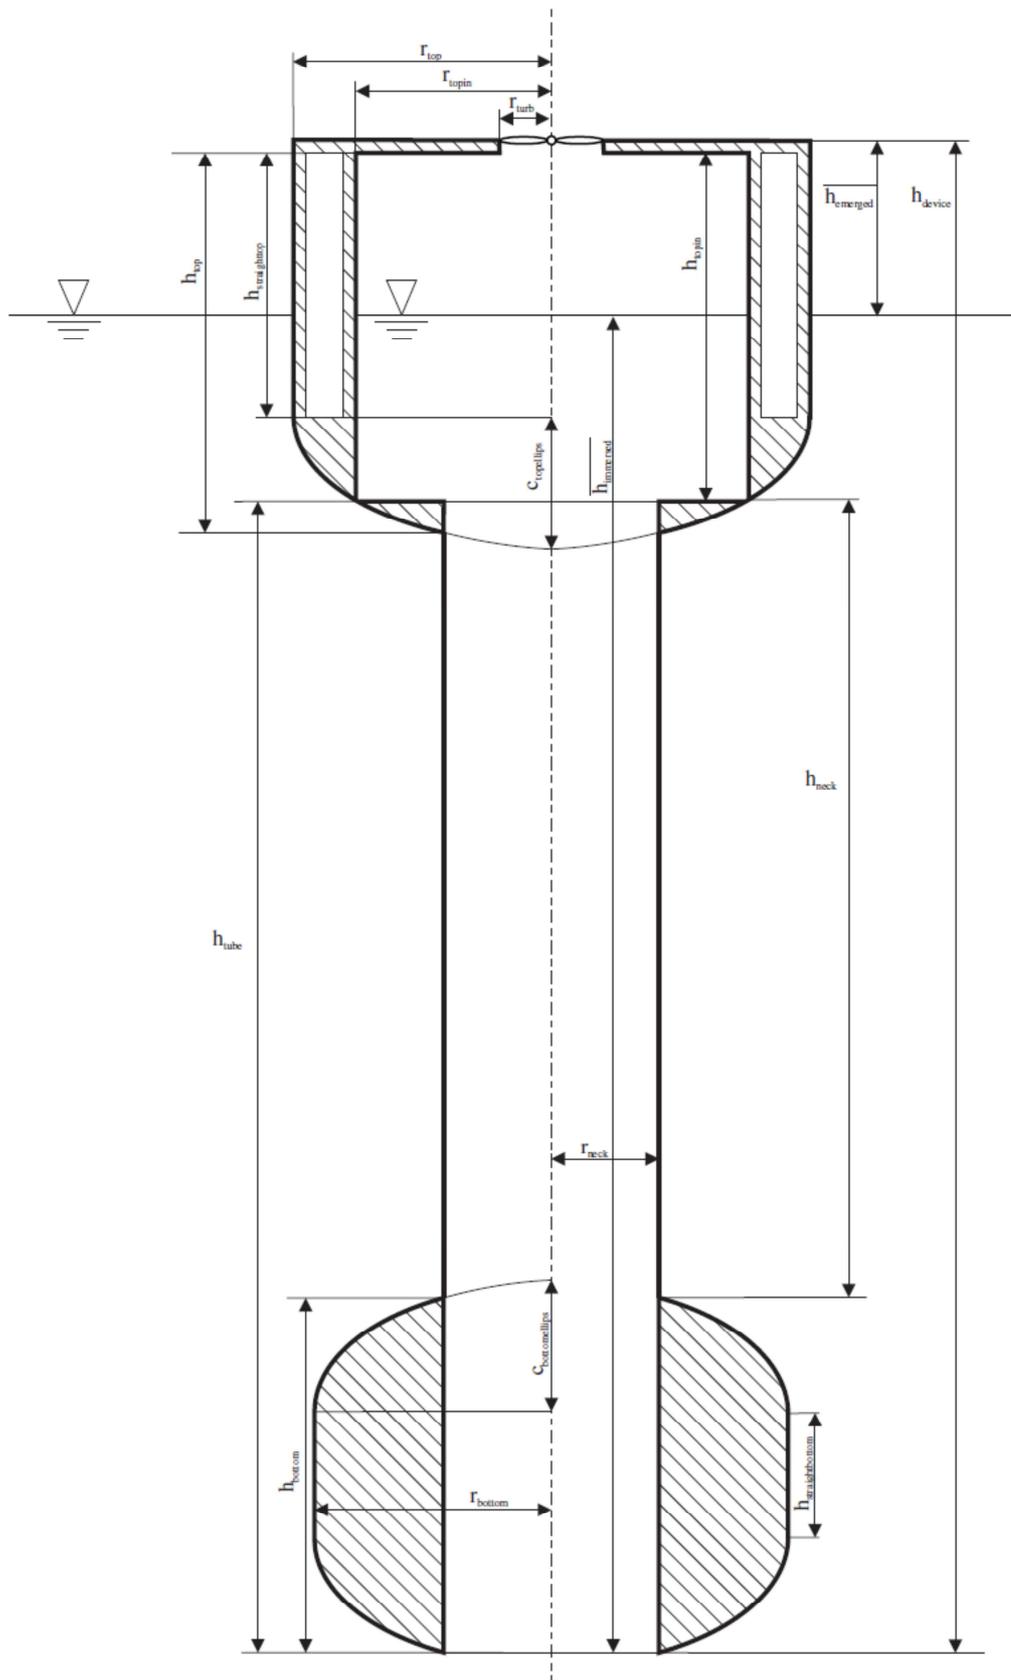
Modelos Fuzzy para N variável entre 79 e 157 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Número de atrasos puros (ciclo)	Número de clusters (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
67	1 a 5	2 a 5	0 a 5	1 a 4	$P_{inside}, h$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco; Pinside em módulo
68	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, \xi, h$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco
69	1 a 5	2 a 5	0 a 5	1 a 4	$F_{turb}, h$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco
70	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, h$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco
71	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, \xi$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco
72	1 a 5	2 a 5	0 a 5	1 a 4	$\xi, h$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco
73	1 a 5	2 a 5	0 a 5	1 a 4	$\eta$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco
74	1 a 5	2 a 5	0 a 5	1 a 4	$\xi$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco
75	1 a 5	2 a 5	0 a 5	1 a 4	$h$	N	<i>idem</i> ; Modelo inverso; N gerado com ruído branco

Modelos Fuzzy para N variável entre 79 e 157 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Número de atrasos puros (ciclo)	Número de clusters (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
76	1 a 5	2 a 5	0 a 5	1 a 4	$F_{turb}, h$	N	<i>idem</i> ; Modelo inverso; Sinal alterado entre 0,34 e 0,68 Hz
77	1 a 5	2 a 5	0 a 5	1 a 4	$F_{turb}, h$	-N	<i>idem</i> ; Modelo inverso; Sinal alterado entre 0,34 e 0,68 Hz
77V2	1 a 5	2 a 5	0 a 5	1 a 4	$F_{turb}, h$	-N	<i>idem</i> ; Modelo inverso; Sinal alterado entre 0,34 e 0,68 Hz; -N aprendizagem
78	1 a 5	2 a 5	0 a 5	1 a 4	$F_{turb}, h$	N	<i>idem</i> ; Modelo inverso; Sinal alterado entre 0,34 e 0,68 Hz; $F_{turb}$ positiva
78V2	1 a 5	2 a 5	0 a 5	1 a 4	$F_{turb}, h$	N	<i>idem</i> ; Modelo inverso; Sinal alterado entre 0,34 e 0,68 Hz; $F_{turb}$ positiva tb na validação

Modelos Fuzzy para N variável entre 79 e 157 rad/s (tempo de amostragem, $T_s = 0,05$ s)							
Modelo	Ciclo de atrasos na entrada	Ciclo de atrasos na saída	Número de atrasos puros (ciclo)	Número de <i>clusters</i> (ciclo)	Variáveis de entrada	Variáveis de saída	Observações
79	1 a 5	2 a 5	0 a 5	1 a 4	$\eta, \xi, h'$	N	<i>idem</i> ; Modelo inverso; Sinal variável; Derivada de h
80	1 a 5	2 a 5	0 a 5	1 a 4	$F_{\text{turb}}, h, h'$	N	<i>idem</i> ; Modelo inverso; Sinal variável; Derivada de h
81	1 a 5	2 a 5	0 a 5	1 a 4	$F_{\text{turb}}, h'$	N	<i>idem</i> ; Modelo inverso; Sinal variável; Derivada de h
82	1 a 5	2 a 5	0 a 5	1 a 4	$F_{\text{turb}}, h$	N	<i>idem</i> ; Modelo inverso; Sinal variável; Igual ao 62 com novos valores
83	1 a 5	2 a 5	0 a 5	1 a 4	$F_{\text{turb}}, h$	$P_{\text{turb}}$	<i>idem</i> ; Modelo inverso; Sinal variável;

## Anexo II

Diagrama do aparelho [2], em repouso, com as respectivas variáveis





## Anexo III

### Rotina para modelos neuronais

#### teseNarxMod29.m

```
% Neural_NARX Mod 29
% Tese (IST 2011)
% © Joao Casanova
% -----
% 1. velocidade turbina: 79 rad/s (754 rpm)
% 2. tempo de amostragem = 0,05 s
% 3. atrasos de 1 a 7 na entrada e 2 a 7 na saída
% 4. critério de paragem: 1000 épocas ou erro=1e-6
% 5. ciclo de neurónios de 10:20
% 6. experiência com 2 entradas: wave_elevation, csi
% 7. variável de saída: h
% -----
%% Dados de treino (vectores coluna passam a vectores linha)
u11 = wave_elevation';
u12 = csi';
y1 = h';

% Dados para validação
u21 = wave_elevation2';
u22 = csi2';
y2 = h2';

%% Mudança do tempo de amostragem (resampling)
u11 = u11(1:25:end);
u12 = u12(1:25:end);

u21 = u21(1:25:end);
u22 = u22(1:25:end);

y1 = y1(1:25:end);
y2 = y2(1:25:end);

%% Pre-processamento de dados
% Normalizar entradas e saídas no intervalo [-1,1]
% Transformar os dados para sequenciais
[y1,ys] = mapminmax(y1);
y1 = con2seq(y1);

u1 = [u11; u12];
[u1,us] = mapminmax(u1);
u1 = con2seq(u1);
```

```

y2 = mapminmax('apply',y2,ys);
y2 = con2seq(y2);

u2 = [u21; u22];
u2 = mapminmax('apply',u2,us);
u2 = con2seq(u2);

% Ciclo com os atrasos da entrada e da saída
cont=1;
for indice1 = 2:7
    OD = [1:indice1]; % Atrasos na saída (Output Delays)
    for indice2 = 1:7
        ID = [0:indice2]; % Atrasos na entrada (Input Delays)
        maxlag = max(max(ID),max(OD)); % Número máximo dos atrasos
        clear p1 p2;
        p1 = u1((maxlag+1):end); % Reconstruir os vectores sem os atrasos
        p2 = u2((maxlag+1):end);
        clear t1 t2;
        t1 = y1((maxlag+1):end);
        t2 = y2((maxlag+1):end);
        clear Pi1;
        Pi1 = [u1(1:maxlag); y1(1:maxlag)]; % Vector com os atrasos iniciais

%% Criar e treinar a rede
% Ciclo para os neurónios
for neuron = 10:20
    clear net tr;
    net = newnarxsp(p1,t1,ID,OD,neuron); % Criar a rede em série-paralela

    net.trainParam.epochs = 1000; % Critério de paragem
    net.trainParam.goal = 1e-6; % Critério de paragem
    net.trainParam.showWindow = false; % Desactivar modo gráfico

    [net,tr] = train(net,[p1;t1],t1,Pi1); % Treino da rede

%% Simular a rede
clear Ys Pfs Afs Es simPerf;
[Ys,Pfs,Afs,Es,simPerf] = sim(net,[p1;t1],Pi1);
clear erro;
erro = cell2mat(Ys) - cell2mat(t1); % Calcular o erro dos dados de treino...
        % ...na configuração série-paralela
clear Perf;
Perf = mse(erro); % Calcular o desempenho da rede

% Validar a rede com dados novos
% Alterar rede: narxsp to narx

```

```

clear net2;
net2 = sp2narx(net); % Alterar configuração da rede em paralela

clear Yv Pfv Afv Ev valPerf Yv2 Pfv2 Afv2 Ev2 valPerf2;
[Yv,Pfv,Afv,Ev,valPerf] = sim(net2,p1); % Simular a rede com dados de treino
[Yv2,Pfv2,Afv2,Ev2,valPerf2] = sim(net2,p2); % Simular a rede com dados novos

clear erro2 erro22;
erro2 = cell2mat(Yv) - cell2mat(t1); % Calcular o erro dos dados de treino
erro22 = cell2mat(Yv2) - cell2mat(t2); % Calcular o erro dos dados novos

clear Perf2 Perf22;
Perf2 = mse(erro2); % Calcular o desempenho da rede
Perf22 = mse(erro22); % Calcular o desempenho da rede

% Guardar dados no ambiente do Matlab (temporariamente)
modelos(cont,1)=indice2;
modelos(cont,2)=indice1;
modelos(cont,3)=Perf;
modelos(cont,4)=Perf2;
modelos(cont,5)=Perf22;
modelos(cont,6)=neuron;
cont=cont+1;

% Guardar dados dos modelos num ficheiro próprio
fOut=sprintf('teseN079Mod29n%2d%2d%2d.mat',neuron,indice2,indice1);
save(fOut, 'ys','us','p1','p2','Pi1','t1','t2','net','tr','Ys','Pfs','Afs','Es','simPerf','erro','Perf',...
'net2','Yv','Yv2','Pfv','Pfv2','Afv','Afv2','Ev','Ev2','valPerf','valPerf2','erro2','erro22',...
'Perf2','Perf22','modelos');
end
end
end

```

## Rotina para modelos Fuzzy

### teseFuzzyMod51.m

```
% Redes dinâmicas Fuzzy: Mod 51
% Tese (IST 2011)
% © Joao Casanova
% -----
% 1. velocidade turbina: constante 79 rad/s
% 2. tempo de amostragem = 0,05 s
% 3. atrasos de 1 a 5 na entrada e 2 a 5 na saída
% 4. atrasos puros de 0 a 5
% 5. número de clusters de 1 a 4
% 6. experiência com 2 entradas: wave_elevation, csi
% 7. estimar: h
% -----

% definição de constantes
clear FM Par Dat Dyn fuzzyIn fuzzyOut modelos
FM.tol = 0.01; % valor por defeito
FM.seed = 0; % semente
FM.ante = 1; % antecedentes: 1 - product-space MFS
% 2 - projected MFS
FM.Ts = 0.05; % tempo de amostragem [s]
FM.m = 2; % fuzziness

% dados para identificação e validação
fuzzyIn(:,1) = wave_elevation(1:25:end);
fuzzyIn(:,2) = csi(1:25:end);
fuzzyOut = h(1:25:end);

fuzzyInVal(:,1) = wave_elevation2(1:25:end);
fuzzyInVal(:,2) = csi2(1:25:end);
fuzzyOutVal = h2(1:25:end);

Dat.U = fuzzyIn(:,1:2);
Dat.Y = fuzzyOut;
Dat.InputName{1} = 'eta';
Dat.InputName{2} = 'csi';
Dat.OutputName{1} = 'h';

% dados para validação
ue = fuzzyInVal(:,1:2);
ye = fuzzyOutVal;

% Ciclo com os atrasos da entrada e da saída
cont=1;
```

```

for indice2 = 2:5
    OD = indice2;
    for indice1 = 1:5
        ID = indice1;
        for delay = 0:5
            for nClusters = 1:4
                FM.Ny = [OD];    % número de atrasos na saída
                FM.Nu = [ID ID]; % número de atrasos na entrada
                FM.Nd = [delay delay]; % número de atrasos puros
                FM.c = nClusters; % número de clusters

                % estimar modelo fuzzy através de fuzzy clustering
                [FM,Part] = fmclust(Dat,FM);

                % simulação do modelo fuzzy com os dados de validação
                try
                    [ym,VAF,dof,yl,ylm] = fmsim(ue,ye,FM,[],[],0);
                catch ME
                    errorMessage = sprintf('Input to EIG must not contain NaN or Inf.\n\nErrorMessage:\n%s', ME.message);
                    fprintf(1, errorMessage);
                    uiwait(warndlg(errorMessage));
                end

                % Guardar dados no ambiente do Matlab (provisoriamente)
                modelos(cont,1) = indice1;
                modelos(cont,2) = indice2;
                modelos(cont,3) = delay;
                modelos(cont,4) = nClusters;
                modelos(cont,5) = VAF;
                cont=cont+1;

                % Guardar dados num ficheiro próprio
                fOut=sprintf('teseN079Mod51n%2d%2d%2d%2d.mat',indice1,indice2,delay,nClusters);
                save(fOut, 'FM','Part','ym','VAF','dof','yl','ylm','modelos');
            end
        end
    end
end
end
end

```