

**MARCO AURÉLIO BRAZÃO COSTA BADAN**

**MICROFONE VIRTUAL COM BASE NO SINAL  
VIBRO ACÚSTICO DA FONTE EMISSORA**



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE ENGENHARIA MECÂNICA  
2015**

**Marco Aurélio Brazão Costa Badan**

**MICROFONE VIRTUAL COM BASE NO SINAL  
VIBRO ACÚSTICO DA FONTE EMISSORA**

**Tese** apresentada ao Programa de Pós-graduação em Engenharia Mecânica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de **DOUTOR EM ENGENHARIA MECÂNICA**.

Área de Concentração: Mecânica dos Sólidos e Vibrações.

Orientador: Prof. Dr. Marcus Antônio Viana Duarte

**UBERLÂNDIA - MG**  
**2015**

---

Dados Internacionais de Catalogação na Publicação (CIP)  
Sistema de Bibliotecas da UFU, MG, Brasil.

---

B132m Badan, Marco Aurélio Brazão Costa, 1965-  
2015 Microfone virtual com base no sinal vibro acústico da fonte emissora  
/ Marco Aurélio Brazão Costa Badan. - 2015.  
121 f. : il.

Orientador: Marcus Antonio Viana Duarte.  
Tese (doutorado) - Universidade Federal de Uberlândia, Programa  
de Pós-Graduação em Engenharia Mecânica.  
Inclui bibliografia.

1. Engenharia mecânica - Teses. 2. Acústica - Teses. 3. Redes  
neurais (Computação) - Teses. I. Duarte, Marcus Antonio Viana. II.  
Universidade Federal de Uberlândia, Programa de Pós-Graduação em  
Engenharia Mecânica. III. Título.

---

CDU: 621

**Marco Aurélio Brazão Costa Badan**

**MICROFONE VIRTUAL COM BASE NO SINAL  
VIBRO ACÚSTICO DA FONTE EMISSORA**

Tese **APROVADA** pelo Programa de Pós-graduação em Engenharia Mecânica da Universidade Federal de Uberlândia.

Área de Concentração: Mecânica dos Sólidos e Vibrações.

Banca Examinadora:

Prof. Dr. Marcus Antonio Viana Duarte (orientador)

UFU 

Prof. Dr. Marcelo Braga dos Santos

UFU 

Prof. Dr. Israel Jorge Cárdenas Nuñez

UFTM 

Profa. Dra. Maria Alzira de Araújo Nunes

UnB 

Prof. Dr. Nilson Barbieri

PUC/PR 

**Uberlândia, 08 de junho de 2015**

DEDICATÓRIA:

A minha esposa Denise  
Aos meus filhos, João Pedro e Giulia  
Aos meus pais, Eudércio e Lucélia

## AGRADECIMENTOS

A Deus, pois sem Ele nada seria possível ... e singularmente por me conduzir e me orientar nas dificuldades.

A minha esposa e filhos pela tolerância, sobretudo pelo o sacrifício da convivência neste período, além da confiança por acreditarem nesta escolha. Especialmente ainda por serem a base e a minha principal motivação para seguir em frente.

Ao meu orientador Prof. Dr. Marcus A. V. Duarte, pela paciência e pelos ensinamentos que foram repassados. Agradeço especialmente pela oportunidade da amizade, extensiva a este breve período de convívio.

A todos os colegas do Laboratório de Acústica e Vibrações - LAV (Marlipe, Júlia, Vinicius (Coroas), Ricardo (Alemão), Israel, Marcela, Patrick, Bruno, Geisa e demais colegas), pelo incentivo, suporte, camaradagem e ótima relação do dia a dia. Sendo um pouco mais contundente, ao Pedro R. P. Nishida e ao João Gabriel O. Miranda pela inestimável amizade ora consolidada.

Ao Prof. Dr. Elias B. Teodoro por todas as contribuições, ajuda e amizade.

Ao Instituto Federal de Goiás e ao grupo da Mecânica pelo suporte e condições fornecidas.

Ao CNPQ pelo esteio financeiro, quesito primordial na elaboração do trabalho.

À Universidade Federal de Uberlândia e a Faculdade de Engenharia Mecânica que propiciaram a realização deste curso.

Ao todos os demais amigos e colegas pelo constante apoio, estima e incentivo.

Aos meus pais que com dificuldade e dedicação, deram a oportunidade e as condições de estudar, possibilitando assim um futuro melhor que está presente hoje.

Meus sinceros agradecimentos

Badan, M. A. B. C. **Microfone virtual com base no sinal vibro acústico da fonte emissora.** 2015. 121 f. Tese de Doutorado, Universidade Federal de Uberlândia, Uberlândia-MG.

### **Resumo**

Para efetivar com eficiência um processo de controle ativo de ruído (CAR), a proximidade dos sensores de erro é fortemente dependente da localização em que a atenuação de ruído é desejada. Um inconveniente disso é a necessidade de posicionar os sensores em locais inapropriados tais como: no centro de quartos, corredores ou perto das orelhas de pessoas. Assim, é investigado um método baseado na detecção da fonte do ruído indesejado a partir de sensores físicos posicionados em pontos remotos e o uso de funções de transferência utilizando Redes Neurais. O uso de Redes Neurais se justifica devido a alterações nas propriedades acústicas no ambiente, a exemplo do que foi estudado nesta tese: Campo reverberante em sala, movimentação de pessoas no local, mudança de layout e etc. A caracterização dos sinais de treinamento, número e posição de sensores remotos também foram investigados. A topologia de rede neural foi estudada e aprimorada por otimização via algoritmo de evolução diferencial. As respostas medidas e estimadas foram avaliadas e comparadas em termos de nível RMS, magnitude e fase. A estimativa de uma região em vez de um único ponto, mostrou ser possível implementar o deslocamento virtual. Da mesma forma, observou-se que uma rede neural treinada com ruído branco tem capacidade de estimar uma resposta virtual harmônica. Estes resultados mostram que é possível obter respostas de uma banda de frequência estreita. Com base nos resultados obtidos, conclui-se que a técnica tem potencial para ser aplicada no processo de CAR. A aplicação on-line do CAR e a utilização da estratégia de deslocamento virtual são sugerida para trabalhos futuros.

---

**Palavras-Chaves:** Sensor virtual, estimativa do campo acústico, redes neurais e aplicações em controle ativo de ruído.

Badan, M. A. B. C. **Virtual microphone based on the vibroacoustic signal of emitting source.** 2015. 121 f. Doctorate Thesis, Federal University of Uberlândia, Uberlândia-MG.

### **Abstract**

The success of an Active Noise Control (ANC) procedure is strongly dependent of the proximity of error sensors and location, where the noise mitigation is desired. One inconvenience of this is the necessity to positioning the sensors in inappropriate places such as: in center of rooms, corridors or near the ears of people. Hence a method based on detection – of undesired noise source - with remote physical sensors and the use of transfer functions estimated by Neural Networks is investigated. The use of Neural Network is justified due to changes in the environmental acoustic properties type as studied in this thesis: reverberant room field, walking people, change in furniture's position and etc. The influence of the signals set, to train the Neural Network, number and position of remote sensors were also investigated. The neural network topology was studied and optimized by differential evolution algorithm. The measured and estimated responses were evaluated and compared in terms of RMS level, magnitude and phase. The estimative in a region instead of a single point, shows that it is possible to implement the virtual displacement. As well, it was observed that a Neural Network trained with white noise was able to estimate a harmonic virtual response. These results show that it is possible to obtain good responses in a narrow frequency band. Based on the results it is concluded that the technique has potential to be applied in ANC procedure. Online implementation of ANC and use of the virtual displacement strategy is suggested for future works.

---

**Keywords:** *Virtual sensor, sound field estimative, neural networks and active noise control applications.*

## LISTA DE FIGURAS

Figura 2.1 – Sistema básico do controle ativo de ruído (adaptado de HANSEN, 2001).	6
Figura 2.2 – Arquitetura dos filtros FIR e IIR respectivamente (adaptado de HANSEN, 2001).	7
Figura 2.3 – Controle de sombra acústica em campo próximo, sistema ECAS apresentado por Wright e Vucksanovisck (1999).	9
Figura 2.4 – Máxima atenuação obtida na potencia sonora utilizando duas fontes pontuais (HANSEN, 2001).	12
Figura 2.5 – (a) Menor nível de pressão acústica obtido na posição do sensor físico. (b) Menor nível de pressão acústica obtido na posição do sensor remoto, virtualmente posicionado na cabeça (ou no ouvido) do receptor (KESTELL et al., 2001).	15
Figura 2.6 – Princípio da extrapolação à frente, utilizando uma estimativa linear (reta) (MUNN et al., 2002).	16
Figura 3.1 – (a) Estrutura do neurônio biológico. (b) Representação da rede neurológica no cérebro. O destaque em (b) mostra a ligação do axônio (saída do sinal) com o dendrito (entrada do sinal) (NG, 2001).	18
Figura 3.2 – (a) Notação clássica do modelo do neurônio artificial. (b) Representação do modelo do neurônio artificial, utilizada no Matlab® (DEMUTH; BEALE, 2002).	19
Figura 3.3 – Função Linear (DEMUTH; BEALE, 2002).	21
Figura 3.4 – Função Limiar (DEMUTH; BEALE, 2002).	21
Figura 3.5 – Função Rampa (DEMUTH; BEALE, 2002).	21
Figura 3.6 – Função Sigmoid (DEMUTH; BEALE, 2002).	21
Figura 3.7 – (a) Neurônios agrupados em uma única camada. (b) Representação compacta da camada de neurônios, utilizada pelo Matlab® (BEALE et. al., 2002).	22
Figura 3.8 – (a) Rede multicamadas com três camadas ocultas. (b) Representação compacta da mesma rede (BEALE et. al., 2002).	23
Figura 3.9 – (a) Rede recorrente tipo: 1x3x1. (b) Rede com atraso na linha direta tipo: 2x4x1 (adaptado de BEALE et. al., 2002).	24
Figura 3.10 – Representação dos ajustes obtidos para a função $y=\text{sen}(2\pi x)$ onde $M$ = ordem do modelo utilizado (a) Sub ajustagem. (b) Ajuste adequado. (c) Super ajuste (adaptado de SRIHARI, 2013).	30
Figura 3.11 – Modelo de mesma ordem, utilizando (a) $N = 15$ dados. (b) $N = 100$ dados para os ajustes (adaptado de SRIHARI, 2013).	30
Figura 3.12 – Rede Neural utilizada como exemplo de identificação dos parâmetros de projeto, nomenclatura utilizada e para descrever os comandos utilizados para geração.	32
Figura 3.13 – (a) Rede neural com uma camada oculta para ajuste de curva (b) Erro entre a resposta e a estimativa. Valor do erro médio quadrático obtido = $108,33 \times 10^{-4}$ .	33
Figura 3.14 – (a) Rede neural com duas camadas ocultas para ajuste de curva (b) Erro entre resposta e estimativa. Valor do erro médio quadrático obtido = $14,11 \times 10^{-4}$ .	34

Figura 3.15 – (a) Filtragem adaptativa - FIR (b) Erro resultante da resposta estimada e da resposta adquirida.	35
Figura 3.16 – (a) Filtragem adaptativa - IIR (b) Erro resultante da resposta estimada e da resposta adquirida.	36
Figura 4.1 – Crescimento e decaimento sonoro em recintos com indicação do tempo de reverberação ( $T_{60}$ ) (BISTAFÁ, 2006).	39
Figura 4.2 – Condição ideal de resposta em frequência.	40
Figura 4.3 – Medição da pressão sonora em função da frequência de uma sala retangular com 180 m <sup>3</sup> . Abaixo de 80 Hz as ressonâncias podem ser identificadas (CROCKER, 2007).	40
Figura 4.4 – Visualização dos modos usando conceito de “raios acústicos” (CROCKER, 2007).	42
Figura 4.5 – Visualização dos modos normais nas direções x e y de uma sala.	43
Figura 4.6 – (a) Modelo numérico estrutural da sala com os respetivos materiais empregados. (b) Elementos de fluido em contato com a estrutura presente pelo lado interno. Os elementos do teto foram deslocados para efeito de visualização.	44
Figura 4.7 – Modo normal mais próximo da frequência de excitação em 250 Hz obtidos pela: (a) Equação analítica. (P <sub>MAX</sub> / MIN = $\pm 1,00$ Pa). (b) Simulação numérica.	45
Figura 4.8 – Modo normal mais próximo da frequência de excitação em 497 Hz obtidos pela: (a) Equação analítica. (P <sub>MAX</sub> / MIN = $\pm 0,58$ Pa). (b) Simulação numérica.	45
Figura 4.9 – Modo normal mais próximo da frequência de excitação em 730 Hz obtidos pela: (a) Equação analítica. (P <sub>MAX</sub> / MIN = $\pm 0,76$ Pa). (b) Simulação numérica.	46
Figura 4.10 – Campo acústico em torno dos sensores em 250 Hz.	46
Figura 4.11 – Campo acústico em torno dos sensores em 497 Hz.	47
Figura 4.12 – Campo acústico em torno dos sensores em 730 Hz.	47
Figura 5.1 – (a) Sala vazia com porta fechada, corresponde ao nível (+). (b) com porta aberta, corresponde ao nível (-).	51
Figura 5.2 – (a) Sala vazia com janela fechada, corresponde ao nível (+). (b) com janela aberta, corresponde ao nível (-).	51
Figura 5.3 – Sala ocupada, corresponde ao nível (-). As placas ilustradas são espumas com propriedades de absorção sonora, sendo: 8 unidades x 1,0 x 1,0 m <sup>2</sup> . Para a sala vazia foi definido o nível (+).	52
Figura 5.4 – Gráfico normal dos valores significativos para o nível RMS.	57
Figura 5.5 – Gráfico normal dos valores significativos para: (a) Magnitude e (b) Fase.	57
Figura 5.6 – Gráfico normal dos valores significativos para o nível RMS.	59
Figura 5.7 – Gráfico normal dos valores significativos para: (a) Magnitude e (b) Fase.	60
Figura 6.1 – Rede <i>Feedforward</i> (FF).	63
Figura 6.2 – Rede <i>Feedforward</i> em Cascata (FFC).	63
Figura 6.3 – Rede com Atraso na Camada Inicial (ACI).	64
Figura 6.4 – Rede com Atraso Distribuído nas Camadas (ADC).	64
Figura 6.5 – Rede Recorrente em Camadas (RC).	64
Figura 6.6 – Rede Auto Regressiva com Entrada Exógena (NARX).	65

Figura 6.7 – Distribuição dos sensores para aquisição dos sinais na sala vazia. Ao fundo o autofalante e na bancada: a instrumentação e o gerador de sinais.	66
Figura 6.8 – Comparação entre sinal obtido e o sinal estimado. (a) Rede <i>Feedforward</i> da Tab. 6.1. (b) Rede NARX da Tab. 6.3.	68
Figura 6.9 – Gráfico comparativo entre desempenhos obtidos pelas redes neurais.	69
Figura 6.10 – Tempos de treinamento utilizados pelas redes neurais.	69
Figura 6.11 – Desempenhos obtidos ao variar a quantidade de neurônios.	71
Figura 6.12 – Desempenhos obtidos ao variar os atrasos de linha.	71
Figura 6.13 – <i>Layout</i> e disposição da matriz de microfones na sala. Os microfones Mic1 ao Mic5 formam um conjunto de aquisição. O Mic6 indica a posição do microfone virtual. A fonte no canto superior a esquerda.	73
Figura 6.14 – Posicionamento de microfones e detalhe da suportação. (a) Foto frontal da 2 <sup>a</sup> aquisição (b) Foto traseira da 4 <sup>a</sup> aquisição.	73
Figura 6.15 – Desempenhos obtidos ao variar os atrasos de linha.	75
Figura 6.16 – Resposta da rede NARX (AF+M1)x03x01 [8]/[8], utilizando: (a) 53000 pts e (b) 500 pontos no treinamento. Estimativa obtida com 81920 pontos ou 49,95 s.	75
Figura 6.17 – Exemplo da “seleção” ou amostragem do sinal em 05 conjuntos de dados (vetores). Cada vetor com 500 pontos para o treinamento da RNA.	76
Figura 6.18 – Sinal medido e estimado em 250 Hz: (a) utilizando apenas o sensor na fonte. (b) utilizando o sensor na fonte + 01 microfone. (c) utilizando o sensor na fonte + 05 mic.	78
Figura 6.19 – Sinal medido e estimado em 497 Hz: (a) utilizando apenas o sensor na fonte. (b) utilizando o sensor na fonte + 01 microfone. (c) utilizando o sensor na fonte + 05 mic.	79
Figura 6.20 – Desempenhos verificados em função da frequência ao variar a quantidade de sensores utilizados na referencia.	80
Figura 6.21 – Desempenhos verificados ao variar posição do Mic1, utilizado como sensor de referencia.	83
Figura 6.22 – Número de eventos para: (a) todos os resultados, (b) resultados próximos à ocorrência mais frequentes.	85
Figura 6.23 – Histograma das ocorrências para: (a) o número de neurônios, (b) o número de atrasos na linha direta e (c) o número de atrasos da linha recorrente.	86
Figura 6.24 – Número de eventos para: (a) todos os resultados, (b) resultados próximos à ocorrência mais frequentes.	87
Figura 6.25 – Histograma das ocorrências para: (a) o número de neurônios, (b) o número de atrasos na linha direta e (c) o número de atrasos da linha recorrente.	87
Figura 7.1 – Distribuição dos microfones nas 4 aquisições, indicadas por (1), (2), (3) e (4).	91
Figura 7.2 – Distribuição dos microfones e detalhe do suporte. (a) Foto da 1 <sup>a</sup> aquisição (b) Foto da 3 <sup>a</sup> aquisição.	91
Figura 7.3 – Magnitude das FRF's medidas e estimadas em 250 Hz. Utilizado 05 microfones na fase de treinamento.	94

Figura 7.4 – Fase das FRF's medidas e estimadas em 250 Hz. Utilizado 05 microfones na fase de treinamento.	94
Figura 7.5 – Magnitude das FRF's medidas e estimadas em 497 Hz. Foram utilizados 05 microfones na fase de treinamento.	98
Figura 7.6 – Fase das FRF's medidas e estimadas em 497 Hz. Foram utilizados 05 microfones na fase de treinamento.	98
Figura 7.7 – Consolidação dos sinais adquiridos em seis microfones. São 18 amostras em 03 condições de sala. Observe que os sinais acústicos mudam em cada condição de sala	99
Figura 7.8 – Comparação das respostas estimadas e medidas no ponto remoto. (a) Nível RMS, (b) Magnitude da FRF e (c) Fase da FRF em 250 Hz.	102
Figura 7.9 – Ruído branco gerado e adquirido nos seis microfones. Os sinais totalizam 18 amostras obtidas em sala fechada.	103
Figura 7.10 – (a) Ruído branco utilizado no treinamento da rede neural e (b) resposta da rede ao sinal harmônico.	103
Figura 7.11 – (a) Auto espectro do sinal de treinamento, (b) Auto espectro da resposta para o sinal harmônico. (c) Fase e coerência do sinal harmônico.	104
Figura 7.12 – Desvios verificados entre as respostas estimadas e medidas a 250 Hz. (a) Nível RMS, (b) Erro na magnitude da FRF e (c) Erro na fase da FRF.	105

## LISTA DE TABELAS

Tabela 5.1 – Resultados do planejamento experimental na frequência de excitação em 250 Hz. A tabela indica a ordem em que foram realizados os ensaios.	53
Tabela 5.2 – Resultados do planejamento experimental na frequência de excitação em 730 Hz. A tabela indica a ordem em que foram realizados os ensaios.	54
Tabela 5.3 – Matriz da combinação de fatores para a frequência de excitação de 250 Hz. No rodapé da tabela é consolidado o cálculo dos efeitos para cada associação de fatores.	55
Tabela 5.4 – Correspondência entre os efeitos calculados com os valores de probabilidade acumulativa e a variável z. Os efeitos estão em ordem crescente para cada parâmetro avaliado, com os respectivos fatores associados.	56
Tabela 5.5 – Matriz da combinação de efeitos para frequência de excitação de 730 Hz.	58
Tabela 5.6 – Correspondência entre os efeitos calculados com os valores de probabilidade acumulativa e a variável z. Os efeitos estão em ordem crescente para cada parâmetro avaliado, com os respectivos fatores associados.	59
Tabela 6.1 – Resultados de treinamento das RNAs. Entrada = AF (Autofalante). Saída = Mic3. Camadas ocultas = 02. Neurônios na camada de entrada = 10.	67
Tabela 6.2 – Resultados de treinamento das RNAs. Entrada = Mic1. Saída = Mic3. Camadas ocultas = 02. Neurônios na camada de entrada = 10.	67
Tabela 6.3 – Resultados de treinamento das RNAs. Entrada = AF + Mic1. Saída = Mic3. Camadas ocultas = 02. Neurônios na camada de entrada = 10.	67
Tabela 6.4 – Resultados de treinamento das RNAs. Entrada = AF + Mic1. Saída = Mic3. Camadas ocultas = 03. Neurônios na camada de entrada = 10.	67
Tabela 6.5 – Resultados de treinamento das RNAs. Entrada = AF. Saída = Mic3. Camadas ocultas = 02. Neurônios na camada de entrada = 20.	67
Tabela 6.6 – Resultados de treinamentos devido a variação do número de neurônios.	70
Tabela 6.7 – Resultados de treinamentos devido a variação no atraso de linha.	70
Tabela 6.8 – Treinamento em função do vetor de amostras. Característica do sinal medido no ponto remoto: Magnitude 0,5462 V. Fase em -66,17°. Sinal com 81920 pontos.	74
Tabela 6.9 – Resultados obtidos utilizando n vetores de dados com 500 pontos cada. Frequência 250 Hz. Magnitude 0,5462 V. Fase em -66,17°. Sinal total com 81920 pontos.	76
Tabela 6.10 – Erros de estimativa em função da quantidade de sensores em 250 Hz.	78
Tabela 6.11 – Erros de estimativa em função da quantidade de sensores em 497 Hz.	79
Tabela 6.12 – Estimativas obtidas em função do posicionamento do Mic1 250 Hz.	81
Tabela 6.13 – Estimativas obtidas em função do posicionamento do Mic1 497 Hz.	82
Tabela 6.14 – Redes neurais que apresentaram as maiores ocorrências na otimização.	86
Tabela 6.15 – Redes neurais que apresentaram as maiores ocorrências na otimização.	88
Tabela 6.16 – Comparação do EMQ entre as redes neurais avaliadas em 497 Hz.	88

Tabela 7.1 – Magnitude e fase dos sinais na 1 <sup>a</sup> aquisição em 250 Hz.	92
Tabela 7.2 – Magnitude e fase dos sinais na 2 <sup>a</sup> aquisição em 250 Hz.	92
Tabela 7.3 – Magnitude e fase dos sinais na 3 <sup>a</sup> aquisição em 250 Hz.	93
Tabela 7.4 – Magnitude e fase dos sinais na 4 <sup>a</sup> aquisição em 250 Hz.	93
Tabela 7.5 – Magnitude e fase dos sinais na 1 <sup>a</sup> aquisição em 497 Hz.	96
Tabela 7.6 – Magnitude e fase dos sinais na 2 <sup>a</sup> aquisição em 497 Hz.	96
Tabela 7.7 – Magnitude e fase dos sinais na 3 <sup>a</sup> aquisição em 497 Hz.	97
Tabela 7.8 – Magnitude e fase dos sinais na 4 <sup>a</sup> aquisição em 497 Hz.	97
Tabela 7.9 – Validação (JA). Sinal em 15 V com porta fechada e janelas abertas.	100
Tabela 7.10 – Validação (PA). Sinal em 15 V com porta aberta e janelas fechadas.	100
Tabela 7.11 – Validação (SF). Sinal em 15 V obtido com a porta e as janelas fechadas.	101
Tabela 7.12 – Treinamento utilizando ruído branco. Validação utilizando sinais harmônicos a 250 Hz medidos em sala fechada.	104

## LISTA DE SÍMBOLOS

$i$	Número de neurônios
$j$	Número de entradas
$l$	Número de camadas
$w_{i0}$	Representa <i>bias</i> ou desvio
$b_i$	Representa <i>bias</i> ou desvio
$a_i$	Saída do neurônio $i$
$m$	Número de amostras de treinamento
$T_{60}$	Tempo de reverberação (s)
$t$	Tempo (s)
$f$	Frequência (Hz)
$f_0$	Frequência fundamental (Hz)
$V$	Volume do recinto ( $m^3$ )
$A$	Absorção sonora total do recinto ( $m^2$ )
$S$	Área superficial ( $m^2$ )
$L$	Distância linear (m)
$L_x$	Dimensão na direção x (m)
$L_y$	Dimensão na direção y (m)
$L_z$	Dimensão na direção z (m)
$n_x$	Inteiro que representa o plano do modo na direção x
$n_y$	Inteiro que representa o plano do modo na direção y
$n_z$	Inteiro que representa o plano do modo na direção z
$c$	Velocidade do som ( $m / s$ )
$P$	Pressão sonora ( $N / m^2$ )
$p$	Pressão sonora ( $N / m^2$ )
$v$	Velocidade da partícula ( $m / s$ )
$Z$	Impedância acústica (rayls = $Ns / m^3$ )

### Campo Vetorial

$\vec{x}$	Vetor de entrada
$\vec{w}$	Vetor de parâmetros ou pesos sinápticos
$\vec{\delta}$	Vetor erro

### Sobrescritos e subscritos

$\bullet^T$	Matriz transposta
$(\bullet)_{ij}^l$	Elemento generalizado na camada ( $l$ ), neurônio ( $i$ ), entrada ( $j$ )

### Letras Gregas

$\alpha$	Taxa de aprendizagem
$\omega$	Frequência angular (rad/s)
$\omega_n$	Frequência natural (rad/s)
$\xi$	Deslocamento da partícula (m)
$\rho$	Densidade do meio (kg / m <sup>3</sup> )

### Operadores

$f(\bullet)$	Função de ativação
$J(\bullet)$	Função de custo a ser minimizada
$z^{-1}$	Operador da transformada $z$
$\circ'$	Derivada primeira em relação a dimensão $\chi$ = $d(\circ)/d\chi$
$\vec{\nabla}$	Operador Nabla = $(\partial/\partial x, \partial/\partial y, \partial/\partial z)$

# SUMÁRIO

<b>CAPÍTULO I – INTRODUÇÃO .....</b>	1
1.1 Contextualização do trabalho de pesquisa .....	1
1.2 Objetivos .....	3
1.3 Organização do trabalho .....	4
<b>CAPÍTULO II - REVISÃO BIBLIOGRÁFICA .....</b>	5
2.1 Introdução ao controle ativo de ruído .....	5
2.2 Atenuação de ruído em nível global .....	10
2.3 Atenuação de ruído em nível local .....	12
2.4 Microfone Virtual .....	13
<b>CAPÍTULO III - REDES NEURAIS .....</b>	18
3.1 Introdução .....	18
3.2 Modelagem do Neurônio Artificial .....	19
3.2.1 <i>Funções de Ativação</i> .....	20
3.3 Estrutura da Rede Neural .....	22
3.3.1 <i>Camadas</i> .....	22
3.3.2 <i>Arquiteturas de Rede</i> .....	23
3.3.3 <i>Treinamento</i> .....	25
3.3.3.1 - Estratégias de Aprendizado: .....	25
3.3.3.2 - Algoritmo de Aprendizado: .....	25
3.3.3.3 - Funções de Treinamento – Matlab®: .....	28
3.4 O problema do super ajuste e da sub ajustagem .....	29
3.4.1 <i>Super ajustagem em Redes Neurais</i> .....	30
3.5 Nomenclatura adotada neste trabalho .....	32
3.6 Estudos de casos .....	33
3.6.1 <i>Ajuste de curvas</i> .....	33
3.6.2 <i>Filtragem adaptativa - Filtro FIR</i> .....	34
3.6.3 <i>Filtragem adaptativa - Filtro IIR</i> .....	35
3.7 Considerações sobre Redes Neurais .....	37

<b>CAPÍTULO IV - ACÚSTICA DE AMBIENTES FECHADOS .....</b>	38
4.1 Introdução .....	38
4.2 Reverberação .....	38
4.3 Ondas estacionárias e modos acústicos .....	40
4.3.1 <i>Modos Acústicos</i> .....	41
4.4 Características acústicas da sala de ensaios .....	44
<b>CAPÍTULO V - ANÁLISE DE SENSIBILIDADE DE PARAMETROS .....</b>	48
5.1 Apresentação .....	48
5.2 Conceitos teóricos .....	49
5.3 Fatores de influencia e metodologia .....	50
5.4 Instrumentação utilizada .....	52
5.5 Ensaios realizados .....	52
5.6 Análise dos resultados .....	55
5.6.1 <i>Análise dos efeitos combinados para a frequência de 250 Hz</i> .....	55
5.6.2 <i>Análise dos efeitos combinados para a frequência de 730 Hz</i> .....	58
5.7 Consolidação dos resultados .....	60
<b>CAPÍTULO VI - PROJETO E CONFIGURAÇÕES DE REDES NEURAIS PARA ESTIMATIVA DE UM SINAL HARMÔNICO .....</b>	62
6.1 Introdução .....	62
6.2 Projeto e seleção da Rede Neural Artificial .....	63
6.2.1 <i>Arquiteturas das Redes Neurais</i> .....	63
6.2.2 <i>Procedimento experimental</i> .....	66
6.2.3 <i>Treinamento das redes projetadas</i> .....	66
6.2.3.1 - Considerações: .....	68
6.2.4 <i>Aprimoramento das arquiteturas das redes ACI e NARX</i> .....	70
6.3 Tratamento dos sinais de treinamento e sinais de entrada de dados para generalização da resposta .....	72
6.3.1 <i>Procedimento experimental</i> .....	72
6.3.2 <i>Avaliação da resposta da Rede Neural em função da amostragem do sinal</i> .....	74
6.3.2.1 - Amostragem dos sinais: .....	76
6.3.3 <i>Resposta da Rede Neural em função do número de sensores de referência</i> .....	77

6.3.4 Qualidade da estimativa em função do posicionamento do sensor de referência .....	80
6.4 Aprimoramentos da rede neural via otimização de parâmetros .....	84
6.4.1 Rede neural otimizada na frequência de 250 Hz .....	85
6.4.2 Rede neural otimizada na frequência de 497 Hz .....	87
6.5 Consolidação das configurações .....	89
<b>CAPÍTULO VII - AVALIAÇÃO DA RESPOSTA VIRTUAL .....</b>	<b>90</b>
7.1 Introdução .....	90
7.2 Estimativa na vizinhança do ponto virtual .....	90
7.2.1 Respostas obtidas por interpolação na frequência de 250 Hz .....	92
7.2.2 Respostas obtidas por interpolação na frequência de 497 Hz .....	96
7.3 Resposta virtual em função de perturbações e descaracterização do ambiente ....	99
7.4 Estimativa a partir do ruído branco .....	103
<b>CAPÍTULO VIII - CONCLUSÕES E PERSPECTIVAS FUTURAS .....</b>	<b>106</b>
8.1 Conclusões .....	106
8.2 Sugestões para trabalhos futuros .....	108
<b>REFERENCIAS BIBLIOGRÁFICAS .....</b>	<b>110</b>
<b>APENDICE A .....</b>	<b>117</b>
<b>APENDICE B .....</b>	<b>119</b>

# CAPÍTULO I

## INTRODUÇÃO

### 1.1 Contextualização do trabalho de pesquisa

Cada vez mais, a geração de ruído torna-se um problema evidente para as pessoas nos centros urbanos pela enorme quantidade de equipamentos que as rodeiam, tais como: veículos, eletroeletrônicos, maquinários, construções e outros fatores associados resultantes do consumo de bens e do crescimento populacional. Paralelamente a isso, as restrições de custo em moradias como uma tendência na utilização de materiais mais leves, intensificam os problemas de transmissão sonora para o interior das residências. Cita-se como exemplo, uma máquina de lavar roupas que impacta diretamente o proprietário que usufrui do benefício do produto (roupas limpas), mas também perturba outras pessoas que não se beneficiam daquele resultado (ruído propagado). De forma geral, o som de aeronaves, dos veículos trafegando nas ruas, festas comemorativas, plantas industriais e outros, impactam acusticamente não somente os beneficiários destes, mas toda uma comunidade ao redor.

O fato é que a cada dia, as pessoas ficam expostas a diversos níveis de ruídos que além de desconfortáveis causam prejuízos à saúde, principalmente se ocorrem em altos níveis. O impacto destes ruídos nas pessoas ainda não são totalmente conhecidos, sendo incertos os impactos efetivos ao sistema nervoso e fisiológico. Mas são bem conhecidos os danos provocados ao sistema auditivo. Neste contexto, diversos estudos realizados por pesquisadores relativos à Perda Auditiva Induzida pelo Ruído (PAIR) evidenciam os danos nos trabalhadores em vários setores industriais. Nas indústrias têxteis brasileiras, Caldart *et al.* (2006) verificaram a PAIR decorrente dos níveis de ruído usualmente encontrados nos vários estágios do processo industrial, variando de 90 a 106 dB (A), níveis suficientemente altos para provocar perda auditiva permanente.

Para atuar efetivamente e assim abrandar os níveis sonoros, uma clara compreensão dos mecanismos de geração e transmissão acústica, tornam-se essenciais para o projeto de sistemas de controle, como também para o projeto de máquinas e equipamentos silenciosos. É natural pensar que ao invés de bloquear ou absorver as

emissões acústicas, o melhor seria não gerar o ruído, ou minimizá-lo na geração, sendo esta uma frente de atuação em uso.

Bistafa (2006) enfatiza que o controle do ruído atua em três frentes bem definidas: controle na fonte, controle na trajetória e controle no receptor. Tipicamente para este último tem-se os Equipamentos de Proteção Individual agindo diretamente nos ouvidos das pessoas.

Fazer o controle na fonte pode significar melhoramento das técnicas de manutenção, alteração do projeto dos equipamentos ou mesmo substituição de elementos, mas não evitam o aparecimento de ruídos com o tempo devido ao uso e desgaste.

Realizar o controle na trajetória de transmissão é o mais usual, com soluções do tipo enclausuramento da fonte, silenciadores de descarga, barreiras acústicas ou absorção sonora. Todavia, em alguns setores da indústria a utilização das técnicas passivas torna-se impraticável, a exemplo de galpões com pés direitos altos uma vez que o controle da temperatura e umidade são cruciais para a eficiência operacional em muitos processos, em outros casos por limitações de *layout* ou principalmente pela necessidade do livre acesso e circulação das equipes de trabalho. Outro problema destes tratamentos é que não se aplicam a todas as faixas de frequências, sendo relativamente volumosos, caros e ineficazes em baixas frequências (KUO *et al.*; 1999). Assim, novas estratégias devem ser pesquisadas e desenvolvidas.

Ainda sobre a mitigação de ruído, justificam-se os investimentos no desenvolvimento de sistemas silenciosos conjugados aos equipamentos, tais como: motores, caixas de redução, ventiladores e outros. Evitando assim futuras soluções paliativas com acréscimo de peso, alteração no tamanho dos produtos ou até mesmo, provocando deficiência na refrigeração em alguns casos. Nos produtos de primeira linha, a exemplo dos eletrodomésticos, veículos e aeronaves, os custos de desenvolvimento e pesquisa são diluídos na produção em massa destes. Mas outras demandas na aplicação de controle de ruído são igualmente prioritárias e vem ganhando importância, como soluções para comunidades residenciais e edifícios.

Uma abordagem atraente é o controle ativo de ruído (CAR) para redução do nível sonoro nas baixas frequências. A ideia básica do CAR é gerar uma onda de igual amplitude mas com fase oposta ao ruído não desejado e que provoque o cancelamento do sinal ruidoso num determinado ponto ou região de interesse (HANSEN; 1997 apud CÁRDENAS; 2005). Na prática, tem-se a dificuldade em achar o posicionamento ótimo para os sensores, devido a enorme quantidade de combinações possíveis dadas algumas posições candidatas e ainda, devido a fatores de alterações ambientais, propagação tridimensional, variação da condição operacional do equipamento e por influencia de outras fontes.

Outro inconveniente do CAR é que os sensores devem ser colocados nas proximidades dos locais onde se quer reduzir o ruído. Pode ser bastante inconveniente ter que colocar um sensor no centro de uma sala ou dentro dos ouvidos dos observadores. Então, o desafio passa a ser o cancelamento sonoro nos pontos de destino, sem realmente colocar os sensores físicos naqueles locais. Um método recente que tem sido investigado é a detecção virtual a partir de sensores físicos que ficam localizados a certa distância do objetivo de controle, sendo esta, a principal motivação para o trabalho.

## 1.2 Objetivos

A técnica de detecção virtual consiste em colocar os sensores físicos nos locais possíveis e a partir destes, os sinais serão processados e deverão ser equivalentes aos sinais obtidos em ponto remoto ou virtual do local desejado. Tais técnicas podem proporcionar melhorias sobre o CAR tradicional por permitir colocar estes sensores em locais fisicamente impraticáveis, como exemplo, no ouvido das pessoas.

Dentro do contexto apresentado, o trabalho de pesquisa que constitui o objeto desta tese de doutorado tem por objetivo geral, o estudo experimental para desenvolvimento de sensores virtuais aplicados em campo fechado e que estejam localizados próximo da fonte sonora, visando aplicações futuras em controle ativo de ruído.

Os objetivos específicos estabelecidos são os seguintes:

- Caracterizar uma fonte sonora com base no sinal vibro-acústico;
- Identificar e caracterizar a transmissão de um sinal harmônico entre o ponto de geração e o de medição por um sensor físico;
- Avaliar os fatores que afetam a propagação sonora em uma sala reverberante;
- Correlacionar a resposta do sensor físico com um sensor virtual, utilizando redes neurais;
- Verificar a acuidade das respostas físicas e virtuais, especialmente na resposta de fase;
- Avaliar limites do posicionamento virtual em relação aos sensores físicos;
- Avaliar a aplicabilidade da técnica, especificamente na estimativa obtida a partir de um conjunto de sensores virtuais e
- Avaliar os limites da estimativa quando ocorre descaracterização do ambiente.

### **1.3 Organização do trabalho**

Além deste capítulo introdutório, este memorial de tese é constituído dos seguintes capítulos:

Capítulo II, onde se apresenta a revisão bibliográfica sobre o controle ativo de ruído e os aspectos específicos sobre sensores virtuais em acústica.

O capítulo III reúne os princípios e as bases fundamentais das redes neurais, suas principais características e limitações. Ilustram-se ainda algumas aplicações na solução de problemas.

No capítulo IV, apresentam-se os fundamentos básicos da acústica de salas para que se tenha uma noção da propagação sonora e da complexa iteração que ocorre entre os sinais gerados e refletidos.

No Capítulo V é realizado um estudo dos fatores que influenciam de forma relevante a acústica da sala, já que o campo acústico é afetado pelos materiais e pelos obstáculos presentes no recinto. O conhecimento dos fatores críticos irá permitir gerar sinais com características relevantes do ambiente para o treinamento de uma rede neural.

No Capítulo VI são projetadas e avaliadas as arquiteturas, a configuração e o desempenho de redes neurais aplicadas à estimativa do sinal acústico. Resultados e discussões são também apresentados no decorrer do capítulo. Após definido a arquitetura da rede neural, são apresentados estudos para uma re-amostragem do sinal. Também é apontado a quantidade de sensores de referência, a qualidade do sinal estimado em função do posicionamento do sensor e a otimização dos parâmetros de configuração.

O Capítulo VII apresenta a consolidação dos estudos realizados. Verifica-se a estimativa de um conjunto de sensores virtuais, mostrando a capacidade de previsão em uma faixa de posicionamentos. As respostas obtidas conforme algumas alterações da característica reverberante da sala e a estimativa de um sinal harmônico a partir de uma rede treinada utilizando ruído branco.

Por fim, apresentam-se as conclusões e as sugestões de trabalhos futuros no capítulo VIII.

## CAPÍTULO II

### REVISÃO BIBLIOGRÁFICA

#### 2.1 Introdução ao controle ativo de ruído

Fundamentalmente, um sistema de controle ativo de ruído (CAR) utiliza o princípio da interferência e da superposição para gerar ondas sonoras que irão atenuar uma fonte de ruído indesejada. O efeito resultante da combinação de ondas superpostas ou interferentes é a intensificação ou atenuação do campo sonoro, respectivamente. Portanto, o conceito da atenuação ativa do som é gerar uma onda de igual amplitude mas com fase oposta ao ruído não desejado e que provoque o cancelamento do sinal ruidoso num determinado ponto ou região de interesse (HANSEN, 1997 apud CÁRDENAS, 2005).

O sistema descrito e utilizado para o cancelamento ativo de ruído em mono canal, pode ser visualizado na figura 2.1 e consiste basicamente de:

- a) Microfone de referência do ruído a ser cancelado;
- b) Sistema de controle ativo para processar o sinal de referência e gerar o sinal de controle (onda defasada);
- c) Alto-falante excitado pelo sinal de controle para gerar o cancelamento do ruído;
- d) Microfone de erro para fornecer ao controlador a informação resultante da atenuação, possibilitando ajustes adaptativos e para minimizar o campo sonoro remanescente.

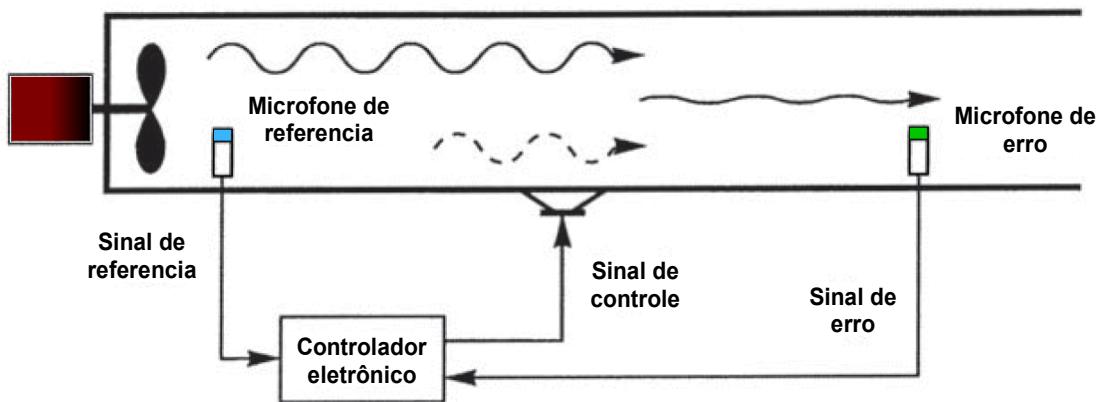


Figura 2.1 – Sistema básico do controle ativo de ruído (adaptado de HANSEN, 2001).

O conceito do cancelamento de ruído foi introduzido por Lueg em 1936, porém a pesquisa e o desenvolvimento do CAR nos dias atuais, tem ocorrido basicamente no sistema de processamento do sinal de referência e na geração do sinal de controle. Ocorre que inicialmente havia o problema de *hardware*, pois os equipamentos eram analógicos, do tipo amplificadores, ou eram dispositivos com baixa capacidade de memória e de processamento. Atualmente esta questão foi resolvida, pois há uma grande disponibilidade de dispositivos digitais, com capacidade de processamento, memória e de protocolos de comunicação a preços razoáveis. O problema que ainda persiste é o aprimoramento das estratégias de controle, desempenho dos sistemas e aplicações para o controle ativo de ruído (KUO *et al.*, 1999), (DELFINO, 2005), (MIRANDA, 2013).

Miranda (2013), referencia que umas das primeiras aplicações do CAR foi o controle de ruído em transformadores elétricos da *General Electric* em 1957 e que durante a década de 70, foram iniciados estudos de controle ativo em dutos, os quais apresentavam grandes desafios devido aos problemas de realimentação acústica e das reflexões que contaminavam o microfone de referência, levando o sistema à instabilidade ou baixa atenuação em algumas bandas de frequências. Nos dutos, as características variantes na fonte e do ambiente, indicavam que o sistema de controle deveria ser adaptativo, assim o próprio sistema compensaria as mudanças nas características da planta.

Foram propostos os controladores automaticamente adaptáveis baseados nas estratégias de filtragem com capacidade de ajuste de seus coeficientes, conhecidos como filtragem FIR e IIR. Os filtros FIR (*Finite Impulse Response*) são filtros estáveis, pois não apresentam polos em sua equação característica, entretanto para modelar um sistema acústico, necessitam de um grande número de coeficientes e de capacidade de processamento. Os filtros IIR (*Infinite Impulse Response*) possuem polos e zeros na

equação característica, normalmente com pequeno número de coeficientes e podem apresentar instabilidade durante o processo de adaptação. (BURGESS, 1981), (GOODWIN *et al.*, 1984), (CLARKSON, 1993). As arquiteturas dos filtros FIR e IIR estão ilustradas a seguir na Fig. 2.2.

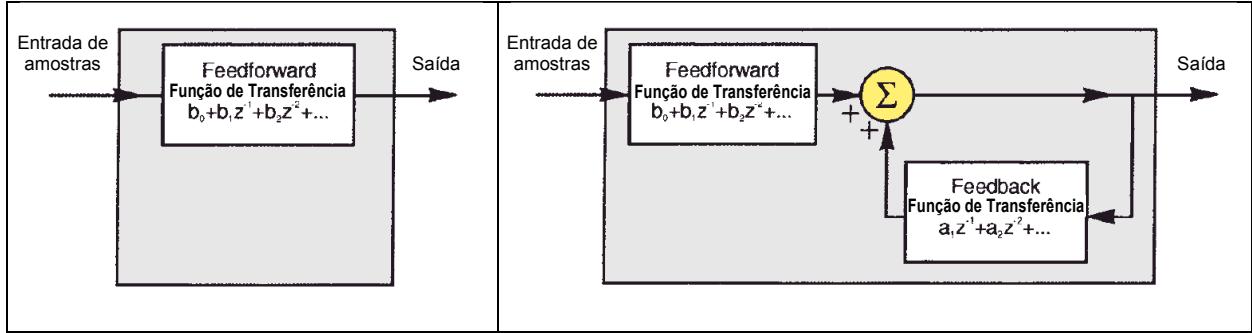


Figura 2.2 – Arquitetura dos filtros FIR e IIR respectivamente (adaptado de HANSEN, 2001).

Na Universidade Federal de Uberlândia algumas propostas têm sido desenvolvidas e avaliadas. Citamos o trabalho de Cárdenas (2005) que avaliou algumas metodologias de controle utilizando algoritmos adaptativos do tipo LMS (*Least Mean Square*) e técnicas de filtragem X-LMS para o controle ativo de ruído em dutos, apresentando ainda uma abordagem numérica e experimental para o problema. Nesta mesma linha de pesquisa, Delfino (2005) avalia estratégias de malha aberta (*feedforward*), malha fechada (*feedback*) e um sistema híbrido que utiliza os dois conceitos. Problemas relativos ao caminho secundário e de realimentação também foram apresentados e discutidos.

Nunes (2009) e Oliveira (2012) propuseram e aplicaram uma metodologia para utilização de CAR em dutos com grandes seções transversais para eliminar o problema de ondas acústicas de alta ordem. A técnica consiste em particionar o duto em subestruturas resultando então na propagação de ondas planas. Através da otimização de modelo acústico foi possível determinar a posição de sensores e atuadores para maximizar a atenuação na frequência de projeto. Já Miranda (2013) abordou a questão do controle tonal em dutos, investigando a otimização de sensores e atuadores com o intuito de ampliar a faixa de frequência de atenuação quando aplicado o controle ativo de ruído monocanal.

Além das aplicações em transformadores e dutos, uma outra forma de tentar controle de ruído é utilizar o Controle Acústico em Estruturas Ativas (CAEA) sendo uma combinação de controle ativo de ruído com controle ativo de vibrações. Este método de controle tem sido pesquisado e desenvolvido por um grande número de autores. O desenvolvimento do CAEA iniciou-se com o trabalho de Fuller e Jones (1987) no qual foi verificado que o campo acústico do interior de uma aeronave está diretamente acoplado com a vibração estrutural

da fuselagem. Assim, o controle sonoro no interior da cabine poderia ser obtido controlando a vibração da fuselagem. Esta ideia foi testada em um cilindro de alumínio com extremidades fechadas representando uma fuselagem simples. O ruído no interior foi simulado utilizando uma fonte pontual e o controle fornecido por um atuador. Experimentos produziram uma atenuação global de 10 a 20 dB no interior. Este ótimo resultado foi obtido porque somente um modo estrutural estava acoplado, assim somente uma fonte de controle foi requerida. Os autores concluíram que para todo modo estrutural bem acoplado com um modo acústico seria necessário uma fonte de controle independente. Portanto, esta técnica é efetiva somente para campos sonoros com baixa densidade modal.

Fuller *et al.* (1991) formularam analiticamente e experimentalmente a utilização da aplicação de forças externas em uma estrutura para a atenuação global do ruído. Foram utilizados atuadores eletromagnéticos, porém estes equipamentos não eram viáveis para estruturas leves. A utilização de materiais piezelétricos foi então introduzida como uma alternativa aos atuadores eletrodinâmicos. Diversos estudos têm demonstrado que tais materiais são bastante adequados e eficientes, oferecendo a possibilidade de ser utilizados em sistemas com geometrias complexas, uma vez que podem ser colados diretamente à superfície da estrutura, ou então inseridos no volume do material que constitui a estrutura, tornando-se parte do sistema. Outra vantagem dos materiais piezelétricos é que estes podem ser utilizados tanto como sensores quanto como atuadores, apresentando inclusive relativa insensibilidade à temperatura, o que os habilita a trabalhar mesmo em condições ambientais mais severas (SANTANA, 2002).

Santana (2002) desenvolveu um estudo sobre a utilização de atuadores piezelétricos sobre placas finas retangulares para o controle ativo de ruído. Neste trabalho, constatou-se que o posicionamento dos atuadores é determinante para a eficiência do controle ativo de ruído e a potência radiada no campo será maior quanto maior for o número de atuadores na placa.

Nishida (2012) propôs a utilização de estruturas inteligentes para o controle de ruído em duto com propagação de modos de alta ordem, utilizando o particionamento do duto a fim de planificar as ondas que se propagam. Na região particionada, foi possível realizar o controle ativo de ruído utilizando sensores e atuadores em cada lado da partição. A proposta é controlar a vibração da placa particionadora, para que possa atuar como uma fonte de controle para redução do nível global.

Maciel (2014) propõe o controle ativo de ruído em venezianas acústicas para a atenuação nas baixas frequências. Trata-se de um procedimento de modelagem da perda por transmissão utilizando materiais inteligentes nas lâminas das venezianas. São empregados métodos analíticos, numéricos e procedimentos de otimização.

Outros estudos também têm sido realizados e aplicados, a exemplo do campo próximo da fonte de ruído, no campo afastado e no campo livre. Nestes ambientes, objetivando a redução do nível acústico, foi proposto um sistema denominado ECAS (*Electronically Controlled Acoustic Shadows*), capaz de produzir zonas de cancelamento ou sombras acústicas, como ilustrado na Fig. 2.3. Este problema em geral é resolvido por meio de redes neurais artificiais ou pelo uso de um algoritmo genético. (WRIGHT e VUCKSANOVISCK, 1996, 1997, 1999, 2001) e (WRIGHT e ATMOKO, 2001).

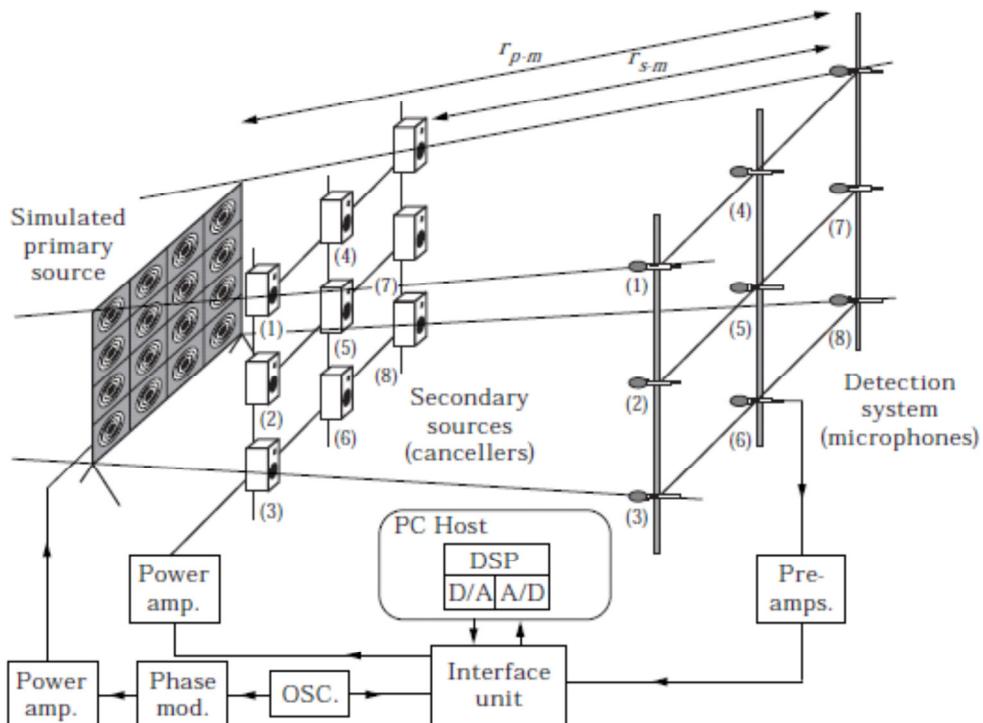


Figura 2.3 – Controle de sombra acústica em campo próximo, sistema ECAS apresentado por Wright e Vucksanovisck (1999).

Basicamente as estratégias de controle ativo de ruído abordam a atenuação em nível global ou local, apresentando respectivas vantagens e limitações. Se a região de cancelamento estender por uma grande área, a abordagem do controle ativo é dito global. Neste caso os microfones de erro devem ser posicionados próximos da fonte primária, pois quando situados no campo distante da fonte, causam instabilidade e problemas de convergência do algoritmo de controle. (GARCIA *et al.*, 2006). Assim, para um cancelamento efetivo nas regiões distantes da fonte de ruído, o posicionamento das fontes secundárias e dos microfones de erro é de suma importância. Neste aspecto um grande problema que surge na acústica de campo é a localização dos microfones que podem se tornar um obstáculo, a exemplo de um *layout* fabril. Se a estratégia de controle for local, a

eficiência da atenuação é fortemente dependente da posição do microfone de erro. Um exemplo é o controle de ruído no encosto de cabeça de carros e aviões. Para obter a máxima atenuação do sistema o microfone teria que ficar no ouvido das pessoas, sendo este um grande problema para a abordagem local.

Em geral, à medida que se investigam novas aplicações surgem dificuldades e novos desafios, mas o fato é que o controle ativo de ruído em baixa frequência tem sido bastante pesquisado e utilizado principalmente em aplicações industriais, residenciais, automotivas e em aeronaves. Neste sentido justifica-se o desenvolvimento de novas tecnologias a exemplo do microfone virtual proposto neste trabalho para que possam efetivamente substituir o microfone de erro quando houver dificuldade ou interferências na instalação física.

## 2.2 Atenuação de ruído em nível global

Para o controle ativo em nível global, tem-se como alvo a redução de ruído no recinto como um todo. A redução é obtida focando na minimização de uma grandeza acústica, a exemplo da energia potencial, ou mesmo, minimizando a soma dos quadrados das pressões sonoras. Nesta abordagem, utiliza-se um grande número de microfones de erro e de fontes secundárias espalhados no ambiente. Normalmente são utilizadas técnicas de otimização para o projeto objetivando minimizar o campo acústico. A estratégia de controle ativo global pode ser alcançada com sucesso focando as ressonâncias dominantes do recinto que contribuem para energia acústica, em uma região de baixa densidade modal (NELSON *et al.*, 1987a), (BULLMORE *et al.*, 1987), (ELLIOTT *et al.*, 1987). No entanto, quando o espectro possui um grande número de modos, o controle global é menos eficaz, tornando a redução de ruído cara e difícil de perceber (THOMAS *et al.*, 1993).

Bullmore *et al.* (1987) investigaram o efeito da localização dos sensores de erro em ambientes fechados. Ondas estacionárias no campo reverberante promovem regiões de máxima e mínima pressão acústica, o que significa dizer, que há regiões de ressonância e nós acústicos que não se alteram com o tempo se também não houver alterações físicas no ambiente. Se o sensor ou fonte estiver posicionado em uma região de mínimo, não se perceberá sinal de resposta ou o modo não poderá ser excitado.

Encontrar o ponto de posicionamento para o controle ótimo de sensores e fontes é um processo complexo. Para aplicações onde são necessárias várias fontes de controle, os locais ideais podem ser determinados por um procedimento numérico envolvendo elementos finitos e processos de otimização, como os algoritmos genéticos. A análise com elementos finitos é usada para calcular as características modais do sistema, sob o campo sonoro das

fontes primárias e de controle. A melhor configuração das fontes de controle pode ser determinada utilizando procedimentos de busca tal como algoritmo genético, como descrito por Simpson e Hansen (1996).

Os procedimentos de otimização aplicam-se estritamente apenas a uma única frequência. Cada frequência de interesse será caracterizada pela localização de uma fonte de controle e do seu sensor correspondente. Se apenas um ou poucos tons serão controlados (ou se as faixas de frequências são de banda estreita), os locais ideais são calculados para cada frequência tonal, sendo possível uma solução para obter a redução global de ruído. No entanto, se o ruído a ser controlado é de banda larga, torna-se impraticável a técnica de otimização para estabelecer os locais de posicionamento das fontes de controle. Alternativamente, pode ser dividir o intervalo de frequências de interesse em um número de faixas estreitas para determinar os locais de origem ideais para cada banda. Assim, na prática, somente algumas partes do espectro de frequências será controlada para aquela determinada configuração da fonte de controle. Um exemplo é o controle de ruído em duto. Se uma única fonte de controle é utilizada, haverá frequências em que não se poderá alcançar um controle significativo. Nestes casos, uma segunda fonte de controle é indicada (SIMPSON e HANSEN, 1996).

Hansen (2001), com base no trabalho de Nelson *et al.* (1987b), comenta que geralmente é mais difícil obter níveis significativos de atenuação global em espaço livre do que em um espaço fechado. O fato é que o controle ativo global é mais suscetível em campos ressonantes com baixa densidade modal. Para reproduzir a radiação acústica indesejada no espaço livre geralmente requer que as fontes de controle (geralmente alto-falantes) sejam colocados nas proximidades da fonte de ruído. Se a origem do ruído indesejado for um monopolo simples, a fonte de controle deverá ser um segundo monopolo. Para atingir uma redução de 10 dB na energia irradiada, as duas fontes devem ser estar distanciadas a menos de um décimo do comprimento de onda na frequência de interesse. Essa restrição é claramente ilustrada na figura 2.4, que demonstra a atenuação em função da distância  $r$ , entre duas fontes. No entanto, em aplicações práticas, esta condição para a separação máxima entre fontes nem sempre podem ser satisfeitas.

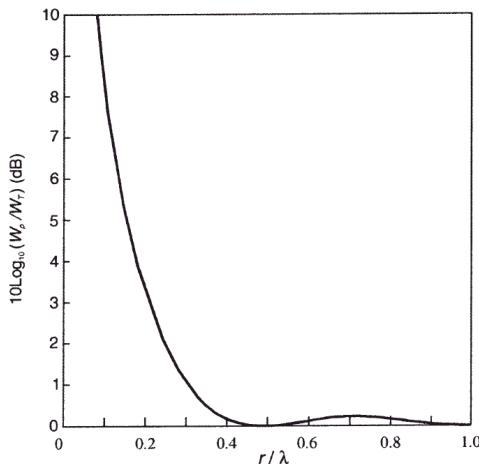


Figura 2.4 – Máxima atenuação obtida na potencia sonora utilizando duas fontes pontuais (HANSEN; 2001).

Guo *et al.* (2002) estudaram o desempenho de um controle ativo global e localizado dentro de salas. O trabalho analisou o efeito do controle com base na localização da fonte primária, considerando o amortecimento da sala e verificando a influencia deste na eficiência obtida. Foi verificado que a localização da fonte primária tem grande influencia no nível global e que a distancia entre o controle e a fonte tem que ser menor do que a metade do comprimento de onda para poder obter o efeito global. Verificaram também que aumentando a quantidade de amortecimento na sala houve uma redução do nível de atenuação obtido.

Devido as dificuldades em obter uma redução global, uma alternativa para efetivar o controle ativo seria gerar uma atenuação localizada. A seguir serão apresentadas as características desta abordagem.

### 2.3 Atenuação de ruído em nível local

O objetivo de muitos sistemas práticos tem sido reduzir o ruído apenas em determinadas localidades, obtidas normalmente em torno dos "sensores de erro". Neste tipo de abordagem, o controle ativo local cria uma "zona de silêncio" requerendo um menor número de fontes secundárias em relação ao controle ativo global. Vários algoritmos de controle ativo, com filtros adaptativos ou não, podem ser utilizados para minimizar a energia do sinal nos sensores de erro, de modo a criar a zona silenciosa. Assim, o desempenho para o controle local é limitado devido à natureza localizada da zona de silêncio. Elliott *et al.* (1988) estudaram o cancelamento ativo da pressão sonora utilizando uma fonte secundária

em um campo difuso tonal. Foi verificado que em média, a forma da zona de silencio, com 10 dB de redução da pressão sonora era uma esfera em torno do ponto de cancelamento cujo diâmetro era de apenas um décimo do comprimento da onda acústica. Isso mostra que o controle local é uma forma eficiente somente para baixas frequências, e estender a região de redução do ruído é algo bastante limitado, já que a ação do controle ativo local pode inclusive aumentar o ruído fora da zona de controle.

Garcia-Bonito *et al.* (1997a) investigaram a zona de silencio na presença de superfícies refletoras e concluíram que a zona de atenuação de 10 dB era maior na presença destas superfícies refletoras em comparação com as zonas obtidas sem a presença destas.

O desempenho do controle local foi analisado em salas com baixo e também com elevados coeficientes de amortecimento. Nestes ambientes foi verificado que o tamanho da zona de silencio era dependente do nível de amortecimento da sala em ambientes não difusos. Salas com baixo amortecimento, com coeficientes de absorção médio em torno de 0.06, a zona de silêncio era aproximadamente um décimo do comprimento de onda. Entretanto a medida que o amortecimento aumenta (média de absorção de 0,30) a zona de silencio ficava em um sétimo do comprimento de onda (GUO *et al.*, 2002).

A estratégia de controle local na geração de uma zona de silencio em torno do sensor de erro se mostra bastante interessante para ser aplicado em espaços fechados a exemplo de carros, aviões e trens, onde o controle ativo pode ser feito no encosto de cabeça dos bancos. A grande desvantagem é a necessidade de posicionar o sensor de erro no local em que se quer atenuar para maximizar a eficiência. Para contornar esta dificuldade foi proposto a substituição do microfone físico por um microfone virtual que possa estimar o campo sonoro no local desejado e efetivar o CAR.

## 2.4 Microfone Virtual

Sensores reais são amplamente utilizados em comunicações, em controle e em processos, para medir e monitorar fenômenos físicos, como temperatura, umidade, pressão, velocidade, emissões, etc. Sensores reais muitas vezes tomam as medidas diretamente do fenômeno observado e as convertem em dados para um processamento adicional. São geralmente caros, precisam de manutenção e além disso, quando há sistemas de controle dependentes dos sensores reais, uma falha em um sensor pode tornar tais sistemas de controle inoperantes. Ao invés das medições diretas, sensores virtuais têm sido

desenvolvidos para processamento de dados e para a estimação de valores que foram previamente medidos por sensores físicos (LIU *et al.*, 2009).

Um sensor é portanto, um dispositivo que mede uma quantidade física e a converte em uma grandeza que pode ser lida diretamente por um observador ou através de uma instrumentação. Por exemplo, um microfone converte a pressão acústica medida em um sinal elétrico que pode ser lido remotamente em um dispositivo de apresentação. Os sensores podem ser separados em duas categorias: sensores físicos ou reais e sensores virtuais, onde, os sensores reais muitas vezes tomam a medição diretamente do fenômeno físico e devem ser instalados no local de medição. Já os sensores virtuais, também conhecidos como sensores suaves, sensores inteligentes ou estimadores são utilizados para estimar as leituras dos sensores físicos reais e calculam as saídas mediante algum algoritmo de processamento para a apresentação (WILSON, 1997).

Sensores físicos e o hardware associado a estes são muitas vezes dispendiosos e por vezes, pouco confiáveis devido a necessidade de manutenção (ou mesmos por deteriorações provocadas pelo meio, calibrações necessárias, etc). Além disso, sensores físicos muitas vezes fornecem dados de sensoriamento em locais fixos e não podem ser implantados em qualquer posição. Frequentemente ficam longe do local ideal a ser detectado. Por estas razões ou por outras necessidades, ocorre o desenvolvimento de sensores virtuais, sendo geralmente utilizados para:

- 1) Substituir um sensor instalado temporariamente;
- 2) Fornecer continuamente saídas com base em medições periódicas dos sensores físicos;
- 3) Prever com antecedência os dados de sensoriamento de um sistema permitindo o controle preditivo e
- 4) Fornecer robustez física na possibilidade de falha ou manutenção.

No entanto, sensores virtuais precisam de modelos de sistemas ou de funções de transferência para processar o fluxo de dados a partir de sensores reais. Por conseguinte, o modelo escolhido é um fator crítico para a exatidão da resposta (WILSON, 1997).

Vários algoritmos de detecção virtual têm sido pesquisados nos últimos anos. O método do microfone virtual proposto por Elliott e David (1992), foi utilizado para prever a pressão sonora a certa distância de um microfone supondo um campo sonoro primário em que as pressões sonoras foram as mesmas dos microfones físicos e virtuais.

Roure e Albarrazin (1999) utilizaram o conceito da técnica de microfone remoto utilizando um conjunto de funções de transferência sem a necessidade de pressupor o campo sonoro para os microfones físicos e virtuais.

Garcia e Elliott (1999) apresentaram um conceito de microfone virtual baseado na superposição do campo reverberante das posições físicas atuais e virtuais do microfone. A posição virtual é estimada quando a cabeça do observador estiver presente, pois esta se localiza num ponto sobre o eixo perpendicular à fonte secundaria mais afastada e mais próxima do ouvido. Este arranjo permite a projeção da zona silenciosa em função da posição real, melhorando o desempenho do sistema a exemplo da figura 2.5.

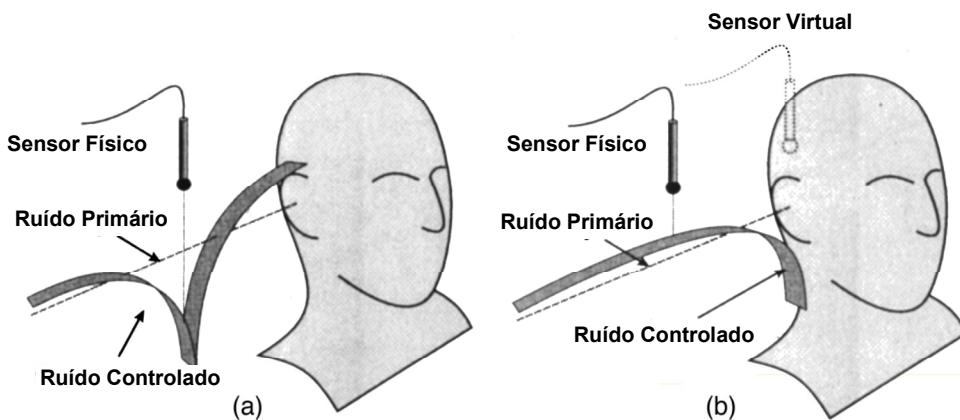


Figura 2.5 – (a) Menor nível de pressão acústica obtido na posição do sensor físico. (b) Menor nível de pressão acústica obtido na posição do sensor remoto, virtualmente posicionado na cabeça (ou no ouvido) do receptor (KESTELL *et al.*, 2001).

Cazzolato (1999) propôs a técnica de previsão futura com base em uma extrapolação polinomial dos sinais acústicos. Estes sinais são observados em um arranjo de microfones que não necessitam a priori da identificação do sistema acústico. Este método foi mais tarde estendido utilizando o algoritmo LMS (*Least Mean Square*) ou mínimos quadrados no qual o algoritmo de adaptação foi usado para obter os pesos ideais para a extrapolação. (MUNN *et al.*, 2002), (CAZZOLATO, 2002).

Hansen (2001) ressalva algumas estratégias utilizadas para a configuração de microfones virtuais: A primeira é baseada na determinação da função de transferência da pressão acústica medida entre um microfone permanentemente localizado e um microfone temporariamente localizado na posição do observador. Retirado o microfone remoto, o sinal do microfone permanente é alterado pela função de transferência criada para estabelecer a posição virtual. Uma segunda possibilidade é estimar a pressão acústica da posição virtual em tempo real, utilizando a extrapolação do sinal a partir de um arranjo de microfones

remotamente posicionados, conforme ilustra a Fig. 2.6. Esta configuração tem a vantagem de não necessitar de uma função de transferência.

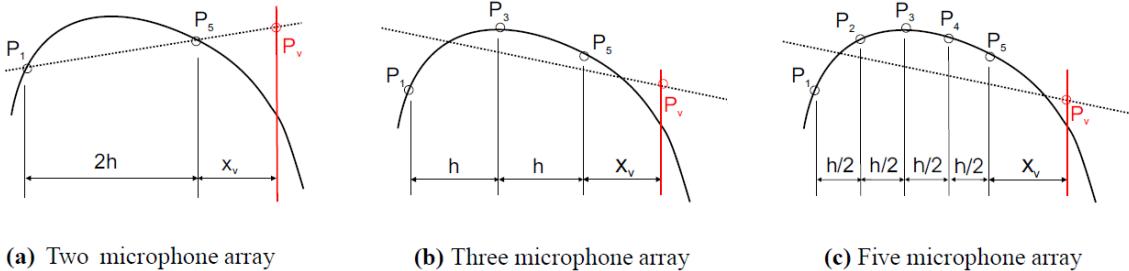


Figura 2.6 – Princípio da extração à frente, utilizando uma estimativa linear (reta) (MUNN *et al.*, 2002).

Masiero *et al.* (2007) apresentaram a metodologia para o uso dos sensores virtuais que utilizam o conhecimento da função de transferência entre as fontes de controle e os sensores reais e virtuais para gerar um sinal de excitação para as fontes de controle.

Petersen *et al.* (2006, 2007) investigaram a movimentação do sensor virtual utilizando um sistema de controle ativo de ruído localizado. Foi então capaz de criar uma zona silenciosa que se movimenta acompanhando a posição do observador.

Moreau *et al.* (2008b) estudaram a performance de um sistema de microfone virtual que acompanha o movimento de rotação da cabeça em um campo tridimensional. Como resultado houve uma melhoria na atenuação comparada com aquela que utiliza o microfone virtual em uma posição estática. Com base na estimativa de estado ideal, Petersen *et al.* (2008) utilizou um filtro de Kalman para projetar um sensor virtual aplicado ao controle ativo de ruído. Houve também o trabalho de sensoriamento virtual para campo sonoro difuso. (MOREAU *et al.*, 2009).

Nos trabalhos relatados, normalmente as técnicas desenvolvidas e aplicadas para os microfones virtuais são lineares, tais como: LMS adaptativo, técnicas de extração, filtragem Kalman e o campo difuso tonal estocástico. Quando existem não linearidades, como por exemplo, turbulência que pode ocorrer devido ao fluxo de ar, estas técnicas não conseguem adaptar-se e portanto, não é obtido o resultado desejado. Neste sentido, o controle ativo de ruído com presença de não linearidades também tem sido um importante tópico de pesquisa nos últimos anos. Das *et al.* (2010, 2013) apresentaram aplicações do algoritmo não linear FSLMS (*Filtered-S Least Mean Square*) para o microfone virtual. Alguns dos algoritmos não-lineares normalmente utilizados em controle ativo são o FXLMS

(*Filtered-X Least Mean Square*), FSLMS e NARX (*Nonlinear autoregressive exogenous model*).

Consolidando todas as informações em um contexto amplo, pode-se dizer que o microfone virtual situa-se atualmente como uma técnica em desenvolvimento. Percebe-se ainda com base nesta revisão bibliográfica que os estudos publicados estão focados principalmente: na apresentação de técnicas de estimação do campo acústico, na geração de algoritmos de controle aplicados aos sensores virtuais, em técnicas que promovem deslocamentos dos sensores virtuais conforme a movimentação do receptor realizado em tempo real, na verificação da acuidade das respostas de fase e de sensibilidade, no estabelecimento de funções de custo para os sistemas de controle dos sensores virtuais e na estimação de sinais acústicos não lineares. Percebe-se ainda que nos estudos comentados, normalmente foram utilizados arranjos de microfones reais em que o posicionamento do sensor virtual ficava pouco a frente dos sensores físicos. (GARCIA-BONITO *et al.*, 1997b), (KESTELL *et al.*, 2001), (MOREAU, 2007, 2008a).

Como vantagens, o desenvolvimento de técnicas virtuais apresentam: uma melhor eficiência na atenuação sonora, quando comparado com o microfone real (MOREAU, 2008b), ver a figura 2.5 como exemplo. Possibilita ainda o deslocamento de sua localização de forma a acompanhar pequenos movimentos do receptor, girar a cabeça como exemplo, de maneira a manter a eficiência na atenuação sonora. (PETERSEN *et al.*, 2006, 2007), (MOREAU *et al.*, 2008b).

# CAPÍTULO III

## REDES NEURAIS

### 3.1 Introdução

Redes Neurais Artificiais (RNA) são algoritmos de processamento de dados inspirados na estrutura do cérebro humano, cuja base unitária é o neurônio. O neurônio é um processador simples e independente, com mecanismo de comunicação via conexões ponderadas chamadas sinapses. No cérebro, as células piramidais como ilustrado na Fig. 3.1(a) são as mais comuns, com ramais na forma de espinhas ou dendritos onde a maioria dos estímulos é recebida. Já o corpo do neurônio é responsável por coletar e combinar informações e nas extremidades do axônio, o sinal é transportado e enviado. O neurônio que recebe um estímulo pode excitá-lo ou inibi-lo, mas não provocam os dois efeitos ao mesmo tempo. Estas células são capazes de receber milhares de conexões sinápticas e podem se projetar sobre outros milhares de células-alvo. Toda esta estrutura, conectada, possibilita uma fabulosa capacidade de processamento e armazenamento de informação. Estima-se que haja aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de conexões entre os mesmos (HAYKIN, 2001).

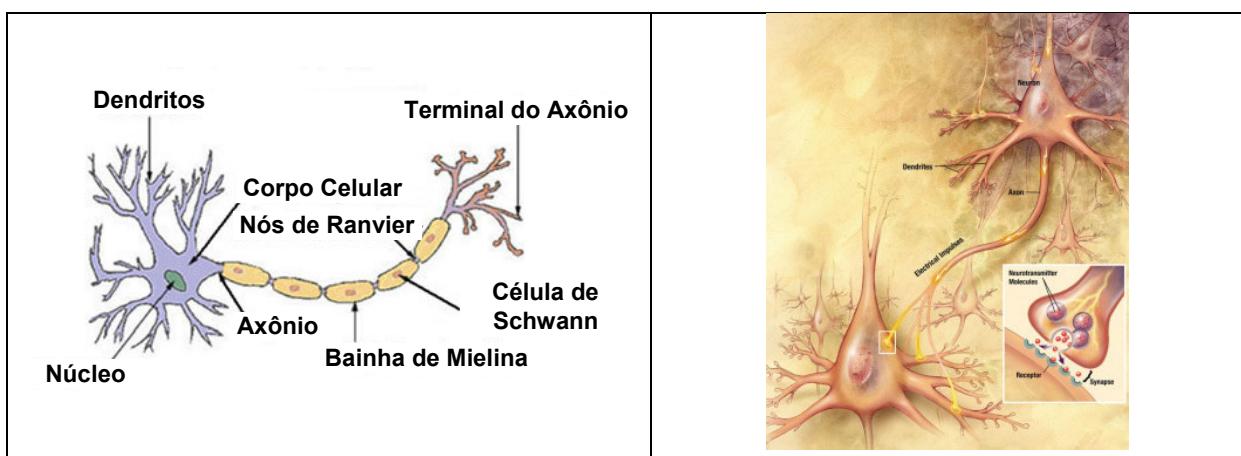


Figura 3.1 – (a) Estrutura do neurônio biológico. (b) Representação da rede neurológica no cérebro. O destaque em (b) mostra a ligação do axônio (saída do sinal) com o dendrito (entrada do sinal) (NG, 2001).

Conceitualmente, uma rede neural artificial é concebida como um sistema de processamento paralelo e distribuído, constituído por unidades simples de processamento. Esta configuração permite armazenar conhecimento com base experimental e disponibilizá-lo para uso futuro. Diz-se que uma rede neural aprende quando ela alcança, através do algoritmo de treinamento, um conjunto de parâmetros (ou pesos) que minimize o erro de classificação do conjunto de dados de treinamento.

Atualmente, as pesquisas realizadas em redes neurais consideram o desenvolvimento de arquiteturas, algoritmos de aprendizagem e a aplicabilidade destas. As aplicações tradicionais das redes neurais são: reconhecimento de padrões, classificação, ajustes, a determinação de similaridades, dentre outras. Haykin (2001) cita ainda que as principais características das redes neurais artificiais são: a modelagem do comportamento não linear dos fenômenos físicos, a capacidade de aprendizagem, a adaptabilidade, a generalização, a informação contextual, a tolerância a falhas, o processamento paralelo e o armazenamento do conhecimento adquirido (pelas conexões entre os neurônios ou pesos sinápticos).

### 3.2 Modelagem do Neurônio Artificial

Na concepção básica, um neurônio configura uma unidade computacional que recebe um número de entradas através de suas conexões, elabora um cálculo conforme sua função de ativação e em seguida, transmite a resposta. A resposta obtida poderá ser recebida e processada por outros neurônios, apenas se este estiver conectado em uma rede. A forma representativa deste modelo é ilustrado na figura 3.2 (a) e (b).

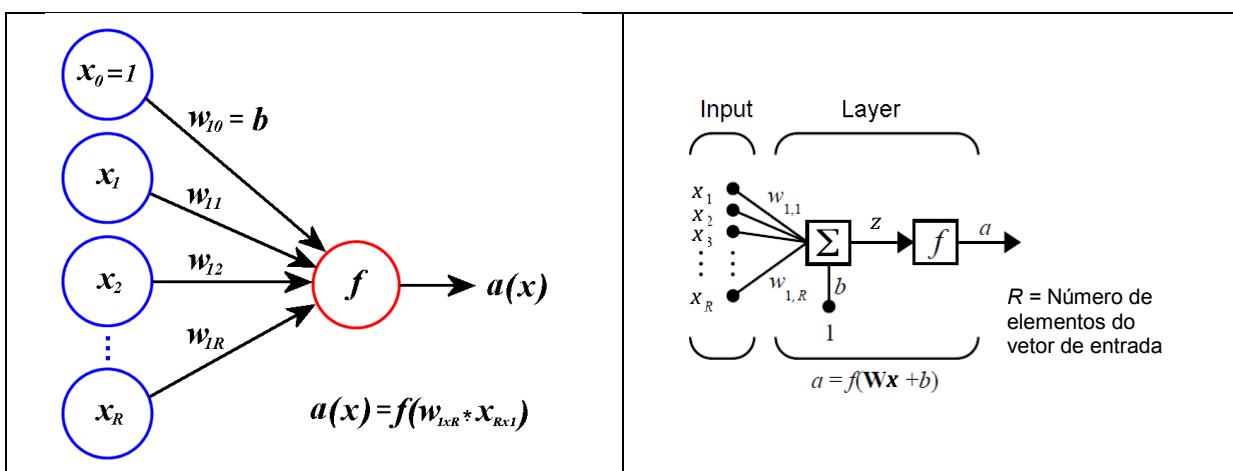


Figura 3.2 – (a) Notação clássica do modelo do neurônio artificial. (b) Representação do modelo do neurônio artificial, utilizada no Matlab® (DEMUTH; BEALE, 2002).

Matematicamente o neurônio é descrito por:

$$a_i = f(\mathbf{w}_i * \mathbf{x}^T) = f(w_{i1} \cdot x_1 + w_{i2} \cdot x_2 + \dots + w_{ij} \cdot x_j + b_i \cdot 1) = f(z) \quad (x.1)$$

onde:

$i$	Número do neurônio
$j$	Número de entradas
$\mathbf{x}^T = \{x_0, x_1, x_2, \dots, x_j\}^T \quad \forall x_0 = 1$	Vetor de entrada.
$\mathbf{w}_i = \{w_{i0}, w_{i1}, w_{i2}, \dots, w_{ij}\}$	Parâmetros ou pesos sinápticos do neurônio $i$ .
$w_{i0} = b_i$	Representa <i>bias</i> ou desvio.
$f(\bullet)$	Função de ativação.
$a_i = f(z)$	Resposta ou saída do neurônio $i$ .
$z = \mathbf{w}_i * \mathbf{x}^T$	Produto escalar

### 3.2.1 Funções de Ativação

Uma função de ativação define a saída do neurônio artificial em termos de um campo induzido. Tipicamente as saídas são definidas nas faixas de  $y \in \{0,1\}$ , mas em alguns casos pode-se estender para  $y \in \{-1,1\}$ . Esta “faixa limitada de resposta” imita o comportamento do neurônio biológico que “decide” sobre o envio ou não da informação. Ou seja, se o campo de hipótese satisfaz o intervalo  $0 \leq y(x) \leq 1$ , implica em dizer que a hipótese indicará a probabilidade da resposta. Por exemplo,  $y(x) = 0.7$  representa a probabilidade de 70% de que a saída será 1 e ao mesmo tempo, indica a probabilidade de 30% para resposta nula. A resposta em termos de probabilidade é descrita como:  $y(x) + P(y = 0|x; w_k) = 1$ . Em suma, uma função de ativação tem que atender a dois critérios (NG, 2001):

1. Deve estar ativa ou próxima de {1} para entradas “corretas” ou inativa próxima de {0} (ou {-1}) para as entradas “erradas”.
2. Deve ser não linear para que a rede como um todo possa representar funções não-lineares.

São várias as funções de ativação que podem ser utilizadas. Neste trabalho citam-se quatro tipos principais de funções de ativação: linear, limiar, rampa e sigmoide.

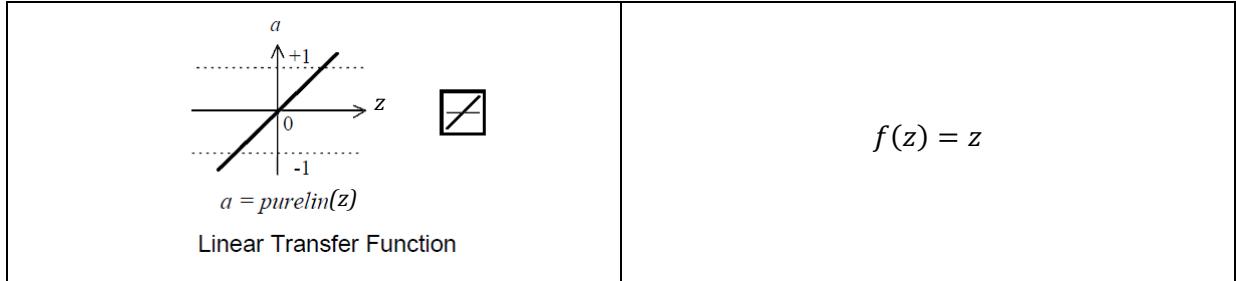


Figura 3.3 – Função Linear (DEMUTH; BEALE, 2002).

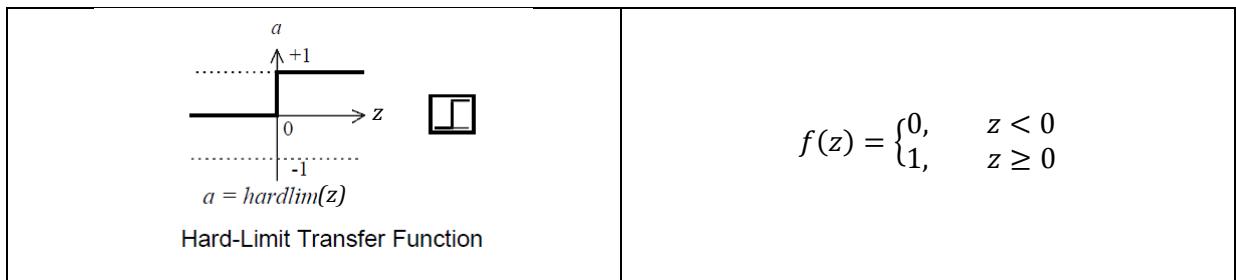


Figura 3.4 – Função Limiar (DEMUTH; BEALE, 2002).

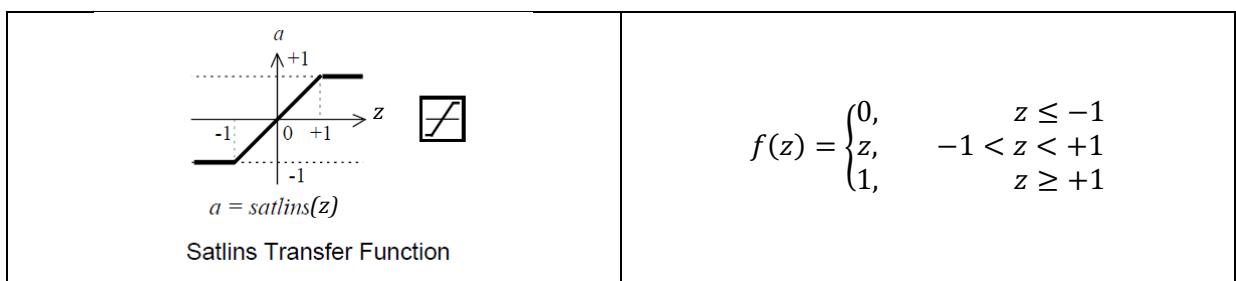


Figura 3.5 – Função Rampa (DEMUTH; BEALE, 2002).

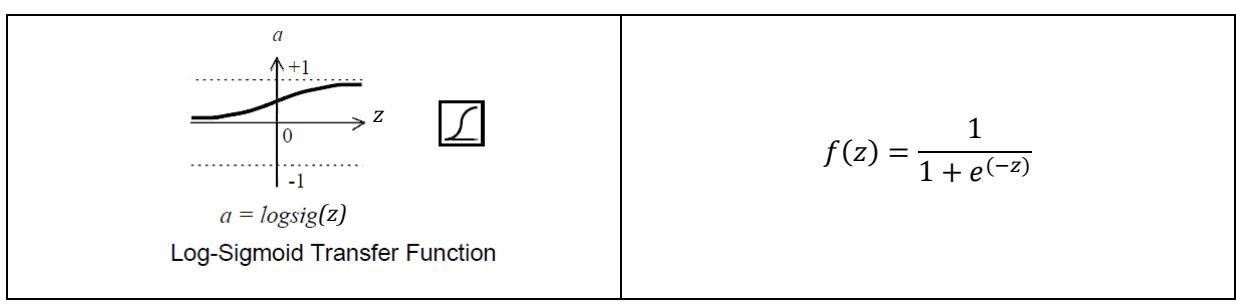


Figura 3.6 – Função Sísmoide (DEMUTH; BEALE, 2002).

### 3.3 Estrutura da Rede Neural

#### 3.3.1 Camadas

Camada ou “layer” de uma rede neural pode ser definida como o conjunto ou agrupamento de dois ou mais neurônios combinados lado a lado ou paralelamente uns aos outros. A principal característica desta configuração é que todos os neurônios presentes na camada recebem a mesma informação simultaneamente, entretanto cada neurônio transmite sua resposta. A figura 3.7 ilustra a topologia característica desta configuração.

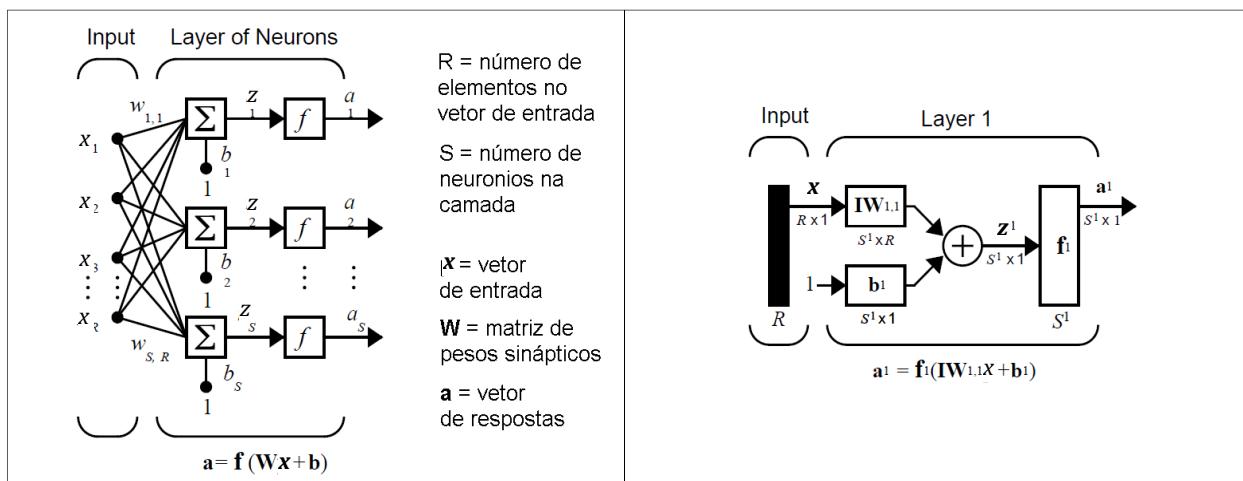


Figura 3.7 – (a) Neurônios agrupados em um única camada. (b) Representação compacta da camada de neurônios, utilizada pelo Matlab® (BEALE *et al.*, 2002).

A disposição sequencial de dois ou mais neurônios definem novas camadas e a rede passar a ser de camadas múltiplas. De forma geral, uma rede neural possui a camada de entrada, uma ou mais camadas ocultas e a camada de saída. A figura 3.8 ilustra uma rede com 3 camadas ocultas.

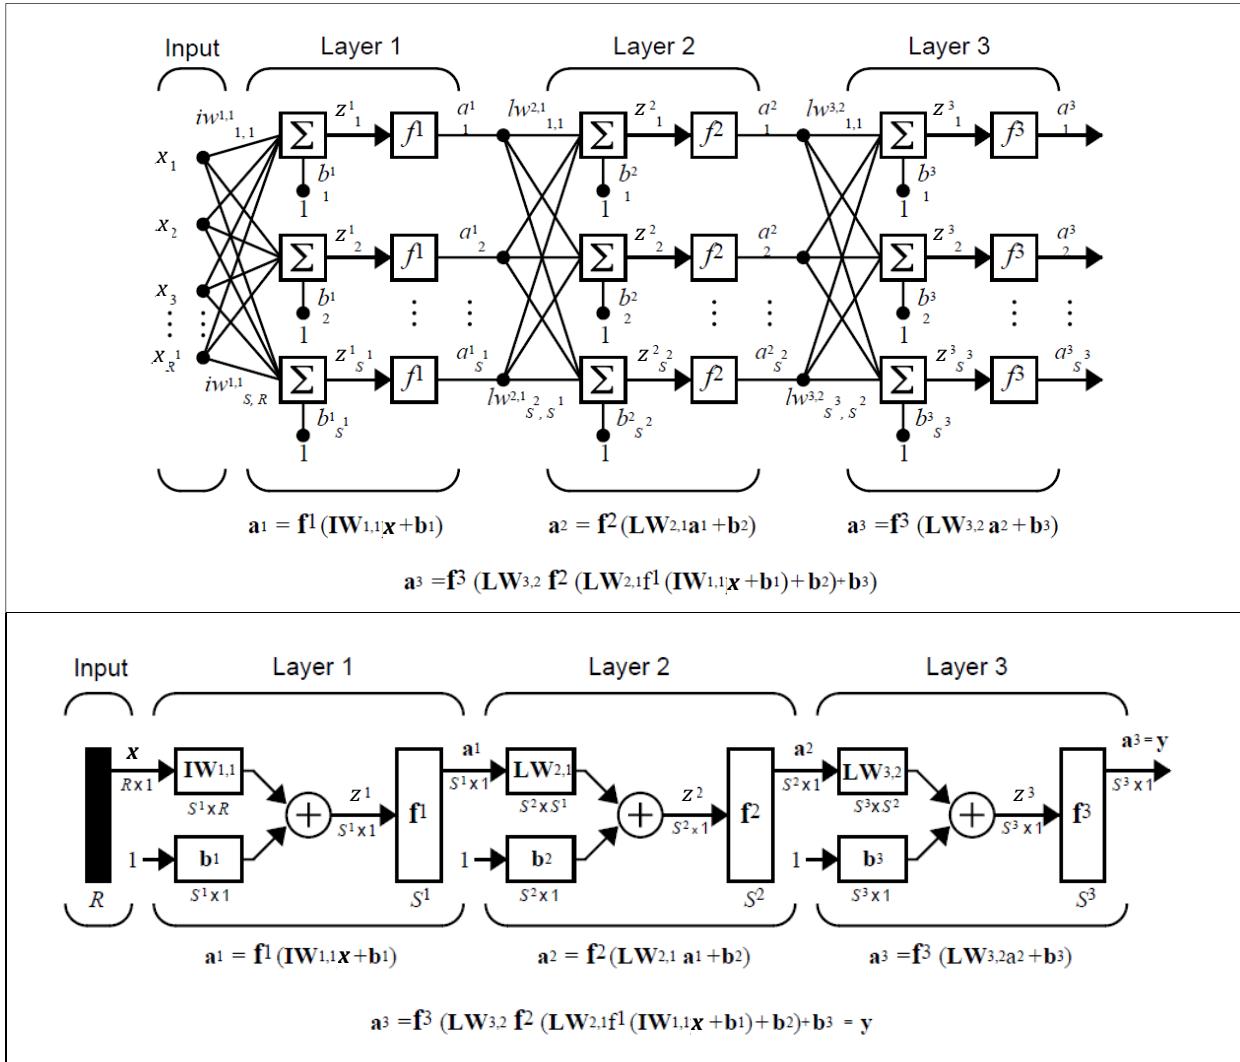


Figura 3.8 – (a) Rede multicamadas apresentando três camadas ocultas. (b) Representação compacta da mesma rede (BEALE *et al.*, 2002).

### 3.3.2 Arquiteturas de Rede

A arquitetura ou projeto de uma rede neural artificial é primordial, pois depende do problema a ser tratado. No projeto de rede são definidos o número de entradas, o número de camadas, o número de neurônios para cada camada, os tipos de conexões considerando a topologia da rede como um todo, os atrasos (*delays*), os algoritmo de aprendizagem usados para o treinamento da rede, suas respectivas funções de otimização e a definição do número de saídas. Em geral, pode-se identificar três tipos básicos de arquiteturas:

- Redes diretas ou *feed-forward*: São redes com fluxo de informação unidirecional para frente, onde as respostas são representadas por uma função direta das entradas. Não apresentam nenhum estado interno a exemplo das redes ilustradas nas figuras 3.7 e 3.8. São tipicamente utilizadas em aproximações de funções.
- Redes recorrentes ou *feed-backward*: São redes que possuem pelo menos um laço de realimentação, como mostrado na figura 3.9(a). A presença da realimentação tem grande impacto na capacidade de aprendizagem dinâmica, sendo responsável pela memória da rede. Como desvantagem apresenta a característica de instabilidade e pode apresentar não convergência para a rede.
- Redes com atraso de linha: São redes também com características dinâmicas que apresentam atrasos sequenciais na entrada de dados para representar uma memória temporal. A figura 3.9(b) ilustra este tipo de rede.

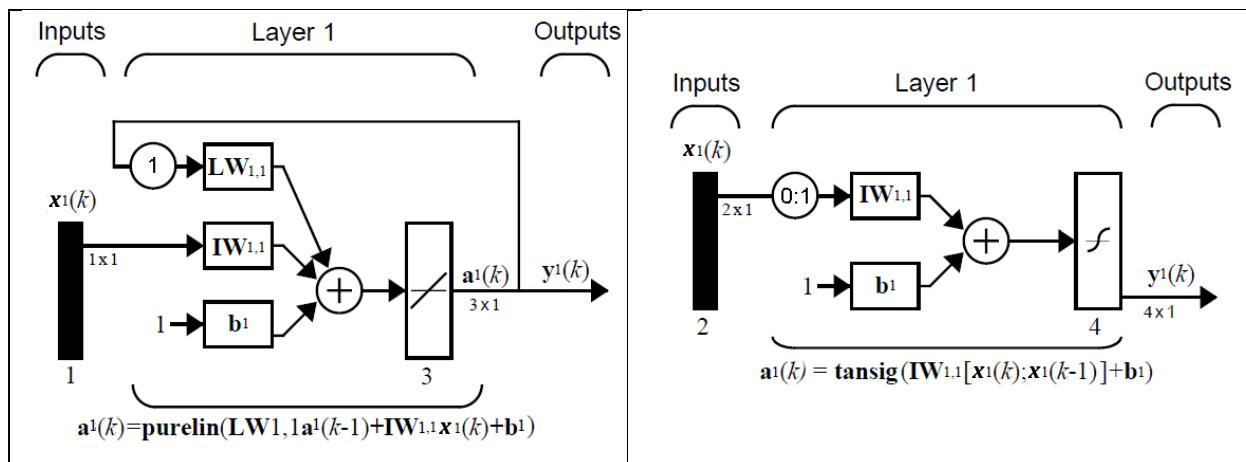


Figura 3.9 – (a) Rede recorrente tipo: 1x3x1. (b) Rede com atraso na linha direta tipo: 2x4x1 (adaptado de BEALE *et al.*, 2002).

Nas redes dinâmicas a saída não depende mais somente dos valores atuais das entradas como nas redes diretas, mas também dos valores passados das entradas e das saídas, inclusive dos estados internos da rede. Esta configuração de rede permite uma memória de curto prazo, possibilitando aprender padrões sequenciais ou variantes no tempo. Como consequência o treinamento se torna mais complexo. (FONSECA, 2013)

### 3.3.3 Treinamento

#### 3.3.3.1 - ESTRATÉGIAS DE APRENDIZADO:

Haykin (2001) comenta que o aspecto primordial de uma rede neural é a habilidade de aprender, dado um conjunto de entradas e saídas desejadas. O processo de aprendizagem é portanto, um processo interativo de ajuste de pesos sinápticos (ou parâmetros) e *bias* de cada neurônio. As estratégias de treinamento são basicamente as seguintes:

- Sem treinamento: Os valores dos pesos sinápticos e *bias* são estabelecidos explicitamente.
- Treinamento supervisionado: A rede é treinada pela apresentação dos vetores de entrada e seus respectivos vetores de saída, chamados de pares de treinamento. No processo interativo a estimativa da resposta fornecida pela rede é comparada com a resposta desejada caracterizando o erro de estimativa. A minimização do erro é obtida por um processo de otimização de variáveis para os parâmetros dos neurônios
- Treinamento não supervisionado: O treinamento consiste da apresentação apenas dos vetores de entrada, a partir dos quais são extraídas as características desse conjunto de padrões, agrupando-os em classes. O treinamento não supervisionado pode ser observado como um processo autônomo ou auto organizável.

#### 3.3.3.2 - ALGORITMO DE APRENDIZADO:

Ao fornecer à rede um determinado padrão de entrada e seu respectivo padrão de saída, obtém-se uma estimativa. A partir da estimativa produzida é calculado um erro que representa a diferença entre o valor obtido e o desejado. O objetivo consiste, em reduzir continuamente o erro até um valor aceitável. Isto é alcançado pelo ajuste dos pesos entre as conexões dos neurônios.

A minimização do erro no algoritmo conhecido como *backpropagation* para redes neurais é obtida pela execução do gradiente decrescente do espaço de pesos. O ajuste dos pesos inicia-se na camada de saída, onde a medida do erro está disponível e procede com a retro propagação desse erro entre as camadas internas, ajustando os pesos até que a camada das unidades de entrada tenha sido processada. A partir da definição da função de custo para o erro, aplica-se o processo de otimização de variáveis do gradiente decrescente

para obter o ajuste de pesos. O processo é reiniciado até que se obtenha o valor aceitável para o erro, previamente estabelecido. Inicialmente, será apresentada a formulação para um neurônio cujo procedimento é bem simples e posteriormente a generalização da rede neural.

Pela Eq. 3.1, a estimativa  $a(x)$  pode ser obtida para um conjunto de  $m$  amostras de treinamento, onde  $\mathbf{x}^T = \{x_1, x_2, \dots, x_j\}^T$  são os valores de entrada e  $(y)$  a resposta desejada. Utilizando uma função de ativação linear, o modelo é descrito pela Eq. 3.2:

$$a_i(x) = w_{i0} \cdot 1 + w_{i1} \cdot x_1 + w_{i2} \cdot x_2 + \dots + w_{ij} \cdot x_j = \mathbf{w}_i * \mathbf{x} = z \quad (3.2)$$

A Eq. 3.3 estabelece uma função de erro entre a resposta  $(y)$  e a estimativa  $(a_i)$ . Esta equação é chamada de média quadrática do erro ou “*mse – mean square error*”. Observe ainda que o erro passa a ser função dos parâmetros da rede:

$$J(w) = \frac{1}{2m} \sum_{k=1}^m [a(x)^{(k)} - y^{(k)}]^2 \quad (3.3)$$

$J(w)$  torna-se, uma função de custo a ser minimizada com base nos parâmetros  $\{w_0, w_1, w_2, \dots, w_j\}_i$ . Isto significa obter o gradiente de  $J(w)$  em relação ao parâmetro  $w_j$ :

$$\min J(w_0, w_1, w_2, \dots, w_j) = \frac{\partial J(w)}{\partial w_j} = \frac{1}{m} \sum_{k=1}^m [a(x)^{(k)} - y^{(k)}] x_j^{(k)} \quad (3.4)$$

Pode-se aplicar o algoritmo do gradiente descendente ao conjunto de parâmetros para obter de forma iterativa o ponto que minimiza a função  $J(w)$ , conforme Eq. 3.5.

$$w_{j+1} = w_j - \alpha \frac{\partial J(w)}{\partial w_j} = w_j - \alpha \frac{1}{m} \sum_{k=1}^m [a(x)^{(k)} - y^{(k)}] x_j^{(k)} \quad (3.5)$$

Onde  $\alpha$  representa a taxa de aprendizagem. Para valores altos de  $\alpha$  o algoritmo pode não convergir, enquanto taxa pequena pode acarretar lentidão na convergência. A convergência depende também de uma boa escolha dos valores iniciais de  $w_j$ . Normalmente os valores iniciais de  $w_j$  são aleatórios, mas uma escolha errada pode levar à saturação. Nguyen e Widrow (1990) encontraram uma função que determina os melhores valores iniciais.

Ao generalizar a formulação para uma rede neural com  $(l + 1)$  camadas e  $(i)$  neurônios, pode-se calcular a saída de cada neurônio na camada conforme Eq. 3.6. Note ainda que se considera uma função de ativação ( $f$ ) não necessariamente linear.

$$a_i^{(l+1)} = f(w_{i0}^{(l)} \cdot 1 + w_{i1}^{(l)} \cdot a_1^{(l)} + w_{i2}^{(l)} \cdot a_2^{(l)} + \dots + w_{ij}^{(l)} \cdot a_j^{(l)}) = f(z_i^{(l)}) \quad (3.6)$$

onde:  $a_j^{(1)} = x_j$

O objetivo continua a ser a determinação dos parâmetros  $w^{(l)}$  que minimiza  $J(w^{(l)})$ , cuja derivada parcial é dada por  $\frac{\partial J(w^{(l)})}{\partial w_{ij}^{(l)}}$ . Como anteriormente, processamos o erro  $\delta_i^{(l)}$  do neurônio  $(i)$  na camada  $(l)$ , assim, na camada de saída o vetor ( $\delta$ ) é calculado por:

$$\delta^{(l+1)} = \delta_i^{(l+1)} = a_i^{(l+1)} - y_i \quad (3.7)$$

Para calcular os valores de erro das camadas anteriores, utilizamos a equação que dá o passo para trás:

$$\delta^{(l)} = ((w^{(l)})^T \delta^{(l+1)}). * f'(z^{(l)}) \quad (3.8)$$

A Eq. 3.8 indica que os erros  $\delta^{(l)}$  são calculados pela multiplicação dos  $\delta^{(l+1)}$  da camada atual com a matriz dos parâmetros  $w^{(l)}$  da camada anterior, sendo multiplicados pela derivada da função de ativação  $f'(z^{(l)})$ . Já os termos da derivada  $f'(z^{(l)})$  podem ser obtidos pela Eq. 3.9, cuja prova pode ser realizada pelo cálculo diferencial.

$$f'(z^{(l)}) = a^{(l)} * (1 - a^{(l)}) \quad (3.9)$$

Portanto, a equação que determina os erros nos neurônios internos no processo de "backpropagation" é dada por:

$$\delta_i^{(l)} = ((w^{(l)})^T \delta_i^{(l+1)}). * a_i^{(l)} * (1 - a_i^{(l)}) \quad (3.9)$$

Por fim é calculada a derivada parcial da função objetivo

$$\frac{\partial J(\mathbf{w}^{(l)})}{\partial w_{i,j}^{(l)}} = a_i^{(l)} \delta_i^{(l+1)} \quad (3.10)$$

Para o procedimento de treinamento como descrito para a equação 3.5.

$$w_{i,j+1}^{(l)} = w_{i,j}^{(l)} - \alpha \frac{\partial J(\mathbf{w}^{(l)})}{\partial w_{i,j}^{(l)}} \quad (3.11)$$

### 3.3.3.3 – FUNÇÕES DE TREINAMENTO – MATLAB<sup>®</sup>:

Os procedimentos descritos anteriormente utilizam algoritmos de otimização que podem ser programados e executados. Entretanto *softwares* especializados como o Matlab<sup>1</sup> ou seu similar Octave<sup>2</sup>, apresentam algoritmos desenvolvidos e testados para estas tarefas, fornecendo inclusive outras ferramentas sofisticadas para o processamento numérico.

Zanata (2005) comenta sobre os algoritmos de treinamento para redes neurais existentes no Matlab<sup>®</sup> e os classifica com base nos algoritmos de otimização:

- Gradiente conjugado
  - Powell-Beale (“traincgb”)
  - Fletcher-Powell (“traincfg”)
  - Polak-Ribiére (“traincgp”)
- Gradiente descendente:
  - Gradiente descedente (“traingd”)
  - Gradiente descedente com momento (“traingdm”)
  - Taxa de aprendizagem variável (“traingdx” / “traingda”)
  - Retropropagação resiliente (“trainrp”)
- Métodos quasi-Newton:
  - BFGS (“trainbfg”)
  - Levenberg-Marquardt (“trainlm”)

<sup>1</sup> Matlab<sup>®</sup> (MATrix LABoratory) trata-se de um *software* interativo de alta performance voltado para o cálculo numérico.

<sup>2</sup> Octave<sup>®</sup> (GNU Octave) *software* para computação matemática de problemas numéricos, lineares e não-lineares. É um *software* livre e possui compatibilidade com Matlab<sup>®</sup>, com um grande número de funções semelhantes.

Beale *et al.* (2013) dizem que é difícil determinar qual algoritmo é o mais rápido ou melhor para uma determinada configuração de rede. Eles apresentam uma comparação entre 6 diferentes problemas, sendo 3 utilizados para reconhecimento e outros 3 para aproximações, onde 2 são fictícios e 4 reais. Foram utilizados 9 algoritmos de treinamento para diferentes arquiteturas e com diferentes níveis de exatidão. Como conclusão o algoritmo de treinamento Levenberg-Marquardt (“*trainlm*”) apresentou rápida convergência e melhor eficiência para redes com poucas centenas de pesos. Como desvantagens, o algoritmo apresenta baixa performance para redes de reconhecimento, consome memória de máquina e reduz velocidade à medida em que o número de pesos da rede aumenta. Para redes de reconhecimento o algoritmo “*trainrp*” apresentou melhor performance. Sendo que para redes com grandes números de pesos, o algoritmo indicado é o “*trainscg*”, inclusive mostrando bons resultados para aproximações e reconhecimento, com modestos consumos de memória.

Os algoritmos de treinamento são utilizados nos problemas, onde se define um conjunto de vetores de entrada e de destino e onde se espera uma solução correlacionada entre as entradas e as saídas. Na adaptação o problema apresenta-se como uma sequência de entrada e de destino ilimitados. A aprendizagem da rede torna-se continua, pois se presume que a natureza dos sinais de entrada / destino pode mudar ao longo do tempo.

### 3.4 O problema do super ajuste e da sub ajustagem

Em estatística e em aprendizagem de máquinas, a super ajustagem ocorre quando um modelo estatístico começa a descrever o erro aleatório ou ruído ao invés de se correlacionar com a tendência dos dados. Isso geralmente acontece quando a ordem do modelo é alta para um pequeno número de observações. Modelos com estas características apresentam baixo desempenho preditivo.

A formulação de um modelo preditivo considera que todas as experiências obtidas podem ser divididas em informações relevantes e irrelevantes ou ruidosas para estabelecer uma estimativa. Assim, pode-se definir um critério para tentar estimar o ruído existente nas informações e que precisam ser ignorados. Esta tarefa torna-se cada vez mais difícil quanto maior for a incerteza agregada aos dados. Um algoritmo de aprendizagem pode ser considerado robusto quando for capaz de minimizar a relevância do ruído.

Desta forma, um modelo que apresenta uma capacidade adequada de estimativa, não é determinado quando são apresentados os dados durante a fase de treinamento, mas sim, por sua capacidade de previsão quando são fornecidos novos conjuntos de dados que

não foram apresentados durante o treinamento. Ou seja, a super ajustagem ocorre quando um modelo começa a memorizar ao invés de aprender a generalizar a partir da tendência, perdendo a robustez na resposta. A fig. 3.10 ilustra este conceito, onde são apresentados exemplos de um ajuste deficiente, um ajuste adequado e um ajuste excessivo.

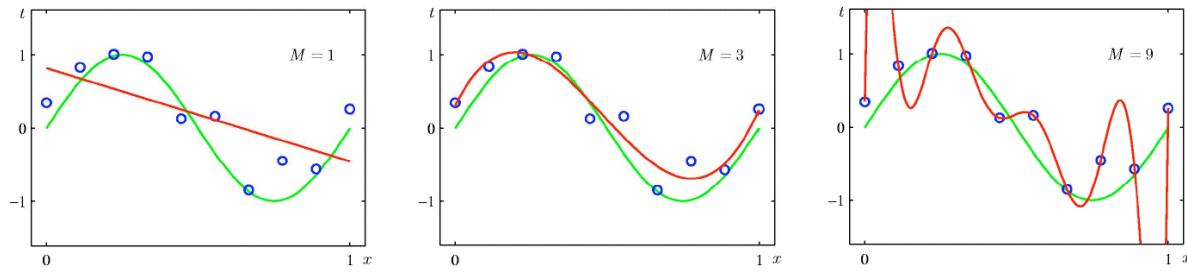


Figura 3.10 – Representação dos ajustes obtidos para a função  $y = \sin(2\pi x)$  onde  $M$  = ordem do modelo utilizado (a) Sub ajustagem. (b) Ajuste adequado. (c) Super ajustagem (adaptado de SRIHARI, 2013).

Para evitar que a super ajustagem ocorra, são utilizadas técnicas a exemplo da: validação cruzada, regularização, interrupção precoce, elevação da quantidade de dados, parâmetros *bayesianos* e outros (NG, 2001). Estas técnicas são baseadas na penalização dos modelos excessivamente complexos ou na verificação da capacidade do modelo em generalizar. Neste último caso, avaliam-se o desempenho mediante um conjunto de dados não utilizados no treinamento. A figura 3.11 ilustra um modelo de ordem  $X$ , onde a elevação do número de dados minimiza a ocorrência do super ajuste.

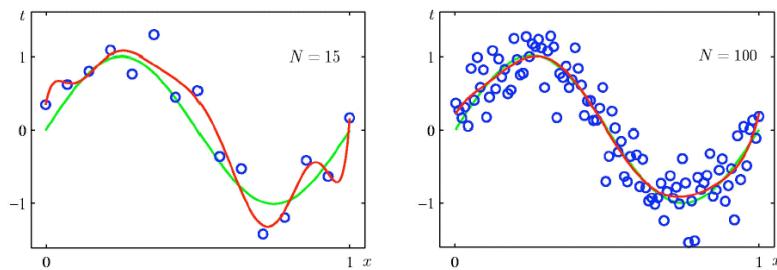


Figura 3.11 – Modelo de mesma ordem, utilizando (a)  $N = 15$  dados. (b)  $N = 100$  dados para os ajustes (adaptado de SRIHARI, 2013).

### 3.4.1 Super ajustagem em Redes Neurais

Durante a fase de treinamento de uma rede neural poderá ocorre o problema do super ajuste. Isso é verificado durante a fase de treino, onde a rede apresenta um valor de

erro muito pequeno e posteriormente o erro aumenta bastante quando novos dados são apresentados, indicando que a rede memorizou os exemplos no treinamento, mas não aprendeu a generalizar a novas situações.

Para melhorar a generalização é indicado utilizar parâmetros que sejam apenas suficientes para proporcionar uma adaptação adequada. Uma rede “grande” irá gerar funções complexas e uma rede “pequena” pode ser incapaz de se ajustar. Infelizmente é muito difícil saber o comportamento de uma rede para uma aplicação específica. Sabe-se entretanto que ao elevar o número de pontos no conjunto de treino em relação ao número de parâmetros, haverá pouca possibilidade do super ajuste acontecer.

O método padrão para melhorar a generalização é a interrupção precoce. Nesta técnica os dados disponíveis são divididos em três subgrupos. O primeiro é o conjunto de treinamento, utilizado para calcular o gradiente e para atualizar os pesos da rede. O segundo grupo é o conjunto de validação, onde o erro é monitorado durante o processo. Normalmente o erro de validação e de treinamento diminui durante a fase inicial de treinamento. No entanto, quando a rede começa com a super ajustagem, o erro na validação começa a subir. Quando o erro de validação ultrapassa determinada condição, o treinamento é interrompido.

Existem quatro funções para a divisão de dados de treinamento, validação e teste no Matlab® que são:

- “*divideind*”. Divide os dados em índices para que as amostras do conjunto de treino, validação e teste sejam sucessivamente atribuídas;
- “*dividerand*”. Divide os dados ao acaso para que as amostras sejam atribuídas ao conjunto de treino, validação e teste;
- “*divideblock*”. Divide os dados ao acaso de modo que as amostras sejam primeiramente atribuídas ao conjunto de treino, seguidas para o conjunto de validação e finalmente para o conjunto de teste;
- “*divideint*”. Dividem os dados de modo a intercalar as amostras para o conjunto de treino, validação e teste.

### 3.5 Nomenclatura adotada neste trabalho

A figura 3.12 apresenta uma rede neural hipotética, utilizada como exemplo para identificar a arquitetura estabelecida, sendo neste caso: 03 entradas de dados ( $M_1$ ,  $M_2$  e  $M_3$ ), 03 camadas, 01 saída ( $MV$ ) e 02 linhas recorrentes com atraso. Como particularidade tem-se ainda: a entrada  $M_1$  exclusiva para a camada 02, 04 elementos de atraso na linha direta da entrada  $M_2$  e 06 elementos no vetor de entrada  $M_3$ . Esta figura consolida todos os detalhes que foram previamente apresentados nas figuras 3.7(b), 3.8(b) e 3.9.

No trabalho adota-se a nomenclatura de rede tipo ( $M_1+M_2+M_3$ )  $10 \times 03 \times 01$  para indicar as entradas utilizadas ( $M_1$ ,  $M_2$  e  $M_3$ ), seguida do número de neurônios em cada camada, sendo: 10 neurônios na 1<sup>a</sup> camada, 03 neurônios na 2<sup>a</sup> camada e 01 na camada de saída. Funções de ativação, algoritmos de aprendizagem e estimador de performance serão apresentados no parágrafo ao descrever a rede projetada.

Todos os comandos de configuração utilizados para gerar a rede neural da figura 3.12 são descritos no Apêndice A. Comandos complementares de configuração podem ser obtidos em Beale *et al.* (2013).

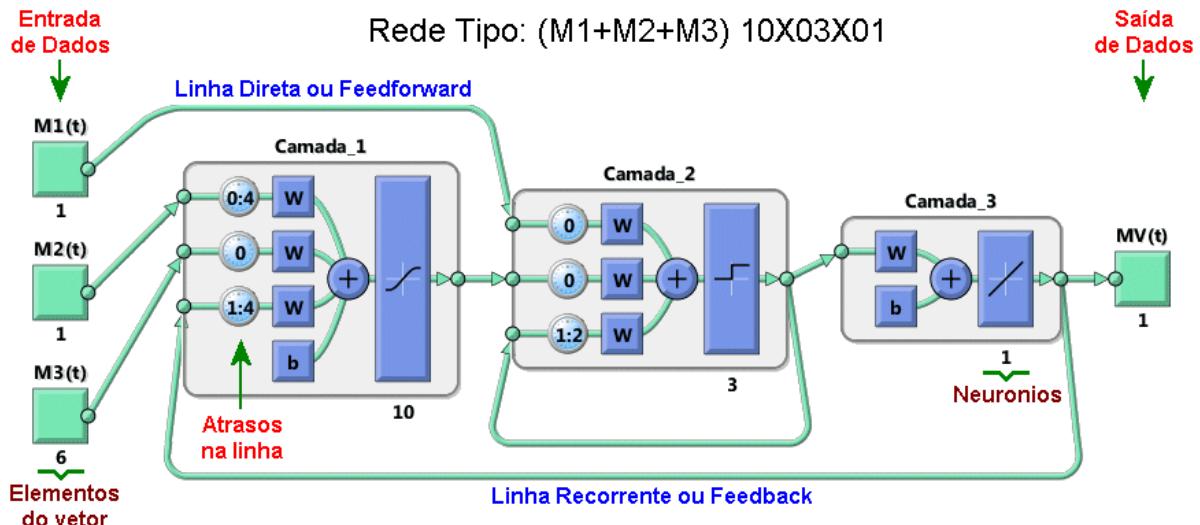


Figura 3.12 – Rede Neural utilizada como exemplo de identificação dos parâmetros de projeto, nomenclatura utilizada e para descrever os comandos utilizados para geração.

### 3.6 Estudos de casos

#### 3.6.1 Ajuste de curvas

Narendra e Parthasarathy (1990) comentam que de acordo com o teorema de Stone-Weierstrauss, uma rede neural com duas camadas e um considerável número de neurônios na camada oculta, pode aproximar qualquer função contínua. Braga *et al.* (1998) afirmam que redes com 02 camadas ocultas conseguem aproximar quaisquer funções não lineares. Entretanto redes com um maior número de camadas não acrescenta nenhuma capacidade estimativa para a rede, mas podem fornecer exatidão e segurança em perdas localizadas.

Neste exemplo foi configurada uma rede para estimar uma função de resposta em frequência (FRF), com ruído de aquisição. As figuras 3.13 e 3.14 apresentam a estimativa de resposta  $a(x)$  da rede. As curvas provem de um ensaio dinâmico realizado com martelo de impacto em uma viga de aço engastada com 376,0 mm x 30,5 mm x 4,7625 mm (3/16"). A rede utilizada é composta por duas camada, função de transferência linear ("*tansig*" e "*purelin*"), algoritmo de treinamento ("*trainlm*"), algoritmo de aprendizagem do gradiente descendente ("*traingd*") e estimador de performance ("*mse*").

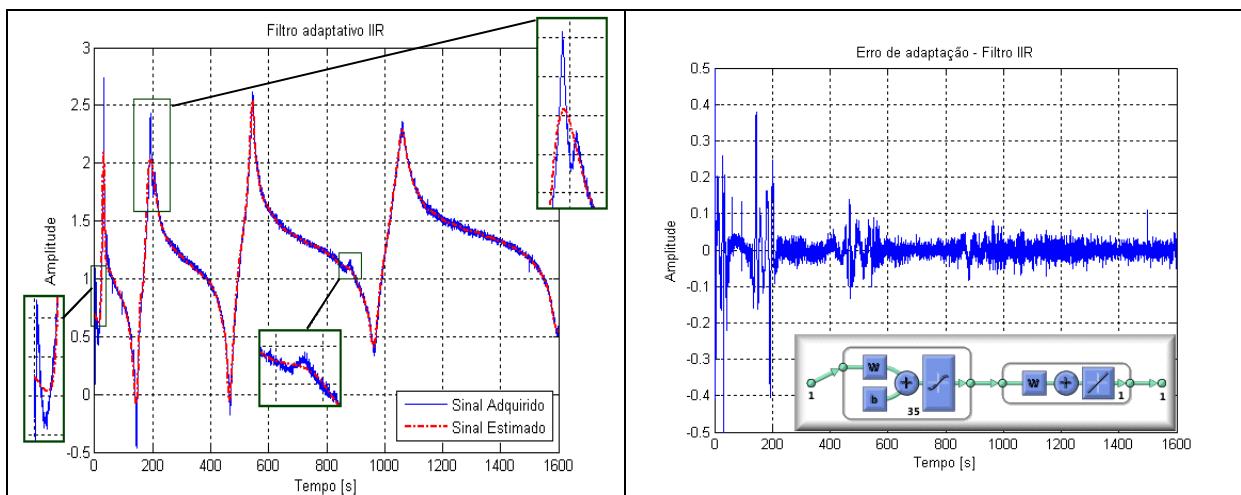


Figura 3.13 – (a) Rede neural com uma camada oculta para ajuste de curva (b) Erro entre a resposta e a estimativa. Valor do erro médio quadrático obtido =  $108,33 \times 10^{-4}$ .

Observa-se pela Fig. 3.13 que o sinal estimado se ajusta muito bem à curva experimental, porém quando ocorrem mudanças abruptas, como nas ressonâncias e antirressonâncias, a curva da estimativa fica suavizada, afastando-se e incrementando o erro nestas regiões. Por outro lado, ao utilizar uma rede com três camadas como ilustra a Fig. 3.14, a estimativa melhora nas regiões onde ocorreram as perdas localizadas. Observa-se ainda a redução expressiva do erro médio quadrático indicado nas figuras.

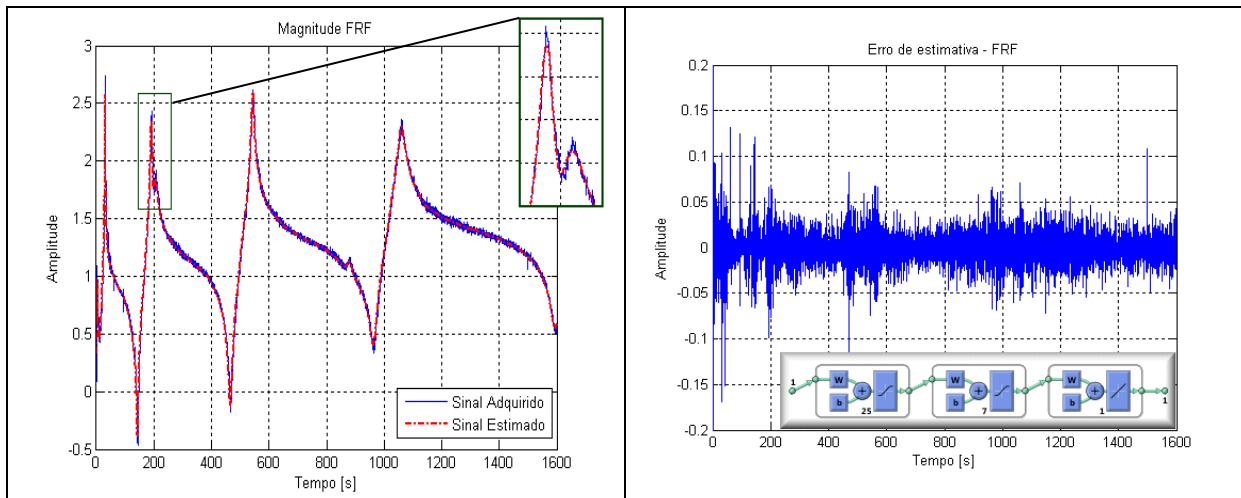


Figura 3.14 – (a) Rede neural com duas camadas ocultas para ajuste de curva (b) Erro entre a resposta e a estimativa. Valor do erro médio quadrático obtido =  $14,11 \times 10^{-4}$ .

### 3.6.2 Filtragem adaptativa - Filtro FIR

Filtros de resposta ao impulso finito (FIR) são ideais para problemas de ruído tonais, onde o sinal de referência é composto de um ou alguns harmônicos e onde o sinal de controle não corrompe o sinal de referência. O filtro recebe amostras discretas do sinal atual e também amostras passadas e estes são multiplicados por um conjunto de coeficientes para produzir o sinal estimado conforme Eq. 3.12. Os valores dos coeficientes são modificados para que a resposta possa adaptar-se e o erro de resposta minimizado. (HANSEN, 2001)

$$y(k) = w_0 \cdot x(k) + w_1 \cdot x(k-1) + \cdots + w_R \cdot x(k-R) = \sum_{i=0}^R w_i x(k-i) \quad (3.12)$$

Neste caso, configurou-se uma rede composta por um neurônio, função de transferência linear (“purelin”), algoritmo de adaptação (“trains”), algoritmo de aprendizagem do gradiente descendente (“traingd”), estimador de performance (“mse”) e atraso com 07 elementos na linha de entrada de dados. A rede com esta configuração é chamado ADALINE (*Adaptive Linear Neuron Network*). A figura 3.15 apresenta a estimativa de resposta  $a(x)$  da rede a partir de uma função senoidal com frequências e amplitudes variáveis.

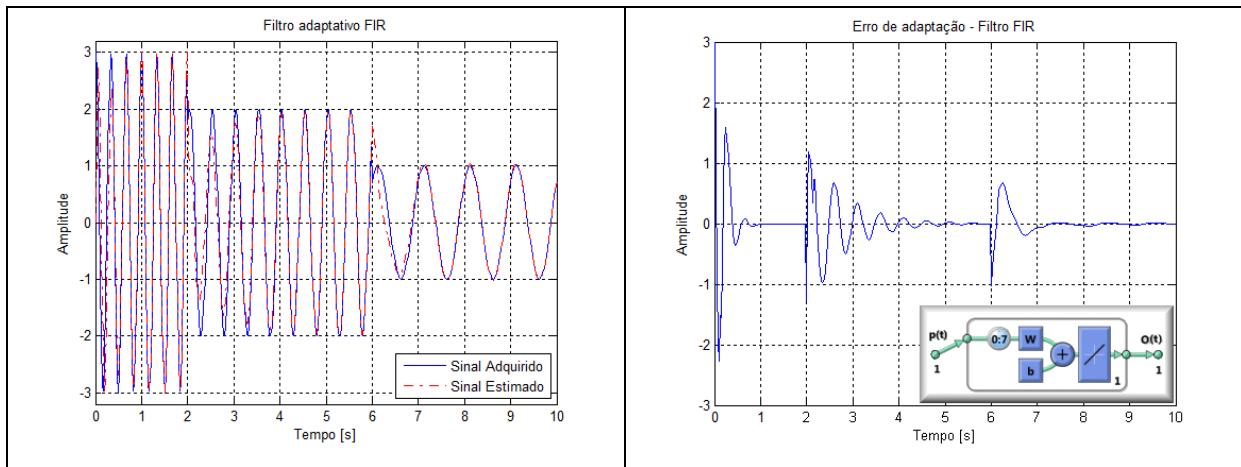


Figura 3.15 – (a) Filtragem adaptativa - FIR (b) Erro resultante da resposta estimada e da resposta adquirida.

### 3.6.3 Filtragem adaptativa - Filtro IIR

Em alguns casos, especialmente quando ocorre ressonância ou se há retorno acústico a partir da fonte de controle para o sensor de referência, ocorre corrupção do sinal de referência e o filtro FIR não é a melhor escolha. Nestes casos, os filtros de resposta ao impulso infinito (IIR) são muitas vezes escolhidos por sua capacidade de modelar diretamente os polos do sistema. O filtro IIR pode ser considerado como sendo composto por dois filtros FIR. (HANSEN, 2001)

Os filtros IIR são preferidos sobre os filtros FIR nos sistemas onde haja ruído de banda larga e especialmente se o sistema a ser controlado apresenta ressonâncias ou onde a velocidade de fase não é independente da frequência (tais como modos de ordem superior que se propagam em dutos de ar condicionado). A equação 3.13 descreve a função de transferência de um filtro IIR que é caracterizada por um denominador bem como um numerador (o filtro FIR não tem denominador). Como vantagem este filtro apresenta convergência mais rápida requerendo menos coeficientes que o filtro FIR. Como desvantagem pode apresentar não convergência. Nos casos onde há várias fontes de controle não lineares ou sistemas não-lineares a serem controlados, nem o filtro IIR ou FIR são adequados. (HANSEN, 2001)

$$\begin{aligned}
 & a_0 \cdot y(k) + a_1 \cdot y(k-1) + \cdots + a_q \cdot y(k-Q) \\
 & = w_0 \cdot x(k) + w_1 \cdot x(k-1) + \cdots + w_R \cdot x(k-R)
 \end{aligned} \tag{3.13}$$

$$\sum_{j=0}^Q a_j y(k-j) = \sum_{i=0}^R w_i x(k-i) \quad (3.14)$$

$$y(k) = \frac{1}{a_0} \left( \sum_{i=0}^R w_i x(k-i) - \sum_{j=1}^Q a_j y(k-j) \right) \quad (3.15)$$

Aplicando a transformada  $z$  na Eq. 3.14, pode-se escrever:

$$\sum_{j=0}^Q a_j z^{-1} Y(z) = \sum_{i=0}^R w_i z^{-1} X(z) \quad (3.16)$$

$$H(z) = \frac{Y(z)}{X(z)} = \frac{\sum_{i=0}^R w_i z^{-1}}{\sum_{j=0}^Q a_j z^{-1}} \quad (3.17)$$

Para este caso, configura-se uma rede recorrente, também composta de um neurônio, função de transferência linear (“purelin”), algoritmo de adaptação (“trains”), algoritmo de aprendizagem do gradiente descendente (“traingd”), estimador de performance (“mse”), atraso de 22 elementos na linha direta de dados e um elemento no *feedback*. A figura 3.16 apresenta a estimativa de resposta  $a(x)$  da rede a partir de uma função senoidal com frequência, amplitude e fase variáveis.

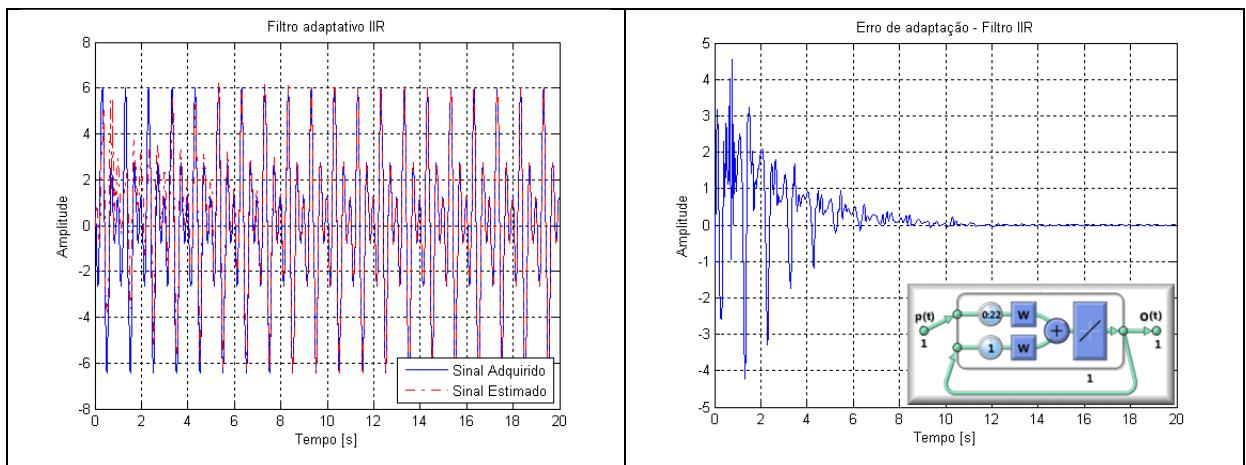


Figura 3.16 – (a) Filtragem adaptativa - IIR (b) Erro resultante para resposta estimada e resposta adquirida.

### 3.7 Considerações sobre Redes Neurais

Redes neurais são poderosos algoritmos de processamento, onde redes configuradas com apenas um neurônio são capazes de solucionar aplicações de regressão e adaptação de sinais, modelando inclusive filtros os FIR e/ou IIR.

Os resultados obtidos são fortemente influenciados pelas condições iniciais (valores iniciais atribuídos aos pesos) para fazer o treinamento ou adaptação dos sinais. Assim uma condição inicial que apresenta convergência com erro reduzido, pode apresentar valores diferentes em outros treinamentos ou mesmo apresentar não convergência nas redes recorrentes.

Da mesma forma, as respostas das redes são bastante influenciadas por sua arquitetura e pelos algoritmos de treinamento, aprendizagem e de aferição do erro. Haykin (2001) comenta que não há regras para obter uma boa arquitetura, sendo recomendável que se faça um estudo experimental exaustivo para obter a melhor configuração.

Redes neurais multicamadas apresentam condições para solucionar problemas não lineares de forma iterativa. Ou seja, são capazes de se adaptarem e apresentar uma estimativa durante a evolução do problema.

## CAPÍTULO IV

### ACÚSTICA DE AMBIENTES FECHADOS

#### 4.1 Introdução

Quando se trata de campo aberto, a propagação de uma onda sonora se dá de forma livre, sem que ocorra qualquer interferência, isto se for considerado apenas uma fonte sonora. Já em recintos fechados, a propagação da onda a partir da fonte sofre interferências devido a reflexões nas superfícies que delimitam o recinto (BISTAFÁ, 2006). Isso porque uma parte da energia sonora é refletida na superfície e interage com a onda que incide. A outra parte não refletida entra pelo material, onde uma parcela será transmitida e outra parte absorvida ou dissipada no material do obstáculo.

Beranek (1993) diz que o estudo do som em ambientes fechados envolve não somente a pesquisa da reflexão sonora, mas também a medição sonora sob certas condições e os efeitos dos materiais na absorção e no controle.

Gerges (2000) afirma que para o estudo do campo sonoro de ambientes fechados, devem-se considerar as várias interações de natureza complexas que ocorrem, tais como: a forma geométrica do ambiente, absorção acústica, reflexões, difrações das paredes e dos elementos internos, fontes sonoras com seus espectros e diretividade, posição das fontes, efeitos de abertura e etc. Ou seja, na acústica de recintos fechados os campos sonoros podem ser caracterizados por sua natureza temporal e espacial.

#### 4.2 Reverberação

Dentro de uma sala, o campo sonoro é composto pelo som direto gerado a partir da fonte e pelo campo reverberante, sendo que o campo reverberante é constituído por todos os sons remanescentes na sala depois de ocorrida a primeira reflexão. A magnitude do som direto relativo ao campo reverberante tem um papel importante no uso da sala, seja para a

inteligibilidade da fala, apresentações musicais ou mesmo para o controle de ruído em um ambiente industrial.

Uma sala reverberante é caracterizada pelo tempo de decaimento da energia sonora remanescente. Quando se liga uma fonte sonora em um recinto, a energia sonora se eleva até atingir um estado estacionário que corresponde ao equilíbrio entre a energia injetada e a energia absorvida pelo ar e superfícies internas do recinto. Ao desligar a fonte, o nível sonoro no recinto cai, ocorrendo uma queda mais acentuada nas salas com altos níveis de absorção. A figura 4.1 apresenta o nível de decaimento sonoro, onde se define o tempo de reverberação como sendo o tempo necessário para que o nível sonoro do recinto caia 60 dB quando se faz o desligamento da fonte.

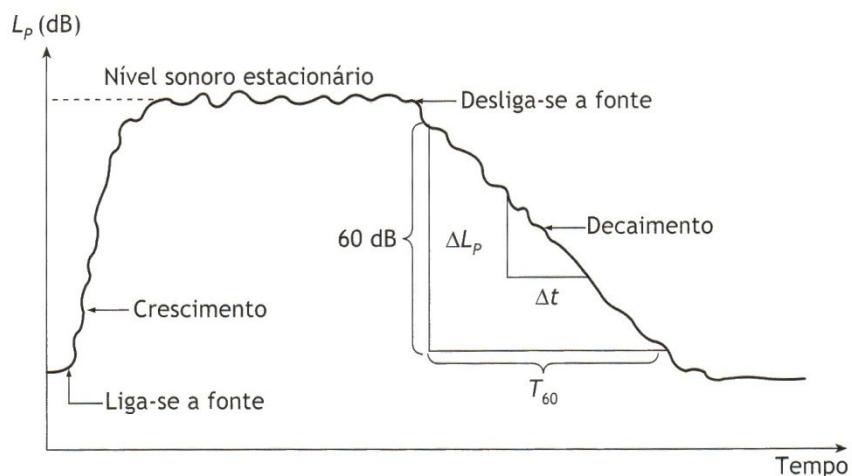


Figura 4.1 – Crescimento e decaimento sonoro em recintos com indicação do tempo de reverberação ( $T_{60}$ ) (BISTAFÁ, 2006).

Portanto a característica temporal de uma sala é relacionada com o tempo de reverberação, sendo dependente do volume espacial e da absorção sonora das superfícies internas, cuja relação é dada pela equação de Sabine.

$$T_{60} = \frac{0.16V}{A} \quad (4.1)$$

onde:

$V$  = Volume do recinto [ $\text{m}^3$ ]

$A$  = Absorção sonora total do recinto [ $\text{Sa} \cdot \text{m}^2$ ]

sendo 1 [Sa] equivalente a 100% de absorção por  $\text{m}^2$ .

### 4.3 Ondas estacionárias e modos acústicos

Uma sala com resposta em frequência ideal é uma sala onde seria possível ouvir todas as frequências com a mesma intensidade, conforme mostra a figura 4.2.

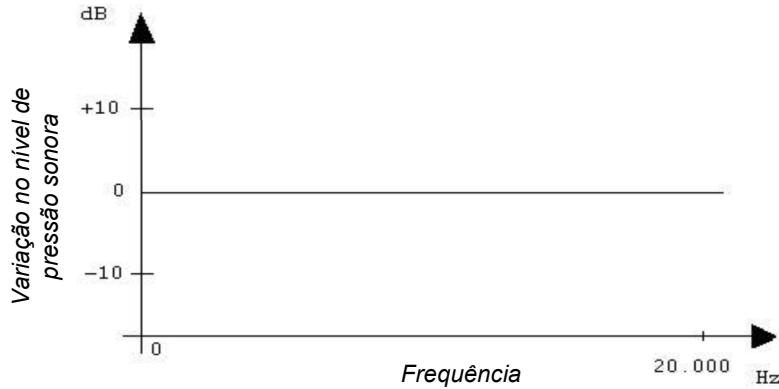


Figura 4.2 – Condição ideal de resposta em frequência.

Entretanto, a resposta de uma sala depende da análise do comportamento quanto ao ganho acústico em certa faixa de frequências, sendo bastante influenciada pelo comprimento de onda, pelas dimensões, pelo formato e pela distância entre a fonte sonora e o receptor. Estes fatores interagem entre si e impedem uma resposta constante na frequência conforme apresentada na fig. 4.2, ocorrendo na prática regiões de picos (ressonâncias) e depressões (antirressonâncias), este comportamento é conhecido como os modos acústicos de uma sala. Os modos são evidenciados em curva de resposta em frequência conforme ilustra a figura 4.3. Na figura destacam-se ainda os modos ( $n_x, n_y, n_z$ ) para as frequências de ressonância abaixo de 80 Hz.

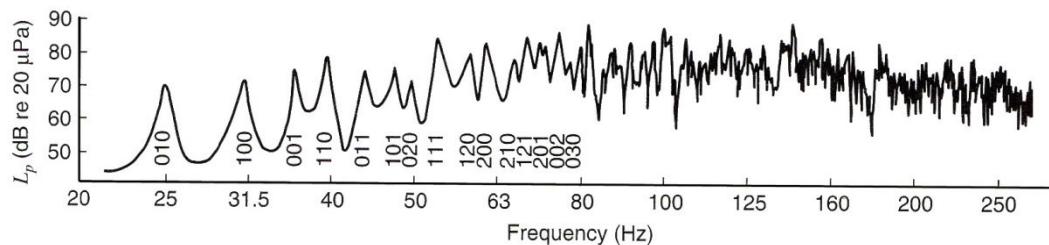


Figura 4.3 – Medição da pressão sonora em função da frequência de uma sala retangular com 180 m<sup>3</sup>. Abaixo de 80 Hz as ressonâncias podem ser identificadas (CROCKER, 2007).

Elevando a frequência de excitação aumenta o número de ressonâncias acústicas na sala e na faixa das altas frequências a ressonância torna-se tão numerosa que elas não

podem se separadas. Em termos da densidade da energia total, o campo sonoro nas regiões distantes da fonte (campo reverberante) torna-se relativamente uniforme e o campo sonoro resultante é essencialmente difuso, sendo descrito em termos estatísticos.

Nas baixas frequências, quando a razão entre o comprimento de onda e dimensão da sala é maior que 0,1 e havendo poucos modos acústicos, o campo sonoro pode ser descrito em termos da superposição dos campos sonoros correspondente a cada modo na faixa de frequência de interesse.

#### 4.3.1 Modos Acústicos

Os modos acústicos são resultantes das reflexões sonoras quando se liga uma fonte em um espaço fechado. Com a fonte ligada, as ondas se espalham pelo ambiente em todas as direções e são refletidas ao encontrar as paredes, geralmente ocorrendo pequena perda de energia. Alguns caminhos percorridos pela onda dentro da sala são repetidos possibilitando iteração com a onda já existente. Quando há coincidência de fase ocorre amplificação da magnitude ou a presença um modo ressonante. Quando há oposição de fase ocorre atenuação ou modo anti ressonante.

Utilizando uma sala de forma retangular pode-se estabelecer um modelo matemático que descreve precisamente as iterações que ocorrem, não sendo válido para salas com formatos irregulares. Neste modelo podem ser definidos os modos normais que são os modos ressonantes que surgem entre duas paredes paralelas. Neste caso quando se tem uma fonte sonora emitindo som na frequência  $f_0$ , surge uma ressonância na frequência  $f_0 = c/2L$ , onde  $c$  é a velocidade do som e  $L$  é a distância entre duas paredes paralelas da sala (BERANEK, 1993).

Ressonâncias similares ocorrerão nas frequências  $2f_0$ ,  $3f_0$ ,  $4f_0$  etc. A frequência  $f_0$  é a frequência fundamental entre duas paredes paralelas e vem acompanhada de uma série de modos com ressonâncias em frequências crescentes a partir de  $f_0$ . Assim tem-se o primeiro modo em  $f_0$ , o segundo em  $2f_0$ , o terceiro em  $3f_0$  e assim por diante. Nesta situação, apenas a ressonância entre duas paredes paralelas está sendo considerada, isto é, apenas os modos axiais. Modos tangenciais envolvem quatro paredes enquanto que modos oblíquos envolvem as seis paredes da sala. A figura 4.4 ilustra os modos, usando o conceito de “raios acústicos”.

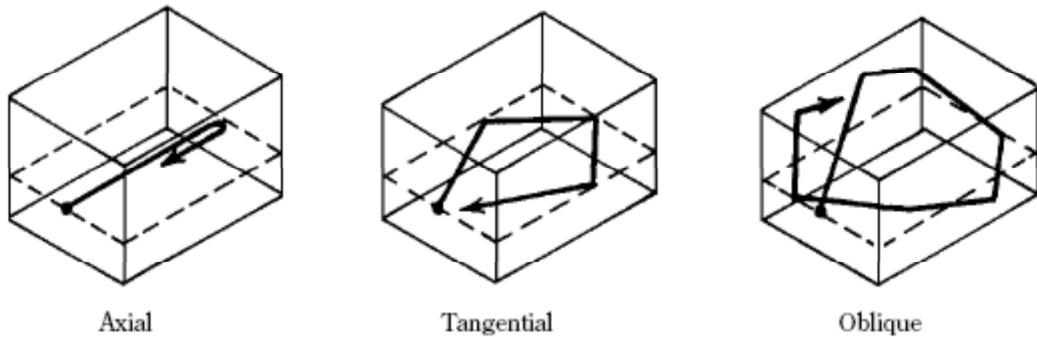


Figura 4.4 – Visualização dos modos usando conceito de “raios acústicos” (CROCKER, 2007).

As frequências para os modos normais podem ser calculadas em função das dimensões da sala retangular sendo dada por:

$$f_n = \frac{\omega_n}{2\pi} = \frac{c}{2} \sqrt{\left(\frac{n_x}{L_x}\right)^2 + \left(\frac{n_y}{L_y}\right)^2 + \left(\frac{n_z}{L_z}\right)^2} = f_{n_x, n_y, n_z} \quad (4.2)$$

onde:

$c$  = velocidade do som [m/s]

$n_x, n_y, n_z$  = valor inteiro que representa o plano do modo

$L_x, L_y, L_z$  = dimensões da sala nas direções  $x, y, z$  [m]

A distribuição da pressão sonora em função de cada frequência normal é proporcional ao produto de três cossenos dado por:

$$P_{n_x, n_y, n_z} = \bar{P}_n \cdot \cos \frac{\pi n_x x}{L_x} \cdot \cos \frac{\pi n_y y}{L_y} \cdot \cos \frac{\pi n_z z}{L_z} \cdot e^{i\omega_n t} \quad (4.3)$$

onde:

$\bar{P}_n$  = pressão de excitação no modo [Pa]

$x, y, z$  = coordenadas nas direções  $x, y, z$  [m]

$n_x, n_y, n_z$  = valor inteiro que representa o plano do modo

$L_x, L_y, L_z$  = dimensões da sala nas direções  $x, y, z$  [m]

Se for considerado como exemplo uma sala retangular com  $5 \times 3 \text{ m}^2$  e 2,5 m de altura, pode-se calcular pela Eq. 4.2 em que o primeiro modo (1,1,0) apresentado na figura 4.5, ocorreria na frequência de 66,47 Hz, o segundo em 68,40 Hz e o terceiro em 89,04 Hz.

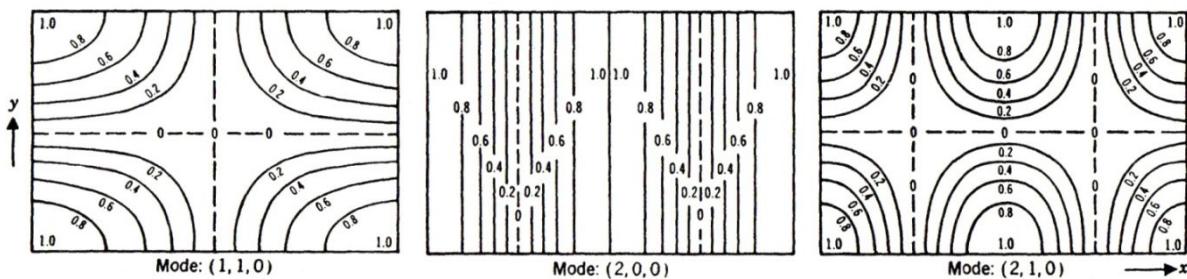


Figura 4.5 – Visualização dos modos normais nas direções x e y de uma sala.

O número de modos que pode ser excitado na faixa de frequência que vai de zero até  $f$  é dado por:

$$N = \frac{4\pi f^3 V}{3c^3} + \frac{\pi f^2 S}{4c^2} + \frac{4(L_x + L_y + L_z)}{8c} f \quad (4.4)$$

onde:

- |                   |  |
|-------------------|--|
| $c$               | = velocidade do som [m/s]                    |
| $V$               | = volume da sala [ $\text{m}^3$ ]            |
| $S$               | = área superficial total [ $\text{m}^2$ ]    |
| $L_x \ L_y \ L_z$ | = dimensões da sala nas direções x, y, z [m] |

#### 4.4 Características acústicas da sala de ensaios

Os ensaios experimentais descritos neste trabalho foram realizados em grande parte utilizando as frequências de excitação sonora em 250, 497 e 730 Hz, numa sala com 4,841 m x 4,023 m e 2,465 m de altura. Os sensores de aquisição ficaram posicionados na altura média de 1,302 m. Pela equação 4.4, o número de modos que pode ser excitado até as frequências indicadas são respectivamente: 117, 762 e 2263 modos.

Para se ter uma noção da distribuição acústica em torno dos sensores, foram realizadas análises modais em cada frequência de excitação. Inicialmente foi considerando um modelo teórico dado pela equação 4.3 e posteriormente, simulação numérica utilizando o software Ansys®, onde foram incorporados detalhes estruturais, de absorção e de *layout*.

Para melhor exatidão na simulação, foi considerado um modelo tridimensional de elementos finitos. Como elementos estruturais foram considerados: porta, janela, teto, piso, paredes e uma mesa. Para os materiais foram configurados: concreto para piso e colunas, PVC para o teto, madeira para porta e mesa, vidro para janelas e alvenaria para paredes. O modelo estrutural pode ser visualizado na figura 4.6(a).

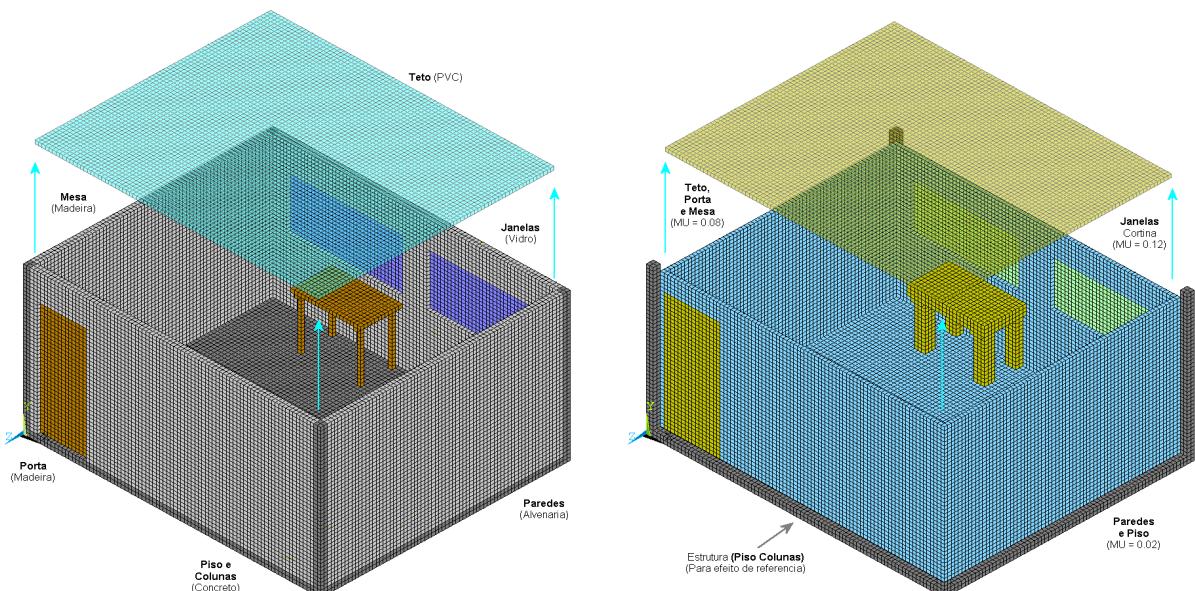


Figura 4.6 – (a) Modelo numérico estrutural da sala com os respectivos materiais empregados. (b) Elementos de fluido em contato com a estrutura presente pelo lado interno. Os elementos do teto foram deslocados para efeito de visualização.

A figura 4.6(b) ilustra os elementos de fluido em contato com a parte estrutural, sendo estes os responsáveis pela iteração fluido estrutura. Para os elementos de fluido foram considerados as seguintes condições de absorção: 0,02 para o fluido em contato com paredes e piso; 0,08 para madeira e teto; 0,12 para vidro (cortina) e 1,00 para absorção total.

Embora não indicado, o espaço vazio no interior da fig. 4.6(b) é totalmente preenchido por elementos do fluido sem contato com os elementos estruturais, sendo estes os responsáveis pelo campo acústico. A simulação numérica considera ar como fluido e o campo acústico gerado é proveniente da excitação sonora de 1,00 Pa, localizado no canto superior esquerdo das figuras 4.7(b) e 4.9(b) na altura de 0,250 m do piso.

As figuras 4.7(a) a 4.9(a) apresentam a componente real do modo mais próximo da frequência de excitação, obtidas analiticamente. No cálculo considerou-se a pressão de excitação em 1,00 Pa (94 dB). Como observação, a equação 4.3 considera um modelo de sala retangular sem que haja qualquer outro detalhe geométrico e não considera a absorção em superfícies.

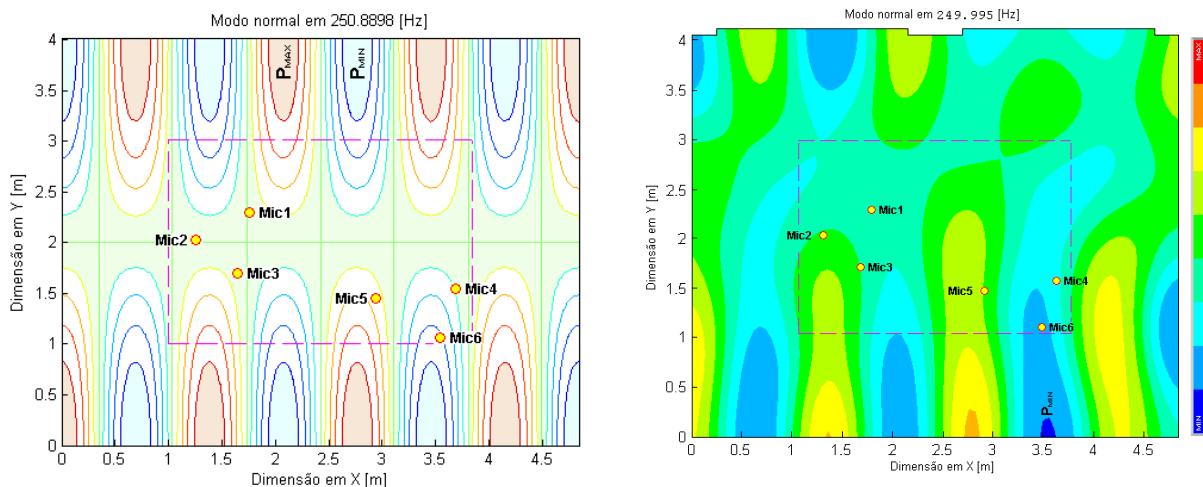


Figura 4.7 – Modo normal mais próximo da frequência de excitação em 250 Hz obtidos pela:  
(a) Equação analítica. ( $P_{\text{MAX}} / \text{MIN} = \pm 1,00 \text{ Pa}$ ). (b) Simulação numérica.

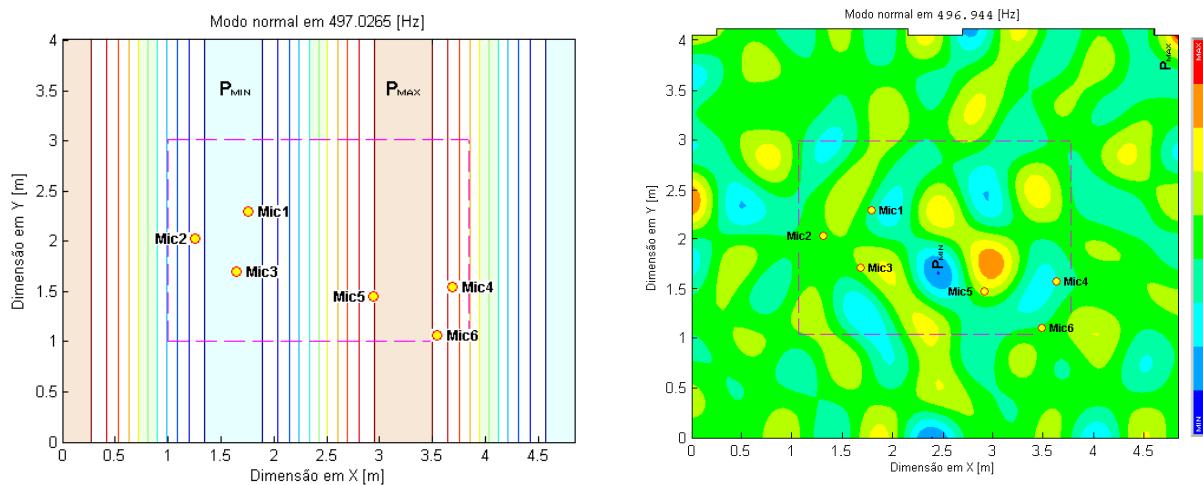


Figura 4.8 – Modo normal mais próximo da frequência de excitação em 497 Hz obtidos pela:  
(a) Equação analítica. ( $P_{\text{MAX}} / \text{MIN} = \pm 0,58 \text{ Pa}$ ). (b) Simulação numérica.

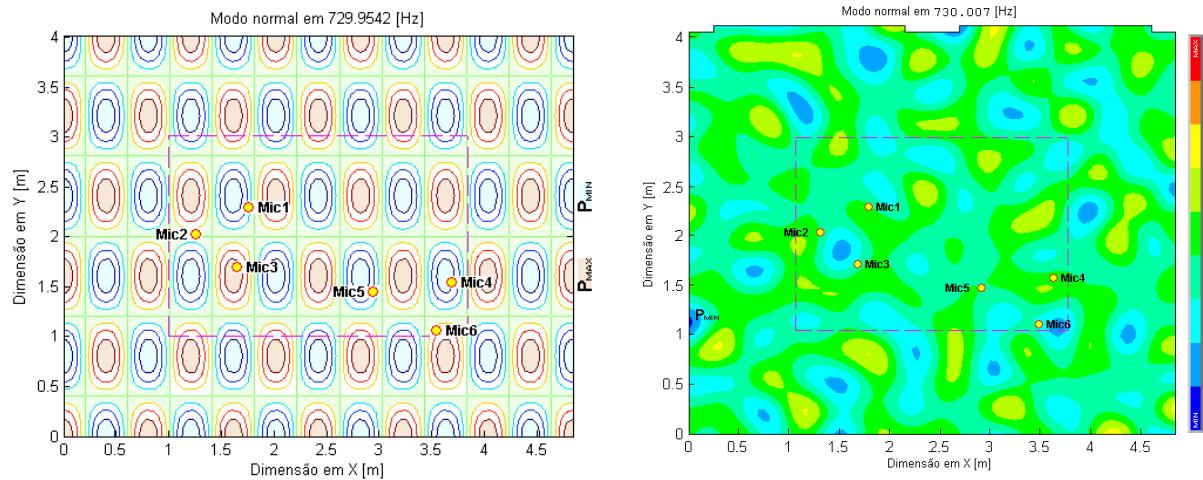


Figura 4.9 – Modo normal mais próximo da frequência de excitação em 730 Hz obtidos pela:  
(a) Equação analítica. ( $P_{\text{MAX}} / \text{MIN} = \pm 0,76 \text{ Pa}$ ). (b) Simulação numérica.

Ao comparar os modos normais das figuras. 4.7 a 4.9 notam-se divergências no aspecto e no valor. Os resultados são diferentes pois utilizam-se modelos distintos: o primeiro é analítico e simplificado e o segundo obtido por simulação numérica onde se incorporou detalhes estruturais, materiais e absorção.

Para evitar posicionar sensores nas as regiões anti-ressonantes, foram realizadas ainda as análises harmônicas nas frequências de excitação, utilizando o modelo numérico como mostra as figuras 4.10 a 4.12.

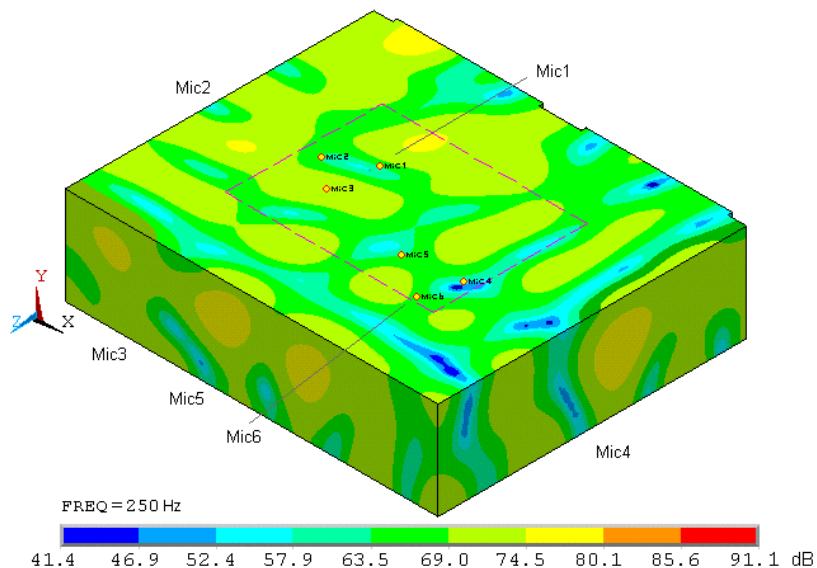


Figura 4.10 – Campo acústico em torno dos sensores em 250 Hz.

A figura 4.10 indica excitação na faixa de 47 dB (para o sensor Mic4) até 75 dB (para o Mic3) estando a fonte em 94 dB.

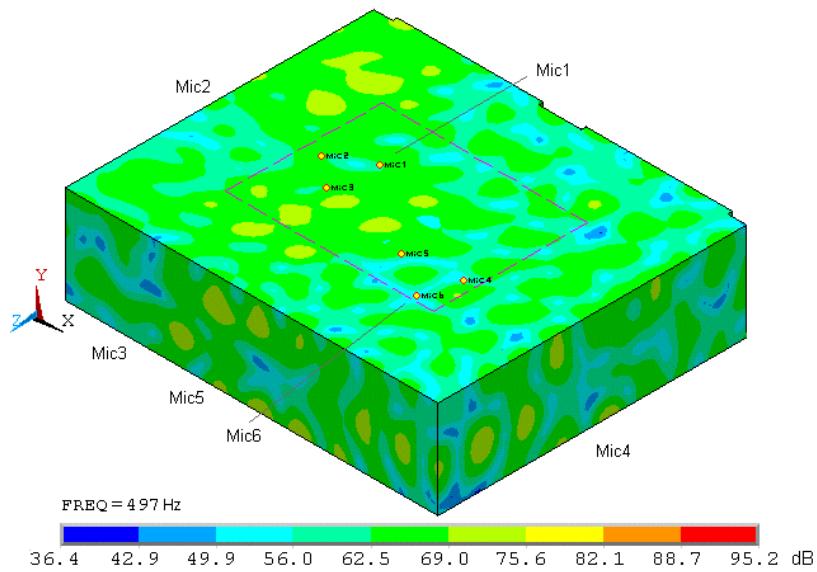


Figura 4.11 – Campo acústico em torno dos sensores em 497 Hz.

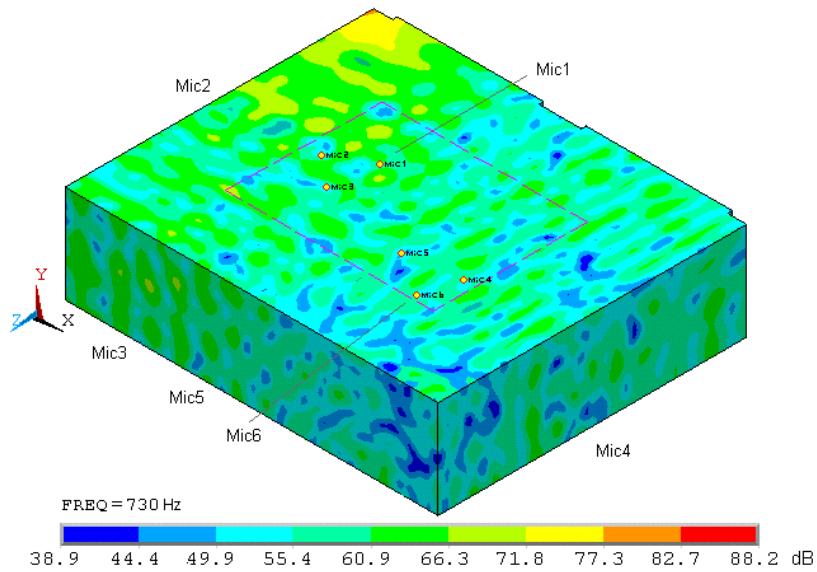


Figura 4.12 – Campo acústico em torno dos sensores em 730 Hz.

Nota-se que a distribuição do campo acústico torna-se difuso ao elevar a frequência de excitação, sendo afetado ainda pela distribuição das formas geométricas e dos materiais no ambiente.

# CAPÍTULO V

## ANÁLISE DE SENSIBILIDADE DE PARAMETROS

### 5.1 Apresentação

Em campo livre a propagação sonora a partir de uma fonte pontual é esférica e sua intensidade depende apenas da impedância do meio e da forma de onda, assim, a frente da onda movimenta-se livremente sem perturbações. Por outro lado, quando a onda incidente é obstruída nos ambientes fechados, esta se divide em uma parte refletida, uma parcela absorvida e outra transmitida, mantendo-se o balanço de energia. A interação da onda incidente com as múltiplas reflexões estabelece o campo reverberante, sendo este, dependente ainda dos materiais e das geometrias no ambiente.

Desta forma, tem-se o sentimento de que os materiais e o *layout* possuem uma grande influência na acústica de salas e qualquer mudança destes irá alterar as características de reverberação e de propagação sonora no ambiente. Assim, a proposta deste capítulo é investigar e avaliar quais os fatores que perturbam de forma relevante a acústica e quais fatores que poderiam ser desprezados.

Sabe-se que em um ambiente qualquer, a geração de um sinal acústico é o bastante para estabelecer a função de transferência entre o emissor e o receptor. No entanto, ocorrendo perturbações a característica do sinal muda. Ao estabelecer os fatores críticos, espera-se então, gerar sinais acústicos que reproduzem as características da dinâmica variacional e assim abranger uma faixa ou região regida por estes fatores críticos. Amostras das características relevantes seriam utilizadas na fase de treinamento de uma rede neural para obter uma estimativa mais robusta devido aos desvios do ambiente original.

## 5.2 Conceitos teóricos

Um dos problemas na experimentação é determinar a influência de uma ou mais variáveis sobre a resposta. Em geral, os fatores são as variáveis que o experimentador tem condições de controlar e as respostas são as saídas do sistema podendo ser afetadas ou não pelos fatores. Para um experimento é importante especificar fatores de influência e ao menos dois nível em que cada fator será estudado. O efeito de um fator será observado na resposta ao variar o seu nível. Assim  $k$  variáveis em dois níveis irão produzir  $2^k$  experimentos, técnica conhecida como planejamento fatorial  $2^k$ . (BARBETTA *et al.*; 2010)

O modelo estatístico usado para descrever um planejamento fatorial é formulado em torno dos efeitos  $x_1, x_2, \dots, x_k$  fornecendo a resposta  $y(x_1, x_2, \dots, x_k)$ . Esta resposta se distribui em torno de uma media populacional  $\mu(x_1, x_2, \dots, x_k)$  e com variância  $\sigma^2(x_1, x_2, \dots, x_k)$ , onde pode-se escrever  $y(x_1, x_2, \dots, x_k) = \mu(x_1, x_2, \dots, x_k) + \varepsilon(x_1, x_2, \dots, x_k)$ , sendo  $\varepsilon(\cdot)$ , o erro aleatório em torno da média (BARROS NETO *et al.*; 2010)

Supondo  $k = 3$  fatores como exemplo para um planejamento fatorial, o modelo postula que a media populacional  $\mu(x_1, x_2, x_3)$  é representada adequadamente pela expressão:

$$y(x_1, x_2, x_3) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{12} x_1 x_2 + \beta_{13} x_1 x_3 + \beta_{23} x_2 x_3 + \beta_{123} x_1 x_2 x_3 + \varepsilon(x_1, x_2, x_3) \quad (5.1)$$

onde:

$\beta_0$  é o valor populacional da media de todas as respostas do planejamento;

$\beta_1, \beta_2, \beta_3$  são os valores populacionais dos efeitos principais;

$\beta_{12}, \beta_{13}, \beta_{23}$  e  $\beta_{123}$  são os valores populacionais dos efeitos de duas e três interações e

$\varepsilon$  o erro aleatório associado à resposta.

Para determinar os valores dos  $\beta$ 's são necessários um número infinito de experimentos, entretanto o que podemos calcular a partir de  $2^3 = 8$  experimentos são apenas as estimativas destes valores e portanto:

$$\hat{y}(x_1, x_2, x_3) = \mathbf{X}\mathbf{b} \quad (5.2)$$

onde:

$$\mathbf{X} = [1 \ x_1 \ x_2 \ x_3 \ x_1 x_2 \ x_1 x_3 \ x_2 x_3 \ x_1 x_2 x_3] \text{ e}$$

$$\mathbf{b} = [b_0 \ b_1 \ b_2 \ b_3 \ b_1 b_2 \ b_1 b_3 \ b_2 b_3 \ b_1 b_2 b_3]^T$$

Considerando uma superfície de respostas suave, pequenas variações dos fatores não causariam variações abruptas na resposta. Assim pode-se esperar que iterações entre os fatores terão peso menor do que os fatores principais. Um critério para separar efeitos relevantes dos ruídos é considerar a probabilidade cumulativa dos efeitos, dada pela equação:

$$f(x)dx = \frac{1}{\sigma\sqrt{2\pi}} e^{\frac{-(x-\mu)^2}{2\sigma^2}} dx \quad (5.3)$$

onde:

- $\mu$  é a média populacional;
- $\sigma$  é a variância populacional e
- $x$  é a variável aleatória.

Ao aplicar o teorema do limite central pode-se considerar os efeitos como uma amostra aleatória retirada de uma distribuição aproximadamente normal de media populacional zero. Desta forma os efeitos da população normal de media zero, são caracterizados como ruídos ou sem significado. Os efeitos distantes da media zero não pertencem a esta população sendo considerados como significativos. Por outro lado, os efeitos de menor relevância podem ser utilizados para estimar o erro experimental. Elevando-se cada um ao quadrado, tem-se uma estimativa da variância de um efeito. A média dos “n” valores dá a estimativa conjunta com “n” graus de liberdade, portanto:

$$V(efeito) = \frac{(efeito\_1)^2 + (efeito\_2)^2 + \dots + (efeito\_n)^2}{n} \quad (5.4)$$

$$Estimativa\ erro \cong \sqrt{V(efeito)} \quad (5.5)$$

### 5.3 Fatores de influência e metodologia

Os ensaios foram realizados em uma sala vazia, com portas e janelas fechadas para geração dos sinais de treinamento de uma rede neural. Porém, para avaliar os desvios das características originais da sala, foram consideradas alterações nos seguintes fatores: ocupação da sala, movimentação interna de pessoas, abertura de janelas e porta.

Outros fatores como frequência de excitação, amplitude do sinal, posicionamento da fonte e de sensores não foram considerados, pois é sabido que os sinais são bastante

afetados pela variação destes. Fatores como temperatura, densidade do ar e umidade, não foram considerados por não ser possível controlar o nível destes durante os ensaios.

Diversos outros fatores poderiam ter sido considerados, tais como: presença de pessoas na sala, conversa interna, ventilação forçada (deslocamento de ar), outras fontes de ruído, etc. Destaca-se que a quantidade de fatores pode ser bastante elevada e complexa e embora possam ser relevantes, iriam acarretar em uma grande quantidade de ensaios para avaliar as influências inicialmente propostas. Estes e outros fatores poderão ser avaliados em trabalhos futuros.

Para avaliação das influências foi definido um planejamento fatorial de dois níveis considerando os quatro fatores definidos inicialmente. Foi realizado ainda um sorteio da ordem em que cada experimento seria executado para garantir aleatoriedade e para que os dados sejam estatisticamente independentes. Barros Neto *et al.*, (2010) mostram como definir um planejamento fatorial de dois níveis. Para os níveis foram definidos:

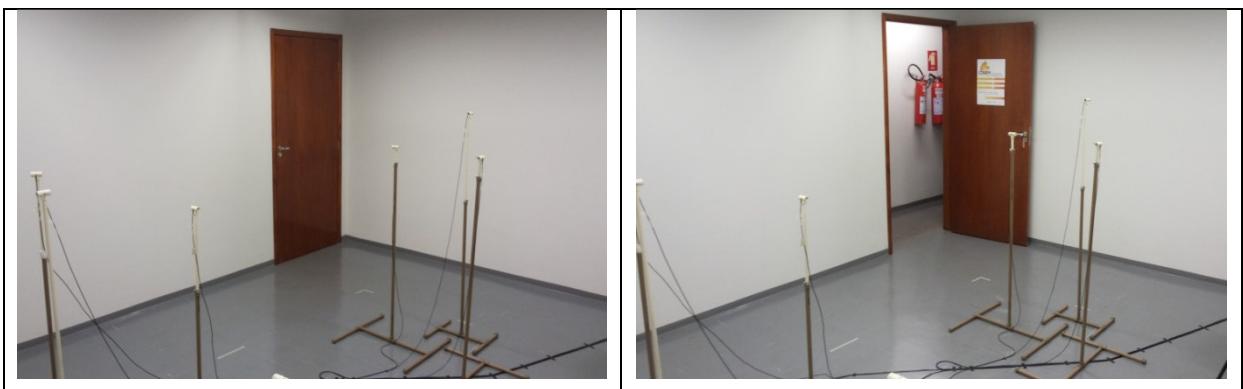


Figura 5.1 – (a) Sala vazia com porta fechada, corresponde ao nível (+). (b) com porta aberta, corresponde ao nível (-).



Figura 5.2 – (a) Sala vazia com janela fechada, corresponde ao nível (+). (b) com janela aberta, corresponde ao nível (-).

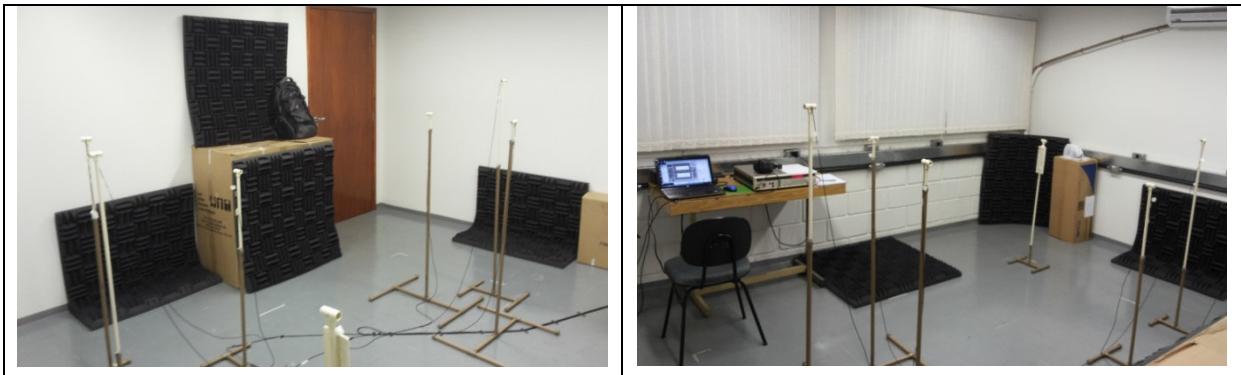


Figura 5.3 – Sala ocupada, corresponde ao nível (–). As placas ilustradas são espumas com propriedades de absorção sonora, sendo: 8 unidades x 1,0 x 1,0 m<sup>2</sup>. Para a sala vazia foi definido o nível (+).

Para o fator movimentação foi definido o nível (+) quando uma pessoa andava pela sala durante o ensaio e o nível (–) sem esta movimentação.

#### 5.4 Instrumentação utilizada

A instrumentação utilizada neste e nos capítulos subsequentes foram listadas no Apêndice B: No entanto as configurações específicas de ajuste, aquisição, posicionamento e quantidade de sensores utilizados, serão detalhadas oportunamente.

#### 5.5 Ensaios realizados

Foram gerados sinais harmônicos na frequência de 250 Hz e 730 Hz como mostrado nas tabelas 5.1 e 5.2. Na geração dos sinais, utilizou-se amplitude de excitação de 15 volts no gerador DS360, aquisição na faixa de 0 a 1640 Hz com 8192 pontos e frequência de corte em 800 Hz. O sinal de excitação foi medido na membrana do alto falante por um acelerômetro e a resposta obtida pelo microfone *Brüel & Kjær*. O sinal de geração no DS360 foi utilizado como parâmetro de referência para o sinal de excitação. As posições dos sensores neste estudo foram mantidas inalteradas e as temperaturas durante os ensaios foram anotadas. A ordem dos ensaios foi aleatorizada, exceto o fator de ocupação para poder manter o mesmo *layout* nas aquisições. Utilizaram-se dois níveis de frequência para estudar o comportamento das influências em baixa e média frequência

Como parâmetro de avaliação utilizou-se: o nível RMS nas respostas no tempo, a magnitude e a fase para as respostas em frequência. Para avaliar a qualidade do sinal de

excitação, os dados foram comparados com o sinal gerado no DS360. Na base das tabelas 6.1 e 6.2 mostra a estatística dos sinais, onde se destaca o baixo coeficiente de variação devido a baixa dispersão no sinal de entrada.

Tabela 5.1 – Resultados do planejamento experimental na frequência de excitação em 250 Hz. A tabela indica a ordem em que foram realizados os ensaios.

Fatores					( + )		( - )		Temp. [°C]		
A: Porta					Fechada		Aberta				
B: Movimentação					Com		Sem				
C: Janela					Fechada		Aberta				
D: Ocupação					Vazia		Ocupada				
No.	A	B	C	D	Sinal de Excitação		Sinal de resposta		Temp. [°C]		
					RMS	FRF (DS360/Veloc.)	RMS	FRF (Mic6/Veloc.)			
Mag.	Fase	Mag.	Fase								
1	+1	+1	-1	+1	83,808	3,270	-91,41	0,245	0,690	-34,12	29,0
2	-1	-1	+1	+1	83,534	3,298	-91,78	0,135	0,389	-96,34	29,0
3	+1	+1	+1	+1	84,377	3,268	-91,42	0,183	0,440	-70,66	29,5
4	+1	-1	+1	+1	84,278	3,282	-91,46	0,168	0,477	-70,04	30,0
5	-1	+1	+1	+1	83,974	3,293	-91,64	0,147	0,353	-90,39	29,5
6	+1	-1	-1	+1	84,205	3,288	-91,13	0,215	0,624	-21,15	29,5
7	-1	+1	-1	+1	84,166	3,292	-91,39	0,158	0,424	-73,76	29,5
8	-1	-1	-1	+1	84,127	3,286	-91,33	0,153	0,439	-78,14	29,5
9	+1	-1	+1	-1	83,216	3,333	-91,19	0,211	0,618	-74,78	29,0
10	+1	-1	-1	-1	84,194	3,296	-91,14	0,171	0,497	-77,12	29,5
11	+1	+1	-1	-1	84,895	3,273	-90,94	0,188	0,527	-82,81	29,5
12	-1	-1	-1	-1	85,447	3,260	-91,00	0,186	0,534	-103,30	29,0
13	-1	-1	+1	-1	84,764	3,288	-91,25	0,202	0,586	-95,65	29,0
14	+1	+1	+1	-1	82,959	3,357	-91,52	0,229	0,672	-78,89	29,0
15	-1	+1	+1	-1	83,391	3,339	-91,68	0,201	0,564	-96,16	29,0
16	-1	+1	-1	-1	83,491	3,332	-91,68	0,188	0,524	-109,40	29,5
Media					84,052	3,297	-91,37	0,186	0,522	-78,29	29,3
Desvio Padrão					0,651	0,028	0,25	0,030	0,099	23,21	0,3
Coef Variação [%]					0,8	0,9	0,3	16,3	19,0	29,6	1,1

Tabela 5.2 – Resultados do planejamento experimental na frequência de excitação em 730 Hz. A tabela indica a ordem em que foram realizados os ensaios.

Fatores					( + )			(-)			
<b>A:</b> Porta					Fechada			Aberta			
<b>B:</b> Movimentação					Com			Sem			
<b>C:</b> Janela					Fechada			Aberta			
<b>D:</b> Ocupação					Vazia			Ocupada			
No.	A	B	C	D	Sinal de Excitação			Sinal de resposta			Temp. [°C]
					RMS	FRF (DS360/Veloc.)		RMS	FRF (Mic6/Veloc.)		
						Mag.	Fase		Mag.	Fase	
17	+1	-1	+1	-1	185,359	5,160	-64,55	0,293	1,142	76,41	29,0
18	+1	-1	-1	-1	186,604	5,124	-64,39	0,126	0,482	93,07	29,0
19	+1	+1	-1	-1	186,013	5,149	-64,26	0,161	0,480	91,74	29,0
20	-1	-1	-1	-1	182,701	5,240	-64,12	0,073	0,243	51,30	29,5
21	-1	-1	+1	-1	181,984	5,262	-64,13	0,175	0,671	51,21	29,0
22	+1	+1	+1	-1	181,895	5,264	-63,87	0,256	0,984	75,54	29,0
23	-1	+1	+1	-1	182,278	5,251	-63,71	0,201	0,725	74,53	29,0
24	-1	+1	-1	-1	181,256	5,278	-63,59	0,092	0,240	87,16	29,0
25	+1	+1	-1	+1	181,640	5,201	-58,07	0,191	0,119	-37,17	29,0
26	-1	-1	+1	+1	175,962	5,399	-60,17	0,185	0,760	179,30	29,5
27	+1	+1	+1	+1	177,416	5,531	-61,17	0,228	0,823	132,24	30,0
28	+1	-1	+1	+1	180,363	5,255	-61,10	0,207	0,814	141,10	30,5
29	-1	+1	+1	+1	178,219	5,320	-60,35	0,167	0,611	-169,80	30,5
30	+1	-1	-1	+1	174,615	5,426	-60,57	0,071	0,236	-153,50	31,0
31	-1	+1	-1	+1	175,778	5,392	-60,74	0,177	0,658	-172,90	31,0
32	-1	-1	-1	+1	176,639	5,361	-60,66	0,186	0,749	-154,40	31,0
Media					180,545	5,288	-62,22	0,174	0,609	22,86	29,7
Desvio Padrão					3,763	0,111	2,05	0,061	0,290	119,92	0,8
Coef Variação [%]					2,1	2,1	3,3	35,1	47,6	524,5	2,8

OBS: Os sinais de 25 a 32 foram obtidos no dia posterior devido a variação do tempo. Começou a ventar e afetar as medições com ruído, principalmente com a janela aberta.

Observe que o coeficiente de variação aumenta indicando uma elevação da dispersão. O coeficiente de variação é obtido dividindo o Desvio Padrão pela Média, indicando que o desvio padrão é proporcionalmente maior na resposta do que na excitação. Isso já é um indicativo de que os fatores utilizados afetam os sinais.

## 5.6 Análise dos resultados

Para determinar a combinação dos fatores, multiplicamos as colunas da matriz de planejamento elemento a elemento das tabelas 5.1 e 5.2. Primeiro combina-se duas a duas, três a três e por ultimo as quatro colunas dos fatores principais.

### 5.6.1 Análise dos efeitos combinados para a frequência de 250 Hz

A tabela 5.3 apresenta a matriz de efeitos obtidos na frequência de 250 Hz e calcula-se a interação entre eles. Como não houve repetição nos ensaios, o erro experimental pode ser estimado supondo que a superfície de resposta seja bastante suave e que pequenas variações nos fatores não causam variações abruptas nas respostas. Sendo assim pode-se esperar que os coeficientes de menor ordem de um modelo sejam mais significativos do que os coeficientes de alta ordem.

Tabela 5.3 – Matriz da combinação de fatores para a frequência de excitação de 250 Hz. No rodapé da tabela é consolidado o cálculo dos efeitos para cada associação de fatores.

MATRIZ DOS EFEITOS																
Media	A	B	C	D	AB	AC	AD	BC	BD	CD	ABC	ABD	ACD	BCD	ABCD	
1	1	1	1	-1	1	1	-1	1	-1	-1	-1	1	-1	-1	-1	-1
2	1	-1	-1	1	1	1	-1	-1	-1	1	1	1	-1	-1	-1	1
3	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
4	1	1	-1	1	1	-1	1	1	-1	-1	1	-1	-1	1	-1	-1
5	1	-1	1	1	1	-1	-1	-1	1	1	-1	-1	-1	1	-1	-1
6	1	1	-1	-1	1	-1	-1	1	1	-1	1	-1	-1	1	1	1
7	1	-1	1	-1	1	-1	1	-1	-1	1	-1	1	-1	1	-1	1
8	1	-1	-1	-1	1	1	1	-1	1	-1	-1	-1	1	1	1	-1
9	1	1	-1	1	-1	-1	1	-1	-1	1	-1	-1	1	-1	1	1
10	1	1	-1	-1	-1	-1	-1	-1	1	1	1	1	1	1	-1	-1
11	1	1	1	-1	-1	1	-1	-1	-1	1	-1	-1	1	1	1	1
12	1	-1	-1	-1	-1	1	1	1	1	1	1	-1	-1	-1	-1	1
13	1	-1	-1	1	-1	1	-1	1	-1	1	-1	1	-1	1	1	-1
14	1	1	1	1	-1	1	1	-1	1	-1	-1	1	-1	-1	-1	-1
15	1	-1	1	1	-1	-1	-1	1	1	-1	-1	-1	1	1	-1	1
16	1	-1	1	-1	-1	-1	1	1	-1	-1	1	1	1	-1	1	-1
<b>RMS</b>	0,186	0,030	0,012	-0,003	-0,022	0,008	-0,003	0,024	-0,001	0,003	-0,031	-0,002	-0,001	-0,017	-0,001	-0,003
<b>MAG</b>	0,522	0,091	0,004	-0,020	-0,086	0,024	-0,013	0,065	-0,014	-0,009	-0,110	-0,006	-0,005	-0,056	-0,017	-0,015
<b>FASE</b>	-78,294	29,196	-2,459	-11,639	22,939	-3,389	-8,154	6,469	2,636	1,644	-18,426	0,846	-2,591	-4,496	0,844	1,849

Considerando os efeitos principais e supondo que a interação de dois fatores basta para descrever a superfície de resposta, o erro experimental é estimado usando os efeitos de 2<sup>a</sup> e 3<sup>a</sup> ordem (ver o tópico 5.2). A tabela 5.4 apresenta a estimativa do erro obtida conforme esta premissa e os efeitos da tabela 5.3 em ordem crescente.

Pela tabela 5.4, pode-se realizar ainda uma análise gráfica para distinguir os efeitos relevantes dos ruídos de aquisição. Esta análise se baseia na noção de probabilidade acumulativa pela amostragem aleatória dos elementos, dada uma distribuição normal padronizada.

Tabela 5.4 – Correspondência entre os efeitos calculados com os valores de probabilidade acumulativa e a variável  $z$ . Os efeitos estão em ordem crescente para cada parâmetro avaliado, com os respectivos fatores associados.

Efeito	RMS	Efeito	MAG	Efeito	FASE	Região de Probab. Acumulativa	Ponto Central	$z$
CD	-0,031	CD	-0,110	CD	-18,426	0,07	0,03	-1,83
D	-0,022	D	-0,086	C	-11,639	0,13	0,10	-1,28
ACD	-0,017	ACD	-0,056	AC	-8,154	0,20	0,17	-0,97
AC	-0,003	C	-0,020	ACD	-4,496	0,27	0,23	-0,73
C	-0,003	BCD	-0,017	AB	-3,389	0,33	0,30	-0,52
ABCD	-0,003	ABCD	-0,015	ABD	-2,591	0,40	0,37	-0,34
ABC	-0,002	BC	-0,014	B	-2,459	0,47	0,43	-0,17
BC	-0,001	AC	-0,013	BCD	0,844	0,53	0,50	0,00
BCD	-0,001	BD	-0,009	ABC	0,846	0,60	0,57	0,17
ABD	-0,001	ABC	-0,006	BD	1,644	0,67	0,63	0,34
BD	0,003	ABD	-0,005	ABCD	1,849	0,73	0,70	0,52
AB	0,008	B	0,004	BC	2,636	0,80	0,77	0,73
B	0,012	AB	0,024	AD	6,469	0,87	0,83	0,97
AD	0,024	AD	0,065	D	22,939	0,93	0,90	1,28
A	0,030	A	0,091	A	29,196	1,00	0,97	1,83
Erro	0,008		0,027		2,521			

OBS: No rodapé da tabela tem-se a estimativa do erro experimental com 5 graus de liberdade

Os gráficos das figuras 5.4 e 5.5 mostram que os pontos centrais se ajustam a uma reta que cruza a probabilidade em 50%, próximo ao ponto zero do eixo das abscissas. Faz sentido considerar estes pontos como provenientes de uma população normal de média zero, ou efeitos sem relevância de significado. Os efeitos distantes da média zero são interpretados como significativos, pois não pertence à mesma população que produziu os pontos centrais.

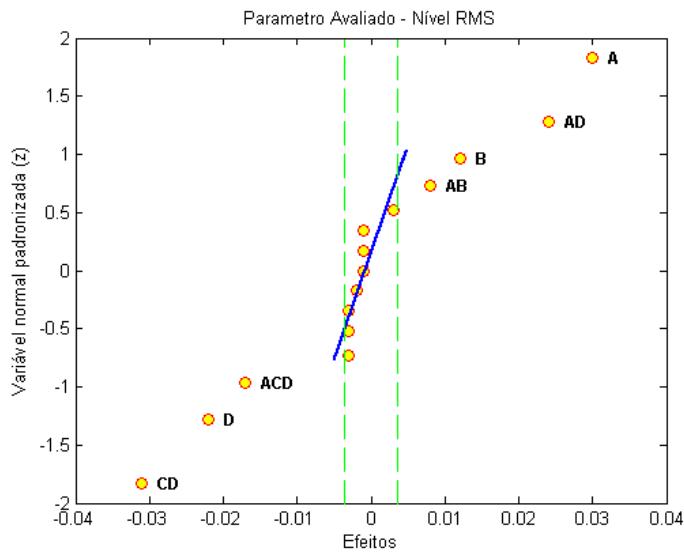


Figura 5.4 – Gráfico normal dos valores significativos para o nível RMS.

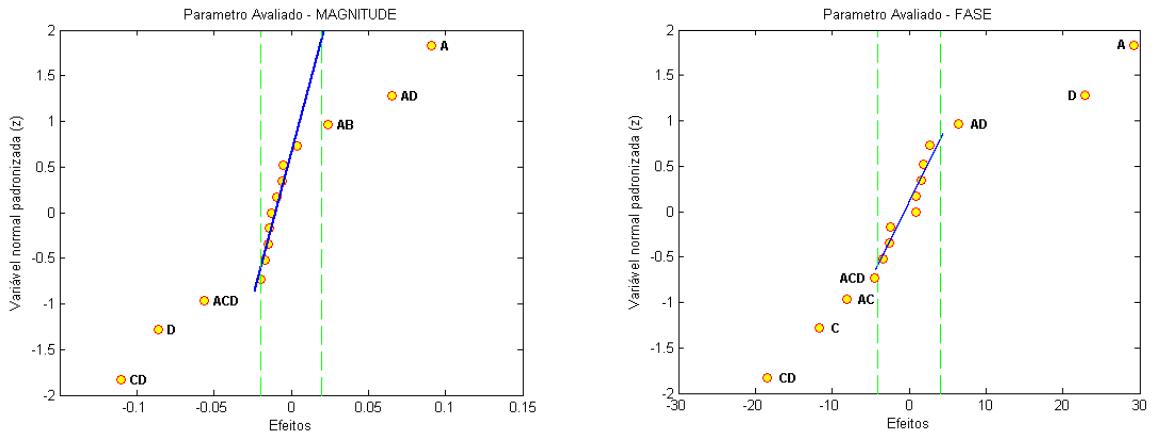


Figura 5.5 – Gráfico normal dos valores significativos para: (a) Magnitude e (b) Fase.

Para o nível RMS do sinal, nota-se que os efeitos CD, D, ACD, AB, B, AD e A, são significativos. Os fatores de segunda ordem (CD, AB e AD) e o fator de terceira ordem (ACD) dependem do fator principal C e portanto, não poderão ser descartados no modelo. Assim os quatro fatores principais tem influência na resposta sonora.

Utilizando a mesma avaliação para a magnitude e a fase do sinal, verifica-se também que todos os fatores principais afetam a resposta em baixa frequência. Assim de forma geral, os fatores A, B, C, D, AB, AC, AD, CD e ACD são relevantes nos 03 parâmetros avaliados.

### 5.6.2 Análise dos efeitos combinados para a frequência de 730 Hz

Utilizando o mesmo procedimento descrito anteriormente foi gerada a tabela 5.5 da matriz de efeitos para a frequência de 730 Hz. De forma semelhante, o erro experimental foi estimado utilizando os efeitos de alta ordem, mediante a suposição de uma superfície de resposta suave.

Tabela 5.5 – Matriz da combinação de efeitos para a frequência de excitação de 730 Hz.

MATRIZ DOS EFEITOS																
Media	A	B	C	D	AB	AC	AD	BC	BD	CD	ABC	ABD	ACD	BCD	ABCD	
<b>1</b>	1	1	-1	1	-1	-1	1	-1	-1	1	-1	-1	1	-1	1	1
<b>2</b>	1	1	-1	-1	-1	-1	-1	-1	1	1	1	1	1	-1	-1	
<b>3</b>	1	1	1	-1	-1	1	-1	-1	-1	1	-1	-1	1	1	1	
<b>4</b>	1	-1	-1	-1	-1	1	1	1	1	1	-1	-1	-1	-1	1	
<b>5</b>	1	-1	-1	1	-1	1	-1	1	-1	1	1	-1	1	1	-1	
<b>6</b>	1	1	1	1	-1	1	1	-1	1	-1	-1	1	-1	-1	-1	
<b>7</b>	1	-1	1	1	-1	-1	-1	1	1	-1	-1	1	1	-1	1	
<b>8</b>	1	-1	1	-1	-1	-1	1	1	-1	-1	1	1	-1	1	-1	
<b>9</b>	1	1	1	-1	1	1	-1	1	-1	1	-1	-1	1	-1	-1	
<b>10</b>	1	-1	-1	1	1	1	-1	-1	-1	1	1	1	-1	-1	1	
<b>11</b>	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	
<b>12</b>	1	1	-1	1	1	-1	1	1	-1	1	-1	-1	1	-1	-1	
<b>13</b>	1	-1	1	1	1	-1	-1	-1	1	1	1	-1	-1	-1	1	
<b>14</b>	1	1	-1	-1	1	-1	-1	1	1	-1	-1	1	-1	-1	1	
<b>15</b>	1	-1	1	-1	1	-1	1	-1	-1	1	-1	1	-1	1	-1	
<b>16</b>	1	-1	-1	-1	1	1	1	-1	1	-1	-1	1	1	1	-1	
<b>RMS</b>	0,174	0,035	0,019	0,079	0,005	0,015	0,029	-0,039	-0,022	0,009	-0,039	-0,021	0,027	0,017	-0,005	-0,001
<b>MAG</b>	0,609	0,053	-0,057	0,416	-0,024	-0,010	0,196	-0,249	-0,004	-0,030	-0,104	-0,004	0,043	0,133	0,021	0,050
<b>FASE</b>	22,864	59,129	-25,394	94,404	-104,51	51,711	13,384	40,989	-58,484	-39,639	105,79	27,301	67,056	18,419	-55,464	24,051

A tabela 5.6 consolida os efeitos da tabela 5.5 em ordem crescente e a estimativa do erro. Como anteriormente, os dados da tabela 5.6, podem ser utilizados para realizar uma análise gráfica objetivando distinguir os efeitos relevantes dos ruídos de aquisição com base na probabilidade acumulativa de uma distribuição normal padronizada.

Tabela 5.6 – Correspondência entre os efeitos calculados com os valores de probabilidade acumulativa e a variável z. Os efeitos estão em ordem crescente para cada parâmetro avaliado, com os respectivos fatores associados.

Efeito	RMS	Efeito	MAG	Efeito	FASE	Região de Probab. Acumulativa	Ponto Central	z
AD	-0,039	AD	-0,249	D	-104,51	0,07	0,03	-1,83
CD	-0,039	CD	-0,104	BC	-58,484	0,13	0,10	-1,28
BC	-0,022	B	-0,057	BCD	-55,464	0,20	0,17	-0,97
ABC	-0,021	BD	-0,030	BD	-39,639	0,27	0,23	-0,73
BCD	-0,005	D	-0,024	B	-25,394	0,33	0,30	-0,52
ABCD	-0,001	AB	-0,010	AC	13,384	0,40	0,37	-0,34
D	0,005	BC	-0,004	ACD	18,419	0,47	0,43	-0,17
BD	0,009	ABC	-0,004	ABCD	24,051	0,53	0,50	0,00
AB	0,015	BCD	0,021	ABC	27,301	0,60	0,57	0,17
ACD	0,017	ABD	0,043	AD	40,989	0,67	0,63	0,34
B	0,019	ABCD	0,050	AB	51,711	0,73	0,70	0,52
ABD	0,027	A	0,053	A	59,129	0,80	0,77	0,73
AC	0,029	ACD	0,133	ABD	67,056	0,87	0,83	0,97
A	0,035	AC	0,196	C	94,404	0,93	0,90	1,28
C	0,079	C	0,416	CD	105,799	1,00	0,97	1,83
Erro	0,017		0,067		42,979			

OBS: No rodapé da tabela tem-se a estimativa do erro experimental com 5 graus de liberdade

Como antes, os pontos centrais se ajustam a uma reta próxima ao ponto zero do eixo das abcissas, indicando efeitos sem sentido. Os efeitos distantes do ponto central são considerados relevantes.

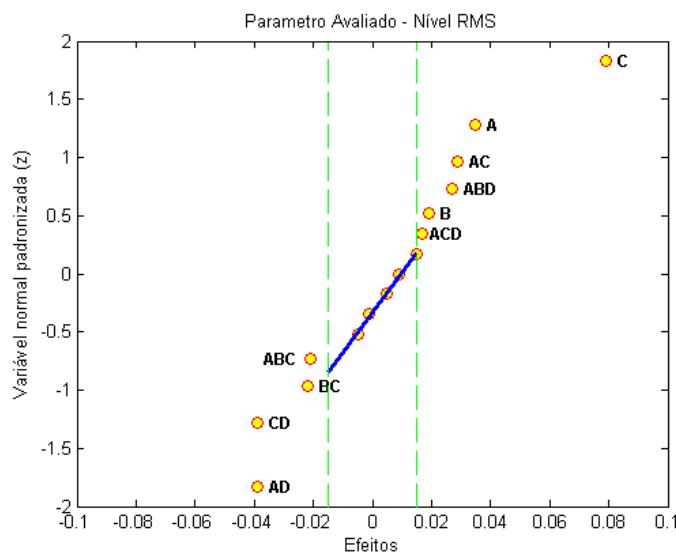


Figura 5.6 – Gráfico normal dos valores significativos para o nível RMS.

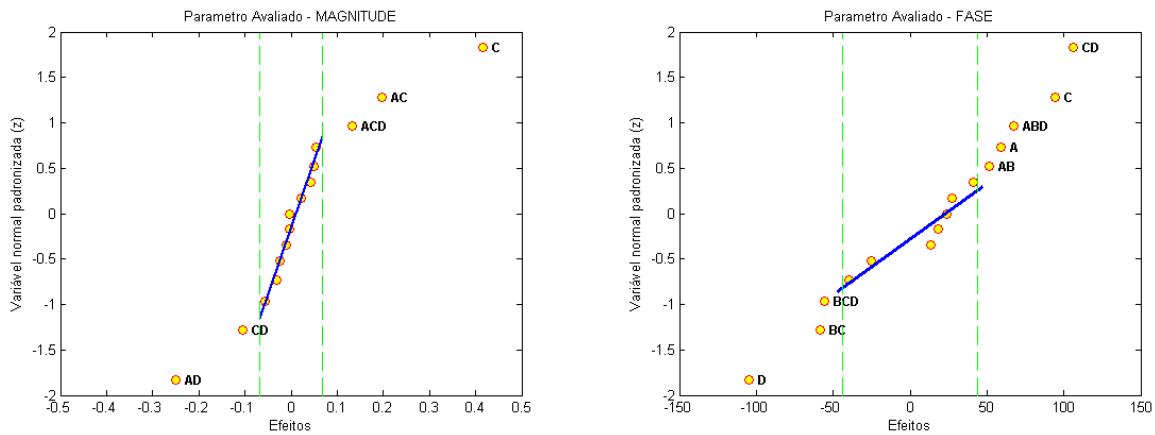


Figura 5.7 – Gráfico normal dos valores significativos para: (a) Magnitude e (b) Fase.

Da mesma forma, nota-se que para o nível RMS, os efeitos AD, CD, BC, ABC, ACD, B, ABD, AC, A e C, são significativos. Como há fatores de segunda ordem (AD, CD, BC e AC) e fatores de terceira ordem (ABC, ACD e ABD) dependentes do fator D, este não poderá ser descartado do modelo. Portanto os quatro fatores principais influenciam na resposta sonora.

Para a magnitude e a fase, verifica-se também que todos os fatores principais afetam a resposta em 730 Hz. Assim de forma geral, os fatores A, B, C, D, AB, AC, AD, BC, CD, ABC, ABD, ACD e BCD são necessários para os 03 parâmetros avaliados. Apenas os fatores BD e BCD são irrelevantes.

## 5.7 Consolidação dos resultados

Como apresentado, nota-se que todos os fatores principais têm influência nas respostas em baixas e médias frequências. Nas médias frequências verifica-se que as respostas são mais sensíveis a uma gama maior de combinação de fatores.

As tabelas 5.4 e 5.6 mostram efeitos em ordem crescente para os parâmetros (Nível RMS, magnitude e fase) nas frequências avaliadas. Nestas tabelas e nos gráficos apresentados, os efeitos A e CD em 250 Hz e C, CD, D e AD em 730 Hz, são os que mais se destacam para os três parâmetros, portanto hierarquicamente seriam os mais contundentes. Isso indica que a abertura e fechamento de portas (A) e janelas (C) promovem grandes perturbações, além da ocupação na sala (D), agindo diretamente no campo reverberante (pela modificação do *layout* e das características de absorção).

Convergindo com o objetivo do trabalho, estas observações indicam que em ambientes dinâmicos ou susceptíveis a mudanças, a estimativa virtual poderá apresentar problemas. Apontam ainda a necessidade de se obter amostras com várias combinações de fatores para promover uma abrangência de situações. Ao passo que aplicações com menor possibilidade de interferência, a exemplo de dutos, a estimativa virtual deverá promover uma melhor previsão.

Ainda no sentido de se obter uma estimativa mais robusta devido aos desvios no ambiente original, as estimativas deverão ser investigadas em função dos sinais gerados, levando-se em conta uma ampla gama de combinações de mudanças. Estas amostras com as características relevantes do ambiente seriam utilizados na fase de treinamento de uma rede neural. Se a rede neural incorporar as características do ambiente devido as mudanças, espera-se que a estimativa apresente um comportamento satisfatório ampliando assim a faixa de aplicações.

## CAPÍTULO VI

### PROJETO E CONFIGURAÇÕES DE REDES NEURAIS PARA ESTIMATIVA DE UM SINAL HARMÔNICO

#### 6.1 Introdução

Neste capítulo definem-se os parâmetros de projeto e de seleção de uma rede neural para que seja possível estimar um sinal acústico em um campo reverberante a partir de uma excitação harmônica na fonte. Pretende-se utilizar uma rede neural para estimar a resposta acústica em um ponto remoto sem a que haja a presença física de um sensor no ponto escolhido. A estimativa do sinal sonoro à distância é chamado de microfone virtual. Ao final serão feitas as considerações relativas às observações verificadas durante o estudo.

Serão consideradas as seguintes etapas

- Projeto de redes neurais artificiais
- Geração de sinal harmônico em um alto-falante (fonte) e a obtenção das respostas acústicas.
- Treinamento das redes neurais projetadas, avaliando a performance, o erro médio quadrático, o tempo de treinamento e o coeficiente de correlação.
- Avaliação das respostas e a seleção da rede neural
- Avaliação da resposta da rede conforme a quantidade de amostras ou vetores fornecidos durante a fase de treinamento;
- A qualidade da resposta obtida em função do número de sensores utilizados como referência para o sinal de entrada e
- A sensibilidade da rede em função da distância do sensor de referência ao ponto remoto.

## 6.2 Projeto e seleção da Rede Neural Artificial

### 6.2.1 Arquiteturas das Redes Neurais

Para o projeto de uma rede neural é necessário definir vários parâmetros de configurações tais como número de entradas, de neurônios, número de camadas, saídas, atrasos de linha, funções de ativação, algoritmos de aprendizagem, conexões, dentre outros. Para a arquitetura das redes, pode-se definir as redes diretas, as com atraso de linha e as redes recorrentes. Como o desenho final da rede depende do problema a ser tratado, é necessário estabelecer critérios de testes de performance e de avaliação de resultados.

Assim, para iniciar as configurações foi estabelecido redes com 02 ou 03 camadas ocultas, 10 e 20 neurônios na camada de entrada, atraso de 04 posições, funções de ativação “*tansig*” e “*purelin*”, uma ou duas entradas para os sinais de referência e critério de parada em 500 iterações. Foi estabelecido também um vetor com 53000 pontos para cada sinal utilizado na fase de treinamento das redes.

Para as redes diretas, foram definidas as redes *Feedforward* (FF) e *Feedforward* em Cascata (FFC), conforme ilustrado nas figuras 6.1 e 6.2. As características principais deste tipo de rede é sua capacidade de adaptar-se a qualquer função com um número finito de descontinuidades e desde que haja um número suficiente de neurônios nas camadas intermediárias. Esta característica foi provada pelo matemático George Cybenko (1989, *apud* FONSECA, 2013). Estas redes são bastante utilizadas como um aproximador universal de funções.

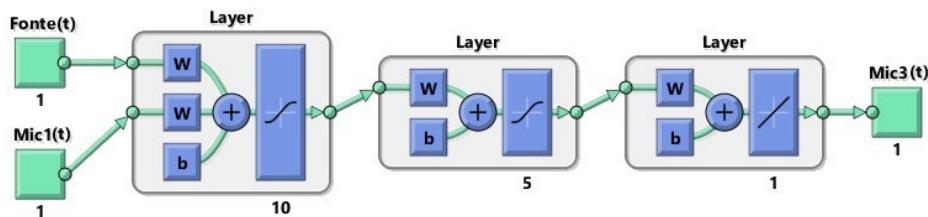


Figura 6.1 – Rede *Feedforward* (FF).

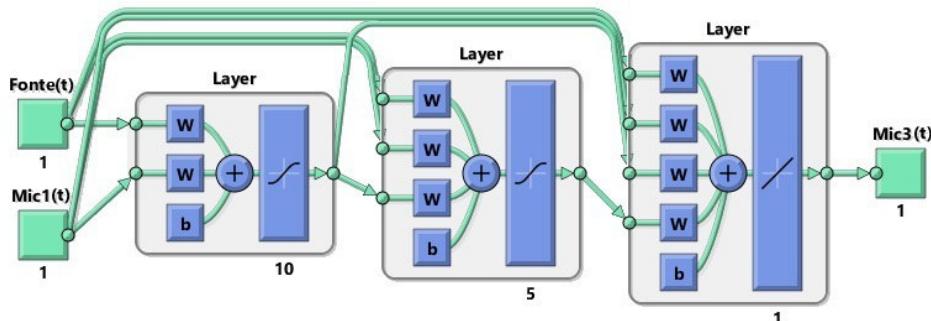


Figura 6.2 – Rede *Feedforward* em Cascata (FFC).

As redes que apresentam características dinâmicas, tais como atraso de linha e realimentação foram definidas como: Redes com Atraso na Camada Inicial (ACI), rede com Atraso Distribuído nas Camadas internas (ADC), rede Recorrente em Camadas (RC) e rede Auto Regressiva com Entrada Exógena (NARX), conforme ilustrado nas figuras de 6.3 a 6.6.

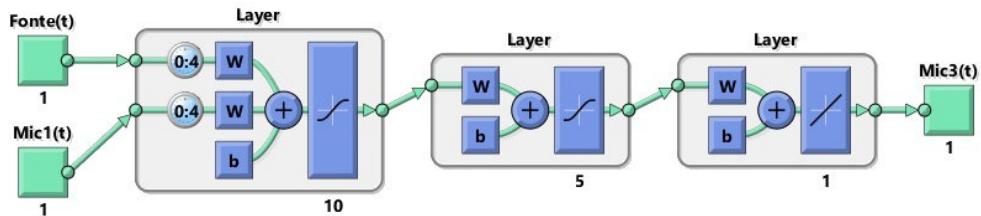


Figura 6.3 – Rede com Atraso na Camada Inicial (ACI).

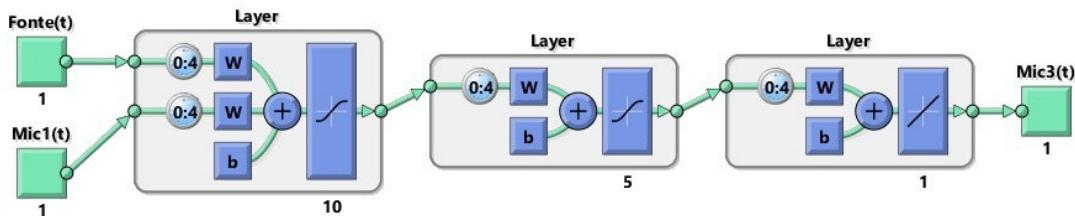


Figura 6.4 – Rede com Atraso Distribuído nas Camadas (ADC).

Fonseca (2013) comenta que as redes com atraso de linha se adequarem muito bem aos problemas de previsão de séries temporais e que a arquitetura da rede ADC foi empregada com sucesso na detecção de fonemas a partir de um sinal sonoro.

Já os modelos auto regressivos são estocásticos, normalmente empregados em estudos estatísticos e em processamento de sinais, para modelar e prever vários tipos de fenômenos naturais. Este tipo de modelo utiliza os valores passados de uma série temporal para prever os valores futuros da mesma.

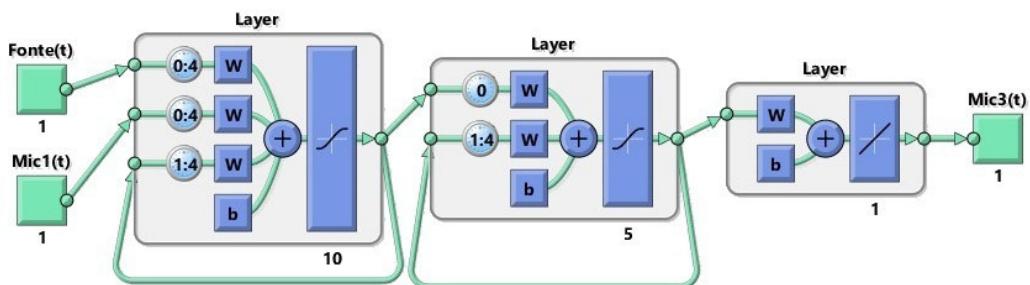


Figura 6.5 – Rede Recorrente em Camadas (RC).

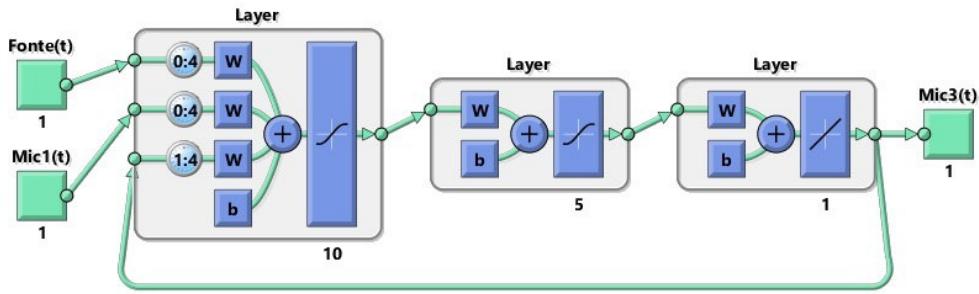


Figura 6.6 – Rede Auto Regressiva com Entrada Exógena (NARX).

As redes NARX possuem conexões de realimentação entre as camadas com arquitetura baseada nos modelos auto regressivos. Um modelo regressivo, também conhecido como ARMAX, pode ser visto como a extensão de um modelo linear. As equações 6.1 a 6.3 formula um modelo com 01 entrada e 01 saída.

$$\begin{aligned} a_0 \cdot y(k) + a_1 \cdot y(k-1) + \dots + a_q \cdot y(k-Q) \\ = w_0 \cdot x(k) + w_1 \cdot x(k-1) + \dots + w_R \cdot x(k-R) \end{aligned} \quad (6.1)$$

$$\sum_{j=0}^Q a_j y(k-j) = \sum_{i=0}^R w_i x(k-i) \quad (6.2)$$

$$y(k) = \frac{1}{a_0} \left( \sum_{i=0}^R w_i x(k-i) - \sum_{j=1}^Q a_j y(k-j) \right) \quad (6.3)$$

Este tipo de modelo implica que a saída atual  $y(k)$  é dada como uma soma ponderada dos valores passados da saída e dos valores exógenos de entrada  $x(k)$ . Na Eq. 6.1, os termos  $x(k), \dots, x(k-R), y(k-1), \dots, y(k-Q)$  são as variáveis de entrada e as saídas desfasadas, denominados regressores. Note que  $R$  indica a quantidade de atrasos na linha de entrada e  $Q$  o número de atrasos na linha recorrente. Desta forma, no modelo ARX a saída atual  $y(k)$  se apresenta como uma soma ponderada de seus regressores. Esta estrutura linear pode ser estendida para criar uma forma não linear (NARX):

$$y(k) = f(x(k), x(k-1), \dots, x(k-R), y(k-1), y(k-2), \dots, y(k-Q)) \quad (6.4)$$

Onde a função  $f$  é uma função não linear e cujas entradas são os regressores do modelo, podendo ter variáveis atrasadas da entrada e da saída.

### 6.2.2 Procedimento experimental

Neste estudo, foi adotado o sinal harmônico na frequência de 160 Hz, gerado com 25 volts. A aquisição ocorreu na faixa de 0 a 1638 Hz com 16384 pontos, duração de 50.01 s, com frequência de corte em 700 Hz. O ruído de fundo antes da aquisição era de 48,4 dB. Durante a aquisição a pressão sonora ficou em 91,3 dB. Foram utilizados microfones PCB nas posições Mic1, Mic2 e Mic3. Como ilustra a fig. 6.7 os microfones *Brüel & Kjær* nas posições Mic4, Mic5, Mic6 e Mic7, não foram considerados.

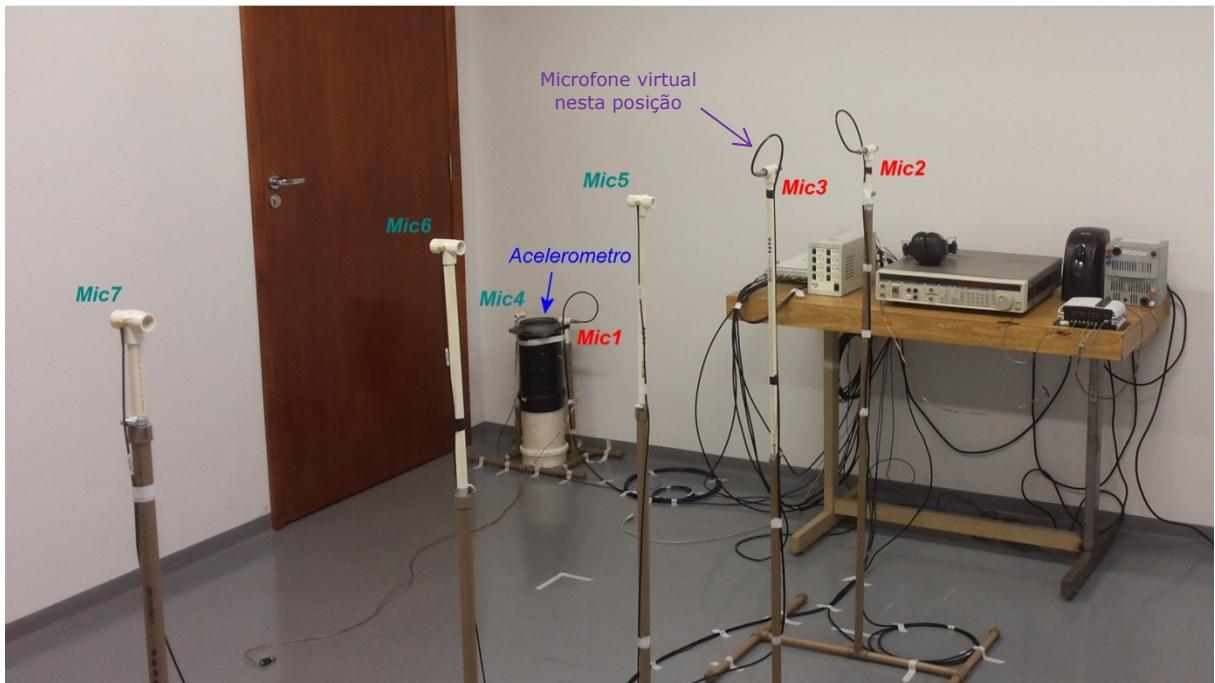


Figura 6.7 – Distribuição dos sensores para aquisição dos sinais na sala vazia. Ao fundo o autofalante e na bancada: a instrumentação e o gerador de sinais.

### 6.2.3 Treinamento das redes projetadas

Após definir as arquiteturas básicas das redes, passou-se para a fase de treinamentos. Os resultados são apresentados nas tabelas 6.1 a 6.6 conforme configurações indicadas no título de cada uma. Para o treinamento, utilizou-se um vetor com 53000 pontos (32,4 s) do total de 81920 (50,0 s). Como resultado, foram tabelados o tempo decorrido no treinamento, o coeficiente de regressão, a performance no treinamento e o erro médio quadrático (EMQ) da diferença entre o sinal estimado e medido. Estes foram utilizados como parâmetros para a avaliação das redes. Os dados foram obtidos comparando o sinal medido pelo microfone na posição Mic3 com o sinal estimado pela rede no mesmo ponto.

Tabela 6.1 – Resultados de treinamento das RNAs. Entrada = AF (Autofalante). Saída = Mic3. Camadas ocultas = 02. Neurônios na camada de entrada = 10.

Rede	Configurações	Atraso	Tempo de treinamento	Coeficiente Recessão	Perfom. treinam.	EMQ
FF	(A) 10x1	[ ] / [ ]	00:01:23	0,90441	$1,35 \times 10^{-4}$	0,0116
FFC		[ ] / [ ]	00:01:23	0,90446	$1,35 \times 10^{-4}$	0,0116
ACI		[04] / [ ]	00:01:53	0,96411	$5,24 \times 10^{-5}$	0,0072
ADC		[04] / [ ]	00:14:03	0,96754	$4,75 \times 10^{-5}$	0,0069
RC		[04] / [04]	02:07:57	0,95711	$6,24 \times 10^{-5}$	0,0079
NARX		[04] / [04]	00:12:12	0,97255	$4,02 \times 10^{-5}$	0,0063

Tabela 6.2 – Resultados de treinamento das RNAs. Entrada = Mic1. Saída = Mic3. Camadas ocultas = 02. Neurônios na camada de entrada = 10.

Rede	Configurações	Atraso	Tempo de treinamento	Coeficiente Recessão	Perfom. treinam.	EMQ
FF	(M1) 10x1	[ ] / [ ]	00:01:21	0,73385	$3,43 \times 10^{-4}$	0,0185
FFC		[ ] / [ ]	00:01:24	0,73388	$3,43 \times 10^{-4}$	0,0185
ACI		[04] / [ ]	00:01:50	0,98819	$1,75 \times 10^{-5}$	0,0042
ADC		[04] / [ ]	00:13:46	0,99269	$1,08 \times 10^{-5}$	0,0033
RC		[04] / [04]	01:07:57	0,99405	$8,82 \times 10^{-6}$	0,0030
NARX		[04] / [04]	00:12:02	0,99309	$1,02 \times 10^{-5}$	0,0032

Tabela 6.3 – Resultados de treinamento das RNAs. Entrada = AF + Mic1. Saída = Mic3. Camadas ocultas = 02. Neurônios na camada de entrada = 10.

Rede	Configurações	Atraso	Tempo de treinamento	Coeficiente Recessão	Perfom. treinam.	EMQ
FF	(A+M1) 10x1	[ ] / [ ]	00:01:32	0,97230	$5,06 \times 10^{-5}$	0,0064
FFC		[ ] / [ ]	00:01:36	0,97188	$4,12 \times 10^{-5}$	0,0064
ACI		[04] / [ ]	00:02:27	0,98992	$1,49 \times 10^{-5}$	0,0039
ADC		[04] / [ ]	00:20:20	0,99296	$1,04 \times 10^{-5}$	0,0032
RC		[04] / [04]	01:24:01	0,99461	$7,99 \times 10^{-6}$	0,0028
NARX		[04] / [04]	00:15:12	0,99333	$9,89 \times 10^{-6}$	0,0031

Tabela 6.4 – Resultados de treinamento das RNAs. Entrada = AF + Mic1. Saída = Mic3. Camadas ocultas = 03. Neurônios na camada de entrada = 10.

Rede	Configurações	Atraso	Tempo de treinamento	Coeficiente Recessão	Perfom. treinam.	EMQ
FF	(A+M1) 10x5x1	[ ] / [ ]	00:02:20	0,97270	$4,00 \times 10^{-5}$	0,0063
FFC		[ ] / [ ]	00:02:50	0,97379	$3,85 \times 10^{-5}$	0,0062
ACI		[04] / [ ]	00:03:05	0,98996	$1,49 \times 10^{-5}$	0,0039
ADC		[04] / [ ]	01:08:24	0,99331	$9,91 \times 10^{-6}$	0,0031
RC		[04] / [04]	02:28:09	0,99430	$8,46 \times 10^{-6}$	0,0029
NARX		[04] / [04]	00:23:51	0,99338	$9,81 \times 10^{-6}$	0,0031

Tabela 6.5 – Resultados de treinamento das RNAs. Entrada = AF. Saída = Mic3. Camadas ocultas = 02. Neurônios na camada de entrada = 20.

Rede	Configurações	Atraso	Tempo de treinamento	Coeficiente Recessão	Perfom. treinam.	EMQ
FF	(A) 20x1	[ ] / [ ]	00:02:04	0,90444	$1,35 \times 10^{-4}$	0,0116
FFC		[ ] / [ ]	00:02:07	0,90448	$1,35 \times 10^{-4}$	0,0116
ACI		[04] / [ ]	00:02:53	0,96766	$5,19 \times 10^{-5}$	0,0072
ADC		[04] / [ ]	00:31:20	0,96766	$4,73 \times 10^{-5}$	0,0069
RC		[04] / [04]	22:23:36	0,96109	$6,24 \times 10^{-5}$	0,0073
NARX		[04] / [04]	00:23:51	0,97326	$3,92 \times 10^{-5}$	0,0063

Todas as redes utilizaram os mesmos sinais e as configurações de entrada e de saída descritos nas tabelas. A figura 6.8 ilustra a resposta medida pelo Mic3 e a resposta estimada pela rede, onde: (a) tem-se um exemplo de um resultado ruim para rede *Feedforward* vindo da tab. 6.1 e (b) um exemplo de um bom resultado para a rede NARX da tab. 6.3. A variação da magnitude evidenciada na figura é devido a ruído na aquisição proveniente de laboratório externo (na mesma edificação).

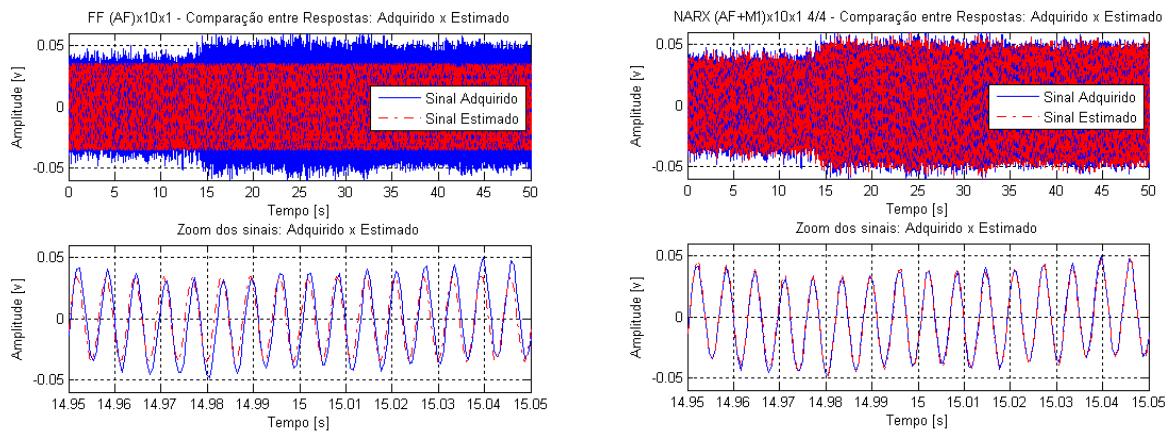


Figura 6.8 – Comparação entre sinal obtido e o sinal estimado. (a) Rede *Feedforward* da Tab. 6.1. (b) Rede NARX da Tab. 6.3.

#### 6.2.3.1 – CONSIDERAÇÕES:

Os resultados das tabelas 6.1 a 6.5 estão consolidados no gráfico da figura 6.9 e 6.10, onde se observa:

- As redes *Feedforward* (FF) e *Feedforward* em Cascata (FFC) apresentam os piores desempenhos em comparação com as demais arquiteturas, nas mesmas configurações.
- Não foi evidenciada uma melhora significativa de desempenho ao aumentar o número de neurônios. Curvas (1) e (5) no gráfico da fig. 6.9.
- Não foi evidenciada uma melhora significativa de desempenho ao aumentar o número de camadas. Curvas (3) e (4) no gráfico da fig. 6.9.
- Com apenas um sinal de entrada, a utilização do microfone Mic1 apresentou melhor estimativa do que o sinal na fonte. Curva (2) em comparação com curvas (1) e (5) no gráfico da fig. 6.9. Isso ocorre devido a maior sensibilidade do microfone ao ruído de fundo e ao campo reverberante da sala. O sinal na fonte possui maior sensibilidade ao campo vibracional.

- Os melhores resultados foram obtidos ao utilizar dois sinais na entrada: o sinal na fonte e o microfone (Mic1). Curva (3) no gráfico da fig. 6.9.
- Em todas as configurações, as redes Recorrentes em Camadas (RC) apresentaram bons resultados de desempenho. Entretanto esta rede apresenta um elevado tempo de processamento conforme a fig. 6.10.

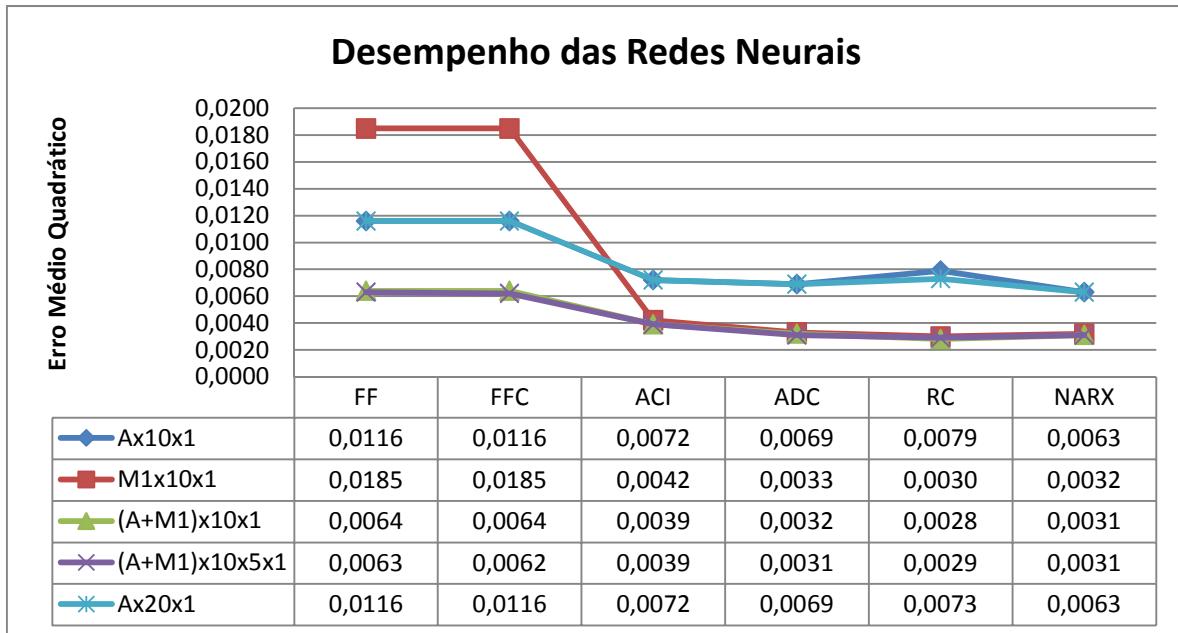


Figura 6.9 – Gráfico comparativo entre desempenhos obtidos pelas redes neurais.

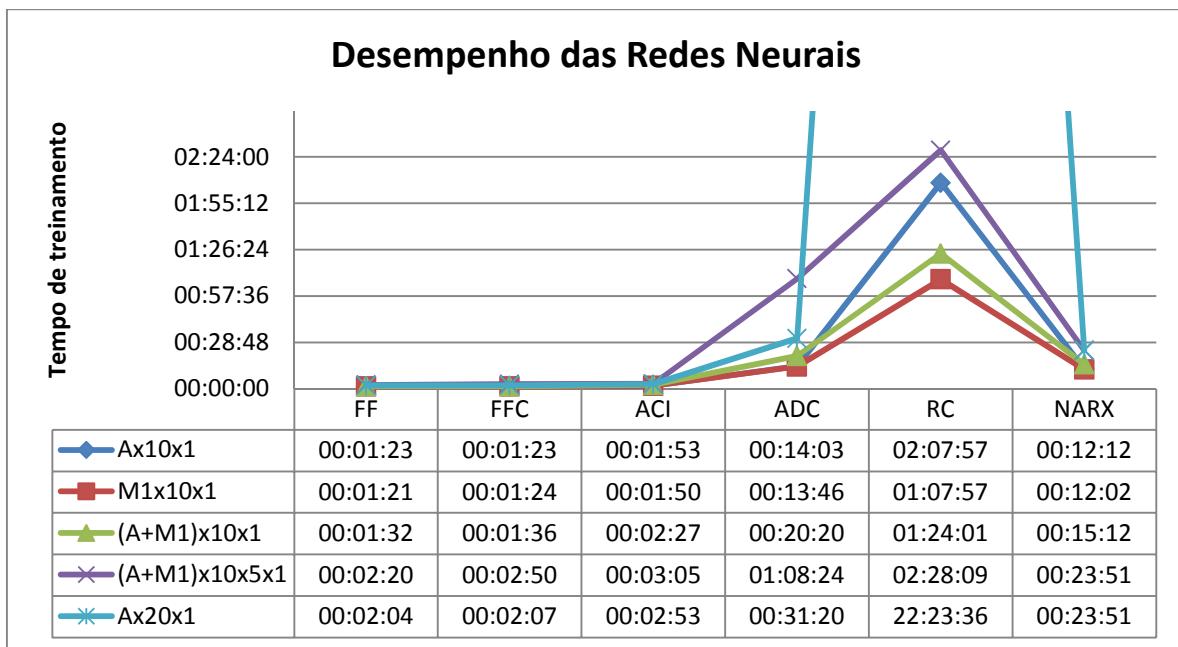


Figura 6.10 – Tempos de treinamento utilizados pelas redes neurais.

As redes com Atraso na Camada Inicial (ACI), rede com Atraso Distribuído nas Camadas internas (ADC) e a rede Auto Regressiva com Entrada Exógena (NARX) foram as que apresentaram melhores resultados, principalmente na configuração de 02 entradas (A+M1), 02 camadas e 10 neurônios. As demais arquiteturas não serão consideradas nos estudos subsequentes.

Como a rede ADC possui um desempenho compatível com a rede NARX, esta também será desconsiderada por apresentar um tempo de processamento ligeiramente maior.

#### 6.2.4 Aprimoramento das arquiteturas das redes ACI e NARX

Nesta etapa serão investigadas outras configurações para atraso de linha e para o número de neurônios das redes ACI e NARX. Serão mantidas as entradas (A + M1), 01 saída (Mic3) e 02 camadas ocultas.

Tabela 6.6 – Resultados de treinamentos devido a variação do número de neurônios.

Rede	Configurações	Atraso	Tempo de treinamento	Coeficiente Regressão	Perfom. treinam.	EMQ
ACI	(A+M1) 10x1	[04] / [ ]	00:02:27	0,98992	$1,49 \times 10^{-5}$	0,0039
	(A+M1) 05x1		00:01:49	0,98955	$1,55 \times 10^{-5}$	0,0039
	(A+M1) 03x1		00:01:16	0,98671	$1,96 \times 10^{-5}$	0,0044
	(A+M1) 01x1		00:00:54	0,97299	$3,96 \times 10^{-5}$	0,0063
NARX	(A+M1) 10x1	[04] / [04]	00:15:12	0,99333	$9,89 \times 10^{-6}$	0,0031
	(A+M1) 05x1		00:07:11	0,99324	$1,00 \times 10^{-5}$	0,0032
	(A+M1) 03x1		00:03:36	0,99317	$1,01 \times 10^{-5}$	0,0032
	(A+M1) 01x1		00:01:32	0,99252	$1,11 \times 10^{-5}$	0,0033

Tabela 6.7 – Resultados de treinamentos devido a variação no atraso de linha.

Rede	Configurações	Atraso	Tempo de treinamento	Coeficiente Regressão	Perfom. treinam.	EMQ
ACI	(A+M1) 05x1	[09] / [ ]	00:03:29	0,99298	$1,04 \times 10^{-5}$	0,0032
		[03] / [ ]	00:02:15	0,98713	$1,90 \times 10^{-5}$	0,0044
		[02] / [ ]	00:02:03	0,98313	$2,49 \times 10^{-5}$	0,0050
		[01] / [ ]	00:01:49	0,97909	$3,08 \times 10^{-5}$	0,0055
		[ ] / [ ]	00:01:33	0,97194	$4,11 \times 10^{-5}$	0,0064
NARX	(A+M1) 03x1	[04] / [04]	00:03:36	0,99317	$1,01 \times 10^{-5}$	0,0032
		[04] / [02]	00:02:56	0,99272	$1,08 \times 10^{-5}$	0,0033
		[02] / [04]	00:02:41	0,99305	$1,03 \times 10^{-5}$	0,0032
		[02] / [02]	00:02:12	0,99256	$1,10 \times 10^{-5}$	0,0033

Os resultados da tabela 6.6 estão consolidados no gráfico da figura 6.11 e os da tabela 6.7 na figura 6.12. Assim, pode-se observar que:

- Pela fig 6.11, ocorre uma piora no desempenho ao reduzir o número de neurônios para a rede ACI. Para a rede NARX, não foi evidenciado a piora dos resultados ao reduzir o número de neurônios. A rede com 03 neurônios mostrou-se como uma boa escolha para esta arquitetura.
- A figura 6.11 evidencia que a rede NARX apresenta melhor desempenho.
- O desempenho é afetado diretamente pelo atraso de linha conforme figura 6.12(a).
- A rede NARX apresenta um melhor desempenho conforme os gráficos da fig. 6.12.

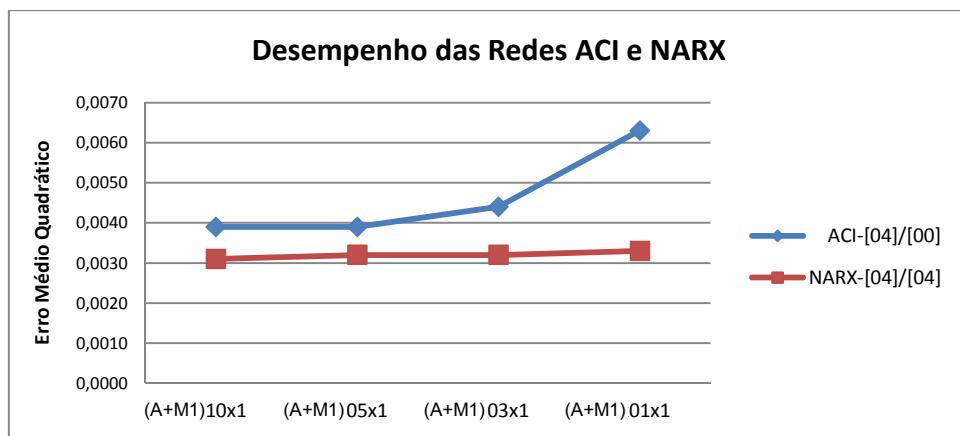


Figura 6.11 – Desempenhos obtidos ao variar a quantidade de neurônios.

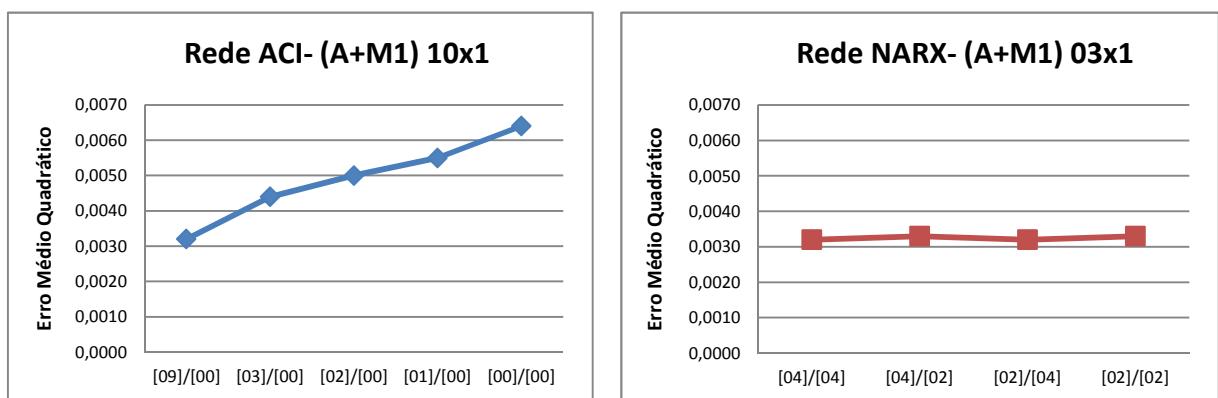


Figura 6.12 – Desempenhos obtidos ao variar os atrasos de linha.

Pode-se verificar que a rede NARX (A+M1) 03x01 apresenta bons resultados. Portanto esta arquitetura de rede será a base para os demais estudos que seguirão.

### 6.3 Tratamento dos sinais de treinamento e sinais de entrada de dados para generalização da resposta

No treinamento das redes neurais do tópico anterior a rede NARX (A+M1) 03x01 mostra-se como uma boa opção. Outra característica foi a utilização de dois sinais de referencia para a entrada da rede, sendo um posicionado na fonte e outro próximo ao ponto a ser estimado. Com base nesta arquitetura de rede, propõe-se:

- avaliar a resposta da rede em função da quantidade de dados durante a fase de treinamento;
- a qualidade da resposta obtida em função do número de sensores utilizados como referencia para o sinal de entrada e
- a sensibilidade da rede conforme se distancia o sensor de referencia do ponto remoto.

#### 6.3.1 *Procedimento experimental*

Para gerar a excitação foram utilizados sinais em dois níveis, um na frequência de 250 Hz e outro em 497 Hz (selecionada por sorteio), ambas com magnitude de 15 volts, aquisição na faixa de 0 a 1640 Hz, 8192 pontos de amostragem, tempo de aquisição de 49,95 s e frequência de corte em 800 Hz. Foram utilizados somente microfones *Brüel & Kjær* nas posições Mic1, Mic2, Mic3, Mic4, Mic5 e Mic6. A posição do Mic6 foi estabelecida como o ponto remoto para estimativa do sinal acústico. O sinal obtido pelo microfone neste ponto será utilizado para comparar e avaliar o erro obtido. Foram adquiridos ainda o sinal de vibração na fonte (membrana do auto falante) e o sinal do gerador de sinais DS360.

Na sala, os microfones Mic1 ao Mic5 foram dispostos em uma linha aproximadamente diagonal, distanciados entre si de 50,0 mm e na altura de 1,302 m. Foram realizadas 8 aquisições, variando a posição dos cinco sensores, abrangendo desta forma 2,000 m de comprimento. Manteve-se inalterada a posição da fonte e do Mic6 durante todo o procedimento. As figuras 6.13 e 6.14 ilustram esta disposição.

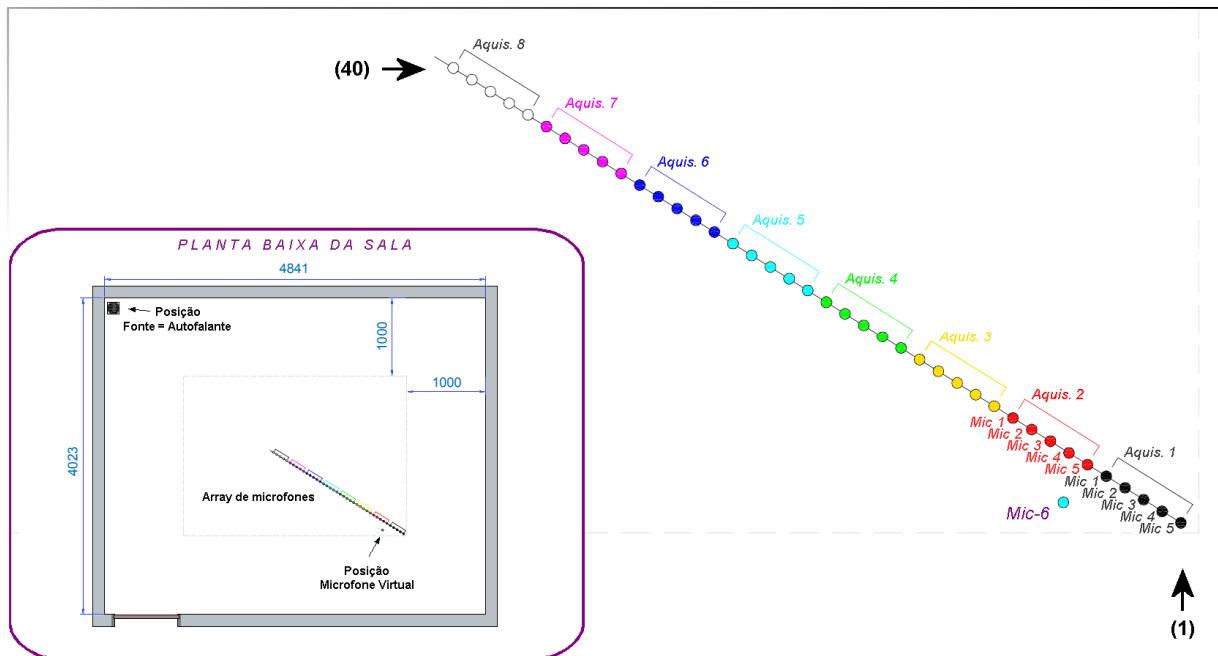


Figura 6.13 – *Layout* e disposição da matriz de microfones na sala. Os microfones Mic1 ao Mic5 formam um conjunto de aquisição. O Mic6 indica a posição do microfone virtual. A fonte no canto superior à esquerda.

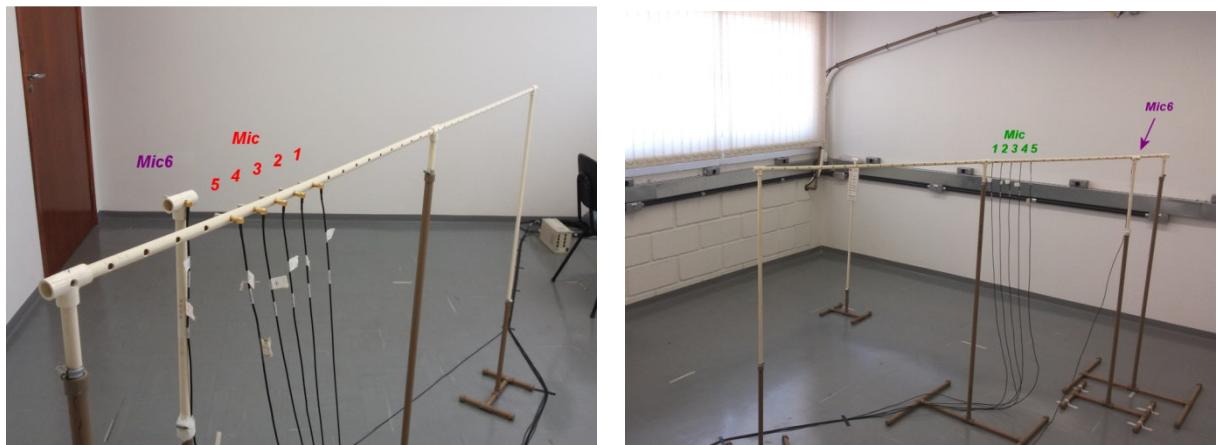


Figura 6.14 – Posicionamento de microfones e detalhe da suportação. (a) Foto frontal da 2<sup>a</sup> aquisição (b) Foto traseira da 4<sup>a</sup> aquisição.

### 6.3.2 Avaliação da resposta da Rede Neural em função da amostragem do sinal

Inicialmente, utilizou-se um sinal com 53000 pontos para avaliar o desempenho e assim selecionar a arquitetura da rede neural. Neste tópico mantém-se a configuração base da rede selecionada e o trecho correspondente à 2ª aquisição mostrado na figura 6.13. Na tabela 6.8 estão consolidadas as respostas obtidas na frequência de 250 Hz, onde se destacam: a configuração de atraso da rede NARX (AF+M1)x03x01, o número de pontos utilizados, o tempo gasto, o erro médio quadrático da estimativa obtida, além do erro de magnitude e fase entre a estimativa e o sinal medido.

Tabela 6.8 – Treinamento em função do vetor de amostras. Característica do sinal medido no ponto remoto: Magnitude 0,5462 V. Fase em -66,17°. Sinal com 81920 pontos.

Config.	Pontos utilizados	Tempo de Treinamento [s]	Resposta	Magnitude da FRF		Fase da FRF	
			EMQ ( $\times 10^{-4}$ )	Estimativa	Erro [%]	Estimativa	Erro [%]
[04]/[04]	53000	347,65	411,87	0,5545	1,52	-67,46	1,95
	25000	134,72	835,83	0,5596	2,45	-70,01	5,80
	12500	86,92	1233,80	0,5762	5,49	-67,58	2,13
	5000	38,18	1492,30	0,5662	3,66	-70,37	6,35
	1000	11,67	1968,10	0,5591	2,36	-71,88	8,63
	500	6,86	785,32	0,5713	4,60	-71,48	8,02
	200	4,25	826,65	0,5992	9,70	-71,61	8,22
[08]/[08]	53000	817,61	344,55	0,5539	1,41	-67,09	1,39
	25000	375,22	469,78	0,5524	1,14	-68,69	3,81
	12500	190,22	949,45	0,5629	3,06	-70,35	6,32
	5000	80,17	1264,10	0,5645	3,35	-70,93	7,19
	1000	5,22	856,03	0,5487	0,46	-71,91	8,67
	500	4,61	612,70	0,5565	1,89	-72,05	8,89
	200	4,41	720,81	0,5690	4,17	-71,14	7,51

Graficamente, os resultados da tabela 6.8 estão representados na figura 6.15. Pode-se observar que no geral as menores diferenças ocorreram quando foi treinada a rede com 53000 pontos, utilizando o maior atraso de linha. Uma maior quantidade de pontos melhora a estimativa da resposta, entretanto, tem-se como desvantagem o tempo de processamento. Nota-se que ao utilizar um vetor com 500 pontos os erros são equivalentes aos obtidos com 53000 pontos, exceto na fase. A figura 6.16 compara os dois vetores (com 53000 e 500 pontos) utilizados no treinamento e as respectivas estimativas obtidas.

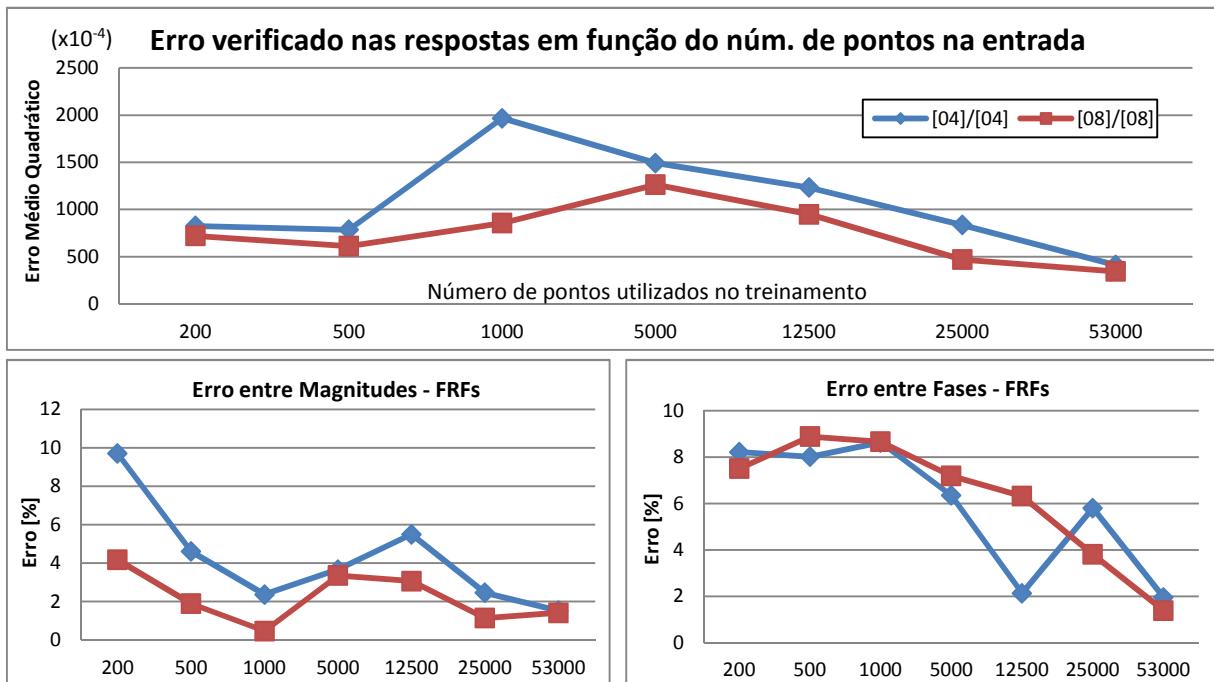


Figura 6.15 – Desempenhos obtidos ao variar os atrasos de linha.

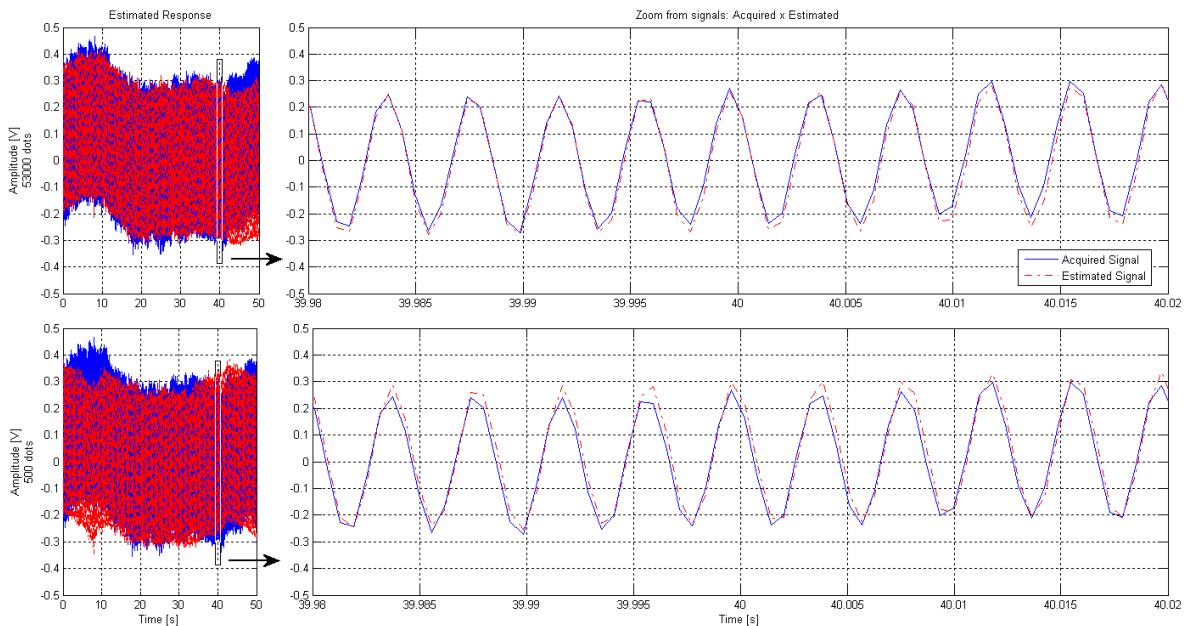


Figura 6.16 – Resposta da rede NARX (AF+M1)x03x01 [8]/[8], utilizando: (a) 53000 pontos e (b) 500 pontos no treinamento. Estimativa obtida com 81920 pontos ou 49,95 s.

Nota-se pela figura 6.15(b) que um vetor modesto (500 pontos) também consegue apresentar uma estimativa. Como vantagem apresenta menor tempo de processamento e como desvantagem, o erro verificado na fase e principalmente que toda a estimativa depende apenas de poucos pontos, sendo uma amostra limitada. Isto pode ser crítico para caracterizar toda a dinâmica do sinal. Baseado nestas observações é proposto o procedimento a seguir.

### 6.3.2.1 AMOSTRAGEM DOS SINAIS:

Ao “selecionar” alguns vetores do conjunto de sinais, obteve-se uma melhora na estimativa e no tempo de processamento. A Fig.6.17 ilustra cinco vetores extraídos em intervalos diferentes e recombinação em uma ordem aleatorizada. Este conjunto foi apresentado na fase de treinamento da rede neural. Os resultados obtidos utilizando este procedimento estão consolidados na Tab.6.9.

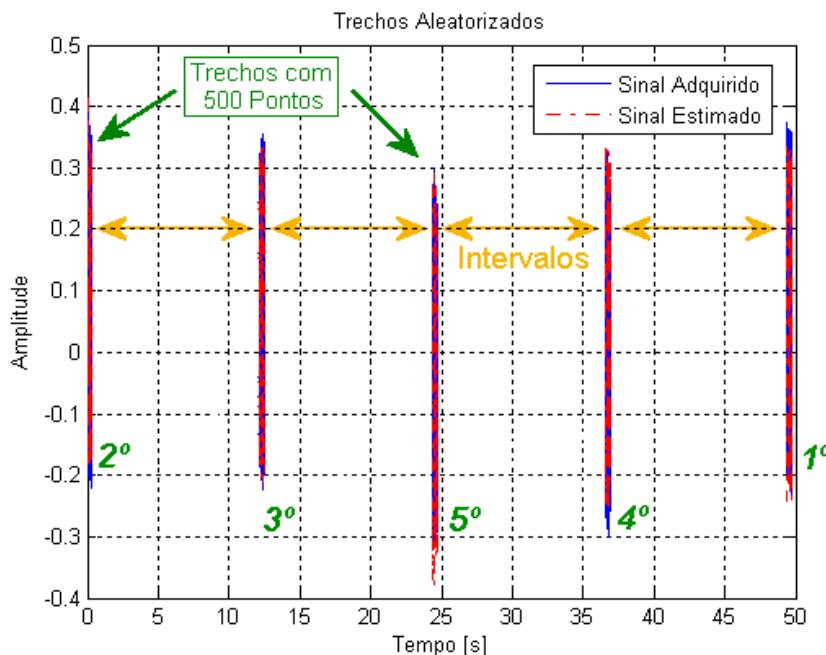


Figura 6.17 – Exemplo da “seleção” ou amostragem do sinal em 05 conjuntos de dados (vetores). Cada vetor com 500 pontos para o treinamento da RNA.

Tabela 6.9 – Resultados obtidos utilizando  $n$  vetores de dados com 500 pontos cada. Frequência 250 Hz. Magnitude 0,5462 V. Fase em -66,17°. Sinal total com 81920 pontos.

Estratégia	Qtd. de vetores	Tempo Proc. [s]	Resposta	Magnitude da FRF		Fase da FRF	
			EMQ ( $\times 10^4$ )	Estimado	Erro [%]	Estimado	Erro [%]
Retreino	5	12,60	555,72	0,5538	1,39	-71,86	8,60
	9	18,18	622,90	0,5527	1,19	-67,17	1,51
	17	31,18	581,16	0,5399	-1,15	-64,34	-2,77
	33	55,99	562,88	0,5493	0,57	-67,07	1,36
Apenas 1 Treinam.	5	6,13	482,48	0,5456	-0,11	-66,53	0,54
	9	8,76	461,36	0,5473	0,20	-66,34	0,26
	17	18,72	391,01	0,5455	-0,13	-65,87	0,17
	33	27,95	402,02	0,5460	-0,04	-66,20	0,05

Mantive-se a configuração NARX (AF+M1)x03x01 [08]/[08] para comparação, onde se utilizam 5, 9, 17 e 33 vetores com 500 pontos cada. Duas estratégias foram adotadas: Na primeira, a rede foi retreinada toda vez em que o vetor era apresentado. Na segunda estratégia, foi criado um conjunto com todos os vetores e realizado apenas um treinamento. Em ambas, foi aleatorizada a ordem em que os vetores foram apresentados.

Observa-se que não houve melhora dos resultados ao retreinar a rede, isso porque no retreino, a rede “aprende” apenas a dinâmica do trecho recém-apresentado. Por outro lado, obteve-se bons resultados ao juntar todos os vetores com as características do sinal e apresentando ao mesmo tempo na fase de treinamento. Ao comparar os dados das tabelas 6.8 e 6.9, nota-se que:

- O erro médio quadrático ficou compatível com o erro verificado em 25000 pontos da tabela 6.8, porém com redução no tempo de processamento de 375,2 s para abaixo de 28,0 s.
- O erro entre as magnitudes das FRF's ficou abaixo de 0,20%. Anteriormente o menor valor obtido foi de 1,14 quando se utilizou 25000 pontos no treinamento.
- O erro entre as fases das FRF's ficou abaixo de 0,54%. Anteriormente o menor valor foi de 1,39% verificado com 53000 pontos.
- Melhorou a exatidão das respostas ao elevar a quantidade de vetores no conjunto de treinamento, contudo, aumentou-se também o tempo de processamento.

### 6.3.3 *Resposta da Rede Neural em função do número de sensores de referencia*

Na etapa de seleção da rede neural (item 6.2.2), foi realizado o treinamento utilizando apenas o sensor na fonte ou um microfone como sinais de entrada e posteriormente utilizando os dois sensores, sendo esta configuração a que apresentou os melhores resultados. Naquele momento o foco era selecionar a arquitetura de rede. Nesta seção será reavaliada a qualidade da resposta em função da quantidade de sensores a serem utilizados como referencia.

É importante lembrar que diferentes respostas podem ser obtidas a cada novo treinamento, inclusive se mantido os mesmos conjuntos de dados. Isso acontece porque na fase de treinamento das redes neurais, os ajuste ou pesos sinápticos ocorrem de forma diferente. Por esta razão, foram realizados 05 treinamentos sucessivos onde se considerou a média dos valores obtidos.

Configurou-se a arquitetura NARX (com  $n$  entradas)x05x01 [08]/[08], 32 vetores com 750 pontos cada, frequências em 250 e 497 Hz e o trecho da 2<sup>a</sup> aquisição mostrado na figura 6.13. As figuras 6.18 e 6.19 apresentam os sinais medidos e estimados em função da quantidade de sensores de referencia, no tempo e na frequência (auto espectro). Nas tabelas 6.10 e 6.11 as características da FRF entre o sinal de aceleração e os sinais medidos e estimados. E finalmente, na figura 6.20 comparam-se os sinais em cada frequência avaliada.

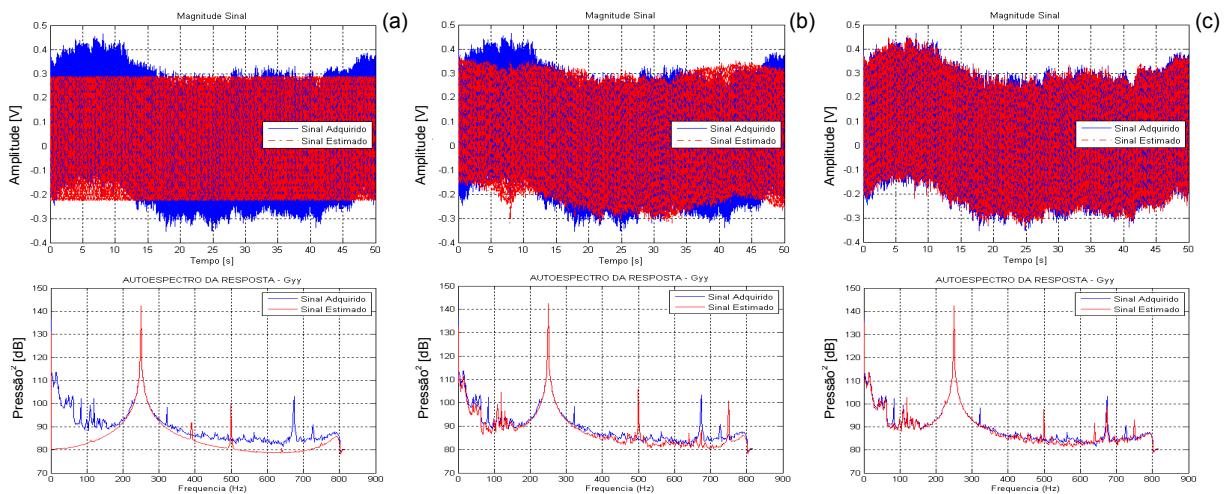


Figura 6.18 – Sinal medido e estimado em 250 Hz: (a) utilizando apenas o sensor na fonte. (b) utilizando o sensor na fonte + 01 microfone. (c) utilizando o sensor na fonte + 05 mic.

Tabela 6.10 – Erros de estimativa em função da quantidade de sensores em 250 Hz.

Sensores	RMS	Magnitude da FRF		Fase da FRF		-66,23	
	EMQ ( $\times 10^{-4}$ )	Sinal		Medido	Estimado		
		Medido	Estimado				
(1) AF	576,92	0,5483	-0,44	-66,24	0,02	-66,23	
	576,75		-0,68				
	577,23		-1,09				
	576,95		-1,00				
	574,18		-0,33				
	<b>576,41</b>	<b>0,5469</b>	<b>-0,71</b>				
(2) AF+M1	368,22	0,5526	0,32	-65,91	-0,48	-66,23	
	374,20		-0,22				
	440,65		-2,12				
	413,34		0,09				
	443,97		-0,72				
	<b>408,07</b>	<b>0,5479</b>	<b>-0,53</b>				
(3) AF+M1+M2	365,85	0,5506	-0,03	-65,88	-0,52	-66,23	
	409,44		-0,28				
	408,56		0,38				
	402,25		-1,11				
	432,23		-0,23				
	<b>403,67</b>	<b>0,5494</b>	<b>-0,25</b>				
(4) AF+M1+M2 +M3	328,16	0,5508	0,48	-65,54	-1,04	-66,23	
	294,73		-0,13				
	297,31		0,15				
	294,22		0,80				
	300,65		-0,47				
	<b>303,02</b>	<b>0,5517</b>	<b>0,17</b>				
(5) AF+M1+M2 +M3+M4	193,68	0,5534	-0,21	-66,32	0,14	-66,23	
	242,64		-0,77				
	189,18		-0,22				
	210,35		-0,11				
	219,76		0,04				
	<b>211,12</b>	<b>0,5494</b>	<b>-0,25</b>				
(6) AF+M1+M2 +M3+M4+M5	101,98	0,5502	-0,10	-67,96	2,62	-66,23	
	115,20		-0,01				
	112,44		-0,06				
	186,20		-1,14				
	118,92		-0,24				
	<b>126,95</b>	<b>0,5491</b>	<b>-0,31</b>				

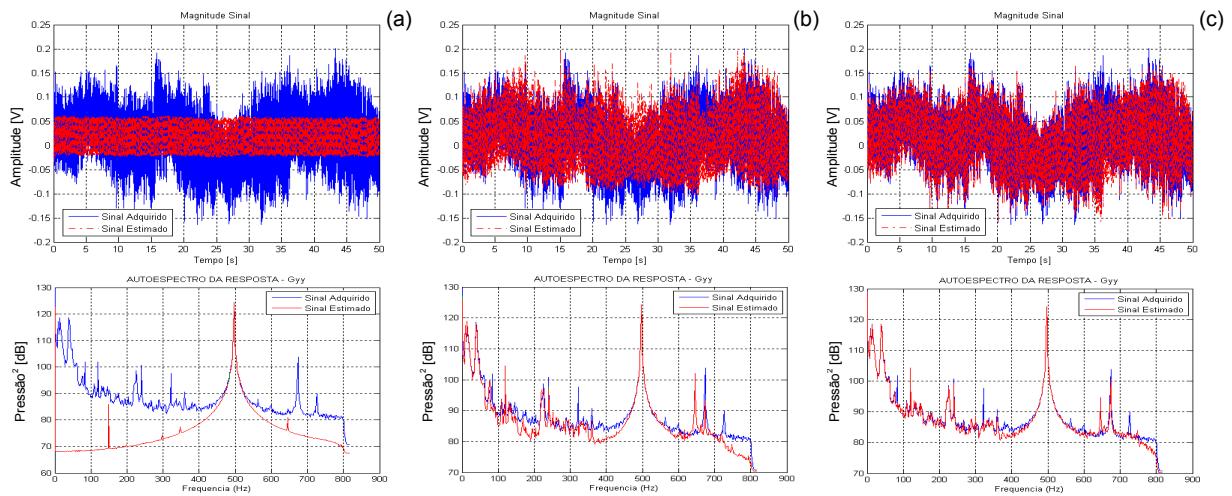


Figura 6.19 – Sinal medido e estimado em 497 Hz: (a) utilizando apenas o sensor na fonte. (b) utilizando o sensor na fonte + 01 microfone. (c) utilizando o sensor na fonte + 05 mic.

Tabela 6.11 – Erros de estimativa em função da quantidade de sensores em 497 Hz.

Sensores	RMS	Magnitude da FRF		Fase da FRF		Erro [%]	
	EMQ ( $\times 10^{-4}$ )	Sinal		Medido	Estimado		
		Medido	Estimado				
(1) AF	412,70	0,1572	0,1572	0,70	-0,09	115,24	
	411,99		0,1555	-0,42		116,00	
	411,93		0,1551	-0,64		116,40	
	412,70		0,1565	0,24		115,52	
	411,94		0,1556	0,33		116,23	
	<b>412,25</b>		<b>0,1560</b>	<b>-0,09</b>		<b>115,88</b>	
(2) AF+M1	261,74	0,1566	0,1566	0,30	-0,28	115,19	
	264,36		0,1560	-0,11		115,66	
	252,71		0,1551	-0,66		116,33	
	238,99		0,1551	-0,66		116,03	
	245,93		0,1557	0,33		116,56	
	<b>252,75</b>		<b>0,1557</b>	<b>-0,28</b>		<b>115,96</b>	
(3) AF+M1+M2	238,73	0,1564	0,1564	0,15	-0,66	115,80	
	255,21		0,1549	-0,77		116,17	
	241,17		0,1525	-2,35		116,21	
	255,76		0,1563	0,11		115,84	
	239,58		0,1554	0,33		115,81	
	<b>246,09</b>		<b>0,1551</b>	<b>-0,66</b>		<b>115,97</b>	
(4) AF+M1+M2 +M3	254,56	0,1561	0,1535	-1,70	-0,07	119,37	
	252,34		0,1560	-0,05		115,77	
	256,40		0,1535	-1,69		118,37	
	201,66		0,1587	1,64		115,42	
	249,84		0,1584	0,33		110,92	
	<b>242,96</b>		<b>0,1560</b>	<b>-0,07</b>		<b>115,97</b>	
(5) AF+M1+M2 +M3+M4	155,97	0,1561	0,1572	0,69	-0,81	115,68	
	158,80		0,1559	-0,12		115,94	
	176,15		0,1535	-1,70		115,39	
	170,11		0,1554	-0,49		115,49	
	163,14		0,1523	-2,44		116,24	
	<b>164,83</b>		<b>0,1549</b>	<b>-0,81</b>		<b>115,75</b>	
(6) AF+M1+M2 +M3+M4+M5	157,75	0,1567	0,1560	-0,08	0,37	115,23	
	144,65		0,1563	0,14		115,83	
	148,67		0,1561	0,00		115,76	
	143,81		0,1558	-0,18		115,77	
	141,00		0,1592	0,33		116,46	
	<b>147,18</b>		<b>0,1567</b>	<b>0,37</b>		<b>115,81</b>	

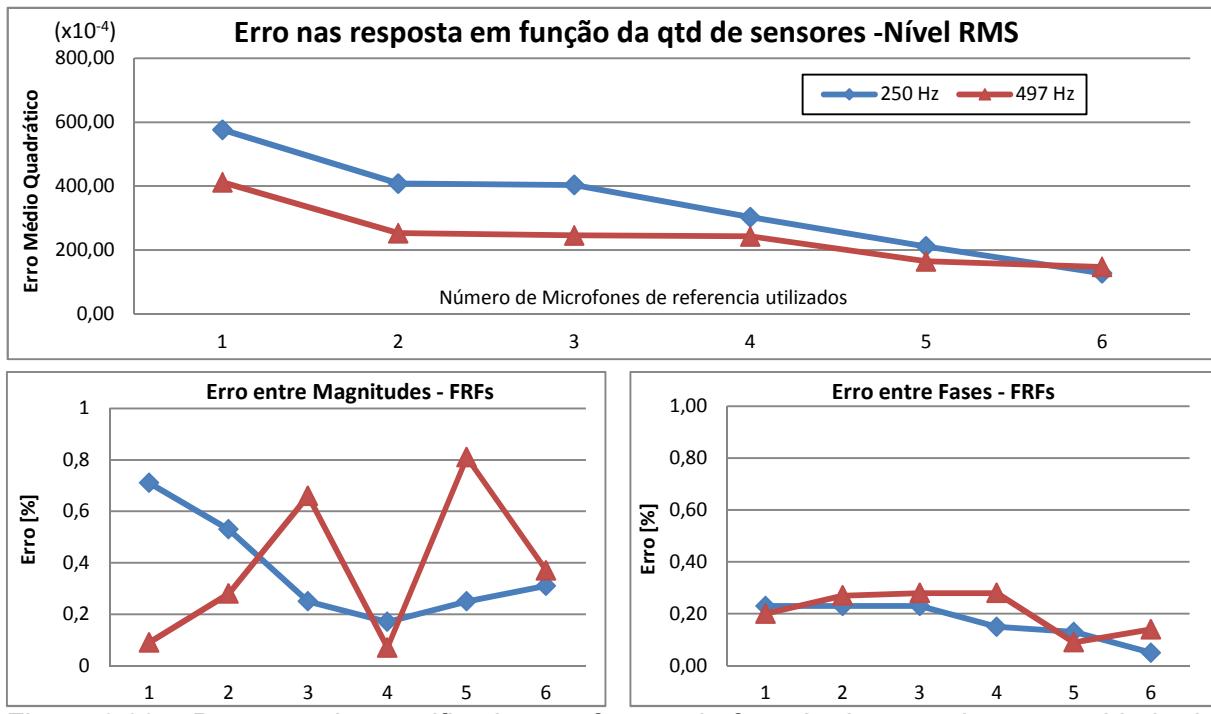


Figura 6.20 – Desempenhos verificados em função da frequência ao variar a quantidade de sensores utilizados na referencia.

Note que as estimativas ficam mais exatas, pela redução do nível RMS, ao aumentar o número de sensores utilizados (fig. 6.20(a)). Verifica-se ainda erro abaixo de 0,80 % na magnitude e 0,30 % na fase das FRFs.

Pode-se observar que 01 sensor é capaz de prever o campo sonoro de forma adequada, apresentando como vantagem baixa sensibilidade a ruídos sonoros e como desvantagem a insensibilidade devido a alterações na dinâmica da sala (fig. 6.18a e 6.19a). A utilização de 02 sensores parece ser adequada para a estimativa (fig. 6.18b e 6.19b), tendo-se como base os erros verificados na magnitude, fase e no nível RMS. A utilização de mais sensores melhora bem a estimativa, sendo também afetado por ruídos e fontes externas.

#### 6.3.4 Qualidade da estimativa em função do posicionamento do sensor de referencia

Para a resposta em função da localização do sensor de referencia, utilizou-se a mesma configuração NARX (AF+M1)x05x01 [08]/[08], 32 vetores com 750 pontos cada e frequências de excitação em 250 e 497 Hz. Mantiveram-se inalterados o sensor na fonte e o microfone (Mic6). Utilizou-se apenas o microfone (Mic1) como sensor de referencia. Na figura 6.13, a indicação (1) e (40), identificam as posições extrema do conjunto de posições. Na primeira avaliação o Mic1 ficou na posição (5), e posteriormente variando de (5) em (5)

até a posição (40). Neste caso, também foram realizados 05 treinamentos sucessivos onde se considera a média obtida. As tabelas 6.12 e 6.13 consolidam as respostas. A figura 6.21 apresentam as respostas nas frequências utilizadas.

Tabela 6.12 – Estimativas obtidas em função do posicionamento do Mic1 250 Hz.

Posição	RMS	Magnitude da FRF			Fase da FRF		
	EMQ ( $\times 10^{-4}$ )	Sinal		Erro [%]	Sinal		Erro [%]
		Medido	Estimado		Medido	Estimado	
1-(05)	443,53	0,4588	0,4591	0,07	-26,11	-25,99	-0,45
	539,48		0,4540	-1,05		-26,43	1,24
	549,94		0,4564	-0,52		-25,44	-2,56
	511,76		0,4461	-2,77		-26,31	0,76
	564,15		0,4654	1,44		-26,04	-0,28
	<b>Média =</b> <b>521,77</b>		<b>0,4562</b>	<b>-0,57</b>		<b>-26,04</b>	<b>-0,26</b>
2-(10)	365,06	0,5462	0,5517	0,17	-66,17	-65,53	-1,06
	418,71		0,5513	0,09		-66,19	-0,05
	428,04		0,5560	0,95		-66,41	0,27
	407,31		0,5453	-1,00		-66,06	-0,26
	402,74		0,5477	-0,55		-66,37	0,22
	<b>Média =</b> <b>404,37</b>		<b>0,5504</b>	<b>-0,07</b>		<b>-66,11</b>	<b>-0,18</b>
3-(15)	332,87	0,5427	0,5427	-0,01	-66,77	-62,07	0,48
	316,86		0,5425	-0,04		-61,91	0,23
	341,19		0,5414	-0,25		-61,94	0,27
	315,86		0,5412	-0,27		-62,03	0,42
	323,93		0,5327	-1,85		-61,70	-0,11
	<b>Média =</b> <b>326,14</b>		<b>0,5401</b>	<b>-0,48</b>		<b>-61,93</b>	<b>0,26</b>
4-(20)	250,71	0,5621	0,5571	-0,89	-64,60	-64,66	0,09
	317,42		0,5631	0,17		-64,14	-0,72
	255,89		0,5601	-0,36		-64,51	-0,14
	354,84		0,5590	-0,56		-65,86	1,95
	254,88		0,5617	-0,08		-64,47	-0,20
	<b>Média =</b> <b>286,75</b>		<b>0,5602</b>	<b>-0,34</b>		<b>-64,73</b>	<b>0,20</b>
5-(25)	328,74	0,5675	0,5591	-1,48	-56,78	-56,42	-0,63
	463,33		0,5636	-0,68		-57,88	1,94
	458,17		0,5630	-0,79		-57,10	0,57
	477,10		0,5706	0,55		-56,12	-1,17
	446,54		0,5584	-1,59		-56,40	-0,67
	<b>Média =</b> <b>434,78</b>		<b>0,5630</b>	<b>-0,80</b>		<b>-56,78</b>	<b>0,01</b>
6-(30)	554,36	0,4511	0,4383	-2,83	-54,43	-54,28	-0,28
	501,92		0,4495	-0,35		-54,14	-0,54
	553,39		0,4411	-2,22		-54,48	0,09
	475,02		0,4497	-0,29		-54,48	0,09
	450,49		0,4447	-1,41		-54,71	0,51
	<b>Média =</b> <b>507,04</b>		<b>0,4447</b>	<b>-1,42</b>		<b>-54,42</b>	<b>-0,02</b>
7-(35)	375,42	0,5683	0,5613	-1,66	-56,83	-56,38	-0,79
	321,75		0,5703	-0,08		-56,80	-0,05
	346,80		0,5712	0,07		-56,56	-0,46
	371,52		0,5740	0,56		-55,91	-1,61
	386,64		0,5765	1,01		-57,41	1,03
	<b>Média =</b> <b>360,42</b>		<b>0,5707</b>	<b>-0,02</b>		<b>-56,61</b>	<b>-0,38</b>
8-(40)	380,61	0,5729	0,5769	-0,02	-52,60	-52,88	0,53
	382,67		0,5814	0,77		-53,14	1,03
	369,35		0,5802	0,56		-52,93	0,63
	368,80		0,5750	-0,35		-52,67	0,14
	416,11		0,5750	-0,34		-52,66	0,11
	<b>Média =</b> <b>383,51</b>		<b>0,5777</b>	<b>0,12</b>		<b>-52,86</b>	<b>0,49</b>

Tabela 6.13 – Estimativas obtidas em função do posicionamento do Mic1 497 Hz.

Posição	RMS	Magnitude da FRF			Fase da FRF		
	EMQ ( $\times 10^{-4}$ )	Sinal		Erro [%]	Sinal		Erro [%]
		Medido	Estimado		Medido	Estimado	
1-(05)	188,17	0,5886	0,5883	-0,05	137,02	136,98	-0,03
	253,72		0,5769	-1,98		135,75	-0,92
	210,12		0,5887	0,03		136,98	-0,03
	208,24		0,5856	-0,51		137,54	0,38
	219,59		0,5889	0,06		137,38	0,27
	<b>Média =</b>	<b>215,97</b>	<b>0,5857</b>	<b>-0,49</b>		<b>136,93</b>	<b>-0,07</b>
2-(10)	231,68	0,1561	0,1575	0,91	115,65	115,28	-0,32
	238,63		0,1574	0,83		115,88	0,20
	237,50		0,1556	-0,34		115,77	0,11
	243,88		0,1585	1,50		115,15	-0,43
	243,20		0,1563	0,11		114,81	-0,73
	<b>Média =</b>	<b>238,98</b>	<b>0,1571</b>	<b>0,60</b>		<b>115,38</b>	<b>-0,23</b>
3-(15)	229,46	0,2417	0,2429	0,49	106,59	106,66	0,07
	251,60		0,2449	1,31		106,89	0,29
	234,17		0,2428	0,45		106,47	-0,11
	247,09		0,2406	-0,48		107,52	0,88
	226,65		0,2420	0,11		106,46	-0,12
	<b>Média =</b>	<b>237,80</b>	<b>0,2426</b>	<b>0,38</b>		<b>106,80</b>	<b>0,20</b>
4-(20)	347,68	0,3366	0,3335	-0,94	101,43	101,75	0,31
	355,35		0,3267	-2,94		101,85	0,41
	337,49		0,3453	2,57		102,71	1,26
	328,52		0,3352	-0,43		101,59	0,15
	341,92		0,3399	0,97		100,98	-0,45
	<b>Média =</b>	<b>342,19</b>	<b>0,3361</b>	<b>-0,15</b>		<b>101,78</b>	<b>0,34</b>
5-(25)	192,72	0,5631	0,5637	0,12	118,67	118,55	-0,10
	201,06		0,5606	-0,43		118,55	-0,10
	224,44		0,5634	0,06		118,61	-0,05
	203,46		0,5740	1,95		118,93	0,22
	201,69		0,5622	-0,16		118,40	-0,23
	<b>Média =</b>	<b>204,68</b>	<b>0,5648</b>	<b>0,31</b>		<b>118,61</b>	<b>-0,05</b>
6-(30)	321,89	0,5356	0,5387	-0,42	155,59	155,90	0,19
	298,59		0,5389	-0,38		155,31	-0,18
	300,90		0,5411	0,02		156,09	0,32
	285,08		0,5386	-0,44		155,85	0,16
	296,98		0,5404	-0,11		155,27	-0,21
	<b>Média =</b>	<b>300,69</b>	<b>0,5395</b>	<b>-0,27</b>		<b>155,68</b>	<b>0,06</b>
7-(35)	451,49	0,3014	0,2987	-0,89	91,50	94,08	2,82
	453,71		0,2993	-0,71		92,22	0,78
	394,05		0,3075	2,03		91,59	0,10
	424,46		0,3036	0,73		91,57	0,08
	426,21		0,3079	2,14		91,58	0,09
	<b>Média =</b>	<b>429,98</b>	<b>0,3034</b>	<b>0,66</b>		<b>92,21</b>	<b>0,77</b>
8-(40)	177,72	0,3283	0,3282	0,03	98,08	98,27	0,19
	173,55		0,3288	0,23		98,08	0,01
	190,47		0,3292	0,35		97,87	-0,21
	177,60		0,3272	-0,28		98,33	0,26
	169,38		0,3301	0,63		98,20	0,13
	<b>Média =</b>	<b>177,74</b>	<b>0,3287</b>	<b>0,19</b>		<b>98,15</b>	<b>0,08</b>

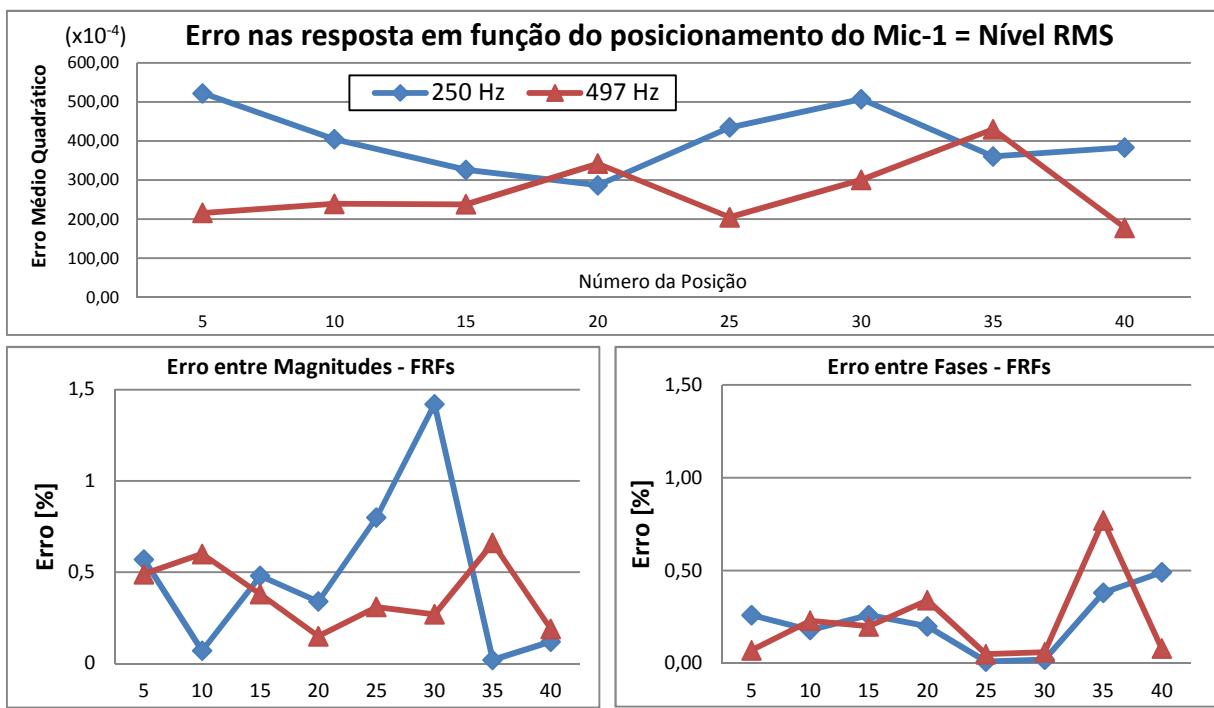


Figura 6.21 – Desempenhos verificados ao variar posição do Mic1, utilizado como sensor de referência.

Para avaliar o que se mostra na figura 6.21, deve-se considerar a acústica de salas especialmente a influencia dos modos acústicos. Ao mudar o posicionamento do microfone (Mic1), o sinal medido é afetado por regiões de ressonância e antirressonância, sendo que nas frequências elevadas o campo torna-se difuso como havia sido indicado na simulação do campo acústico da sala. Esta é a razão da oscilação no nível RMS. Tem-se, portanto, que o sinal estimado não apresenta tendências em função do posicionamento do sensor de referência na sala.

## 6.4 Aprimoramentos da rede neural via otimização de parâmetros

Devido a enorme gama de combinação que são possíveis para a configuração de uma rede neural, foi utilizado o processo de otimização baseado na evolução diferencial para indicar o número de neurônios, a quantidade de atrasos nas linhas direta e recorrente, o número de vetores e a quantidade de amostras no vetor. Utilizou-se a arquitetura NARX com duas camadas ocultas e as entradas (AF+M1) para possibilitar a comparação com os estudos anteriores. Todos os indivíduos no processo de otimização foram treinados utilizando os mesmos sinais de aquisição, sendo os obtidos na 2<sup>a</sup> aquisição (fig. 6.13).

O processo de otimização é uma técnica que tenta identificar o mínimo global de uma função. Porém, no caso das redes neurais esta condição de mínimo é mais complicada de ser obtida pelo fato das redes neurais não serem funções, mas modelos com parâmetros ajustados que se adaptam de forma diferente a cada treinamento e portanto, apresentam diferenças nas respostas a cada treinamento submetido, mesmo que não haja qualquer mudança nos dados ou na configuração da rede.

Devido a esta situação, foram realizados 05 treinamentos consecutivos para cada indivíduo na otimização, mantendo-se as configurações. Como resposta, foi considerado a média dos EMQ's para os 04 melhores resultados dentre os 05 treinamentos realizados. Foi estabelecida uma população de 50 indivíduos no processo de otimização, 50 gerações e dois processos iterativos. Portanto, foram realizados  $5 \times 2550 \times 2$  treinamentos para cada frequência de excitação.

Para evitar complexidade da rede e precaver a possibilidade de super ajustagem, otimizou-se as seguintes variáveis entre os respectivos limites:

- |                                    |            |             |
|------------------------------------|------------|-------------|
| • Número de neurônios (NN)         | mín. = 03  | máx. = 10   |
| • Atraso na linha direta (ALD)     | mín. = 04  | máx. = 20   |
| • Atraso na linha recorrente (ALR) | mín. = 04  | máx. = 10   |
| • Quantidade de vetores (QV).      | mín. = 04  | máx. = 16   |
| • Número de pontos no vetor (NPV)  | mín. = 100 | máx. = 1000 |

#### 6.4.1 Rede neural otimizada na frequência de 250 Hz:

Ao otimizar, foram obtidos 5100 valores médios para o EMQ, situados entre  $307,43 \times 10^{-4}$  a  $12225,66 \times 10^{-4}$ . O menor valor médio do EMQ foi obtido pela rede  $(AF+M1) \times 09 \times 01$  [20]/[04], com 16 vetores e 614 pontos em cada. Entretanto, utilizar a rede com o melhor resultado não garante sempre o melhor desempenho. Isso porque o processo de otimização é uma técnica que tenta identificar o mínimo global de uma função. Contudo, as redes neurais não são funções e sim modelos com parâmetros ajustados que se adaptam de forma diferente a cada treinamento.

Por esta razão foi proposto um método para identificar o indivíduo mais frequente já que no algoritmo de evolução, o melhor indivíduo evolui a partir dos indivíduos mais promissores. Ao plotar o histograma com 5100 valores do EMQ, como mostrado na figura 6.22(a), notam-se 52 eventos em  $432,00 \times 10^{-4}$  e  $435,00 \times 10^{-4}$ . Supondo o valor de  $434,00 \times 10^{-4}$  como mediana a partir do melhor resultado em  $307,43 \times 10^{-4}$  tem-se uma amostra onde se aglomera 77,43% dos indivíduos. A figura 6.22(b) ilustra esta distribuição.

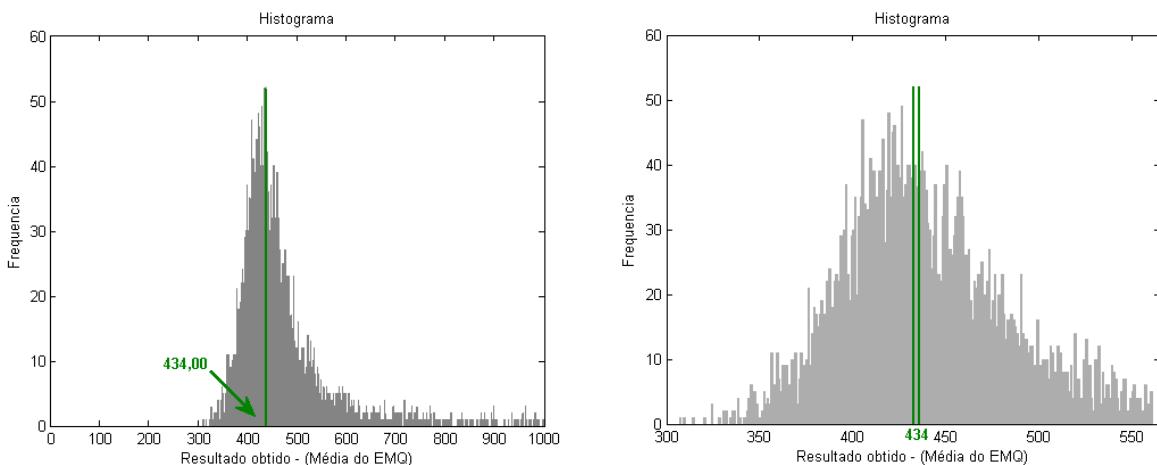


Figura 6.22 – Número de eventos para: (a) todos os resultados, (b) resultados próximos à ocorrência mais frequente.

Nota-se que não se trata de uma distribuição estatística, mas um conjunto de resultados obtidos pela otimização em torno da ocorrência mais frequente. Do grupo apresentado na Fig. 6.22(b) uma rede com 03 neurônios aparece 777 vezes, 1333 vezes com 20 elementos no atraso na linha direta e 1465 vezes com 04 elementos no atraso na linha recorrente.

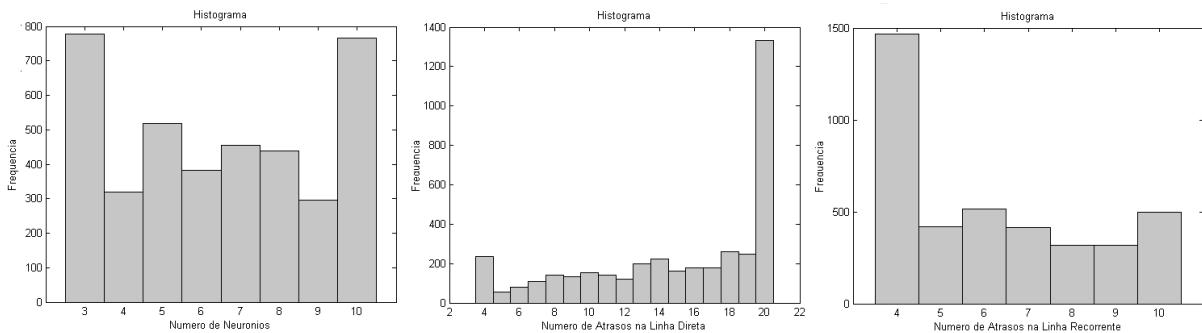


Figura 6.23 – Histograma das ocorrências para: (a) o número de neurônios, (b) o número de atrasos na linha direta e (c) o número de atrasos da linha recorrente.

A figura 6.23 mostra que as redes mais frequentes evoluem para indivíduos com 03 ou 10 neurônios, 20 atrasos na linha direta e com 04 atrasos na linha recorrente. Na tabela 6.14 são apresentados os 10 indivíduos com as maiores ocorrências, onde o indivíduo selecionado pela otimização aparece em 9º lugar.

Tabela 6.14 – Redes neurais que apresentaram as maiores ocorrências na otimização.

	Rede NARX (AF+M1)x...	Ocorrências	Valor min. ( $\times 10^{-4}$ )	Valor máx. ( $\times 10^{-4}$ )
<b>01</b>	...x10x01 [20]/[04]	117	331,09	559,95
<b>02</b>	...x03x01 [20]/[04]	106	351,44	545,97
<b>03</b>	...x08x01 [20]/[04]	75	362,19	557,48
<b>04</b>	...x05x01 [20]/[04]	71	335,73	557,22
<b>05</b>	...x06x01 [20]/[04]	69	343,14	551,16
<b>06</b>	...x04x01 [20]/[04]	55	330,60	558,40
<b>07</b>	...x07x01 [20]/[04]	55	324,28	495,66
<b>08</b>	...x03x01 [20]/[06]	51	328,40	557,39
<b>09</b>	...x09x01 [20]/[04]	37	307,43	518,51
<b>10</b>	...x10x01 [20]/[05]	34	320,79	551,60
<hr/>				
<b>Total</b>	com 03 neurônios	157		
	com 10 neurônios	151		
	com 08 neurônios	75		
	com 05 neurônios	71		
	com 06 neurônios	69		
	com 04 neurônios	55		
	com 07 neurônios	55		
	com 09 neurônios	37		

Pode-se evidenciar que houveram 157 ocorrências para as redes com 03 neurônios e 20 elementos no atraso da linha direta. Portanto, a rede NARX do tipo (AF+M)x03x01 [20]/[04] parece ser a mais indicada em 250 Hz com 106 ocorrências, também pelo menor tempo de processamento ao comparar com uma rede com 10 neurônios.

#### 6.4.2 Rede neural otimizada na frequência de 497 Hz:

De forma equivalente, foram avaliadas respostas obtidas do EMQ entre  $231,42 \times 10^{-4}$  a  $15625,03 \times 10^{-4}$  onde a rede  $(AF+M1) \times 10 \times 01$  [13]/[10], com 1000 pontos e 15 vetores apresentou o menor valor médio.

Para identificar o indivíduo mais frequente, plota-se o histograma com os 5100 valores do EMQ, conforme figura 6.24(a). Verifica-se 179 ocorrências em  $264,00 \times 10^{-4}$ .

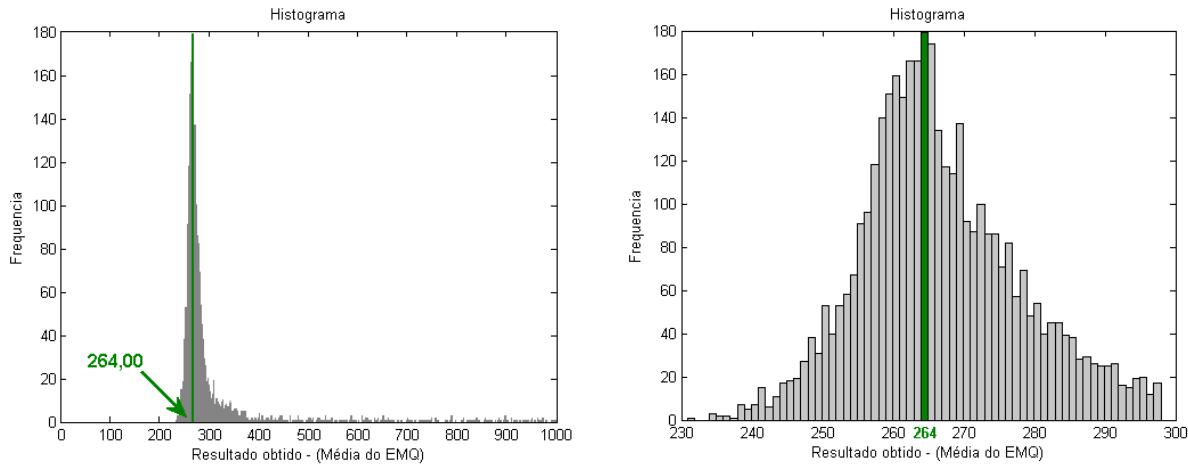


Figura 6.24 – Número de eventos para: (a) todos os resultados, (b) resultados próximos à ocorrência mais frequente.

Supondo o resultado  $264,00 \times 10^{-4}$  como mediana a partir do menor valor, calcula-se o limite superior em  $297,00 \times 10^{-4}$  e assim tem-se uma amostra com 3869 elementos que abrange 75,86% do total. A figura 6.24(b) ilustra esta distribuição. Salienta-se que não se trata de uma distribuição estatística, mas um conjunto de resultados em torno da ocorrência mais frequente.

A figura 6.25 mostra que a configuração com 03 neurônios aparece 1176 vezes, 1189 vezes com 20 elementos no atraso da linha direta aparece e 987 vezes com 10 elementos no atraso da linha recorrente.

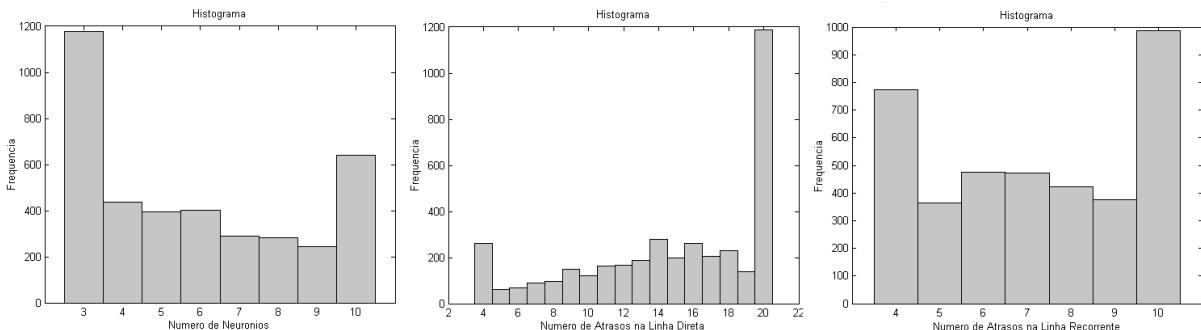


Figura 6.25 – Histograma das ocorrências para: (a) o número de neurônios, (b) o número de atrasos na linha direta e (c) o número de atrasos da linha recorrente.

Pode-se observar que a rede de melhor performance evolui para indivíduos com 03 ou 10 neurônios, com 20 atrasos na linha direta e com 10 ou 04 atrasos na linha recorrente. Na tabela 6.15 apresentamos os 10 indivíduos com as maiores ocorrências na otimização.

Tabela 6.15 – Redes neurais que apresentaram as maiores ocorrências na otimização.

	Rede NARX (AF+M1)x...	Ocorrências	Valor min. ( $\times 10^{-4}$ )	Valor máx. ( $\times 10^{-4}$ )
<b>01</b>	...x03x01 [20]/[04]	84	251,62	295,11
<b>02</b>	...x10x01 [20]/[10]	81	239,98	289,79
<b>03</b>	...x03x01 [20]/[10]	68	243,94	295,75
<b>04</b>	...x03x01 [20]/[07]	47	247,40	291,37
<b>05</b>	...x03x01 [20]/[06]	46	247,94	294,57
<b>06</b>	...x03x01 [20]/[05]	42	250,80	290,93
<b>07</b>	...x03x01 [20]/[08]	42	244,74	295,93
<b>08</b>	...x03x01 [20]/[09]	40	249,73	292,99
<b>09</b>	...x10x01 [20]/[04]	33	242,03	297,51
<b>10</b>	...x06x01 [20]/[10]	32	236,84	290,08
		com 03 neurônios	369	
<b>Total</b>		com 10 neurônios	114	
		com 06 neurônios	32	

Pode-se evidenciar que houveram 369 ocorrências para as redes com 03 neurônios e 20 elementos no atraso da linha direta. A rede NARX do tipo (AF+M)x03x01 [20]/[04] parece ser a mais indicada em 497 Hz com 84 ocorrências. A tabela 6.16 apresenta ainda uma comparação entre a rede otimizada, a de maior número de ocorrências e a rede trabalhada nos tópicos anteriores.

Tabela 6.16 – Comparaçao do EMQ entre as redes neurais avaliadas em 497 Hz.

NARX (AF+M1)...	EMQ ( $\times 10^{-4}$ )				Média	Desvio Padrão
...x10x01 [13]/[10]	241,36	256,08	*2309,10	237,91	233,19	
	259,91	272,35	249,73	258,78	259,44	254,61
	256,96	259,44	259,46	259,29	260,68	10,50
...x03x01 [20]/[04]	235,97	259,21	242,51	257,03	239,90	
	265,80	266,88	235,64	234,72	263,51	255,17
	269,06	260,89	263,16	268,36	264,94	13,26
...x03x01 [08]/[08]	*5228,30	256,75	258,32	254,25	267,08	
	271,29	259,90	255,96	262,59	274,22	265,14
	268,09	267,65	281,42	284,85	259,73	9,48

\* Valores eliminados pelo critério de Chauvenet.

A rede selecionada pelo número de ocorrências pode ser indicada por apresentar menor tempo de processamento, embora tenha apresentado resultado equivalente à rede otimizada. Houveram ainda duas instabilidades no treinamento das redes com valores discrepantes em relação a média.

## 6.5 Consolidação das configurações

Baseados na informação de que não há regras para uma boa arquitetura de rede, é recomendável que se faça um estudo experimental exaustivo para obter a melhor configuração (HAYKIN, 2001). Assim, foram estabelecidos parâmetros de configuração para avaliar o desempenho de seis arquiteturas de redes. A rede baseada na arquitetura NARX foi a que apresentou melhores resultados de performance e menor tempo de processamento na fase de treinamento.

Havendo selecionado a arquitetura básica, foram avaliados os sinais de treinamento e os sinais de entrada para a rede neural. Com relação aos sinais de treinamento, as respostas ficaram melhores quando se utilizou vetores com amostras do sinal, ao invés de apenas um vetor com grande número de amostras, apresentando ainda a vantagem do menor tempo de treinamento para a rede. As respostas obtidas neste estudo foram avaliadas em termos de magnitude, fase e nível RMS. Com relação aos sinais de entrada foram avaliadas as respostas em função da quantidade de sensores e a localização destes no ambiente. Quando se utilizou apenas o sensor na fonte de ruído, foi possível caracterizar o sinal acústico na sala sem interferência devido a ruídos no ambiente. Como desvantagem apresenta insensibilidade devido a alterações na dinâmica da sala. Ao acrescentar um sensor como referência, têm-se a sensibilidade devido ao campo reverberante e também de ruídos. Foi verificado ainda que a posição do sensor de referência é irrelevante para a qualidade do sinal, mas recomenda-se uma proximidade ao ponto estimado.

Devido a enorme gama de combinação possíveis para estabelecer a configuração de uma rede neural, foi utilizado o processo de otimização baseado na evolução diferencial para indicar o número de neurônios, a quantidade de atrasos nas linhas direta e recorrente, o número de vetores e a quantidade de amostras no vetor, no sentido de aprimorar as respostas estimadas. Com base no processo de otimização e da identificação do indivíduo mais frequente indicou-se a configuração (A+M1) 03x01 [20]/[04] para as duas frequências analisadas.

# CAPÍTULO VII

## AVALIAÇÃO DA RESPOSTA VIRTUAL

### 7.1 Introdução

Após abordar a arquitetura e o treinamento da rede neural, far-se-á a avaliação da resposta virtual em função da característica dinâmica da sala e de perturbações. Neste capítulo, serão consideradas as seguintes etapas:

- Estimar uma resposta interpolada com base nos sensores de referência utilizados;
- Verificar a resposta virtual ao considerar variações no nível de pressão sonora e a descaracterização do ambiente (mudanças no layout que afetem as características reverberantes da sala).
- Verificar a estimativa de um sinal harmônico utilizando uma rede neural treinada com sinais de ruído branco.

### 7.2 Estimativa na vizinhança do ponto virtual

Nesta etapa, utilizam-se um sensor no autofalante e seis microfones, sendo que os microfones Mic1 ao Mic5 ficaram dispostos em uma linha e o microfone Mic6 posicionado ao lado. Ao contrário dos estudos anteriores, os Mic1 ao Mic5 foram utilizados para treinar a resposta virtual e o Mic6 usado como referência. Para este estudo, foram obtidas 04 aquisições, conforme se eleva a distância entre os sensores. Os sensores Mic1 ao Mic5 foram afastados entre si nas distâncias de 100, 150, 200 e 300 mm, como indicado na figura 7.1. Não houve alteração de posição dos sensores Mic4, Mic6 e na fonte sonora durante todo o procedimento. O Mic4 foi para que a resposta no ponto seja a mesma em todas as aquisições. A figura 7.2 mostra a foto da 1<sup>a</sup> e da 3<sup>a</sup> aquisição, cujos afastamentos entre os sensores estavam em 100 e 200 mm respectivamente.

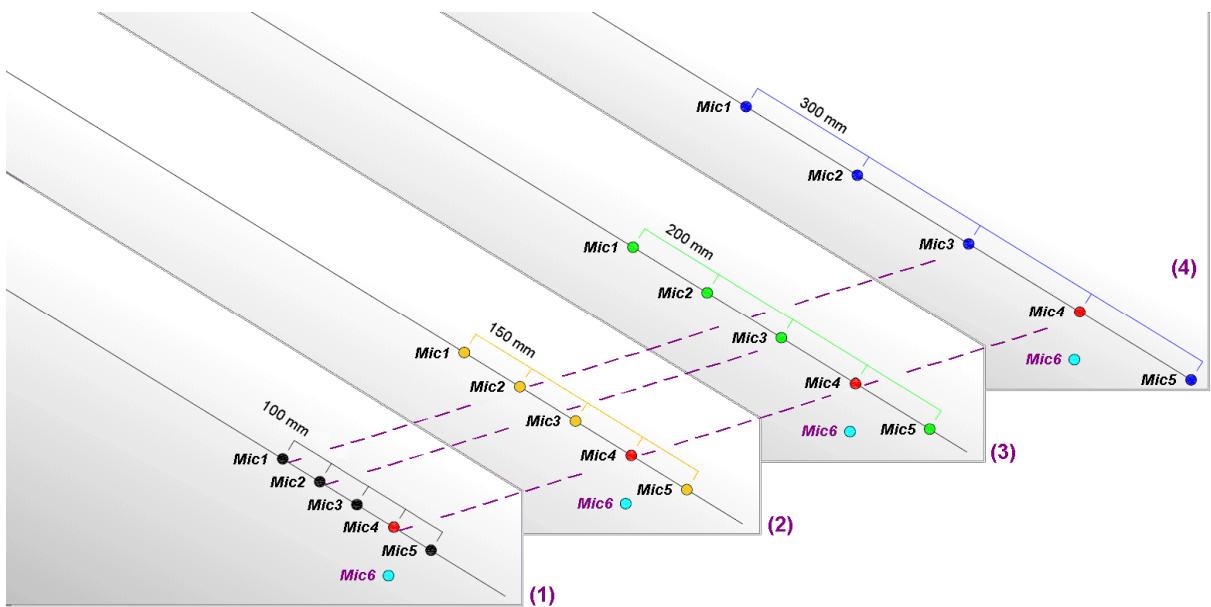


Figura 7.1 – Distribuição dos microfones nas 4 aquisições, indicadas por (1), (2), (3) e (4).

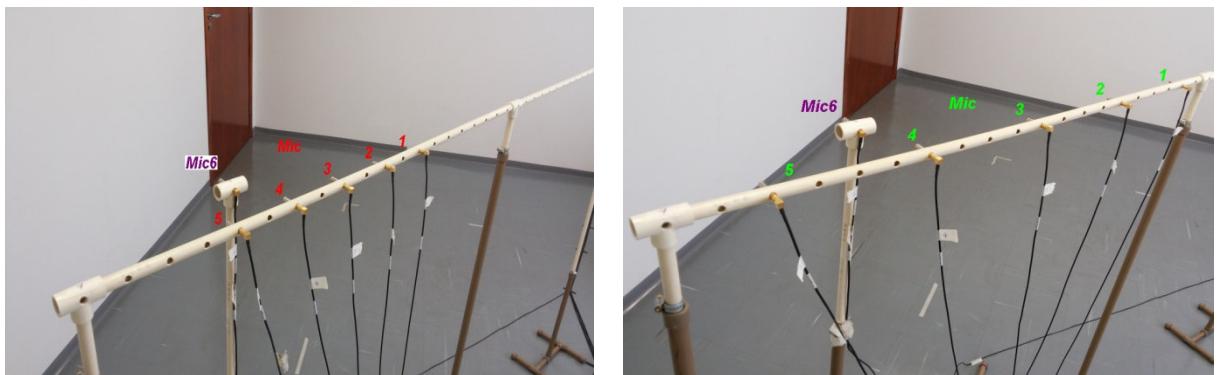


Figura 7.2 – Distribuição dos microfones e detalhe do suporte. (a) Foto da 1<sup>a</sup> aquisição (b) Foto da 3<sup>a</sup> aquisição.

Para relacionar todas as aquisições no mesmo sistema de coordenadas, foi referenciado um valor de posição para cada cavidade do suporte (fig. 7.2). Desta forma, as posições 1 e 25 identificam os pontos mais extremos, sendo 50 mm o espaço entre duas posições adjacentes. Assim, os sensores na 4<sup>a</sup> aquisição ficaram nas posições 1, 7, 13, 19 e 25. O Mic4 se manteve na posição 19 em todas as aquisições.

Para as estimativas, foram gerados sinais em 250 e 497 Hz, com aquisição na faixa de 0 a 1640 Hz, 8192 pontos de amostragem e tempo de aquisição em 49,95 s. Utilizou-se a rede NARX (AF+M6+Posição esperada da resposta)x03x01 [20]/[04], 30 vetores com 350 pontos cada.

### 7.2.1 Respostas obtidas entre os sensores na frequência de 250 Hz

As tabelas 7.1 a 7.4 apresentam os dados medidos e estimados para cada uma das quatro aquisições. As tabelas contêm as estimativas utilizando 05 microfones no treinamento. Entre os sensores, os sinais foram estimados.

Tabela 7.1 – Magnitude e fase dos sinais na 1<sup>a</sup> aquisição em 250 Hz.

Posição	Treinamento com 05 sensores			
	Magnitude		Fase	
	Medido	Estimado	Medido	Estimado
13,0	0,72	0,71	24,79	25,46
13,4		0,68		21,12
13,8		0,65		16,22
14,2		0,62		10,91
14,6		0,61		5,30
15,0	0,60	0,59	-1,45	-0,41
15,4		0,58		-6,07
15,8		0,58		-11,57
16,2		0,57		-16,83
16,6		0,56		-21,86
17,0	0,58	0,56	-27,40	-26,67
17,4		0,55		-31,27
17,8		0,54		-35,71
18,2		0,52		-39,99
18,6		0,51		-44,15
19,0	0,49	0,50	-48,85	-48,17
19,4		0,48		-52,07
19,8		0,46		-55,83
20,2		0,45		-59,43
20,6		0,44		-62,89
21,0	0,43	0,42	-68,87	-66,16

Tabela 7.2 – Magnitude e fase dos sinais na 2<sup>a</sup> aquisição em 250 Hz.

Posição	Treinamento com 05 sensores			
	Magnitude		Fase	
	Medido	Estimado	Medido	Estimado
10,0	1,03	0,98	55,19	55,54
10,6		0,92		51,50
11,2		0,87		46,49
11,8		0,81		40,56
12,4		0,77		33,88
13,0	0,74	0,73	26,61	26,67
13,6		0,69		19,20
14,2		0,67		11,75
14,8		0,65		4,47
15,4		0,63		-2,54
16,0	0,62	0,61	-9,50	-9,30
16,6		0,58		-15,85
17,2		0,56		-22,30
17,8		0,54		-28,78
18,4		0,51		-35,38
19,0	0,49	0,48	-44,14	-42,25
19,6		0,46		-49,48
20,2		0,44		-57,16
20,8		0,42		-65,31
21,4		0,40		-73,84
22,0	0,36	0,39	-76,61	-82,58

Tabela 7.3 – Magnitude e fase dos sinais na 3<sup>a</sup> aquisição em 250 Hz.

Posição	Treinamento com 05 sensores			
	Magnitude		Fase	
	Medido	Estimado	Medido	Estimado
7,0	1,35	1,33	75,14	74,80
7,8		1,25		70,89
8,6		1,17		66,30
9,4		1,08		60,99
10,2		1,00		54,91
11,0	0,93	0,93	48,23	48,07
11,8		0,86		40,51
12,6		0,80		32,29
13,4		0,75		23,53
14,2		0,70		14,27
15,0	0,66	0,65	4,90	4,65
15,8		0,61		-5,21
16,6		0,58		-15,22
17,4		0,55		-25,27
18,2		0,52		-35,37
19,0	0,49	0,49	-45,42	-45,42
19,8		0,47		-55,30
20,6		0,45		-64,88
21,4		0,44		-73,94
22,2		0,43		-82,35
23,0	0,33	0,42	-89,96	-89,95

Tabela 7.4 – Magnitude e fase dos sinais na 4<sup>a</sup> aquisição em 250 Hz.

Posição	Treinamento com 05 sensores			
	Magnitude		Fase	
	Medido	Estimado	Medido	Estimado
1,0	1,43	1,43	105,15	105,25
2,2		1,41		103,39
3,4		1,36		99,90
4,6		1,28		94,67
5,8		1,18		87,64
7,0	1,07	1,07	78,33	78,85
8,2		0,96		68,39
9,4		0,85		56,50
10,6		0,76		43,56
11,8		0,67		29,85
13,0	0,61	0,59	15,31	15,63
14,2		0,52		1,00
15,4		0,47		-13,81
16,6		0,43		-28,31
17,8		0,40		-41,92
19,0	0,38	0,37	-53,38	-54,01
20,2		0,35		-64,18
21,4		0,34		-72,34
22,6		0,31		-78,57
23,8		0,29		-83,13
25,0	0,33	0,25	168,34	-86,28

As figuras 7.3 e 7.4 consolidam graficamente os dados das tabelas apresentadas. Os sinais medidos, utilizados no treinamento são indicados pelo marcador quadrado (em cores) e os estimados pelo marcador circular. As setas verdes mostram as respostas esperadas nas 4 aquisições e a seta em roxo destaca onde houve desvio na resposta esperada.

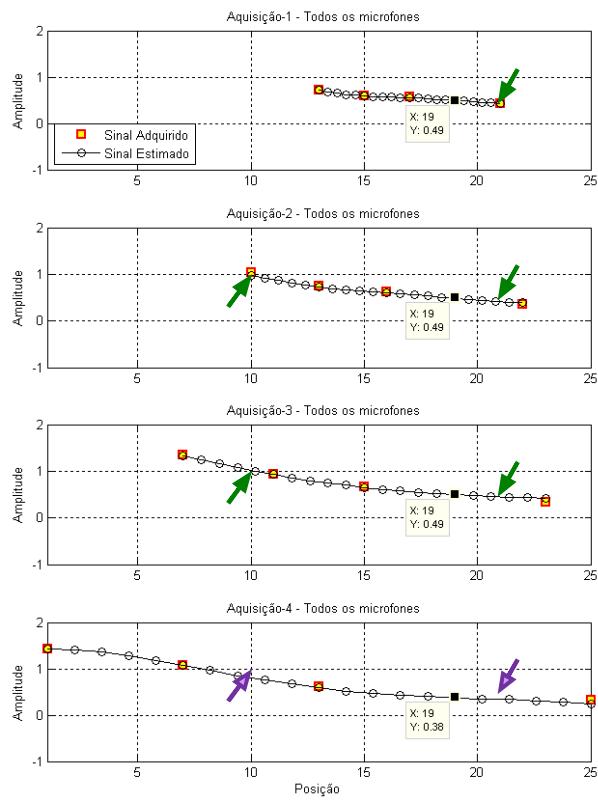


Figura 7.3 – Magnitude das FRF's medidas e estimadas em 250Hz. Utilizado 05 microfones na fase de treinamento.

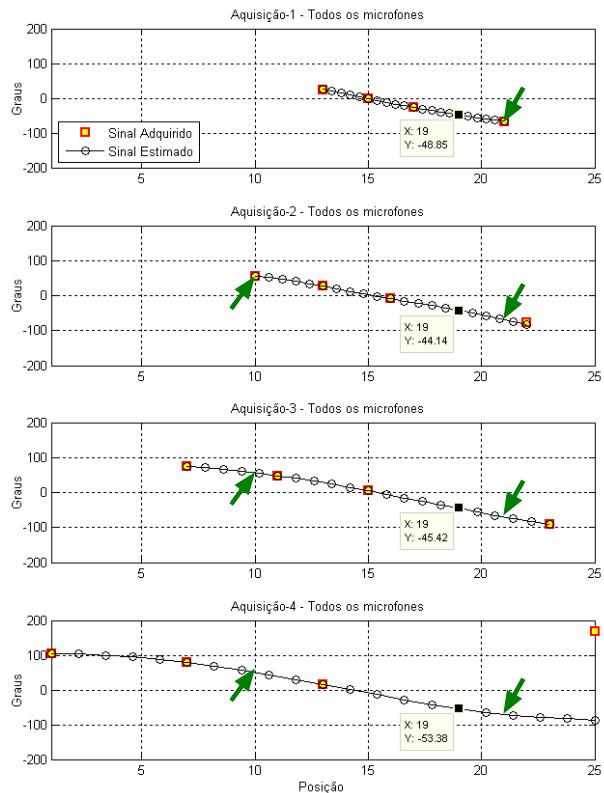


Figura 7.4 – Fase das FRF's medidas e estimadas em 250Hz. Utilizado 05 microfones na fase de treinamento.

Ao analisar as tabelas 7.1 a 7.4 e as figuras 7.3 e 7.4, pode-se observar que:

- Quanto menor a distância entre os sensores, melhor a estimativa (1<sup>a</sup> linha nas figuras 7.3 e 7.4 em comparação com as demais), principalmente na resposta de fase.
- Sensores em linha possibilita estimar o sinal em uma posição intermediária entre eles, conforme mostra a tendência das curvas nas quatro aquisições. Nota-se que um sinal medido em uma aquisição é estimado na outra, como indicado pelas setas.
- O desvio de estimativas observado na 4<sup>a</sup> aquisição é causado pelo maior afastamento entre os sensores.
- Para o treinamento utilizou-se 05 microfones conforme relatado. Na estimativa foi considerado apenas o sensor na fonte e o Mic6 como referência. Também foi indicado a posição de cada sensor virtual em cada resposta esperada. Toda as curvas de estimativas foi levantada com base nestes 03 parâmetros.
- Escolhemos duas posições quaisquer para indicar com setas. Em outras posições também é possível evidenciar respostas coerentes.

Estes resultados mostram que é possível obter uma estimativa remota em uma vizinhança ao invés um ponto apenas. Isso traz oportunidades, a possibilidade de utilizar diversos sensores virtuais e inclusive a possibilidade de implementar o deslocamento do sensor virtual em tempo real. Ambas as possibilidades são uma importante estratégia de controle quando há mais de uma frequência no sistema, objetivando assim, maximizar a eficiência.

O estudo para a frequência de 497 Hz foi realizado de forma equivalente, onde foram evidenciadas as mesmas observações.

### 7.2.2 Respostas obtidas por interpolação na frequência de 497 Hz

As tabelas 7.5 a 7.8 apresentam os dados medidos e estimados para cada uma das quatro aquisições em 497 Hz. As tabelas contêm as estimativas utilizando 05 microfones no treinamento. As figuras 7.5 e 7.6 consolidam os dados de magnitude e de fase das FRF's dos sinais.

Tabela 7.5 – Magnitude e fase dos sinais na 1<sup>a</sup> aquisição em 497 Hz.

Posição	Treinamento com 05 sensores			
	Magnitude		Fase	
	Medido	Estimado	Medido	Estimado
13,0	0,88	0,87	-51,25	-51,21
13,4		0,88		-50,92
13,8		0,86		-50,76
14,2		0,80		-51,31
14,6		0,75		-50,99
15,0	0,71	0,72	-50,18	-50,54
15,4		0,64		-50,83
15,8		0,56		-51,50
16,2		0,46		-52,77
16,6		0,37		-55,11
17,0	0,27	0,27	-60,57	-59,69
17,4		0,17		-70,09
17,8		0,10		-100,48
18,2		0,10		-161,22
18,6		0,17		170,11
19,0	0,28	0,25	157,94	160,03
19,4		0,34		155,33
19,8		0,41		152,69
20,2		0,49		150,99
20,6		0,55		149,77
21,0	0,58	0,61	154,05	148,81

Tabela 7.6 – Magnitude e fase dos sinais na 2<sup>a</sup> aquisição em 497 Hz.

Posição	Treinamento com 05 sensores			
	Magnitude		Fase	
	Medido	Estimado	Medido	Estimado
10,0	0,55	0,51	-48,49	-47,72
10,6		0,59		-47,80
11,2		0,66		-47,86
11,8		0,72		-47,98
12,4		0,76		-48,20
13,0	0,77	0,77	-50,74	-48,57
13,6		0,75		-49,12
14,2		0,70		-49,91
14,8		0,62		-51,06
15,4		0,52		-52,77
16,0	0,36	0,40	-57,33	-55,54
16,6		0,28		-60,72
17,2		0,16		-73,53
17,8		0,08		-122,66
18,4		0,12		172,50
19,0	0,32	0,20	156,00	155,45
19,6		0,28		149,58
20,2		0,34		147,00
20,8		0,39		145,86
21,4		0,42		145,55
22,0	0,46	0,43	162,03	145,81

Tabela 7.7 – Magnitude e fase dos sinais na 3<sup>a</sup> aquisição em 497 Hz.

Posição	Treinamento com 05 sensores			
	Magnitude		Fase	
	Medido	Estimado	Medido	Estimado
7,0	0,02	0,03	26,03	22,00
7,8		0,13		-41,58
8,6		0,27		-45,61
9,4		0,42		-45,98
10,2		0,57		-45,82
11,0	0,70	0,70	-46,23	-45,82
11,8		0,79		-46,26
12,6		0,82		-47,23
13,4		0,80		-48,80
14,2		0,72		-51,06
15,0	0,60	0,59	-54,42	-54,35
15,8		0,41		-59,91
16,6		0,23		-73,17
17,4		0,11		-124,36
18,2		0,17		172,86
19,0	0,28	0,27	156,58	157,02
19,8		0,35		151,92
20,6		0,41		150,06
21,4		0,46		149,69
22,2		0,50		150,16
23,0	0,36	0,53	158,74	151,23

Tabela 7.8 – Magnitude e fase dos sinais na 4<sup>a</sup> aquisição em 497 Hz.

Posição	Treinamento com 05 sensores			
	Magnitude		Fase	
	Medido	Estimado	Medido	Estimado
1,0	0,57	0,51	-136,29	-138,05
2,2		0,54		-139,82
3,4		0,56		-141,36
4,6		0,57		-142,49
5,8		0,54		-142,76
7,0	0,52	0,47	-152,68	-140,00
8,2		0,37		-126,51
9,4		0,29		-85,67
10,6		0,41		-40,93
11,8		0,60		-22,31
13,0	0,81	0,71	-12,73	-15,90
14,2		0,64		-16,09
15,4		0,39		-22,59
16,6		0,11		-72,97
17,8		0,24		-159,28
19,0	0,56	0,38	-178,27	-169,16
20,2		0,44		-172,34
21,4		0,46		-174,20
22,6		0,45		-175,31
23,8		0,43		-175,59
25,0	0,28	0,40	20,81	-174,85

De forma semelhante, as figuras 7.5 e 7.6 consolidam os dados das tabelas apresentadas. Os sinais medidos, utilizados no treinamento são indicados pelo marcador quadrado e os estimados pelo marcador circular.

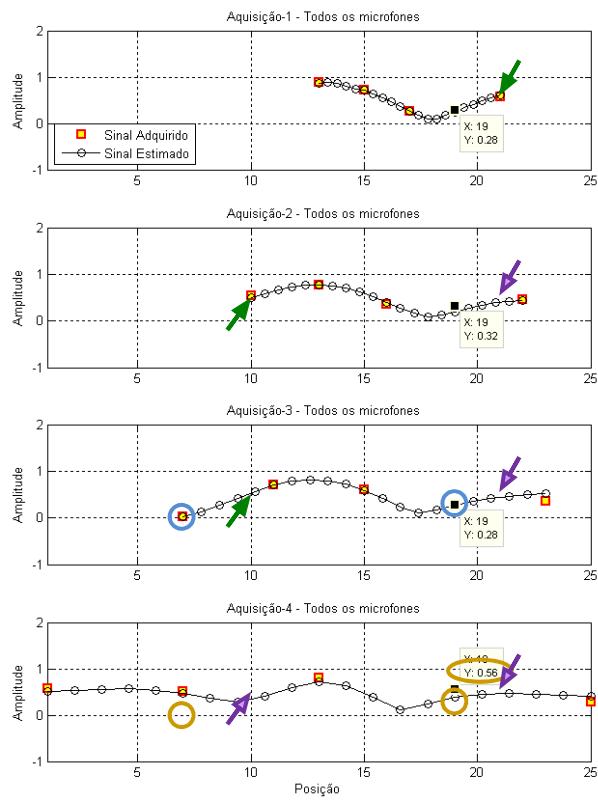


Figura 7.5 – Magnitude das FRF's medidas e estimadas em 497Hz. Foram utilizados 05 microfones na fase de treinamento.

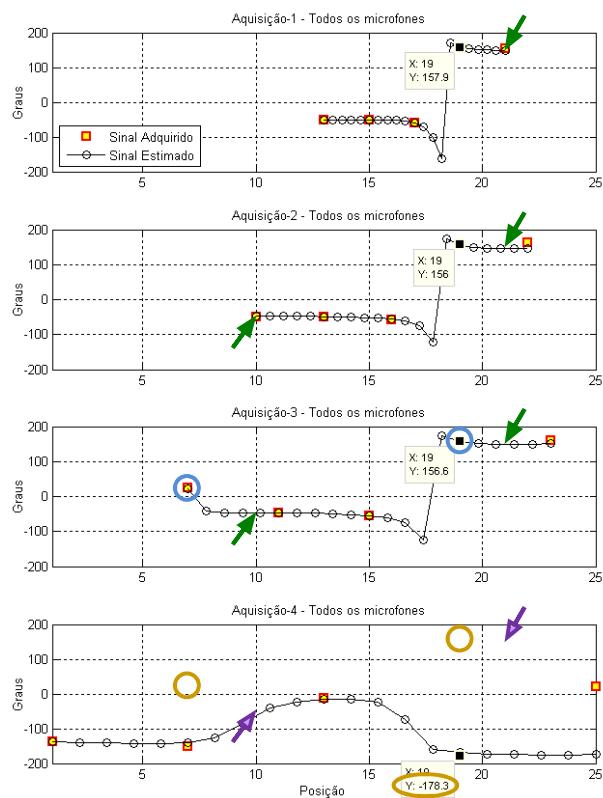


Figura 7.6 – Fase das FRF's medidas e estimadas em 497Hz. Foram utilizados 05 microfones na fase de treinamento.

Note que houve grande divergência na 4<sup>a</sup> aquisição em relação às demais, isso ocorreu porque houve queda de energia elétrica durante a aquisição. Ao refazer pode ter ocorrido saturação ou ruído eletrônico no sistema de aquisição, haja visto que no ponto 19 correspondente ao Mic4 (ponto comum), ficou fora do padrão, bem como os outros sensores utilizados ao comparar com as demais aquisições (destacado com círculo). Isto foi verificado somente durante a análise de dados, sendo assim, desconsideramos este resultado.

Como comentado no tópico anterior, tem-se as mesmas observações ao analisar as tabelas 7.5 até 7.8 e figuras 7.5 e 7.6. Os resultados mostram ser possível obter estimativas em uma vizinhança ao invés um ponto apenas e que, um conjunto (ou “array”) de microfones próximos produz melhores estimativas.

### 7.3 Resposta virtual conforme perturbações ou descaracterização do ambiente

A análise de sensibilidade apresentada no Capítulo V, mostra que a resposta acústica depende das características do ambiente, sendo bastante influenciado pela variação destes. Todos os fatores avaliados influenciam a acústica, entretanto a variação entre os níveis aberto e fechado para porta e janelas foram os mais relevantes em hierarquia. Na condução deste estudo, não será avaliado perturbações decorrentes da ocupação e da movimentação na sala, mas será introduzido variação nas amplitudes dos sinais para avaliar as respostas.

Os sinais de caracterização foram gerados nas amplitudes de 10, 12, 14, 16, 18 e 20 V e em 3 condições de sala (Janela aberta (JA), porta aberta (PA) e sala fechada (SF)), conforme consolidado na figura 7.7. Todos os sinais foram adquiridos na frequência de 250 Hz, faixa de 0 a 1640 Hz, com 8192 pontos, durante 4,99 s cada.

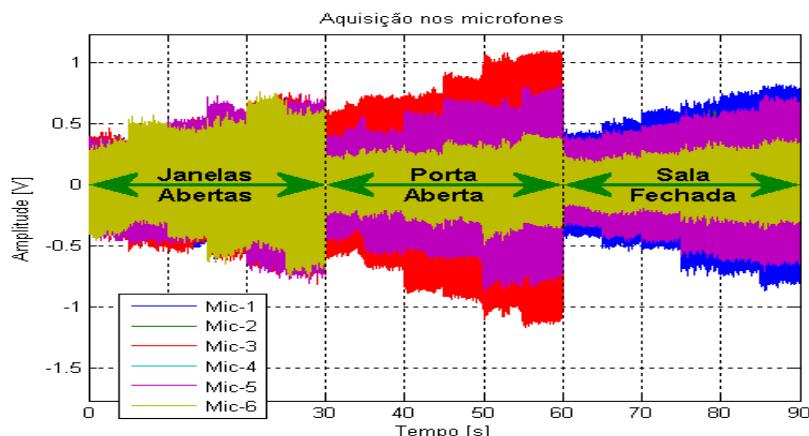


Figura 7.7 – Consolidação dos sinais adquiridos em seis microfones. São 18 amostras em 03 condições de sala. Observe que os sinais acústicos mudam para cada condição de sala

Estas amostras foram utilizadas no treinamento de 18 redes neurais. Todas tem a mesma configuração NARX (AF+M5)x03x01 [20]/[04], sendo: o sinal de vibração na fonte (AF), o sensor de referencia posicionado próximo ao ponto desejado (Mic5) e a resposta medida ou esperada (Mic6) no ponto remoto. A primeira rede foi treinada com 4,99 s do sinal apresentado na figura 7.7, a segunda com 9,98 s e a última incorpora todos os 89,92 s. As amostras de treinamento foram aleatorizadas em 06 vetores com 500 pontos cada. Para validação, mediu-se outros 03 sinais em 15 V durante 14,98 s, em cada uma das condições. As tabelas 7.9 a 7.11 apresentam as estimativas para cada um dos sinais de validação.

Tabela 7.9 – Validação (JA): Sinal em 15 V com porta fechada e janelas abertas.

	Amostras utilizadas no treinamento	Nptos	RMS (x 10 <sup>3</sup> )	Magnitude da FRF			Fase da FRF			
				Sinal		Erro [%]	Sinal		Erro [%]	
				Medido	Estimado		Medido	Estimado		
1	JA	4,99 s	03	370,63	0,89	0,89	0,54	-81,10	-83,04	2,39
2		9,98 s	06	2045,06		0,86	3,73		-84,13	3,74
3		14,97 s	09	729,62		0,87	2,10		-83,12	2,48
4		19,96 s	12	321,34		0,87	2,52		-83,45	2,89
5		24,95 s	15	767,41		0,87	2,56		-82,77	2,05
6		29,94 s	18	674,91		0,85	4,81		-81,65	0,68
7	PA	34,93 s	21	698,77	0,89	0,88	1,14	-81,10	-81,89	0,97
8		39,92 s	24	691,00		0,88	1,35		-81,71	0,75
9		44,91 s	27	492,83		0,88	1,02		-81,43	0,41
10		49,90 s	30	624,87		0,87	2,09		-81,88	0,96
11		54,89 s	33	468,87		0,87	2,19		-81,73	0,77
12		59,88 s	36	751,06		0,88	1,88		-81,70	0,73
13	SF	64,87 s	39	604,01	0,89	0,83	7,44	-81,10	-80,95	0,18
14		69,86 s	42	816,22		0,77	14,10		-80,95	0,19
15		74,85 s	45	701,12		0,85	5,23		-80,74	0,45
16		79,84 s	48	583,08		0,88	1,64		-81,61	0,62
17		84,83 s	51	668,24		0,88	1,72		-81,92	1,01
18		89,82 s	54	582,03		0,88	1,80		-82,34	1,52

Tabela 7.10 – Validação (PA): Sinal em 15 V obtido com porta aberta e janelas fechadas.

	Amostras utilizadas no treinamento	Nptos	RMS (x 10 <sup>3</sup> )	Magnitude da FRF			Fase da FRF			
				Sinal		Erro [%]	Sinal		Erro [%]	
				Medido	Estimado		Medido	Estimado		
1	JA	4,99 s	03	2931,86	0,51	1,05	107,92	-110,42	-66,45	39,82
2		9,98 s	06	2193,33		0,91	79,49		-74,55	32,48
3		14,97 s	09	2958,97		1,12	120,86		-74,61	32,43
4		19,96 s	12	2703,73		1,13	122,57		-76,97	30,29
5		24,95 s	15	3065,71		1,00	98,07		-88,19	20,13
6		29,94 s	18	1864,79		0,95	87,23		-89,27	19,16
7	PA	34,93 s	21	7450,85	0,51	0,57	13,27	-110,42	-113,71	2,98
8		39,92 s	24	934,54		0,53	4,19		-110,01	0,38
9		44,91 s	27	1307,81		0,52	3,04		-110,86	0,39
10		49,90 s	30	297,72		0,52	2,31		-110,47	0,04
11		54,89 s	33	443,25		0,51	1,35		-110,80	0,34
12		59,88 s	36	568,58		0,51	1,55		-110,89	0,42
13	SF	64,87 s	39	466,90	0,51	0,52	2,04	-110,42	-110,44	0,02
14		69,86 s	42	428,89		0,53	5,51		-110,27	0,14
15		74,85 s	45	475,73		0,52	3,04		-111,11	0,62
16		79,84 s	48	504,91		0,52	2,16		-110,98	0,51
17		84,83 s	51	450,71		0,52	2,59		-111,01	0,53
18		89,82 s	54	486,69		0,52	2,48		-110,87	0,41

Tabela 7.11 – Validação (SF): Sinal em 15 V obtido com a porta e as janelas fechadas.

	Amostras utilizadas no treinamento	Npts (x 10 <sup>3</sup> )	RMS (x 10 <sup>4</sup> )	Magnitude da FRF			Fase da FRF		
				Sinal		Erro [%]	Sinal		Erro [%]
				Medido	Estimado		Medido	Estimado	
1	JA	4,99 s	03	1576,71	0,84	88,64	-68,02	-85,71	26,02
2		9,98 s	06	1969,09	0,84	88,41		-85,52	25,73
3		14,97 s	09	1533,42	0,79	76,90		-82,02	20,59
4		19,96 s	12	1572,41	0,81	82,11		-83,72	23,08
5		24,95 s	15	1728,58	0,84	86,97		-81,25	19,46
6		29,94 s	18	1511,94	0,84	88,55		-79,80	17,33
7	PA	34,93 s	21	1808,72	0,94	109,19		-80,72	18,68
8		39,92 s	24	1832,42	0,96	113,71		-81,12	19,27
9		44,91 s	27	7992,21	0,96	113,60		-75,44	10,91
10		49,90 s	30	1827,30	0,94	110,19		-80,56	18,44
11		54,89 s	33	2405,58	0,95	111,86		-80,86	18,88
12		59,88 s	36	1864,65	0,96	115,51		-81,16	19,32
13	SF	64,87 s	39	1639,87	0,90	101,61		-79,25	16,52
14		69,86 s	42	1461,56	0,85	88,97		-79,37	16,70
15		74,85 s	45	767,47	0,61	37,06		-78,14	14,89
16		79,84 s	48	446,25	0,45	0,55		-71,43	5,02
17		84,83 s	51	458,29	0,47	5,04		-71,83	5,61
18		89,82 s	54	447,71	0,46	3,24		-68,99	1,43

Ao gerar o gráfico com os dados das tabelas 7.9 a 7.11 e apresenta-lo na figura 7.8, observa-se que as estimativas convergem para um bom resultado, somente quando se utilizam redes treinadas com as características do ambiente em que houve a validação. Os treinamentos das redes foram acumulativos, ou seja, a rede 1 treinada com 01 sinal, rede 2 treinada com 02 sinais e assim por diante. Ao utilizar o sinal de validação (JA), obtido com janelas abertas, obteve-se boas respostas nas 18 redes avaliadas, principalmente a partir da 3<sup>a</sup> rede treinada com sinais em 14 V. Ao usar o sinal de validação (PA), a estimativa melhorou a partir da 8<sup>a</sup> rede e para sinal de validação (SF), somente a partir da 16<sup>a</sup> rede treinada. Isto aconteceu porque amostras obtidas com a porta aberta foram incorporadas somente a partir da 7<sup>a</sup> rede treinada e as amostras com a sala fechada somente a partir da 13<sup>a</sup> rede neural. As faixas em destaque na figura 7.8 indicam respostas abaixo de 0,10 para o EMQ, erro menor que 10% na magnitude e 5% na fase.

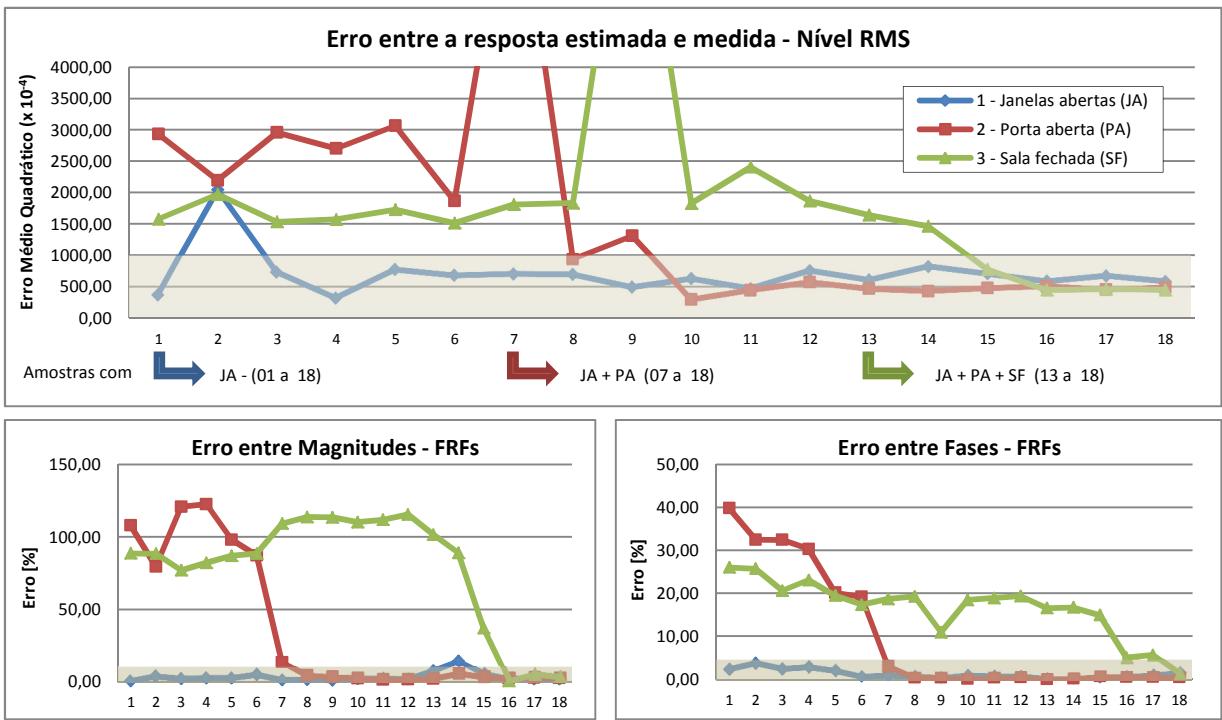


Figura 7.8 – Comparação das respostas estimadas e medidas no ponto remoto. (a) Nível RMS, (b) Magnitude da FRF e (c) Fase da FRF em 250 Hz.

Os resultados indicam que uma rede neural poderá apresentar abrangência e melhores estimativas se na fase de treinamento forem apresentados os sinais acústicos com as várias características do ambiente. Nota-se ainda que ao abranger as possibilidades, não se obtém respostas tão satisfatórias quanto às obtidas nos ambientes sem as alterações. Como a arquitetura das redes neurais utilizadas tem a característica de ajuste de funções, ao apresentar várias amostras de várias condições, os pesos sinápticos se adaptam, mas apresentam ruído numérico pelas demais condições em função da generalização. É diferente de ser apresentar várias amostras de uma mesma condição onde ocorre ajuste de forma mais específica.

## 7.4 Estimativa a partir do ruído branco

Foi verificado ainda a estimativa da resposta ao utilizar ruído branco na identificação do ambiente. O ruído foi gerado nas amplitudes de 2, 3, 4, 5, 6 e 7 V e com sala fechada (SF). Foram realizados 03 conjuntos de aquisições para uma melhor caracterização. A figura 7.9 ilustra as amostras adquiridas e que foram posteriormente utilizadas no treinamento.

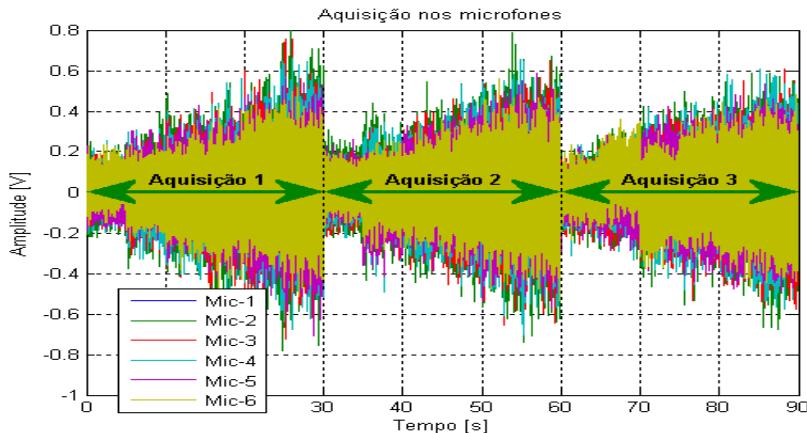


Figura 7.9 – Ruído branco gerado e adquirido nos seis microfones. Os sinais totalizam 18 amostras obtidas em sala fechada.

Na aquisição, manteve-se os mesmos sensores em suas respectivas posições: Sensor de vibração na fonte (AF), dois sensores de referência posicionados próximos ao ponto desejado (Mic4 e Mic5) e a resposta medida (Mic6) no ponto desejado. Ruído branco foi gerado na faixa de 0 a 800 Hz como sinal de excitação. Aquisição realizada entre 0 a 1640 Hz, com 8192 pontos na amostragem durante 4,99 s cada. Como se trata de uma nova caracterização de sinais, projetou-se a rede NARX (AF+M4+M5)x03x01 [30]/[12]. As amostras foram aleatorizadas em 07 vetores com 750 pontos cada.

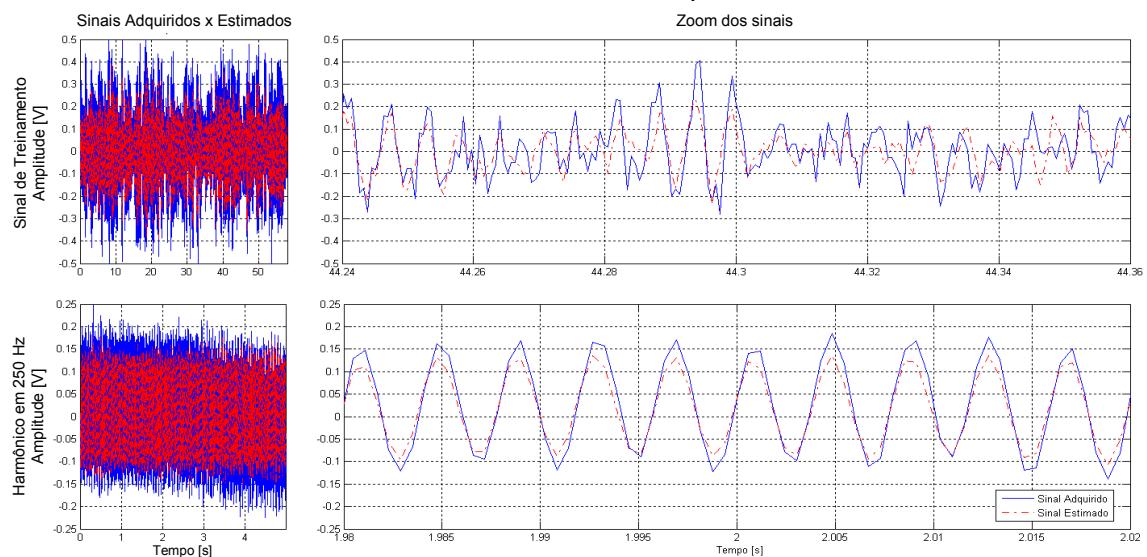


Figura 7.10 – (a) Ruído branco utilizado no treinamento da rede neural e (b) resposta da rede ao sinal harmônico.

A figura 7.10(a) ilustra os sinais utilizados no treinamento e compara a estimativa obtida com o ruído medido pelo sensor físico. A fig. 7.10(b) mostra a resposta estimada ao apresentar um sinal harmônico em 250 Hz e compara a estimativa com o sinal medido. A fig. 7.11 apresenta as respostas em frequência dos sinais de treinamento e de validação.

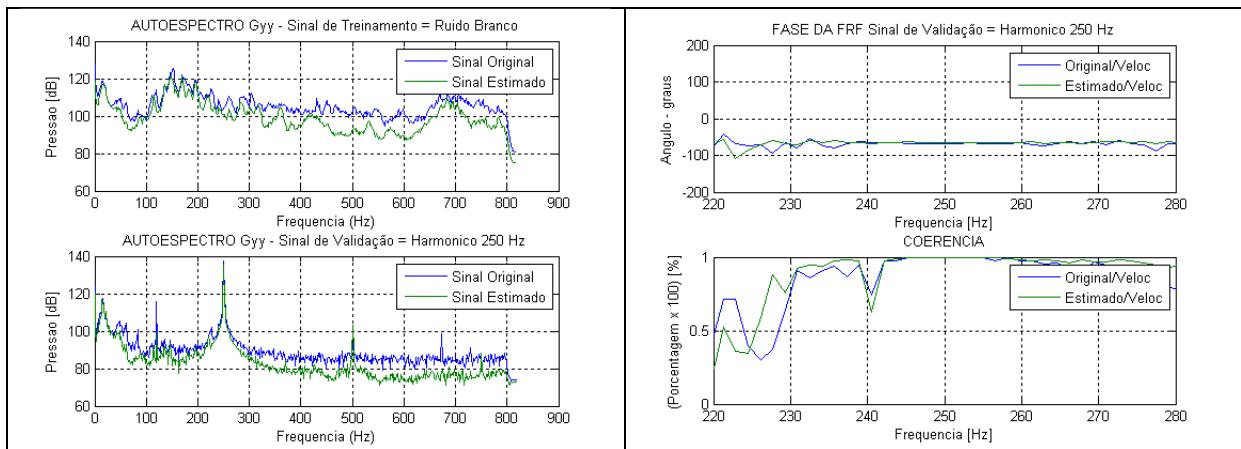


Figura 7.11 – (a) Auto espectro do sinal de treinamento, (b) Auto espectro da resposta para o sinal harmônico. (c) Fase e coerência do sinal harmônico.

Para validar foram utilizados os 06 sinais gerados em 250 Hz (SF) da seção anterior, com amplitudes de 10 a 20 V. A tabela 7.12 apresenta os desvios verificados ao utilizar os sinais harmônicos na rede treinada com ruído branco. A figura 7.12 apresenta graficamente estes desvios.

Tabela 7.12 – Treinamento utilizando ruído branco e validação com sinais harmônicos em 250 Hz, ambos obtidos em sala fechada.

	RMS	Magnitude da FRF				Fase da FRF		
		Sinal		Erro [%]	Sinal		Erro [%]	
		Medido	Estimado		Medido	Estimado		
1	290,55	4,53	3,57	21,21	-67,95	-64,18	5,55	
2	318,39	4,52	3,55	21,62	-67,91	-64,48	5,05	
3	356,04	4,51	3,57	20,93	-68,21	-64,30	5,74	
4	383,79	4,34	3,50	19,51	-67,94	-65,37	3,78	
5	394,20	4,32	3,49	19,06	-67,70	-64,97	4,03	
6	415,69	4,32	3,53	18,33	-67,34	-64,21	4,64	

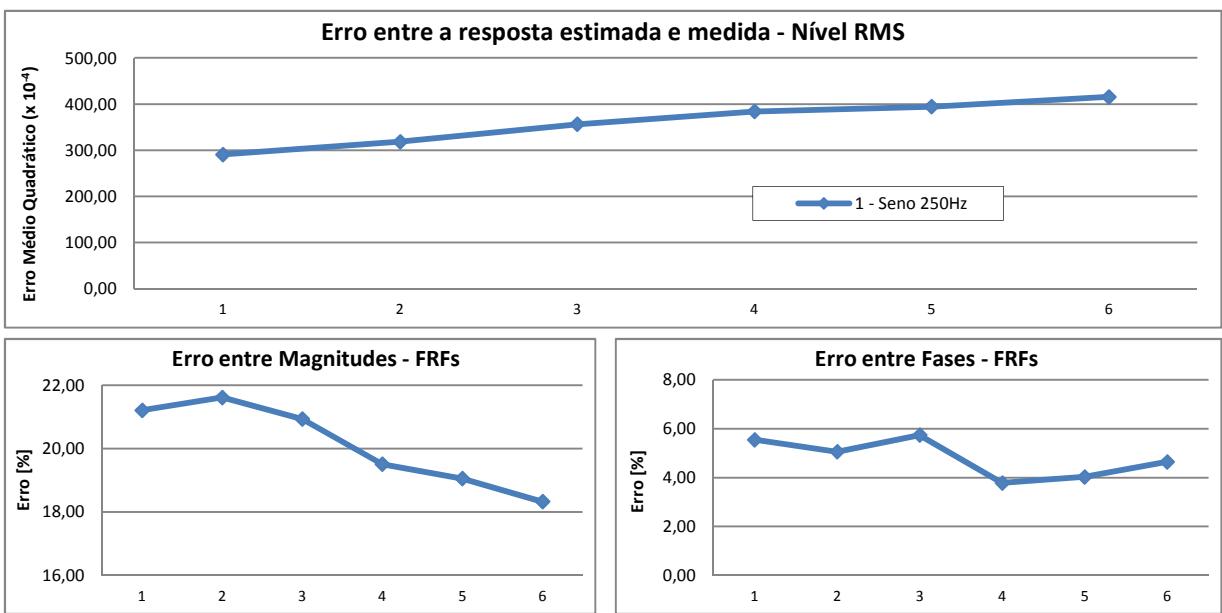


Figura 7.12 – Desvios verificados entre as respostas estimadas e medidas a 250 Hz. (a) Nível RMS, (b) Erro na magnitude da FRF e (c) Erro na fase da FRF.

Apesar do erro na faixa de 20% para a magnitude e de 5% para a fase, a caracterização por ruído branco apresenta potencial para a estimativa de sinais harmônicos. Os erros na magnitude são devidos às diferenças nas amplitudes dos sinais utilizados no treinamento e na verificação, pois no treinamento utilizou-se ruído branco gerado entre 2 a 7 V e na verificação utilizou-se sinal harmônico gerado entre 10 a 20 V. O ruído branco foi gerado abaixo de 7 V devido a limitação do Gerador de Sinais DS360. O projeto e a arquitetura da rede neural também podem influenciar na exatidão das respostas. Estes resultados são um indicativo para trabalhos futuros visto que o desenvolvimento do microfone virtual em bandas de frequência extrapola os objetivos propostos para este trabalho.

## CAPÍTULO VIII

### CONCLUSÕES E PERSPECTIVAS FUTURAS

#### 8.1 Conclusões

Como primeira observação, verifica-se que atualmente o microfone virtual situa-se como uma técnica recente e em desenvolvimento, cujas pesquisas focam: em técnicas de estimação, em algoritmos de controle, nas respostas de fase, na sensibilidade e na estimativa de sinais acústicos não lineares. Verifica-se ainda que os estudos investigam ou utilizam modelos formulados com base na suposição de um campo sonoro, modelos de funções de transferência, previsão futura com base na extrapolação de sinais de pressão e em algoritmos adaptativos não lineares.

Conforme os objetivos do trabalho foram investigados a acústica de sala, com relação ao campo reverberante, os modos acústicos e os fatores que influenciam a propagação sonora. Pode-se concluir que todos os fatores avaliados (porta, janela, ocupação e movimentação interna) perturbam a acústica na sala, agindo diretamente no campo reverberante ao introduzir mudanças no *layout* e nas características de absorção.

Ao caracterizar a fonte sonora, pode-se evidenciar que o campo acústico proveniente de um sinal harmônico, pode ser caracterizado a partir de um sinal vibratório, estando bem correlacionado com o sinal gerado em termos de amplitude e fase. Foi possível ainda identificar a transmissão de um sinal harmônico entre o ponto de geração e o de medição por um sensor físico.

De forma a contribuir com as investigações em microfone virtual, nossa proposta investigou ainda a aplicação de modelos baseados em redes neurais, já que se tratam de poderosos algoritmos de processamento, capazes de solucionar aplicações de regressão e adaptação de sinais, modelando inclusive filtros.

Observou-se que redes neurais são bastante influenciadas pelas condições iniciais ao treinar, onde uma condição inicial que apresenta convergência com erro reduzido, pode apresentar valores diferentes em outros treinamentos ou não convergência em redes recorrentes. Uma outra dificuldade no projeto das redes neurais é o fato de não haver regras

para uma boa arquitetura, sendo recomendável um estudo experimental exaustivo para obter a melhor configuração.

Ao avaliar parâmetros de configuração e o desempenho de diferentes arquiteturas de redes neurais. A rede baseada na arquitetura NARX foi a que apresentou melhores resultados na estimativa do sinal acústico no ponto remoto, inclusive menor tempo de processamento na fase de treinamento.

Com relação aos sinais de treinamento, houve melhorias nas respostas quando se utilizou vetores com amostras do sinal, ao invés de apenas um vetor com grande número de dados, reduzindo também o tempo de treinamento da rede.

Com relação aos sinais de entrada foram avaliadas as respostas em função da quantidade de sensores e a localização destes no ambiente. Quando se utilizou apenas o sensor na fonte de ruído, foi possível caracterizar o sinal acústico na sala sem modelar o ruído no ambiente. Como desvantagem não se modela também a dinâmica que por ventura venha a ocorrer na sala. Ao acrescentar um sensor como referência, têm-se a sensibilidade devido ao campo reverberante e também a ruídos.

Conclui-se ainda que é bastante satisfatório aplicar o procedimento de otimização, para indicar os parâmetros de configuração de uma rede neural. Foi evidenciada uma melhoria na exatidão das respostas após o aprimoramento da rede neural realizado pela otimização.

Dentre os resultados apresentados, um dos mais expressivos mostra a possibilidade de se obter a estimativa em uma vizinhança ao invés um ponto apenas. Isso traz oportunidades pela viabilidade de se utilizar diversos sensores virtuais e inclusive a possibilidade de implementar o deslocamento virtual em tempo real.

Para obter uma estimativa mais robusta em ambientes susceptíveis a alterações, deve-se levar em conta uma ampla gama de combinações de mudanças. Estas amostras com as características relevantes do ambiente devem ser utilizadas na fase de treinamento de uma rede neural para que a rede possa incorporar as características do ambiente. Conclui-se ainda que em ambientes dinâmicos ou susceptíveis a mudanças, a estimativa virtual poderá apresentar desvios, ao contrário das aplicações com menor possibilidade de interferência, como em dutos, por exemplo.

Verificou-se ainda a estimativa obtida de um sinal harmônico ao utilizar ruído branco no treinamento da rede. Este resultado é interessante pois é um indicativo para a obtenção de estimativas em uma faixa de frequências.

Conclui-se, portanto que a técnica de sensor virtual utilizando redes neurais possibilita a estimativa do sinal acústico em termos de magnitude, fase e do nível RMS, conforme os objetivos propostos para o trabalho.

## 8.2 Sugestões para trabalhos futuros

Para o problema proposto foi apresentado uma solução, entretanto muitas questões foram levantadas, inclusive algumas abordagens interessantes para serem investigadas. Portanto, como proposta de continuidade do estudo aqui reportado, são sugeridos:

- Elaborar e aplicar simulações numéricas para treinamento e validação das redes neurais. O treinamento e a validação com base em técnicas experimentais tem a vantagem de representar o fenômeno físico com fidelidade, entretanto a quantidade de experimentos a serem executados é um fator limitante, pelo tempo demandado na preparação, na execução e na abrangência dos ensaios. Ambientes apropriados para medições experimentais é outro ponto a ser considerado, havendo a necessidade de ambientes acusticamente isolados para o controle do processo e a exatidão nos dados.
- Modelos e simulações numéricas devem ser cuidadosamente aplicados, pois softwares baseados em elementos finitos com interação fluido estrutura permitem ensaios acústicos em pequenos volumes, mas apresentam problemas em ambientes maiores como uma sala por exemplo, principalmente devido ao tamanho de malha e pelo tempo de processamento. Assim a investigação de outros algoritmos é incentivada. Outro fator a observar é a validação das simulações relativa às propriedades acústicas para os materiais como a impedância e absorção.
- Ao obter um modelo numérico que seja bastante representativo do ambiente físico, propõe-se treinar uma rede neural a fim de obter respostas virtuais em uma ampla região no ambiente (região volumétrica). Neste trabalho a estimativa ficou limitada em grande parte a um ponto no espaço (ponto virtual), entretanto foi possível verificar a resposta virtual ao utilizar sensores alinhados, o que possibilitou estimativas na vizinhança e a possibilidade de implementação do deslocamento virtual em tempo real.
- Sugere-se ainda aplicar a técnica de microfone virtual no controle ativo de dutos para averiguar os limites e os resultados desta técnica, haja visto que no controle tradicional, ocorrem alguns problemas de convergência ou instabilidade: O primeiro problema é devido a realimentação pelo caminho secundário, pela contaminação do som de controle, do sensor de referência que mede o ruído gerado. Um outro problema é o posicionamento dos sensores físicos, a fim de evitar os pontos modais do sistema. A aplicação do microfone virtual com base no sinal vibro acústico poderá eliminar os problemas de realimentação e ao implementar o deslocamento virtual, o

sistema de controle poderá estimar uma resposta sempre na posição mais adequada, maximizando a eficiência.

- Aprofundar estudos de projeto e de aplicações em microfone virtual para que seja possível as estimativas em bandas de frequências.
- Trabalhar nos modelos de redes neurais para fazer o treinamento e *feedback* dinâmico ao implementar o controle online. Na técnica avaliada, o treinamento ocorre em modo off-line gerando um modelo representativo daquele momento. Para uma melhor robustez da resposta, sugere-se o estudo de modelos híbridos com o sistema de controle para fornecer o sinal de *feedback* e atualização do modelo conforme a adaptação se desenvolve.
- Verificar outras estratégias de inteligência artificial para abranger respostas em ambientes dinâmicos que sejam susceptíveis a mudanças no *layout* ou mesmo pela movimentação interna de pessoas. Sugere-se a técnica de “*blind separation*” para separar o sinal alvo de outras fontes ou mesmo ruídos. Esta técnica permite inclusive a implementação em tempo real.
- Também é sugerida a investigação de métodos de “*deep learning*”, que são algoritmos de aprendizagem focados em níveis altos de abstração de dados, tendo inclusive as bases fundamentadas nas redes neurais. Algumas aplicações de “*deep learning*” são: visão computacional, reconhecimento de fala, processamento de sinal, aprendizagem multitarefa, previsão de séries temporais e bioinformática.

## REFERÊNCIAS BIBLIOGRÁFICAS

- BARROS NETO, B.; SCARMINIO, I. S.; BRUNS, R. E. **Como Fazer Experimentos: Pesquisa e desenvolvimento na ciência e na indústria.** 4<sup>a</sup> ed. Porto Alegre – RS: Ed. Artmed S.A., 2010. 413p.
- BARBETTA, P. A.; REIS, M. M.; BORNIA, A. C. **Estatística para cursos de engenharia e informática**, Editora Atlas, 2004
- BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B.; **Neural Network Toolbox Matlab Use's Guide.** 27<sup>a</sup> ed. The MathWorks Inc, 2013. 430p.
- BERANEK, L. L. **Acoustics.** Revised edition. Cambridge – MA: Acoustical Society of America, 1993. 491p.
- BISTAFA, S. R. **Acústica Aplicada ao Controle de Ruído.** São Paulo – SP: Ed. Edgard Blucher, 2006. 368p.
- BRAGA, A. P.; CARVALHO, A. C. P. F. L.; LURDERMIR, T. B.; **Fundamentos de redes neurais artificiais.** Escola de computação, Rio de Janeiro-RJ, 1998. 246p.
- BULLMORE, A. J.; NELSON, P. A.; CURTIS, A. R. D.; ELLIOTT, S. J. The active minimisation of harmonic enclosed sound fields, part II. **Journal of Sound and Vibration.** v.117, p.15-33, 1987.
- BURGES, J. C. Active Adaptive control in a duct: A computer simulation. **Journal of The Acoustical Society of America.** p. 715-726, 1981.
- CALDART, A. U.; ADRIANO, C. F.; TERRUEL, I.; MARTINS, R. F.; MOCELLIN, M. Prevalência da perda auditiva induzida pelo ruído em trabalhadores de indústria têxtil, **Arquivos internacionais de Otorrinolaringologia.** v.10, n.3, 2006.

CÁRDENAS, N. I. J. **O controle ativo de ruídos em dutos: Um estudo teórico - experimental.** 2005. 129f. Tese de doutorado - Universidade Federal de Uberlândia, Uberlândia – MG.

CLARKSON, P. M. **Optimal and adaptive signal processing.** Boca Raton - FL: CRC Press, 1993. 531p.

CAZZOLATO, B. S. **Sensing systems for active control of sound transmission in cavities.** 1999. 436f. PhD thesis - Department of Mechanical Engineering of University of Adelaide - Australia.

CAZZOLATO, B. S. An adaptive LMS virtual microphone. In **Proceedings of Active 2002.** p.105–116. 2002.

CROCKER, M. J. **Handbook of noise and vibration control.** New Jersey – USA: Ed. John Wiley & Sons Inc, 2007. 1568p.

DAS, D. P.; MOREAU, D. J.; CAZZOLATO, B. S. **Nonlinear Active Noise Control with Virtual Sensing Technique.** School of Mechanical Engineering - University of Adelaide, 2010.

DAS, D. P.; MOREAU, D. J.; CAZZOLATO, B. S. Nonlinear active noise control for headrest using virtual microphone control. **Elsevier: Control Engineering Practice.** v.21, n.4, p.544-555. 2013.

DELFINO, L. C. **Controle ativo de ruído em dutos utilizando processadores digitais de sinais.** 2005. 151f. Dissertação de mestrado - Universidade Federal de Uberlândia, Uberlândia – MG.

DEMUTH, H.; BEALE, M. **Neural Network Toolbox for use with Matlab.** 8<sup>a</sup> ed. The MathWorks Inc, 2002. 840p.

ELLIOTT, S. J.; CURTIS, A. R. D.; BULLMORE, A. J.; NELSON, P. A. The active minimisation of harmonic enclosed sound fields, part III. **Journal of Sound and Vibration.** v.117, p.35-58, 1987.

ELLIOTT, S. J.; JOSEPH, P.; BULLMORE, A. J.; NELSON, P. A. Active cancellation at a point in a pure tone diffuse sound field. **Journal of Sound and Vibration.** v.120, n.1, p.183–189, 1988.

ELLIOTT, S. J.; DAVID, A. Virtual microphone arrangement for local active sound control. In **Proc. of 1st International conference on motion and vibration control.** p.1027-1031, 1992.

FONSECA, P. C. **Uma alternativa aos Modelos NEWAVE e DECOMP por meio da Aplicação de Técnicas de Inteligência Artificial.** 2013. 78 f. Dissertação de Mestrado – Universidade Federal de Itajubá, Itajubá – MG.

FULLER, C. R., JONES, J. D. Experiments on reduction of propeller interior noise by active control of cylinder vibration, **Journal of Sound and Vibration.** v.112, n.3, p.389-395, 1987.

FULLER, C. R., HANSEN, C. H., SNYDER, S. D. Experiments on active control of sound radiation from a panel using piezoceramic actuator, **Journal of Sound and Vibration.** v.150, p.179-190, 1991.

GARCIA B.; BURGOS J. C.; ALONSO A. M. Transformer tank vibration modeling as a method of detecting winding deformation - part 1 theoretical foundation. **IEEE Transactions On Power Delivery.** v.21, n.1, p.157–163, 2006.

GARCIA-BONITO, J.; ELLIOTT, S. J.; BONILHA, M. Active cancellation of pressure at a point in a pure diffracted diffuse sound field. **Journal of Sound and Vibration.** v.201, n.1, p.43-665, 1997a.

GARCIA-BONITO, J.; ELLIOTT, S. J.; BOUCHER, C. C. Generation of zones of quiet using a virtual microphone arrangement. **Journal of The Acoustical Society of America.** v.101, n.6, p.3498-3516, 1997b.

GARCIA-BONITO, J.; ELLIOTT, S. J. Active cancellation of pressure and particle velocity in the near field of source. **Journal of Sound and Vibration.** p.85-116, 1999.

GERGES, S. N. Y. **Ruído – Fundamentos e Controle**, 2<sup>a</sup> ed. Florianópolis – SC: 2000. 696p.

GOODWIN, G. C.; SIN, K. S. **Adaptive Filtering Prediction and Control**. Englewood Cliffs - NJ: Prentice-Hall, 1984. 540p.

GUO, J.; PAN, J.; HODGSON, M. Local or global control – The applicable active noise control strategy in enclosed environments. In **Proceedings of Active 2002**. p.93-104, 2002.

HANSEN, C. H. **Understanding Active Noise Cancellation**. 1<sup>a</sup> ed. London and New York: Spon Press – Taylor e Francis Group, 2001. 173p.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. Trad: Engel; P.M. 2<sup>a</sup> ed. Porto Alegre – RS. Editora Bookman, 2001. 900p.

KESTELL, C. D.; CAZZOLATO, B. S.; HANSEN, C. H. Active noise control in a free field with virtual sensors. **Journal of The Acoustical Society of America**. v.109, n.1, p.232-243, 2001.

KUO, S. M.; MORGAN, D. R. Active Noise Control: A Tutorial Review. in **Proceedings of IEEE International Symposium on Circuits and Systems**, p.943–973, 1999.

LIU, L.; KUO, S. M.; ZHOU, M. C. Virtual sensing techniques and their applications. In **Proceedings of the 2009 IEEE International conference on networking, sensing and control**. 2009.

MACIEL, M. A. **Controle ativo de ruído aplicado a venezianas acústicas**. 2014. 119f. Tese de doutorado - Universidade Federal de Uberlândia, Uberlândia – MG.

MASIERO, B. S. **Controle ativo de ruído para transformadores de potencia em campo aberto**. Dissertação de mestrado, Escola Politécnica da Universidade de São Paulo, São Paulo-SP, 2007.

MIRANDA, J. G. O. **Controle ativo de ruído em dutos: Otimização do posicionamento dos sensores receptores**. 2013. 143f. Dissertação de mestrado - Universidade Federal de Uberlândia, Uberlândia – MG.

MOREAU, D. J.; GHAN, J.; CAZZOLATO, B. S.; ZANDER, A. C. Active noise control in a pure-tone diffuse sound field using virtual sensing. In **Proceedings of the 14th International Congress on Sound and Vibration**. Australia, 2007.

MOREAU, D. J.; CAZZOLATO, B.; ZANDER, A.; PETERSEN, C. A Review of Virtual Sensing Algorithms for Active Noise Control. **Algorithms Journal**. v.1, p.69-99, 2008a.

MOREAU, D. J.; CAZZOLATO, B.; ZANDER, A. **Active noise control at a moving virtual sensor in three-dimensions**. School of Mechanical Engineering - University of Adelaide, 2008b.

MOREAU, D.; GHAN, J.; CAZZOLATO, B. S.; ZANDER, A. C. Active noise control in a pure tone diffuse sound field using virtual sensing. **Journal of The Acoustical Society of America**. v.125, n.6, p.3742–3755, 2009.

MUNN, J. M.; CAZZOLATO, B. S.; HANSEN C. H. Virtual sensing: Open loop vs adaptive LMS. **Acoustics 2002 - Innovation in Acoustics and Vibration, The Annual Conference of the Australian Acoustical Society**. p.24-33, 2002.

NARENDRA, K. S.; PARTHASARATHY, K. Identification and Control of Dynamical Systems Using Neural Networks. **IEEE transactions on neural networks**. v.1, n.1, p.4-27, 1990.

NELSON, P. A.; CURTIS, A. R. D.; ELLIOTT, S. J.; BULLMORE, A. J. The active minimisation of harmonic enclosed sound fields, part I. **Journal of Sound and Vibration**. v.117, p.1-13, 1987a.

NELSON, P.A. ; CURTIS, A. R. D. ; ELLIOTT, S. J.; BULLMORE, A. J. The minimum power output of free field point sourced and the active control of sound. **Journal of Sound and Vibration**. v.116, p. 397-414, 1987b.

NG, A. Y. **Neural Networks - Coursera's Machine Learning**. 2012. 47 f. Apostila - Stanford University - USA.

NGUYEN, D.; WIDROW, B. Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptative weights. **IJCNN: International Joint Conference on Neural Networks**. p.21-26, 1990.

NISHIDA, P. P. R. **Estruturas inteligentes aplicadas ao controle ativo de ruído de alta ordem em dutos.** 2012, 110 f. Dissertação de Mestrado - Universidade Federal de Uberlândia, Uberlândia – MG.

NUNES, M. A. **Utilização de síntese modal de componentes e particionamento axial de dutos para controle dos modos acústicos de alta ordem.** 2009. 223f. Tese de doutorado - Universidade Federal de Uberlândia, Uberlândia – MG.

OLIVEIRA, E. L. **Controle ativo de ruído aplicado a dutos com propagação de modos acústicos de alta ordem via particionamento axial.** 2012. 130f. Tese de doutorado - Universidade Federal de Uberlândia, Uberlândia – MG.

PETERSEN, C. D.; CAZZOLATO, B. S.; ZANDER, A. C.; HANSEN, C. H. Active noise control at a moving location using virtual sensing. **The Thirteenth International Congress on Sound and Vibration.** 2006.

PETERSEN, C. D.; ZANDER, A. C.; CAZZOLATO, B. S.; HANSEN, C. H. A moving zone of quiet for narrowband noise in a one-dimensional duct using virtual sensing. **Journal of The Acoustical Society of America.** v.121, n.3, p.1459–1470, 2007.

PETERSEN, C. D.; FRAANJE, R.; CAZZOLATO, B. S.; ZANDER, A. C.; HANSEN, C. H. A Kalman filter approach to virtual sensing for active noise control. **Mech. Syst. Signal Process.** v.22, p.490–508, 2008.

ROURE, A.; ALBARAZIN, A. The remote microphone technique for active noise control. **In Proceedings of Active 1999.** p.1233–1244, 1999.

SANTANA, D. C. **Controle ativo de ruído empregando placas retangulares com atuadores piezoelétricos distribuídos.** 2002, 198 f. Dissertação de Mestrado - Universidade Federal de Uberlândia, Uberlândia – MG.

SIMPSON, M.T.; HANSEN, C.H. Use of genetic algorithms to optimise actuator placement for active control of interior noise in a cylinder with floor structure. **Noise Control Engineering Journal.** v.44, p.169–184. 1996.

SRIHARI, S. N.; **Machine Learning and Probabilistic Graphical Models Course**, New York, Department of Computer Science and Engineering, Buffalo University. Disponível em: <<http://www.cedar.buffalo.edu/~srihari/CSE574/>>. Acesso em: 4 set. 2013.

THOMAS, D.; NELSON, P.; ELLIOTT, S. Active control of the transmission of sound through a thin cylindrical shell. Part I: The minimisation of vibrational energy. **Journal of Sound and Vibration.** v.167, n.1, p.91–111, 1993.

WILSON, E. Virtual sensor technology for process optimization. In **Symposium on Computers and Controls in the Metals Industry in Iron and Steel Society.** 1997.

WRIGHT, S. E.; VUKSANOVIC, D. Active control of environmental noise. **Journal of Sound and Vibration.** p.565-585, 1996.

WRIGHT, S. E.; VUCKSANOVISCK, B. Active control enviornmental noise II: Non compact acoustic sources. **Journal of Sound and Vibration.** p.313-359, 1997.

WRIGHT, S. E.; VUCKSANOVISCK, B. Active control enviornmental noise III: Implementation of theory into practice. **Journal of Sound and Vibration.** p.313-359, 1999.

WRIGHT, S. E.; VUCKSANOVISCK, B. Active control environmental noise IV: Performance of a fundamental free-field sound cancelling system. **Journal of Sound and Vibration.** p.313-359, 2001a.

WRIGHT, S. E.; ATMOKO, H. Active control of environmental noise V: the effect of environment change on the stability of electronically controlled acoustic shadow systems. **Journal of Acoustic and Vibration.** p.107-122, 2001b.

ZANATA, D. R. P. **Desenvolvimento de sensor virtual empregando redes neurais para medição da composição em uma coluna de destilação.** 2005. 229 f. Dissertação de Mestrado – Escola Politécnica da Universidade de São Paulo, São Paulo – SP.

## APÊNDICE A

A seguir, descreve-se o código desenvolvido na linguagem MatLab® para gerar a arquitetura apresentada na figura 3.12. Os códigos abaixo apenas constroem a arquitetura da rede. Códigos complementares são necessários para os algoritmos de aprendizagem, estimadores de performance, entrada de dados, inicialização de pesos e treinamento da rede. Devido a diversidade de opções, comandos complementares de configuração podem ser obtidos em Beale *et al.* (2013).

```
%UNIVERSIDADE          FEDERAL DE UBERLÂNDIA
%DOUTORADO:           MICROFONE VIRTUAL
%ORIENTADOR:          MARCUS ANTONIO V. DUARTE
%ALUNO:               MARCO AURELIO B. C. BADAN
%VERSÃO:              Set/2014

%-----%
%           Descrição - PROGRAMA PRINCIPAL
%-----%
% 1) Configura uma Rede Neural Hipotética estabelecendo Num. de: entrada e
%    a saida de dados, camadas, conexões e atrasos de linha.
% 2) Rede com 03 entradas (vetores de dados) e 03 camadas
% 3) Bias apenas para 1a e 3a camadas
% 4) Todas as camadas conectadas à frente
% 5) Conexão recorrente da 3a para a 1a e da 2a para a 2a camadas
% 6) Saída de dados apenas na ultima camada
%-----%

close all; clear all; clc;

%-----%
%   CONFIGURAÇÃO REDE NEURAL HIPOTÉTICA
%   Estabelece a estrutura básica
%-----%
net          = network;                      % Cria uma RN personalizada de nome "net"
net.numInputs = 03;                          % Define 03 entradas (vetores) de dados
net.numLayers = 03;                          % Define 03 camadas para a rede

%-----%
%   ENTRADA DE DADOS
%   Configura os pesos "IW" das 03 entradas para 1a e 2a camadas
%-----%
net.inputConnect(2,1) = 1;                   % Conecta 1a entrada na 2a camada
net.inputs{1}.size = 1;                      % Num de elementos no vetor de entrada
net.inputs{1}.name = 'M1';                   % M1 no Rotulo

net.inputConnect(1,2) = 1;                   % Conecta 2a entrada na 1a camada
net.inputs{2}.size = 1;                      % Num de elementos no vetor de entrada
net.inputs{2}.name = 'M2';                   % M2 no Rotulo
net.inputWeights{1,2}.delays = [0:4];        % Atraso de 5 elementos p/ 2a entrada

net.inputConnect(1,3) = 1;                   % Conecta 3a entrada na 1a camada
net.inputs{3}.size = 6;                      % Num de elementos no vetor de entrada
net.inputs{3}.name = 'M3';                   % M3 no Rotulo

%-----%
%   BIAS
```

```

%     Configura bias "b" somente para 1a e 3a camadas
% -----
net.biasConnect(1)      = 1;
net.biasConnect(3)      = 1;

% -----
%     CAMADAS
%     Configuração dos pesos "LW" entre camadas
% -----
%     Trecho => FEEDFORWARD
net.layerConnect(2,1)   = 1;                      % Ligacao da saida a1 com 2a camada
net.layerConnect(3,2)   = 1;                      % Ligacao da saida a2 com 3a camada

%     Trecho => FEEDBACK
net.layerConnect(1,3)   = 1;                      % Ligacao da saida a3 com 1a camada
net.layerWeights{1,3}.delays = [1:4];             % Atraso de 4 elementos na 1a camada

net.layerConnect(2,2)   = 1;                      % Ligacao da saida a2 com 2a camada
net.layerWeights{2,2}.delays = [1:2];             % Atraso de 2 elementos na 2a camada

% -----
%     SAIDA DE DADOS
%     Resposta apenas na saida ultima camada (em a3)
% -----
net.outputConnect(3)   = 1;                      % Define ligacao y3 com a3
net.outputs{net.numLayers}.name = 'MV';           % MV no Rotulo de saída

% -----
%     NÚMERO DE CAMADAS
% -----
net.layers{1}.size     = 10;                     % 10 neurônios p/ 1a camada
net.layers{1}.transferFcn = 'tansig';           % Define função de ativação
net.layers{1}.name      = 'Camada_1';            % Camada_1 no Rotulo

net.layers{2}.size     = 03;                     % 03 neurônios p/ 2a camada
net.layers{2}.transferFcn = 'hardlim';           % Define função de ativação
net.layers{2}.name      = 'Camada_2';            % Camada_2 no Rotulo

net.layers{3}.size     = 01;                     % 01 neurônios p/ 3a camada
net.layers{3}.transferFcn = 'purelin';           % Define função de ativação
net.layers{3}.name      = 'Camada_3';            % Camada_3 no Rotulo

```

## APÊNDICE B

A seguir, apresentam-se toda a instrumentação e equipamentos utilizados nas aquisições experimentais e na calibração de sensores. Todos os ensaios foram realizados em uma sala com dimensões de 4,841 m x 4,023 m e 2,465 m de altura.

A) Auto falante, tipo *woofer*, marca *Bossound*, modelo BS16 com:

- Potência nominal: 100 W RMS;
- Impedância nominal: 8Ω;
- Resposta em frequência: 80 a 9000 Hz;
- Diâmetro: 152 mm.

B) Acelerômetro *Brüel & Kjær* tipo 4516 com as seguintes características:

- Faixa de frequência: 1 a 20000 Hz;
- Sensibilidade: 5 mV/g);
- Pico máximo operacional: 1000 g;
- Massa: 1,5 g;
- Frequência de ressonância: 60 kHz.

C) Microfone *Brüel & Kjær* tipo 4957:

- Sensibilidade: 11,2 mV/Pa (0,39 dB re 1 V/Pa);
- Faixa de frequência: 50 a 10000 Hz;
- Faixa dinâmica: 32 a 134 dB;
- Dimensões: 34 x Ø = 7 mm.

D) Microfone PCB tipo 377B02:

- Diâmetro Nominal:  $\phi 1/2"$ ;
- Sensibilidade: 50 mV/Pa (-0,26 dB re 1 V/Pa);
- Faixa de frequência: 5 a 10000 Hz;
- Faixa dinâmica: 15 a 146 dB;
- Montado em pré-amplificador 426E01 ICP (faixa de resposta 6,3 a 125000 Hz).

E) Calibrador sonoro *Larson Davis CAL200* com as seguintes características:

- Precisão da calibração:  $\pm 0,2\text{dB}$ ;
- Níveis de pressão acústica de saída: 94 ou 114 dB;
- Frequência de saída: 1000 Hz.

F) Calibrador de vibração *Brüel & Kjær* tipo 4294 com as seguintes características:

- Frequência de calibração: 159,2 Hz.
- Níveis RMS: Aceleração =  $10 \text{ m/s}^2$ , Velocidade = 10 mm/s, Deslocamento = 10  $\mu\text{m}$ .

G) Gerador de sinais *Stanford Research Systems – Model DS360 Function Generator*:

- Faixa de frequências: 1 mHz a 200 kHz;
- Distorção menor que 100 dB (20 kHz);
- Sinais gerados: Seno, onda quadrada, ruído branco e ruído rosa;
- Tensões de saída: 20  $\mu\text{Vpp}$  a 40 Vpp;
- Frequências de varreduras lineares e logarítmicas;
- Acuidade de frequência de 25 ppm.

H) Condicionador de sinais PCB 482A20 com 8 canais ICP:

- Ganho em tensão: x1, x10, x100;
- Faixa de frequência: 0,225 a 50000 Hz.

I) Medidor de pressão sonora *Larson Davis – Sound Track LXT*:

- Faixa de medição: 27 a 118 dB SPL – Curva de ponderação A;
- Filtros: 1/1 ou 1/3 de oitava;
- Armazenamento de 2Gb, comunicação via USB.

J) Módulo de aquisição *National Instruments*:

- Modelo NI USB-625;
- Resolução: 16 bits;
- Taxa de amostragem: 1.00 MS/s (multi canal);
- Fundos de escala:  $\pm 10$  V,  $\pm 5$  V,  $\pm 2$  V,  $\pm 1$  V,  $\pm 0.5$  V,  $\pm 0.2$  V,  $\pm 0.1$  V.



Figura B.1 – Apresentação parcial do conjunto utilizado. Destaque para o módulo de aquisição, condicionador de sinais e o gerador de sinais DS360.