

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
INFORMÁTICA INDUSTRIAL

DENYS DE SOUZA SCHEINER

**ESTUDOS DE MODELOS PARA PREDIÇÃO DE PARÂMETROS DE
ENSAIOS DE CABOS LAN**

DISSERTAÇÃO

CURITIBA
2012

DENYS DE SOUZA SCHEINER

**ESTUDOS DE MODELOS PARA PREDIÇÃO DE PARÂMETROS DE
ENSAIOS DE CABOS LAN**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Ciências” – Área de Concentração: Engenharia de Automação e Sistemas.

Orientadora: Prof^ª. Dr^ª. Lucia Valéria Ramos de Arruda

CURITIBA
2012

Dados Internacionais de Catalogação na Publicação

S319 Scheiner, Denys de Souza
Estudos de modelos para predição de parâmetros de ensaios de cabos LAN
/ Denys de Souza Scheiner. — 2012.
127 f. : il. ; 30 cm

Orientador: Lucia Valéria Ramos de Arruda.
Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná.
Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial.
Área de concentração: Engenharia de Automação e Sistemas, Curitiba, 2012.
Bibliografia: p. 119-121.

1. Redes locais de computação. 2. Redes neurais (Computação). 3. Critério de informação de Akaike. 4. Sistemas de identificação por radiofrequência. 5. Engenharia elétrica – Dissertações. I. Arruda, Lucia Valéria Ramos, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD (22. ed.) 621.3

Título da Dissertação Nº.617

“Estudos de Modelos Para Predição de Parâmetros de Ensaios de Cabos LAN”

por

Denys de Souza Scheiner

Esta dissertação foi apresentada como requisito parcial à obtenção do grau de MESTRE EM CIÊNCIAS – Área de Concentração: Engenharia de Automação e Sistemas, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI – da Universidade Tecnológica Federal do Paraná – UTFPR, às 09:30h do dia 09 de novembro de 2012. O trabalho foi aprovado pela Banca Examinadora, composta pelos professores:

Prof^ª. Lúcia Valéria Ramos de Arruda, Dr.
(Presidente – UTFPR)

Prof^ª. Jussara Farias Fardin, Dr.
(UFES)

Prof. João Alberto Fabro, Dr.
(UTFPR)

Visto da coordenação:

Prof. Ricardo Lüders, Dr.
(Coordenador do CPGEI)

AGRADECIMENTO

À empresa Furukawa Industrial que me autorizou a cursar o mestrado e a freqüentar as aulas durante o expediente de trabalho.

À minha professora orientadora Lucia Valéria Ramos de Arruda que aceitou o desafio de me orientar, sem mesmo me conhecer, por ser um aluno que estudou apenas em escolas paulistas, assim dedicando seu precioso tempo para me orientar durante todas as fases do mestrado.

À minha amada esposa Priscila Satie que pacientemente entendeu todos os momentos em que estive ausente para me dedicar aos estudos.

RESUMO

SCHEINER, Denys. Estudos de Modelos para predição de parâmetros de ensaios de cabos LAN. 2012. 127f. Dissertação (Mestrado em Engenharia Elétrica e Informática Industrial) – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2012.

Este estudo consiste na comparação de 2 técnicas de modelagem da área de identificação de sistemas aplicadas à predição de dois importantes parâmetros elétricos de um cabo de telecomunicação do tipo LAN, que são Atenuação e Resíduo de Telediafonia. O foco do trabalho é representar a relação existente entre duas maneiras distintas de efetuar a medição dessas grandezas em um cabo. O estudo se iniciou através da aplicação de técnicas de modelagem que buscam Modelos Paramétricos, através da comparação polinomial, baseadas nas respostas dos modelos para os critérios de Akaike, *Bestfits* e Análise dos resíduos. Na seqüência, a fim de investigar o comportamento não-linear dos parâmetros do cabo em estudo, desenvolveram-se modelos baseados em Redes Neurais Artificiais. Estas redes são técnicas de inteligência artificial, inspiradas na natureza e capazes de identificar padrões e inferir conhecimentos, realizando comparações entre a saída real e a gerada pelo modelo. Utilizaram-se os *toolboxes* de identificação de sistemas e de redes neurais disponíveis no software Matlab, para desenvolvimento dos modelos. Com estes, neste trabalho foram apresentados os principais conceitos envolvidos em modelagem utilizando modelos paramétricos e redes neurais artificiais. Por fim, são apresentadas comparações entre os resultados obtidos com os respectivos critérios adotados e as técnicas utilizadas apontando para suas virtudes e limitações na solução deste problema. Essas comparações são feitas baseando-se em resultados obtidos para os modelos propostos a partir de dados reais obtidos em testes de qualidade de cabos LAN.

Palavras-chave: Cabos LAN. Identificação de sistemas. Modelos Paramétricos. Redes Neurais Artificiais, Critério de Akaike.

ABSTRACT

SCHEINER, Denys. Studies of models to predict tests parameters of LAN cables. 2012. 127f. Dissertação (Mestrado em Engenharia Elétrica e Informática Industrial)– Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2012.

This study consists of a comparison between two system identification modeling techniques applied to predict two important performance parameter involved on a LAN telecommunication cable, which are Insertion Loss and Attenuation Crosstalk Ratio Far End. This work focused on representing the relation between two different ways of measuring a cable by modeling techniques using Parametric Models, which are based on techniques of polynomial comparison performing output models comparison considering Akaike, *Bestfit* and Residuals analyses criteria and in sequence the Artificial Neural Network, which is an artificial intelligence technique inspired on nature that can identify standards and knowledge, performing a comparison between the real output and the model output. All of that using the Matlab system identification and neural networks *toolboxes*. On this work were presented the main concepts involved on modeling using parametric models and Neural Networks and was performed a comparison between the obtained results with the adopted criteria and the applied techniques pointing to each advantage and disadvantage for the solution of this problem.

Keywords: LAN cables. System Identification. Parametric Models. Artificial Neural Network. Akaike Criteria.

LISTA DE TABELAS

Tabela 1 – Média e Covariância da amostra em caixa e o 1º 100m para atenuação	50
Tabela 2 – Média e Covariância da amostra em caixa e o 2º 100m para atenuação	50
Tabela 3 – Média e Covariância da amostra em caixa e o 3º 100m para atenuação	51
Tabela 4 – Comparativo dos <i>Bestfits</i> entre os 100 metros.....	69
Tabela 5 – Média e Covariância da amostra em caixa e o 1º 100m para ACRF.....	69
Tabela 6 – Média e Covariância da amostra em caixa e o 2º 100m para ACRF.....	69
Tabela 7 – Média e Covariância da amostra em caixa e o 3º 100m para ACRF.....	70
Tabela 8 – Comparativo dos <i>Bestfits</i> entre os 100 metros para ACRF	81
Tabela 9 – Erros do modelo considerando a caixa utilizada no treinamento para Atenuação	97
Tabela 10 – Erros dos modelos considerando as caixas utilizadas na validação para atenuação	97
Tabela 11 – Erros do modelo considerando a caixa utilizada no treinamento de ACRF	112
Tabela 12 – Erros dos modelos considerando as caixas utilizadas na validação de ACRF	112
Tabela 13 – Comparativo dos <i>Bestfit</i> para a predição de atenuação do par 1.	113
Tabela 14 – Comparativo dos <i>Bestfit</i> para a predição de ACRF da combinação 1x2.....	113
Tabela 15 – Comparativo dos <i>Bestfit</i> da validação dos modelos para a predição de atenuação do par 1.....	114
Tabela 16 – Comparativo dos <i>Bestfit</i> da validação dos modelos para a predição de ACRF da combinação 1x2.....	115

LISTA DE FIGURAS

Figura 1 – Mapeamento da relação entre resultados do cabo testado em caixa e esticado.	16
Figura 2 – Ilustração de um cabo LAN	19
Figura 3 – Esquemático de atenuação do sinal em um cabo	20
Figura 4 – Esquemático da perda de retorno em um par.	20
Figura 5 – Esquemático dos parâmetros de Paradiafônia e Resíduo de telediafônia	21
Figura 6 – Amostras em caixa e esticadas.....	22
Figura 7 – Resultados de atenuação em caixa	23
Figura 8 – Resultados de atenuação com cabo esticado	23
Figura 9 – Resultados de ACRF em caixa.....	23
Figura 10 – Resultados de ACRF com cabo esticado	24
Figura 11 – Esquemático de teste da amostra de 305m com super bobina.	26
Figura 12 – Fluxo da identificação de um sistema	30
Figura 13 – Estrutura do modelo geral linear	33
Figura 14 – Estrutura do modelo ARX.....	34
Figura 15 – Estrutura do modelo ARMAX	35
Figura 16 – Estrutura do modelo BJ	35
Figura 17 – Neurônio Biológico.....	40
Figura 18 – Neurônio artificial.	41
Figura 19 – Fase de propagação.	43
Figura 20 – Fase de retro-propagação.	44
Figura 21 – Tela principal da <i>Toolbox</i> de identificação de sistemas.....	48
Figura 22 – Escolha de diversas ordens para o modelo ARX	51
Figura 23 – Resultados do <i>Bestfit</i> de vários modelos ARXs após diferentes pré-processamentos.....	52
Figura 24 – Resultados do <i>Bestfit</i> de vários modelos IV após diferentes pré-processamentos.....	53
Figura 25 – Comparação entre modelos ARX441 e IV441.	54
Figura 26 – Resultados do <i>Bestfit</i> de vários modelos ARMAX após diferentes pré-processamentos.....	54
Figura 27 – Análise dos resíduos do modelo ARX441 para 1º 100 metros do par 1.....	55
Figura 28 – Análise dos resíduos do modelo IV441 para 1º 100 metros do par 1.	56
Figura 29 – Análise dos resíduos do modelo ARMAX4421 para 1º 100 metros do par 1	57
Figura 30 – Resultados comparativo do <i>Bestfit</i> dos modelos ARX 441, IV441 e ARMAX4421	57
Figura 31 – Análise dos resíduos do modelo ARX441 para 2º 100 metros do par 1.....	59
Figura 32 – Análise dos resíduos do modelo IV441 para 2º 100 metros do par 1.	59
Figura 33 – Análise dos resíduos do modelo ARMAX4421(laranja) e ARMAX4321 (roxo) para 2º 100 metros do par 1.....	60
Figura 34 – Resultados comparativo do <i>Bestfit</i> dos modelos ARX 441, IV441, ARMAX4421 e ARMAX4321.....	60
Figura 35 – Análise dos resíduos do modelo ARX441 (verde) e ARX10102(roxo) para 3º 100 metros do par 1.....	62
Figura 36 – Análise dos resíduos do modelo IV441 para 3º 100 metros do par 1.	63
Figura 37 – Análise dos resíduos do modelo ARMAX4421(verde), ARMAX4321 (azul) e ARMAX2221(bege) para 3º 100 metros do par 1.....	63
Figura 38 – Resultados comparativo do <i>Bestfit</i> dos modelos ARX 441, IV441,	

ARMAX4421 e ARMAX4321.....	64
Figura 39 – Resultados do <i>Bestfit</i> e do erro do modelo ARX 441 para 1º 100 do par 1 de uma nova caixa.	65
Figura 40 – Resultados do <i>Bestfit</i> e do erro do modelo ARX 441 para 2º 100 do par 1 de uma nova caixa.	65
Figura 41 – Resultados do <i>Bestfit</i> e do erro do modelo ARX 441 para 3º 100 do par 1 de uma nova caixa.	65
Figura 42 – Resultados do <i>Bestfit</i> e do erro do modelo IV 441 para 1º 100 do par 1 de uma nova caixa.	66
Figura 43 – Resultados do <i>Bestfit</i> e do erro do modelo IV 441 para 2º 100 do par 1 de uma nova caixa.	66
Figura 44 – Resultados do <i>Bestfit</i> e do erro do modelo IV 441 para 3º 100 do par 1 de uma nova caixa.	67
Figura 45 – Resultados do <i>Bestfit</i> e do erro dos modelos ARMAX 4421 para 1º 100 do par 1 de uma nova caixa.	67
Figura 46 – Resultados do <i>Bestfit</i> e do erro do modelo ARMAX 4421 para 2º 100 do par 1 de uma nova caixa.	68
Figura 47 – Resultados do <i>Bestfit</i> e do erro do modelo ARMAX 4421 para 3º 100 do par 1 de uma nova caixa.	68
Figura 48 – Simulação do modelo ARX para diversas ordens.....	70
Figura 49 – Sinais de entrada e Modelos obtidos.....	70
Figura 50 – Resultados do <i>Bestfit</i> e do erro do modelo ARX215 para 1º 100m de ACRF combinação 1x2	71
Figura 51 – Resultados do <i>Bestfit</i> e do erro do modelo ARMAX2221 para 1º 100m de ACRF combinação 1x2.....	72
Figura 52 – Resultados do <i>Bestfit</i> e do erro do modelo IV441 para 1º 100m de ACRF combinação 1x2.....	72
Figura 53 - Resultados do <i>Bestfit</i> e do erro dos modelos ARX213 e ARX215 para 2º 100m de ACRF combinação 1x2	73
Figura 54 – Resultados do <i>Bestfit</i> e do erro do modelo ARMAX2221 para 2º 100m de ACRF combinação 1x2.....	74
Figura 55 - Resultados do <i>Bestfit</i> e do erro dos modelos ARX213 e ARX215 para 3º 100m de ACRF combinação 1x2	74
Figura 56 – Resultados do <i>Bestfit</i> e do erro do modelo ARMAX2221 para 3º 100m de ACRF combinação 1x2.....	75
Figura 57 – Análise dos resíduos do modelo ARX215 para 1º 100 metros da combinação 1x2 com intervalo de confiança de 99%.	76
Figura 58 – Análise dos resíduos do modelo ARMAX2221 para 1º 100 metros da combinação 1x2 com intervalo de confiança de 99%.	76
Figura 59 – Análise dos resíduos do modelo IV441 para 1º 100 metros da combinação 1x2 com intervalo de confiança de 99%.	77
Figura 60 – Análise dos resíduos dos modelos ARX213 e 215 para 2º 100 metros da combinação 1x2 com intervalo de confiança de 99.9%.	77
Figura 61 – Análise dos resíduos do modelo ARMAX2221 para 2º 100 metros da combinação 1x2 com intervalo de confiança de 99.9%.	78
Figura 62 – Análise dos resíduos do modelo ARX215 para 3º 100 metros da combinação 1x2 com intervalo de confiança de 99.9%.	78
Figura 63 – Análise dos resíduos do modelo ARMAX2221 para 3º 100 metros da combinação 1x2 com intervalo de confiança de 99.9%.	79
Figura 64 – Resposta e erro do modelo ARX 215 para 1º 100m de uma caixa nova	79

Figura 65 – Resposta e erro do modelo ARX 215 para 2° 100m de uma caixa nova	80
Figura 66 – Resposta e erro do modelo ARX 215 para 3° 100m de uma caixa nova	80
Figura 67 – Resposta e erro do modelo ARMAX 2221 para 1° 100m de uma caixa nova	80
Figura 68 – Resposta e erro do modelo ARMAX 2221 para 2° 100m de uma caixa nova	81
Figura 69 – Resposta e erro do modelo ARMAX 2221 para 3° 100m de uma caixa nova	81
Figura 70 – Tela inicial da <i>toolbox Neural Network Fitting Tool</i>	82
Figura 71 – Tela de seleção dos dados da <i>toolbox Neural Network Fitting Tool</i>	83
Figura 72 – Tela de configuração dos dados da <i>toolbox Neural Network Fitting Tool</i>	83
Figura 73 – Tela de configuração da quantidade de neurônios na camada escondida da rede	84
Figura 74 – Tela de resultados da rede	84
Figura 75 – Performance da rede.....	85
Figura 76 – Tela de avaliação da rede	85
Figura 77 – Tela para exportar os resultados.....	86
Figura 78 – Configuração de testes do par 1	86
Figura 79 – Resultado do treinamento para rede do par 1.....	87
Figura 80 – Resultado da regressão do treinamento para rede do par 1.....	87
Figura 81 – Resultado da regressão de uma nova caixa	88
Figura 82 – Configuração de testes dos 4 pares	88
Figura 83 – Resultado do treinamento para rede dos 4 pares.....	89
Figura 84 – Resultado da regressão do treinamento para rede dos 4 pares.....	89
Figura 85 – Erro da rede para cada um dos 4 pares.....	90
Figura 86 – Erro geral da rede.....	90
Figura 87 – Resultado da regressão da validação da nova caixa 1 para atenuação.....	91
Figura 88 – Erro da rede para cada um dos 4 pares para nova caixa 1 para atenuação.....	91
Figura 89 – Erro geral da rede da nova caixa 1 para atenuação	92
Figura 90 – Resultado da regressão da validação da nova caixa 2 para atenuação.....	92
Figura 91 – Erro da rede para cada um dos 4 pares para nova caixa 2 para atenuação.....	93
Figura 92 – Erro geral da rede da nova caixa 2 para atenuação	93
Figura 93 – Resultado da regressão da validação da nova caixa 3 para atenuação.....	94
Figura 94 – Erro da rede para cada um dos 4 pares para nova caixa 3 para atenuação.....	94
Figura 95 – Erro geral da rede da nova caixa 3 para atenuação	95
Figura 96 – Resultado da regressão da validação da nova caixa 4 para atenuação.....	95
Figura 97 – Erro da rede para cada um dos 4 pares para nova caixa 4 para atenuação.....	96
Figura 98 – Erro geral da rede da nova caixa 4 para atenuação	96
Figura 99 – Configuração de testes do par 1	98
Figura 100 – Resultado do treinamento para rede com todas as combinações	98
Figura 101 – Resultado da regressão do treinamento para com todas as combinações	99
Figura 102 – Erros da rede para as combinações 1x2 e 1x3.....	99
Figura 103 – Erros da rede para as combinações 1x4 e 2x3.....	100
Figura 104 – Erros da rede para as combinações 2x4 e 3x4.....	100
Figura 105 – Erro geral da rede para todas as combinações	101
Figura 106 – Resultado da regressão da validação da nova caixa 1 para ACRF	102
Figura 107 – Erro da rede para as combinações 1x2 e 1x3 para nova caixa 1 para ACRF.....	102
Figura 108 – Erro da rede para as combinações 1x4 e 2x3 para nova caixa 1 para ACRF	103

Figura 109 – Erro da rede para as combinações 2x4 e 3x4 para nova caixa 1 para ACRF.....	103
Figura 110 – Erro geral da rede da nova caixa 1 para ACRF.....	104
Figura 111 – Resultado da regressão da validação da nova caixa 2 para ACRF	104
Figura 112 – Erro da rede para as combinações 1x2 e 1x3 para nova caixa 2 para ACRF	105
Figura 113 – Erro da rede para as combinações 1x4 e 2x3 para nova caixa 2 para ACRF.....	105
Figura 114 – Erro da rede para as combinações 2x4 e 3x4 para nova caixa 2 para ACRF	106
Figura 115 – Erro geral da rede da nova caixa 2 para ACRF.....	106
Figura 116 – Resultado da regressão da validação da nova caixa 3 para ACRF	107
Figura 117 – Erro da rede para as combinações 1x2 e 1x3 para nova caixa 3 para ACRF.....	107
Figura 118 – Erro da rede para as combinações 1x4 e 2x3 para nova caixa 3 para ACRF	108
Figura 119 – Erro da rede para as combinações 2x4 e 3x4 para nova caixa 3 para ACRF	108
Figura 120 – Erro geral da rede da nova caixa 3 para ACRF.....	109
Figura 121 – Resultado da regressão da validação da nova caixa 4 para ACRF	109
Figura 122 – Erro da rede para as combinações 1x2 e 1x3 para nova caixa 4 para ACRF.....	110
Figura 123 – Erro da rede para as combinações 1x4 e 2x3 para nova caixa 4 para ACRF.....	110
Figura 124 – Erro da rede para as combinações 2x4 e 3x4 para nova caixa 4 para ACRF	111
Figura 125 – Erro geral da rede da nova caixa 4 para ACRF.....	111
Figura 126 – Margem de atenuação no par 1 nos 1º 100m em caixa	121
Figura 127 – Margem de atenuação no par 1 nos 2º 100m em caixa	121
Figura 128 – Margem de atenuação no par 1 nos 3º 100m em caixa	121
Figura 129 – Covariância da atenuação no par 1 nos 1º 100m em caixa	122
Figura 130 – Covariância da atenuação no par 1 nos 2º 100m em caixa	122
Figura 131 – Covariância da atenuação no par 1 nos 3º 100m em caixa	122
Figura 132 – Periodograma da atenuação no par 1 nos 1º 100m em caixa	123
Figura 133 – Periodograma da atenuação no par 1 nos 2º 100m em caixa	123
Figura 134 – Periodograma da atenuação no par 1 nos 3º 100m em caixa	123
Figura 135 – Margem de ACRF na combinação 1x2 nos 1º 100m em caixa.....	124
Figura 136 – Margem de ACRF na combinação 1x2 nos 2º 100m em caixa.....	124
Figura 137 – Margem de ACRF na combinação 1x2 nos 3º 100m em caixa.....	124
Figura 138 – Covariância de ACRF na combinação 1x2 nos 1º 100m em caixa.....	125
Figura 139 – Covariância de ACRF na combinação 1x2 nos 2º 100m em caixa.....	125
Figura 140 – Covariância de ACRF na combinação 1x2 nos 3º 100m em caixa.....	125
Figura 141 – Periodograma de ACRF na combinação 1x2 nos 1º 100m em caixa.....	126
Figura 142 – Periodograma de ACRF na combinação 1x2 nos 2º 100m em caixa.....	126
Figura 143 – Periodograma de ACRF na combinação 1x2 nos 3º 100m em caixa.....	126

LISTA DE ACRÔNIMOS

ACRF	Attenuation CrossTalk Ratio – Far end
AR	Auto Regressivo
ARIMA	Auto Regressivo Integrado com Média móvel
ARMAX	Auto Regressivo com Média móvel e entrada externa
ARX	Auto Regressivo com entrada externa
BJ	Box-Jenkins
EMQ	Estimador estendido de mínimos quadrados
FEXT	Far End CrossTalk
FPE	Final Prediction Error
GMQ	Estimador generalizado de mínimos quadrados
IV	Instrumental Variable ou Variável Instrumental
IWCS	International Wire and Cable Symposium
LAN	Local Area Network
MIMO	Multiple-Input and Multiple-Output
MISO	Multiple-Input and Single-Output
MQ	Estimador dos mínimos quadrados
MQP	Estimador de mínimos quadrados ponderados
NARX	Non linear autoregressive model with exogenous variables
NEXT	Near End CrossTalk
NRMSE	Normallized Root Mean Square Error
RBF	Radial basis function
RNA	Redes Neuras Artificiais
RNN	Redes Neuras Naturais
SISO	Single-Input and Single-Output
SS	State-Space
TIA	Telecommunications Industry Association

SUMÁRIO

1 INTRODUÇÃO	15
1.1 OBJETIVO DO TRABALHO	15
1.2 JUSTIFICATIVA	15
1.3 METODOLOGIA	17
1.4 ESTRUTURA DO TRABALHO	18
2 DESCRIÇÃO DO TRABALHO	19
2.1 REVISÃO DA LITERATURA	24
2.2 PRÁTICAS ADOTADAS PARA REALIZAÇÃO DOS TESTES	25
2.3 CONCLUSÕES DO CAPÍTULO	28
3 IDENTIFICAÇÃO DE SISTEMAS	29
3.1 MODELOS POLINOMIAIS	30
3.1.1 Modelo de função de transferência.....	31
3.1.2 Modelo Polinomial Geral Linear.....	32
3.1.3 Modelo ARX	33
3.1.4 Modelo ARMAX.....	34
3.1.5 Modelo BOX-JENKINS.....	35
3.1.6 Estimador de Mínimos quadrados.....	35
3.1.7 Variáveis Instrumentais.....	36
3.1.8 Análise dos modelos.....	37
3.2 REDES NEURAIS ARTIFICIAIS	40
3.2.1 Modelo geral de neurônio.....	41
3.2.2 Caracterização da RNA.....	41
3.2.3 Aprendizado da RNA	42
3.2.3.1 Aprendizado supervisionado	42
3.2.3.2 Aprendizado não supervisionado.....	42
3.2.4 Topologias da RNA.....	42
3.2.5 Algoritmo de Retropropagação do erro (<i>Back-Propagation</i>).....	43
3.2.6 Algoritmo de Levenberg-Marquardt	46
4 IMPLEMENTAÇÕES E RESULTADOS	48
4.1 IMPLEMENTAÇÕES E RESULTADOS UTILIZANDO MODELOS PARAMÉTRICOS POLINOMIAIS.....	48
4.1.1 Pré-processamento do sinal de entrada.....	49
4.1.2 Análise do parâmetro de atenuação com modelos polinomiais.....	50
4.1.2.1 Análise do par 1 referente ao 1º 100 metros	51
4.1.2.1.1 Comparação da análise dos resíduos para atenuação	54
4.1.2.1.2 Comparação dos modelos	57
4.1.2.2 Análises do par 1 referente ao 2º 100 metros	58
4.1.2.3 Análises do par 1 referente ao 3º 100 metros	60
4.1.2.4 Validações dos modelos polinomiais para atenuação.....	64
4.1.2.4.1 Erros dos modelos polinomiais para atenuação.....	68
4.1.3 Análise do parâmetro de ACRF com modelos polinomiais	69
4.1.3.1 Análise da combinação 1x2 referente ao 1º 100 metros	70
4.1.3.2 Análise da combinação 1x2 referente ao 2º 100 metros	73
4.1.3.3 Análise da combinação 1x2 referente ao 3º 100 metros	74
4.1.3.4 Análise dos resíduos dos modelos para ACRF	75
4.1.3.5 Validações dos modelos polinomiais para ACRF	79
4.1.3.5.1 Erros dos modelos polinomiais para ACRF	81
4.2 IMPLEMENTAÇÕES E RESULTADOS UTILIZANDO REDES NEURAIS ARTIFICIAIS.....	82

4.2.1	Análise do parâmetro de atenuação com RNA.....	82
4.2.1.1	Análise do par 1 com RNA.....	86
4.2.1.1.1	Validação da rede para o par 1	87
4.2.1.2	Análise dos 4 pares com RNA.....	88
4.2.1.2.1	Validação da rede para os 4 pares	90
4.2.1.2.2	Erros dos modelos de atenuação com RNA	97
4.2.2	Análise do parâmetro de ACRF com RNA.....	97
4.2.2.1.1	Validação da rede para todas as combinações.....	101
4.2.2.1.2	Erros dos modelos de ACRF com RNA.....	111
4.3	CONCLUSÕES DO CAPÍTULO	112
5	CONCLUSÕES FINAIS	116
5.1	TRABALHOS FUTUROS	117
	REFERÊNCIAS	118
	ANEXO I – DADOS DE ATENUAÇÃO DO PAR 1.....	121
	ANEXO II – DADOS DE ACRF DA COMBINAÇÃO 1X2.....	124

1 INTRODUÇÃO

Atualmente o mercado de cabos apresenta um cenário em que as indústrias deste segmento vivenciam uma constante batalha contra seus concorrentes e contra si mesma, na busca por novos mercados, consolidação da marca, novos clientes, etc, além disso, a exigência por reduções de custos é um fator indispensável para a sobrevivência destas empresas. Assim, torna-se necessário gastar menos, porém produzindo com qualidade. Devido a essa competitividade, as margens de vendas estão cada vez menores, sendo necessário vender grandes quantidades para se obter lucros significativos.

Diante deste cenário, o estudo da metodologia de testes de cabos LAN é um assunto bastante relevante já que envolve ensaios que podem ser destrutivos, aumentando ainda mais os custos de fabricação dos cabos, além de ser uma excelente fonte de economia, contribuindo para que a empresa permaneça saudável e competitiva no mercado.

1.1 OBJETIVO DO TRABALHO

O objetivo do presente trabalho é estudar técnicas de predição, considerando modelos paramétricos polinomiais e topologias de redes neurais artificiais, a fim de modelar dois importantes parâmetros elétricos de um cabo de telecomunicação do tipo LAN, que são Atenuação e Resíduo de Telediafonia. Através desses modelos, busca-se demonstrar a correlação existente entre diferentes metodologias de testes de performance elétrica de cabos LAN, atualmente em uso na indústria. Essas metodologias realizam medições dos parâmetros em estudo a partir de amostras de cabos em caixa ou diretamente testando essas mesmas amostras esticadas. Como resultado final, pretende-se, após análises, testes e validações dos modelos desenvolvidos, implementar um procedimento automático de avaliação dos cabos.

1.2 JUSTIFICATIVA

A quantia de dinheiro empregada em testes de conferência de qualidade em uma indústria de cabos LAN é muito elevada, já que as amostras coletadas da produção para testes de liberação do lote são descartadas após os testes, deste modo, gerando um alto impacto ambiental no descarte das amostras ou nos recursos empregados para o seu reaproveitamento.

Além disso, também é necessário mencionar o tempo gasto nos ensaios, a mão-de-obra envolvida, etc. Isso acontece em virtude da atual regulamentação, TIA-568-C.2 (TIA, 2011) recomendar que os cabos sejam ensaiados em amostras de 100 metros esticados sobre uma superfície não condutora e livre de esforços mecânicos ou através de algum método alternativo que seja provadamente equivalente ao sugerido pela norma.

Contudo, as recomendações desta normativa no quesito condições de ensaio se fazem necessárias, já que os testes em cabos em caixa apresentam elevados índices de ruídos durante a medição, devido a auto-indução gerada pelo cabo em virtude de sua acomodação em caixa. Logo seria muito desejável que estes cabos pudessem ser testados em caixa e liberados quando não apresentarem nenhum problema. Assim como os cabos são comercializados em caixa, a sua aprovação não geraria nenhum descarte ou desperdício após as medições, como acontece com os testes em amostras esticadas.

Desta maneira, objetiva-se encontrar uma maneira alternativa de efetuar tais testes de performance elétrica, de modo a representar a relação existente entre o ensaio do cabo na caixa e em uma amostra de 100 metros através da utilização dos modelos paramétricos e das redes neurais artificiais. Com efeito, deseja efetuar o mapeamento entre os resultados obtidos quando o cabo é testado em caixa e correlacioná-los com os resultados obtidos se o mesmo cabo tivesse sido testado, esticado com uma amostra de 100 metros, conforme ilustração da figura 1.



Figura 1 - Mapeamento da relação entre resultados do cabo testado em caixa e esticado.

Devido ao pouco conhecimento sobre o mapeamento a ser feito foram implementadas representações lineares e não lineares. Em virtude da presença de ruído nas medições, foram avaliados os modelos polinomiais do tipo ARX, ARMAX cujos parâmetros foram obtidos com o método dos mínimos quadrados e com o método das variáveis instrumentais. Por outro lado, foram desenvolvidos modelos baseados em redes neurais

artificiais para efetuar uma tratativa do problema considerando-o como não-linear. Espera-se que os modelos obtidos capturem a natureza do problema real fornecendo soluções fisicamente realizáveis, fáceis de serem implementadas e com boa assertividade.

1.3 METODOLOGIA

Considerando que os cabos LAN são comercializados em caixas e que os ensaios são realizados em amostras de 100 metros, diversos cabos LAN categoria 6 U/UTP foram ensaiados primeiramente em caixas de 305 metros e na seqüência fracionados em amostras de 100 metros, conforme recomendado pela norma TIA (2011). O protocolo de testes foi configurado para que a resolução do equipamento *Network Analyzer*, o qual é utilizado para avaliações de performances elétricas de cabos, de cada ensaio seja composto de 401 pontos, ou seja, de modo a fornecer 401 pontos de medições ao longo da freqüência. Desta maneira, o conjunto de dados do ensaio em caixa foi utilizado como dado de entrada e o conjunto de dados dos ensaios nas amostras de 100 metros foi utilizado como dado de saída para obtenção de modelos que representem a relação entre ensaios.

Para a representação através de modelos paramétricos testou-se diferentes tipos de pré-processamento com o intuito de remover distúrbios de medição que poderiam afetar a predição dos modelos. Na seqüência, foram analisados e comparados modelos ARX e ARMAX obtidos com o método dos mínimos quadrados e com o método das variáveis instrumentais com diferentes ordens para cada ensaio. Os valores dos parâmetros elétricos atenuação e ACRF obtidos com os vários modelos foram comparados, utilizando os critérios de Akaike, *Bestfit* e Erro do Modelo para avaliar as respectivas assertividades. Após esta etapa, os modelos que apresentaram os melhores resultados com os dados de treinamento foram submetidos a testes de validação com novos dados, não utilizados no treinamento utilizando os mesmos critérios adotados anteriormente.

Por outro lado, em virtude da natureza não linear, dos parâmetros estudados, também foram estudadas abordagens não-lineares baseados em redes neurais artificiais. Foram analisadas configurações da rede *Backpropagation* implementadas com o algoritmo de Levenberg-Marquardt com diferentes dados de entrada e quantidades de neurônios nas camadas escondidas utilizando os critérios de Regressão e Erro da rede, como indicadores para a avaliação de desempenho.

Por fim, realizou-se a comparação dos resultados gerados pelos modelos paramétricos e pelas redes neurais utilizando o critério de *Bestfit* para efetuar a comparação entre as técnicas. Grande parte das implementações foram realizadas através dos *toolboxes* *System Identification* e *Neural Network Fitting Tool*, ambos presentes na versão 2007 do *software* Matlab.

1.4 ESTRUTURA DO TRABALHO

O trabalho está organizado em seis capítulos, sendo o primeiro de introdução fornecendo uma visão geral do trabalho desenvolvido, explicitando seu objetivo e resultados esperados.

O Capítulo 2 apresenta as soluções e alternativas usualmente aplicadas para este problema, apresentando ainda uma pesquisa bibliográfica sobre o tema.

O Capítulo 3 apresenta uma breve introdução sobre identificação de sistemas, abordando os principais conceitos e definições das técnicas utilizadas, que são os modelos paramétricos e as redes neurais artificiais.

O Capítulo 4 possui a maior parte do trabalho desenvolvido, descrevendo como os modelos foram obtidos, apresentando as implementações e ensaios realizados, bem como fazendo uma comparação de desempenho entre ambos os modelos e finalizando com as discussões dos resultados obtidos.

O Capítulo 5 encerra com as conclusões finais e uma proposta de desenvolvimento futuro.

O Capítulo 6 fornece as referências utilizadas na elaboração deste trabalho.

2 DESCRIÇÃO DO TRABALHO

Os cabos LAN são constituídos usualmente por 4 pares de fios identificados por cores, os quais são estrategicamente torcidos, ou também chamados de binados, cada um com um passo diferente, separados por um elemento separador, na seqüência agrupados e por fim revestidos por uma capa de material não propagante a chama, conforme ilustrado na figura 2.

Usualmente, o par azul é conhecido como par 1, o laranja como par 2, o verde como par 3 e por fim, o marrom como par 4.

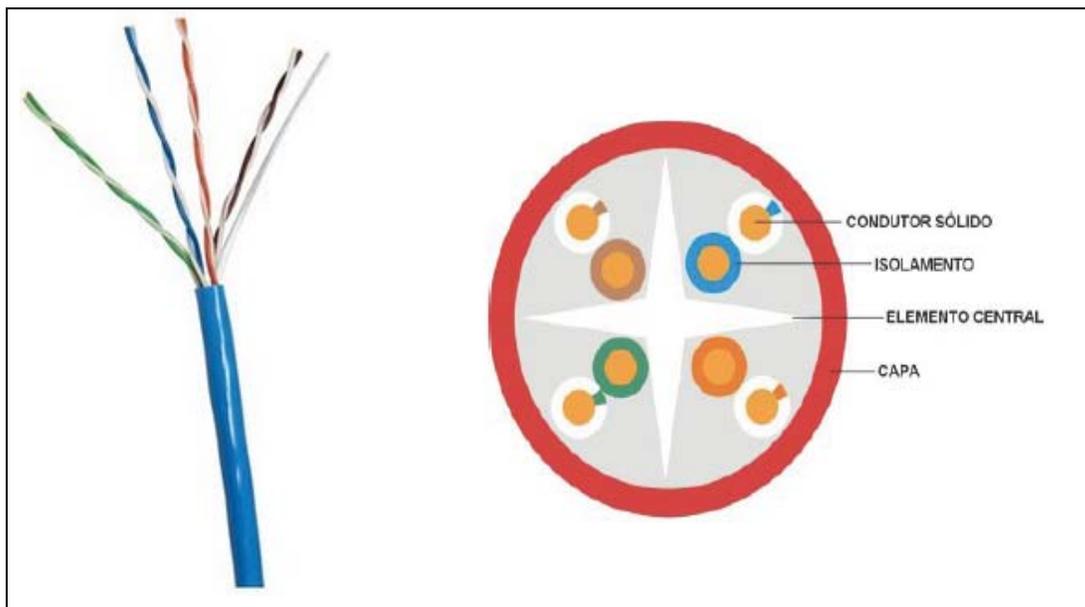


Figura 2 - Ilustração de um cabo LAN

Um conjunto de normas regula a produção e comercialização desses cabos, dentre as quais se destaca a TIA568-C2 (TIA, 2011) a qual especifica os requisitos de performance elétrica que os cabos devem atender, dentre os quais se destacam:

- Atenuação (*Insertion Loss*): nível que a amplitude de um sinal, na figura 3 representada pela amplitude de uma senóide, é atenuada ao trafegar pelos pares do cabo.

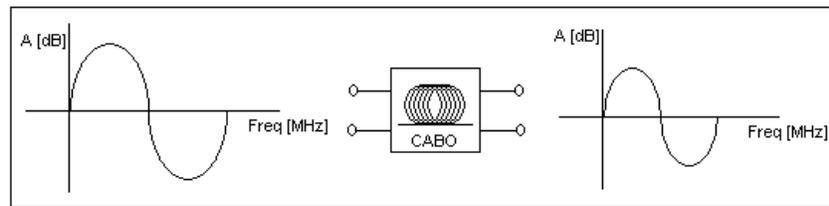


Figura 3 - Esquemático de atenuação do sinal em um cabo

- Perda de Retorno (*Return Loss*): perda de sinal devido o não casamento de impedância entre o cabo e o transmissor, conforme mostrado na figura 4.

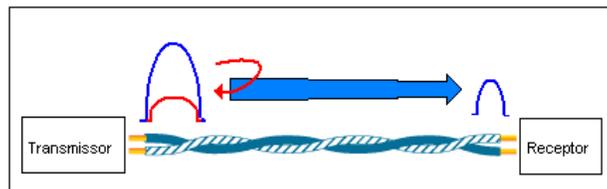


Figura 4 - Esquemático da perda de retorno em um par.

- Paradiafonia (*NEXT – Near End CrossTalk*): ruído induzido no par i , devido a transmissão de algum sinal no par j , medido no lado de transmissor;
- Telediafonia (*FEXT – Far End CrossTalk*): ruído induzido no par i , devido a transmissão de algum sinal no par j , medido no lado de receptor;
- Resíduo de telediafonia (*ACRF – Attenuation Crosstalk Ratio Far End*): ruído atenuado induzido no par i , devido à transmissão de algum sinal no par j , medido no lado do receptor, ou seja, FEXT subtraído da atenuação.

A figura 5 traz um esquemático ilustrando os parâmetros de Paradiafônia e Resíduo de telediafônia

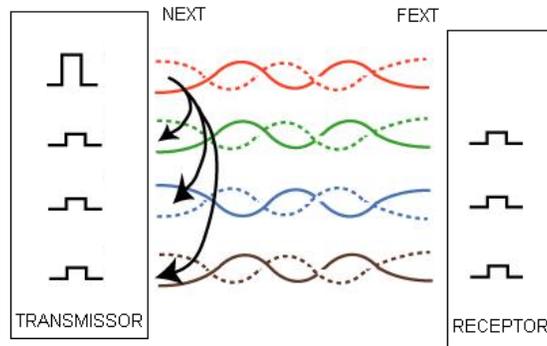


Figura 5 - Esquemático dos parâmetros de Paradiafonia e Resíduo de telediafonia

O conjunto de normas TIA568-C2 (TIA, 2011) determina que todo ensaio elétrico deve ser realizado com uma amostra de 100 metros do cabo, esticada sobre uma superfície não condutora e livre de qualquer esforço mecânico exercido sobre o cabo ou de alguma forma que equivalha a esta condição, ou seja, esta norma autoriza que sejam realizadas medições através de métodos alternativos, desde que comprovada sua eficácia. Contudo, como os cabos são comercializados em caixas com 305 metros, este teste destrutivo impossibilita a comercialização dessas amostras, gerando diariamente uma elevada quantidade de amostras sucateadas, impactando profundamente no balanço financeiro da empresa.

Usualmente as empresas testam uma amostra de 100 metros a cada lote, gerando algo em torno de 100 metros desperdiçados a cada 6.100 metros de cabos produzidos. Considerando uma produção média 150 km de cabo por dia, em um mês terá ocorrido um desperdício de mais de 50 km de cabo, considerando 21 dias trabalhados.

Para alguns testes de performance elétrica, tais como *Delay skew* e *Propagation velocity*, os quais também estão referenciados na TIA568-C2 (TIA, 2011), a condição do ensaio não interfere no resultado. Porém, para a determinação dos parâmetros de Atenuação e ACRF, citados acima, a condição de teste faz toda diferença, já que os cabos apresentam um alto nível de ruído em altas frequências, quando não testado esticado, especialmente para aqueles que possuem pares com menores passos de binagem. Este fenômeno acontece devido ao cabo estar acomodado na caixa na forma de espiras, assim, gerando um campo magnético que interfere nas medições dos parâmetros de Atenuação e ACRF.

A figura 6 exibe as condições de teste, a fim de evidenciar a razão de a normativa prever que os ensaios devam ser realizados com as amostras esticadas.

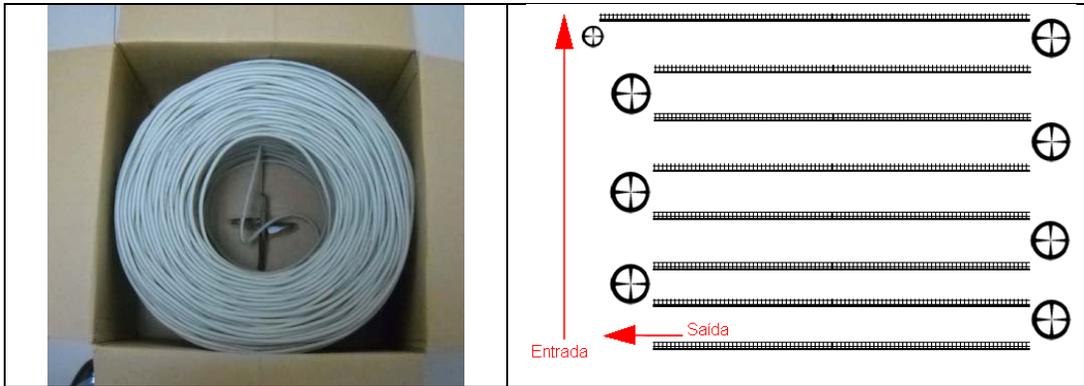


Figura 6 - Amostras em caixa e esticadas

Como exemplo, as figuras 7, 8, 9 e 10 exibem as diferenças de resultados para amostras testadas em caixa e esticadas para os parâmetros de atenuação e ACRF, respectivamente.

Os gráficos de atenuação exibem a atenuação do cabo categoria 6 U/UTP de 4 pares, assim cada uma das cores no gráfico representa um determinado par no cabo, ou seja, a linha azul representa a atenuação no par azul, e assim por diante.

Analogamente os gráficos de ACRF exibem os resultados deste ensaio, o qual por ser combinatorial, apresenta os resultados de ACRF para as combinações entre pares, ou seja, entre os pares 1 e 2, 1 e 3, 1 e 4, 2 e 3, 2 e 4 e por fim 3 e 4.

Nessas figuras, é possível observar que os resultados dos ensaios realizados em caixa apresentam desempenho fora dos limites desejáveis, ou seja, os cabos reprovaram nos ensaios em virtude da maneira que foram acomodadas para o teste. Em especial, comprova-se a reprovação de alguns pares nas frequências próximas de 160 MHz para o ensaio de atenuação em caixa (compare figuras 7 e 8) e para algumas combinações de ACRF próximas de 80 MHz (compare figuras 9 e 10).

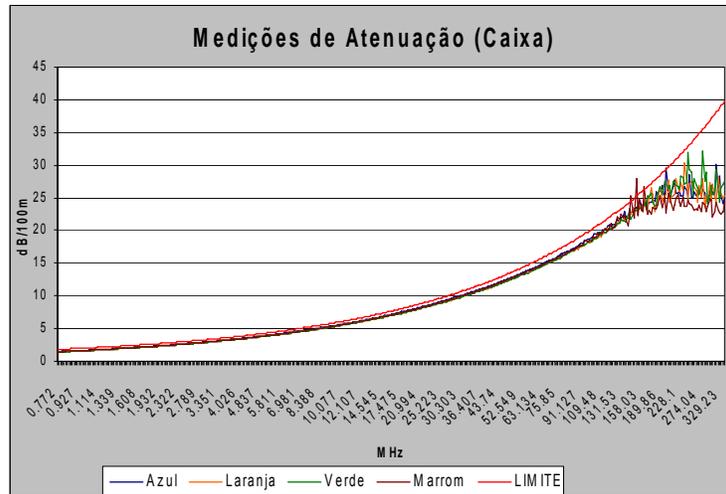


Figura 7 - Resultados de atenuação em caixa

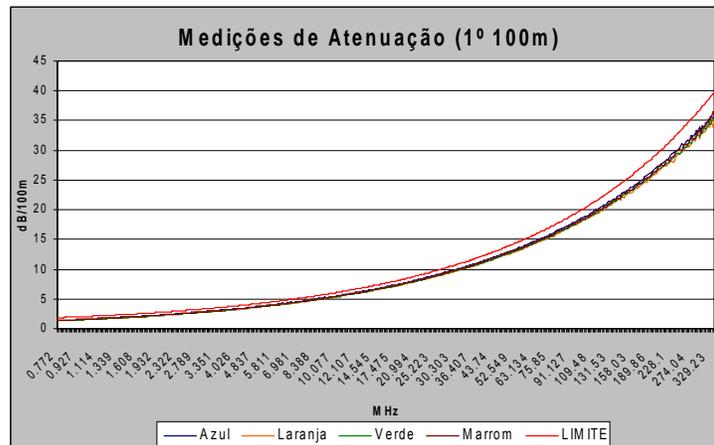


Figura 8 - Resultados de atenuação com cabo esticado

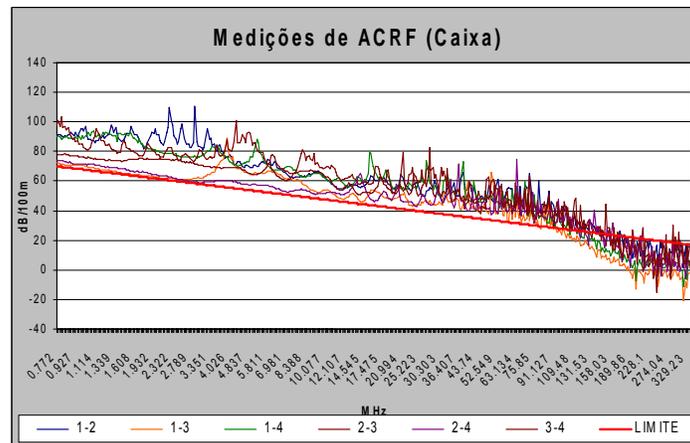


Figura 9 - Resultados de ACRF em caixa

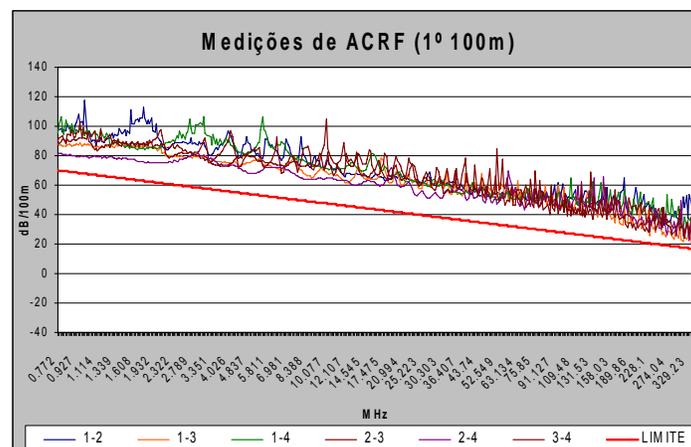


Figura 10 - Resultados de ACRF com cabo esticado

2.1 REVISÃO DA LITERATURA

As soluções ou alternativas para este tipo de problema é um assunto muito restrito, e pouca literatura existe sobre o tema, uma vez que é considerado um segredo industrial, pela maioria de fabricantes de cabos. Assim, existem muito poucos trabalhos disponíveis na literatura sobre a modelagem de parâmetros em toda a área de cabos.

Contudo, existe um simpósio americano conhecido como IWCS (International Wire and Cable Symposium), através do qual anualmente acontecem apresentações de artigos técnicos, palestras, debates, etc. Deste modo, foi efetuada uma pesquisa bibliográfica nas publicações dos últimos 20 anos e os trabalhos encontrados mais relevantes sobre temas relacionados ao assunto da dissertação são brevemente discutidos a seguir.

Nalsén (1999) comparou a eficiência das redes neurais artificiais e de um algoritmo de regressão linear na modelagem do parâmetro Impedância de transferência em cabos blindados. Porém, os resultados alcançados com ambas as técnicas não atingiram a precisão suficiente para os modelos serem considerados utilizáveis.

Goddard (1999) utilizou o modelo Auto-regressivo integrado com média móvel (ARIMA) para eliminar o efeito da autocorrelação em uma carta de controle estatístico de processo de cabos ópticos e variáveis de processo de montagens ribbon, considerando as variáveis de processo como séries temporais e adequando-as ao modelo ARIMA.

Josefsson e colaboradores (JOSEFSSON, POLTZ e BECKETT, 2004) propuseram a simulação e medição do parâmetro FEXT em cabos de par trançado utilizando a combinação das técnicas de elementos finitos e de fronteira. A correlação obtida entre os resultados teóricos e práticos não foi satisfatória para baixas frequências. Contudo, para altas frequências provou ser uma ferramenta útil no desenvolvimento de novos cabos.

Josefsson e Poltz (2008) propuseram a medição e simulação de linhas de transmissão simétricas desbalanceadas, realizando diversas medições em cabos e efetuando modelagens envolvendo a combinação das técnicas de elementos finitos e de fronteira. Seus experimentos concluíram que o ensaio elétrico chamado Atraso Diferencial é uma excelente maneira de verificar o nível de desbalanceamento de um cabo blindado.

Castro e Walling (2010) propuseram a aplicação de matrizes de dispersão generalizadas para a modelagem de cabos de par trançados. Os resultados obtidos através desta técnica serviram para se obter a ordem de grandeza dos resultados de vários ensaios elétricos. Deste modo, a técnica de matrizes de dispersão pode ser usada como ferramenta útil para a predição de resultados de ensaios elétricos de novos cabos em desenvolvimento.

Apesar de apresentar semelhanças metodológicas com os trabalhos de Nalssen (1999) e Godard (1999), é outro o objetivo da presente dissertação. Em relação aos demais trabalhos citados, tanto o conjunto de métodos utilizados neste trabalho, como os parâmetros e efeitos modelados, são outros. Assim espera-se contribuir com resultados que melhorem a prática industrial de medição de parâmetros e testes em cabos.

2.2 PRÁTICAS ADOTADAS PARA REALIZAÇÃO DOS TESTES

De modo geral, as principais práticas utilizadas pelas empresas para evitar a indesejável geração de ruídos advindas da condição de teste e ao mesmo tempo reduzir a quantidade de cabos sucateados são:

- a) Reduzir a amostragem de cabos testados: essa medida é muito perigosa, sendo que somente pode ser adotada com base em estudos estatísticos que indiquem uma perfeita estabilidade de processo de fabricação e que haja também outros

procedimentos de controle de qualidade durante o processo de fabricação, capazes de identificar previamente problemas que supostamente apenas seriam identificados nos testes finais. A grande dificuldade entre as indústrias é justamente criar testes intermediários capazes de identificar problemas antes que o cabo esteja totalmente manufaturado. Contudo, mesmo que esses procedimentos possam ser implementados, ainda assim existiria uma maior probabilidade de eventuais cabos não conformes serem comercializados sem o controle da empresa, já que os mesmos não teriam sido exatamente inspecionados para os parâmetros em questão, por estarem fora da amostragem submetida aos ensaios destrutivos.

- b) Testar apenas os parâmetros elétricos passíveis de serem testados em caixa: igualmente a opção anteriormente mencionada, a opção de desprezar alguns parâmetros pode ser interessante caso se tenha uma grande confiança no processo, porém aumenta o risco de serem vendidos produtos não conformes.
- c) Rebobinar a amostra da caixa de 305m em uma super bobina, de modo que as camadas do cabo fiquem distantes entre si. Não há um tamanho padrão definido para esta bobina, assim obrigando que cada empresa analise de acordo com os projetos de seus cabos, qual deve ser o tamanho desta bobina a minimizar interferências nos ensaios. A principal vantagem dessas super bobinas é que após os ensaios com o equipamento *Network Analyzer*, o cabo pode ser recolocado na caixa e ser comercializado, contudo demandará tempo extra do setor produtivo para fazer estas atividades, conforme esquemático da figura 11.

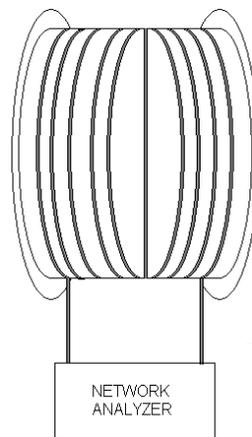


Figura 11 - Esquemático de teste da amostra de 305m com super bobina.

d) Realizar normalmente os testes nas amostras de 100m, conforme exige a norma, e avaliar uma forma de inserir este custo no custo total do produto.

Independentemente da prática adotada, a norma TIA-568-C.2 (TIA, 2011) especifica a maneira de proceder ao ensaio de modo a não haver interferências ou dúvidas quanto aos resultados obtidos. Por sua vez, cada empresa adota uma maneira diferente de minimizar seus gastos, englobando novos desenvolvimentos, produtos mais competitivos, reduções de custos nos processos e matérias-primas, etc. Considerando o alto valor agregado do produto e o montante de cabos produzidos, o desenvolvimento de novos métodos de ensaio para reduzir custos, evitar desperdícios e ter confiabilidade dos produtos produzidos é uma alternativa promissora para a indústria de cabos.

Neste contexto de busca de uma nova metodologia que permita o desenvolvimento de testes de cabo LAN em caixa se insere o presente trabalho. A proposta é mapear a correlação entre os resultados de performance elétrica dos cabos quando testados esticados com uma amostra de 100 metros e quando testados em caixa com seu comprimento total de 305 metros. A partir da análise dessas correlações, pretende-se construir modelos que permitam prever corretamente o valor dos parâmetros de atenuação e ACRF dos cabos quando testados em caixa.

A obtenção desses modelos é baseada em técnicas clássicas de identificação paramétrica (Ljung,1999) para obtenção de modelos lineares (polinomiais) para a predição desses parâmetros a partir de medidas em caixa. Devido a natureza não linear, dos parâmetros estudados, foram também desenvolvidos modelos não-lineares baseados em redes neurais artificiais.

Para obtenção de todos os modelos é utilizado uma base de dados da empresa Furukawa que contém dados históricos de vários ensaios em diferentes cabos. Os modelos paramétricos são desenvolvidos utilizando a *toolbox System Identification Tool* e os modelos baseados em redes neurais artificiais utilizando a *toolbox Neural Network Fitting Tool*, os quais estão presentes na versão 2007 do programa MATLAB.

2.3 CONCLUSÕES DO CAPÍTULO

Diante das diferenças nos resultados dos testes para atenuação e ACRF entre as amostras de cabo em caixa e esticadas, essa dissertação estuda um modelo alternativo que permita corrigir os erros dos testes em caixa, aproximando-os dos testes esticados, evitando diariamente o sucateamento de vários quilômetros de cabos.

Os modelos a serem desenvolvidos são baseados na aplicação de técnicas de identificação via algoritmo dos mínimos quadrados (Ljung,1999) e via redes neurais (Haykin, 2001) em um conjunto de dados reais de testes em cabo.

A fim de balizar o desenvolvimento desses modelos, o capítulo a seguir traz uma discussão sobre os principais conceitos de identificação de sistemas baseada em dados, englobando os principais modelos paramétricos e de redes neurais artificiais.

3 IDENTIFICAÇÃO DE SISTEMAS

A identificação de sistemas é a área do conhecimento que visa desenvolver modelos capazes de emular o comportamento de um sistema, independentemente de sua estrutura, forma ou tipo, a partir de dados amostrados do sistema, aos quais são aplicadas técnicas de estimação que são capazes inferir seu comportamento e representá-lo através de um modelo. Ljung (1999) propõe que a identificação de um sistema segue um fluxo natural composto das etapas abaixo e ilustrados na figura 12.

- a) Projeto de experimento: análise do tipo de experimento necessário para determinar quando e quais sinais são necessários de serem monitorados para se obter o máximo de informações relevantes do sistema;
- b) Aquisição de dados: coleta de informações relevantes, devidamente filtradas para que a maioria dos dados esteja livre de ruídos além de informações imprecisas e incompletas;
- c) Escolha da estrutura do modelo: escolha da arquitetura do modelo a ser utilizado, sendo esta a etapa mais difícil da identificação, na qual, o conhecimento a priori e alguns *feelings* sobre o assunto são empregados. De maneira geral, a estrutura do modelo é um mapeamento parametrizado entre o espaço de medidas e o espaço de saída do modelo.
- d) Escolha do critério de *fitness*: escolha do critério de avaliação para determinar se o modelo obtido pode ser considerado como satisfatório.
- e) Determinação do modelo: utilização de um método de estimação derivado da escolha do critério de *fitness* que permite calcular os parâmetros do modelo, a partir de um conjunto de medidas disponíveis. Com isso, as características do modelo são ajustadas de modo a aproximar a saída do modelo ao máximo à saída real do sistema;

- f) Validação do modelo: teste para avaliar se realmente o modelo obtido corresponde à saída desejada, de acordo com o critério estipulado, de modo que se o modelo estiver de acordo, poderá ser considerado apto para uso, caso contrário deverá ser revisado.

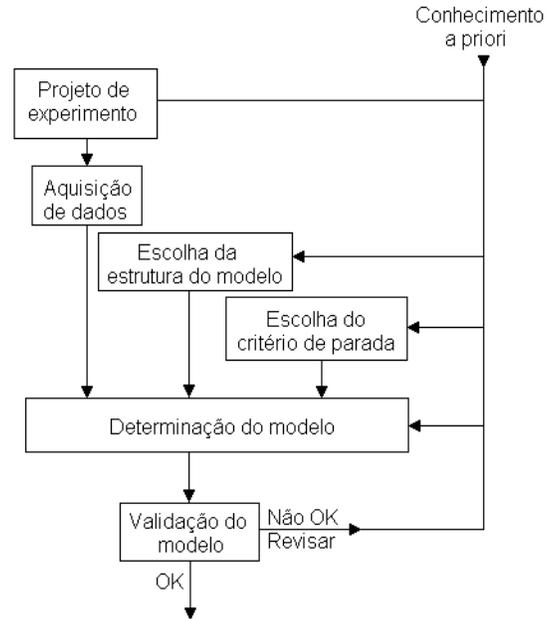


Figura 12 - Fluxo da identificação de um sistema

A seguir serão apresentados os principais conceitos dos modelos polinomiais e das redes neurais artificiais.

3.1 MODELOS POLINOMIAIS

Existem diversas estruturas de modelos que podem auxiliar na modelagem de um sistema desconhecido, dentre os quais se destaca os modelos paramétricos polinomiais que descrevem o sistema em termos de funções de transferências e equações diferenciais. Considerando que muitas vezes, em aplicações reais, descrever um sistema desconhecido usando apenas equações físicas é uma tarefa bem complexa, estes modelos exercem grandes auxílios por proporcionarem estruturas compactas para estes sistemas. Os modelos paramétricos são largamente utilizados em uma abordagem de identificação chamada de modelagem “caixa preta”, uma vez que se admite uma estrutura matemática para o modelo cujos parâmetros são desconhecidos. Em seguida, a partir de dados disponíveis sobre o sistema em que se deseja modelar, são realizados

diversos ajustes nos parâmetros do modelo até que se atinja um erro máximo admissível entre o modelo e o sistema real que se deseja modelar.

Contudo, a escolha do modelo que proporcione a melhor aderência possível ao sinal de saída, de modo a minimizar a diferença entre o dado observado, ou seja, sinal de saída medido e a saída gerada pelo modelo é uma das etapas mais importantes do processo de identificação. Sendo que apesar de existirem algumas técnicas para escolher os modelos, é recomendável testar diversas estruturas antes de selecionar a que melhor se adéque ao sistema conforme proposto por Luminita (2007).

3.1.1 Modelo de função de transferência

Funções de transferência, as quais são expressas como uma razão entre dois polinômios, são responsáveis por modelar o comportamento dinâmico entre a entrada e a saída de um sistema. Por definição, a função de transferência de um sistema contínuo é a transformada de Laplace da sua resposta ao impulso. Para os sistemas discretos, a função de transferência corresponde a transformada Z de sua resposta ao impulso.

As equações 1 e 2 descrevem os modelos de função de transferência para os domínios contínuo e discreto, respectivamente.

$$y(t) = G(s)u(t) + e(t) \quad (1)$$

$$y(k) = G(z)u(k) + e(k) \quad (2)$$

Onde

$y(t)$ e $y(k)$ são as saídas contínuas e discretas respectivamente do sistema

$G(s)$ e $G(z)$ são as funções de transferência contínuas e discretas respectivamente

$u(t)$ e $u(k)$ são as entradas contínuas e discretas respectivamente do sistema.

$e(t)$ e $e(k)$ são os erros de modelagem contínuos e discretos respectivamente do sistema.

A função de transferência descreve a relação causa-efeito entre entrada e saída do sistema, porém não fornece informação detalhada sobre o que acontece dentro do sistema. Assim, uma representação que pode ser utilizada para modelar estas relações, além de ser mais conveniente do que a função ou matriz de transferências para representar sistemas não-lineares e multivariáveis é a representação no Espaço de

Estados (Aguirre, 2007). No entanto, esta forma de representação não será utilizada nesta dissertação por inserir complexidade nos modelos obtidos.

3.1.2 Modelo Polinomial Geral Linear

Usualmente se descreve um sistema utilizando a equação conhecida como modelo geral linear ou modelo polinomial geral linear, conforme equação 3.

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}e(k) \quad (3)$$

Onde $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são polinômios no operador deslocamento ‘ q ’ conforme discutido a seguir.

Simplificando, se obtém a equação 4.

$$y(k) = \frac{B(q)}{F(q)A(q)}u(k) + \frac{C(q)}{D(q)A(q)}e(k) \quad (4)$$

E por fim a equação 5.

$$y(k) = G(q)u(k) + H(q)e(k) \quad (5)$$

Onde usualmente a função de transferência $G(q)$ representa o comportamento dinâmico do sistema a ser modelado e a função de transferência $H(q)$ representa a influência da perturbação e demais erros de modelagem sobre as medições $y(k)$ (Aguirre 2007).

Considerando $u(k)$ a entrada do sistema, $y(k)$ a saída do sistema, $e(k)$ o distúrbio ou ruído do sistema, q^{-1} o operador de atraso, de forma que $y(k)q^{-1} = y(k-1)$, os polinômios $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são definidos nas equações 6, 7, 8, 9 e 10.

$$A(q) = 1 + a_1q^{-1} + \dots + a_{n_y}q^{-n_y} \quad (6)$$

$$B(q) = b_1q^{-1} + \dots + b_{n_u}q^{-n_u} \quad (7)$$

$$C(q) = 1 + c_1q^{-1} + \dots + c_{n_e}q^{-n_e} \quad (8)$$

$$D(q) = 1 + d_1q^{-1} + \dots + d_{n_d}q^{-n_d} \quad (9)$$

$$F(q) = 1 + f_1q^{-1} + \dots + f_{n_f}q^{-n_f} \quad (10)$$

A figura 13 exibe a estrutura do modelo geral linear.

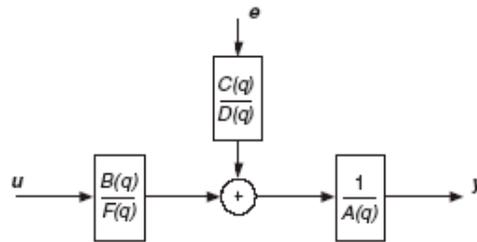


Figura 13 – Estrutura do modelo geral linear

Fonte: National Instruments (2012)

Modelos mais simplificados podem ser obtidos através da estrutura do modelo geral adotando-se simplificações de fazer um ou mais dos polinômios $A(q)$, $B(q)$, $C(q)$ ou $D(q)$ igual a 1, deste modo, obtendo-se vários modelos amplamente utilizados como ARX, ARMAX, Box-Jenkins e outros (Aguirre, 2007).

A escolha de um destes modelos em uma aplicação específica depende da dinâmica do sistema (raízes do polinômio A) a ser modelado e do tipo de distúrbio do sistema, sendo que muitas vezes a modelagem pode levar a um modelo fisicamente não realizável. Uma vez escolhida uma família de modelos, a estimação de seus parâmetros corresponde a calcular os coeficientes dos polinômios envolvidos a partir de dados medidos do sistema.

Dentre os possíveis modelos obtidos a partir dos polinômios escolhidos $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$, destacam-se a seguir os modelos ARX, ARMAX e Box-Jenkins que serão utilizados nesta dissertação.

3.1.3 Modelo ARX

O modelo ARX, ou seja, modelo auto regressivo com entrada externa (*autoregressive model with external input*) é obtido a partir do modelo geral linear, considerando $C(q)$, $D(q)$ e $F(q)$ igual a 1, sendo $A(q)$ e $B(q)$ polinômios arbitrários. As equações 11 e 12 exibem maneiras alternativas de representar o modelo ARX.

$$A(q)y(k) = B(q)u(k) + e(k) \quad (11)$$

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{1}{A(q)}e(k) \quad (12)$$

Como neste modelo, o ruído $e(k)$ aparece diretamente na equação, o modelo ARX é normalmente classificado como pertencente à classe de modelos de Equação de Erro.

A figura 14 exibe a estrutura do modelo ARX.

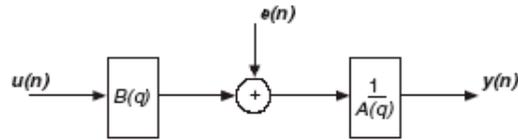


Figura 14 – Estrutura do modelo ARX

Fonte: National Instruments (2012)

Como será abordado posteriormente, os parâmetros de um modelo ARX podem ser obtidos com a utilização do estimador dos mínimos quadrados, assumindo que o ruído presente no sistema é branco, sendo que para o estimador MQ ser consistente é necessário que as premissas sobre os momentos estatísticos, média e covariância dos sinais de entrada e saída envolvidos ($\text{cov}(u, e) = 0$ e $E(u|e) = 0$) sejam verdadeiras (Davila, 2008).

3.1.4 Modelo ARMAX

O modelo ARMAX, ou seja, modelo auto regressivo com média móvel e entrada externa (*autoregressive-moving average with external input*) é obtido a partir do modelo geral, considerando $D(q)$, $F(q)$ igual a 1 e $A(q)$, $B(q)$ e $C(q)$ polinômios arbitrários. A equação 13 exibe a equação do modelo.

$$A(q)y(k) = B(q)u(k) + C(q)e(k) \quad (13)$$

A grande vantagem do modelo ARMAX sobre o ARX é devido o modelo ARX não possuir flexibilidade para descrever as propriedades da parte do distúrbio, em contrapartida o modelo ARMAX possui maior flexibilidade, por prevê a equação de erro como uma média móvel do ruído branco (Ljung, 1999). A figura 15 exibe a estrutura do modelo ARMAX.

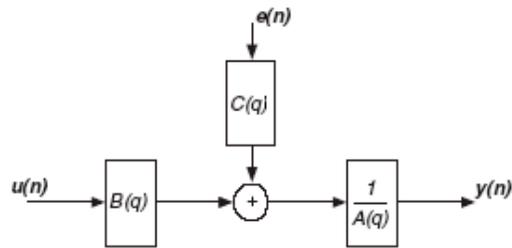


Figura 15 – Estrutura do modelo ARMAX

Fonte: National Instruments (2012)

3.1.5 Modelo BOX-JENKINS

O modelo Box-Jenkins (BJ) é obtido através da equação geral, considerando $A(q)$ igual a 1 e os demais polinômios arbitrários. A equação 14 exibe o modelo.

$$y(k) = \frac{B(q)}{F(q)} u(k) + \frac{C(q)}{D(q)} e(k) \quad (14)$$

Este modelo é da família dos modelos Erros de Saída, uma vez que as funções de transferência $B(q)/F(q)$ e $C(q)/D(q)$ não possuem parâmetros em comum, ou seja, são independentemente parametrizadas, sendo este fator o que o diferencia dos modelos ARX e ARMAX. A figura 16 exibe a estrutura do modelo BJ.

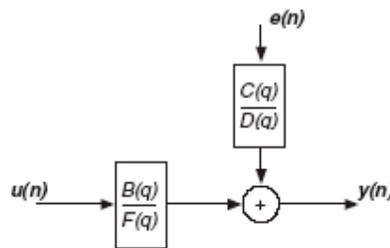


Figura 16 – Estrutura do modelo BJ

Fonte: National Instruments (2012)

3.1.6 Estimador de Mínimos quadrados

O método dos mínimos quadrados é um dos mais conhecidos e utilizados para estimação de parâmetros de funções em diversas áreas do conhecimento, sendo que teve origem em trabalhos e estudos de Gauss sobre astronomia. O estimador MQ e suas

variações são facilmente aplicáveis na obtenção de diversos modelos paramétricos como ARX e ARMAX.

Aguirre (2007) resume como o estimador que fornece o valor estimado do vetor de parâmetros, $\hat{\theta}$, que minimiza o somatório dos quadrados dos erros, conforme equação 15.

$$\hat{\theta}_{MQ} = \arg_{\theta} \min J_{MQ} \quad (15)$$

Sendo que $\arg_{\theta} \min J_{MQ}$ indica o argumento, pertencente ao domínio de θ , que minimiza a função J_{MQ} , conforme equação 16.

$$J_{MQ} = \sum_{i=1}^N \zeta(i)^2 = \zeta^T \zeta = \|\zeta\|^2 \quad (16)$$

Onde $\zeta \in \Re^N$ é o erro gerado na estimação.

A expressão da equação 16 também é conhecida como estimador de mínimos quadrados clássico ou ordinário, porém existem versões mais sofisticadas deste estimador, como o estimador de mínimos quadrados ponderados (MQP), o estimador generalizado de mínimos quadrados (GMQ) utilizado para estimar os parâmetros do modelo ARX e o estimador estendido de mínimos quadrados (EMQ) utilizado para estimar os parâmetros do modelo ARMAX (Aguirre, 2007).

Informações adicionais sobre o estimador de MQ e suas variações como GMQ, EMQ e outras podem ser obtidas nas referências Aguirre (2007), Ljung (1999) e Soderstrom e Stoica (2001).

3.1.7 Variáveis Instrumentais

Diferentemente dos modelos ARX e ARMAX que utilizam o estimador dos mínimos quadrados, existe o método das variáveis instrumentais (IV – *Instrumental Variables*) que pode ser implementado utilizando a estrutura do modelo ARX, porém sua principal diferença está na tratativa dada ao ruído, uma vez que o estimador de mínimos quadrados considera as funções de transferência do processo $G(q)$ e do ruído $H(q)$, em contrapartida o método das IV despreza a função de transferência do ruído. Assim, dependendo do sistema a ser modelado este poderá ser o fator decisivo para o sucesso na modelagem já que a característica do ruído é muito importante.

Resumidamente, a variável instrumental, usualmente representada por Z , é uma variável que é inserida no modelo com duas importantes propriedades: ser descorrelacionada com o ruído da medição e ser correlacionada com o dado de entrada ($E(Z|e) = 0$ e $E(Z|u) \neq 0$). A equação 17 representa o estimador de variáveis instrumentais para um simples sistema do tipo $y = X\beta + e$.

$$\hat{\beta}_{IV} = (Z'X)^{-1}Z'y \quad (17)$$

Informações adicionais sobre este método podem ser encontradas em Aguirre (2007), Ljung (1999) e Soderstrom e Stoica (2001).

3.1.8 Análise dos modelos

Além do modelo e de sua ordem é necessário saber avaliar sua resposta para verificar sua aderência ao tipo do problema e ao sinal de saída. Desta maneira, foram analisados vários critérios, a saber:

a) Best Fit: é o termo em inglês na tradução livre de “melhor encaixe”, que mensura quão semelhante é a resposta do modelo frente à resposta real, a qual é expressa pela equação 18.

$$Best_fit = \left(1 - \frac{\|y - \hat{y}\|}{\|y - \bar{y}\|}\right) \times 100 \quad (18)$$

Sendo que y é a resposta real, \hat{y} é a resposta do modelo ou predição e por fim \bar{y} é a média de y , e $\|\cdot\|$ é a norma euclidiana de um vetor. Desta forma, 100% corresponde a uma perfeita aderência entre as respostas, enquanto 0% indica nenhuma aderência.

b) Critério de Akaike: também conhecido como Erro final de predição de Akaike (FPE - *Final Prediction Error*) é um critério que avalia a qualidade do modelo simulando situações aonde o modelo é testado com diferentes conjuntos de dados, sendo possível efetuar a comparação dos mesmos através deste critério. Quanto menor for o valor obtido através de seu critério, mais preciso será o modelo (Ljung, 1999).

A FPE do Akaike é apresentada na equação 19.

$$FPE = V \begin{pmatrix} 1 + \frac{d}{N} \\ 1 - \frac{d}{N} \end{pmatrix} \quad (19)$$

Sendo que V é a função perda (*Insertion Loss*), d é o número de parâmetros estimados, ou ordem do modelo, e N é a quantidade de valores do conjunto de dados de estimação. Assumindo que FPE é assintoticamente convergente para $d \ll N$ é possível efetuar a aproximação, conforme a equação 40 (Ljung, 1999).

$$FPE = V \left(1 + \frac{2d}{N} \right) \quad (20)$$

Sendo que a função de perdas é definida pela equação 21.

$$V = \det \left(\frac{1}{N} \sum_{i=1}^N \varepsilon(t, \theta_N) (\varepsilon(t, \theta_N))^T \right) \quad (21)$$

Onde \det é o determinante da função e $\varepsilon(t, \theta_N)$ é o erro de predição no instante t entre saída do sistema e a saída gerada pela predição com os parâmetros estimados θ_N .

C) Análise dos Resíduos: é uma importante ferramenta de avaliação para verificar se os parâmetros do modelo foram identificados corretamente, uma vez que considera o desempenho do modelo sobre um conjunto de dados medidos. Os resíduos são definidos como a série temporal de erro um passo a frente, obtida com os dados gerados pelo estimador MQ (Aguirre, 2007).

A equação 22 exhibe o vetor de resíduos, o qual depende dos parâmetros estimados e dos regressores que compõe o modelo.

$$\xi = y - \Psi \hat{\theta} \quad (22)$$

Onde ξ é vetor de resíduos, y é a saída do sistema, Ψ é a matriz de regressores de modelos dinâmicos e $\hat{\theta}$ é o vetor de parâmetros estimados.

Se o estimador usado for baseado nos mínimos quadrados, a soma dos quadrados dos resíduos é mínima para o vetor de regressores escolhido, sendo que uma das condições requeridas para que o estimador MQ não apresente polarização na determinação de $\hat{\theta}$ é que o erro na equação deve ser ruído branco. Considerando que o modelo identificado

$y(k) = \Psi^T \hat{\theta} + \zeta(k)$ é obtido através da equação de regressão após a estimação de parâmetros, para se obter $E[\hat{\theta}_{MQ}] = 0$, onde E é a esperança, é necessário que os resíduos sejam brancos, desta forma a análise dos resíduos é um conjunto de testes que verifica se os resíduos são ou não aleatórios, uma vez que se forem brancos significa que não há informações úteis nos resíduos, porém se não forem brancos significa que há informações úteis, assim caracterizando que o modelo não conseguiu explicar tudo que era explicável nos dados (Aguirre, 2007).

Desta forma são realizados os testes de autocorrelação do resíduo e de correlação cruzada entre o vetor de resíduos e o sinal de entrada $u(k)$, conforme as equações 23 e 24.

$$r_{\zeta\zeta}(\tau) = E\{\zeta(k-\tau)\zeta(k)\} = \delta(\tau) \quad (23)$$

$$r_{u\zeta}(\tau) = E\{u(k-\tau)\zeta(k)\} = 0, \forall \tau \quad (24)$$

Por fim, o teste de autocorrelação dos resíduos, também chamado de teste de branqueza (*whiteness test*) diz que um bom modelo possui a autocorrelação dos resíduos dentro do intervalo de confiança da correspondente estimação, indicando que os resíduos estão descorrelacionados (Ljung, 1999).

Em contrapartida o teste de correlação cruzada, também chamado de teste de independência (*independence test*) diz que um bom modelo possui resíduos descorrelacionados das entradas anteriores. Por exemplo, um pico fora do intervalo de confiança para o intervalo k significa que a saída $y(t)$ que se originou da entrada $u(t-k)$ não foi descrita pelo modelo (Ljung, 1999).

Por fim, esta sessão apresentou objetivamente a teoria necessária para o entendimento dos modelos paramétricos e dos principais métodos de validação utilizados para sua avaliação, uma vez que a sessão 4.1 abordará os resultados de diversas análises e comparações envolvendo diferentes estruturas de modelos paramétricos.

Na próxima sessão serão apresentadas objetivamente as Redes Neurais Artificiais.

3.2 REDES NEURAIS ARTIFICIAIS

Os sistemas dinâmicos encontrados na prática são, em sua maioria, não-lineares, de modo que, muitas vezes os sistemas lineares não serão satisfatórios e as representações não-lineares serão necessárias, apesar do usual aumento de complexidade dos algoritmos que essa representação utiliza.

O processo de identificação pode ser abordado de diferentes formas, dependendo do nível de conhecimento que se tem sobre o sistema. Conforme comentado anteriormente, se a identificação for do tipo caixa preta, ou seja, aonde o conhecimento veio exclusivamente através de medições de dados e não se possui quase ou nenhuma informação sobre a física do sistema, e considerando ainda que o sistema seja além de dinâmico, não-linear, a complexidade para se selecionar uma estrutura de modelo que se adéque a este sistema desconhecido se torna elevada. Deste modo, a utilização de redes neurais artificiais se torna uma excelente ferramenta disponível para realizar a identificação de um sistema não-linear, devido a sua capacidade de aprendizado e inferência de relacionamentos não-lineares a partir de dados, e também devido as suas propriedades e robustez como um aproximador universal (Norgaard, 2000).

A construção de redes neurais artificiais (RNA) tem inspiração nos neurônios biológicos, o qual é ilustrado na figura 17, e nos sistemas nervosos.

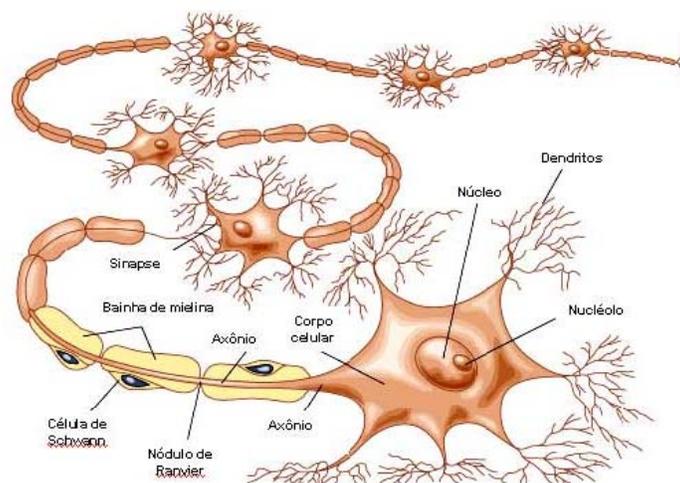


Figura 17 - Neurônio Biológico.

Fonte: Portal Só Biologia (2012)

Porém, a utilização de RNA em identificação de sistemas é motivada pelo fato de ser uma importante representação não-linear, dentre outras disponíveis, mas de mais fácil

implementação, como modelos de Hammerstein e de Wiener, modelo Auto-regressivo como entrada exógena não linear (*NARX - Non linear autoregressive model with exogenous variables*), Funções radiais de base (*RBF - Radial basis functions*), Série de Volterra, etc (Aguirre, 2007).

3.2.1 Modelo geral de neurônio

O modelo geral de neurônio, mostrado na figura 18, é uma generalização do modelo de McCulloch e Pitts, sendo estes os primeiros pesquisadores a proporem um modelo de neurônio em 1943. No modelo geral as entradas u_i e as ponderações w_i são combinadas usando uma função η , para produzir um estado de ativação do neurônio que através da função Φ vai produzir a saída do neurônio. Um valor auxiliar θ é geralmente usado para representar uma polarização.

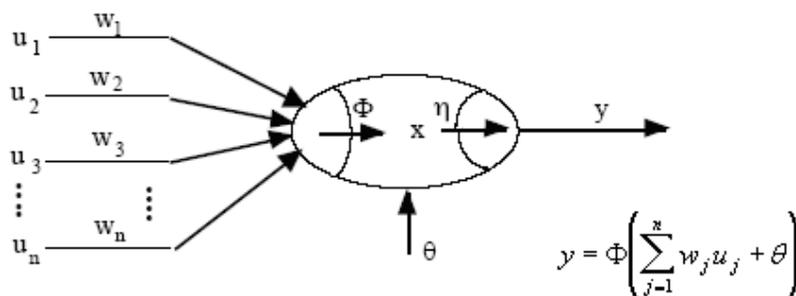


Figura 18 - Neurônio artificial.

Fonte: Adaptação de Barreto (2002)

3.2.2 Caracterização da RNA

Normalmente diz-se que uma RNA é um sistema composto por vários neurônios, ligados entre si por várias conexões, as quais são chamadas de conexões sinápticas. Alguns neurônios recebem excitações do meio externo e são chamados neurônios de entrada e correspondem aos neurônios dos órgãos dos sentidos. Outros têm suas respostas usadas para alterar, de alguma forma, o mundo exterior e são chamados neurônios de saída. Os neurônios que não são nem entrada nem saída são conhecidos como neurônios internos, sendo estes de grande importância e são conhecidos como “*hidden*” fazendo com que algumas literaturas traduzam como “escondidos”.

3.2.3 Aprendizado da RNA

As RNAs possuem a capacidade de aprenderem por exemplos, e fazerem interpolações do que aprenderam. Deste modo, podem-se destacar dois modos de aprendizado, os quais são: aprendizado supervisionado e aprendizado não supervisionado.

3.2.3.1 Aprendizado supervisionado

No aprendizado supervisionado, analogamente, pode-se dizer que a rede neural opera como se houvesse um professor avaliando e indicando explicitamente o comportamento da rede. Por exemplo, seja o caso de reconhecimento de caracteres e, para simplificar se deseje reconhecer entre um A ou um X. Escolhe-se uma rede, com dois neurônios na camada de saída, uma ou várias camadas internas e um conjunto de neurônios na camada de entrada capaz de representar com a precisão desejada a letra em questão. Apresentam-se estas letras sucessivamente a uma retina artificial constituída por uma matriz de elementos fotossensíveis, cada um ligado a um neurônio. Observa-se qual dos dois neurônios de saída está mais excitado. Se for o que se convencionou representar a letra que for apresentada, nada deve ser corrigido, caso contrário modificam-se os valores das conexões sinápticas no sentido de fazer a saída se aproximar da desejada, ou seja, corrigindo o valor de entrada conforme o valor da saída (Barreto, 2002).

3.2.3.2 Aprendizado não supervisionado

Diferentemente do aprendizado supervisionado, é como se não houvesse um professor avaliando o desempenho da rede. Sendo que para se executar modificações nos valores das conexões sinápticas não se usam informações sobre se a resposta da rede foi correta ou errada, ou seja, não existe a orientação do professor avaliando o comportamento da rede. Usa-se por outro lado um esquema, tal que, para exemplos de coisas semelhantes, a rede responda de modo semelhante (Barreto, 2002).

3.2.4 Topologias da RNA

Existem basicamente dois tipos de topologia de RNA, as quais são:

- Redes com alimentação direta (*feedforward networks*): onde o fluxo de dados flui diretamente da entrada para a saída, podendo até envolver várias camadas. Porém, não existindo a realimentação dos dados. Exemplos clássicos deste tipo de rede são: Perceptron e Adaline.
- Redes recorrentes (*recurrent networks*): é o caso oposto à rede com alimentação direta, uma vez que esta possui a realimentação, assim permitindo a utilização dos dados de saída na entrada. Exemplos clássicos deste tipo de rede são: Kohonen e Hopfield.

3.2.5 Algoritmo de Retropropagação do erro (*Back-Propagation*)

O algoritmo de Retropropagação do erro (*Back-propagation*) é o algoritmo mais difundido para treinamento de redes multicamadas, sendo que o mesmo baseia-se no Aprendizado Supervisionado por Correção de Erros, sendo composto por duas fases: fase de propagação e fase de retropropagação.

- Propagação: Depois de apresentado o padrão de entrada, a resposta de uma unidade é propagada como entrada para as unidades na camada seguinte, até a camada de saída, onde é obtida a resposta da rede e o erro é calculado;

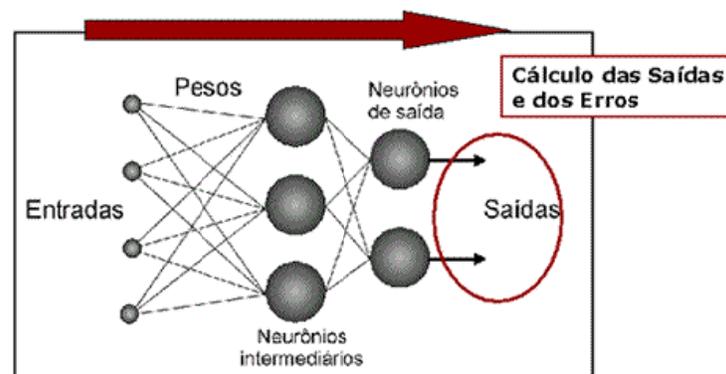


Figura 19 – Fase de propagação.

Fonte: Laboratório Nacional de Computação Científica (2012)

- Retropropagação (*backpropagation*): Desde a camada de saída até a camada de entrada, são feitas alterações nos pesos sinápticos.

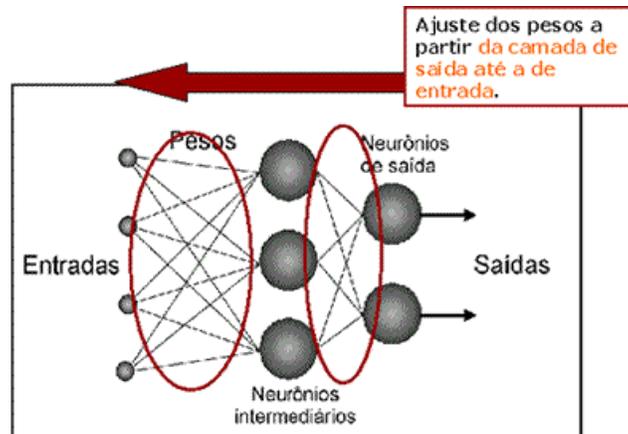


Figura 20 – Fase de retro-propagação.

Fonte: Laboratório Nacional de Computação Científica (2012)

Durante a fase treinamento deve-se apresentar um conjunto formado pelo par: entrada para a rede e valor desejado para resposta a entrada. A saída será comparada ao valor desejado e será computado o erro global da rede, que influenciará na correção dos pesos no passo de retro-propagação. Apesar de não haver garantias de que a rede forneça uma solução ótima para o problema, este processo é muito utilizado por apresentar uma boa solução para o treinamento de Perceptrons Multicamadas.

Conforme proposto por várias literaturas como HAYKIN (2001), segue o resumo do Algoritmo:

1- Inicialização: Inicialize os pesos sinápticos e os *bias* aleatoriamente, com valores no intervalo $[-1;1]$;

2- Apresentação dos Exemplos de Treinamento:

- Treinamento *on-line*: Para cada exemplo do conjunto de treinamento, efetue os passos 3 e 4.
- Treinamento em lote: Para cada época do conjunto de treinamento, efetue os passos 3 e 4.

3- Computação para Frente (Propagação): Depois de apresentado o exemplo do conjunto de treinamento $T = \{(x(n),d(n))\}$, sendo $x(n)$ a entrada apresentada à rede e $d(n)$ a saída desejada, calcule o valor da ativação v_j e a saída para cada unidade da rede, da seguinte forma:

$$v_j = \sum_{i=1}^m w_{ji} x_i + b \quad (25)$$

Para o cálculo do valor da ativação e para o cálculo da saída y da unidade k, utilizar a função sigmóide ou outra função se necessário.

$$f(v) = \frac{1}{1 + e^{(-av)}} \quad (26)$$

Utilize a saída das unidades de uma camada como entradas para a seguinte, até a última camada. A saída das unidades da última camada será a resposta da rede.

4- Calcule o Sinal de Erro: Fazendo a saída $y_j = O_j(n)$, será $O_j(n)$ a resposta da rede, calcule o sinal de erro através da seguinte fórmula:

$$e_j(n) = d_j(n) - O_j(n) \quad (27)$$

Onde $d_j(n)$ é a saída desejada com resposta para cada unidade na interação (n).

Este sinal de erro será utilizado para computar os valores dos erros das camadas anteriores e fazer as correções necessárias nos pesos sinápticos.

5- Computação para Trás (Retropropagação): Calcule os erros locais, δ_j , para cada unidade, desde a camada de saída até a de entrada. O gradiente local é definido por:

$$\delta_j(n) = e_j(n) O_j(n) (1 - O_j(n)) \quad (28)$$

para a unidade da camada de saída ou

$$\delta_j(n) = O_j(n) (1 - O_j(n)) \sum \delta_k w_{jk} \quad (29)$$

para as unidades das demais camadas.

Onde:

$O_j(1-O_j)$ - é a função de ativação diferenciada em função do argumento, i.e., valor de ativação;

δ_k - é o erro das unidades da camada anterior conectada a unidade j;

w_{jk} - são os pesos das conexões com a camada anterior.

Após o cálculo dos erros de cada unidade, calcule o ajuste dos pesos de cada conexão segundo a regra delta generalizada e atualize os pesos:

$$\Delta w_{kj}(n+1) = \alpha w_{kj}(n) + \eta \delta_j y_j \quad (30)$$

para o cálculo dos ajustes dos pesos.

Faça:

$$w(n+1) = w(n) + \Delta w_{kj}(n) \quad (31)$$

para atualizar os pesos sinápticos.

Onde:

α - é a constante de *momentun*, quando $\alpha=0$, esta função funciona como a regra delta comum;

η - é a taxa de aprendizado;

δ_j - é o erro da unidade;

y_j - é a saída produzida pela unidade j ;

6- Interação: Refaça os itens 3, 4 e 5 referentes à propagação, cálculo do erro e retropropagação, apresentando outros estímulos de entrada, até que sejam satisfeitas as condições de treinamento; as quais podem ser:

- O erro da rede está baixo, sendo pouco alterado durante o treinamento;
- O número máximo de ciclos de treinamento foi alcançado.

3.2.6 Algoritmo de Levenberg-Marquardt

O algoritmo de retropropagação do erro, que é baseado no algoritmo do gradiente descendente, pode apresentar instabilidade numérica e problemas de convergência dependendo da função de custo que é minimizada para a obtenção da regra de atualização dos pesos, da taxa de aprendizado, da quantidade de neurônios na camada escondida e da qualidade dos dados utilizados para o treinamento.

A fim de amenizar esses problemas, uma variante robusta do algoritmo de retropropagação do erro é obtida ao se aplicar o algoritmo de Levenberg-Marquadt em lugar do gradiente descendente, para a minimização da função custo da rede neural.

A descrição original do algoritmo de Levenberg-Marquardt é apresentada em Marquardt (1963) podendo ser resumido da seguinte maneira.

Considere a função não-linear do tipo $f(Y) = X$, onde $X \in \mathfrak{R}^M$ e $Y \in \mathfrak{R}^N$ são vetores e $M \geq N$. Dado o vetor \hat{X} medido é necessário encontrar \hat{Y} que minimiza $\|\varepsilon\|$, sujeito a $\hat{X} = f(\hat{Y}) + \varepsilon$.

Considerando a estimação inicial \hat{Y} , o método de Newton a refina assumindo que $f(\hat{Y} + \Delta) = f(\hat{Y}) + J\Delta$, onde J é a matriz jacobiana, ou seja, $J = \partial X / \partial Y$ e Δ é um pequeno incremento de \hat{Y} . Dessa forma, minimizar $\|\varepsilon\|$ equivale a $\|\varepsilon - J\Delta\|$, que é o mesmo que resolver a equação 32.

$$J^T J \Delta = J^T \varepsilon \quad (32)$$

Além disso, a solução refinada, \hat{Y}_r , é dada pela equação 33 e pode ser melhorada iterativamente.

$$\hat{Y}_r = \hat{Y} + \Delta \quad (33)$$

Levenberg (1944) propôs uma alteração no algoritmo de Newton para acelerar sua convergência, de modo que a equação 31 é substituída pela equação 34.

$$(J^T J + I\lambda)\Delta = J^T \varepsilon \quad (34)$$

O método de Levenberg (1944) possui instabilidades numéricas quando λ aumenta, deste modo, anos depois, Marquardt (1963) propôs uma pequena alteração no algoritmo de Levenberg, ou seja, cada componente do gradiente é ponderada de acordo com sua curvatura. Deste modo, a equação 34 é substituída pela equação 35.

$$(J^T J + \text{diag}(J^T J)\lambda)\Delta = J^T \varepsilon \quad (35)$$

A aplicação de Levenberg-Marquardt para o treinamento de redes neurais é apresentada em HAGAN (1994).

O capítulo a seguir exhibe as implementações dos modelos paramétricos e das RNA aplicadas para modelar a correlação entre os diferentes tipos de acomodação do cabo para os ensaios de atenuação e ACRF.

4 IMPLEMENTAÇÕES E RESULTADOS

Este capítulo exhibe as implementações e resultados gerados pelos modelos paramétricos e pelas RNA para os ensaios de atenuação e ACRF.

No contexto de predição os modelos paramétricos utilizados foram ARX e ARMAX, além do método das IV, sendo que os 2 primeiros utilizam variações do estimador de mínimos quadrados, enquanto o IV não considera o ruído do sistema como branco. Entretanto, na técnica da RNA foi utilizada a rede do tipo *feed-forward* de 2 camadas treinadas com o algoritmo de Levenberg-Marquardt, topologia esta utilizada amplamente para problemas de identificação.

Desta forma o capítulo está dividido em três sessões, sendo a primeira considerando os modelos paramétricos, a segunda considerando as RNA e a última efetuando um comparativo dos resultados entre as diferentes técnicas.

4.1 IMPLEMENTAÇÕES E RESULTADOS UTILIZANDO MODELOS PARAMÉTRICOS POLINOMIAIS

Foi utilizado a *toolbox System Identification Tool* do Matlab versão 2007 para realizar as simulações dos modelos paramétricos, devido a seu manuseio simples, rápido e eficaz. A figura 21 exhibe a tela principal da ferramenta.

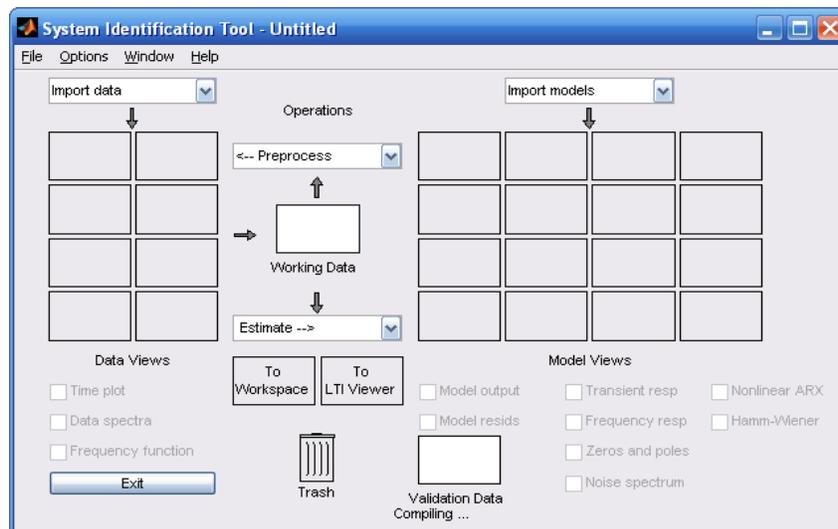


Figura 21 – Tela principal da *Toolbox* de identificação de sistemas

Inicialmente foi coletada uma caixa de cabos da produção, realizados os testes elétricos desta caixa com 305m e fracionada em partes de 100 metros para se efetuar a correlação

entre os resultados, ou seja, utilizando a medição em caixa como dado de entrada e cada uma das amostras de 100 metros como dado de saída, na seguinte seqüência:

- 1º) Experimento 01: teste na amostra em caixa com 305 metros;
- 2º) Experimento 02: teste nos primeiros 100 metros da caixa e testados esticados;
- 3º) Experimento 03: teste no segundo 100 metros da caixa e testados esticados;
- 4º) Experimento 04: teste no terceiro 100 metros da caixa e testados esticados;

Os 5 metros restantes da caixa foram sucateados por não poder ser reutilizado.

O equipamento analisador de espectro usado para efetuar as medições está programado para medir no intervalo de 0.772 MHz até 350 MHz, sendo que sua amostragem é de 401 pontos. Desta maneira, este foi o conjunto de dados usado na identificação e na validação, ou seja, os 401 pontos da medição em caixa como dado de entrada e os 401 pontos da medição do cabo esticado como dado de saída. Não foi possível dividir em 2 grupos de identificação e validação, já que muitas informações úteis seriam perdidas e comprometeriam a identificação.

Como a atenuação é uma grandeza avaliada individualmente para cada par, considerando que os cabos LAN possuem 4 pares, logo seria necessário obter um modelo para cada par para cada uma das amostras de 100m totalizando 12 modelos. Por outro lado, em virtude do ACRF ser um ensaio combinatorial, ou seja, medidas entre pares, serão necessários 18 modelos.

Contudo, a modelagem com modelos paramétricos neste trabalho apresenta apenas os melhores modelos para o par 1 no ensaio de atenuação e para a combinação dos pares 1x2 no ensaio de ACRF, uma vez que os demais pares e combinações seriam apenas extensões das técnicas aplicadas. Entretanto, com as RNA são considerados os casos de modelagem de apenas de 1 par no ensaio de atenuação, na seqüência os 4 pares neste mesmo ensaio e por fim as 06 combinações para o ensaio de ACRF.

4.1.1 Pré-processamento do sinal de entrada

Essa atividade tem grande importância por efetuar uma limpeza nos dados, com o intuito de eliminar características indesejáveis presentes no sinal. O *toolbox* do MATLAB dispõe de algumas funções de pré-processamento, dentre as quais se destacam três delas:

- a) *Remove means*: para retirar a média, ou em outras palavras, retirar o *offset* do sinal;
- b) *Remove trends*: para retirar tendências do sinal;
- c) *Filter*: para filtrar o sinal;

Idealmente seria desejável que o sinal de entrada, ou seja, as medições em caixa fossem do tipo ruído branco (média igual a zero e desvio padrão igual a 1) e excitação em todo espectro de frequência do periodograma. Porém, como não são, foram analisados os 3 tipos de pré-processamento disponíveis no *toolbox* em vários tipos de estruturas e ordens dos modelos, inclusive a opção sem nenhum tipo de pré-processamento.

4.1.2 Análise do parâmetro de atenuação com modelos polinomiais

O anexo I exhibe os gráficos das margens em atenuação do par 1, bem como os gráficos de covariância entre os valores dos cabos medidos em caixa e esticados e por fim seus periodogramas. As tabelas 01, 02 e 03 exibem os valores das médias e covariâncias dos 4 pares, ao longo das amostras em caixa e esticadas.

Tabela 1 – Média e Covariância da amostra em caixa e o 1º 100m para atenuação

Margens elétricas Atenuação	Caixa				1º 100m			
	Par 1	Par 2	Par 3	Par 4	Par 1	Par 2	Par 3	Par 4
Pares	Par 1	Par 2	Par 3	Par 4	Par 1	Par 2	Par 3	Par 4
Média	1.358	1.521	1.421	1.660	1.002	1.307	1.247	1.121
Covariância	6.161	5.966	4.789	9.422	0.611	1.096	0.950	0.764

Tabela 2 – Média e Covariância da amostra em caixa e o 2º 100m para atenuação

Margens elétricas Atenuação	Caixa				2º 100m			
	Par 1	Par 2	Par 3	Par 4	Par 1	Par 2	Par 3	Par 4
Pares	Par 1	Par 2	Par 3	Par 4	Par 1	Par 2	Par 3	Par 4
Média	1.358	1.521	1.421	1.660	1.087	1.330	1.341	1.219
Covariância	6.161	5.966	4.789	9.422	0.737	1.220	1.113	0.906

Tabela 3 – Média e Covariância da amostra em caixa e o 3° 100m para atenuação

Margens elétricas Atenuação	Caixa				3° 100m			
	Par 1	Par 2	Par 3	Par 4	Par 1	Par 2	Par 3	Par 4
Pares	Par 1	Par 2	Par 3	Par 4	Par 1	Par 2	Par 3	Par 4
Média	1.358	1.521	1.421	1.660	1.018	1.330	1.292	1.160
Covariância	6.161	5.966	4.789	9.422	0.623	1.149	1.024	0.832

4.1.2.1 Análise do par 1 referente ao 1° 100 metros

Primeiramente foram analisados os diferentes tipos de pré-processamento, iniciando-se pelo modelo ARX através do recurso “*Order Selection*” que no eixo horizontal exibe o número total de parâmetros, enquanto que o eixo vertical chamado “*Unexplained output variance*” (em %) é a predição do erro do modelo para um número específico de parâmetros.

$$\text{Modelo ARX} - A(q).y(q) = B(q).u(t) + .e(t)$$

Três barras estão destacadas nas cores verde, azul e vermelho, sendo que cada uma identifica o melhor resultado para um determinado critério, a saber:

- Vermelho: minimiza a soma dos quadrados da diferença entre o dado de validação de saída e a saída do modelo. Essa opção é considerada o melhor “Bestfit” global;
- Verde: minimiza o critério de Rissanen, o qual é explicado em Ljung (1999);
- Vermelho: minimiza o critério de Akaike;

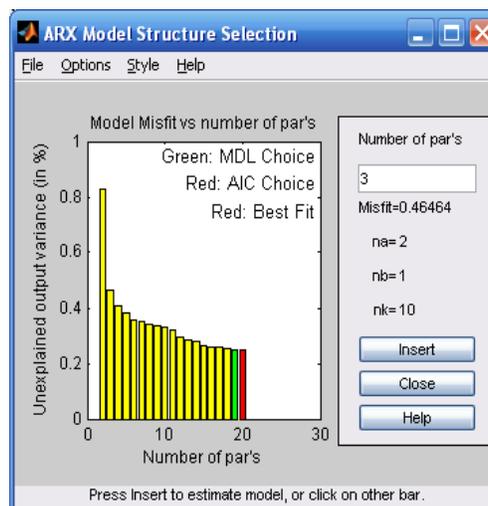


Figura 22 – Escolha de diversas ordens para o modelo ARX

Utilizando-se o critério de parcimônia, visando um modelo de ordem não muito elevada, em contrapartida que proporcionasse resultados satisfatórios, foram analisados vários modelos ARXs, com diferentes ordens para os polinômios $A(q)$ e $B(q)$, gerados a partir do mesmo dado de entrada sendo pré-processado de diferentes formas e comparados pelo critério do *Bestfit*, após 1 instante de tempo, conforme ilustrado na figura 23.

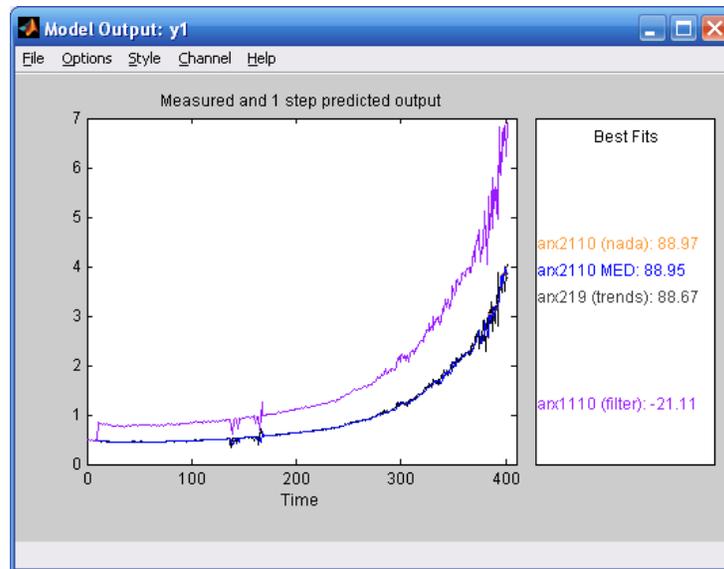


Figura 23 – Resultados do *Bestfit* de vários modelos ARXs após diferentes pré-processamentos

Assim, o melhor modelo ARX foi o sem nenhum pré-processamento de ordem $n_a=2$, $n_b=1$ e $n_k=10$.

$$\begin{aligned} \text{Modelo ARX: } A(q)y(t) &= B(q)u(t) + e(t) \\ A(q) &= 1 - 0.3409 (+0.03826) q^{-1} - 0.648 (+0.03828) q^{-2} \\ B(q) &= 0.02134 (+0.004181) q^{-10} \end{aligned}$$

FPE – Critério de Akaike: 0.00753962

Erro quadrático médio (valor absoluto): *Loss function* 0.00742764

Na seqüência, foi analisado o modelo da Variável instrumental (IV), o qual é similar ao ARX, porém o tratamento do ruído é feito de maneira diferente. O ARX assume que o ruído é branco, enquanto que IV não é sensível à cor do ruído, assim sendo uma opção interessante quando não se conhece o ruído. Igualmente feito na análise do ARX, também foi efetuado a comparação através do *Bestfit*, conforme figura 24.

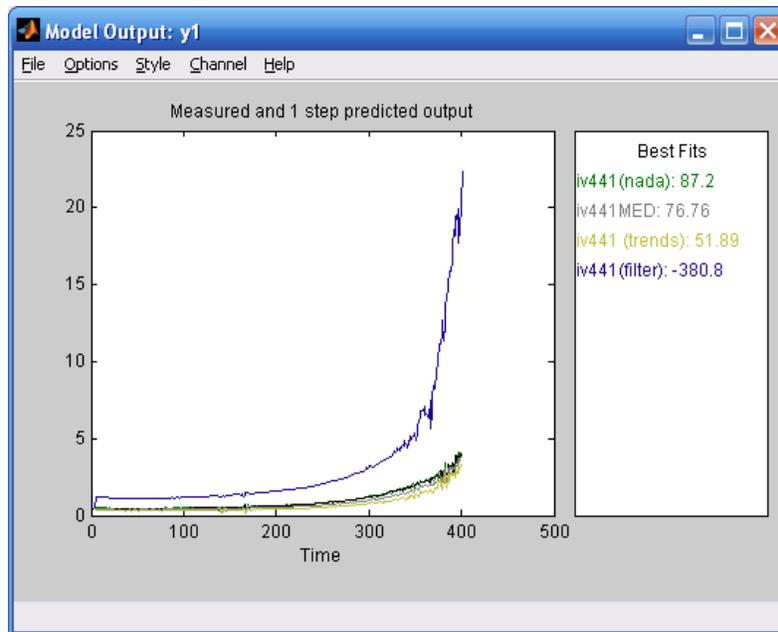


Figura 24 – Resultados do *Bestfit* de vários modelos IV após diferentes pré-processamentos.

Sendo que os melhores resultados foram obtidos quando não foi utilizado nenhum tipo de pré-processamento, a saber, IV441 ordem $n_a=4$, $n_b=4$ e $n_k=1$.

Modelo IV: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 + 0.4598 (+0.1998) q^{-1} - 0.4782 (+0.07877) q^{-2} - 0.07952 (+0.06456) q^{-3} - 0.9194 (+0.1815) q^{-4}$$

$$B(q) = 0.04034 (+0.01187) q^{-1} - 0.05127 (+0.01063) q^{-2} - 0.008267 (+0.01407) q^{-3} + 0.03931 (+0.01821) q^{-4}$$

FPE – Critério de Akaike: 0.0104037

Erro quadrático médio (valor absoluto): *Loss function* 0.0099967

Em virtude da semelhança entre o ARX e IV, o *toolbox* do Matlab trás os dois modelos juntos, e de fato os resultados simulados com ambos são muito parecidos, por exemplo, a figura 25 mostra o *Bestfit* para o modelo ARX441 (dados em amarelo) e IV441 (dados em verde). Contudo, a pequena diferença entre resultado se dá pelo tratamento do ruído em cada modelo.

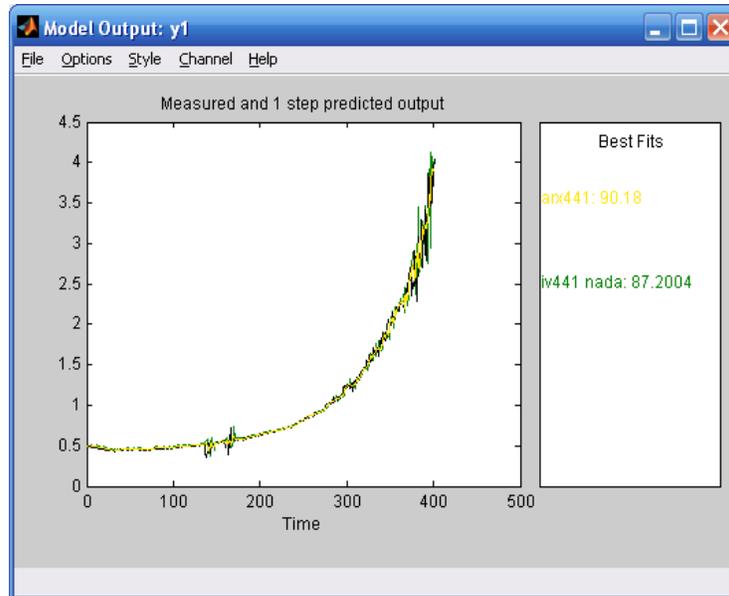


Figura 25 – Comparação entre modelos ARX441 e IV441.

Continuando, foi analisado um modelo ARMAX genérico sob diferentes tipos de pré-processamento, de acordo com o critério de *Bestfit*, conforme figura 26.

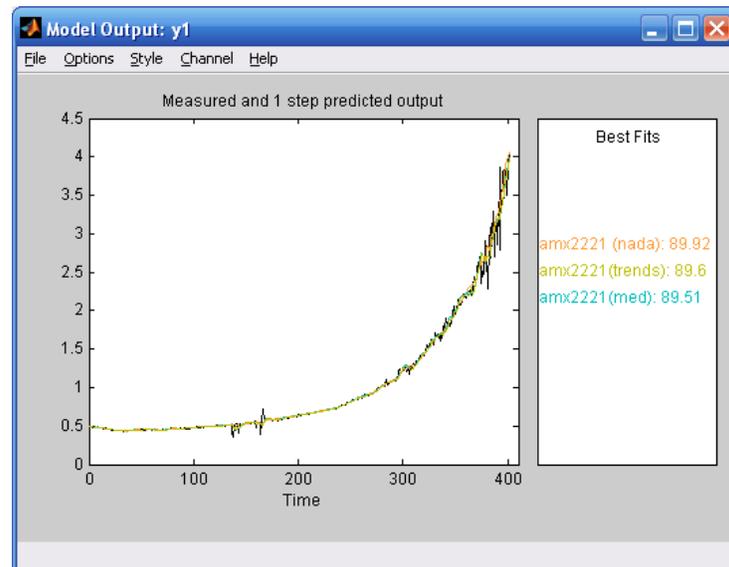


Figura 26 – Resultados do *Bestfit* de vários modelos ARMAX após diferentes pré-processamentos.

4.1.2.1.1 Comparação da análise dos resíduos para atenuação

Apesar da análise do *Bestfit* ser muito importante por dizer o nível de acertos de uma determinada predição, a análise dos resíduos do modelo também traz informações muito

importantes, uma vez que dois testes são realizados, o primeiro seria um teste de “brancheza” do sinal e o segundo um teste de independência do sinal.

Conforme mencionado anteriormente, o teste de “brancheza” assume que um bom modelo deve ter a função de autocorrelação dentro do intervalo de confiança, assim informando que os resíduos são descorrelacionados. Já o teste de independência do sinal diz que um bom modelo tem resíduos descorrelacionados com as entradas anteriores. Porém, os limites do intervalo de confiança são importantes para avaliar a qualidade do modelo, já que dependendo dos intervalos um modelo pode atender ou não este quesito. Deste modo, utilizando o critério de parcimônia, os modelos com *Bestfit* alto foram analisados pelo critério da análise dos resíduos.

a) Modelo ARX: A figura 27 exibe a análise dos resíduos para o modelo ARX441, sendo que o modelo não ficou dentro do intervalo de 99.9% no teste de autocorrelação ou bancheza, porém ficou dentro do intervalo no teste correlação cruzada ou independência do sinal.

Modelo ARX: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.01195 q^{-1} - 0.3861 q^{-2} - 0.3069 q^{-3} - 0.3004 q^{-4}$$

$$B(q) = 0.01727 q^{-1} - 0.02806 q^{-2} - 0.0006605 q^{-3} + 0.02812 q^{-4}$$

FPE – Critério de Akaike: 0.00611852

Erro quadrático médio (valor absoluto): *Loss function* 0.00587917

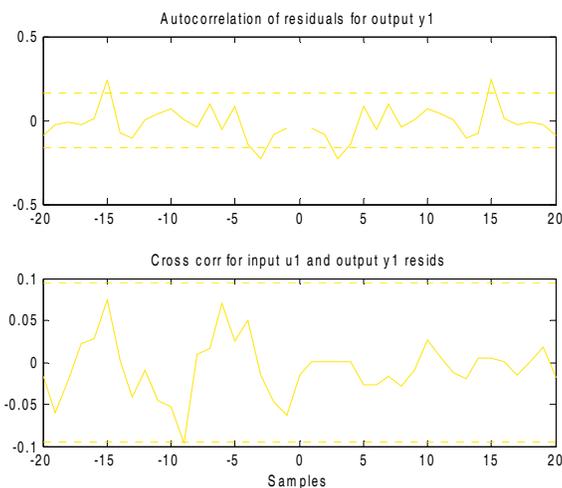


Figura 27 – Análise dos resíduos do modelo ARX441 para 1º 100 metros do par 1.

b) Modelo IV: A figura 28 exibe a análise dos resíduos para o modelo IV441, sendo que o gráfico autocorrelação ou bancheza pode ser desconsiderado, já que o algoritmo

de IV não modela os erros de medição como ruído branco. No entanto, o gráfico de correlação cruzada ou independência do sinal está praticamente dentro do intervalo de confiança de 99.9%.

Modelo IV: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 + 0.4598 (+0.1998) q^{-1} - 0.4782 (+0.07877) q^{-2} - 0.07952 (+0.06456) q^{-3} - 0.9194 (+0.1815) q^{-4}$$

$$B(q) = 0.04034 (+0.01187) q^{-1} - 0.05127 (+0.01063) q^{-2} - 0.008267 (+0.01407) q^{-3} + 0.03931 (+0.01821) q^{-4}$$

FPE – Critério de Akaike: 0.0104037

Erro quadrático médio (valor absoluto): *Loss function* 0.0099967

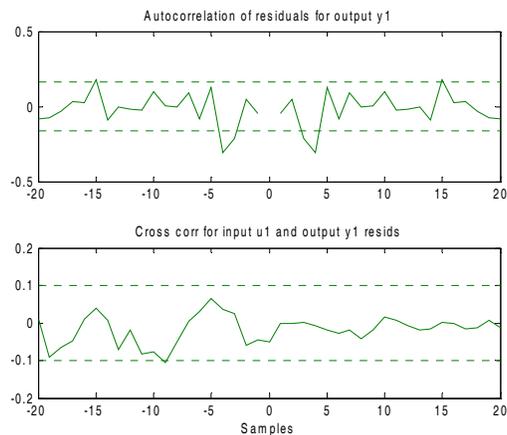


Figura 28 – Análise dos resíduos do modelo IV441 para 1º 100 metros do par 1.

c) Modelo ARMAX: A figura 29 exhibe a análise dos resíduos para o modelo ARMAX4421, sendo que o modelo não ficou dentro do intervalo de 99.9% no teste de autocorrelação ou branqueza, porém ficou dentro do intervalo no teste correlação cruzada ou independência do sinal.

Modelo ARMAX: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 + 0.3285 q^{-1} - 0.9486 q^{-2} - 0.3326 q^{-3} - 0.04792 q^{-4}$$

$$B(q) = 0.02234 q^{-1} - 0.02828 q^{-2} - 0.01938 q^{-3} + 0.04577 q^{-4}$$

$$C(q) = 1 + 0.4555 q^{-1} - 0.5551 q^{-2}$$

FPE – Critério de Akaike: 0.00613759

Erro quadrático médio (valor absoluto): *Loss function* 0.00583599

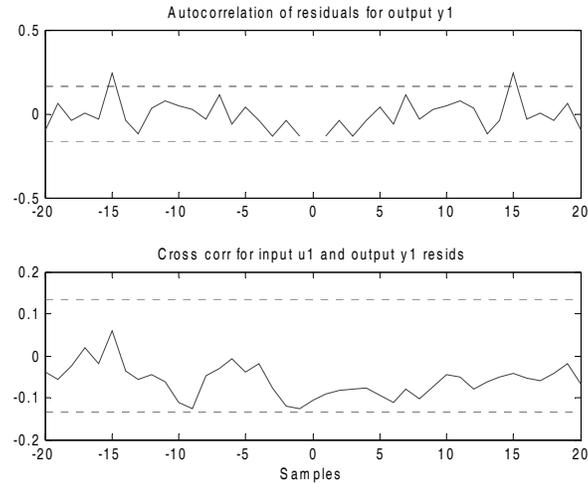


Figura 29 – Análise dos resíduos do modelo ARMAX4421 para 1º 100 metros do par 1.

4.1.2.1.2 Comparação dos modelos

Comparativamente todos os modelos analisados (ARX441, IV441 e ARMAX 4421) não atenderam o intervalo de confiança de 99.9% no teste de branqueza, uma vez que o sinal de saída realmente não é um ruído branco. Porém, atenderam o teste de correlação cruzada no intervalo 99.9%. Os acertos dos *Bestfits* estão na figura 30.

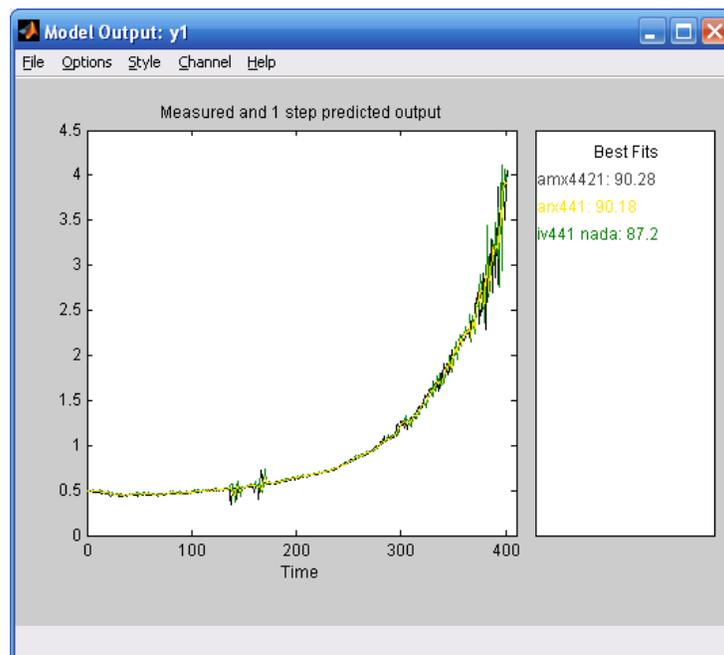


Figura 30 – Resultados comparativo do *Bestfit* dos modelos ARX 441, IV441 e ARMAX4421.

4.1.2.2 Análises do par 1 referente ao 2º 100 metros

Analogamente ao realizado para os 1º 100 metros do par 1, o mesmo foi realizado para o 2º e 3º 100 metros.

Os modelos obtidos foram:

a) Modelo ARX441:

Modelo ARX: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.5042 q^{-1} - 0.1245 q^{-2} - 0.2441 q^{-3} - 0.1401 q^{-4}$$

$$B(q) = -0.01147 q^{-1} + 0.02777 q^{-2} + 0.0145 q^{-3} - 0.02627 q^{-4}$$

FPE – Critério de Akaike: 0.00193651

Erro quadrático médio (valor absoluto): *Loss function* 0.00186075

b) IV441:

Modelo IV: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 + 0.07643 q^{-1} - 0.3368 q^{-2} - 0.4397 q^{-3} - 0.3201 q^{-4}$$

$$B(q) = -0.01465 q^{-1} + 0.01813 q^{-2} + 0.02462 q^{-3} - 0.02016 q^{-4}$$

FPE – Critério de Akaike: 0.00269589

Erro quadrático médio (valor absoluto): *Loss function* 0.00259042

c) ARMAX4421:

Modelo: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 0.2055 q^{-1} - 0.7978 q^{-2} - 0.03227 q^{-3} + 0.02936 q^{-4}$$

$$B(q) = -0.02276 q^{-1} + 0.01663 q^{-2} + 0.03312 q^{-3} - 0.02048 q^{-4}$$

$$C(q) = 1 + 0.326 q^{-1} - 0.5857 q^{-2}$$

FPE – Critério de Akaike: 0.00177724

Erro quadrático médio (valor absoluto): *Loss function* 0.0016899

Para comparação, também foi simulado o modelo ARMAX4321 que possui a correlação cruzada dentro dos limites.

d) ARMAX4321:

Modelo: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 0.191 q^{-1} - 0.6624 q^{-2} - 0.0924 q^{-3} - 0.06661 q^{-4}$$

$$B(q) = -0.01214 q^{-1} - 0.0005786 q^{-2} + 0.01944 q^{-3}$$

$$C(q) = 1 + 0.2864 q^{-1} - 0.6398 q^{-2}$$

FPE – Critério de Akaike: 0.00176194

Erro quadrático médio (valor absoluto): *Loss function* 0.00168382

As figuras 31, 32 e 33 exibem as análises de correlações para os modelos ARX441, IV441, ARMAX4321, ARMAX4421 para o 2º 100 metros.

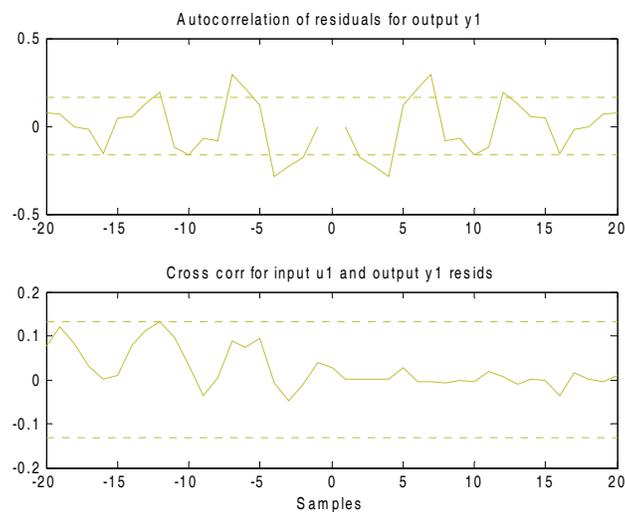


Figura 31 – Análise dos resíduos do modelo ARX441 para 2º 100 metros do par 1.

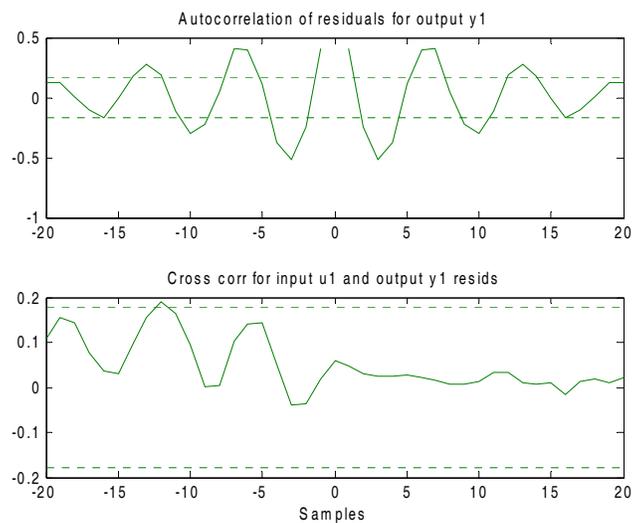


Figura 32 – Análise dos resíduos do modelo IV441 para 2º 100 metros do par 1.

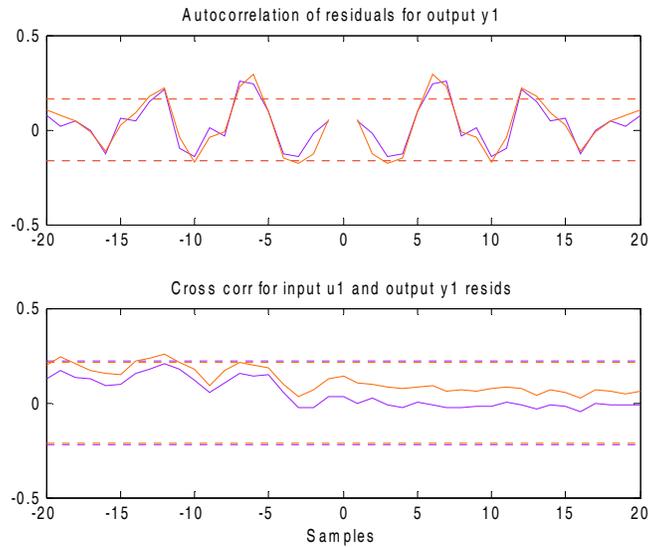


Figura 33 – Análise dos resíduos do modelo ARMAX4421(laranja) e ARMAX4321(rox) para 2º 100 metros do par 1.

A figura 34 exhibe a comparação dos modelos e seus respectivos *Bestfits*.

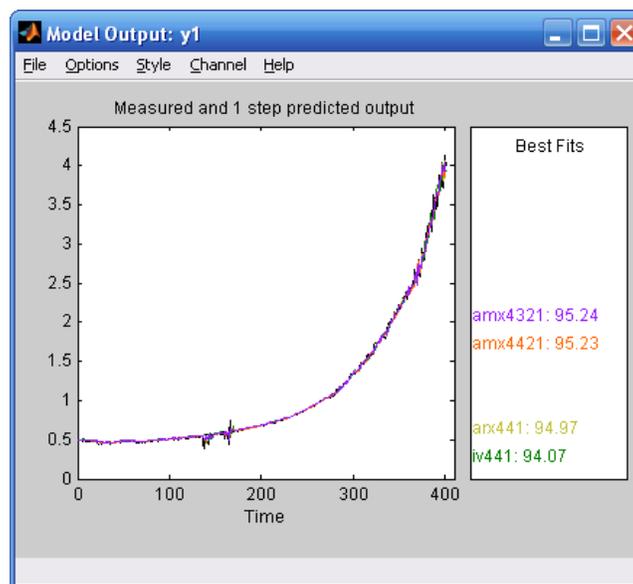


Figura 34 – Resultados comparativo do *Bestfit* dos modelos ARX 441, IV441, ARMAX4421 e ARMAX4321.

4.1.2.3 Análises do par 1 referente ao 3º 100 metros

Analogamente ao realizado para os 1º e 2º 100 metros do par 1, foram obtidos vários modelos. O melhor modelo ARX dentro dos intervalos de 99.9% na análise dos resíduos

foi o ARX10102, porém igualmente nas demais medições o modelo ARX441 também gerou resultados satisfatórios.

a) Modelo ARX441:

Modelo ARX: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.3035 q^{-1} - 0.2897 q^{-2} - 0.2023 q^{-3} - 0.2247 q^{-4}$$

$$B(q) = 0.02756 q^{-1} + 0.02589 q^{-2} - 0.02246 q^{-3} - 0.03326 q^{-4}$$

FPE – Critério de Akaike: 0.00373906

Erro quadrático médio (valor absoluto): *Loss function* 0.00359279

b) Modelo ARX10102:

Modelo ARX: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.2561 q^{-1} - 0.3045 q^{-2} - 0.05616 q^{-3} - 0.1918 q^{-4} + 0.0869 q^{-5} + 0.04373 q^{-6} - 0.08649 q^{-7} + 0.08478 q^{-8} - 0.2916 q^{-9} - 0.07088 q^{-10}$$

$$B(q) = 0.02882 q^{-2} - 0.01007 q^{-3} - 0.0329 q^{-4} + 0.00993 q^{-5} - 0.007828 q^{-6} + 0.005043 q^{-7} + 0.06818 q^{-8} + 0.01361 q^{-9} - 0.02539 q^{-10} - 0.05853 q^{-11}$$

FPE – Critério de Akaike: 0.0028878

Erro quadrático médio (valor absoluto): *Loss function* 0.00261342

c) IV441:

Modelo IV: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.3463 q^{-1} + 0.1318 q^{-2} - 0.8183 q^{-3} + 0.0112 q^{-4}$$

$$B(q) = 0.02951 q^{-1} + 0.02868 q^{-2} - 0.02799 q^{-3} - 0.03266 q^{-4}$$

FPE – Critério de Akaike: 0.00539604

Erro quadrático médio (valor absoluto): *Loss function* 0.00518495

Diferentemente das demais medições, os modelos ARMAX4421 e ARMAX4321 geraram resultados satisfatórios, mas baseados na análise dos resíduos desta vez estes modelos não ficaram dentro do intervalo de confiança.

d) ARMAX4421:

Modelo: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 0.5947 q^{-1} - 0.5019 q^{-2} + 0.1198 q^{-3} - 0.03308 q^{-4}$$

$$B(q) = 0.02596 q^{-1} + 0.01505 q^{-2} - 0.02066 q^{-3} - 0.0229 q^{-4}$$

$$C(q) = 1 - 0.2309 q^{-1} - 0.1088 q^{-2}$$

FPE – Critério de Akaike: 0.00416547

Erro quadrático médio (valor absoluto): *Loss function* 0.00396078

e) ARMAX4321:

Modelo: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 1.117 q^{-1} + 0.01269 q^{-2} + 0.3042 q^{-3} - 0.2096 q^{-4}$$

$$B(q) = 0.0299 q^{-1} - 0.001899 q^{-2} - 0.03098 q^{-3}$$

$$C(q) = 1 - 0.7819 q^{-1} + 0.1549 q^{-2}$$

FPE – Critério de Akaike: 0.0040474

Erro quadrático médio (valor absoluto): *Loss function* 0.00386796

f) ARMAX2221:

Modelo: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 1.404 q^{-1} + 0.3982 q^{-2}$$

$$B(q) = 0.03144 q^{-1} - 0.03215 q^{-2}$$

$$C(q) = 1 - 1.168 q^{-1} + 0.2927 q^{-2}$$

FPE – Critério de Akaike: 0.00374373

Erro quadrático médio (valor absoluto): *Loss function* 0.00363281

As figuras 35, 36 e 37 exibem as análises de correlações para os modelos ARX441, ARX10102, IV441, ARMAX4321, ARMAX4421, ARMAX2221 para o 3º 100 metros.

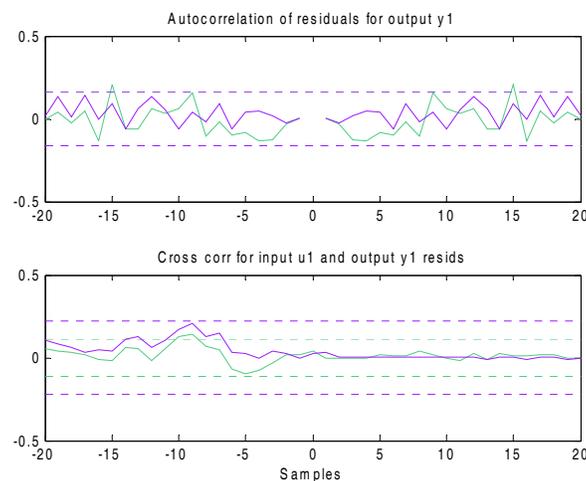


Figura 35 – Análise dos resíduos do modelo ARX441(verde) e ARX10102(rox) para 3º 100 metros do par 1.

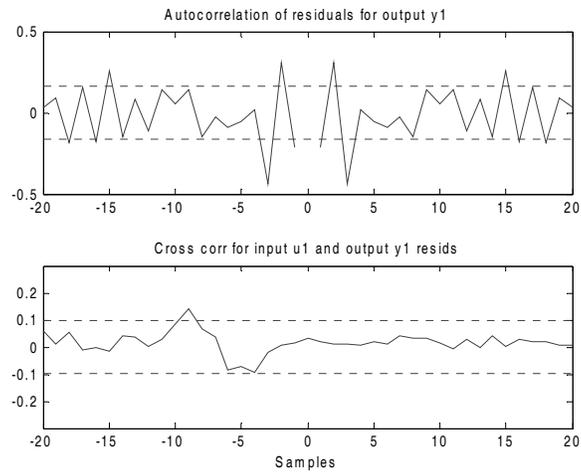


Figura 36 – Análise dos resíduos do modelo IV441 para 3° 100 metros do par 1.

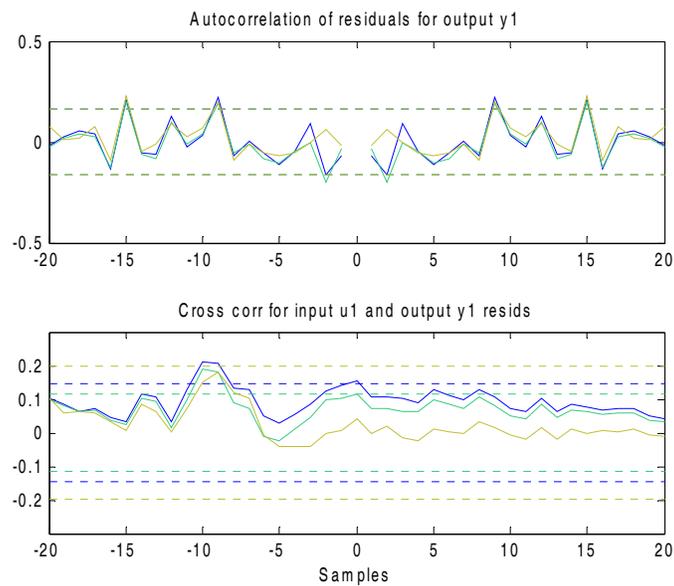


Figura 37 – Análise dos resíduos do modelo ARMAX4421(verde), ARMAX4321(azul) e ARMAX2221(bege) para 3° 100 metros do par 1.

A figura 38 exibe a comparação dos modelos e os respectivos *Bestfits*.

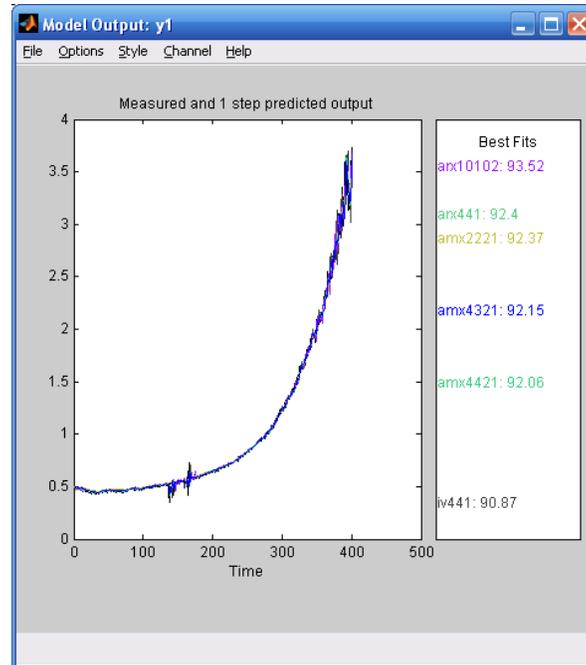


Figura 38 – Resultados comparativo do *Bestfit* dos modelos ARX 441, IV441, ARMAX4421 e ARMAX4321.

4.1.2.4 Validações dos modelos polinomiais para atenuação

Para realizar as validações dos modelos foram realizadas novas medições de uma nova caixa aleatória com 305m, de modo que estes resultados serviram de dados de entrada para o modelo previamente definido gerar as respectivas saídas. Na seqüência, foram testados os respectivos 100 metros desta nova caixa, e efetuado a comparação das respostas reais com a que o modelo gerou.

Foi analisado o melhor modelo ARX441, no caso o obtido para os 1º 100 metros e utilizado o mesmo para validar o restante. Sendo que apresentou um *Bestfit* de 90.18 durante a fase de treinamento.

Modelo ARX: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.01195 q^{-1} - 0.3861 q^{-2} - 0.3069 q^{-3} - 0.3004 q^{-4}$$

$$B(q) = 0.01727 q^{-1} - 0.02806 q^{-2} - 0.0006605 q^{-3} + 0.02812 q^{-4}$$

As figuras 39, 40 e 41 exibem os comportamentos do modelo ARX441 e dos valores reais, referentes ao *Bestfit* e ao erro da modelagem.

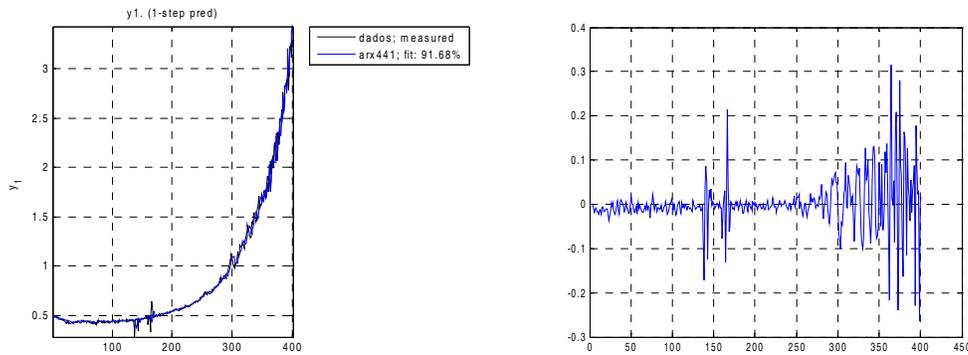


Figura 39 – Resultados do *Bestfit* e do erro do modelo ARX 441 para 1º 100 do par 1 de uma nova caixa.

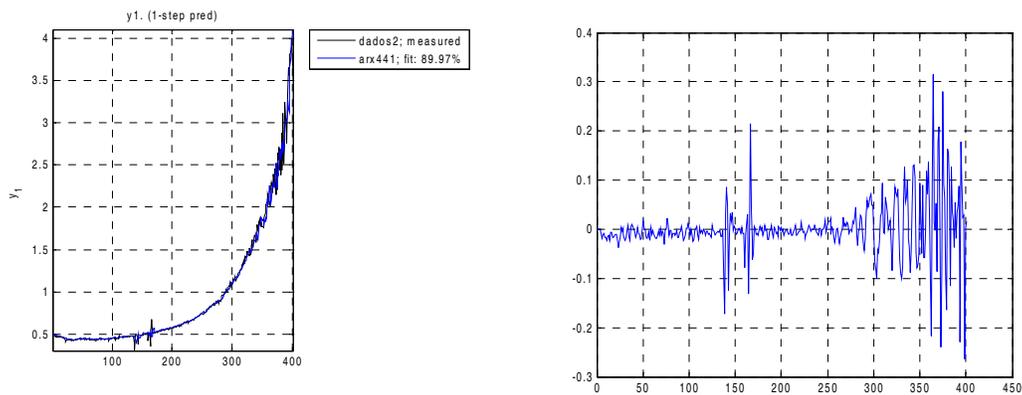


Figura 40 – Resultados do *Bestfit* e do erro do modelo ARX 441 para 2º 100 do par 1 de uma nova caixa.

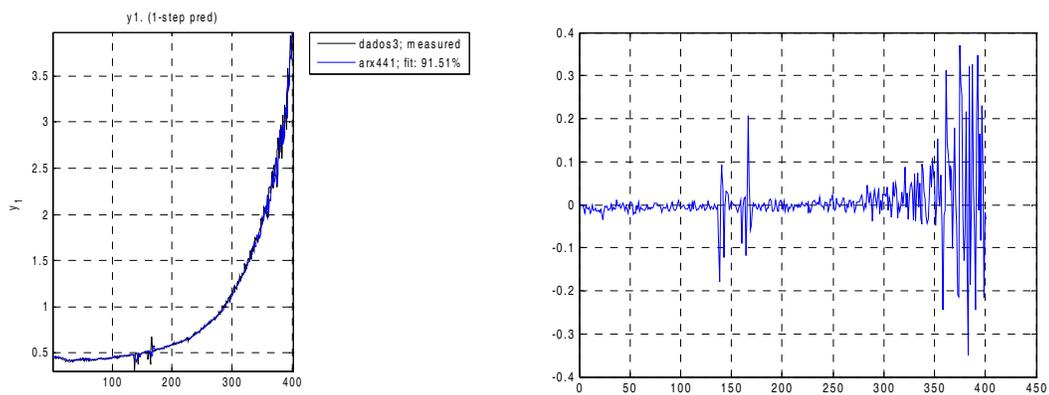


Figura 41 – Resultados do *Bestfit* e do erro do modelo ARX 441 para 3º 100 do par 1 de uma nova caixa.

Analogamente ao realizado para os modelos ARX441, foram analisadas as respostas geradas pelo modelo IV abaixo, o qual foi analisado anteriormente e apresentou um *Bestfit* de 87.2.

Modelo IV: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 + 0.4598 (+0.1998) q^{-1} - 0.4782 (+0.07877) q^{-2} - 0.07952 (+0.06456) q^{-3} - 0.9194 (+0.1815) q^{-4}$$

$$B(q) = 0.04034 (+0.01187) q^{-1} - 0.05127 (+0.01063) q^{-2} - 0.008267 (+0.01407) q^{-3} + 0.03931 (+0.01821) q^{-4}$$

As figuras 42, 43, 44 exibem os comportamentos do modelo IV441 e dos valores reais, referentes ao *Bestfit* e ao erro da modelagem.

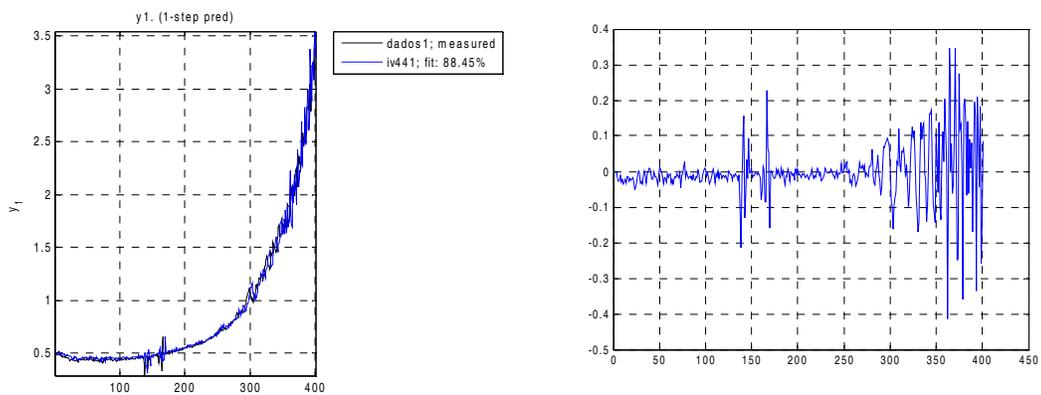


Figura 42 – Resultados do *Bestfit* e do erro do modelo IV 441 para 1º 100 do par 1 de uma nova caixa.

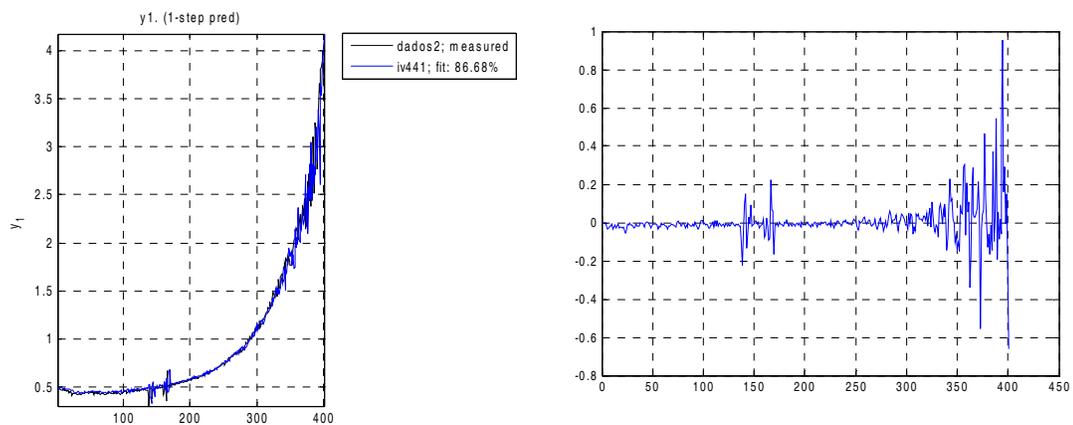


Figura 43 – Resultados do *Bestfit* e do erro do modelo IV 441 para 2º 100 do par 1 de uma nova caixa.

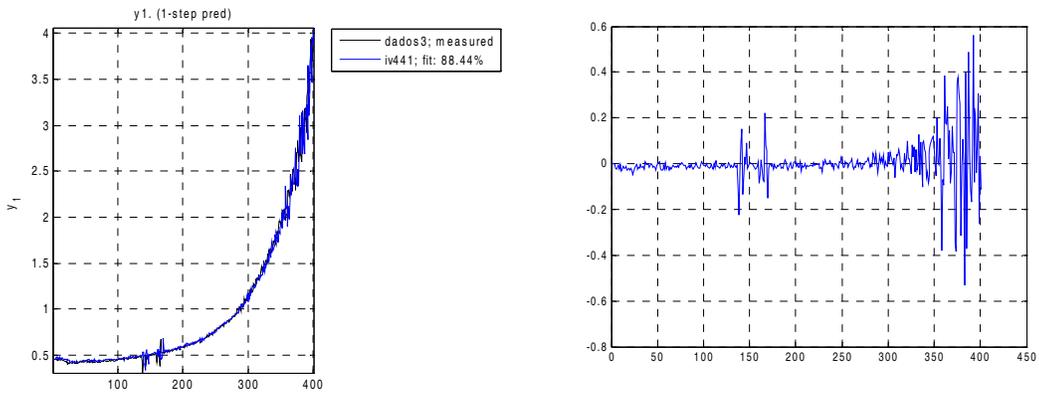


Figura 44 – Resultados do *Bestfit* e do erro do modelo IV 441 para 3º 100 do par 1 de uma nova caixa.

Analogamente ao realizado para os modelos ARX441 e IV441, foram analisadas as respostas geradas pelo modelo ARMAX 4421 abaixo, o qual foi analisado anteriormente e apresentou um *Bestfit* de 90.28.

Modelo ARMAX: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 + 0.3285 q^{-1} - 0.9486 q^{-2} - 0.3326 q^{-3} - 0.04792 q^{-4}$$

$$B(q) = 0.02234 q^{-1} - 0.02828 q^{-2} - 0.01938 q^{-3} + 0.04577 q^{-4}$$

$$C(q) = 1 + 0.4555 q^{-1} - 0.5551 q^{-2}$$

As figuras 45, 46, 47 exibem os comportamentos do modelo ARMAX4421 e dos valores reais, referentes ao *Bestfit* e ao erro da modelagem.

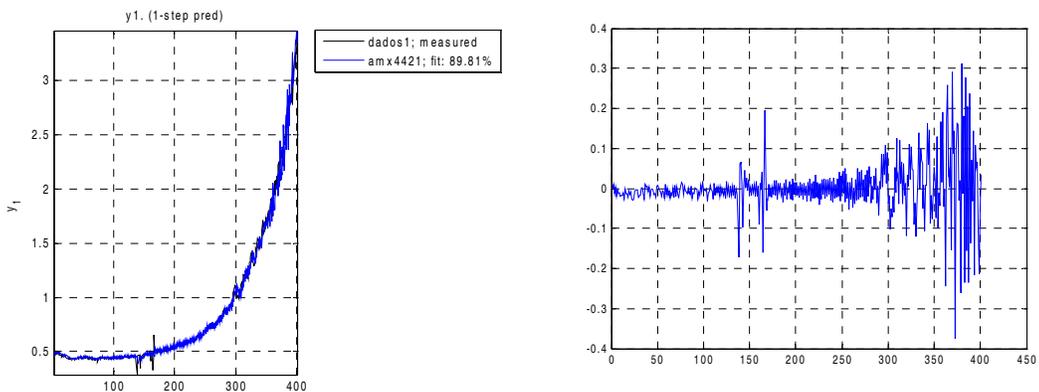


Figura 45 – Resultados do *Bestfit* e do erro dos modelos ARMAX 4421 para 1º 100 do par 1 de uma nova caixa.

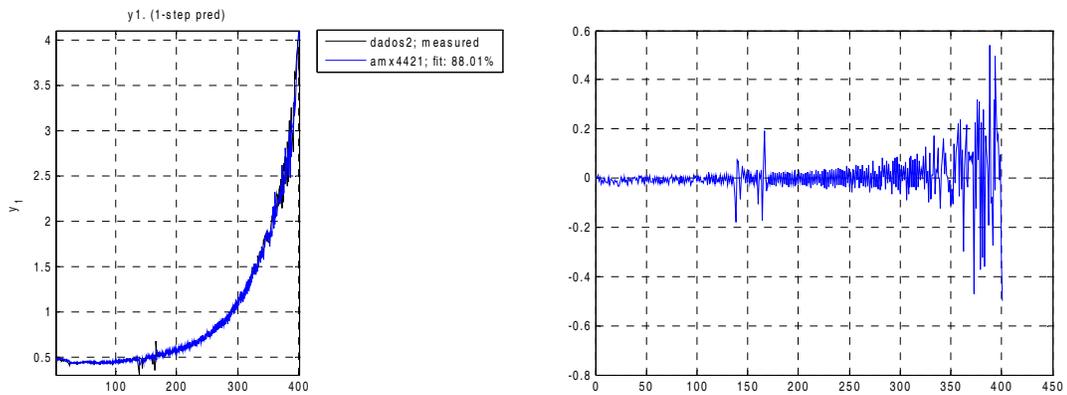


Figura 46 – Resultados do *Bestfit* e do erro do modelo ARMAX 4421 para 2º 100 do par 1 de uma nova caixa.

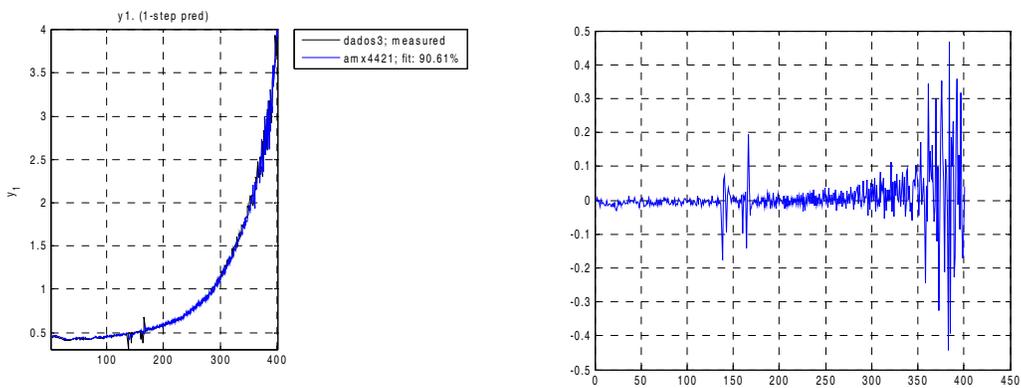


Figura 47 – Resultados do *Bestfit* e do erro do modelo ARMAX 4421 para 3º 100 do par 1 de uma nova caixa.

4.1.2.4.1 Erros dos modelos polinomiais para atenuação

Para efeito de comparação entre os 100 metros, a tabela 04 exibe os *Bestfits* obtidos em cada modelo para cada 100 metros, ou seja, utilizando um mesmo modelo para todos os testes de 100 metros. Pode-se concluir que um mesmo modelo apresenta valores similares de *Bestfit* para todas as amostras de 100 metros.

Tabela 4 – Comparativo dos *Bestfits* entre os 100 metros

Validação Atenuação: <i>Bestfit</i> dos modelos						
Modelos	ARX441		IV441		ARMAX4421	
Amostras	Caixa Original	Caixa Nova	Caixa Original	Caixa Nova	Caixa Original	Caixa Nova
1° 100 metros	90.18	91.68	87.2	88.45	90.28	89.91
2° 100 metros	94.97	89.97	94.07	86.68	95.23	88.01
3° 100 metros	92.4	91.51	90.87	88.44	92.06	90.61

4.1.3 Análise do parâmetro de ACRF com modelos polinomiais

O anexo II exibe os gráficos das margens em ACRF para a combinação 1x2, bem como os gráficos de covariância entre os valores dos cabos medidos em caixa e esticados e por fim os respectivos periodogramas. As tabelas 05, 06 e 07 exibem os valores das médias e covariâncias das 6 combinações, ao longo das amostras em caixa e esticadas.

Tabela 5 – Média e Covariância da amostra em caixa e o 1° 100m para ACRF

Margens elétricas de ACRF	Caixa						1° 100m					
	1x2	1x3	1x4	2x3	2x4	3x4	1x2	1x3	1x4	2x3	2x4	3x4
Média	15.04	1.57	12.00	14.51	3.40	9.62	26.42	19.86	26.10	23.72	17.37	22.59
Covariância	128.5	131.6	182.4	131.8	64.8	92.2	35.5	24.3	38.2	36.8	22.6	45.1

Tabela 6 – Média e Covariância da amostra em caixa e o 2° 100m para ACRF

Margens elétricas de ACRF	Caixa						2° 100m					
	1x2	1x3	1x4	2x3	2x4	3x4	1x2	1x3	1x4	2x3	2x4	3x4
Média	15.04	1.57	12.00	14.51	3.40	9.62	27.62	25.06	22.99	21.27	14.21	22.80
Covariância	128.5	131.6	182.4	131.8	64.8	92.2	38.0	61.3	24.7	29.5	9.4	34.2

Tabela 7 – Média e Covariância da amostra em caixa e o 3° 100m para ACRF

Margens elétricas de ACRF	Caixa						3° 100m					
	1x2	1x3	1x4	2x3	2x4	3x4	1x2	1x3	1x4	2x3	2x4	3x4
Média	15.04	1.57	12.00	14.51	3.40	9.62	25.09	23.65	31.28	23.53	11.94	21.71
Covariância	128.5	131.6	182.4	131.8	64.8	92.2	42.6	27.9	37.5	32.1	5.7	12.5

4.1.3.1 Análise da combinação 1x2 referente ao 1° 100 metros

Esta sessão exibe os melhores resultados com cada tipo de modelo considerando os 1° 100 metros da caixa.

Modelo ARX:

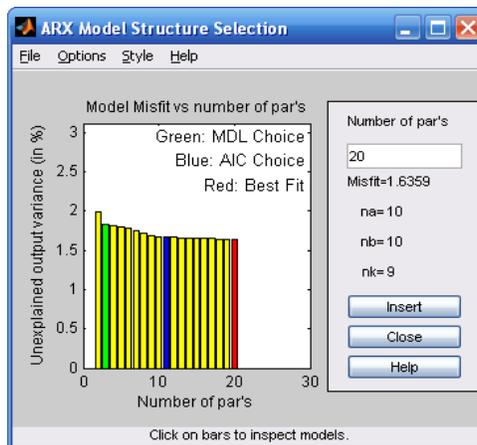


Figura 48 – Simulação do modelo ARX para diversas ordens

Os melhores resultados obtidos, utilizando-se o critério de parcimônia, foram sem nenhum tipo de pré-processamento:

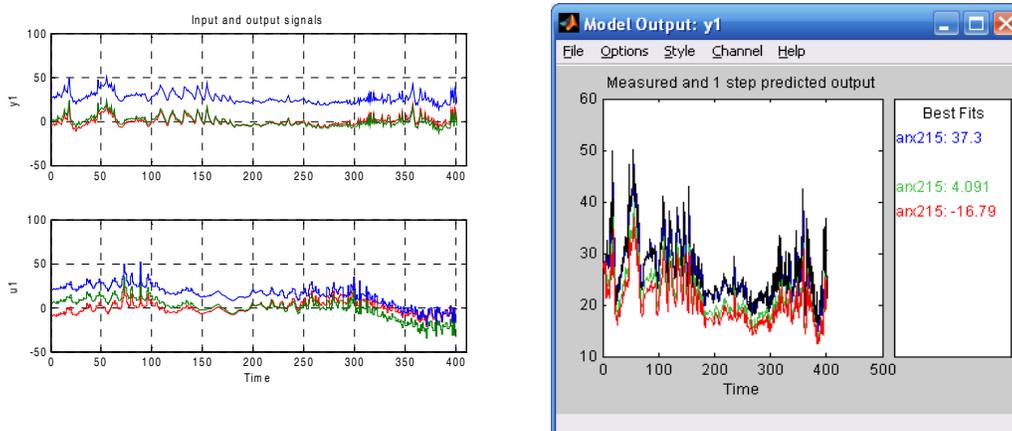


Figura 49 – Sinais de entrada e Modelos obtidos.

Sinal puro (em azul), sinal com média removida (em verde) e sinal filtrado (em vermelho).

Modelo ARX: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.644 q^{-1} - 0.3226 q^{-2}$$

$$B(q) = 0.04418 q^{-5}$$

FPE – Critério de Akaike: 14.1378

Erro quadrático médio (valor absoluto): *Loss function* 13.9278

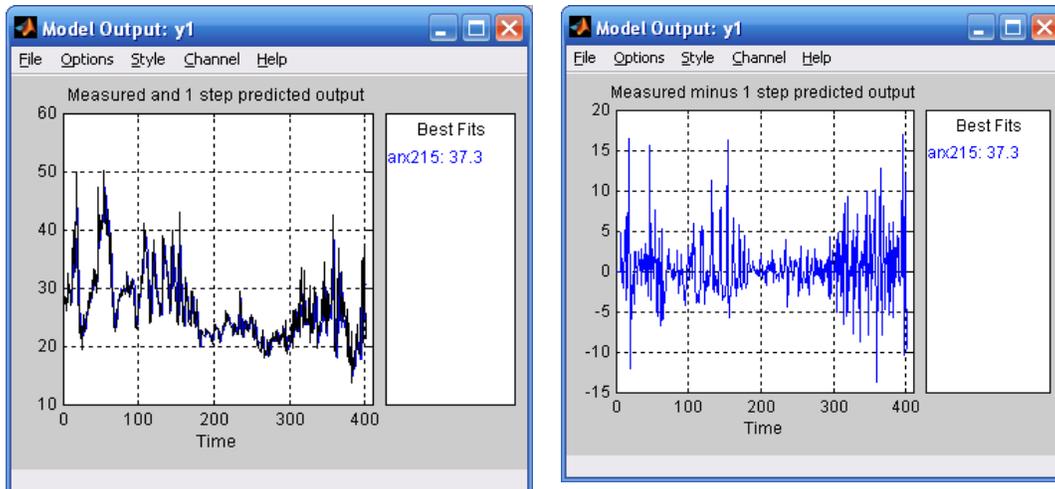


Figura 50 – Resultados do *Bestfit* e do erro do modelo ARX215 para 1º 100m de ACRF combinação 1x2

a) Modelo ARMAX:

Modelo ARMAX: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 1.801 q^{-1} + 0.8018 q^{-2}$$

$$B(q) = -0.01886 q^{-1} + 0.01932 q^{-2}$$

$$C(q) = 1 - 1.163 q^{-1} + 0.1676 q^{-2}$$

FPE – Critério de Akaike: 13.7848

Erro quadrático médio (valor absoluto): *Loss function* 13.3764

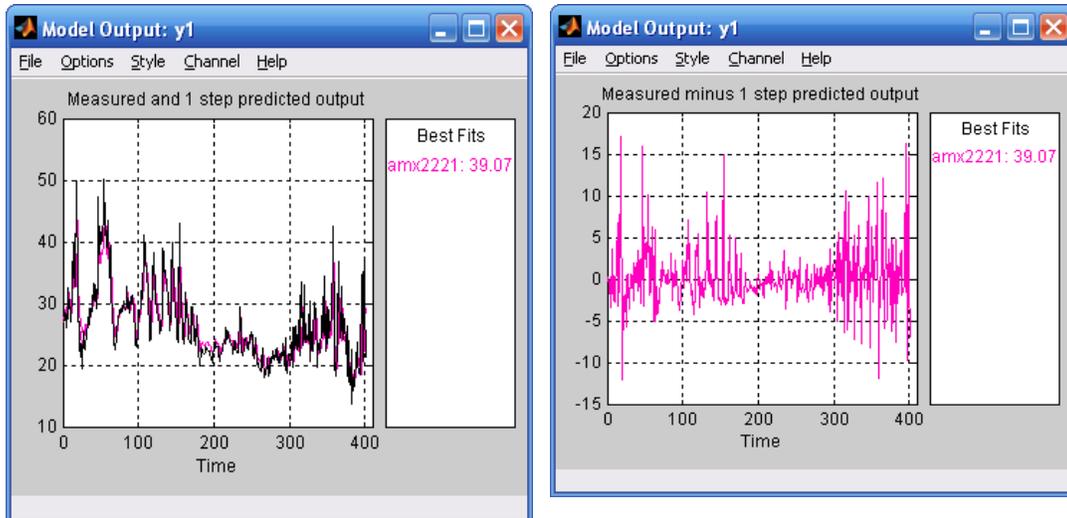


Figura 51 – Resultados do *Bestfit* e do erro do modelo ARMAX2221 para 1º 100m de ACRF combinação 1x2

b) Modelo IV:

Modelo IV: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 + 0.5503 q^{-1} - 0.3794 q^{-2} - 0.8266 q^{-3} - 0.3361 q^{-4}$$

$$B(q) = -0.009364 q^{-1} + 0.01366 q^{-2} + 0.06827 q^{-3} - 0.05768 q^{-4}$$

FPE – Critério de Akaike: 39.8696

Erro quadrático médio (valor absoluto): *Loss function* 38.3099

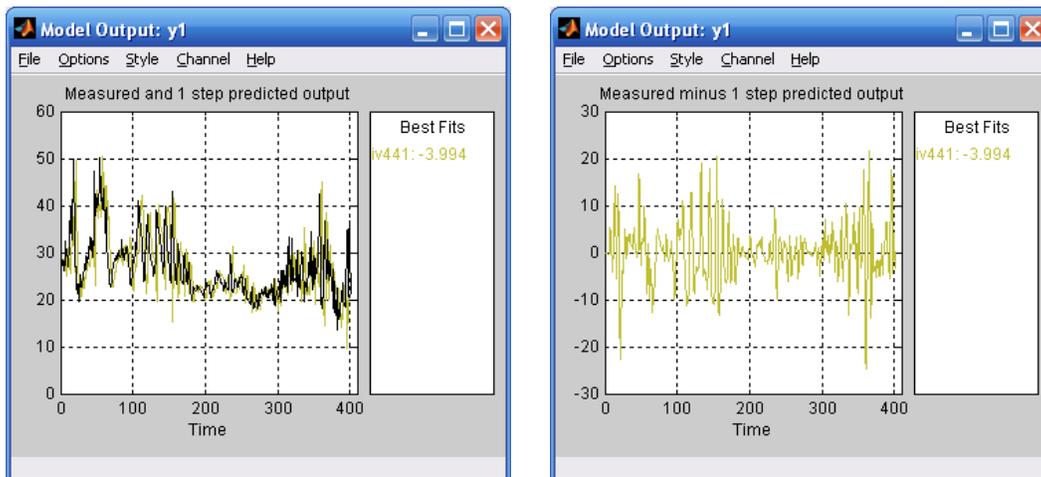


Figura 52 – Resultados do *Bestfit* e do erro do modelo IV441 para 1º 100m de ACRF combinação 1x2

4.1.3.2 Análise da combinação 1x2 referente ao 2º 100 metros

a) Modelo ARX:

Modelo ARX213: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.5338 q^{-1} - 0.4249 q^{-2}$$

$$B(q) = 0.05746 q^{-3}$$

FPE – Critério de Akaike: 20.6724

Erro quadrático médio (valor absoluto): *Loss function* 20.3654

Modelo ARX215: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.5417 q^{-1} - 0.4228 q^{-2}$$

$$B(q) = 0.04613 q^{-5}$$

FPE – Critério de Akaike: 20.7636

Erro quadrático médio (valor absoluto): *Loss function* 20.4552

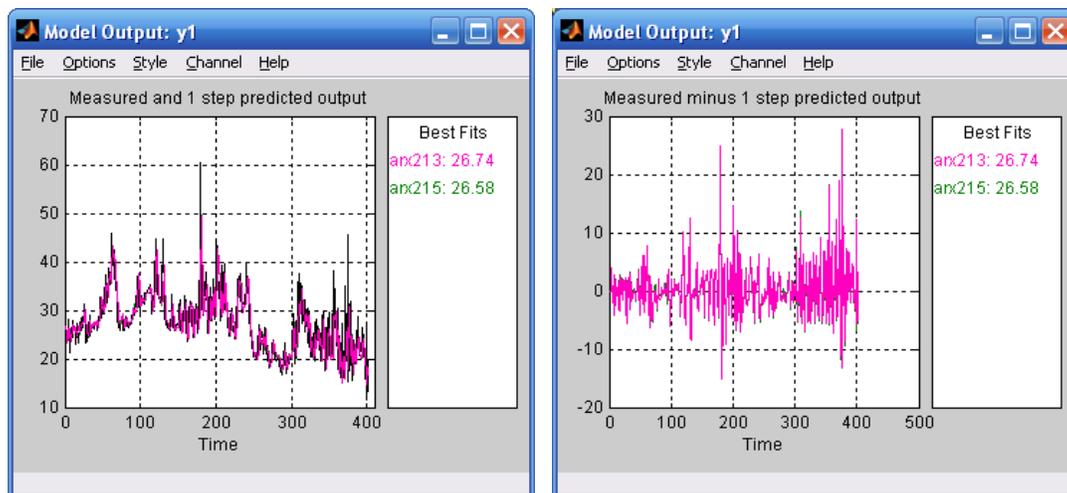


Figura 53 - Resultados do *Bestfit* e do erro dos modelos ARX213 e ARX215 para 2º 100m de ACRF combinação 1x2

b) Modelo ARMAX:

Modelo ARMAX: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 0.09832 q^{-1} - 0.8666 q^{-2}$$

$$B(q) = 0.09463 q^{-1} - 0.05088 q^{-2}$$

$$C(q) = 1 + 0.2707 q^{-1} - 0.5281 q^{-2}$$

FPE – Critério de Akaike: 19.1655

Erro quadrático médio (valor absoluto): *Loss function* 18.5977.

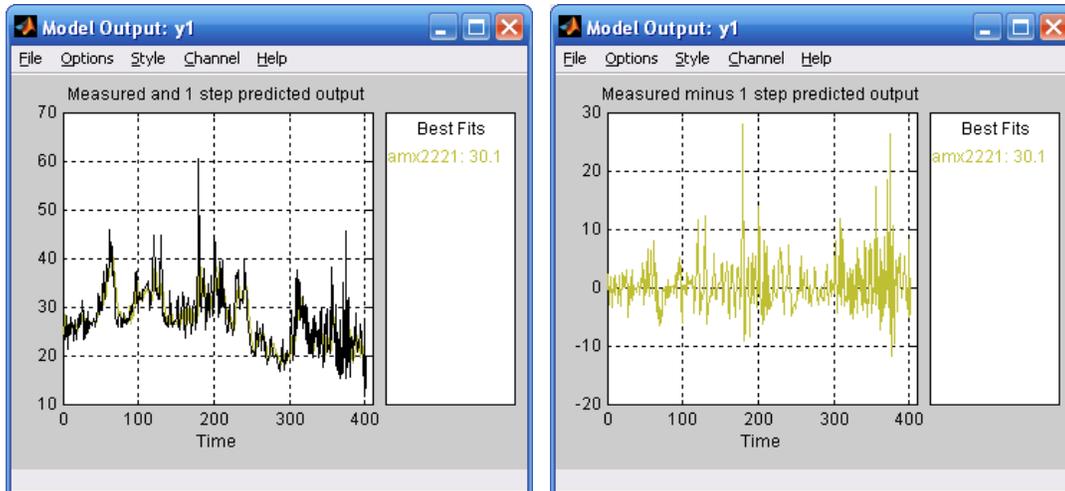


Figura 54 – Resultados do *Bestfit* e do erro do modelo ARMAX2221 para 2º 100m de ACRF combinação 1x2

- c) Modelo IV: em virtude dos insatisfatórios resultados obtidos com o IV durante a análise dos 1º 100m, a análise deste método para os demais 100 metros foi abandonada.

4.1.3.3 Análise da combinação 1x2 referente ao 3º 100 metros

- a) Modelo ARX:

Modelo ARX: $A(q)y(t) = B(q)u(t) + e(t)$

$$A(q) = 1 - 0.6554 q^{-1} - 0.3376 q^{-2}$$

$$B(q) = 0.007089 q^{-5}$$

FPE – Critério de Akaike: 8.0339

Erro quadrático médio (valor absoluto): *Loss function* 7.91458

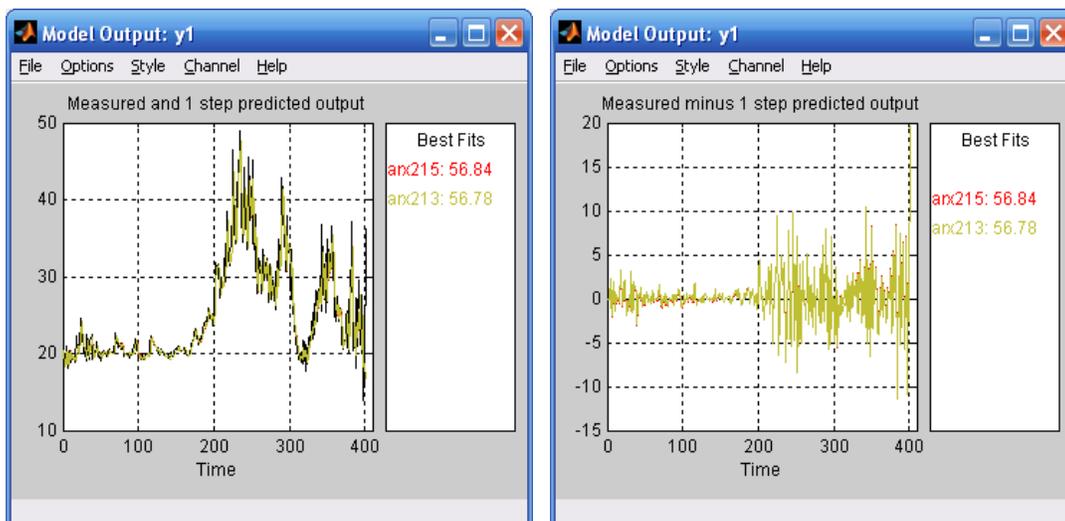


Figura 55 - Resultados do *Bestfit* e do erro dos modelos ARX213 e ARX215 para 3º 100m de ACRF combinação 1x2

b) Modelo ARMAX:

Modelo ARMAX: $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 1.272 q^{-1} + 0.277 q^{-2}$$

$$B(q) = -0.02384 q^{-1} + 0.02778 q^{-2}$$

$$C(q) = 1 - 0.6838 q^{-1} + 0.03243 q^{-2}$$

FPE – Critério de Akaike: 7.73523

Erro quadrático médio (valor absoluto): *Loss function* 7.50603

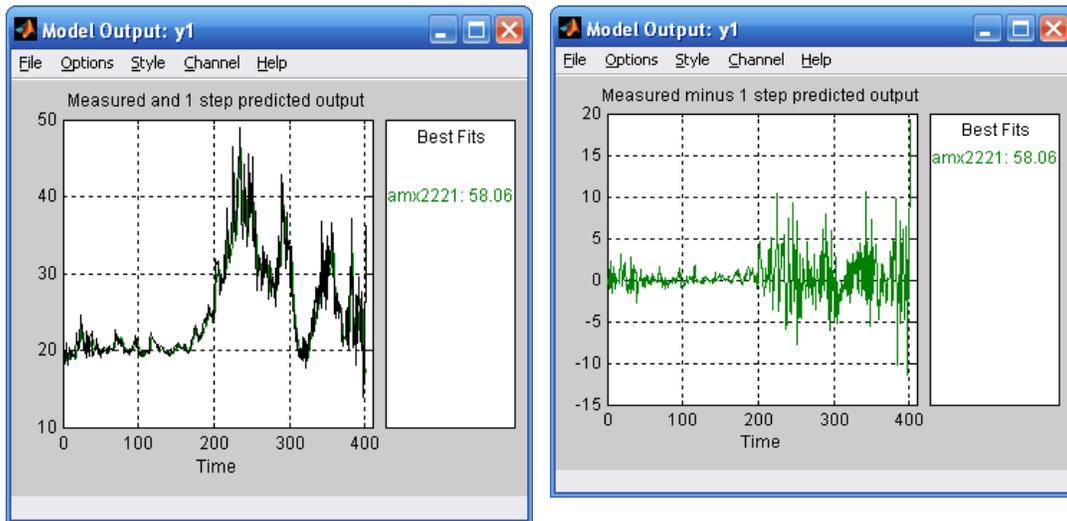


Figura 56 – Resultados do *Bestfit* e do erro do modelo ARMAX2221 para 3º 100m de ACRF combinação 1x2

4.1.3.4 Análise dos resíduos dos modelos para ACRF

Os resíduos das medições de ACRF são mais parecidos com um sinal ruído branco do que os resultantes das medições de atenuação. Deste modo, os modelos se mostraram dentro do intervalo de 99% em todos os casos.

☑ Modelos do 1º 100m:

a) ARX215:

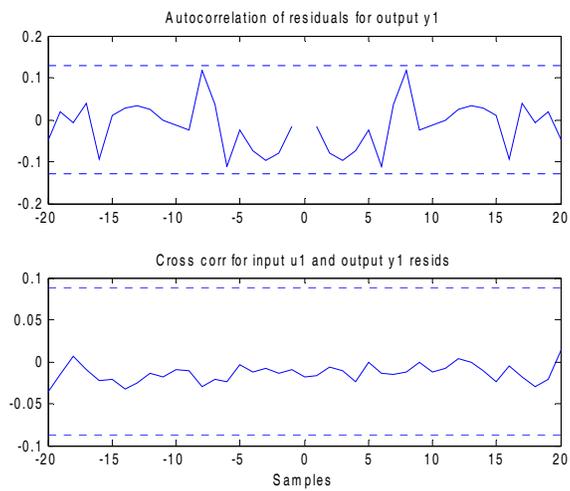


Figura 57 – Análise dos resíduos do modelo ARX215 para 1º 100 metros da combinação 1x2 com intervalo de confiança de 99%.

b) ARMAX2221:

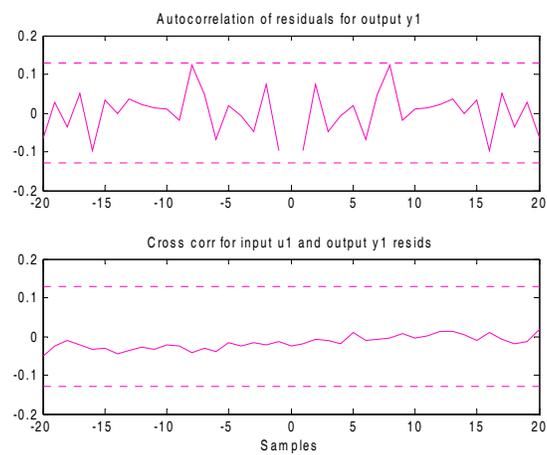


Figura 58 – Análise dos resíduos do modelo ARMAX2221 para 1º 100 metros da combinação 1x2 com intervalo de confiança de 99%.

c) IV441:

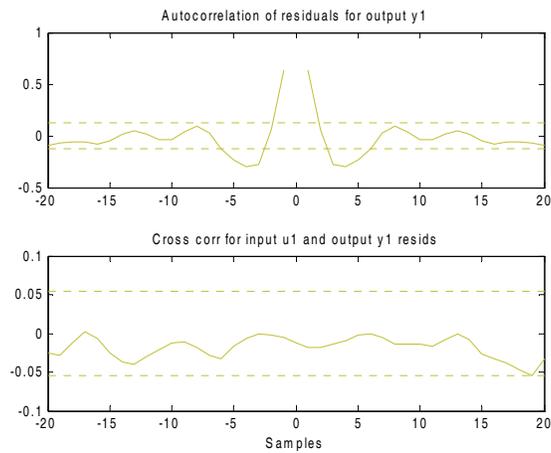


Figura 59 – Análise dos resíduos do modelo IV441 para 1º 100 metros da combinação 1x2 com intervalo de confiança de 99%.

Modelos do 2º 100m:

a) ARX213 e ARX215:

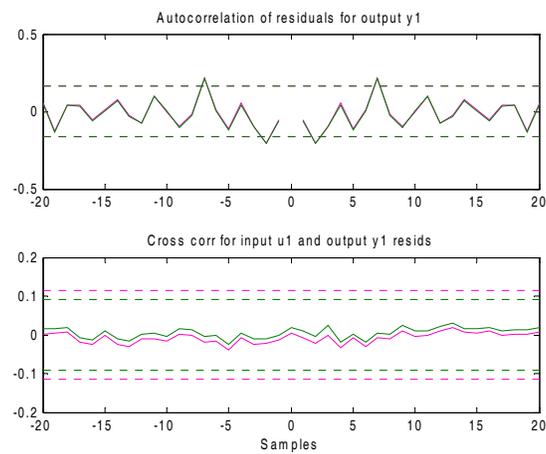


Figura 60 – Análise dos resíduos dos modelos ARX213 e 215 para 2º 100 metros da combinação 1x2 com intervalo de confiança de 99.9%.

b) ARMAX2221:

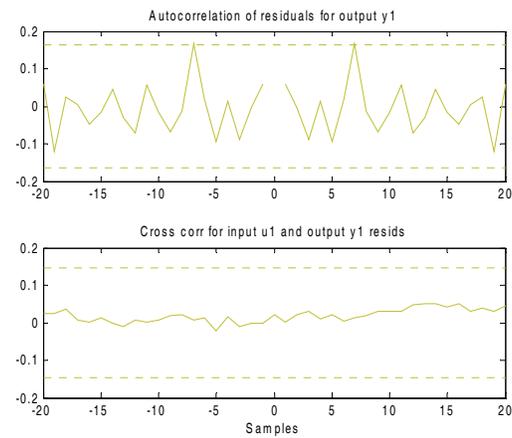


Figura 61 – Análise dos resíduos do modelo ARMAX2221 para 2º 100 metros da combinação 1x2 com intervalo de confiança de 99.9%.

Modelos do 3º 100m:

a) ARX215:

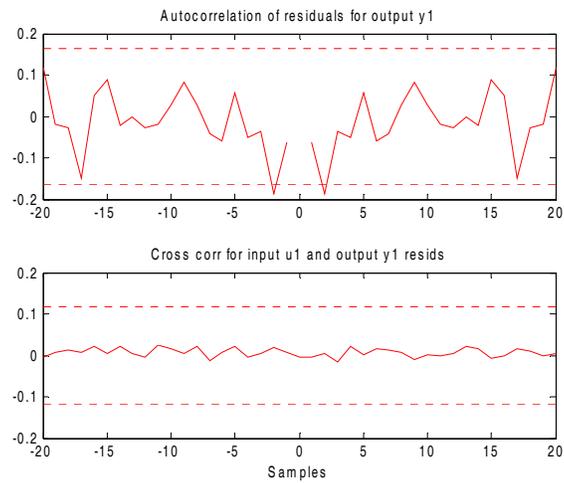


Figura 62 – Análise dos resíduos do modelo ARX215 para 3º 100 metros da combinação 1x2 com intervalo de confiança de 99.9%.

b) ARMAX2221:

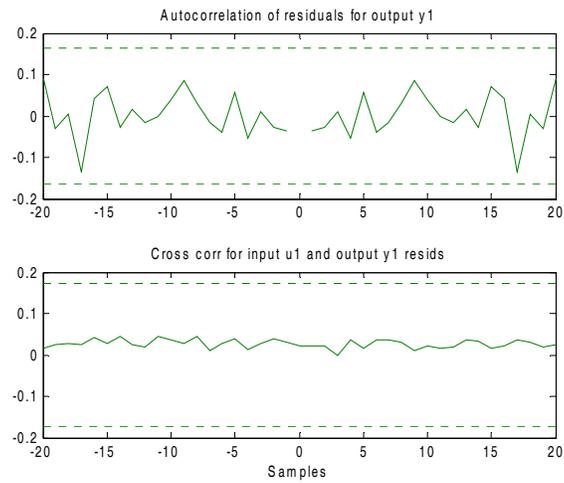


Figura 63 – Análise dos resíduos do modelo ARMAX2221 para 3º 100 metros da combinação 1x2 com intervalo de confiança de 99.9%.

4.1.3.5 Validações dos modelos polinomiais para ACRF

Analogamente ao realizado para o parâmetro atenuação, foi aplicado o modelo do 1º 100m em uma caixa nova para avaliar se os resultados estão similares aos identificados anteriormente, assim validando os modelos. As figuras 64, 65 e 66 exibem os resultados para o modelo ARX215.

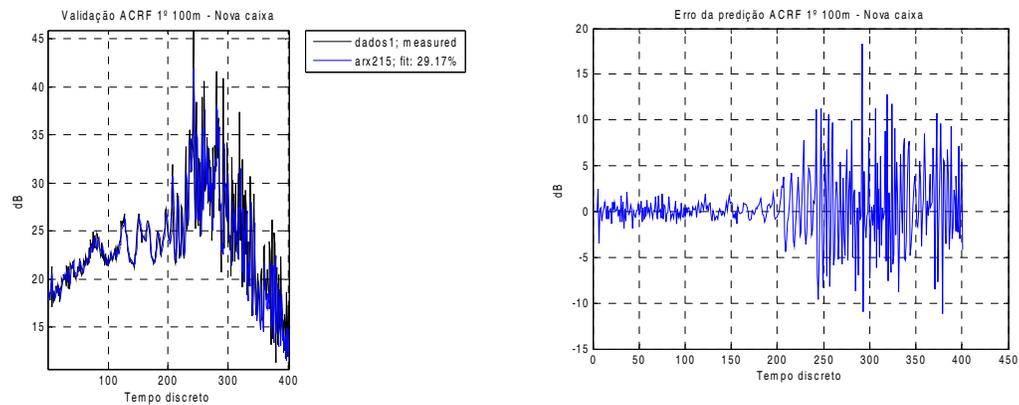


Figura 64 – Resposta e erro do modelo ARX 215 para 1º 100m de uma caixa nova

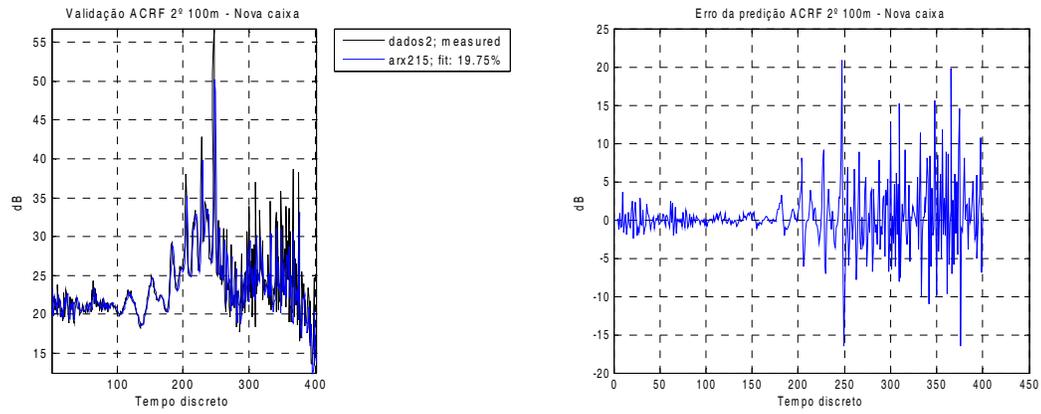


Figura 65 – Resposta e erro do modelo ARX 215 para 2° 100m de uma caixa nova

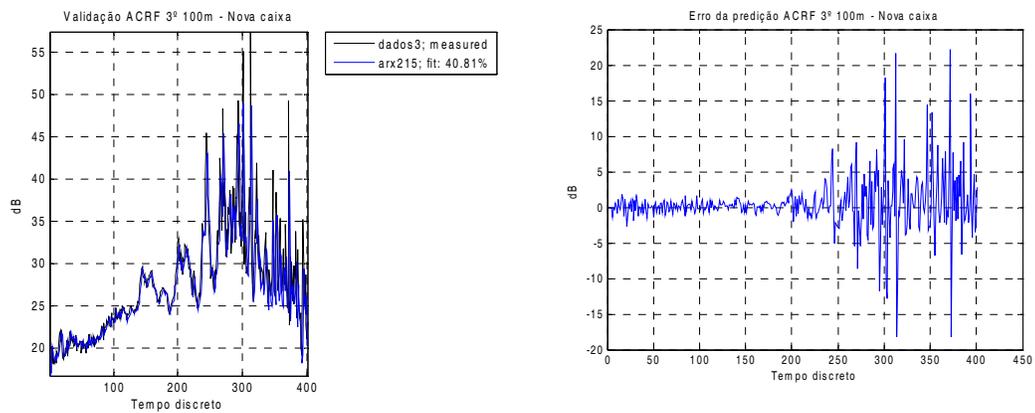


Figura 66 – Resposta e erro do modelo ARX 215 para 3° 100m de uma caixa nova

As figuras 67, 68 e 69 exibem os resultados para o modelo ARMAX2221.

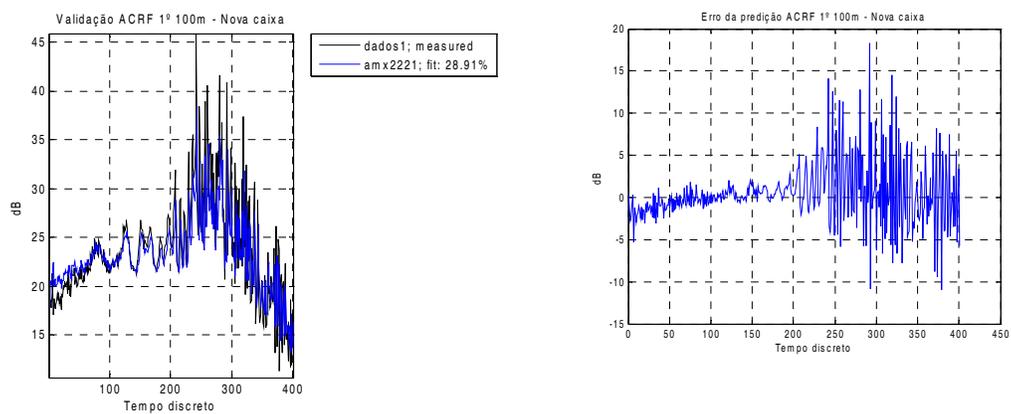


Figura 67 – Resposta e erro do modelo ARMAX 2221 para 1° 100m de uma caixa nova

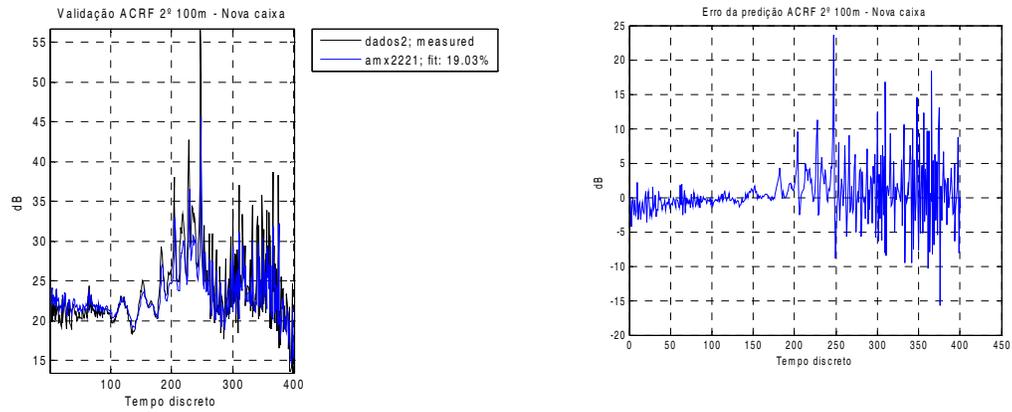


Figura 68 – Resposta e erro do modelo ARMAX 2221 para 2º 100m de uma caixa nova

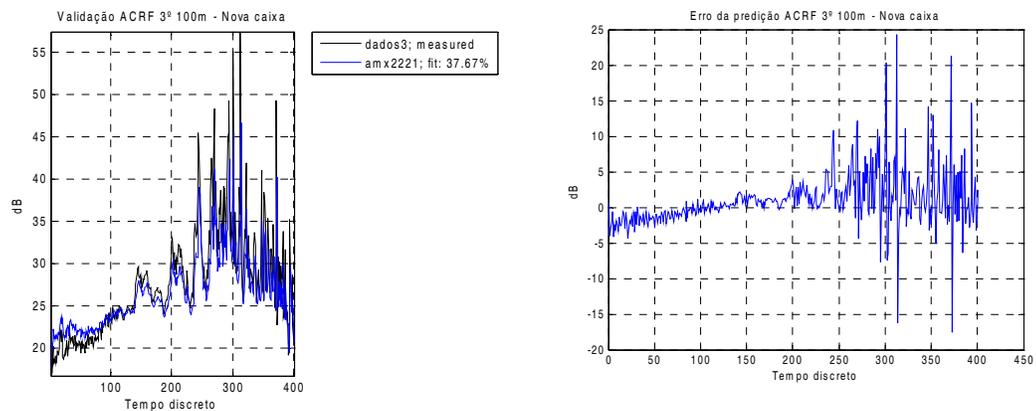


Figura 69 – Resposta e erro do modelo ARMAX 2221 para 3º 100m de uma caixa nova

4.1.3.5.1 Erros dos modelos polinomiais para ACRF

A tabela 08 exibe os valores de *Bestfit* para cada modelo considerando como dados de entrada uma nova caixa.

Tabela 8 – Comparativo dos *Bestfits* entre os 100 metros para ACRF

Validação ACRF: <i>Bestfit</i> dos modelos				
Modelos	ARX215		ARMAX2221	
Amostras	Caixa Original	Caixa Nova	Caixa Original	Caixa Nova
1º 100 metros	37.3	29.17	39.07	28.91
2º 100 metros	26.58	19.75	30.1	19.03
3º 100 metros	56.84	40.81	58.06	37.67

4.2 IMPLEMENTAÇÕES E RESULTADOS UTILIZANDO REDES NEURAIIS ARTIFICIAIS

Inicialmente foi utilizada a *toolbox Neural Network Fitting Tool* do Matlab versão 2007 para criar modelos que representassem a correlação entre métodos de ensaios dos parâmetros de atenuação e ACRF. Este *toolbox* oferece de maneira prática e ágil a implementação da rede tipo *feed-forward* de 2 camadas treinadas com o algoritmo de Levenberg-Marquardt com critérios de avaliação de erro médio quadrático e análise de regressão. A figura 70 apresenta a tela inicial da *toolbox*.

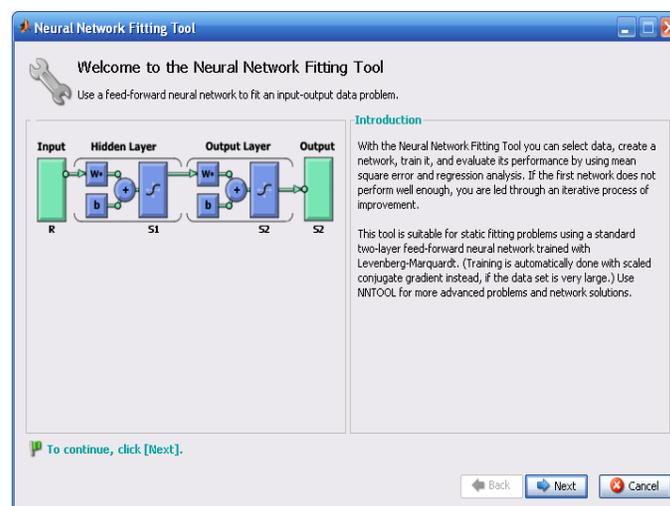


Figura 70 – Tela inicial da *toolbox Neural Network Fitting Tool*

4.2.1 Análise do parâmetro de atenuação com RNA

Como dados de entrada foi considerado o vetor com a medição em caixa e como saída os resultados das 3 amostras de 100mesticadas. A figura 71 exibe a tela de seleção dos dados de entrada e saída da *toolbox*.

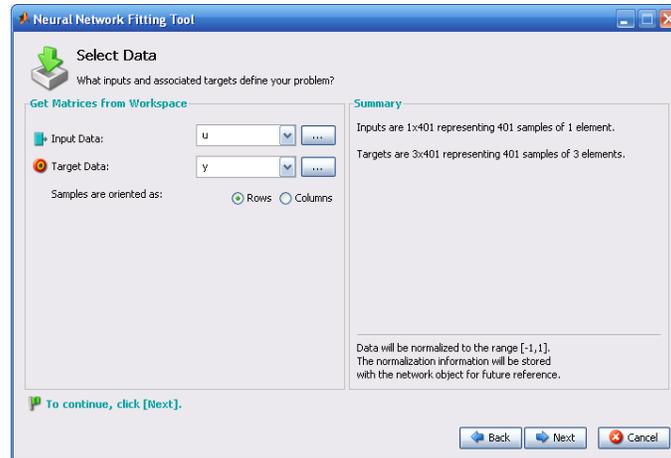


Figura 71 – Tela de seleção dos dados da *toolbox Neural Network Fitting Tool*

As amostras foram divididas aleatoriamente, de modo que 60% dos dados foram utilizados para o treinamento da rede, 20% para validação e os 20% restantes para testes de performance. A figura 72 exibe a tela de configuração dos dados definindo a quantidade de dados utilizados para treinar, validade e testar a rede.

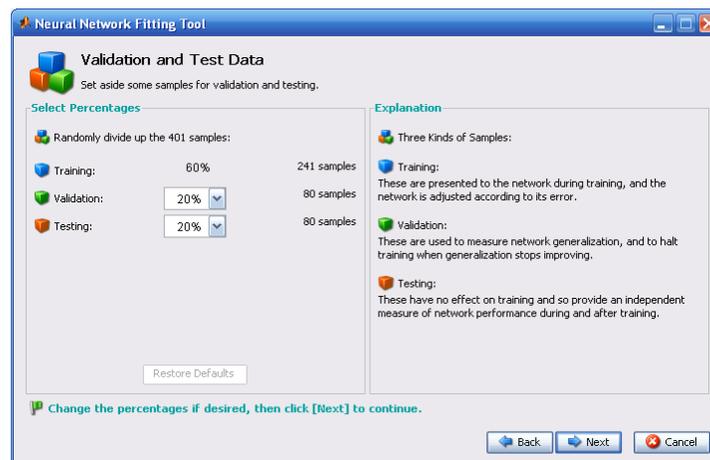


Figura 72 – Tela de configuração dos dados da *toolbox Neural Network Fitting Tool*

Foram considerados 20 neurônios na camada escondida, conforme exibido na figura 73.

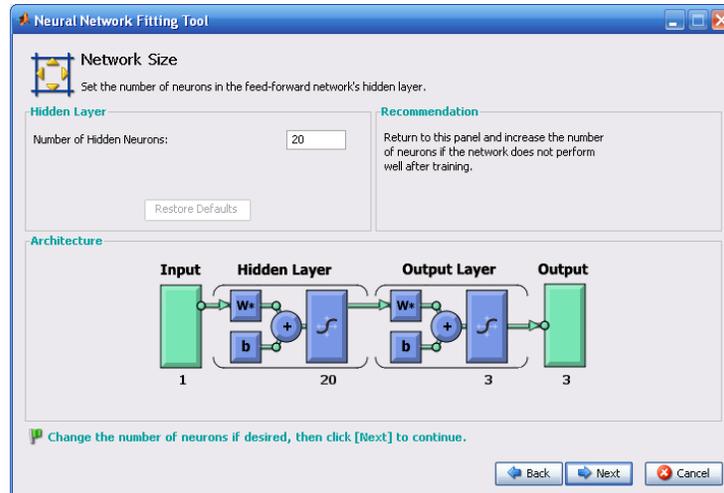


Figura 73 – Tela de configuração da quantidade de neurônios na camada escondida da rede

Os resultados de treinamento foram bastante satisfatórios, já que a regressão atingiu valor acima de 0.97, sendo que o máximo é 1.0 e o erro quadrático médio ficou menor que 0.066, sendo que o recomendável é estar abaixo de 0.66, conforme figura 74.

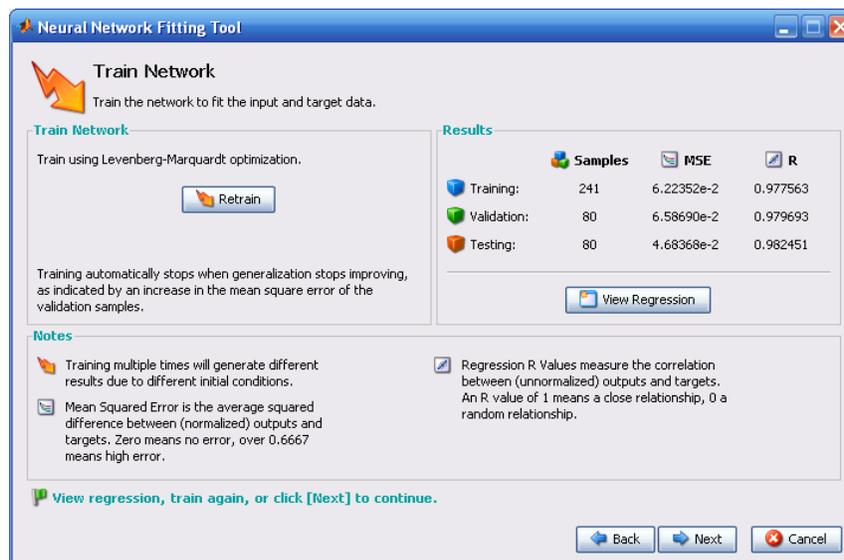


Figura 74 – Tela de resultados da rede

A figura 75 exibe a performance da rede que ficou em 0.060835, sendo que o ideal seria 0.

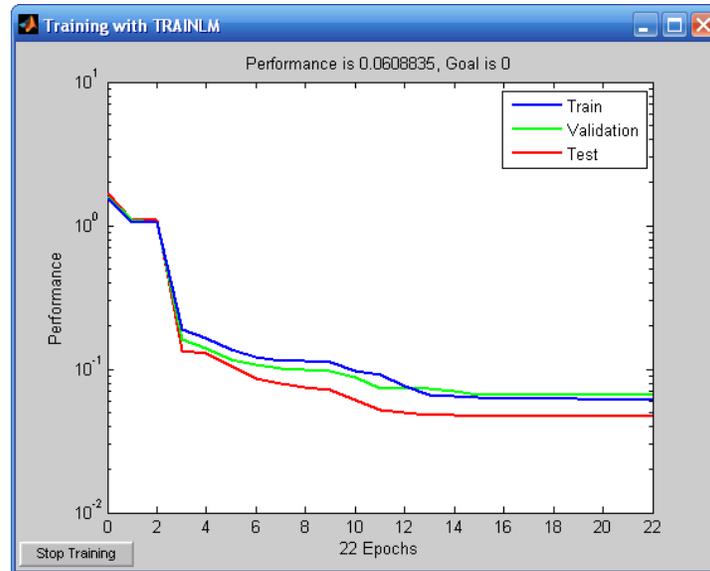


Figura 75 – Performance da rede

Caso os resultados não estivessem a contento seria possível treinar novamente a rede, aumentar a quantidade de neurônios na camada escondida ou aumentar a quantidade de dados de treinamento, sendo que a cada novo teste os resultados são diferentes, uma vez que as condições iniciais mudam a cada teste. Na seqüência é possível treinar a rede com novos dados, realizando uma validação da mesma, conforme figura 76.

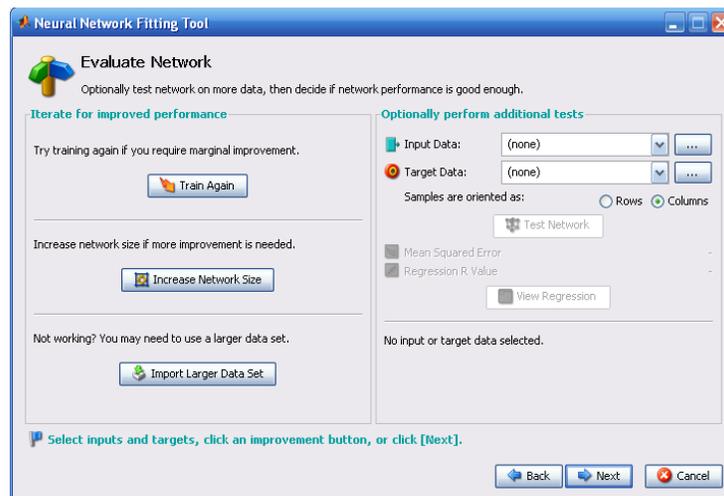


Figura 76 – Tela de avaliação da rede.

Por fim, é possível exportar os dados para o *workspace* para utilizações futuras, conforme figura 77.

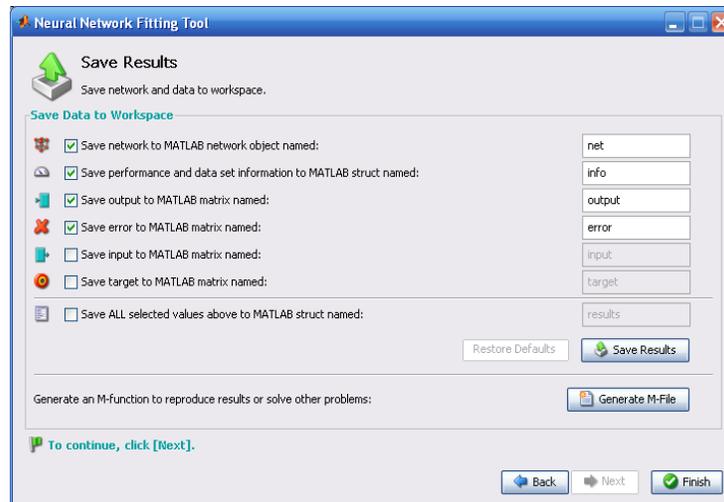


Figura 77 – Tela para exportar os resultados.

Contudo, para facilitar as validações dos resultados optou-se em desenvolver um código que representasse as atividades da *toolbox*, uma vez que não é possível efetuar novas validações após ela ser fechada, sendo necessário efetuar os testes logo após a criação e treinamento da rede.

4.2.1.1 Análise do par 1 com RNA

Foram considerados os dados do ensaio de atenuação do par 1 em caixa como dado de entrada e as 3 amostras de 100 metros como dado de saída, conforme ilustrado na figura 78.

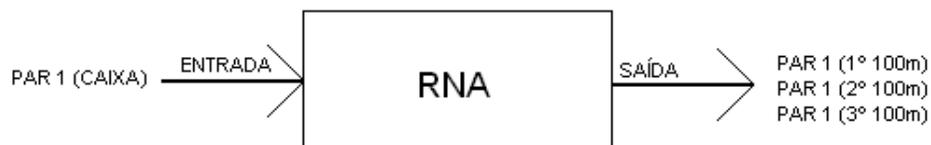


Figura 78 – Configuração de testes do par 1

Conforme comentado anteriormente, cada vez que os treinamentos são executados as respostas são diferentes, já que a rede se inicia com diferentes valores, porém os resultados não diferem muito. A figura 79 exibe o resultado de treinamento, o qual apresentou o resultado de 0.0115286, sendo que o ideal seria 0, assim sendo um resultado muito satisfatório.

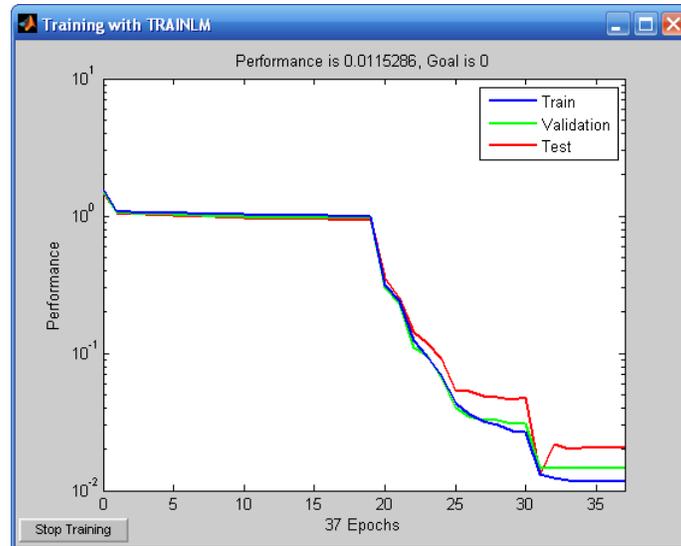


Figura 79 – Resultado do treinamento para rede do par 1.

A figura 80 exibe o resultado da regressão do treinamento, o qual também foi muito satisfatório por atingir 0.95828, sendo que o ideal é 1.

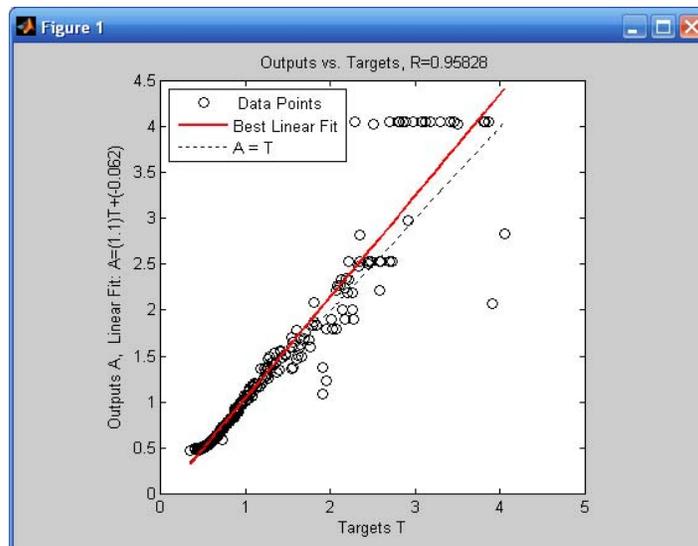


Figura 80 – Resultado da regressão do treinamento para rede do par 1.

4.2.1.1.1 Validação da rede para o par 1

Para avaliar se a rede efetivamente foi bem treinada é necessário testá-la com novos dados de entrada, ou seja, considerando os resultados de teste de uma nova caixa. A figura 81 exibe os resultados da regressão considerando uma nova caixa.

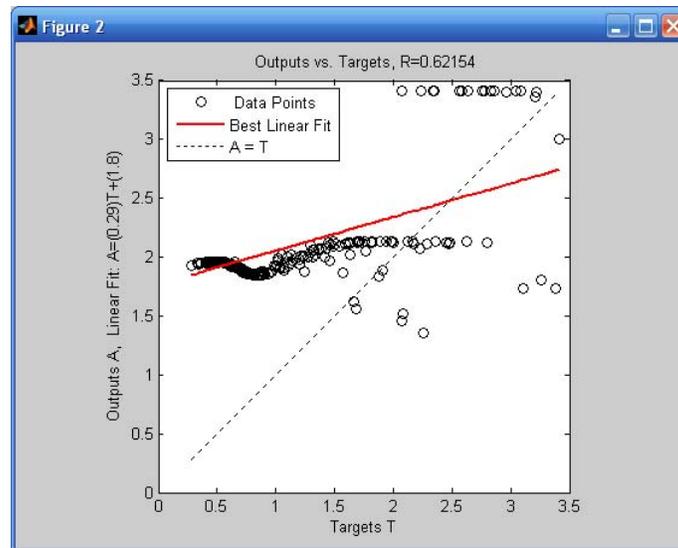


Figura 81 – Resultado da regressão de uma nova caixa

Os resultados não foram satisfatórios, já que a regressão está baixa. Assim, para melhorar a rede é necessário avaliar as alternativas:

- Aumentar a quantidade de dados de treinamento, ou seja, ao invés de utilizar apenas uma caixa para treinamento, aumentar esta quantidade.
- Aumentar quantidade de neurônios na camada escondida, uma vez que foi considerado 20.

4.2.1.2 Análise dos 4 pares com RNA

Nesta configuração foram considerados os 4 pares do ensaio em caixa como dado de entrada e os 3 100 metros como dado de saída, conforme ilustrado na figura 82.

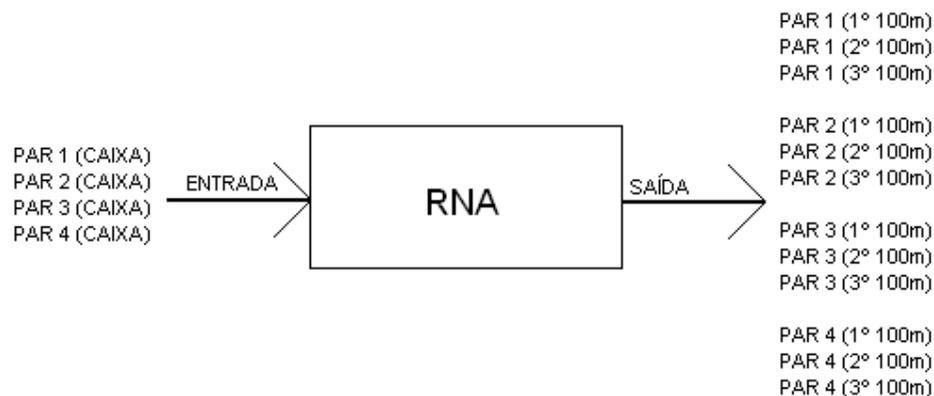


Figura 82 – Configuração de testes dos 4 pares

Após executar o algoritmo algumas vezes, obtiveram-se resultados satisfatórios de treinamento, conforme ilustrado nas figuras a seguir.

A figura 83 exibe o resultado de treinamento, o qual apresentou o resultado de 0.0009455355, sendo que o ideal seria 0, assim sendo um resultado muito satisfatório.

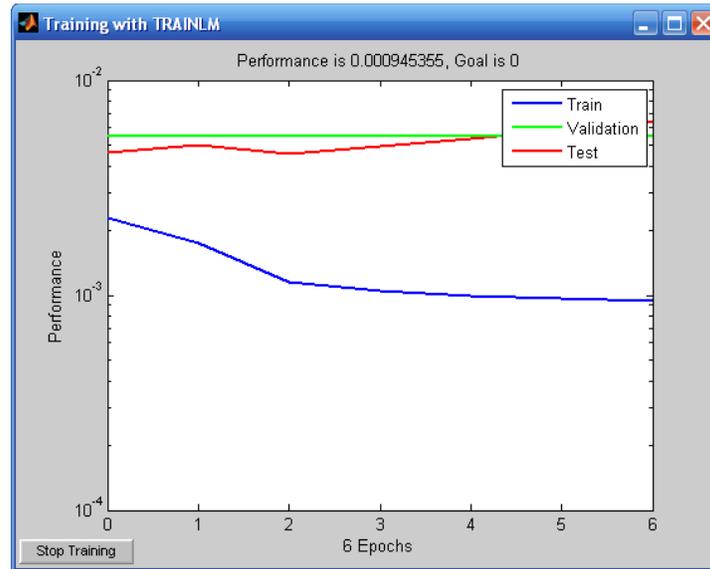


Figura 83 – Resultado do treinamento para rede dos 4 pares

A figura 84 exibe o resultado da regressão do treinamento, o qual também foi muito satisfatório por atingir 0.99223, sendo que o ideal é 1.

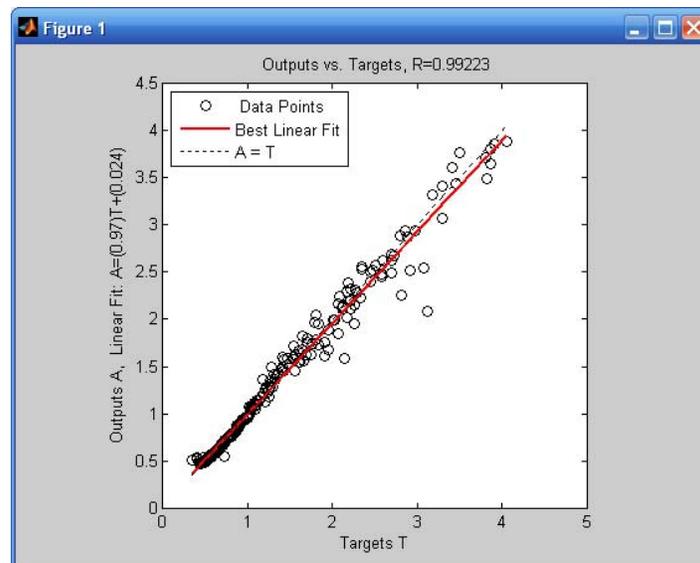


Figura 84 – Resultado da regressão do treinamento para rede dos 4 pares

A figura 85 exibe o erro da rede para cada amostra de 100 metros para cada um dos pares.

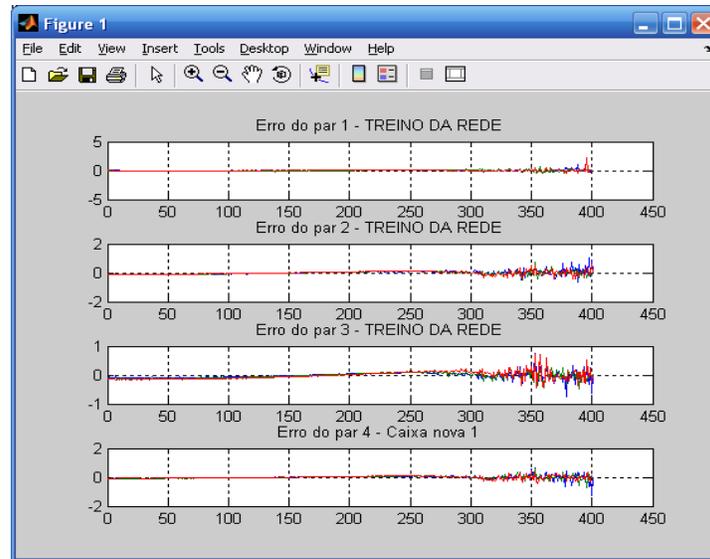


Figura 85 – Erro da rede para cada um dos 4 pares

A figura 86 exibe o erro geral da rede, ou seja, considerando todas as amostras de 100m de todos os pares.

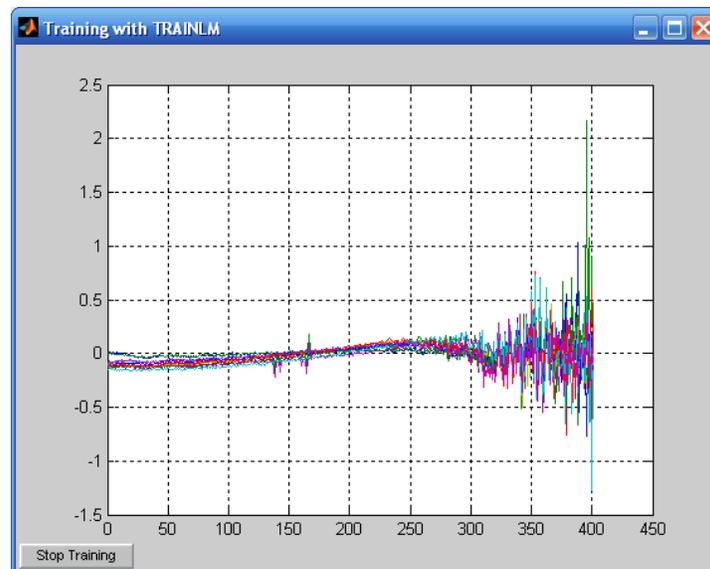


Figura 86 – Erro geral da rede

4.2.1.2.1 Validação da rede para os 4 pares

Para validação se utilizou a regressão e os erros da rede considerando novos dados de entrada, ou seja, 4 novas caixas não utilizadas no treinamento da rede.

a) CAIXA 1:

A figura 87 exhibe o resultado da regressão da validação, no qual se obteve o valor 0.94487.

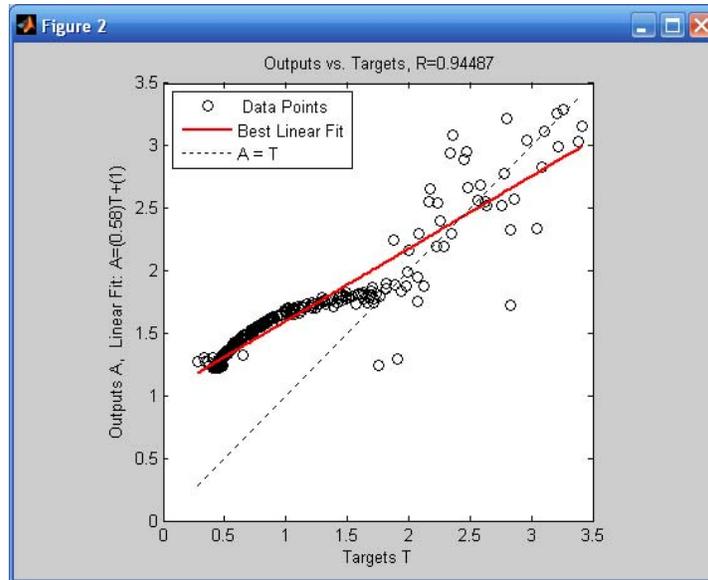


Figura 87 – Resultado da regressão da validação da nova caixa 1 para atenuação

A figura 88 exhibe o erro da rede considerando a 1ª nova caixa para cada amostra de 100 metros para cada um dos pares, sendo que quanto mais próximo de zero, melhor está a rede.

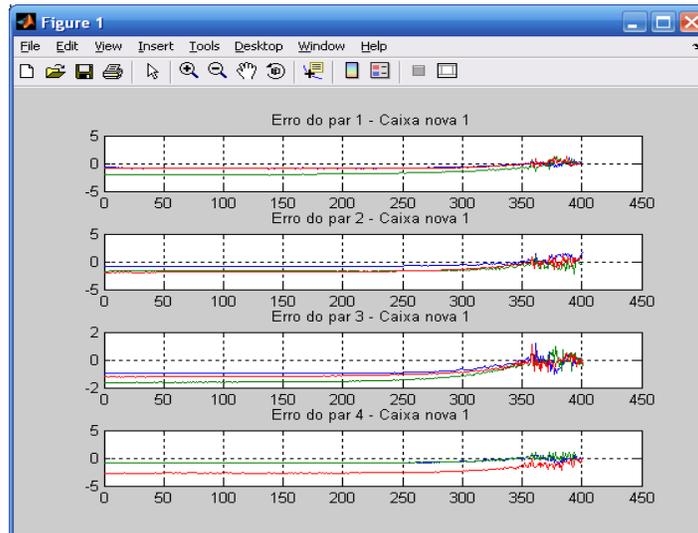


Figura 88 – Erro da rede para cada um dos 4 pares para nova caixa 1 para atenuação

A figura 89 exhibe o erro geral da rede para a 1ª nova caixa, ou seja, considerando todas as amostras de 100 metros de todos os pares.

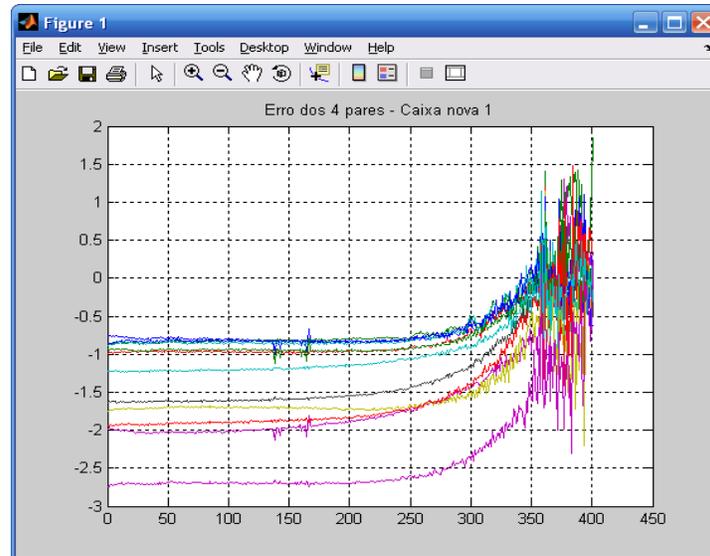


Figura 89 – Erro geral da rede da nova caixa 1 para atenuação

b) CAIXA 2:

A figura 90 exibe o resultado da regressão da validação, no qual se obteve o valor 0.9655.

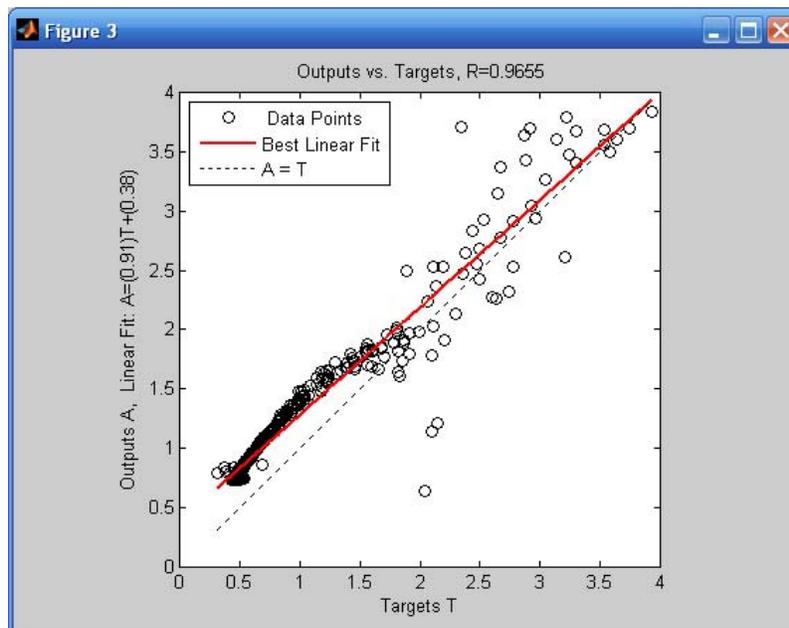


Figura 90 – Resultado da regressão da validação da nova caixa 2 para atenuação

A figura 91 exibe o erro da rede considerando a 2ª nova caixa para cada amostra de 100 metros para cada um dos pares.

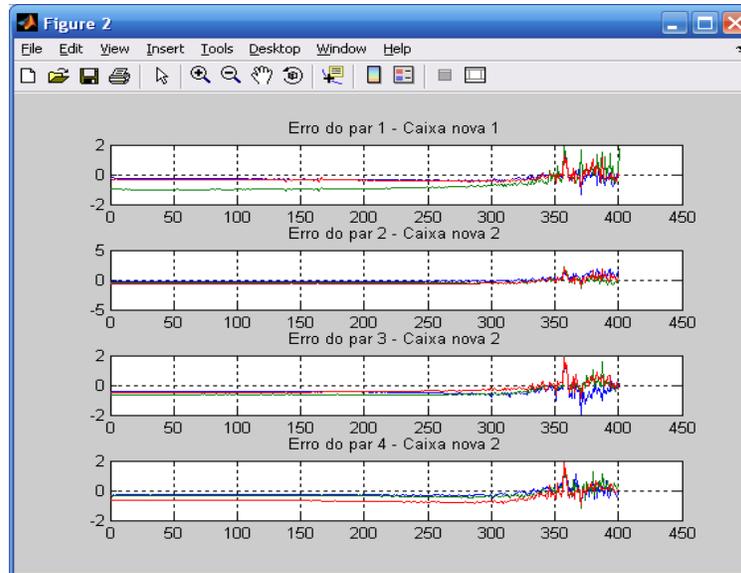


Figura 91 – Erro da rede para cada um dos 4 pares para nova caixa 2 para atenuação

A figura 92 exhibe o erro geral da rede para a 2ª nova caixa.

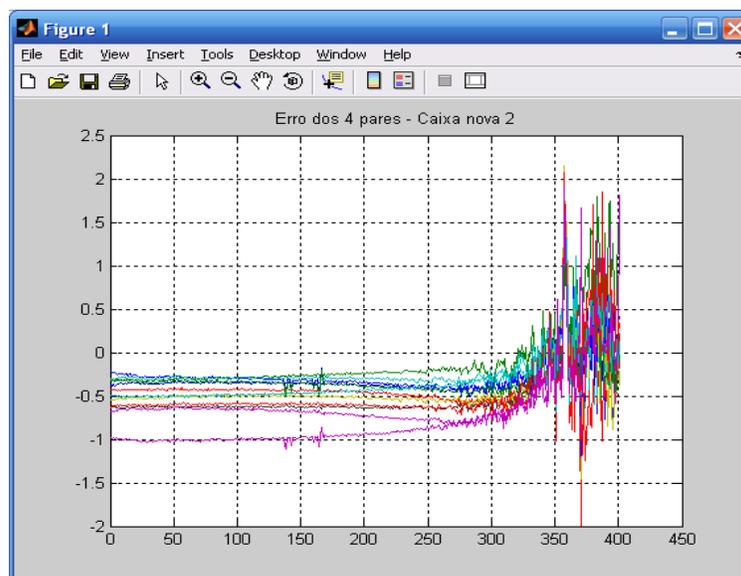


Figura 92 – Erro geral da rede da nova caixa 2 para atenuação

c) CAIXA 3:

A figura 93 exhibe o resultado da regressão da validação, no qual se obteve o valor 0.949223.

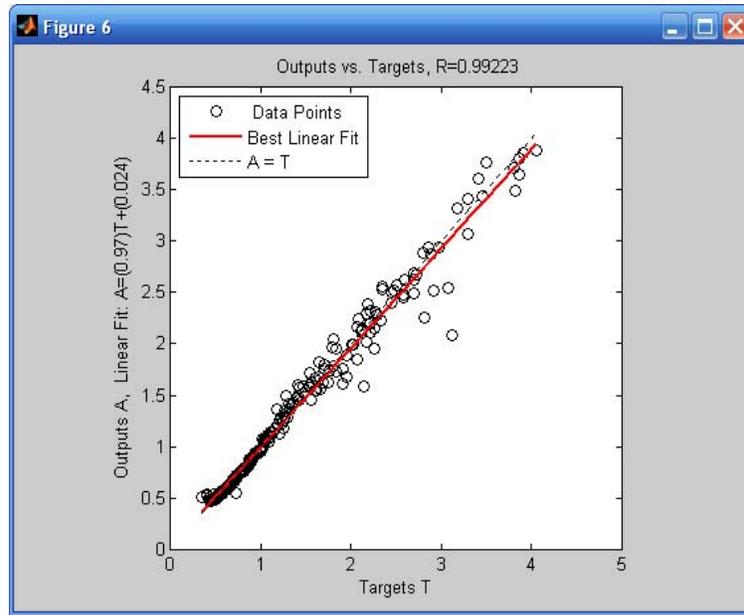


Figura 93 – Resultado da regressão da validação da nova caixa 3 para atenuação

A figura 94 exibe o erro da rede considerando a 3ª nova caixa para cada amostra de 100 metros para cada um dos pares.

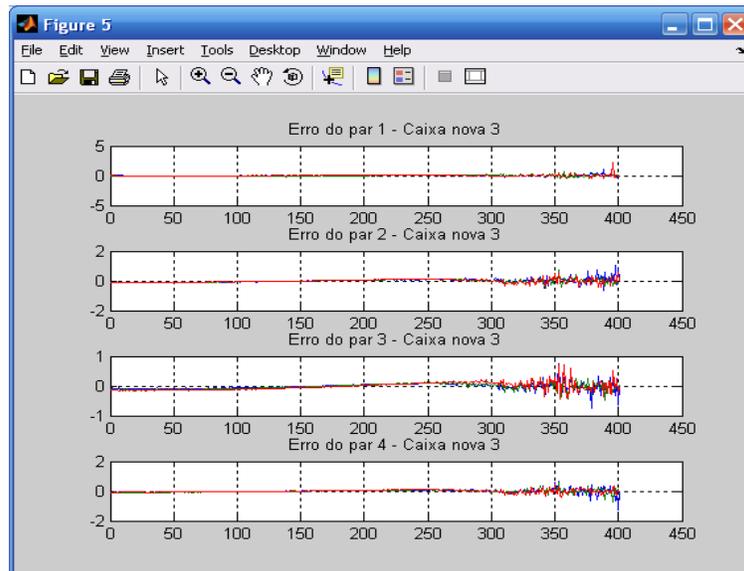


Figura 94 – Erro da rede para cada um dos 4 pares para nova caixa 3 para atenuação

A figura 95 exibe o erro geral da rede para a 3ª nova caixa, ou seja, considerando todas as amostras de 100 metros de todos os pares.

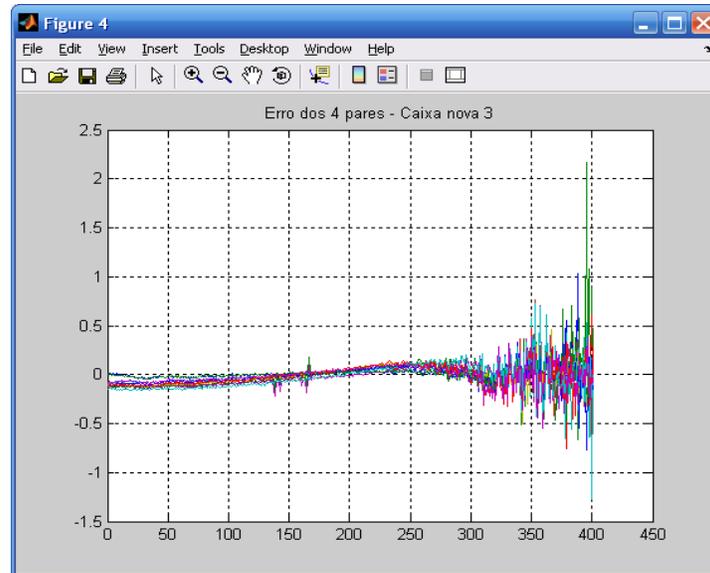


Figura 95 – Erro geral da rede da nova caixa 3 para atenuação

d) CAIXA 4:

A figura 96 exibe o resultado da regressão da validação, no qual se obteve o valor 0.91567.

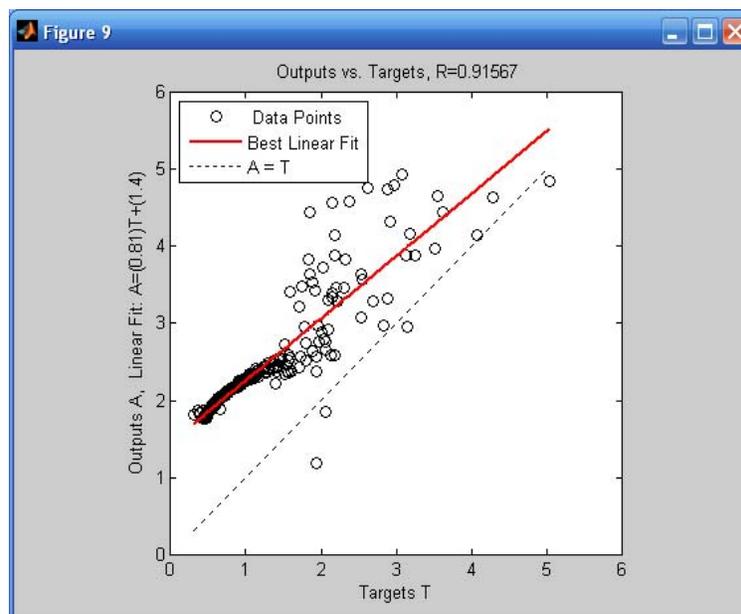


Figura 96 – Resultado da regressão da validação da nova caixa 4 para atenuação

A figura 97 exibe o erro da rede considerando a 4ª nova caixa para cada amostra de 100 metros para cada um dos pares.

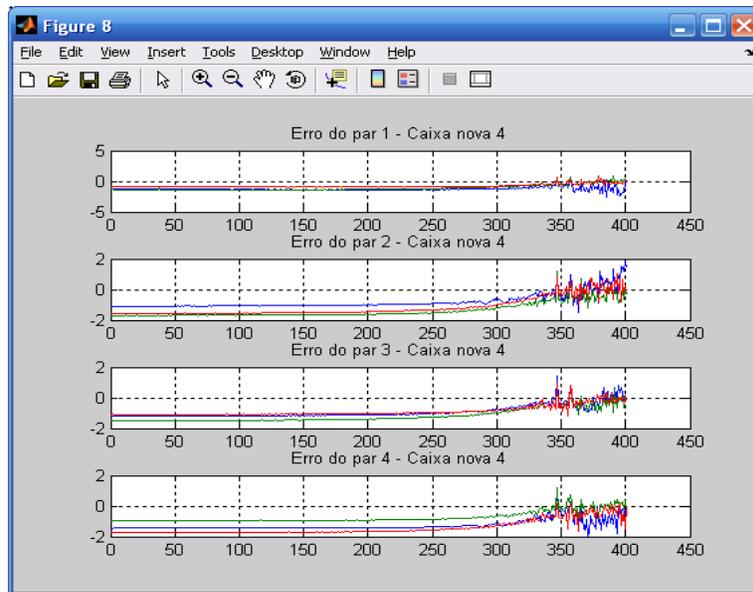


Figura 97 – Erro da rede para cada um dos 4 pares para nova caixa 4 para atenuação

A figura 98 exibe o erro geral da rede para a 1ª nova caixa, ou seja, considerando todas as amostras de 100 metros de todos os pares.

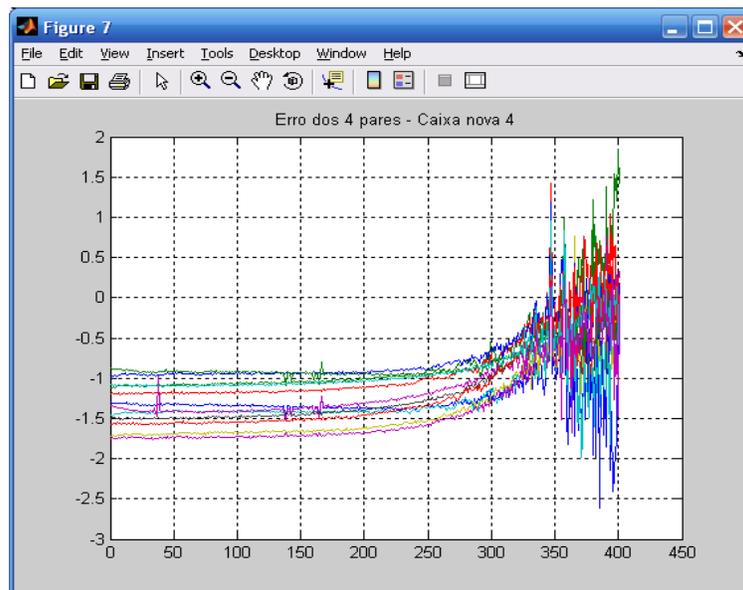


Figura 98 – Erro geral da rede da nova caixa 4 para atenuação

4.2.1.2.2 Erros dos modelos de atenuação com RNA

As tabelas 09 e 10 exibem os piores casos de cada combinação de atenuação utilizando as RNA, uma vez que destes dados refletem as piores condições, ou seja, o pior cenário.

Tabela 9 – Erros do modelo considerando a caixa utilizada no treinamento para atenuação

	CAIXA UTILIZADA NO TREINO		
	1º100m	2º100m	3º100m
P1	1.03	0.70	2.17
P2	1.07	0.69	0.61
P3	0.76	0.47	0.72
P4	-1.27	-0.76	-0.44
\bar{X}	0.39	0.27	0.76
σ	1.12	0.69	1.07

Tabela 10 – Erros dos modelos considerando as caixas utilizadas na validação para atenuação

	ERROS											
	CAIXA 1			CAIXA 2			CAIXA 3			CAIXA 4		
	1º100m	2º100m	3º100m									
P1	1.10	-2.12	1.15	1.03	0.70	2.17	1.40	1.89	1.35	-2.60	-1.53	-1.09
P2	1.85	-2.20	-1.95	1.07	0.69	0.61	1.79	2.14	2.07	1.84	-1.72	-1.58
P3	1.20	-1.64	-1.24	-0.75	0.47	0.72	-1.99	1.94	1.94	1.42	-1.51	-1.18
P4	1.11	-1.12	-2.75	-1.27	-0.76	-0.44	-1.17	1.69	1.89	-1.97	1.18	-1.76
\bar{X}	1.31	-1.77	-1.19	0.02	0.27	0.76	0.00	1.91	1.81	-0.32	-0.89	-1.40
σ	0.35	0.49	1.68	1.20	0.69	1.07	1.87	0.18	0.31	2.28	1.38	0.31

4.2.2 Análise do parâmetro de ACRF com RNA

Foram considerados os dados do ensaio de ACRF de todas as combinações da caixa como dado de entrada e as 3 amostras de 100 metros como dado de saída, conforme ilustrado na figura 99.

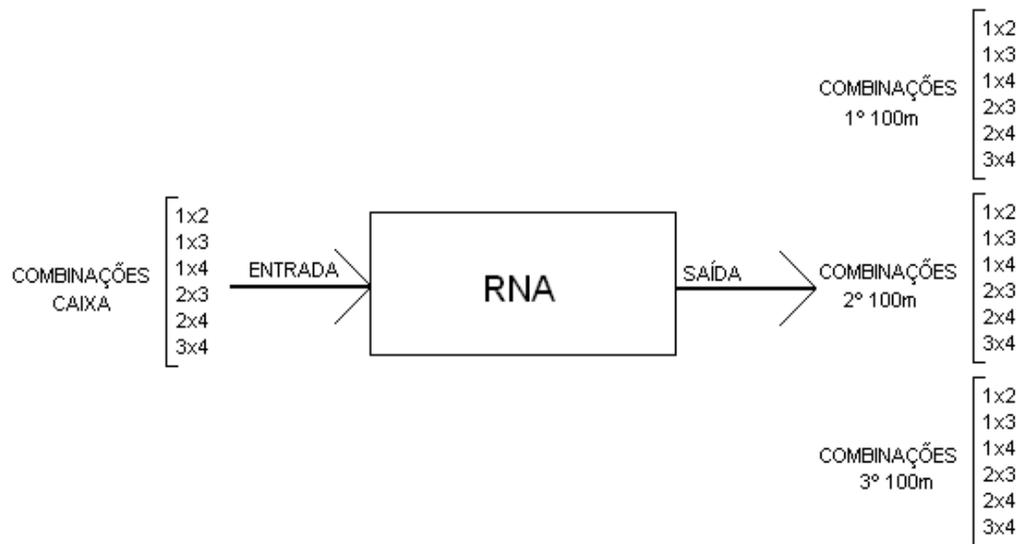


Figura 99 – Configuração de testes do par 1

Apesar dos resultados serem diferentes a cada vez que o algoritmo é executado, os resultados são similares.

A figura 100 exibe o resultado de treinamento, o qual apresentou o resultado de 0.116866, sendo que o ideal seria 0, assim sendo um resultado simplesmente razoável.

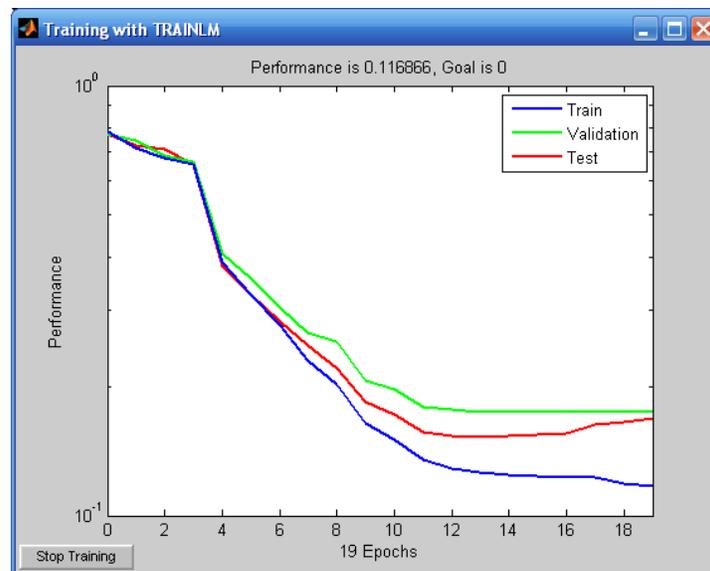


Figura 100 – Resultado do treinamento para rede com todas as combinações

A figura 101 exibe o resultado da regressão do treinamento, o qual também foi razoável por atingir 0.66462, sendo que o ideal é 1.

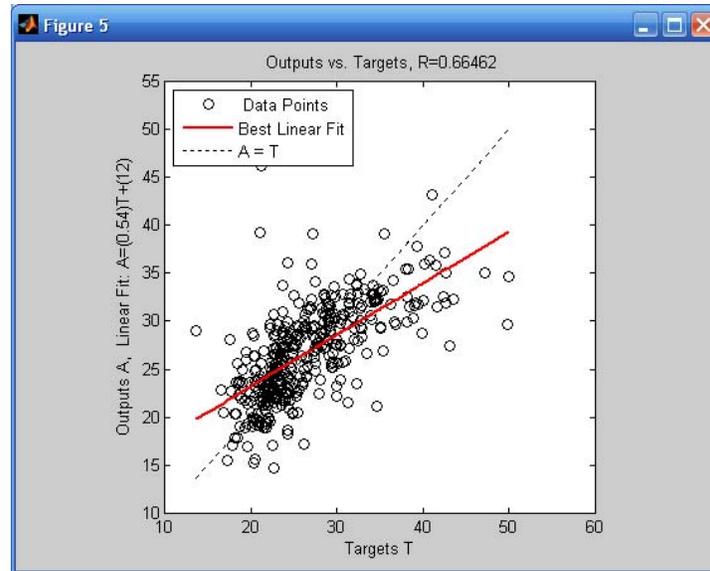


Figura 101 – Resultado da regressão do treinamento para com todas as combinações

A figura 102 exibe o erro da rede no treinamento para cada amostra de 100 metros para as combinações 1x2 e 1x3.

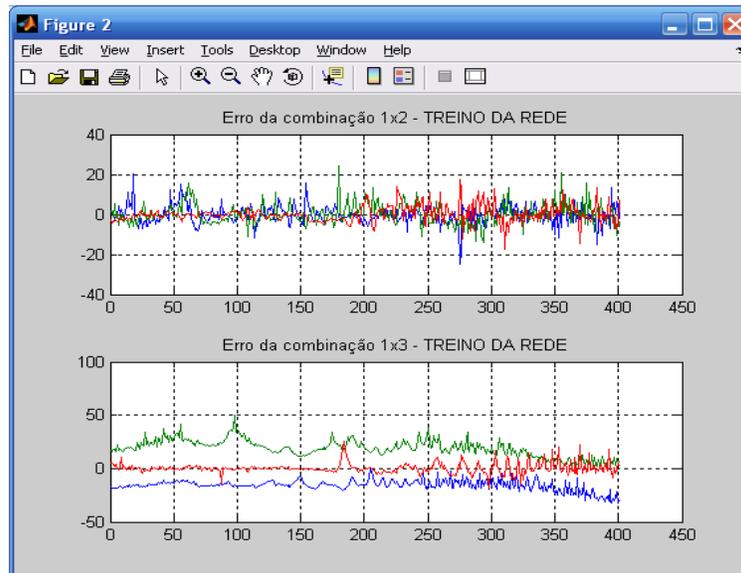


Figura 102 – Erros da rede para as combinações 1x2 e 1x3

A figura 103 exibe o erro da rede no treinamento para cada amostra de 100 metros para as combinações 1x4 e 2x3.

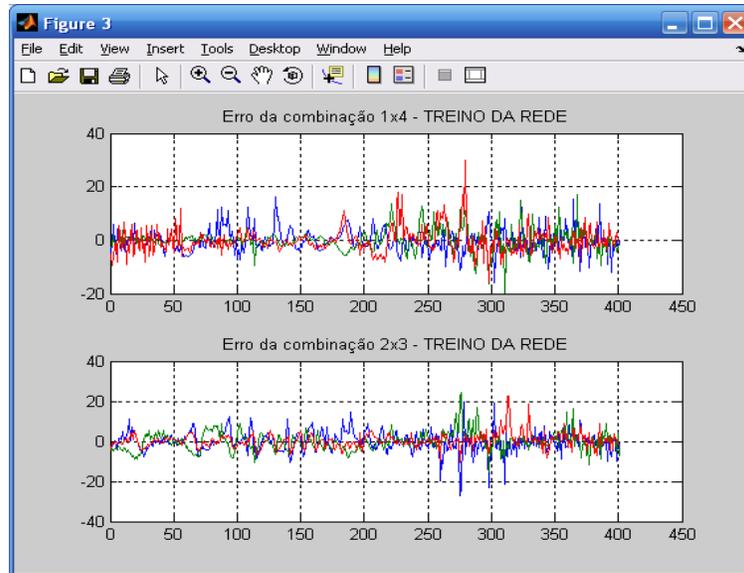


Figura 103 – Erros da rede para as combinações 1x4 e 2x3

A figura 104 exibe o erro da rede no treinamento para cada amostra de 100 metros para as combinações 2x4 e 3x4.

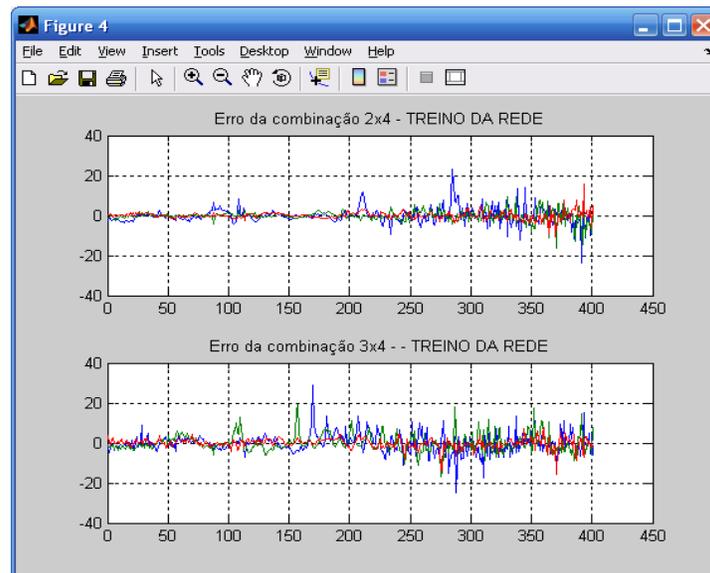


Figura 104 – Erros da rede para as combinações 2x4 e 3x4

A figura 105 exibe o erro geral da rede no treinamento para todas as amostras de 100 metros em todas as combinações.

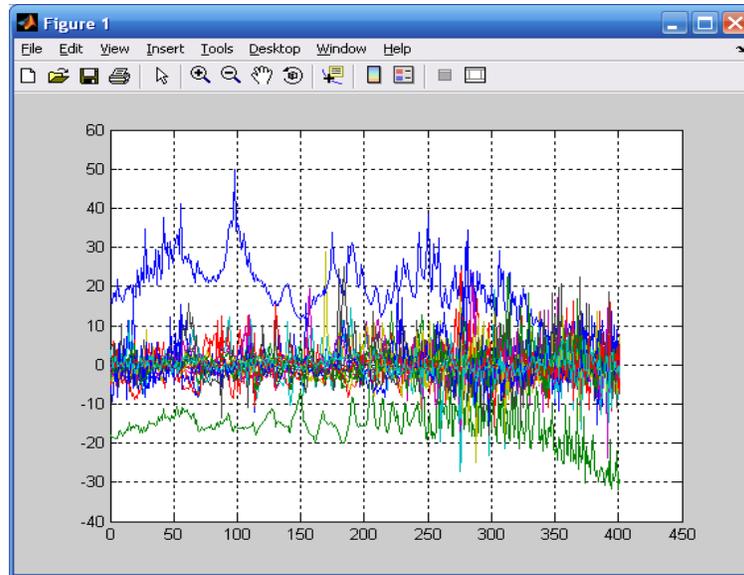


Figura 105 – Erro geral da rede para todas as combinações

Mesmo alterando-se a quantidade de neurônios na camada escondida, os resultados ficaram muito similares, entretanto, o tempo de treinamento da rede aumentou significativamente, o que se mostrou ineficiente para melhorar a performance da rede.

4.2.2.1.1 Validação da rede para todas as combinações

Para validação se utilizou a regressão e os erros da rede considerando novos dados de entrada, ou seja, 4 novas caixas não utilizadas no treinamento da rede.

a) CAIXA 1:

A figura 106 exibe o resultado da regressão da validação, no qual se obteve o valor 0.15367, sendo que o ideal é 1.

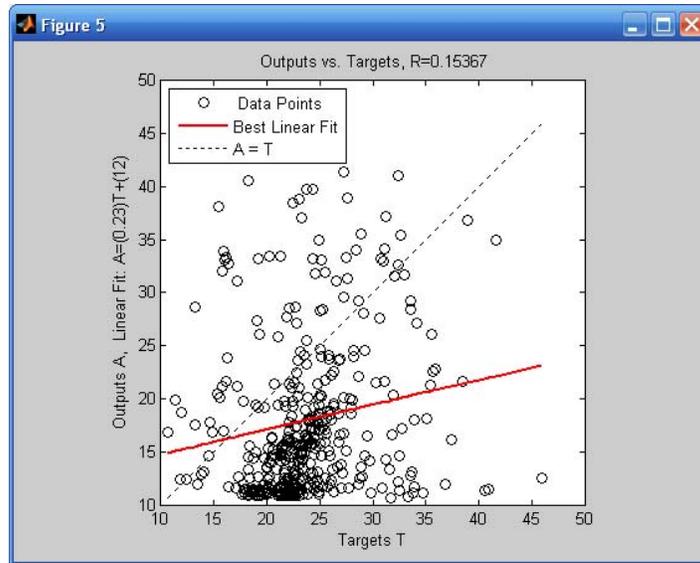


Figura 106 – Resultado da regressão da validação da nova caixa 1 para ACRF

A figura 107 exibe o erro da rede considerando a 1ª nova caixa para cada amostra de 100 metros para as combinações 1x2 e 1x3.

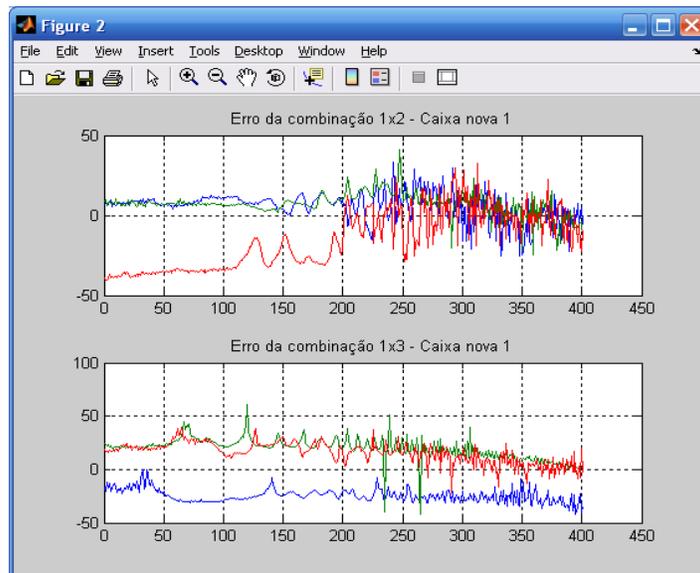


Figura 107 – Erro da rede para as combinações 1x2 e 1x3 para nova caixa 1 para ACRF

A figura 108 exibe o erro da rede considerando a 1ª nova caixa para cada amostra de 100 metros para as combinações 1x4 e 2x3.

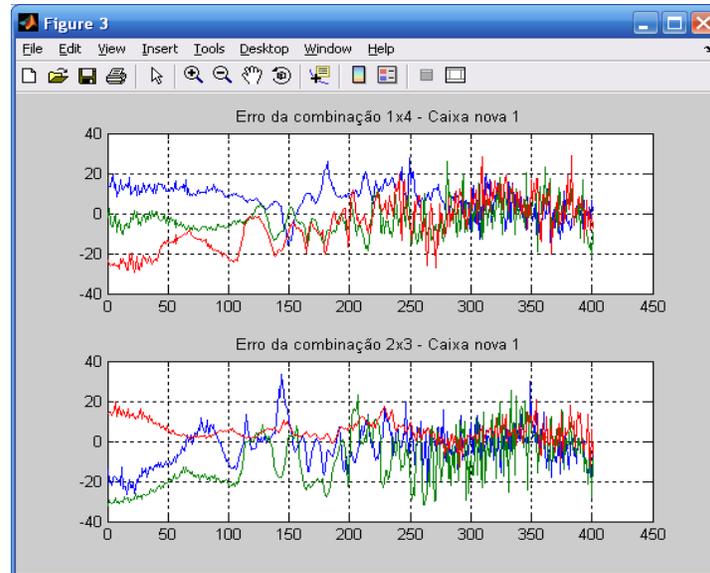


Figura 108 – Erro da rede para as combinações 1x4 e 2x3 para nova caixa 1 para ACRF

A figura 109 exibe o erro da rede considerando a 1ª nova caixa para cada amostra de 100 metros para as combinações 2x4 e 3x4.

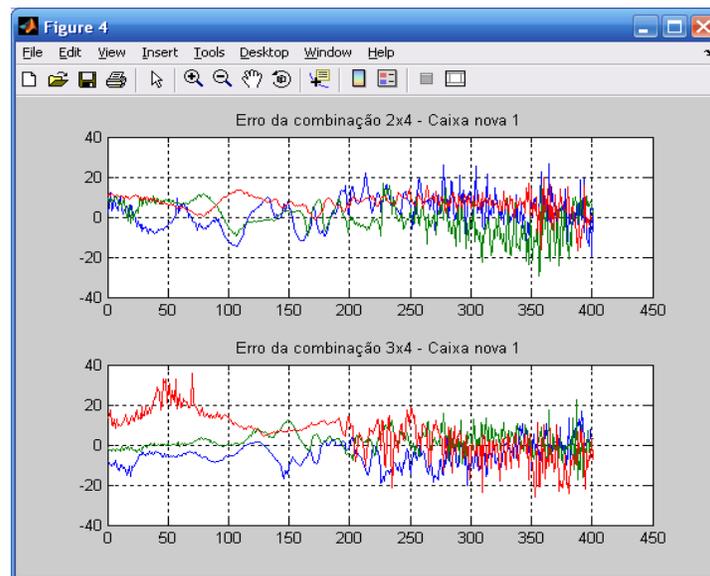


Figura 109 – Erro da rede para as combinações 2x4 e 3x4 para nova caixa 1 para ACRF

A figura 110 exibe o erro geral da rede para a 1ª nova caixa, ou seja, considerando todas as amostras de 100 metros de todas as combinações.

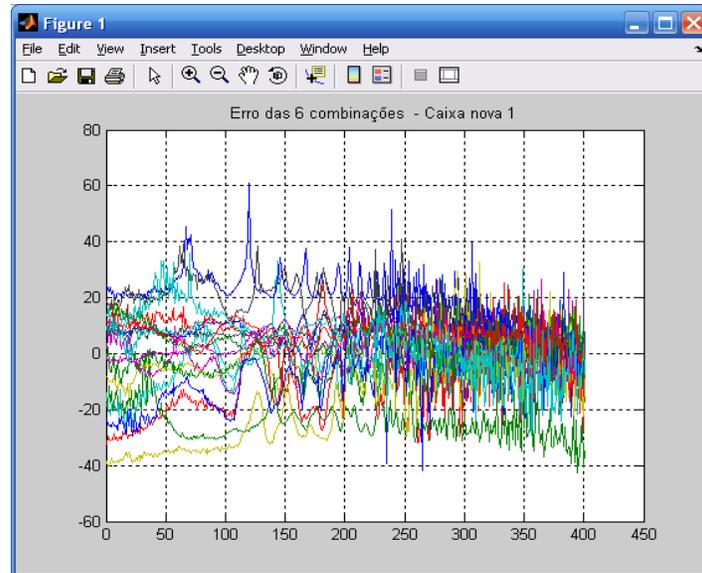


Figura 110 – Erro geral da rede da nova caixa 1 para ACRF

b) CAIXA 2

A figura 111 exibe o resultado da regressão da validação, no qual se obteve o valor 0.15367.

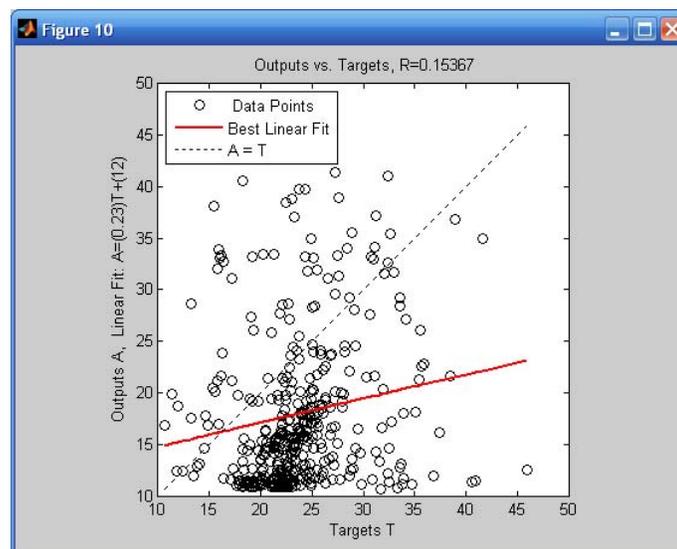


Figura 111 – Resultado da regressão da validação da nova caixa 2 para ACRF

A figura 112 exibe o erro da rede considerando a 2ª nova caixa para cada amostra de 100 metros para as combinações 1x2 e 1x3.

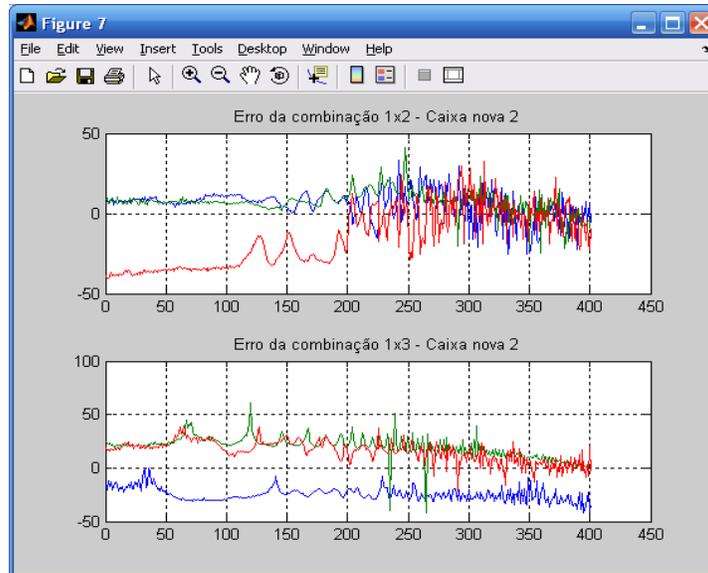


Figura 112 – Erro da rede para as combinações 1x2 e 1x3 para nova caixa 2 para ACRF

A figura 113 exibe o erro da rede considerando a 2ª nova caixa para cada amostra de 100 metros para as combinações 1x4 e 2x3.

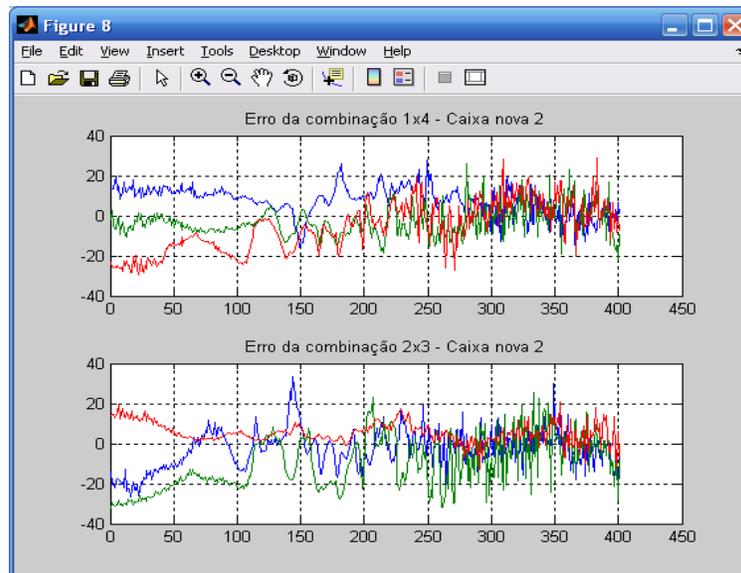


Figura 113 – Erro da rede para as combinações 1x4 e 2x3 para nova caixa 2 para ACRF

A figura 114 exibe o erro da rede considerando a 2ª nova caixa para cada amostra de 100 metros para as combinações 2x4 e 3x4.

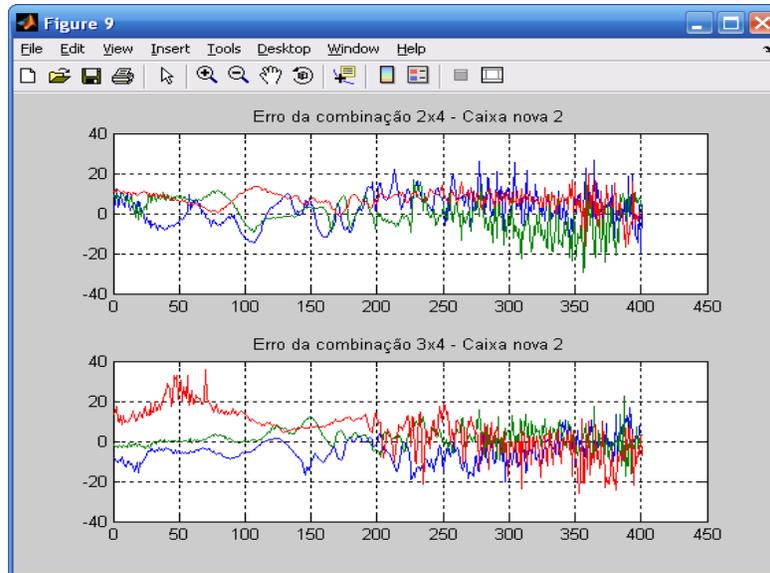


Figura 114 – Erro da rede para as combinações 2x4 e 3x4 para nova caixa 2 para ACRF

A figura 115 exibe o erro geral da rede para a 2ª nova caixa, ou seja, considerando todas as amostras de 100 metros de todas as combinações.

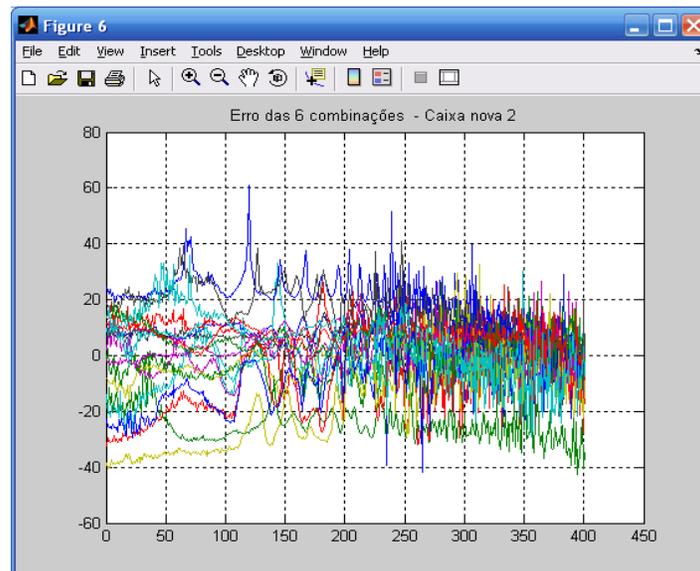


Figura 115 – Erro geral da rede da nova caixa 2 para ACRF

c) CAIXA 03:

A figura 116 exibe o resultado da regressão da validação, no qual se obteve o valor 0.66462.

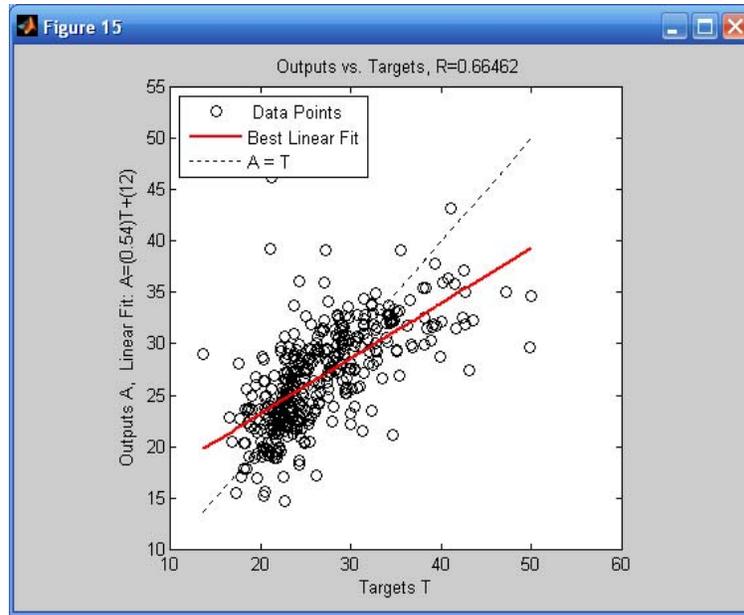


Figura 116 – Resultado da regressão da validação da nova caixa 3 para ACRF

A figura 117 exibe o erro da rede considerando a 3ª nova caixa para cada amostra de 100 metros para as combinações 1x2 e 1x3.

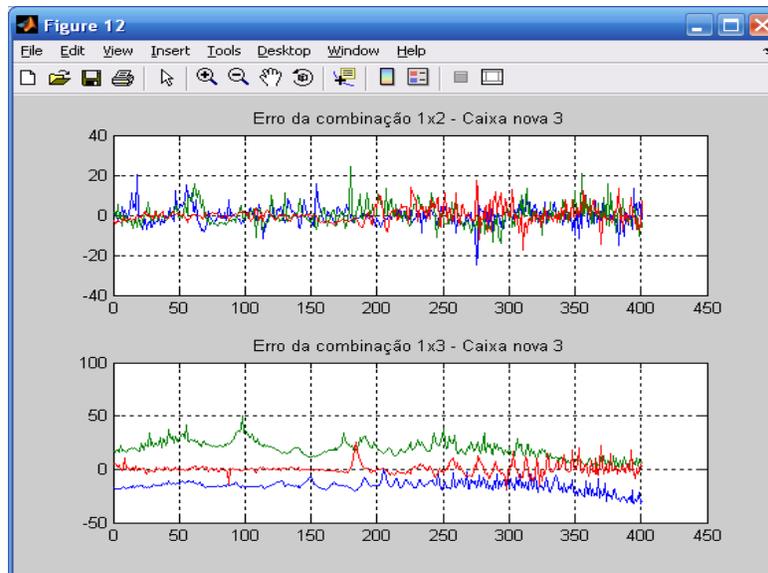


Figura 117 – Erro da rede para as combinações 1x2 e 1x3 para nova caixa 3 para ACRF

A figura 118 exibe o erro da rede considerando a 3ª nova caixa para cada amostra de 100 metros para as combinações 1x4 e 2x3.

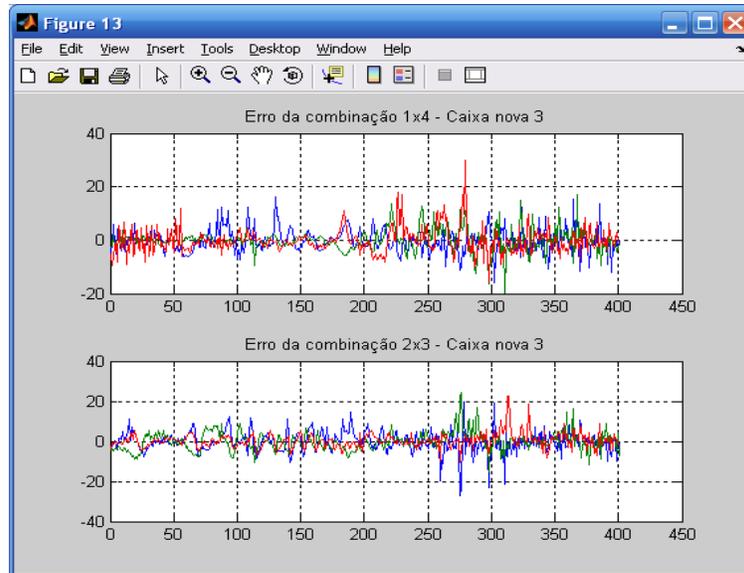


Figura 118 – Erro da rede para as combinações 1x4 e 2x3 para nova caixa 3 para ACRF

A figura 119 exibe o erro da rede considerando a 3ª nova caixa para cada amostra de 100 metros para as combinações 2x4 e 3x4.

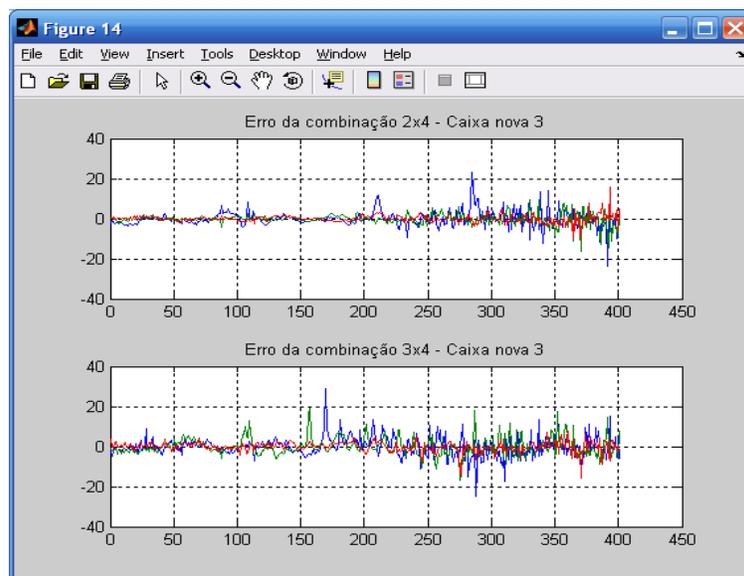


Figura 119 – Erro da rede para as combinações 2x4 e 3x4 para nova caixa 3 para ACRF

A figura 120 exibe o erro geral da rede para a 3ª nova caixa, ou seja, considerando todas as amostras de 100 metros de todas as combinações.

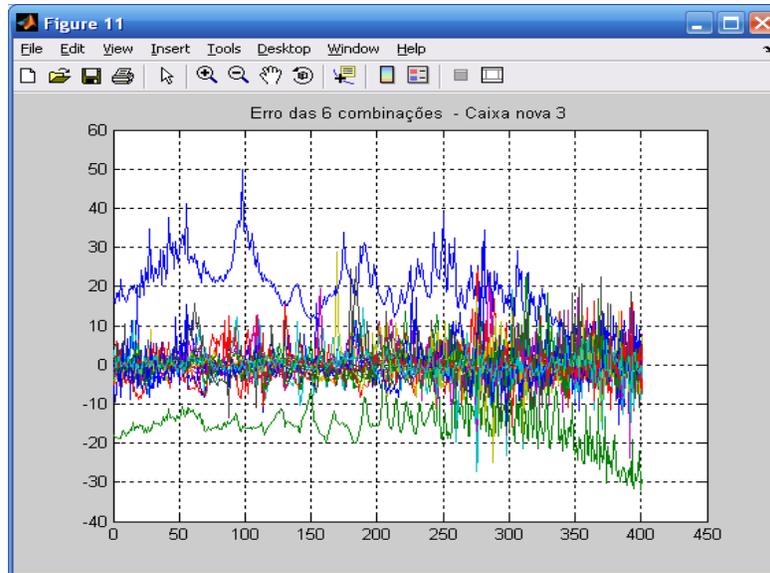


Figura 120 – Erro geral da rede da nova caixa 3 para ACRF

d) CAIXA 04:

A figura 121 exibe o resultado da regressão da validação, no qual se obteve o valor 0.33856.

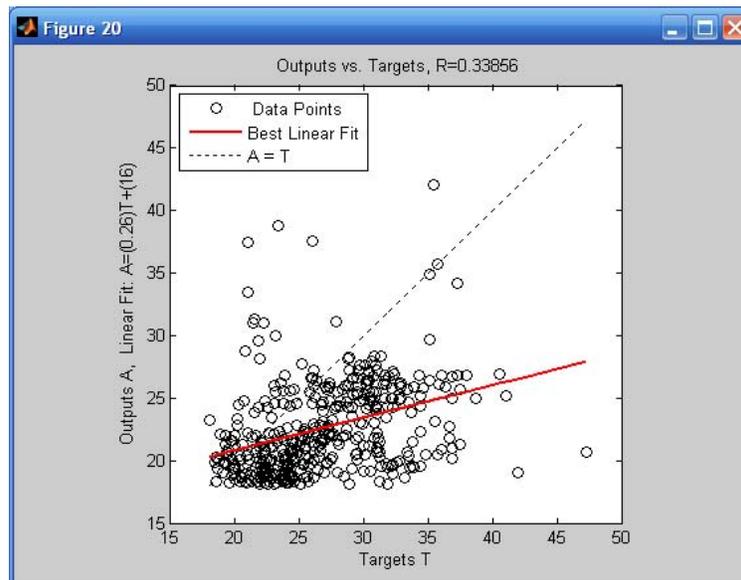


Figura 121 – Resultado da regressão da validação da nova caixa 4 para ACRF

A figura 122 exibe o erro da rede considerando a 4ª nova caixa para cada amostra de 100 metros para as combinações 1x2 e 1x3.

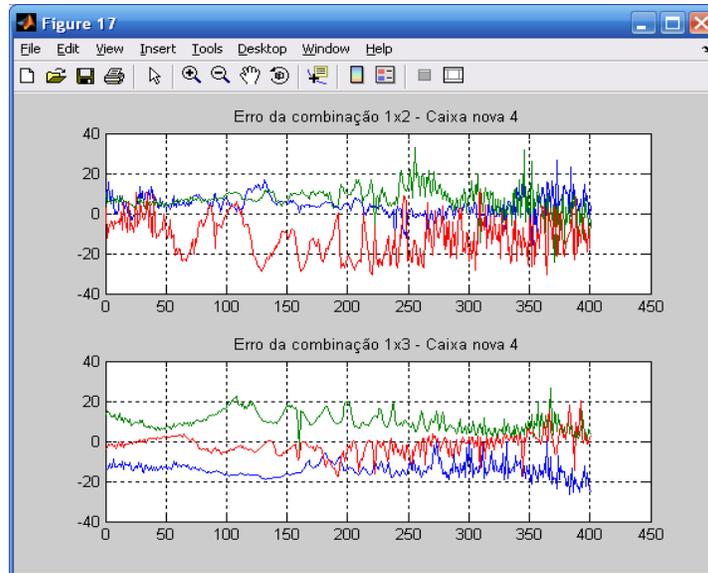


Figura 122 – Erro da rede para as combinações 1x2 e 1x3 para nova caixa 4 para ACRF

A figura 123 exibe o erro da rede considerando a 4ª nova caixa para cada amostra de 100 metros para as combinações 1x4 e 2x3.

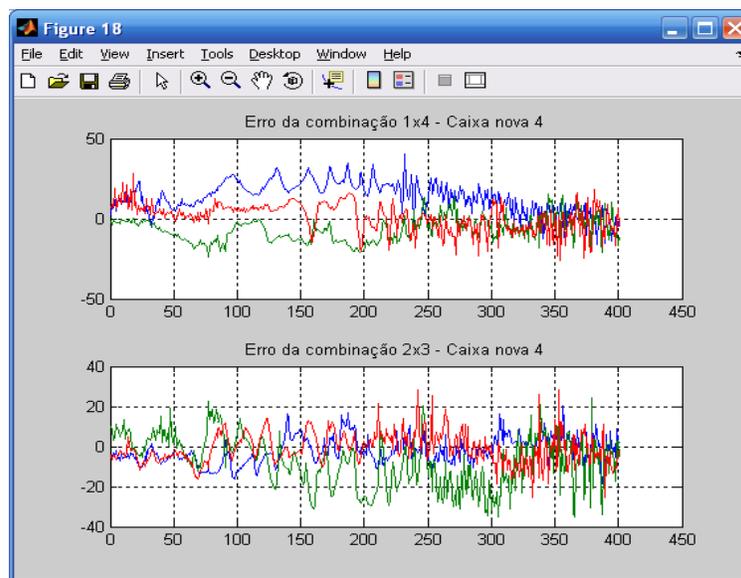


Figura 123 – Erro da rede para as combinações 1x4 e 2x3 para nova caixa 4 para ACRF

A figura 124 exibe o erro da rede considerando a 4ª nova caixa para cada amostra de 100 metros para as combinações 2x4 e 3x4.

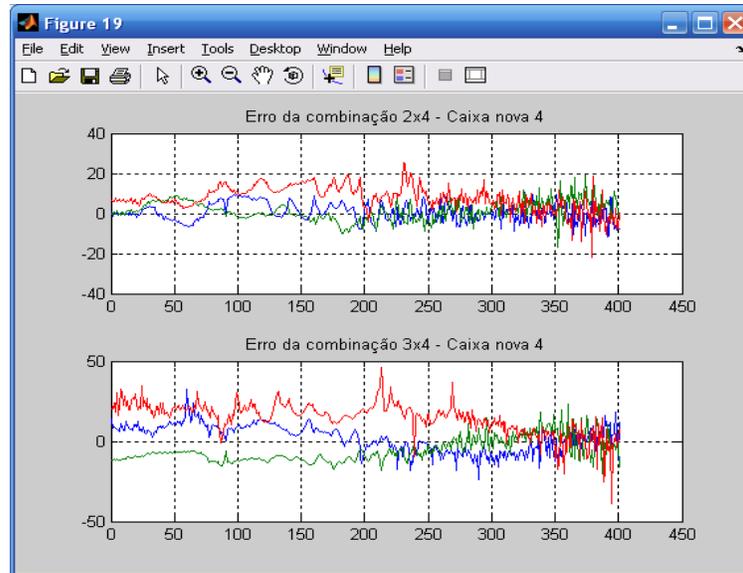


Figura 124 – Erro da rede para as combinações 2x4 e 3x4 para nova caixa 4 para ACRF

A figura 125 exibe o erro geral da rede para a 4ª nova caixa, ou seja, considerando todas as amostras de 100 metros de todas as combinações.

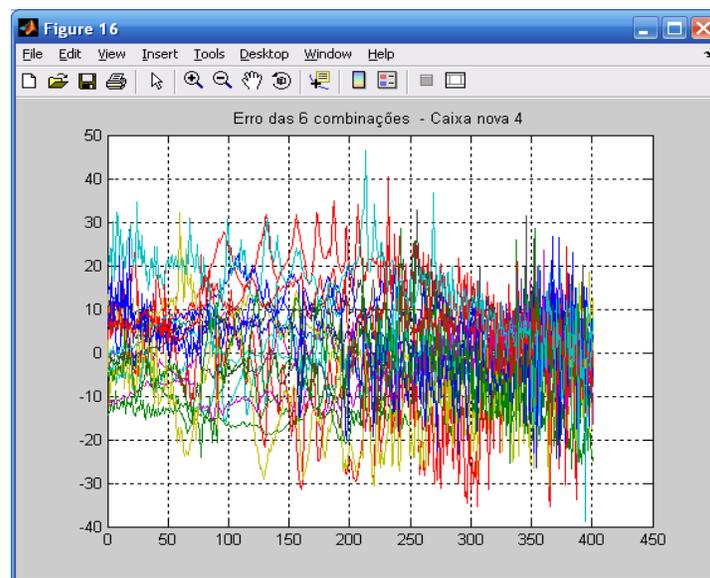


Figura 125 – Erro geral da rede da nova caixa 4 para ACRF

4.2.2.1.2 Erros dos modelos de ACRF com RNA

As tabelas 11 e 12 exibem os piores casos de cada combinação de ACRF utilizando as RNA.

Tabela 11 – Erros do modelo considerando a caixa utilizada no treinamento de ACRF

COMBINAÇÕES	CAIXA UTILIZADA NO TREINO		
	1º100m	2º100m	3º100m
1x2	-25.03	24.41	17.33
1x3	-32.00	50.02	25.12
1x4	-16.01	-19.80	30.06
2x3	-27.35	24.31	22.55
2x4	-23.89	-16.48	15.89
3x4	28.88	19.39	-15.75
\bar{X}	-15.9	13.64	15.46
σ	22.25	26.87	16.33

Tabela 12 – Erros dos modelos considerando as caixas utilizadas na validação de ACRF

	ERROS											
	CAIXA 1			CAIXA 2			CAIXA 3			CAIXA 4		
	1º100 m	2º100 m	3º100 m	1º100 m	2º100 m	3º100 m	1º100 m	2º100 m	3º100 m	1º100 m	2º100 m	3º100 m
1x2	33.35	41.10	-40.56	33.35	41.10	-40.56	-25.03	24.41	17.33	26.56	32.71	-30.78
1x3	-42.42	60.85	39.31	-42.42	60.82	39.31	-32.00	50.02	25.12	-26.81	26.59	20.20
1x4	27.80	26.09	-29.63	27.80	26.09	-29.63	16.11	-19.80	30.06	40.50	-24.09	28.38
2x3	33.28	-32.44	21.09	33.28	-32.44	21.09	-27.35	24.31	22.55	20.17	-35.31	28.52
2x4	26.75	-29.25	19.62	26.75	-29.25	19.62	23.28	-16.48	15.89	-11.95	19.33	25.15
3x4	-20.20	22.75	35.83	-20.20	22.75	35.83	28.88	19.39	-15.75	32.17	23.44	46.42
\bar{X}	9.76	14.85	1.96	9.76	5.65	1.27	-2.68	6.36	15.86	13.44	7.11	16.64
σ	32.69	37.88	34.92	32.69	34.04	34.01	28.25	22.49	16.33	26.70	29.06	26.24

4.3 CONCLUSÕES DO CAPÍTULO

Esta sessão visa efetuar uma comparação dos resultados entre as técnicas, sendo que para isso foi escolhido o critério de *Bestfit* para ser o critério em comum entre as técnicas. Lembrando que o cálculo do *Bestfit* é 1-NRMSE (Normalized Root Mean Square Error).

No quesito treinamento para predição da atenuação, conforme exibido na tabela 13, ambas as técnicas obtiveram resultados satisfatórios já que alcançaram altos índices de assertividade. Contudo, vale ressaltar que os melhores resultados estão atribuídos aos modelos paramétricos, em especial o ARX441 e o ARMAX4421 que obtiveram as médias mais altas. Entretanto, apesar da RNA ter obtido o pior *Bestfit*, a mesma apresentou o menor desvio padrão que é um fator bem positivo em predição.

Tabela 13 – Comparativo dos *Bestfit* para a predição de atenuação do par 1.

<i>Bestfit</i> (%)	Modelos Paramétricos			RNA
Amostras	ARX441	IV441	ARMAX4421	Back-propagation
1°100m	90.18	87.20	90.28	87.49
2°100m	94.97	94.07	95.23	85.10
3°100m	92.40	90.87	92.06	83.14
\bar{X}	92.51	90.71	92.52	85.24
σ	2.39	3.43	2.50	2.17

Entretanto, no treinamento para predição da combinação 1x2 de ACRF os resultados não foram satisfatórios, uma vez que todas as tentativas apresentaram baixo nível de assertividade *Bestfit*. Igualmente ao ocorrido nos experimentos de atenuação, os modelos paramétricos apresentaram os melhores resultados, no entanto, a RNA apresentou o menor desvio padrão, conforme apresentado na tabela 14.

Tabela 14 – Comparativo dos *Bestfit* para a predição de ACRF da combinação 1x2.

<i>Bestfit</i> (%)	Modelos Paramétricos		RNA
Amostras	ARX215	ARMAX2221	Back-propagation
1°100m	37.30	39.07	23.89
2°100m	26.58	30.10	19.07
3°100m	56.84	58.06	37.37
\bar{X}	40.24	42.41	26.77
σ	15.34	14.27	9.48

Na validação das técnicas e modelos aonde são apresentados novos dados que não foram utilizados no treinamento é bem nítida a assertividade dos modelos paramétricos frente a RNA. Com o intuito de certificar que as RNAs não obtiveram uma aderência satisfatória na predição do parâmetro atenuação foram apresentadas várias caixas diferentes como entrada, porém apenas em uma delas o resultado se aproximou de estar satisfatório. Os destaques dos *Bestfits* ficaram com os modelos ARX441 e ARMAX, devido sua tratativa com a cor do ruído, que apresentaram resultados satisfatórios e muito similares aos resultados de treinamento, deste modo, demonstrando a solidez dos resultados e do modelo obtido. A tabela 15 sumariza o comparativo dos *Bestfits* das técnicas para os dados de validação de atenuação do par 1.

Tabela 15 – Comparativo dos *Bestfit* da validação dos modelos para a predição de atenuação do par 1.

<i>Bestfit</i> (%)	Modelos Paramétricos			RNA			
	ARX441	IV441	ARMAX4421	Back-propagation			
Amostras	CAIXA 1	CAIXA 1	CAIXA 1	CAIXA 1	CAIXA 2	CAIXA 3	CAIXA 4
1° 100 m	91.68	88.45	89.91	-7.33	53.88	87.43	-76.73
2° 100 m	89.97	86.68	88.01	-125.47	-9.97	85.10	-68.64
3° 100 m	91.51	88.44	90.61	-6.98	51.79	83.14	-33.01
\bar{X}	91.05	87.86	89.51	-46.59	31.90	85.22	-59.46
σ	0.94	1.02	1.35	68.31	36.28	2.15	23.26

A tabela 16 apresenta os resultados comparativos de *Bestfit* para predição de ACRF, sendo que todos os modelos apresentaram resultados insatisfatórios. Comparativamente aos resultados obtidos durante a fase de treinamentos (tabela 14), os *besfits* obtidos na validação ficaram significativamente inferiores, de modo que o modelo não conseguiu apresentar comportamento adequado frente a este tipo de sinal.

Tabela 16 – Comparativo dos *Bestfit* da validação dos modelos para a predição de ACRF da combinação 1x2

<i>Bestfit</i> (%)	Modelos Paramétricos		RNA			
	ARX215	ARMAX2221	Back-propagation			
Amostras	CAIXA 1	CAIXA 1	CAIXA 1	CAIXA 2	CAIXA 3	CAIXA 4
1° 100 m	29.17	28.91	-103.04	-317.76	23.89	-33.06
2° 100 m	19.75	19.03	-104.39	-161.01	19.07	-102.70
3° 100 m	40.81	37.67	-281.32	-156.92	37.37	-210.87
\bar{X}	29.91	28.54	-162.92	-211.90	26.78	-115.54
σ	10.55	9.33	102.54	91.70	9.49	89.60

Devido à natureza do sinal, ou seja, os dados de medições em caixa, eram esperados que ambas as técnicas utilizadas proporcionassem resultados minimamente satisfatórios. Porém, ao longo dos experimentos foi-se constatando uma grande superioridade dos modelos polinomiais frente as RNA, no quesito assertividade (*Bestfit*). Este fato, de certo modo, causou certa estranheza, uma vez que as RNA possuem grande facilidade de aprendizado e de identificação de padrões. Sendo que os resultados se mantiveram insatisfatórios mesmo quando foi aumentada a quantidade de neurônios nas camadas escondidas e quando os dados de entrada foram aumentados.

Os dados de entrada para o ensaio de atenuação possuem ruído apenas no final do espectro, o que reduz a complexidade na identificação. Porém, no caso de ACRF, a quantidade de ruído presente no sinal é muito grande, deste modo, influenciando negativamente na predição dos modelos independentemente da técnica utilizada. Foi constatado que um modelo bem identificado para uma caixa no ensaio de ACRF não responde de maneira minimamente similar em outras caixas, sendo a razão para isso são as diversas condições de processo que diferenciam as caixas durante suas produções, como: espaçamento das espiras do cabo dentro da caixa, aperto do cabo na caixa, tamanho do rolo, etc.

Idealmente seria desejável comercializar estes cabos em caixas devidamente dimensionadas, de modo que, as espiras ficassem minimamente espaçadas e que o diâmetro do rolo fosse grande o suficiente a não sofrer pela auto-indução de ruídos.

Porém, essa alternativa merece ser mais bem estudada para ver seus impactos logísticos e financeiros.

Por fim, os modelos paramétricos tiveram melhores resultados do que as RNA, devido à natureza dos sinais possuírem características muito similares a de um ruído branco filtrado por um modelo linear, de modo, que o estimador de MQ tem grande eficiência nestas condições. Ao passo que a RNA busca o aprendizado através da identificação de padrões, porém nem sempre alcançam o resultado esperado devido à natureza do problema.

5 CONCLUSÕES FINAIS

O objetivo deste trabalho era estudar modelos capazes de demonstrar a correlação existente entre as metodologias de ensaio de cabo esticado e em caixa dos importantes parâmetros de performance elétricas de cabos LAN que são atenuação e ACRF.

Foram analisados os modelos paramétricos ARX, IV e ARMAX utilizando os critérios de *Bestfit* e erro do modelo, além da avaliação do gráfico de resíduos. Além disso, foram implementadas redes neurais artificiais do tipo *feed-forward* dotadas do algoritmo de Levenberg-Marquardt para auxiliar no estudo dessa correlação.

Apesar da RNA serem conhecidas como preditores universais, ou seja, uma ferramenta que pode ser utilizada para predizer um sistema qualquer, a mesma não proporcionou resultados tão satisfatórios quanto os obtidos com os modelos paramétricos, principalmente o ARX e ARMAX, e no caso da IV houve a limitação da modelagem devido o mesmo considerar o ruído como não branco.

Através dos modelos paramétricos polinomiais foi possível encontrar uma excelente correlação entre os ensaios para o parâmetro de atenuação com o pior caso de aproximadamente 90% de assertividade. Contudo, para ACRF o resultado não foi tão bom, devido à natureza do sinal de medição, uma vez que o nível de ruído presente na medição é tão intenso que não há repetibilidade na medição e a diferença de resultados entre amostras de 100 metros e entre caixas é muito grande.

Foram analisados diferentes tipos de filtros disponíveis na *toolbox* de identificação de sistemas para reduzir a parcela de ruído o sinal, de modo, a contribuir na identificação de um modelo útil para este problema, porém não houve ganho já que partes significativas de sinal estavam sendo eliminadas e contribuindo negativamente na

modelagem, de modo, que a melhor opção foi utilizar o sinal sem nenhum tipo de filtragem.

Para as RNAs a quantidade de neurônios na camada escondida bem como a quantidade de treinamento apenas contribuiu para que a rede ficasse mais lenta, uma vez que não houve nenhuma melhora significativa.

A utilização de modelos paramétricos polinomiais é uma técnica amplamente utilizada com bastante sucesso em várias áreas do conhecimento, porém ela demanda uma dificuldade extra, já que a dificuldade inicial é encontrar um modelo adequado para o problema, e se não bastasse isso, é necessário encontrar qual a ordem deste modelo, considerando um balanço entre acurácia e complexidade. Contudo, as RNA por serem uma ferramenta universal, requerem menos conhecimentos *a priori* do problema, sendo também de fácil implementação, porém demandando do usuário a escolha da topologia de rede mais aplicável.

Por fim, esta dissertação contribuiu para o estudo da predição dos ensaios elétricos de cabos LAN, de modo a minimizar o impacto produtivo para tais fabricantes.

5.1 TRABALHOS FUTUROS

Para dar continuidade neste trabalho seria interessante realizar a modelagem dos demais parâmetros de performance elétrica de alta frequência existente nos ensaios de cabos LAN, sendo que destes se destacam Perda de Retorno e NEXT. Também seria interessante avaliar outras técnicas de modelagem que possam apresentar maior grau de aderência a natureza do problema.

REFERÊNCIAS

AGUIRRE, L., **Introdução à identificação de sistemas**. 3ª Edição revista e ampliada. Editora UFMG. 2007

ANSI/TIA-568-C.2 – Balanced Twisted-Pair Telecommunications Cabling and Components Standards. 2011.

BARRETO, J., **Introdução a Redes Neurais Artificiais**. Universidade Federal de Santa Catarina /Departamento de Informática e Estatística. 2002

CASTRO, J. WALLING, J. **Application of Generalizes Scattering Matrices for the Modeling of Twisted-pair cables**. International Wire and Cable Symposium. Proceedings 2008 JOSEFSSON, M. POLTZ, J. **Measuring and Modeling of Insertion Loss in Cables with Helical Screens**. International Wire and Cable Symposium. Proceedings 2010

DAVILA, V. **Regressão por Variáveis Instrumentais (VI)**. Instituto de Matemática e Estatística e Computação Científica, IMECC-UNICAMP. Disponível em <<http://www.ime.unicamp.br/~hlauchos/Instrumentais.pdf>>. Acesso em 14 jun. 2012.

GODDARD, T., **Statistical Process Control Techniques for on-line measurement of autocorrelated process variables**. International Wire and Cable Symposium. Proceedings 1999

HAGAN, M., MENHAJ, M., **Training feedforward networks with the Marquardt algorithm**. IEEE Transactions on Neural Networks. 1994.

HAYKIN, S., **Redes Neurais – Princípios e prática**. 2ª Edição. Editora Bookman. 2001.

JOSEFSSON, M. POLTZ, J. **Measuring and Simulation of Unbalances in Symmetrical Transmission Lines**. International Wire and Cable Symposium. Proceedings 2008

JOSEFSSON, M., POLTZ, J., BECKETT, J., **Simulation and Measurement of FEXT in Twisted Pair Cables**. International Wire and Cable Symposium. Proceedings 2004

LABORATÓRIO NACIONAL DE COMPUTAÇÃO CIENTÍFICA. **Tutorial sobre Redes Neurais - Backpropagation.** Disponível em: < http://www.lncc.br/~labinfo/tutorialRN/frm4_backpropagation.htm > Acesso em 20 abr. 2012.

LJUNG, L., **System Identification: Theory for the user.** 2nd Edition Linkoping University. Prentice Hall. 1999

LEVENBERG, K. **A method for the solution of certain non-linear problems in least squares.** Quarterly of Applied Math, Providence, 1944.

LIMA, D., **Introdução às Redes Neurais.** CBPF-NT-006/97. 1999

LUMINITA, G., MIRCEA, P., On parametric model estimation. **WSEAS International Conference on Computers.** Wisconsin, USA. 608-612. 2007

MARQUARDT, D. W. **An algorithm for least-squares estimation of nonlinear parameters.** Journal of the Society for Industrial and Applied Mathematics, Philadelphia, 1963.

NALSÉN T., **Modeling the transfer impedance of shielded cables.** International Wire and Cable Symposium. Proceedings 1999

NATIONAL INSTRUMENTS. **Selecting a Model Structure in the System Identification Process.** June 17, 2010. Disponível em < <http://www.ni.com/white-paper/4028/en> >. Acesso em 10 abr. 2012

NATIONAL UNIVERSITY OF MALAYSIA. Jul. 2011. Disponível em: < <http://www.hindawi.com/journals/ijp/2012/798361/> > Acesso em 25 abr. 2012

NORGAARD, O. RAVN, O. POULSEN, N. HANSEN, L. **Neural Networks for Modelling and Control of Dynamic Systems.** 1st Edition. Springer-Verlag London Limited. 2000.

PORTAL SÓ BIOLOGIA. **Sistema Nervoso.** Disponível em < <http://www.sobiologia.com.br/conteudos/Corpo/sistemanervoso3.php> >. Acesso em 10 abr. 2012

SODERSTROM, T., STOICA, P., **System Identification.** 2nd Edition. Prentice Hall. 2001

SUBIYANTO, S., Azah, M., Hussain, S. **Hopfield Neural Network Optimized Fuzzy Logic Controller for Maximum Power Point Tracking in a Photovoltaic System.**

ANEXO I – DADOS DE ATENUAÇÃO DO PAR 1

a) Gráficos das margens de atenuação:

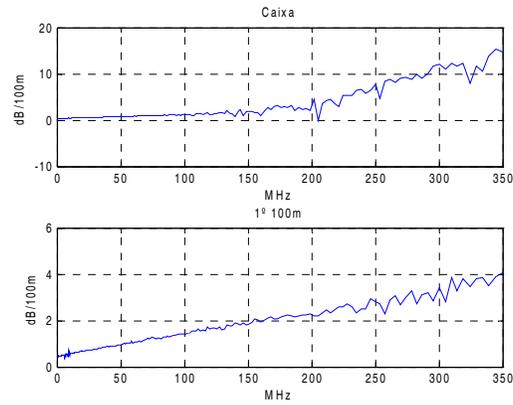


Figura 126 – Margem de atenuação no par 1 nos 1º 100m em caixa

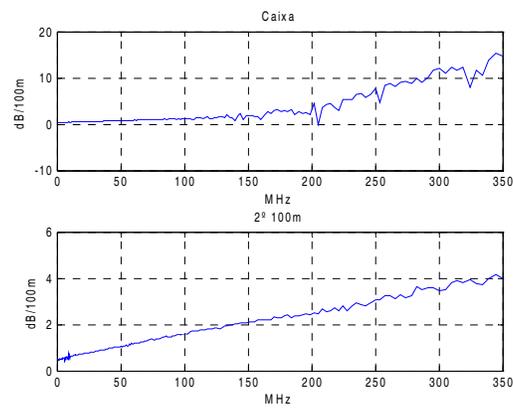


Figura 127 – Margem de atenuação no par 1 nos 2º 100m em caixa

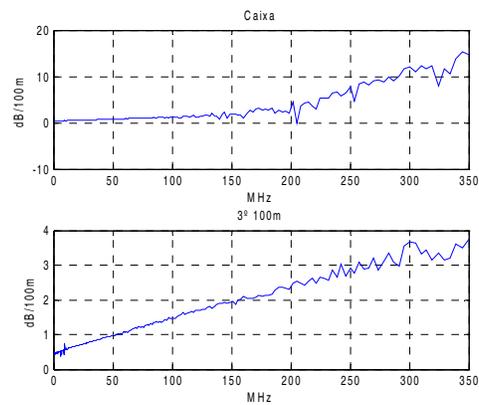


Figura 128 – Margem de atenuação no par 1 nos 3º 100m em caixa

b) Gráficos da covariância:

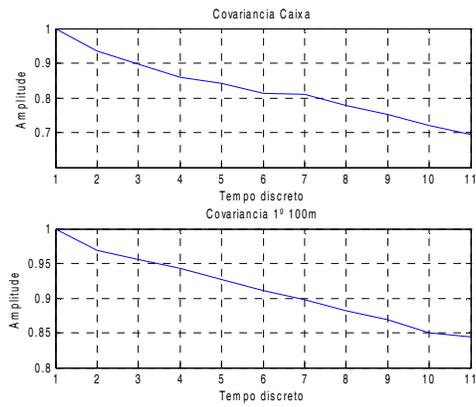


Figura 129 – Covariância da atenuação no par 1 nos 1º 100m em caixa

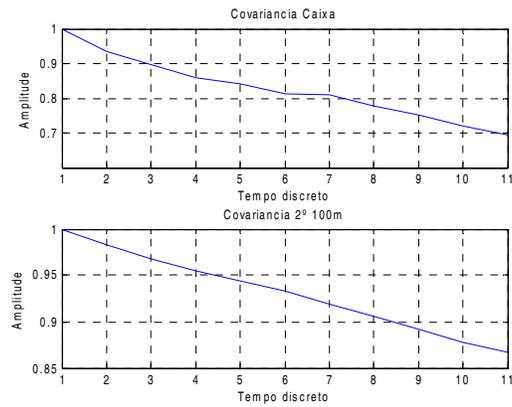


Figura 130 – Covariância da atenuação no par 1 nos 2º 100m em caixa

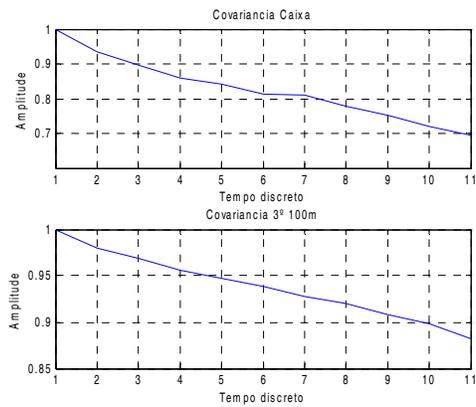


Figura 131 – Covariância da atenuação no par 1 nos 3º 100m em caixa

c) Gráficos do periodograma:

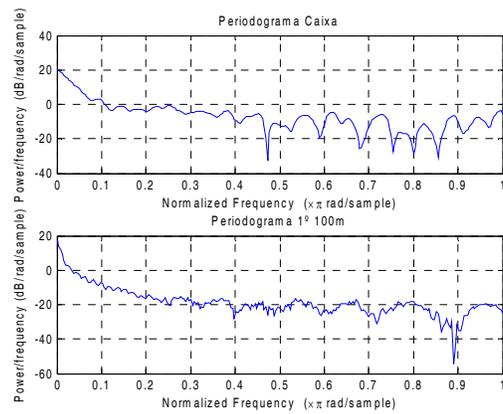


Figura 132 – Periodograma da atenuação no par 1 nos 1º 100m em caixa

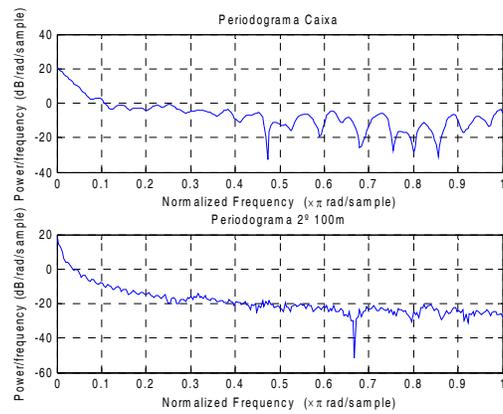


Figura 133 – Periodograma da atenuação no par 1 nos 2º 100m em caixa

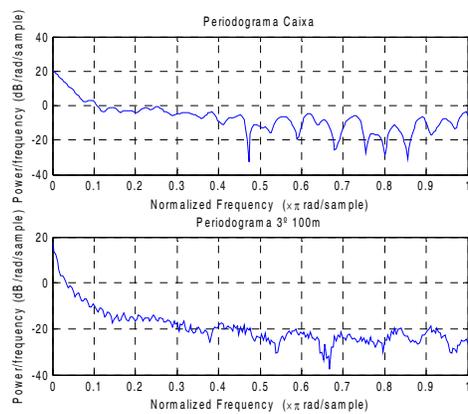


Figura 134 – Periodograma da atenuação no par 1 nos 3º 100m em caixa

ANEXO II – DADOS DE ACRF DA COMBINAÇÃO 1x2

a) Gráficos das margens de ACRF:

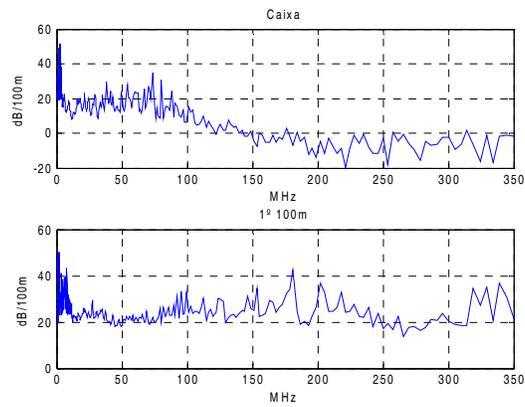


Figura 135 – Margem de ACRF na combinação 1x2 nos 1º 100m em caixa

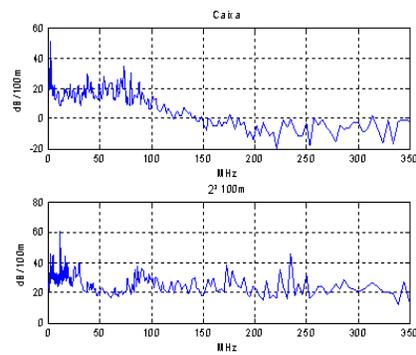


Figura 136 – Margem de ACRF na combinação 1x2 nos 2º 100m em caixa

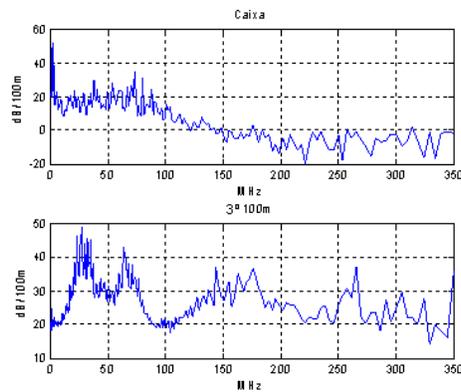


Figura 137 – Margem de ACRF na combinação 1x2 nos 3º 100m em caixa

b) Gráficos da covariância:

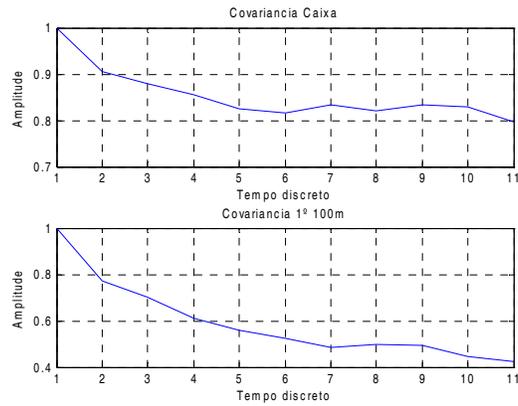


Figura 138 – Covariância de ACRF na combinação 1x2 nos 1º 100m em caixa

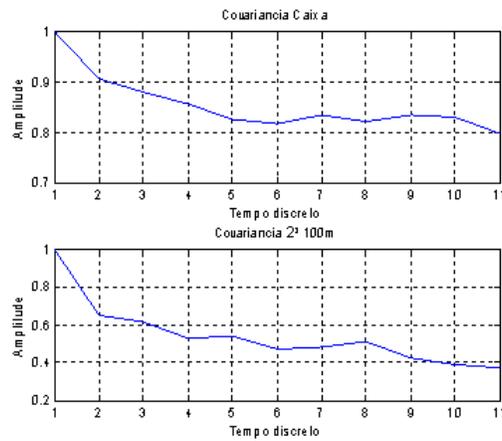


Figura 139 – Covariância de ACRF na combinação 1x2 nos 2º 100m em caixa

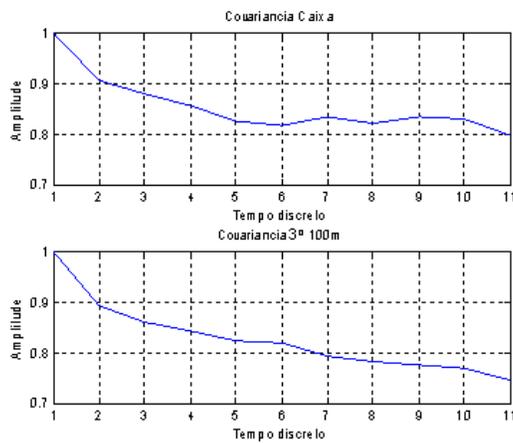


Figura 140 – Covariância de ACRF na combinação 1x2 nos 3º 100m em caixa

c) Gráficos do periodograma:

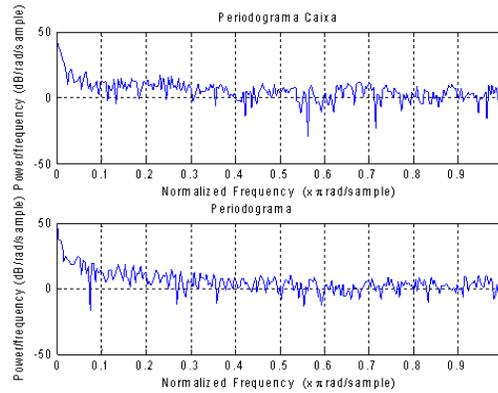


Figura 141 – Periodograma de ACRF na combinação 1x2 nos 1º 100m em caixa

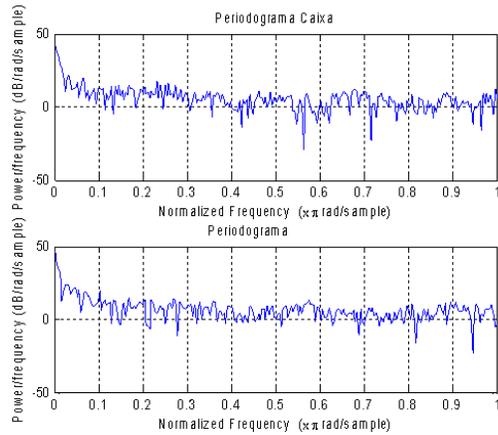


Figura 142 – Periodograma de ACRF na combinação 1x2 nos 2º 100m em caixa

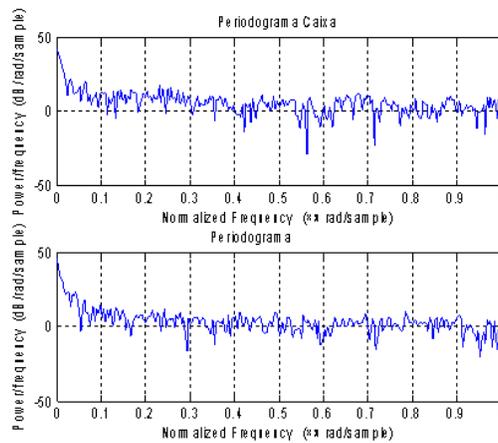


Figura 143 – Periodograma de ACRF na combinação 1x2 nos 3º 100m em caixa