

UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE ASTRONOMIA, GEOFÍSICA E CIÊNCIAS
ATMOSFÉRICAS
DEPARTAMENTO DE GEOFÍSICA

VINICIUS RAFAEL NERIS DOS SANTOS

DETECÇÃO E CLASSIFICAÇÃO AUTOMÁTICA DE
INTERFERÊNCIAS DO SUBSOLO COM GPR UTILIZANDO
REDES NEURAS ARTIFICIAIS: ESTUDO NO SCGR DO
IAG/USP

SÃO PAULO
2014

VINICIUS RAFAEL NERIS DOS SANTOS

DETECÇÃO E CLASSIFICAÇÃO AUTOMÁTICA DE
INTERFERÊNCIAS DO SUBSOLO COM GPR UTILIZANDO
REDES NEURAS ARTIFICIAIS: ESTUDO NO SCGR DO
IAG/USP

Tese apresentada ao Instituto de Astronomia,
Geofísica e Ciências Atmosféricas para
obtenção do título de Doutor em Geofísica.

Área de Concentração: Geofísica Aplicada

Orientador: Prof. Dr. Jorge Luís Porsani
(IAG/USP)

Co-orientadora: Profa. Dr. Nina S. T. Hirata
(IME/USP)

Versão corrigida

Original encontra-se disponível na Unidade

SÃO PAULO
2014

FOLHA DE APROVAÇÃO

Vinicius Rafael Neris dos Santos

Detecção e Classificação Automática de Interferências no Subsolo com GPR Utilizando Redes Neurais Artificiais: Estudo no SCGR do IAG/USP

Tese apresentada ao Instituto de Astronomia,
Geofísica e Ciências Atmosféricas para
obtenção do título de Doutor em Geofísica.
Área de Concentração: Geofísica Aplicada

Aprovado em: 31 de Março de 2014

Banca Examinadora

Prof. Dr. Jorge Luís Porsani

Instituição: IAG/USP

Prof. Dr. Antonio Abel González Carrasquilla

Instituição: UENF

Prof. Dr. Flávio Soares Correa da Silva

Instituição: IME/USP

Prof. Dr. Wladimir Shukowsky

Instituição: IAG/USP

Prof. Dr. Carlos Alberto Mendonça

Instituição: IAG/USP

AGRADECIMENTOS

Agradeço a todos que, de alguma forma direta ou indireta, contribuíram para o desenvolvimento desta pesquisa e, em especial:

Ao Prof. Dr. Jorge Luís Porsani que me orientou durante 10 anos (Graduação – IC e TG, Mestrado e Doutorado), mostrando um profundo respeito e confiança, durante todo o período de pesquisa.

A Prof. Dr. Nina S. T. Hirata, por aceitar esse novo desafio conjunto, pelas discussões, sugestões e ajuda durante o desenvolvimento da pesquisa.

Ao Prof. Dr. Waleed Al-Nuaimy pela recepção em Liverpool (Inglaterra) e toda ajuda tanto na pesquisa quanto na adaptação durante um ano em que estive na Universidade de Liverpool.

À FAPESP pela concessão da bolsa de Doutorado (processo: 2009/05882-6).

Ao CNPq pela concessão da bolsa de Doutorado Sanduíche em Liverpool (processo: 200740/2011-3).

Ao Departamento de Geofísica do Instituto de Astronomia, Geofísica e Ciências Atmosféricas pela oportunidade de realizar esta pesquisa e ao IAG pela infra-estrutura oferecida.

Às secretárias da Graduação, Pós-Graduação e do Departamento de Geofísica pelas inúmeras ajudas.

À equipe de aquisição de dados, em especial ao Ernande, Marcelo, Emerson e Cassiano pela ajuda.

A todos os amigos e colegas que fiz no IAG durante estes **10 ANOS**.

A toda minha família e a Alessandra, minha esposa, por ter aguentado as viagens de campo, os feriados e finais de semana de trabalho. Muito obrigado.

RESUMO

SANTOS, V.R.N. **Detecção e Classificação Automática de Interferências no Subsolo com GPR Utilizando Redes Neurais Artificiais: Estudo no SCGR do IAG/USP**. 2014. 217p. Tese (Doutorado) – Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2014.

Esta pesquisa foi uma continuidade dos estudos que estão sendo desenvolvidos no âmbito do Projeto de Pesquisa, já concluído, e apoiados pela FAPESP intitulado “Caracterização geofísica de alvos rasos com aplicações no planejamento urbano, meio ambiente e arqueologia: estudo sobre o sítio controlado do IAG/USP”. A presente pesquisa visa aprimorar a detecção de alvos no subsolo, determinando o tipo de material, a fim de reduzir as ambiguidades na interpretação geofísica de duas importantes famílias de alvos encontrados no ambiente urbano: os alvos resistores (manilhas de concreto, tubos e tambores de plástico) e os alvos condutores (tambores e tubulações metálicas). Esses alvos foram estudados em um ambiente controlado, no SCGR – Sítio Controlado de Geofísica Rasa do IAG/USP, através do uso do método GPR – *Ground Penetrating Radar* onde foram realizados perfis 2D sobre as linhas contendo estes alvos. Sobre esses dados foi aplicado um algoritmo, desenvolvido nesta pesquisa, que utilizando Redes Neurais Artificiais (RNAs) detectou automaticamente os alvos segundo os tipos de materiais encontrados em subsuperfície. A princípio foram determinadas as características utilizadas como parâmetros de entrada do algoritmo de RNAs, usando todos os alvos do SCGR (plásticos, metálicos e de concreto). Em seguida, tais características foram aplicadas no reconhecimento e classificação das difrações hiperbólicas. O algoritmo de treinamento baseia-se no aprendizado supervisionado por correção de erros ou *backpropagation*. Após a verificação dos resultados sob condições controladas, a rotina de RNA foi utilizada para reconhecer e classificar hiperboles em uma situação real de campo, em locais que existam alvos de plástico, metal ou concreto, sendo que estes estudos foram feitos dentro do campus da USP em São Paulo e em Pirassununga. Os resultados obtidos, em condições controladas e não controladas, apresentaram um acerto na classificação dos alvos de aproximadamente 80% e contribuirão na melhoria da interpretação de dados geofísicos e terão aplicações diretas nas áreas de planejamento urbano, infraestrutura e estudos ambientais em áreas urbanas.

Palavras Chave: GPR, RNA, Sítio controlado de Geofísica Rasa.

ABSTRACT

SANTOS, V.R.N. **Automatic detection and classification of interferences in the subsoil using GPR and Artificial Neural Networks: study on the IAG/USP test site.** 2014. 217p. Thesis (Doctoral) – Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2014.

This research is a continuation of the studies that were being carried out within the research project, already completed, and supported by FAPESP entitled "Characterization of shallow geophysical targets with applications in urban planning, environment and archeology: study on the IAG/USP test site". This research aims to improve the detection of underground targets, determining the type of material in order to reduce the ambiguities in geophysical interpretation of two important families of targets found in the urban environment: resistors targets (concrete pipes, plastic pipes and drums) and conductors targets (metal pipes and drums). These targets were studied in a controlled environment, through the use of 2D GPR - *Ground Penetrating Radar* profiles which were conducted on the lines containing these targets. An algorithm using Artificial Neural Networks (ANN) was applied on these data and it automatically detected targets according to the types of materials found in the subsurface. First, in order to recognize hyperbolic diffraction, all plastics, metal and concrete targets present in the test site were used, helping determination of characteristics that served as a parameter in the input file of the ANN algorithm. The training algorithm is based on supervised learning by error correction or *backpropagation*. After checking the results under controlled conditions, the ANN routine was used to recognize and classify hyperbolas in a real field, in places where there are plastic, metal or concrete targets and these studies were done on the campus of USP in São Paulo and in Pirassununga. The results obtained in controlled and uncontrolled conditions contributed in improving the interpretation of geophysical data and have direct applications in the areas of urban planning, infrastructure and environmental studies in urban areas.

Keywords: GPR, ANN, IAG/USP test site.

LISTA DE FIGURAS

Figura 2.1 - Localização do SCGR do IAG/USP.....	27
Figura 2.2 - Croqui esquemático mostrando a localização das sete linhas contendo os alvos instalados no SCGR do IAG/USP e o cano metálico guia. As linhas de 2 a 7 (em verde) são as linhas nas quais os estudos foram concentrados.....	29
Figura 2.3 - Esquema das linhas de estudos. a) Linha 2 – tubos de PVC. b) Linha 3 – manilhas de concreto. c) Linha 4 – tambores metálicos. d) Linha 5 – tambores plásticos. e) Linha 6 – tubos metálicos. f) Linha 7 – Tubos metálicos e cabos elétricos.....	30
Figura 4.1 - Esquema de uma unidade neural básica.....	43
Figura 4.2 - Componentes do neurônio biológico.....	46
Figura 4.3 - Exemplos de função de ativação.....	48
Figura 4.4 - Algumas arquiteturas de RNAs. a) Rede <i>feedforward</i> com uma camada de entrada e saída. b) Rede <i>feedforward</i> com uma camada de entrada e saída e uma camada intermediária. c) Rede com recorrência entre saídas e camada intermediária. d) Rede com recorrência auto-associativa.....	50
Figura 5.1 - Aquisição de dados no SCGR. a) Antena de 400 MHz. b) Antena de 200 MHz.....	65
Figura 5.2 - Aquisição de dados no SCGR. a) Antena de 900 MHz. b) Antena de 270 MHz.....	65
Figura 5.3 - Áreas escolhidas na Cidade Universitária para aquisição GPR (foto de satélite: Google Earth).....	67
Figura 5.4 - Aquisição de dados na Cidade Universitária. a) Biologia (200 MHz). b) Biologia (400 MHz). c) Praça do Relógio (200 e 400 MHz). d) CEPE (200 e 400 MHz).....	68
Figura 5.5 - Aquisição de dados na Cidade Universitária. a) Raia Olímpica (200 MHz). b) Raia Olímpica (200 e 400 MHz). c) Escola Politécnica (200 MHz). d) Escola Politécnica (400 MHz).....	68
Figura 5.6 - Exemplos de perfis GPR obtidos na Escola Politécnica. a) 200 MHz. b) 400 MHz.....	69
Figura 5.7 – Mapa de localização da cidade de Pirassununga no Estado de São Paulo.....	70
Figura 5.8 - Aquisição de dados na USP campus de Pirassununga com antenas de 270 e 900 MHz. a) Refeitório do Campus. b) Prédio do FZEA (Edifício Leste). c) Rua lateral ao Prédio Principal. d) Rua em frente ao Prédio Principal.....	71

Figura 5.9 - Exemplo de perfis GPR obtidos no campus da USP em Pirassununga. a) 270 MHz. b) 900 MHz.....	72
Figura 6.1 - Exemplos de A-scan (a) e B-scan (b) (Adaptado de DANIELS, 2007).....	73
Figura 6.2 - Exemplo de A-scan para “não alvo”. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.....	76
Figura 6.3 - Exemplo de A-scan para alvo plástico. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.....	76
Figura 6.4 - Exemplo de A-scan para alvo de concreto. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.....	77
Figura 6.5 - Exemplo de A-scan para alvo metálico. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.....	65
Figura 6.6 - Exemplo de periodograma obtido com antena de 200 MHz no período seco. a) Periodograma para traços com alvos. b) Periodograma para traços sem alvos. c) Média dos periodogramas de todos os traços (preto: com alvo e vermelho: sem alvo). d) Zoom do pico da média dos valores mostrado em c).....	80
Figura 6.7 - Exemplo de periodograma obtido com antena de 200 MHz no período seco. a) Periodograma para traços com alvos de plástico. b) Periodograma para traços com alvos de concreto. c) Periodograma para traços com alvos de metal. d) Periodograma para traços sem alvos. e) Média dos periodogramas de todos os traços (preto: plástico, vermelho: concreto, azul: metal e verde: sem alvo). f) Zoom do pico da média dos valores mostrado em e).....	81
Figura 6.8 - Exemplo de STFT para alvo metálico com antena de 200 MHz no período seco.....	83
Figura 6.9 - Exemplo de STFT para alvo metálico com antena de 200 MHz no período úmido.....	83
Figura 6.10 - Exemplo de STFT para alvo metálico com antena de 270 MHz.....	84
Figura 6.11 - Exemplo de STFT para alvo metálico com antena de 400 MHz no período seco.....	84
Figura 6.12 - Exemplo de STFT para alvo metálico com antena de 400 MHz no período úmido.....	85
Figura 6.13 - Exemplo de STFT para alvo metálico com antena de 900 MHz.....	85

Figura 6.14 - Exemplo de STFT com antena de 200 MHz no período seco para diferentes tipos de alvos. a) Plástico. b) Concreto. c) Metal. d) Sem alvo.....	86
Figura 6.15 - Exemplo de STFT para antena de 200 MHz no período seco. a) Sinal original. b) STFT em função do tempo. c) STFT em função da frequência.....	87
Figura 6.16 - Exemplo de WVD para alvo metálico com antena de 200 MHz no período seco.....	89
Figura 6.17 - Exemplo de WVD para alvo metálico com antena de 200 MHz no período úmido.....	89
Figura 6.18 - Exemplo de WVD para alvo metálico com antena de 270 MHz.....	90
Figura 6.19 - Exemplo de WVD para alvo metálico com antena de 400 MHz no período seco.....	90
Figura 6.20 - Exemplo de WVD para alvo metálico com antena de 400 MHz no período úmido.....	91
Figura 6.21 - Exemplo de WVD para alvo metálico com antena de 900 MHz.....	91
Figura 6.22 - Exemplo de WVD com antena de 200 MHz no período seco para diferentes tipos de alvos. a) Plástico. b) Concreto. c) Metal. d) Sem alvo.....	92
Figura 6.23 - Exemplo de WVD para antena de 200 MHz no período seco. a) Sinal original. b) WVD em função do tempo. c) WVD em função da frequência.....	93
Figura 6.24 - Exemplo de WT para alvo metálico com antena de 200 MHz no período seco. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).....	95
Figura 6.25 - Exemplo de WT para alvo metálico com antena de 200 MHz no período úmido. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).....	96
Figura 6.26 - Exemplo de WT para alvo metálico com antena de 270 MHz. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).....	97
Figura 6.27 - Exemplo de WT para alvo metálico com antena de 400 MHz no período seco. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).....	98
Figura 6.28 - Exemplo de WT para alvo metálico com antena de 400 MHz no período úmido. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).....	99
Figura 6.29 - Exemplo de WT para alvo metálico com antena de 900 MHz. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).....	100
Figura 6.30 - Exemplo de WT para antena de 200 MHz no período seco sem alvo. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).....	101

Figura 7.1 – Ajuste da função seno com 100 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente....	104
Figura 7.2 – Ajuste da função seno com 1.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	105
Figura 7.3 – Ajuste da função seno com 10.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	106
Figura 7.4 – Ajuste da função seno com 100.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	107
Figura 7.5 – Ajuste da função seno com ruído, 100 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	108
Figura 7.6 – Ajuste da função seno com ruído, 1.000 iterações e arquitetura 1-3-1. a) Saídas deseja (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	109
Figura 7.7 – Ajuste da função seno com ruído, 10.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	110
Figura 7.8 – Ajuste da função seno com ruído, 100.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	111
Figura 7.9 – Ajuste da função seno com ruído, 100.000 iterações e arquitetura 1-15-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	112
Figura 7.10 – Ajuste da função seno com ruído, 100.000 iterações e arquitetura 1-3-1. a) Saídas desejada (1257 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	113
Figura 7.11 – Ajuste da função seno com ruído, 100.000 iterações e arquitetura 1-3-5-1. a) Saídas desejada (1257 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.....	114

Figura 7.12 – Esquema das etapas de identificação e classificação do programa NC_GPR.....	117
Figura 7.13 – Esquema da rede neural final utilizada para identificação de alvos.....	119
Figura 7.14 – Rede neural 11-30-1 utilizando A-scans. a) Variação dos erros de treinamento, validação e teste. b) Variação do gradiente. c) Saídas calculadas pela rede.....	120
Figura 7.15 – Ajuste de hipérboles. a) Modelo gerado. b) Ajuste obtido a partir do dado original.....	122
Figura 7.16 – Ajuste obtido a partir de dados reais selecionados pela RNA.....	122
Figura 7.17 – Linha 2, 200 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	124
Figura 7.18 – Linha 3, 270 MHz. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	125
Figura 7.19 – Linha 4, 200 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	126
Figura 7.20 – Linha 4, 200 MHz, período de chuva. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	127
Figura 7.21 – Linha 4, 270 MHz. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	128
Figura 7.22 – Linha 4, 400 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	129
Figura 7.23 – Linha 4, 400 MHz, período de chuva. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	130
Figura 7.24 – Linha 5, 400 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	131
Figura 7.25 – Linha 6, 200 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	132
Figura 7.26 – Linha 7, 200 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.....	133
Figura 7.27 – Esquema da rede neural final utilizada para classificação de hipérboles.....	137
Figura 7.28 – Rede neural 11-40-3 utilizando A-scans. a) Variação dos erros de treinamento, validação e teste. b) Variação do gradiente.....	138

Figura 7.29 – Classificação obtida pelo NC_GPR para a Linha 2 (tubos de PVC), utilizando antena de 200 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).....	140
Figura 7.30 – Classificação obtida pelo NC_GPR para a Linha 3 (manilhas de concreto), utilizando antena de 270 MHz (vermelho: plástico, magenta: concreto, azul: metal).....	141
Figura 7.31 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 200 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).....	142
Figura 7.32 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 200 MHz, no período de chuva (vermelho: plástico, magenta: concreto, azul: metal).....	143
Figura 7.33 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 270 MHz (vermelho: plástico, magenta: concreto, azul: metal).....	144
Figura 7.34 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 400 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).....	145
Figura 7.35 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 400 MHz, no período de chuva (vermelho: plástico, magenta: concreto, azul: metal).....	146
Figura 7.36 – Classificação obtida pelo NC_GPR para a Linha 5 (tambores plásticos), utilizando antena de 400 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).....	147
Figura 7.37 – Classificação obtida pelo NC_GPR para a Linha 6 (tubos metálicos), utilizando antena de 200 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).....	148
Figura 7.38 – Classificação obtida pelo NC_GPR para a Linha 7 (tubos metálicos e cabos elétricos), utilizando antena de 200 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).....	149
Figura 7.39 – Local da aquisição com antena de 200 MHz na rotatória da Biologia no Campus USP da Capital.....	151
Figura 7.40 – Classificação do perfil GPR com antena de 200 MHz na rotatória da Biologia no Campus USP da Capital.....	151

Figura 7.41 – Local da aquisição com antena de 400 MHz na rotatória da Biologia no Campus USP da Capital.	152
Figura 7.42 – Classificação do perfil GPR com antena de 400 MHz na rotatória da Biologia no Campus USP da Capital.	152
Figura 7.43 – Local da aquisição com antena de 200 MHz próximo à Praça do Relógio no Campus USP da Capital.	153
Figura 7.44 – Classificação do perfil GPR com antena de 200 MHz próximo à Praça do Relógio no Campus USP da Capital.	153
Figura 7.45 – Local da aquisição com antena de 400 MHz no prédio do IAG no Campus USP da Capital.	154
Figura 7.46 – Classificação do perfil GPR com antena de 400 MHz no prédio do IAG no Campus USP da Capital.	154
Figura 7.47 – Local da aquisição com antena de 200 MHz na POLI no Campus USP da Capital.	155
Figura 7.48 – Classificação do perfil GPR com antena de 200 MHz na POLI no Campus USP da Capital.	155
Figura 7.49 – Local da aquisição com antena de 200 MHz na POLI no Campus USP da Capital.	156
Figura 7.50 – Classificação do perfil GPR com antena de 400 MHz na POLI no Campus USP da Capital.	156
Figura 7.51 – Local da aquisição com antena de 270 MHz e detalhe da manilha de concreto no Campus USP de Pirassununga.	158
Figura 7.52 – Classificação do perfil GPR com antena de 270 MHz sobre uma manilha de concreto no Campus USP de Pirassununga.	158
Figura 7.53 – Local da aquisição com antena de 270 MHz no corredor com colunas de concreto no Campus USP de Pirassununga.	159
Figura 7.54 – Classificação do perfil GPR com antena de 270 MHz no corredor com colunas de concreto no Campus USP de Pirassununga.	159
Figura 7.55 – Local da aquisição com antena de 270 MHz no Campus USP de Pirassununga.	160
Figura 7.56 – Classificação do perfil GPR com antena de 270 MHz no Campus USP de Pirassununga.	160

Figura 7.57 – Local da aquisição com antena de 270 MHz e detalhe do tubo de PVC no Campus USP de Pirassununga.....	161
Figura 7.58 – Classificação do perfil GPR com antena de 270 MHz do tubo de PVC no Campus USP de Pirassununga.....	161
Figura 7.59 – Classificação do perfil GPR com antena de 900 MHz em solo arenoso para um alvo metálico.....	162
Figura 7.60 – Classificação do perfil GPR com antena de 900 MHz em solo arenoso para um alvo metálico.....	163
Figura A.1 – Exemplo da variação da janela para o cálculo da STFT para dado obtido com antena de 200 MHz no período seco. a) Janela de 10 amostras. b) Janela de 53 amostras (correto). c) Janela de 200 amostras.....	183
Figura G.1 – Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 200 MHz, em ambiente seco.....	191
Figura G.2 – Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 200 MHz, em ambiente úmido.....	191
Figura G.3 – Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 270 MHz.....	192
Figura G.4 – Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 400 MHz, em ambiente seco.....	192
Figura G.5 – Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 400 MHz, em ambiente úmido.....	193
Figura G.6 – Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 900 MHz.....	193
Figura G.7 – Perfis GPR (direção X, alvo 1) sobre a Linha 2 – tubos de PVC. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.....	194
Figura G.8 – Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 200 MHz, em ambiente seco.....	195
Figura G.9 – Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 200 MHz, em ambiente úmido.....	195
Figura G.10 – Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 270 MHz.....	196

Figura G.11 – Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 400 MHz, em ambiente seco.....	196
Figura G.12 – Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 400 MHz, em ambiente úmido.....	197
Figura G.13 – Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 900 MHz.....	197
Figura G.14 – Perfis GPR (direção X, alvo 17) sobre a Linha 3 – manilhas de concreto. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.....	198
Figura G.15 – Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 200 MHz, em ambiente seco.....	199
Figura G.16 – Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 200 MHz, em ambiente úmido.....	199
Figura G.17 – Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 270 MHz.....	200
Figura G.17 – Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 400 MHz, em ambiente seco.....	200
Figura G.18 – Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 400 MHz, em ambiente seco.....	201
Figura G.19 – Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 900 MHz.....	201
Figura G.20 – Perfis GPR (direção X, alvo 30) sobre a Linha 4 – tambores metálicos. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.....	202
Figura G.21 – Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 200 MHz, em ambiente seco.....	203
Figura G.22 – Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 200 MHz, em ambiente úmido.....	203
Figura G.23 – Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 270 MH.....	204

Figura G.24 – Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 400 MHz, em ambiente seco.....	204
Figura G.25 – Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 400 MHz, em ambiente úmido.....	205
Figura G.26 – Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 900 MHz.....	205
Figura G.27 – Perfis GPR (direção X, alvo 38) sobre a Linha 5 – tambores plásticos. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.....	206
Figura G.28 – Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 200 MHz, em ambiente seco.....	207
Figura G.29 – Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 200 MHz, em ambiente úmido.....	207
Figura G.30 – Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 270 MHz.....	208
Figura G.31 – Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 400 MHz, em ambiente seco.....	208
Figura G.32 – Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 400 MHz, em ambiente úmido.....	209
Figura G.33 – Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 900 MHz.....	209
Figura G.34 – Perfis GPR (direção X, alvo 43) sobre a Linha 6 – tubos metálicos. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.....	210
Figura G.35 – Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 200 MHz, em ambiente seco.....	211
Figura G.36 – Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 200 MHz, em ambiente úmido.....	211
Figura G.37 – Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 270 MHz.....	212
Figura G.38 – Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 400 MHz, em ambiente seco.....	212

Figura G.39 – Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 400 MHz, em ambiente úmido.....	213
Figura G.40 – Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 900 MHz.....	213
Figura G.41 – Perfis GPR (direção X, alvo 51) sobre a Linha 7 – tubos metálicos e cabos elétricos. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.....	214

LISTA DE TABELAS

Tabela 4.1 – Eventos históricos relacionados à RNAs (RAUBER, 1998).....	45
Tabela 4.2 – Fases relacionadas à RNAs (RAUBER, 1998).....	45
Tabela 5.1 – Número de perfis adquiridos na área do SCGR.....	66
Tabela 5.2 – Número de perfis adquiridos na área da Cidade Universitária.....	67
Tabela 6.1 – Número de A-scans utilizados para a determinação das características utilizando antenas de 200 e 400 MHz.....	74
Tabela 6.2 – Número de A-scans utilizados para a determinação das características utilizando antenas de 270 e 900 MHz.....	74
Tabela 7.1 – Resumo dos testes realizado com a rede neural artificial desenvolvida (backpropagation com gradiente descendente e momentum) para o ajuste da função seno.....	116
Tabela 7.2 – Erro quadrático médio de validação (EQMv), tempo de treinamento e número de iterações dos testes realizados com a rede neural artificial desenvolvida utilizando A-scans.....	118
Tabela 7.3 – Tempo de identificação de hipérboles dos exemplos mostrados.....	134
Tabela 7.4 – Matriz de confusão para a identificação dos alvos.....	134
Tabela 7.5 – Erro quadrático médio de validação (EQMv) e tempo de treinamento dos testes realizados com a rede neural artificial desenvolvida utilizando A-scans.....	136
Tabela 7.6 – Erro quadrático médio de validação (EQMv) e tempo de treinamento dos testes realizados com a rede neural artificial desenvolvida utilizando A-scans.....	136
Tabela 7.7 – Matriz de confusão para a classificação dos alvos.....	150
Tabela 7.8 – Tempo de identificação e classificação das anomalias dos exemplos mostrados.....	163
Tabela B.1 – Valores calculados para a janela STFT (win em amostras) para as diferentes frequências GPR.....	188

APRESENTAÇÃO

A presente tese está organizada em oito capítulos que se referem ao agrupamento temático, não correspondendo, necessariamente, à ordem cronológica em que foi desenvolvida a pesquisa. Essa forma de apresentação foi escolhida a fim de sistematizar o conteúdo abordado de forma mais objetiva.

No capítulo 1 tem-se a introdução ao problema proposto, com os objetivos e a justificativa da pesquisa.

O capítulo 2 traz uma descrição sobre o Sítio Controlado de Geofísica Rasa do Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo (SCGR do IAG/USP). Nesse capítulo, é apresentada uma descrição da geologia da área, bem como, as informações acerca das linhas de estudo, com os tipos de alvos e as respectivas características.

No capítulo 3 é apresentada uma revisão bibliográfica contendo diversos trabalhos na área de Geofísica e Reconhecimento de Padrões utilizando Redes Neurais Artificiais (RNA), pois esse estudo se fez necessário devido a não familiaridade com o assunto dos pesquisadores brasileiros da área de Geofísica.

Os fundamentos teóricos da metodologia GPR – *Ground Penetrating Radar* e das Redes Neurais Artificiais – RNA são apresentados no capítulo 4.

No capítulo 5, são apresentados os parâmetros de campo utilizados na aquisição de dados, tanto no SCGR, quanto no campus da USP em São Paulo e em Pirassununga.

No capítulo 6, são descritas as ferramentas de processamento de sinais utilizadas para a extração das características que serviram como entrada para a RNA.

As metodologias utilizadas para a detecção e classificação de hipérboles estão apresentadas no capítulo 7.

As conclusões e as recomendações do estudo estão apresentadas no capítulo 8.

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTES TRABALHOS, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

SUMÁRIO

CAPÍTULO 1

1. INTRODUÇÃO.....	22
1.1 OBJETIVOS.....	25

CAPÍTULO 2

2. ÁREA DE ESTUDO.....	27
2.1 SCGR DO IAG/USP.....	27
2.2 LINHAS DE ESTUDO.....	29

CAPÍTULO 3

3. REVISÃO BIBLIOGRÁFICA.....	32
-------------------------------	----

CAPÍTULO 4

4. METODOLOGIAS.....	38
4.1 MÉTODO GPR.....	38
4.1.1 Princípios eletromagnéticos do GPR.....	38
4.2 REDES NEURAIS ARTIFICIAIS.....	42
4.2.1 Histórico.....	42
4.2.2 Motivação – inspiração biológica.....	45
4.2.3 Modelagem matemática.....	46
4.2.4 Arquiteturas de RNAs.....	48
4.2.5 Aprendizado.....	51
4.2.6 MLP – Multilayer Perceptron.....	56

CAPÍTULO 5

5. AQUISIÇÃO E PROCESSAMENTO DOS DADOS.....	64
5.1 SCGR DO IAG/USP.....	64
5.2 USP CAMPUS SÃO PAULO.....	67
5.3 USP CAMPUS PIRASSUNUNGA.....	69

CAPÍTULO 6

6. EXTRAÇÃO DE CARACTERÍSTICAS.....	73
6.1 CARACTERÍSTICAS ESTATÍSTICAS.....	78
6.2 CARACTERÍSTICAS ESPECTRAIS.....	78
6.2.1 Densidade Espectral – PSD (<i>Power Spectral Density</i>).....	79

6.2.2 Transformada de Fourier no tempo curto – STFT (<i>Short-time Fourier Transform</i>).....	82
6.2.3 Distribuição Wigner-Ville – WVD (<i>Wigner-Ville Distribution</i>)...	88
6.2.4 Transformada da Wavelet – WT (<i>Wavelet Transform</i>).....	94

CAPÍTULO 7

7. NC_GPR – NEURAL CLASSIFIER GPR.....	102
7.1 ANÁLISE DA REDE NEURAL.....	102
7.2 IDENTIFICAÇÃO DE HIPÉRBOLES.....	118
7.3 CLASSIFICAÇÃO DE HIPÉRBOLES.....	134
7.4 APLICAÇÕES DO NC_GPR.....	150

CAPÍTULO 8

9. CONCLUSÕES E RECOMENDAÇÕES.....	165
REFERÊNCIAS BIBLIOGRÁFICAS.....	167
APÊNDICES.....	178

CAPÍTULO 1

1. INTRODUÇÃO

O processo de expansão das grandes cidades tem se dado de forma rápida e desordenada. Com a ocupação territorial não planejada houve a necessidade de se melhorar a infraestrutura da subsuperfície por meio de obras geotécnicas, por exemplo, ampliações das linhas do metrô, instalação de cabos elétricos e telefônicos, gasodutos, galerias de água e esgoto, etc.

Com a instalação de novas obras subterrâneas fica evidente o aparecimento de acidentes relacionados com o rompimento de cabos, tubulações pré-existentes de água, esgoto ou gás, trazendo prejuízos financeiros, transtornos no trânsito, além de colocar a vida da população em risco. Assim, a Geofísica Aplicada pode minimizar a ocorrência de incidentes através do uso de métodos não destrutivos para caracterização da subsuperfície, visando à localização de interferências no subsolo e zonas de contaminação ambiental.

Segundo REYNOLDS (1997) as principais vantagens dos métodos geofísicos são o baixo custo e a rapidez nos levantamentos de campo. Por outro lado, o emprego dos métodos geofísicos em áreas urbanas apresenta algumas limitações, devido a grande quantidade de ruídos eletromagnéticos (ondas de telefonia celular e transmissoras de rádio) ou ruídos culturais (edificações de grande porte e ruas movimentadas) que podem comprometer a qualidade dos dados, bem como a ambiguidade encontrada na interpretação dos resultados. Dessa forma, os estudos para minimizar tais problemas nos levantamentos geofísicos em áreas urbanas têm caminhado para pesquisas realizadas em locais controlados. Vários pesquisadores pelo mundo já realizaram e vem realizando estudos em áreas com tais características, dentre os quais podemos citar BOWDERS et al., 1982; DANIELS et al., 1994; GRANDJEAN et al., 2000; RADZEVICIUS & DANIELS, 2000; GERBER et al., 2004; PANIAGUA et al., 2004; PORSANI et al., 2006, 2008, 2010, 2012; RODRIGUES & PORSANI, 2006; PORSANI & SAUCK, 2007; NASER & JUNGE, 2008; SANTOS & PORSANI, 2011; dentre outros.

No campus da Universidade de São Paulo (USP), na capital paulista, foi instalada a primeira área para testes controlados de geofísica rasa do Brasil, onde foram enterrados alvos normalmente encontrados nos grandes centros urbanos. O Sítio Controlado de Geofísica Rasa- SCGR do Instituto de Astronomia, Geofísica e Ciências Atmosféricas da USP teve como objetivos simular problemas geotécnicos, ambientais e arqueológicos através da instalação de sete linhas de estudos constituídas por diferentes materiais enterrados, como cabos elétricos e de fibra ótica, tubulações metálicas e de PVC, tambores plásticos e metálicos, manilhas de concreto e materiais que simulam alvos arqueológicos. Detalhes sobre a instalação do SCGR do IAG/USP e resultados geofísicos podem ser encontrados em PORSANI et al, 2006, BORGES, 2007, dentre outros.

Apesar de sua recente construção já foram realizados diversos estudos, sendo contabilizadas até o momento, quatro dissertações de mestrado (RODRIGUES, 2004; SILVA, 2004; LIMA, 2006; SANTOS, 2009), uma tese de doutorado (BORGES, 2007) e várias publicações (PORSANI et al., 2006, 2010; RODRIGUES & PORSANI, 2006; PORSANI & SAUCK, 2007, SANTOS & PORSANI, 2011, SANTOS et al., 2014, dentre outras), os quais geraram importantes resultados. Além das pesquisas realizadas, esta área de estudos, certamente, comportará outras pesquisas em geofísica rasa.

Nesta pesquisa o método geofísico GPR foi empregado de maneira conjunta às RNAs - Redes Neurais Artificiais, com objetivos de aprimorar a detecção e conseqüentemente minimizar as ambigüidades presentes nas interpretações dos resultados geofísicos por meio de classificação automática dos alvos. A metodologia GPR foi empregada sobre duas importantes famílias de alvos instaladas no SCGR do IAG/USP, os alvos resistores, como as manilhas de concreto, tambores e tubos de plástico e os alvos condutores, como os tambores e tubulações metálicas. Os alvos simulam situações reais do dia-a-dia na área do planejamento urbano, infraestrutura e de estudos de contaminação do meio ambiente.

A escolha desses alvos se deve à importância que eles possuem no ambiente urbano, pois as manilhas de concreto constituem as galerias de canalização de águas pluviais e redes de esgotos, as tubulações metálicas são responsáveis pelo transporte de água potável, enquanto, os tambores metálicos e plásticos podem abrigar diferentes tipos de resíduos e contaminantes.

No método GPR, o procedimento padrão de aquisição de dados vêm sendo frequentemente utilizado por pesquisadores do mundo todo, por apresentarem resultados satisfatórios na solução de grande parte dos problemas científicos em vários campos de aplicações. Entretanto, em estudos de sítios controlados, como por exemplo, no mapeamento e identificação de redes de interferências enterradas no subsolo, tais como, manilhas de concreto, tambores metálicos e plásticos, tubulações etc., os métodos convencionais de tratamento dos dados nem sempre apresentam resultados satisfatórios devido à complexidade nos padrões de reflexão do sinal eletromagnético, gerando as ambiguidades na interpretação dos resultados.

Neste sentido, as RNAs são uma ferramenta computacional muito importante para minimizar as ambiguidades presentes no cotidiano da Geofísica Rasa. Este recurso é utilizado largamente nas ciências exatas e biológicas e são sistemas computacionais que “imitam” as habilidades do sistema nervoso biológico, utilizando um grande número de simples neurônios artificiais interconectados. De uma maneira geral pode se dizer que as RNAs funcionam com a aprendizagem e a generalização. Nesta pesquisa de doutorado foram empregadas as etapas de reconhecimento de hipérboles e uma vez reconhecidas, estas foram classificadas automaticamente por meio de rotinas computacionais previamente treinadas. Nesta linha de pesquisa podemos citar os trabalhos de AI-NUAIMY et al., 2000a; GAMBA & LOSSANI, 2000 e YOUN & CHEN, 2004.

O reconhecimento e classificação dos padrões de reflexões envolveu o estudo de algumas características referentes a um determinado tipo alvo. As características utilizadas foram: estatísticas (variância, desvio médio absoluto e quarto momento) e espectrais (densidade espectral, transformada de Fourier no tempo curto, distribuição Wigner-Ville e a transformada da wavelet). A metodologia proposta fez uso do algoritmo *backpropagation* (RUMELHART et al., 1986; CHAUVIN & RUMELHART, 1995), que consiste de uma aprendizagem supervisionada da RNA.

A partir dos resultados obtidos em local controlado, foi aplicada a RNA em dados reais coletados em locais sob condições não controladas, ou seja, numa situação real do dia-a-dia. No Campus da USP existem registros de manilhas de concreto e tubulações metálicas onde foi possível realizar este estudo a fim de validar a RNA. Esses locais de aquisição GPR foram definidos contando com o apoio da Prefeitura do

Campus da USP, com o Sr. Nelson Carlos Assumpção Junior do COCESP (Coordenadoria do Campus da Capital do Estado de São Paulo) e do Prof. Carlos Bezerra de Albuquerque do CEPE (Centro de Práticas Esportivas da USP).

Outro local escolhido para realizar os testes do algoritmo foi no Campus USP em Pirassununga. O local foi escolhido para verificar a aplicabilidade da rede em um ambiente geológico diferente da que foi submetido o treinamento. Os dados foram adquiridos com o auxílio da Sra. Marta R. B. K. Guiguer da Divisão de Manutenção e Operação (Divisão de Infraestrutura da Prefeitura do Campus) e do Sr. Renato Nascimento Rodrigues, Chefe Técnico da Divisão Produção Agropecuária da Prefeitura do Campus USP em Pirassununga.

Os resultados obtidos nesta pesquisa, sob condições controladas de campo, contribuem com a nossa habilidade em interpretar dados geofísicos rasos e poderão ser extrapolados para áreas onde não se têm informações da subsuperfície. Esta pesquisa terá implicações importantes e poderá auxiliar nas futuras aplicações do GPR em estudos geotécnicos e ambientais, por exemplo, na detecção automática de redes subterrâneas instaladas no subsolo dos grandes centros urbanos.

1.1 OBJETIVOS

Nesta pesquisa de doutorado o método geofísico GPR foi empregado utilizando-se uma nova abordagem de tratamento de dados, com o auxílio de redes neurais artificiais – RNAs. Por meio da técnica de aquisição de dados 2D, os principais objetivos consistem em melhorar a interpretação de dados, minimizando a ambiguidade de alvos condutores (metal) e resistores (plástico e concreto) instalados no Sítio Controlado de Geofísica Rasa - SCGR do IAG/USP. A metodologia geofísica foi empregada sobre as linhas de manilhas de concreto, tambores metálicos e plásticos, e tubulações metálicas e plásticas instaladas no SCGR.

Para alcançar os objetivos propostos, foram desenvolvidas as seguintes atividades:

- i) Aquisição GPR 2D com as antenas de 200, 270, 400 e 900 MHz, nas linhas de manilhas de concreto, tambores metálicos e plásticos e tubulações metálicas e plásticas no SCGR, nas direções X, Y;
- ii) Extração de características provenientes das hipérboles geradas pelos alvos no SCGR;
- iii) Desenvolvimento de um algoritmo para reconhecimento de hipérbole utilizando RNAs;
- iv) Desenvolvimento de um algoritmo para classificação de alvos no subsolo utilizando RNAs;
- v) Aplicação dos algoritmos em ambientes não controlados (Campus USP/SP e USP/Pirassununga).

CAPÍTULO 2

2. ÁREA DE ESTUDO

2.1 SCGR DO IAG/USP

O Sítio Controlado de Geofísica Rasa-SCGR do IAG/USP está localizado no campus da USP, em um terreno cedido pelo Instituto de Física (IF), em frente ao IAG (Figura 1). Segundo MARCELINO (1999) o campus está situado sobre as formações São Paulo e Itaquaquecetuba, ambas, evidenciadas pelos afloramentos localizados, respectivamente, ao sul e ao norte da Cidade Universitária. Dessa maneira, devido o SCGR situar-se na zona sul do campus, este está contido sobre a borda da bacia sedimentar de São Paulo, a qual compreende uma porção do *rift* continental do Sudeste do Brasil, formada na era Cenozóica (IRITANI, 1993).

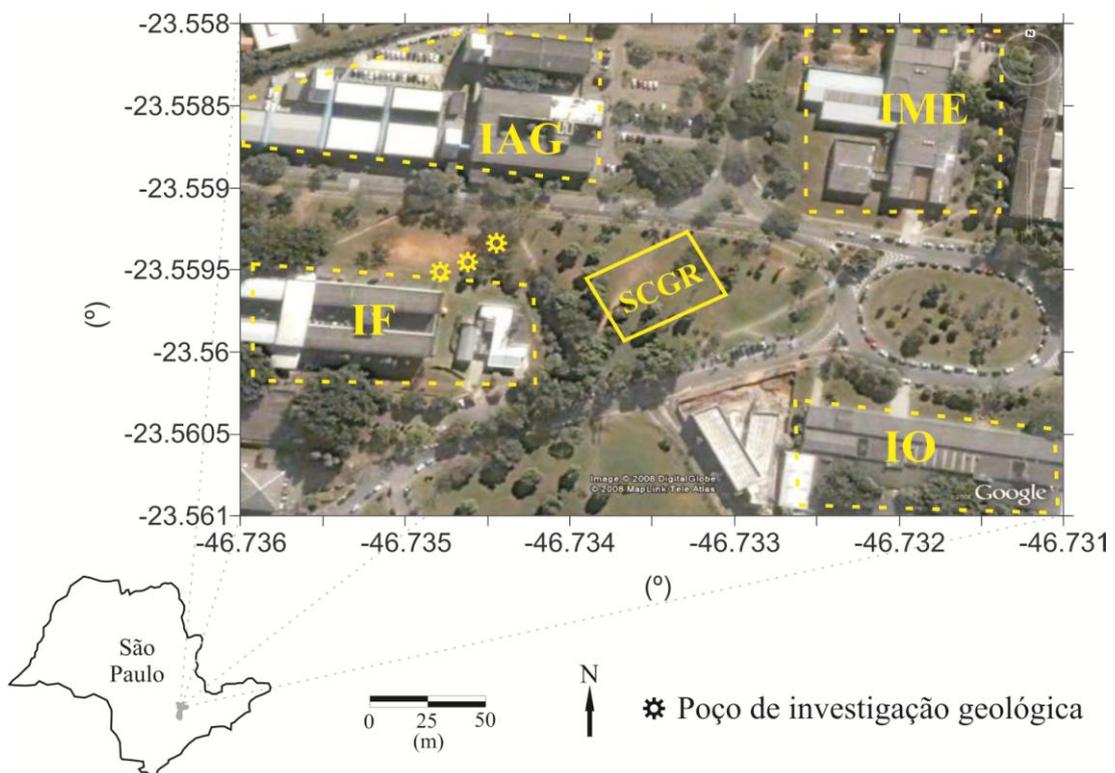


Figura 2.1 - Localização do SCGR do IAG/USP.

A geologia da área de testes controlados foi efetivamente estudada, através da perfuração de três poços de investigações geológicas e geofísicas que serviram para estabelecer perfis litológicos, nos quais BORGES (2002), através das informações desses poços, juntamente com furos de sondagens a trado e metodologias geofísicas estimou, na porção sul do campus, a profundidade da base do aterro e o topo da camada de areia grossa por meio do método GPR. Além disso, foram delimitados os horizontes resistivos e condutivos da Bacia de São Paulo na área do SCGR, sendo que a partir da profundidade de 43 metros foi obtido o valor de resistividade de, aproximadamente, 2500 ohm.m, indicando o topo do embasamento granito-gnáissico.

Após a integração de dados GPR, sísmica (reflexão e refração), eletrorresistividade e perfilagens de poços, ficou evidenciado pelas perfilagens que a espessura do pacote de sedimentos contidos na área de instalação do sítio controlado não excede os 53 metros de profundidade (PORSANI et al., 2004). Dessa maneira, foi determinado que a área do SCGR é composta por um aterro caracterizado por argila arenosa a siltosa com espessura inferior a 3 metros. Uma cobertura neocenozóica é observada até 6 metros de profundidade, sendo constituída por argilas enriquecidas em matéria orgânica. A partir daí, predominam 47 metros de sedimentos areno-argilosos (formações Resende e São Paulo), sobrepostos ao embasamento granito-gnáissico.

Os diversos objetos implantados nas linhas de estudos do SCGR do IAG/USP foram escolhidos visando simular alvos normalmente encontrados em ambiente urbano, tais como, alvos geotécnicos, arqueológicos, situações de contaminação ambiental, etc. Assim, nessa área foram instaladas sete linhas de estudos: arqueologia (linha 1), tubulações de PVC (linha 2), manilhas de concreto (linha 3), tambores metálicos (linha 4), tambores plásticos (linha 5), tubulações metálicas (linha 6), cabos elétricos, hidráulicos e conduítes de PVC (linha 7). Informações detalhadas sobre a instalação do SCGR do IAG, bem como resultados geofísicos são encontrados em PORSANI *et al.* (2006), RODRIGUES & PORSANI (2006), PORSANI & SAUCK (2007), BORGES (2007), SANTOS (2009), PORSANI *et al.* (2010), SANTOS & PORSANI (2011).

2.2 LINHAS DE ESTUDO

O SCGR possui uma área total de 1500 m² (30 m x 50 m) e é composto por sete linhas contendo diferentes materiais como descritos anteriormente (Figura 2.2). As profundidades dos topos dos alvos variam de 0,5 metro a 2 metros e na posição de 15 metros (NS) foi enterrado um cano metálico guia de 3,8 cm de diâmetro, que serve de referência para os levantamentos geofísicos que vierem a ser realizados. Neste trabalho foram utilizadas seis linhas para os levantamentos geofísicos (linhas 2 a 7), caracterizadas por materiais plásticos, metálicos e de concreto (Figura 2.3).

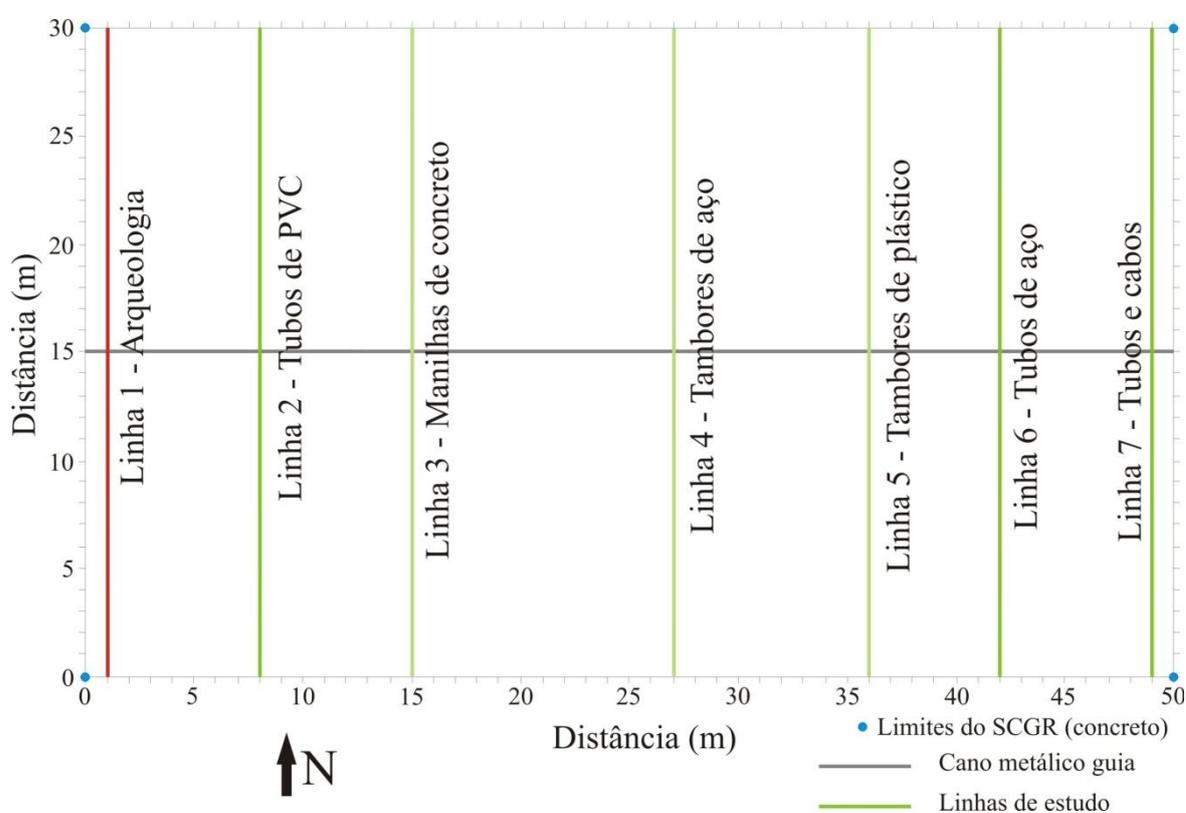


Figura 2.2 - Croqui esquemático mostrando a localização das sete linhas contendo os alvos instalados no SCGR do IAG/USP e o cano metálico guia. As linhas de 2 a 7 (em verde) são as linhas nas quais os estudos foram concentrados.

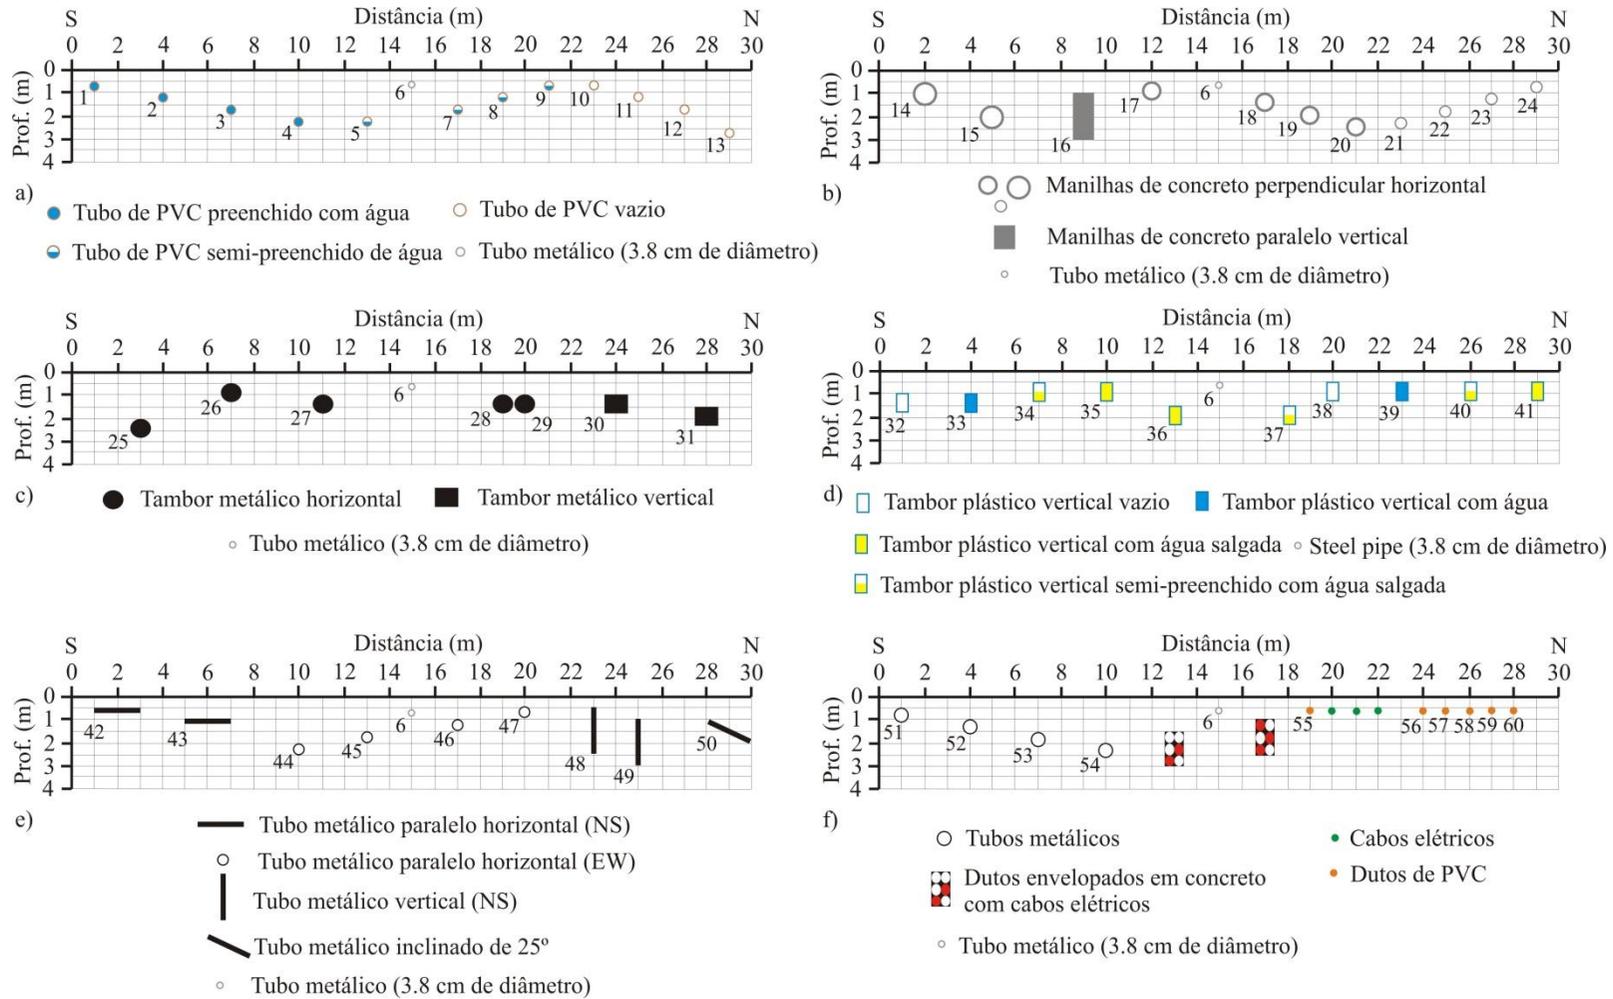


Figura 2.3 - Esquema das linhas de estudos. a) Linha 2 – tubos de PVC. b) Linha 3 – manilhas de concreto. c) Linha 4 – tambores metálicos. d) Linha 5 – tambores plásticos. e) Linha 6 – tubos metálicos. f) Linha 7 – Tubos metálicos e cabos elétricos.

Na Linha 2 de Tubulação Hidráulica (posição X = 8 m) foram enterrados tubos de PVC fornecidos pela SABESP - Companhia de Saneamento Básico do Estado de São Paulo, simulando o transporte de água. Os tubos possuem 2 m de comprimento, com diâmetro de 13,6 cm e estão vazios, totalmente e parcialmente preenchidos com água de torneira. Para evitar a saída da água os mesmos foram lacrados nas extremidades.

Na linha 3 (posição X = 15 m) foram enterradas manilhas de concreto com diâmetro externo de 70, 48 e 26 cm e comprimento de 2 m, na horizontal (direção EW magnético) e na vertical. Estes alvos simulam a passagem de água e esgoto nas grandes cidades.

A linha 4 (posição X = 27 m) apresenta tambores de aço carbono de 200 litros, pintados com tinta anti-ferrugem, com 86 cm de altura e 59 cm de diâmetro externo e dispostos na horizontal e na vertical, individual e aos pares. Estes materiais eram utilizados para armazenar produtos tóxicos em fábricas, simulando problemas ambientais.

A linha 5 (posição X = 36 m) apresenta tambores plásticos de PVC com 100 litros de capacidade, com 69 cm de altura e 47 cm de diâmetro externo. Alguns dos tambores estão totalmente e parcialmente preenchidos com água de torneira e salgada e dois estão vazios. Estes alvos simulam estudos de contaminação do meio ambiente com materiais condutores e resistores, além de simular áreas de dissolução cárstica (vazios no solo).

Na Linha 6 (posição X = 42 metros) foram enterrados tubos de ferro com diâmetro externo de 4 polegadas, nas direções EW e NS magnético, dispostos na horizontal, na vertical e inclinados (25°). Estes alvos simulam corpos geológicos magnéticos (mineralizações e diques) e de redes para transporte de água e gás.

A Linha 7 (posição X = 49 m), é constituída por cabos elétricos, hidráulicos e conduítes plásticos e de PVC para passagem de cabos de fibra ótica. Os alvos utilizados foram fornecidos pela Sabesp e pela Eletropaulo - Companhia de Eletricidade de São Paulo SA, consistindo de tubos de ferro, conduítes para passagem de cabos de fibra ótica, cabos elétricos de média e baixa tensão (não energizados) e dutos elétricos envelopados em caixas de concreto.

CAPÍTULO 3

3. REVISÃO BIBLIOGRÁFICA

Para o melhor entendimento sobre reconhecimento de padrões e Redes Neurais Artificiais-RNAs buscou-se na literatura trabalhos relacionados a aplicação destas técnicas com a Geofísica. Primeiramente, são apresentados alguns trabalhos específicos da área de reconhecimento de padrões que tratam sobre o efeito das camadas ocultas de redes *perceptron*, classificadores lineares e processamento de imagens utilizando redes neurais. Aplicando as duas técnicas, de redes neurais e Geofísica, pode-se citar trabalhos de sísmica, eletrorresistividade e previsões de magnitudes de terremotos. Por fim são apresentados trabalhos que envolvem RNAs e GPR, tendo aplicações nas áreas de localização de objetos enterrados, detecção de minas e caracterização geológica.

O trabalho de CHANG JOU et al. (1994) mostra a relação entre tolerância a falhas e as camadas ocultas (camadas intermediárias da rede) utilizadas em uma rede MLP (*multilayer perceptron*). Ao aumentar o número de nós da camada oculta, aumentamos o grau de tolerância a falhas, porém é exigido uma maior complexidade computacional e assim foi proposta uma nova estratégia para balancear esses dois fatores em função do erro da rede neural. Em 1991, Flemming Barlach propôs uma técnica para um classificador linear baseado em um procedimento de busca exaustiva. O padrão das classes é projetado em subespaços do espaço total de padrões e esta é delimitada por hiperplanos com orientação fixa. Um conjunto de discriminantes lineares é então submetido a um procedimento de otimização que desloca os discriminadores. O procedimento de otimização é caracterizado como uma pesquisa exaustiva linear que realiza uma ordenação do conjunto de todas as posições possíveis dos discriminadores. A partir desta sequência ordenada de soluções pode-se escolher uma solução particular. EGMONT-PETERSEN et al. (2002) realizaram uma revisão de mais de 200 aplicações de redes neurais artificiais em processamento de imagens e discutem o presente e um possível futuro das aplicações das redes neurais. Este trabalho é importante por apresentar uma análise crítica sobre as perspectivas futuras para as aplicações dessas metodologias.

JUSTICE et al. (1985) propuseram que a interpretação de dados sísmicos para prospecção de hidrocarbonetos tem raízes profundas na análise de padrões. A base para essa abordagem é a identificação de um grande número de atributos que podem ser combinados, através da análise de padrões, inferindo informações necessárias para interpretar corretamente os dados sísmicos e localizar reservatórios de hidrocarbonetos potencialmente comerciais.

NEYAMADPOUR et al., 2009 realizaram uma inversão 2D de resistividade utilizando redes neurais artificiais. Nesse trabalho, investigou-se a aplicabilidade do software MATLAB para criar, treinar e testar uma rede neural artificial desenvolvida para inversão 2D de resistividade. Já HO (2009) realizou uma inversão 3D para dados geoeletricos utilizando uma rede neural do tipo *backpropagation*. A técnica de "tomografia de fluxo de fluido" foi desenvolvida pelo Laboratório de Pesquisa Geofísica na Universidade de Kyushu (Japão). Essa técnica monitora o comportamento do fluxo de fluido durante a injeção de água e produção em um campo de energia geotérmica. Entretanto, o processamento dos dados é muito complexo, de maneira que esse trabalho abordou uma solução para redução da complexidade através da aplicação de uma rede neural durante a fase do processamento.

ADELI & PANAKKAT, 2009 desenvolveram uma metodologia para prever a magnitude de terremotos através de uma rede neural probabilística (RNP). A rede neural probabilística foi apresentada para prever a magnitude do maior tremor de terra em um período de tempo pré-definido em uma região sísmica com oito parâmetros matematicamente calculados, conhecidos como indicadores de sismicidade. O modelo fornece uma boa previsão para os terremotos de magnitude entre 4,5 e 6,0, complementando o modelo desenvolvido pelos autores anteriormente, em que os bons resultados foram relatados para prever terremotos com magnitude superior a 6,0.

Tratando especificamente do uso de RNAs e o método geofísico GPR, pode-se citar o trabalho de POULTON & EL-FOULY (1991), um dos primeiros trabalhos sobre o tema. Nesse trabalho foi desenvolvido um novo método de extração e delimitação de reflexões através do uso de filtros lógicos. A rede neural foi construída em cascata, iniciando o treinamento com o método LVQ (*Learning Vector Quantization*) e finalizado com o *backpropagation*. O método classifica o tipo de alvo como um ponto ou plano, identifica a composição, tamanho e a sua localização. Os alvos utilizados

foram tubos de cobre, alumínio e PVC, com vários diâmetros. Para a aquisição de dados GPR foi utilizada uma antena de 500 MHz. A natureza modular da rede permitiu um treinamento mais rápido e fornece resultados mais precisos.

MOLYNEAUX et al., 1995 apresentaram uma avaliação da capacidade das redes neurais artificiais para interpretar imagens de GPR em concreto armado. A capacidade de uma rede neural de três camadas foi testada para detectar a presença de barras de ferro em concreto, estimando seu tamanho e sua profundidade. Foram utilizados 153 dados para treinamento, sendo que 99 dados apresentavam a barra de ferro em diferentes profundidades (25, 50, 100, 155, 200 ou 260 mm) e 54 dados sem a barra de ferro. A rede foi treinada com 30000 iterações, obtendo um erro de 0,1 (em relação aos dados de saída desejado). Do número total de testes (132) realizados com a rede, em apenas 13 a rede identificou a presença da barra de aço incorretamente. O estudo demonstrou que o uso de uma abordagem de redes neurais para interpretar os resultados GPR no concreto, com a presença das barras de reforço foi promissor. O uso de RNAs obteve sucesso na localização das barras de reforço em uma determinada faixa de profundidades em quase todas as ocasiões.

AL-NUAIMY et al., 2000a utilizaram uma rede neural *backpropagation* como identificador de alvos enterrados, compreendendo a fase de reconhecimento de padrões, pré-processamento, extração de características e processamento da imagem. Esta rede neural foi utilizada para identificar partes do radargrama correspondente às reflexões. Como resultado obtêm-se uma classificação das informações úteis e redundantes e um processamento adicional é realizado apenas na primeira etapa. A Transformada de Hough foi aplicada nas bordas dessas reflexões, a fim de identificar com precisão a profundidade e posição dos alvos enterrados. Tal resultado permite uma reconstrução de alta resolução da subsuperfície com tempo de cálculo reduzido. O sistema foi testado em um tanque controlado em laboratório contendo tubos, cabos e minas terrestres, e os resultados indicaram que a detecção automática é eficaz no mapeamento dessas estruturas em tempo quase-real.

O trabalho apresentado acima utilizou técnicas de reconhecimento de padrões para a *identificação* das hipérboles e assim encontrar, sem a necessidade de um intérprete, as anomalias provenientes de alvos enterrados. Esta pesquisa teve como objetivo a *identificação* e também *classificação* do tipo de material de objetos

enterrados utilizando também técnicas de reconhecimento de padrões (redes neurais artificiais). Assim, o presente trabalho vem aprimorar uma técnica já apresentada na literatura de forma inédita.

GAMBA & LOSSANI (2000) apresentaram uma sequência de processamento para a análise espacial dos dados registrados por GPR. A interpretação da imagem é realizada através de um classificador neural após um pré-processamento visando a melhoria das assinaturas do objeto enterrado. A estrutura da rede neural utilizada para reconhecer os padrões das tubulações em imagens GPR foi construída com duas camadas do tipo *feedforward*, com 400 neurônios na camada de entrada (correspondendo a uma imagem binária de 20 x 20) e um neurônio na camada de saída. O treinamento foi realizado com o algoritmo *backpropagation*, utilizando o *momentum* para a convergência da rede. A saída da rede é binária, sendo 1 quando há hipérbole na figura e 0 para qualquer outra situação. A taxa de acerto do sistema foi de 91%, mostrando a eficácia da metodologia empregada.

Outra aplicação conjunta das RNAs e o método GPR está relacionada com a detecção de minas enterradas. Os trabalhos de GADER et al., 2001, MILISAVLJEVIC et al., 2003 e HARA & HIROSE, 2004 utilizaram técnicas de reconhecimento de padrões para detectar minas terrestres convencionais e plásticas diminuindo as chances de erros provocados pelos “falsos alarmes”.

SHIHAB et al. (2002) estudaram a interpretação automática e não supervisionada de dados GPR através da implementação de uma RNA para discriminar os sinais provenientes de diferentes tipos de alvos e de outras fontes de reflexões, como a geologia do meio. O classificador neural foi capaz de devolver a imagem 3D que define a região de alvos em subsuperfície, tais como concreto armado, solo perturbado, tanques de armazenamento, minas ou tubulações. Os resultados obtidos pela rede mantiveram-se de acordo com os obtidos manualmente por um operador treinado. Foi utilizada uma rede do tipo MLP, com três camadas *feedforward* e com algoritmo de treinamento *backpropagation*.

Em 2003, MOYSEY et al. apresentaram um método para identificar fácies geológicas em perfis GPR. Nesse trabalho, redes neurais foram utilizadas para estimar heterogeneidades em perfis GPR, produzindo modelos estocásticos baseados em fácies do subsolo. Para perfis GPR sintéticos, a rede neural foi capaz de identificar

corretamente 90% das estruturas. Já em dados reais, a rede foi capaz de identificar duas fácies com exatidão de 80%.

Al-NUAIMY et al., 2004 aprimoraram a detecção e caracterização de objetos cilíndricos enterrados em tanque de laboratório utilizando GPR. As características utilizadas foram: a permissividade dielétrica do meio, o raio do cilindro, azimute e ângulo de inclinação do cilindro e o padrão de radiação eletromagnética das antenas. Essa fusão de dados é realizada de maneira automática e sem supervisão através da utilização de RNA e reconhecimento de padrões. O resultado é uma interpretação tridimensional que pode ser facilmente visualizada, sem necessidade de conhecimentos especializados.

YOUN & CHEN (2004) apresentaram um algoritmo de detecção automática de tubulação enterrada aplicando duas etapas de RNA em dados GPR analisando as características de polarização. A linearidade e a orientação do objeto enterrado são estimados através da análise dos dados GPR. A orientação estimada é utilizada para normalizar o padrão de variação espacial antes de aplicar o segundo passo da RNA quando a direção da aquisição não é perpendicular ao tubo. O algoritmo de detecção, em seguida, fornece como resultado a localização, profundidade e orientação de um tubo enterrado. O desempenho de detecção do algoritmo foi testado através de simulações de Monte Carlo, na presença de diferentes relações sinal-ruído e sinal-desordem. O algoritmo de detecção foi capaz de detectar efetivamente tubos enterrados até um metro de profundidade, com apenas algumas varreduras do radar.

SHAW et al. (2005) utilizaram a abordagem de redes neurais para automatizar e facilitar o pós-processamento dos resultados GPR. As reflexões geradas por vergalhões de ferro em concreto são detectadas através de uma rede MLP com uma única camada escondida contendo oito neurônios para reconhecer a forma hiperbólica. Os resultados mostraram que o uso da rede neural MLP pode ser bastante eficaz para automatizar a identificação e localização do ferro em concreto utilizando o GPR.

No ano de 2010, Bernd Ehret, mostrou um novo método de classificação de rochas para dados GPR, onde não há informações geológicas disponíveis. O reconhecimento de padrões e o aprendizado estatístico multivariado foram utilizados para mostrar a relação entre as propriedades petrofísicas das rochas e as ondas eletromagnéticas. O método discrimina os limites entre as rochas de camadas diferentes.

O processo inicia-se a partir de modelos geológicos com diferentes parâmetros petrofísicos de rocha, que devem ser procurados nos dados de medição. Os modelos são usados para gerar radargramas sintéticos a partir da qual as propriedades das rochas podem ser derivadas usando atributos de onda, onde são armazenados em um conjunto de dados multivariados, que são utilizados para treinar a rede. O método pode ser usado para combinar as reflexões nos dados GPR diretamente com os limites da camada de formações rochosas.

KHAN et al. (2010) apresentaram uma abordagem cepstral para a detecção automática de minas terrestres e alvos enterrados utilizando GPR. O *cepstrum* é o resultado de considerar a Transformada de Fourier do espectro do registro como se fosse um sinal. Essa abordagem é baseada no tratamento do problema como sendo um problema de reconhecimento de padrões. As características utilizadas na rede neural são as *Características Ceptrais* do sinal GPR e os resultados experimentais mostram a eficiência do método em detectar minas terrestres e outros alvos.

O método GPR apresenta uma ambiguidade com relação ao alvo encontrado em subsuperfície, uma vez que não é possível determinar o tipo de material responsável pela anomalia, como por exemplo, se é metal, concreto ou plástico. Com base nas referências supracitadas, a presente tese utiliza RNA para identificar e classificar anomalias observadas em dados de GPR. Assim, a contribuição tecnológica desta pesquisa é diferenciar os três tipos de materiais mencionados, utilizando um classificador baseado na teoria de RNA. Com os resultados obtidos pode-se reduzir tais ambiguidades e auxiliar o geofísico na interpretação dos resultados.

CAPÍTULO 4

4. METODOLOGIAS

4.1 MÉTODO GPR

4.1.1 Princípios eletromagnéticos do GPR

Ground Penetrating Radar (GPR) é um método geofísico muito bem aceito atualmente. Ele utiliza ondas de rádio para sondar a subsuperfície. A princípio foi utilizado apenas em estruturas geológicas, mas atualmente, é amplamente utilizado em concreto, metal, asfalto, entre outros, que constituem os principais materiais envolvidos em estudos geotécnicos.

A existência de vários materiais dielétricos de baixa perda no ambiente, juntamente com um amplo espectro de frequência, implica em um vasto número de aplicações do método GPR. A metodologia pode ser aplicada desde estudos glaciais até estruturas de concreto, variando de quilômetros, como no estudo realizado na Lua (ROSSITER et al., 1973) a centímetros de profundidade de investigação.

O GPR é um método eletromagnético que emprega ondas de rádio em frequências muito altas (normalmente entre 10 MHz e 2,5 GHz). O princípio físico e a metodologia de aquisição de dados GPR são semelhantes às técnicas de reflexão sísmica e a técnica de sonar, exceto pelo GPR ser baseado na reflexão de ondas eletromagnéticas.

A forma mais comum de realizar medidas com o GPR é através de um transmissor e um receptor com uma geometria fixa, que são movidos sobre a superfície para detectar reflexões a partir de características do solo. A propagação da energia eletromagnética (EM) é descrita pelas Equações de Maxwell, através dos campos elétrico (\vec{E}) e magnético (\vec{H}). O comportamento da propagação e da atenuação do campo eletromagnético em um determinado meio depende das propriedades elétricas e magnéticas dos materiais constituintes.

O campo eletromagnético está relacionado com as propriedades elétricas e magnéticas do meio através das relações constitutivas. Tais relações descrevem as

respostas do meio ao interagir com campos EM. Para o GPR as propriedades elétricas e magnéticas são muito importantes e as relações constitutivas (Equações 4.1, 4.2 e 4.3) fornecem uma descrição macroscópica de como os elétrons, átomos e moléculas respondem à aplicação de um campo EM:

$$\vec{D} = \epsilon \vec{E} \quad (4.1)$$

$$\vec{B} = \mu \vec{H} \quad (4.2)$$

$$\vec{J} = \sigma \vec{E} \quad (4.3)$$

nas quais ϵ é a permissividade dielétrica (F/m), caracterizada pela limitação de polarização do material na presença de um campo elétrico, μ é a permeabilidade magnética (H/m) e corresponde ao grau de magnetização de um material em resposta a um campo magnético, σ é a condutividade elétrica (S/m), sendo a relação (4.3) a Lei de Ohm, caracterizada pelas cargas livres em movimento quando um campo elétrico está presente, ou seja, é a medida de sua capacidade em conduzir corrente elétrica (KELLER, 1987).

Para a maioria das aplicações do GPR assume-se um escalar constante para ϵ , μ e σ . A permissividade dielétrica ou constante dielétrica é a propriedade mais importante e normalmente utiliza-se a permissividade dielétrica relativa,

$$\epsilon_r = \frac{\epsilon}{\epsilon_0} \quad (4.4)$$

na qual ϵ é a permissividade dielétrica do material (F/m) e ϵ_0 é a permissividade dielétrica no vácuo ($8,854 \times 10^{-12}$ F/m).

Através de manipulação algébrica pode-se relacionar as propriedades elétricas e magnéticas do meio com as equações de Maxwell em termos da intensidade de campo elétrico e da intensidade de campo magnético. Estas equações caracterizam a propagação do campo eletromagnético em um meio isotrópico e homogêneo relacionando a condutividade elétrica, a permissividade dielétrica e a permeabilidade magnética.

A condutividade elétrica afeta diretamente a atenuação e a permissividade dielétrica afeta a propagação das ondas de radar (ANNAN, 1996). Em geral, a

condutividade é dominante para ondas EM de baixas frequências (< 1 MHz) enquanto que, para altas frequências (≥ 1 MHz), a permissividade dielétrica torna-se dominante (WARD & HOHMANN, 1987). Já a permeabilidade magnética não é considerada quando são feitas medidas eletromagnéticas na Terra, por admitir-se que a mesma não varia significativamente em relação a permeabilidade magnética do espaço livre (OLHOEFT, 1998; KELLER, 1987).

Substituindo-se as relações constitutivas nas equações de Maxwell (MACHADO, 2013), obtemos o número de onda k :

$$k^2 = \omega^2 \mu \epsilon - i \omega \mu \sigma \quad (4.5)$$

Nas altas frequências, é usual reescrever k como:

$$k = \alpha + i\beta \quad (4.6)$$

sendo que α é a constante de atenuação e β é a constante de propagação, definidos originalmente em STRATTON (1941).

Nas baixas frequências utilizadas na maioria dos métodos eletromagnéticos, os estudos de indução de correntes elétricas no solo são adequadamente descritos por um processo de difusão do campo eletromagnético, sendo que as correntes de deslocamento podem ser desprezadas e somente as correntes de condução são consideradas. Entretanto, para as altas frequências do radar, tanto as correntes de condução quanto as correntes de deslocamento devem ser consideradas (WARD & HOHMANN, 1987).

O método GPR explora o caráter ondulatório dos campos EM. As Equações de Maxwell descrevem a variação no tempo dos campos elétrico e magnético, dependendo da magnitude relativa de energia perdida (relacionada a condutividade) e energia armazenada (relacionada a permissividade), podendo ser difuso ou se propagar.

O caráter ondulatório fica evidente quando as Equações de Maxwell são reescritas eliminando o campo elétrico ou o campo magnético. O GPR é eficaz em meios de baixa perda onde a energia dissipada é menor comparada com a energia armazenada.

Nas condições de baixa perda definimos v como a velocidade de propagação e α como a atenuação da onda EM:

$$v = \frac{1}{\sqrt{\epsilon\mu}} \quad (4.7)$$

$$\alpha = \frac{1}{2} \sigma \sqrt{\frac{\mu}{\epsilon}} \quad (4.8)$$

Uma vez a velocidade de propagação definida, pode-se definir sua constante de propagação (β) que depende da frequência de operação:

$$\beta = \omega \sqrt{\mu\epsilon} \quad (4.9)$$

As propriedades de um campo ondulatório são: velocidade (v), atenuação (α) e impedância (Z) (ANNAN, 2003). Para altas frequências do GPR estas propriedades independem da frequência. A transição de difusão para propagação ocorre quando o comportamento da corrente elétrica muda de *condução de corrente* (cargas livres) para *deslocamento de corrente* (cargas armazenadas).

Todo o intervalo das altas frequências do GPR está sujeito a mesma velocidade de propagação e a mesma atenuação. O sinal irá percorrer o meio de forma intacta, que é a propagação sem dispersão (ANNAN, 1996). Assim, a velocidade, a atenuação e a impedância podem ser reescritas por:

$$v = \frac{1}{\sqrt{\epsilon\mu}} = \frac{c}{\sqrt{\epsilon_r}} \quad (4.10)$$

$$\alpha = \sqrt{\frac{\mu}{\epsilon}} \frac{\sigma}{2} = Z_0 \frac{\sigma}{2\sqrt{\epsilon_r}} \quad (4.11)$$

$$Z = \sqrt{\frac{\mu}{\epsilon}} = \frac{Z_0}{\sqrt{\epsilon_r}} \quad (4.12)$$

Com: $\mu = \mu_0 = 4\pi \cdot 10^{-12}$ H/m, $c = 3 \cdot 10^8$ m/s e $Z_0 = \sqrt{\frac{\mu_0}{\epsilon_0}} = 377$.

Em estudos de GPR, normalmente supõe-se que as ondas EM se propagam com uma incidência normal às interfaces das camadas (ANNAN, 1992). Estas camadas possuem diferentes propriedades elétricas que podem causar uma forte impedância nas interfaces, determinando assim a quantidade do sinal que deverá ser refletida, expressa pelo coeficiente de reflexão (WARD & HOHMANN, 1987).

A amplitude do coeficiente de reflexão pode ser escrita em termos da impedância elétrica, Z . Uma onda se propagando através de um meio atenua-se com a profundidade até encontrar uma interface onde ocorra um contraste na impedância elétrica, onde parte dessa onda é refletida. A impedância Z é definida pela relação entre o campo elétrico E e o campo magnético H , ortogonais entre si. Na superfície, a impedância é expressa por:

$$Z = \sqrt{\frac{i\omega\mu}{\sigma+i\omega\epsilon}} \quad (4.13)$$

Segundo DANIELS (2007), para uma incidência normal (ângulo de incidência da onda EM perpendicular à superfície) e lembrando que, tanto as correntes de deslocamento, quanto as de condução devem ser consideradas e, portanto, a amplitude do coeficiente de reflexão GPR, r_{gpr} , para um meio composto por duas camadas, pode ser escrita como:

$$r_{\text{GPR}} = \frac{\sqrt{\sigma_2+i\omega\epsilon_2}-\sqrt{\sigma_1+i\omega\epsilon_1}}{\sqrt{\sigma_2+i\omega\epsilon_2}+\sqrt{\sigma_1+i\omega\epsilon_1}} \quad (4.14)$$

Os fatores que influenciam a profundidade de penetração do sinal GPR são o espalhamento geométrico, atenuação pelo terreno e a partição da energia nas interfaces, todos relacionados à perda de energia durante a propagação da onda EM.

Informações completas sobre as deduções das equações utilizadas no método GPR, bem como, sobre o histórico da metodologia, parâmetros de aquisição e processamento dos dados podem ser encontradas em ANNAN (1992), DANIELS (2007) e JOL (2009).

4.2 REDES NEURAIS ARTIFICIAIS

4.2.1 Histórico

As Redes Neurais Artificiais (RNAs) constituem um paradigma computacional baseado no modelo biológico do cérebro humano. Warren McCulloch e Walter Pitts publicaram, em 1943, a teoria de redes neurais artificiais e foram os primeiros a propor um modelo computacional para o neurônio biológico (KARTALOPOULOS, 1996). Apesar de simples, o neurônio modelado constituía-se em um dispositivo binário capaz

de implementar algumas funções lógicas simples. A rede não possuía qualquer mecanismo de comparação entre entrada e saída ou qualquer processo de ajuste de pesos.

A Figura 4.1 apresenta o modelo do neurônio artificial de McCulloch e Pitts (neurônio MCP), o qual é composto por um conjunto de entradas x_1, x_2, \dots, x_n , uma unidade de processamento Σ_i , uma função de ativação não linear f_i e uma saída y_i . Cada entrada j recebe um estímulo x_j que é ponderado pelo peso w_{ij} , que pode ser excitatório ou inibitório. A unidade de processamento coleta os sinais ponderados e os agrega juntamente com o termo *bias*, ou limiar, θ_i . A soma de todas as entradas ponderadas, dado por a_i , é então modulada pela função de ativação f_i que determina o nível de excitação y_i gerado pelo elemento neural.

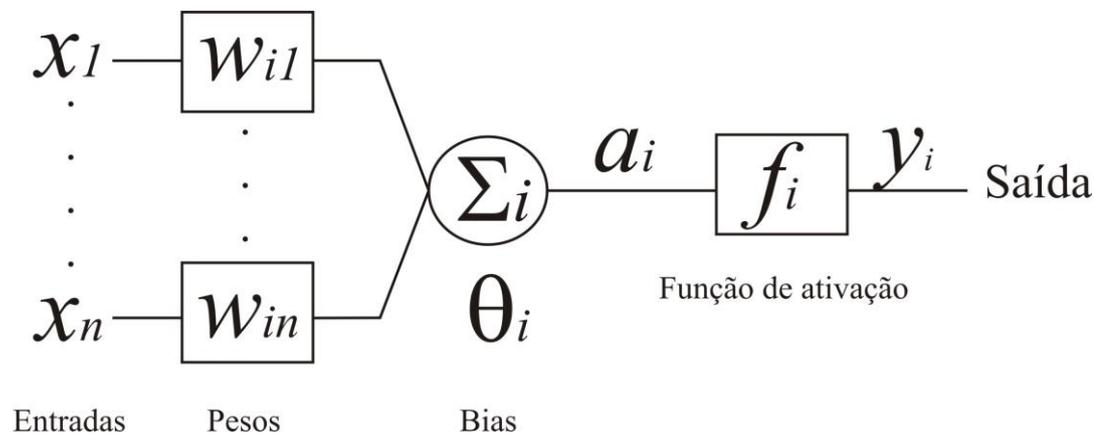


Figura 4.1 - Esquema de uma unidade neural básica.

Em 1949, HEBB traduz matematicamente a sinapse dos neurônios biológicos. As primeiras utilizações surgiram já na década de 1950, a partir da reunião *Dartmouth College* (1956), na qual surgiu o termo *Inteligência Artificial* (IA) para designar um conjunto de técnicas que permitiriam o desenvolvimento de sistemas suficientemente genéricos para resolver qualquer problema, desde que devidamente representado. Desta forma, as RNAs, também chamadas de abordagem conexionista, surgiram como uma alternativa à abordagem simbólica, baseada na lógica (KRATZER, 1991 *apud* BISHOP, 1995).

Segundo KOVÁCS (1996), no final da década de 50, dando prosseguimento às ideias de McCulloch e Pitts, Rosenblatt cria uma rede com múltiplos elementos neurais dispostos em camadas, a qual chama *perceptron*. Este se tornou um sistema de

classificação capaz de reconhecer padrões geométricos e abstratos (ROSENBLATT, 1958).

Na IAS (Inteligência Artificial Simbólica), o comportamento inteligente global é simulado, sem considerar os mecanismos responsáveis por este comportamento. Enquanto que na IAC (Inteligência Artificial Conexionista) acredita-se que construindo máquina que imite a estrutura do cérebro ela apresentará inteligência. Progressivamente as duas correntes para IA separaram-se, e as pesquisas em redes neurais (corrente conexionista) andaram lentamente enquanto a corrente da manipulação simbólica apresentou um significativo avanço.

Um motivo para esta divisão foi o livro de MINSKY & PAPERT (1969). Esse trabalho constitui um dos primeiros estudos sobre a complexidade do problema e a correspondente capacidade das redes neurais para resolvê-lo, afirmando que: “um perceptron de uma única camada é incapaz de resolver um problema não linearmente separável”.

Como tal característica não está presente na maioria dos sistemas reais, a abordagem conexionista sofreu um grande impacto e durante a década de 70 a área de IA voltou-se bastante para a abordagem lógica. Entretanto, alguns grupos continuaram buscando alternativas que suplantassem a limitação apresentada e para obter verbas para suas pesquisas passaram a utilizar uma denominação diferente de redes neurais. Devido a este fato, encontram-se muitas vezes outros termos que são sinônimos de redes neurais artificiais, tais como: Sistemas Neurais Artificiais, Sistemas Adaptativos, Neurocomputadores, Sistemas Maciçamente Paralelos, entre outros (HASSOUN, 1995).

Essa situação foi alterada de maneira drástica com a apresentação de um artigo que demonstrava uma maneira de expandir o algoritmo do perceptron para uma rede com várias camadas (HOFFMANN, 1993 *apud* BISHOP, 1995). O modelo matemático desenvolvido provava que tal rede, denominada de Perceptron de Múltiplas Camadas (MLP - *MultiLayer Perceptron*) poderia ser treinada para atingir qualquer valor desejado de precisão, para qualquer tipo de problema (RUMELHART et al., 1986). Isto despertou novamente um grande interesse na comunidade científica a partir de 1980.

Nas tabelas a seguir temos um resumo dos eventos históricos e das fases relacionadas às Redes Neurais Artificiais.

Tabela 4.1 - Eventos históricos relacionados à RNAs (RAUBER, 1998).

ANO	AUTOR	EVENTO
1943	McCulloch & Pitts	Modelo de neurônio artificial
1949	Hebb	Regra de Aprendizagem de um neurônio
1958	Rosenblatt	<i>Perceptron</i>
1960	Widrow & Hoff	Adaline
1969	Minsky & Papert	Problema XOR em <i>Perceptrons</i>
1982	Hopfield	Rede realimentada com função de energia
1986	Rumelhart <i>et al.</i>	Retropropagação de erro

Tabela 4.2 - Fases relacionadas à RNAs (RAUBER, 1998).

INTERVALO	FASE
1943 – 1969	Entusiasmo
1969 – 1982	Depressão
1982 - presente	Renascença

4.2.2 Motivação – inspiração biológica

O cérebro humano contém aproximadamente 10^{11} neurônios e cada um desses neurônios processa e se comunica com milhares de outros continuamente e em paralelo. A estrutura individual desses neurônios, a topologia de suas conexões e o comportamento conjunto desses elementos de processamento naturais formam a base para o estudo das RNAs.

Um neurônio típico é composto por um corpo celular, um axônio tubular e várias ramificações arbóreas conhecidas como dendritos (Figura 4.2). Os dendritos formam uma malha de filamentos muito finos ao redor do neurônio, ao passo que o axônio consta de um tubo longo e fino que ao final se divide em ramos que terminam em pequenos bulbos que quase tocam os dendritos dos outros neurônios. O pequeno espaço entre o fim do bulbo e o dendrito é conhecido como sinapse, através da qual as informações se propagam. O número de sinais recebidos por cada neurônio varia de 100 a 100000, sendo que elas podem ser tanto excitatórias como inibitórias.

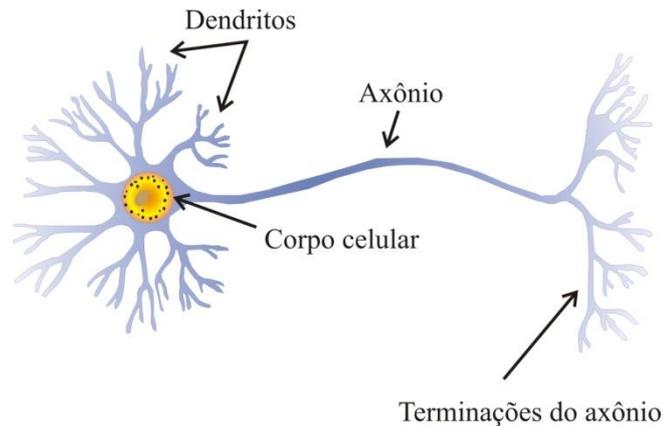


Figura 4.2 - Componentes do neurônio biológico.

O cérebro humano é responsável por funções cognitivas básicas, execução de funções sensoriomotoras e autônomas. Além disso, a rede de neurônios tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência e interpretar observações.

As RNAs tentam reproduzir as funções das redes biológicas, buscando implementar seu comportamento funcional e sua dinâmica. Tanto as RNAs quanto as redes biológicas se baseiam em unidades de computação paralela e distribuída, se comunicando por meio de conexões sinápticas e possuem detectores de características, redundância e modularização das conexões.

4.2.3 Modelagem matemática

O modelo de neurônio artificial proposto por McCulloch e Pitts (neurônio MCP) é uma simplificação do que se conhecia na época a respeito do neurônio biológico (Figura 4.2). Sua descrição matemática resultou em um modelo com n terminais de entrada (dendritos) que recebem os valores x_1, x_2, \dots, x_n (representando as ativações dos neurônios anteriores) e apenas um terminal de saída y (representando o axônio). Para as sinapses, os terminais de entrada do neurônio possuem pesos acoplados w_1, w_2, \dots, w_n , cujos valores podem ser positivos ou negativos, dependendo de as sinapses correspondentes serem inibitórias ou excitatórias. O efeito de uma determinada sinapse i é dado por $x_i w_i$.

Um neurônio biológico dispara quando a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação (*threshold*). Já no neurônio artificial, a decisão de disparar ou não depende da soma dos valores $x_i w_i$ recebidos por ele (soma ponderada) e decide uma saída igual a 1 ou 0, comparando a soma obtida ao limiar do neurônio. Esta ativação é obtida através da aplicação de uma *função de ativação*, que ativa ou não a saída, dependendo do valor da soma ponderada das suas entradas.

A função de ativação é responsável por gerar a saída y do neurônio a partir dos valores do vetor de peso $\vec{w} = (w_1, w_2, \dots, w_n)^T$ e de entradas $\vec{x} = (x_1, x_2, \dots, x_n)^T$. A função de ativação de um neurônio MCP é do tipo degrau, deslocada do limiar de ativação θ em relação a origem:

$$f(u) = \begin{cases} 1, & \text{se } u \geq \theta \\ 0, & \text{se } u < \theta \end{cases} \quad (4.15)$$

onde $u = \sum_{i=1}^n x_i w_i$, é a soma ponderada entre as entradas e os pesos e θ é o limiar da função de ativação.

Uma aproximação contínua da função degrau, cuja derivada é conhecida em sua forma analítica é dada da seguinte forma:

$$f(u) = \frac{1}{1 + e^{-\beta(u + \theta)}} \quad (4.16)$$

com β sendo a inclinação da função. Essa função, chamada de função sigmoideal, além de ser diferenciável, possui uma região semilinear, que pode ser importante na aproximação de funções contínuas. Dependendo do tipo de problema a ser abordado, neurônios com funções de ativação lineares ($f(u) = au + b \rightarrow a, b \in \mathfrak{R}$) podem também ser utilizadas.

Por sua vez, as RNAs do tipo RBF (*Radial Basis Functions*) utilizam neurônios com funções de ativação radiais, como a função gaussiana (BROOMHEAD & LOWE, 1988), mostrada a seguir:

$$f(u) = \frac{1}{r\sqrt{2\pi}} e^{-\frac{(u-\mu)^2}{2r^2}} \quad \text{ou} \quad f(u) = e^{-u^2} \quad (4.17)$$

onde μ é o centro (ponto médio) e r é o raio de abertura da função. Dentre as funções de ativação, a sigmoideal, por ser uma função monotônica, limitada e ter uma derivada fácil de calcular é mais amplamente utilizada em aplicações que envolvem o uso de RNAs. Outra função de ativação que se pode destacar é a tangente hiperbólica, sendo esta uma

função limitada entre -1 e 1 definida por $\tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$:

$$f(u) = \tanh(u) \tag{4.18}$$

As funções de ativação mais comuns são: função degrau, função sigmoideal, função linear, a função gaussiana e a função tangente hiperbólica (Figura 4.3).

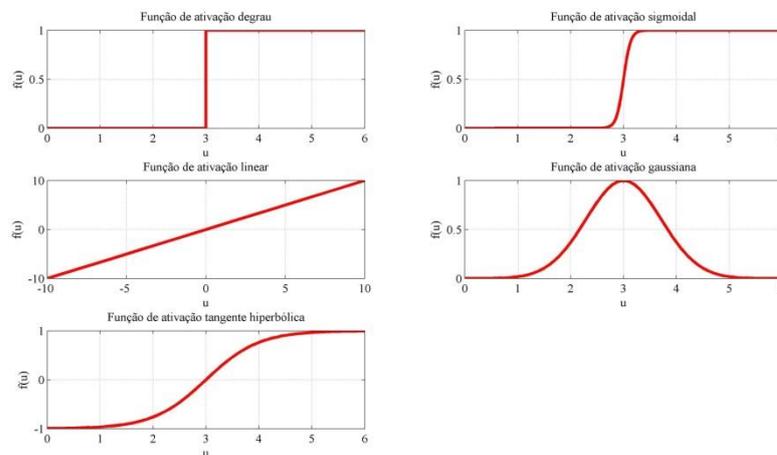


Figura 4.3 - Exemplos de função de ativação.

4.2.4 Arquiteturas de RNAs

Independentemente da função de ativação escolhida, neurônios individuais possuem capacidade computacional limitada. Assim, faz-se necessário um conjunto de neurônios artificiais conectados na forma de uma rede, para resolver problemas de complexidade elevada.

Uma RNA possui, como componentes básicos, (i) um conjunto de elementos neurais, (ii) uma arquitetura que define o número de elementos e a forma como se interconectam, e (iii) propriedades funcionais que definem como a rede aprende, recorda, associa, compara e classifica. Os elementos que recebem diretamente as características da rede constituem o que se chama de camada de entrada, que estão ligadas a primeira camada de neurônios. As saídas dessa primeira camada de neurônios

serão as entradas das camadas seguintes que constituem a segunda camada de neurônios e assim sucessivamente até a camada final, denominada camada de saída. As camadas intermediárias (internas) são geralmente mencionadas como camadas ocultas.

A estrutura mais simples corresponde a uma rede neural com uma camada de entrada e uma única camada de neurônios (camada de saída) alimentada para frente (*feedforward*), sendo estas capazes de resolver problemas multivariáveis de múltiplas funções acopladas, mas com algumas restrições de complexidade, por terem apenas uma única camada de processamento. À medida que se insere camadas intermediárias adicionais a RNA apresenta maior capacidade computacional.

Os tipos de arquiteturas supracitadas correspondem às RNAs estáticas. Tal tipo de arquitetura não possui recorrência em sua estrutura, ou seja, as saídas em um determinado instante dependem apenas das entradas atuais (Figura 4.4a e Figura 4.4b). As estruturas apresentadas nas Figuras 4.4c e 4.4d possuem conexões recorrentes entre neurônios de uma mesma camada ou entre neurônios de saída e de camadas anteriores. A saída depende não somente das entradas, mas também do seu valor atual. Essa estrutura é utilizada na resolução de problemas que envolvam processamento temporal, como previsão de eventos futuros. Pode-se ter também uma única camada de neurônios, em que a saída de cada um deles está conectada as entradas de todos os outros, sendo essa a estrutura típica de uma rede de Hopfield (HOPFIELD, 1982).

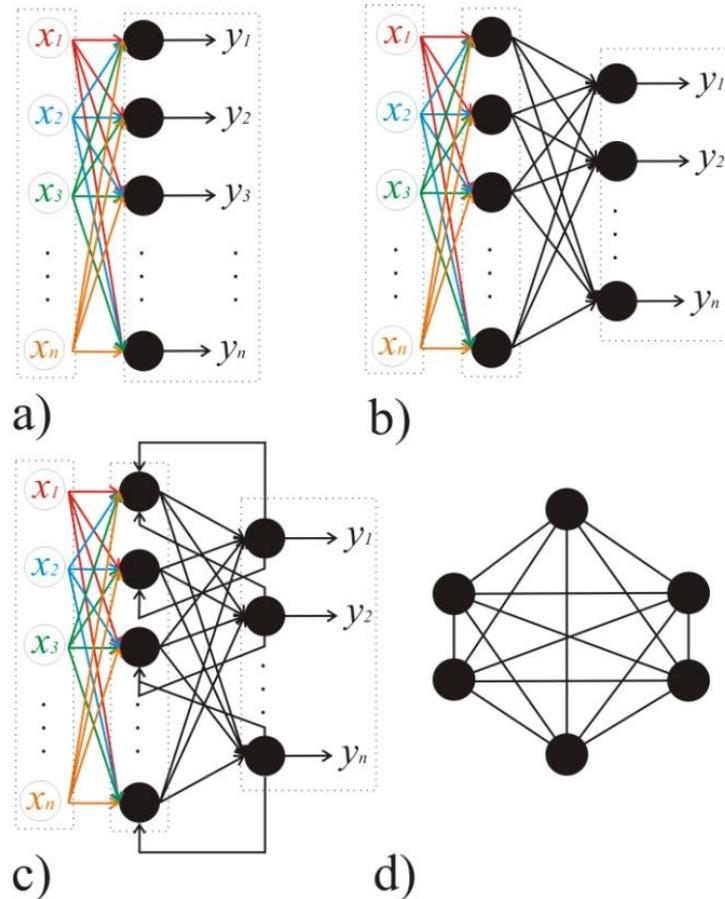


Figura 4.4 - Algumas arquiteturas de RNAs. a) Rede feedforward com uma camada de entrada e saída. b) Rede feedforward com uma camada de entrada e saída e uma camada intermediária. c) Rede com recorrência entre saídas e camada intermediária. d) Rede com recorrência auto-associativa.

A definição da estrutura de uma RNA para a resolução de um determinado problema depende dos seguintes fatores:

- Complexidade do problema;
- Dimensionalidade do espaço de entrada;
- Características dinâmicas ou estáticas;
- Conhecimento *a priori* sobre o problema;
- Representatividade dos dados.

4.2.5 Aprendizado

Um das características mais importantes das RNAs é a capacidade de aprender por meio de exemplos. Na abordagem conexionista, o conhecimento não é adquirido através de regras explícitas, como na IA simbólica, mas através do ajuste das intensidades das conexões entre os neurônios.

Segundo MENDEL & FU (1970) aprendizado é o processo pelo qual os parâmetros livres de uma rede neural são ajustados por meio de uma forma continuada de estímulos pelo ambiente externo. O tipo específico de aprendizado é definido pela maneira particular como ocorrem os ajustes dos parâmetros livres. Esse conceito está relacionado com a melhoria do desempenho da rede segundo algum critério pré-estabelecido. Quando a saída estiver dentro dos limites estabelecidos como toleráveis, a fase de treinamento estará terminada, tendo a rede adquirido “*conhecimento*”.

Existem diferentes processos de aprendizado e nem todos possuem o mesmo grau de eficiência. Em redes neurais artificiais, é necessário escolher dentre as diferentes técnicas de aprendizado disponíveis, aquela que melhor se adapte às características de cada rede e à natureza do problema em consideração. O erro quadrático médio da resposta da rede em relação ao conjunto de dados fornecido pelo ambiente, por exemplo, pode ser utilizado como critério de desempenho pelos algoritmos de correção de erros. Assim, quando esses algoritmos são utilizados no treinamento de RNAs, espera-se que o erro diminua à medida que o aprendizado prossiga.

Os algoritmos de treinamento podem ser vistos como algoritmos de otimização que promovem a minimização da função erro, definida em relação aos valores esperados na saída, obedecendo aos limites de tolerância pré-estabelecidos. Dentre as diferentes técnicas de otimização aplicáveis, podem ser citados: a regra delta, o algoritmo de Boltzmann, o algoritmo *backpropagation*, o *simulated annealing* e algoritmos baseados em cadeias de Markov (KARTALOPOULOS, 1996).

O valor do vetor de pesos $\vec{w}(t+1)$ no instante $t+1$ pode ser escrito da seguinte forma:

$$\vec{w}(t+1) = \vec{w}(t) + \Delta\vec{w}(t) \quad (4.19)$$

na qual $\vec{w}(t)$ e $\vec{w}(t+1)$ representam os valores dos pesos nos instantes t e $t+1$, respectivamente, e $\Delta\vec{w}(t)$ é o ajuste aplicado aos pesos.

Os algoritmos de aprendizado diferem, basicamente, na forma como $\Delta\vec{w}(t)$ é calculado. Existem vários algoritmos diferentes para treinamento de redes neurais artificiais, agrupados em dois tipos: o aprendizado supervisionado e o aprendizado não-supervisionado.

O aprendizado supervisionado é um processo realizado mediante sucessivas apresentações de padrões de entrada e saída conhecidos, requerendo um “supervisor”. O supervisor é responsável pelo treinamento da rede, que resulta em um processo de minimização da diferença entre a resposta da rede e a resposta esperada e também determina os ajustes que devem ser feitos para que o erro seja minimizado.

Esse tipo de aprendizado se aplica a problemas em que se deseja obter um mapeamento entre padrões de entrada e saída. Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a *regra delta* (WIDROW & HOFF, 1960), e a sua generalização para redes de múltiplas camadas - o algoritmo *backpropagation* (RUMELHART et al., 1986, CHAUVIN & RUMELHART, 1995).

O aprendizado supervisionado pode ser implementado de duas maneiras: *off-line* e *on-line*. Os dados utilizados para treinamento *off-line* não mudam e uma vez obtida uma solução para a rede, esta deve permanecer fixa e caso novos dados sejam adicionados, um novo treinamento deve ser realizado incluindo os dados anteriores. Já no aprendizado *on-line* o conjunto de dados muda continuamente, ficando a rede sujeita a um contínuo processo de adaptação.

Um dos exemplos mais comuns de aprendizado supervisionado é o aprendizado por correção de erros. Esse tipo de algoritmo procura minimizar o erro da resposta atual da rede em relação a saída desejada. A expressão para o erro $e(t)$ no instante de tempo t pode ser escrita como:

$$e(t) = y^d(t) - y(t) \quad (4.20)$$

em que $y^d(t)$ é a saída desejada e $y(t)$ é a resposta atual calculada pela rede. A forma genérica para a atualização dos pesos por correção de erros é apresentada na Equação 52:

$$w_i(t+1) = w_i(t) + \eta e(t)x_i(t) \quad (4.21)$$

na qual $w_i(t)$ é o peso da entrada i , η é a taxa de aprendizado, $e(t)$ é uma medida de erro e $x_i(t)$ é a entrada i do neurônio no instante t .

Segundo a Equação 4.21 o ajuste dos pesos deve ser proporcional ao produto do erro pelo valor de entrada da sinapse naquele instante de tempo. Essa expressão aparece tanto no algoritmo de treinamento do *perceptron* (ROSENBLATT, 1958) quanto no algoritmo para treinamento de redes ADALINE (WIDROW & HOFF, 1960), e também na posterior generalização para o algoritmo *backpropagation*. O erro relativo a um conjunto de treinamento com p exemplos é a soma dos erros quadráticos das saídas:

$$\varepsilon^2 = \frac{1}{2} \sum_{i=1}^p (y_i^d - y)^2 \quad (4.22)$$

Calculado sobre o conjunto de exemplos de treinamento (\vec{x}_i, y_i) com p exemplos, na qual y_i^d é a saída desejada para o vetor de entradas \vec{x}_i e y é a saída corrente da rede para o vetor \vec{x}_i .

Para cada valor possível de \vec{w} , a soma dos erros quadráticos do conjunto de dados é calculada e um valor de ε^2 é obtido. A superfície formada por todos os valores de ε^2 resulta na superfície de erro para o conjunto de dados. O valor de \vec{w} que minimiza ε^2 corresponde ao erro mínimo, ou mínimo global, para o conjunto de dados atual. O objetivo do treinamento é encontrar \vec{w} que corresponde ao mínimo na superfície de erro.

Dependendo do tipo de unidade de processamento utilizado para construir a rede, a superfície de erro pode assumir formas diferentes. No caso da rede ser formada por unidades de processamento lineares, a superfície de erro é dada por uma função quadrática dos pesos da rede, podendo a mesma ter um único mínimo. Em redes formadas por unidades não-lineares, a superfície de erro terá uma forma irregular e vários mínimos locais, além do mínimo global.

Outro tipo de aprendizado supervisionado é o aprendizado por reforço. Nesse caso um “crítico” externo procura maximizar o reforço das ações boas executadas pela rede. Ou seja, trata-se de um processo de tentativa e erro que visa maximizar o índice de desempenho escalar chamado de *senal de reforço*.

O termo aprendizado por reforço foi utilizado por Minsky em 1961 em seus trabalhos iniciais de IA. SUTTON et al. (1991) reformularam a ideia de reforço apresentando uma nova interpretação descrevendo que se uma ação tomada pelo sistema de aprendizado é seguida de estados satisfatórios, então a tendência do sistema de produzir essa ação particular é reforçada, já se não for seguida de estados satisfatórios, a tendência do sistema de produzir essa ação é enfraquecida. O aprendizado por reforço se aplica principalmente a problemas de aprendizado envolvendo tarefas de controle nas quais é permitido a rede errar durante o processo de interação com o sistema a ser controlado.

O aprendizado não-supervisionado não requer um “supervisor” e não existe uma saída esperada. Requer que sejam definidas diretrizes para a formação de agrupamentos de características que constituirão diferentes classes. Durante a sessão de treinamento a rede recebe em suas entradas, diferentes padrões que são organizados segundo as categorias definidas. Quando, depois de treinada, a rede recebe um estímulo, é gerada uma resposta indicando a classe a qual tal estímulo pertence. Se a rede não for capaz de encontrar a classe para o estímulo recebido, uma nova classe será gerada, conforme as diretrizes para seleção de características de agrupamentos, incluídas no projeto da rede.

Este tipo de aprendizado se aplica a problemas que visam a descoberta de características estatisticamente relevantes nos dados de entrada, como por exemplo, a descoberta de agrupamentos ou classes. Os modelos mais conhecidos são os mapas auto-organizativos de Kohonen (KOHONEN, 1982) e os modelos ART (CARPENTER & GROSSBERG, 1988). Os algoritmos baseados na regra de Hebb (HEBB, 1949) são também classificados como não-supervisionados, embora necessitem também de pares de entradas e saída para o treinamento. No entanto, nesta metodologia de aprendizado não existe a figura do supervisor externo, sendo o ajuste dos pesos feito independentemente de qualquer critério de desempenho da resposta da rede, por meio de um mecanismo local às sinapses.

O aprendizado Hebbiano é um dos métodos mais importantes de aprendizado em RNAs. A regra de Hebb propõe que os pesos de uma conexão sináptica devem ser ajustados se houver sincronismo entre os níveis de atividade da entrada e saída. Se dois neurônios, em lados distintos de uma sinapse, são ativados sincronamente, tem-se um fortalecimento dessa sinapse. Entretanto, se os neurônios forem ativados assincronamente, a sinapse será enfraquecida ou mesmo eliminada. Ou seja, se um neurônio pré-sináptico tem grande influência na ativação do neurônio pós-sináptico, a conexão entre eles deve ser reforçada.

O ajuste dos pesos no tempo t deve ser proporcional ao produto dos valores de entrada e saída da rede, ou seja:

$$\Delta w_{ij}(t) = \eta y_i(t) x_j(t) \quad (4.23)$$

na qual $w_{ij}(t)$ é o valor do peso j do neurônio i , $x_j(t)$ é o valor da entrada j , $y_i(t)$ é a saída do neurônio i e η é uma constante positiva que determina a taxa de aprendizado.

Outro método de aprendizado não-supervisionado, sendo este um caso particular, é o aprendizado por competição (FUKUSHIMA, 1975; GROSSBERG, 1976). Dado um padrão de entrada, faz-se com que as unidades de saída disputem entre si para serem ativadas. Existe, portanto, uma competição entre as unidades de saída para decidir qual delas será a vencedora e, conseqüentemente, terá sua saída ativada. A unidade vencedora tem os seus pesos atualizados no treinamento. As unidades de entrada são diretamente conectadas às unidades de saída e estas últimas podem estar ligadas entre si via conexões laterais inibitórias.

A unidade de saída com maior ativação inicial terá maior chance de vencer a disputa com as outras unidades, que perderão o poder de inibição ao longo do tempo sobre a unidade de maior ativação. A unidade mais forte fica ainda mais forte e seu efeito inibidor sobre as outras se torna dominante e com o tempo todas as outras unidades de saída ficarão completamente inativas, exceto a vencedora. Este tipo de procedimento é conhecido como WTA - *Winer Takes All* (KOHONEN, 1982).

Dentre os tipos de redes neurais artificiais, o *perceptron* é a arquitetura mais simples, apresentando apenas um conjunto de entradas e uma saída sem haver nenhuma camada de neurônios intermediária (ROSENBLATT, 1958). Este tipo de rede neural é

simples e apresenta problemas específicos, não podendo ser utilizada em aplicações mais avançadas, mas apenas em estruturas de decisão simples.

4.2.6 MLP – Multilayer Perceptron

Redes de uma única camada têm a limitação de resolver apenas problemas com características lineares. No entanto, a não-linearidade está inerente à maioria das situações e problemas reais, sendo necessária a utilização de estruturas com características não-lineares para a resolução de tais problemas.

A não-linearidade está incorporada a modelos neurais através das funções de ativação não-lineares de cada neurônio da rede e da composição de sua estrutura em camadas sucessivas. Assim, a resposta da camada mais externa da rede corresponde à composição das respostas dos neurônios das camadas anteriores. Redes neurais de múltiplas camadas composta por neurônios com funções de ativação não-lineares nas camadas intermediárias são denominadas de *Perceptron de Múltiplas Camadas* (MLP – *Multilayer Perceptron*).

Uma das características mais importantes das redes MLP, segundo CYBENKO (1989), é a capacidade de aproximar qualquer função contínua com uma camada intermediária em sua estrutura. Qualquer função pode ser aproximada por uma rede MLP com duas camadas intermediárias, no entanto não se sabe quantos nós são necessários em cada camada (DUDA *et al.*, 2001).

O comportamento de uma rede MLP pode ser descrito por meio de duas transformações sucessivas, a $H(\vec{x}, \vec{w}_H)$ relativa à camada intermediária e a $Y(H(\vec{x}, \vec{w}_H), w_s)$ relativa à camada de saída, com w_H sendo o vetor de pesos das camadas escondidas e w_s o vetor de pesos da camada de saída.

O processamento realizado por cada neurônio de uma determinada camada é definido pela combinação dos processamentos realizados pelos neurônios da camada anterior que estão conectados a ele. Quando se segue da primeira camada intermediária em direção a camada de saída, as funções implementadas se tornam cada vez mais complexas. Estas funções definem como é realizada a divisão do espaço de decisão.

Para uma rede com pelo menos duas camadas intermediárias, pode-se dizer que o seguinte processamento ocorre em cada uma das camadas:

- Primeira camada intermediária: cada neurônio contribui com retas para a formação de superfícies no espaço de entrada;
- Segunda camada intermediária: cada neurônio combina as retas descritas pelos neurônios da camada anterior conectados a ele, formando regiões convexas, onde o número de lados é definido pelo número de unidades conectados a ele;
- Camada de saída: cada neurônio forma regiões que são combinações das regiões convexas definidas pelos neurônios da camada anterior a ela conectados. Os neurônios definem, dessa maneira, regiões com formatos diversos.

As camadas intermediárias de uma MLP geram uma codificação interna para os padrões de entrada, que é então utilizada pela camada de saída da rede. Dado um número suficientemente grande de unidades intermediárias, é possível formar representações internas para qualquer conjunto de padrões de entrada.

A grande maioria dos problemas práticos raramente necessita de mais de uma camada intermediária (BRAGA *et al.*, 2007). A utilização de duas camadas intermediárias somente é necessária quando a função a ser aproximada apresenta descontinuidades. Assim, a utilização de um número maior de camadas pode levar a problemas de convergência da rede, já que as camadas intermediárias trabalham com estimativas de erro e quando em maior quantidade, podem dificultar a convergência global da rede.

Uma vez definido o número de camadas, é necessário determinar as funções de ativação de cada camada. Os teoremas que tratam da questão de aproximação universal de funções por redes MLP não são restritivos quanto às funções de ativação utilizadas. Assim, todas as funções apresentadas anteriormente atendem aos requisitos básicos de universalidade. Obviamente, deve-se utilizar funções de ativação não-lineares nas camadas intermediárias para que a composição das funções nas camadas sucessivas seja capaz de resolver os problemas de maior ordem no espaço de entrada. A utilização de funções puramente lineares em múltiplas camadas resultaria em uma rede de uma única

camada, já que transformações lineares sucessivas podem ser descritas como uma única transformação linear.

Deste modo, pelo menos uma das camadas intermediárias deverá ter funções de ativação não-lineares. As redes MLP se caracterizam pela utilização de funções sigmoidais nas camadas intermediárias e sigmoidais ou lineares na saída. Normalmente, as funções lineares na saída são utilizadas em problemas de aproximação de funções e as sigmoidais em problemas de classificação. A utilização de funções gaussianas na camada escondida e lineares na saída caracteriza as redes RBF – *Radial Basis Functions* (BROOMHEAD & LOWE, 1988).

A definição do número de neurônios em cada camada da rede é de extrema importância para o seu desempenho, principalmente no que se refere à sua capacidade de generalização. O número de neurônios determina a capacidade da rede em resolver problemas de determinada complexidade. Quanto maior o número de neurônios, maior a complexidade da rede e maior a sua abrangência em termos de soluções possíveis.

O problema básico de dimensionamento envolve um ajuste entre a complexidade do modelo e a complexidade do problema a ser resolvido. Existem várias abordagens para contornar e solucionar este problema, que variam desde a estimativa do número efetivo de parâmetros utilizados em Regularização Bayesiana (MACKAY, 1992) às técnicas de validação (AMARI *et al.*, 1996) e à abordagem multiobjetivo para treinamento de redes neurais (TEIXEIRA *et al.*, 2000).

A estimativa do número de neurônios de forma empírica corresponde ao ajuste de outra função-objetivo para a resolução do problema, além da minimização do erro quadrático. Assim, procura-se por uma rede de estrutura mínima que atenda aos requisitos de minimização do erro quadrático do conjunto de treinamento. Esta abordagem empírica para a resolução do problema corresponde ao que Boser *et al.* caracterizam como minimização do risco estrutural (BOSER *et al.*, 1992).

Tem-se uma rede MLP com n entradas, uma única camada escondida com N_e neurônios e uma camada de saída com m neurônios. Esta estrutura neural possuirá um total de n_p pesos, que pode ser calculado com:

$$n_p = (n \cdot N_e + N_e) + (N_e \cdot m + m) \quad (5.24)$$

sendo que N_e e m são os termos de polarização dos neurônios das camadas escondida e de saída, respectivamente. Como n e m são inerentes ao problema e a formulação de sua solução, somente N_e é um parâmetro que altera a estrutura e a complexidade da rede para um determinado problema. O aumento de N_e causará um aumento linear no número total de parâmetros n_p da rede. Para duas redes R_1 e R_2 com números diferentes de parâmetros, n_{p1} e n_{p2} respectivamente, onde $n_{p1} > n_{p2}$ e $\Delta n_p = n_{p1} - n_{p2}$, tem-se que as soluções alcançadas por R_1 serão todas aquelas descritas por R_2 mais aquelas proporcionadas pela diferença de parâmetros Δn_p . As duas redes terão complexidades equivalentes quando os Δn_p parâmetros adicionais de R_1 forem nulos.

O aumento no número de parâmetros causará o crescimento no número de soluções possíveis para se alcançar a solução de um determinado problema, já que a rede com maior número de parâmetros incluirá além das soluções dos modelos de menor complexidade, mais aquelas geradas pelos parâmetros adicionais. Considerando somente o erro de treinamento como critério único de seleção do modelo, essa interpretação é equivalente a se dizer que quanto maior o número de neurônios na rede, maior será o número de soluções que atendem ao critério de minimização do erro. No entanto, as soluções que se aproximam da função geradora dos dados estão em número restrito no espaço de soluções e não aumentam em quantidade com o aumento do número de parâmetros. Assim, quanto maior o número de parâmetros, mais difícil é a busca pelas soluções que se aproximam da função geradora dos dados.

O algoritmo de treinamento de redes MLP mais utilizado é o *backpropagation* e ocorre em duas fases, em que cada fase percorre a rede em um sentido. Essas fases são chamadas de fase *forward* e fase *backward*. A primeira é utilizada para definir a saída da rede para um dado padrão de entrada. Já fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões.

O algoritmo de treinamento *backpropagation* é conceitualmente uma generalização do algoritmo de aprendizado de Widrow e Hoff - *Least Mean Square* (LMS), também conhecido como Regra Delta (KOSCO, 1992; KOVÁCS, 1996 e KARTALOPOULOS, 1996). Neste algoritmo que se enquadra na categoria de aprendizagem supervisionada, o desempenho da rede é medido por uma função erro que considera, para cada um dos diversos padrões p de entrada, o quadrado da diferença

entre o valor esperado e a respectiva saída calculada. Em outras palavras, o erro é o somatório dos erros quadráticos, definido pela seguinte expressão:

$$E = \sum_i E_i = \frac{1}{2} \sum_i (y_i^d - y_i)^2 \quad (4.25)$$

onde E_i representa o erro do elemento neural, para o dado padrão de entrada, y_i^d é a saída desejada no elemento neural, para um dado padrão de entrada e y_i é a saída produzida, definida como:

$$y_i = f(a_i) = f\left(\sum_j w_{ij} x_j - \theta_i\right) \quad (4.26)$$

sendo x_j uma componente do padrão de entrada X_p .

O algoritmo *backpropagation* atua nos pesos sinápticos, minimizando a função erro, por meio da técnica do gradiente descendente. Neste método, os valores dos pesos são modificados proporcionalmente ao oposto da derivada do erro, de acordo com a seguinte expressão:

$$\Delta w_{ij} = -\eta \frac{\partial E_i}{\partial w_{ij}} \quad (4.27)$$

onde η é a taxa de aprendizado.

Definindo-se $y_i^{d,k}$, como a saída desejada na unidade da camada, quando o padrão é apresentado à rede e,

$$y_i^k = f_i(a_i^k) \quad (4.28)$$

a função erro na camada k pode ser escrita como:

$$E_k = \frac{1}{2} \sum_i (y_i^{d,k} - y_i^k)^2 \quad (4.29)$$

A correção nos pesos na camada de saída k é dada pela aplicação da regra da cadeia:

$$\Delta w_{ij}^k = -\eta \frac{\partial E^k}{\partial w_{ij}^k} = -\eta \sum_i \frac{\partial E^k}{\partial O_i^k} \frac{\partial O_i^k}{\partial a_i^k} \frac{\partial a_i^k}{\partial w_{ij}^k} = \eta \sum_p \delta_i^k y_j^{k-1} \quad (4.30)$$

sendo

$$\delta_i^k = f'(a_i^k) (y_i^{d,k} - y_i^k) \quad (4.31)$$

Similarmente, pode ser mostrado que nas camadas intermediárias a correção é dada por:

$$\Delta w_{ij}^k = -\eta \sum_i \frac{\partial E^k}{\partial w_{ij}^k} = \eta \sum_i \delta_i^k y_j^{k-1} \quad (4.32)$$

com

$$\delta_i^k = f'(a_i^k) \sum_j w_{ij}^{k+1} \delta_j^{k+1} \quad (4.33)$$

O algoritmo *backpropagation* ajusta os pesos das unidades das camadas intermediárias a partir dos erros das unidades da camada de saída. Para iniciar este processo de aprendizado é necessário estabelecer:

- i) um conjunto de padrões de entrada e respectivas saídas esperadas;
- ii) a taxa de aprendizado η ;
- iii) um critério de parada, com o qual se dará o treinamento como concluído;
- iv) uma função de ativação.

A aplicação do algoritmo *backpropagation* envolve um deslocamento para frente, através da rede, para calcular as saídas de cada elemento neural da camada de saída e o seu respectivo erro. A segunda fase envolve um deslocamento no sentido contrário, durante o qual o sinal de erro é passado para cada elemento e as mudanças nos pesos são efetuadas. A rede é treinada através da apresentação de todos os dados de treinamento repetidas vezes. Em cada iteração, a diferença entre o valor da saída e o valor esperado determina a correção que deverá ser feita nos valores dos pesos e dos limiares. Os valores dos pesos são ajustados após cada etapa de treinamento, até que a função erro seja reduzida a um valor tido como aceitável.

A principal dificuldade encontrada no treinamento de redes MLP com o algoritmo *backpropagation* está relacionada à sua sensibilidade às características da superfície de erro, o que dificulta a sua convergência em regiões de baixo gradiente e de mínimos locais. Uma forma de minimizar esse problema é considerar efeitos de segunda ordem para o gradiente descendente.

Algumas abordagens podem ser utilizadas tanto para acelerar o algoritmo quanto para reduzir os *efeitos* dos mínimos locais: utilizar taxa de aprendizado decrescente, adicionar ruídos aos dados ou utilizar um termo *momentum* (RUMELHART & McCLELLAND, 1986). O termo *momentum* é representado pela Equação 25:

$$\psi = \alpha(w_{ji}(t) - w_{ji}(t-1)) \quad (4.34)$$

A expressão para ajuste dos pesos utilizando o termo *momentum* pode ser descrito como:

$$w_{ji}(t+1) = w_{ji}(t) + \eta \delta_j(t) x_i(t) + \psi \quad (4.35)$$

A inclusão do termo ψ na expressão de ajuste dos pesos adiciona inércia ao aprendizado, resultando em um aumento de velocidade de convergência em regiões de descida da superfície de erro, já que o novo ajuste será sempre adicionado a uma parcela do ajuste anterior.

Outro problema relacionado à convergência do algoritmo *backpropagation* é conhecido como *flat spot* (FAHLMAN, 1988), que ocorre quando a derivada da função sigmoideal de uma unidade se aproxima de zero durante o treinamento. Esse efeito ocorre, pois a derivada da função sigmoideal se aproxima de zero quando a saída y do neurônio se aproxima de um dos seus limites de saturação. Existem algumas propostas para a solução deste problema: utilizar uma medida de erro que tenda para o infinito quando a derivada da sigmoideal tender a zero (FRANZINI, 1987); adicionar uma constante a derivada, evitando que o erro seja igual a zero e utilizar uma função de erro não-linear (ANDREWS & GEVA, 1994).

O algoritmo *backpropagation*, em algumas aplicações, pode ser muito lento e seu desempenho piora sensivelmente para problemas maiores e mais complexos. Mesmo para problemas simples, o algoritmo geralmente requer que todos os padrões de treinamento sejam apresentados centenas ou até mesmo milhares de vezes. Isso limita a

utilização prática, permitindo apenas o treinamento de pequenas redes, com poucos milhares de pesos ajustáveis (BISHOP, 1995).

Desde a sua criação, várias modificações do algoritmo *backpropagation* têm sido propostas visando tanto a acelerar seu tempo de treinamento quanto a melhorar seu desempenho. Dessas variações, as mais utilizadas são:

- *backpropagation* com *momentum* (RUMELHART & McCLELLAND, 1986);
- Quickprop (FAHLMAN, 1988);
- Levenberg-Marquardt (HAGAN & MENHAJ, 1994);
- *Momentum* de segunda ordem (PEARLMUTTER, 1992);
- Newton (BATTITI, 1991);
- Rprop (RIEDMILLER, 1994);
- MOBJ (TEIXEIRA *et al.*, 2000);

Assim, neste trabalho foi utilizado uma rede do tipo *backpropagation*, utilizando *momentum*. As características da rede desenvolvida serão descritas no Capítulo 7.

CAPÍTULO 5

5. AQUISIÇÃO E PROCESSAMENTO DOS DADOS

5.1 SCGR DO IAG/USP

A aquisição de dados 2D foi realizada no SCGR nas linhas de 2 a 7, nas direções X e Y. Foram necessárias três etapas de aquisição, a primeira no período de chuva que compreendeu os meses de Fevereiro e Março com as antenas de 200 e 400 MHz (Figura 5.1), a segunda etapa no período sem chuva, nos meses de Agosto e Setembro com as antenas de 200 e 400 MHz e a terceira etapa com as antenas de 270 e 900 MHz. As antenas blindadas utilizadas foram da fabricante americana GSSI – *Geophysical Survey System, Inc.*, de propriedade do Departamento de Geofísica do IAG/USP (200 e 400 MHz) e do Museu de Arqueologia e Etnologia - MAE da USP (270 e 900 MHz), no modo contínuo. No total foram adquiridos 132 perfis, para todas as frequências, que estão descritos na Tabela 5.1.

Os parâmetros de aquisição foram: traços a cada 2 cm, 512 amostras por traço, janela temporal de 110 ns (200 e 270 MHz) e 80 ns (400 e 900 MHz) e constante dielétrica de 5 (solo argiloso seco) e 12 (solo argiloso saturado). A constante dielétrica foi corrigida durante o processamento, para fornecer uma profundidade correta do alvo. Durante a aquisição foram dados ganhos lineares para melhorar a visualização dos dados em campo. Na direção Y os perfis possuem 30 m de comprimento, já os perfis na direção X, apenas sobre os alvos, possuem 4 m de comprimento.



Figura 5.1 - Aquisição de dados no SCGR. a) Antena de 400 MHz. b) Antena de 200 MHz.

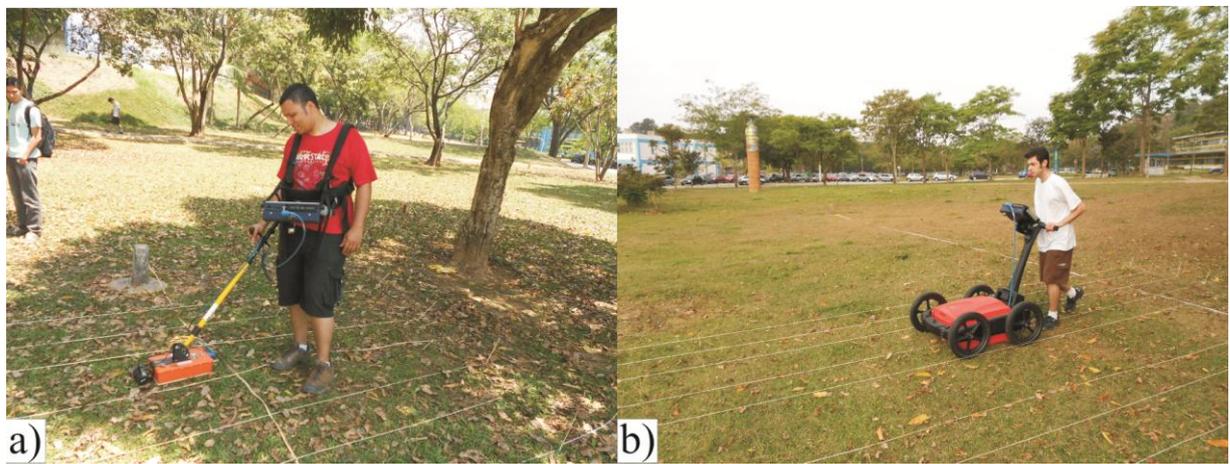


Figura 5.2 - Aquisição de dados no SCGR. a) Antena de 900 MHz. b) Antena de 270 MHz.

Tabela 5.1 - Número de perfis adquiridos na área do SCGR.

Linha	Direção	Frequência			
		200 MHz	270 MHz	400 MHz	900 MHz
2	X	8	-	6	-
	Y	2	1	2	1
3	X	15	-	6	-
	Y	2	1	2	1
4	X	14	-	10	-
	Y	2	1	2	1
5	X	4	-	4	-
	Y	2	1	2	1
6	X	10	-	9	-
	Y	2	1	2	1
7	X	6	-	4	-
	Y	2	1	2	1

O processamento dos dados obtidos no SCGR foi realizado visando preservar ao máximo as características do sinal. As etapas de processamento utilizadas foram:

1. *Edição do header*: modificação, se necessário, de alguns parâmetros de campo ou do meio, como constante dielétrica, janela temporal, posição do traço ou qualquer outra informação que se julgar necessário;
2. *Ajuste do tempo zero*: correção da posição do tempo zero no radargrama;
3. *Remoção do ganho de tela*: remoção do ganho utilizado durante a aquisição;
4. *Background removal*: filtro 2D que permite remover ruídos horizontais e atua também como um filtro passa alta;
5. *Filtros temporais 1D*: remoção de frequências não desejadas utilizando filtro passa banda;
6. *Ganho linear*: realçar as difrações hiperbólicas para melhor caracterização.

O processamento foi realizado no software RADAN 7.0 (GSSI, 2003). No Apêndice G são apresentados os resultados do processamento dos dados obtidos no SCGR, para as linhas de 2 a 7. Os retângulos em branco mostram os alvos utilizados para a extração de características para cada linha e a numeração corresponde ao objeto segundo a Figura 2.3.

5.2 USP CAMPUS SÃO PAULO

Para a validação da metodologia de identificação e classificação automática utilizando GPR e RNA foram realizadas algumas aquisições GPR na Cidade Universitária. Foram selecionadas algumas áreas com a ajuda da Prefeitura do Campus, onde existem tubulações plásticas, metálicas e de concreto (Figura 5.3). Foram adquiridos 152 perfis (Tabela 5.2), com antenas de 200 e 400 MHz, distribuídos entre a rotatória do Instituto de Biologia, Praça do Relógio, Raia Olímpica da USP, IAG, Escola Politécnica (POLI – Engenharia de Minas) e o Centro de Práticas Esportivas da USP (CEPE). Nas Figuras 5.4 e 5.5 temos algumas ilustrações das aquisições.



Figura 5.3 - Áreas escolhidas na Cidade Universitária para aquisição GPR (foto de satélite: Google Earth).

Tabela 5.2 - Número de perfis adquiridos na área da Cidade Universitária.

Local	Frequência	
	200 MHz	400 MHz
Biologia	17	8
Praça do Relógio	21	19
Raia Olímpica	21	11
IAG	-	10
POLI	15	16
CEPE	4	10

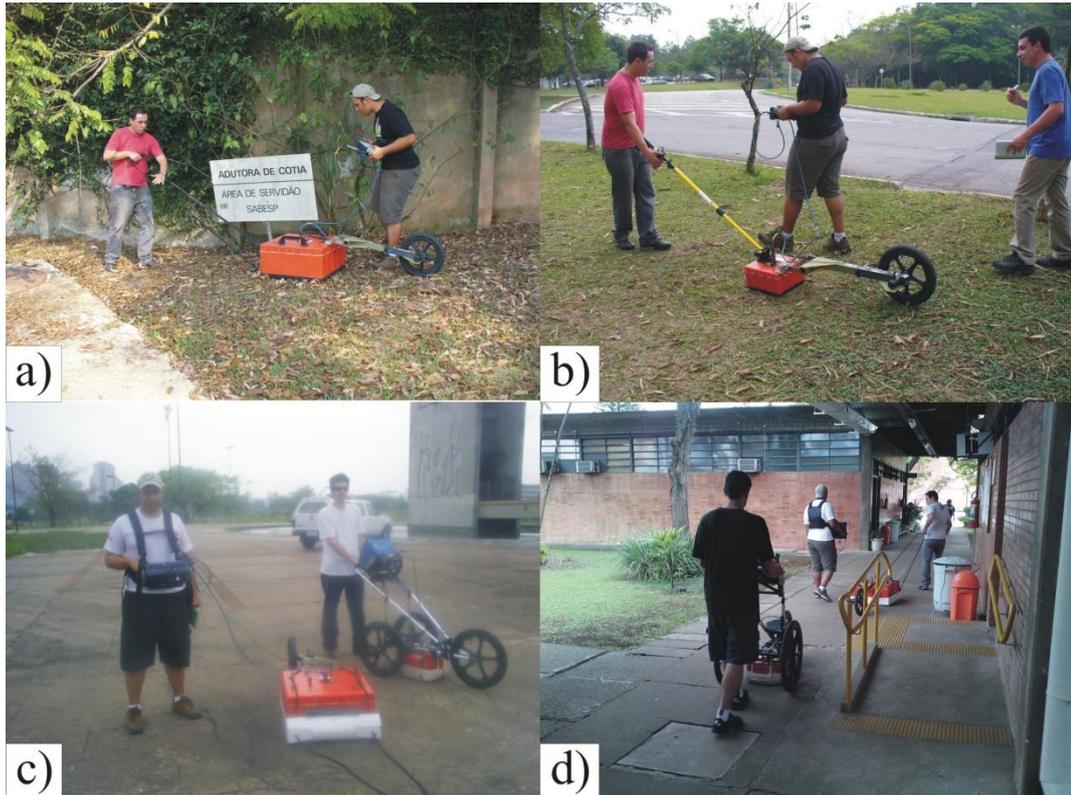


Figura 5.4 - Aquisição de dados na Cidade Universitária. a) Biologia (200 MHz). b) Biologia (400 MHz). c) Praça do Relógio (200 e 400 MHz). d) CEPE (200 e 400 MHz).

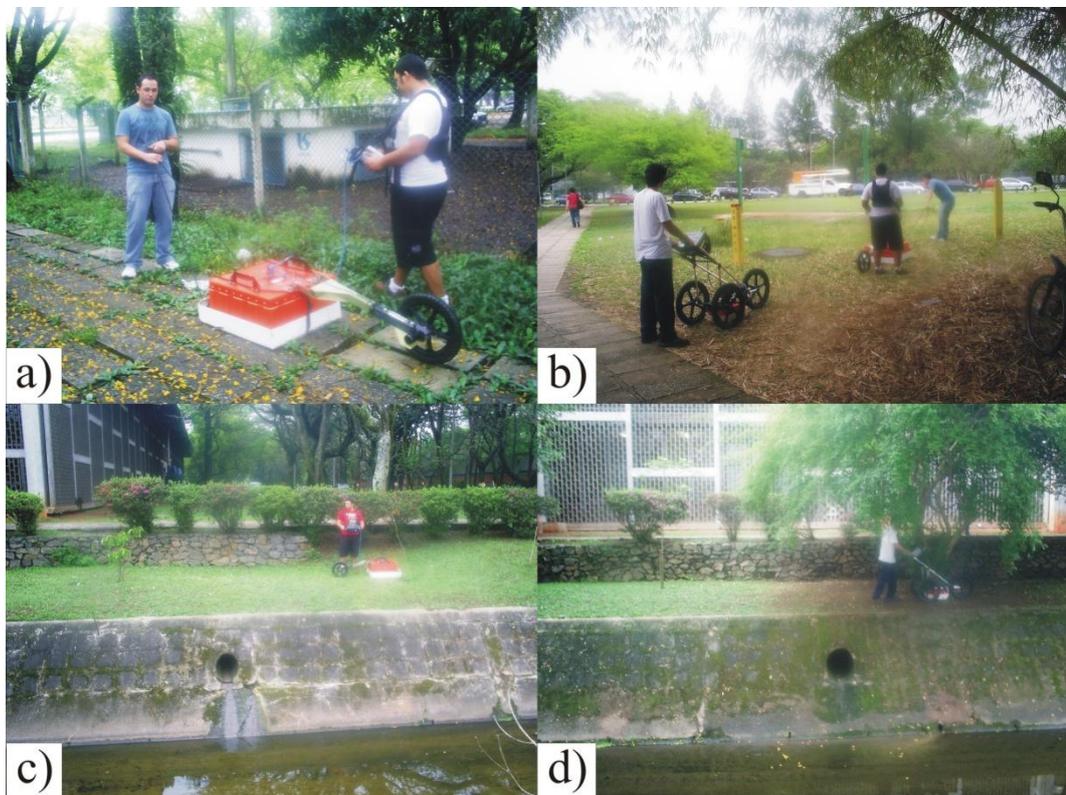


Figura 5.5 - Aquisição de dados na Cidade Universitária. a) Raia Olímpica (200 MHz). b) Raia Olímpica (200 e 400 MHz). c) Escola Politécnica (200 MHz). d) Escola Politécnica (400 MHz).

O processamento foi realizado de forma semelhante aos dados obtidos no SCGR. Estes dados foram utilizados para a validação da metodologia proposta nesta pesquisa, onde primeiramente as hipérboles são identificadas e em seguida são classificadas como alvos plásticos, metálicos ou de concreto. Exemplos de perfis obtidos na POLI (manilhas de concreto) com as antenas de 200 e 400 MHz podem ser vistos na Figura 5.6.

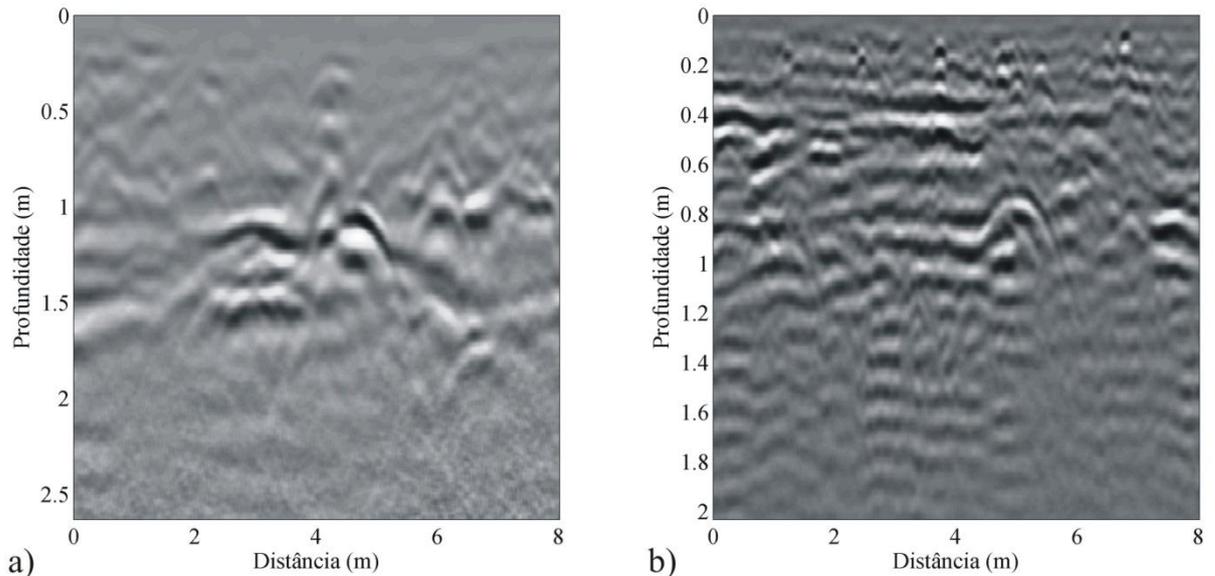


Figura 5.6 - Exemplos de perfis GPR obtidos na Escola Politécnica. a) 200 MHz. b) 400 MHz.

5.3 USP CAMPUS PIRASSUNUNGA

Outra forma de validação da metodologia proposta consistiu de aquisições GPR fora da cidade de São Paulo, para que a geologia dos locais de treinamento e teste da rede mudasse. O local escolhido foi a cidade de Pirassununga (Figura 5.7), situada a 190 km de São Paulo, onde localiza-se o Campus Pirassununga da Universidade de São Paulo. Dessa forma, com apoio da prefeitura do Campus, foram selecionadas algumas áreas onde existem tubulações plásticas, metálicas ou de concreto. Foi realizado um trabalho conjunto com a prefeitura com o objetivo de encontrar e classificar tubulações pré-existentes para auxiliar nas futuras obras de instalação de tubos e cabos.

A geologia da cidade de Pirassununga é formada basicamente pela formação Pirassununga (Terciário), apresentando uma granulometria de 67,03% de areia, 7,43%

de silte e 25,52% de argila (MASSOLI, 1983). A diferença para a área da Cidade Universitária em SP diz respeito à quantidade de argila, pois na cidade de São Paulo a presença deste material é maior, o que faz com que a onda eletromagnética do GPR sofra maior atenuação com relação ao Campus de Pirassununga.

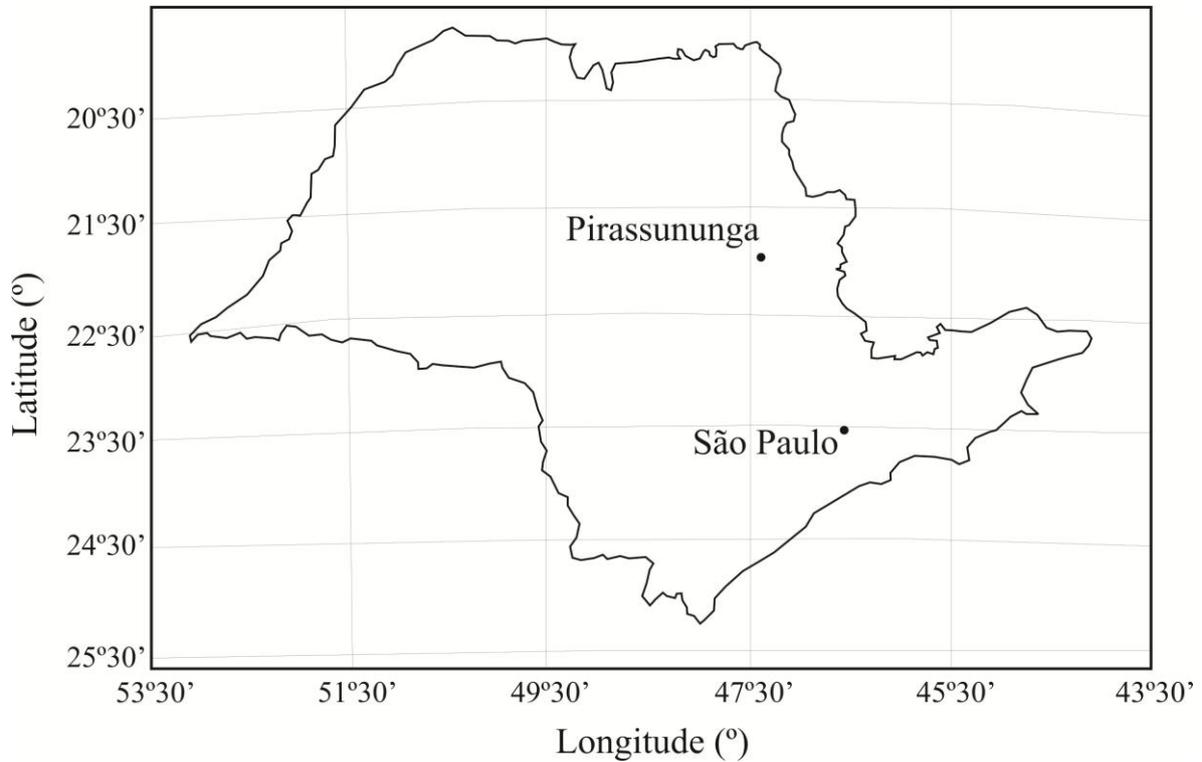


Figura 5.7 – Mapa de localização da cidade de Pirassununga no Estado de São Paulo.

As aquisições foram realizadas no prédio do FZEA (Faculdade de Zootecnia e Engenharia de Alimentos), em frente aos Edifícios Leste e Oeste, no refeitório, nas ruas em torno do Prédio Principal e bem como no interior do prédio. Algumas imagens das aquisições podem ser vistas a seguir na Figura 5.8. As antenas utilizadas foram de 270 e 900 MHz, com os mesmos parâmetros utilizados nas aquisições no SCGR e no Campus da Capital. A Figura 5.9 ilustra alguns exemplos de perfis obtidos no Campus de Pirassununga.



Figura 5.8 - Aquisição de dados na USP campus de Pirassununga com antenas de 270 e 900 MHz. a) Refeitório do Campus. b) Prédio do FZEA (Edifício Leste). c) Rua lateral ao Prédio Principal. d) Rua em frente ao Prédio Principal.

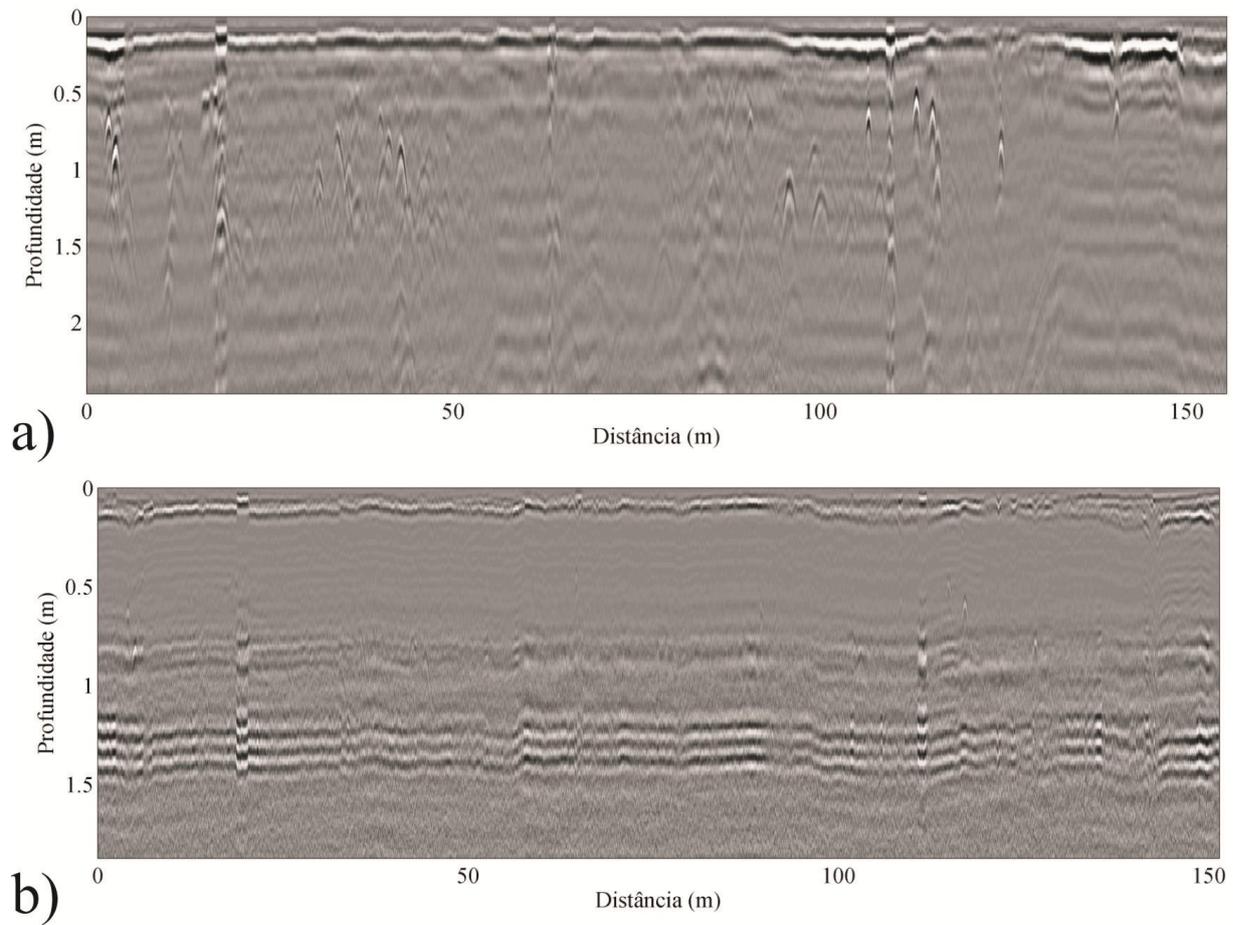


Figura 5.9 - Exemplo de perfis GPR obtidos no campus da USP em Pirassununga. a) 270 MHz. b) 900 MHz.

CAPÍTULO 6

6. EXTRAÇÃO DE CARACTERÍSTICAS

As técnicas desenvolvidas neste estudo para a detecção e classificação automática de alvos em perfis GPR envolvem um grau considerável de técnicas de processamento de sinais, combinados com técnicas de classificação de inteligência artificial. RNAs foram escolhidas em particular para auxiliar na identificação e interpretação do reconhecimento de alvos em potencial e rejeição de dados indesejados. Nas seções seguintes, uma descrição detalhada é apresentada das técnicas de discriminação que foram testadas.

A análise descrita neste capítulo resolve este problema através da redução da dimensionalidade dos dados, destacando regiões dentro dos dados que contêm reflexões (Figura 6.1), com base em propriedades específicas do sinal (A-scan) ou imagem (B-scan). Esta redução permite um processamento dos dados mais exaustivo e os resultados em termos de eficiência computacional melhorada na estimativa da posição do alvo e da composição.

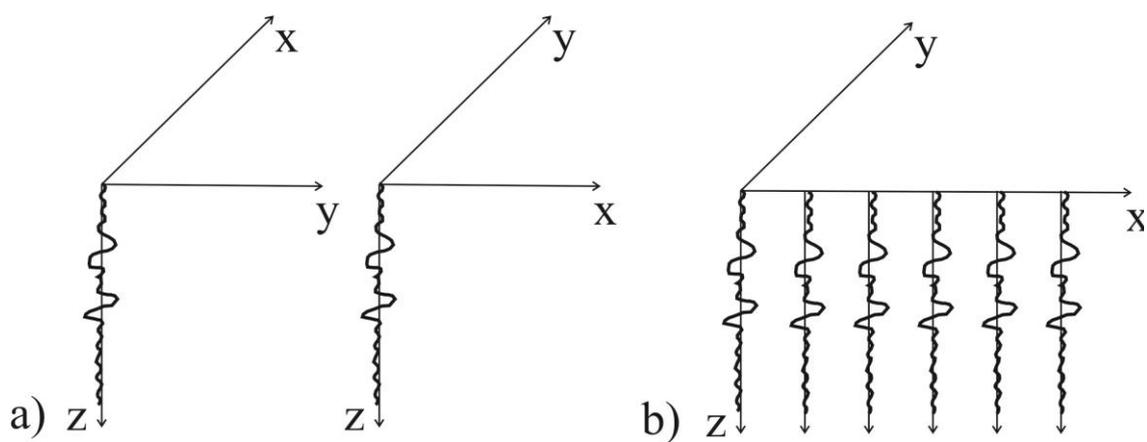


Figura 6.1 - Exemplos de A-scan (a) e B-scan (b) (Adaptado de DANIELS, 2007).

No caso ideal, um sinal recebido pela antena receptora num ponto particular deve corresponder a uma anomalia que está situada junto a esse ponto. Na realidade, o sinal transmitido se propaga ao longo de mais de um caminho antes de ser captado pela antena receptora, devido à natureza das antenas e da geometria do arranjo de aquisição de dados. Assim, o sinal recebido seria uma combinação de diferentes reflexões ao longo de diferentes caminhos. O processo de detecção e classificação dos alvos visa, primeiramente, distinguir os alvos reais de outras reflexões indesejadas.

O primeiro passo e mais importante para uma classificação automática rápida e robusta é identificar com sucesso os dados relacionados a alvos e rejeitar os demais, a fim de reduzir a quantidade do conjunto de dados com o qual as fases subsequentes tratariam e este seria o limitante do custo computacional adicional durante as etapas posteriores de processamento.

Todos os alvos que foram possíveis identificar nos perfis GPR (Apêndice G) foram utilizados para a extração de características, em um total de 294 A-scans (Tabelas 6.1 e 6.2), em ambas as direções.

Tabela 6.1 - Número de A-scans utilizados para a determinação das características utilizando antenas de 200 e 400 MHz.

Frequência (MHz)	Tipo de Alvo	Período seco	Período chuvoso
200	Plástico	18	18
	Concreto	16	14
	Metal	33	33
400	Plástico	16	16
	Concreto	8	6
	Metal	27	25

Tabela 6.2 - Número de A-scans utilizados para a determinação das características utilizando antenas de 270 e 900 MHz.

Frequência (MHz)	Tipo de Alvo	Número de alvos
270	Plástico	12
	Concreto	7
	Metal	18
900	Plástico	11
	Concreto	2
	Metal	14

Apesar dos operadores optarem por lidar com dados de radar na forma de B-scans, pois é mais fácil e mais conveniente, é interessante mencionar que todas as informações da subsuperfície das áreas digitalizadas estão contidas em reflexões individuais (A-scans). Apesar deste fato, é quase impossível para um operador diferenciar, primeiramente, entre as reflexões que representam alvos e outras não úteis e mais difícil ainda é classificar o alvo quanto ao tipo de material. Este fato pode ser claramente observado nas figuras abaixo (Figuras 6.2, 6.3, 6.4 e 6.5), onde sinais tanto de alvos plásticos, metálicos, de concreto ou de “não alvo”, parecem muito semelhantes. Com base nisso, torna-se crucial encontrar as características que possam fornecer uma boa discriminação entre os alvos e “não alvos”.

O processo de seleção das características adequadas para um sinal é uma das tarefas mais crítica e importante. Há dois pontos que deve-se ter em mente quando se está procurando por tais descritores. O primeiro ponto é a natureza do sinal, pois algumas características podem ser úteis em algumas aplicações e não em outras. A segunda é que a característica selecionada deve, de alguma maneira, realçar esta característica do sinal que é quase exclusiva para essa classe de sinais, para que possa ser discriminado de outras classes. Além dos dois fatores acima, um terceiro motivo de preocupação neste estudo é o tempo de processamento.

Durante os últimos anos, muitas tentativas foram feitas por diversos pesquisadores para produzir técnicas de segmentação automáticas (Al-NUAIMY *et al.*, 2000b e Al-NUAIMY *et al.*, 2003) e essas técnicas variam de um para outro em muitos aspectos, tais como confiabilidade, precisão e velocidade.

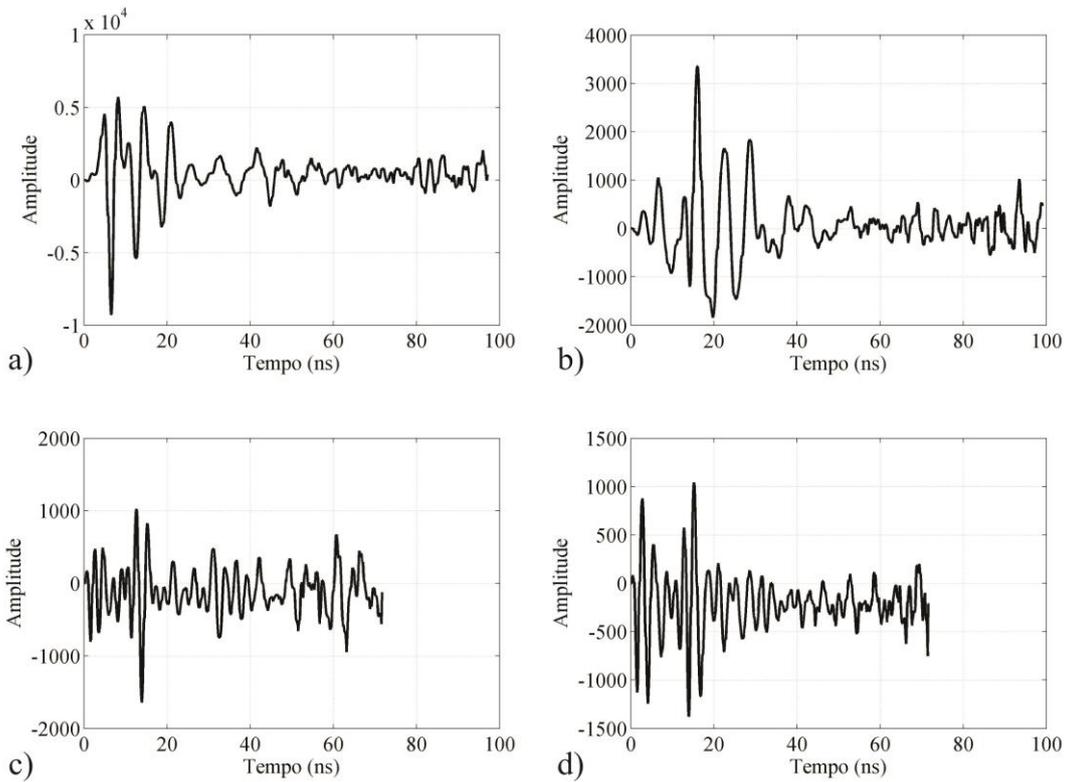


Figura 6.2 - Exemplo de A-scan para “não alvo”. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.

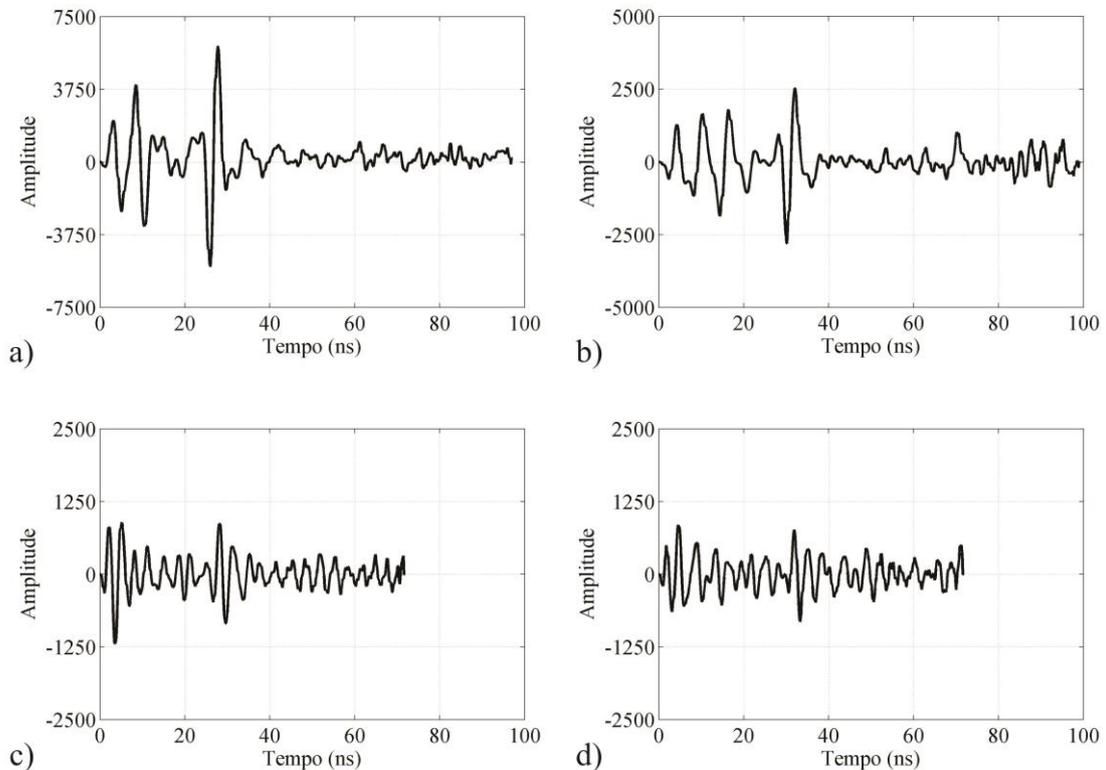


Figura 6.3 - Exemplo de A-scan para alvo plástico. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.

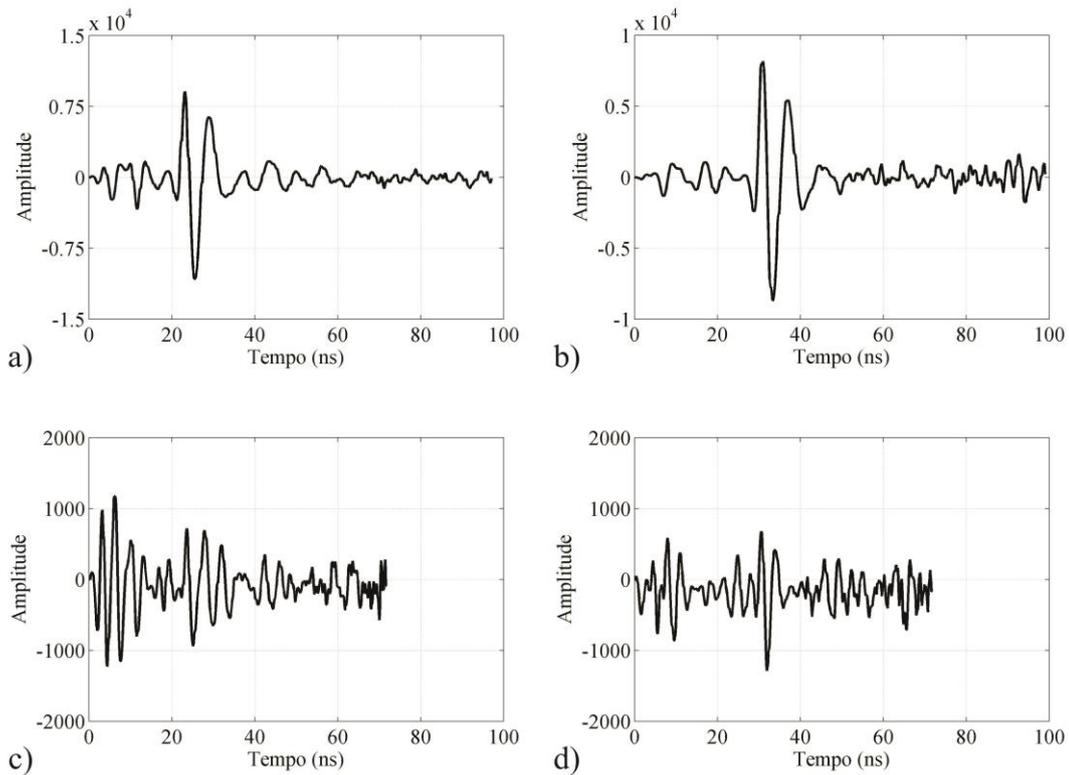


Figura 6.4 - Exemplo de A-scan para alvo de concreto. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.

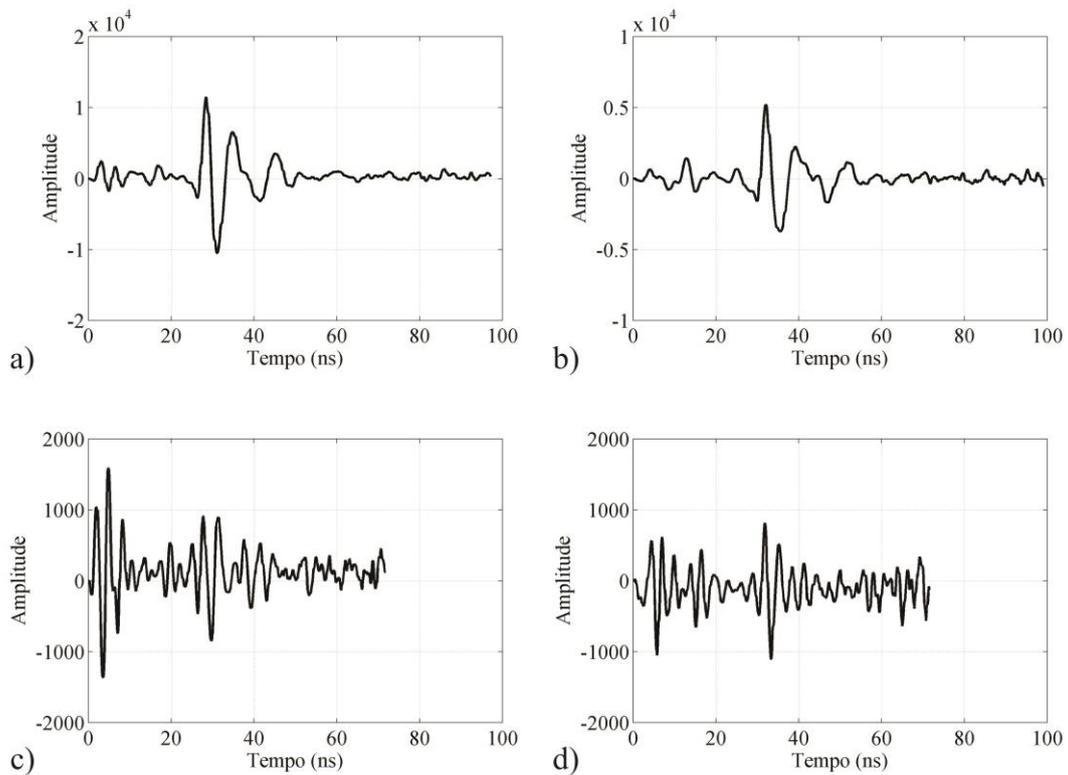


Figura 6.5 - Exemplo de A-scan para alvo metálico. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.

Com base na literatura, as características escolhidas para se ter uma melhor discriminação entre os sinais GPR são:

- **Características estatísticas** (PAPOULIS, 1984 e GONZALEZ & WOODS, 1992): variância, desvio médio absoluto e quarto momento.
- **Características espectrais** (ROSA, 2010; SHIHAB, 2005; COHEN, 1995): densidade espectral (*Power Spectral Density* - PSD), Transformada de Fourier no tempo curto (*Short time Fourier Transform* - STFT), Distribuição Wigner-Ville (*Wigner-Ville Distribution* - WVD) e as Transformadas contínua e discreta da Wavelet (*Continuous Wavelet Transform* – CWT e *Discrete Wavelet Transform* - DWT).

A descrição, bem como as equações matemáticas de todas as características estudadas encontram-se nos Apêndices de A a F.

6.1 CARACTERÍSTICAS ESTATÍSTICAS

Para cada A-scan calculou-se a variância, o desvio médio absoluto e o quarto momento, utilizando os valores de amplitude, para verificar a existência de algum padrão. A variância nos dá uma medida de dispersão estatística e pode ser chamada de segundo momento central. Já o desvio médio absoluto calcula a diferença absoluta entre cada elemento e o valor médio do conjunto de dados. O quarto momento ou curtose caracteriza a curva da função de distribuição de probabilidade.

6.2 CARACTERÍSTICAS ESPECTRAIS

Diferentes representações no domínio da frequência dos dados de séries temporais facilitam a tarefa de reconhecimento de padrões, extraindo características diferentes do sinal (SANTOS et. al, 2014). Como não se sabe quais dos recursos são diretamente relevantes para a discriminação acima, algumas representações espectrais foram investigadas.

6.2.1 Densidade Espectral – PSD (*Power Spectral Density*)

Uma sequência de amostras pode ser representada por um conjunto de coeficientes espectrais chamado de densidade espectral (PSD – *Power Spectral Density*), que fornece uma medida significativa da distribuição da potência média em uma série de tempo (WELCH, 1967). Uma estimativa PSD chama-se de periodograma. As Figuras 6.6 e 6.7 mostram dois exemplos de periodogramas obtidos com a antena de 200 MHz no período seco, onde o primeiro discrimina os traços com alvo dos traços sem alvo. Já o segundo periodograma diferencia o tipo de material em subsuperfície.

Pelas figuras observa-se que o PSD pode fornecer uma boa discriminação entre os tipos de alvos estudados. Na presença de alvos, os valores de PSD são maiores em relação aos traços sem alvos e isso já era esperado, pois a amplitude do sinal geralmente é maior na presença de alvos. Os alvos metálicos apresentaram uma maior amplitude de densidade espectral em comparação com os alvos de plástico e de concreto. Entre os alvos resistores ainda existe uma pequena ambiguidade na amplitude do PSD, sendo que estes valores são muito próximos. No início de cada curva observa-se a presença de um ruído de baixa frequência presente na maioria dos dados.

Utilizando o PSD podemos definir duas características: a amplitude máxima do espectro e a frequência correspondente a este máximo. Para a determinação destas duas características utilizou-se um “filtro passa alta”, para que o ruído de baixa frequência não influenciasse na determinação destas características. Uma melhor visualização foi obtida através do zoom da região do pico na media do espectro de densidade, sendo que este zoom é mostrado nas figuras.

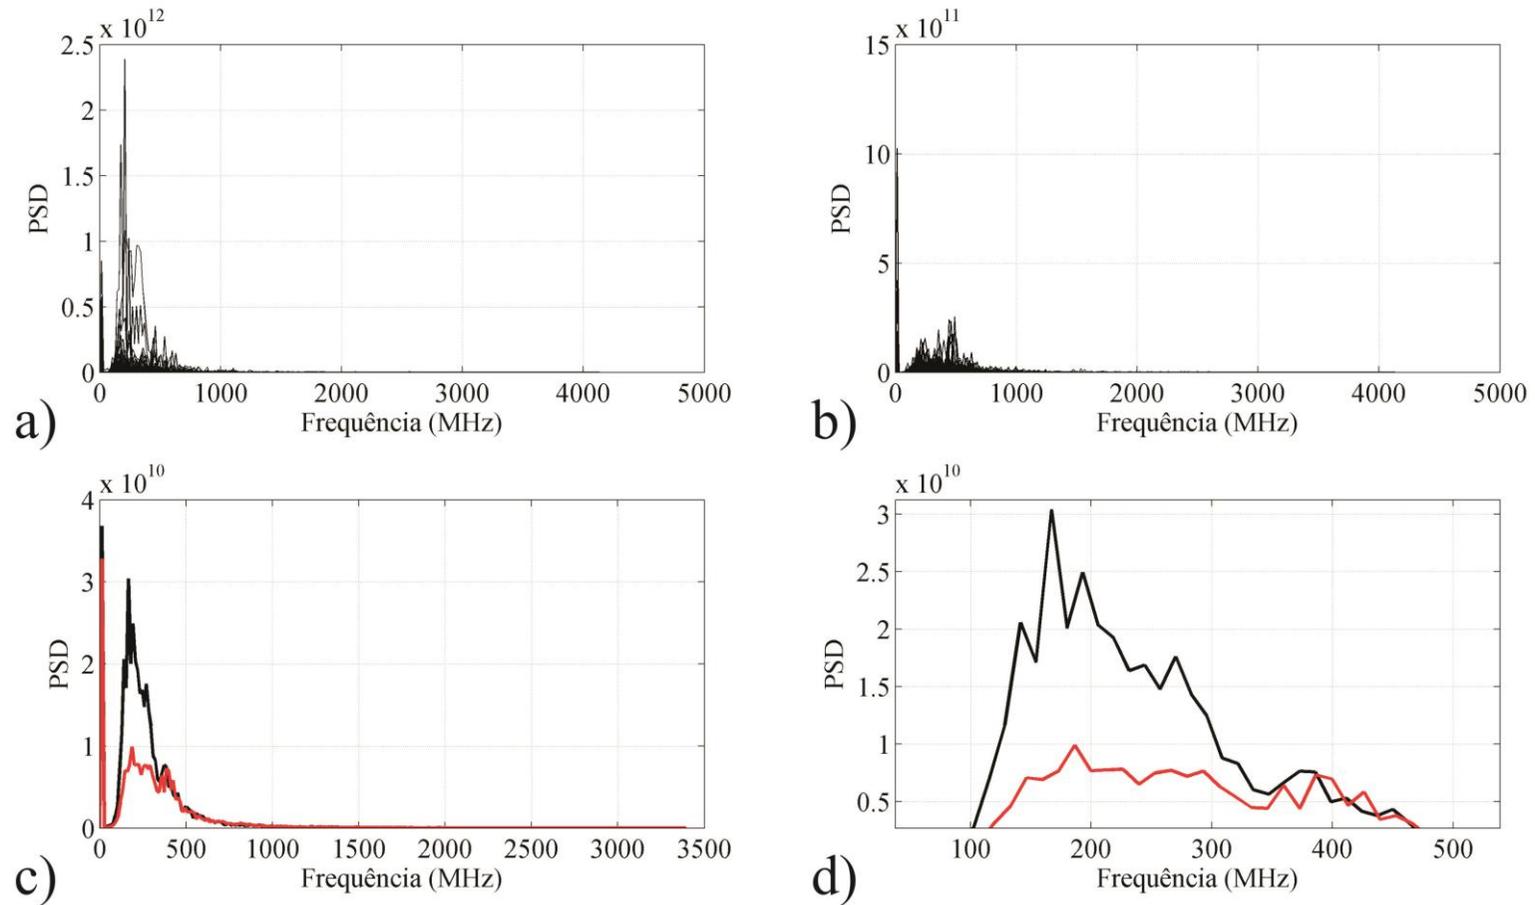


Figura 6.6 - Exemplo de periodograma obtido com antena de 200 MHz no período seco. a) Periodograma para traços com alvos. b) Periodograma para traços sem alvos. c) Média dos periodogramas de todos os traços (preto: com alvo e vermelho: sem alvo). d) Zoom do pico da média dos valores mostrado em c).

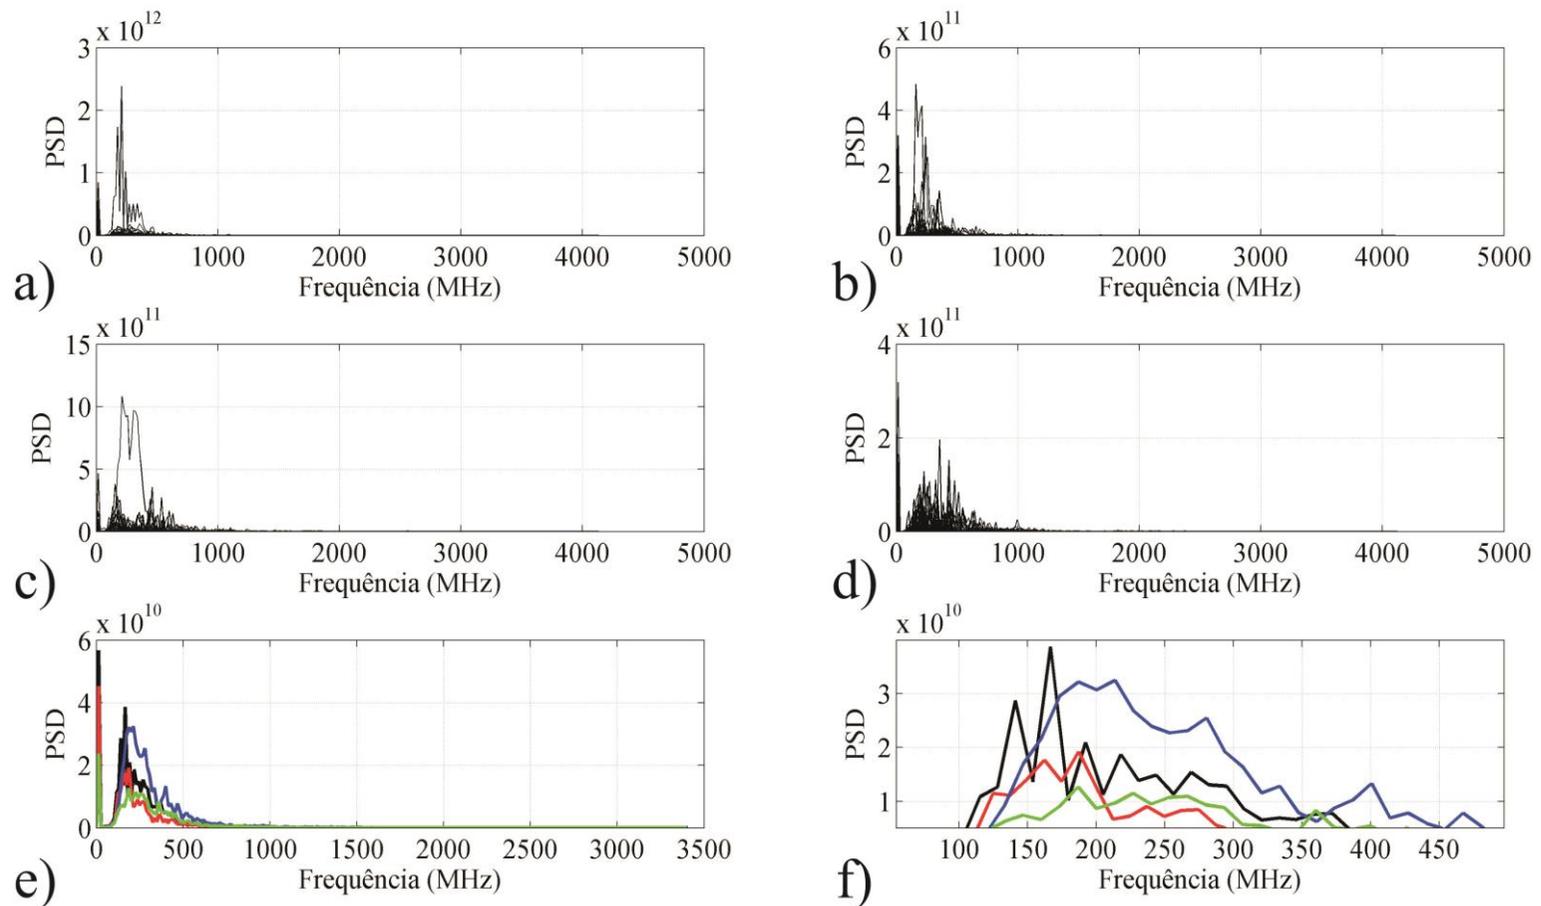


Figura 6.7 - Exemplo de periodograma obtido com antena de 200 MHz no período seco. a) Periodograma para traços com alvos de plástico. b) Periodograma para traços com alvos de concreto. c) Periodograma para traços com alvos de metal. d) Periodograma para traços sem alvos. e) Média dos periodogramas de todos os traços (preto: plástico, vermelho: concreto, azul: metal e verde: sem alvo). f) Zoom do pico da média dos valores mostrado em e).

6.2.2 Transformada de Fourier no tempo curto – STFT (*Short time Fourier Transform*)

Em alguns casos práticos é necessário estabelecer como varia, com o tempo, o conteúdo de frequências do sinal. Para resolver esse problema, uma solução consiste em se aplicar a Transformada de Fourier no tempo curto (ou Transformada móvel de Fourier ou *Running Fourier Transform* ou *Short Time Fourier Transform* - STFT), que corresponde a uma técnica de decomposição espectral ou decomposição tempo-frequência (ROSA, 2010).

A superfície do espectrograma é analisada em cada passo de tempo, a fim de quantificar aspectos característicos da série no tempo. As características extraídas são a frequência e magnitude do pico do espectro em cada ponto no eixo do tempo. A amplitude apresentou uma pequena variação com relação ao material, já a frequência não apresentou uma diferença significativa.

As Figuras de 6.8 a 6.13 mostram exemplos do espectrograma para um alvo metálico (tambor metálico a 0,5 m de profundidade, localizado em 7 m da Linha 4), para as frequências de 200 (seco e úmido), 270, 400 (seco e úmido) e 900 MHz. Já na Figura 6.14 observa-se a diferença entre os tipos de materiais estudados para um exemplo obtido com a antena de 200 MHz em ambiente seco. Para cada imagem podemos determinar a amplitude da STFT em função do tempo e da frequência (Figura 6.15). As duas características obtidas foram a amplitude do pico e a frequência correspondente a este pico.

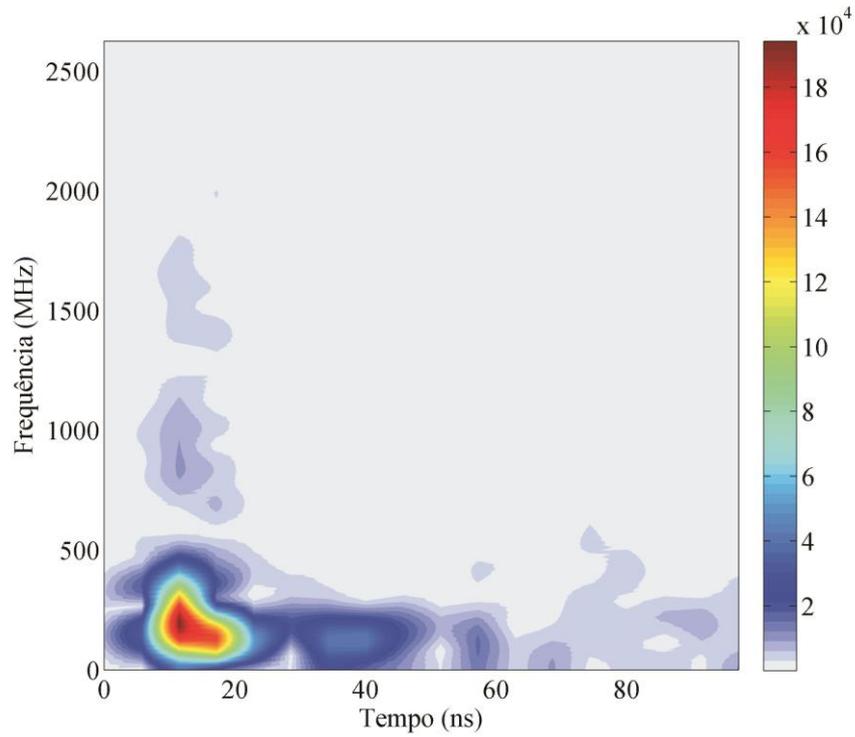


Figura 6.8 - Exemplo de STFT para alvo metálico com antena de 200 MHz no período seco.

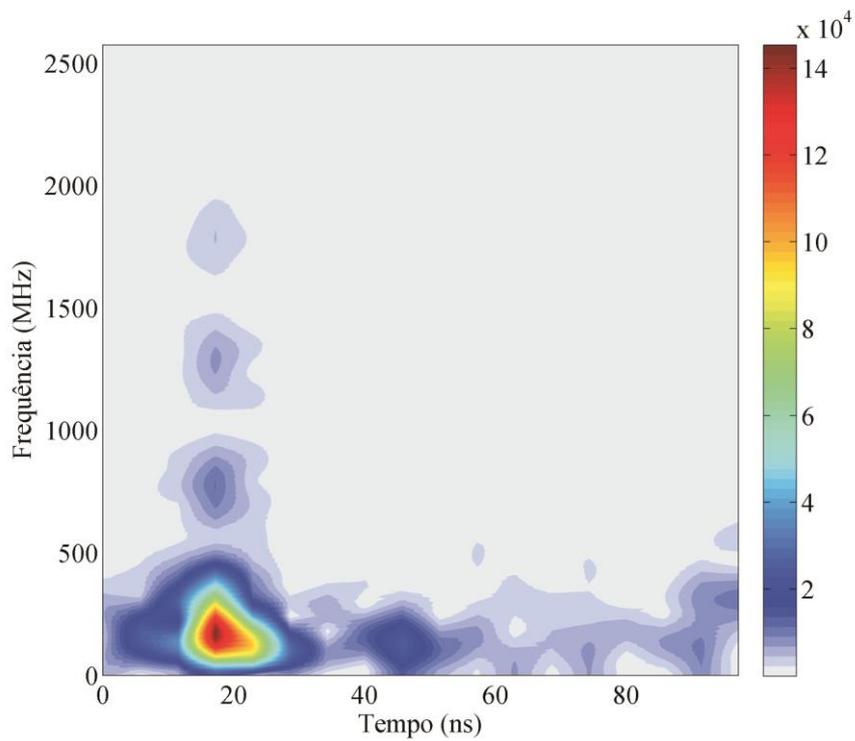


Figura 6.9 - Exemplo de STFT para alvo metálico com antena de 200 MHz no período úmido.

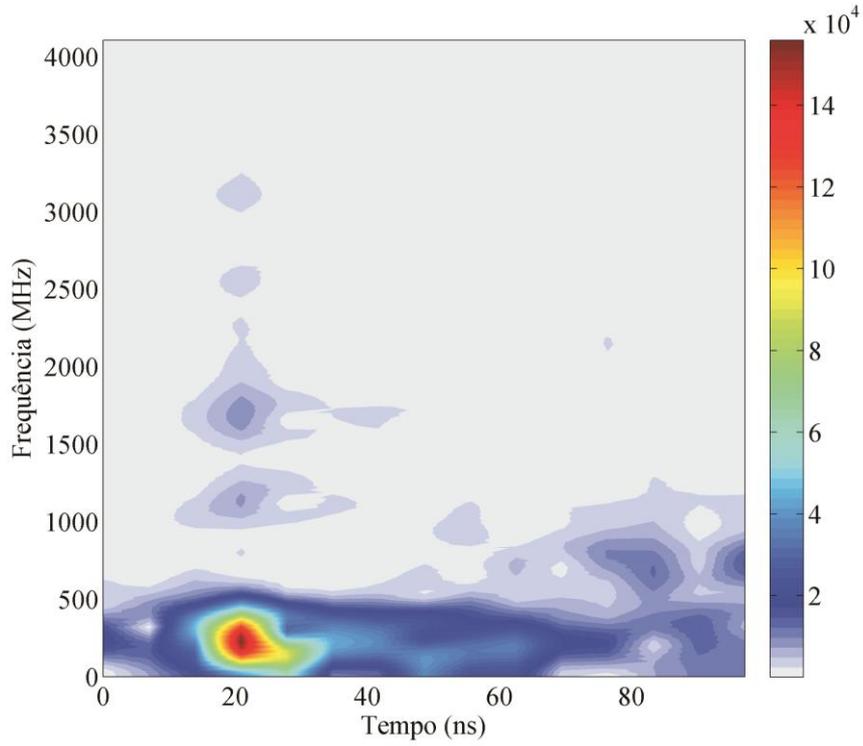


Figura 6.10 - Exemplo de STFT para alvo metálico com antena de 270 MHz.

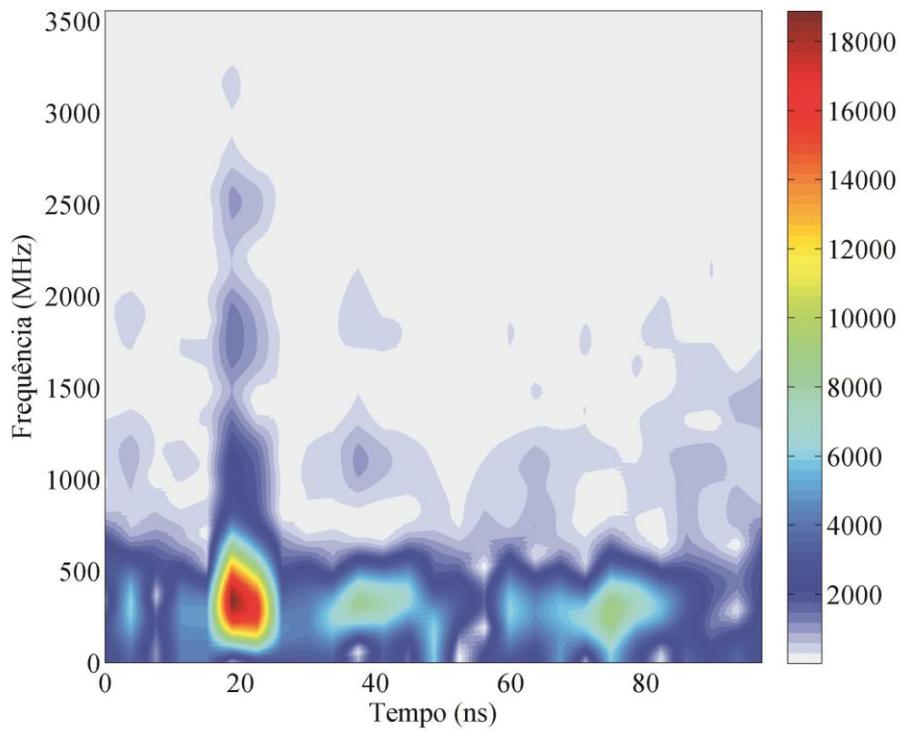


Figura 6.11 - Exemplo de STFT para alvo metálico com antena de 400 MHz no período seco.

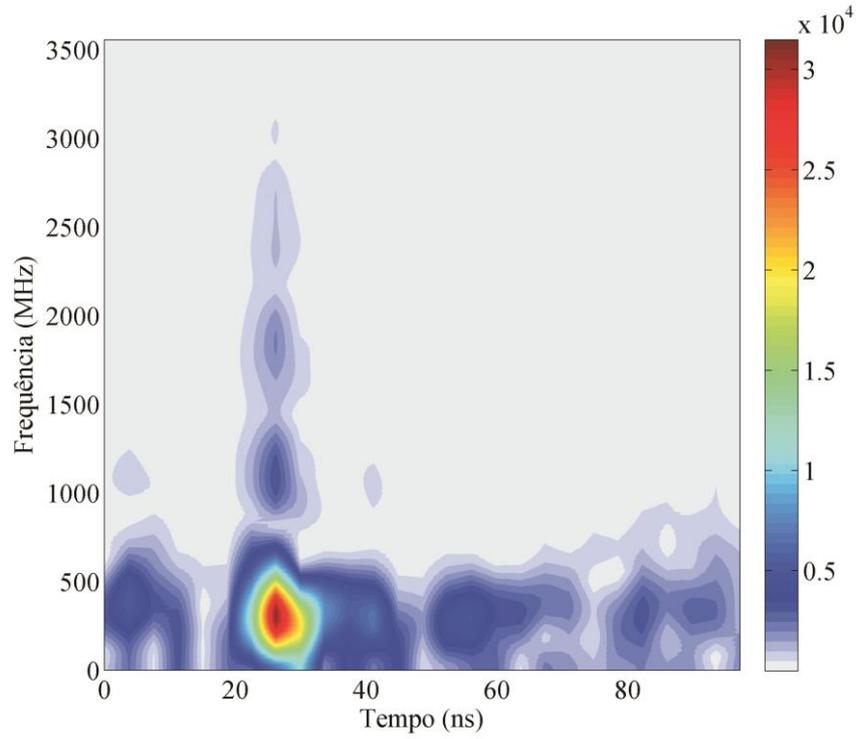


Figura 6.12 - Exemplo de STFT para alvo metálico com antena de 400 MHz no período úmido.

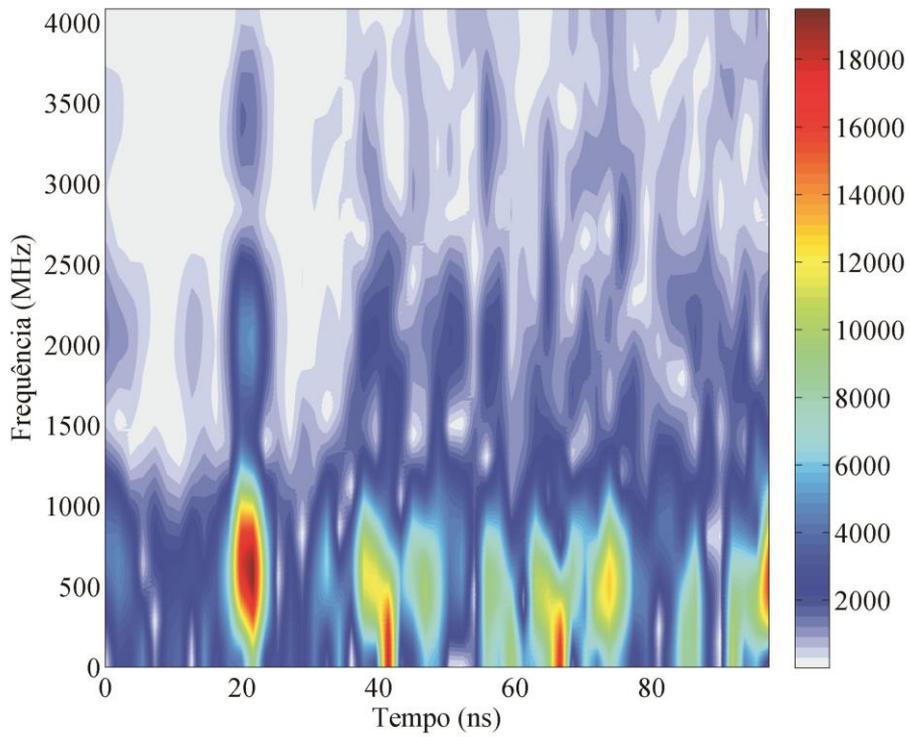


Figura 6.13 - Exemplo de STFT para alvo metálico com antena de 900 MHz.

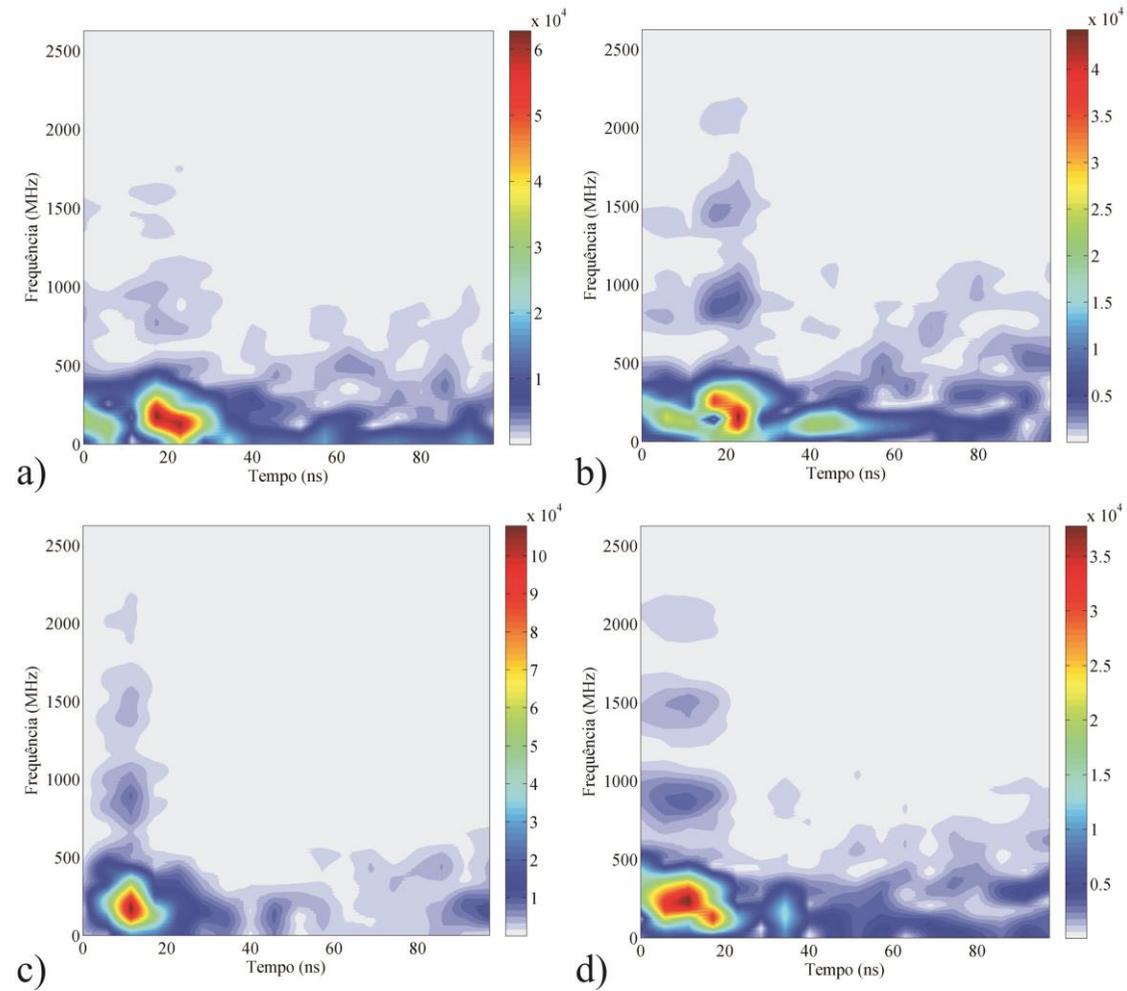


Figura 6.14 - Exemplo de STFT com antena de 200 MHz no período seco para diferentes tipos de alvos. a) Plástico. b) Concreto. c) Metal. d) Sem alvo.

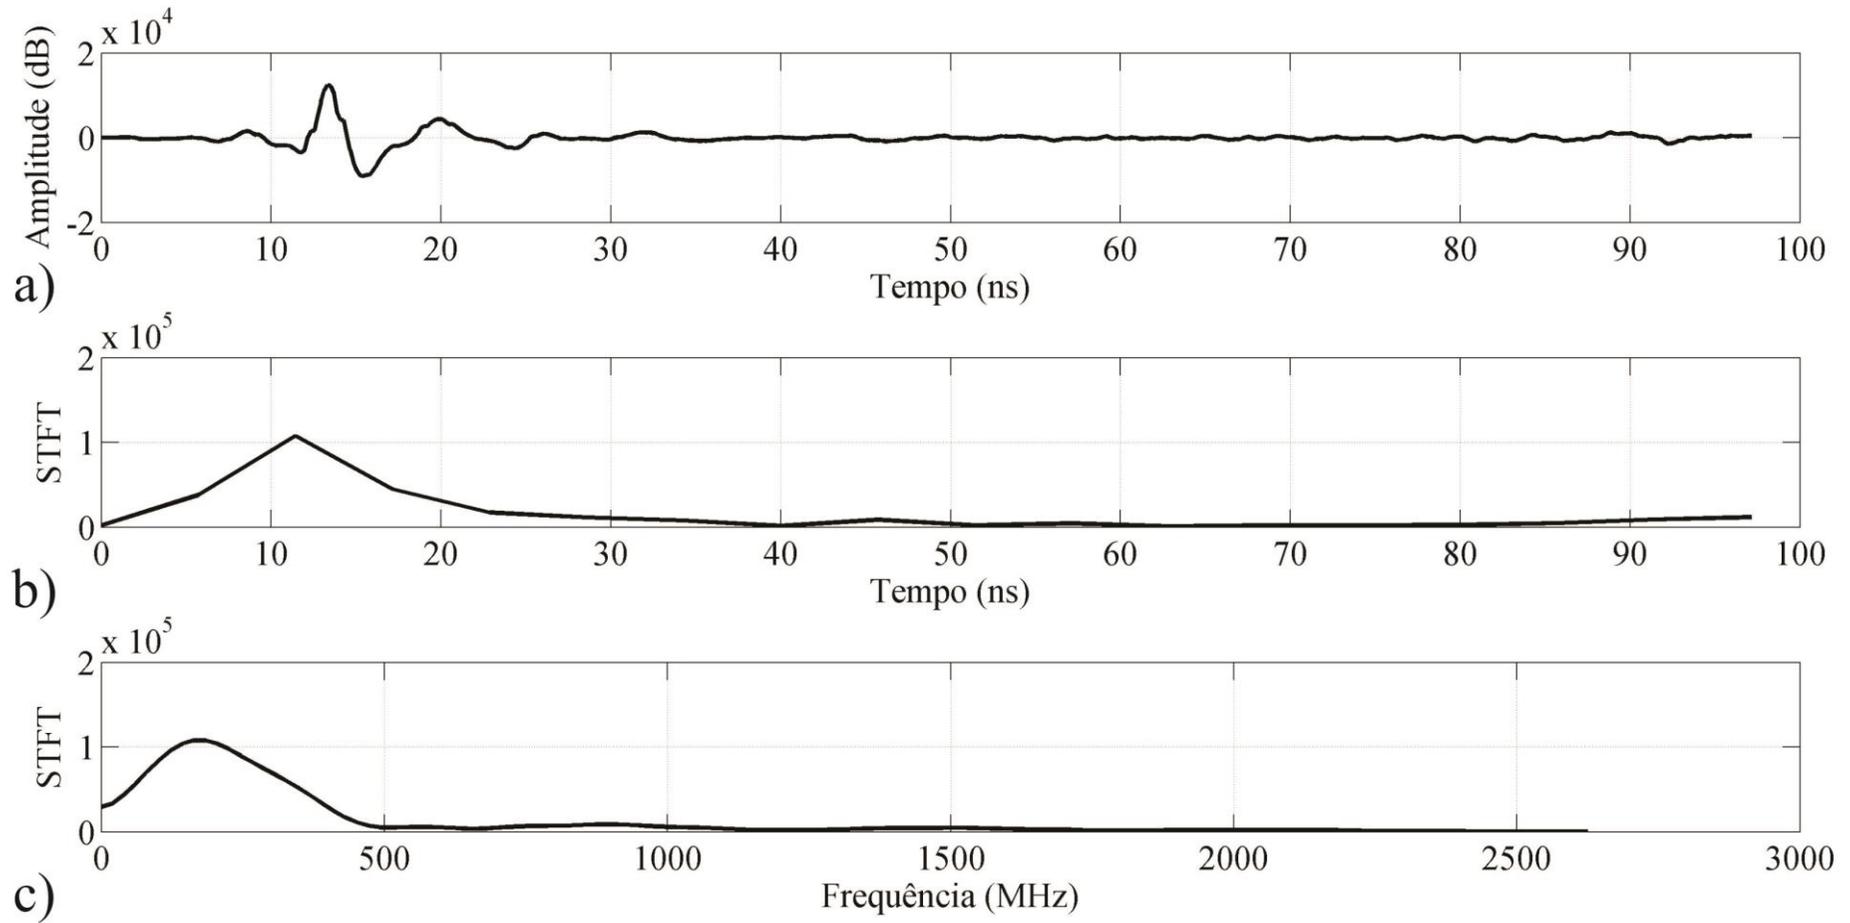


Figura 6.15 - Exemplo de STFT para antena de 200 MHz no período seco. a) Sinal original. b) STFT em função do tempo. c) STFT em função da frequência.

6.2.3 Distribuição Wigner-Ville – WVD (*Wigner-Ville Distribution*)

A distribuição *Wigner-Ville* (WVD – *Wigner-Ville Distribution*) é uma técnica tempo-frequência amplamente aplicada em uma variedade de casos. A WVD pode ser definida como uma densidade espectral instantânea (COHEN, 1995 e SEJDIC et al., 2009).

Para cada A-scan correspondente aos alvos plásticos, metálicos e de concreto calculou-se a WVD e obteve-se a distribuição no plano *Tempo x Frequência* e a partir deste pode se determinar *Tempo x Amplitude* e *Frequência x Amplitude*. Nas figuras a seguir (Figuras 6.16 a 6.21) temos alguns exemplos dos resultados obtidos para a WVD para o mesmo tambor metálico da Linha 4, com diferentes frequências de antenas.

Após o cálculo da WVD para os sinais GPR, a magnitude do pico correspondente a cada instante de tempo é tomada como uma característica. Uma segunda característica, que representa a frequência do pico correspondente ao valor da amplitude máxima da WVD é extraída. Uma desvantagem importante do método é o seu custo de tempo extremamente alto, quando comparado com outros métodos apresentados neste estudo.

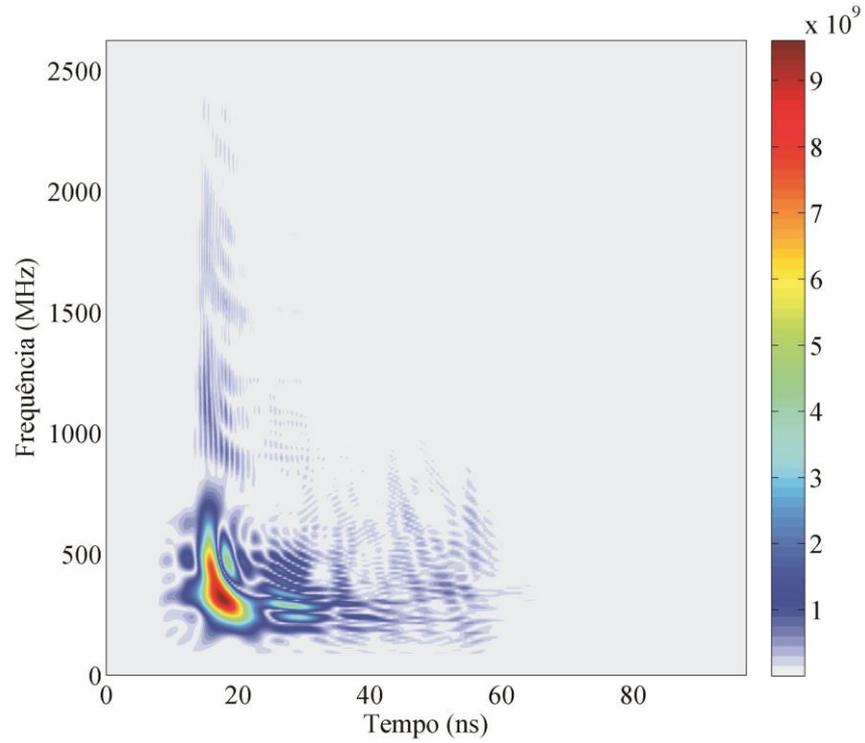


Figura 6.16 - Exemplo de WVD para alvo metálico com antena de 200 MHz no período seco.

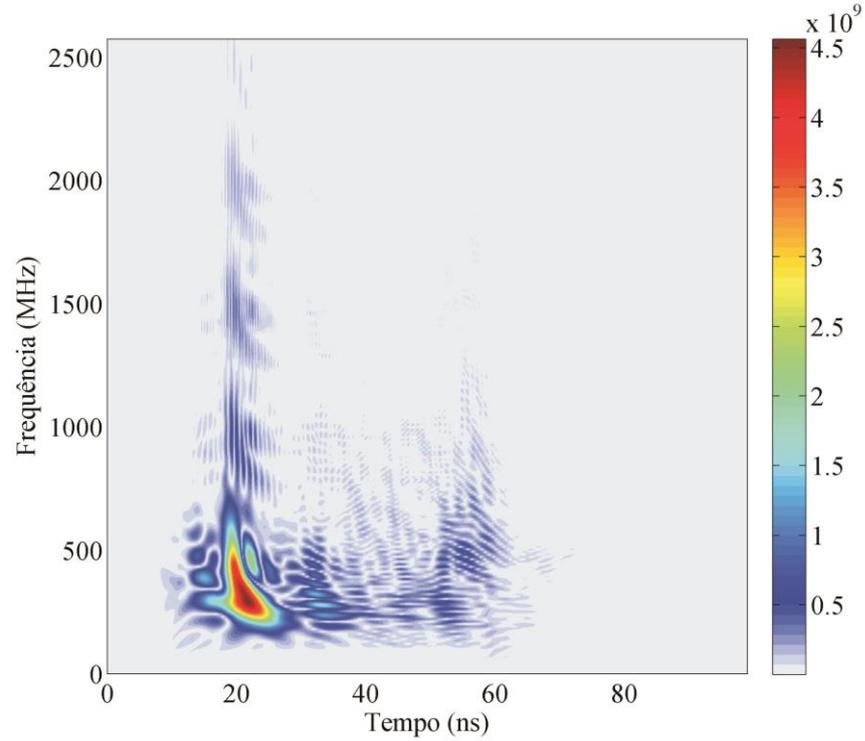


Figura 6.17 - Exemplo de WVD para alvo metálico com antena de 200 MHz no período úmido.

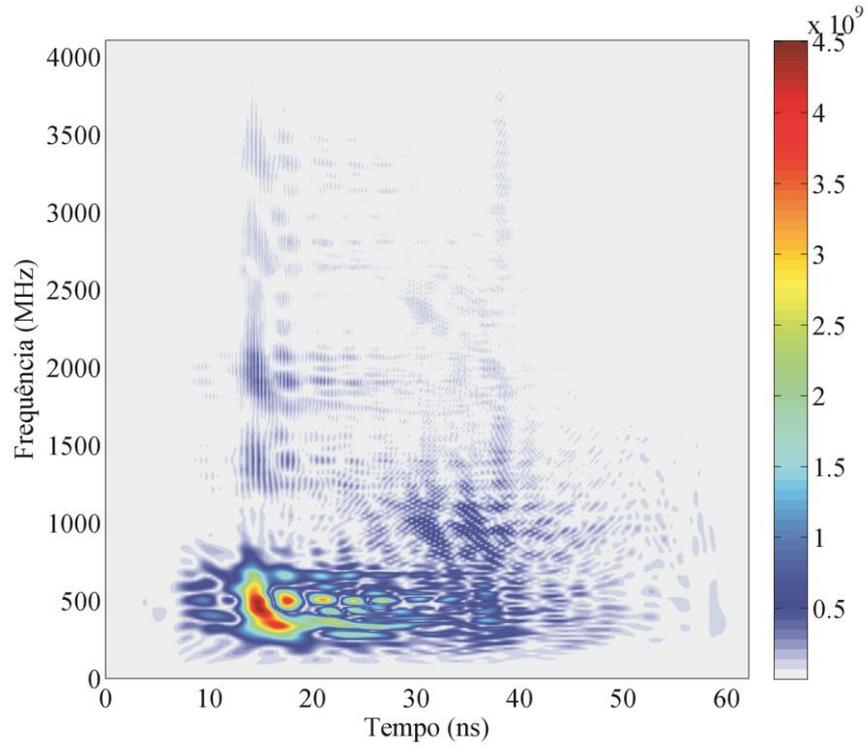


Figura 6.18 - Exemplo de WVD para alvo metálico com antena de 270 MHz.

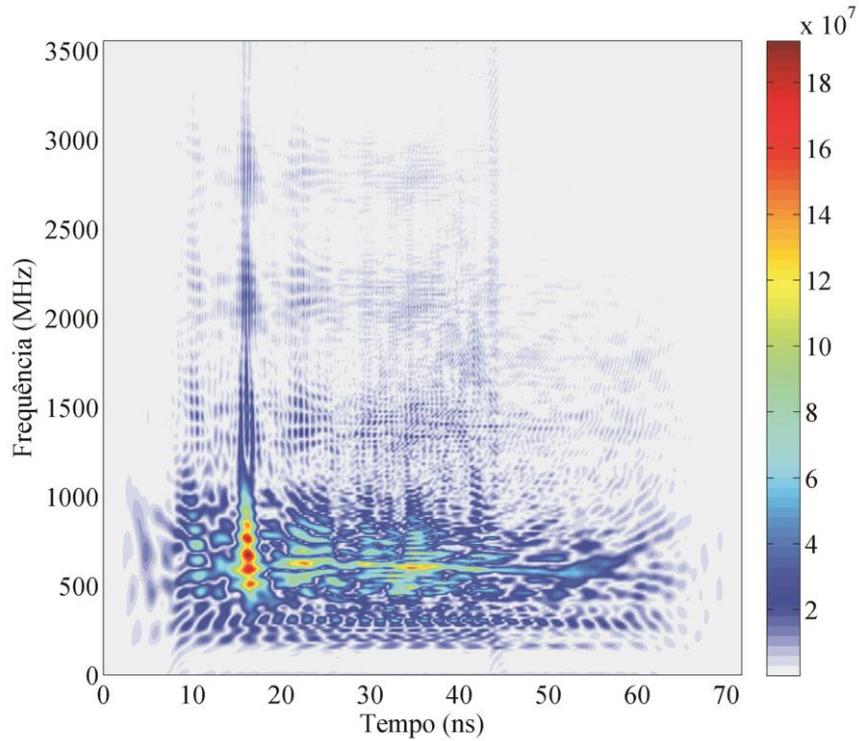


Figura 6.19 - Exemplo de WVD para alvo metálico com antena de 400 MHz no período seco.

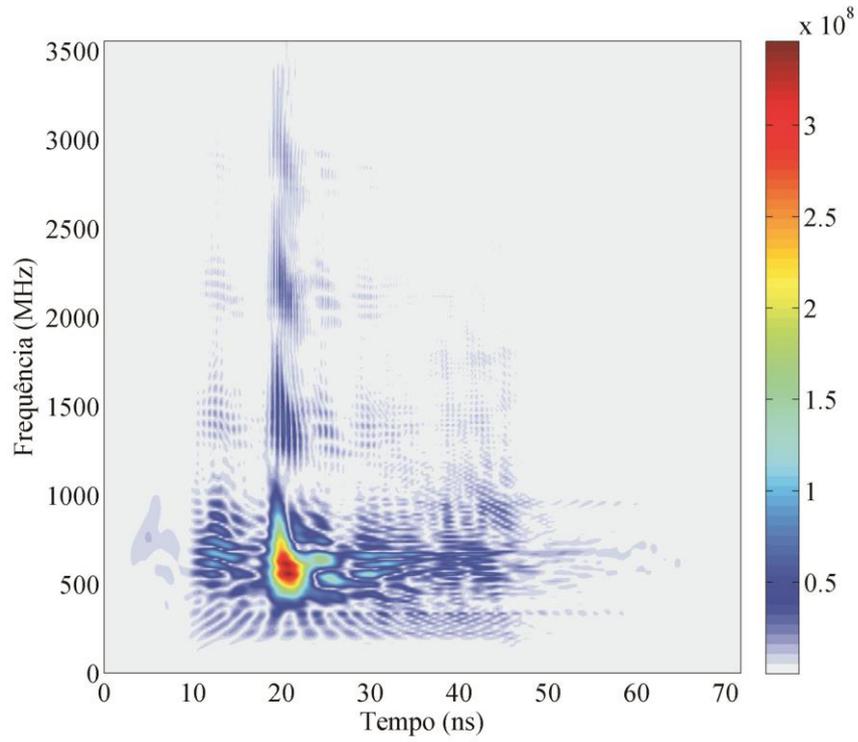


Figura 6.20 - Exemplo de WVD para alvo metálico com antena de 400 MHz no período úmido.

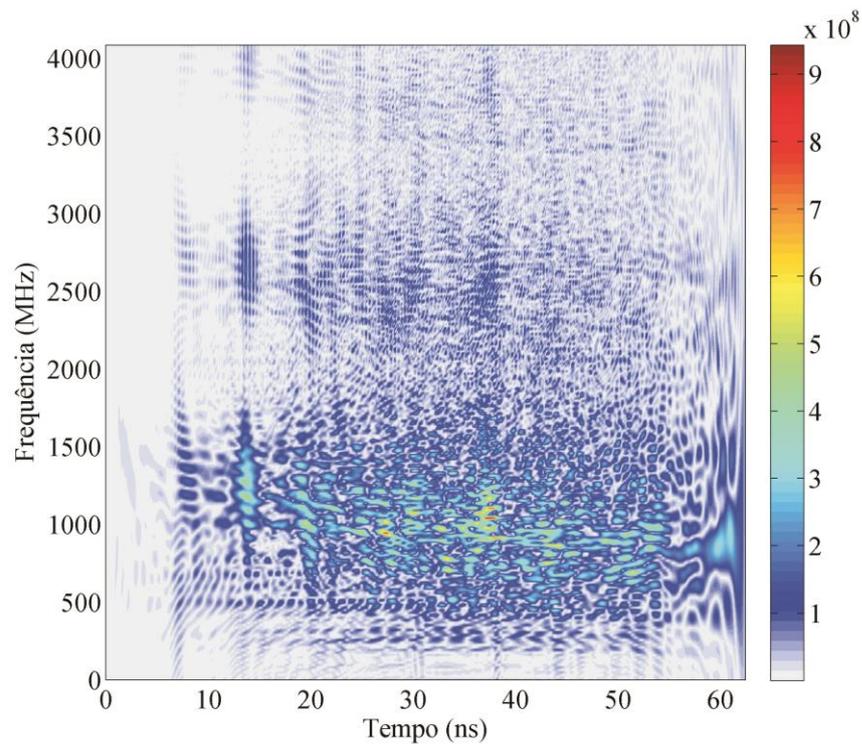


Figura 6.21 - Exemplo de WVD para alvo metálico com antena de 900 MHz.

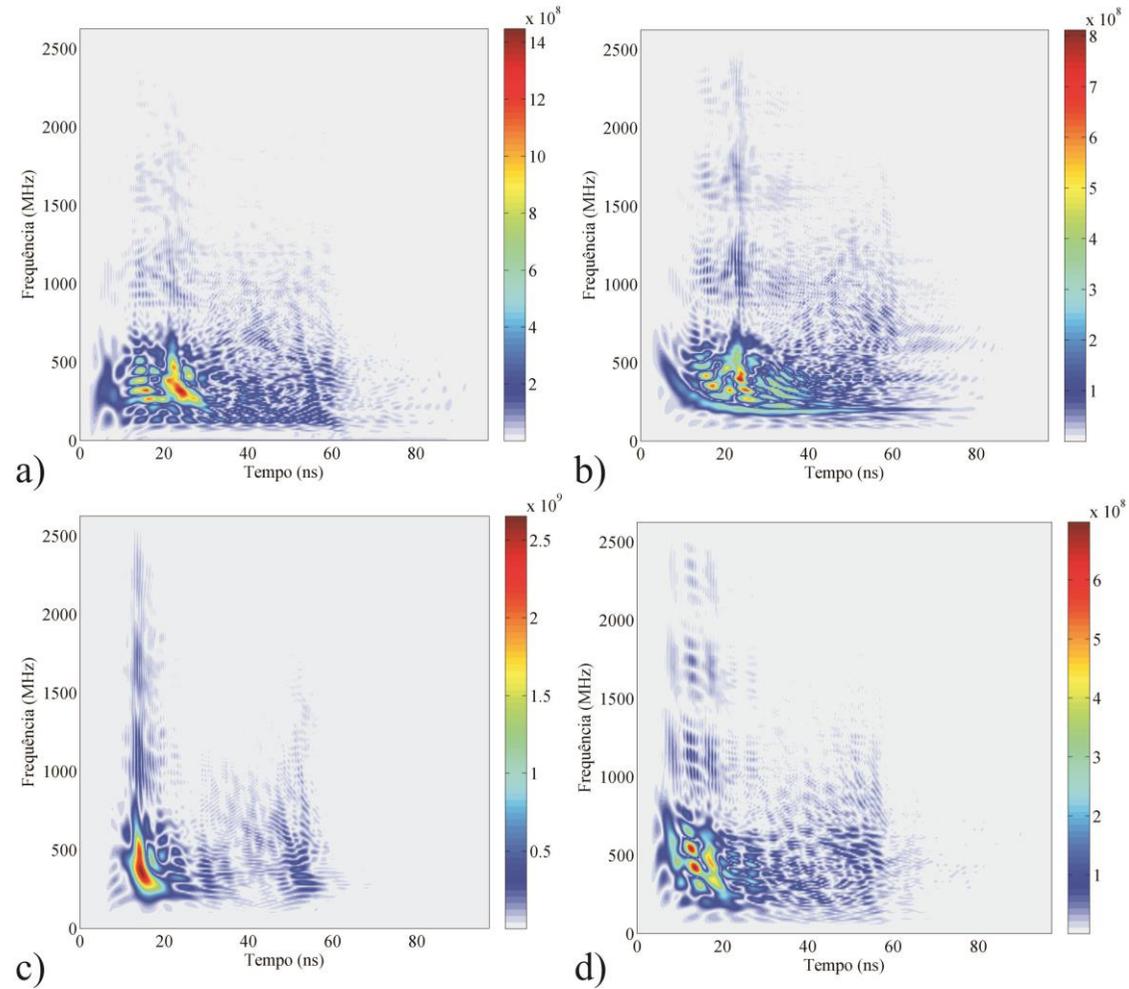


Figura 6.22 - Exemplo de WVD com antena de 200 MHz no período seco para diferentes tipos de alvos. a) Plástico. b) Concreto. c) Metal. d) Sem alvo.

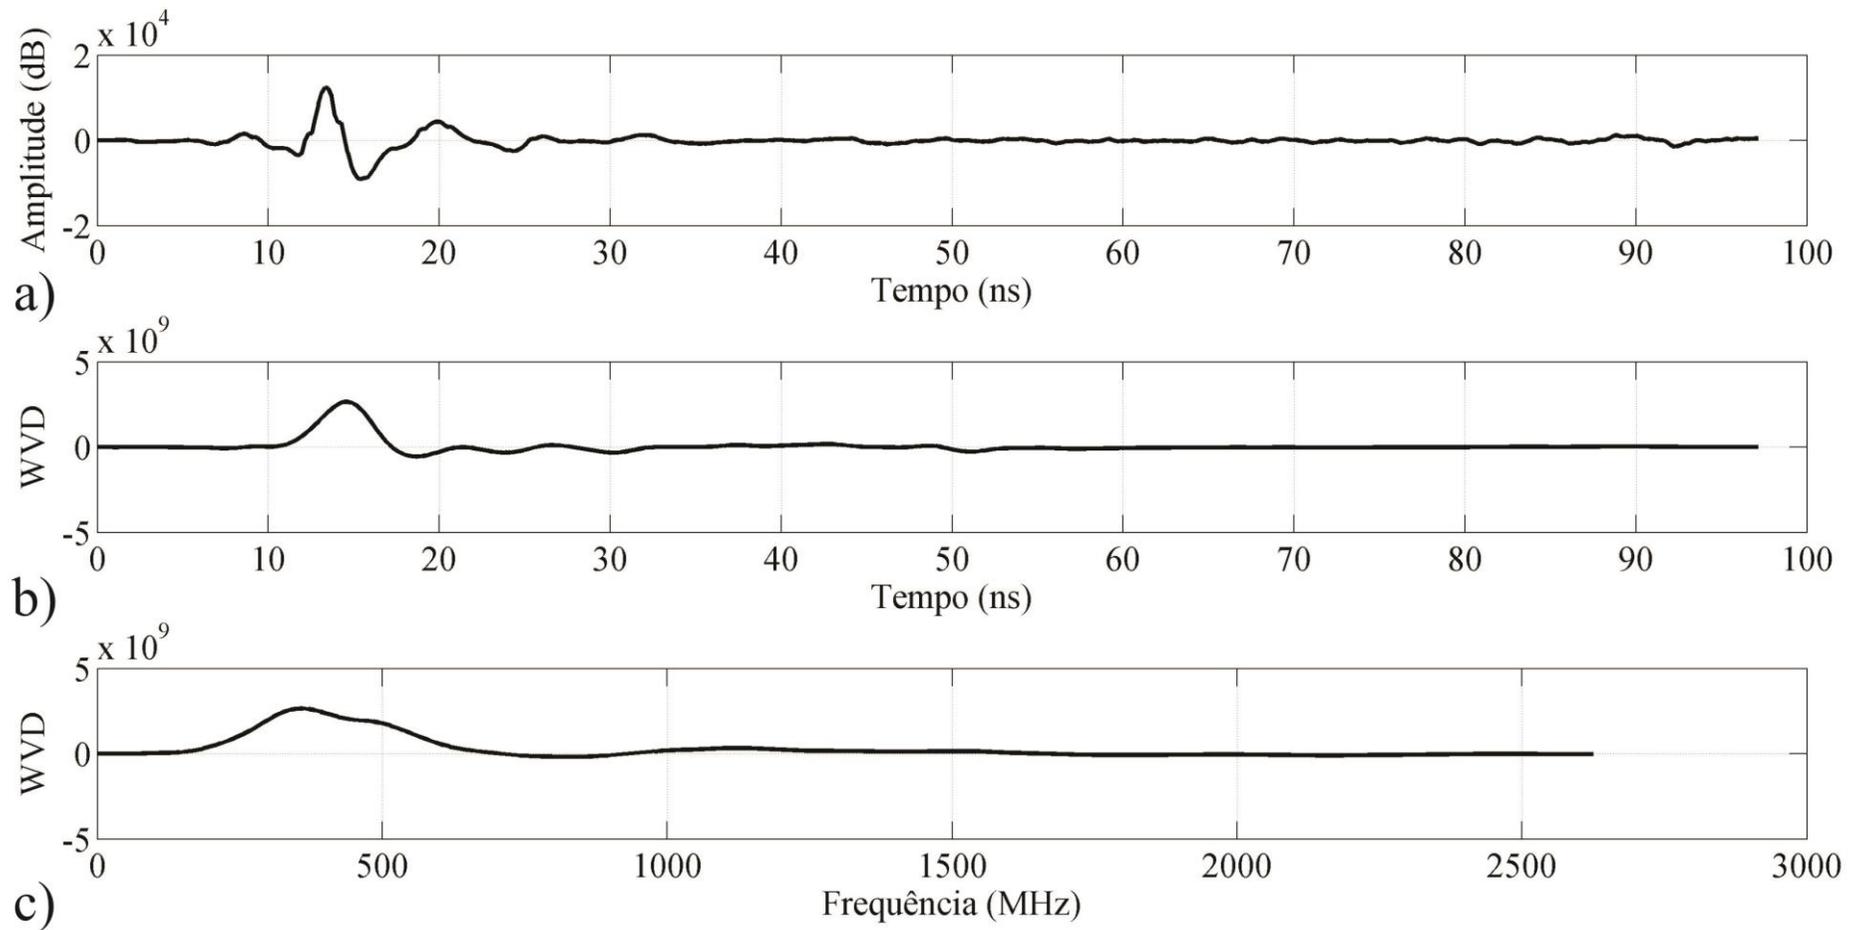


Figura 6.23 - Exemplo de WVD para antena de 200 MHz no período seco. a) Sinal original. b) WVD em função do tempo. c) WVD em função da frequência.

6.2.4 Transformada da Wavelet (WT – Wavelet Transform)

Muitas séries temporais exibem comportamentos não estacionários, como mudança de tendências e estas características são frequentemente as partes mais importantes do sinal e aplicando a TF ou a STFT não se pode determinar eficientemente esses eventos. Nesse sentido a Transformada da Wavelet (*Wavelet Transform* - WT) surge como ferramenta útil para a análise de sinais não estacionários (STARK, 2005).

As wavelets são ondas de curta duração com energia concentrada em um intervalo de tempo curto (GRAPS, 1995). A transformada da wavelet decompõe uma função definida no domínio do tempo em outra função, definida no domínio do tempo e da frequência, a partir de outra . Isso significa que a função decomposta possui diferentes níveis de resolução (escalas) e tempos de localização. A partir desses níveis é possível reconstruir ou apresentar uma função utilizando as bases wavelet e coeficientes desses níveis apropriadamente (WEEKS, 2012).

Nas Figuras 6.24 a 6.29 tem-se exemplos da Transformada Wavelet para o tambor metálico da Linha 4, obtido com as antenas de 200 (seco e úmido), 270, 400 (seco e úmido) e 900 MHz. Nas figuras supracitadas, aquelas de índice *a* são os sinais refletidos originais, enquanto os índices *b* e *c* mostram a DWT (*Discrete WT*) e CWT (*Continuous WT*), respectivamente. Nestes exemplos é fácil definir a reflexão e a amplitude dos coeficientes pode ser utilizada como característica do classificador. Já a Figura 6.30 mostra um exemplo da WT para um sinal sem alvo.

Para cada A-scan foram calculados os coeficientes da DWT e a CWT. Na DWT foram utilizados os coeficientes do nível quatro e na CWT foram utilizados os coeficientes da escala 16 para determinar o máximo valor de cada variável. Nas diferentes frequências e tipos de materiais as amplitudes variam mostrando que a WT pode ser uma característica importante na detecção e classificação de alvos.

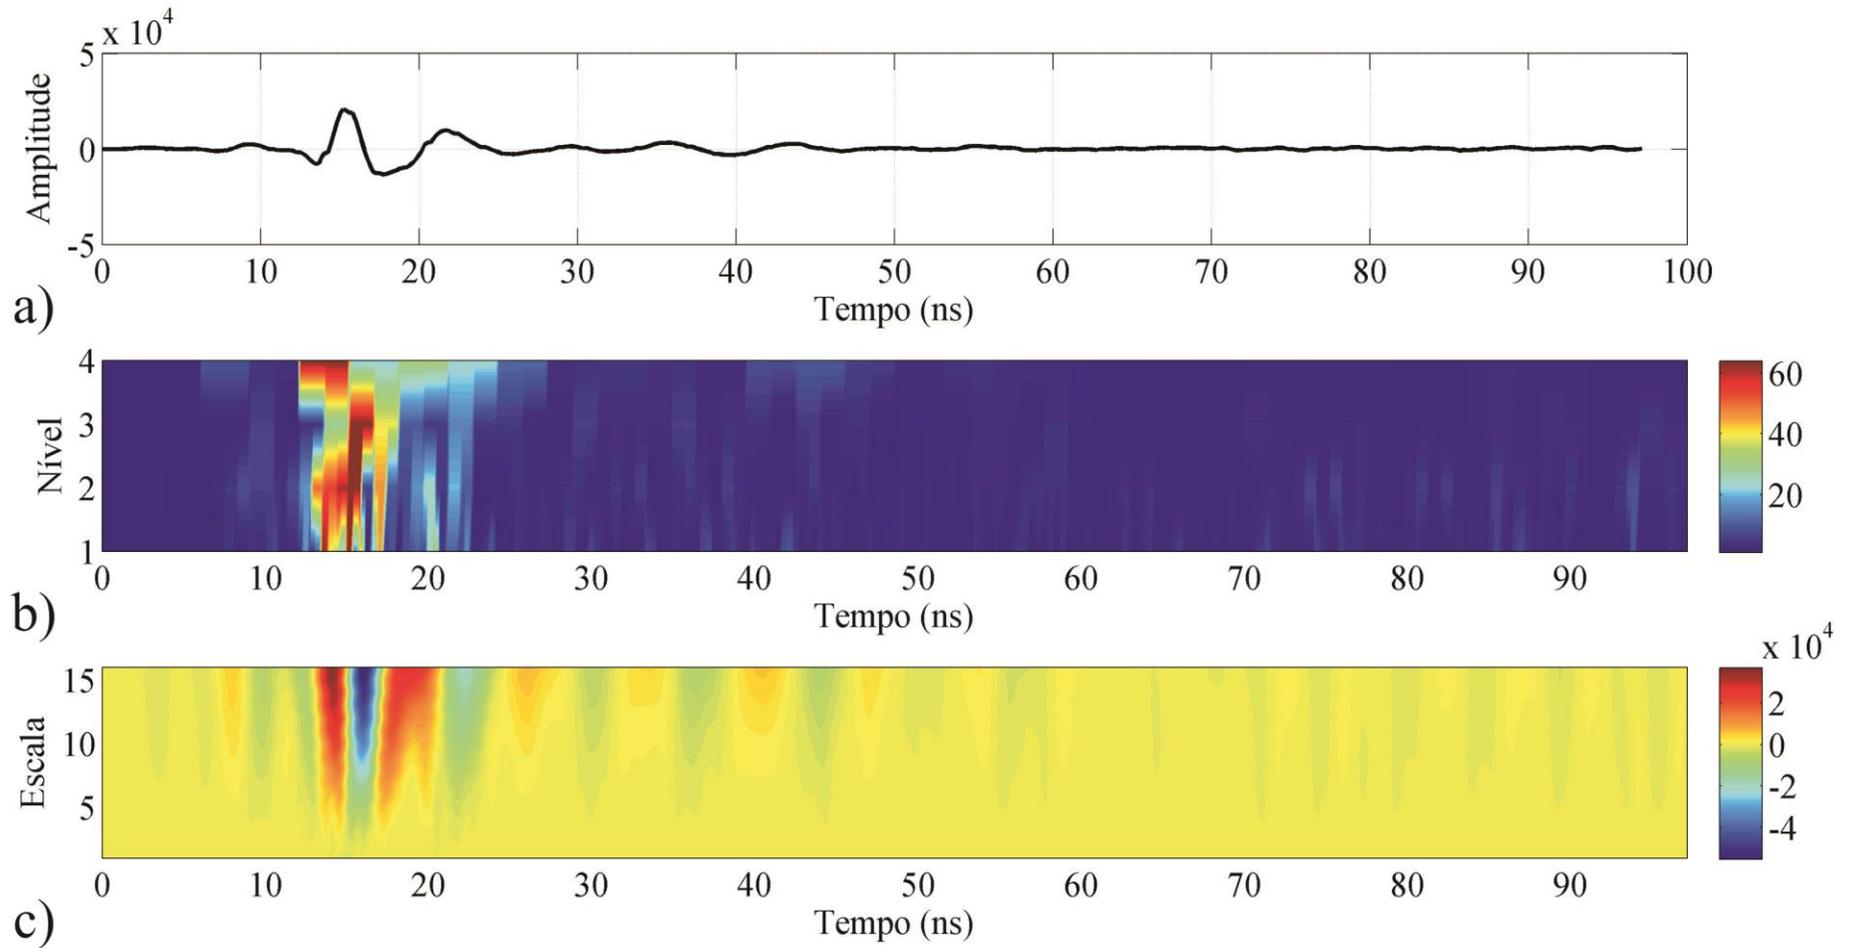


Figura 6.24 - Exemplo de WT para alvo metálico com antena de 200 MHz no período seco. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).

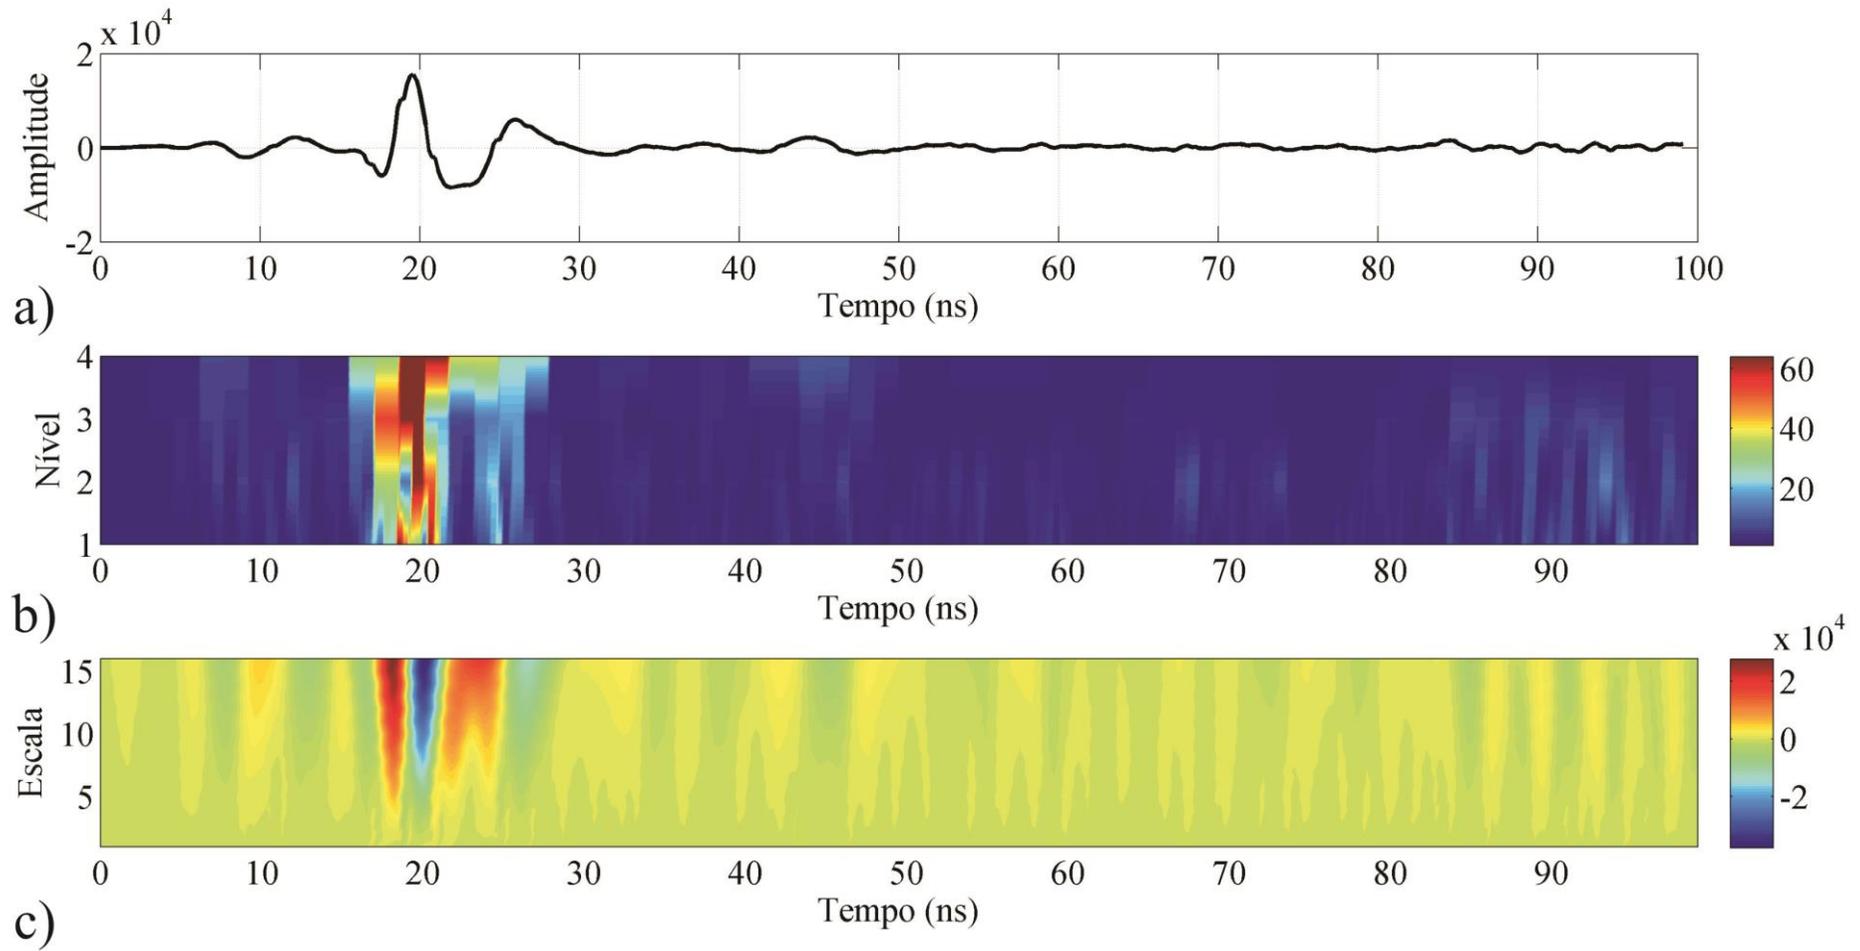


Figura 6.25 - Exemplo de WT para alvo metálico com antena de 200 MHz no período úmido. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).

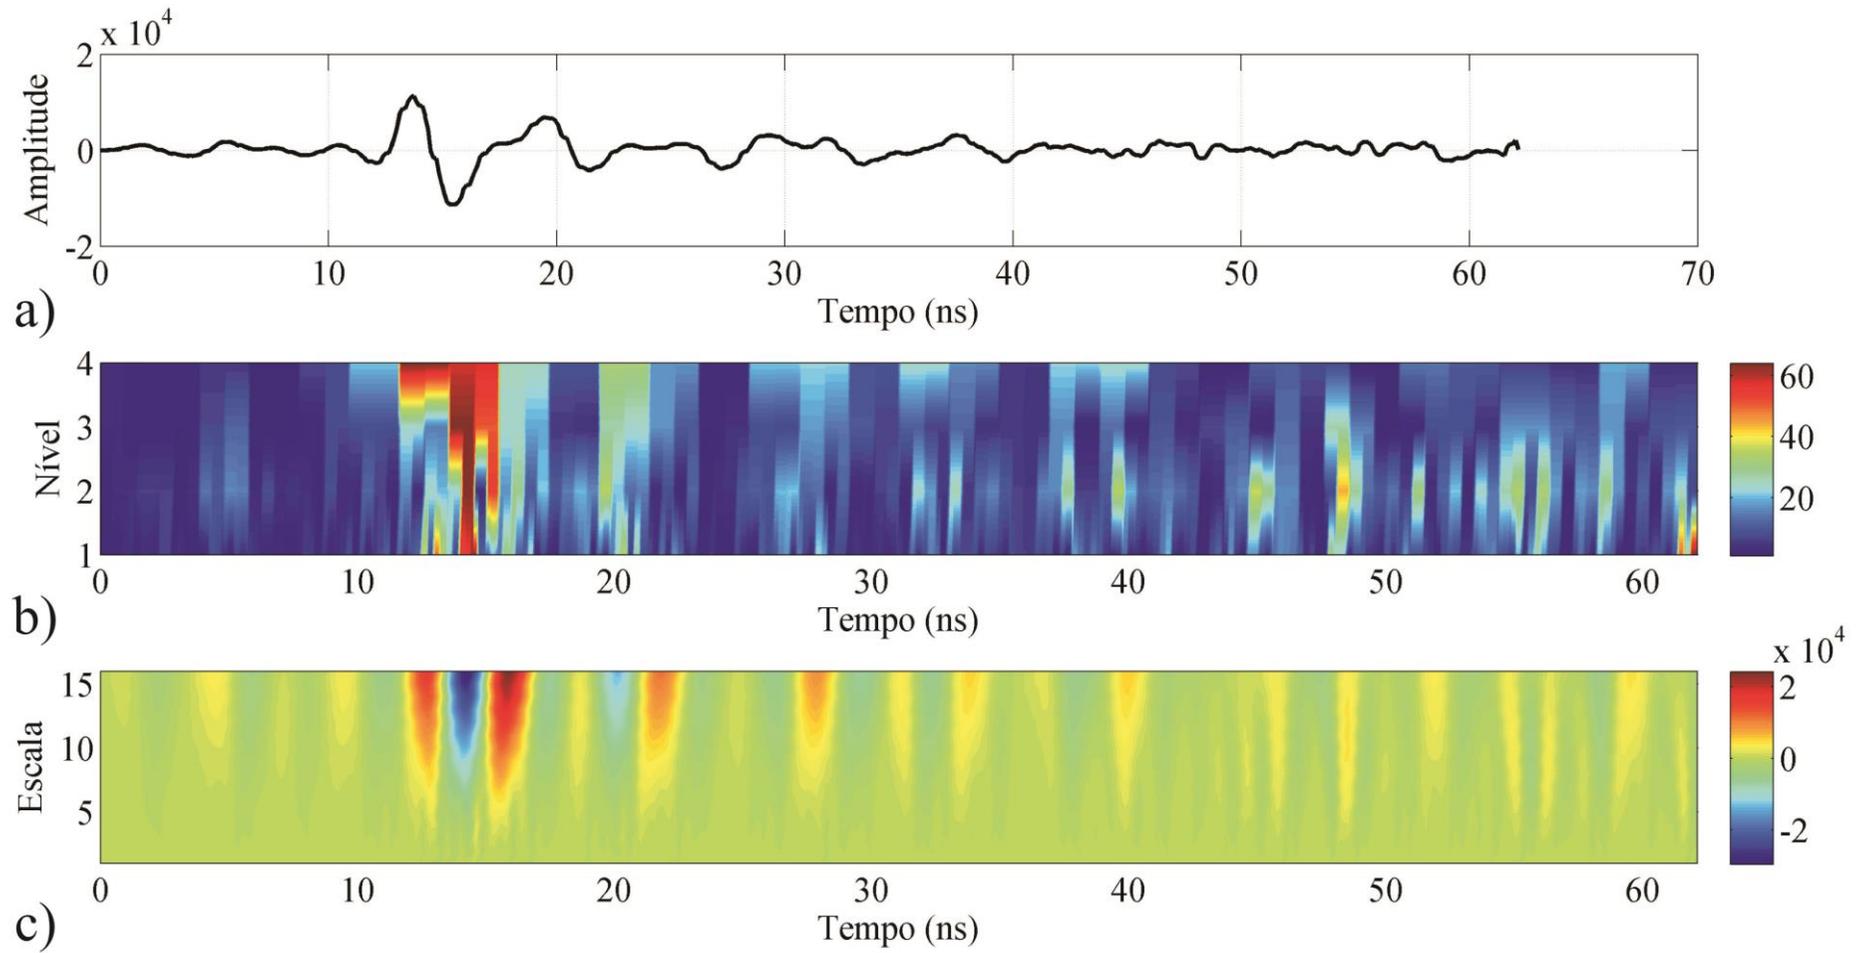


Figura 6.26 - Exemplo de WT para alvo metálico com antena de 270 MHz. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).

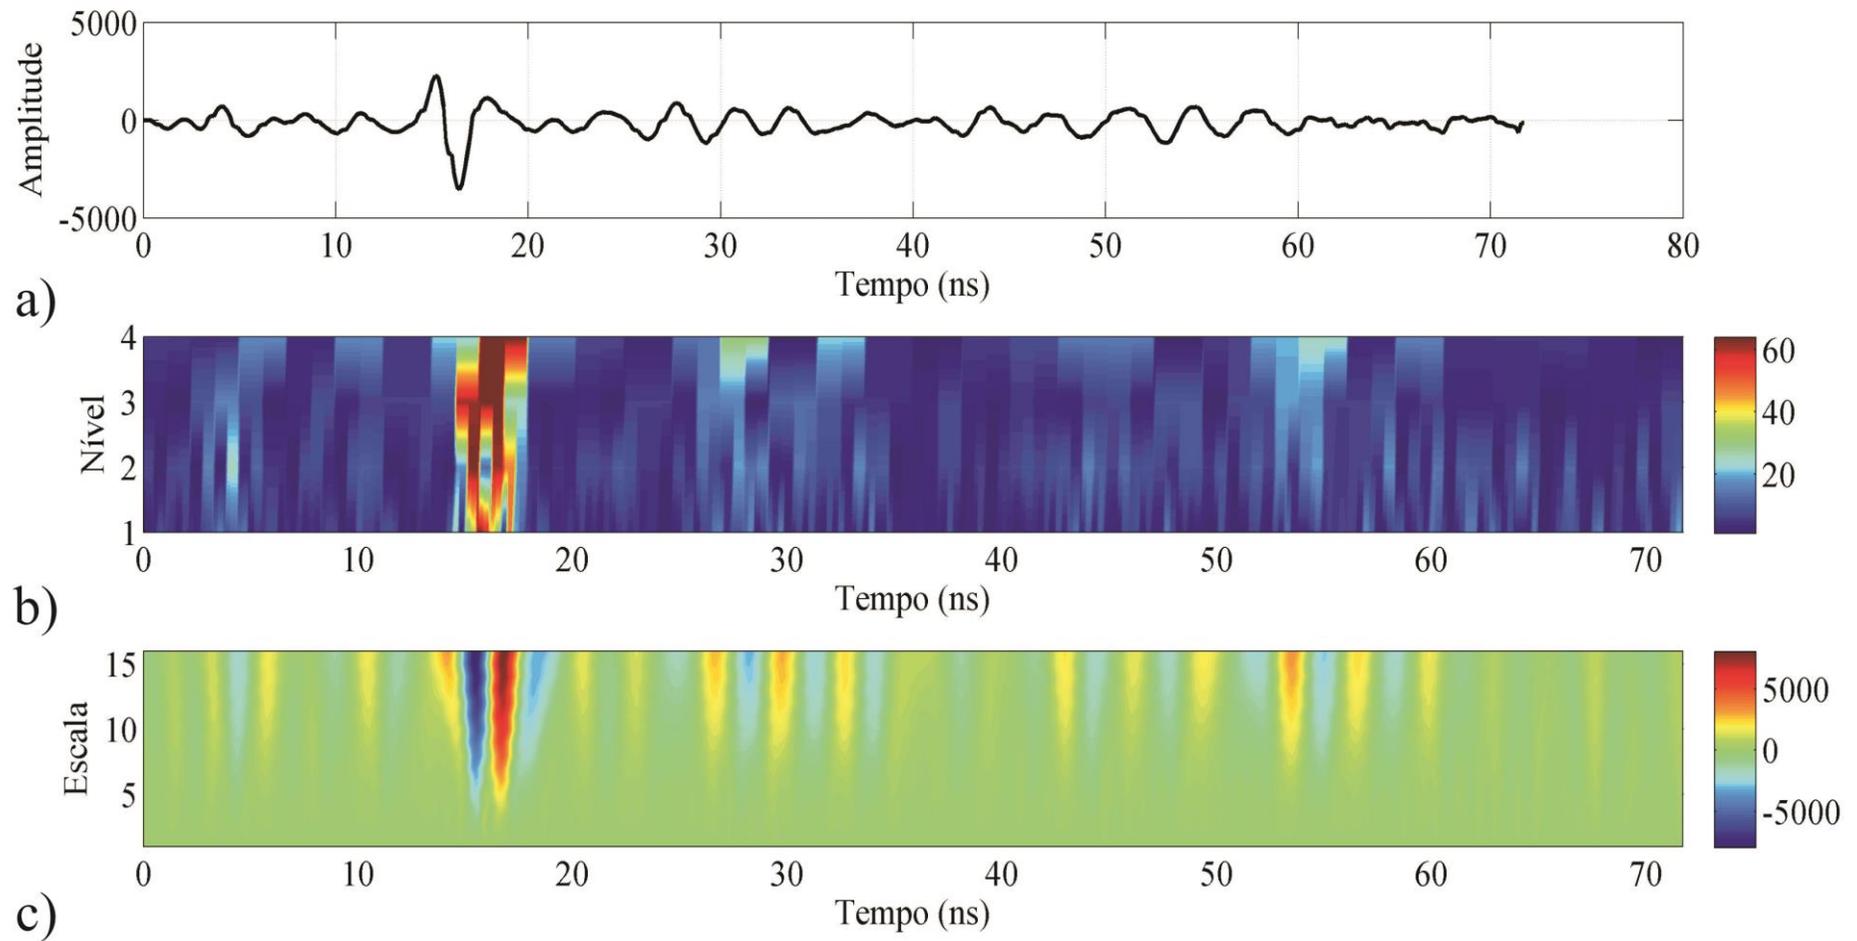


Figura 6.27 - Exemplo de WT para alvo metálico com antena de 400 MHz no período seco. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).

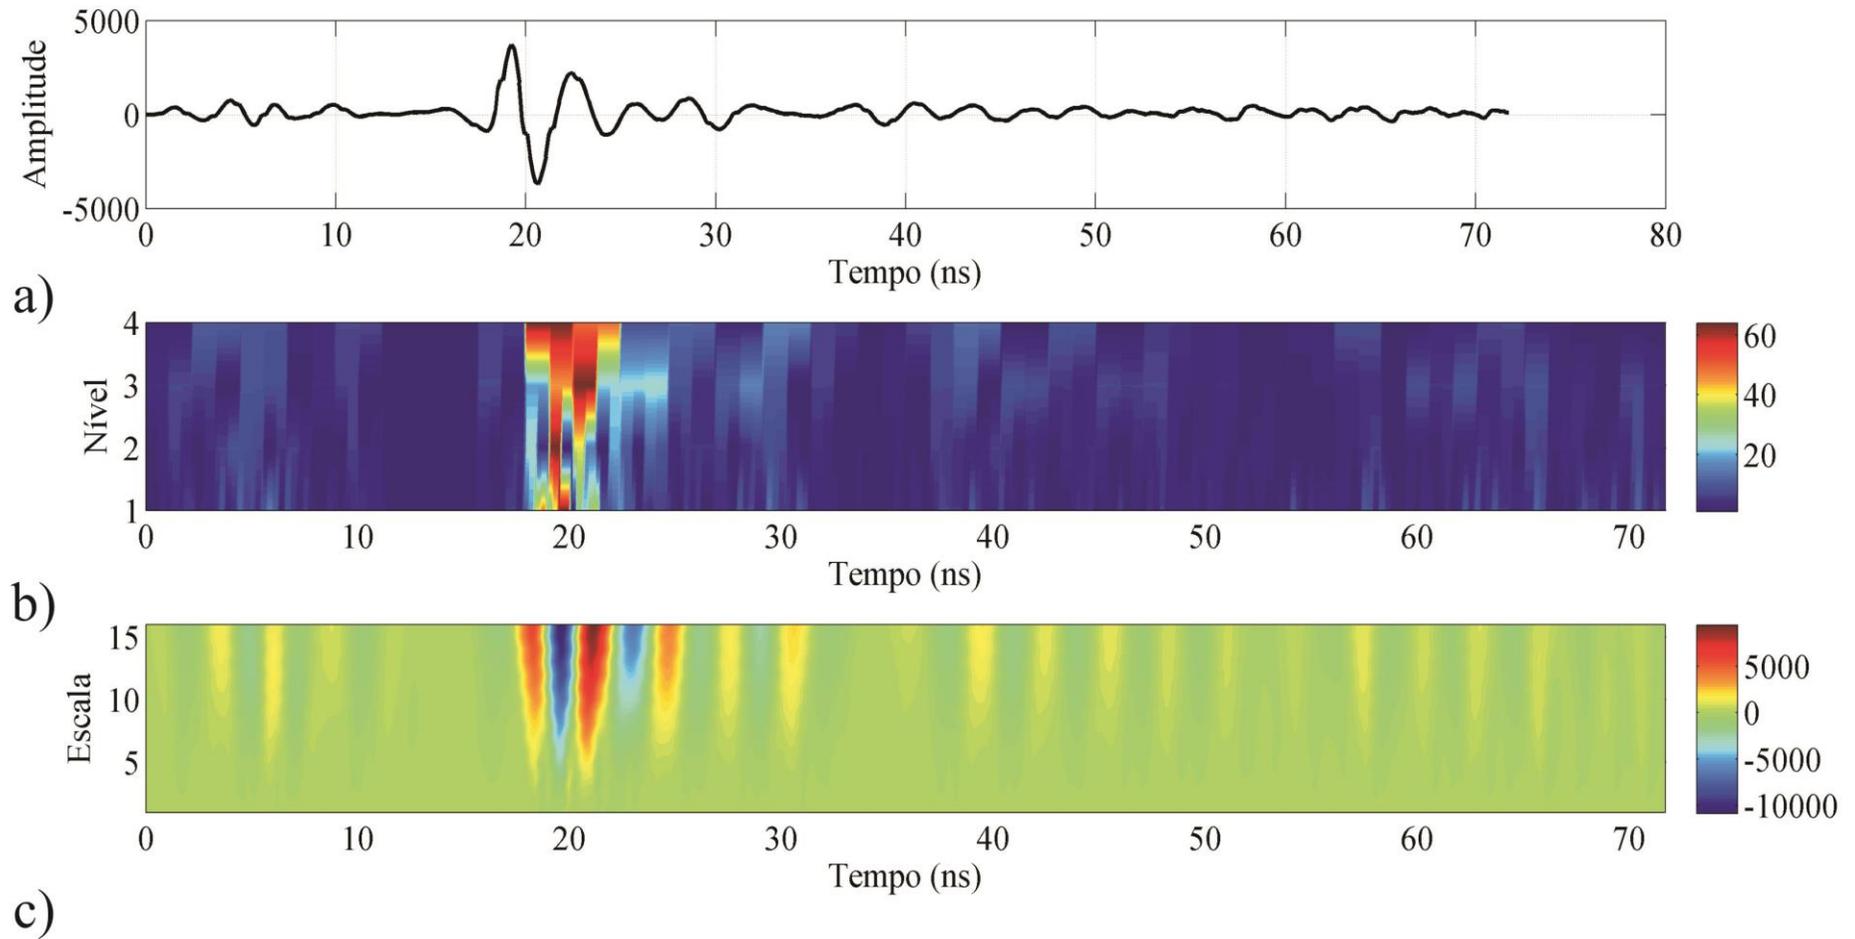


Figura 6.28 - Exemplo de WT para alvo metálico com antena de 400 MHz no período úmido. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).

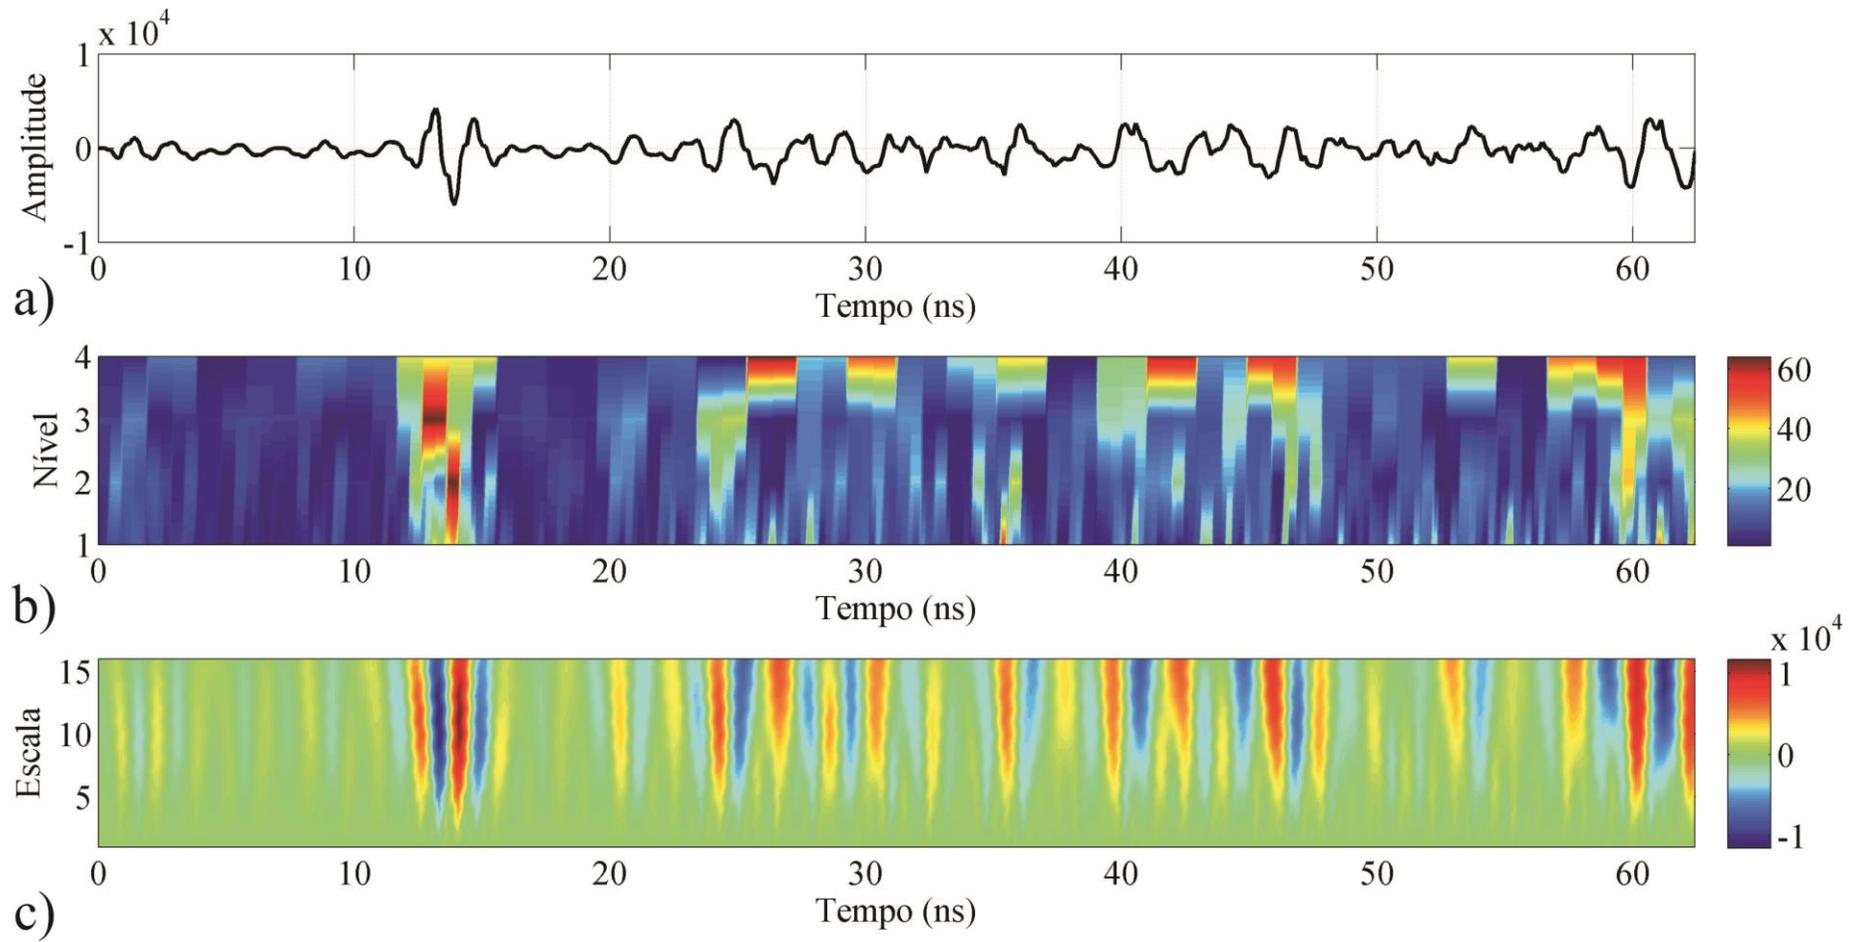


Figura 6.29 - Exemplo de WT para alvo metálico com antena de 900 MHz. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).

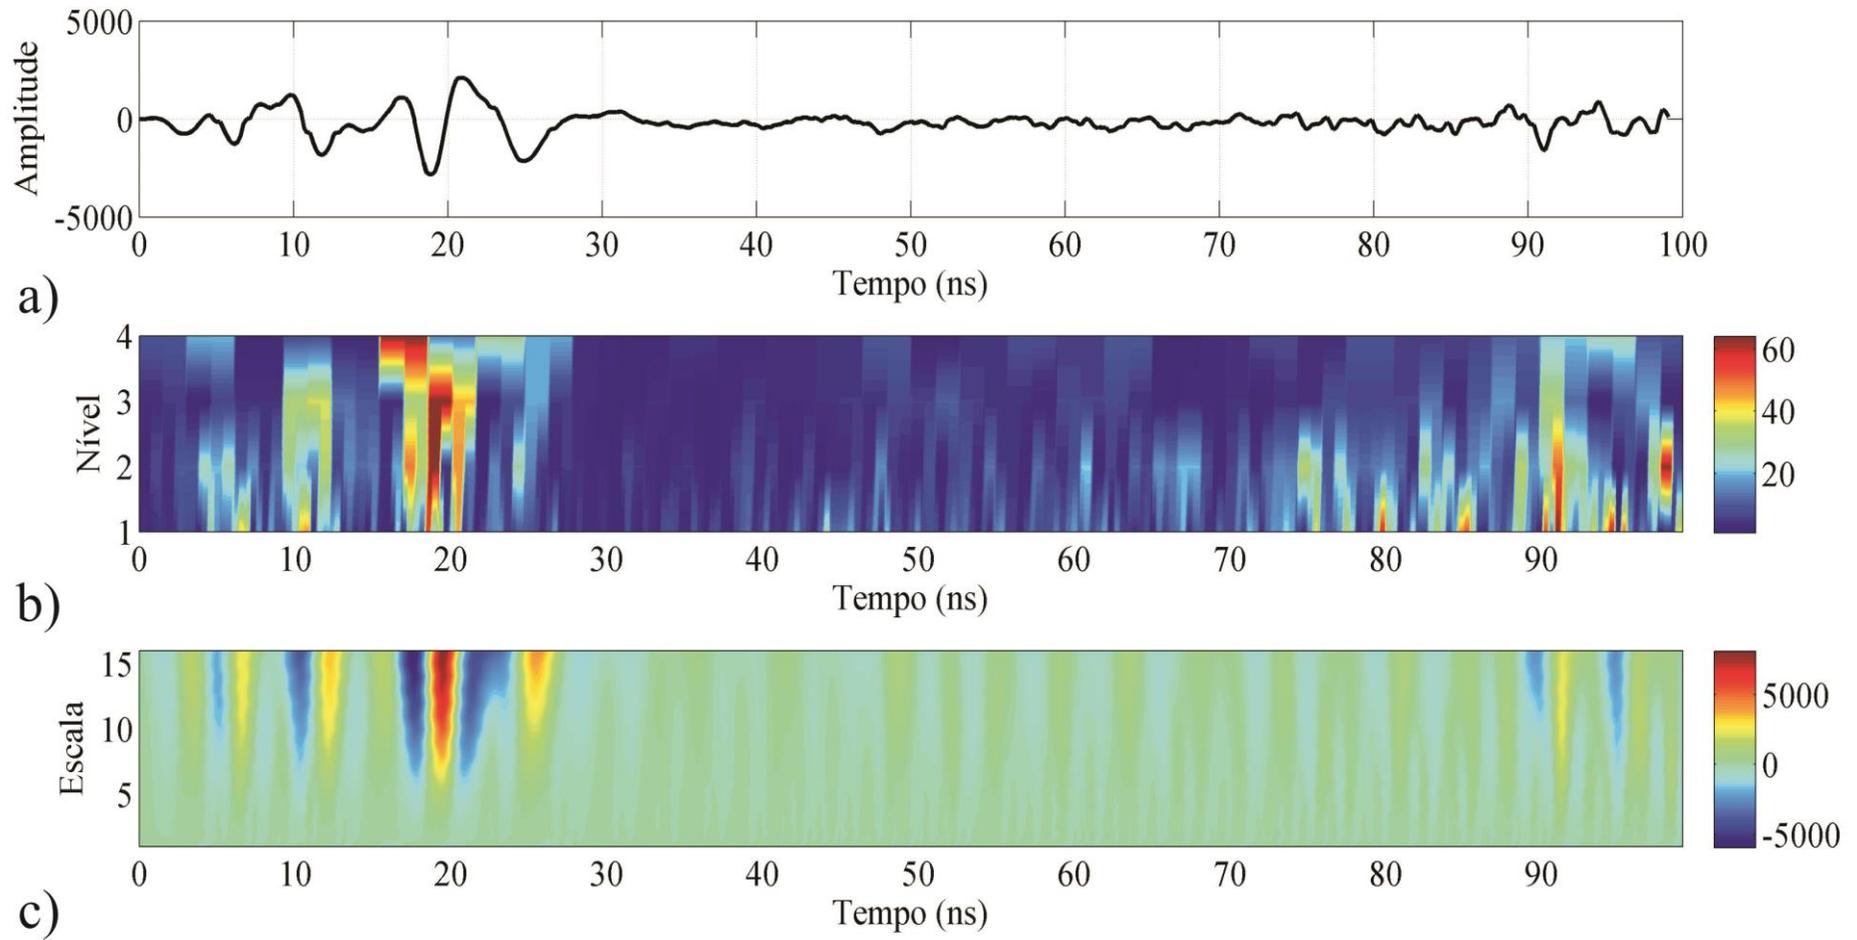


Figura 6.30 - Exemplo de WT para antena de 200 MHz no período seco sem alvo. a) Sinal original. b) DWT (nível 4). c) CWT (escala 16).

CAPÍTULO 7

7. NC_GPR – NEURAL CLASSIFIER GPR

Neste capítulo serão mostrados os resultados da identificação e classificação das hipérboles, desde os primeiros testes da rede implementada para o ajuste da função seno, finalizando com a inserção das características estudadas anteriormente para uma “interpretação automática” dos dados GPR. O algoritmo desenvolvido para identificar e classificar as hipérboles em perfis GPR foi denominado *NC_GPR* (*Neural Classifier GPR*) e tem a capacidade de fazer uma análise espectral do sinal para extrair as características e em seguida realizar a interpretação dos dados pela rede neural já treinada.

7.1 ANÁLISE DA REDE NEURAL

Fazendo uso da técnica de retropropagação de erros ou *backpropagation*, desenvolveu-se uma RNA de múltiplas camadas (MLP – *Multilayer Perceptron*) *feedforward* utilizando gradiente descendente, *momentum* e taxa de aprendizado variável (decrece com o número de iterações). Como exposto anteriormente, este tipo de rede estima o erro das camadas intermediárias por meio de uma avaliação do efeito que as mesmas causam no erro da camada de saída. Assim, o erro de saída da rede é calculado e retroalimentado para as camadas intermediárias, possibilitando o ajuste dos pesos proporcionalmente aos valores das conexões entre camadas.

A rede neural foi desenvolvida em MATLAB[®] e as onze características estudadas no capítulo anterior foram extraídas dos perfis GPR obtidos no SCGR, sendo utilizadas como entrada da rede para identificar as hipérboles e posteriormente as classificar. Os atributos da rede neural artificial desenvolvida são:

- **Função de ativação:** tangente hiperbólico (camadas ocultas) e linear (camada de saída);
- **Treinamento:** *backpropagation* com gradiente descendente, *momentum* e taxa de aprendizado decrescente;
- **Erro:** erro quadrático médio.

Primeiramente, com a finalidade de testar a robustez da rede desenvolvida, utilizou-se o ajuste da função seno para treinar, validar e testar a rede. Os dados de entrada foram os ângulos variando em $x = [0, 2\pi]$, sendo que os dados de saída desejados são o $\text{sen}(x)$. Segundo BRAGA et al. 2012, a rede neural através da qual se obtém o melhor ajuste da função seno é do tipo 1-3-1, ou seja, um neurônio na camada de entrada, 3 neurônios na camada oculta e um neurônio na camada de saída. Assim, os testes prosseguiram de maneira a variar o número de iterações e de dados, a arquitetura da rede, dados de entrada ruidosos, tipos de funções de ativação e de treinamento, a fim de se obter o melhor ajuste. O conjunto total de dados foi dividido em duas partes, sendo que a primeira (70%) para treinamento e validação da rede, e a segunda (30%) para o teste da rede treinada, a cada passo do treinamento foi calculado o erro quadrático médio.

As figuras a seguir (7.1 a 7.11) mostram as variações desses parâmetros, podendo ser observadas: a função seno (saída desejada em preto), a saída calculada pela rede neural (em vermelho), a variação do erro quadrático médio em função da iteração para o treinamento, validação e teste, bem como a variação do gradiente em função da iteração. O número de iterações foi variado entre 100, 1.000, 10.000 e 100.000.

Nas Figuras 7.1 a 7.4, com arquitetura 1-3-1 e 63 pontos de entrada, a variação foi feita no número de iterações e observa-se que o melhor ajuste obtido corresponde a 100.000 iterações, uma vez que o erro quadrático médio foi menor tanto para o treinamento, quanto validação ou teste. Por sua vez, nas Figuras 7.5 a 7.8 tem-se a mesma arquitetura 1-3-1 e variação do número de iterações, mas os dados de treinamento são os valores de $\text{sen}(x)$ adicionados de um ruído aleatório (em verde). Novamente o melhor ajuste foi encontrado com 100.000 iterações, pois também apresentam um erro quadrático médio menor.

A Figura 7.9 apresenta resultado de teste no qual foi inserido um número maior de neurônios na camada oculta (arquitetura 1-15-1), mantendo os outros parâmetros, e

sendo executado com 100.000 iterações. O ajuste calculado não está de acordo com os dados de entrada, não sendo preservada nem mesmo a tendência dos dados originais, uma vez que o erro quadrático médio mostra um aumento de valor com o decorrer das iterações, juntamente com o gradiente.

Um ajuste com a arquitetura 1-3-1, 100.000 iterações e utilizando dados com ruído aleatório, mas com um número maior de dados, passando de 63 para 1257 (20 vezes aproximadamente), a fim de se analisar o comportamento da rede com relação a sua estabilidade, é mostrado na Figura 7.10. A saída calculada pela rede foi concordante com os dados de entrada, apresentando um erro baixo em todas as etapas do processamento. Na Figura 7.11 mantiveram-se os mesmos parâmetros anteriores, porém, foi adicionada mais uma camada oculta na rede, com cinco neurônios, ficando da forma 1-3-5-1. Em comparação com o resultado do teste anterior (Figura 7.10), esse ajuste não se mostrou tão satisfatório, mesmo preservando a tendência da curva original.

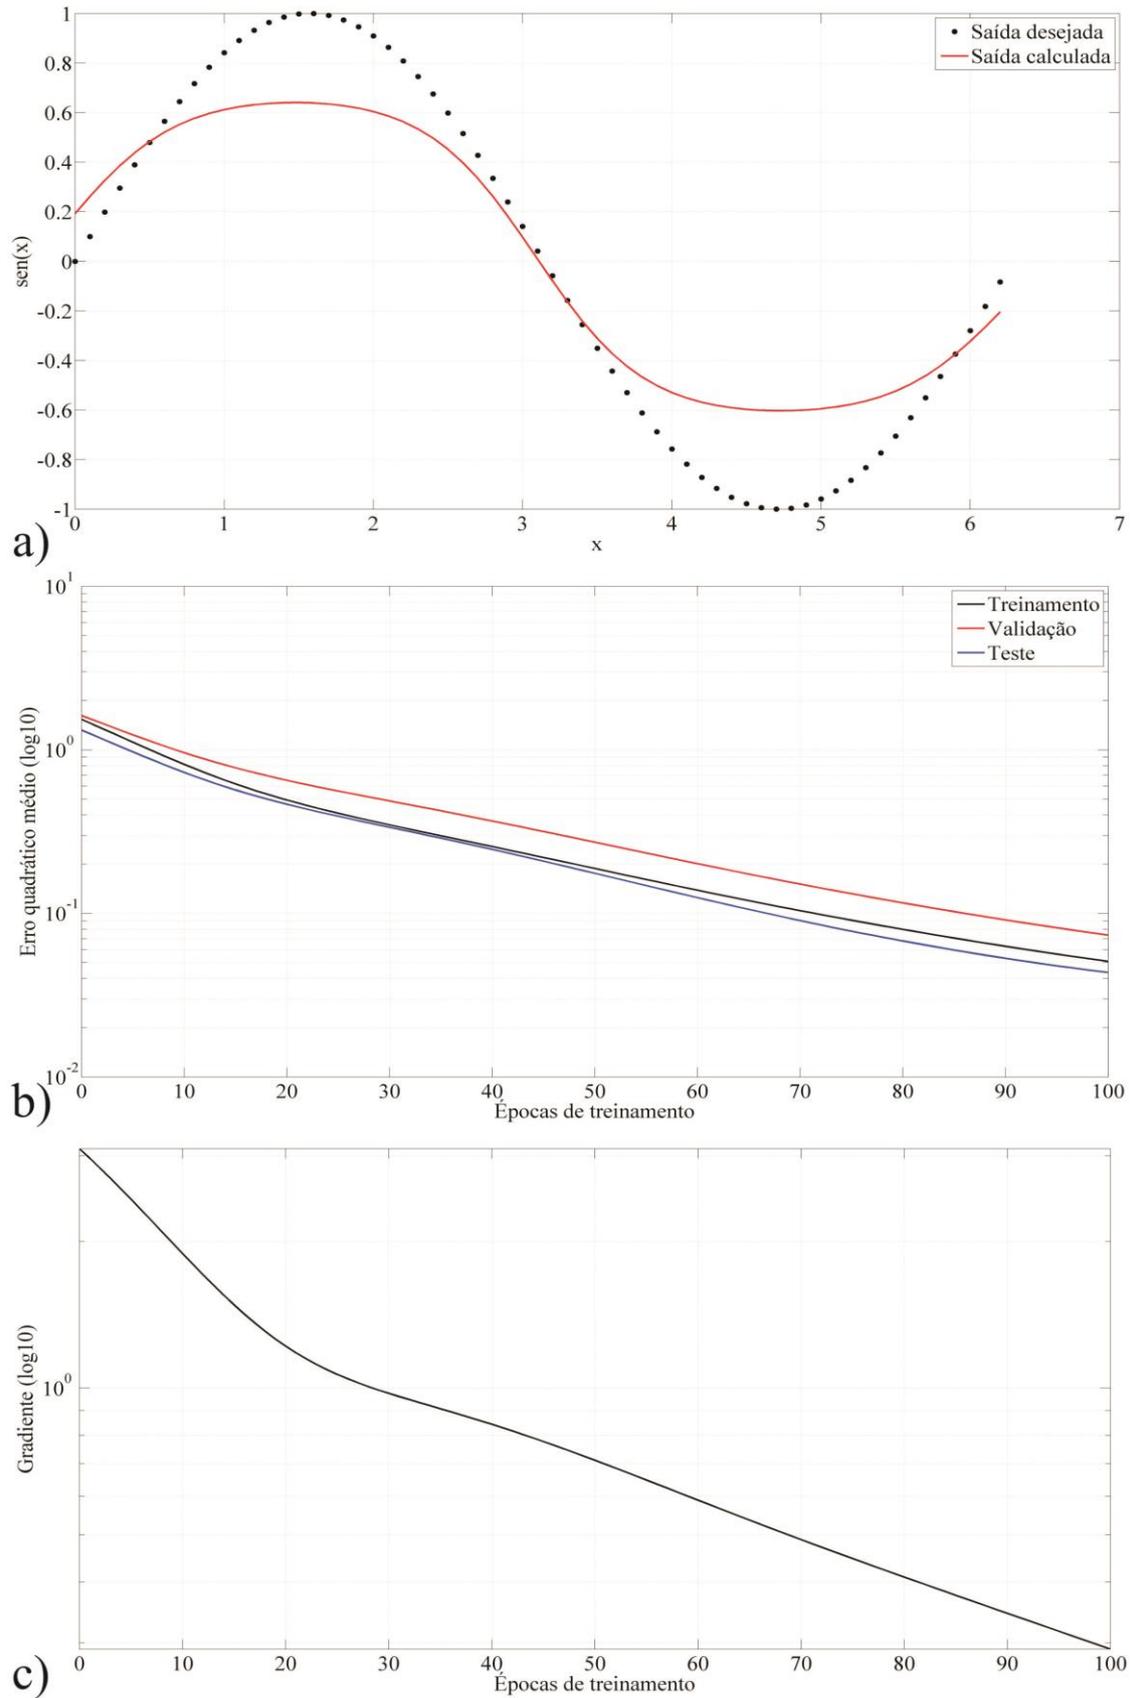


Figura 7.1 – Ajuste da função seno com 100 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

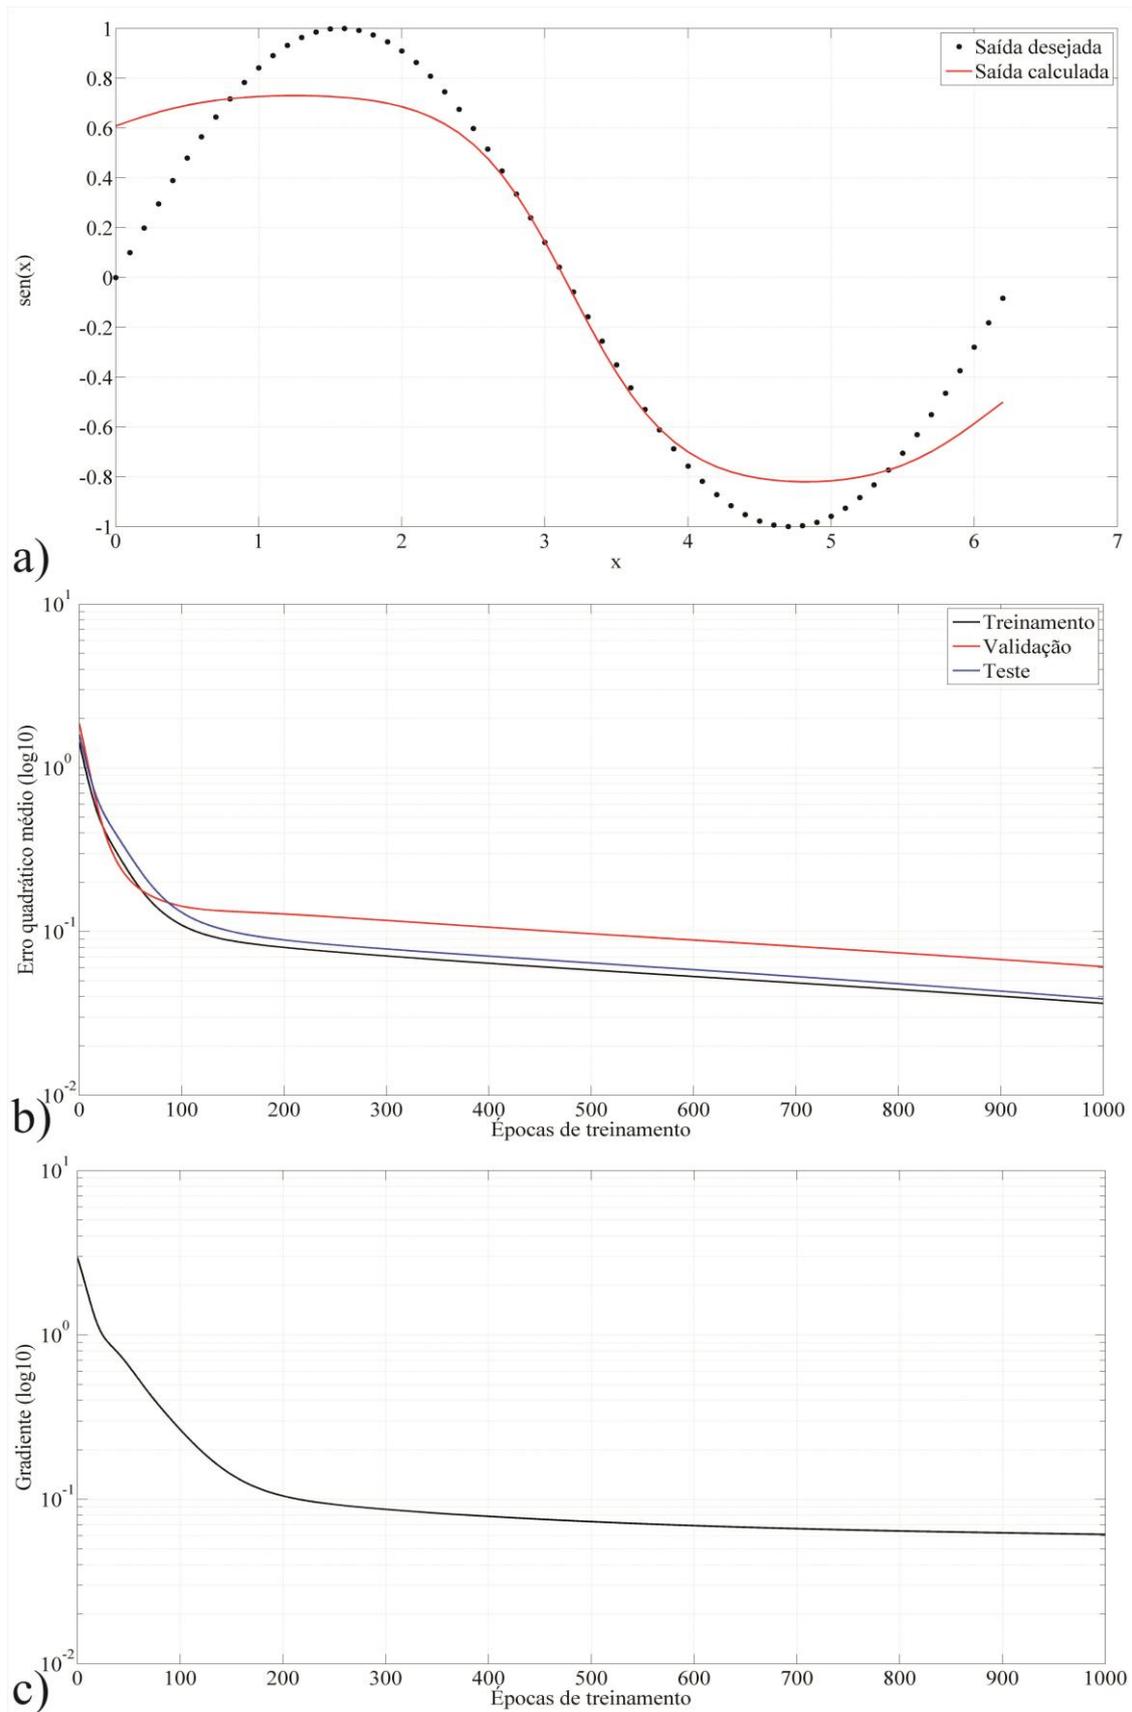


Figura 7.2 – Ajuste da função seno com 1.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

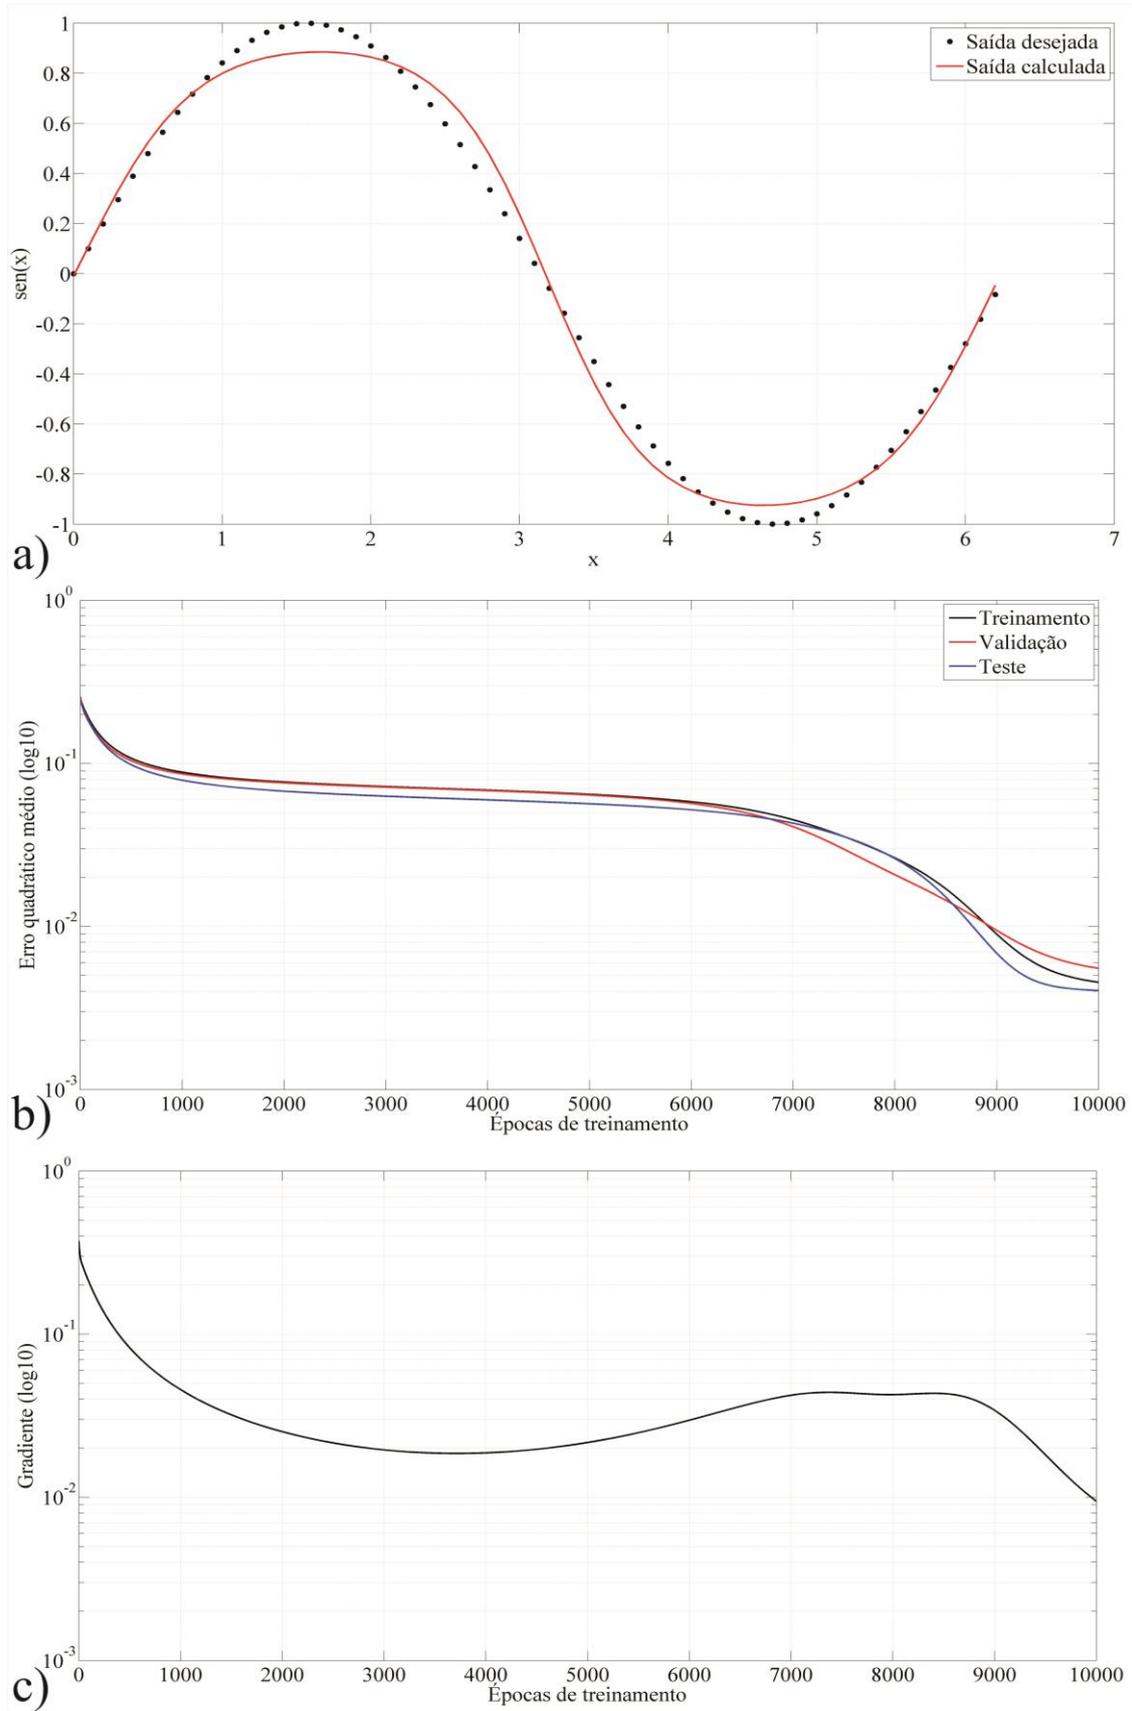


Figura 7.3 – Ajuste da função seno com 10.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

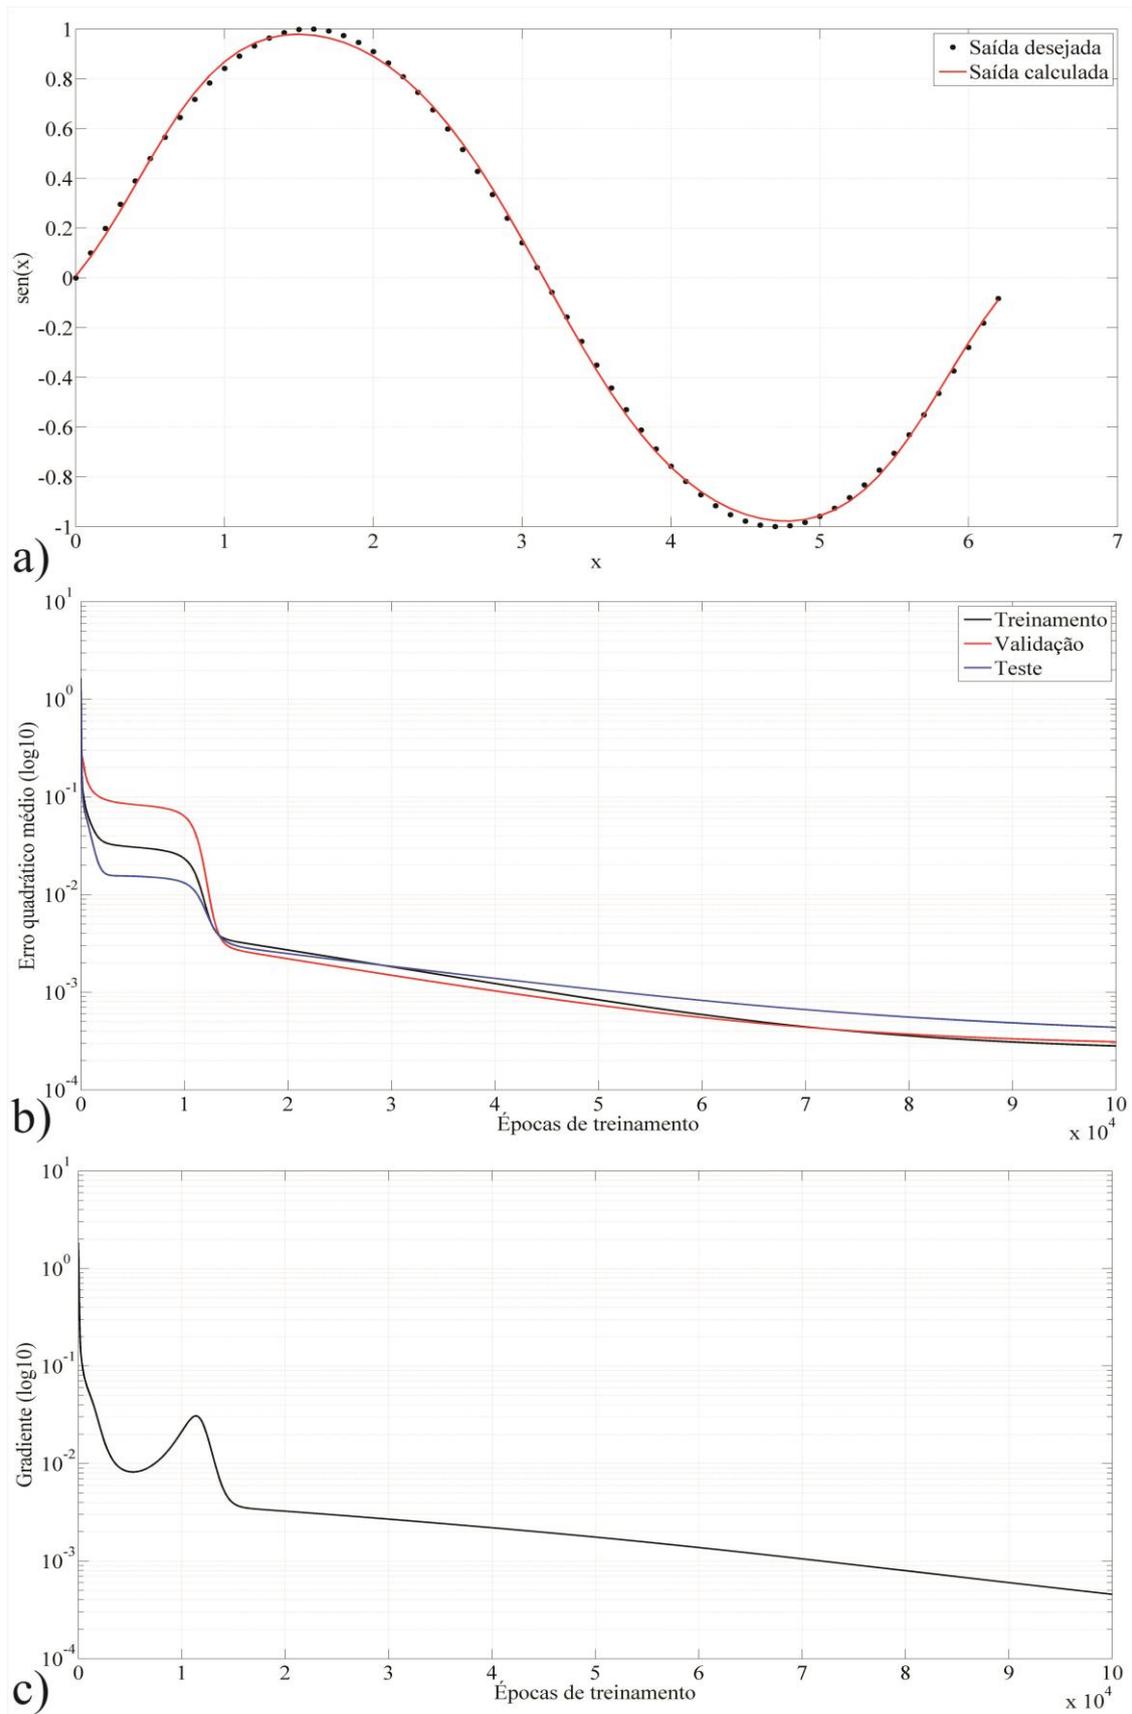


Figura 7.4 – Ajuste da função seno com 100.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

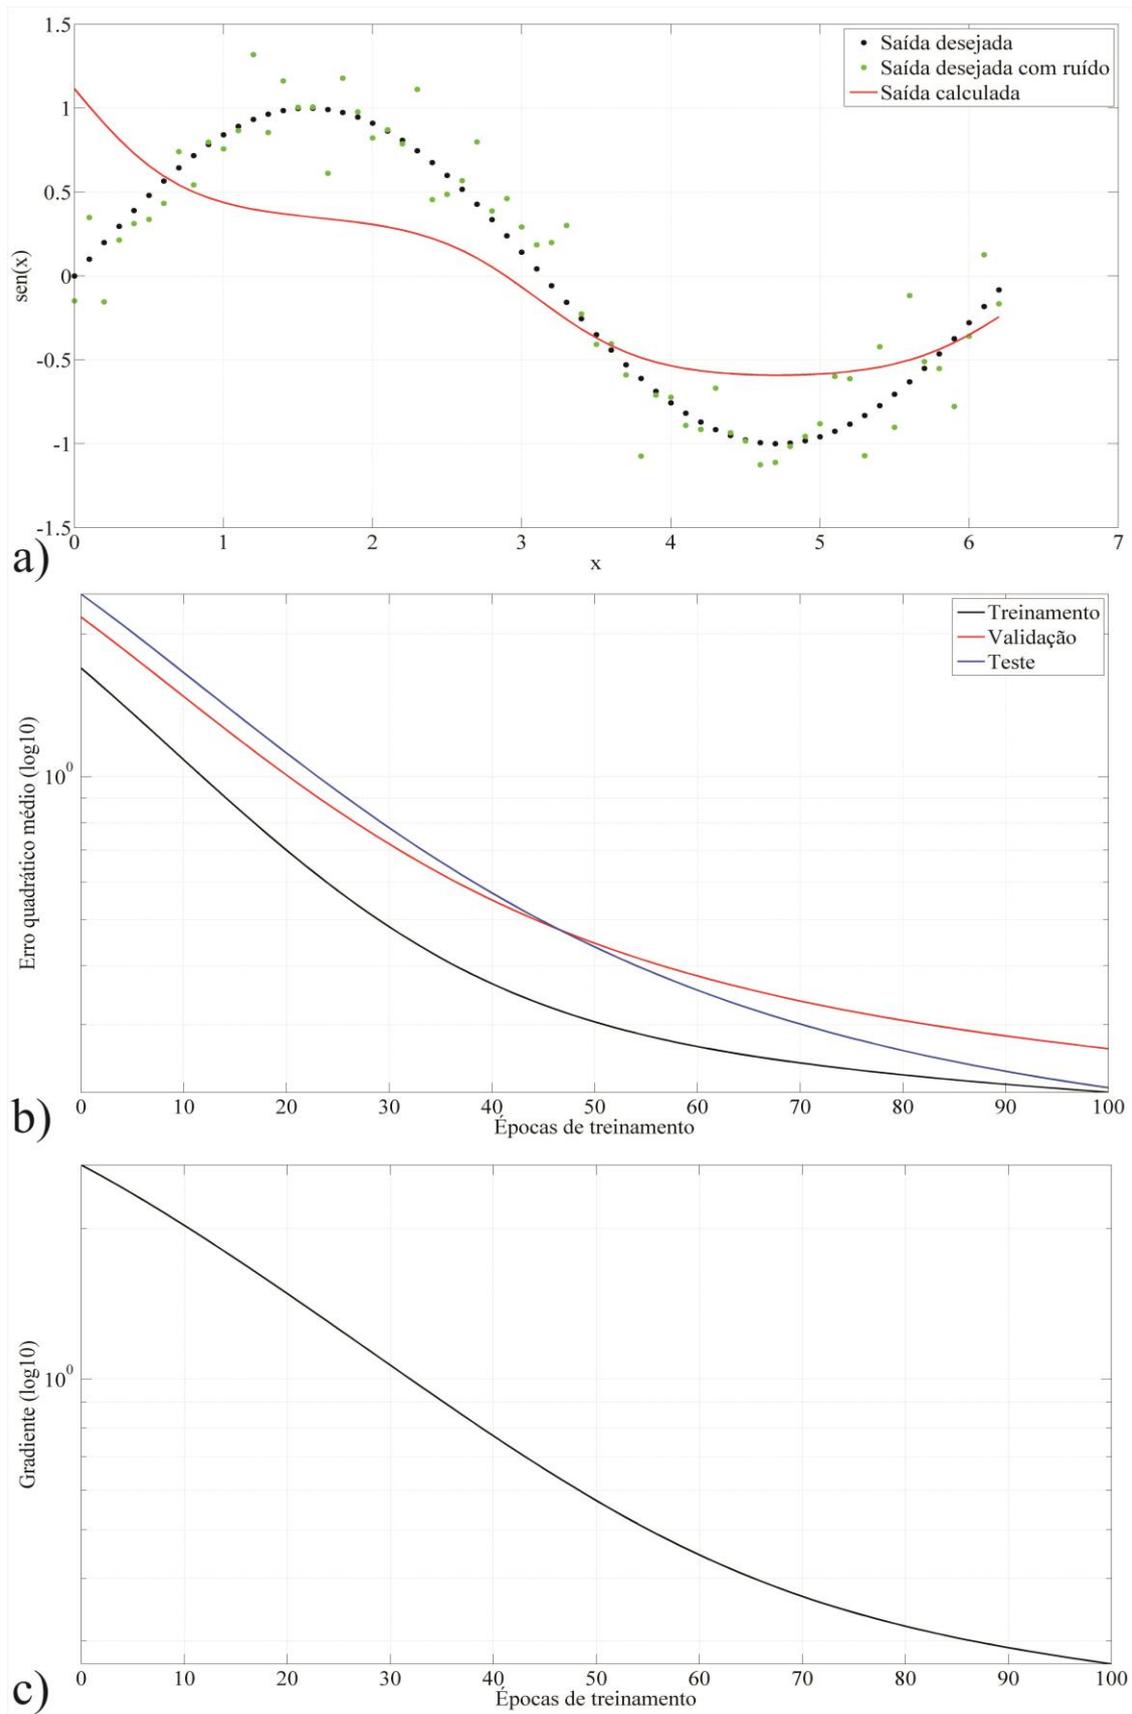


Figura 7.5 – Ajuste da função seno com ruído, 100 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

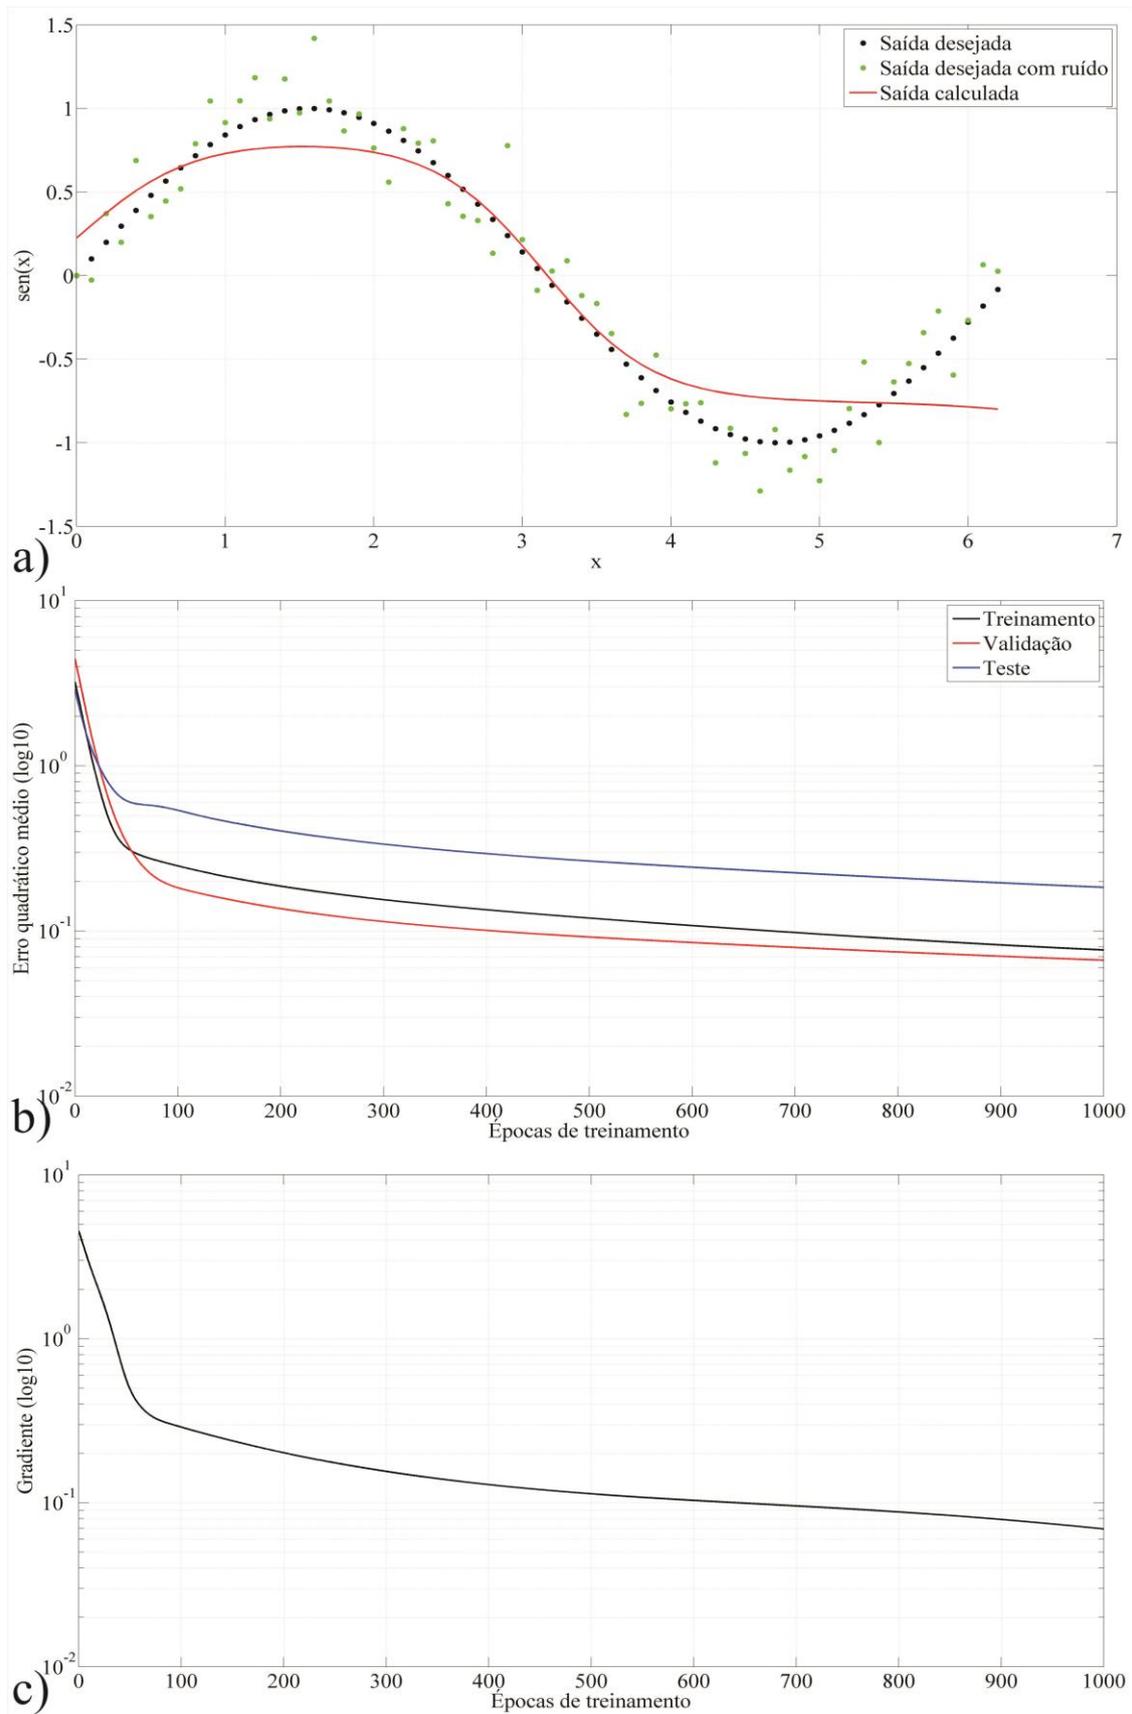


Figura 7.6 – Ajuste da função seno com ruído, 1.000 iterações e arquitetura 1-3-1. a) Saídas deseja (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

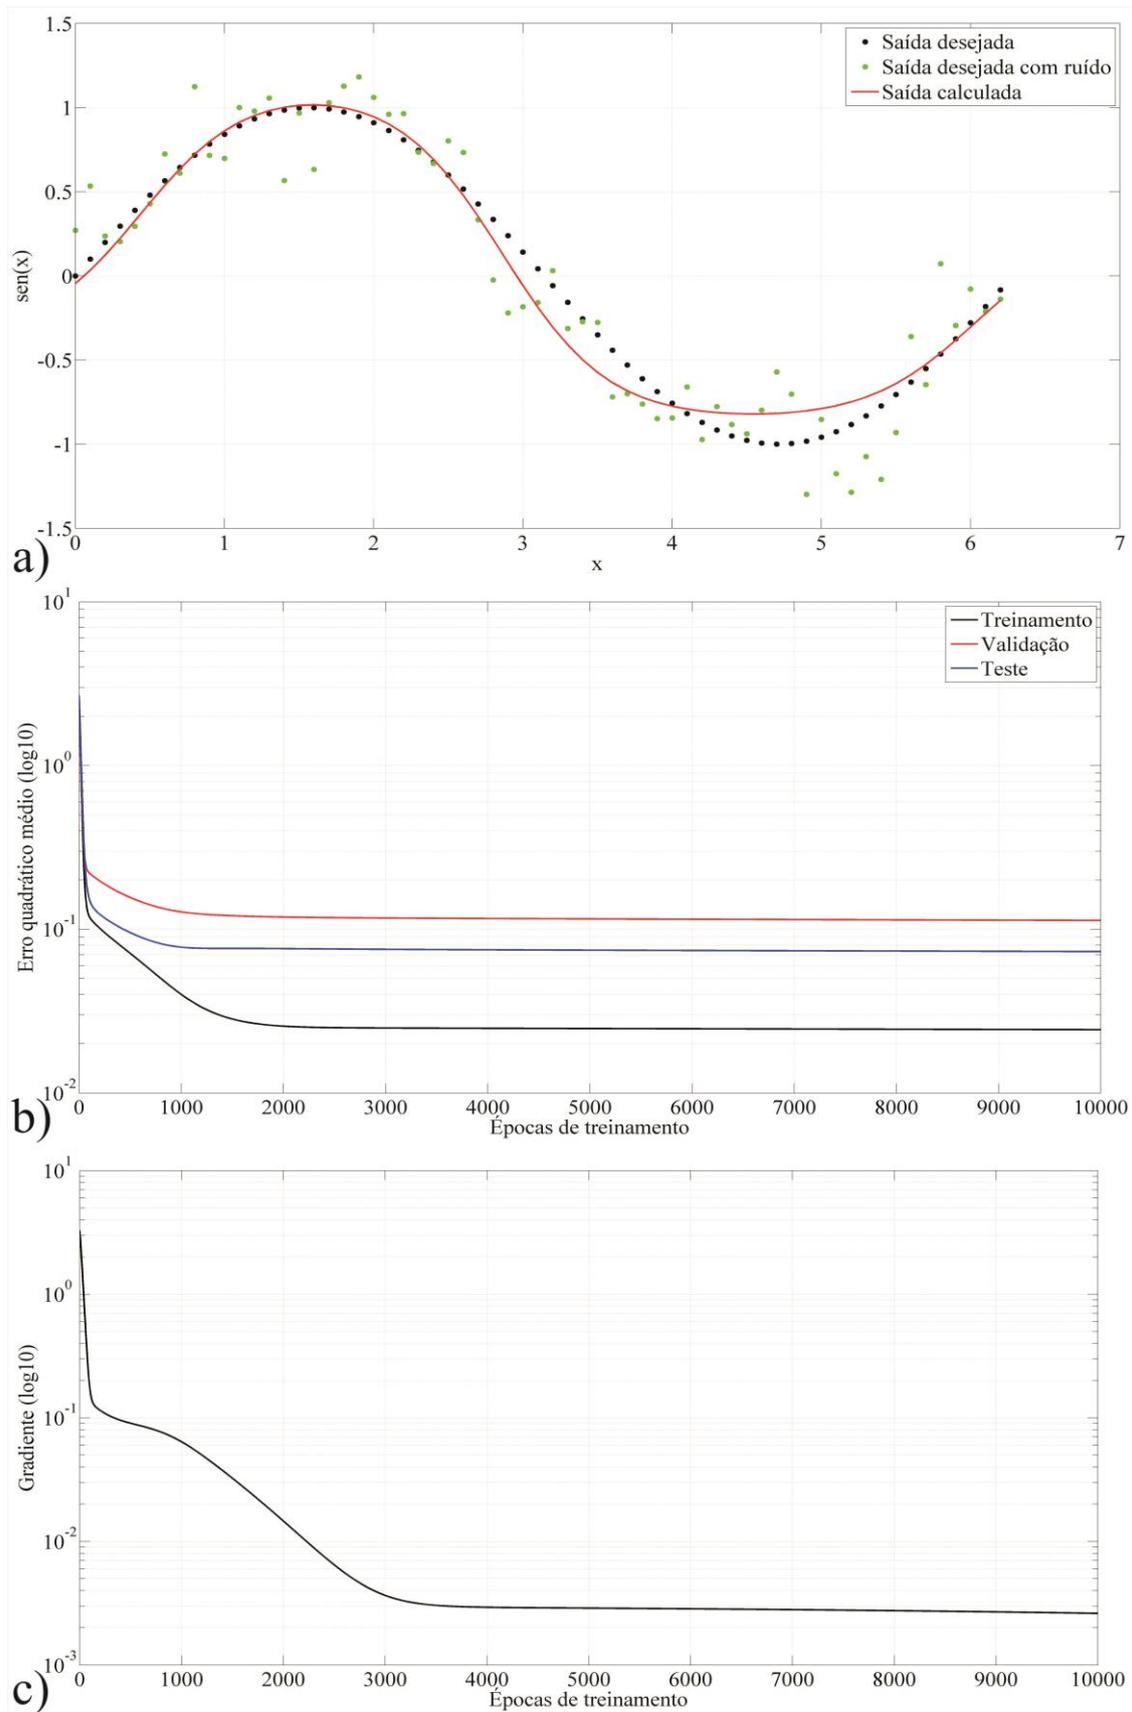


Figura 7.7 – Ajuste da função seno com ruído, 10.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

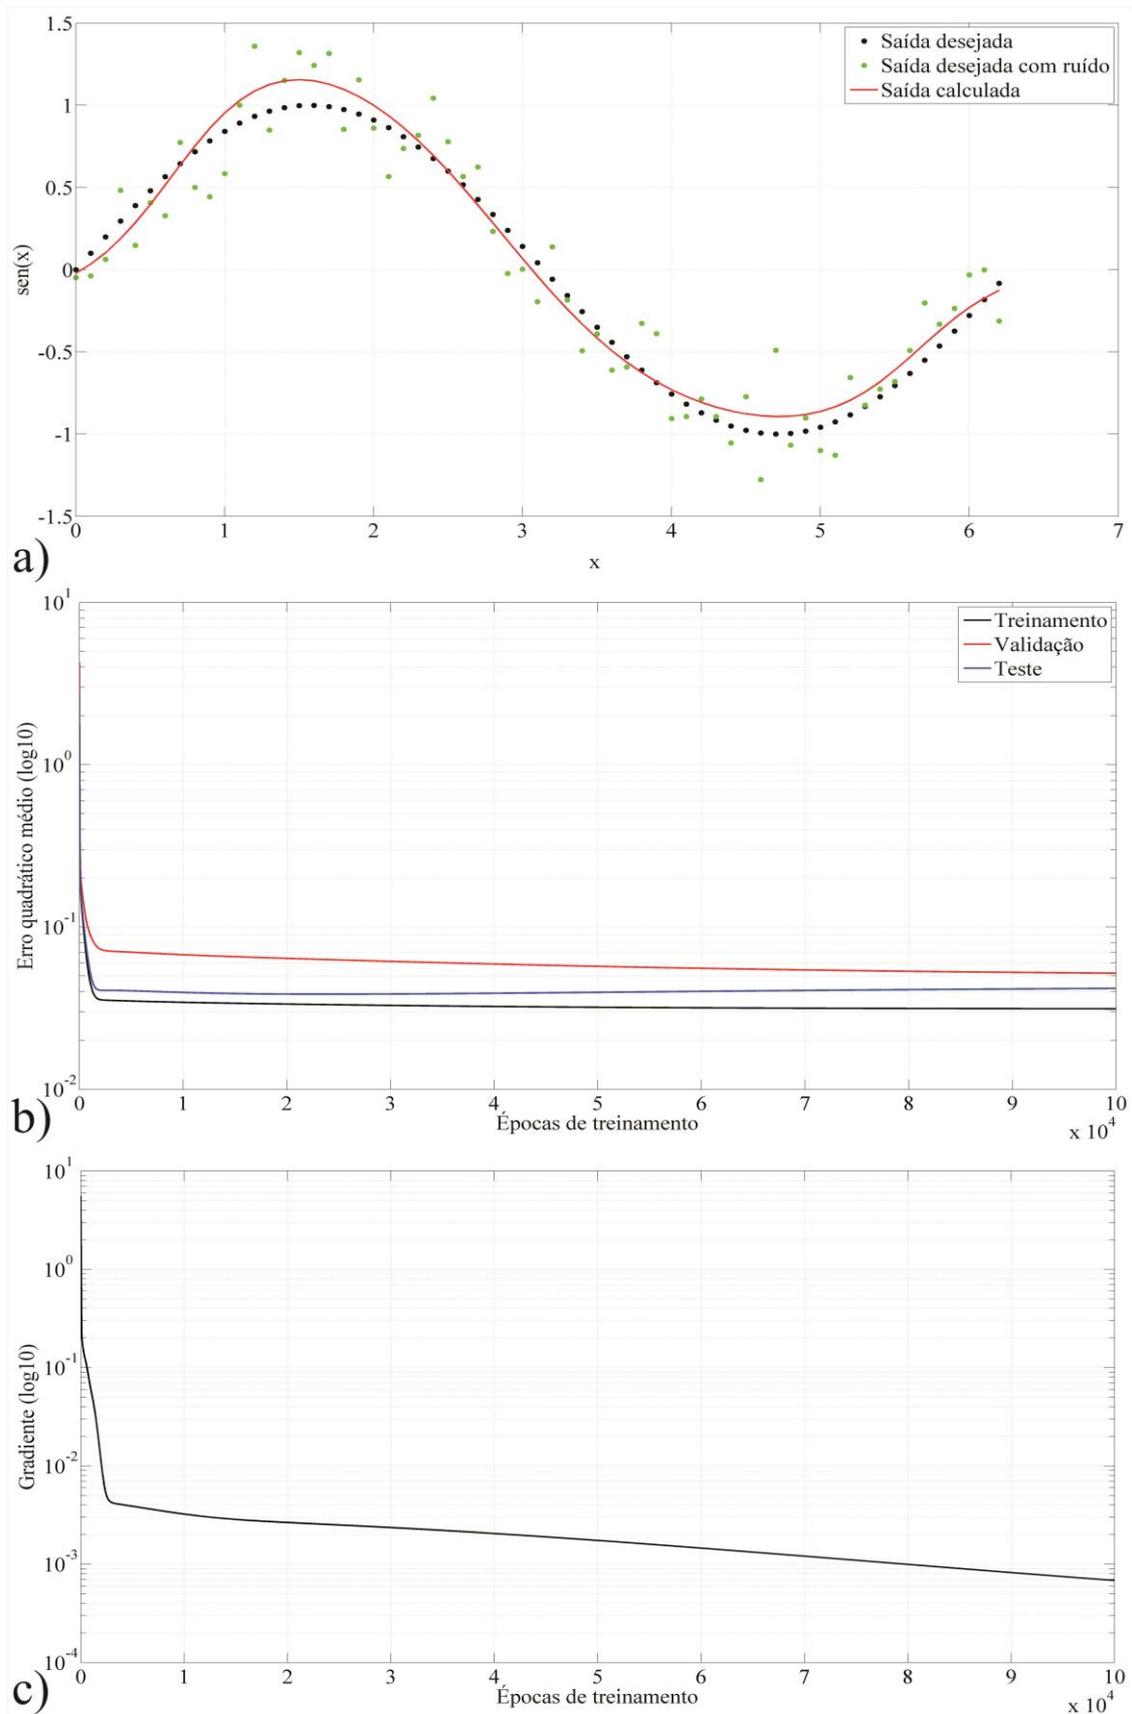


Figura 7.8 – Ajuste da função seno com ruído, 100.000 iterações e arquitetura 1-3-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

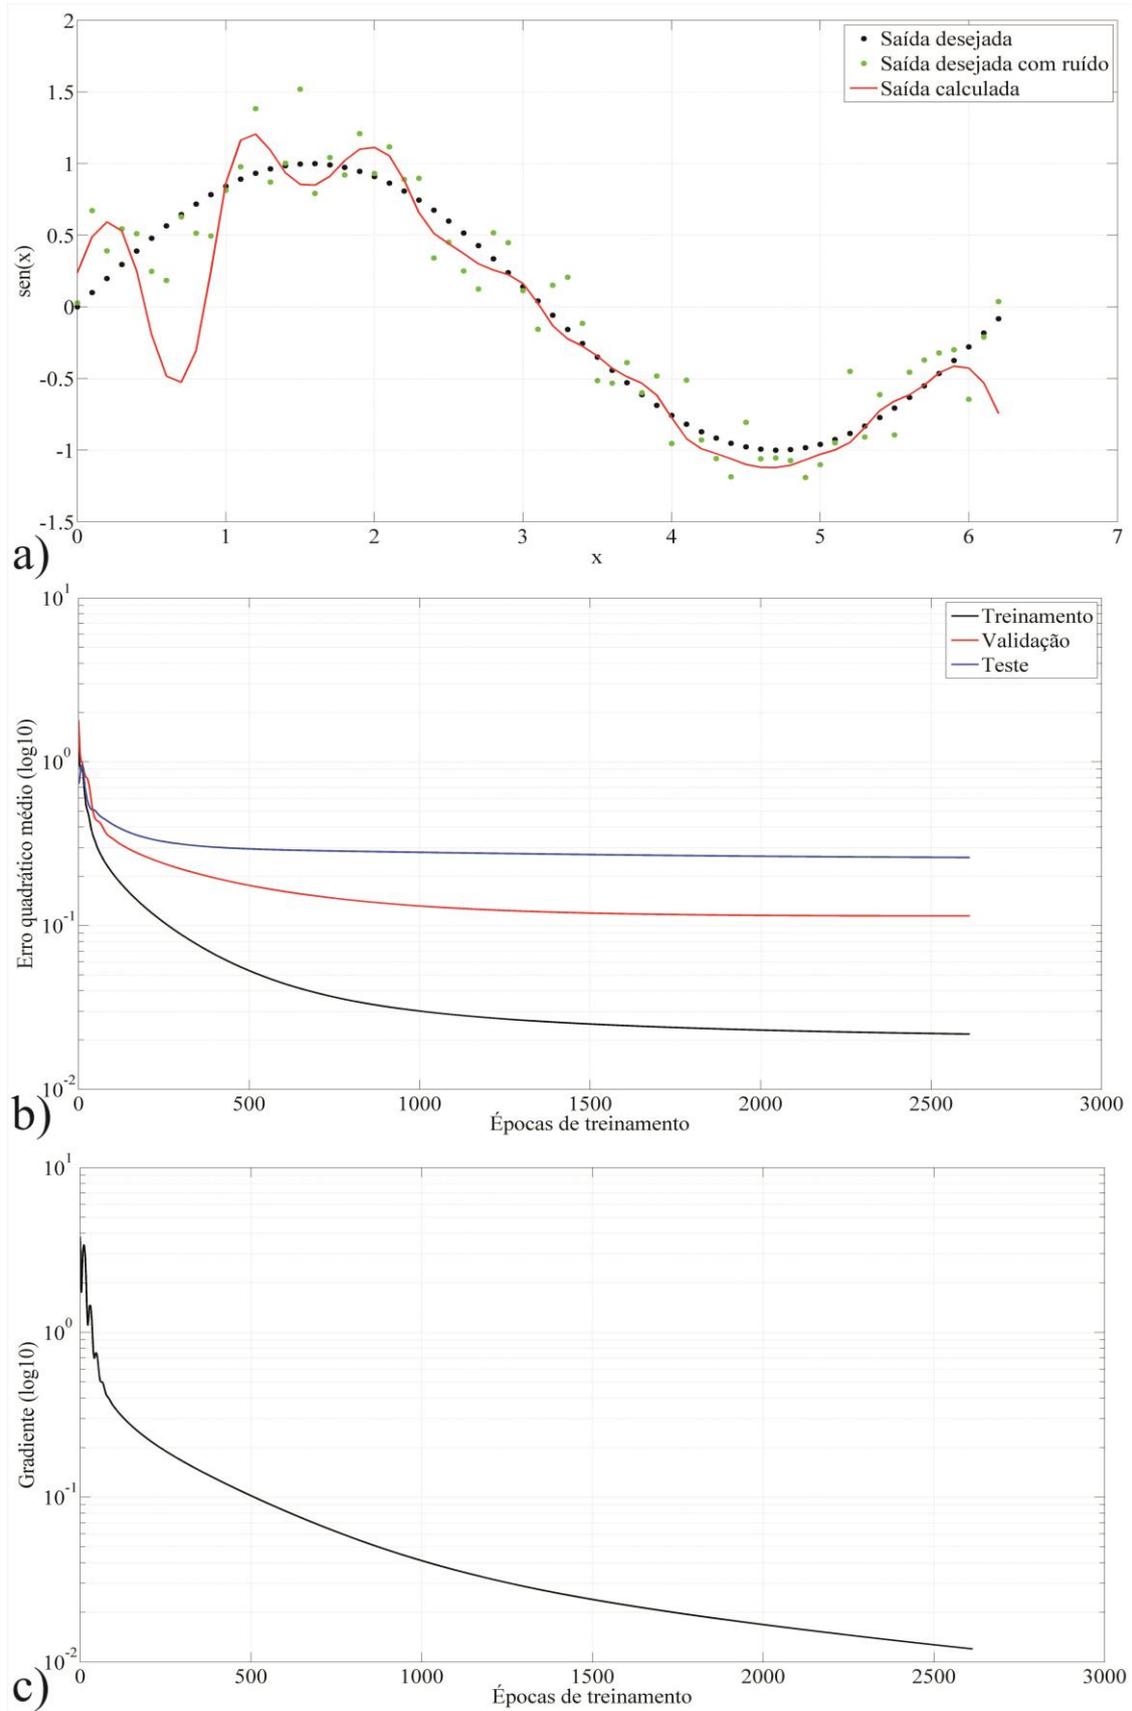


Figura 7.9 – Ajuste da função seno com ruído, 100.000 iterações e arquitetura 1-15-1. a) Saídas desejada (63 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

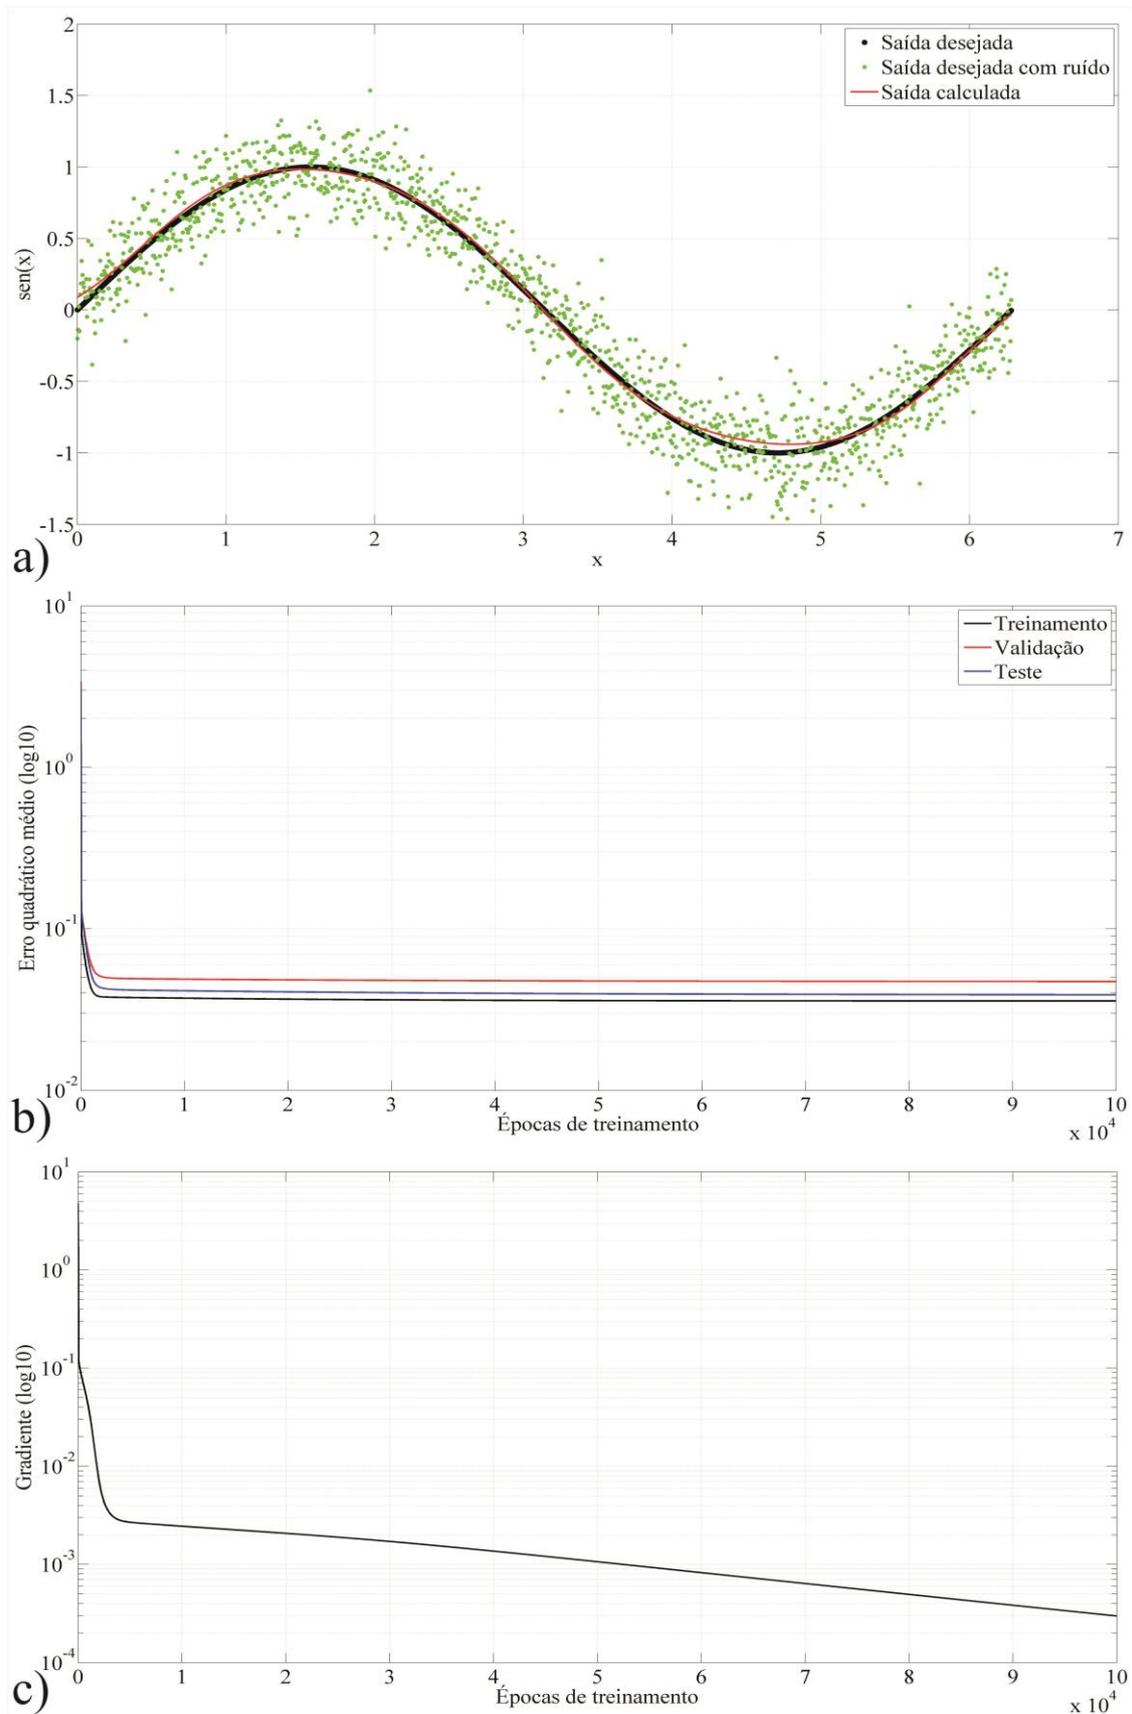


Figura 7.10 – Ajuste da função seno com ruído, 100.000 iterações e arquitetura 1-3-1. a) Saídas desejada (1257 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

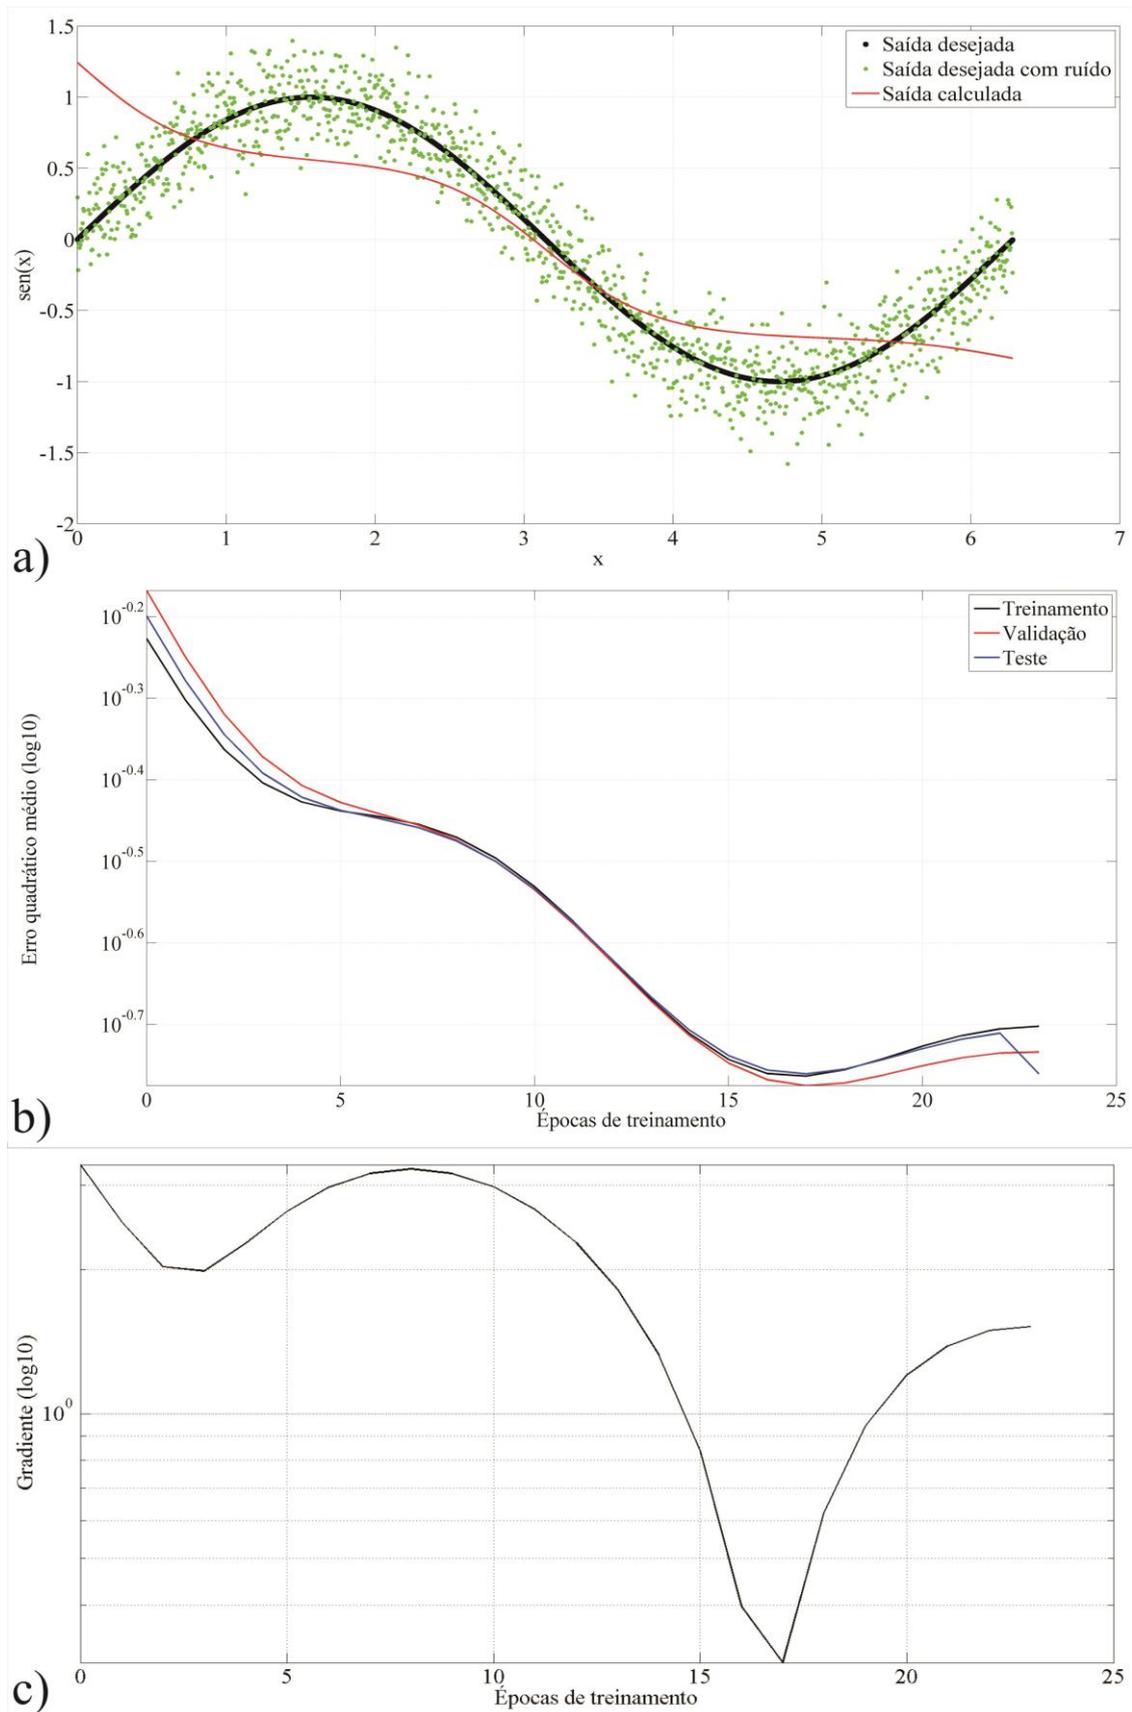


Figura 7.11 – Ajuste da função seno com ruído, 100.000 iterações e arquitetura 1-3-5-1. a) Saídas desejada (1257 pontos) e calculada. b) Variação do erro quadrático médio. c) Variação do gradiente.

A partir dos resultados apresentados, conclui-se que a rede neural desenvolvida está de acordo com a literatura, pois o melhor ajuste obtido da função seno é a rede do tipo 1-3-1. Um resumo dos primeiros testes realizados com a função seno da rede neural pode ser visto na Tabela 7.1.

A rede mostrou-se estável mesmo para um grande número de dados com ruído aleatório e, com isso, tal modelo de rede pode ser utilizado como ponto de partida para a identificação das hipérboles, com as características extraídas dos perfis GPR. Após encontrar uma arquitetura adequada para tal finalidade, aliando os fatores tempo de processamento e taxa de acerto na identificação, essas hipérboles foram submetidas ao segundo processo da análise, que consiste na classificação do tipo de material utilizando as mesmas características.

O programa desenvolvido baseia-se no esquema mostrado na Figura 7.12. No primeiro passo foram processados todos os dados a serem utilizados no treinamento. Esse processamento visou conservar ao máximo as características originais do sinal, destacando sempre as difrações hiperbólicas, e foi realizado segundo as etapas descritas no capítulo anterior.

Após o processamento, os traços correspondentes a alvos em subsuperfície e a “não alvos” foram selecionados para a extração das características e assim efetuar o treinamento da rede. Em seguida, a rede treinada foi aplicada no conjunto de teste para a determinação da “taxa de identificação”. Uma vez separados os traços com alvos determinados, inicia-se a etapa da classificação. De modo independente, outra rede neural foi treinada utilizando as mesmas características, porém, com os dados divididos em traços correspondentes a plástico, concreto e metal.

A princípio, foi necessário desenvolver uma rotina para ler os dados de entrada que são provenientes das aquisições GPR com o equipamento *GSSI*, pois tais dados possuem extensão *.dzt*. A partir dessa rotina foi possível extrair todas as informações para iniciar o processo. Para cada característica foi desenvolvida uma rotina em que é gerado um arquivo contendo todas elas para efetuar o treinamento da rede.

Tabela 7.1 – Resumo dos testes realizado com a rede neural artificial desenvolvida (backpropagation com gradiente descendente e momentum) para o ajuste da função seno.¹

	Rede										
	1-3-1	1-3-1	1-3-1	1-3-1	1-3-1	1-3-1	1-3-1	1-3-1	1-15-1	1-3-1	1-3-5-1
Figura	1	2	3	4	5	6	7	8	9	10	11
Número de dados	63	63	63	63	63	63	63	63	63	1257	1257
Iteração	100	1.000	10.000	100.000	100	1.000	10.000	100.000	100.000	100.000	100.000
Tempo	00'01''	00'08''	01'26''	15'58''	00'01''	00'08''	01'29''	17'05''	00'22''	43'09''	00'01''
Ruído	não	não	não	não	sim						
Erro quadrático médio (validação)	0,074	0,061	0,005	0,0003	0,267	0,066	0,113	0,052	0,115	0,047	0,168

¹ Computador utilizado: Intel Core i5 (terceira geração), 2,70 GHz, 8 GB de RAM.

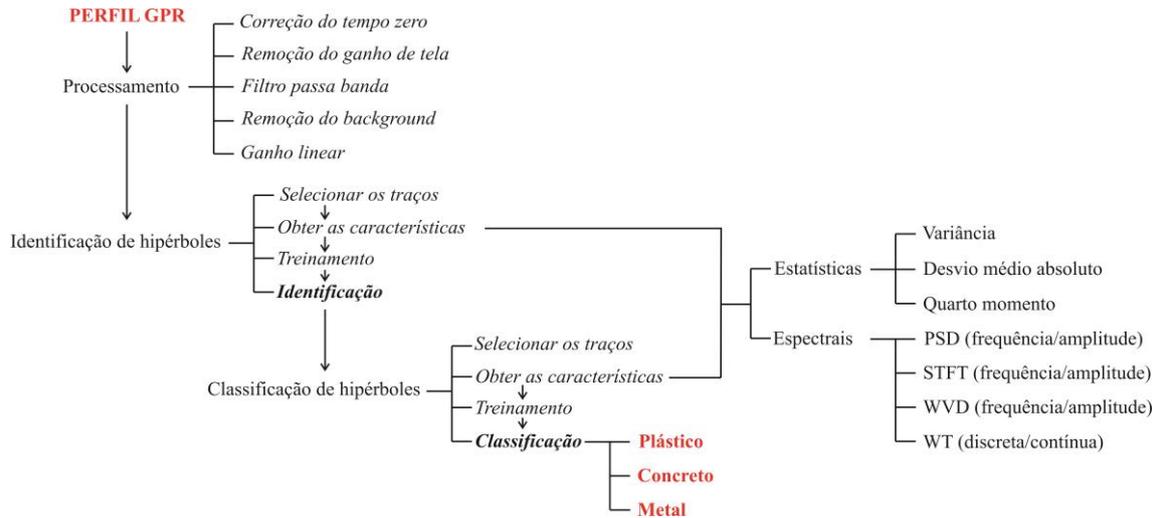


Figura 7.12 – Esquema das etapas de identificação e classificação do programa NC_GPR.

As características foram extraídas dos traços na forma de A-scans, sendo estes sinais GPR apenas referentes aos alvos nos quais se tem amplitude por tempo de percurso da onda eletromagnética. Para aumentar o número de dados de treinamento optou-se por utilizar cinco A-scans de cada alvo, ou seja, um A-scan central (sobre o alvo) e mais dois à esquerda e à direita, totalizando assim 1470 (294 x 5) A-scans com alvos coletados no SCGR e 1470 A-scans, selecionados aleatoriamente, correspondendo a “não alvos”. Desse modo, como dito anteriormente, o conjunto total de dados (2940) foi dividido em 2058 (70%) A-scans para o treinamento e validação e 882 (30%) para o teste da rede.

O erro de validação foi utilizado como critério de parada do treinamento, ou seja, caso o erro aumentasse em um determinado momento das iterações, o treinamento era encerrado. Para encontrar uma rede que se adequasse aos dados o número de neurônios na camada oculta foi variado em 10, 30, 45, 70 e 100, visando encontrar a arquitetura que fornecesse um menor erro quadrático médio, relativo ao conjunto de validação. Optou-se por utilizar uma rede com apenas uma camada oculta, pois sempre se busca um modelo mais simples de arquitetura para evitar que o treinamento fique com muitos processos e aumente o tempo gasto para tal tarefa.

A camada de entrada possui 11 neurônios, correspondendo ao número de características e apenas um neurônio na camada de saída, sendo 1 para hipérbole e 0 para “não hipérbole”. A tolerância assumida para as saídas (y) serem consideradas hipérboles foi de $0,9 \leq y \leq 1,1$.

7.2 IDENTIFICAÇÃO DE HIPÉRBOLES

A identificação automática das hipérboles foi desenvolvida utilizando também as RNAs. Essa etapa foi importante para tornar o processo de classificação mais rápido, uma vez que identificada automaticamente uma hipérbole, essa já é classificada sem interação com o usuário.

Para determinar qual arquitetura de rede utilizar foram feitos testes visando encontrar a rede com menor erro de treinamento. Na Tabela 7.2 pode-se observar os resultados obtidos para o erro quadrático médio de validação (EQM_v), tempo de treinamento e número de iterações, sendo que em vermelho está indicando o menor EQM_v encontrado.

Tabela 7.2 – Erro quadrático médio de validação (EQM_v), tempo de treinamento e número de iterações dos testes realizados com a rede neural artificial desenvolvida utilizando A-scans.²

Neurônios na camada oculta	EQM _v	Tempo	Iterações
10	0,009	1h42'20''	351.558
30	0,005	6h36'16''	699.903
45	0,023	15'33''	54.652
70	0,017	15'31''	48.841
100	0,012	1h20'10''	194.004

A partir das tabelas acima observa-se que a rede com 30 neurônios na camada oculta (Figura 7.13) e com 699.903 iterações atingiu o menor EQM_v (0,005) no tempo de 6 horas, 36 minutos e 16 segundos. A variação do EQM (treinamento, validação e teste), do gradiente e as saídas calculadas podem ser vistas na Figura 7.14 e pode-se dizer que a rede treinada não sofreu com o *overfitting*, pois a diferença entre os erros de treinamento/validação e de teste é pequena e a arquitetura da rede é simples.

Uma característica importante que foi observada diz respeito a estabilidade da rede. Todas elas apresentaram uma estabilidade constante para 10, 30 e 45 neurônios na camada oculta, uma vez que não foi necessária a repetição do treinamento para a diminuição do gradiente e convergência da rede. Já para 70 e 100 foram necessárias várias repetições do treinamento até atingir a diminuição do gradiente.

² Computador utilizado: Intel Core i5 (terceira geração), 2,70 GHz, 8 GB de RAM.

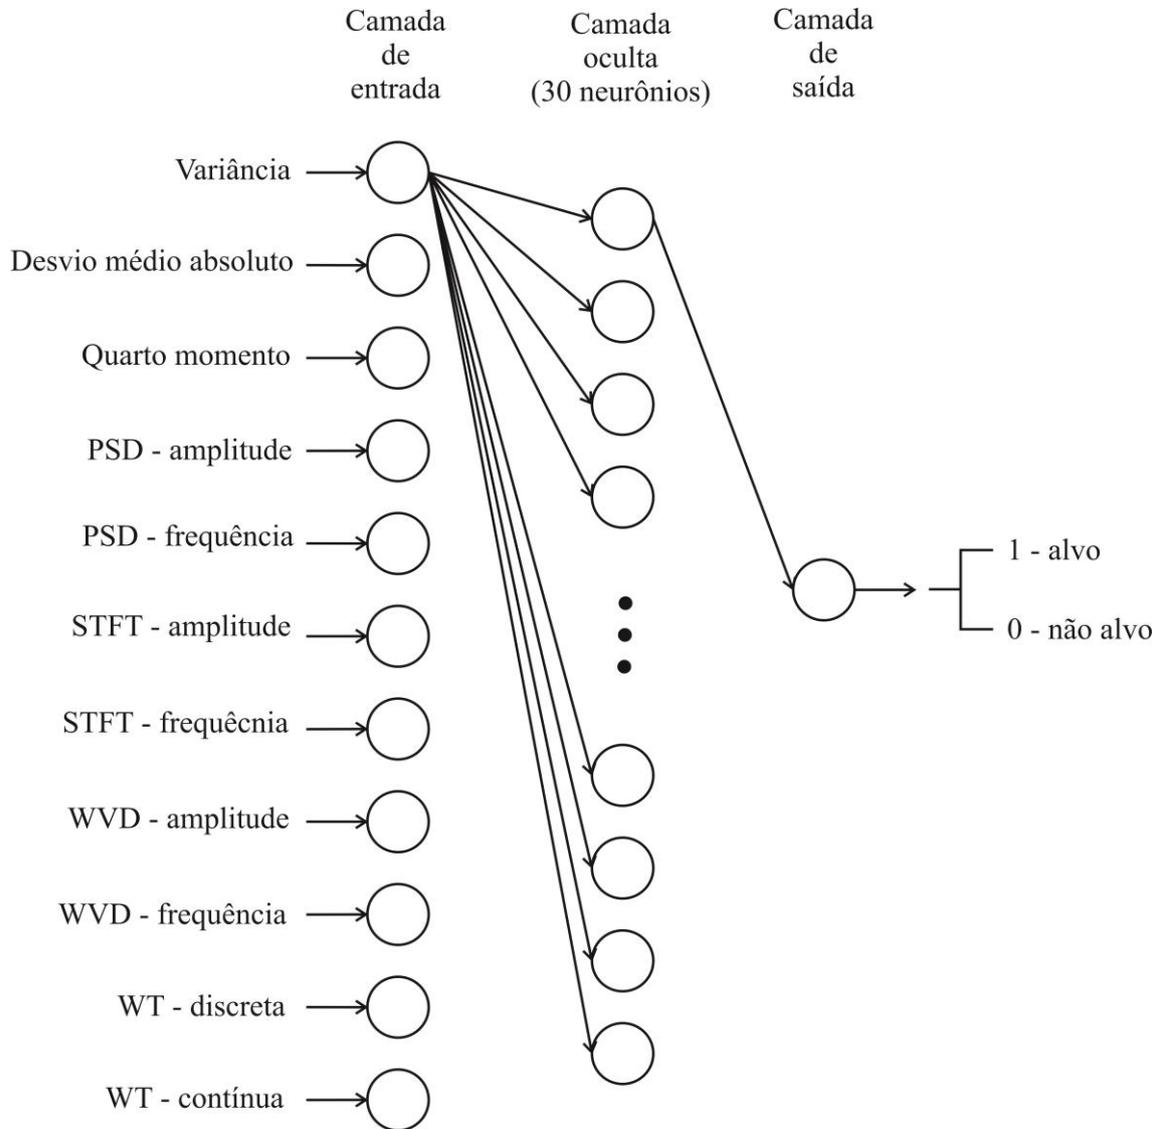


Figura 7.13 – Esquema da rede neural final utilizada para identificação de alvos.

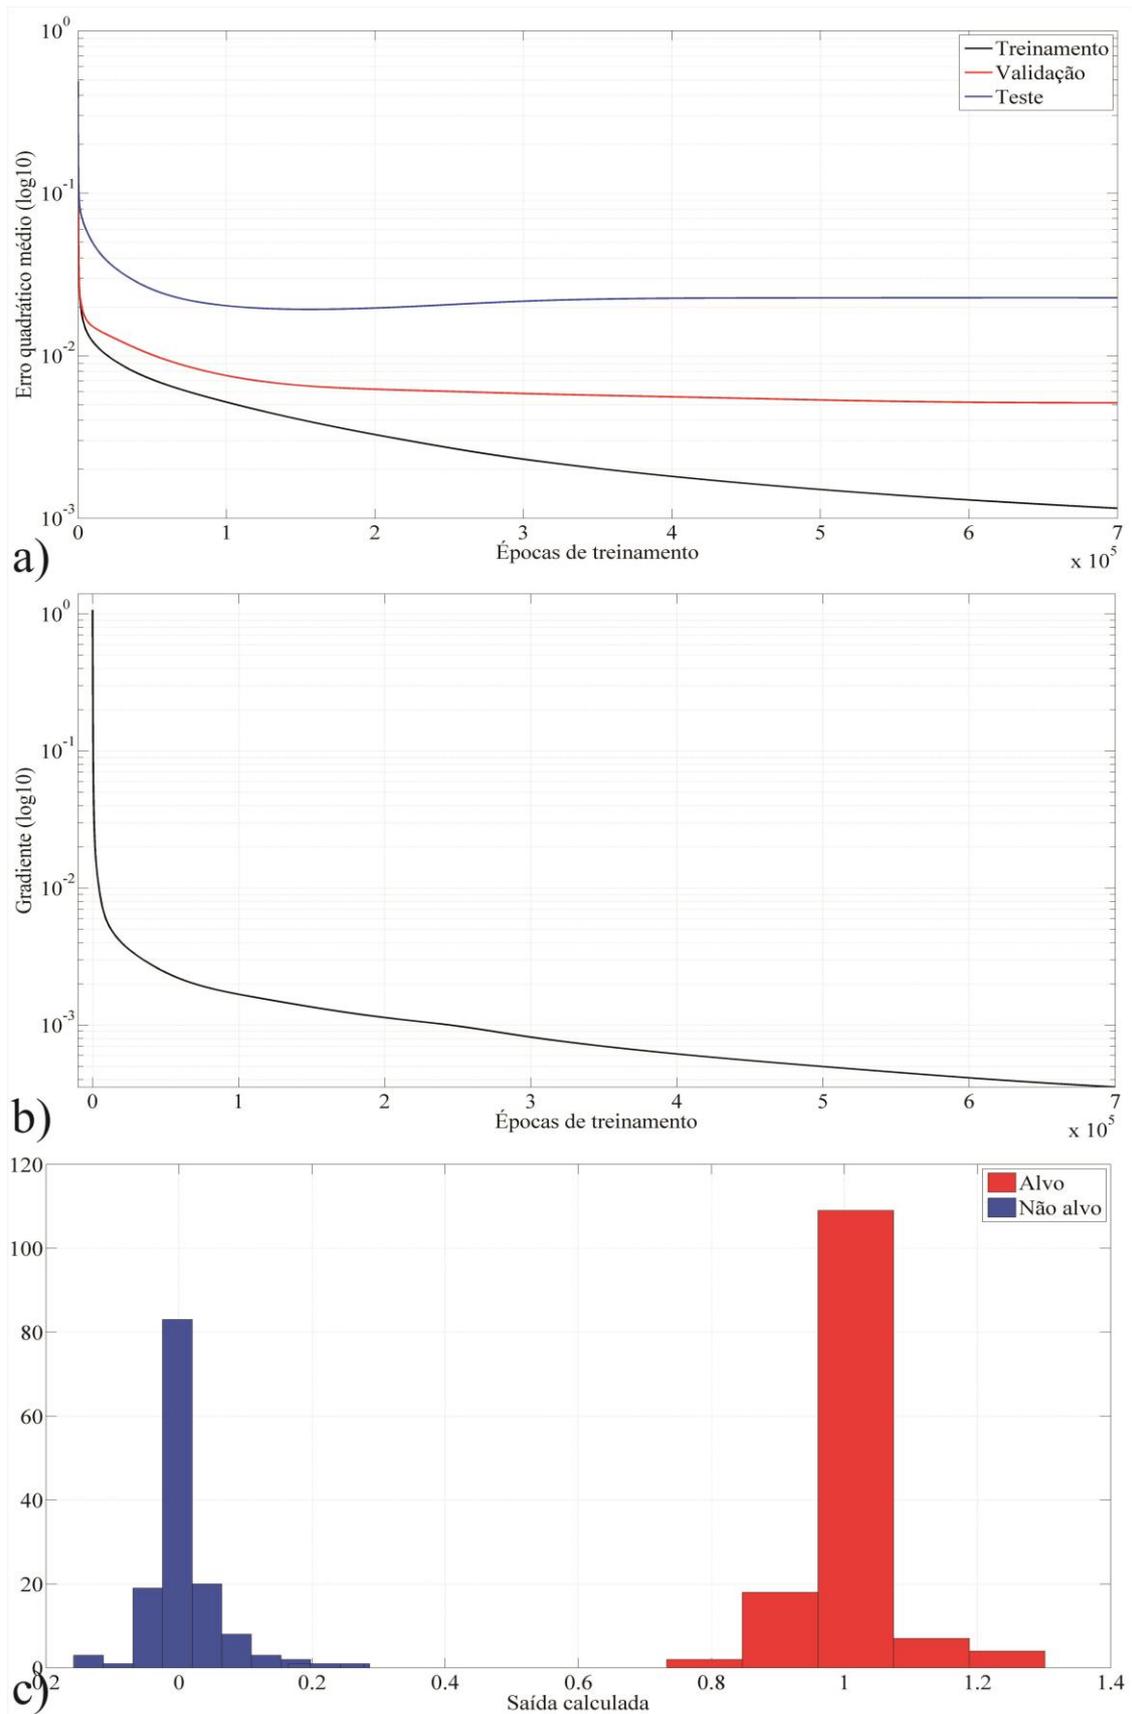


Figura 7.14 – Rede neural 11-30-1 utilizando A-scans. a) Variação dos erros de treinamento, validação e teste. b) Variação do gradiente. c) Saídas calculadas pela rede.

Com a rede para identificar hipérboles treinada, o próximo passo foi de aplicação da mesma em perfis GPR para a identificação de A-scans provenientes de alvos em subsuperfície. Porém, para uma efetiva localização das hipérboles, foi necessário utilizar um método de interpolação de pontos para verificar se os pontos determinados são de uma hipérbole ou não.

Para tal tarefa foi desenvolvida uma rotina que verifica se os pontos determinados pela RNA caracterizam ou não uma hipérbole. A equação da hipérbole é definida da seguinte forma:

$$\frac{(y-k)^2}{a^2} - \frac{(x-h)^2}{b^2} = 1 \quad (7.1)$$

com (h,k) sendo o centro da hipérbole, a é o semi-eixo maior e b o semi-eixo menor. Desenvolvendo a equação acima temos:

$$-a^2x^2 + 0xy + b^2y^2 + 2a^2hx - 2b^2ky - a^2h^2 + b^2k^2 - a^2b^2 = 0 \quad (7.2)$$

A equação obtida (Eq.7.2) é um polinômio bivariado de grau 2:

$$Ax^2 + Bxy + Cy^2 + Dx + Ey + F = 0 \quad (7.3)$$

com A, B, C, D, E e F sendo os coeficientes do polinômio. Fazendo a correlação entre as equações 7.2 e 7.3 temos que:

- $A = -a^2$
- $B = 0$
- $C = b^2$
- $D = 2a^2h$
- $E = -2b^2k$
- $F = -a^2h^2 + b^2k^2 - a^2b^2$

Calculando os coeficientes do polinômio bivariado pode se determinar se a curva é ou não uma hipérbole, sendo que o critério para esta escolha baseia-se no erro de ajuste. Para determinar se no perfil estudado existem hipérboles, foram selecionados pontos de maior variação na amplitude e a partir destes pontos calcula-se os coeficientes do polinômio, ajusta-se a curva aos dados e com o erro determina-se se é ou não uma hipérbole.

A confiabilidade desta metodologia foi testada primeiramente em dados sintéticos obtidos com o *software* ReflexW (SANDMEIER, 2013). Um exemplo de teste realizado pode ser visto na Figura 7.15, onde foi simulado um tambor metálico a 0,5 m de profundidade. A média do resíduo para a função ajustada foi de $-6,36e-012$.

Assim, a partir de um conjunto de pontos selecionado pela rede neural, pode-se fazer o ajuste para a verificação hipérbole/não hipérbole. Um exemplo de ajuste pode ser visto na Figura 7.16.

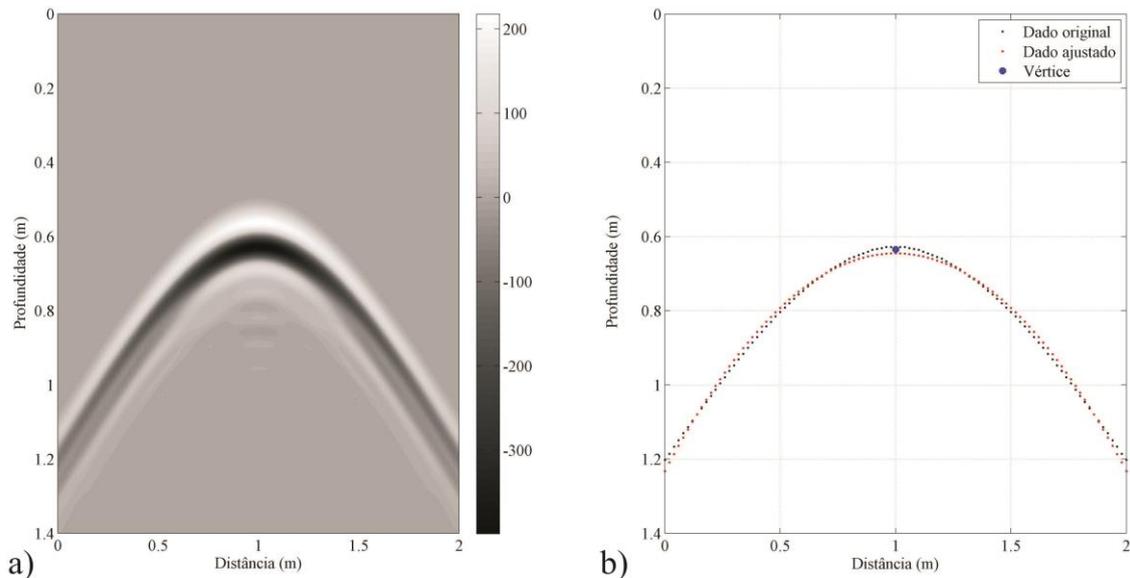


Figura 7.15 – Ajuste de hipérboles. a) Modelo gerado. b) Ajuste obtido a partir do dado original.

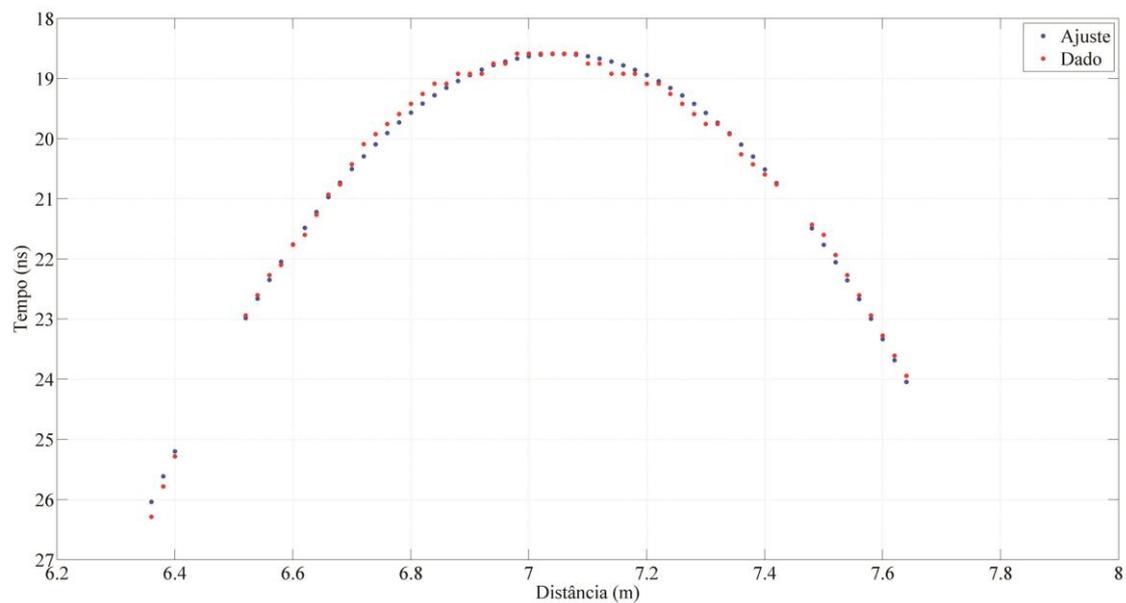


Figura 7.16 – Ajuste obtido a partir de dados reais selecionados pela RNA.

Para a identificação de hipérboles foi necessário duas etapas: seleção de traços com alvos em subsuperfície e ajuste desses traços para verificar se é ou não hipérbole. A partir disso avaliou-se a primeira parte do NC_GPR nos dados selecionados para o teste da rede treinada. Os dados mostrados abaixo fazem parte do conjunto selecionado para o teste, que não foram utilizados para o treinamento da rede. O identificador de hipérboles percorre todo o perfil GPR classificando os traços em alvo ou “não alvo” e em seguida faz o ajuste da hipérbole, assim sendo necessário verificar todos os traços do perfil. Para exemplificar foram selecionados 10 perfis:

1. Linha 2, com antena de 200 MHz, em período seco (Figura 7.17);
2. Linha 3, com antena de 270 MHz (Figura 7.18)
3. Linha 4, com antena de 200 MHz, em período seco (Figura 7.19);
4. Linha 4, com antena de 200 MHz, em período de chuva (Figura 7.20);
5. Linha 4, com antena de 270 MHz (Figura 7.21)
6. Linha 4, com antena de 400 MHz, em período seco (Figura 7.22);
7. Linha 4, com antena de 400 MHz, em período de chuva (Figura 7.23);
8. Linha 5, com antena de 400 MHz, em período seco (Figura 7.24);
9. Linha 6, com antena de 200 MHz, em período seco (Figura 7.25);
10. Linha 7, com antena de 200 MHz, em período seco (Figura 7.26).

Em cada perfil foi determinado o tempo de processamento (Tabela 7.3). O resultado do programa é uma figura mostrando o perfil original na parte superior, seguido do resultado da aplicação da rede neural com os traços selecionados indicando possíveis alvos e por fim a identificação com o ajuste hiperbólico.

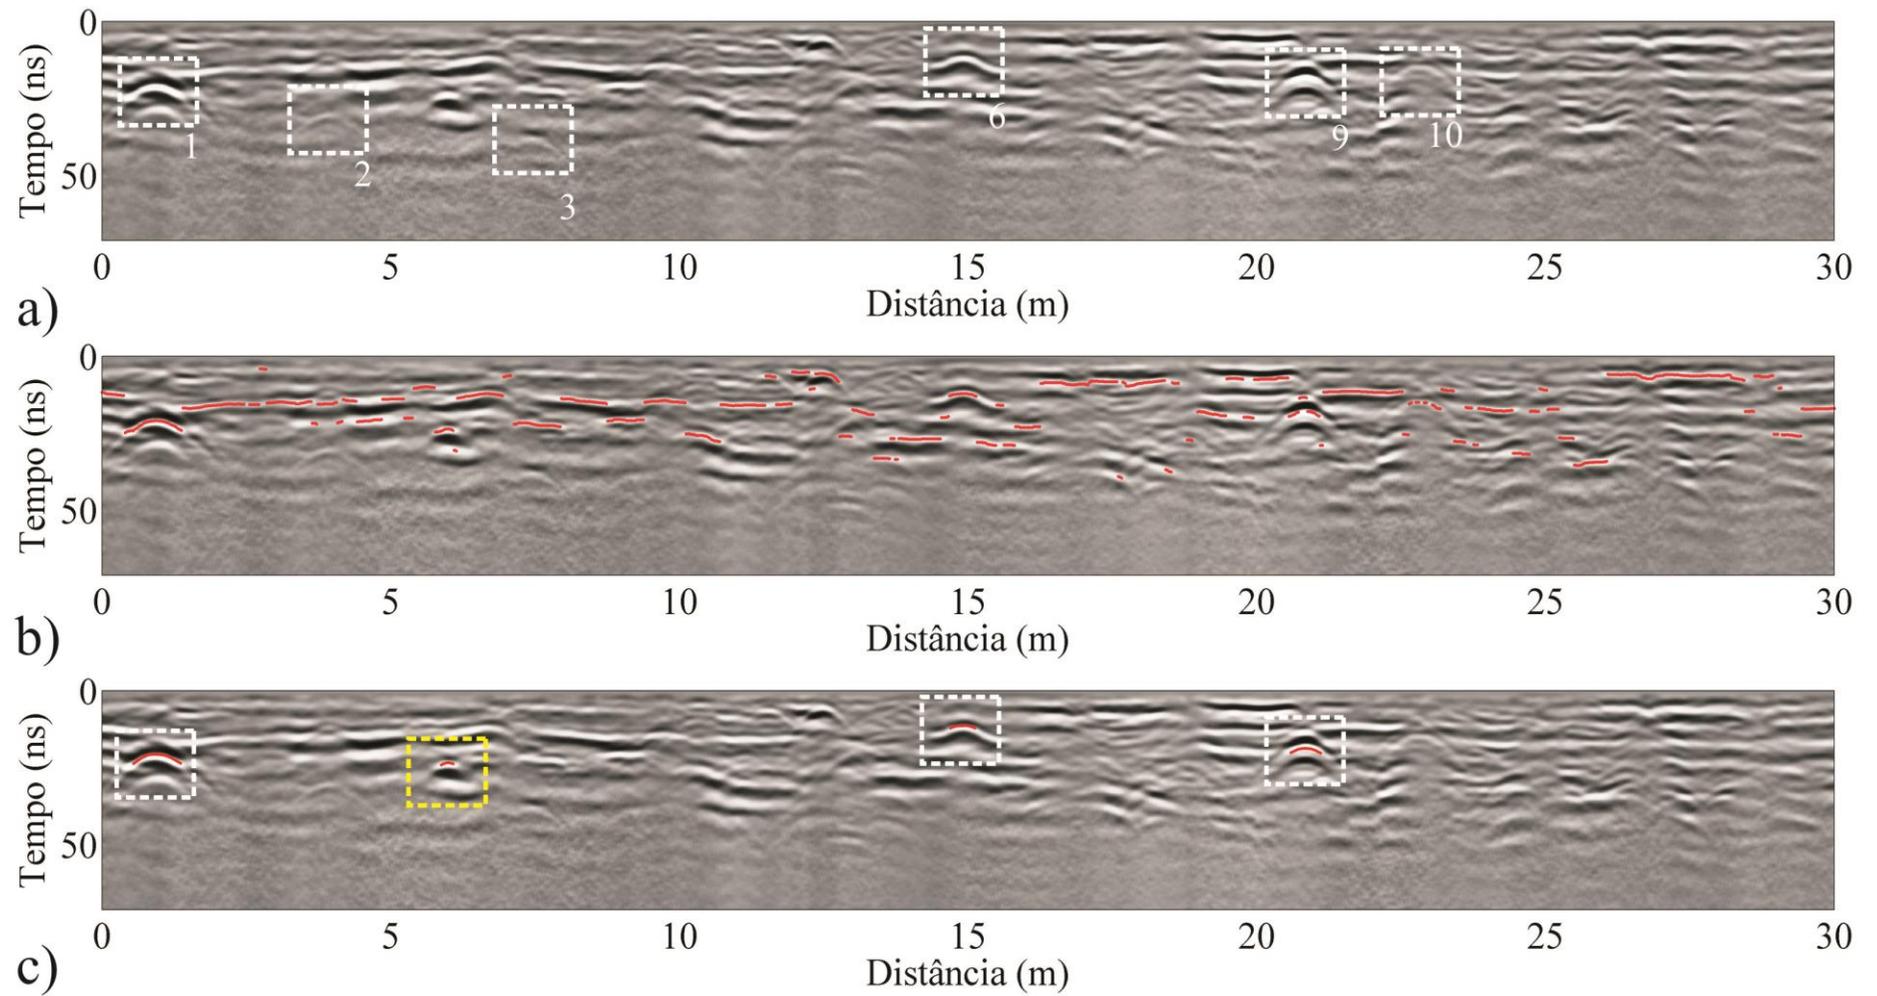


Figura 7.17 – Linha 2, 200 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

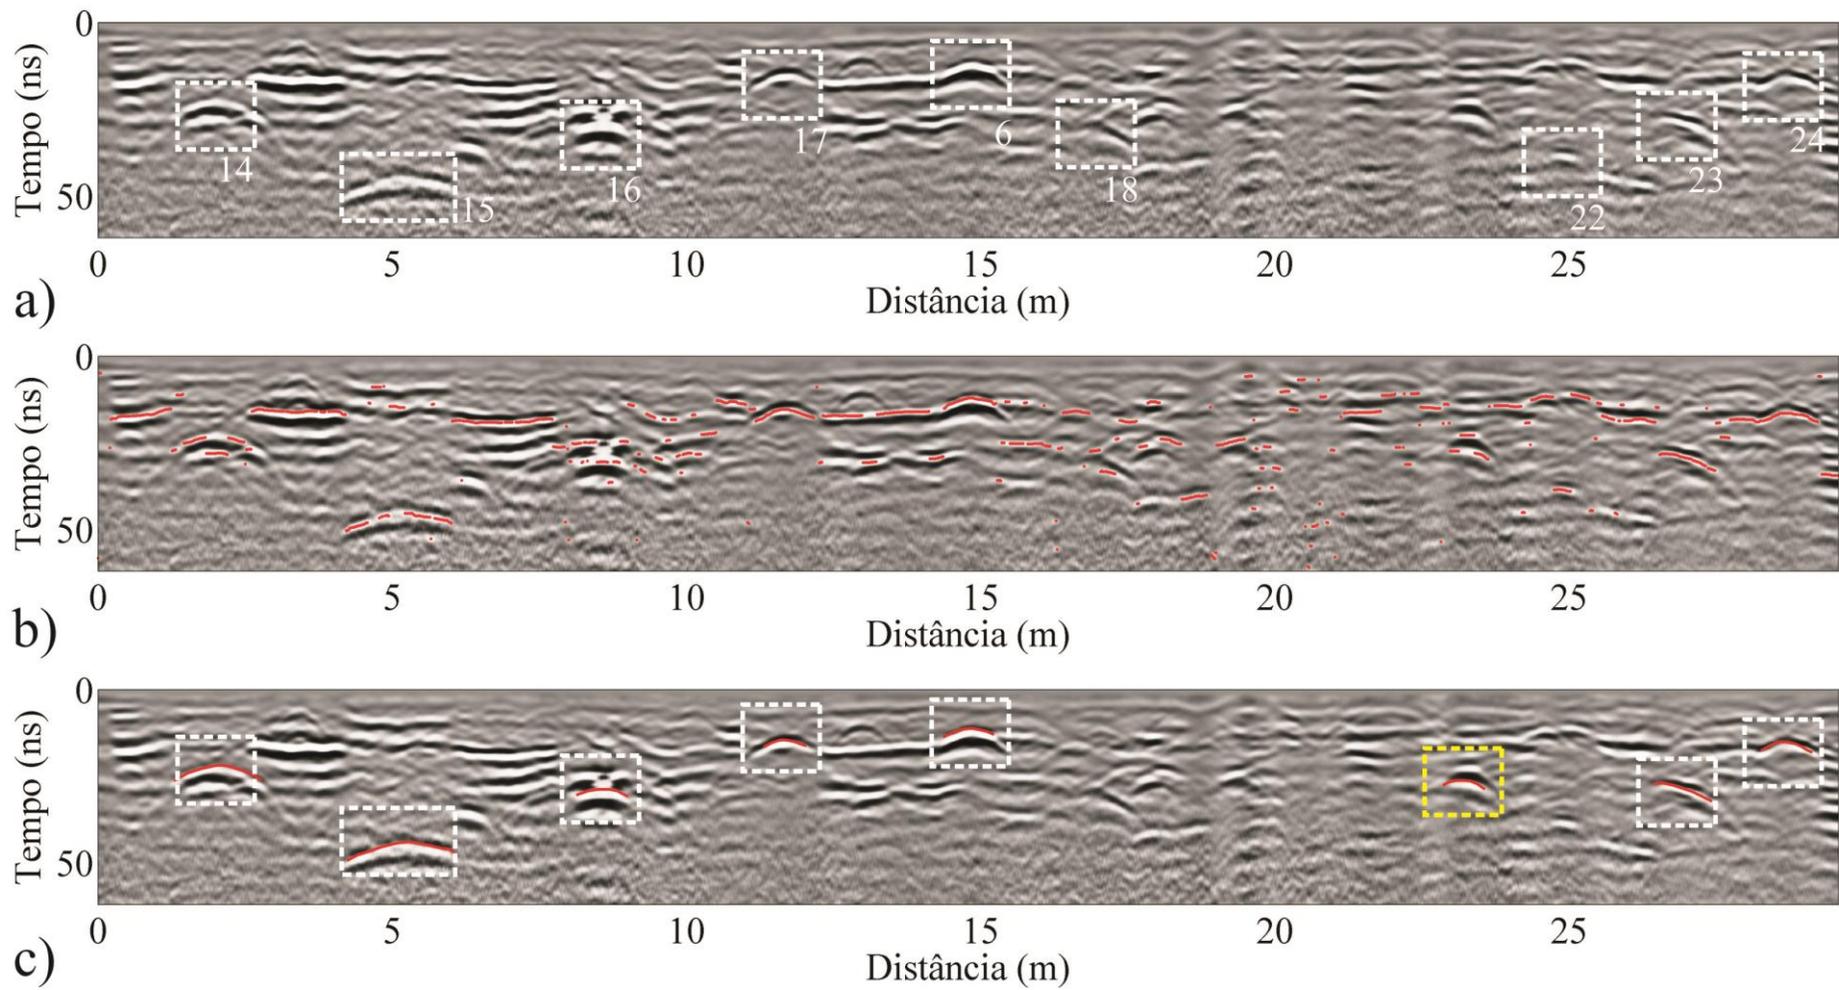


Figura 7.18 – Linha 3, 270 MHz. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

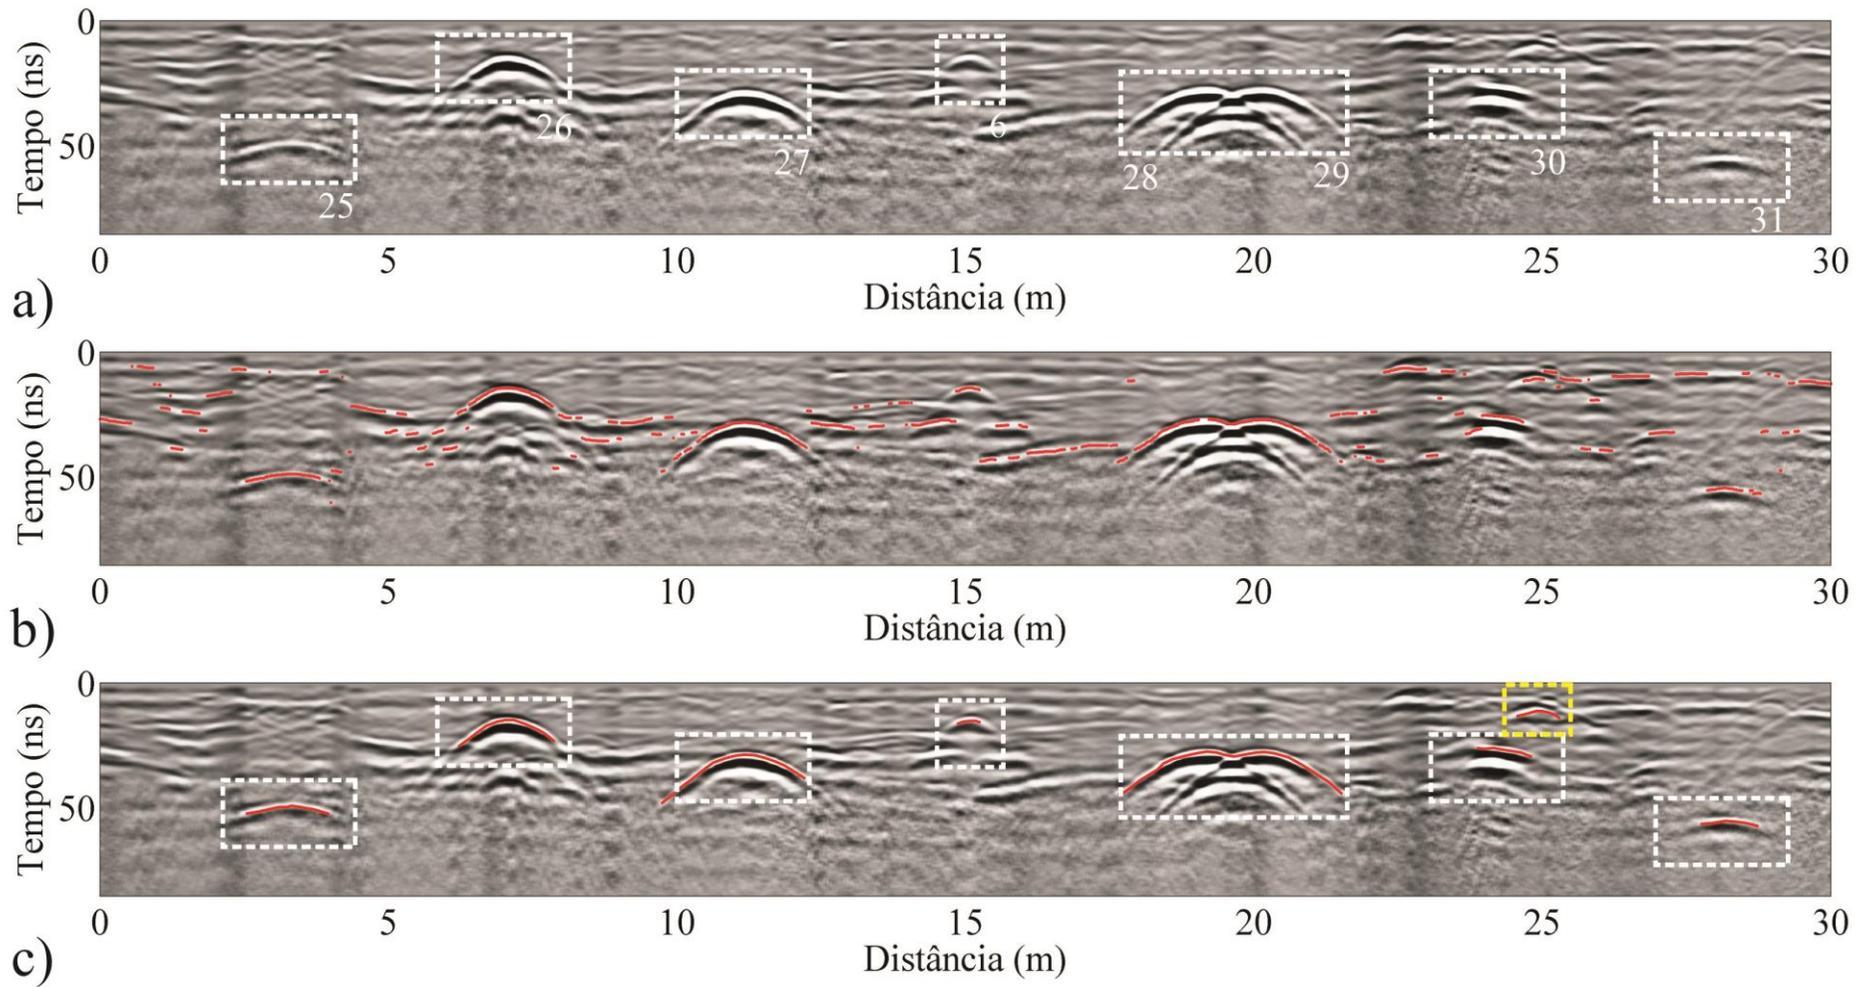


Figura 7.19 – Linha 4, 200 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

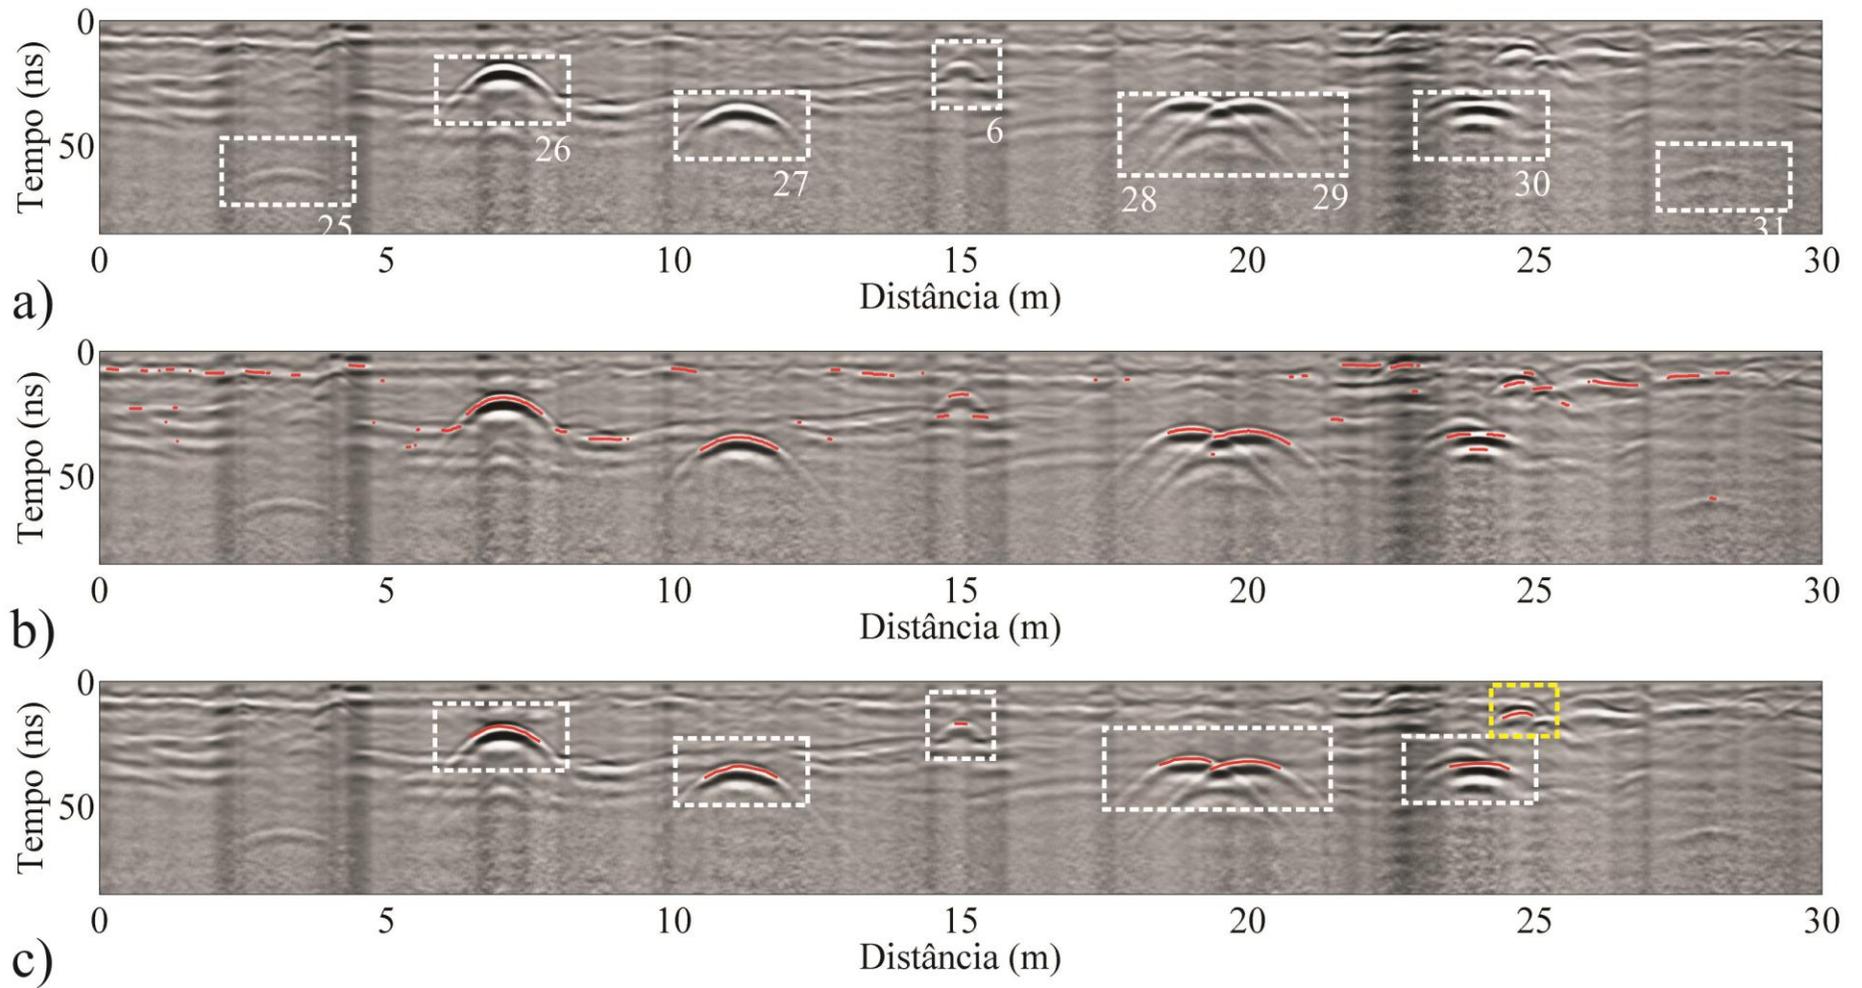


Figura 7.20 – Linha 4, 200 MHz, período de chuva. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

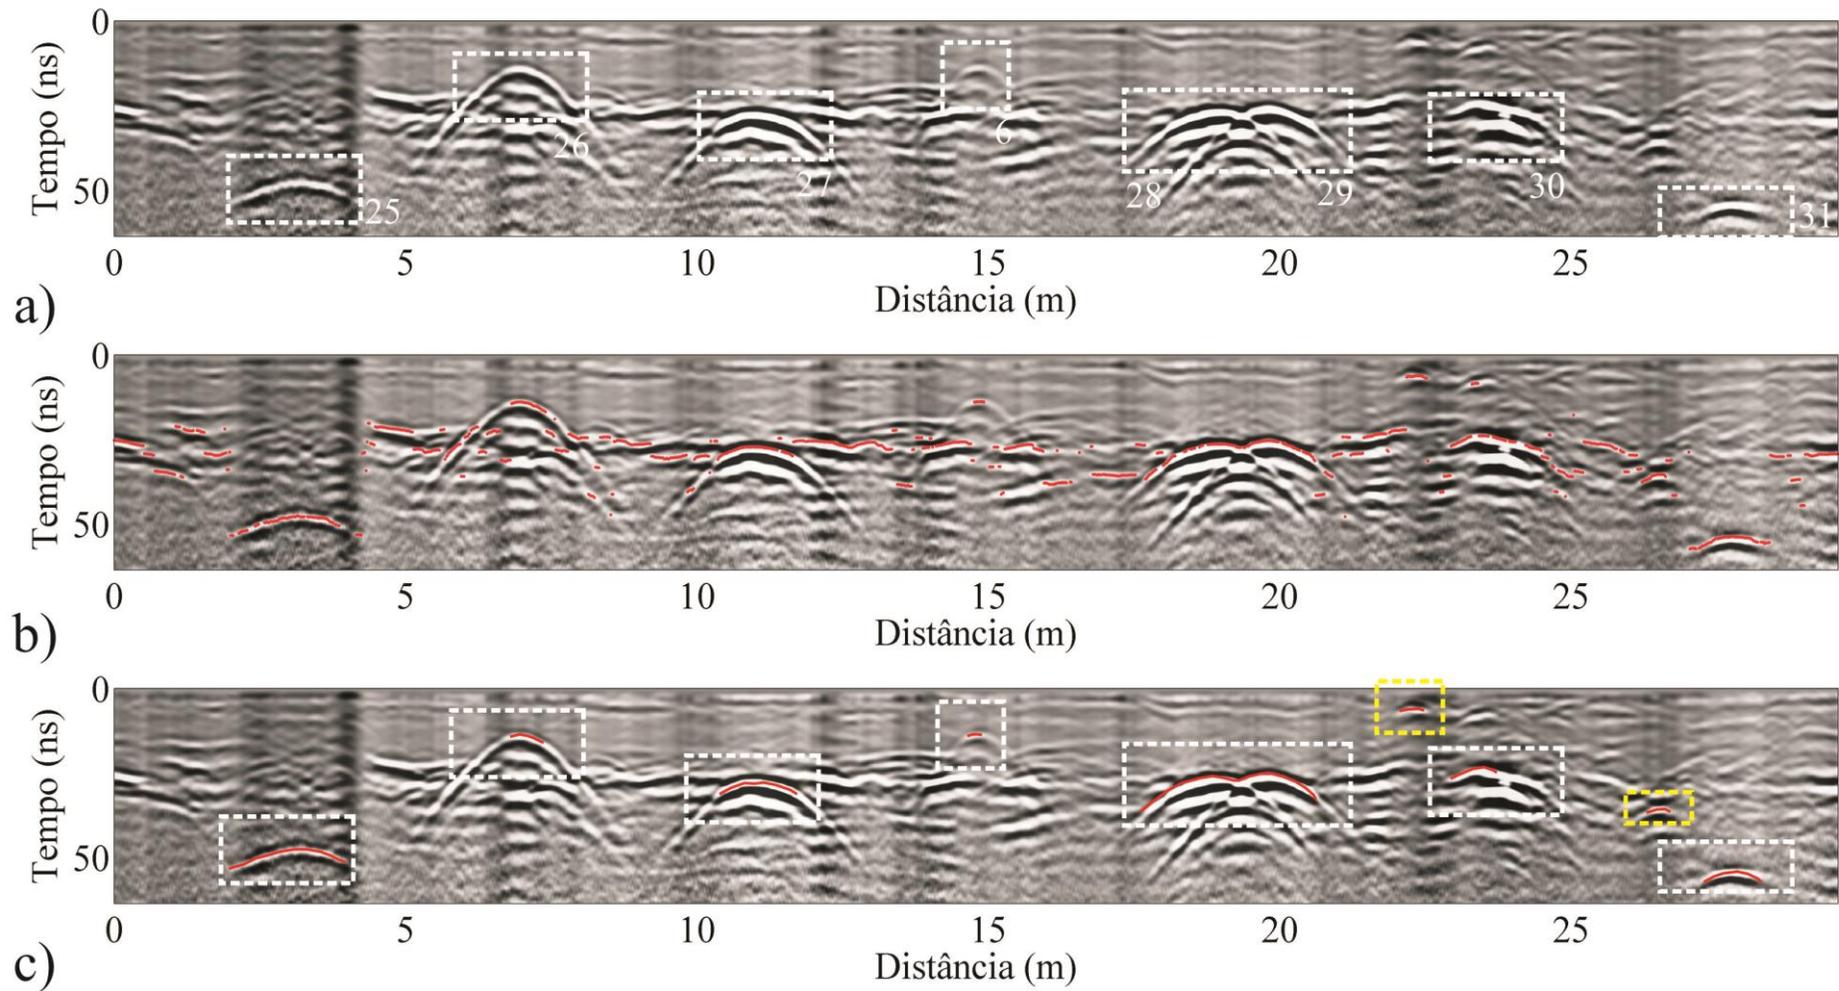


Figura 7.21 – Linha 4, 270 MHz. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

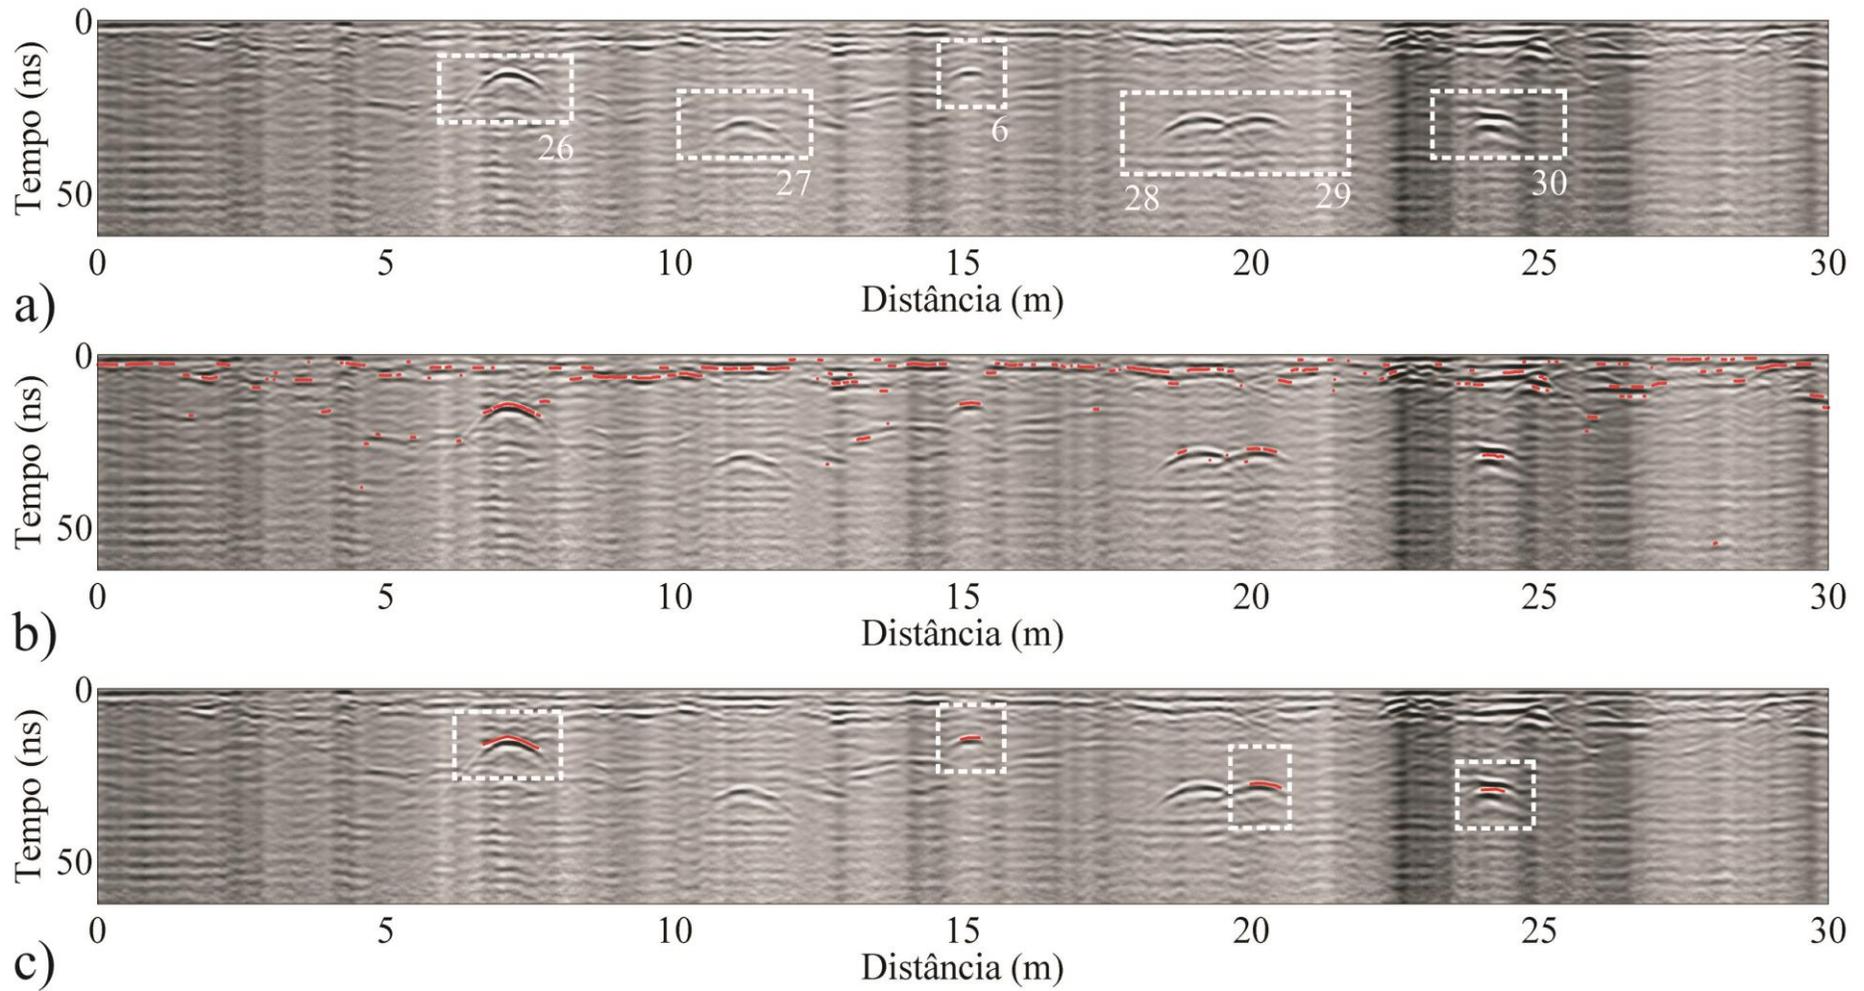


Figura 7.22 – Linha 4, 400 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

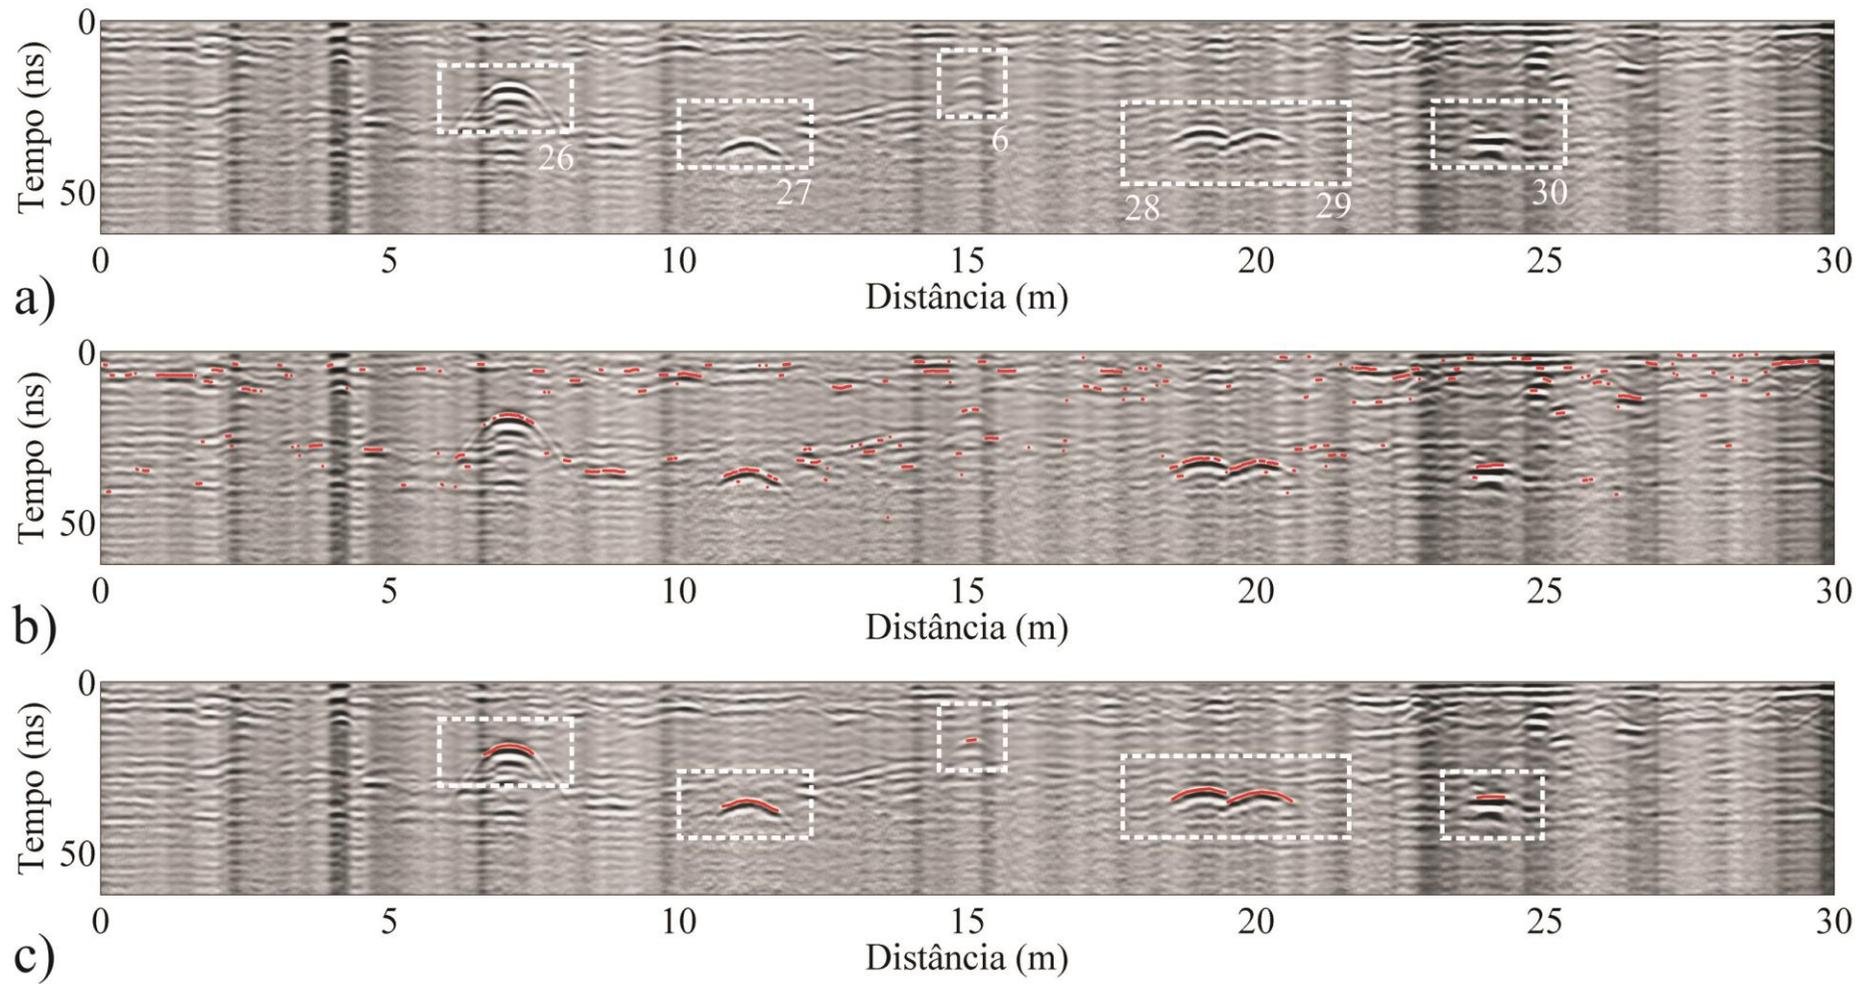


Figura 7.23 – Linha 4, 400 MHz, período de chuva. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

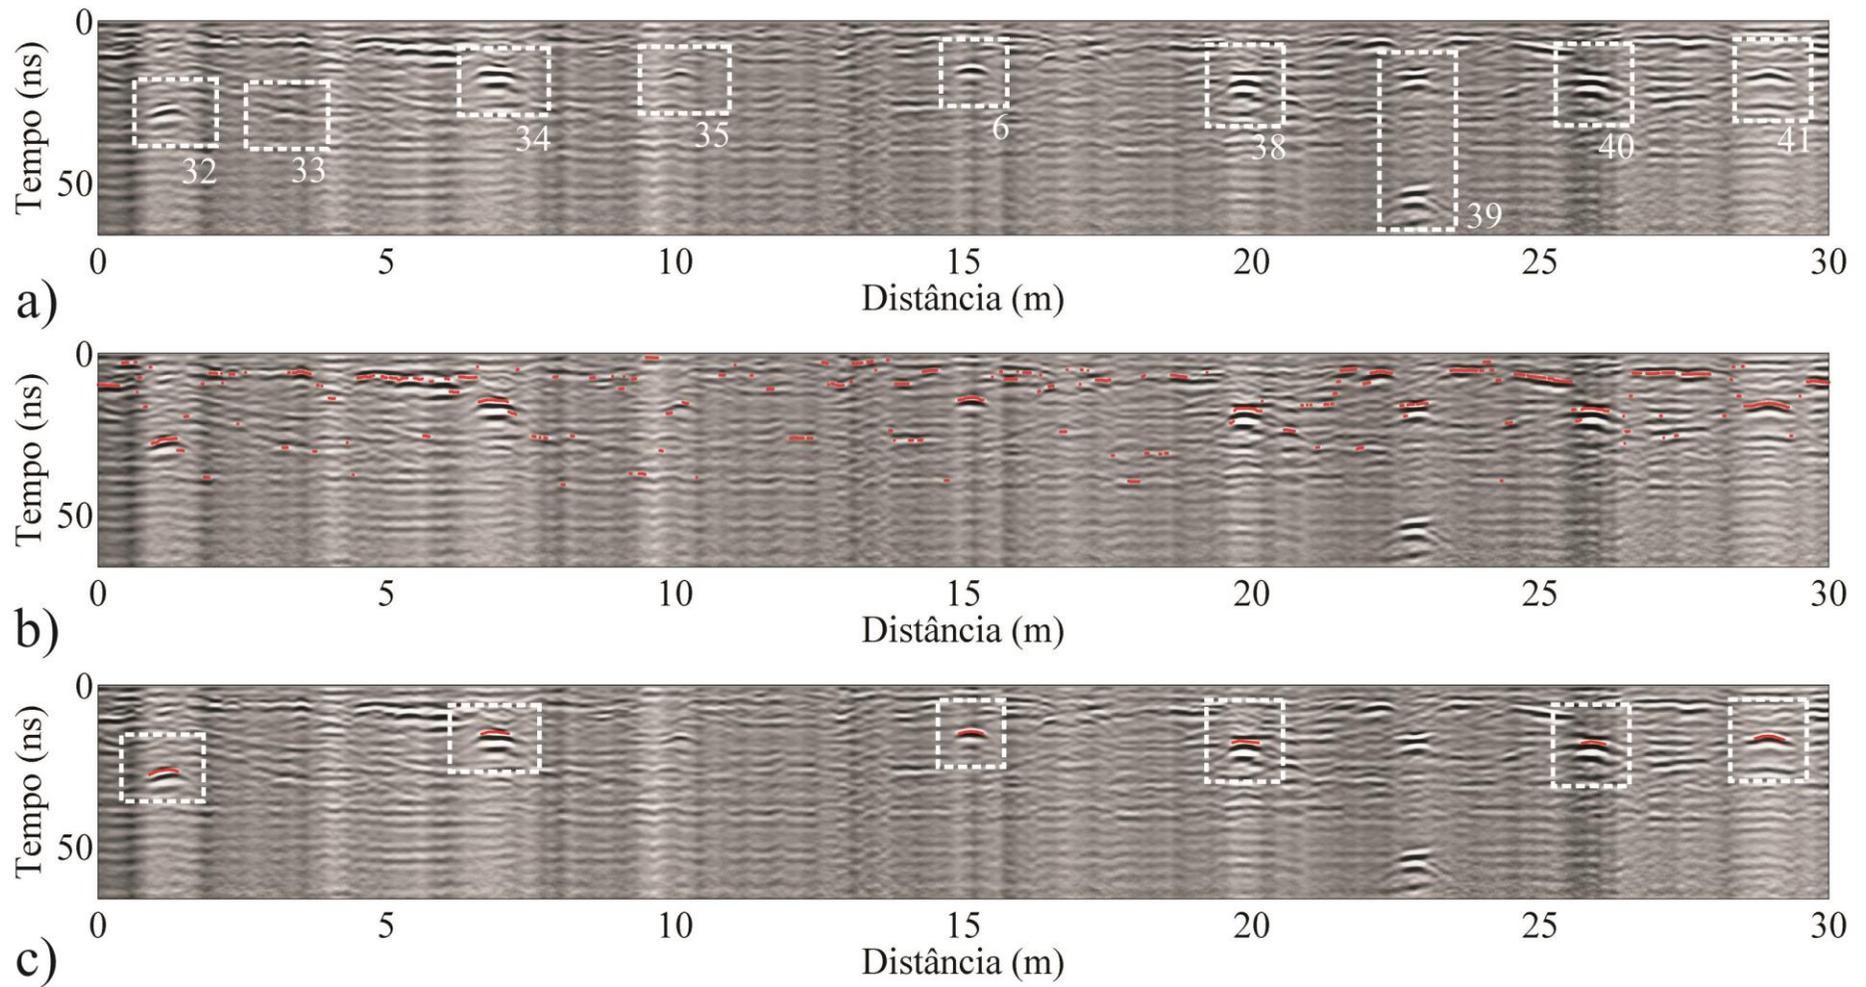


Figura 7.24 – Linha 5, 400 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

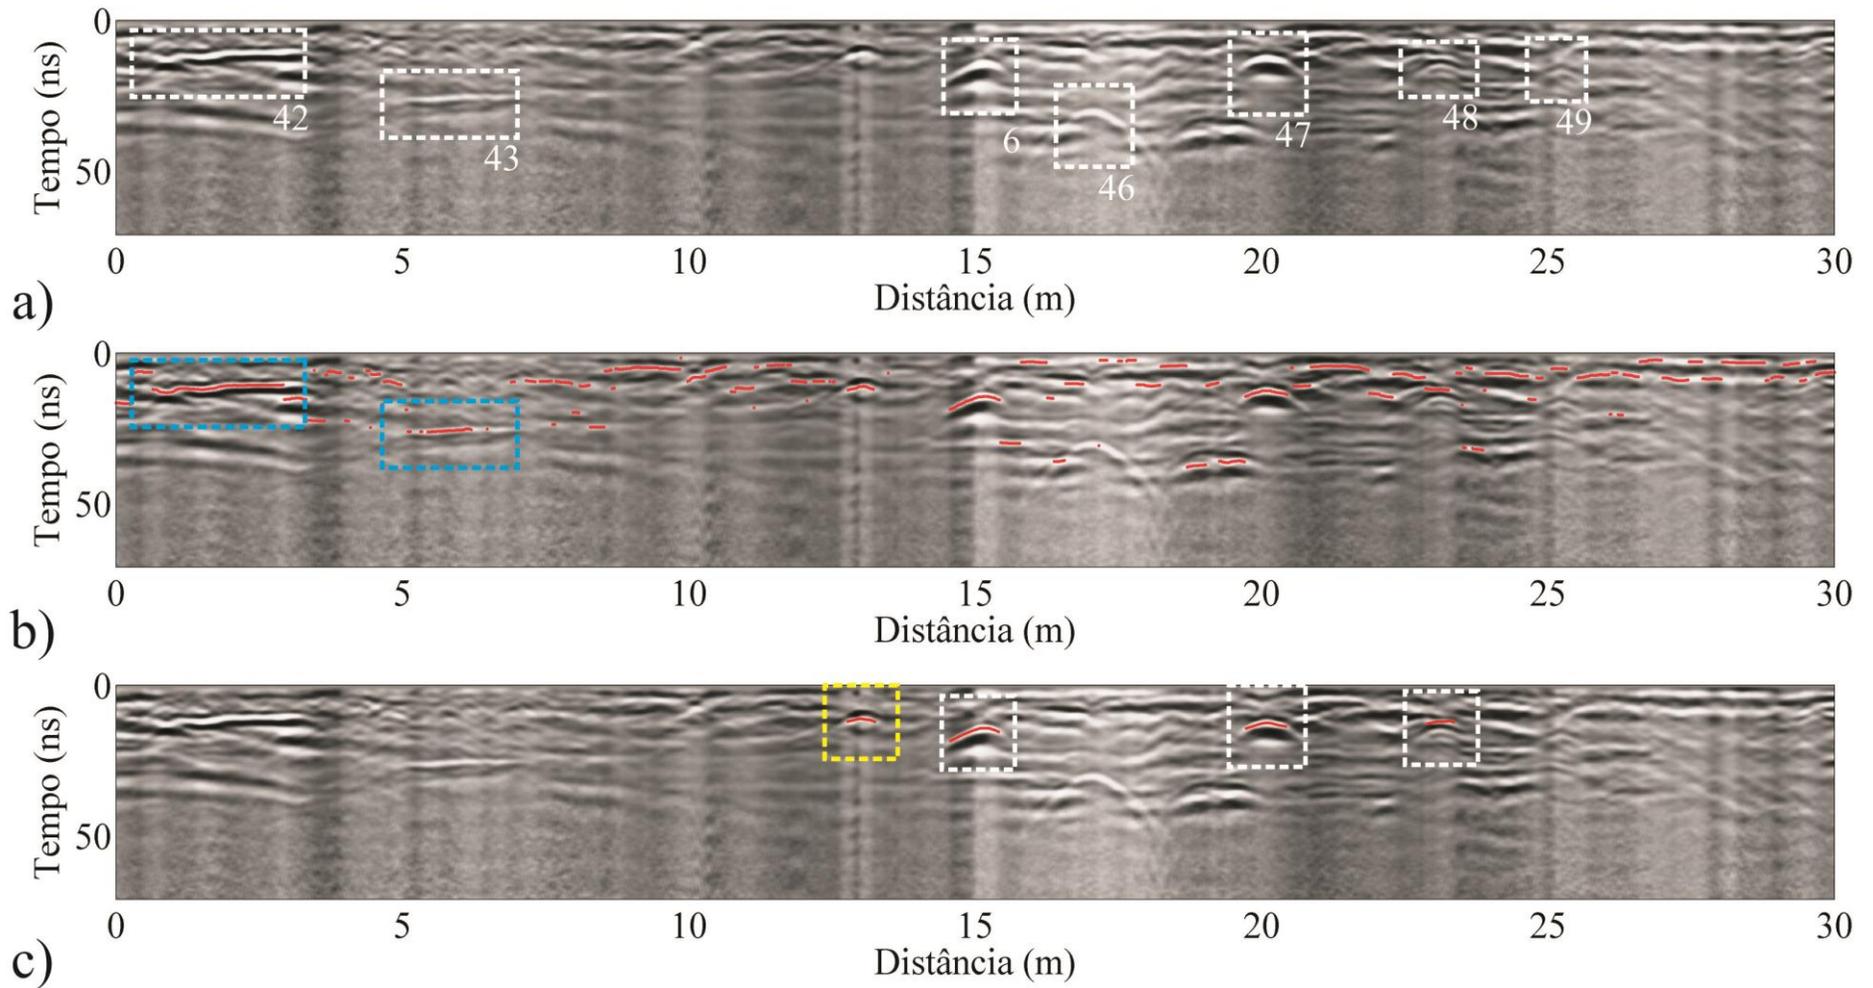


Figura 7.25 – Linha 6, 200 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

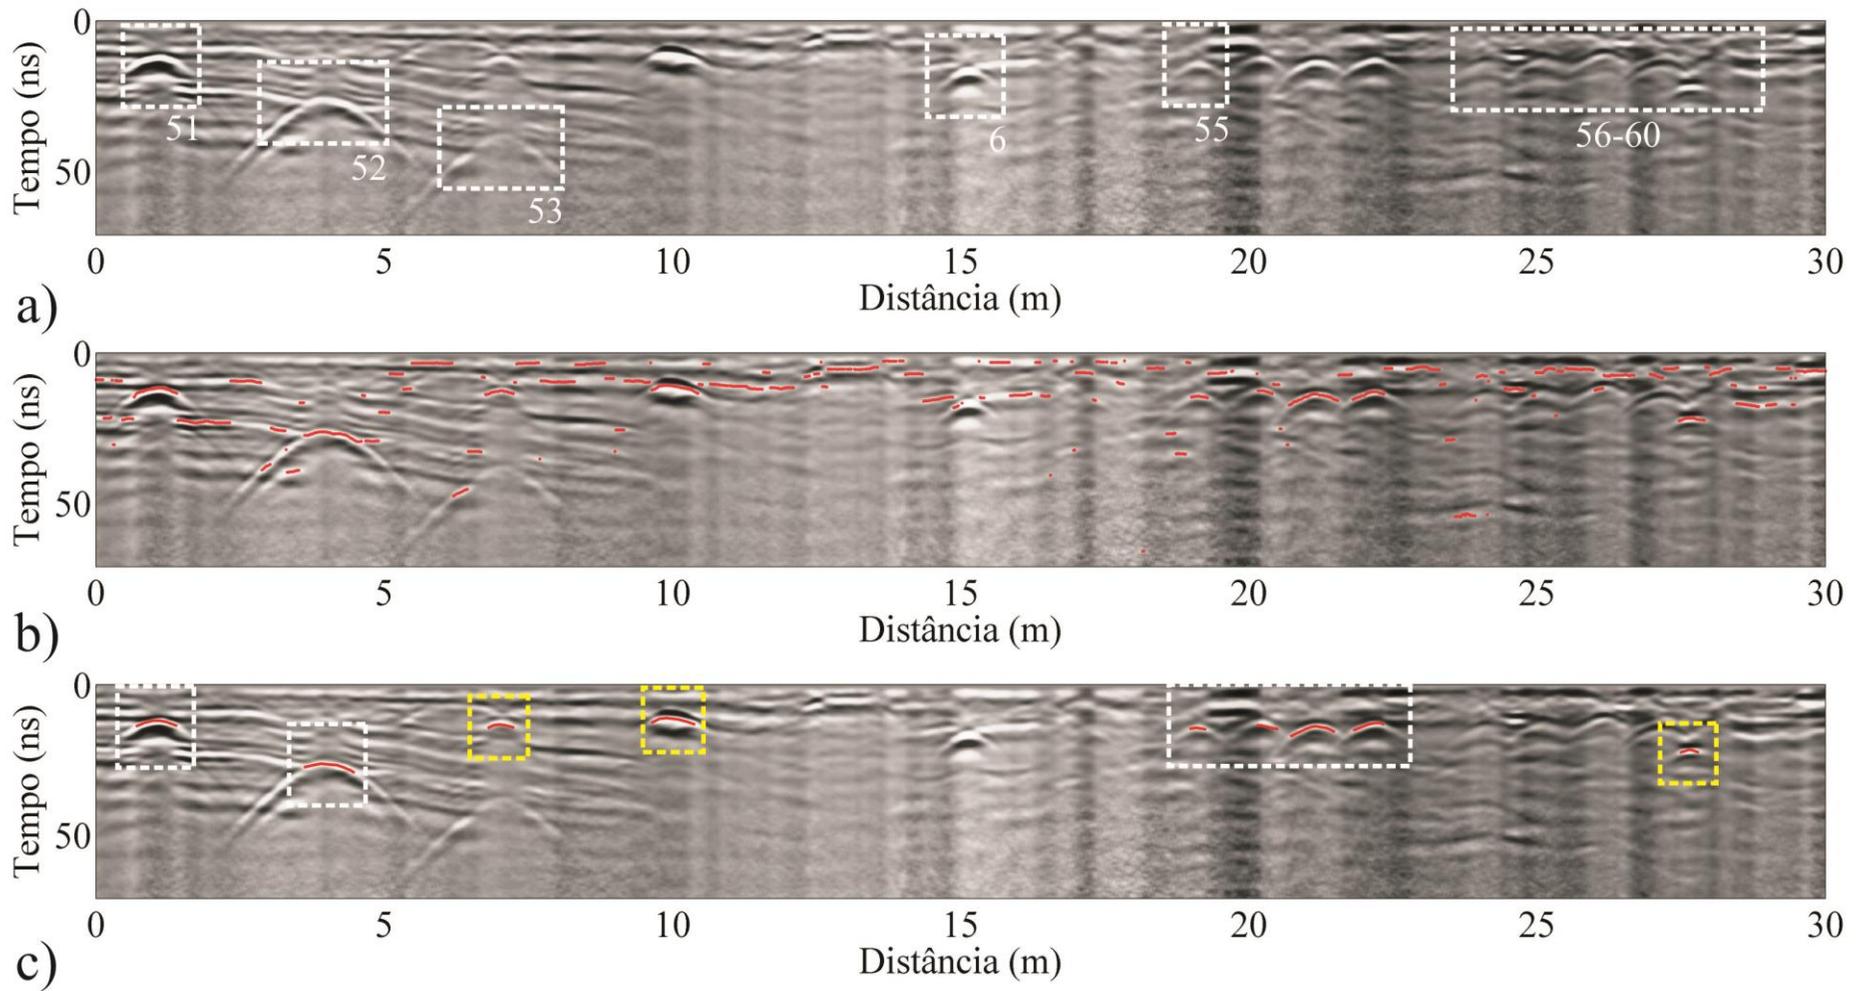


Figura 7.26 – Linha 7, 200 MHz, período seco. a) Perfil GPR original. b) Perfil GPR com os traços selecionados pela RNA. c) Perfil GPR com ajuste hiperbólico.

Tabela 7.3 – Tempo de identificação de hipérboles dos exemplos mostrados.³

Linha	Tempo (s)
2	161,13
3	186,36
4/200 MHz/seco	182,91
4/200 MHz/chuvoso	103,84
4/270	179,59
4/400 MHz/seco	180,53
4/400 MHz/chuvoso	200,97
5	183,51
6	163,36
7	189,98

O tempo de identificação das hipérboles, englobando as duas etapas, se mostrou bastante elevado. Esse tempo é proporcional ao número de traços que o perfil possui, pois o algoritmo precisa verificar todos os traços, um a um. Apesar desse fato, o programa alcançou uma “taxa de identificação” de 88,66%, identificando corretamente 782 traços com alvos em um total de 882. Também foram identificados possíveis alvos (blocos de rocha, pedaços de madeira, etc) que possuem a difração hiperbólica e estão marcadas em amarelo nas figuras anteriores. A matriz de confusão para a identificação dos alvos pode ser vista na Tabela 7.4.

Na Linha 6 (Figura 7.25), nas posições de 2 e 6 m estão enterrados dois tubos horizontalmente e portanto não possuem a forma de uma hipérbole. Porém, o algoritmo de RNA identificou os traços dessa posição como sendo de um alvo (em azul), o que está perfeitamente correto.

Tabela 7.4 – Matriz de confusão para a identificação dos alvos.

	Alvo	Não alvo	Total
Alvo	403	38	441
Não Alvo	62	379	441
Total	465	417	882

³ Computador utilizado: Intel Core i5 (terceira geração), 2,67 GHz, 8 GB de RAM.

7.3 CLASSIFICAÇÃO DE HIPÉRBOLES

De forma análoga ao item anterior, foi desenvolvida a rede neural para a classificação das hipérboles identificadas anteriormente. Novamente utilizou-se os A-scans nas redes com uma camada oculta, variando entre 10, 30, 45, 70 e 100 neurônios. A camada de saída neste caso foi modificada para três neurônios, com saídas:

1. [1 0 0] → plástico
2. [0 1 0] → concreto
3. [0 0 1] → metal

A tolerância foi novamente estabelecida como a saída $y = 1$ sendo:

$$0,9 \leq y \leq 1,1$$

porém, agora, a saída $y = 0$ possui uma tolerância de:

$$-0,1 \leq y \leq 0,1$$

O novo conjunto de dados possui agora somente sinais com exemplos de alvos de concreto, plástico e metal. Do total de 1470 (294 alvos \times 5 traços), foram utilizados para treinamento e validação 1029 (70%) A-scans e 441 para o teste da rede.

Na Tabela 7.4 encontram-se os resultados obtidos para o erro de validação e o tempo de treinamento, sendo que o negrito indica o menor EQM_v encontrado. A partir dessa tabela observa-se que, utilizando A-scans, a rede com 45 neurônios na camada oculta e com 32.351 iterações atingiu o mínimo do EQM (0,16) no tempo de seis minutos e 38 segundos, sendo que esta configuração foi a mais estável dentre as mostradas. Esses valores estão relativamente altos em comparação ao treinamento entre alvos/“não alvos” e existe uma considerável diferença entre os erros de treinamento/validação e teste.

Desta maneira foram realizados mais testes variando o número de neurônios na camada oculta de acordo com a Tabela 7.5. A partir da tabela pode-se observar que a rede com 40 neurônios na camada oculta atingiu um menor erro de validação (0,12) em relação as outras. Assim, essa rede (Figura 7.27) foi utilizada para a classificação das hipérboles e os erros obtidos por ela e bem como a variação do gradiente podem ser vistos na Figura 7.28.

Para a classificação do tipo de material a rede se comportou de maneira mais instável com relação a rede de identificação. Isso se deve ao fato de que os traços devem ser mais facilmente separáveis entre traços de alvos ou “não alvos” do que os traços dos tipos de materiais. Ou seja, a diferença de amplitude entre um traço com alvo e outro sem alvo é muito maior do que a diferença entre um objeto plástico e de concreto, pois

nesse caso existe a ambiguidade inerente ao método envolvendo a profundidade do alvo.

Tabela 7.5 – Erro quadrático médio de validação (EQM_v) e tempo de treinamento dos testes realizados com a rede neural artificial desenvolvida utilizando A-scans.⁴

Neurônios na camada oculta	EQM _v	Tempo	Iterações
10	0,14	16'50''	98.500
30	0,22	06'09''	39.109
45	0,16	06'38''	32.351
70	0,15	07'23''	30.204
100	0,24	05'38''	19.481

Tabela 7.6 – Erro quadrático médio de validação (EQM_v) e tempo de treinamento dos testes realizados com a rede neural artificial desenvolvida utilizando A-scans.⁴

Neurônios na camada oculta	EQM _v	Tempo	Iterações
5	0,18	08'03''	52.866
15	0,17	03'21''	23.291
20	0,18	03'56''	27.145
25	0,19	01'52''	12.031
35	0,20	03'18''	20.441
40	0,11	02'28''	15.873
50	0,15	03'46''	17.954
55	0,19	04'39''	21.249

⁴ Computador utilizado: Intel Core i5 (terceira geração), 2,70 GHz, 8 GB de RAM.

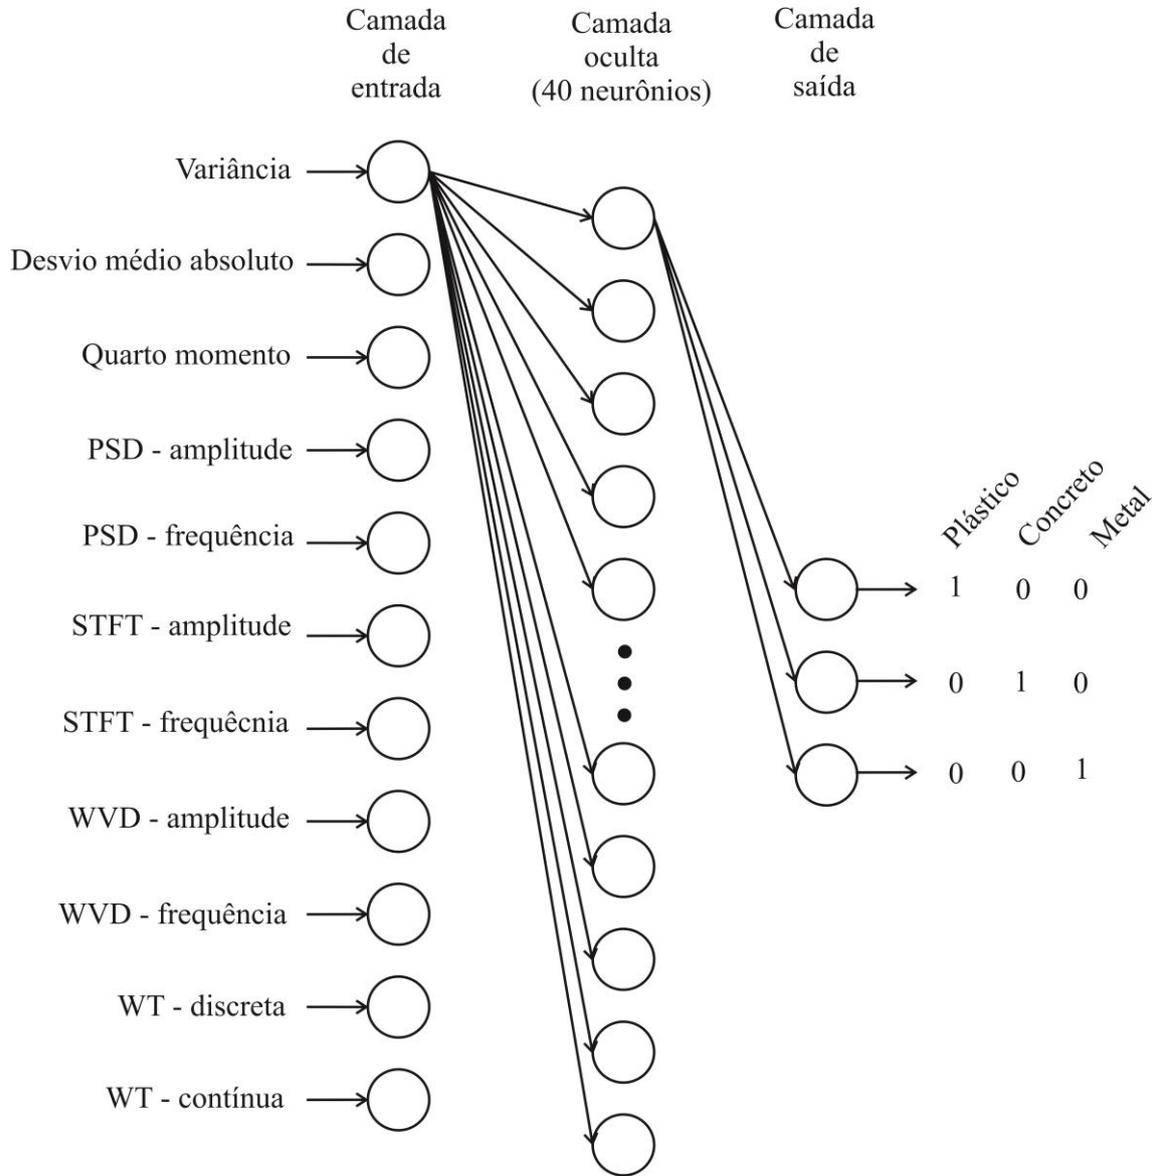


Figura 7.27 – Esquema da rede neural final utilizada para classificação de hipérboles.

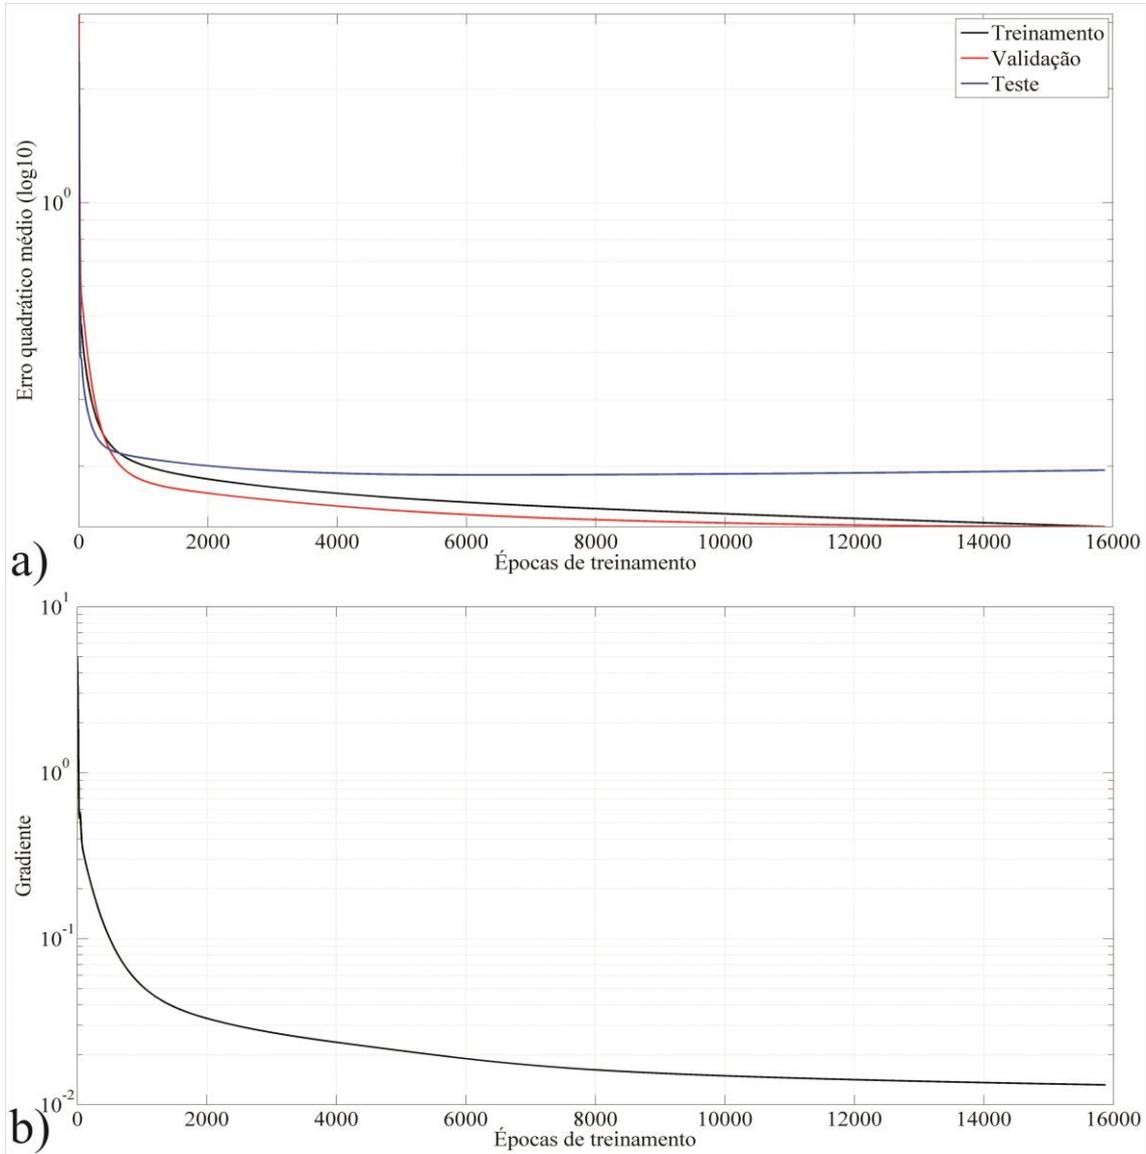


Figura 7.28 – Rede neural 11-40-3 utilizando A-scans. a) Variação dos erros de treinamento, validação e teste. b) Variação do gradiente.

Assim, a rede escolhida para a classificação possui uma arquitetura 11-40-3. Essa nova rede recebe agora os traços identificados pela rede anterior para efetuar a classificação, fazendo com que o tempo de processamento seja reduzido consideravelmente, pois são apenas alguns traços que servem como entrada na segunda parte do programa.

Com as duas etapas do NC_GPR concluídas, utilizou-se o conjunto de teste para se obter a taxa de acerto final. Os exemplos a seguir para a classificação são os mesmos mostrados para a identificação das hipérbolas e não foram utilizados para nenhum dos dois treinamentos (Figuras de 7.29 a 7.38). O resultado final do programa é uma figura com o perfil GPR e linhas verticais na posição dos alvos encontrados. Cada cor representa um tipo de material: vermelho para plástico, magenta para concreto e azul para metal.

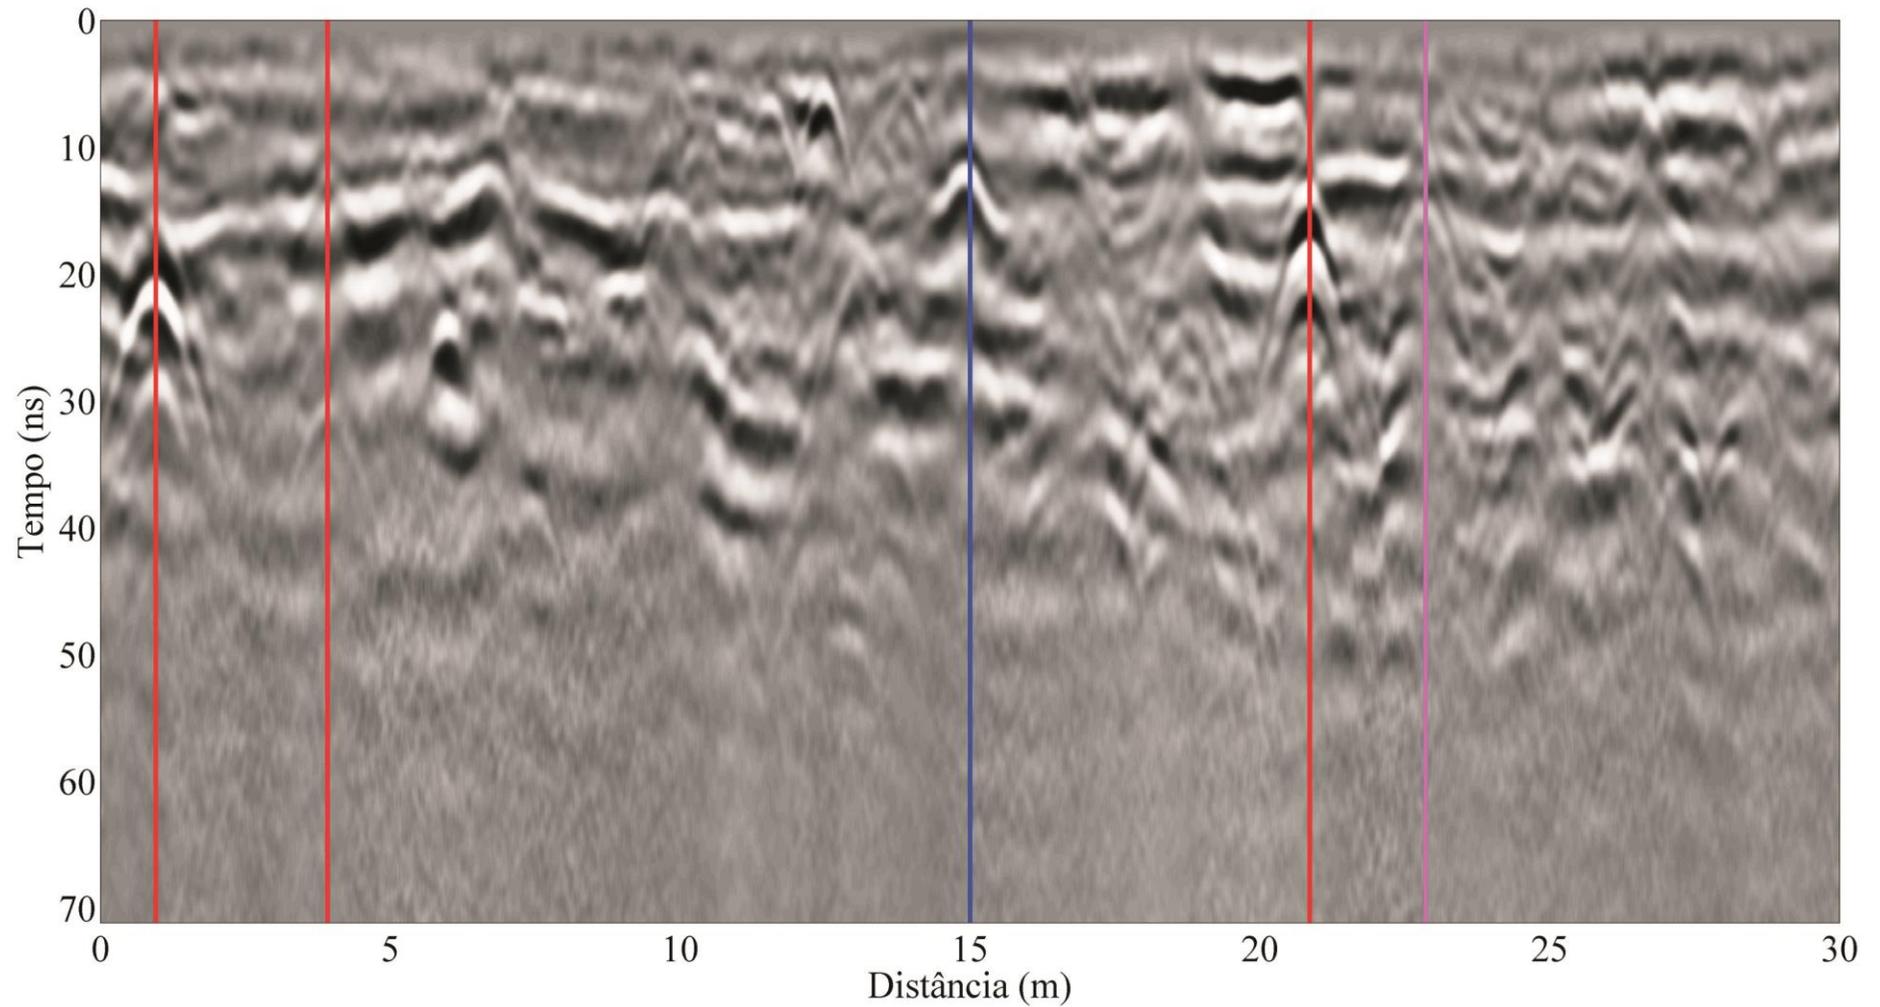


Figura 7.29 – Classificação obtida pelo NC_GPR para a Linha 2 (tubos de PVC), utilizando antena de 200 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).

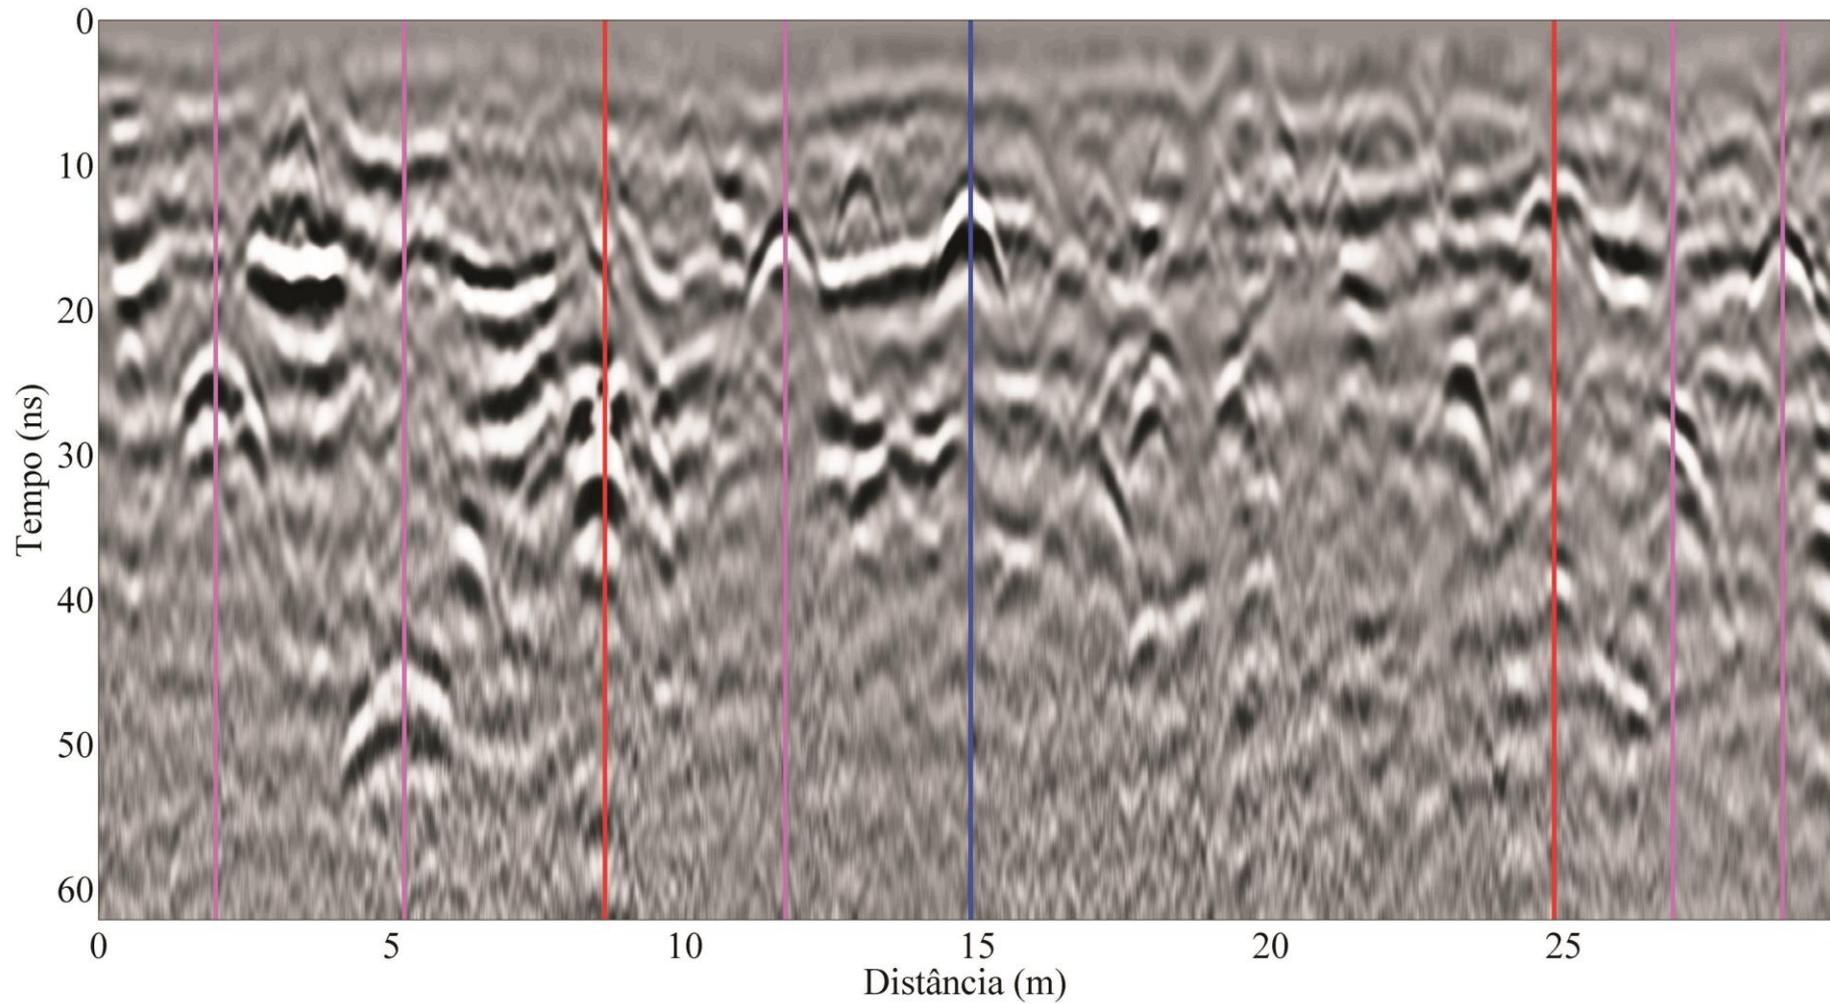


Figura 7.30– Classificação obtida pelo NC_GPR para a Linha 3 (manilhas de concreto), utilizando antena de 270 MHz (vermelho: plástico, magenta: concreto, azul: metal).

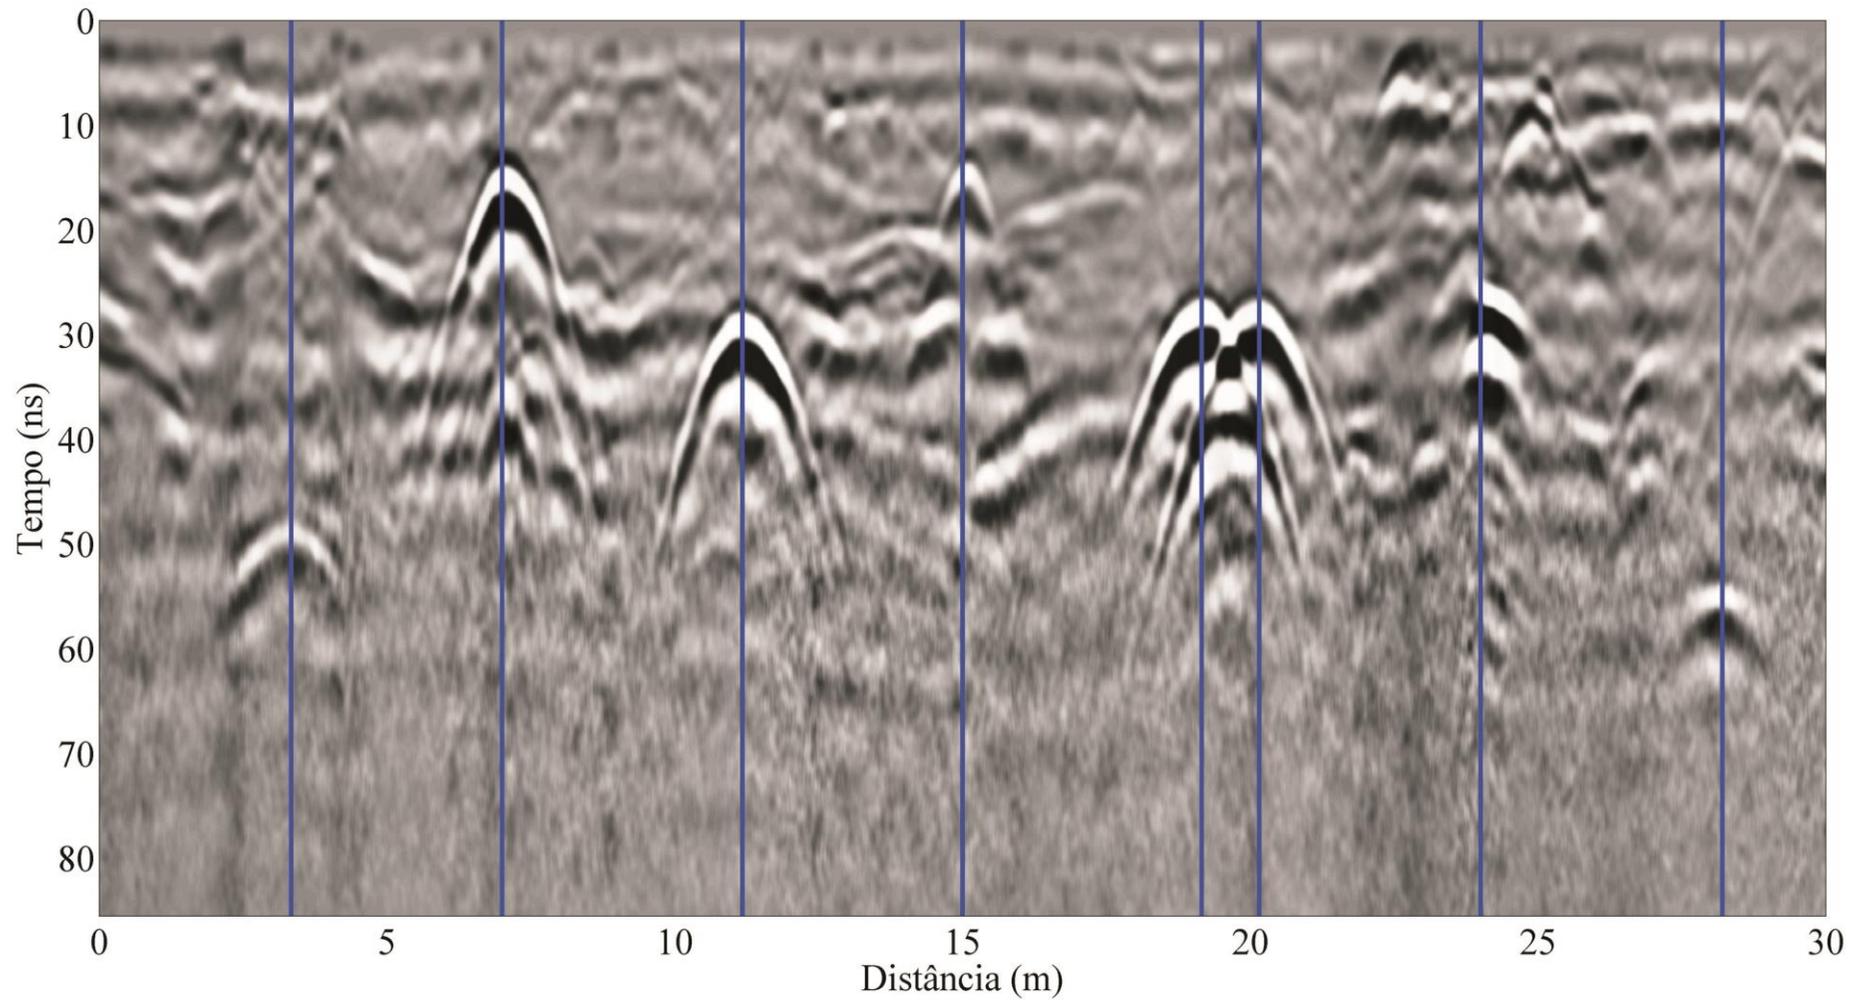


Figura 7.31 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 200 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).

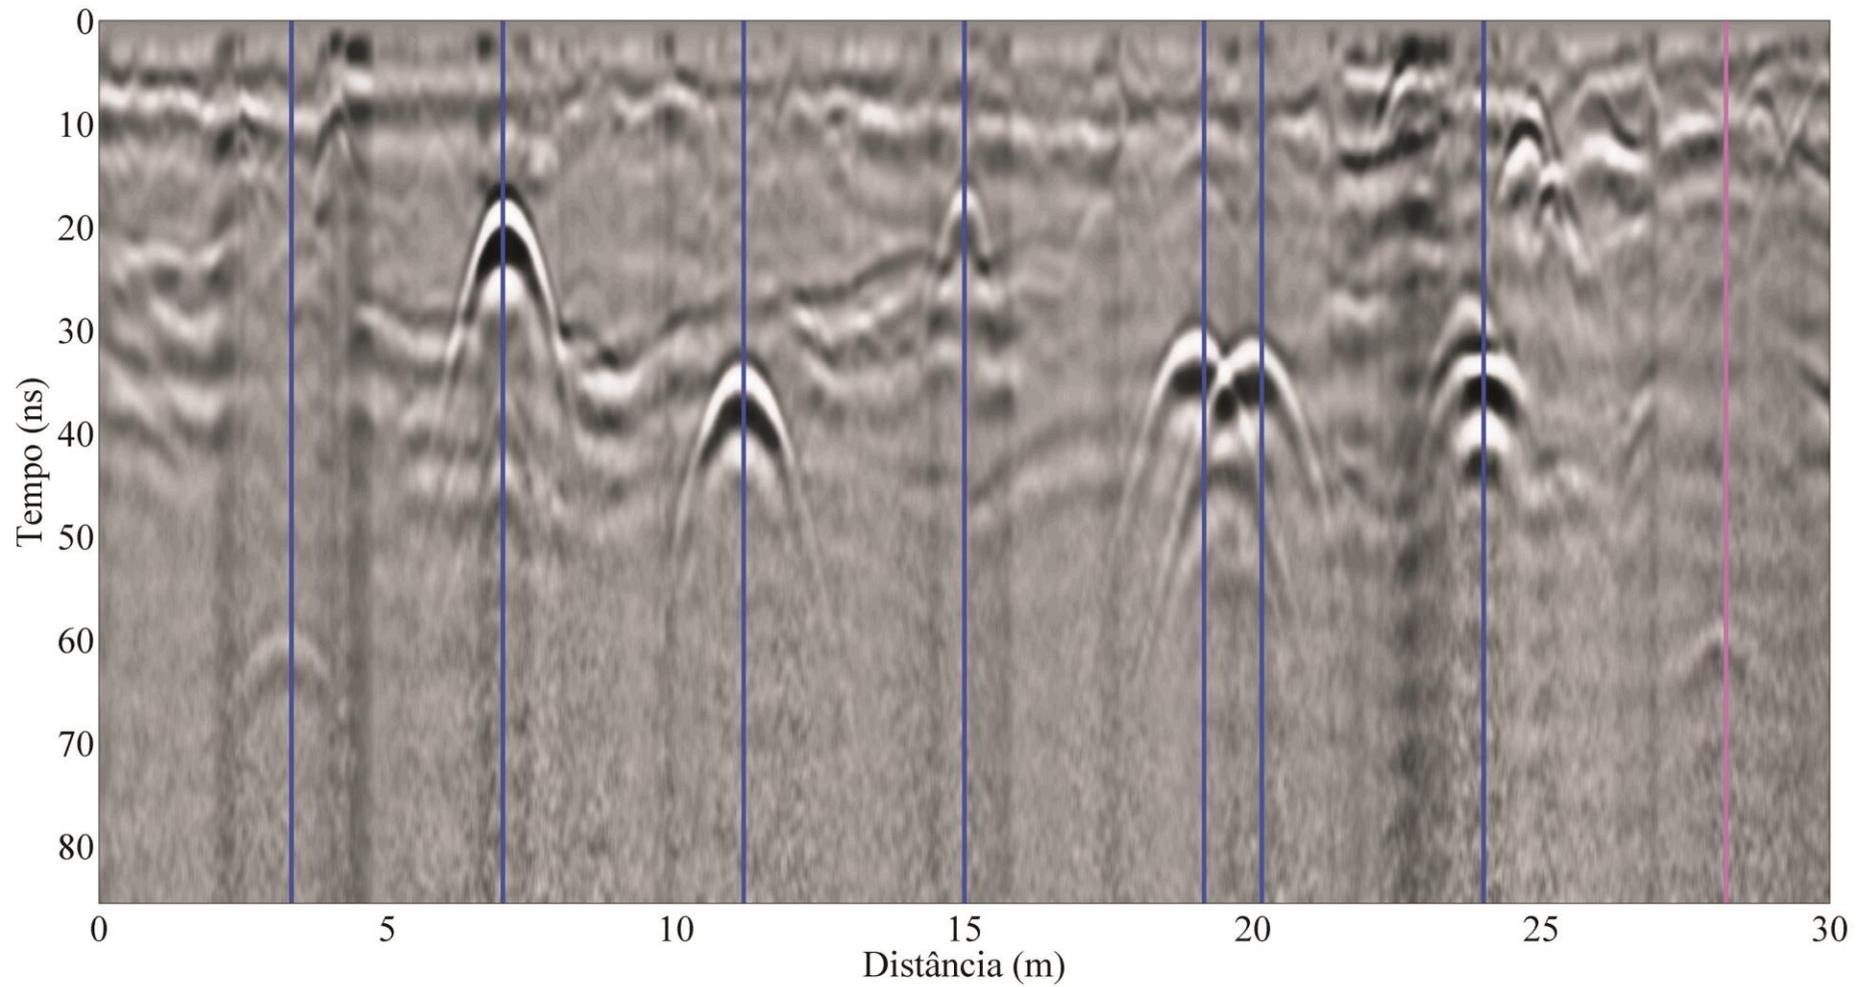


Figura 7.32 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 200 MHz, no período de chuva (vermelho: plástico, magenta: concreto, azul: metal).

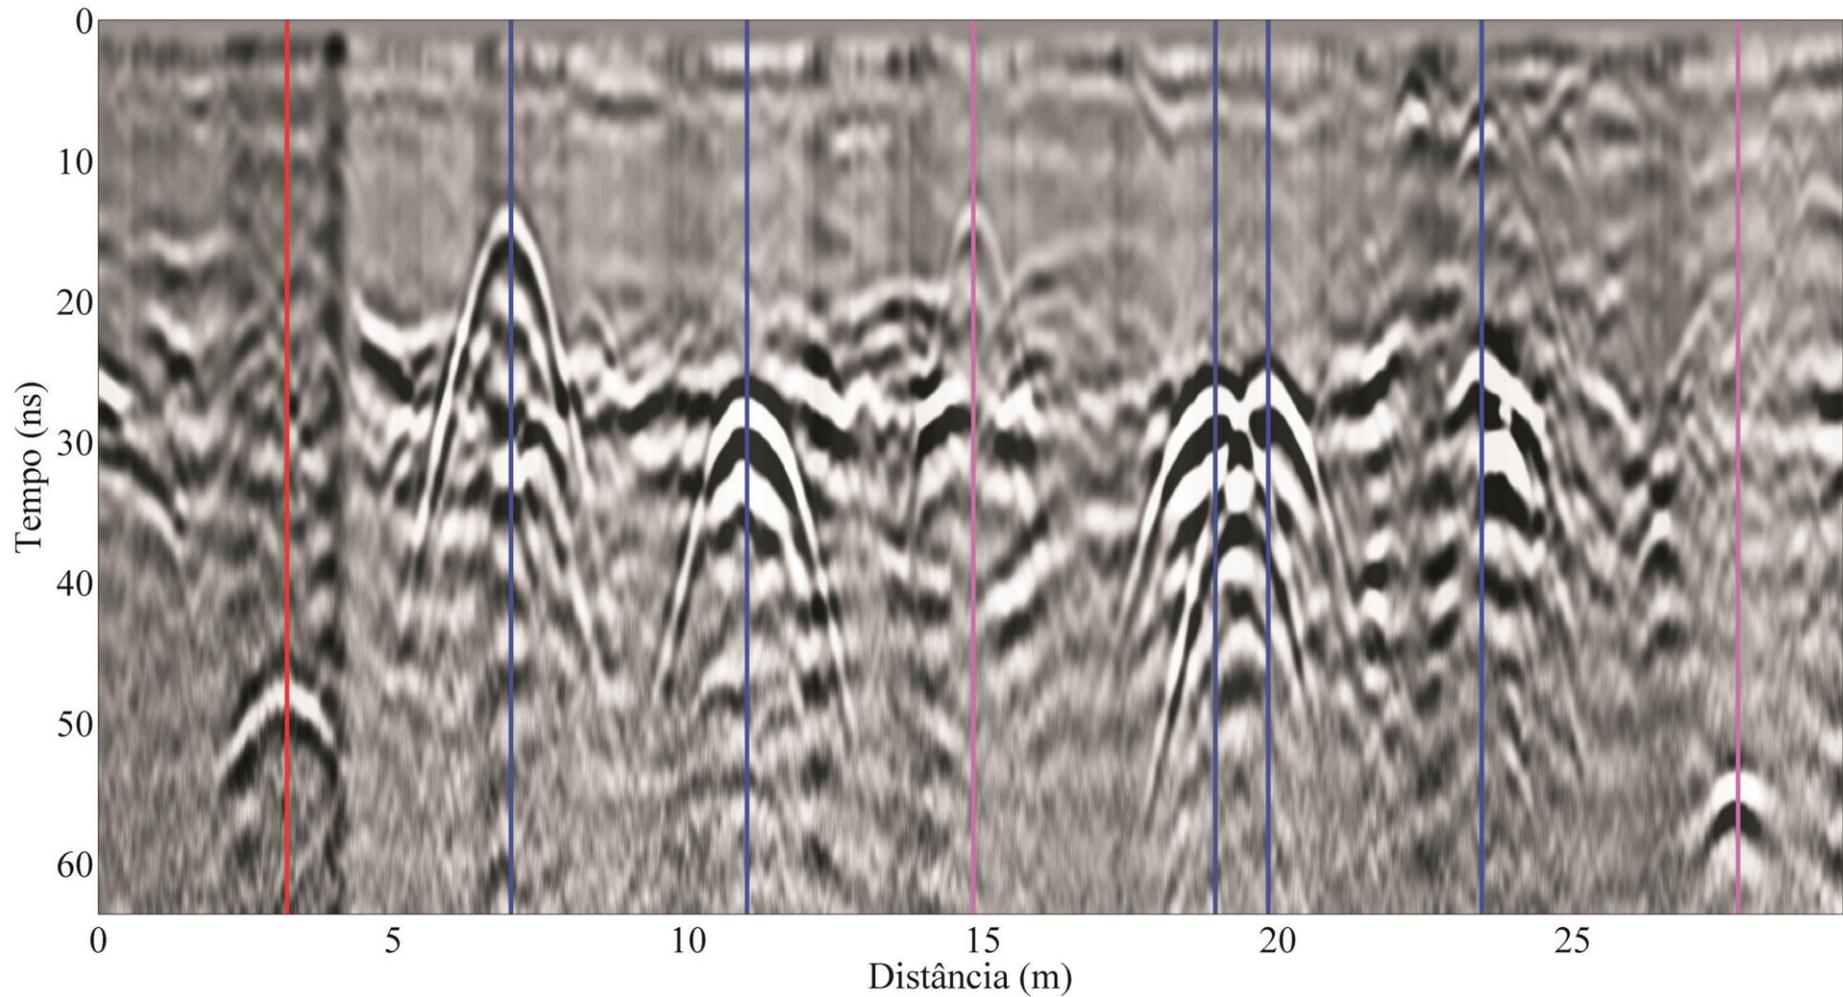


Figura 7.33 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 270 MHz (vermelho: plástico, magenta: concreto, azul: metal).

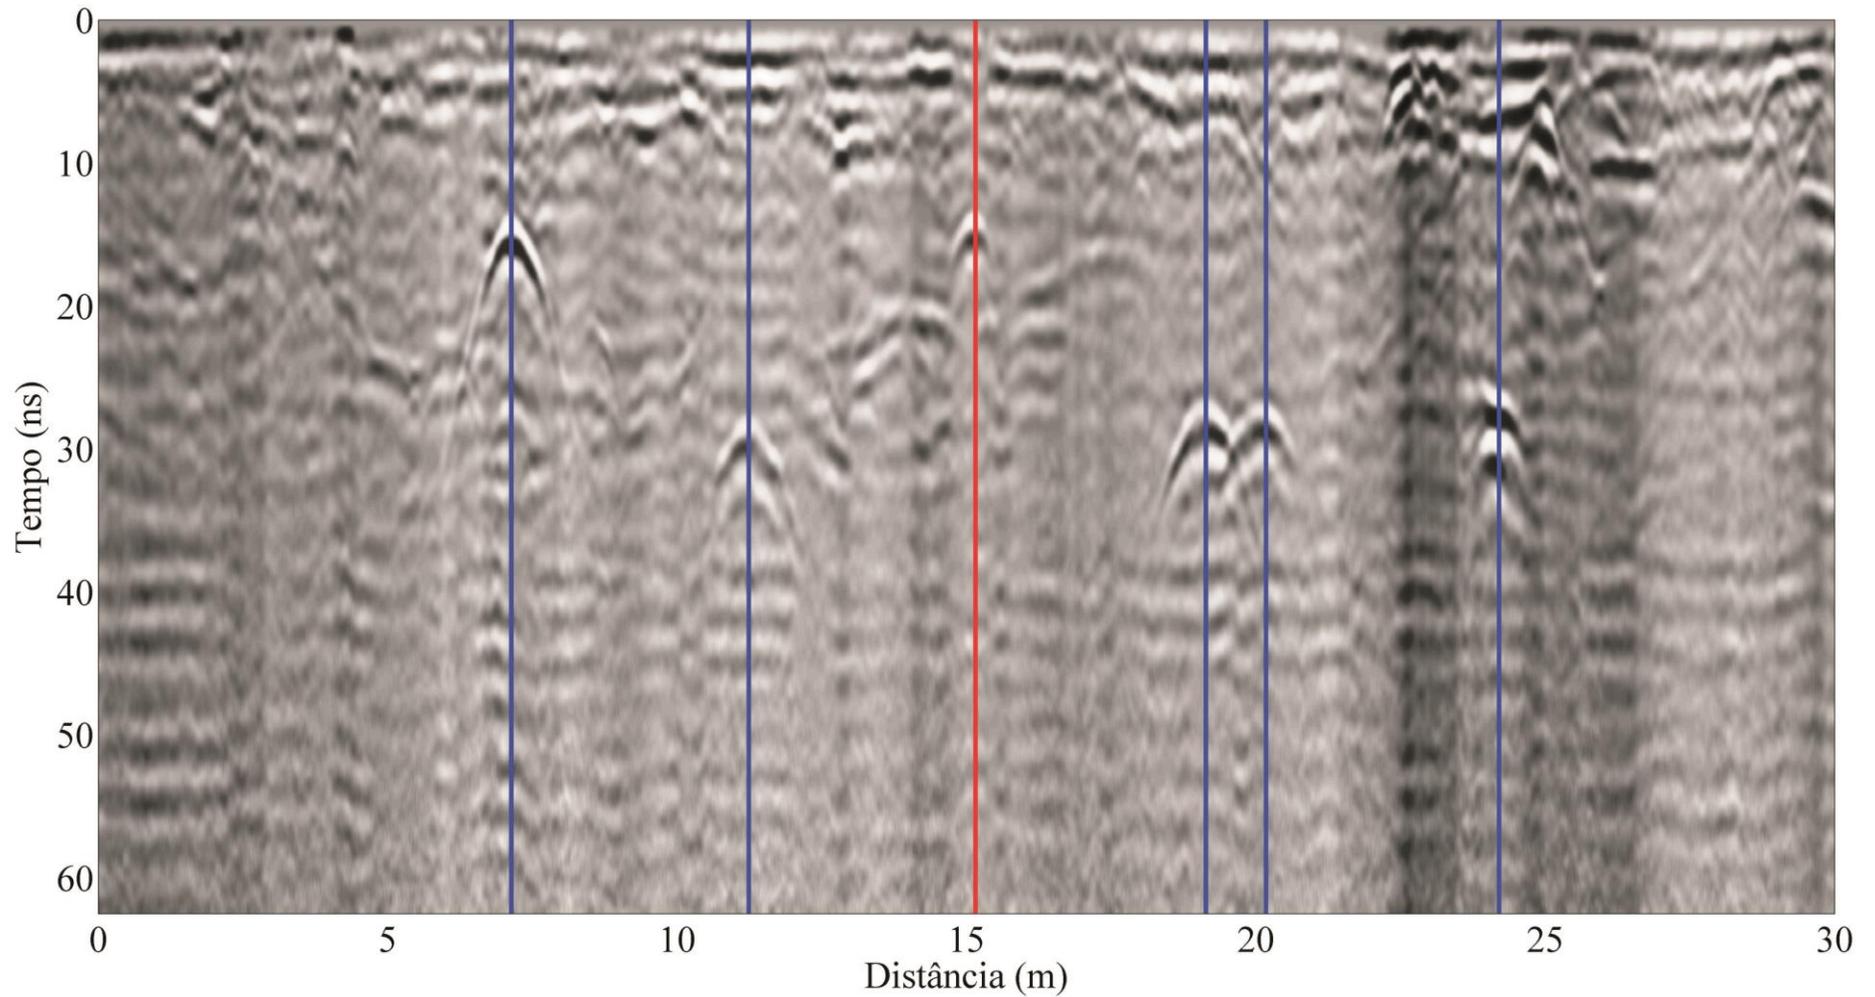


Figura 7.34 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 400 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).

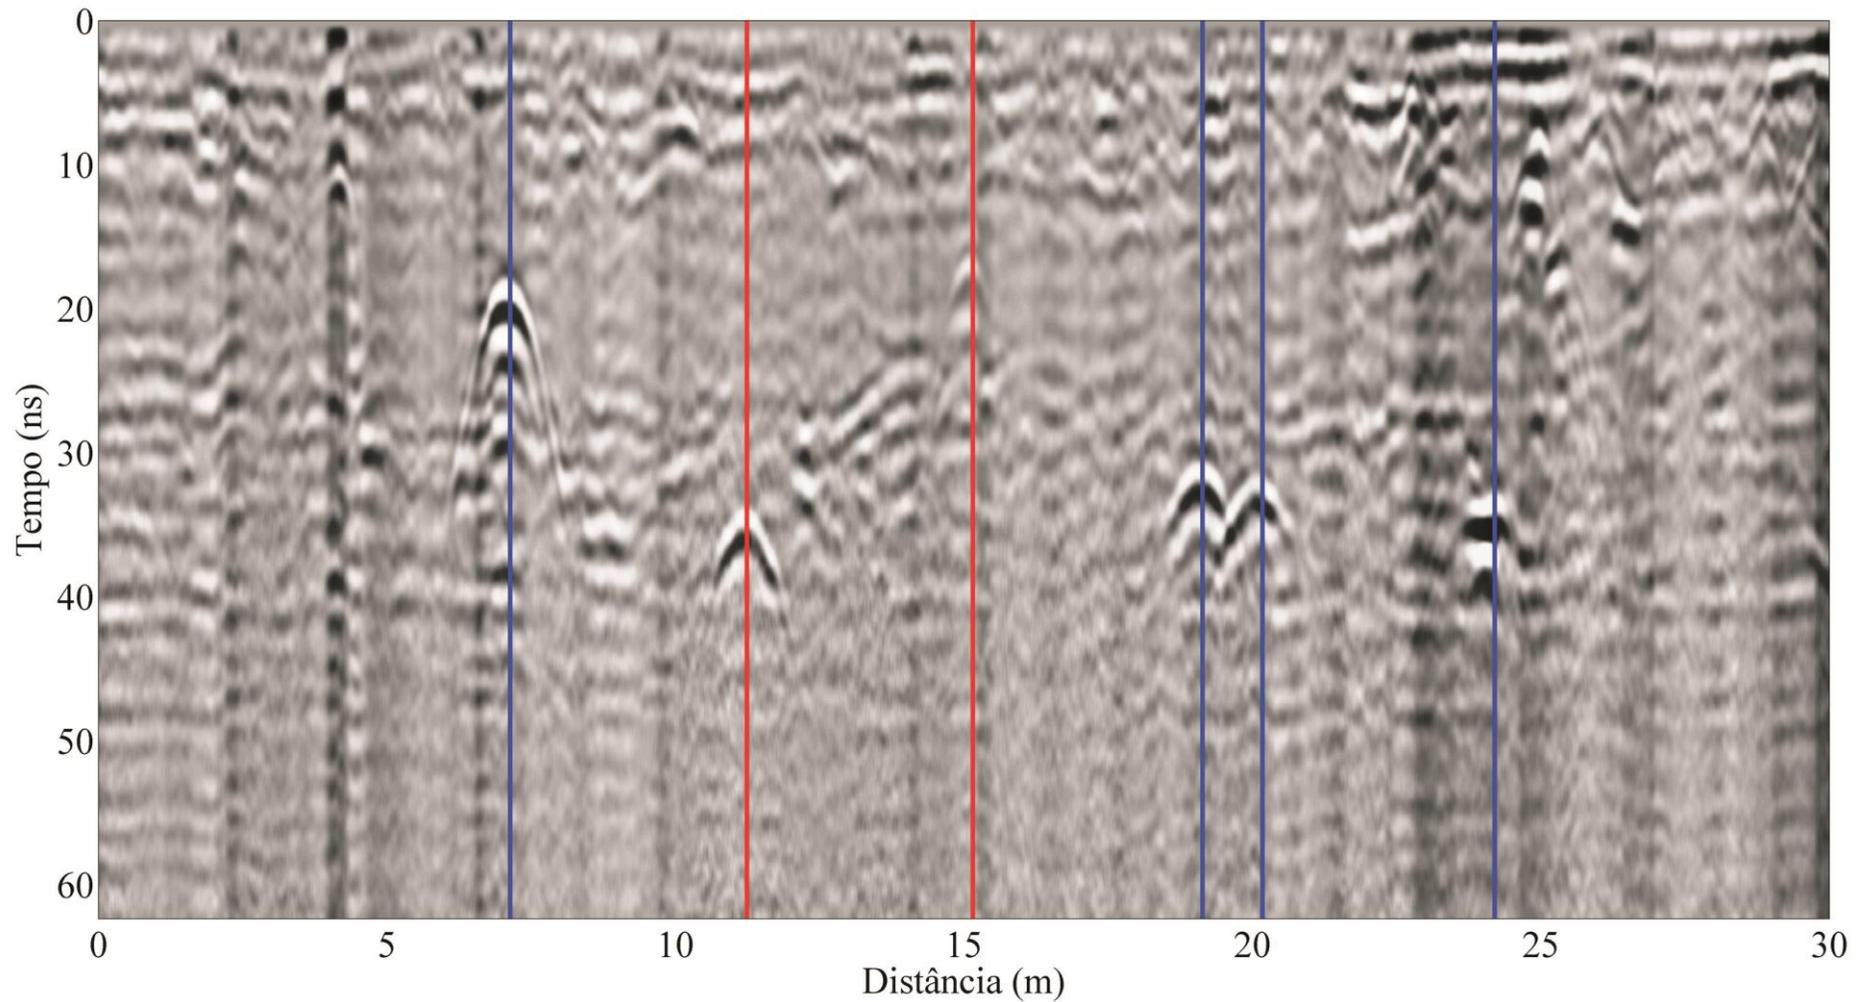


Figura 7.35 – Classificação obtida pelo NC_GPR para a Linha 4 (tambores metálicos), utilizando antena de 400 MHz, no período de chuva (vermelho: plástico, magenta: concreto, azul: metal).

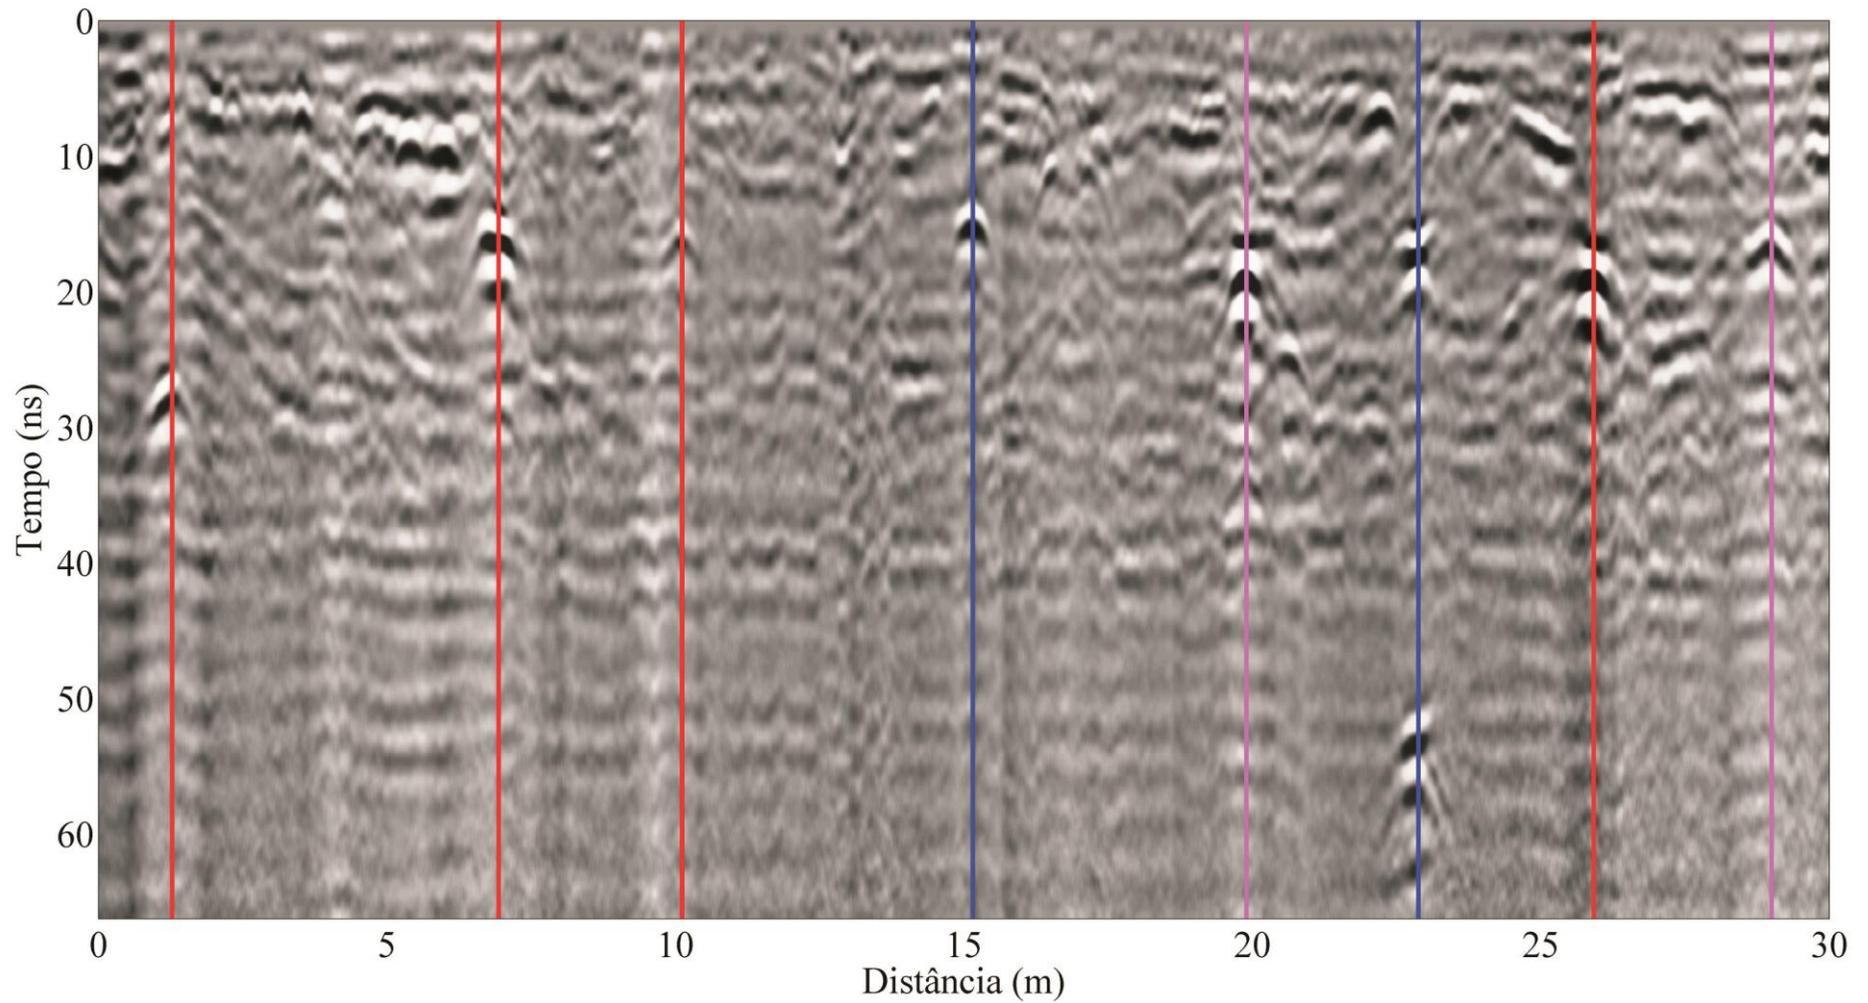


Figura 7.36– Classificação obtida pelo NC_GPR para a Linha 5 (tambores plásticos), utilizando antena de 400 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).

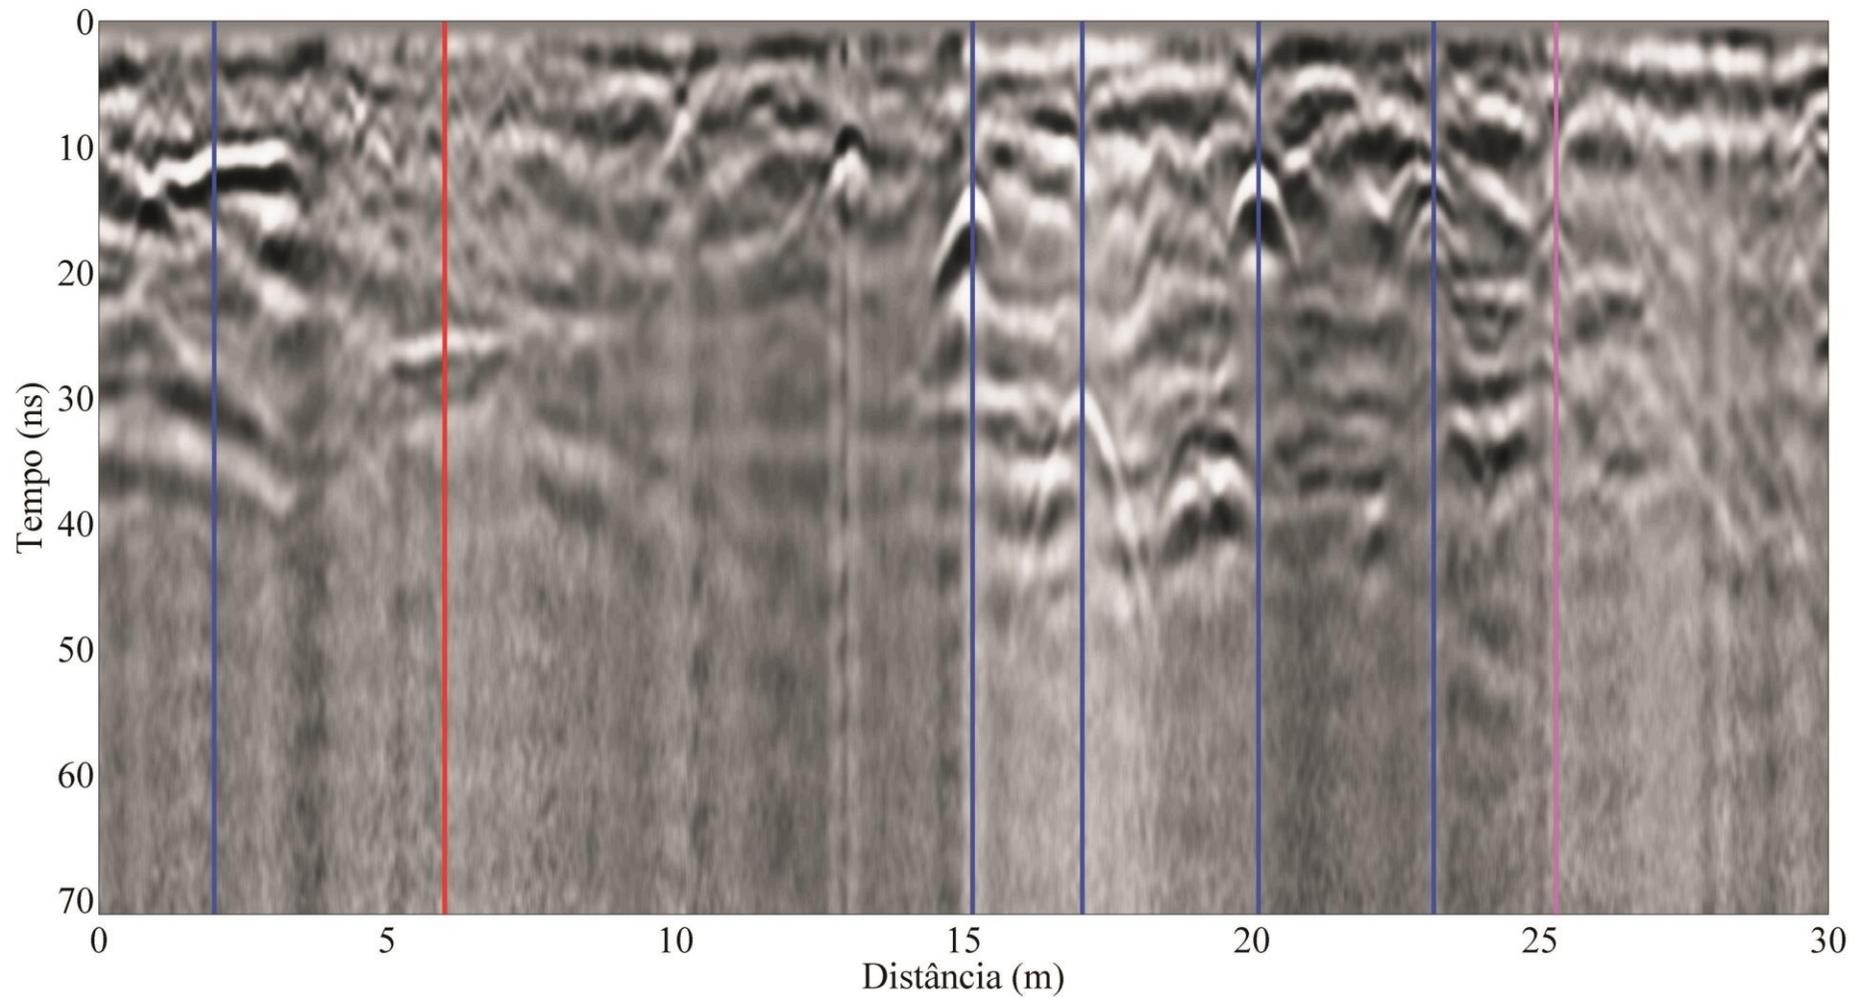


Figura 7.37 – Classificação obtida pelo NC_GPR para a Linha 6 (tubos metálicos), utilizando antena de 200 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).

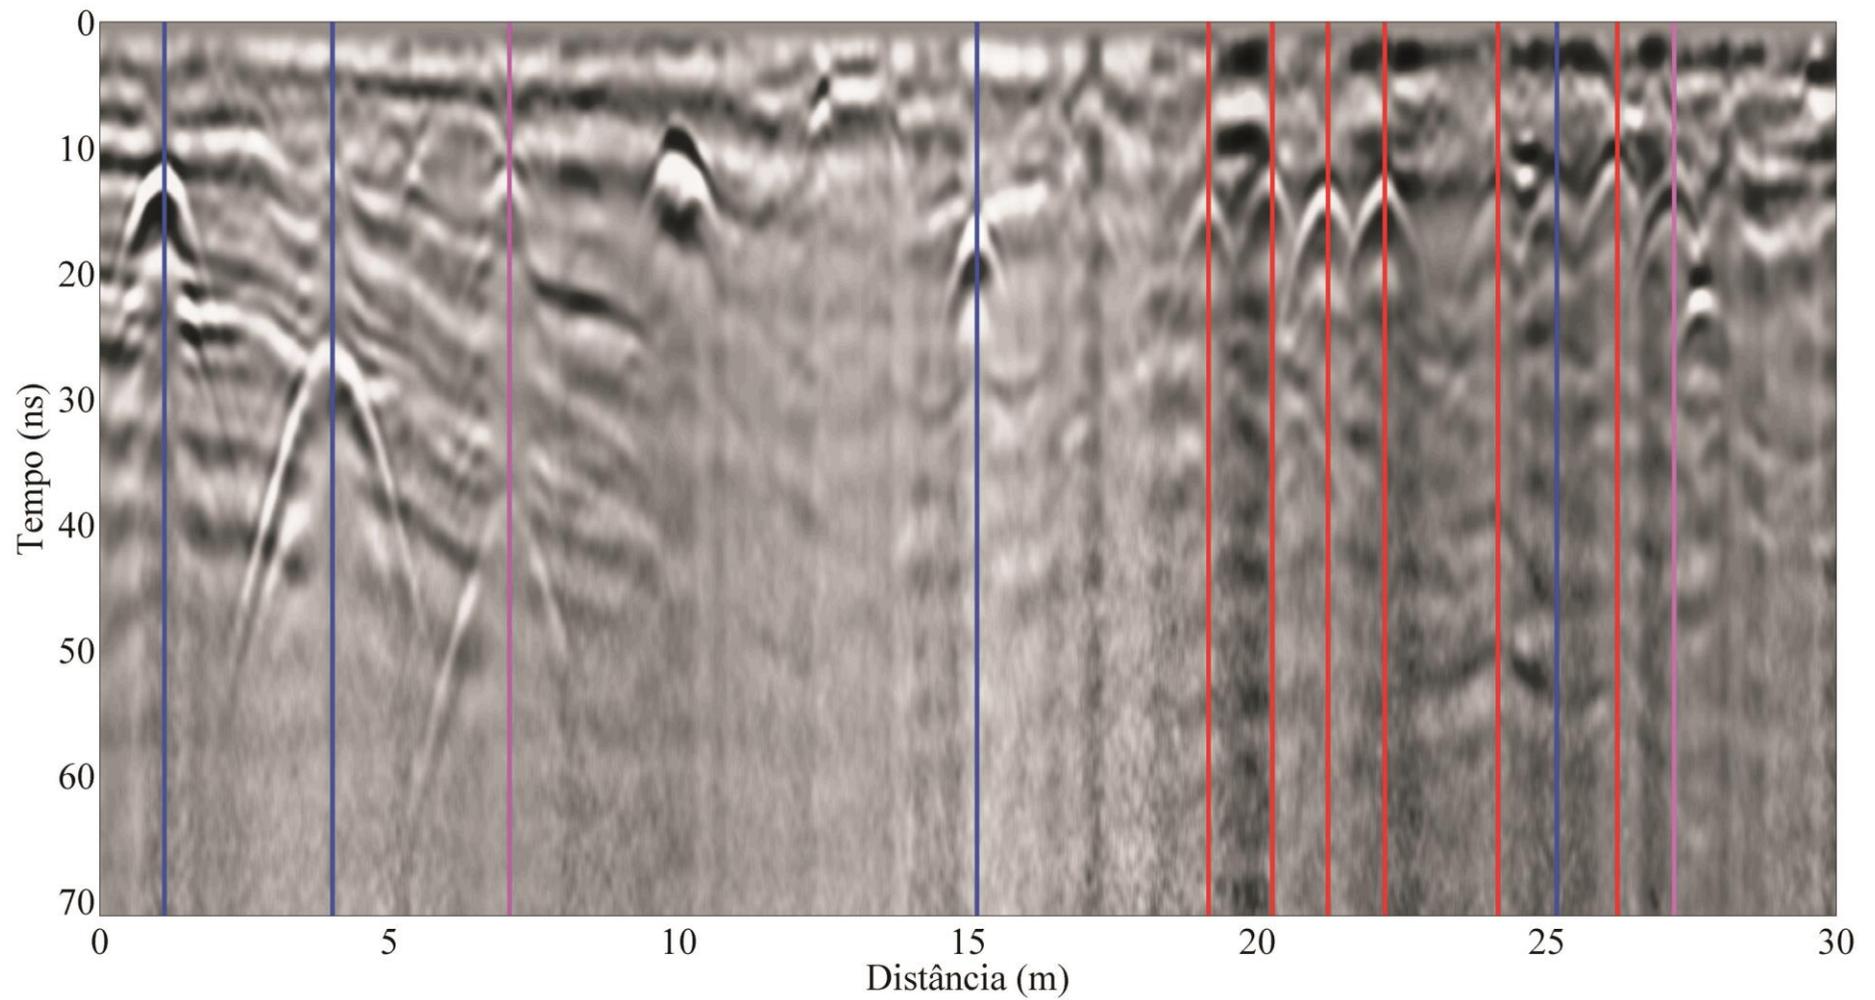


Figura 7.38 – Classificação obtida pelo NC_GPR para a Linha 7 (tubos metálicos e cabos elétricos), utilizando antena de 200 MHz, no período seco (vermelho: plástico, magenta: concreto, azul: metal).

A partir dos resultados das classificações podemos chegar a uma taxa de acerto efetiva de 88,43% (390 acertos em 441 traços). A maioria dos alvos metálicos foi classificada de maneira correta. A maioria dos erros corresponde, principalmente, aos materiais plásticos e de concreto, pois ambos são resistores e não possuem um grande contraste de amplitude, como pode ser visto na matriz de confusão mostrada abaixo (Tabela 7.7).

Tabela 7.7 – Matriz de confusão para a classificação dos alvos.

	Metal	Concreto	Plástico	Total
Metal	216	5	4	225
Concreto	1	69	10	80
Plástico	3	28	105	136
Total	220	102	119	441

7.4 APLICAÇÕES DO NC_GPR

Para verificar as aplicabilidades do NC_GPR fora de um ambiente controlado, foram analisadas as classificações dos perfis GPR obtidos fora da área do SCGR. Dentre as áreas estudadas (Capítulo 5), foram selecionadas algumas para servirem de exemplo. As figuras geradas podem ser vistas a seguir.

As hipérboles das Figuras 7.40 (200 MHz) e 7.42 (400 MHz) correspondem a duas tubulações metálicas da Adutora de Cotia (Figuras 7.39 e 7.41) e o NC_GPR indicou como sendo metal o material enterrado e, portanto está correta a classificação. Já a Figura 7.44 corresponde ao perfil GPR com antena de 200 MHz na área de uma estação da Sabesp (Figura 7.43), com a presença de dois tubos de PVC e que também foram classificados corretamente. O perfil obtido no IAG/USP (400 MHz) apresenta tubos de PVC enterrados ao longo do caminho de ligação entre o estacionamento e a biblioteca (Figura 7.45) e dentre os seis tubos, cinco foram classificados corretamente, sendo que a última hipérbole, na posição de 11, 7 m, não corresponde a tubulação, mas foi apontado como um alvo de concreto (Figura 7.46). Na Escola Politécnica foram obtidos dois perfis sobre manilhas de concreto (Figuras 7.47 e 7.49) com antenas de 200 MHz (Figura 7.48) e 400 MHz (Figura 7.50) e ambas também foram classificadas corretamente.



Figura 7.39 – Local da aquisição com antena de 200 MHz na rotatória da Biologia no Campus USP da Capital.

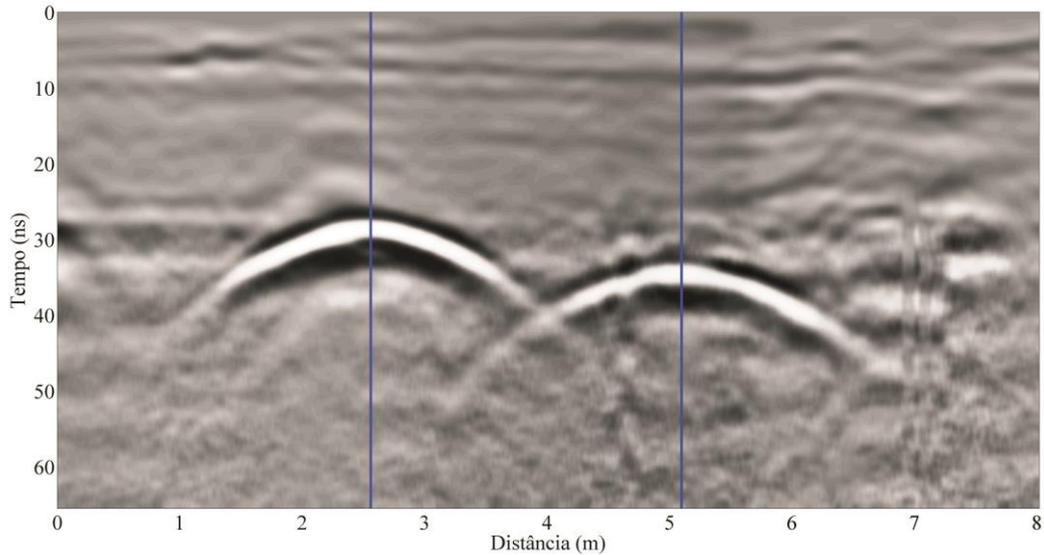


Figura 7.40 – Classificação do perfil GPR com antena de 200 MHz na rotatória da Biologia no Campus USP da Capital.



Figura 7.41 – Local da aquisição com antena de 400 MHz na rotatória da Biologia no Campus USP da Capital.

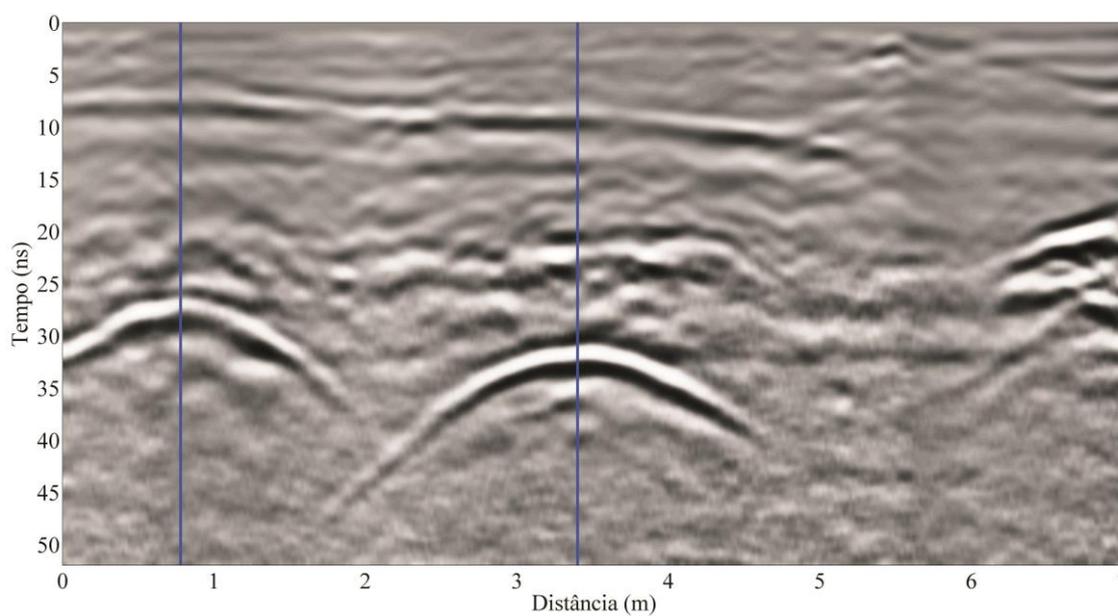


Figura 7.42 – Classificação do perfil GPR com antena de 400 MHz na rotatória da Biologia no Campus USP da Capital.

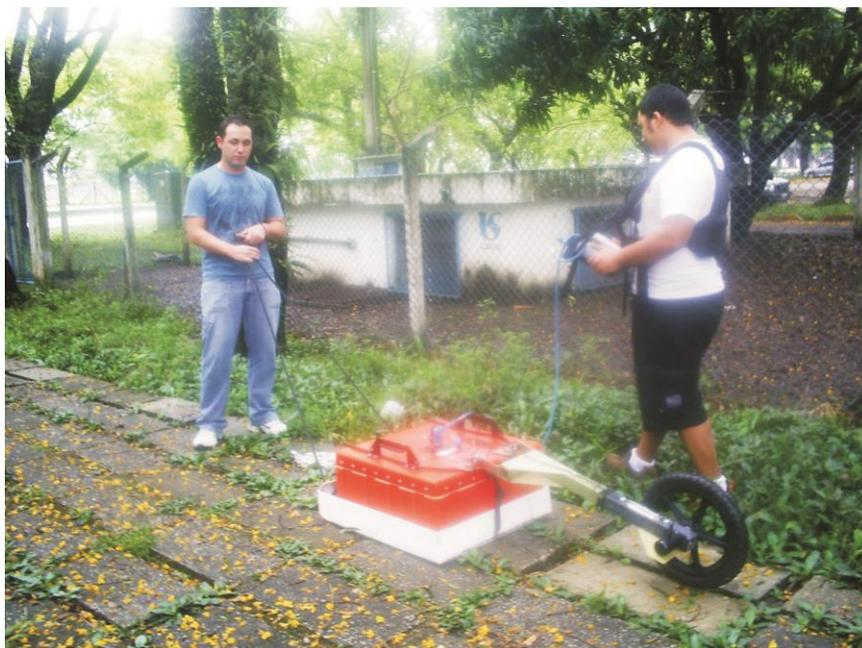


Figura 7.43 – Local da aquisição com antena de 200 MHz próximo à Praça do Relógio no Campus USP da Capital.

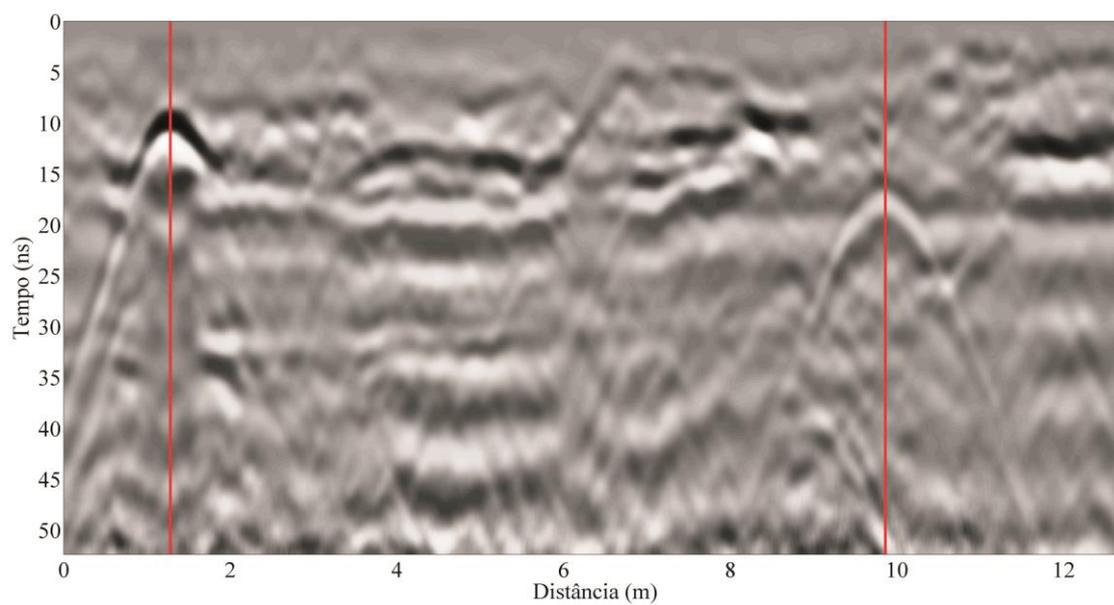


Figura 7.44 – Classificação do perfil GPR com antena de 200 MHz próximo à Praça do Relógio no Campus USP da Capital.



Figura 7.45 – Local da aquisição com antena de 400 MHz no prédio do IAG no Campus USP da Capital.

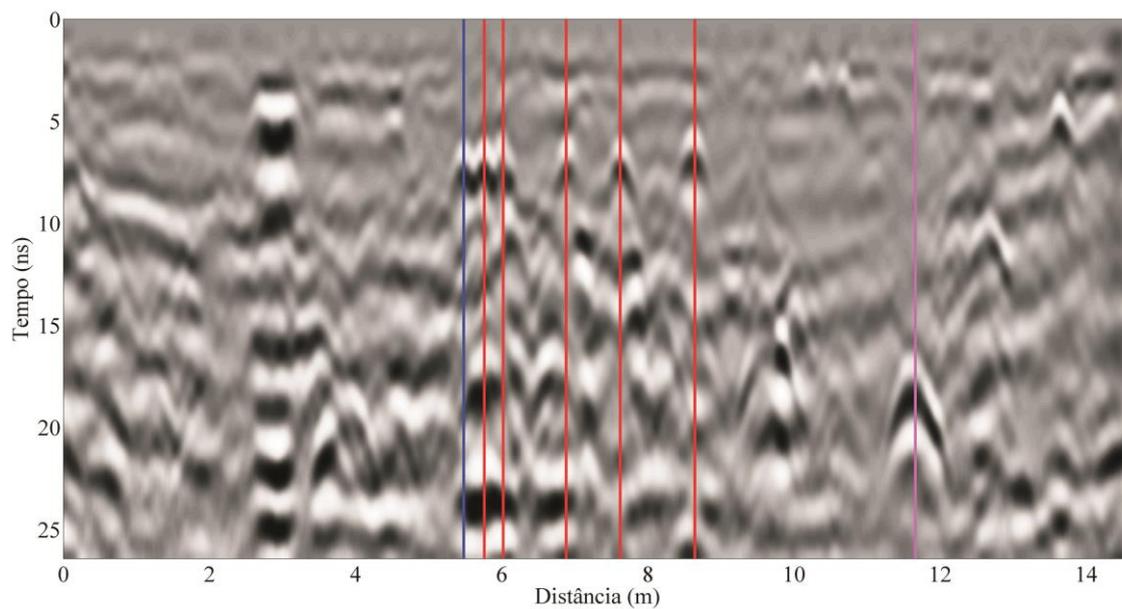


Figura 7.46 – Classificação do perfil GPR com antena de 400 MHz no prédio do IAG no Campus USP da Capital.



Figura 7.47 – Local da aquisição com antena de 200 MHz na POLI no Campus USP da Capital.

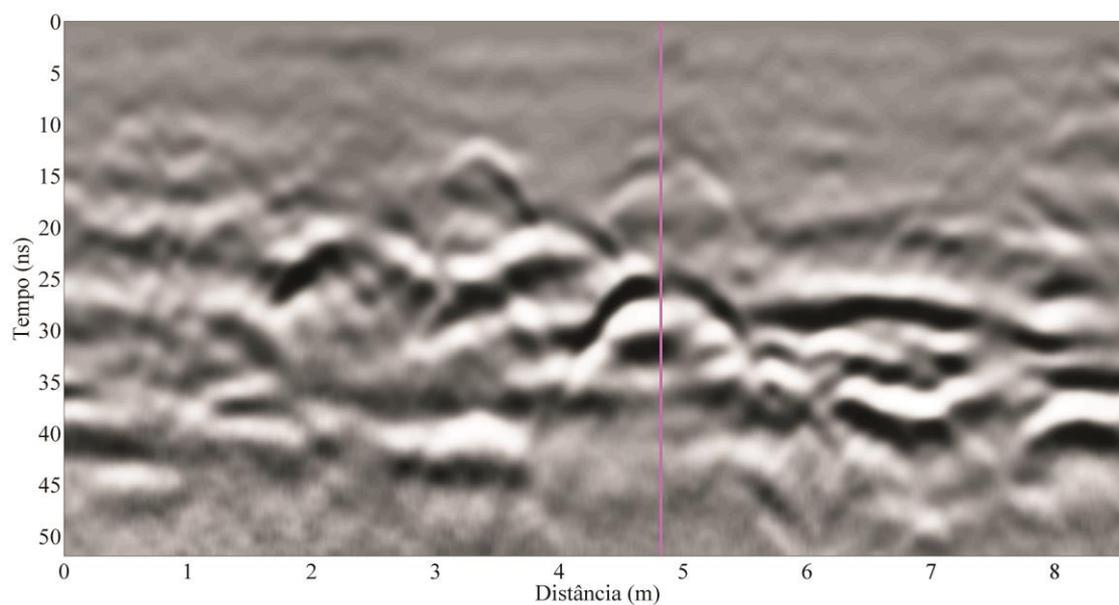


Figura 7.48 – Classificação do perfil GPR com antena de 200 MHz na POLI no Campus USP da Capital.



Figura 7.49 – Local da aquisição com antena de 200 MHz na POLI no Campus USP da Capital.

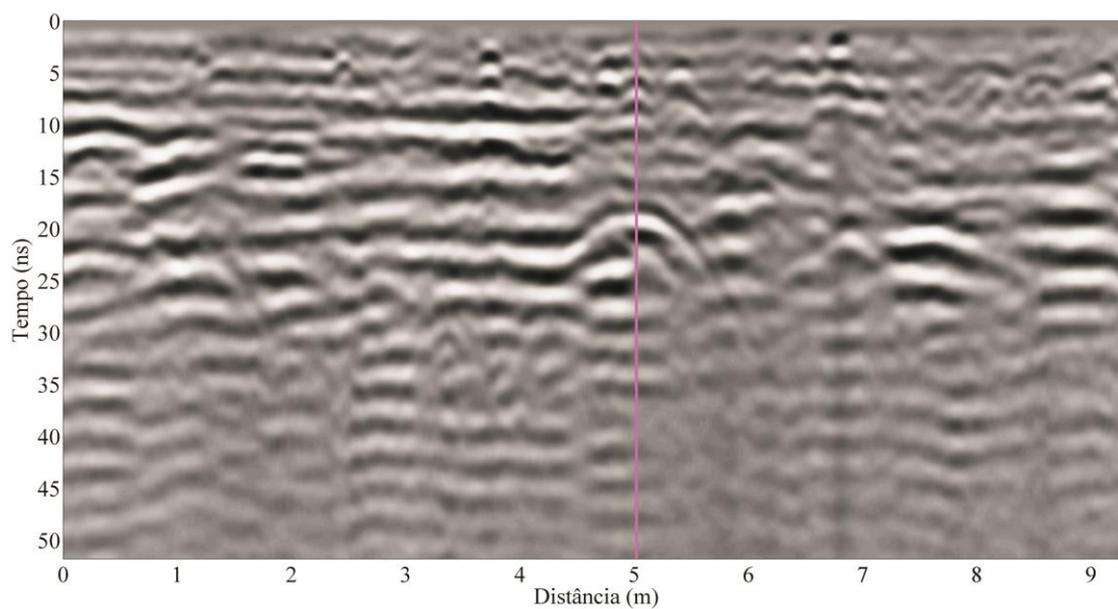


Figura 7.50 – Classificação do perfil GPR com antena de 400 MHz na POLI no Campus USP da Capital.

Já no Campus USP de Pirassununga o NC_GPR foi utilizado para classificar objetos enterrados em outro ambiente geológico. A maioria dos alvos observados foram previamente já identificados com relação ao material, com a ajuda da equipe de Infraestrutura do Campus de Pirassununga e dessa forma buscou-se verificar a aplicabilidade do NC_GPR em estudos geotécnicos. A Figura 7.51 mostra uma manilha de concreto que foi utilizada para testar o algoritmo e a anomalia GPR vista na Figura 7.52 foi identificada e classificada corretamente.

Outro exemplo de aplicação pode ser visto na Figura 7.53 em que foi utilizada a antena de 270 MHz para identificar as estruturas de concreto dos pilares do corredor que liga o saguão do Prédio Principal ao refeitório. O perfil GPR obtido (Figura 7.54) mostra seis estruturas equiespaçadas, sendo que três delas foram classificadas corretamente como de concreto. Já no Prédio da FZEA (Edifício Leste) foi realizada uma aquisição para verificar se havia algo no subsolo daquela área (Figura 7.55). Foram identificadas duas anomalias (Figura 7.56) e classificadas como metálicas, podendo estar relacionadas a tubulações desativadas, segundo o responsável que acompanhou as aquisições. Já no Edifício Oeste (Figura 7.57) existe uma rede de tubulações de amianto que possuem derivações de PVC e essas derivações foram detectadas pelo NC_GPR e classificadas como plástico, corretamente (Figura 7.58).



Figura 7.51 – Local da aquisição com antena de 270 MHz e detalhe da manilha de concreto no Campus USP de Pirassununga.

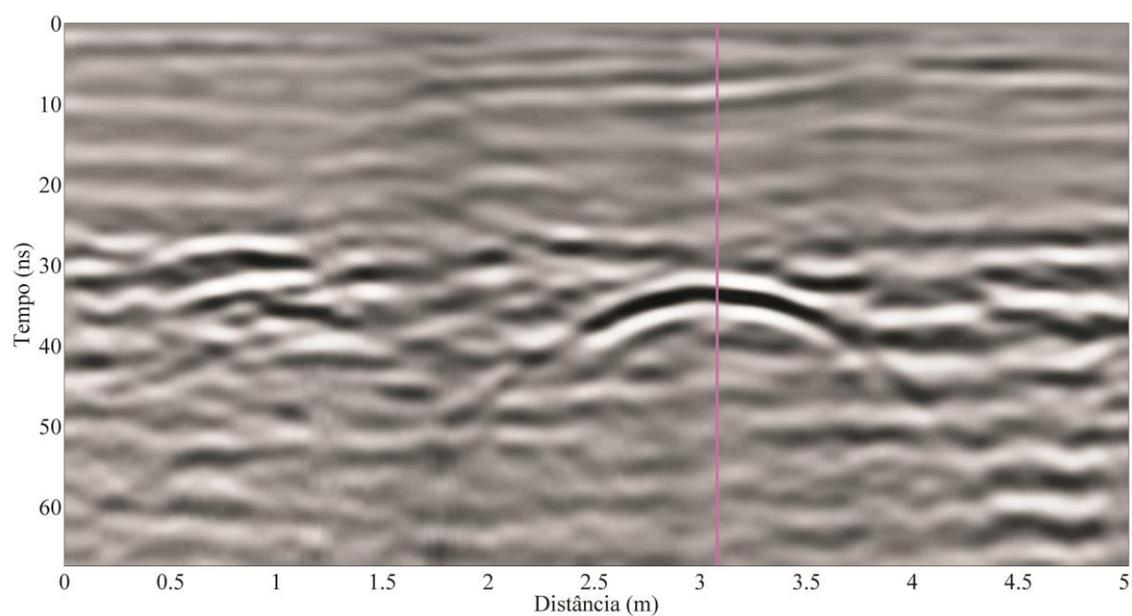


Figura 7.52 – Classificação do perfil GPR com antena de 270 MHz sobre uma manilha de concreto no Campus USP de Pirassununga.

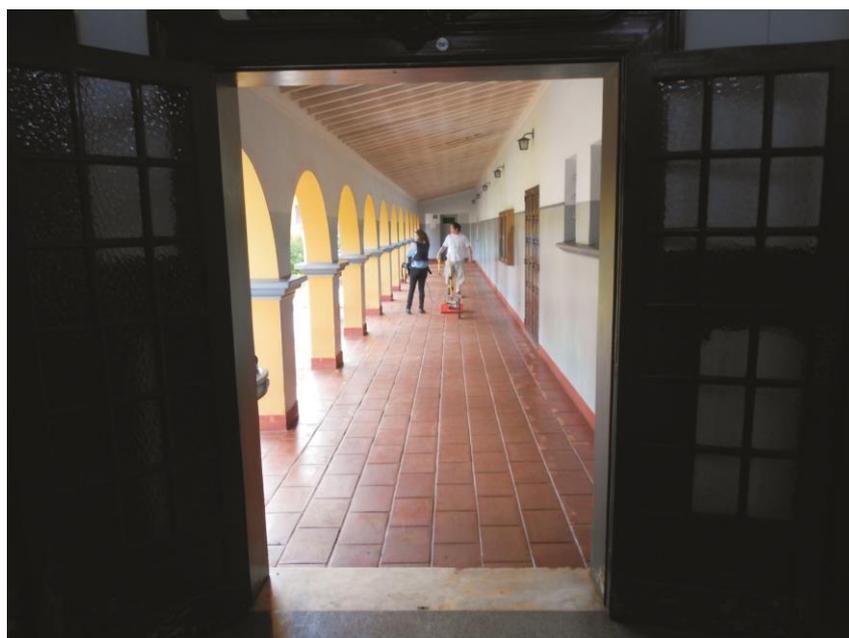


Figura 7.53 – Local da aquisição com antena de 270 MHz no corredor com colunas de concreto no Campus USP de Pirassununga.

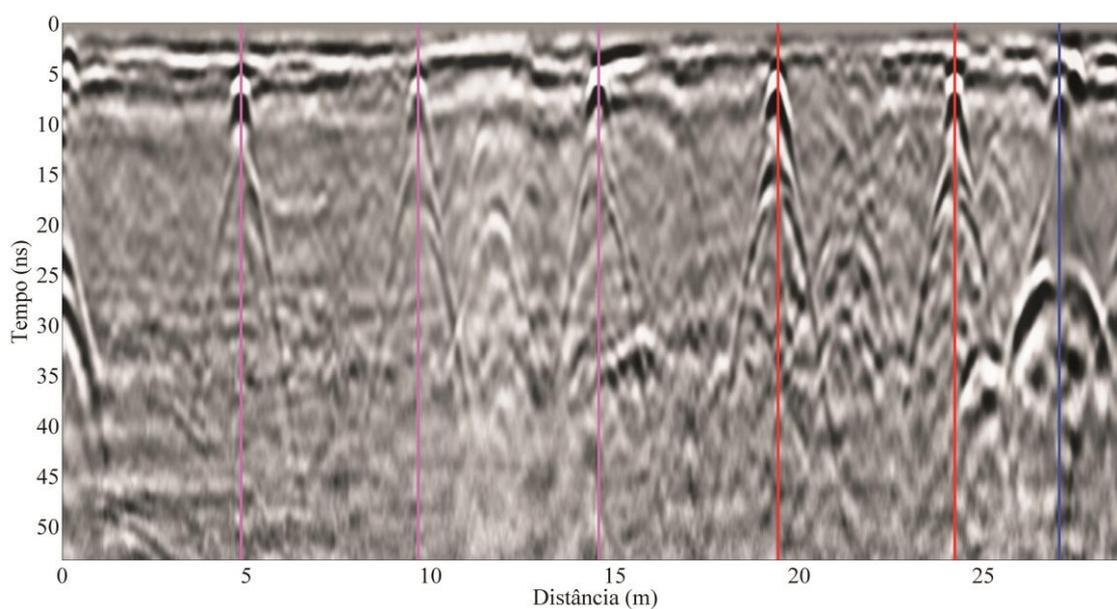


Figura 7.54 – Classificação do perfil GPR com antena de 270 MHz no corredor com colunas de concreto no Campus USP de Pirassununga.



Figura 7.55 – Local da aquisição com antena de 270 MHz no Campus USP de Pirassununga.

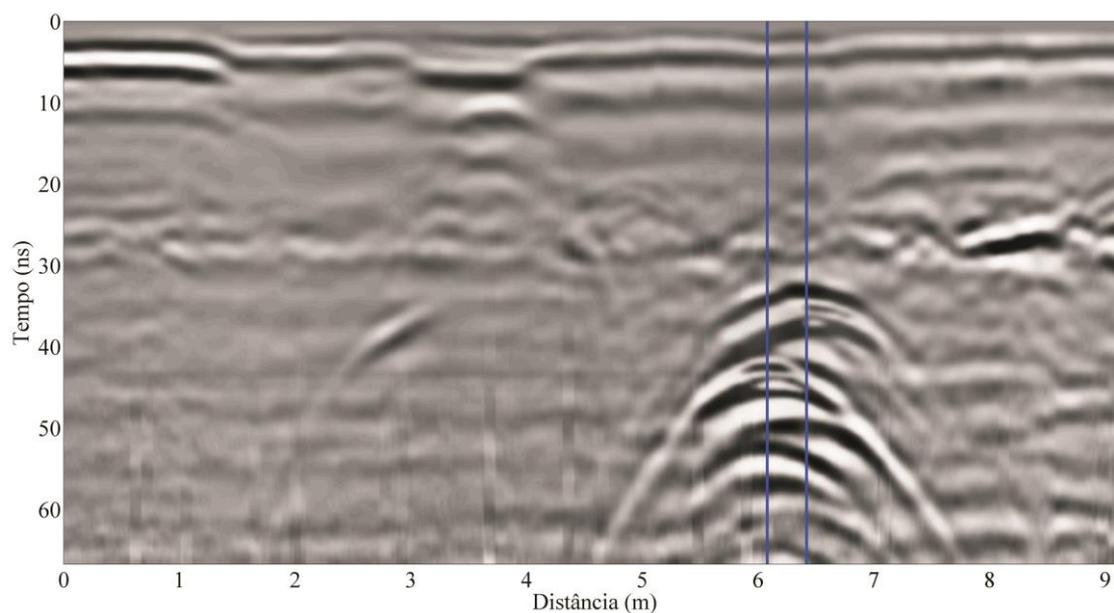


Figura 7.56 – Classificação do perfil GPR com antena de 270 MHz no Campus USP de Pirassununga.

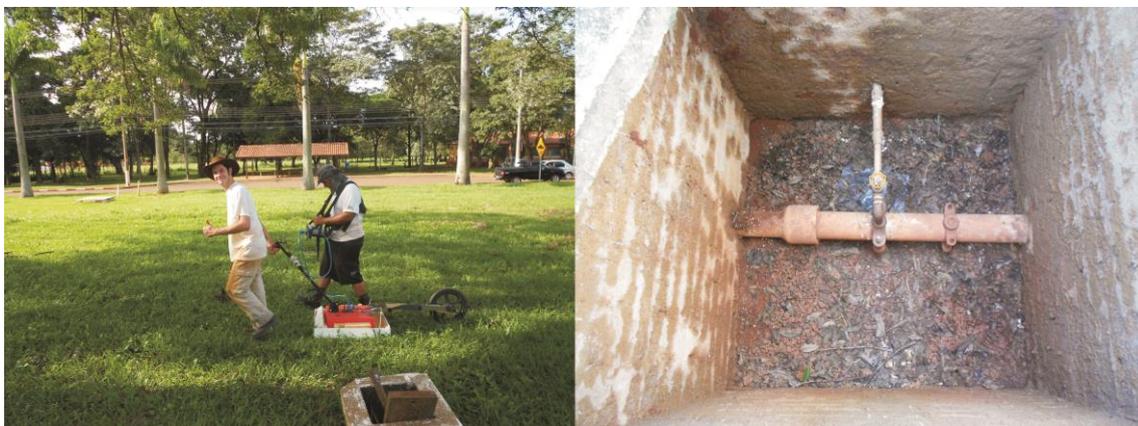


Figura 7.57 – Local da aquisição com antena de 270 MHz e detalhe do tubo de PVC no Campus USP de Pirassununga.

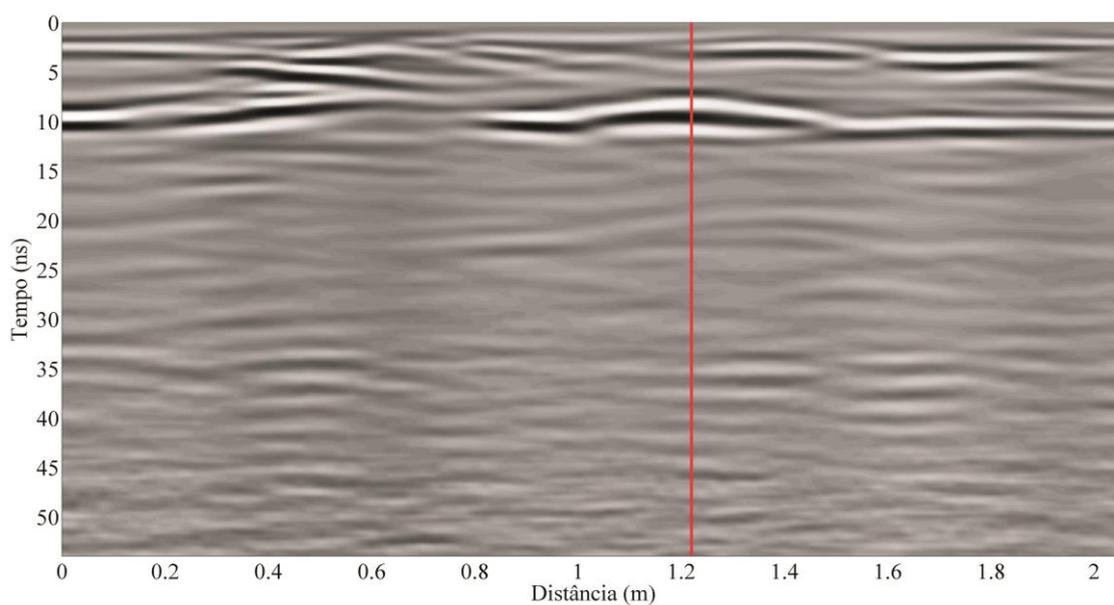


Figura 7.58 – Classificação do perfil GPR com antena de 270 MHz do tubo de PVC no Campus USP de Pirassununga.

As Figuras 7.59 e 7.60 correspondem a dois testes realizados em um solo arenoso com antena de 900 MHz. Nesse local foram enterrados um latão de ferro e uma tubulação metálica a 0,75 m e 0,30 m de profundidade, respectivamente. O objetivo desse teste foi de verificar o comportamento do NC_GPR em um solo que não é “conhecido” pelo algoritmo. Todos os treinamentos foram realizados em um ambiente areno-argiloso, de uma condutividade relativamente alta e já a geologia deste local é composta de um solo areno-siltoso com granulometria fina e uniforme. A princípio, os resultados indicam que a rede possui uma limitação, pois os dois alvos metálicos foram classificados como de concreto, mas é necessário mais exemplos para que essa informação seja realmente validada.

A Tabela 7.8 mostra a relação entre o tempo gasto para a identificação e classificação das anomalias aqui apresentadas, com o número de traços e o tamanho do perfil. A grande parte do tempo é para a identificação, uma vez que é necessário analisar cada traço do perfil e com esses identificados, a etapa de classificação se dá de forma rápida devido ao pequeno número de traços para a análise.

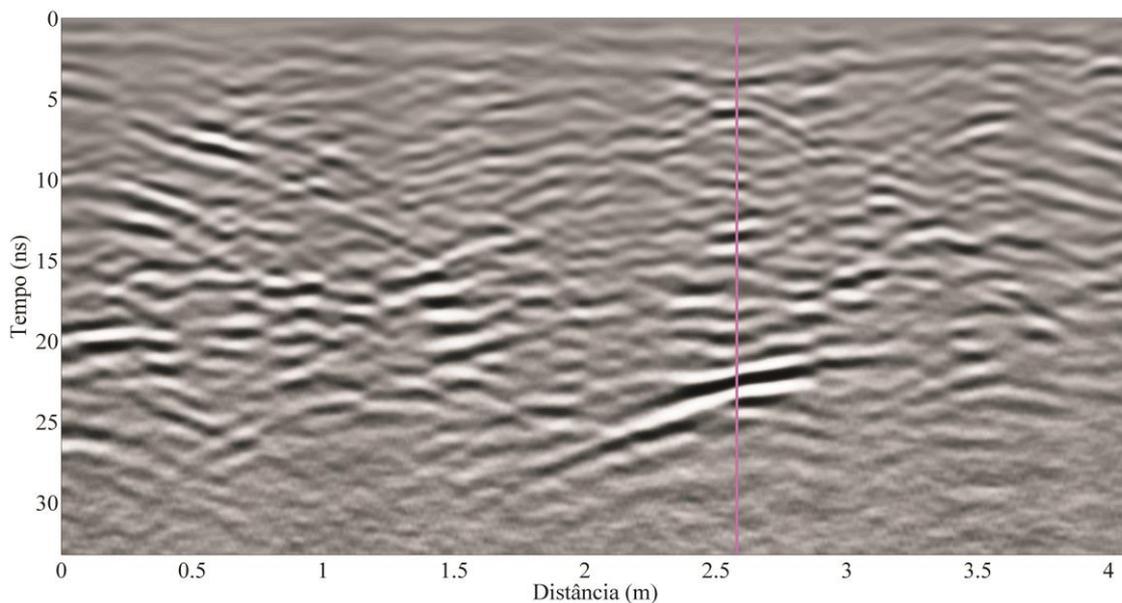


Figura 7.59 – Classificação do perfil GPR com antena de 900 MHz em solo arenoso para um alvo metálico.

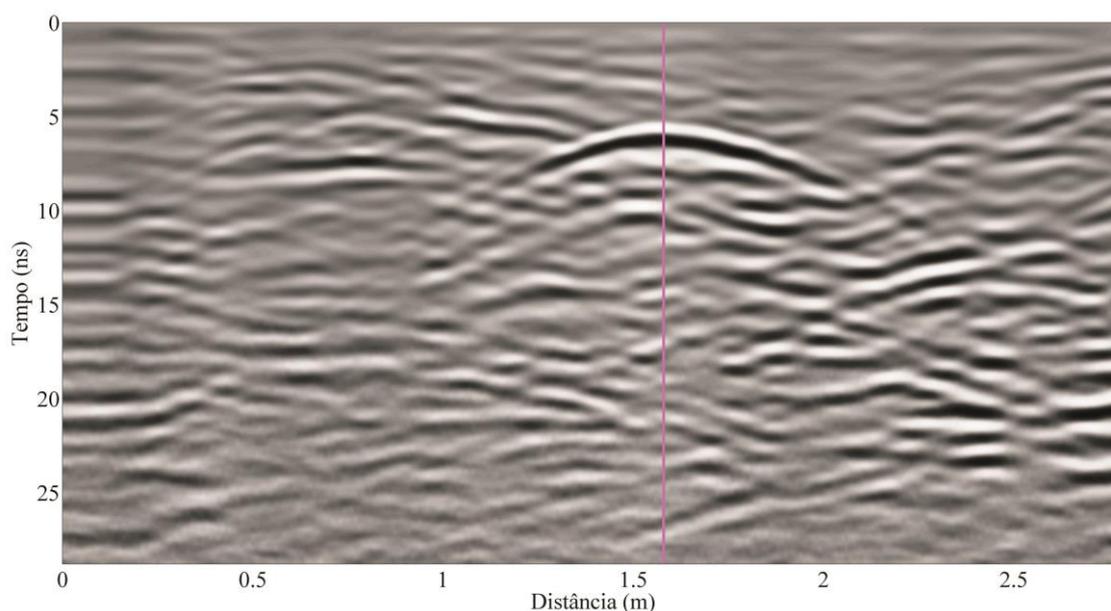


Figura 7.60 – Classificação do perfil GPR com antena de 900 MHz em solo arenoso para um alvo metálico.

Tabela 7.8 – Tempo de identificação e classificação das anomalias dos exemplos mostrados.⁵

Figura	Tempo (s)	Número de traços	Tamanho (m)
7.40	36,64	402	8
7.42	40,29	352	7
7.44	79,74	639	12,8
7.46	91,05	732	14,6
7.48	52,93	432	8,6
7.50	53,01	468	9,3
7.52	28,46	252	5
7.54	186,11	1448	29
7.56	55,85	460	9,2
7.58	10,28	104	2,3
7.59	76,71	409	4
7.60	51,38	280	2,8

⁵ Computador utilizado: Intel Core i5 (terceira geração), 2,67 GHz, 8 GB de RAM.

CAPÍTULO 8

8. CONCLUSÕES E RECOMENDAÇÕES

Os resultados da aplicação das metodologias GPR e RNAs se mostraram eficazes na detecção e classificação de anomalias. O treinamento da rede utilizando os dados obtidos no Sítio Controlado de Geofísica Rasa do IAG/USP foi de grande importância para a aplicação da metodologia proposta no Campus da USP na Capital e em Pirassununga.

A taxa de acerto de 88% no conjunto de teste está muito boa e dentro das ambiguidades que o método GPR apresenta. Os alvos plásticos foram os que sofreram maior taxa de erro e isso pode ser explicado devido ao número reduzido de exemplos e ao fato da baixa amplitude de reflexão do GPR com esse tipo de material. Os alvos de concreto e de metal apresentaram as maiores taxas de acertos no conjunto de testes e nos perfis adquiridos no Campus da Capital e de Pirassununga.

As características estudadas se mostraram eficazes para realizar o treinamento da rede. O estudo no domínio da frequência fornece muitas informações importantes para a caracterização do tipo de material, pois mostra a interação da onda eletromagnética com o meio. Recomenda-se para trabalhos futuros a aplicação destas mesmas características na forma 2-D (B-scans) para tornar a rede mais robusta, bem como a utilização de outras como o Modelo Mistura (modelo probabilístico que indica a presença de sub-populações dentro de uma população geral) ou a Transformada de Hilbert (transformada integral que mapeia uma determinada função em outra).

O método de identificação de hipérboles utilizando RNAs e ajuste dos pontos pode ser melhorado para diminuir o tempo de processamento. Pode ser utilizado algum tipo de processamento de imagem, como a Transformada Hough, para tornar essa etapa mais eficiente e diminuir o tempo gasto com essa tarefa.

Também se faz necessário obter dados de treinamento em outros tipos de ambientes geológicos para aumentar a aplicabilidade da rede. A rede foi desenvolvida

para receber novos dados de treinamento e assim torná-la flexível para novas aplicações.

A classificação de alvos em subsuperfície utilizando o método GPR possui extrema importância em diversas áreas e os resultados obtidos, em condições controladas e não controladas, contribuíram na melhoria da interpretação de dados geofísicos e têm aplicações diretas nas áreas de planejamento urbano, infraestrutura e estudos ambientais em áreas urbanas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADELI, H. & PANAKKAT, A., 2009. A probabilistic neural network for earthquake magnitude prediction. *Neural Networks*, vol. 22, p. 1018-1024.
- AI-NUAIMY, W.; HUANG, Y.; NAKHKASH, M.; FANG, M.T.C.; NGUYEN, V.T.; ERIKSEN, A., 2000a. Automatic detection of buried utilities and solid objects with GPR using neural network and pattern recognition. *Journal of Applied Geophysics*, 43, 157-165.
- AI-NUAIMY, W., HUANG, Y., ERIKSEN A., NGUYEN, V.T., 2000b. Automatic feature selection for unsupervised image segmentation. *Applied Physics Letters*, Vol. 77, no. 8.
- AI-NUAIMY, W., HUANG, Y., SHIHAB, S., 2003. Multi-channel filtering approach for unsupervised segmentation of subsurface radar images. *Environmental and Engineering Geophysics*, Vol. 8, p. 93-101.
- AI-NUAIMY, W.; SHIHAB, S.; ERIKSEN, A., 2004. Data Fusion for Accurate Characterization of Buried Cylindrical Objects Using GPR. Tenth International Conference on Ground Penetrating Radar, 21-24 June, 2004, Delft, The Netherlands.
- AMARI, S., MURATA, N., MULLER, K.R., FINKE, M., YANG, H., 1996. Statistical theory of overtraining: is cross-validation asymptotically effective? *Advances in Neural Information Processing Systems*, vol. 8, p.176-182, The MIT Press.
- ANDREWS, R. & GEVA, S., 1994. Rule extraction from a constrained error backpropagation MLP. In *Proceedings of the 5th Australian Conference on Neural Networks*, p. 9-12, Brisbane, Austrália.
- ANNAN, A.P., 1992. Ground Penetrating Radar Performance Predictions. The Geological Survey of Canada, Paper 90-4, p. 5-13.

- ANNAN, A.P., 1996. Transmission dispersion and GPR. *JEEG*, Vol. 0, January 1996, pp. 125–136.
- ANNAN, A.P., 2003. Ground penetrating radar: Principles, procedures & applications. Sensors & Software Inc. Technical Paper.
- BARTLETT, M.S., 1948. Periodogram analysis and continuous spectra. *Biometrika* Trust, Vol. 37, no. 1, p. 1-16.
- BATTITI, R., 1991. First and second order methods for learning: between steepest descent and Newton's method. Technical report, University of Trento.
- BISHOP, C. M., 1995. *Neural Networks for Pattern Recognition*. OXFORD University Press. 482p.
- BORGES, W.R., 2007. Caracterização geofísica de alvos rasos com aplicações no planejamento urbano e meio ambiente: estudo sobre o Sítio Controlado do IAG/USP. PhD Thesis, Instituto de Astronomia, Geofísica e Ciências Atmosféricas, USP, São Paulo, Brazil.
- BOSE, B., GUYON, I., VAPNIK, V., 1992. A training algorithm for optimal margin classifiers. 5th Annual Workshop on Computational Learning Theory, p. 144-152.
- BOWDERS J.J.; KOERNER, R.M.; LORD, A.E., 1982. Buried container detection using ground-probing radar. *Journal of Hazardous Materials*, v.7, n^o. 1, p. 1-17.
- BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B., 2007. *Redes Neurais Artificiais: Teoria e Aplicações*. Ed. LTC, 2^a Edição.
- BROOMHEAD, D.S. & LOWE, D., 1988. Multivariable functional interpolation and adaptive networks. *Complex Systems*, vol. 2, p. 321-355.
- CARPENTER, G.A. & GROSSBERG, S., 1988. The ART of adaptive pattern recognition by a self-organizing neural network. *Computer*, vol. 21, p. 77-88.
- CHANG JOU, I., SHIH-SHIEN YOU, LONG-WEN CHANG, 1994. Analysis of hidden nodes for multi-layer perceptron neural networks. *The Journal of the Pattern Recognition Society*. 27 (1994) 859-864.

- CHAUVIN, Y. & RUMELHART, D., 1995. BACKPROPAGATION: Theory, architectures and applications (edited collection). Hillsdale, NJ: Lawrence Erlbaum Assoc.
- COHEN, L., 1995. Time-frequency analysis. Hunter College and Graduate Center of the City university of New York. Prentice Hall PTR, Upper Saddle River, New Jersey 07458.
- CYBENKO, G., 1989. Approximation by superpositions of a sigmoid function. Mathematics of Control, Signals and Systems, vol. 2, p.303-314.
- DANIELS, D.J., 2007. Ground Penetrating Radar. IET Radar, Sonar, Navigation and Avionics Series 15. 2nd Edition.
- DANIELS, J.J.; ROBERTS, R.; VENDL, M., 1994. Ground penetration radar for the detection of liquids contaminants. Journal of Applied Geophysics, v.33, n° 1-3, p. 195-207.
- DAUBECHIES, I., 1990. The Wavelet Transform, time-frequency localization and signal analysis. IEEE Transaction on Information Theory, Vol. 36, no. 5, pp. 961-1005.
- DUDA, R. O., HART, P. E., STORK, D. G., 2001. Pattern Classification. Second Edition. Wiley-Interscience Publication. JOHN WILEY & SONS, INC. 654p.
- EGMONT-PETERSEN, M., de RIDDER, D., HANDELS, H., 2002. Image processing with neural networks – a review. Pattern Recognition. 35 (2002) 2279-2301.
- EHRET, B., 2010. Pattern recognition of geophysical data. Geoderma. 160 (1), 111-125.
- FAHLMAN, S.E., 1988. An empirical study of learning speed in backpropagation networks. Technical report, Carnegie Mellon University.
- FRANZINI, M., 1987. Speech recognition with backpropagation. In 9th Annual Conference of IEEE Engineering in Medicine and Biology Society.

- FUKUSHIMA, K., 1975. Cognitron: a self-organizing multilayered neural network. *Biological Cybernetics*, vol. 23, p. 121-134.
- GADER, P.D.; KELLER, J.M.; NELSON, B.N., 2001. Recognition Technology for the Detection of Buried Land Mines. *IEEE TRANSACTIONS ON FUZZY SYSTEMS*, VOL. 9, NO. 1, FEBRUARY 2001.
- GAMBA, P.; LOSSANI, S., 2000. Neural Detection of Pipe Signatures in Ground Penetrating Radar Images. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 38, no. 2, p. 790-797.
- GERBER, R.; FELIX-HENNINGSSEN, P.; SALAT, C. & JUNGE, A., 2004. Investigation of the GPR reflection pattern for shallow depths on a test site. *Proceeding of the Tenth International Conference on Ground Penetrating Radar, GPR 2004*, v.1, p.275-278.
- GONZALEZ, R., WOOD, H., 1992. *Digital Image Processing*. Addison Wesley, 1992.
- GRANDJEAN, G.; GOURRY, J.C.; BITRI, A., 2000. Evaluation of GPR techniques for civil-engineering applications: study on a test site. *Journal of Applied Geophysics*, Elsevier, 45: 141-156.
- GRAPS, A., 1995. An introduction to wavelets. *Computational Science & Engineering*, IEEE. Vol. 2, Issue: 2, 50-61.
- GROSSBERG, S., 1976. Adaptive pattern recognition and universal recoding: Parallel development and coding of neural feature detectors. *Biological Cybernetics*, vol. 24, p. 121-134.
- GSSI. 2003. *RADAN for Windows. User's Manual*. Version 7.0. Geophysical Survey Systems, Inc., North Salem, NH, 135p.
- HAGAN, M. & MENHAJ, M., 1994. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*. Vol. 5, p. 989-993.
- HARA, T. & HIROSE, A., 2004. Plastic mine detecting radar system using complex-valued self-organizing map that deals with multiple-frequency interferometric images. *Neural Networks*, vol. 17, p. 1201–1210.

- HASSOUN, M.H., 1995. Fundamentals of artificial neural networks. MIT Press, Cambridge, MA.
- HEBB, D.O., 1949. The organization of behavior. Wiley.
- HOPFIELD, J.J., 1982. Neural networks and physical systems with emergent collective properties. Proceeding of the National Academy of Science of the United States of America, vol. 79, p. 2554-2558.
- IRITANI, M. A., 1993. Potencial hidrológico da Cidade Universitária de São Paulo. Dissertação de Mestrado, IG/USP, 63p.
- JOL, H. M., 2009. Ground Penetrating Radar: Theory and Applications. Elsevier. 524p.
- JUSTICE, J. H., HAWKINS, D. J., WONG, G., 1985. Multidimensional attribute analysis and pattern recognition for seismic interpretation. The Journal of the Pattern Recognition Society. 18 (1985) 391-407.
- KANASEWICH, E.R., 1975. Time sequence analysis in Geophysics. University of Alberta Press, Canada, second revised edition.
- KARTALOPOULOS, S. V., 1996. Understanding Neural Networks and Fuzzy Logic - Basic Concepts and Applications. IEEE, Inc., New York, USA.
- KELLER, G.V., 1987. Rock and mineral properties. Investigations in Geophysics, no 3. Electromagnetic Methods in Applied Geophysics. Society of Exploration Geophysicists, Ed. Misac N. Nabighian, vol.1, p.13-51.
- KHAN, U. S., Al-NUAIMY, W., El-SAMIE, F.E.A., 2010. Detection of landmines and underground utilities from acoustic and GPR images with a cepstral approach. Journal of Visual Communication and Image Representation, vol. 21, issue 7, p. 731-740.
- KOHONEN, T., 1982. Self-organized formation of topologically correct feature maps. Biological Cybernetics, vol. 43.
- KOSKO, B., 1992. Neural Networks and Fuzzy Systems - A dynamical systems approach to machine intelligence, Prentice - Hall International, Inc., USA.

- KOVÁCS, Z. L., 1996. Redes Neurais Artificiais - Fundamentos e Aplicações. Edição Acadêmica, São Paulo, Brasil.
- LIMA, R.S. 2006. Otimização de Perfis de Reflexão GPR Sobre Manilhas de Concreto e Tubulações de PVC Instaladas no Sítio Controlado de Geofísica Rasa do IAG/USP. *Dissertação de Mestrado*, IAG/USP, São Paulo/SP, 131p.
- MACHADO, K.D., 2013. Eletromagnetismo: Volumes 1 e 2. Todapalavra Editora.
- MACKAY, D.J.C., 1992. Bayesian interpolation. *Neural Computation*, vol.4, p.415-447.
- MARCELINO, M.B., 1999. Delimitação de Perímetros de Proteção dos Poços tubulares (PPP) empregando a técnica de modelagem numérica tridimensional. *Dissertação de Mestrado*. IGc/USP. São Paulo. 122p.
- MASSOLI, M., 1983. Geologia da folha de Piraçununga, SP. *Revista do Instituto Geológico*. 4 (1983) 25-51.
- MENDEL, J.M. & FU, K.S., 1970. Adaptive, learning and pattern recognition systems: theory and applications. New York Academic Press.
- MILISAVLJEVIC, N., BLOCH, I., VAN DEN BROEK, S., ACHEROY, M., 2003. Improving mine recognition through processing and Dempster-Shafer fusion of ground penetrating radar data. *The Journal of the Pattern Recognition Society*. 36 (2003) 1233-1250.
- MINSKY, M.L. & PAPERT, S., 1969. Perceptron: An introduction to computational geometry. MIT Press, Massachusetts.
- MINSKY, M.L., 1961. Steps towards artificial intelligence. In *Proc. of the Institute of Radio Engineers* 49, p. 8-32.
- MOLYNEAUX, T. C. K., MILLARD, S.G., BUNGEY, J. H., ZHOU, J. Q., 1995. Radar assessment of structural concrete using neural networks. *NDT&E International*, vol. 28, no. 5, p. 281-288.

- MOYSEY, S.; CAERS, J.; KNIGHT, R.; ALLEN-KING, R.M., 2003. Stochastic estimation of facies using ground penetrating radar data. *Stochastic Environmental Research and Risk Assessment* 17 (2003) 306–318.
- NASER, M., and JUNGE, A., 2008. The Frankfurt test site for utility detection – construction and first GPR tests: 12th International Conference on Ground Penetrating Radar, GPR'2008, Birmingham, Inglaterra, 16-19 de junho. Cdrom.
- NEYAMADPOUR, A., TAIB, S., WAN ABDULLAH, W.A.T., 2009. Using artificial neural networks to invert 2D DC resistivity imaging data for high resistivity contrast regions: A MATLAB application. *Computers & Geosciences*, vol. 35, p. 2268-2274.
- OLHOEFT, G. R., 1998. Electrical, magnetic and geometric properties that determine ground penetrating radar performance. 7th International Conference on Ground Penetrating Radar, The Univ. of Kansas, Lawrence, USA, p.177-182.
- OPPNHEIM, A.V., SCHAFER, R.W., 1989. *Discrete-time signal processing*. Prentice-Hall.
- PANIAGUA, J.; DEL RÍO, M.; RUFO, M., 2004. Test site for the analysis of subsoil GPR signal propagation. 10th International Conference on Ground Penetrating Radar, Delft, The Netherlands, p. 751-754.
- PAPOULIS, A., 1984. *Probability, random variables and stochastic processes*. McGraw-Hill, USA, 1984.
- PEARLMUTTER, B., 1992. Gradient descent: second order momentum and saturation error. *Advances in neural information processing systems* 2. Morgan Kaufmann, p. 887-894.
- PORSANI, J.L.; BORGES, W.R.; ELIS, V.R.; DIOGO, L.A.; HODO, F.Y.; MARRANO, A.; BIRELLI, C.A. 2004. Investigações Geofísicas de Superfície e de Poço no Sítio Controlado de Geofísica Rasa do IAG-USP. *Revista Brasileira de Geofísica*, Vol. 22 (3):245 – 258.

- PORSANI, J.L., BORGES, W.R., RODRIGUES, S.I., HODO, F.Y., 2006. O sítio controlado de geofísica rasa do IAG-USP: Instalação e resultados GPR 2D-3D. *Revista Brasileira de Geofísica* 24, 49–61.
- PORSANI, J.L., SANTOS, V.R.N., RODRIGUES, S.I., ALMEIDA, E.R., 2008. GPR characterization of plastic and steel tanks buried in the test site at University of São Paulo: applications to environmental studies. Proceedings of the 12th International Conference on Ground Penetrating Radar (GPR'2008), Birmingham, United Kingdom, cd-rom.
- PORSANI, J.L., SAUCK, W.A., 2007. Ground-penetrating radar profiles over multiple steel tanks: artifact removal through effective data processing. *Geophysics* 72, J77–J83.
- PORSANI, J.L., SLOB, E., LIMA, R.S., LEITE, D.N., 2010. Comparing detection and location performance of perpendicular and parallel broadside GPR antenna orientations. *Journal of Applied Geophysics*, vol. 70, issue 1, p. 1-8.
- PORSANI, J.L., RUY, Y.B., RAMOS, F.P., YAMANOUTH, G.R.B., 2012. GPR applied to mapping utilities along the route of the Line 4 (yellow) subway tunnel construction in São Paulo City, Brazil. *Journal of Applied Geophysics*, vol. 80, p. 25-31.
- PORTUGAL, R.S., 2012. Fundamentos matemáticos para Geofísica I: Funções de uma variável. Editora Edgard Blücher Ltda. 422p.
- POULTON, M. M. & EL-FOULY, A., 1991. Preprocessing GPR signatures for cascading neural network classification. 61st Annual International Meeting, Society of Exploration Geophysicists. Expanded abstracts, E/G1.8, 507-509.
- QIAN, S., MORRIS, J.M., 1992. Wigner Distribution decomposition and cross-terms deleted representation. *Signal Processing*, Vol. 27, pp. 125-144.
- RADZEVICIUS, S.J.; DANIELS, J.J., 2000. Ground penetrating radar polarization and scattering from cylinders. *Journal of Applied Geophysics*, v.45, p. 111-125.
- RAUBER, T.W., 1998. Redes Neurais. Encontro Regional de Informática - ERI98. Sociedade Brasileira de Computação. Nova Friburgo, RJ, Março, 1998.

- REYNOLDS, J.M., 1997. An introduction to applied and environmental geophysics. John Wiley; Sons Ltd., 806p.
- RIEDMILLER, M., 1994. Rprop – description and implementation details. Technical report, University of Karlsruhe.
- RODRIGUES, S.I., 2004. Caracterização GPR de tambores metálicos e plásticos: Estudo sobre o Sítio Controlado do IAG-USP. Departamento de Geofísica, Instituto de Astronomia, geofísica e ciências atmosféricas, Universidade de São Paulo, São Paulo-SP, 89p.
- RODRIGUES, S.I., PORSANI, J.L., 2006. Utilização do GPR para caracterizar tambores plásticos enterrados no sítio controlado de geofísica rasa do IAG/USP. Revista Brasileira de Geofísica 24, 157–168.
- ROSA, A.L.R., 2010. Análise do sinal sísmico. Sociedade Brasileira de Geofísica – SBGf. 668p.
- ROSENBLATT, F., 1958. The perceptron: a probabilistic model for information storage and organization in the brain. Psychological Review, vol. 65, p.386-408.
- ROSSITER, J.R., LaTORRACA, G.A., ANNAN, A.P., STRANGWAY, D.W., SIMMONS, G., 1973. Radio interferometry depth sounding: Part II - Experimental results. Geophysics, Vol. 38, No. 3, P. 581-599.
- RUMELHART, D.E. & McCLELLAND, J.L., 1986. Parallel distributed processing. The MIT Press, vol.1.
- RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J., 1986. Learning representations by back-propagating errors. Nature, vol. 323, p.533-536.
- SANDMEIER, K.J., 2013. REFLEXW Version 7.1.3, Windows 9x/2000/NT/XP/7 - Program for processing of seismic, acoustic or eletromagnetic reflection, refraction and transmission data. Software manual. Karlsruhe, Germany, 272p.
- SANTOS, V. R. N. & PORSANI, J.L., 2011. Comparing performance of instrumental drift correction by linear and quadratic adjusting in inductive electromagnetic data. Journal of Applied Geophysics, vol. 73, issue 1, p. 1-7.

- SANTOS, V.R.N., 2009. Emprego dos métodos eletromagnético indutivo e GPR no mapeamento de redes de interferências instaladas no Sítio Controlado de Geofísica Rasa do IAG/USP. M.Sc. Thesis, Instituto de Astronomia, Geofísica e Ciências Atmosféricas, USP, São Paulo, Brazil.
- SANTOS, V.R.N., AL-NUAIMY, W., PORSANI, J.L., HIRATA, N.S.T., 2014. Spectral analysis of ground penetrating radar signals in concrete, metallic and plastic targets. *Journal of Applied Geophysics*, vol. 100, p. 32-43.
- SEJDICC, E., DJUROVIC, I., JIANG, J., 2009. Time-frequency feature representation using energy concentration: an overview of recent advances. *Digital Signal Processing*, Vol. 19, pp. 153-183.
- SHAW, M.R., MILLARD, S.G., MOLYNEAUX, T.C.K., TAYLOR, M.J., BUNGEY, J.H., 2005. Location of steel reinforcement in concrete using ground penetrating radar and neural networks. *NDT&E International*, vol. 38, p. 203-212.
- SHIHAB, S., AL-NUAIMY, W., HUANG, Y., ERIKSEN, A., 2002. Neural network target identifier based on statistical features of GPR signals. *GPR2002 International conference on ground penetrating radar N^o9*, vol. 4758, p. 135-138.
- SHIHAB, S., 2005. Automatic detection and characterization of cylindrical objects using Ground Penetrating Radar. Ph.D. Thesis, University of Liverpool, March 2005.
- SILVA, E.M.A. da, 2004. Aplicação de Resistividade e Polarização Induzida na Investigação de objetos enterrados em Sítio Controlado do IAG/USP, *Dissertação de Mestrado* (Departamento de Geofísica), IAG/USP, São Paulo, SP, 79p.
- STARK, H.G., 2005. *Wavelets and Signal Processing: An Application-Based Introduction*. Springer. 150p.
- STRATTON, J. A., 1941. *Electromagnetic Theory*. McGraw Hill Book Company, New York, 615p.

- SUTTON, R.S., BARTO, A.G., WILLIAMS, R.J., 1991. Reinforcement learning is direct adaptive optimal control. In Proc. of the American Control Conference, p. 2143-2146.
- TEIXEIRA, R.A., BRAGA, A.P., TAKAHASHI, R.H.C., REZENDE, R., 2000. Improving generalization of MLPs with multi-objective optimization. *Neurocomputing*, vol.35, p.189-194.
- WARD, S. H., HOHMANN, G. W., 1987. Electromagnetic theory for geophysical applications: Electromagnetic Methods in Applied Geophysics. Tulsa: Society of Exploration Geophysicists, ed. Misac N. Nabighian, vol.1, p.131-311. (Investigations in Geophysics, n.3).
- WEEKS, M., 2012. Processamento digital de sinais utilizando Matlab e Wavelets. 2ª Edição, LTC. 409p.
- WIDROW, B. & HOFF, M.E., 1960. Adaptive switching circuits. Institute of Radio engineers, *Western Electronic Show and Convention*, 1960.
- YOUN, H., CHEN, C., 2004. Neural Detection for Buried Pipe Using Fully Polarimetric GPR. Tenth International Conference on Ground Penetrating Radar, 21-24 June, 2004, Delft, The Netherlands.

APÊNDICE A: TRANSFORMADA DE FOURIER

Uma função periódica suave por partes pode ser representada completamente por uma série de Fourier. Em Geofísica existe uma grande variedade de funções não periódicas onde se faz necessário uma representação alternativa para tais funções e a maneira de representa-las é através de uma integral imprópria, conhecida como integral de Fourier.

A função não periódica que cumpre algumas condições específicas sobre a regularidade e integrabilidade pode ser representada similarmente à série de Fourier, sendo denominada genericamente por representação espectral. A representação espectral de uma função é chamada de *análise espectral* ou *análise de Fourier* (Transformada de Fourier - TF). Já a *síntese espectral* ou *síntese de Fourier* (Transformada inversa de Fourier) tem objetivo contrário, construindo uma função a partir da representação espectral (PORTUGAL, 2012).

Existe uma relação muito próxima entre a Transformada de Laplace e a de Fourier. A Transformada de Laplace de uma função $h = h(t)$ integrável, denotada por $L(s) = L(h(t))$, é definida para $s > 0$, por:

$$L(s) = \int_0^{\infty} h(t)e^{-st} dt \quad (\text{A.1})$$

Substituindo s por $i\omega$ e integrando no intervalo entre $-\infty$ e $+\infty$, teremos a Transformada de Fourier.

A representação integral de uma função f é conhecida por integral de Fourier e todo o processo de construção desta, a partir de uma função dada, é a TF. As formas mais comuns de representação da transformada são: forma real, complexa e polar. Se uma função f é suave por partes e absolutamente integrável, então a Transformada de Fourier fornece as funções $a_f(\omega)$ e $b_f(\omega)$ através dos seguintes teoremas:

Teorema 1: Transformada de Fourier na forma real

Se uma função real qualquer $f: \mathbb{R} \rightarrow \mathbb{R}$ é suave por partes e absolutamente integrável, então ela pode ser representada da seguinte forma integral:

$$f(t) = \int_0^{\infty} a_f(\omega) \cos(\omega t) + b_f(\omega) \sin(\omega t) d\omega \quad (\text{A.2})$$

onde as funções $a_f(\omega)$ e $b_f(\omega)$ são definidas por:

$$a_f(\omega) = \frac{1}{\pi} \int_{-\infty}^{\infty} f(t) \cos(\omega t) dt \quad (\text{A.3})$$

$$b_f(\omega) = \frac{1}{\pi} \int_{-\infty}^{\infty} f(t) \sin(\omega t) dt \quad (\text{A.4})$$

A integral em $f(t)$ é denominada de Transformada inversa de Fourier e o par de funções $a_f(\omega)$ e $b_f(\omega)$ é denominada Transformada de Fourier na forma real.

Teorema 2: Transformada de Fourier na forma complexa

Se uma função real qualquer $f: \mathbb{R} \rightarrow \mathbb{R}$ é suave por partes e absolutamente integrável, então ela pode ser representada da seguinte forma integral:

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega) e^{i\omega t} d\omega \quad (\text{A.5})$$

onde $i = \sqrt{-1}$ e a função complexa $F(\omega)$ é dada por:

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-i\omega t} dt \quad (\text{A.6})$$

$F(\omega)$ é denominada Transformada de Fourier e $f(t)$ é denominada Transformada inversa de Fourier.

Teorema 3.1: Transformada de Fourier na forma polar - seno

Se uma função $f: [0, \infty) \rightarrow \mathbb{R}$ é suave por partes e absolutamente integrável, então ela pode ser representada da seguinte forma integral:

$$f(t) = \frac{2}{\pi} \int_0^{\infty} F_s(\omega) \text{sen}(\omega t) d\omega \quad (\text{A.7})$$

onde $F_s(\omega)$ é denominada de Transformada seno de Fourier e é dada por:

$$F_s(\omega) = \int_0^{\infty} f(t) \text{sen}(\omega t) dt \quad (\text{A.8})$$

A integral em $f(t)$ é denominada de Transformada seno inversa de Fourier.

Teorema 3.2: Transformada de Fourier na forma polar - cosseno

Se uma função $f: [0, \infty) \rightarrow \mathbb{R}$ é suave por partes e absolutamente integrável, então ela pode ser representada da seguinte forma integral:

$$f(t) = \frac{2}{\pi} \int_0^{\infty} F_c(\omega) \text{cos}(\omega t) d\omega \quad (\text{A.9})$$

onde $F_c(\omega)$ é denominada de Transformada cosseno de Fourier e é dada por:

$$F_c(\omega) = \int_0^{\infty} f(t) \text{sen}(\omega t) dt \quad (\text{A.10})$$

A integral em $f(t)$ é denominada de Transformada seno inversa de Fourier.

Principais propriedades da Transformada de Fourier (adaptado de ROSA, 2010):

$$f(t) \leftrightarrow F(\omega)$$

a) Linearidade:

$$\alpha f(t) + \beta g(t) \rightarrow \alpha F(\omega) + \beta G(\omega)$$

b) Dualidade ou simetria:

$$F(t) \rightarrow 2\pi f(-\omega)$$

c) Soma:

$$f(t) + g(t) \rightarrow F(\omega) + G(\omega)$$

d) Deslocamento:

$$f(t - a) \rightarrow F(\omega)e^{i\omega a}$$

$$f(t)e^{iat} \rightarrow F(\omega + a)$$

e) Transformada da derivada:

$$f'(t) \rightarrow -i\omega F(\omega)$$

$$f^{(k)}(t) \rightarrow (i\omega)^k F(\omega)$$

f) Derivada da transformada:

$$tf(t) \rightarrow iF(\omega)$$

$$t^k f(t) \rightarrow i^k F^k(\omega)$$

g) Escala:

$$f(at) \rightarrow \frac{1}{|a|} F\left(\frac{\omega}{a}\right)$$

Como visto anteriormente através da definição da TF e suas propriedades, esta ferramenta matemática auxilia na mudança de funções no domínio do tempo para funções no domínio da frequência. O sinal eletromagnético do GPR é normalmente representado em função do tempo e das coordenadas espaciais, mas em alguns casos é necessário representar o mesmo sinal no domínio da frequência, assim fazendo uso da TF. Como exemplo dessa conveniência, cita-se o fato de que alguns processamentos realizados nos dados GPR são feitos no domínio da frequência ou para indicar o conteúdo espectral do sinal faz-se o uso da interpretação neste domínio.

APÊNDICE B:

TRANSFORMADA DE FOURIER NO TEMPO CURTO

Em alguns casos práticos é necessário estabelecer como varia, com o tempo, o conteúdo de frequências do sinal. Para resolver esse problema, uma solução consiste em se aplicar a Transformada de Fourier no tempo curto (ou Transformada móvel de Fourier ou *Running Fourier Transform* ou *Short Time Fourier Transform* - STFT), que corresponde a uma técnica de decomposição espectral ou decomposição tempo-frequência (ROSA, 2010).

Embora a análise de Fourier permita a passagem do domínio do tempo para o domínio da frequência, a sua utilização refere-se a sinais estacionários, cujas propriedades não evoluem com o tempo. Apenas a Transformada de Fourier não permite uma combinação dos dois domínios e, em particular, a informação temporal não é facilmente acessível no domínio da frequência. Enquanto o espectro mostra a amplitude total com a qual cada frequência está contida no sinal, o mesmo geralmente não fornece informação sobre a localização do tempo de componentes espectrais (DAUBECHIES, 1990). Qualquer mudança abrupta no tempo de um sinal não estacionário é espalhada sobre o eixo da frequência na Transformada de Fourier, sendo que esta é baseada na informação global que não é adequado para o estudo de padrões compactos ou local.

Assim, uma análise adaptada para sinais não estacionários requer mais do que a Transformada de Fourier (COHEN, 1995). A STFT é uma das técnicas tempo-frequências normalmente utilizadas para esta finalidade. A STFT pode ser definida da seguinte forma:

$$STFT(\tau, f) = \int_{-\infty}^{\infty} s(t)g(t - \tau)e^{i2\pi ft} d\tau \quad (B.1)$$

onde $STFT(\tau, f)$ é a Transformada de Fourier no tempo curto do sinal $s(t)$ em torno do tempo τ , enquanto $g(t)$ é a função responsável pelo janelamento.

Na forma discreta para uma serie temporal $s(n)$ formada por b amostras:

$$STFT(i, p) = \sum_{n=0}^b s(n)g(m - n)e^{i\frac{2\pi cm}{b}} \quad (B.2)$$

onde m e $p = 0, 1, 2, \dots, b-1$. Isto produz um espectro local do sinal $s(n)$ entorno do tempo de análise i . O conjunto do espectro de potência correspondente a todos os tempos produz uma representação bidimensional, tempo-frequência, chamado de espectrograma. O espectrograma é uma ferramenta muito comum na análise de sinais e fornece a distribuição de energia do sinal no plano tempo-frequência.

$$SPEC(i, p) = |STFT|^2 \quad (B.3)$$

A STFT introduz uma dependência da frequência com o tempo com um filtro passa-banda centrado em cada frequência individual e cuja resposta ao impulso é o da função de janela $g(i-n)$. A escolha do comprimento da janela é muito importante nesta análise espectral (SHIHAB, 2005). Quanto menor o tamanho da janela, melhor a resolução no tempo. No entanto, se o tamanho da janela for pequeno, o número de frequências discretas que podem ser representadas no domínio da frequência será reduzido e, por assim, mais enfraquecida será a discriminação entre as frequências. A janela pode ser calculada da seguinte forma (**freq** – frequência da antena; **n_samp** – número de amostras no traço; **range** – tamanho da janela temporal; **T_{ant}** – “tempo da antena”; **win** – tamanho da janela para a STFT):

$$T_{ant} = \frac{1000}{freq} \rightarrow ns \quad (B.4)$$

$$T_{ant} = \frac{1000}{freq} \cdot \frac{n_samp}{range} \rightarrow amostras \quad (B.5)$$

$$win = 2T_{ant} \quad (B.6)$$

$$win = \frac{2000n_sample}{freq \cdot range} \quad (B.7)$$

Os valores calculados para a janela STFT para as frequências utilizadas nesta pesquisa estão apresentados na Tabela B.1.

Tabela B.1 - Valores calculados para a janela STFT (*win* em amostras) para as diferentes frequências GPR.

Frequência (MHz)	Janela temporal (ns)	Amostras	Janela STFT - <i>win</i>
200	97,13	512	53
270	62,13	512	61
400	71,73	512	36
900	62,42	512	18

A Figura A.1 mostra a diferença na escolha do comprimento da janela.

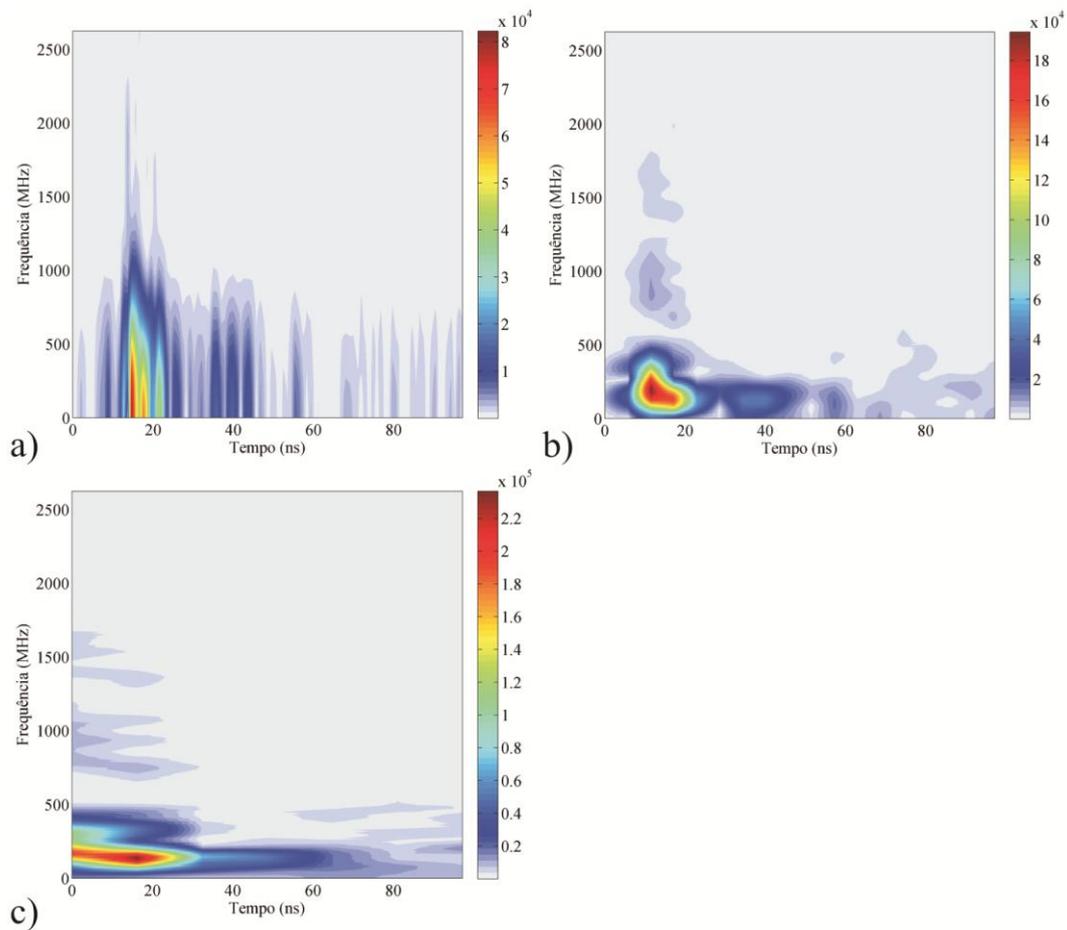


Figura A.1 - Exemplo da variação da janela para o cálculo da STFT para dado obtido com antena de 200 MHz no período seco. a) Janela de 10 amostras. b) Janela de 53 amostras (correto). c) Janela de 200 amostras.

APÊNDICE C: DENSIDADE ESPECTRAL

Uma sequência de amostras pode ser representada por um conjunto de coeficientes espectrais chamado de densidade espectral (PSD – *Power Spectral Density*), que fornece uma medida significativa da distribuição da potência média em uma série de tempo. Uma estimativa PSD chama-se de periodograma e pode ser definida da seguinte maneira (WELCH, 1967):

$$PSD = \frac{X(f)X(f)^*}{2\pi} \quad (C.1)$$

onde $X(f)$ é a Transformada de Fourier, $X(f)^*$ é o complexo conjugado da Transformada de Fourier e f representa o domínio da frequência. A transformada de Fourier pode ser definida segundo WUNSCH, 2003:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-i2\pi ft} dt \quad (C.2)$$

A incerteza nos resultados é reduzida localizando as reflexões detectadas ao longo do eixo do tempo. Isto é obtido pela segmentação do sinal em partes e assim extrair a informação espectral de apenas essas secções que contêm reflexões causadas pelos alvos. Cada sinal é seccionado em oito segmentos de 64 amostras cada. Para cada segmento, o logaritmo da densidade espectral da janela de 64 pontos é extraído como uma característica discriminatória, e apenas as primeiras 12 amostras espectrais são retidos. A janela escolhida para esta aplicação é a janela de Hanning dada por (OPPNHEIM, 1989):

$$w(n) = \begin{cases} \frac{1}{2} \left(1 + \cos \frac{n\pi}{J}\right), & |n| \leq win \\ 0, & |n| > win \end{cases} \quad (C.3)$$

onde win é o comprimento da janela.

O periodograma sofre com vários inconvenientes e entre eles uma variação excessiva (KANASEWICH, 1975). Bartlett (BARTLETT, 1948) sugeriu que a variância seria reduzida se o segmento de tempo fosse dividido em subgrupos, com o periodograma então calculado para cada subconjunto e a densidade de energia média

obtida para cada frequência de forma a obter uma maior redução na variância. Isto foi aplicado sobre os dados de radar e, como resultado, a segmentação tornou-se mais sensível à presença e a localização do alvo.

APÊNDICE D: DISTRIBUIÇÃO WIGNER-VILLE

A distribuição *Wigner-Ville* (WVD – *Wigner-Ville Distribution*) é uma técnica tempo-frequência amplamente aplicada em uma variedade de casos. A WVD pode ser definida como uma densidade espectral instantânea da seguinte maneira (COHEN, 1995 e SEJDIC et al., 2009):

$$W_S(t, f) = \int_{-\infty}^{+\infty} s\left(t + \frac{\tau}{2}\right) s^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau \quad (D.1)$$

com t sendo o tempo, f a frequência e sabendo que a função de correlação instantânea $R_S(\tau, t)$ do sinal $s(t)$ é dada por:

$$R_S(\tau, t) = s\left(t + \frac{\tau}{2}\right) s^*\left(t - \frac{\tau}{2}\right) \quad (D.2)$$

a Transformada de Fourier de $R_S(\tau, t)$ nos dá uma função de densidade espectral instantânea:

$$D_S(f, t) = \int_{-\infty}^{+\infty} e^{-j2\pi f\tau} d\tau R_S(\tau, t) \equiv W_S(t, f) \quad (D.3)$$

A WVD é utilizada em muitas aplicações de processamento de sinais, pois é o que melhor caracteriza um sinal nas mudanças de frequência e possui muitas propriedades úteis (COHEN, 1995). Mas uma das principais deficiências da WVD é a interferência *cross-term*. Esta interferência está relacionada ao aparecimento de artefatos na representação WVD, que correspondem a certas componentes do sinal (QIAN & MORRIS, 1992). Este problema foi reduzido utilizando o sinal chamado de *analítico* associado ao sinal real (SHIHAB, 2005). Seja $u(t)$ um sinal real quadrado-integrável no tempo e o sinal correspondente analítico é definido como:

$$s(t) = u(t) + jh(t) \quad (D.4)$$

onde $h(t)$ é a Transformada de Hilbert de $u(t)$.

APÊNDICE E: TRANSFORMADA DA WAVELET

Como visto anteriormente a Transformada de Fourier mostra apenas o conteúdo espectral do sinal estudado, não fornecendo o instante ou o intervalo de tempo em que essas componentes espectrais aparecem. Em alguns casos é importante saber quando ou em que intervalo de tempo as frequências ocorrem. Como solução a isso surgiu primeiro a STFT (Apêndice B), mas esta metodologia apresenta alguns problemas, como por exemplo, a largura da janela estudada.

Muitas séries temporais exibem comportamentos não estacionários, como mudança de tendências e estas características são frequentemente as partes mais importantes do sinal e aplicando a TF ou a STFT não se poderá determinar eficientemente esses eventos. Nesse sentido a Transformada da Wavelet (*Wavelet Transform* - WT) surge como ferramenta útil para a análise de sinais não estacionários.

As wavelets são ondas de curta duração com energia concentrada em um intervalo de tempo curto (GRAPS, 1995). A transformada da wavelet decompõe uma função definida no domínio do tempo em outra função, definida no domínio do tempo e da frequência. Isso significa que a função decomposta possui diferentes níveis de resolução (escalas) e tempos de localização. A partir desses níveis é possível reconstruir ou apresentar uma função utilizando as bases wavelet e coeficientes desses níveis apropriadamente.

A transformada contínua da wavelet (CWT – *Continuous Wavelet Transform*) pode ser definida como:

$$CWT_s^\psi(a, b) = \int_t s(t) \cdot \psi_{a,b}^* dt \quad (E.1)$$

Com a função base ou wavelet-mãe definida como (com a e b reais e $b \neq 0$):

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|b|}} \psi^* \left(\frac{t-a}{b} \right) \quad (E.2)$$

A CWT mede a similaridade entre o sinal e a função base, sendo que a análise resulta em um conjunto de coeficientes que indicam o quão similar é o sinal da função base.

A DWT – *Discrete Wavelet Transform* (Transformada Discreta da Wavelet) por utilizar apenas as potências de dois da função base produz um menor conjunto de dado, apresentando uma representação mais compacta, sem perder informações significantes. A função base da DWT é definida como:

$$\hat{\psi}_{a,b}(t) = 2^{-\frac{b}{2}} \cdot \hat{\psi}(2^{-b}t - a) \quad (\text{E.3})$$

onde a , b e t são inteiros que representam o deslocamento discreto, a escala e o tempo respectivamente. A DWT pode ser definida através da seguinte expressão:

$$DWT_s^{\hat{\psi}}(a, b) = \sum_t s(t) \cdot \hat{\psi}_{a,b}^* \quad (\text{E.4})$$

Neste trabalho a função "*Mexican Hat Wavelet*" foi utilizada como base ou wavelet-mãe. Esta função é a segunda derivada da função Gaussiana $-0,5e^{-t^2}$ e é dada por:

$$\psi(t) = (1 - 2t^2)e^{-t^2} \quad (\text{E.5})$$

APÊNDICE F: CARACTERÍSTICAS ESTATÍSTICAS: VARIÂNCIA, DESVIO MÉDIO ABSOLUTO E 4º MOMENTO

Características estatísticas de sinais são sempre úteis para fornecer informações exclusivas sobre os diferentes tipos de sinais, seja individualmente ou coletivamente. O tipo de sinal e a capacidade de cada recurso em fornecer base discriminante são importantes elementos para decidir quais características utilizar. Além disso, como mencionado anteriormente, a questão do tempo de processamento é de grande importância e isso pode significar um limitante no processo de escolha das características mais adequadas entre eficiência e complexidade.

A investigação de uma variedade de recursos levou a seleção de três principais características estatísticas, que produzem uma boa discriminação entre sinais refletidos. Estas três características são: variância (segundo momento), desvio médio absoluto e quarto momento (PAPOULIS, 1984 e GONZALEZ & WOODS, 1992).

A variância (σ_v) é a medida da dispersão estatística de uma variável aleatória, indicando a distância entre os valores e um determinado valor esperado. A variância de uma variável aleatória é o seu segundo momento central e pode ser definida segundo a equação abaixo.

$$\sigma_v = \frac{1}{n-1} \sum_{i=1}^n (s_i - \bar{s})^2 \quad (\text{F.1})$$

onde s_i são os elementos de um grupo de tamanho n e \bar{s} é a média dos valores.

O desvio médio absoluto (*MAD – mean absolute deviation*) é a média dos desvios absolutos de um conjunto de dados sobre a média dos mesmos. Pode ser considerada a distância média do conjunto de dados a partir de sua média e pode ser definida segundo a seguinte equação:

$$MAD = \frac{1}{n} \sum_{i=1}^n |s_i - \bar{s}| \quad (\text{F.2})$$

O quarto momento central ou curtose é uma medida de dispersão que caracteriza a curva da função de distribuição de probabilidade. Pode ser definida da seguinte forma:

$$m_4 = \frac{1}{n-1} \sum_{i=1}^n (s_i - \bar{s})^4 \quad (\text{F.3})$$

APÊNDICE G: PERFIS GPR ADQUIRIDOS NO SCGR

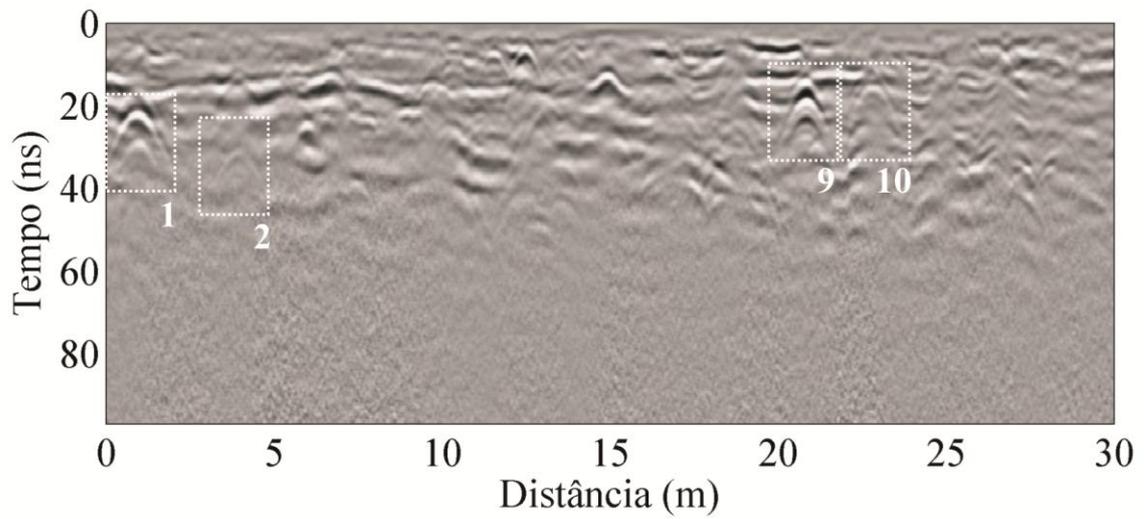


Figura G.1 – Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 200 MHz, em ambiente seco.

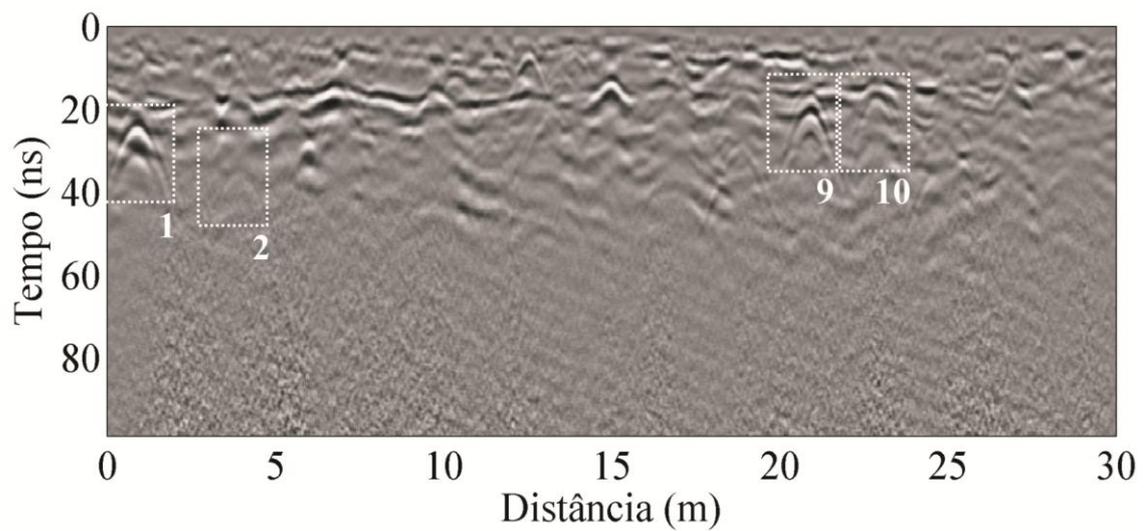


Figura G.2 - Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 200 MHz, em ambiente úmido.

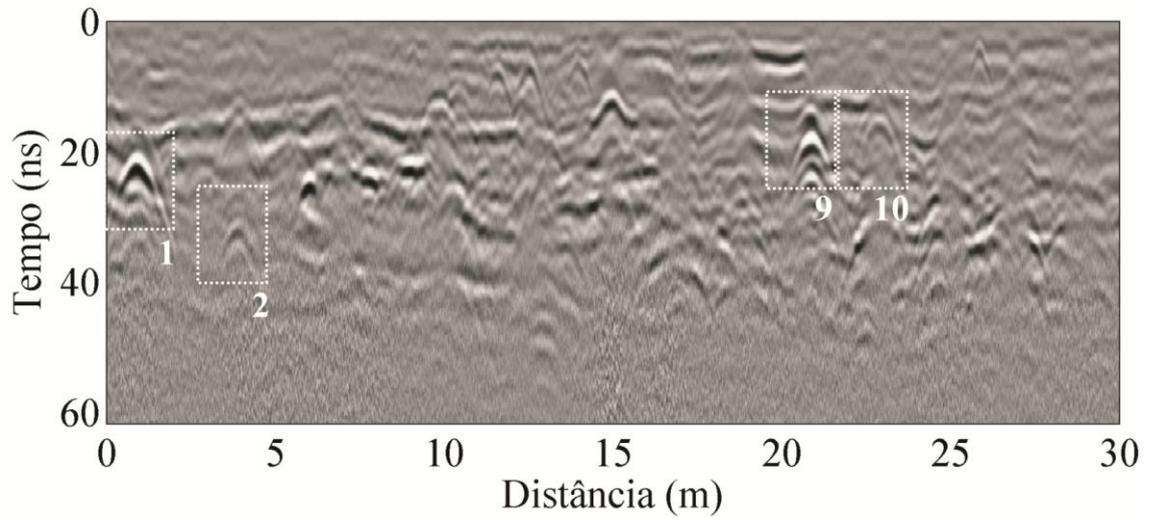


Figura G.3 - Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 270 MHz.

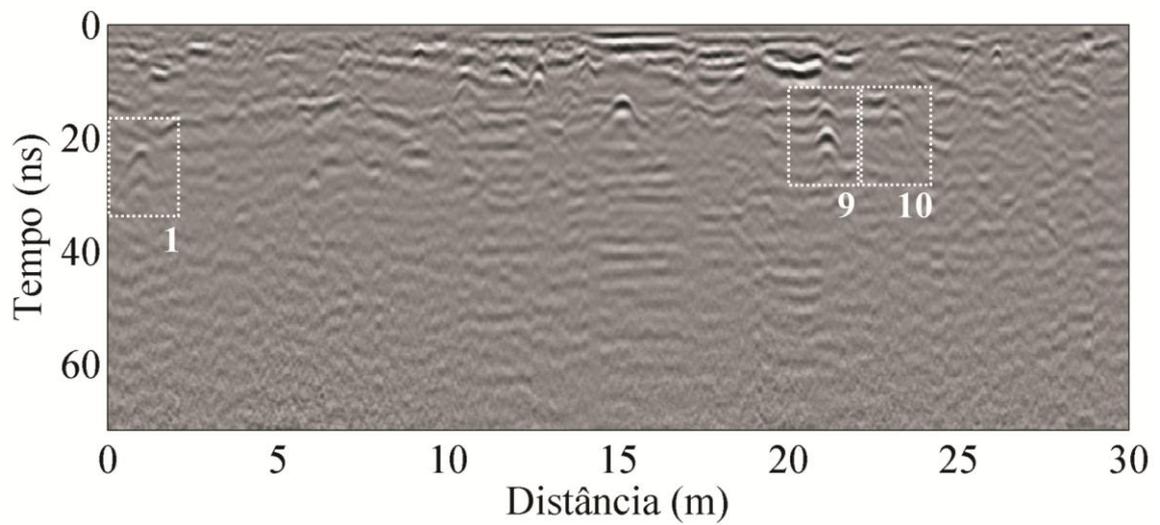


Figura G.4 - Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 400 MHz, em ambiente seco.

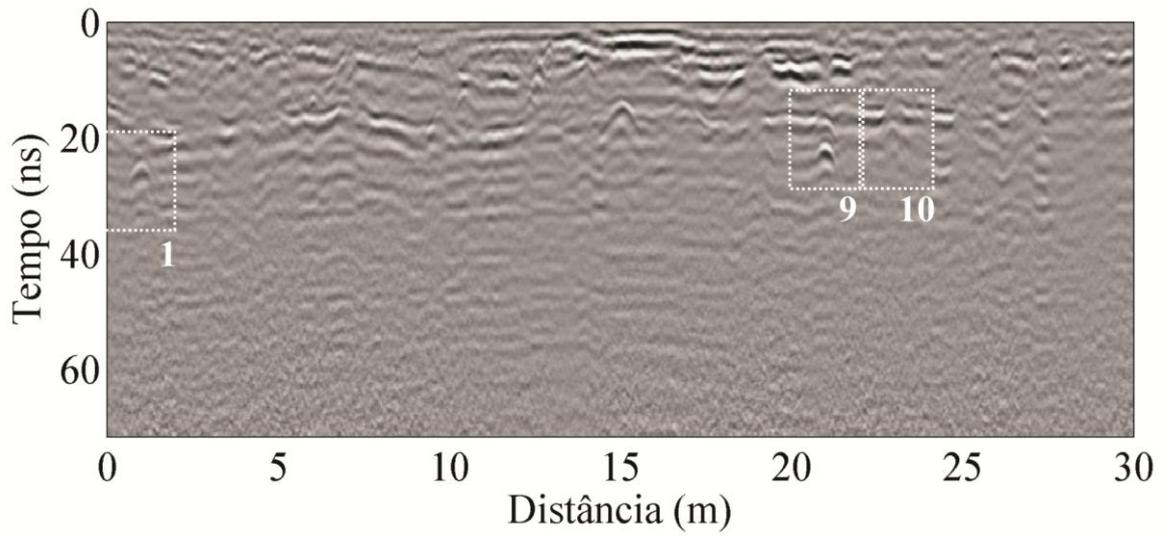


Figura G.5 - Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 400 MHz, em ambiente úmido.

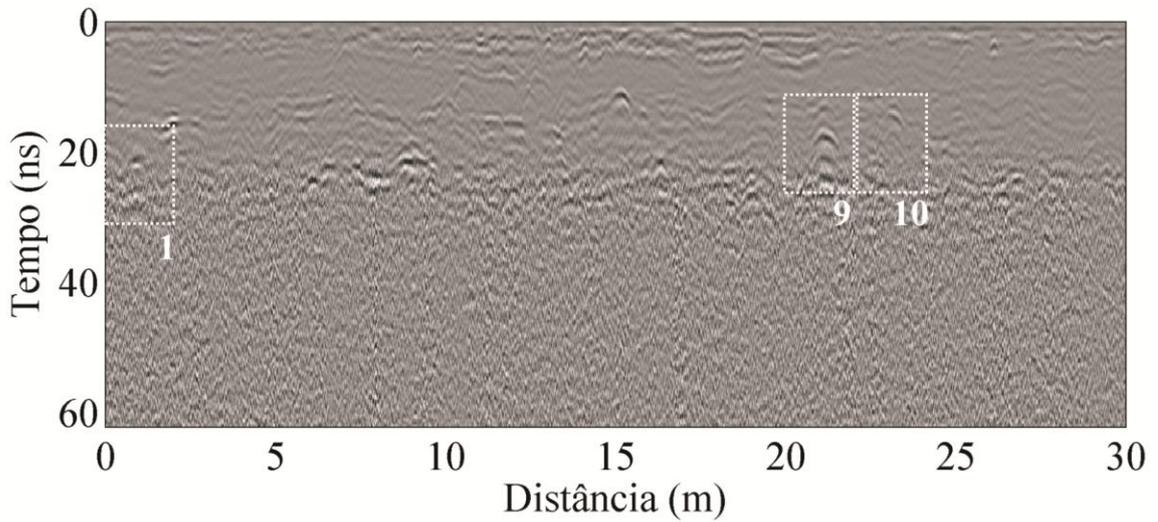


Figura G.6 - Perfil GPR (direção Y) sobre a Linha 2 – tubos de PVC utilizando antena de 900 MHz.

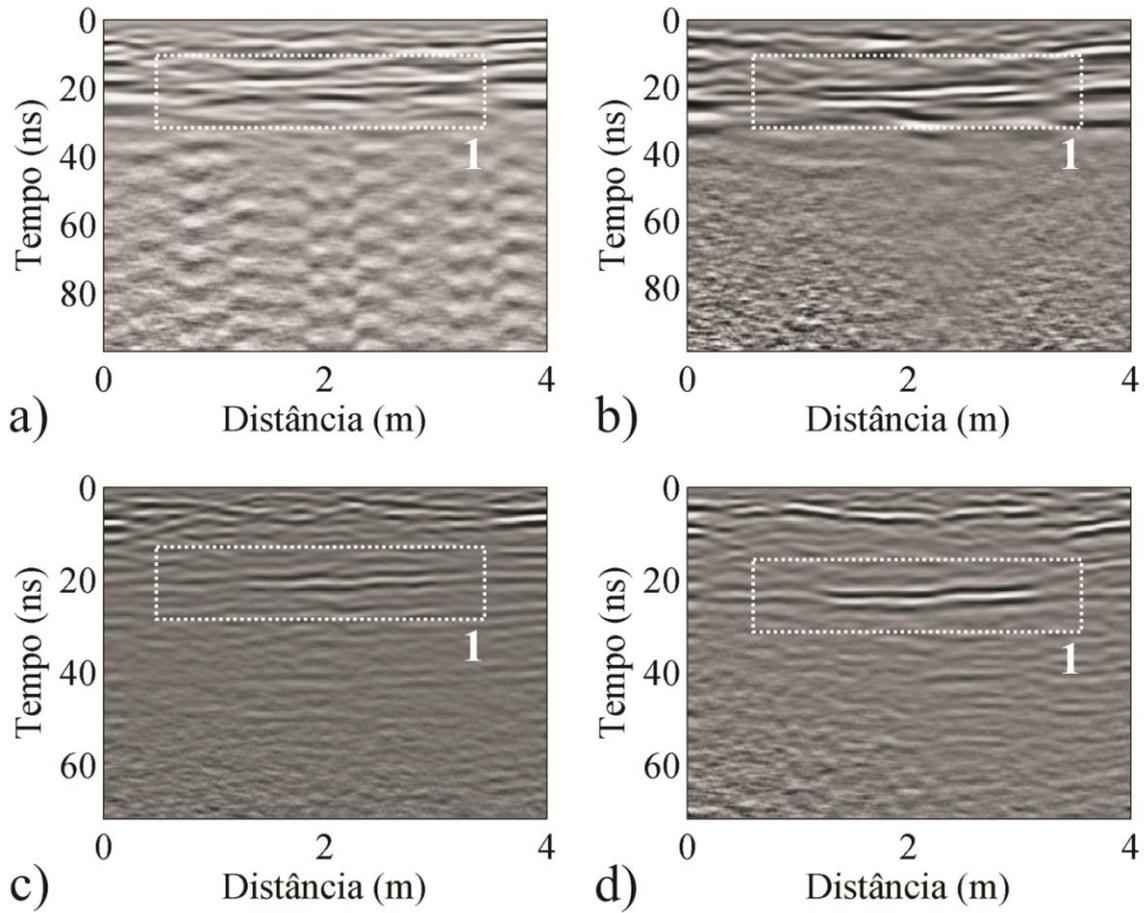


Figura G.7 - Perfis GPR (direção X, alvo 1) sobre a Linha 2 – tubos de PVC. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.

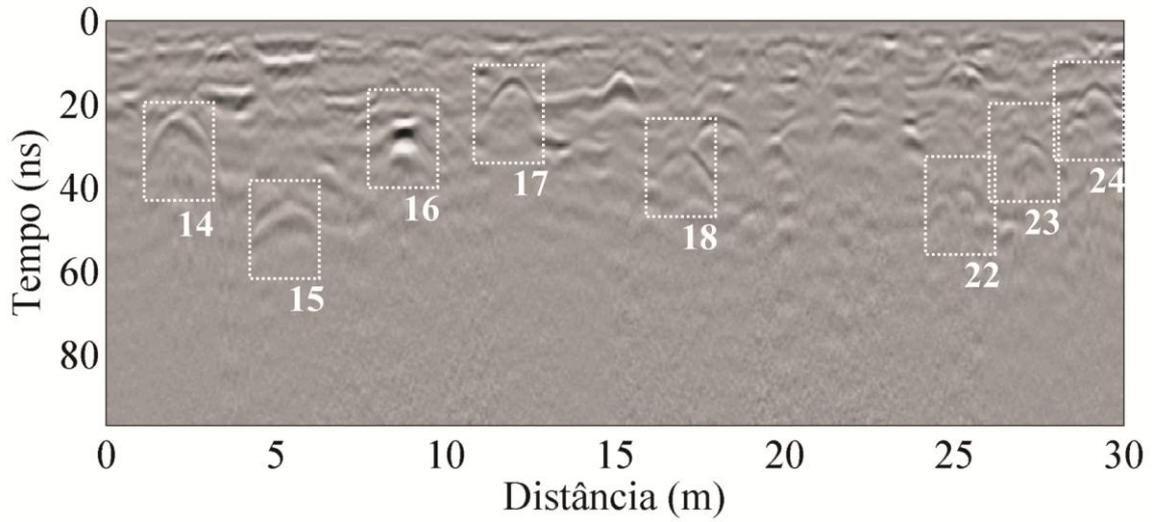


Figura G.8 - Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 200 MHz, em ambiente seco.

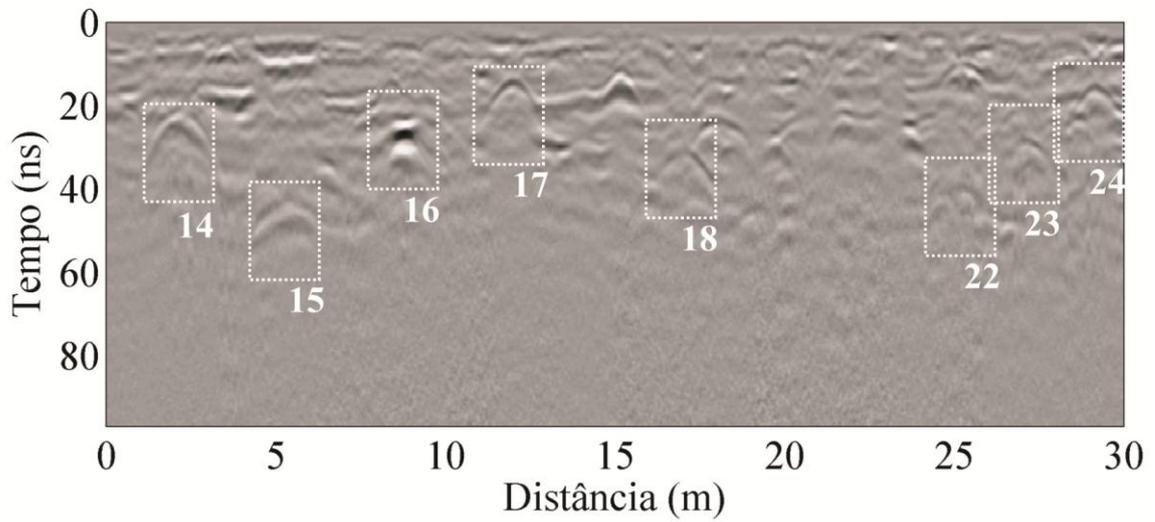


Figura G.9 - Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 200 MHz, em ambiente úmido.

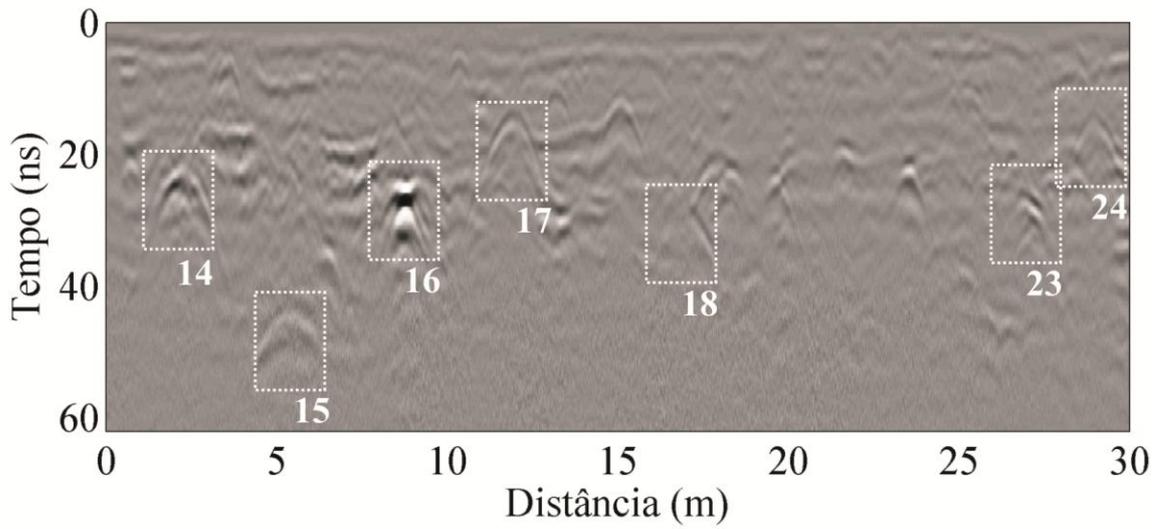


Figura G.10 - Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 270 MHz.

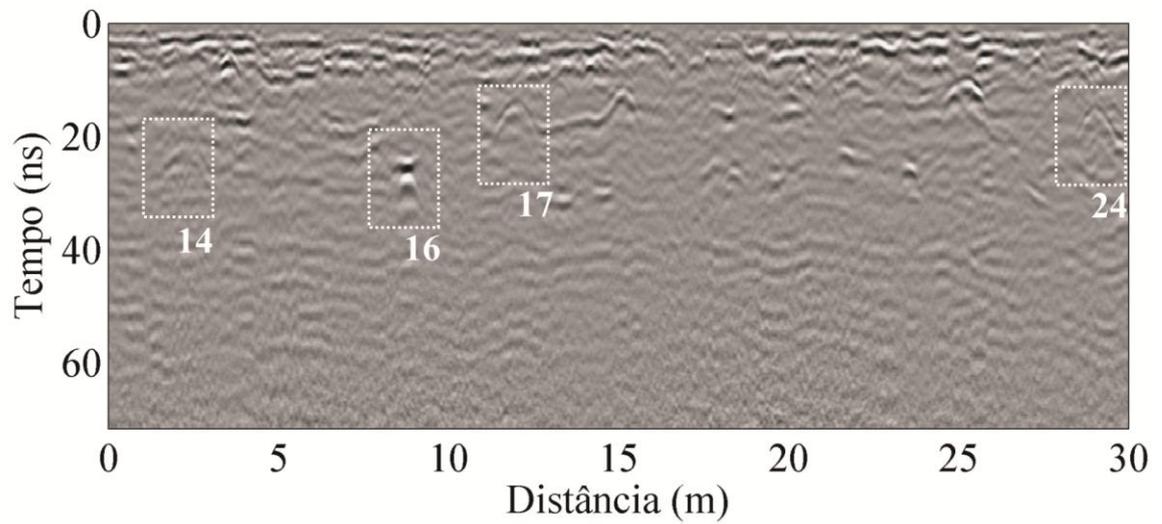


Figura G.11 - Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 400 MHz, em ambiente seco.

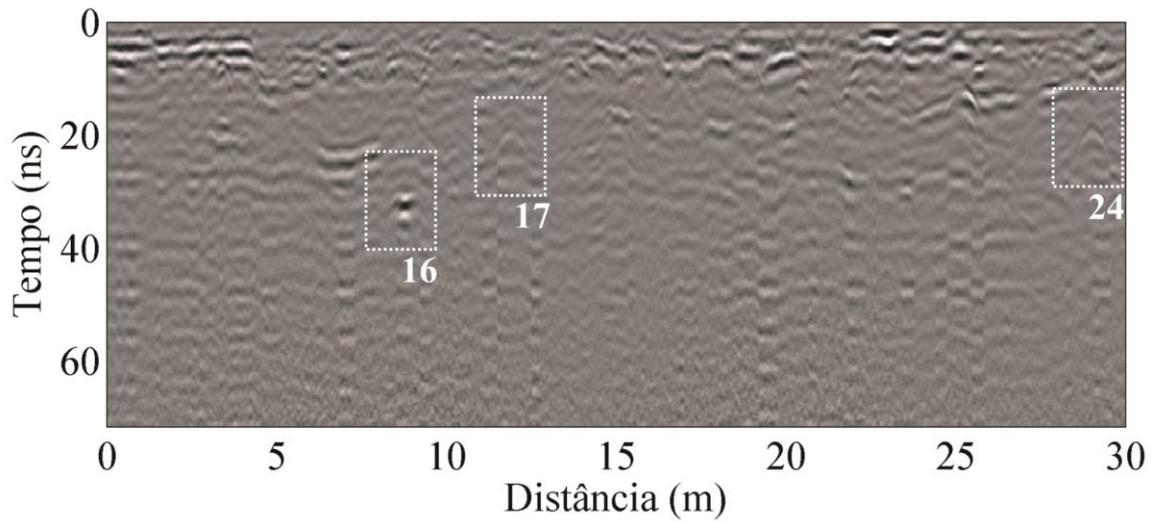


Figura G.12 - Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 400 MHz, em ambiente úmido.

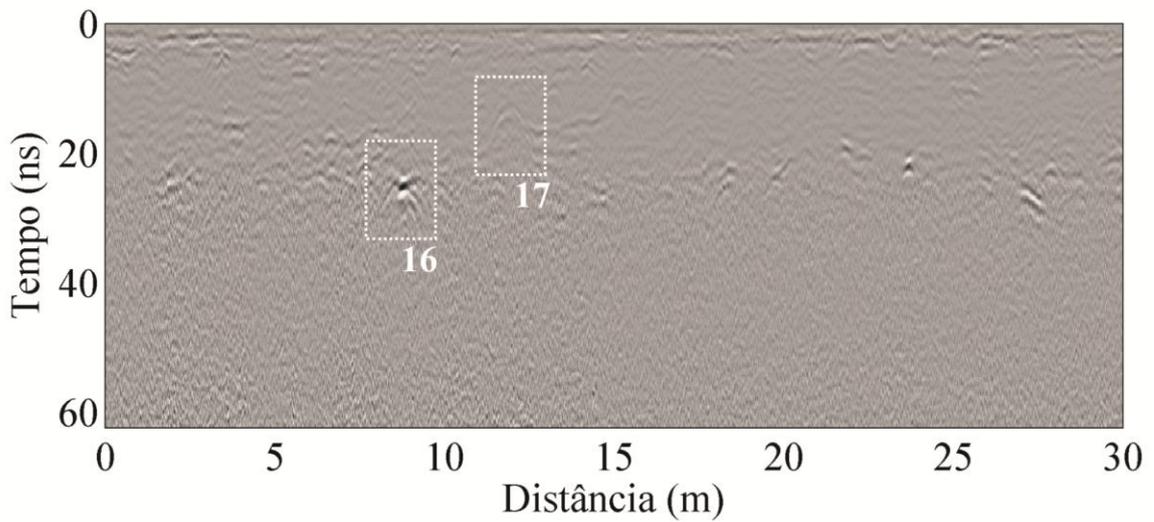


Figura G.13 - Perfil GPR (direção Y) sobre a Linha 3 – manilhas de concreto utilizando antena de 900 MHz.

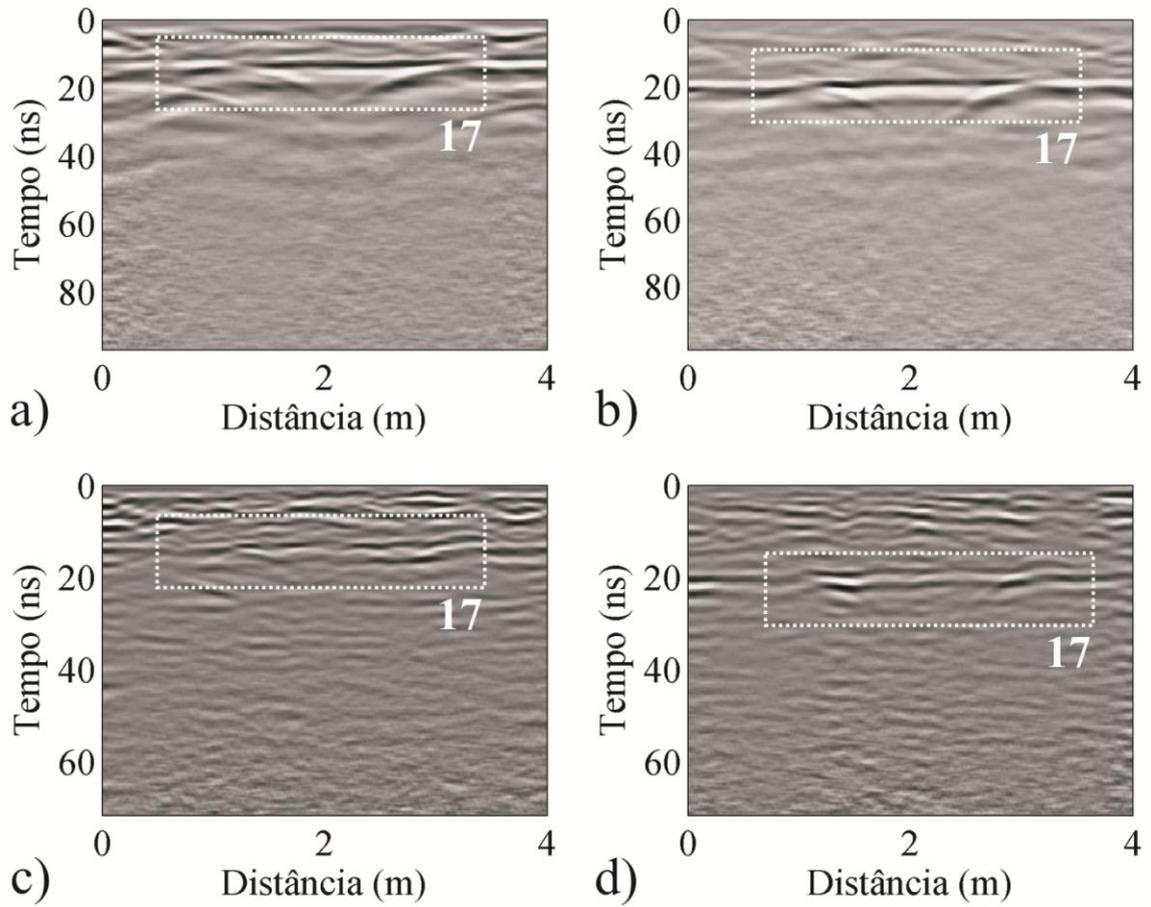


Figura G.14 - Perfis GPR (direção X, alvo 17) sobre a Linha 3 – manilhas de concreto. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.

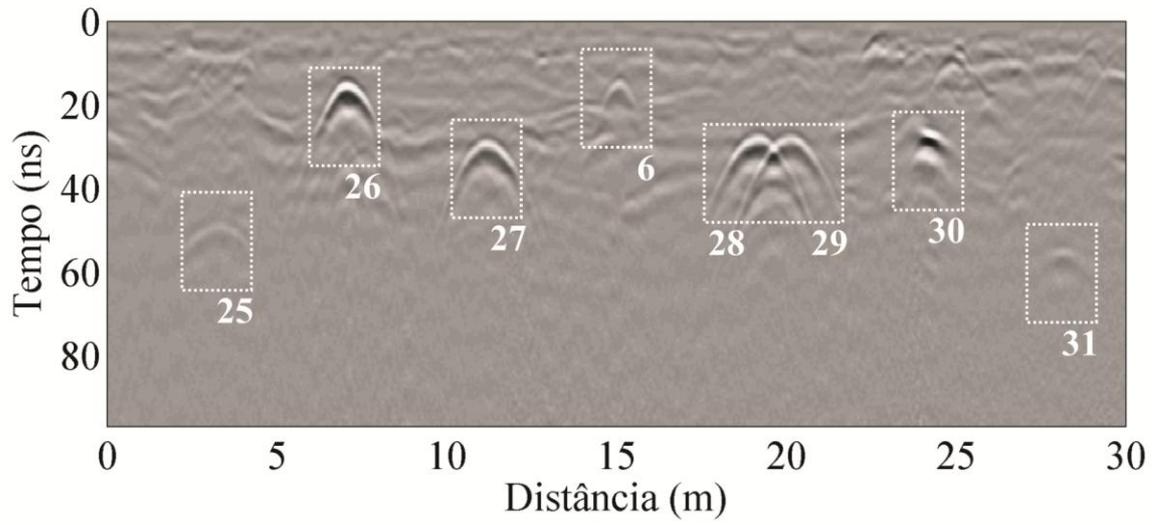


Figura G.15 - Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 200 MHz, em ambiente seco.

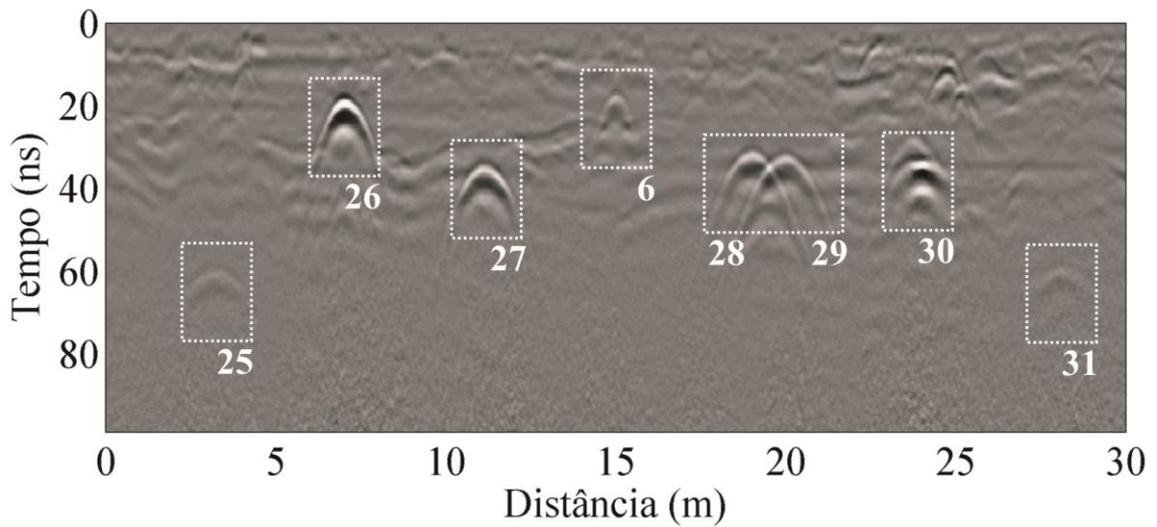


Figura G.16 - Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 200 MHz, em ambiente úmido.

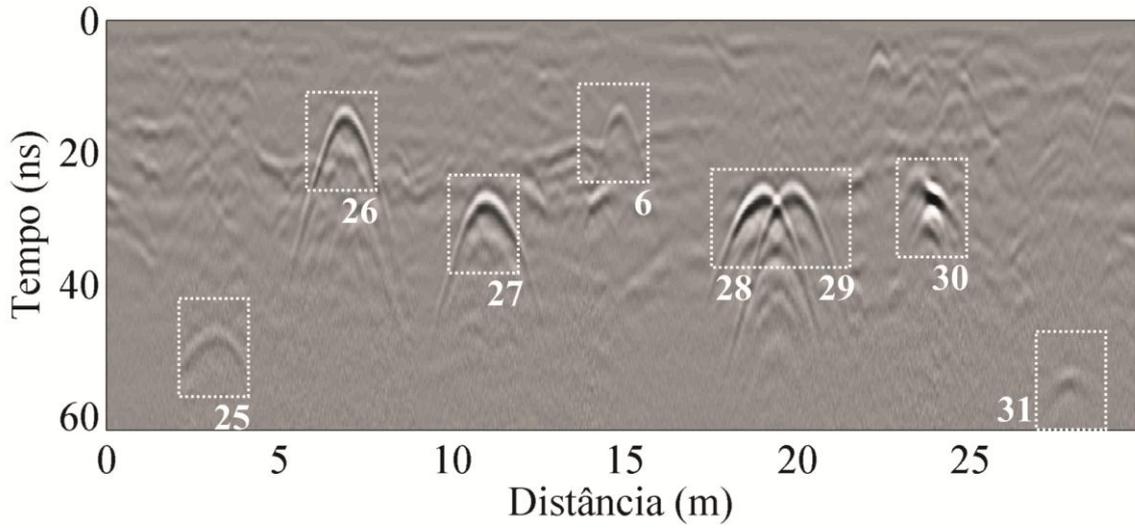


Figura G.17 - Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 270 MHz.

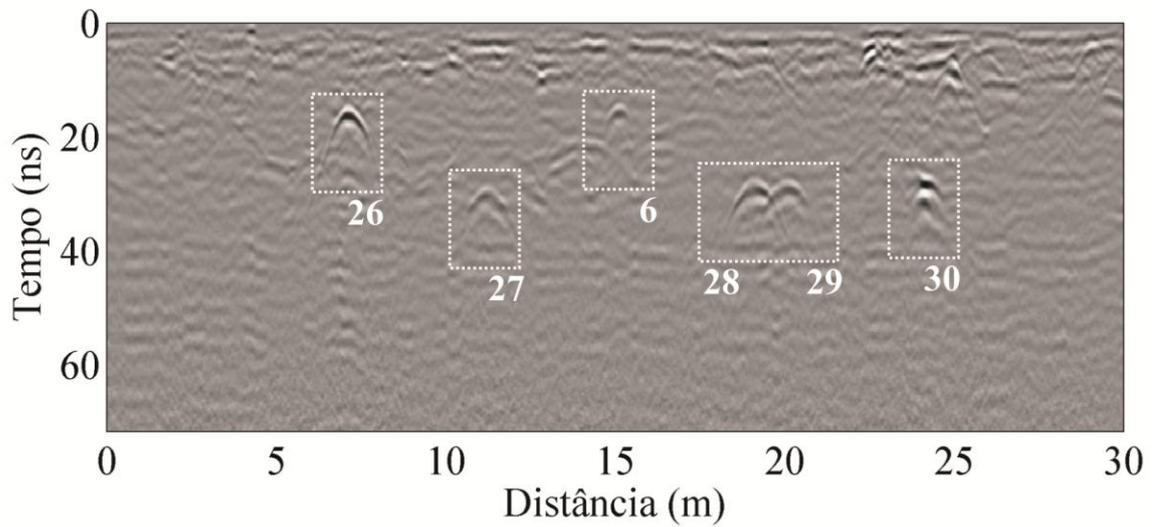


Figura G.17 - Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 400 MHz, em ambiente seco.

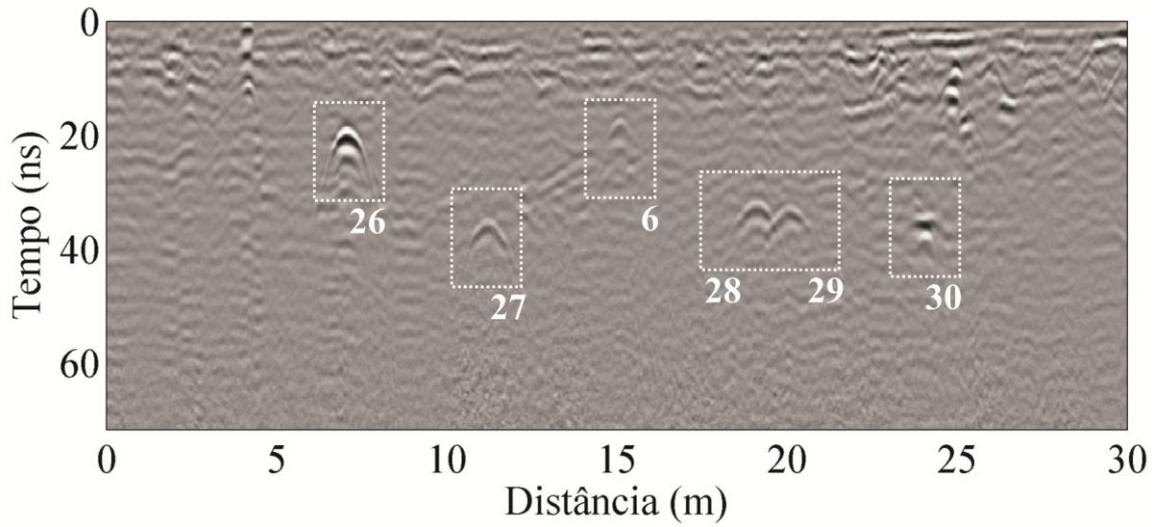


Figura G.18 - Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 400 MHz, em ambiente seco.

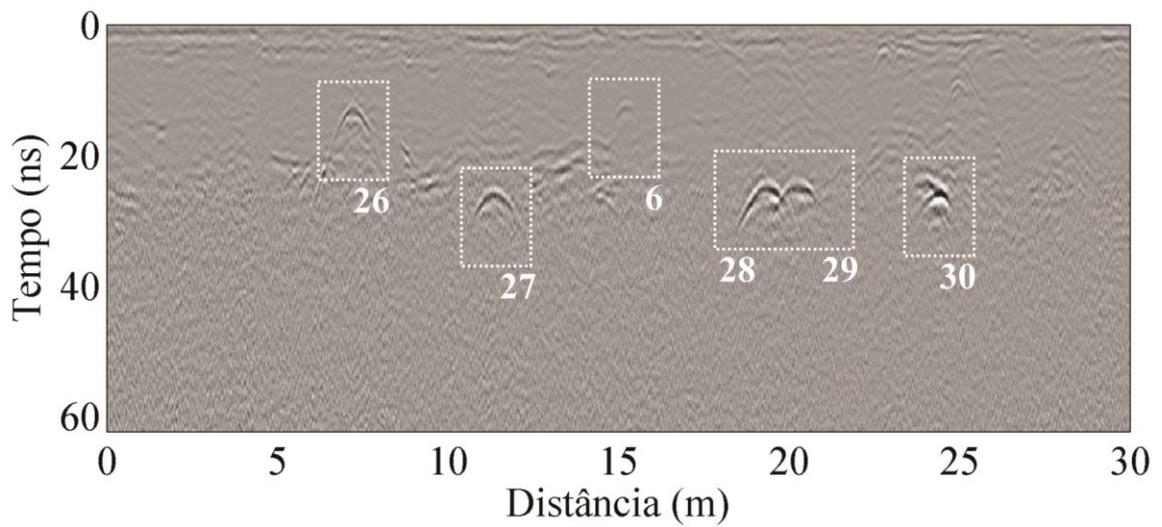


Figura G.19 - Perfil GPR (direção Y) sobre a Linha 4 – tambores metálicos utilizando antena de 900 MHz.

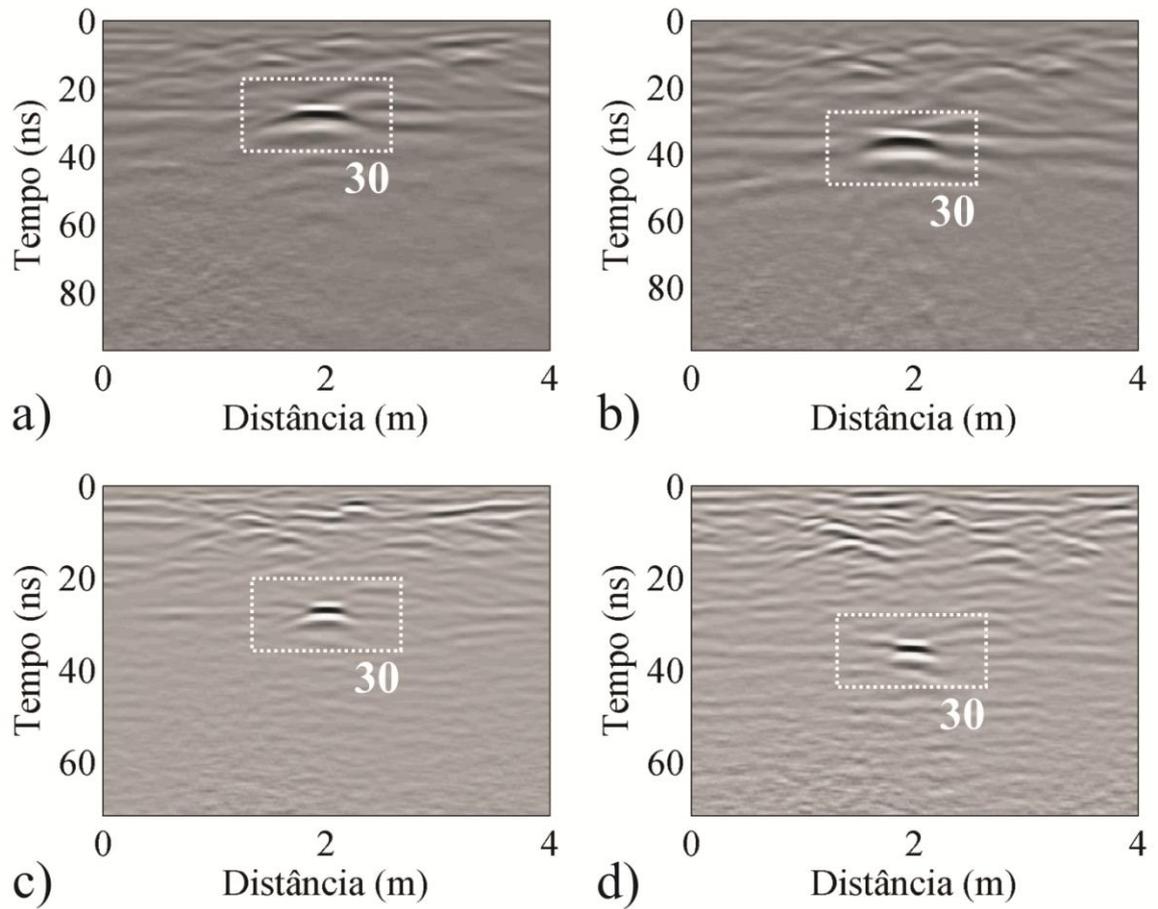


Figura G.20 - Perfis GPR (direção X, alvo 30) sobre a Linha 4 – tambores metálicos. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.

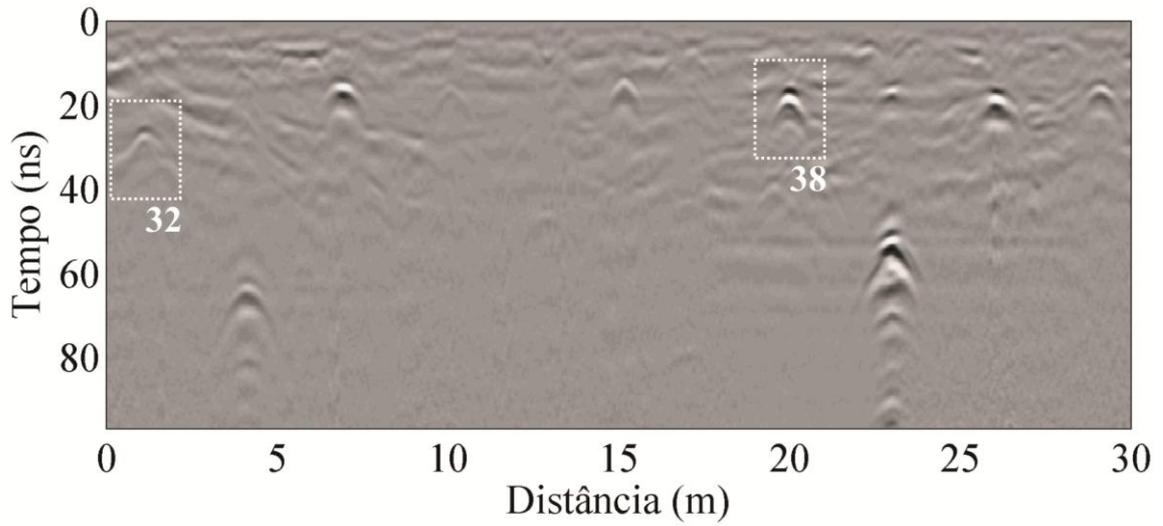


Figura G.21 - Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 200 MHz, em ambiente seco.

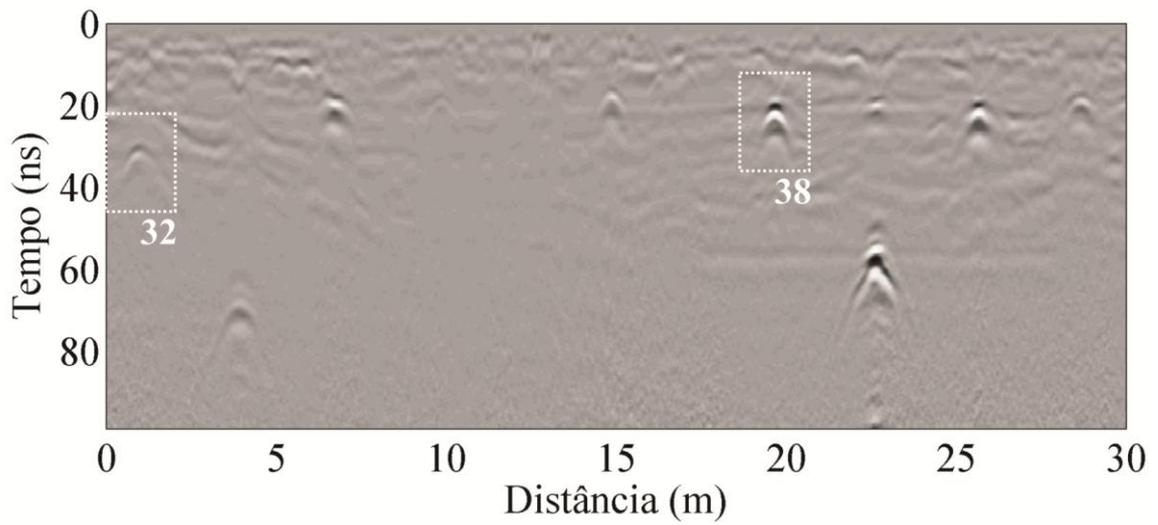


Figura G.22 - Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 200 MHz, em ambiente úmido.

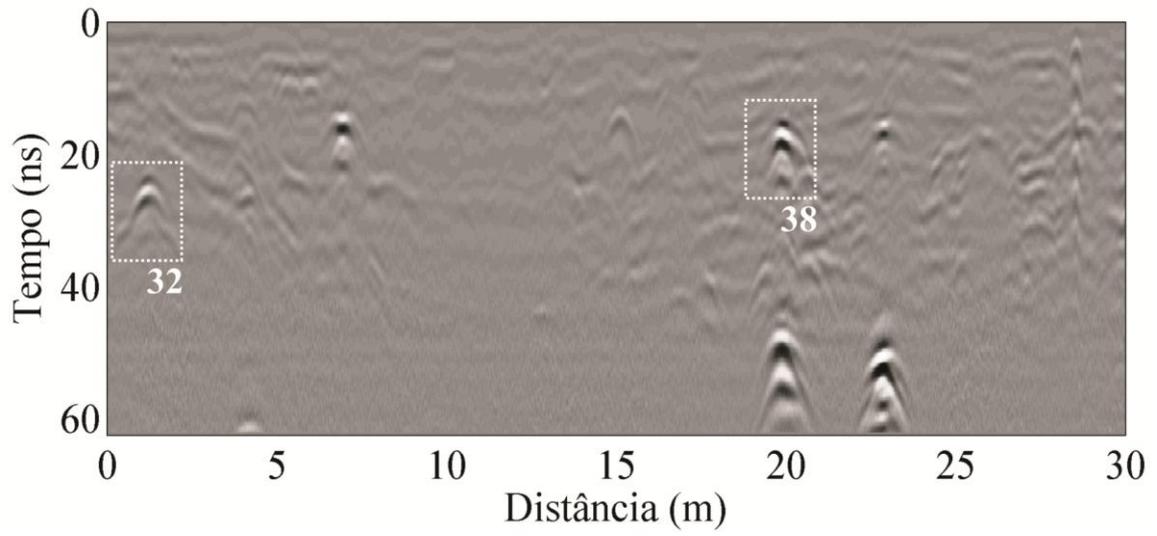


Figura G.23 - Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 270 MHz.

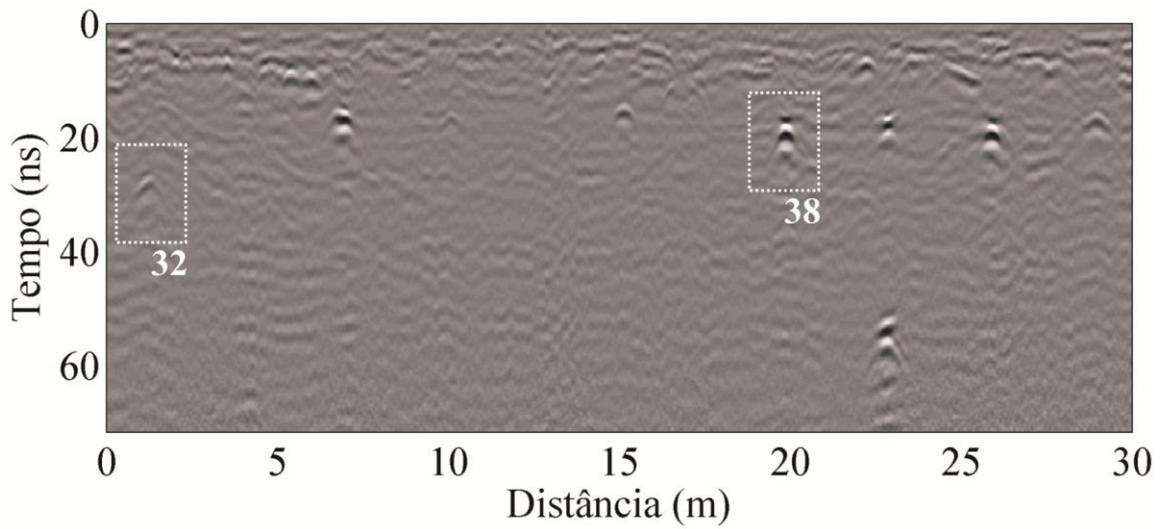


Figura G.24 - Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 400 MHz, em ambiente seco.

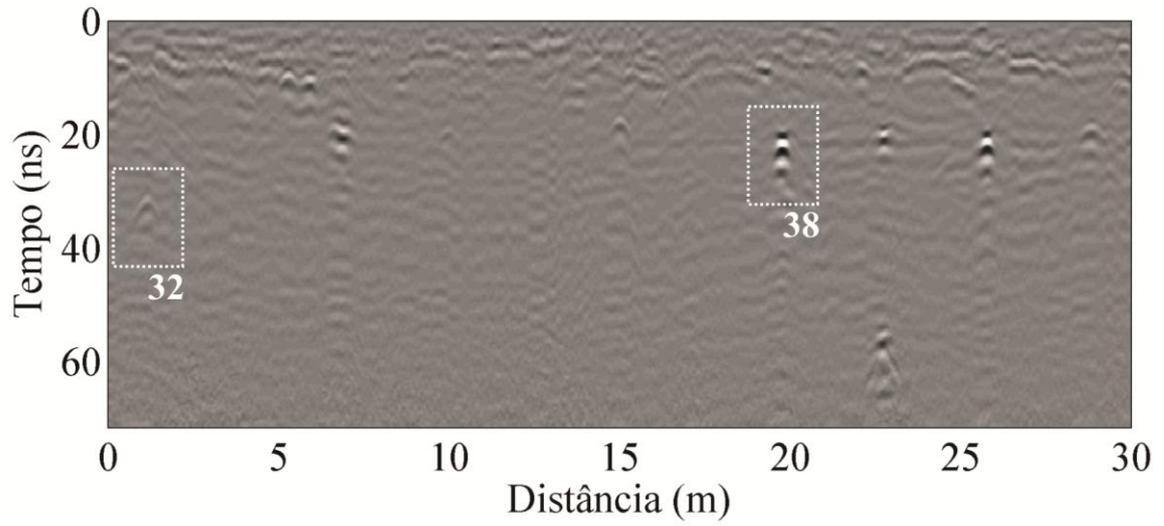


Figura G.25 - Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 400 MHz, em ambiente úmido.

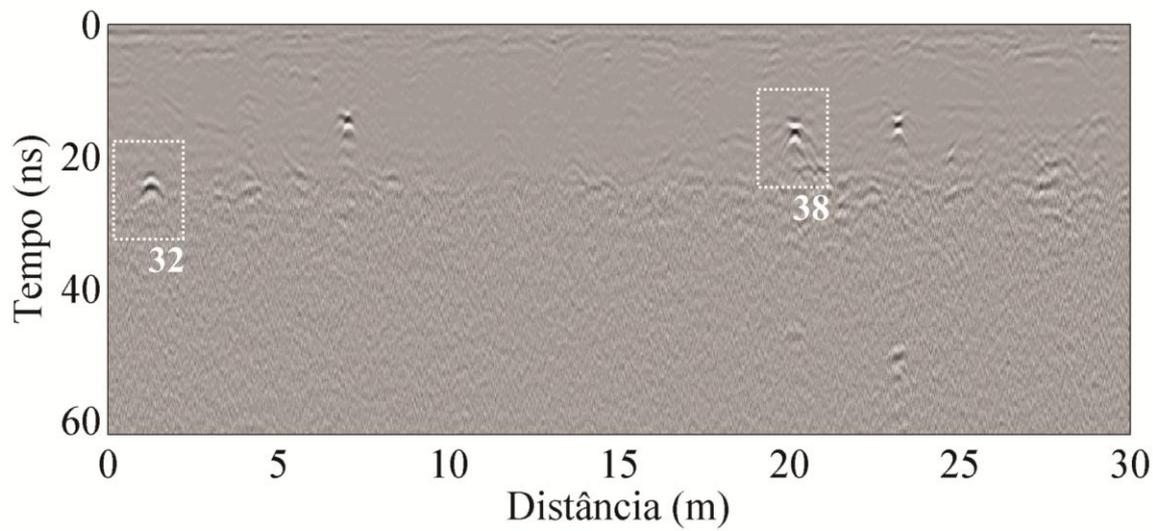


Figura G.26 - Perfil GPR (direção Y) sobre a Linha 5 – tambores plásticos utilizando antena de 900 MHz.

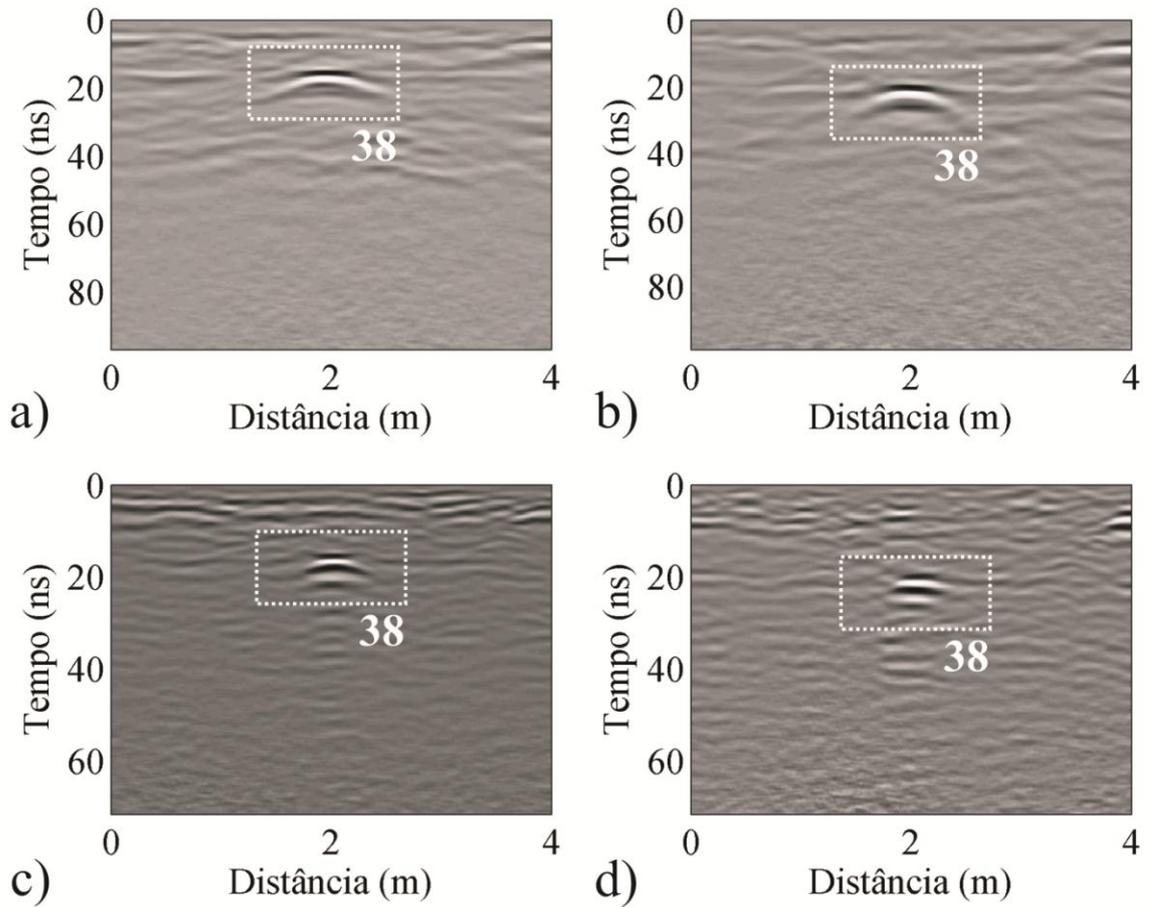


Figura G.27 - Perfis GPR (direção X, alvo 38) sobre a Linha 5 – tambores plásticos. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.

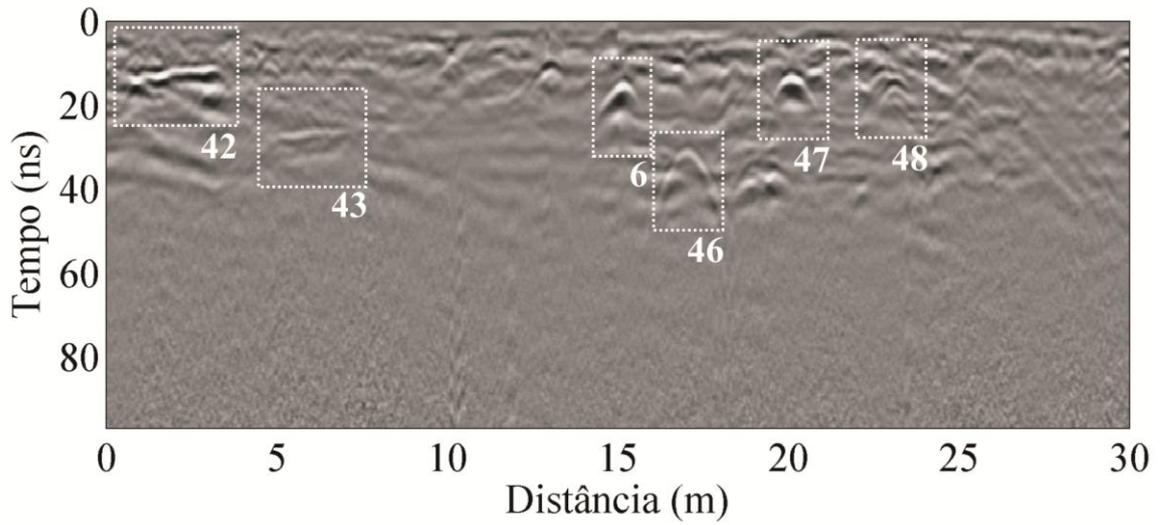


Figura G.28 - Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 200 MHz, em ambiente seco.

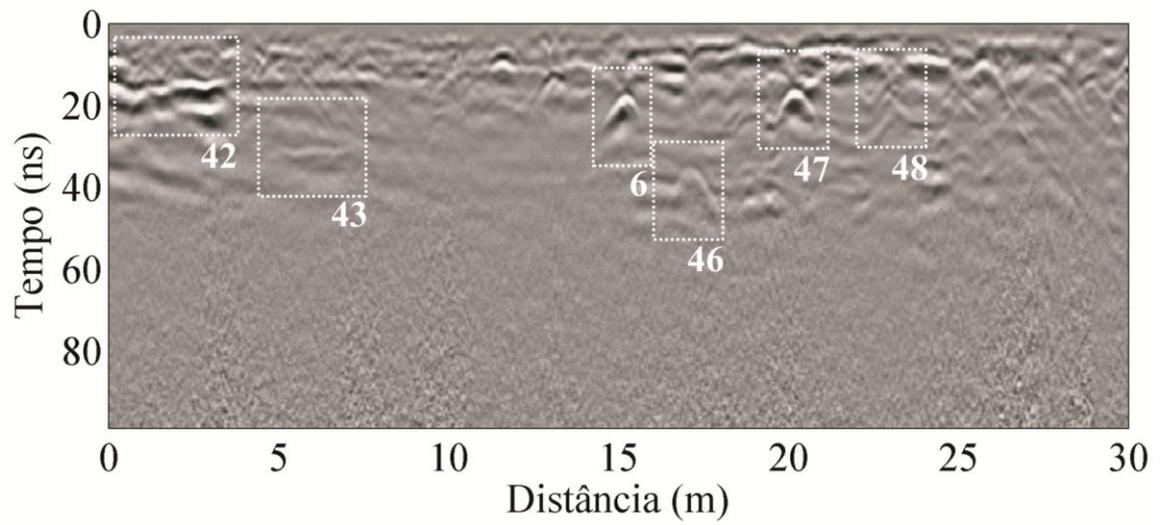


Figura G.29 - Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 200 MHz, em ambiente úmido.

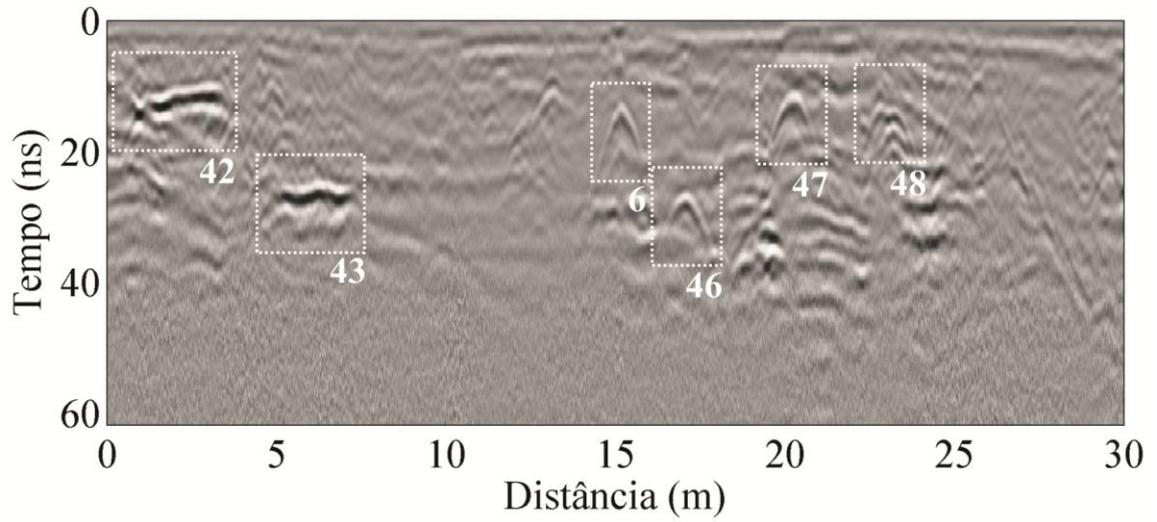


Figura G.30 - Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 270 MHz.

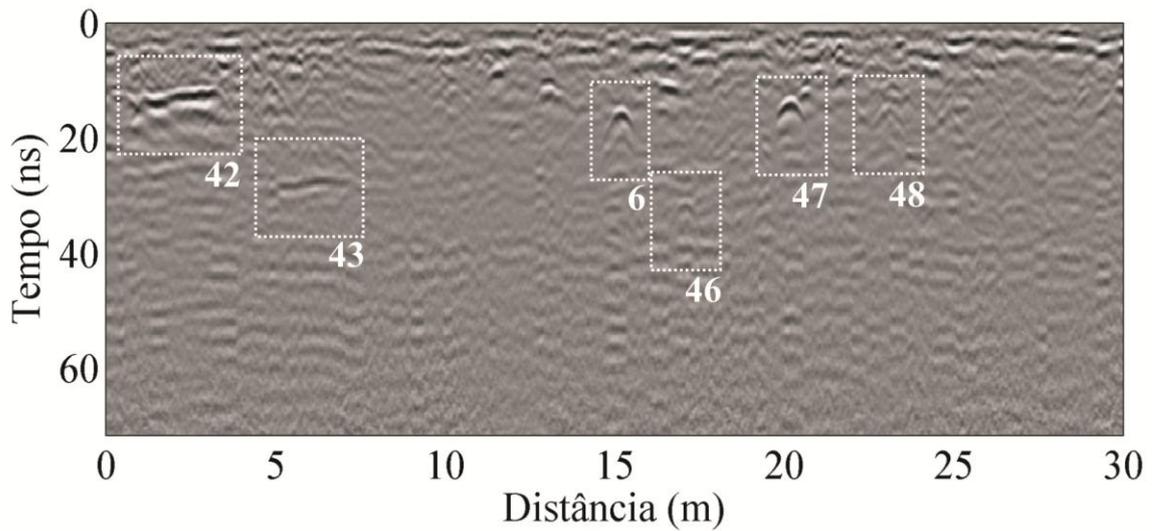


Figura G.31 - Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 400 MHz, em ambiente seco.

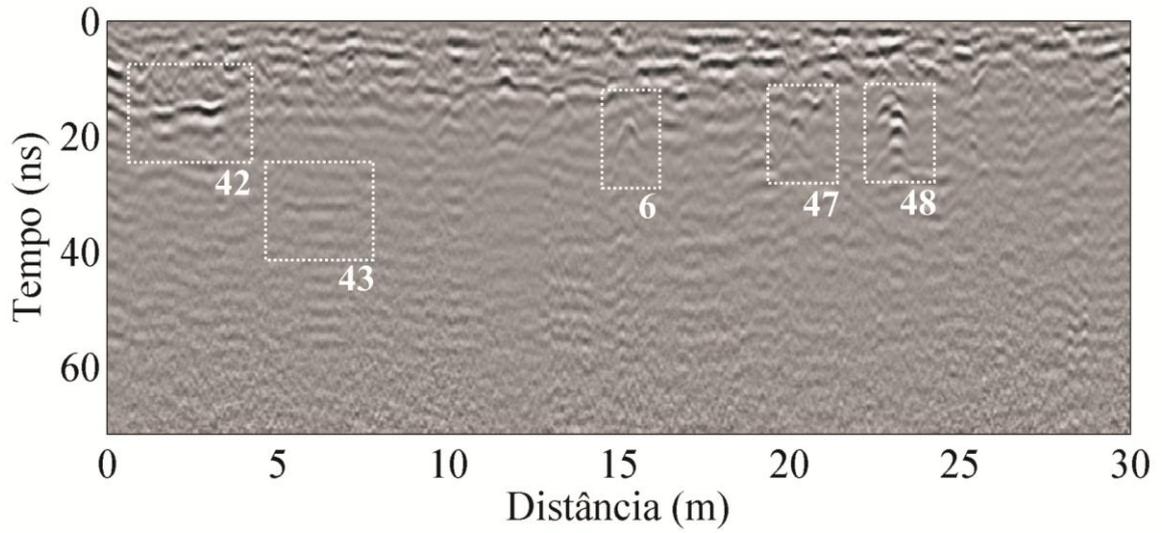


Figura G.32 - Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 400 MHz, em ambiente úmido.

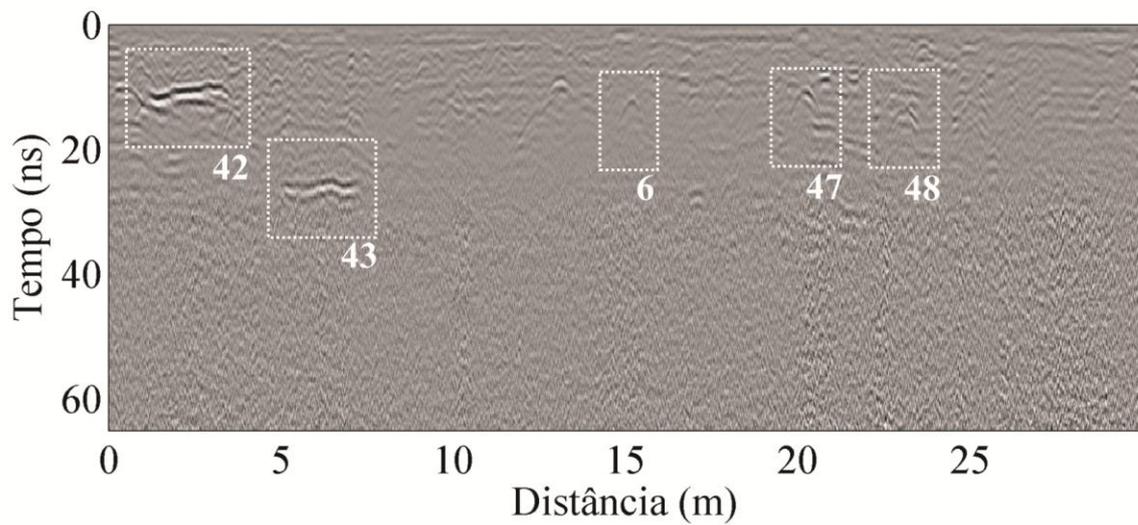


Figura G.33 - Perfil GPR (direção Y) sobre a Linha 6 – tubos metálicos utilizando antena de 900 MHz.

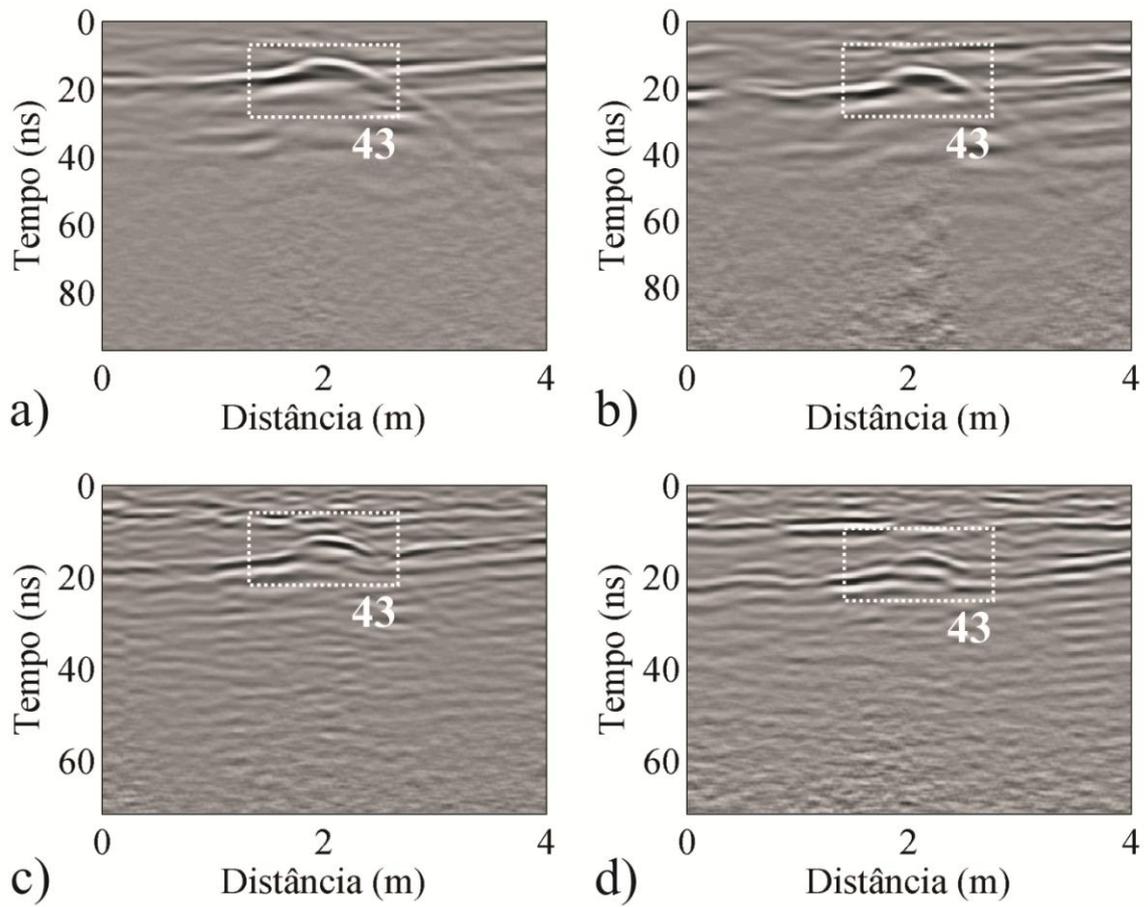


Figura G.34 - Perfis GPR (direção X, alvo 43) sobre a Linha 6 – tubos metálicos. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.

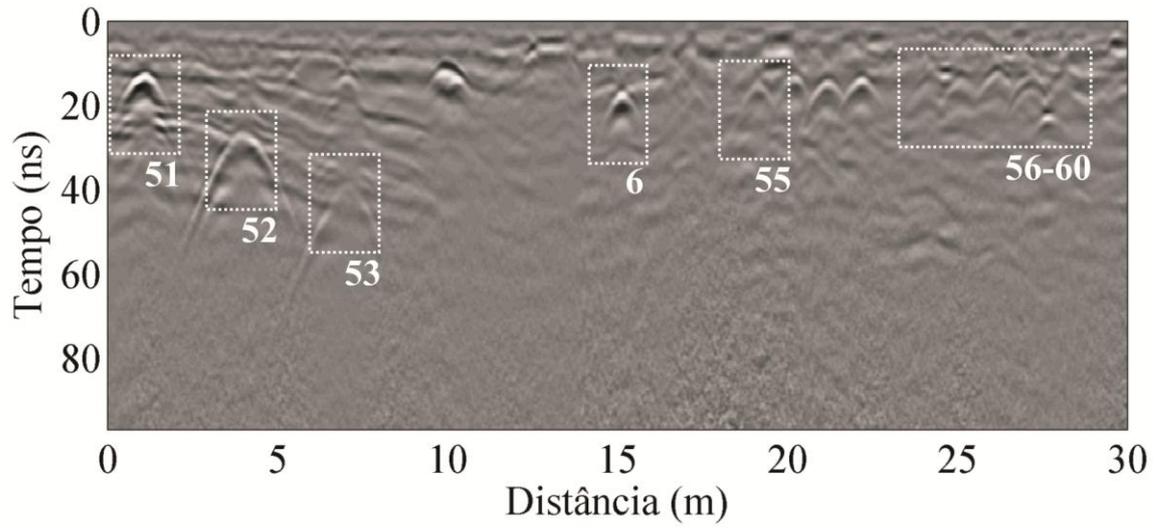


Figura G.35 - Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 200 MHz, em ambiente seco.

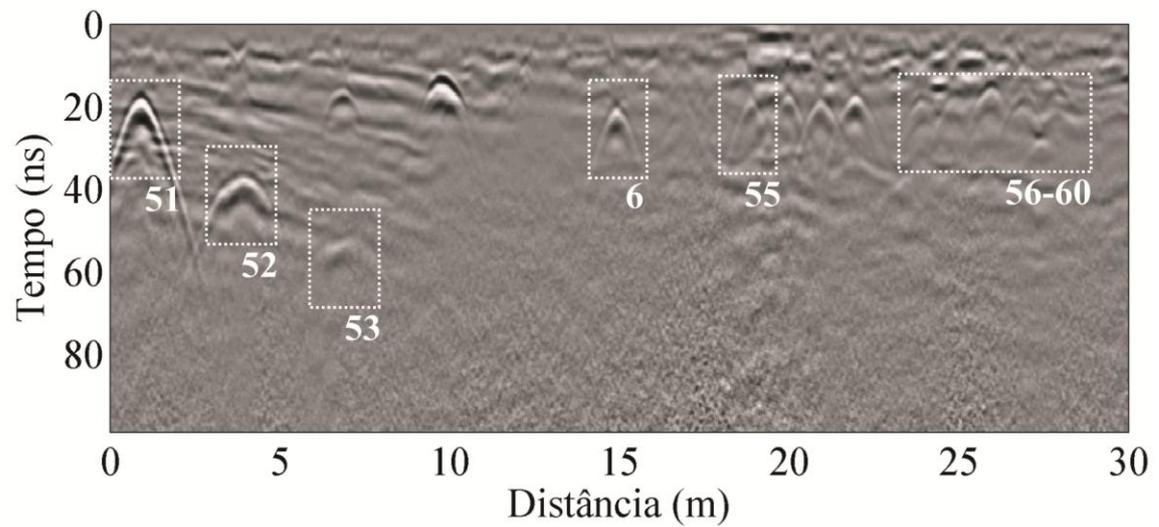


Figura G.36 - Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 200 MHz, em ambiente úmido.

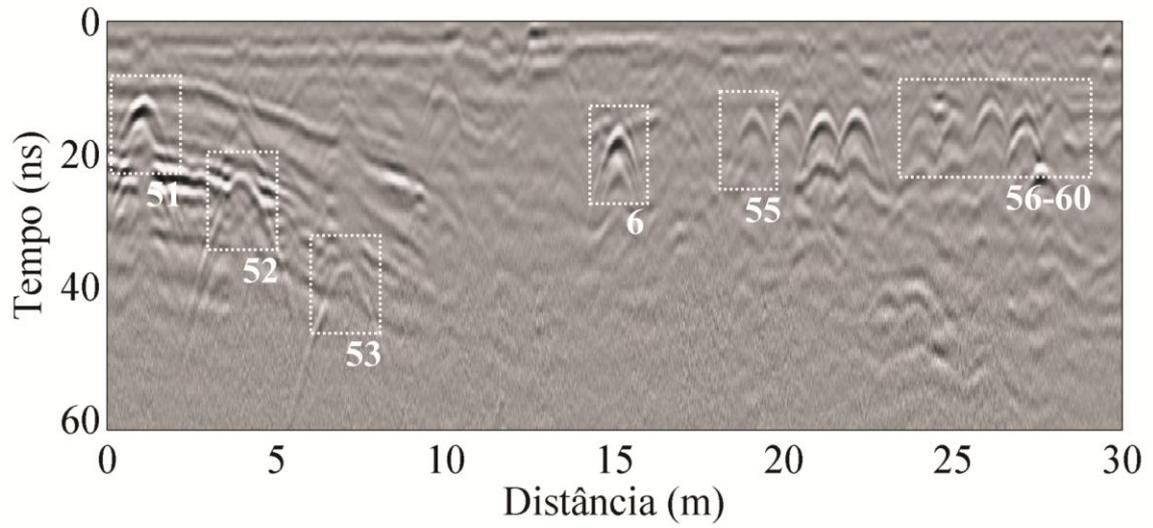


Figura G.37 - Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 270 MHz.

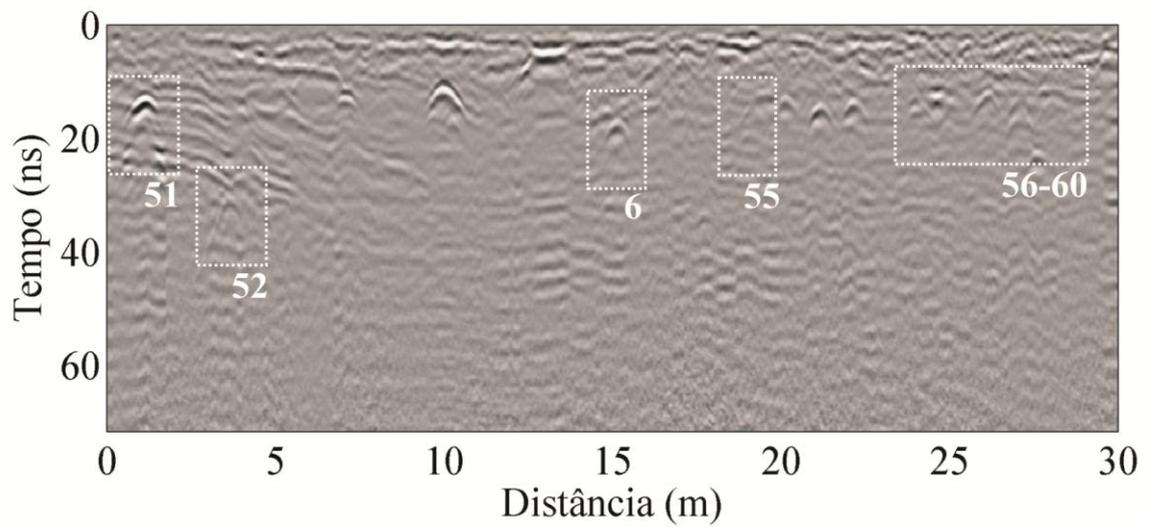


Figura G.38 - Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 400 MHz, em ambiente seco.

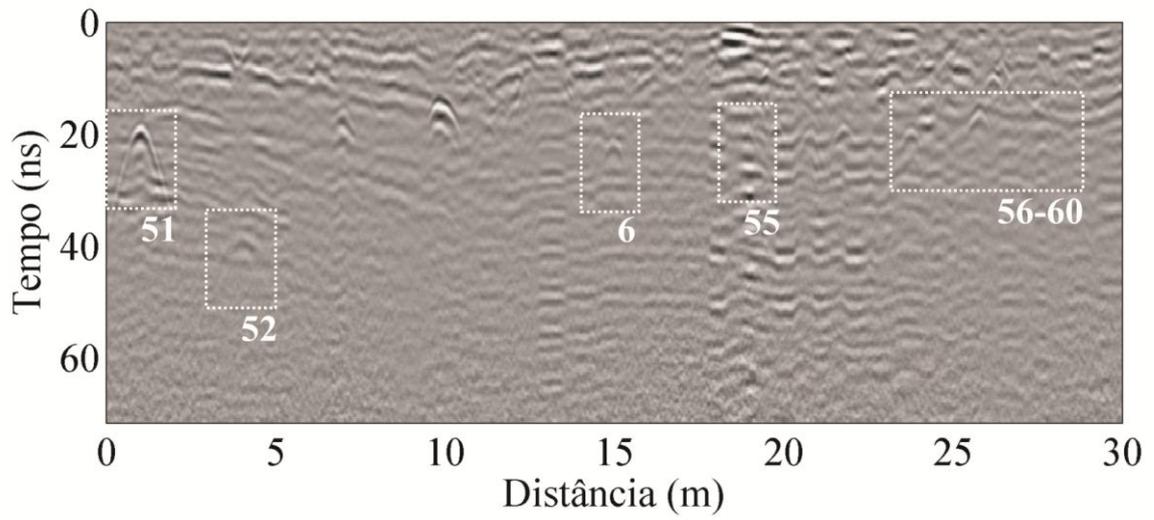


Figura G.39 - Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 400 MHz, em ambiente úmido.

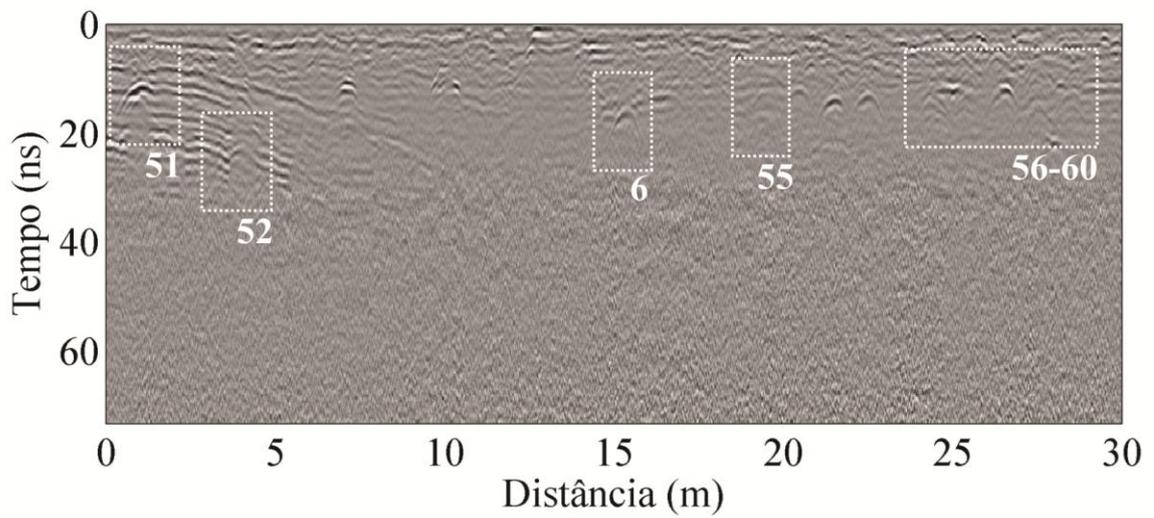


Figura G.40 - Perfil GPR (direção Y) sobre a Linha 7 – tubos metálicos e cabos elétricos utilizando antena de 900 MHz.

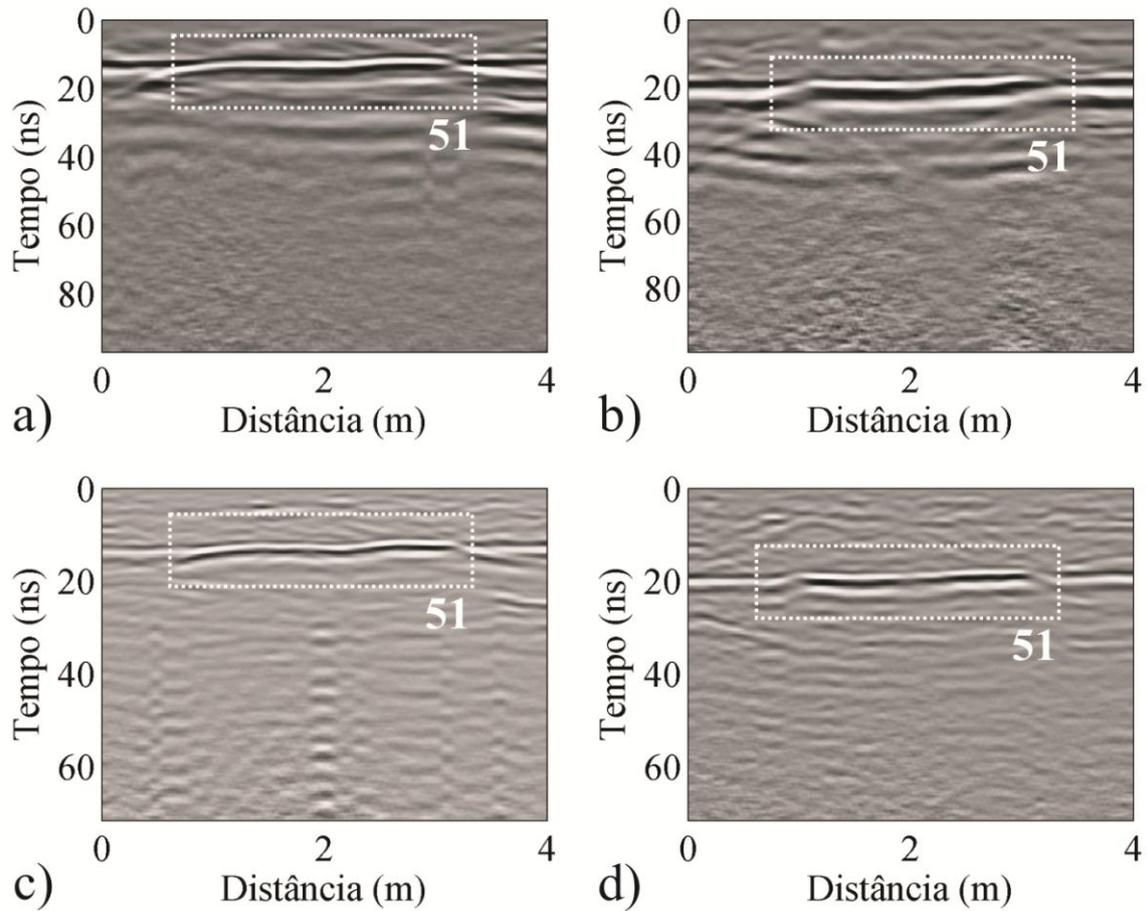


Figura G.41 - Perfis GPR (direção X, alvo 51) sobre a Linha 7 – tubos metálicos e cabos elétricos. a) antena de 200 MHz em ambiente seco. b) antena de 200 MHz em ambiente úmido. c) antena de 400 MHz em ambiente seco. d) antena de 400 MHz em ambiente úmido.

APÊNDICE H: PRODUÇÕES BIBLIOGRÁFICAS

H.1 Artigo Publicado na *Journal of Applied Geophysics*: “**Spectral analysis of ground penetrating radar signals in concrete, metallic and plastic targets**”.

Autores:

M.Sc. Vinicius Rafael Neris dos Santos – IAG/USP

Prof. Dr. Waleed Al-Nuaimy – Universidade de Liverpool

Prof. Dr. Jorge Luís Porsani – IAG/USP

Prof. Dra. Nina S. T. Hirata – IME/USP

M.Sc. Hamzah S. Alzubi – Universidade de Liverpool

Journal of Applied Geophysics

Disponível *online*: 24 de Outubro de 2013

DOI: 10.1016/j.jappgeo.2013.10.002

Volume: 100 (2014)

Páginas: 32-43

H.2 Resumo expandido: XIII *International Conference on Ground Penetrating Radar* (GPR2010, Lecce, Itália): “**Automatic classification of metallic targets using pattern recognition of GPR reflection: a study in the IAG-USP Test Site, São Paulo, Brazil**”.

Autores:

M.Sc. Vinicius Rafael Neris dos Santos – IAG/USP

Prof. Dr. Jorge Luís Porsani – IAG/USP

Prof. Dra. Nina S. T. Hirata – IME/USP

H.3 Resumo expandido: 2010 The Meeting of the Americas (AGU2010, Foz do Iguaçu, Brasil): “**Use of Neural Network Methodology Applied to GPR data for Automatic Classification of Metallic and Plastic Targets buried at IAG/USP Geophysical Test Site, São Paulo, Brazil**”.

Autores:

M.Sc. Vinicius Rafael Neris dos Santos – IAG/USP

Prof. Dr. Jorge Luís Porsani – IAG/USP

Prof. Dra. Nina S. T. Hirata – IME/USP

H.4 Resumo expandido: 17th *European Meeting of Environmental and Engineering Geophysics of the Near Surface Geoscience Division of EAGE* (NSG2011, Leicester, Inglaterra): “**Automatic classification of metallic, plastic and concrete targets buried at IAG/USP geophysical test site using ANN and GPR methodologies**”.

Autores:

M.Sc. Vinicius Rafael Neris dos Santos – IAG/USP

Prof. Dr. Jorge Luís Porsani – IAG/USP

Prof. Dra. Nina S. T. Hirata – IME/USP