UNIVERSIDADE DE SÃO PAULO

INSTITUTO DE ASTRONOMIA, GEOFÍSICA E CIÊNCIAS ATMOSFÉRICAS

DEPARTAMENTO DE GEOFÍSICA

Curso 3ª Idade

“Radar de Penetração no Solo e Meio-Ambiente”

Vinicius Rafael Neris dos Santos

SUMÁRIO

I - Radar de Penetração no Solo – aplicações

II - Aplicações do método de RNAs

III – Motivação – inspiração biológica

IV – Introdução Histórica

V – Redes Neurais Artificiais

VI – Aplicação no método GPR

Radar de Penetração no Solo - aplicações

Arqueologia

Agricultura

Arqueologia / Contaminação

Contaminação

Contaminação

Engenharia

Engenharia

Engenharia

Geologia

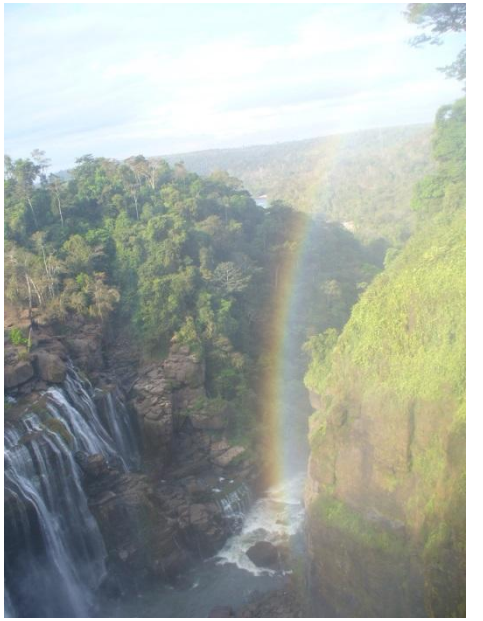

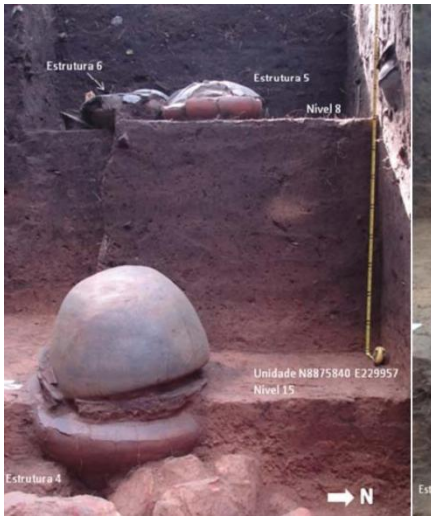

Arqueologia

Geologia

Contaminação

Forense

Forense

Contaminação

Engenharia

Forence

Forense

Como identificar o alvo num radargrama:

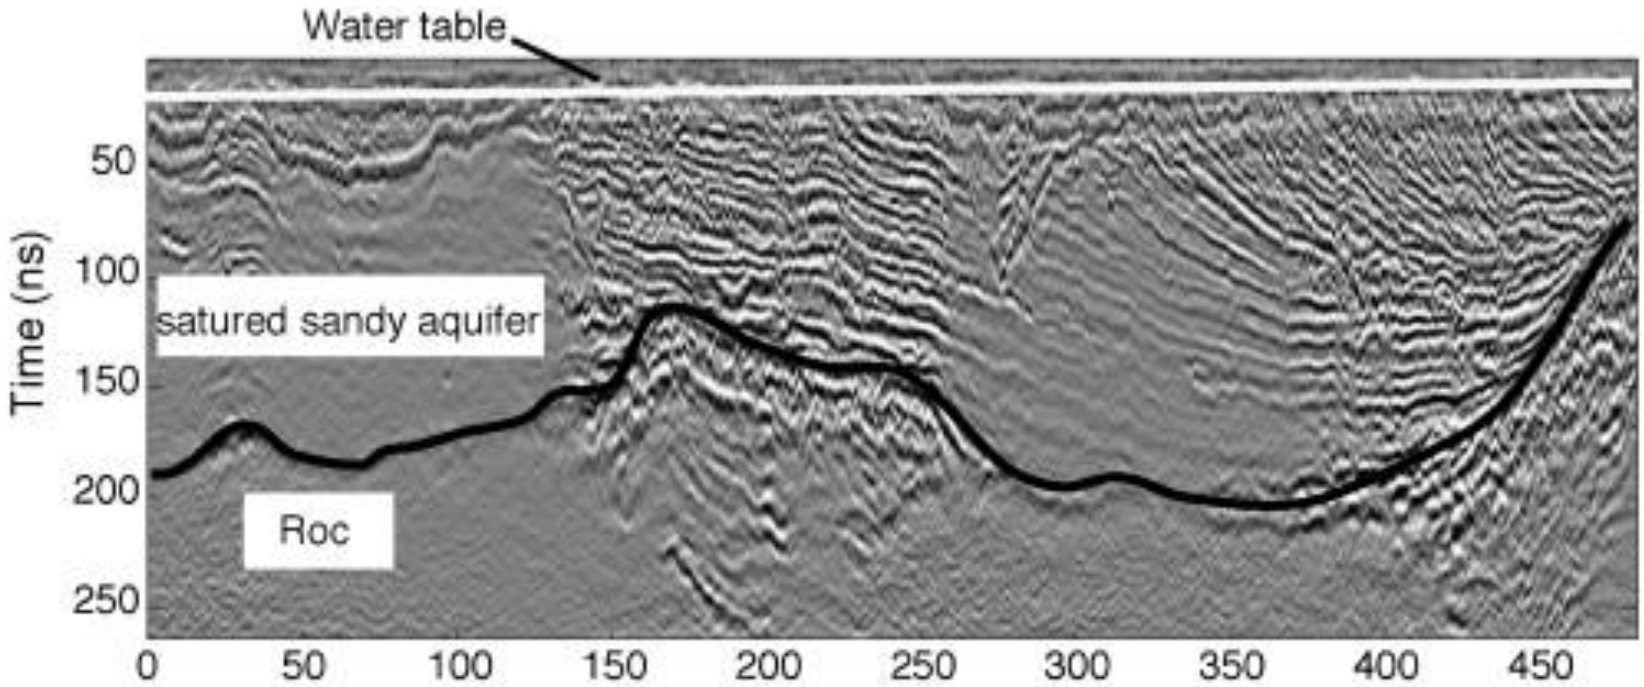

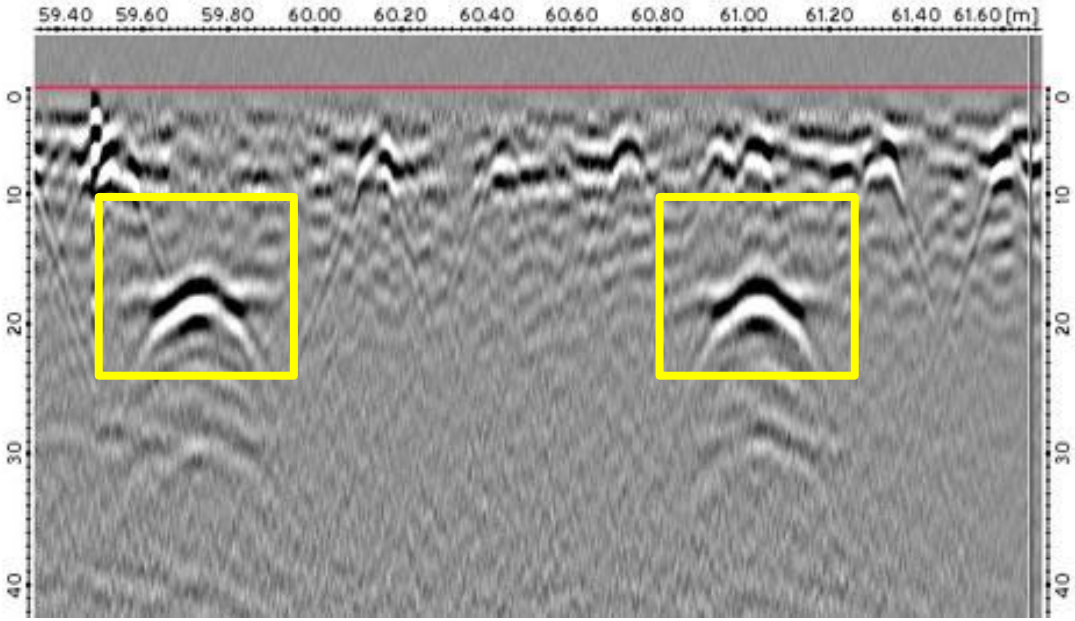

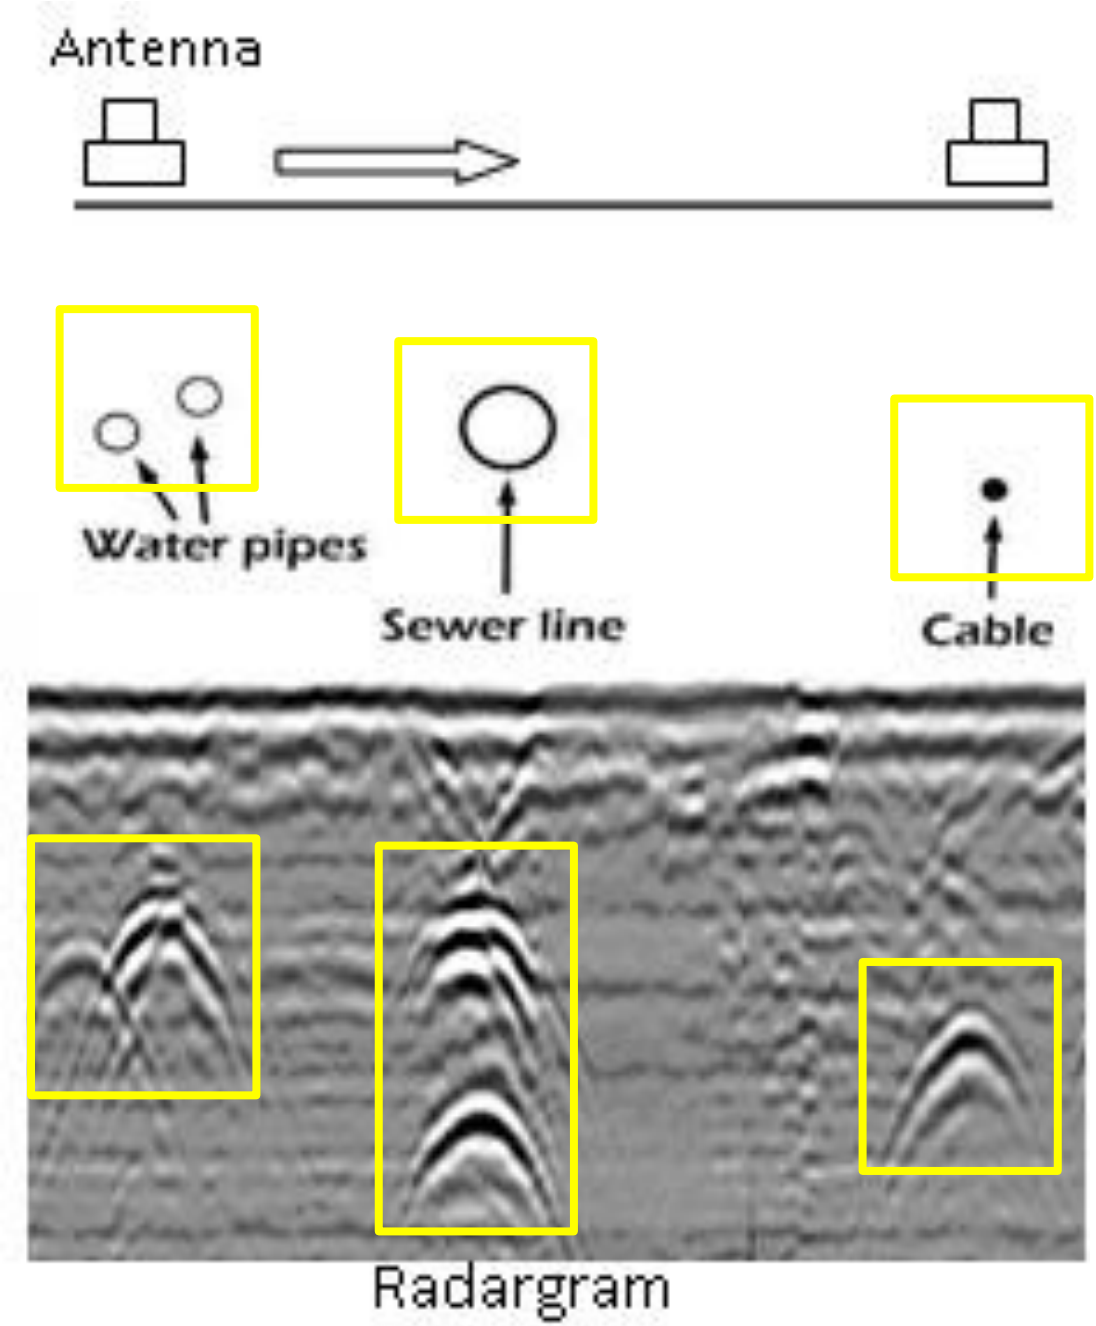
Antenna
Water pipes
Sewer line
Cable
Radargram

- ✓ Problema existente no método GPR: ambiguidade (raiz de árvore x artefato arqueológico);
- ✓ Projeto de Doutorado: “Detecção e Classificação Automática de Interferências no Subsolo com GPR Utilizando Redes Neurais Artificiais (RNAs): Estudo no SCGR do IAG/USP”

Por que Redes Neurais Artificiais (RNA)?

- ✓ Capacidade de aprender por meio de exemplos;
- ✓ Ferramenta computacional de fácil desenvolvimento;
- ✓ Apresenta boa resposta em dados geofísicos.

II – Aplicações do método de RNAs

Tarefas	Algumas aplicações
Classificação	Reconhecimento de caracteres Reconhecimento de imagens Diagnóstico (médico, equipamentos, etc.) Análise de risco de crédito Detecção de fraudes Detecção de falhas em sistemas industriais
Categorização	Agrupamento de sequências de DNA Mineração de dados Análise de expressão gênica Agrupamento de clientes
Previsão	Previsão do tempo Previsão financeira Modelagem de sistemas dinâmicos Previsão de sequências de DNA

Principais tarefas que as RNAs podem executar e algumas aplicações.

Aplicações em Geofísica

- ✓ **JUSTICE *et al.* (1985)**: propuseram uma interpretação de dados sísmicos para prospecção de hidrocarbonetos a partir da análise de padrões, sendo estes analisados por RNA.

- ✓ **NEYAMADPOUR *et al.* (2009)**: realizaram uma inversão 2D de resistividade utilizando redes neurais artificiais.

- ✓ **TRONG LONG HO (2009)**: realizou uma inversão 3D para dados geoelétricos utilizando uma rede neural do tipo *backpropagation*.

- ✓ **ADELI & PANAKKAT (2009)**: desenvolveram uma metodologia para prever a magnitude de terremotos através de uma rede neural probabilística (RNP). O modelo fornece uma boa previsão para os terremotos de magnitude entre 4,5 e 6,0.

- ✓ **AL-NUAIMY *et al.* (2000)**: Uma rede neural foi utilizada para identificar alvos enterrados nos perfis GPR.

III – O que é o RNA? – inspiração biológica

✓ O cérebro humano contém aproximadamente 100 bilhões de neurônios e cada um desses 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 Redes Neurais Artificiais (RNAs).

- ✓ Um neurônio biológico típico é composto por um corpo celular, um axônio tubular e várias ramificações conhecidas como dendritos.

- ✓ O número de sinais recebidos por cada neurônio varia de 100 a 100.000, sendo que eles podem ser tanto excitatórios como inibitórios.

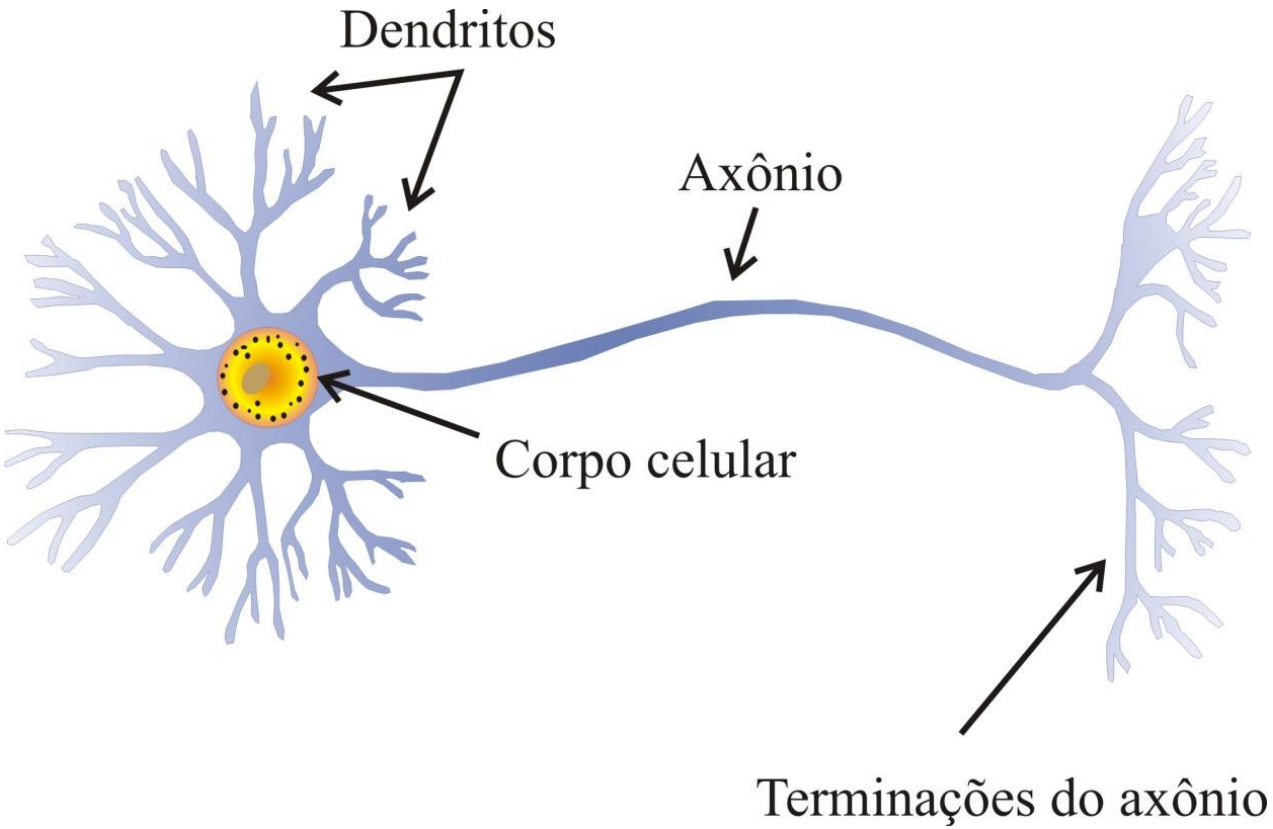

Dendritos – Ramificações correspondentes aos canais de entrada de informação (sinais elétricos, escala mVolt = 1/1000 Volt);

Corpo celular – Local onde é feito o balanço energético da célula nervosa (soma das contribuições de energia);

Axônio – Canal de saída do neurônio, ou seja, caminho de propagação dos impulsos nervosos em direção a outros neurônios ou músculos;

Sinapses – Pontos de contato entre neurônios onde há passagem de neurotransmissores das terminações do axônio de um neurônio para os dendritos de outro neurônio.

O fluxo da informação ocorre sempre no sentido:

Dendritos ➔ Corpo Celular s ➔ Axônio

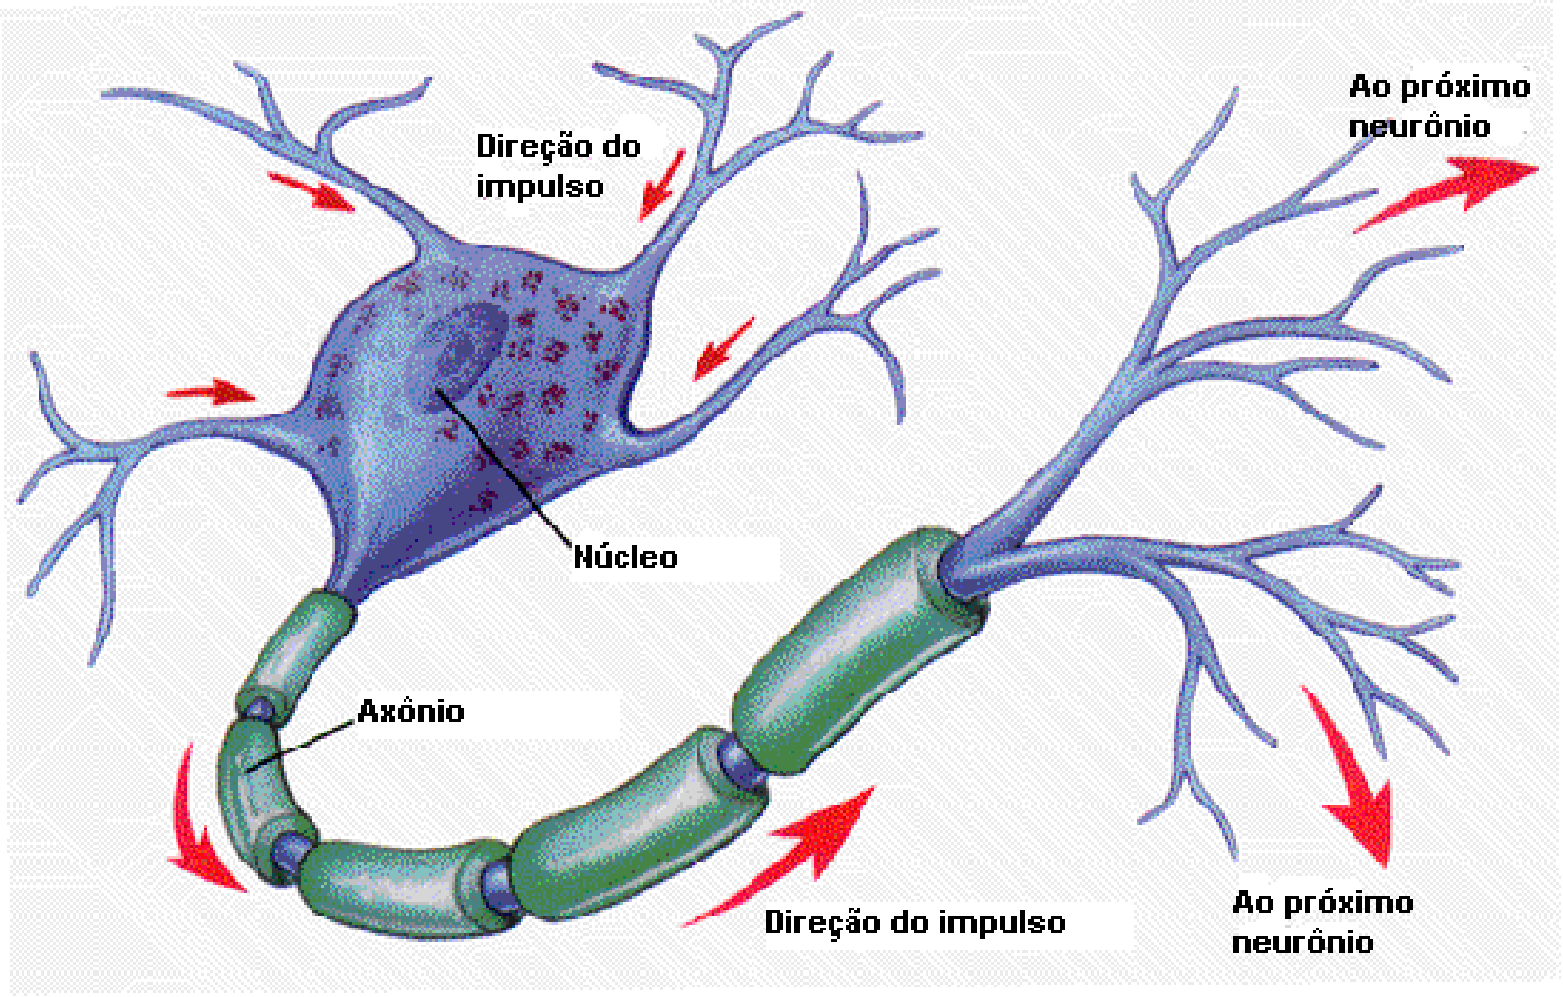

Neurônios podem se conectar com outros neurônios ...

... com os músculos diretamente ...

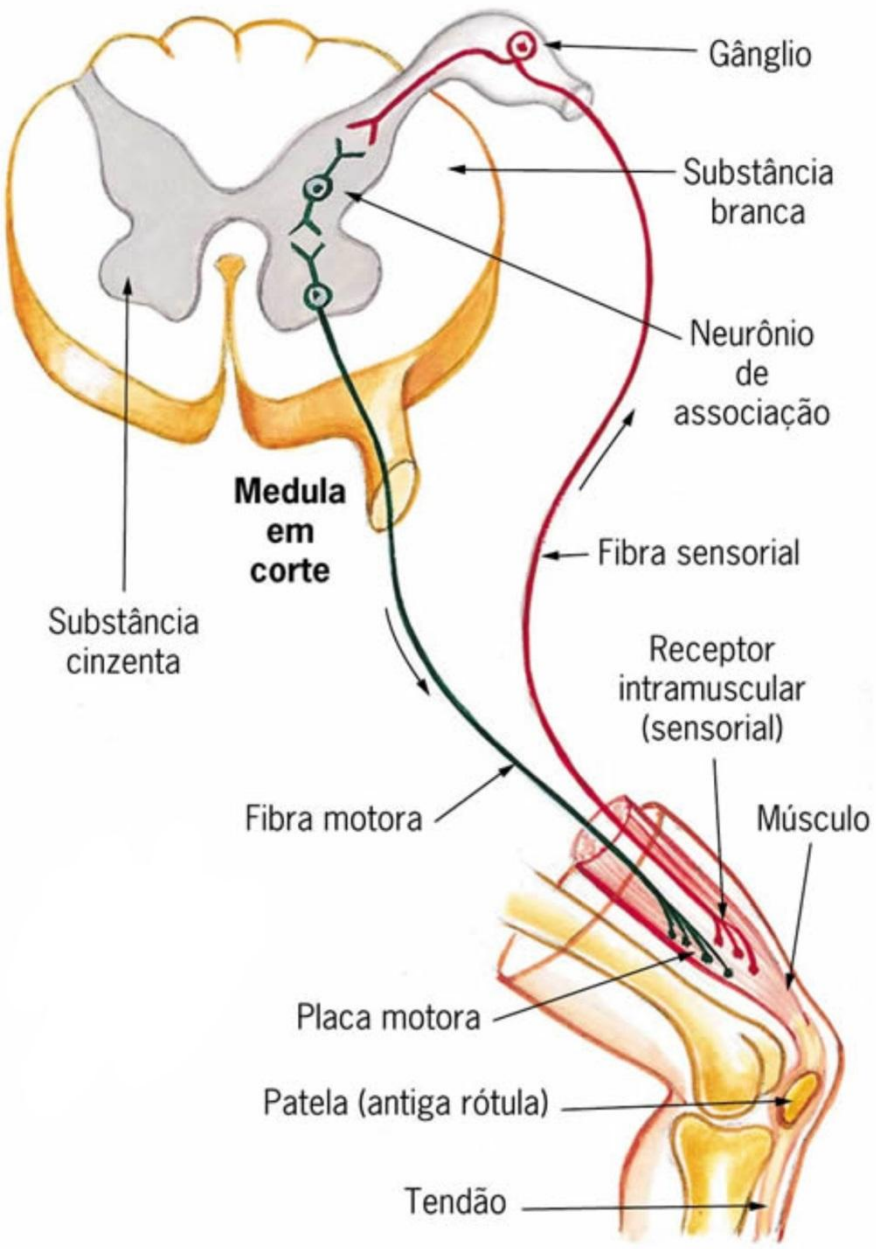

... ou com órgãos sensoriais (por exemplo a visão).

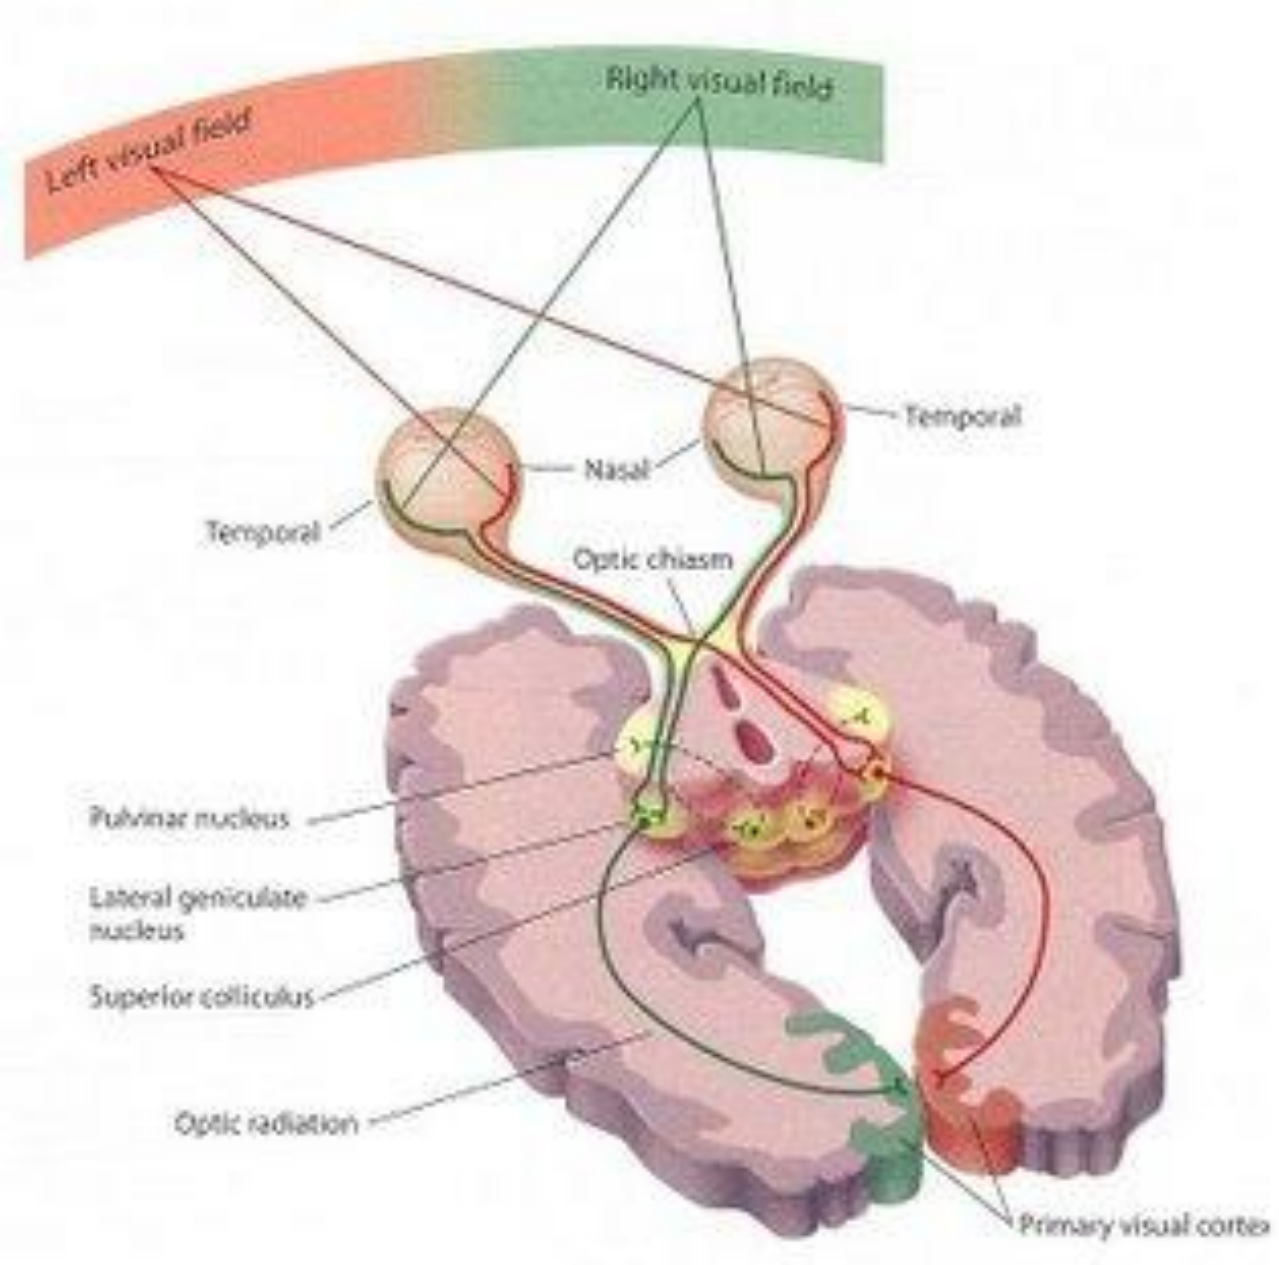

Três tipos de neurônios:

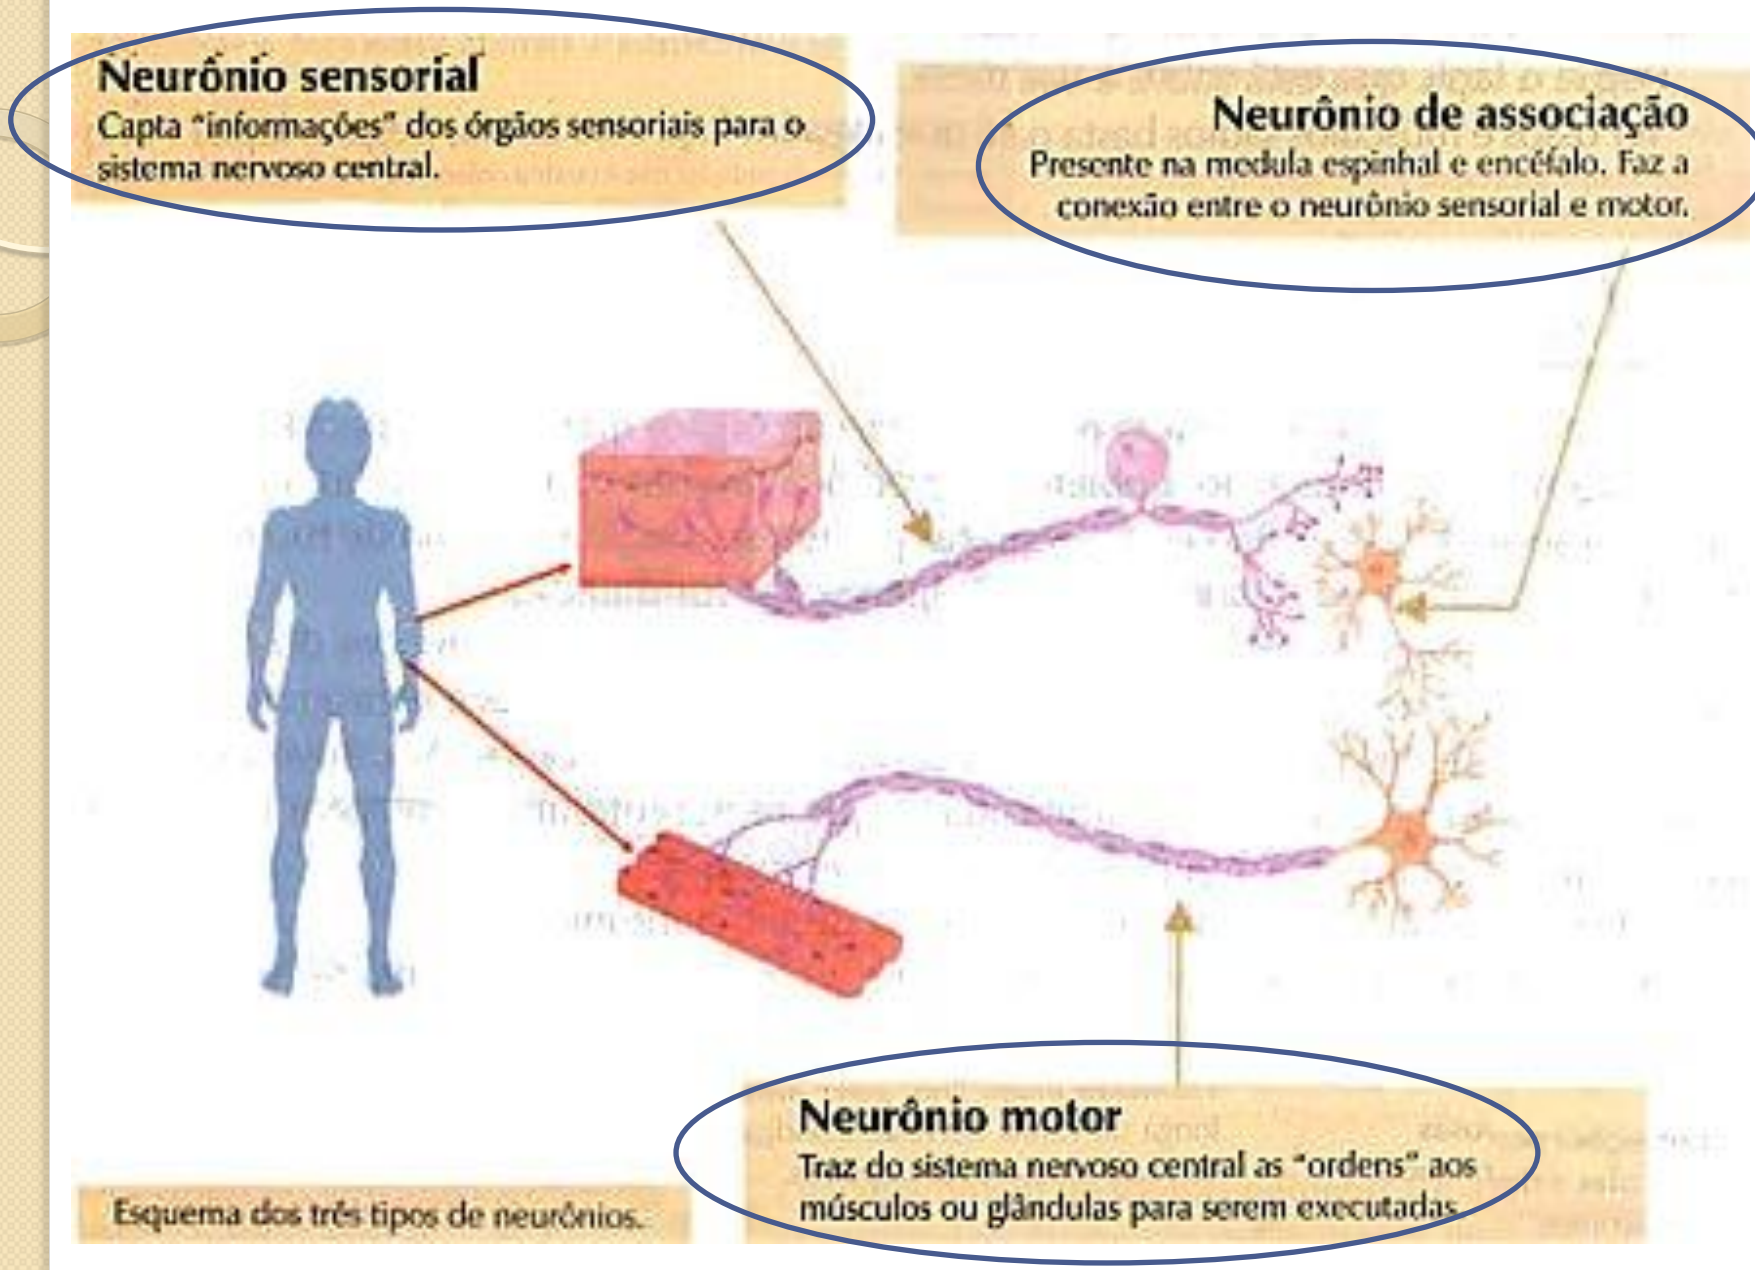

Esquema dos três tipos de neurônios.

III – RNA - Introdução Histórica

- ✓ **1943**: **M**c**C**ulloch e **P**itts publicaram a teoria de **Redes Neurais Artificiais** e propuseram um modelo computacional para o neurônio biológico (neurônio MCP);

- ✓ O neurônio modelado foi capaz de implementar funções lógicas simples, sendo um dispositivo binário e não possuía mecanismos de comparação entre entrada e saída ou qualquer processo de ajuste de pesos;

- ✓ Foram desenvolvidos modelos matemáticos que representem os dendritos, as sinapses, o corpo celular e o axônio.

Passo 1: Cada ramo da árvore dendrítica é modelado como uma linha ou canal de transmissão por onde flui a informação de entrada;

"Entrada" dos estímulos

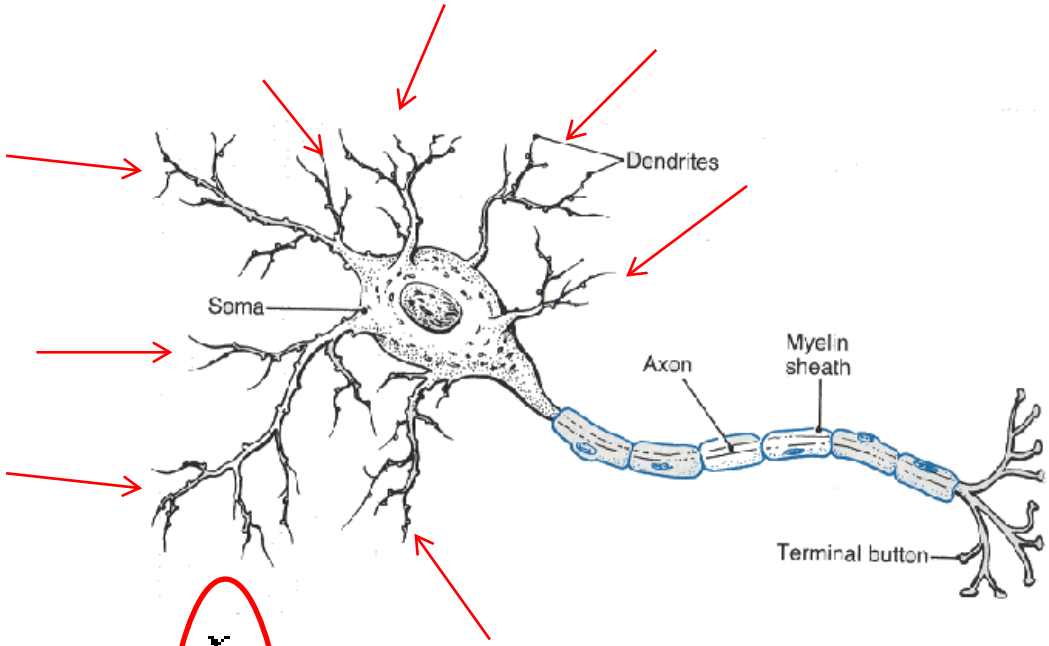

Entradas da RNA

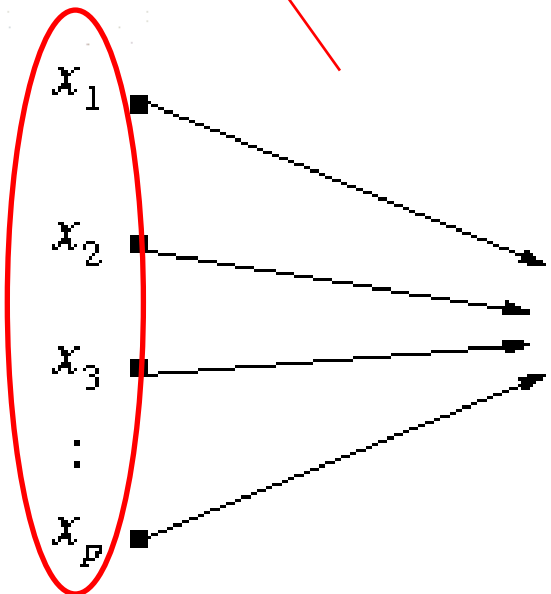

Passo 2: A força (ou eficiência) das conexões sinápticas de uma certa árvore dendrítica é modelada como um fator (peso sináptico), cujo papel é modular o fluxo de sinais passando por uma certa árvore dendrítica.

Neurônio

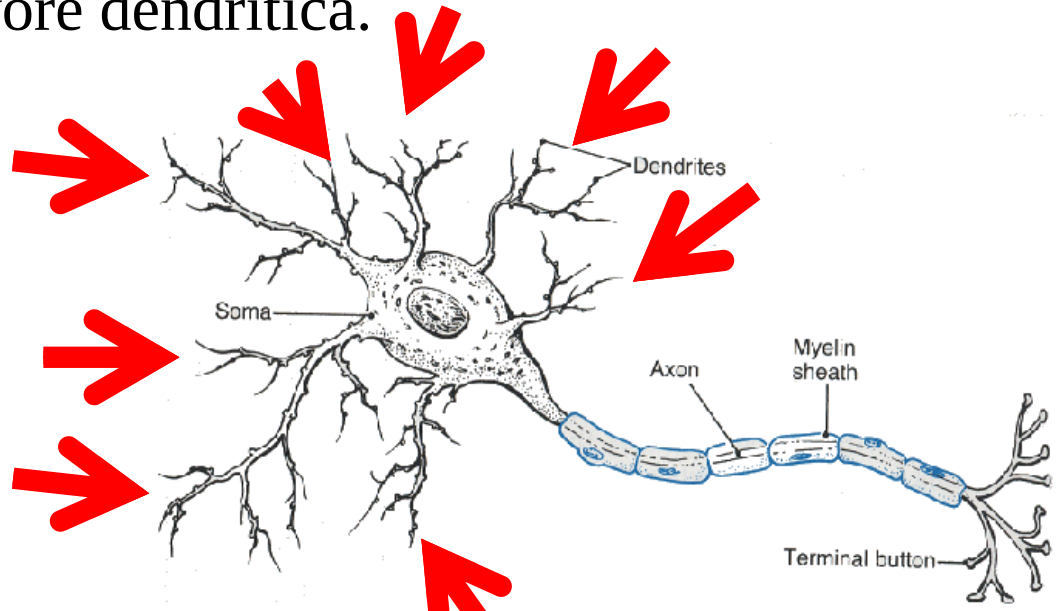

RNA

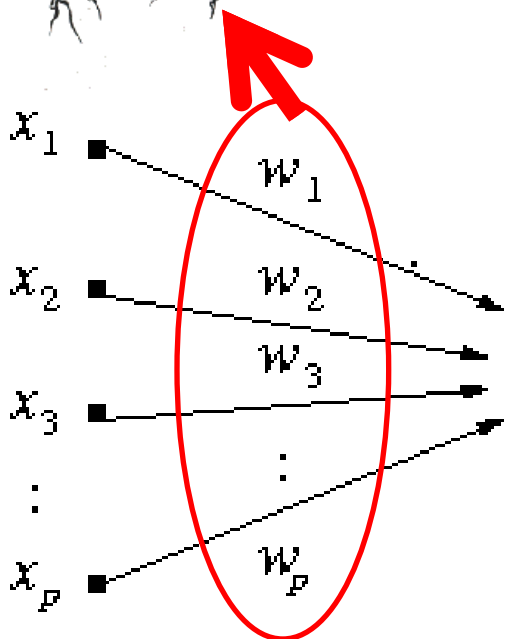

Passo 3: A função do corpo celular de realizar o balanço ou acúmulo energético é modelada por uma operação de somatório sobre as entradas moduladas pelos pesos sinápticos.

Neurônio

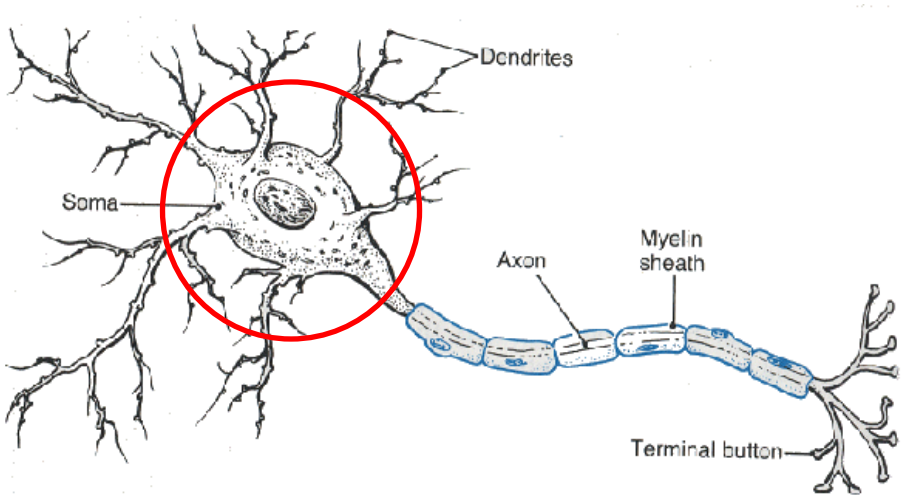

RNA

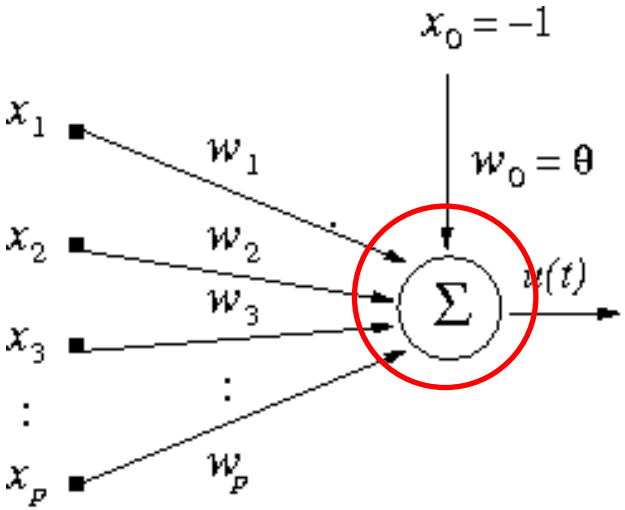

Passo 4: O axônio é modelado como uma chave ON/OFF, que indica se o neurônio respondeu ao estímulo atual. Em outras palavras, se houve ou não o envio de um potencial de ação.

Neurônio

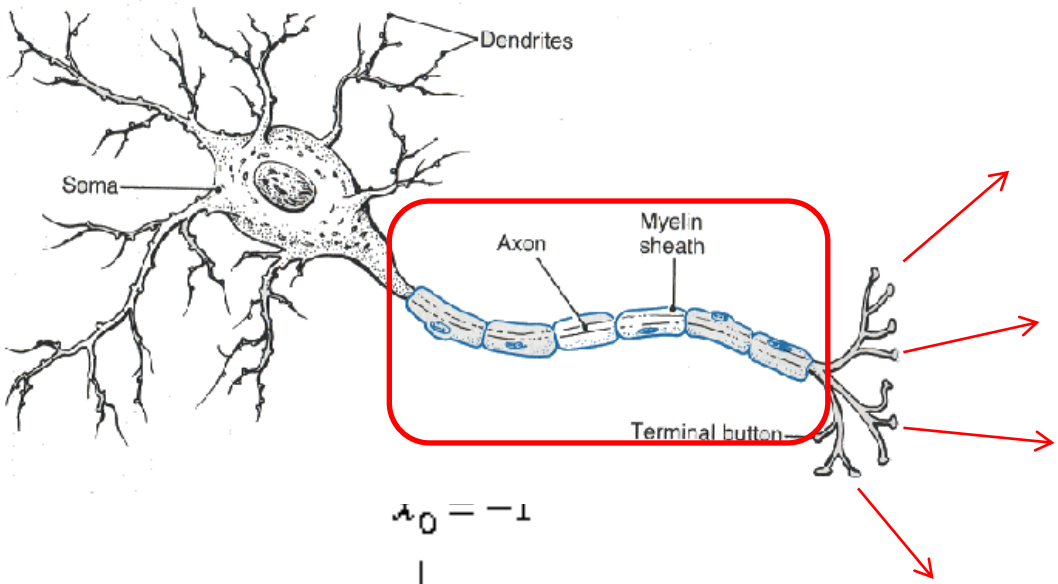

RNA

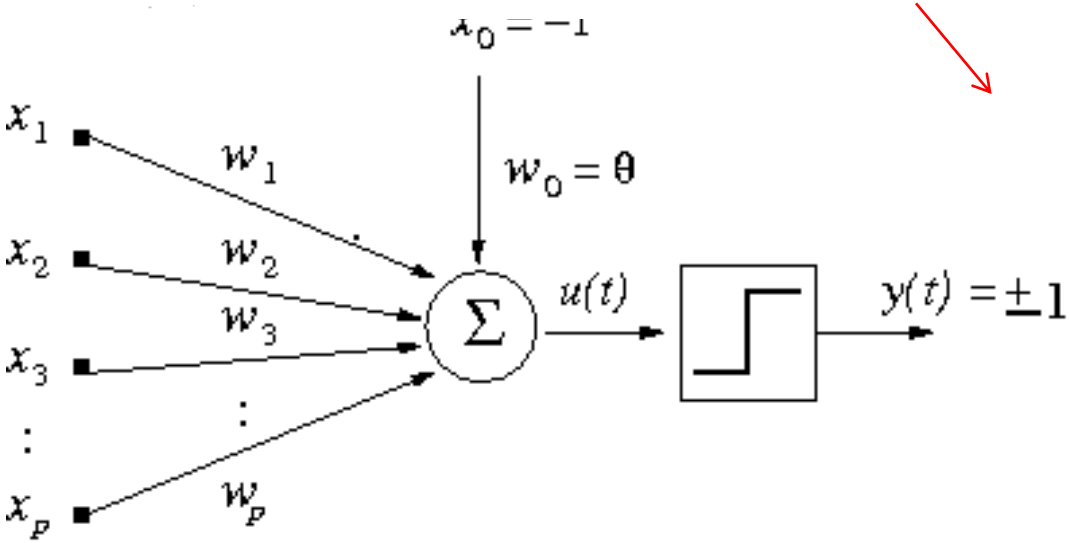

Modelo Completo do Neurônio Artificial de McCulloch-Pitts

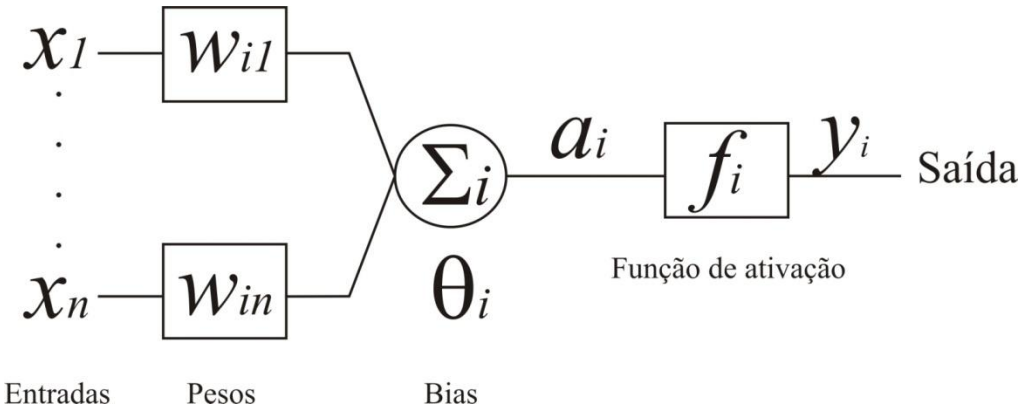

- ✓ $x_1, x_2, \ldots, x_n$ são as entradas;
- ✓ $\sum i$: unidade de processamento;
- ✓ função de ativação não linear f_i ;
- ✓ saída y_i.

✓Cada entrada recebe um estímulo 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 limiar, θi;

✓ A soma de todas as entradas ponderadas e o limiar, dado por a_i, é então modulada pela função de ativação f_i que determina o nível de excitação gerado pelo elemento neural.

V – RNA

✓ Neurônios individuais possuem capacidade computacional limitada;

✓ Um conjunto de neurônios artificiais conectados na forma de uma rede é capaz de resolver problemas de complexidade elevada;

✓ Uma RNA possui:

(i) um conjunto de elementos neurais;

(ii) uma arquitetura que define o número de elementos e a forma com se interconectam, e;

(iii) propriedades funcionais que definem como a rede aprende, recorda, associa, compara e classifica.

- ✓ Umas das características mais importantes das RNAs é a capacidade de aprender por meio de exemplos.

- ✓ Aprendizado: processo pelo qual os parâmetros livres de uma RNA são ajustados por meio de uma forma continuada de estímulos pelo ambiente externo.

ENTENDENDO AS

REDES NEURAIS ARTIFICIAIS

- ✓ O que precisamos:

  - ➢ Características de entrada da rede;
  - ➢ Definição dos tipos de saídas;
  - ➢ Tempo de treinamento;
  - ➢ Análise da classificação feita.

- ✓ Exemplo: classificador de lápis verde

- Características de entrada da rede

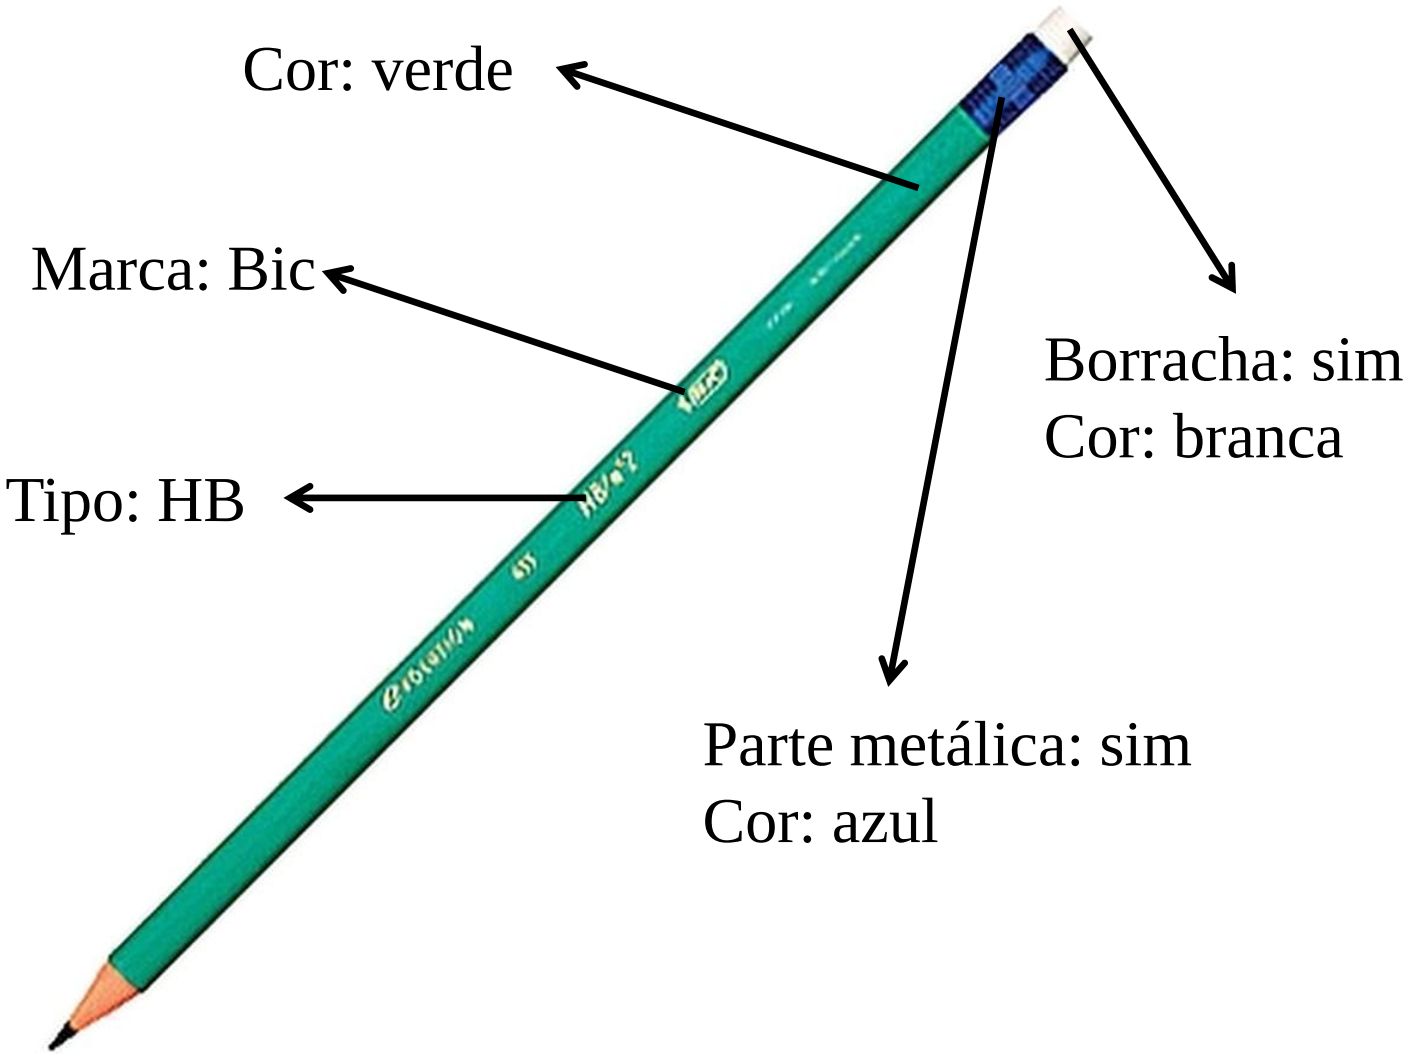

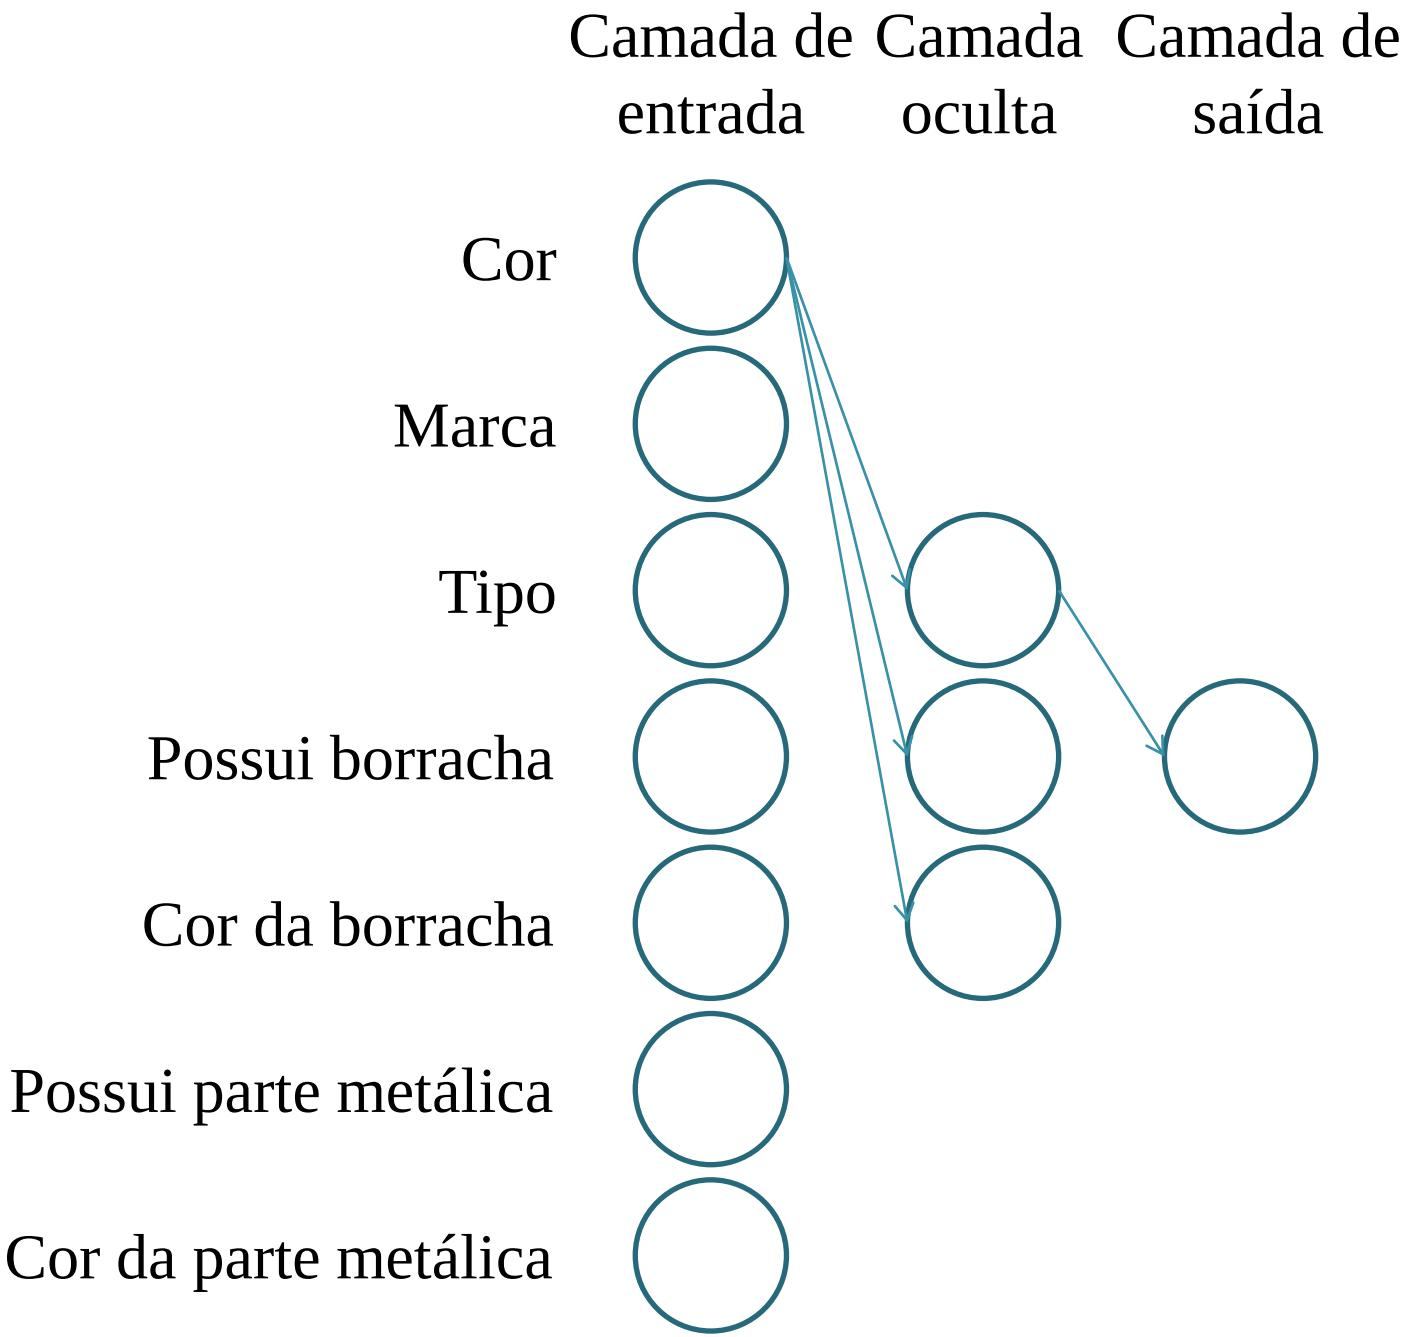
Camada de entrada
Camada oculta
Camada de saída
Cor
Marca
Tipo
Possui borracha
Cor da borracha
Possui parte metálica
Cor da parte metálica

- Treinamento: é realizado quantas vezes for necessário, de acordo com o usuário.

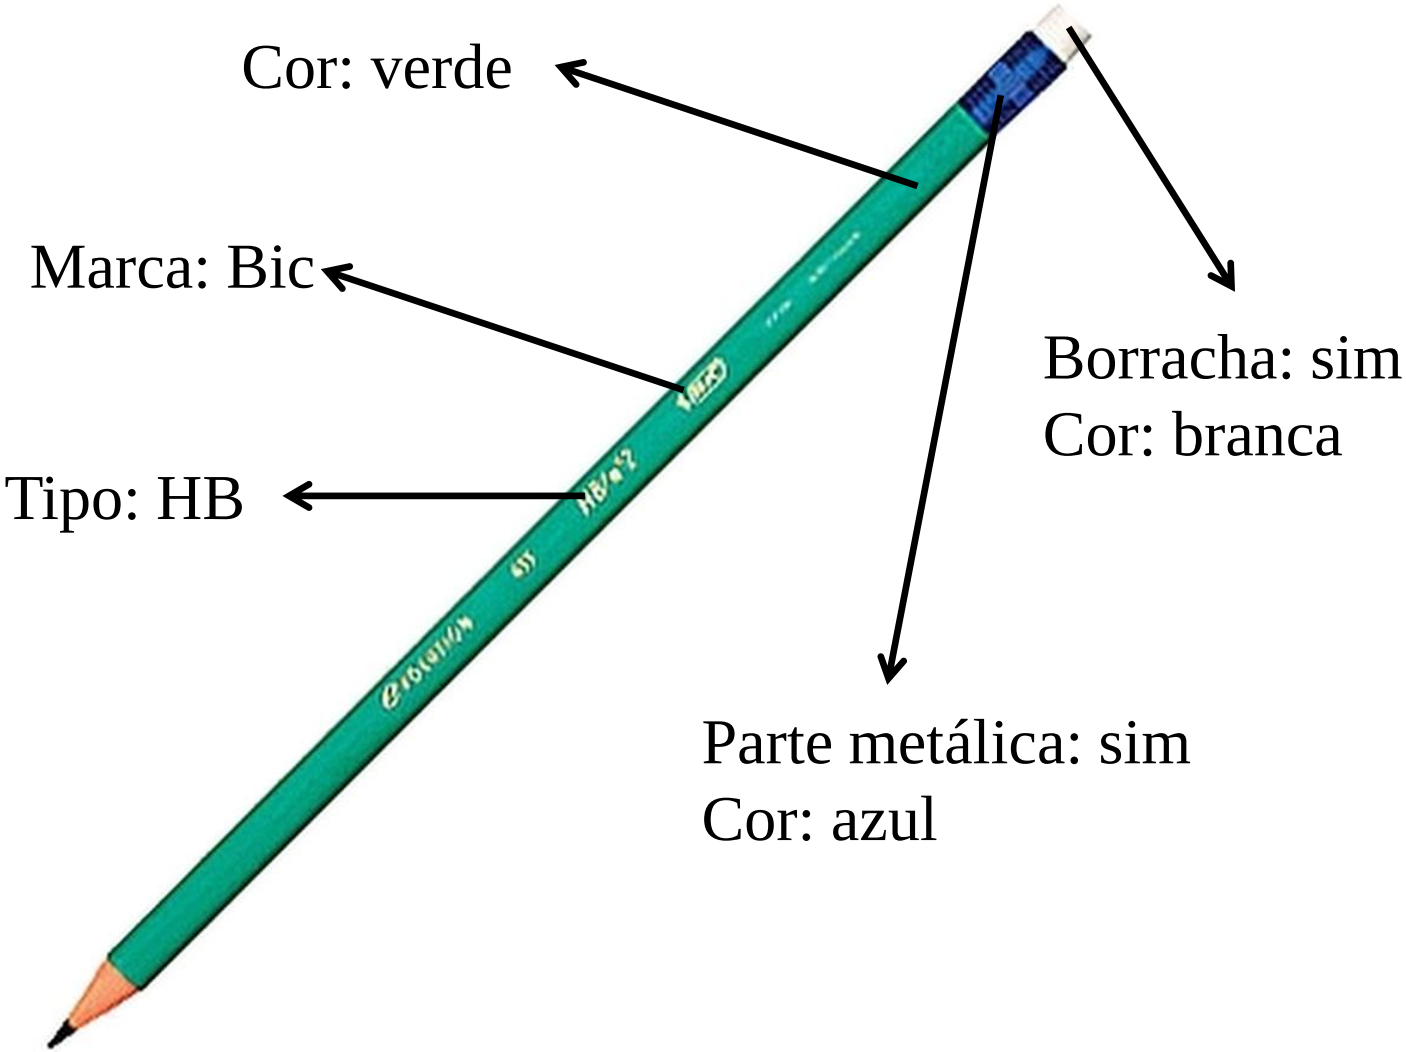

- Classificação: conjunto de 6 elementos para serem classificados de acordo com as características selecionadas.

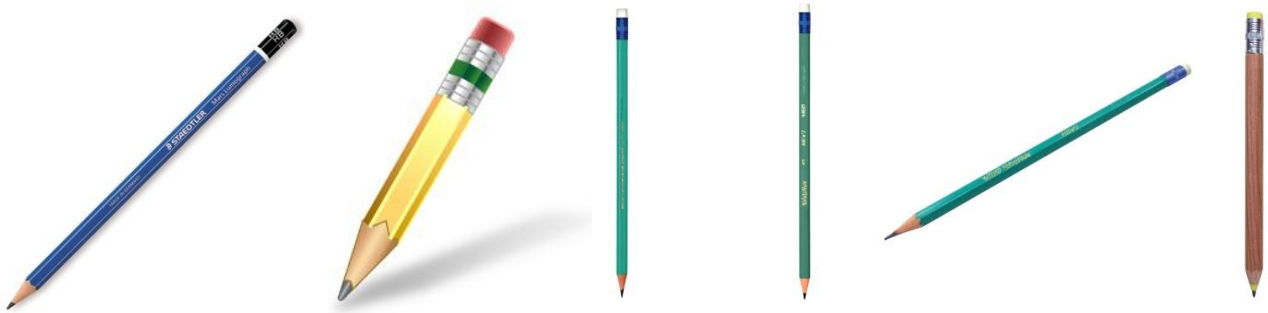

Cor	azul	amarelo	verde	verde	verde	marrom
Marca	A	B	A	Bic	Bic	C
Tipo	B	HB	HB	HB	HB	2B
Possui borracha	sim	sim	sim	sim	sim	sim
Cor da borracha	branca	vermelha	branca	branca	branca	amarela
Possui parte metálica	sim	sim	sim	sim	sim	sim
Cor da parte metálica	preta	prata	azul	azul	azul	prata

Classificador de lápis

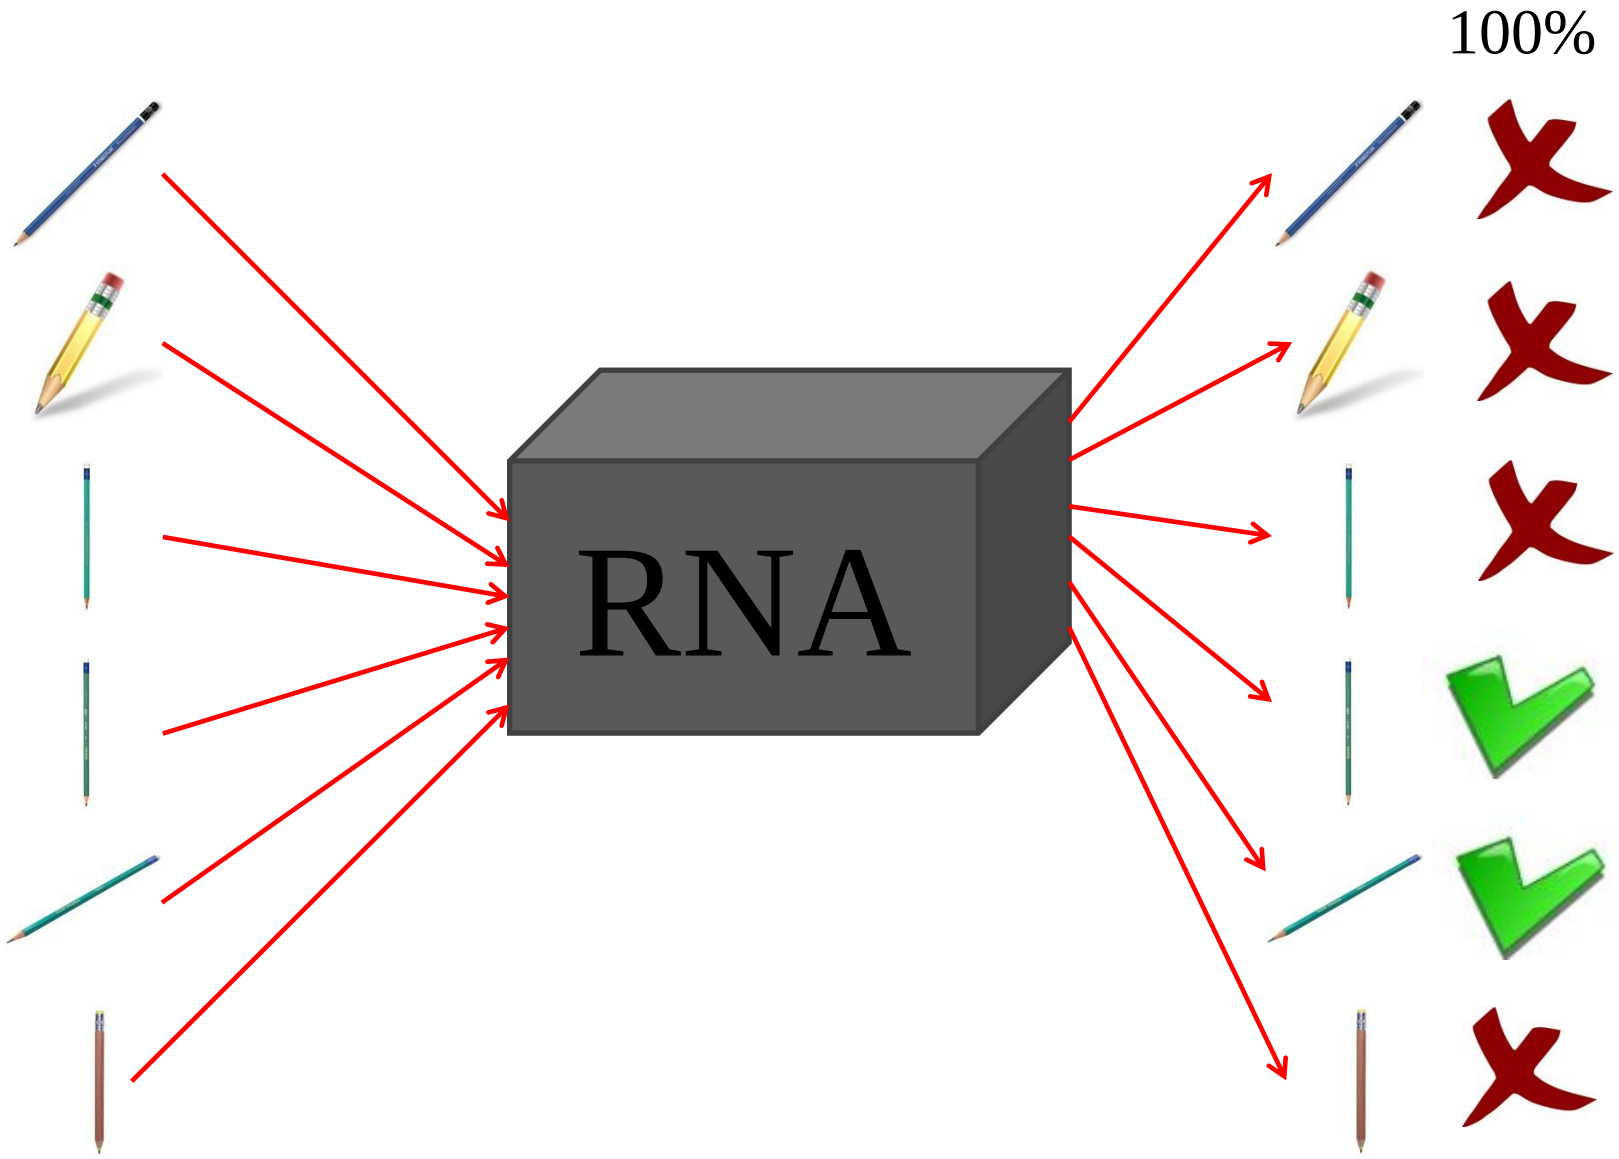

Classificador de lápis

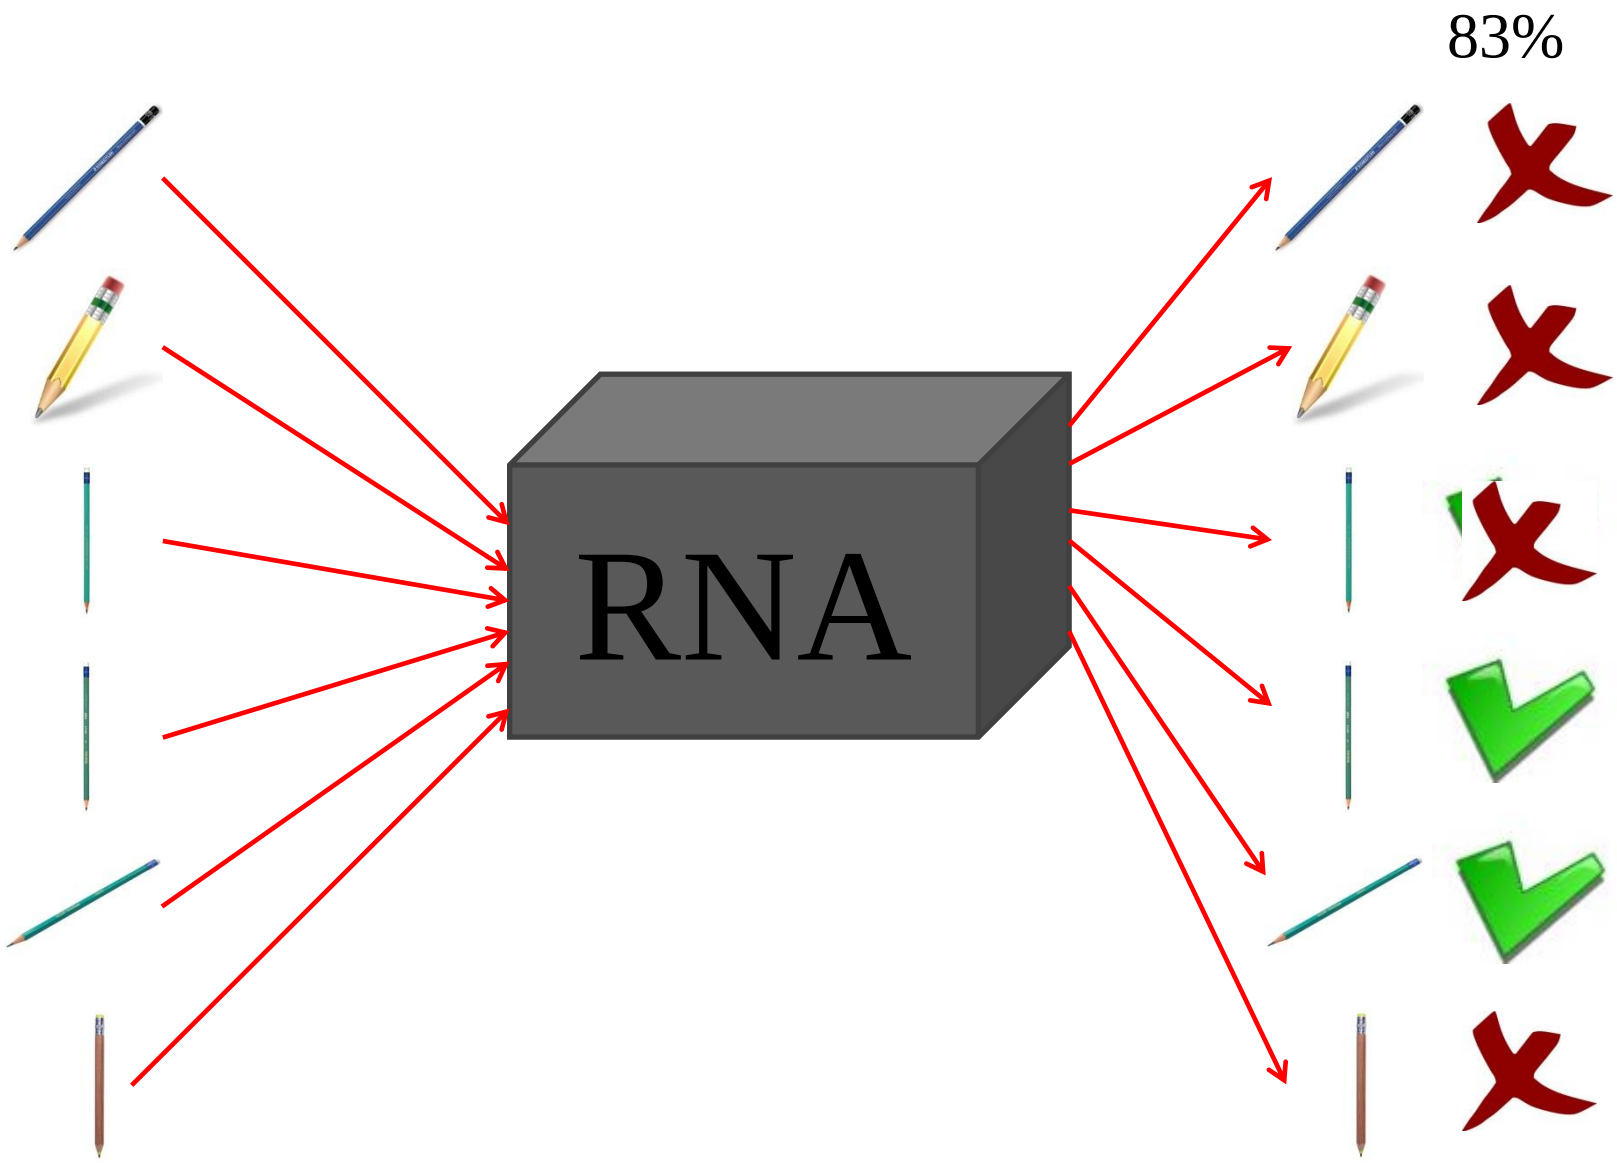

VI – Aplicação no método GPR

O Sítio Controlado de Geofísica Rasa – SCGR/IAG-USP

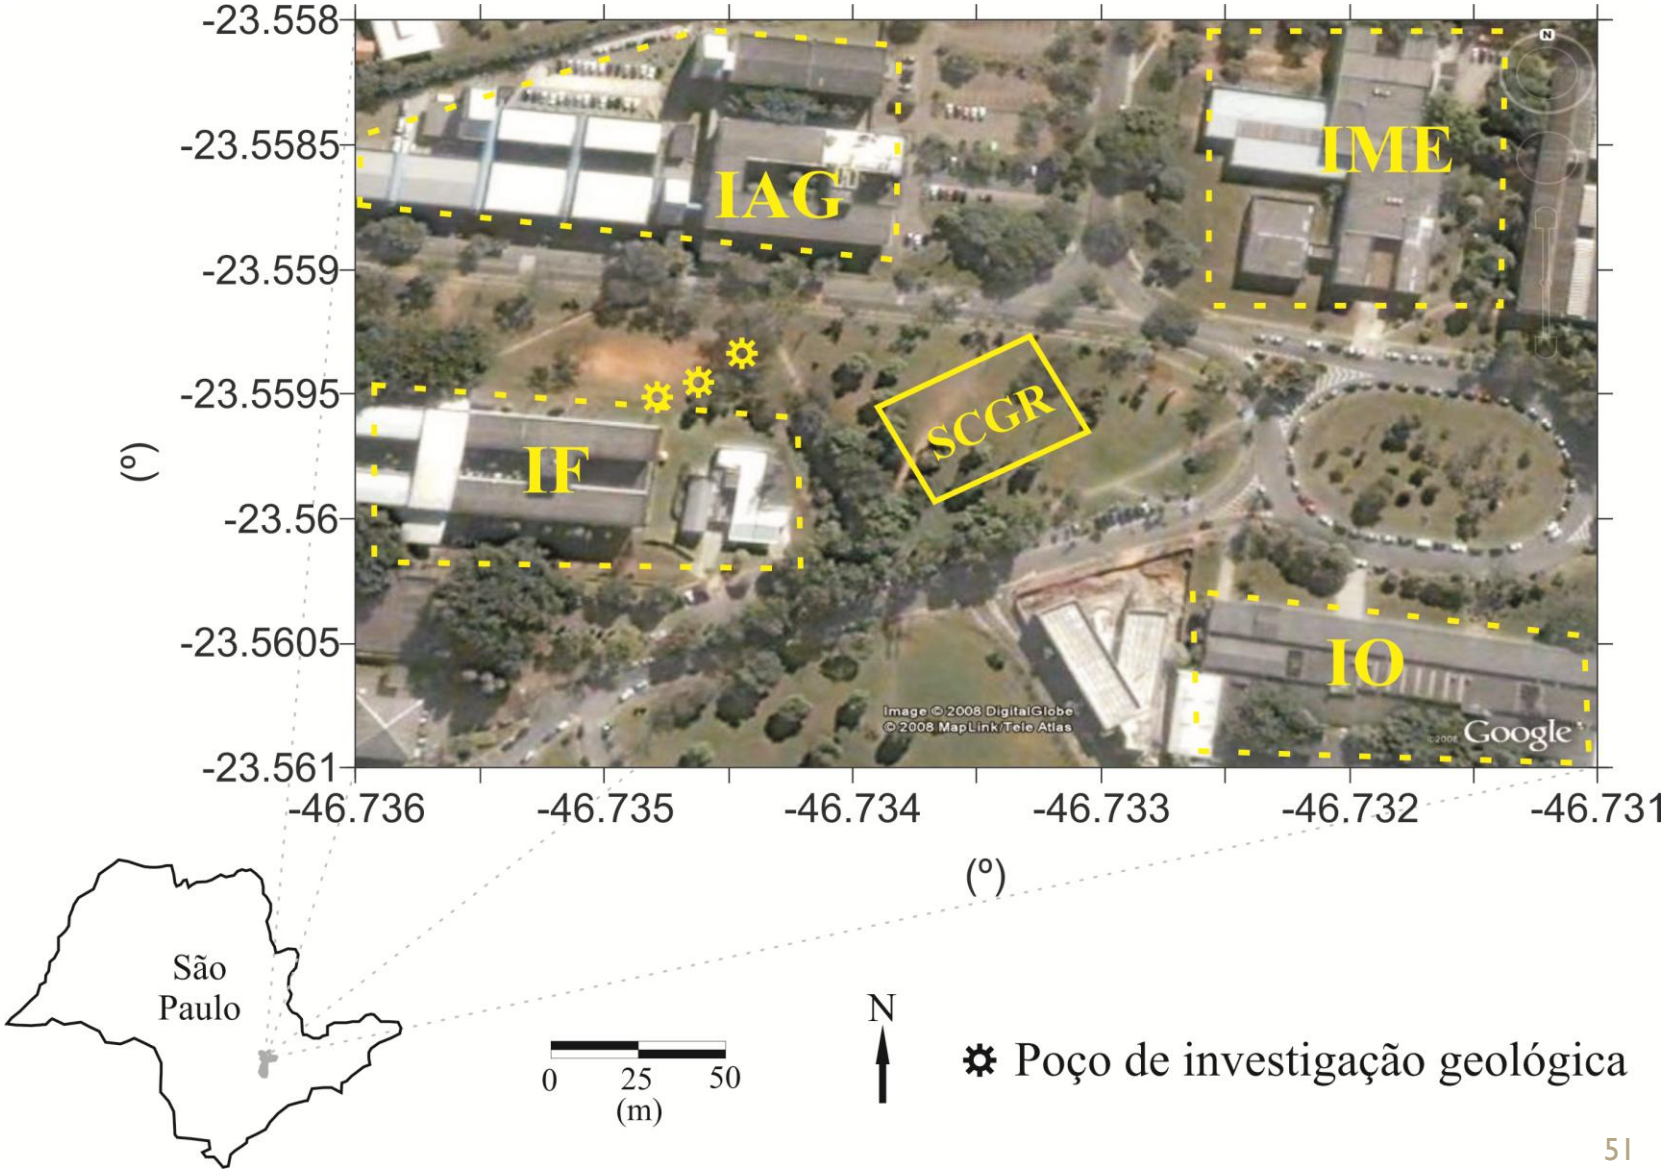

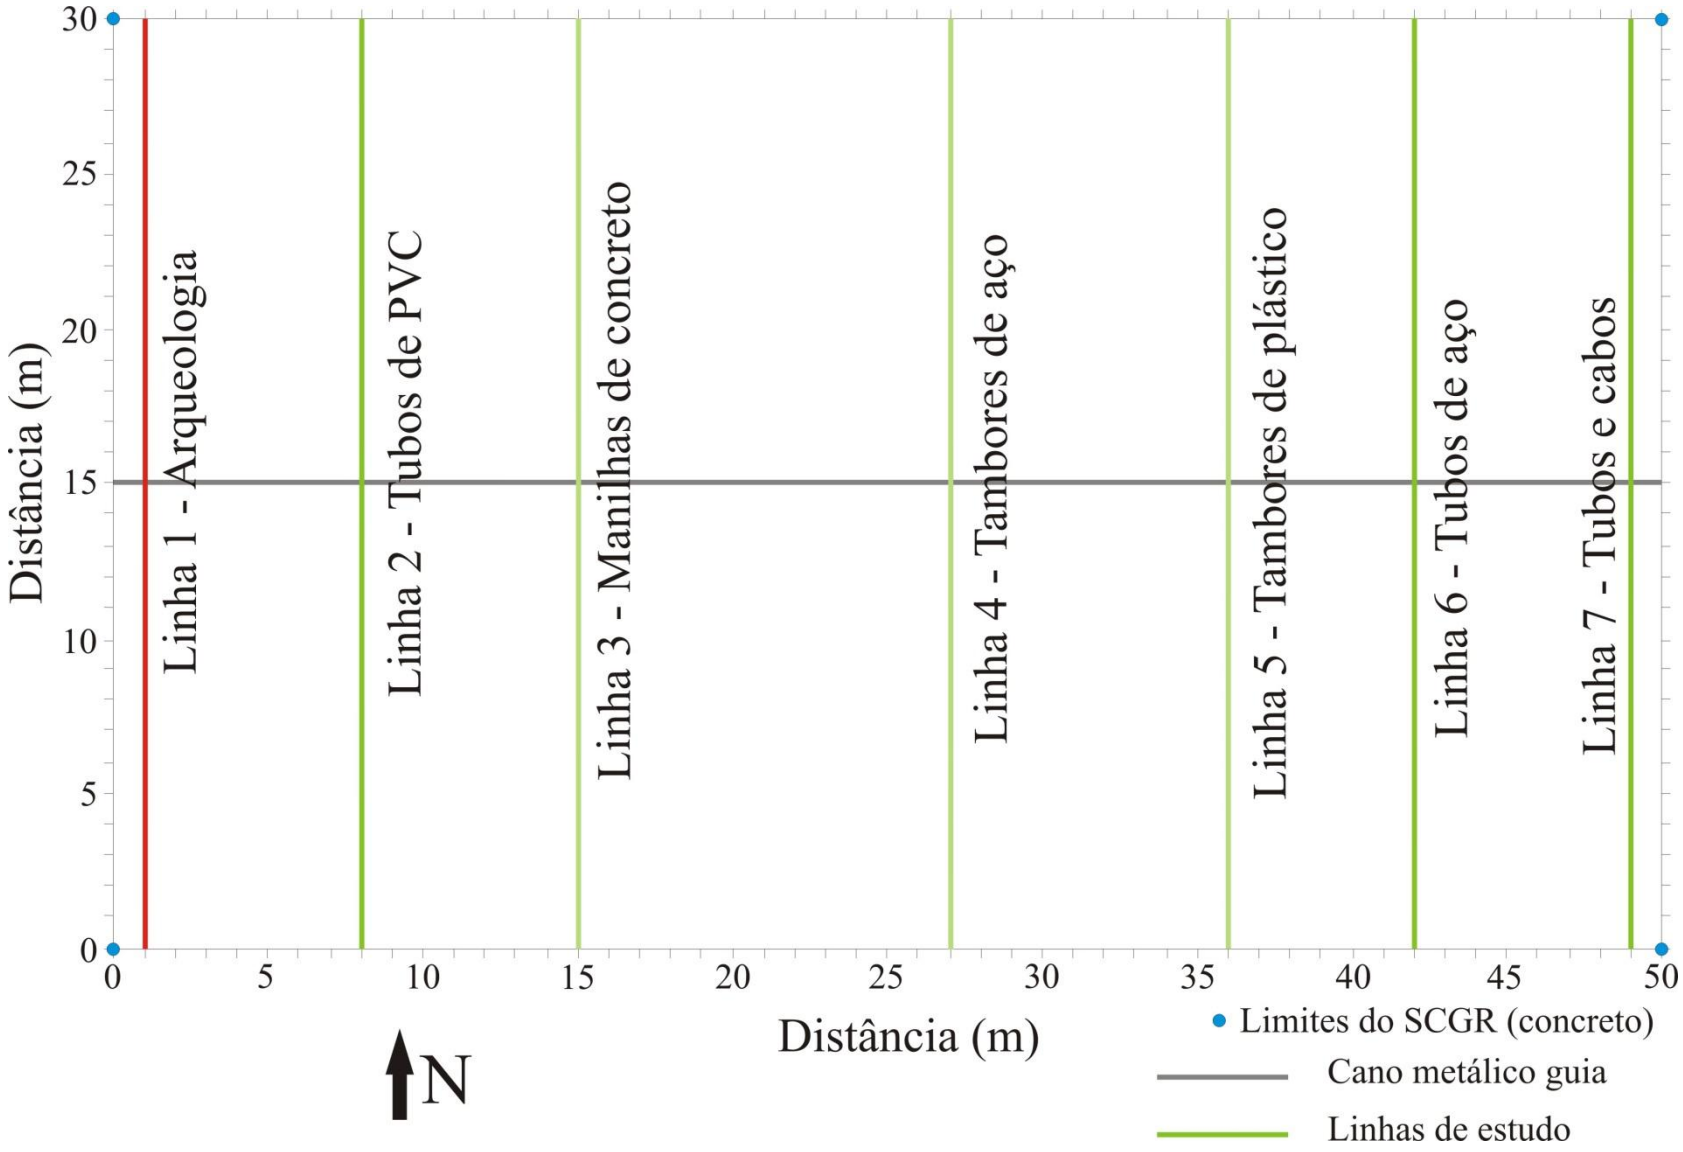
Distância (m)
30
25
20
15
10
5
0
Linha 1 - Arqueologia
Linha 2 - Tubos de PVC
Linha 3 - Manilhas de concreto
Linha 4 - Tambores de aço
Linha 5 - Tambores de plástico
Linha 6 - Tubos de aço
Linha 7 - Tubos e cabos
0
5
10
15
20
25
30
35
40
45
50
Distância (m)
N
Limites do SCGR (concreto)
Cano metálico guia
Linhas de estudo

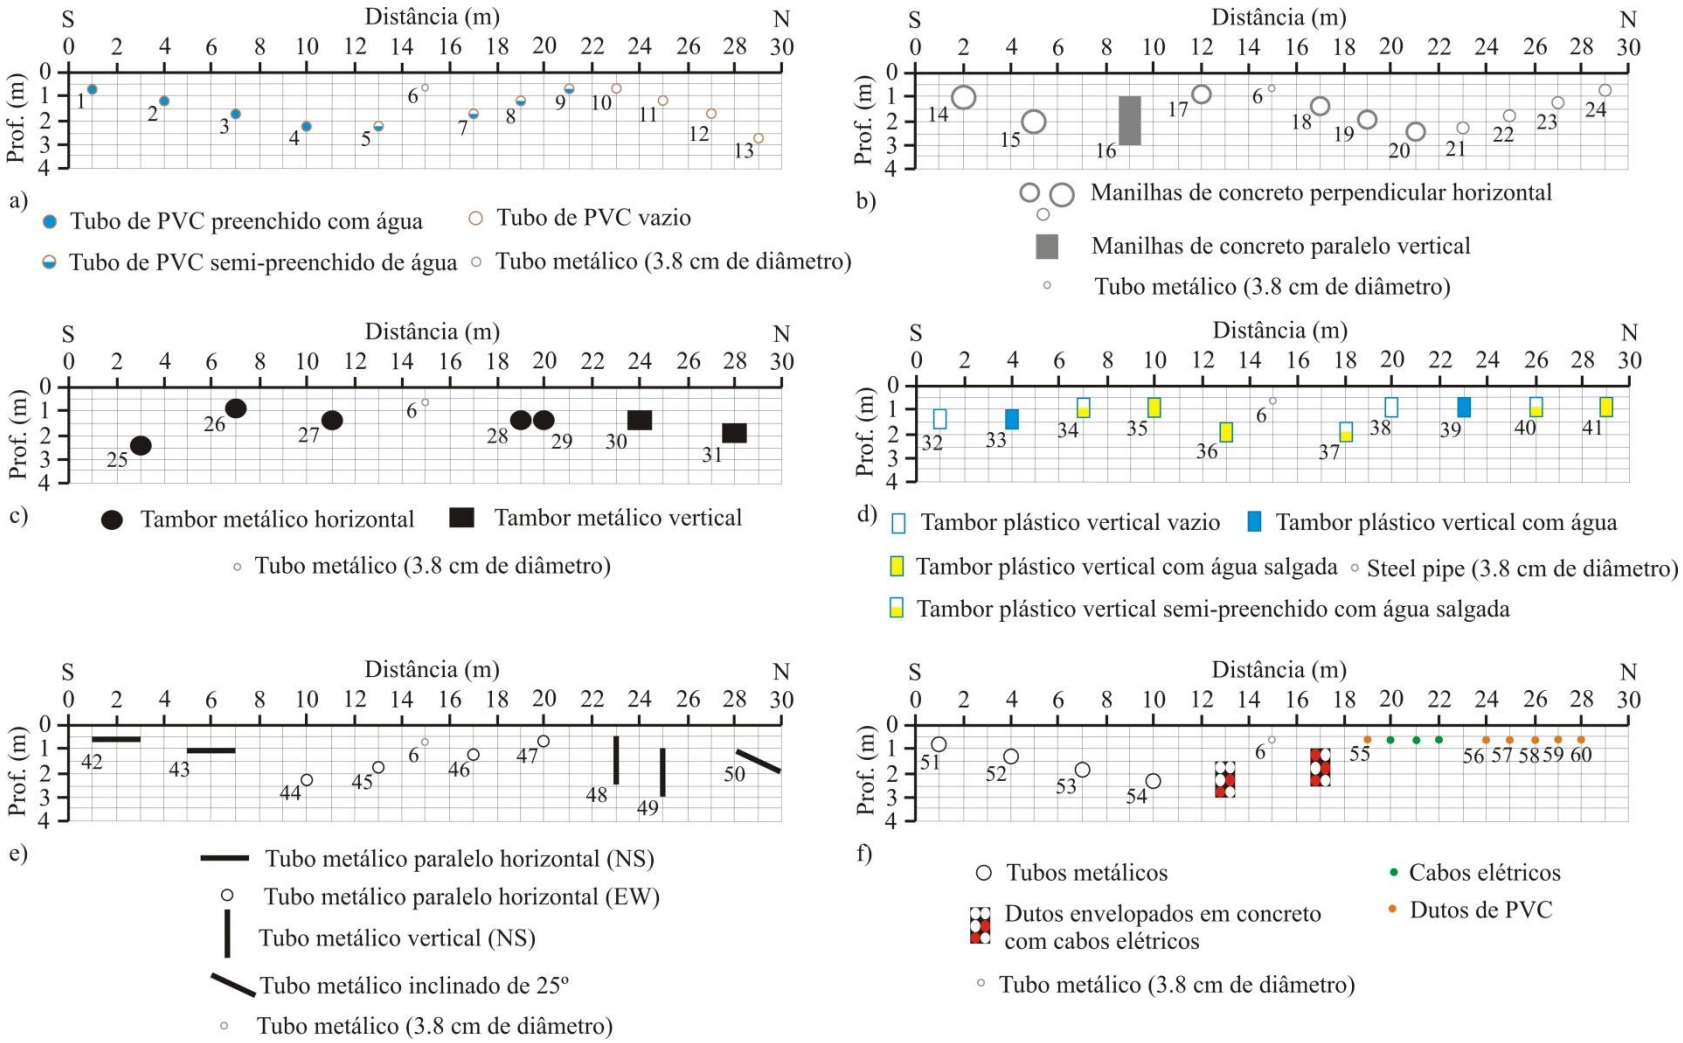

Linhas utilizadas para a classificação automática utilizando RNAs: a) Linha 2 (tubos de PVC). b) Linha 3 (manilhas de concreto). c) Linha 4 (tambores metálicos). d) Linha 5 (tambores plásticos). e) Linha 6 (tubos metálicos). f) Linha 7 (tubos metálicos e cabos elétricos)

TUBULAÇÃO HIDRÁULICA

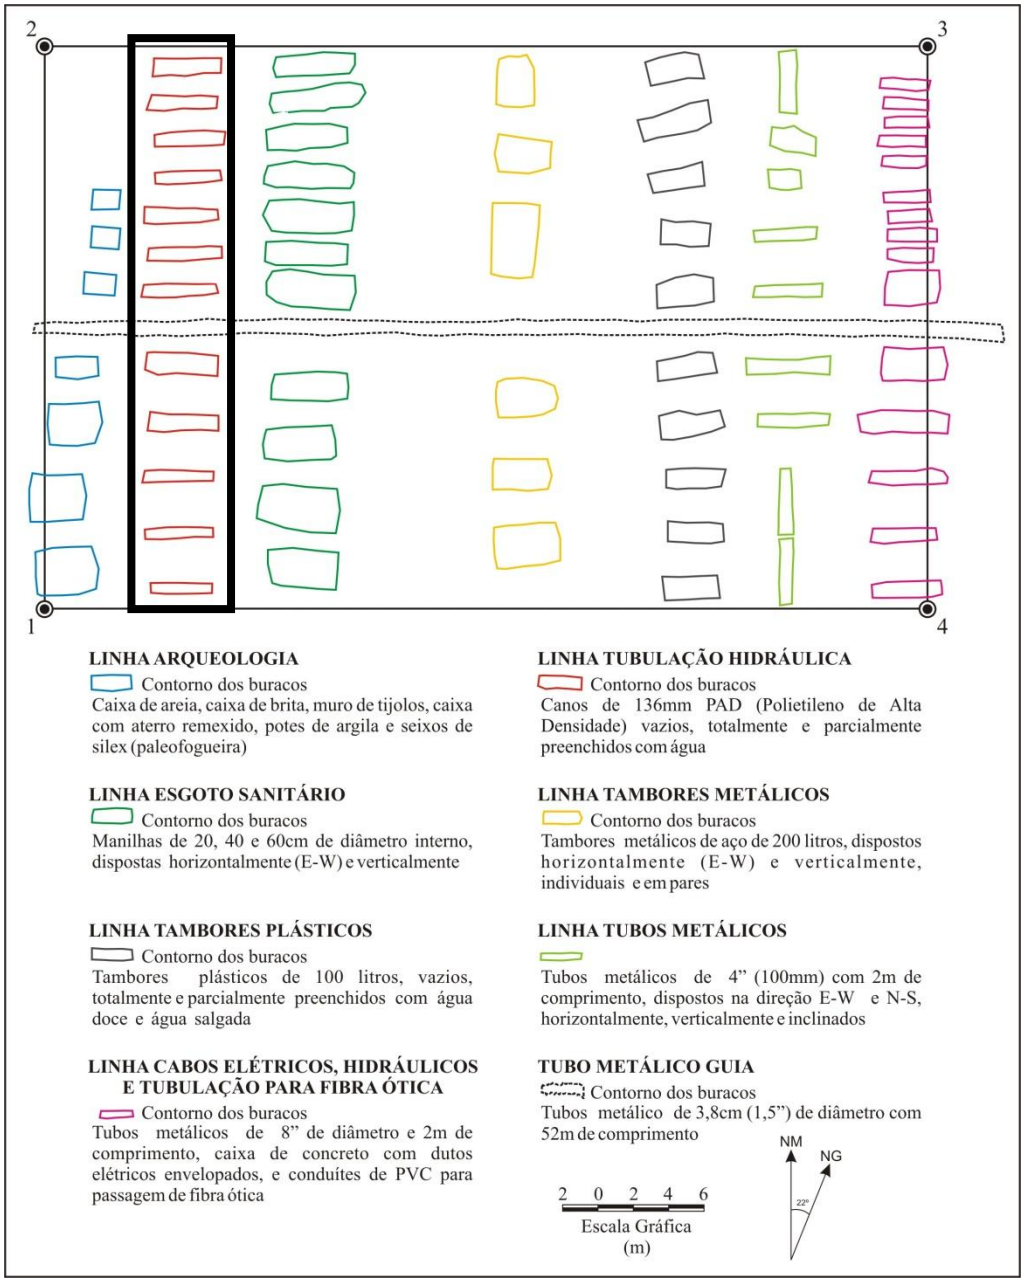

ESGOTO SANITÁRIO

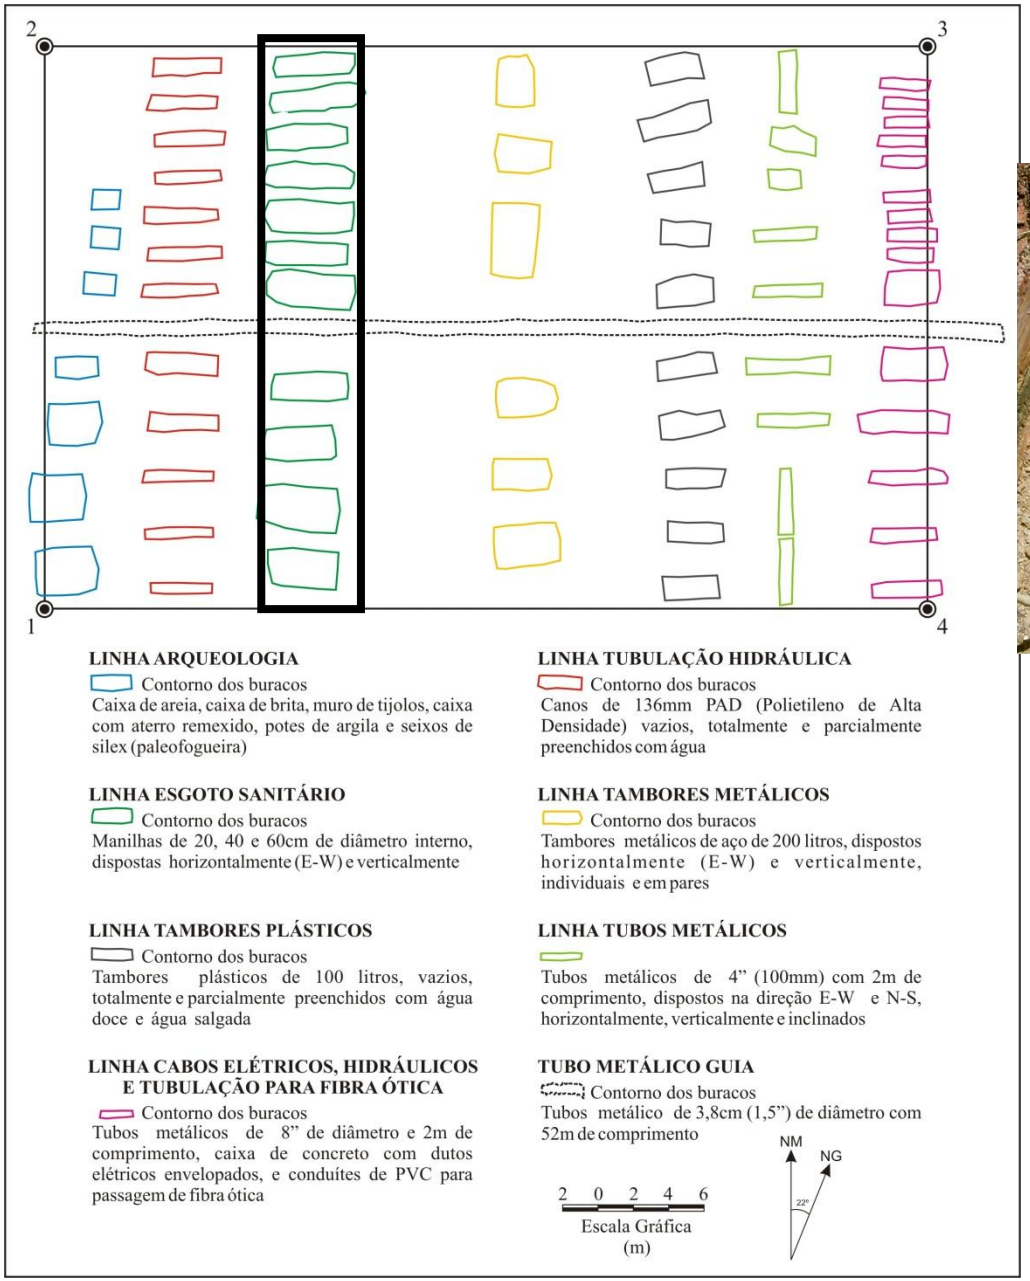

TAMBORES METÁLICOS

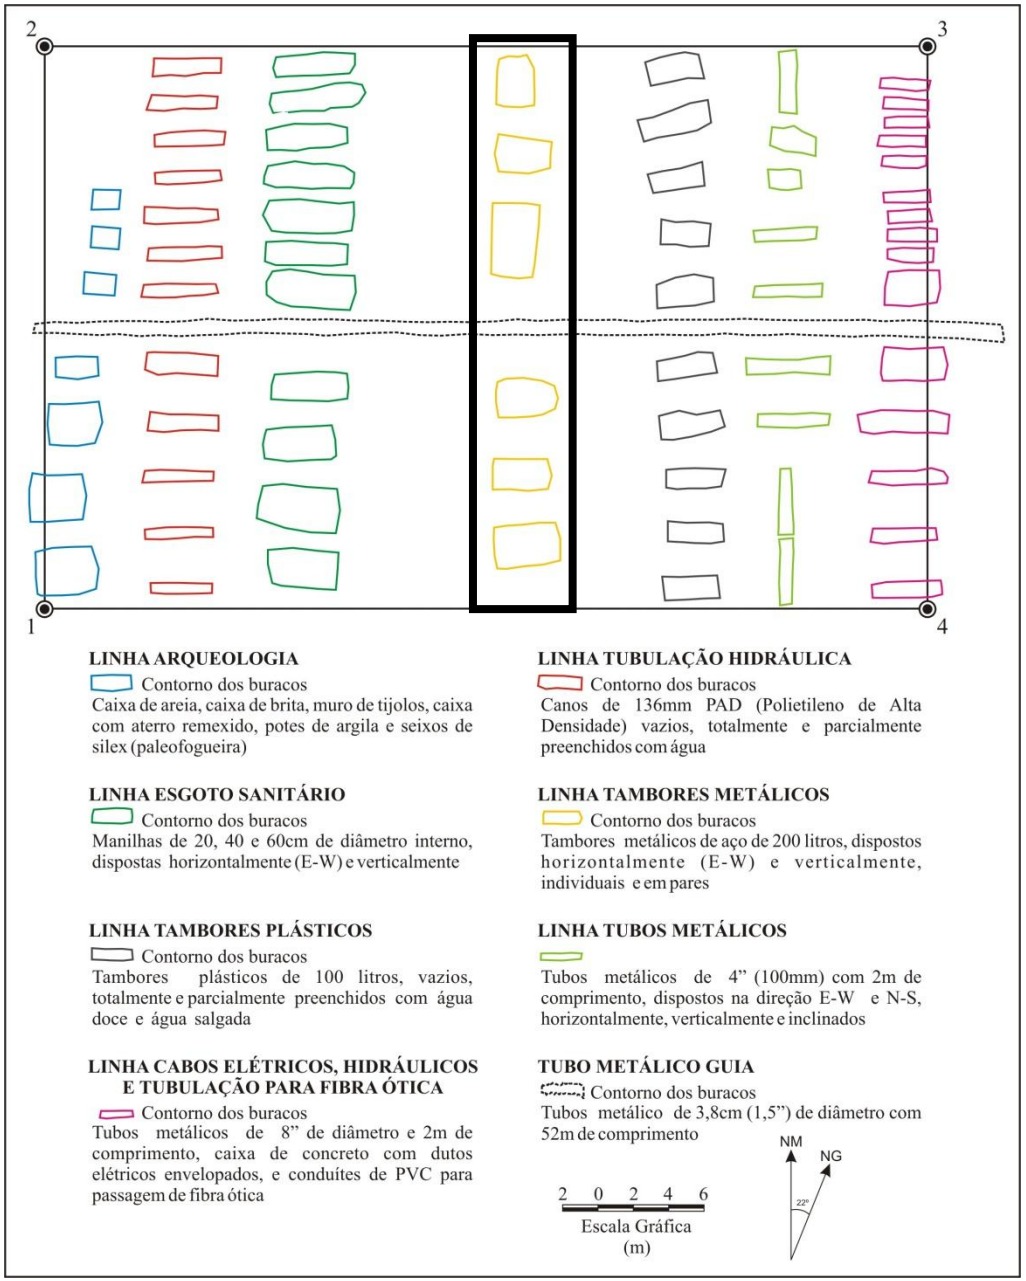

TAMBORES PLÁSTICOS

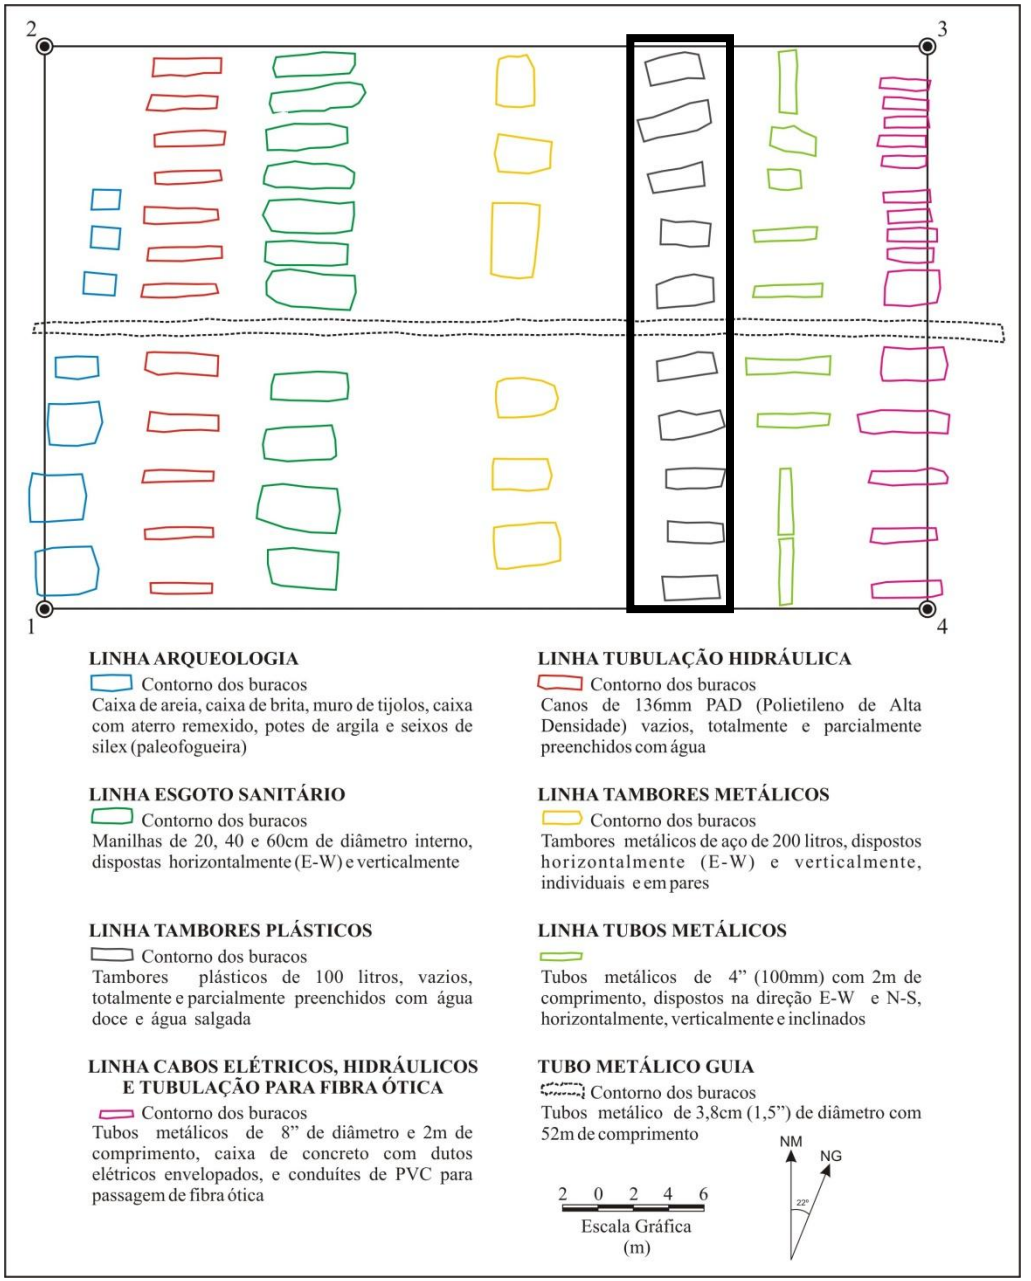

TUBOS METÁLICOS

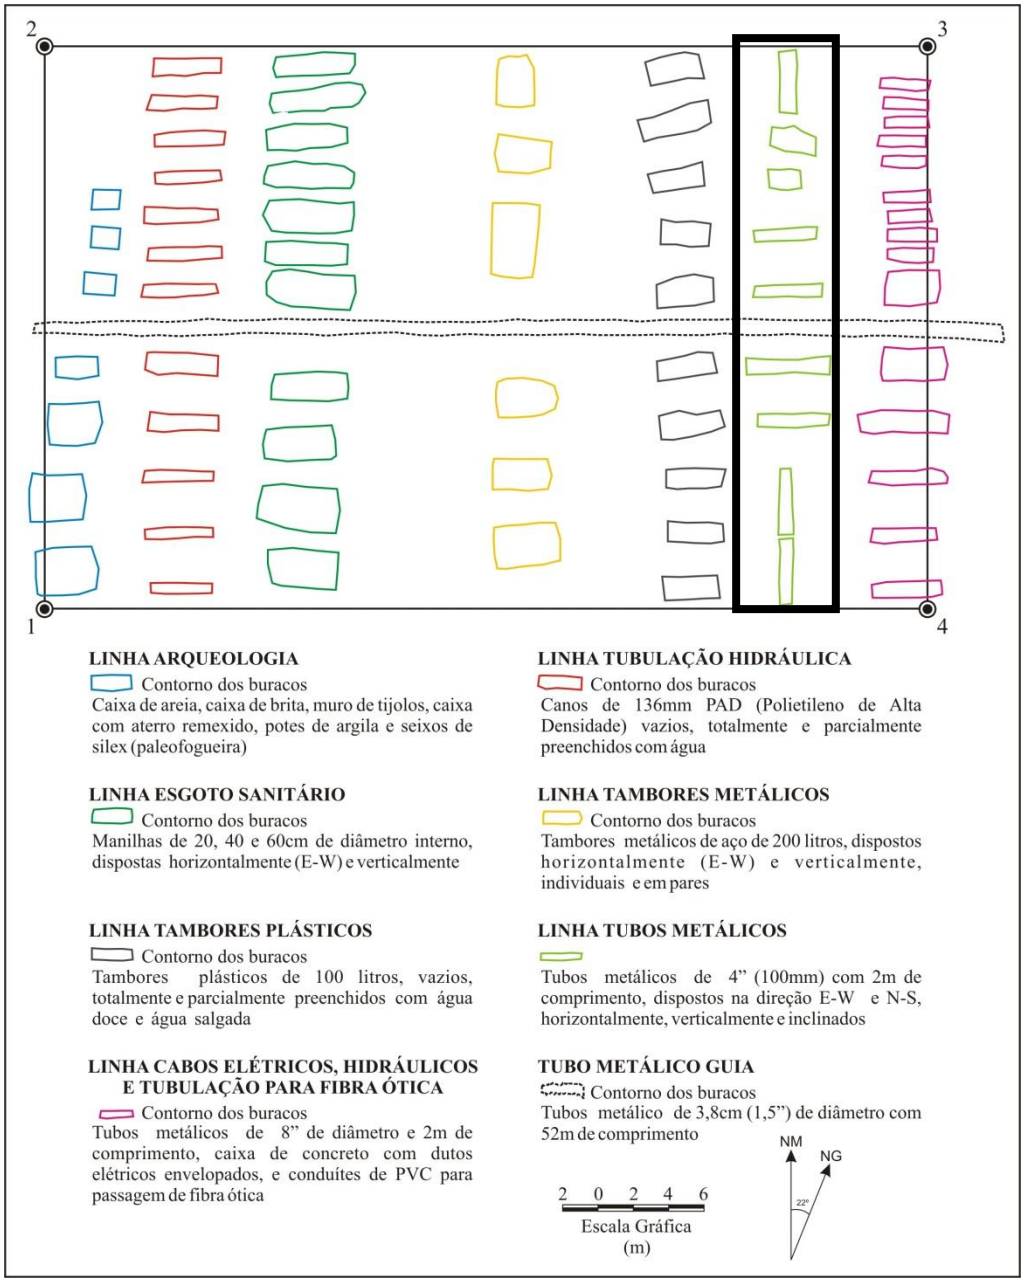

CABOS ELETROPAULO E TUBOS FIBRA ÓTICA

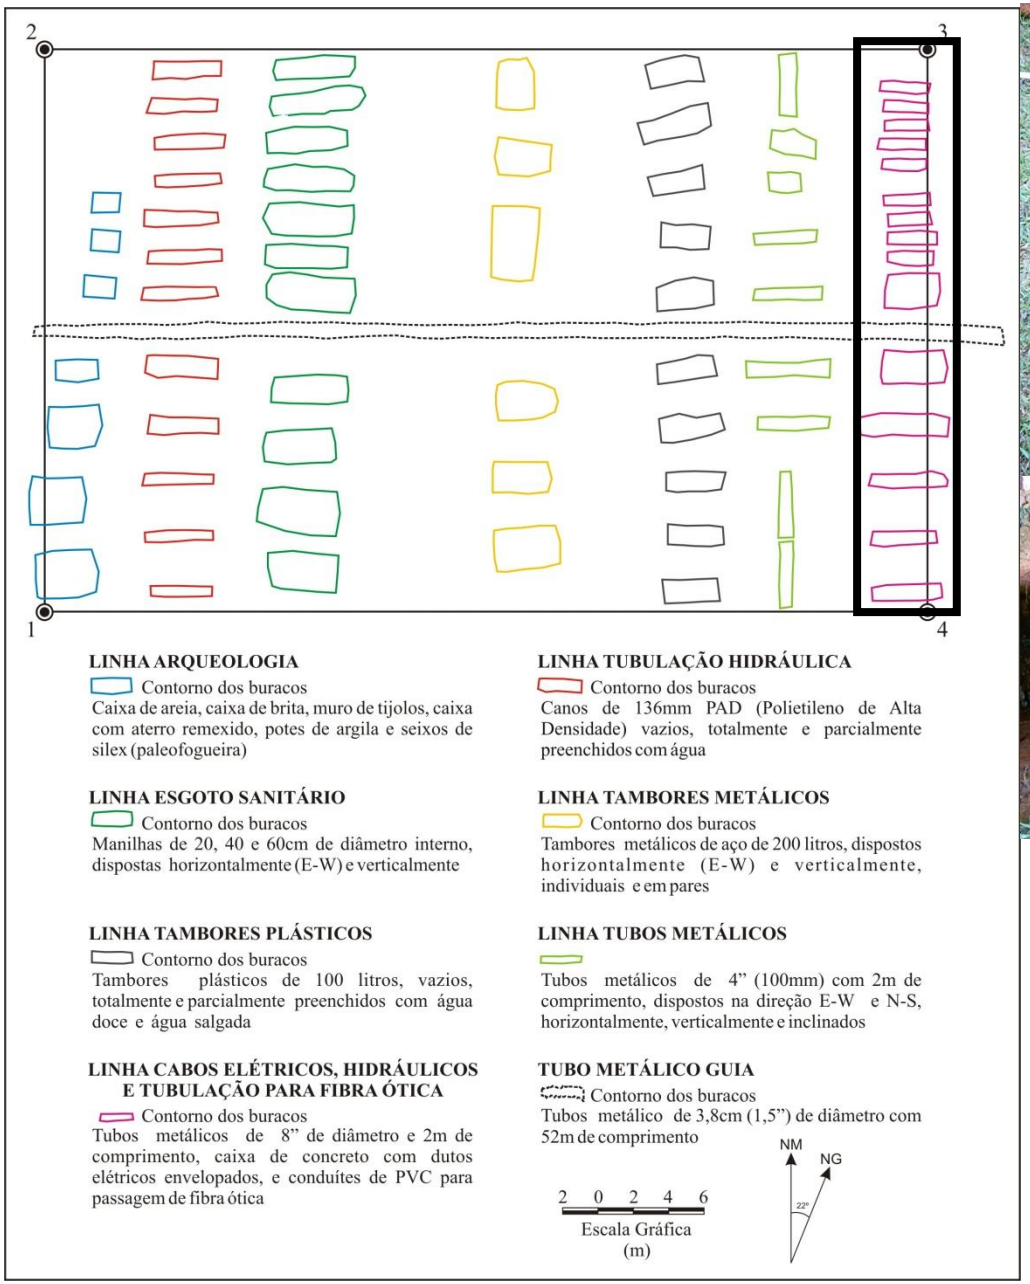

Aquisição de dados no SCGR. a) Antena de 400 MHz. b) Antena de 200 MHz.

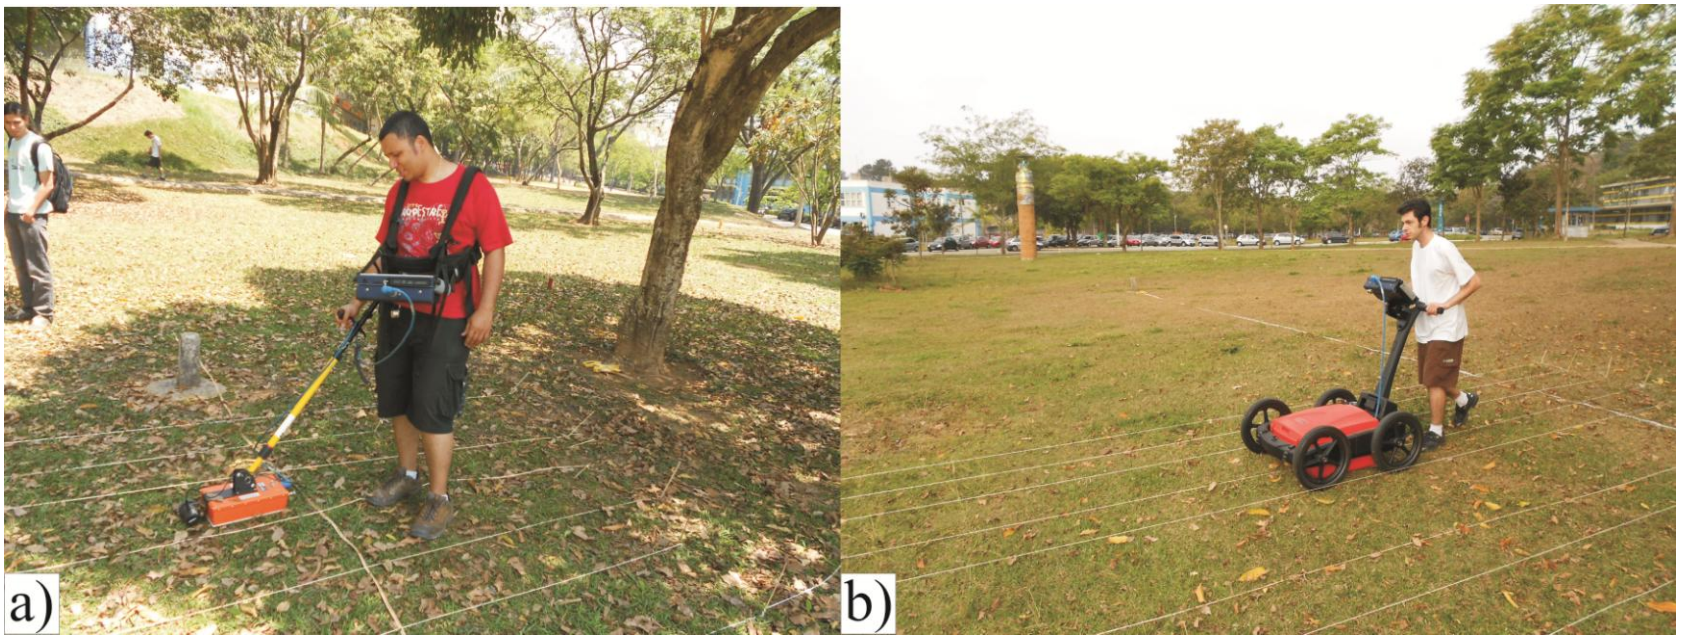

Aquisição de dados no SCGR. a) Antena de 900 MHz. b) Antena de 270 MHz.

Linha 2 – Tubos de PVC

200 MHz **270 MHz**

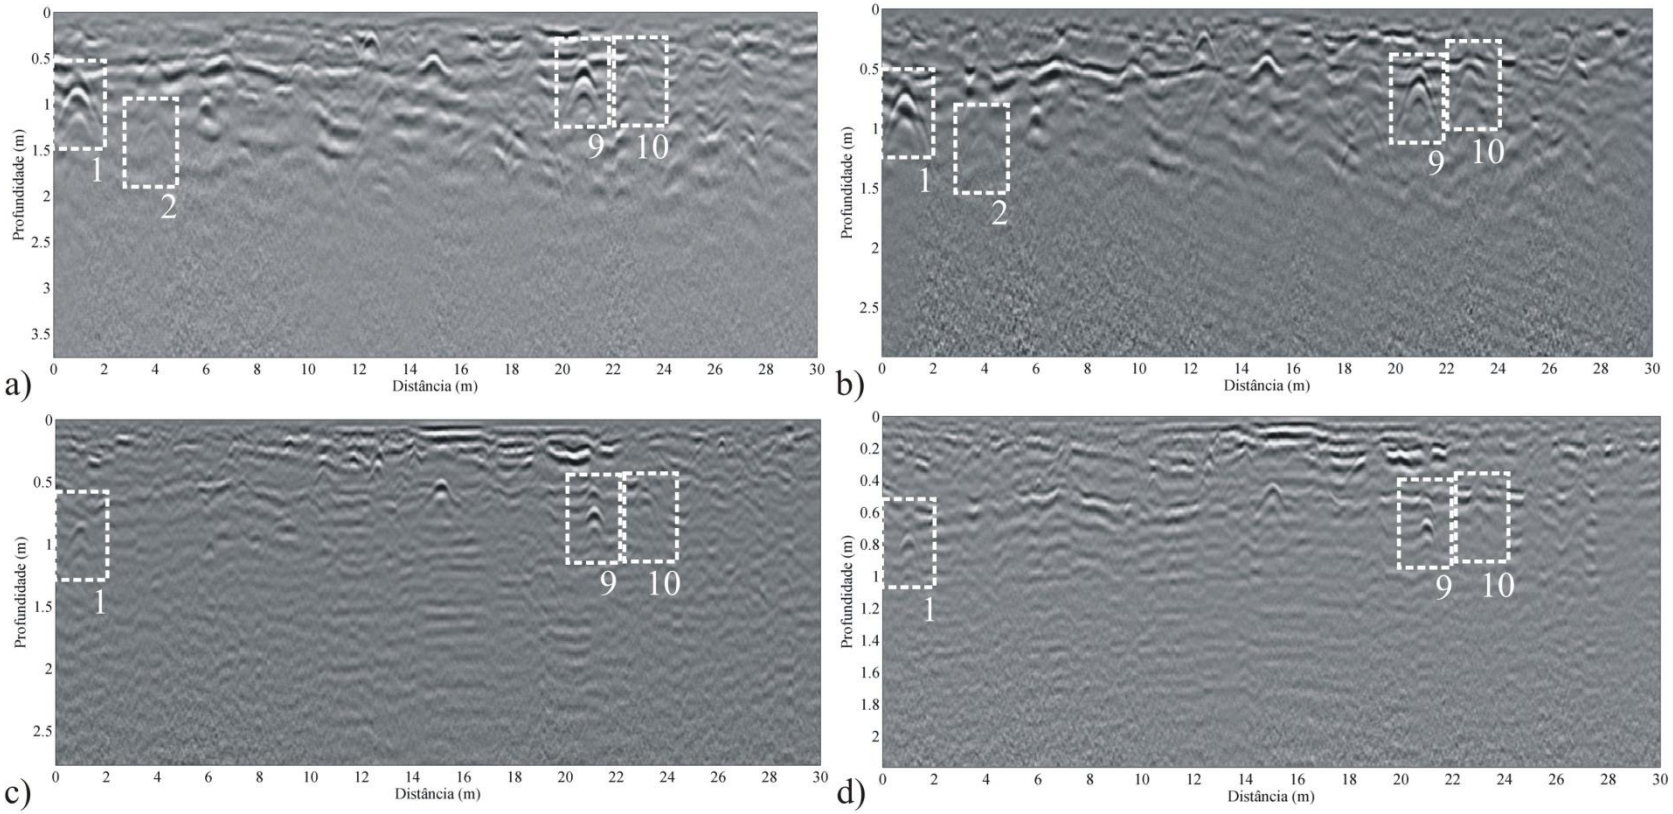

400 MHz **900 MHz**

Linha 3 – Manilhas de concreto

200 MHz **270 MHz**

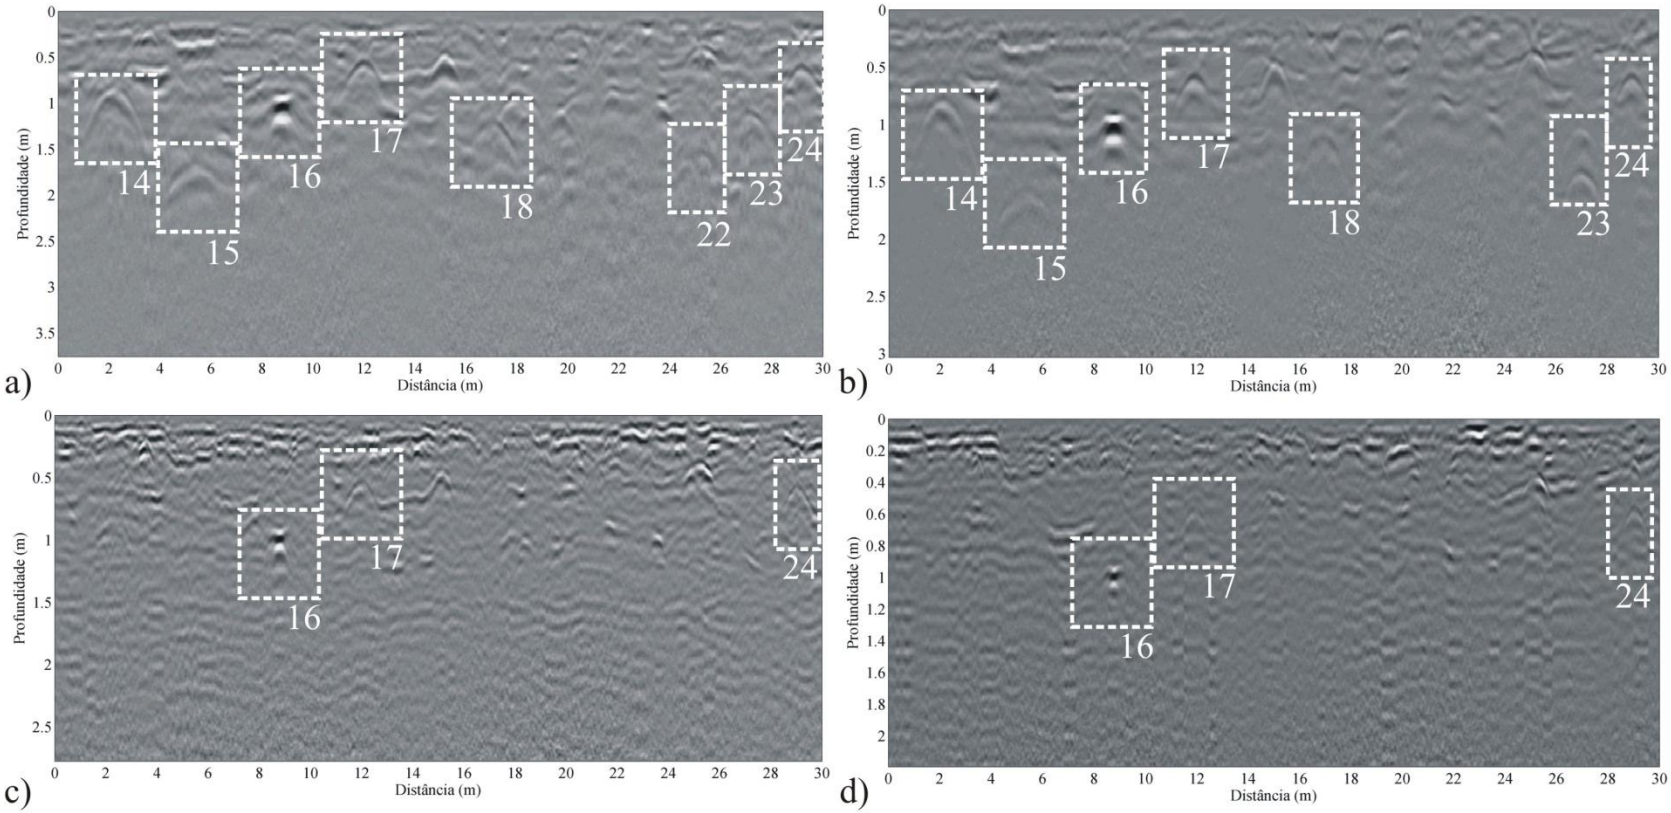

400 MHz **900 MHz**

Linha 4 – Tambores metálicos

200 MHz **270 MHz**

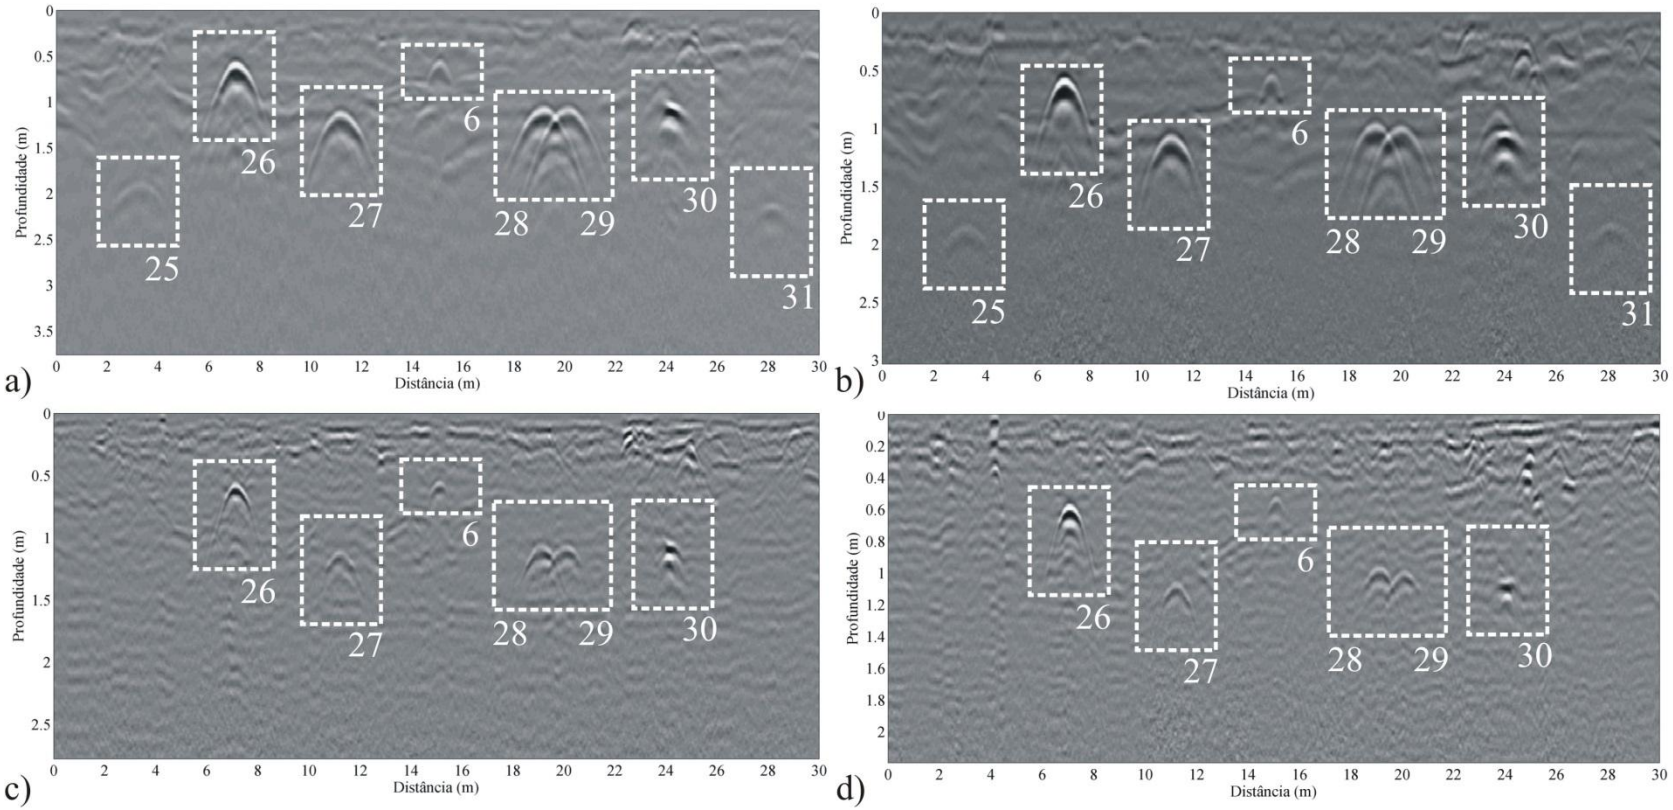

400 MHz **900 MHz**

Linha 5 – Tambores plásticos

200 MHz **270 MHz**

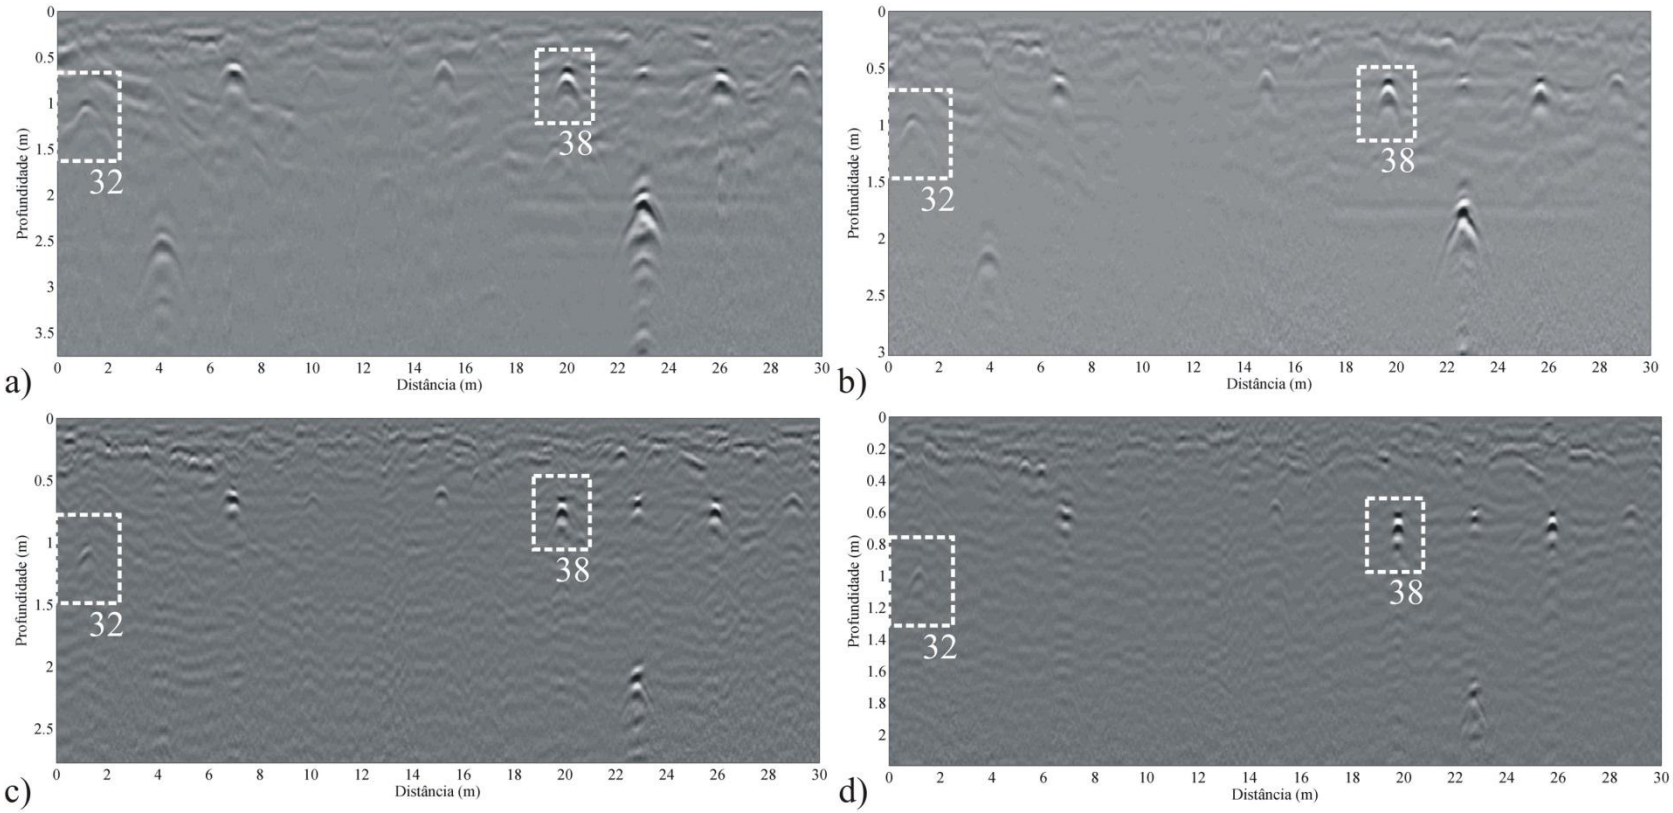

400 MHz **900 MHz**

Linha 6 – Tubos metálicos

200 MHz **270 MHz**

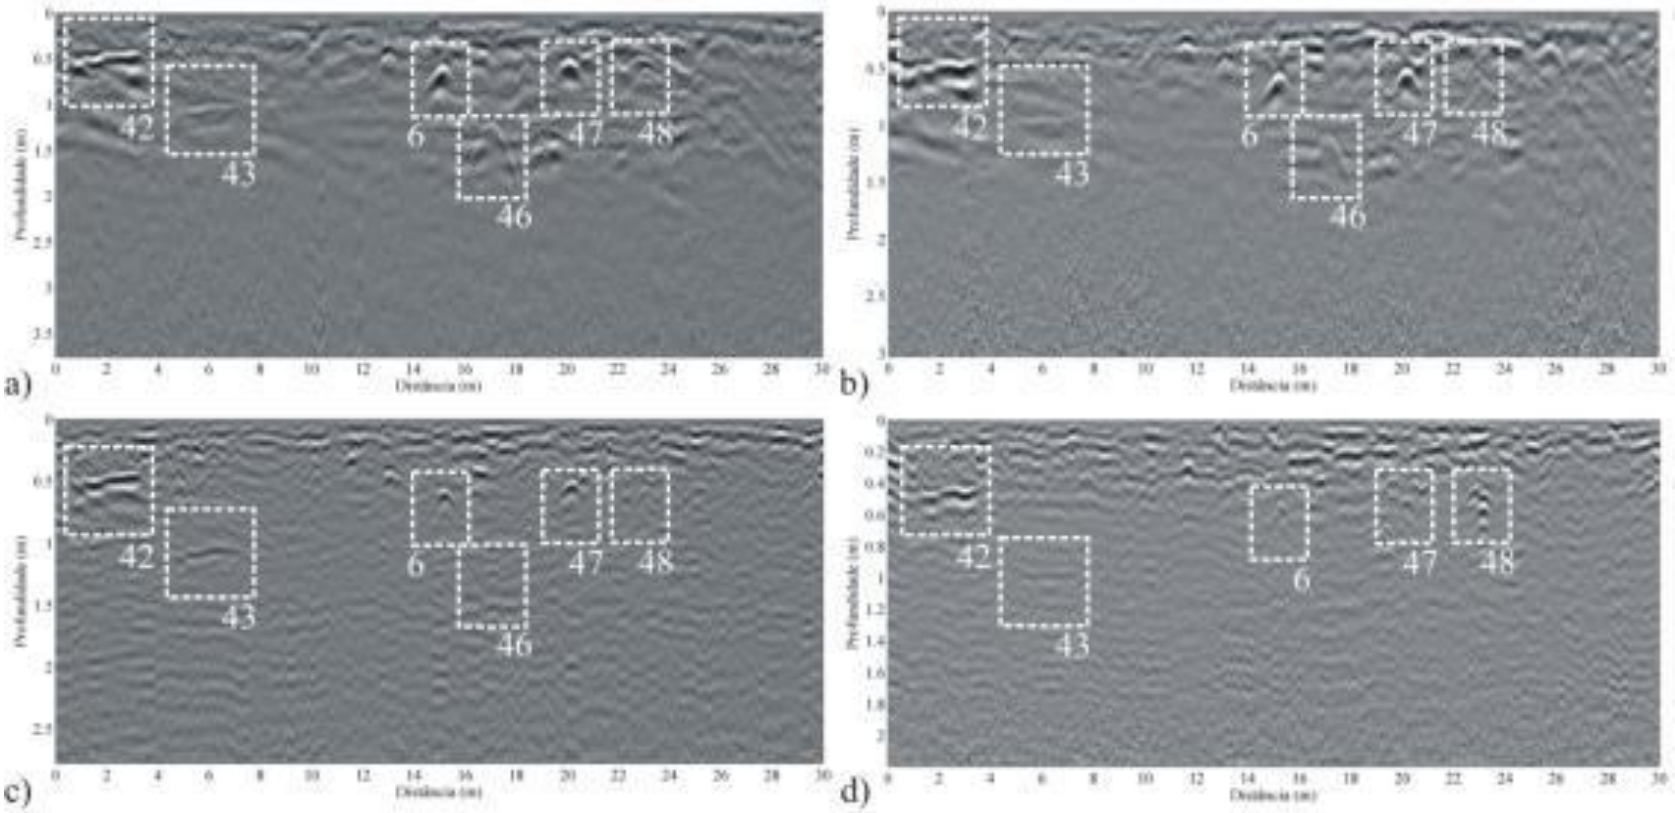

400 MHz **900 MHz**

Linha 7 – Tubos metálicos e cabos elétricos

200 MHz **270 MHz**

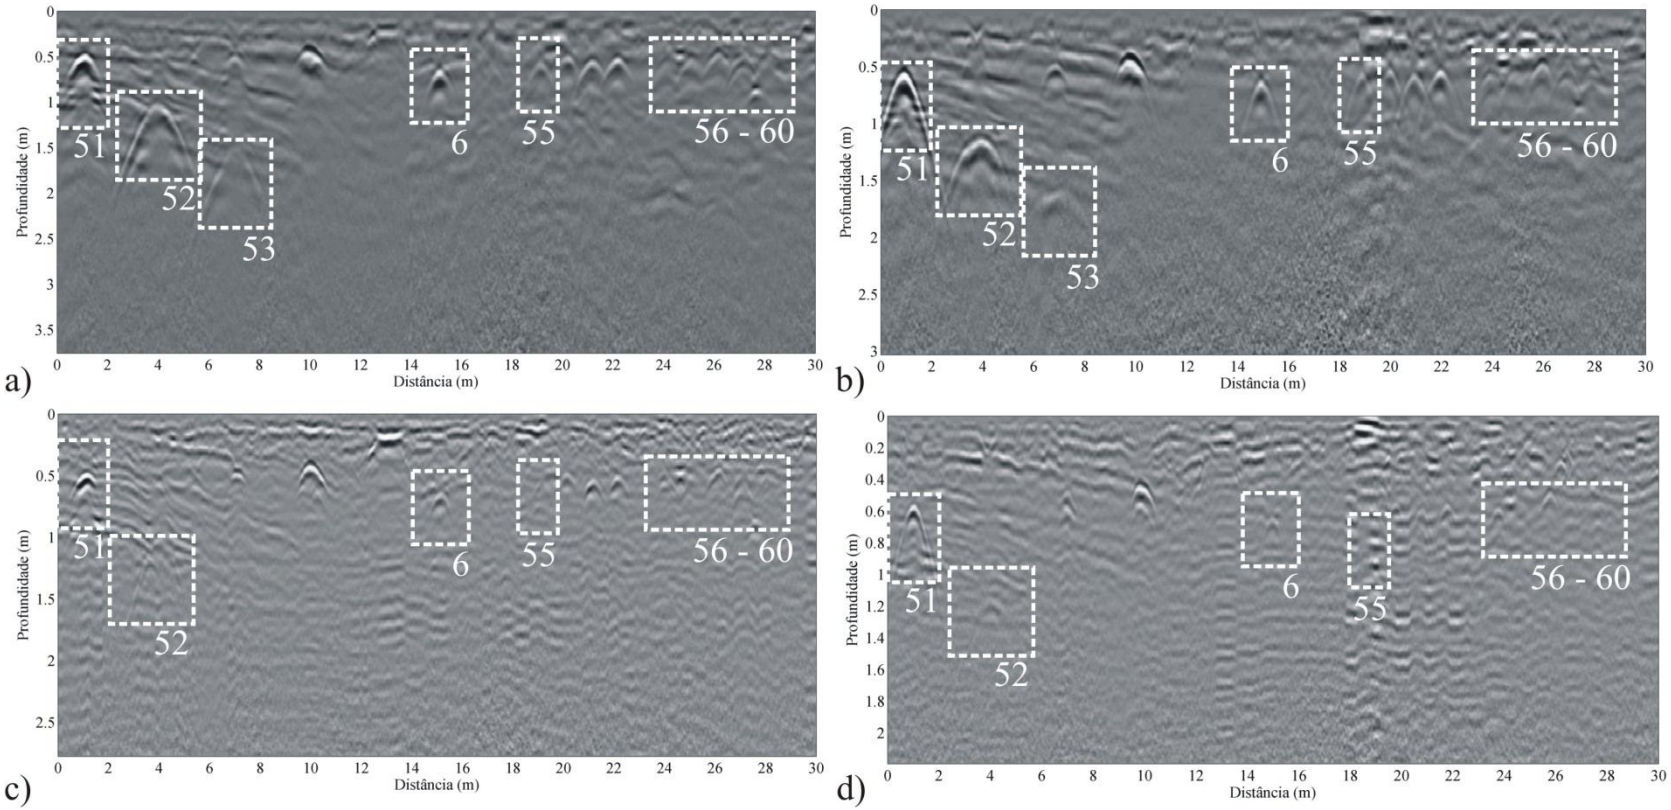

400 MHz **900 MHz**

Motivação

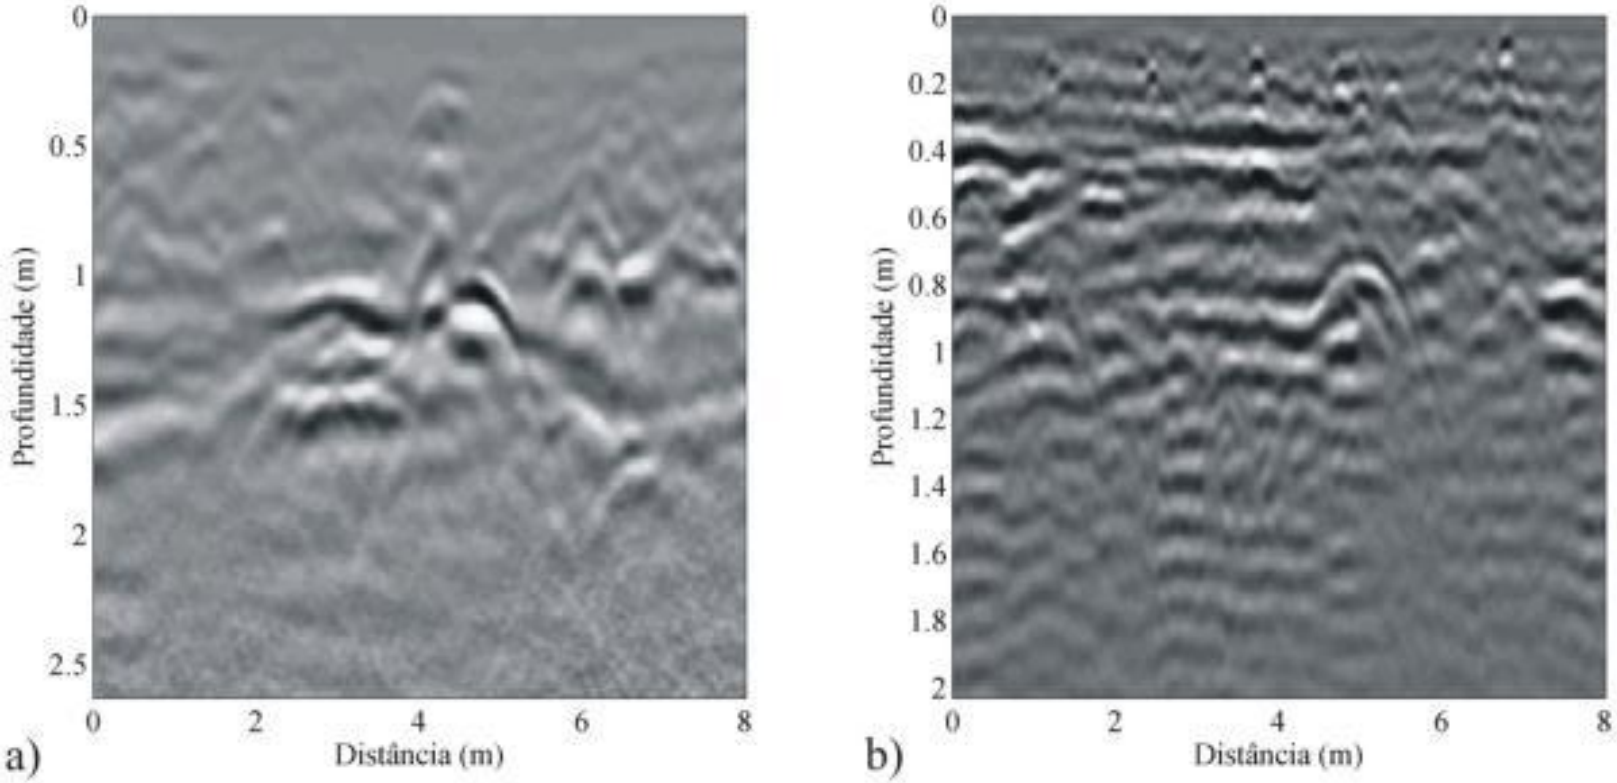

Exemplo de perfis GPR.

✓ Características extraídas dos perfis GPR:

	Características
Características Estatísticas	Variância
	Desvio médio absoluto
	4° momento
Características Espectrais	Densidade espectral
	Distribuição Wigner-Ville
	Transformada de Fourier no tempo curto
	Transformada da Wavelet

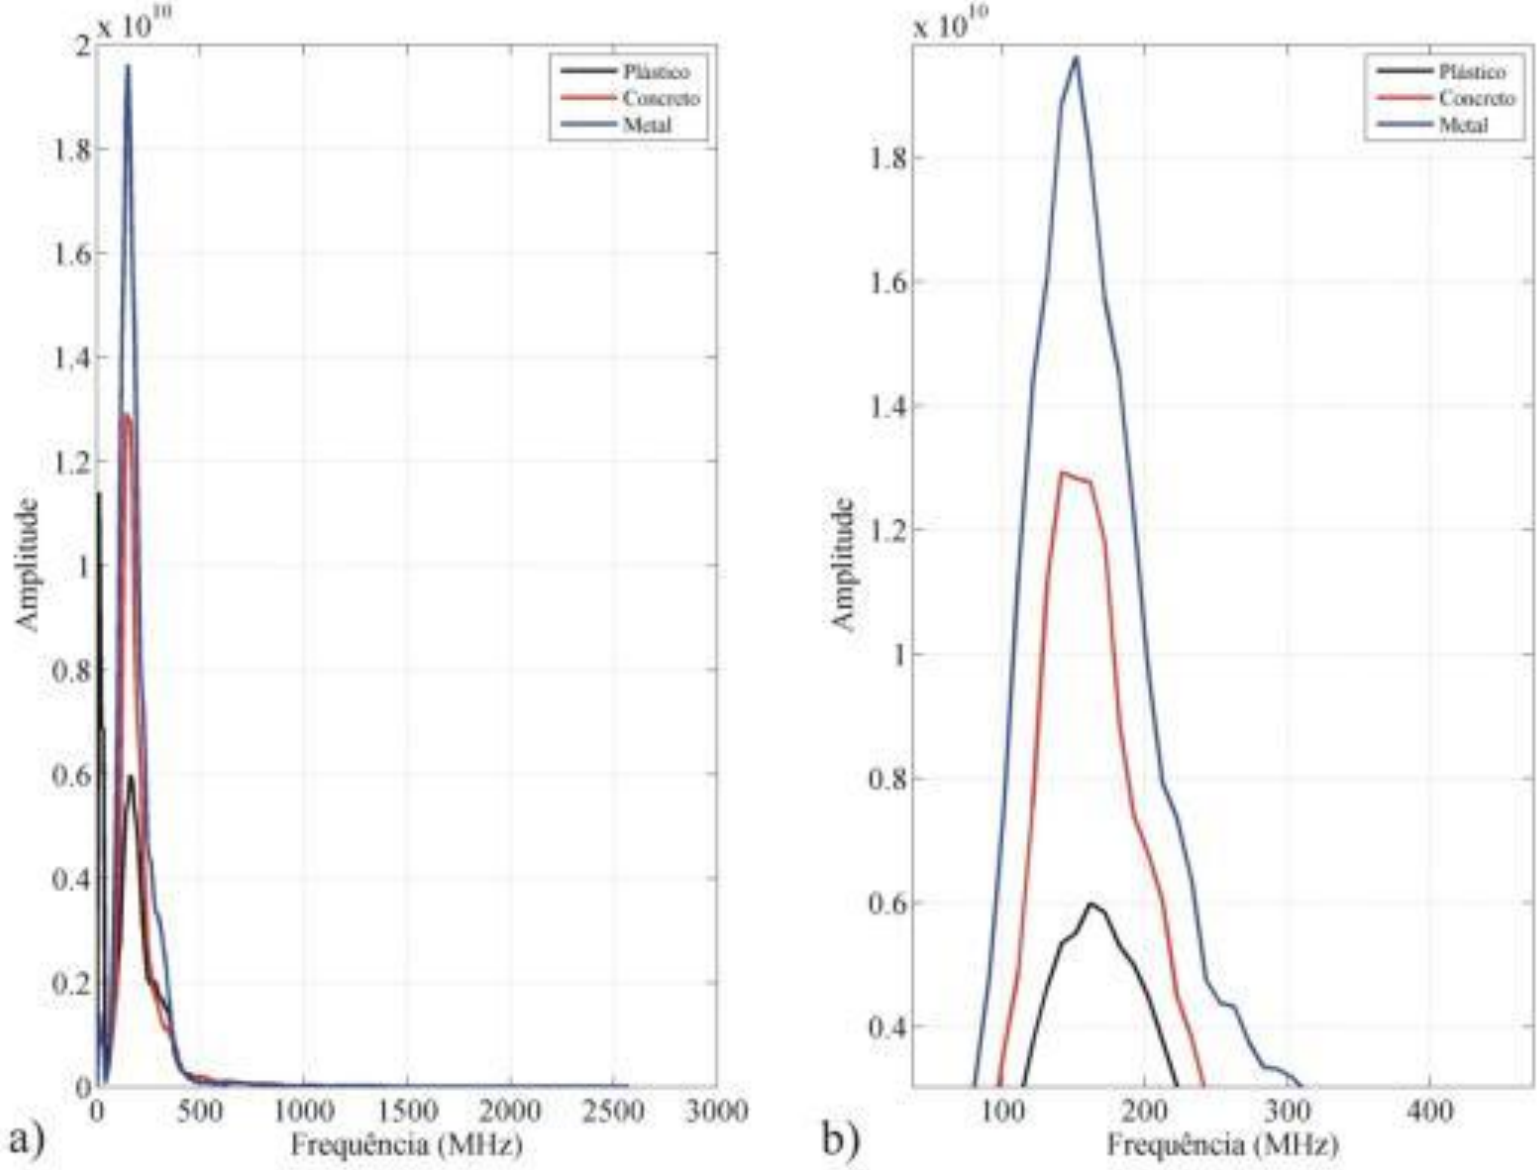

Densidade espectral para dados obtidos com antena de 200 MHz. a) Densidade espectral médio. b) Zoom da região do pico.

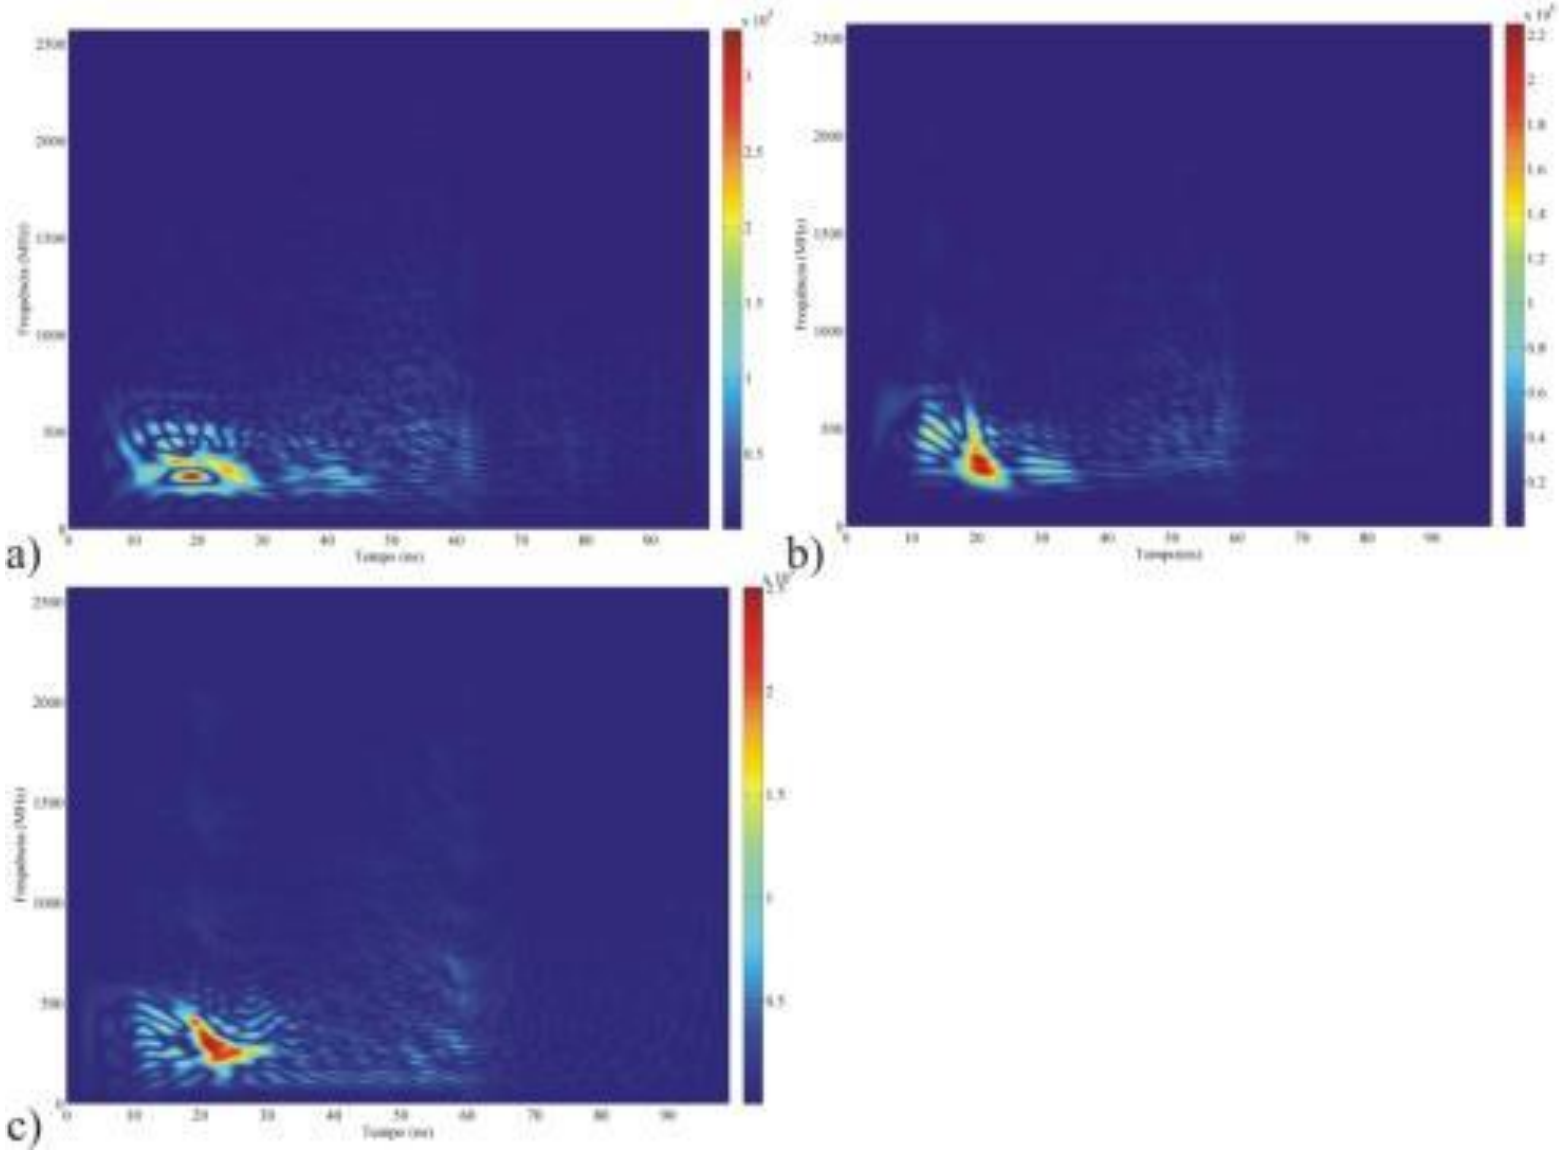

Distribuição Wigner-Ville para dados obtidos com antena de 200 MHz. a) Alvo plástico. b) Alvo de concreto. c) Alvo metálico.

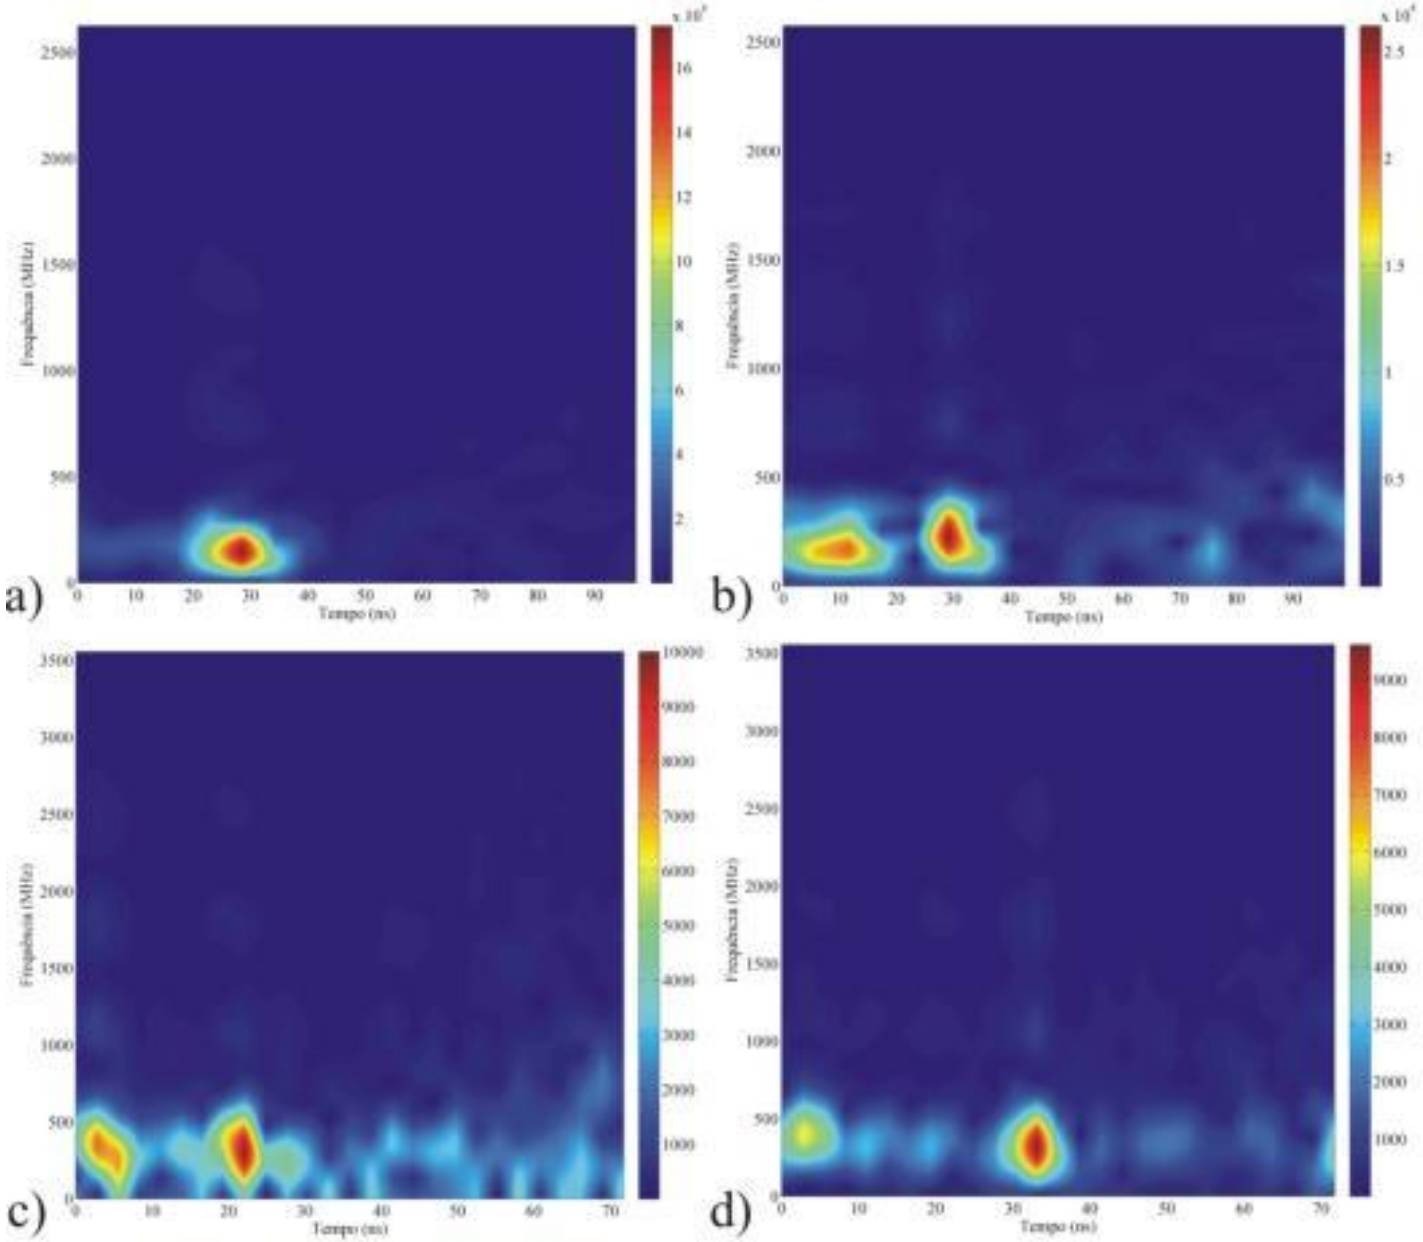

TFTC. a) 200 MHz no período seco. b) 200 MHz no período de chuva. c) 400 MHz no período seco. d) 400 MHz no período de chuva.

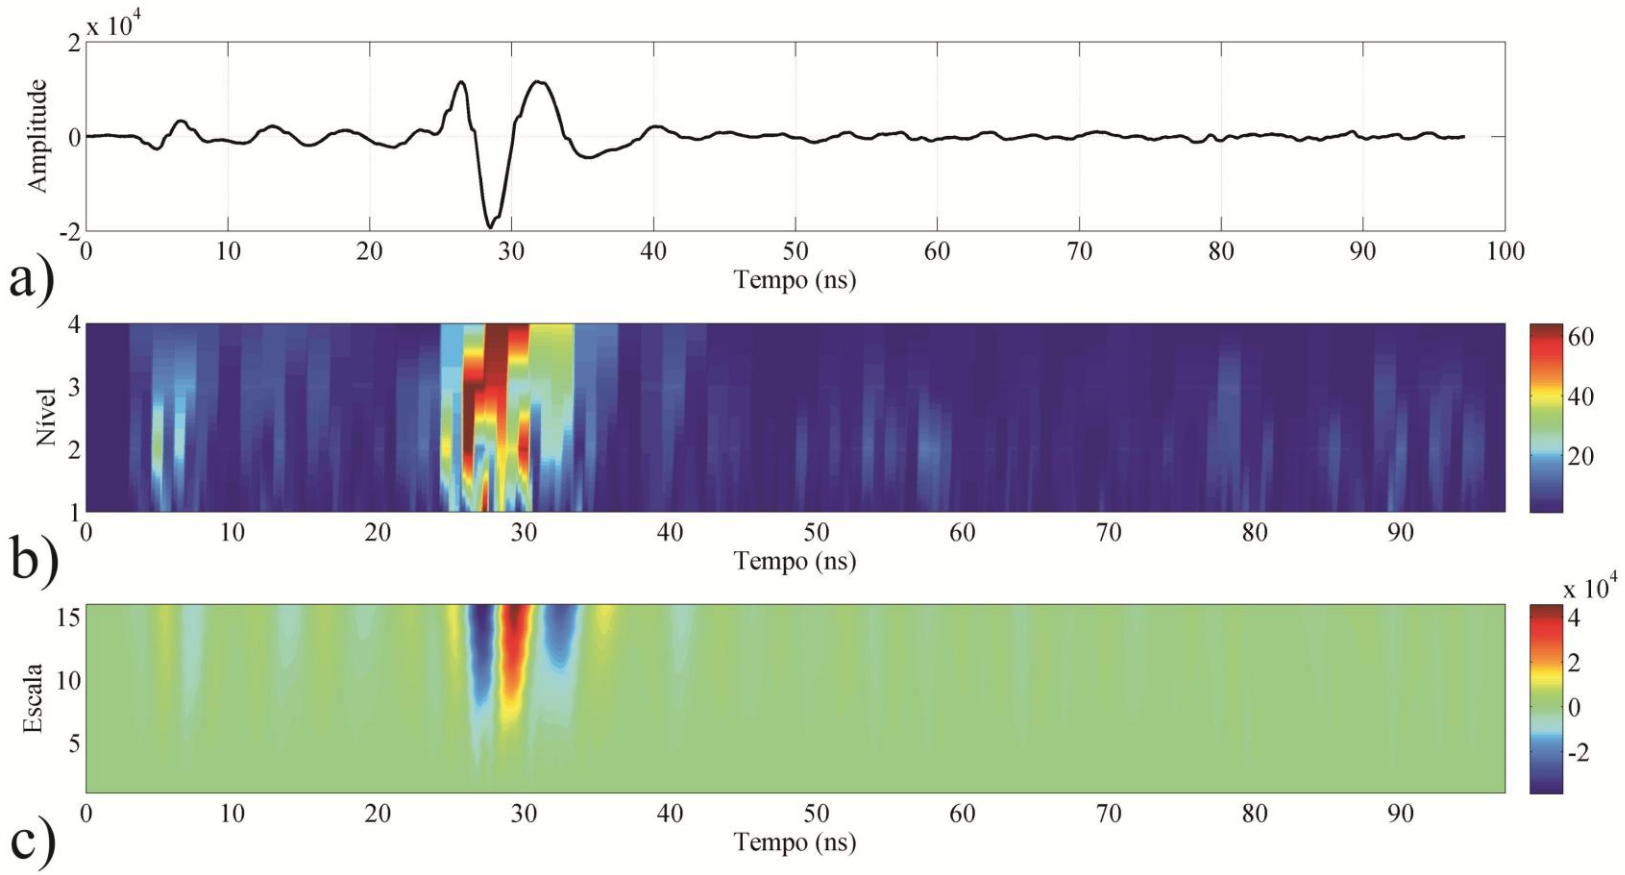

Transformada Wavelet (WT) para antena de 200 MHz. a) Sinal original. b) Transformada Wavelet Discreta (DWT). c) Transformada Wavelet Contínua (CWT).

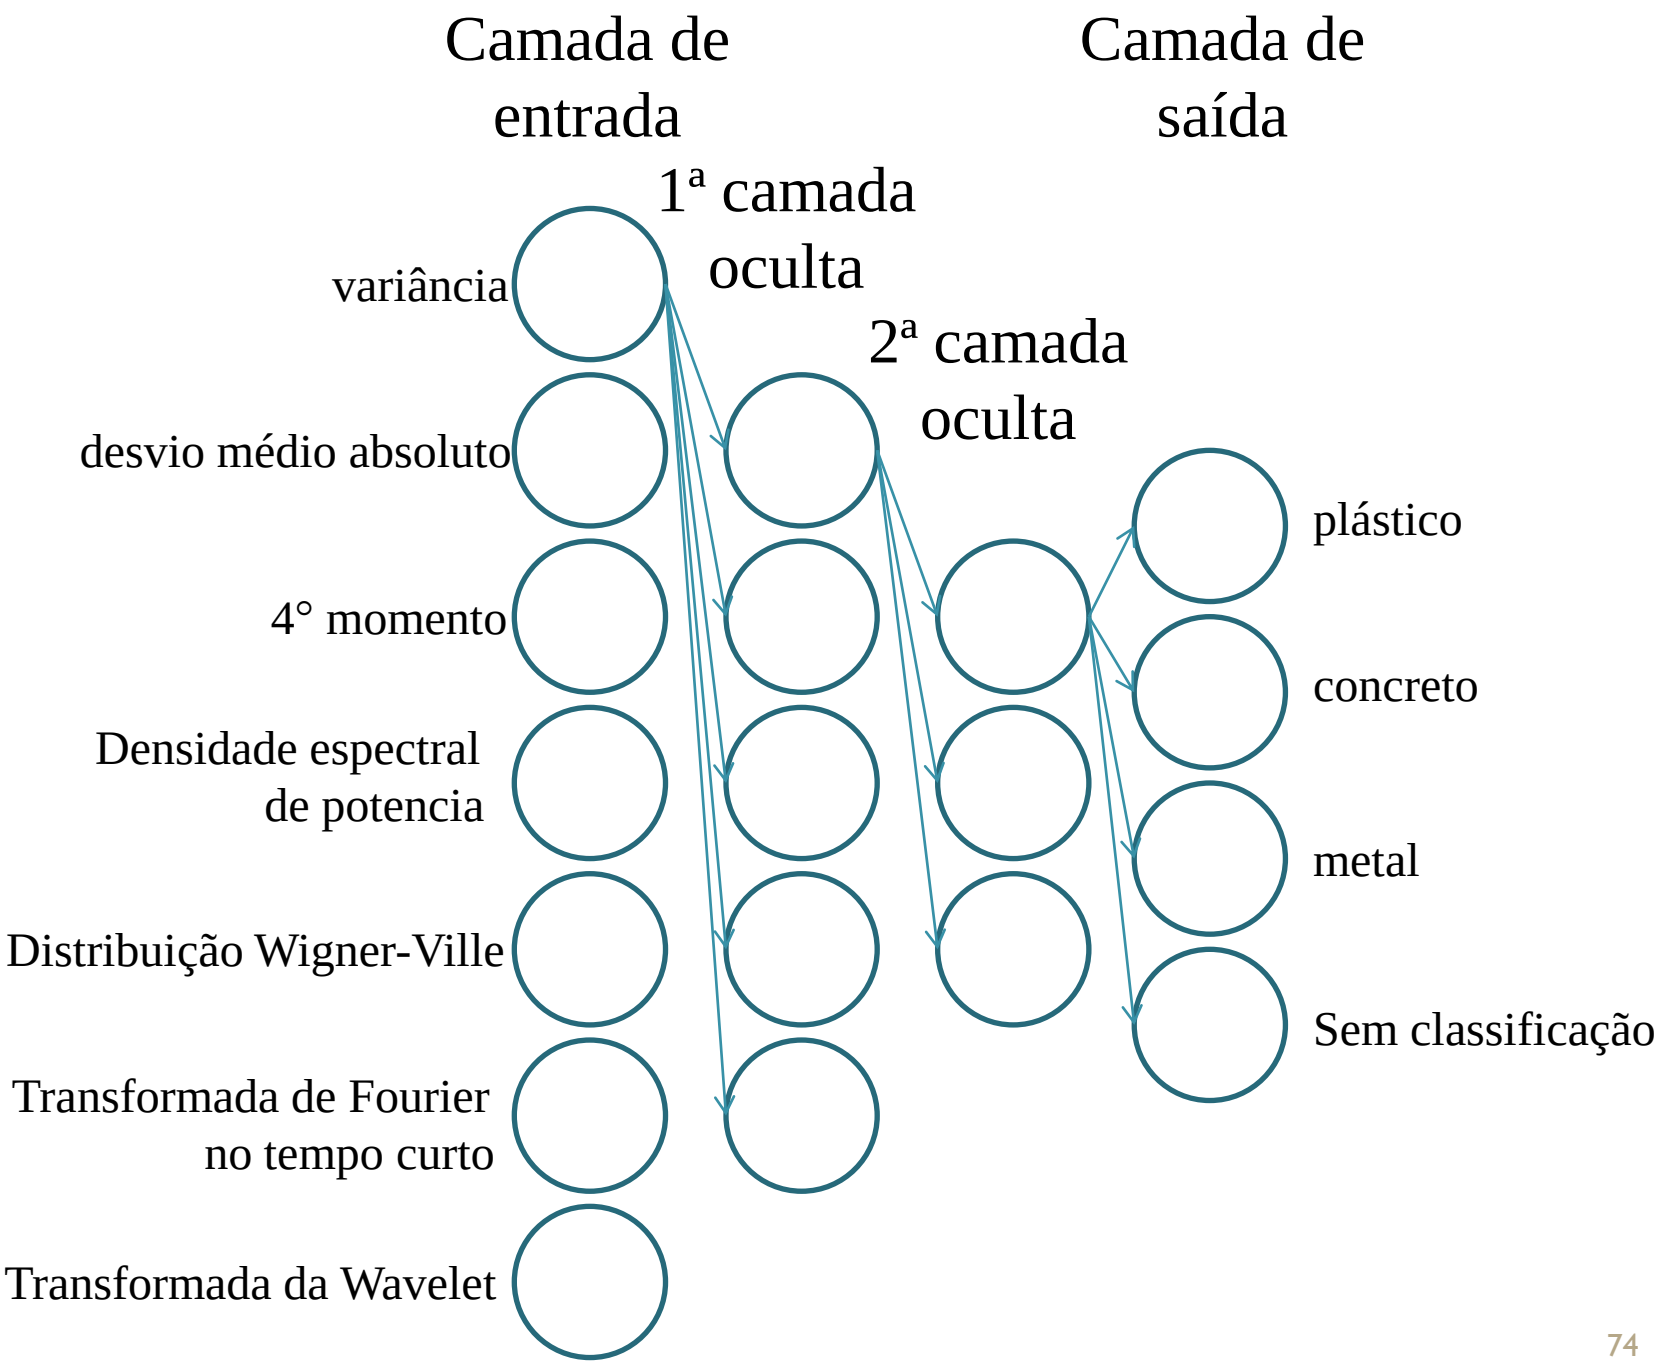
Camada de entrada
1ª camada oculta
2ª camada oculta
Camada de saída
variância
desvio médio absoluto
4° momento
Densidade espectral de potencia
Distribuição Wigner-Ville
Transformada de Fourier no tempo curto
Transformada da Wavelet
plástico
concreto
metal
Sem classificação

- ✓ Saídas:
  - Plástico: [1 0 0 0];
  - Concreto: [0 1 0 0];
  - Metal: [0 0 1 0];
  - Sem classificação: [0 0 0 1].

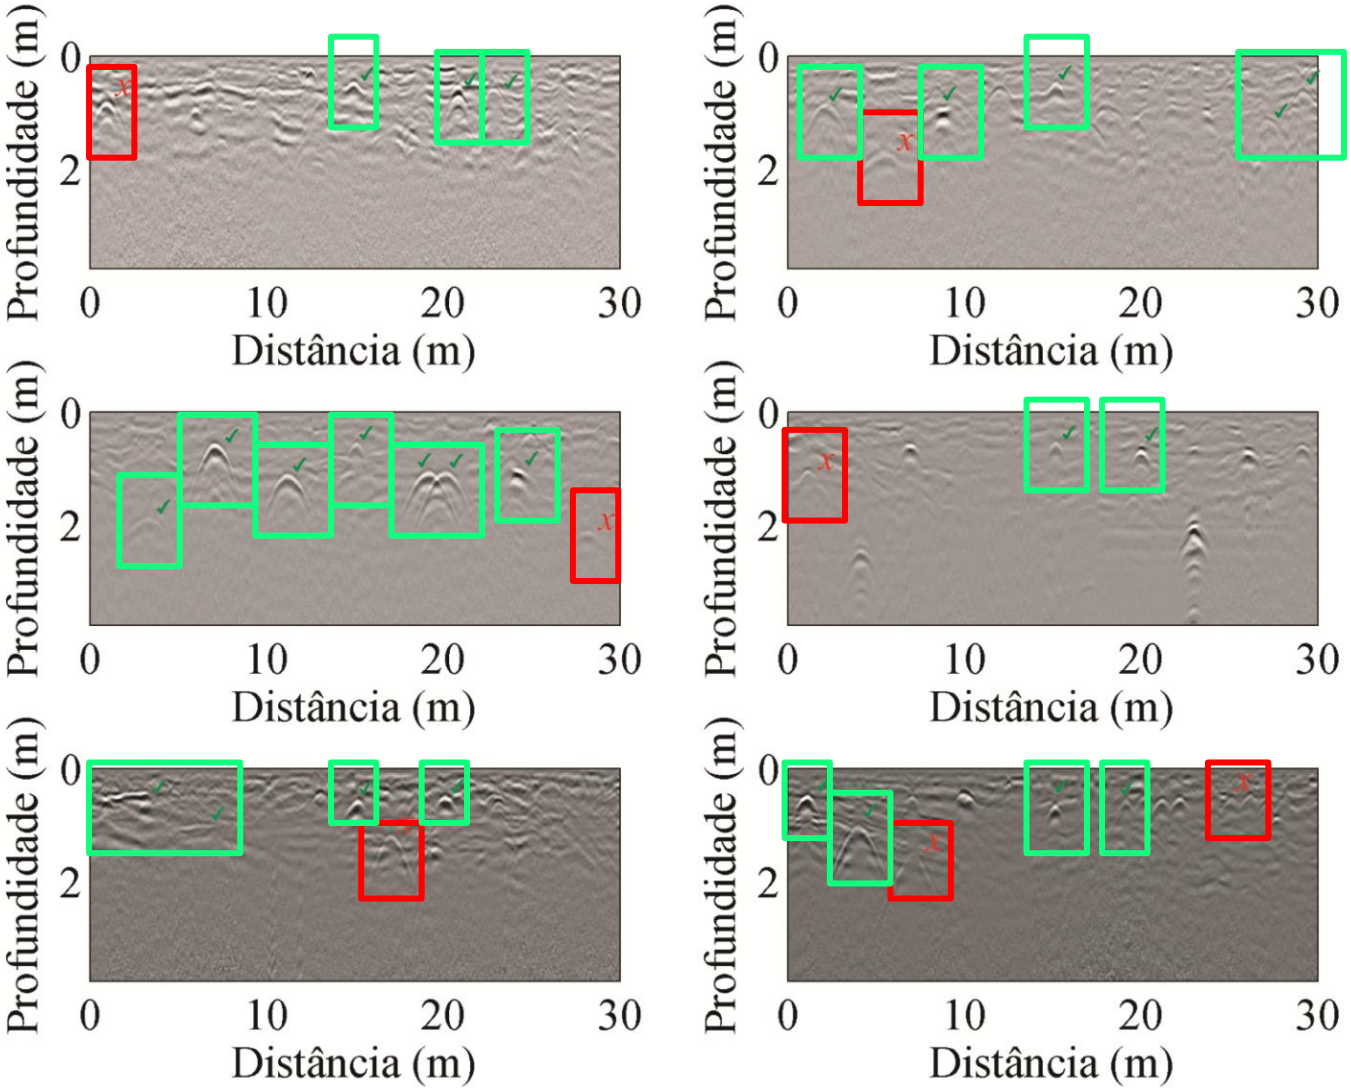

Resultados para a classificação automática utilizando RNA, em verde classificação correta e vermelho classificação errada. a) Linha 2. b) Linha 3. c) Linha 4. d) Linha 5. e) Linha 6. f) Linha 7.

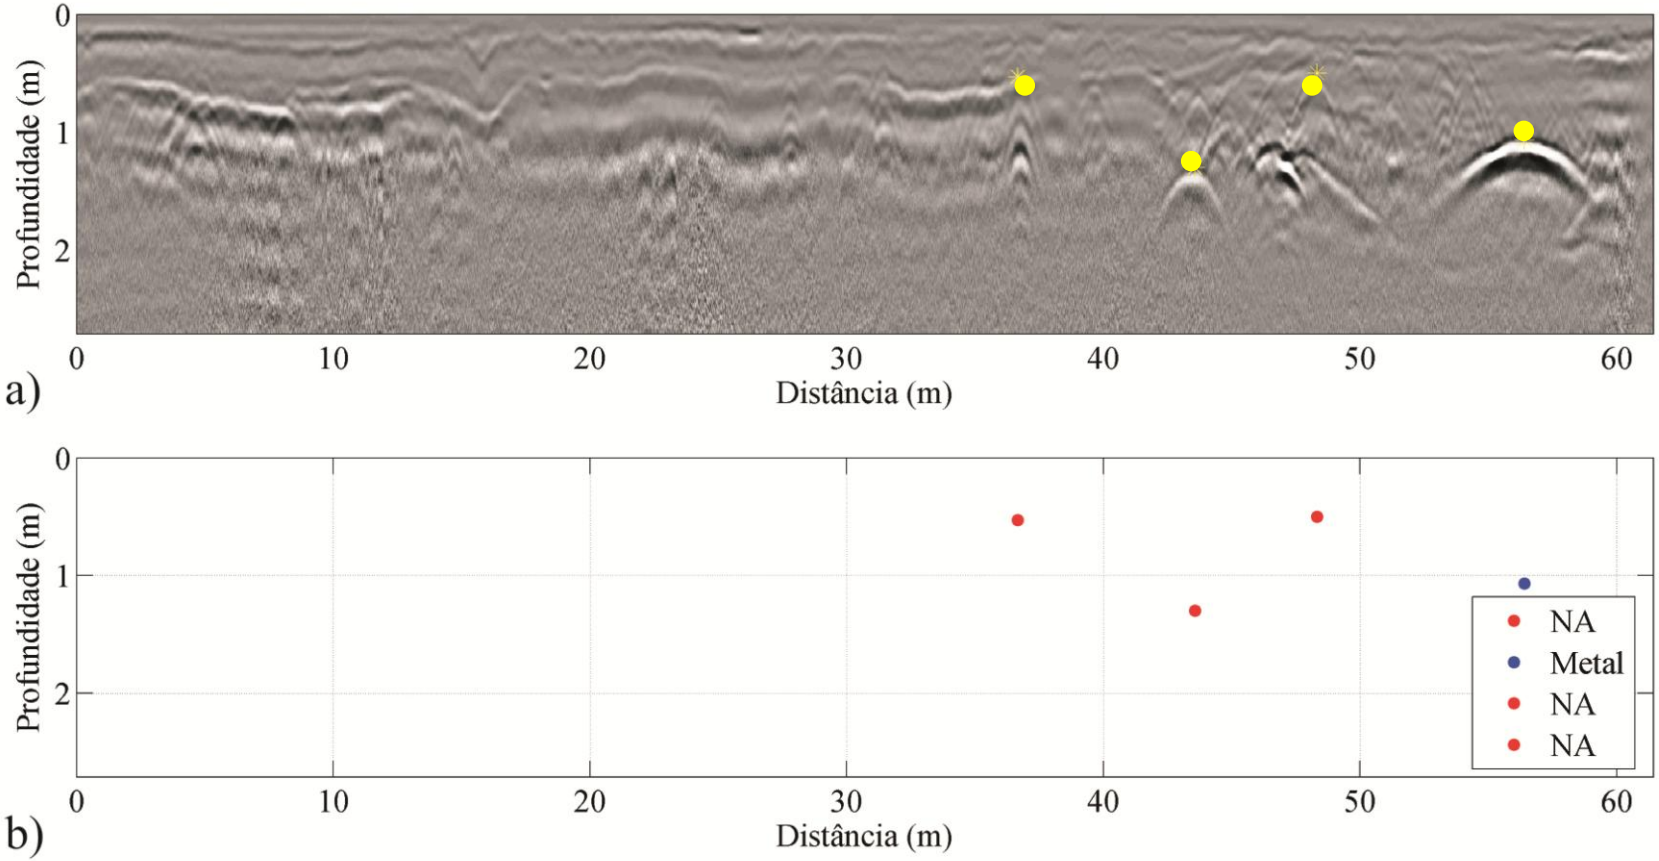

Resultados obtidos para a identificação e classificação em dados não controlados (Biologia/USP SP). a) Identificação das hipérboles. b) Classificação das hipérboles.

- ✓ A rede conseguiu uma taxa de acerto de 91%
- ✓ A utilização destas duas metodologias para identificar e classificar alvos em subsuperfície se mostrou eficiente e com bons resultados, contribuindo para reduzir as ambiguidades na interpretação dos dados geofísicos.

Aplicação do método GPR com RNA:

- **Campus USP Pirassununga**

CÉREBRO
?!
sen60 √144 v
x² log10
FÍSICA