



UNIVERSIDADE FEDERAL DO AMAZONAS
PROGRAMA MULTI-INSTITUCIONAL DE PÓS-GRADUAÇÃO EM
BIOTECNOLOGIA

SENSORIAMENTO AMBIENTAL COM GYMNOTIFORMES
(PISCES)

GILBERTO SCHWERTNER FILHO

Tese apresentada ao Programa Multi-Institucional de Pós-Graduação em Biotecnologia da Universidade Federal do Amazonas - UFAM, como parte dos requisitos para obtenção do título de Doutor em Biotecnologia, área de concentração Agroflorestal.

Manaus – Amazonas

Dezembro 2010



UNIVERSIDADE FEDERAL DO AMAZONAS
PROGRAMA MULTI-INSTITUCIONAL DE PÓS-GRADUAÇÃO EM
BIOTECNOLOGIA

SENSORIAMENTO AMBIENTAL COM GYMNOTIFORMES
(PISCES)

GILBERTO SCHWERTNER FILHO

Orientador: José Antônio Alves-Gomes, Dr. (INPA).

Co-orientador: Roberto F. Tavares Filho, Dr. (CTI).

Tese apresentada ao Programa Multi-Institucional de Pós-Graduação em Biotecnologia da Universidade Federal do Amazonas - UFAM, como parte dos requisitos para obtenção do título de Doutor em Biotecnologia, área de concentração Agroflorestal.

Manaus – Amazonas

Dezembro 2010

FICHA CATALOGRÁFICA

(Catalogação realizada pela Biblioteca Central da UFAM)

Schwertner Filho, Gilberto

S415s Sensoriamento ambiental com Gymnotiformes (Pisces) /
Gilberto Schwertner Filho. - Manaus: UFAM, 2010.
113 f.: il. color; 30 cm

Tese (Doutorado em Biotecnologia, área de concentração em
Agroflorestal) — Universidade Federal do Amazonas, 2010.

Orientador: Dr. José Antônio Alves-Gomes

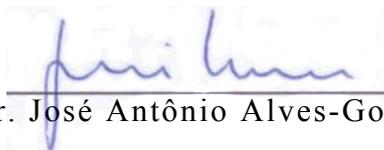
Co-orientador: Dr. Roberto F. Tavares Filho

1. Peixes elétricos 2. Água – Poluição por petróleo - Amazônia
3. Peixe – Proteção ambiental 4. Monitoramento biológico I. Alves-
Gomes, José Antônio(Orient.) II. Universidade Federal do Amazonas
III. Título

CDU(1997): 597.554.2(811)(043.2)

**SENSORIAMENTO AMBIENTAL COM GYMNOTIFORMES
(PISCES)**

BANCA EXAMINADORA



Dr. José Antônio Alves-Gomes

Instituto Nacional de Pesquisas do Amazonas – INPA



Dr. Antônio Ocimar Manzi

Instituto Nacional de Pesquisas do Amazonas – INPA



Dr. Ari de Oliveira Marques Filho

Instituto Nacional de Pesquisas do Amazonas – INPA



Dr. Bruce Rider Forsberg

Instituto Nacional de Pesquisas do Amazonas – INPA



Dr. Olavo Correa Pedrollo

Instituto de Pesquisas Hidráulicas – IPH/UFRGS

Tese apresentada ao Programa Multi-Institucional de Pós-Graduação em Biotecnologia da Universidade Federal do Amazonas - UFAM, como parte dos requisitos para obtenção do título de Doutor em Biotecnologia, área de concentração Agroflorestal.

Manaus – Amazonas

Dezembro 2010

“Há um grande silêncio que está sempre à escuta”...

(Mário Quintana)

...

*“é preciso a gente fazer um esforço para se comunicar com alguma dessas luzes que brilham,
de longe em longe”...*

(Antoine de Saint-Exupéry)

...

*“a partir deste instante
a liberdade será algo vivo e transparente
como um fogo ou um rio,
e a sua morada será sempre
o coração do homem.”*

(Thiago de Melo)

In memoriam:

Paula da Luz Simões Pires

Gilberto Schwertner

AGRADECIMENTOS

À FAPEAM – Fundação de Amparo à Pesquisa do Amazonas.

À PPGBIOTEC/UFAM – Programa de Pós-Graduação em Biotecnologia da Universidade Federal do Amazonas.

Ao LFCE/INPA – Laboratório de Fisiologia Comportamental e Evolução do Instituto Nacional de Pesquisas da Amazônia.

Ao CTI – Centro de Tecnologia da Informação Renato Archer.

À Pós-Graduação do IPH/UFRGS – Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul.

Ao Projeto COGNITUS – PETROBRAS.

Ao Projeto FRONTEIRA – INPA.

Ao IFAM/EAFSGC – Instituto Federal Educação, Ciência e Tecnologia do Amazonas, Escola Agrotécnica Federal São Gabriel da Cachoeira.

Ao IFFARROUPILHA – Instituto Federal Educação, Ciência e Tecnologia Farroupilha.

Especial Agradecimento:

José Antônio Alves-Gomes; Roberto Fernandes Tavares Filho; Ilse Walker; Lauro Frederico Barbosa da Silveira; Aristides Pavani Filho; Edgar Alberto Brito; Antônio Ocimar Manzi; Ari Oliveira Marques Filho; Bruce Rider Forsberg; Olavo Correa Pedrollo; Spartaco Astolfi Filho; José Odair Pereira; Carlos David Canabarro Machado de Santana; Adília Nogueira; Daniel Ricardo Arsand; Cléria Bitencorte Meller; Everton Freitas Martins; Carlismar S. Guedes.

Aos colegas do INPA/LFCE/LTBM; colegas de pesca do INPA/CPBA/CPEC; amigos de Santa Rosa – Porto Alegre – Campinas – Manaus – São Gabriel da Cachoeira (IFFARROUPILHA – UFRGS/IPH – CTI/DRVC – INPA e UFAM/PPGBIOTEC – IFAM/EAFSG).

Aos seres que deram a vida pela ciência.

Aos meus filhos.

À minha família.

RESUMO

A Amazônia Brasileira contém a maior diversidade conhecida de peixes da Ordem Gymnotiformes. Estes peixes elétricos, como são popularmente conhecidos, têm sido intensamente estudados por causa de sua capacidade bioelétrica. Em função destes dois fatores, neste estudo desenvolveu-se procedimentos biotecnológicos para sensoriamento ambiental por meio do processamento e análise das descargas do órgão elétricos (DOEs) de Gymnotiformes. Estes procedimentos geraram subsídios para compor um sistema de alerta ambiental, com peixes elétricos como biossensores de contaminações por petróleo na água, com dois principais fatores modelados: depleção de oxigênio dissolvido (hipoxia) e a presença da fração solúvel de petróleo em água (Benzeno, Tolueno, Etilbenzeno e Xileno - BTEX). Foram desenvolvidos algoritmos computacionais utilizando-se técnicas de inteligência artificial com redes neurais artificiais de múltiplas camadas. Estes algoritmos foram testados para o reconhecimento de padrões nas DOEs de Gymnotiformes, com a classificação por meio de características mais basais da taxa de repetição (pulso e onda), e, com a classificação por Genero de Gymnotiformes onduladores. Redes neurais artificiais de uma camada interna com 64 neurônios, algoritmo de treinamento retropropagativo com renovação das taxas de aprendizados por relações heurísticas e validação cruzada via erro médio quadrático, obtiveram máxima performance na avaliação computacional das DOEs.

Palavras-chave: Peixes Elétricos Neotropicais, Biomonitoramento, Redes Neurais Artificiais.

ABSTRACT

The Brazilian Amazon contains the greatest diversity of fish of the Order Gymnotiformes. These “electric fish”, as they are popularly known, have been intensively studied due to their bioelectric capability. As a product of these two factors, in this study technological procedures were developed to be used in environmental monitoring warning system, through the processing and analysis of the gymnotiform's electric organ discharges (EODs). These procedures subsidized the composition of an environment alert system, with electric fish as biosensors, for contamination of water by crude oil, with two main factors modeled: dissolved oxygen depletion (hypoxia) and the presence of the oil's soluble fraction in water (Benzene, Toluene, Ethyl-benzene and Xylene – BTEX). Computational algorithms using artificial intelligence with artificial neural network of multiple layers were developed. These algorithms were able to recognize and classify gymnotiform signals by their basal repetition rate into pulse and wave types and, further, classified the wave species into their respective correct genera. Neural networks of one internal layer of 64 neurons, training backpropagation algorithms with heuristical renewal learning rates and cross validation by the mean squared error, obtained the maximum performance in the computational evaluation of the EODs.

Keywords: Neotropical Electric Fish, Biomonitoring, Artificial Neural Networks.

ACRONÔMIOS

AM: Estado do Amazonas, Brasil.

BTEX: Mistura complexa de hidrocarbonetos composta por Benzeno, Tolueno, Etilbenzeno e Xilenos.

CE: Condutividade elétrica.

CONAMA: Conselho Nacional de Meio Ambiente.

CV: Coeficiente de variação (desvio padrão/média).

DOE: Descarga do Órgão Elétrico.

Hz: Hertz, ciclos por segundo.

IA: Inteligência Artificial.

INPA: Instituto Nacional de Pesquisas do Amazonas.

l: Litro.

LFCE: Laboratório de Fisiologia Comportamental e Evolução.

mg/l: Miligramas por Litro.

ml: Mililitro.

mm: Milímetro.

ms: Milissegundos.

° C: Graus Celsius.

OD: Oxigênio Dissolvido (em miligramas por Litro).

ppm: Parte por milhão; equivalente em mg/L.

PVC: Policloreto de Vinila; IUPAC: Policloroeteno.

s: Segundos.

T°: Temperatura em ° C.

V: Volts.

μS/cm: Micro Siemens por centímetro, medida de CE.

LISTA DE FIGURAS

Figura 01– BTEX: <u>B</u> enzenos, <u>T</u> oluenos, <u>E</u> tilbenzenos e <u>X</u> ilenos (orto, meta e para).....	15
Figura 02 – Distribuição dos Gymnotiformes no Neotrópico (Albert e Crampton, 2005).....	18
Figura 03 – DOE tipo Pulso (Gymnotidae).....	20
Figura 04 – DOE tipo Onda (Apteronotidae).....	20
Figura 05 – DOE de <i>Electrophorus</i>	21
Figura 06 – DOE de <i>Gymnotus</i>	22
Figura 07 – DOE de <i>Gymnorhamphichthys</i>	22
Figura 08 – DOE de <i>Rhamphichthys</i>	22
Figura 09 – DOE de <i>Hypopygus</i>	23
Figura 10 – DOE de <i>Stegostenopus</i>	23
Figura 11 – DOE de <i>Steatogenys</i>	24
Figura 12 – DOE de <i>Brachyhypopomus</i> sp. I.....	25
Figura 13 – DOE de <i>Brachyhypopomus</i> sp. II.....	25
Figura 14 – DOE de <i>Microsternarchus</i>	25
Figura 15 – DOE de <i>Racenisia</i>	25
Figura 16 – DOE de <i>Sternopygus</i>	26
Figura 17 – DOEs de <i>Distocycclus</i>	27
Figura 18 – DOEs de <i>Eigenmannia</i>	27
Figura 19 – DOEs de <i>Adontosternarchus</i>	28
Figura 20 – DOEs de <i>Apteronotus</i>	28
Figura 21 – DOEs de <i>Orthosternarchus</i>	28
Figura 22 – DOEs de <i>Parapteronotus</i>	28
Figura 23 – DOEs de <i>Platyurosternarchus</i>	29
Figura 24 – DOEs de <i>Porotergus</i>	29
Figura 25 – DOEs de <i>Sternarchella</i>	29
Figura 26 – DOEs de <i>Sternarchogiton</i>	29
Figura 27 – DOEs de <i>Sternarchorhamphus</i>	29
Figura 28 – DOEs de <i>Sternarchorhynchus</i>	29
Figura 29 – Esquema do neurônio artificial MCP.....	34
Figura 30 – Rede neural artificial de multiplas camadas (rede 5-3-1).....	35
Figura 31 – Rede neural com 1 camada interna.....	36
Figura 32 – Rede neural com 2 camadas internas.....	36
Figura 33 – Exemplo de uma hipotética superfície de desempenho: gráfico à esquerda representa a variação dos parâmetros no espaço unidimensional e à direita a variação no espaço bidimensional. Fonte: Hagan et al., 1996.....	38
Figura 34 – Exemplo da renovação da taxa de aprendizado constante em uma hipotética superfície de desempenho: em vermelho taxas pequenas, em azul taxas grandes. Fonte: Pedrollo, 2007.....	39
Figura 35 – Gráficos das avaliações da sequência de treinamento com o algoritmo desenvolvido para tese.....	41
Figura 36 – Gráficos da sequência de treinamento com o algoritmo desenvolvido para tese, validando uma séire de dados reais, a parada do sistema ocorreu em 3650 ciclos com o limiar de precisão atingido.....	41
Figura 37 – Gráficos da sequência de treinamento ótimo com o algoritmo desenvolvido para tese. No eixo das abcissas estão os ciclos de treinamento, nas ordenadas estão valores adimensionais representativos das magnitudes da raiz quadrada dos erros, da taxa de aprendizado e da soma das derivadas.....	43
Figura 38 – Gráficos da sequência de treinamento não convergente	44
Figura 39 – <i>Parapteronotus hasemani</i>	48
Figura 40 – Tanques experimentais e haste com eletrodos.....	51
Figura 41 – Esquema de rede neural artificial para classificação de peixes pulsadores e onduladores.....	53
Figura 42 – Sinais de peixes elétricos onduladores: A) <i>Sternopygus</i> sp.; B) <i>Distocycclus</i> sp.; C) <i>Eigenmannia</i> sp.; D) <i>Parapteronotus hasemani</i>	55
Figura 43 – Sinais de peixes elétricos onduladores: A) <i>Sternarchorhynchus roseni</i> ; B) <i>Platyurosternarchus macrostomus</i> ; C) <i>Adontosternarchus balaneops</i> ; D) <i>Orthosternarchus tamandua</i>	55
Figura 44 – Sinais de peixes elétricos onduladores: A) <i>Apteronotus albifrons</i> ; B) <i>Sternarchogiton nattereri</i> ; C) <i>Porotergus gymnotus</i> ; D) <i>Sternarchella schotti</i>	56
Figura 45 – Sinais de peixes elétricos onduladores: A) <i>Parapteronotus hasemani</i> ; B) <i>P. hasemani</i> ; C) <i>Apteronotus bonapartii</i> ; D) <i>Sternarchorhamphus muelleri</i>	56
Figura 46 – Esquema de rede neural artificial para classificação de peixes onduladores.....	57

Figura 47 – Equipamentos de gravações. A) tubo experimental de 750 mL; B) amplificador diferencial AC/DC; C) gaiola de Faraday; D) conversor A/D; E) osciloscópio; F) computador.....	59
Figura 48 – Gaiola de Faraday fechada.....	59
Figura 49 – Tubo experimental para oxigênio dissolvido (OD).....	60
Figura 50 – Retirada de amostra do tubo experimental para oxigênio dissolvido (OD).....	60
Figura 51 – Esquema de rede neural artificial para hipoxia.....	61
Figura 52 – Tubo experimental (750 ml) para BTEX com sistema de aeração constante.....	62
Figura 53 – Esquema de rede neural artificial para detecção de BTEX.....	64
Figura 54 – Esquema de rede neural artificial para classificação de BTEX em diferentes concentrações.....	64
Figura 55 – Função de ativação sigmoide unipolar; representada pela equação: $unisig=1/(1 + \exp(-n))$	66
Figura 56 – Gráficos de desempenho da rede neural artificial 64-1 para classificação de gimnotiformes pulsadores e onduladores.....	69
Figura 57 – Acompanhamento de treinamento e validação de rede neural artificial classificadora de peixes onduladores.....	74
Figura 58 – Sinais normais (azul) e de hipoxia (vermelho); à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.....	77
Figura 59 – Redes neurais artificiais 64-1 com 100% de acertos, taxa de aprendizado e soma das derivadas.....	81
Figura 60 – DOEs Normal (em azul) e na presença de 5 mg/l de BTEX (em vermelho), à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.....	84
Figura 61 – DOEs Normal (em azul) e na presença de 10 mg/l de BTEX (em vermelho), à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.....	84
Figura 62 – DOEs Normal (em azul) e na presença de 50 mg/l de BTEX (em vermelho), à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.....	84
Figura 63 – DOEs Normal (em azul) e na presença de 100 mg/l de BTEX (em vermelho), à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.....	85
Figura 64 – Rede neural artificial 64-1 com 100% de acertos, taxa de aprendizado e soma das derivadas.....	87
Figura 65 – Rede neural artificial 64-3 com 100% de acertos, taxa de aprendizado e soma das derivadas.....	88
Figura 66 – Esquema de redes neurais artificiais: A) classificação de peixes pulsadores e onduladores, B) classificação de peixes onduladores, C) detecção de hipoxia, D) detecção de BTEX e E) classificação de BTEX em diferentes concentrações.....	89

LISTA DE QUADROS E TABELAS

Quadro 01 – Lista de Generos de Gymnotiformes avaliados.....	52
Quadro 02 – Lista de espécies de Gymnotiformes onduladores.....	54
Tabela 01 – Taxa de Repetição (Hz) das DOEs e tipos de órgãos elétricos dos gimnotiformes usados neste estudo. Tipo de DOE: P=pulsador, O=ondulador; Órgão elétrico (OE): M=miogênico, N=neurogênico.....	68
Tabela 02 – Taxa de Repetição (Hz), Coeficiente de Variação (CV) e codificação de saída de rede neural artificial (COD.) para DOEs de gimnotiformes onduladores.....	72
Tabela 03 – Taxa de repetição sinais normais (HzN) e sinais em pré-hipoxia (HzH) e Coeficiente de Variação (CVN e CVH, normais e pré-hipoxia, respectivamente) para DOEs de <i>Parapteronotus hasemani</i> do experimento de OD.....	78
Tabela 04 – Taxa de Repetição (Hz), Coeficiente de Variação (CV) para DOEs de <i>P. hasemani</i> do experimento piloto, sinais anteriores à aclimação (An. Aclim.), Normal, imediatamente após aplicação de BTEX (0'), de 5 mim. a 60 min. e após experimento em água sem BTEX.....	82
Tabela 05 – Taxa de Repetição (Hz) e Coeficiente de Variação (CV) de DOEs de <i>Parapteronotus hasemani</i> do experimento com BTEX.....	85

SUMÁRIO

RESUMO.....	VI
ABSTRACT.....	VII
ACRONÔMIOS.....	VIII
LISTA DE FIGURAS.....	IX
LISTA DE QUADROS E TABELAS.....	XI
SUMÁRIO.....	XII
INTRODUÇÃO.....	14
1 REVISÃO BIBLIOGRÁFICA.....	15
1.1 CONTAMINAÇÃO AQUÁTICA POR HIDROCARBONETOS DE PETRÓLEO.....	15
1.2 PEIXES ELÉTRICOS NEOTROPICAIS (GYMNOTIFORMES).....	17
1.2.1 Gênero <i>Electrophorus</i>	20
1.2.2 Gênero <i>Gymnotus</i>	21
1.2.3 Gêneros <i>Rhamphichthys</i> e <i>Gymnorhamphichthys</i>	22
1.2.4 Gênero <i>Hypopygus</i> , <i>Stegostenopus</i> e <i>Steatogenys</i>	23
1.2.5 Gêneros <i>Brachyhypopomus</i> e <i>Hypopomus</i>	24
1.2.6 Gêneros <i>Microsternarchus</i> e <i>Racenisia</i>	25
1.2.7 Gênero <i>Sternopygus</i>	26
1.2.8 Gêneros <i>Archolaemus</i> , <i>Distocyclus</i> , <i>Eigenmannia</i> e <i>Rhabdolichops</i>	26
1.2.9 Gêneros da Família Apterontidae.....	27
1.3 GIMNOTIFORMES COMO BIOSSENSORES.....	30
1.4 INTELIGÊNCIA ARTIFICIAL.....	32
1.4.1 Redes Neurais Artificiais.....	33
1.5 OBJETIVOS.....	47
1.5.1 Objetivo Geral.....	47
1.5.2 Objetivos Específicos.....	47
2 METODOLOGIA.....	48
2.1 CAPTURA DE GIMNOTIFORMES.....	49
2.1.1 Captura de Espécimes para Classificação de Sinais.....	49
2.1.2 Captura de Espécimes para Biomonitoramento.....	49
2.2 CLASSIFICAÇÃO DE SINAIS DE GIMNOTIFORMES.....	50
2.2.1 Aquisição e Pré-processamento de Sinais.....	50

2.2.2 Classificação de Gimnotiformes Pulsadores e Onduladores.....	52
2.2.3 Classificação de Gimnotiformes Onduladores.....	54
2.3 BIOMONITORAMENTO COM GIMNOTIFORMES.....	58
2.3.1 Aquisição e Processamento de Sinais.....	58
2.3.2 Experimento de Depleção de Oxigênio Dissolvido.....	59
2.3.3 Experimento para Detecção de Hidrocarbonetos de Petróleo.....	62
2.4 REDES NEURAS ARTIFICIAIS.....	65
3 RESULTADOS E DISCUSSÃO.....	68
3.1 CLASSIFICAÇÃO DE SINAIS DE GIMNOTIFORMES.....	68
3.1.1 Classificação de Gimnotiformes Pulsadores e Onduladores.....	68
3.1.2 Classificação de Gimnotiformes Onduladores.....	71
3.2 SENSORIAMENTO DE OXIGÊNIO DISSOLVIDO.....	76
3.3 SENSORIAMENTO DE HIDROCARBONETOS DE PETRÓLEO.....	82
3.3.1 Experimento Piloto.....	82
3.3.2 Experimento de Sensoriamento de BTEX.....	83
CONSIDERAÇÕES FINAIS.....	90
REFERÊNCIAS BIBLIOGRÁFICAS.....	94
ANEXOS.....	108
ANEXO I – ARQUIVOS m.....	109
ANEXO II – ARQUIVOS m.....	111

INTRODUÇÃO

Possibilidades de contaminação das águas continentais por hidrocarbonetos derivados de petróleo são preocupações constantes e de alto risco ambiental. Este cenário de insegurança é superlativo quando relacionado à região amazônica, onde, qualquer impacto significativo desta natureza, tende a proporção de desastre e custos de remediação incalculáveis. Na constante observância à estas preocupações, sistemas de monitoramento e defesa ambiental, prevenção de acidentes, gestão integrada de segurança, meio ambiente e saúde (SMS), auditorias de conformidade, análises de riscos, sistemas de informação geográfica, mapeamento de sensibilidade ambiental, entre outras ações, fazem parte da realidade das políticas e diretrizes ambientais das organizações do ramo petrolífero e, não obstante, das empresas atuantes na Amazônia.

Fomentando a melhoria contínua para os sistemas de monitoramento e defesa ambiental na Amazônia, aqui se apresentam subsídios para um novo modo de sensoriamento ou alerta ambiental, direcionado para a detecção da presença de hidrocarbonetos derivados do petróleo em ambientes aquáticos por vias biotecnológicas e inteligência artificial, com peixes elétricos (Gymnotiformes) e sua capacidade bioeletrogênica como sensores. Neste estudo teve-se como foco o sensoriamento de dois parâmetros associados a acidentes com petróleo em ambientes aquáticos: depleção de oxigênio dissolvido (hipoxia) e presença de fração solúvel de petróleo em água (hidrocarbonetos aromáticos – BTEX).

O problema da identificação de padrões em sinais de peixes elétricos por sistemas computacionais para o propósito do biossensoriamento ambiental de petróleo pode ser resolvido com uso de técnicas em inteligência artificial baseadas em redes neurais artificiais. Estes sinais resultam em padrões temporais de descargas elétricas e dispõe-se de grande número de amostras experimentais. Portanto, o recurso das redes neurais artificiais, passa a ser um candidato natural para a investigação e para a classificação destes sinais. Principalmente porque a condição para o uso das redes neurais artificiais é a existência de grande quantidade de dados experimentais, o que, neste caso, é plenamente satisfeita. Hoje, possibilidades à vista, assentados em ombros de gigantes!

1 REVISÃO BIBLIOGRÁFICA

1.1 CONTAMINAÇÃO AQUÁTICA POR HIDROCARBONETOS DE PETRÓLEO

O petróleo, por sua característica hidrofóbica, quando em contato com o meio aquoso é impulsionado pelos ventos e pelas correntes locais dispersando-se sobre águas. Inicialmente, o petróleo encontra-se em fase com a água, mas a ação dos processos físicos fazem com que os seus componentes mais voláteis (naftas) evaporem; os componentes de média densidade (óleos) se emulsionem com a água, formando uma pluma ou até uma borra flutuante; e, os mais pesados, após adsorção das partículas em suspensão sedimentam (Harte et al., 1991).

Os hidrocarbonetos mais leves (hidrocarbonetos de cadeia curta) tendem a ser miscíveis em água, se espalham com alto poder de fugacidade, formando uma abrangente pluma de dispersão. Os elementos químicos presentes nesta pluma de dispersão são classificados como fração solúvel de petróleo (Freedman, 1989; CONCAWE, 1988; 1992; Sauer e Boehm, 1995). Desta fração solúvel, os compostos que apresentam maior capacidade de dispersão em água, maior toxicidade e que, conseqüentemente, causam problemas de maior complexidade ambiental, são: benzenos, toluenos, etilbenzenos e xilenos (*orto*, *meta* e *para*), também referenciados como compostos BTEX (Manahan, 2000; Baird, 2002; figura 01).

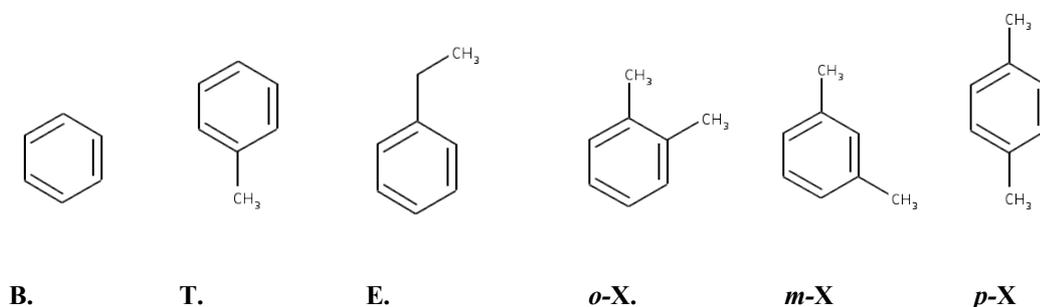


Figura 01– BTEX: Benzenos, Toluenos, Etilbenzenos e Xilenos (*orto*, *meta* e *para*).

Os BTEX são os compostos aromáticos de menor peso molecular existentes no petróleo. A identificação destes hidrocarbonetos aromáticos leves em água revela indubitavelmente a presença de produtos de petróleo (Farhadian et al., 2008). Sendo o benzeno, o mais leve e volátil, também, o mais tóxico e com a maior capacidade de solubilidade e dispersão em água (CONCAWE, 1992; ASTDR, 1997). Há registros de que o benzeno cause câncer (leucemia) (ATSDR, 1999), classificado no Grupo 1 pela Agência Internacional de Pesquisas em Câncer, como cancerígeno para humanos (IARC, 2010). As composições de BTEX, nos mais diferentes produtos (benzol, toluol, xilol, solventes, combustíveis) e tipos de petróleo, ficam em torno de: *orto*-xileno: 12 a 23%, *meta*-xileno: 31 a 85%; *para*-xileno: 9 a 21%; etilbenzeno: 9% a 11%, o tolueno: 9% a 26% e o benzeno de traços à 11% (Tiburtius et al., 2004).

Quanto à toxicidade, os BTEX podem afetar o sistema nervoso central em vertebrados, com risco de morte se a exposição a estes compostos for suficientemente alta (CONCAWE, 1988; ASTDR 1993; 1997; 2000). Estes hidrocarbonetos aromáticos de baixo ponto de ebulição são muito tóxicos para os seres vivos (Tiburtius et al., 2004), altamente tóxicos à vida aquática, mesmo em baixas concentrações, pois são capazes de transmitir qualidades indesejáveis à água prejudicando seu uso (ASTDR, 1993; 1997; 2000). Por isso, é comum a utilização dos compostos BTEX como representantes das contaminações por hidrocarbonetos de petróleo em água nas mais diferentes abordagens científicas, sejam para determinação de índices de toxicidade e de contaminação (principalmente em águas subterrâneas, Corseuil e Fernandes, 1999) ou no desenvolvimento de padrões e modelos de dispersão ou no monitoramento do ambiente. Os BTEX são os compostos do petróleo mais estudados nas relações dos derivados de petróleo com o ambiente (CONCAWE, 1992; Farhadiana et al., 2008).

Uma das mais significativas ações sinérgicas resultantes da dispersão do petróleo no ambiente aquático é a depleção de oxigênio. Esta ocorre pela formação de uma camada superficial de hidrocarbonetos, bloqueadora dos processos naturais de difusão de oxigênio da interface da coluna d'água com a atmosfera, levando o meio à hipoxia. Esta camada bloqueadora geralmente é formada por hidrocarbonetos de cadeia mais longa que são menos solúveis em água e, conseqüentemente, mais persistentes nos ecossistemas aquáticos (Val e Almeida-Val, 1999). Os hidrocarbonetos de cadeia longa

com menor densidade que a água permanecem na superfície dos ambientes aquáticos, formando uma barreira físico-química na interface ar/água, impedindo a penetração de luz e diminuindo a capacidade de difusão de oxigênio via contato da coluna água-atmosfera, também, alterando a capacidade fotossintética do meio (Val e Almeida-Val, 1999; Duarte, 2005). Estes hidrocarbonetos de cadeia longa são considerados menos tóxicos aos organismos aquáticos, mas tendem a ser potencialmente perigosos à ictiofauna não adaptada a baixas taxas de oxigênio dissolvido (OD) ou que não possua alternativas de respiração aérea (Val e Almeida-Val, 1995; Val, 1996). Conforme as características da coluna d'água e da biota existente, diferentes taxas de depleção de oxigênio podem ocorrer, fato que reflete diretamente no metabolismo dos organismos aquáticos.

Tais características de dispersão do petróleo em água podem ser utilizadas como fonte de informação para alerta ou indicativo de contaminação de petróleo com a utilização de sensores, ou biossensores, adequados.

1.2 PEIXES ELÉTRICOS NEOTROPICAIS (GYMNOTIFORMES)

Os gimnotiformes representam um grupo de peixes popularmente conhecidos como peixes elétricos, que possuem a capacidade de produzir corrente elétrica alternada (Chagas e Carvalho, 1961; Bennett, 1971). A Ordem dos Gymnotiformes compreende 133 espécies, 30 Gêneros (Mago-Leccia, 1994; Albert, 2003a; Albert e Crampton, 2005; Lêvêque et al., 2008), divididas em cinco (Gymnotidae: Gymnotidae + Electrophoridae, Sternopygidae, Rhamphichthyidae, Hypopomidae e Aptereronotidae; Albert e Campos-da-Paz, 1998; Albert, 2001), seis (Gymnotidae, Electrophoridae, Sternopygidae, Rhamphichthyidae, Hypopomidae e Aptereronotidae; Triques, 1993; Mago-Leccia, 1994) ou sete (Gymnotidae, Electrophoridae, Sternopygidae, Rhamphichthyidae, Hypopomidae, Eigenmanniidae e Aptereronotidae; Alves-Gomes et al., 1995) Famílias, dependendo da classificação a ser seguida.

Espécimes de gimnotiformes são encontrados em todos os sistemas fluviais Neotropicais (Albert e Crampton, 2005 – figura 02), com registros da Argentina ao México, em vários rios a oeste dos Andes, e em abundância e diversidade na Bacia dos

rios Amazonas, Orinoco e rio de la Plata (Hagedorn, 1986; Moller, 1995; Albert e Crampton, 2005). Com grande diversidade de espécies capazes de tolerar um amplo espectro de condições ambientais (condutividade, temperatura, oxigênio dissolvido, pH, quantidade de nutrientes, etc.), habitam diferentes ambientes aquáticos, desde as calhas de grandes rios, pequenos cursos de água (igarapés), florestas alagadas (igapós), lagos, cachoeiras (Kramer et al., 1981; Hagedorn, 1986; Moller, 1995; Alves-Gomes, 1997) e cavernas (Bichuette e Trajano, 2006). Sendo encontrados em quase todos os ambientes límnicos amazônicos, com algumas raras exceções, como o lago do Dragão e o lago da Pata no Morro dos Seis Lagos em São Gabriel da Cachoeira (registro de Expedições do Lab. de Fisiologia Comportamental e Evolução – LFCE/INPA, informações não publicadas).



Figura 02 – Distribuição dos Gymnotiformes no Neotrópico (Albert e Crampton, 2005): AC – América Central, PC – Pacífico Norte da América do Sul, NO – Noroeste da América do Sul, OR – Bacia Rio Orinoco, GU – Guianas, AM – Amazônia, NE – Nordeste da América do Sul, PA – Bacia dos rios Paraná-Paraguai, SE – Sudeste a América do Sul.

Embora representem apenas 3% da diversidade total de peixes Neotropicais de Água Doce (Albert e Crampton, 2005), compreendem uma fração considerável da ictiofauna bentônica dos rios Neotropicais (Barlettta, 1995; Cox-Fernandes, 1995; Crampton, 1996; Cox-Fernandes et al., 2004), representando, por exemplo, cerca de 86% da biomassa em alguns pontos na calha do rio Orinoco (Marrero e Taphorn, 1991) e 27 a

80% em regiões do médio rio Negro (Garcia, 1995). A maioria dos gimnotiformes são carnívoros, com uma dieta baseada em larvas de invertebrados, pequenos insetos e pequenos peixes, buscando alimento ao redor das folhas de plantas aquáticas, raízes de plantas flutuantes ou no lodo (Hagedorn, 1986; Alves-Gomes, 1997).

Os gimnotiformes disparam os seus órgãos elétricos constantemente, durante toda a vida de cada indivíduo (Alves-Gomes et al., 1995; Alves-Gomes, 2004). Estes órgãos elétricos especializados, em atividade coordenada com os eletrorreceptores, formam o Sistema Eletrogênico e Eletrosensorial (SEE), para a produção e recepção de correntes elétricas, sendo o sistema motor e sensorial complexo, utilizado para várias das relações dos gimnotiformes com o meio onde vivem (Alves-Gomes, 1999).

A capacidade que os gimnotiformes têm de produzir corrente elétrica alternada (ou Descargas dos Órgãos Elétricos – DOEs) é uma característica eletrofisiológica associada a tecidos especializados chamados órgãos elétricos. Estes órgãos responsáveis pela geração das DOEs compreendem dois tipos distintos: órgãos miogênicos com eletrócitos (unidade celular do órgão elétrico) de origem muscular e órgãos neurogênicos com os próprios neurônios funcionando como eletrócitos (Bullock et al., 1979; Bullock e Heiligenberg, 1986; Kirschbaum, 1995; Alves-Gomes, 1997). Gimnotiformes utilizam-se das DOEs para interagir com o ambiente, seja para localização (eletrolocalização) (Bullock et al., 1979; Bullock e Heiligenberg, 1986; Rasnow et al., 1993; Bastian 1994; Rasnow, 1996; Rasnow e Bower, 1996; Nelson et al., 2002), para comunicação (eletrocomunicação) (Knudsen, 1974; 1975; Bullock et al., 1979; Hagedorn e Heiligenberg, 1985; Bullock e Heiligenberg, 1986; Bastian, 1994), seleção de parceiros reprodutivos, disputas hierárquicas, reconhecimento co-específico, busca por alimentos, e detecção de objetos e abrigos (Alves-Gomes et al., 1995).

As características biofísicas das DOEs são espécie-específicas (Hopkins e Heiligenberg, 1978; Heiligenberg e Bastian, 1980), variam intra-especificamente e entre os sexos (Hopkins e Heiligenberg, 1978), como também, em função do ciclo circadiano (Bullock et al., 1979; Zupanc et al., 2001; Nogueira, 2006). Pode-se classificar as DOEs sob os aspectos eletrofisiológicos em função das taxas de repetição, dividindo-se os Gymnotiformes em dois grupos: pulsadores (figura 03) e onduladores (figura 04) (Mago-Leccia, 1994; Alves-Gomes et al., 1995; Alves-Gomes, 1997).

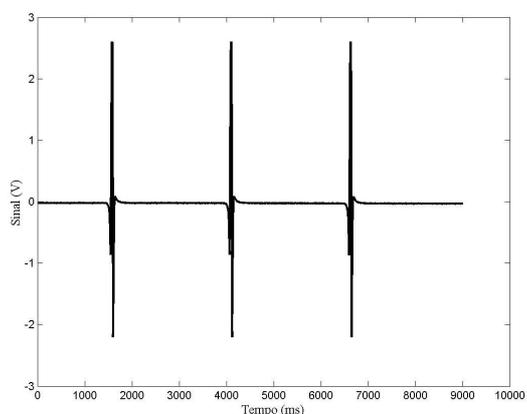


Figura 03 – DOE tipo Pulso (Gymnotidae).

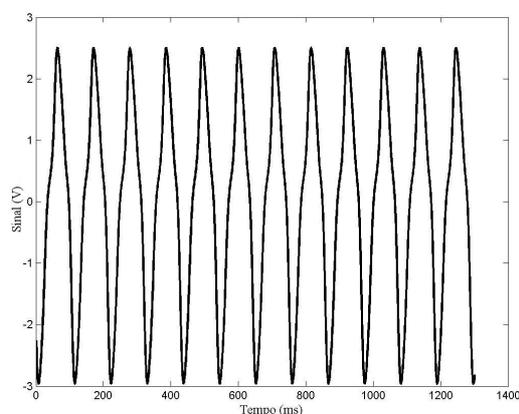


Figura 04 – DOE tipo Onda (Apterontidae).

Segue informações sobre a diversidade da Ordem Gymnotiformes:

1.2.1 Gênero *Electrophorus*

O gênero *Electrophorus* é um gênero monotípico, com uma única espécie descrita: *E. electricus* (forma de onda da DOE mostrada na figura 05). É o gimnotiforme mais conhecido pela capacidade de gerar fortes descargas elétricas por meio de órgãos elétricos miogênicos, que podem descarregar rapidamente (1 ms) correntes de 1 Ampère com tensão de até 600 Volts. Popularmente chamado de enguia elétrica, poraquê ou puraquê, é o maior gimnotiforme (Alves-Gomes et al., 1995; Moller, 1995). Possui três órgãos elétricos: o de Sachs, o de Hunter e o órgão principal. O órgão de Sachs e a porção posterior do órgão de Hunter podem ser descarregados sem uma descarga acompanhante do órgão principal. Esta descarga é de baixa tensão (cerca de 10 V) e provavelmente é usada para a detecção de presa, eletrolocalização e eletrocomunicação. A descarga forte, de mais de 500 Volts, é produzida quando todos os órgãos descarregam simultaneamente, com maior contribuição do órgão principal (Bullock et al., 1979). São peixes de corpo anguiliforme, desprovidos de escamas e com respiração aérea obrigatória por meio da mucosa bucal altamente vascularizada. *Electrophorus* é comumente encontrado em águas rasas, mas habitam os mais diversos ambientes aquáticos de água doce do norte da América do Sul, especialmente nas bacias dos rios Amazonas e Orinoco (Moller, 1995; Campos-da-Paz, 2003).

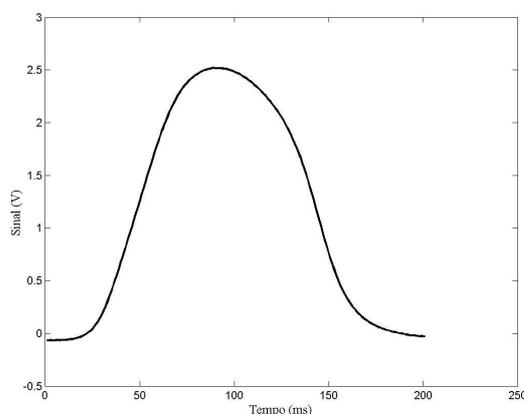


Figura 05 – DOE de *Electrophorus*.

1.2.2 Gênero *Gymnotus*

O gênero *Gymnotus* compreende gimnotiformes com o corpo mais cilíndrico do que a maioria dos peixes elétricos. É o gênero com espécies mais amplamente distribuídas e mais diverso (com mais de 34 espécies) entre os Gymnotiformes (Lovejoy et al., 2009). No Brasil são chamados de sarapó ou tuvira. Possuem mandíbula prognata visível e DOEs em forma de pulsos (figura 06) de baixa tensão (miliVolts), com órgãos elétricos miogênicos. São predadores noturnos agressivos, com comportamento territorial e cuidados parentais (Crampton e Hopkins, 2005). Alternativamente, podem respirar ar atmosférico por meio da bexiga natatória. Habitam águas rasas, com ampla distribuição desde o sul da América do Sul (Argentina) ao sul da América do Norte (México), com registros também em Trinidad, Granada, e regiões Trans-andinas da Colômbia e do Equador (Campos-da-Paz, 2003). São utilizados como isca viva para captura de grandes bagres, e eventualmente comercializados como peixes ornamentais.

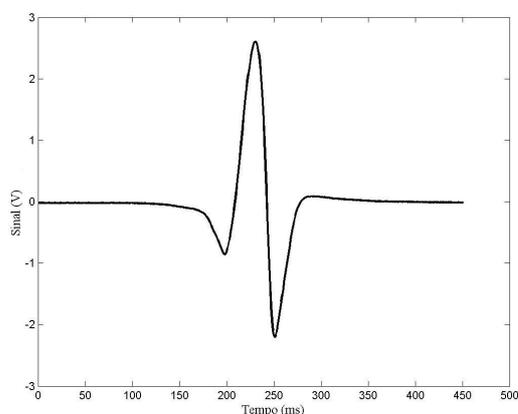


Figura 06 – DOE de *Gymnotus*.

1.2.3 Gêneros *Rhamphichthys* e *Gymnorhamphichthys*

Os gêneros *Rhamphichthys* e *Gymnorhamphichthys* podem ser facilmente reconhecidos pelo corpo comprimido, boca tubular pequena e mandíbula desprovida de dentes (Planquette et al. 1996). São peixes pulsadores (forma de onda do gênero *Gymnorhamphichthys* vide figura 07 e do gênero *Rhamphichthys* vide figura 08) e com órgão elétrico miogênico. Habitam praticamente todas as bacias de drenagem dos rios da América do Sul, somente não há registros destes peixes nas bacias hidrográficas dos Andes, e não ocorrem na América Central. Vivem em riachos, lagos marginais de rios, praias de areia e nas regiões mais profundas do canal dos rios principais (Mago-Leccia, 1994). Permanecem parcialmente enterrados na areia ou na lama durante o dia, pouco se sabe sobre sua biologia (Heiligenberg e Bastian, 1980).

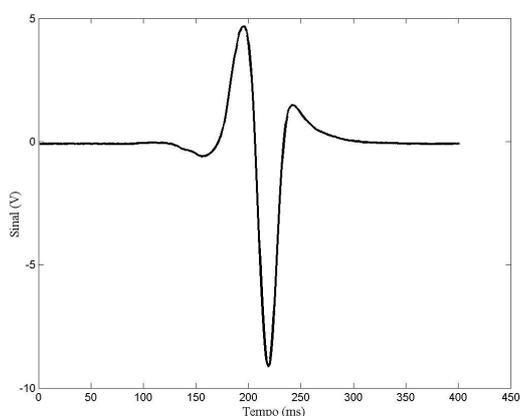


Figura 07 – DOE de *Gymnorhamphichthys*.

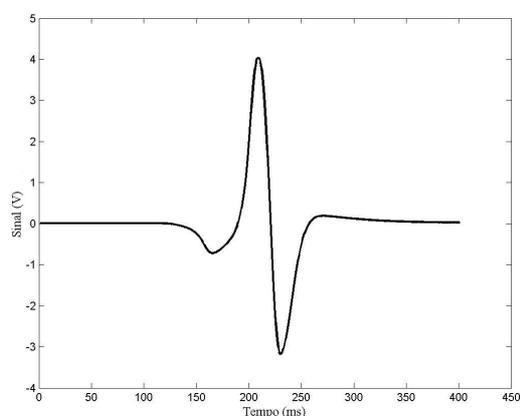


Figura 08 – DOE de *Rhamphichthys*.

1.2.4 Gênero *Hypopygus*, *Stegostenopus* e *Steatogenys*

A maioria das espécies dos gêneros *Hypopygus* (sinal figura 09), *Steatogenys* (sinal figura 10) e *Stegostenopus* (sinal figura 11), ocorrem amplamente distribuídos pela região cis-andina. Porém, algumas espécies, principalmente atribuídas ao gênero *Hypopygus*, são restritas às bacias dos rios Orinoco e Negro (Mago-Leccia, 1994), geralmente associados a pequenos tributários (igarapés) ao longo destes rios, habitando regiões de floresta alagada, entre folhiços, serrapilheira e raízes submersas (Schmitt, 2005). De um modo geral habitam pequenos tributários e lagos, não havendo registro de coletas no canal principal dos grandes rios (Mago-Leccia, 1994). Espécies do gênero *Hypopygus* apresentam o menor tamanho adulto entre os Gymnotiformes (100 a 120 mm – comprimento total) (Walker, 2001; Schmitt, 2005). São peixes com DOEs de pulso e órgãos elétricos miogênicos. Eventualmente ou acidentalmente são comercializados entre outros peixes ornamentais do rio Amazonas, exportados para mercados nacionais e internacionais, misturados a outras espécies de Gymnotiformes como *Apteronotus albifrons* (Chao, 2001).

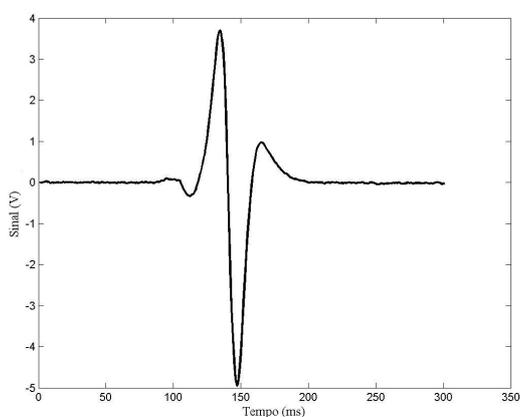


Figura 09 – DOE de *Hypopygus*.

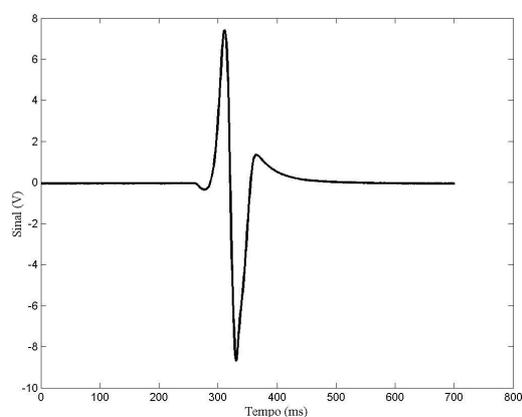


Figura 10 – DOE de *Stegostenopus*.

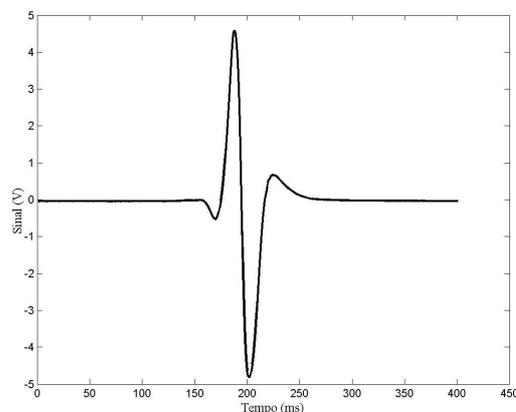


Figura 11 – DOE de *Steatogenys*.

1.2.5 Gêneros *Brachyhypopomus* e *Hypopomus*

São amplamente distribuídos, tanto em termos geográficos quanto em diversidade de habitats. São capazes de viver em córregos límpidos até áreas altamente degradadas. São encontrados no noroeste da Venezuela e Guianas (*Hypopomus* mais restrito a estas regiões), na região semiárida do Nordeste brasileiro, até no sudeste do Brasil e norte da Argentina (Costa e Campos-da-Paz, 1992). *Brachyhypopomus* é um gênero altamente diverso e abundante na Amazônia, com muitas espécies desconhecidas pela ciência. São facilmente encontrados em bancos de macrófitas flutuantes nas várzeas da Amazônia Central e capazes de tolerar prolongados períodos em condições de hipoxia, porque podem reter bolhas de ar na câmara branquial, o que pode ser considerado como uma adaptação para respiração aérea alternativa. Possuem DOEs de pulso (figura 12 e 13) e órgãos elétricos miogênicos. Muitas espécies de *Brachyhypopomus* são ecologicamente importantes nas regiões de várzea em rios de água branca, pois constituem uma fração significativa da biomassa (Crampton, 1996).

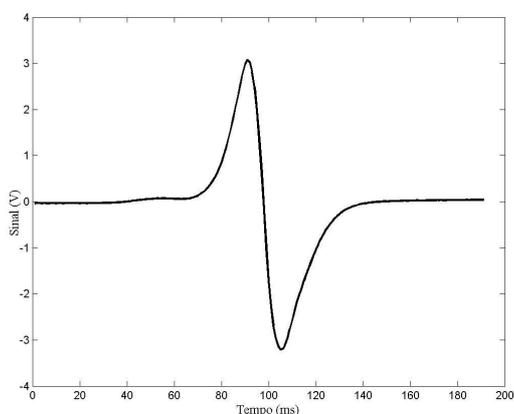


Figura 12 – DOE de *Brachyhypopomus* sp. I.

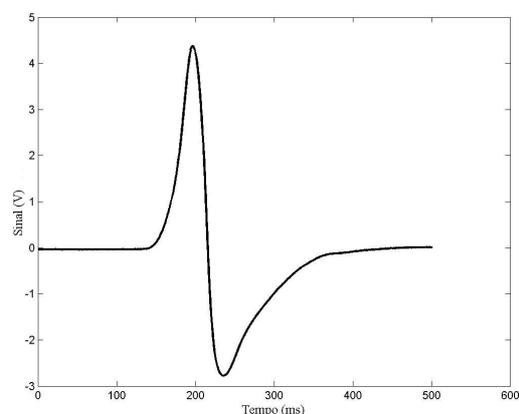


Figura 13 – DOE de *Brachyhypopomus* sp. II.

1.2.6 Gêneros *Microsternarchus* e *Racenisia*

Os gêneros *Microsternarchus* (sinal figura 14) e *Racenisia* (sinal figura 15) compõem a tribo Microsternarchini. São gêneros ainda descritos como monotípicos, porém, diferenças nas variações de morfologia externa e nas características de DOEs preconizam que a diversidade destes gêneros, assim como dos gimnotiformes em geral, se encontra subestimada (Nogueira, 2006; Maia et al., 2010). São organismos encontrados preferencialmente em pequenos cursos de água, em locais em que a corrente não é muito forte, sob a serrapilheira em bancos de areia (Walker, 2001) ou no emaranhado de raízes da vegetação marginal que pende para dentro dos igarapés (Schmitt, 2005). São peixes elétricos com órgãos elétricos miogênicos e possuem DOE tipo pulso. Os *Microsternarchus* são atualmente considerados os representantes da transição da descarga do tipo pulso para onda (Nogueira, 2006).

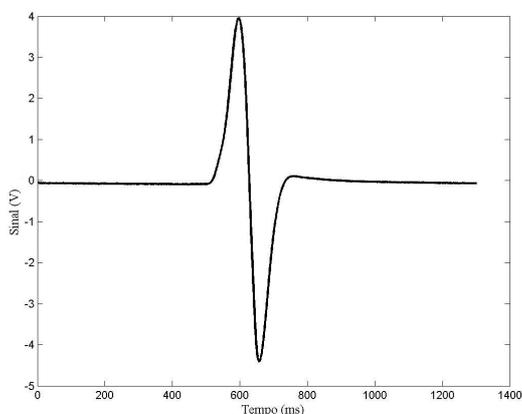


Figura 14 – DOE de *Microsternarchus*.

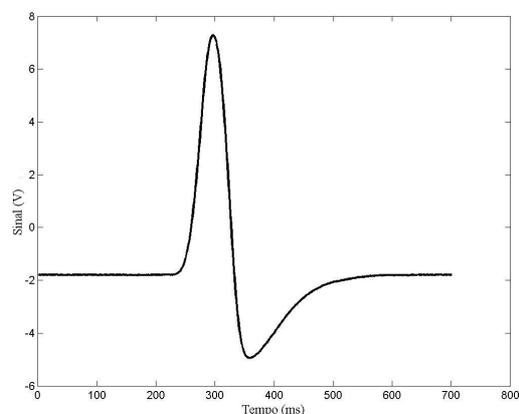


Figura 15 – DOE de *Racenisia*.

1.2.7 Gênero *Sternopygus*

Os peixes do gênero *Sternopygus* são caracterizados por apresentarem linhas longitudinais na superfície do corpo e dentes em ambas as maxilas. As DOEs são em forma de onda com a linha de base negativa. Possuem órgãos elétricos miogênicos, com taxa de repetição das DOEs entre 100 e 200 Hz (sinal figura 16). A maioria das espécies habitam os canais dos rios principais e fundo de lagos. *Sternopygus* é um gênero de ampla distribuição na América do Sul, exceto Chile (Albert, 2001). Habitam várzeas de rios, rios de terra firme e lagos. A espécie *Sternopygus macrurus* é comum no comércio de aquariofilia (Albert, 2003b).

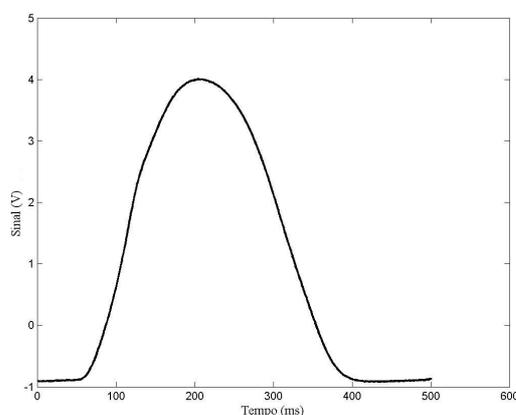


Figura 16 – DOE de *Sternopygus*.

1.2.8 Gêneros *Archolaemus*, *Distocyclus*, *Eigenmannia* e *Rhabdolichops*

As espécies dos gêneros *Archolaemus*, *Distocyclus* (sinais figura 17), *Eigenmannia* (sinais figura 18) e *Rhabdolichops* têm corpo comprimido lateralmente, de coloração clara ou translúcido e olhos de grande diâmetro quando comparados com outros gimnotiformes. Possuem órgãos elétricos miogênicos, com taxa de repetição das DOEs na forma de onda entre 400-800 Hz. Estão confinados à região neotropical úmida, com distribuição variando da Argentina até o Panamá, com maior diversidade na região da bacia Amazônica. Algumas espécies são ecologicamente importantes em muitos sistemas hídricos Amazônicos, representando grande proporção da biomassa, com conseqüente importância na cadeia trófica (Lundberg et al., 1987). A espécie *Eigenmannia virescens* é muito comercializada como peixe ornamental, com

representativo volume de vendas, não por ser um peixe elétrico, mas principalmente pelo comportamento de vida em cardume e pela transparência do corpo, chamados comumente de peixes de vidro.

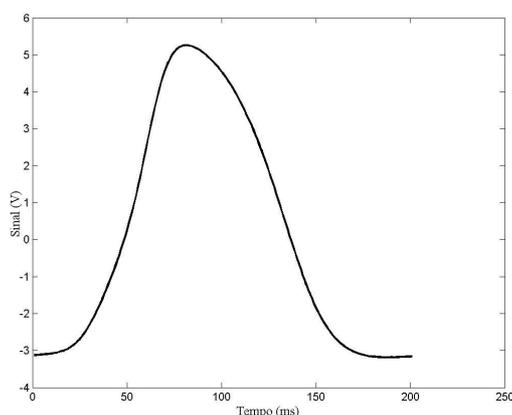


Figura 17 – DOEs de *Distocyclus*.

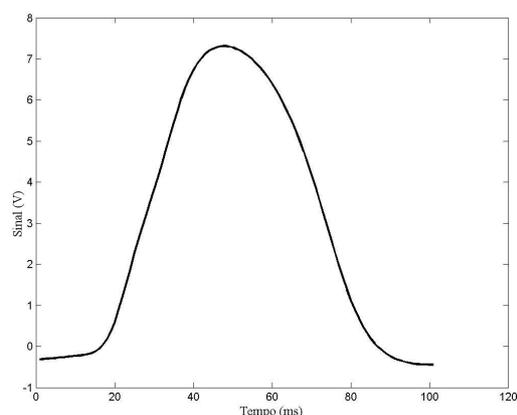


Figura 18 – DOEs de *Eigenmannia*.

1.2.9 Gêneros da Família Apterontidae

A característica fundamental que difere esta Família dos outros Gymnotiformes é a presença da nadadeira caudal e um filamento dorsal (Mago-Leccia, 1994; Cox-Fernandes, 1995), sendo que muitas espécies apresentam dimorfismo sexual secundário com diferenciação no tamanho e forma da região maxilar (Cox-Fernandes, 1998; Cox-Fernandes et al., 2004; Rapp-Py-Daniel e Cox-Fernandes, 2005; Hilton e Cox-Fernandes, 2006). Além destas diferenças, a Família Apterontidae tem a peculiaridade de possuir órgãos elétricos neurogênicos (Kirschbaum, 1983). Em função do órgão neurogênico, esta família contém as únicas espécies que produzem DOEs em frequências altas, podendo chegar além de 2000 Hz (Alves-Gomes, 1997). Habitam a região neotropical úmida; encontrados nas águas continentais de todos os países sul-americanos, exceto Chile (Albert, 2001). São mais diversos, tanto taxonomicamente quanto ecologicamente na bacia amazônica. Apresentam substancial diversidade de tamanhos quando adultos, variando de 0,16 m como em algumas espécies de *Adontosternarchus* e *Megadontognathus* até o *Apteronotus magdalenese* com tamanho por volta de 1,3 m (Campos-da-Paz, 1999). Constituem significativa fração da biomassa nas grandes várzeas amazônicas, denotando-lhes grande importância ecológica (Crampton, 1996). Duas espécies (*Apteronotus albifrons* e *A. leptorhynchus*) são comuns no comércio

aquariofilista (Albert, 2001). Os Aptonotidae são classificados nos seguintes gêneros (Albert, 2003a): *Adontosternarchus* (DOEs figura 19), *Apteronotus* (DOEs figura 20), *Compsaraia*, *Magosternarchus*, *Megadontognathus*, *Orthosternarchus* (DOEs figura 21), *Parapteronotus* (DOEs figura 22), *Platyurosternarchus* (DOEs figura 23), *Porotergus* (DOEs figura 24), *Sternarchella* (DOEs figura 25), *Sternarchogiton* (DOEs figura 26), *Sternarchorhamphus* (DOEs figura 27), *Sternarchorhynchus* (DOEs figura 28).

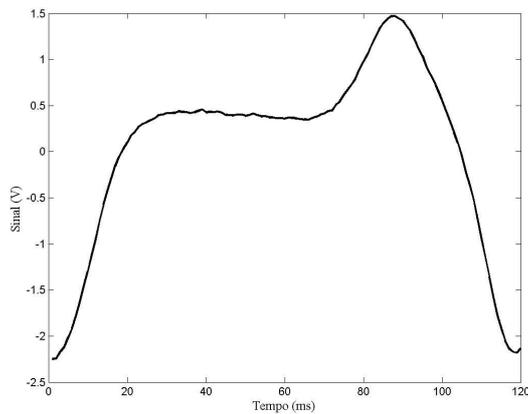


Figura 19 – DOE de *Adontosternarchus*.

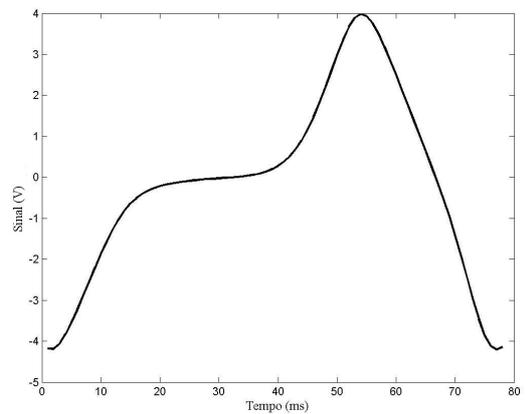


Figura 20 – DOE de *Apteronotus*.

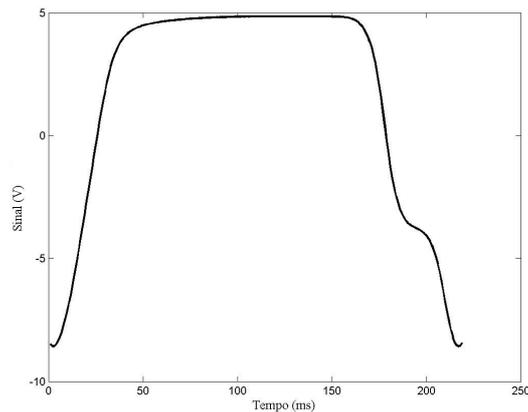


Figura 21 – DOE de *Orthosternarchus*.

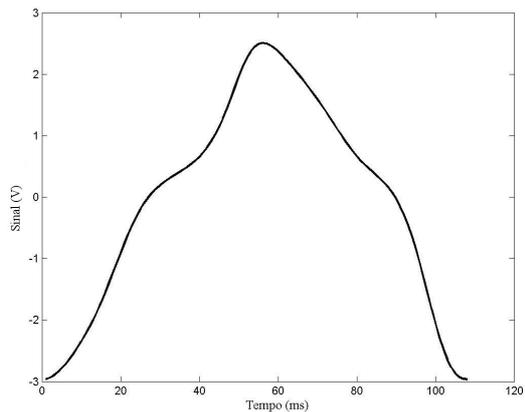


Figura 22 – DOE de *Parapteronotus*.

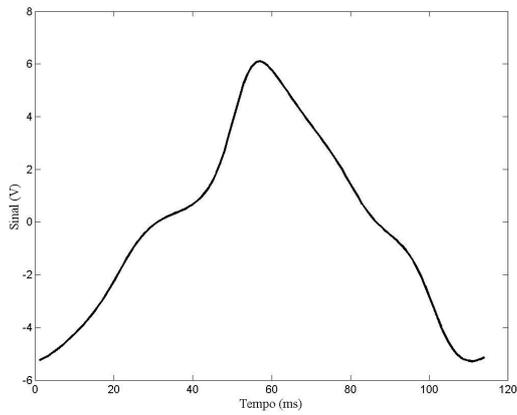


Figura 23 – DOE de *Platyrosternarchus*.

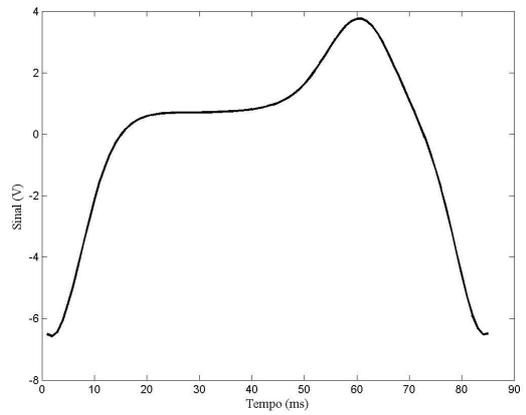


Figura 24 – DOE de *Porotergus*.

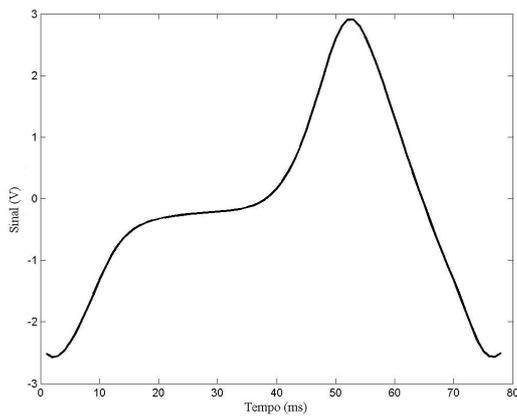


Figura 25 – DOE de *Sternarchella*.

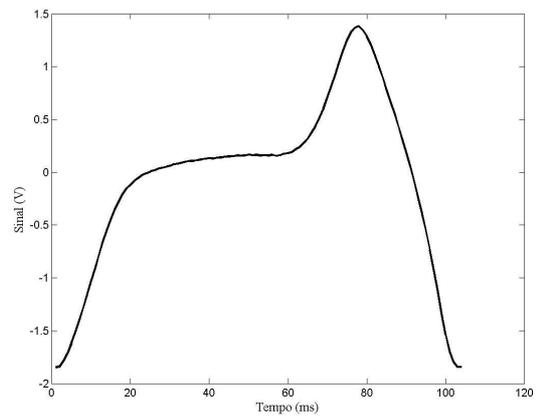


Figura 26 – DOE de *Sternarchogiton*.

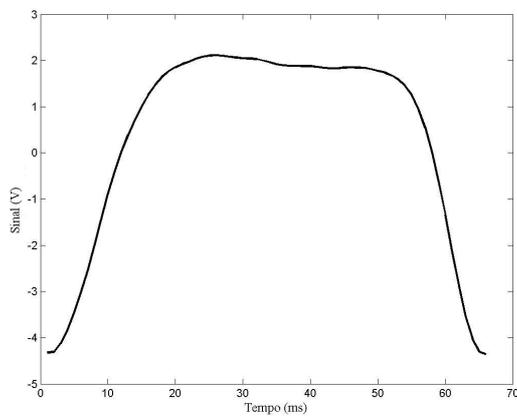


Figura 27 – DOE de *Sternarchorhamphus*.

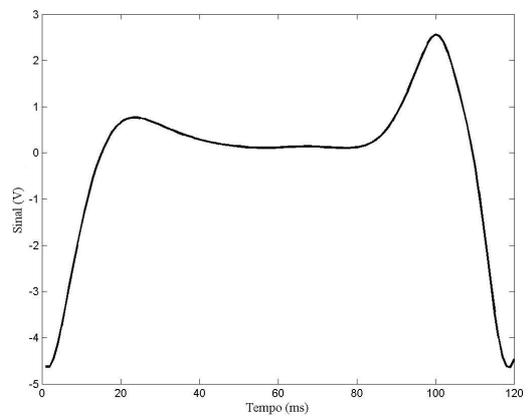


Figura 28 – DOE de *Sternarchorhynchus*.

1.3 GIMNOTIFORMES COMO BIOSSENSORES

Há muito tempo utilizam-se seres vivos com intuito de monitorar ambientes. Vários processos e equipamentos de monitoramento ambiental incorporam organismos como sensores, principalmente em ambientes marinhos e límnicos (Botterweg e Kramer, 1991). Sejam como indicadores de qualidade, pela presença ou não de determinados organismos no ambiente (bioindicadores); sejam por relações dose - resposta; concentração letal ou sub-letal de determinados contaminantes; atividades biológicas, comportamentais e fisiológicas ou, simplesmente, a tolerância e capacidade da manutenção de vida destes organismos (biomonitoramento) (Jeffrey e Madden, 1991).

Existem sistemas de biomonitoramento com resposta em tempo real, ou sistemas de alerta ambiental com biossensores (fugindo de uma tradução literal de BEWS – *Biological Early Warning Systems*, em Botterweg e Kramer, 1991), que compreendem maior capacidade autômata para detectar situações de contaminação, sejam elas potencializadas ou não pela sinergia e relações dinâmicas no ambiente. Estes sistemas de alerta ambiental apresentam a capacidade de detectar grande variação de concentrações de componentes tóxicos, embora, na quase totalidade das aplicações, sejam apenas utilizados como indicativos de contaminação aguda.

Tradicionalmente, utilizava-se somente algumas espécies de peixes em sistemas de alerta ambiental com biossensores, mas atualmente é utilizada grande variedade de organismos, que inclui bactérias: sistemas baseados em emissão de luz; micro-crustáceos: sistemas baseados em atividade; bivalves: sistemas baseados no movimento das válvulas; e, maior diversidade de espécies de peixes: sistemas baseados no batimento opercular, comportamento e descargas elétricas de peixes elétricos (Botterweg e Kramer, 1991).

No caso dos peixes elétricos, o interesse por estes peixes especializados como possíveis sensores do ambiente iniciou a partir da década de 1950 com a descoberta das descargas elétricas fracas produzidas por alguns peixes africanos. Porém, foi apenas na década de 1980, com a utilização de tecnologias eletroeletrônicas modernas, que os estudos sobre eletrorrecepção e eletrogênese prosperaram (Moller, 1995; Hopkins, 1995;

Zakon e Unguez, 1999; Bullock, 1999), ao ponto de inspirar pesquisas que envolviam monitoramento ambiental e peixes elétricos.

Os estudos de biomonitoramento com peixes elétricos iniciaram com peixes africanos. Os pioneiros no biomonitoramento com peixes elétricos foram Grove e Moller (1979), que estudaram as variações nas DOEs de *Brienomyrus niger* (Mormyriiformes) pelo efeito de dois inseticidas comerciais: Dieldrin e Malathion. Depois, Geller (1984) estudou alterações causadas por mercúrio, cobre, cianeto e arsênico nas DOEs do peixe elétrico africano *Gnathonemus petersi* (Mormyriiformes). Outros autores estudaram a influência de fatores físico-químicos no comportamento elétrico de *Gnathonemus*: Kunze e Wezstein (1987) testaram as drogas dopaminérgicas apomorfina e haloperidol, Lewis e Kay (1991) estudaram o efeito da temperatura e Lewis et al. (1992a) o efeito do pH. Seguiram-se estudos com cianeto (Lewis et al. 1992b), com os pesticidas Atrazina e Lindane (Lewis et al. 1993), com níveis de poluição da água (Kai e Lewis, 1993), com os metais pesados cádmio, cromo e cobre (Lewis et al. 1994), e outros compostos químicos: amônia, nitrato, e fosfato (Lewis et al. 1995). Foi notória a sensibilidade das espécies de peixes elétricos africanos às mais diferentes substâncias avaliadas, porém, os sistemas eram pouco confiáveis devidos a variações naturais nas DOEs, que também podiam ocorrer por situações comportamentais, como durante alimentação, agonismos, locomoção, e diferentes interações dos peixes com o meio.

Pimentel-Souza e Siqueira (1992) haviam sugerido a utilização de gimnotiformes para o propósito de biomonitoramento. Thomas et al. (1996a; 1996b) observando a inadequação de *Gnathonemus* e suas instáveis DOEs para o biomonitoramento, propuseram a utilização da espécie Neotropical *Apteronotus albifrons* (peixe Gymnotiformes da família Apterontidae), conduzindo testes que avaliaram a influência de cianeto de potássio sobre as DOEs destes peixes da América do Sul. Com resultados de maior estabilidade das DOEs, Thomas et al. (1997; 1998) utilizaram *Apteronotus albifrons* para compor o desenvolvimento de um sistema de biomonitoramento em tempo real. Thomas (2000) apresentou um sistema de acompanhamento da qualidade de água em tempo real por análise computadorizada das DOEs de *Apteronotus albifrons* (sistema produzido para França denominado: GYMNOTOX[®]).

Estes trabalhos demonstraram que gimnotiformes neurogênicos têm enorme potencial como modelo de bioindicador para qualidade de água. *Apteronotus albifrons* foi usado pela facilidade com que estes animais são encontrados no mercado nacional e internacional de peixes ornamentais. Contudo, esta espécie é apenas uma entre as mais de 40 espécies da Família Apterontidae presentes na Amazônia brasileira (Alves-Gomes et al., 2005). Schwertner e Alves-Gomes (2003), Schwertner et al. (2004), Alves-Gomes et al. (2005), Schwertner (2005) e Rossoni (2005) sugerem a utilização de *Parapteronotus hasemani* (Gymnotiformes, Apterontidae) para compor sistemas de biomonitoramento, voltados para monitorar resíduos provenientes das atividades petrolíferas na Amazônia.

A espécie *P. hasemani* tende a ser um padrão para os estudos com Apterontidae na Amazônia central, sendo referenciada em outros trabalhos para o propósito de biomonitoramento desenvolvidos no LFCE/INPA (Alves-Gomes et al., 2005; Schwertner, 2005; Rossoni, 2005); com referências para o biomonitoramento de água de formação (Rossoni, 2005), de BTEX (Alves-Gomes et al., 2005; Schwertner, 2005) e biomonitoramento de combustível automotivo e derivados de petróleo (Ferreira, 2008).

Mesmo que a ideia de se utilizar peixes elétricos para detecção de substâncias químicas na água não seja recente, e a utilização de peixes elétricos Africanos para este fim fora praticamente abandonada; persiste potencial para desenvolvimentos de sistemas de sensoriamento ou alerta ambiental com peixes elétricos da América do Sul (Gymnotiformes).

1.4 INTELIGÊNCIA ARTIFICIAL

A inteligência artificial (IA) pode ser definida como a parte da ciência da computação dedicada a fornecer métodos, técnicas e sistemas computacionais, inspirados na inteligência humana, para a solução de problemas, emulando habilidades cognitivas humanas. Segundo Norving e Russel (1995) o objeto da IA é atender a quatro categorias: sistemas que pensam como humanos (autômatos, com atividades como tomada de decisões, solução de problemas, aprendizados); sistemas que pensam racionalmente (estudos das faculdades mentais com uso de modelos computacionais, possibilidades de percepção, ação e reação); sistemas que agem como humanos (performance humana) e

sistemas que agem racionalmente (desenvolvimento de emuladores de inteligência em termos de processos computacionais). Estes processos envolvem dinamicamente uma linguagem natural, representações cognitivas, reações autômatas e aprendizado de máquina.

Uma das aplicações mais importantes da inteligência artificial é a identificação de padrões, a qual tem sido empregada para o reconhecimento de imagens, de caracteres escritos e da fala humana, por exemplo. Portanto, os padrões passíveis de pesquisa podem ser classificados, segundo Kasabov (1998), em espaciais (imagens e caracteres) ou temporais (reconhecimento da fala, batimentos cardíacos, sinais cerebrais, etc.). O problema da classificação, a qual consiste na associação de um objeto (uma imagem ou uma série temporal) a algum grupo ou classe pré-existente, é diretamente relacionado ao reconhecimento de padrões, sendo a classificação decorrente deste reconhecimento.

1.4.1 Redes Neurais Artificiais

Dentre as ferramentas de IA mais utilizadas atualmente destacam-se as redes neurais artificiais. As redes neurais artificiais são sistemas computacionais bio-inspirados, formados por elementos de processamento de informação que, em analogia com o cérebro, são chamados de neurônios artificiais e por conexões ponderadas entre estes, semelhantes às sinapses dos neurônios biológicos. As redes neurais artificiais têm capacidade de aprender por meio de exemplos e de generalizar informações aprendidas (Bishop, 1995; Hagan et al., 1996; Freeman e Skapura, 2000; Haykin, 2007). Uma rede neural artificial é uma estrutura maciçamente paralela com habilidade de generalização, capaz de produzir valores de saída adequados para valores de entrada que não fizeram parte do treinamento (Haykin, 2007).

A origem das redes neurais artificiais está associada a modelos matemáticos simples da fisiologia de neurônios biológicos (Norving e Russel, 1995). A era moderna das redes neurais começou com o trabalho pioneiro de McCulloch e Pitts (1943), no qual descrevem um cálculo lógico das redes neurais que unificava os estudos de neurofisiologia e da lógica matemática, assumindo que seu modelo formal de neurônio seguia um sistema booleano (Haykin, 2007).

Este neurônio pioneiro (chamado de MCP, em homenagem aos criadores) constituiu-se de uma estrutura composta de entradas, cuja soma é submetida a um limiar estabelecido, resultando em verdadeiro ou falso conforme este limiar seja ou não ultrapassado. O modelo de neurônio artificial proposto por McCulloch e Pitts, resultou em um modelo com n terminais de entrada (dendritos) que recebem os valores $x_0, x_1, x_2, \dots, x_n$ (que representam as ativações dos neurônios anteriores) e apenas um terminal de saída j (representando o axônio). Para realizar o processo de transferência relativo às sinapses, aos terminais de entrada do neurônio são ponderados pesos sinápticos ($w_{j0}, w_{j1}, w_{j2}, \dots, w_{jn}$), representando sinapses inibitórias ou excitatórias. O processo de ativação do neurônio artificial MCP (figura 29) é representado por um mecanismo simples que faz a soma dos valores xw_j recebidos pelo neurônio (soma ponderada – função soma ou função de ativação) e decide se o neurônio deve ou não disparar (saída igual a 1 ou a 0), comparando a soma obtida ao limiar ou termo independente do neurônio (Braga et al., 2007).

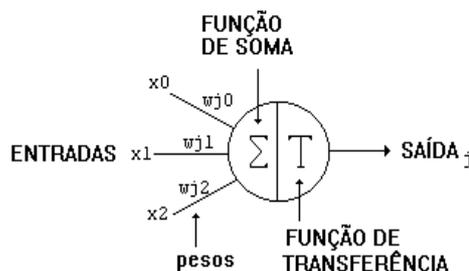


Figura 29 – Esquema do neurônio artificial MCP.

Após a consagração do modelo do neurônio artificial MCP, outros fatores propiciaram o desenvolvimento das técnicas de redes neurais atuais: Donald Hebb (1949) descreveu o condicionamento amostral por reforço que subsidiou os métodos de treinamento para redes neurais artificiais. Rosenblatt em, 1958, desenvolveu o PERCEPTRON, modelo constituído por neurônios MCP (com saídas binárias) organizados lado a lado em uma camada. Widrow e Hoff, em 1960, apresentaram uma versão mais poderosa que o PERCEPTRON, o ADALINE, com saídas numéricas, mediante o uso de função de ativação linear, com o algoritmo gradiente-descendente como técnica de aprendizado. Porém, Minsky e Papert, em 1969, demonstraram as

limitações das redes de uma camada, que apenas são capazes de reconhecer classes linearmente separáveis; com estes argumentos somados à indisponibilidade de tecnologia e de algoritmos matemáticos para solucionar o treinamento de redes neurais artificiais de múltiplas camadas, os estudos sobre redes neurais artificiais foram praticamente abandonados (Norving e Russel, 1995; Haykin, 2007).

Depois de um período de esquecimento, em 1986, Rummelhart, Hinton e Williams apresentaram o método de retropropagação para treinamento de redes de múltiplas camadas (figura 30) e as redes neurais artificiais retornam das cinzas. Com o trabalho destes autores, há um renascimento dos interesses e dos investimentos nos estudos com redes neurais, que, somados aos desenvolvimentos tecnológicos, principalmente aos avanços da capacidade computacional, resultaram em aplicações crescentes em diversas áreas: sistemas de controle, reconhecimento de padrões e aproximação de funções (Hagan et al., 1996; Pedrollo, 2005; Haykin, 2007).

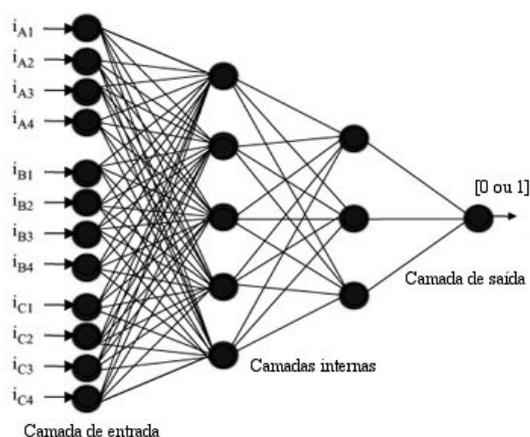


Figura 30 – Rede neural artificial de múltiplas camadas (rede 5-3-1).

Uma rede neural artificial de múltiplas camadas é composta por diferentes camadas de processamento, podendo ter em cada camada vários neurônios. Segundo o Teorema de Kolmogorov-Nielsen, as redes neurais artificiais que contêm apenas uma camada interna (figura 31) podem aproximar qualquer função contínua, sendo suficientes para resolver a maioria dos problemas de generalização. As redes neurais artificiais com duas camadas internas (figura 32), permitem a aproximação de qualquer função,

apresentando enorme potencial para a resolução de problemas complexos (Hagan et al., 1996; Haykin, 2007).

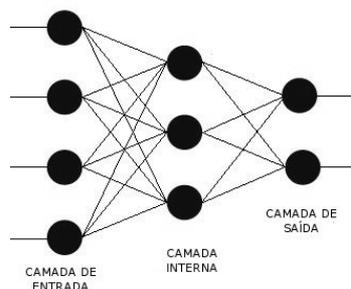


Figura 31 – Rede neural com 1 camada interna.

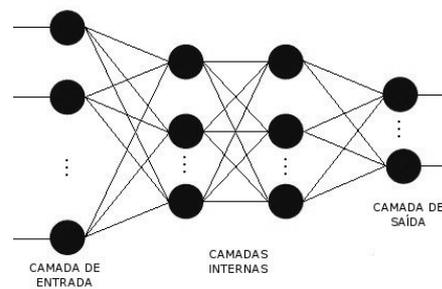


Figura 32 – Rede neural com 2 camadas internas.

Antes do desenvolvimento do método de Rummelhart, Hinton e Williams (1986), nenhum outro método existente era capaz de treinar redes neurais artificiais com neurônios em camadas internas. Atualmente, as redes neurais artificiais de múltiplas camadas estão sendo amplamente utilizadas e o algoritmo retropropagativo é o mais popular algoritmo de treinamento para redes neurais artificiais, sendo usado em cerca de 70 % das aplicações de redes neurais artificiais (Werbos, 2005).

O processo de treinamento com o algoritmo retropropagativo fornece à rede neural artificial um conjunto de dados para o ajuste progressivo dos parâmetros, de modo a tornar a rede neural artificial capaz de aproximar a relação entre os dados de entrada e os dados de saída (via treinamento supervisionado). Os parâmetros ajustados durante o processo de treinamento são os pesos sinápticos e as tendências (bias ou viés). Estes parâmetros, pesos sinápticos e tendências, podem ser pré determinados ou gerados automaticamente na inicialização do treinamento. Tais valores, quando gerados automaticamente são obtidos dentro de uma distribuição aleatória, utilizando-se a relação entre o número de neurônios e o número de amostras da série de treinamento (exemplo, rotina *iniciaisfn*, em Anexo II).

No treinamento de uma rede neural artificial sob a ação de um método supervisor, as alterações dos pesos sinápticos ocorrem no sentido de aproximar as respostas obtidas das respostas desejáveis. No aprendizado supervisionado são sucessivamente apresentados à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída. O dado é apresentado aos neurônios da primeira camada (ou camada de entrada),

produzindo sinais em sua saída, que por sua vez, irão estimular os neurônios da camada subsequente e assim por diante, até atingir a última camada (camada de saída) (Pedrollo, 2007). Com o método de treinamento retropropagativo o valor de ajuste dos pesos sinápticos é propagado a partir da saída da rede até a sua camada inicial. Os pesos de cada neurônio são atualizados isoladamente a cada neurônio, sendo que as suas entradas são as saídas da camada anterior, e o seu erro resulta da soma, ponderada pelos pesos da camada posterior, dos produtos dos seus erros pelas derivadas das suas funções de ativação (Dornelles et al., 2007). Durante este processo, a rede ajusta os pesos das conexões entre os neurônios artificiais, até que o erro entre os padrões de saída gerados pela rede alcancem um valor mínimo desejado (Hagan et al., 1996; Pedrollo, 2007).

As funções de ativação são escolhidas pela complexidade do fenômeno ou função representada, funções não-lineares possuem maior capacidade de aproximação. Por isto, utiliza-se na camada interna as funções de ativação sigmoide, e na camada de saída funções de ativação linear. Alternativamente, pode-se aumentar a capacidade de aproximação não-linear utilizando-se funções de ativação não-lineares em ambas as camadas, com escalonamento dos dados de saída (Pedrollo, 2007).

Uma das dificuldades do uso de redes neurais artificiais consiste em identificar o melhor ponto de parada no treinamento, obtendo-se os parâmetros para a melhor generalização da rede. O erro de treinamento inicia com um valor alto, decresce rapidamente, e continua diminuindo lentamente, tendendo a atingir um mínimo local na superfície de erro. A alternativa para se evitar o estacionamento em um mínimo local e os consequentes problemas de generalização é a utilização da técnica da regra de parada antecipada, com base na validação cruzada (Hagan et al., 1996; Pedrollo, 2007). A generalização é a capacidade de responder a situações que não foram apresentadas à rede neural na etapa de aprendizado (Pedrollo, 2005). A regra de validação cruzada consiste em uma técnica estatística, para validar o modelo obtido durante o treinamento da rede, utilizando um conjunto de dados diferentes dos usados, para estimar os parâmetros durante o treinamento (Haykin, 2007). Este método consiste em acompanhar a evolução do aprendizado nas curvas correspondentes aos subconjuntos de dados de treinamento e de validação (Dornelles et al., 2007; Pedrollo, 2007).

Para cada ajuste dos pesos dos neurônios é calculado o erro da saída da amostra de validação e, após a conclusão do treinamento, tem-se os valores dos erros da amostra de treinamento e de validação. Estes erros são obtidos simultaneamente com o treinamento, sendo possível identificar o número da iteração onde foi atingido o mínimo para a amostra de validação. São escolhidos os valores dos pesos sinápticos desta iteração para a rede. Uma vez que o treinamento é iterativo, a partir de condições iniciais aleatórias, e que estas condições iniciais afetam o resultado, existe a possibilidade de estacionamento do processo de treinamento em um ponto chamado mínimo local, que não consiste, necessariamente, na melhor solução para rede neural artificial (Pedrollo, 2007). Evita-se este estacionamento com a execução do procedimento completo de treinamento, utilizando-se grande quantidade de iterações para caracterizar cada treinamento, adotando-se a rede que obteve melhores resultados. A tentativa que apresentar o menor erro será então adotada como o mínimo global (Dornelles et al., 2007).

Como a convergência dos pesos sinápticos (parâmetros) dependem das características da superfície de desempenho (figura 33), se faz necessário adotar um artifício para melhorar a convergência da rede neural artificial. Neste trabalho foi utilizada a renovação heurística da taxa de aprendizado. Com esta adaptação, de acordo com Vogl et al. (1988), quando a avaliação do erro diminui aceita-se as últimas estimativas e aumenta-se a taxa de aprendizado; se a avaliação do erro aumenta, mantém-se as estimativas anteriores ao aumento do erro e diminui-se a taxa de aprendizado.

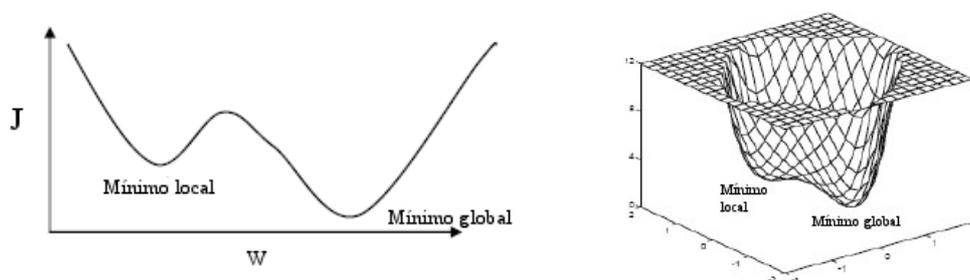


Figura 33 – Exemplo de uma hipotética superfície de desempenho: gráfico à esquerda representa a variação dos parâmetros no espaço unidimensional e à direita a variação no espaço bidimensional.

Fonte: Hagan et al. (1996).

Na maioria dos algoritmos de treinamento com redes neurais artificiais utilizam-se taxas de aprendizado constantes (Demuth et al., 2008), que acabam se tornando: ou taxas de variação muito pequenas com conseqüente consumo de tempo de processamento, que, em superfícies de desempenho mais complexas, tendem a estacionar em um mínimo local; ou taxas muito grandes, com oscilação em torno de um valor ótimo (Pedrollo, 2007), podendo resultar em instabilidade no treinamento (figura 34).

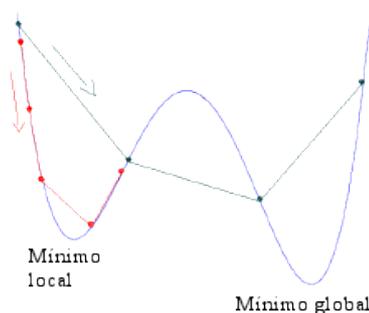


Figura 34 – Exemplo da renovação da taxa de aprendizado constante em uma superfície hipotética de desempenho: em vermelho, taxas pequenas; em azul, taxas grandes.

Fonte: Pedrollo (2007).

O método mais simples de variar a taxa de aprendizado, evitando-se a instabilidade e minimizando as oscilações indesejadas na convergência do treinamento é a incorporação de um termo de inércia (ou termo de momento), conferindo maior estabilidade e mantendo certa resiliência das últimas tendências por operar um atraso no controle do laço de retroalimentação da rede retropropagativa (Haykin, 2007). Com a incorporação do termo de inércia e a utilização da renovação heurística da taxa de aprendizado, a taxa de aprendizado oscila menos e, assim, evita-se os valores mínimos locais ou situações divergentes, resultando efetivamente em treinamento convergente, com o erro aproximando-se monotonicamente do mínimo.

Para se avaliar as redes neurais artificiais utiliza-se o índice de desempenho obtido pela raiz quadrada destes erros quadráticos médios (figuras 35, 36, 37 e 38) (Haykin, 2007; Pedrollo, 2007). O erro quadrático é a diferença entre o valor resultante do treinamento e o valor desejado (alvo) elevados ao quadrado. O somatório destes erros, dividido pelo número total de avaliações de erro, resulta no erro quadrático médio.

Para qualificar a convergência das redes neurais artificiais utiliza-se também os valores da taxa de aprendizado (segundo gráfico das figuras 35, 36, 37 e 38). Se os valores da taxa de aprendizado aumentarem e os valores do índice de desempenho reduzirem, fica caracterizado o fim de processamento com convergência. Ou seja, um treinamento que apresentou a ocorrência de taxas de aprendizado muito altas, ao final, foi compensado pela pequena magnitude dos erros, nesta etapa, qualificando uma rede neural artificial de bom desempenho. No caso de ter ocorrido o contrário, com os valores da taxa de aprendizado diminuindo muito ao final, isto representa o indício de não convergência, uma vez que erros crescentes provocam redução contínua da taxa de aprendizado (Pedrollo, 2007), resultando em redes neurais artificiais ineficientes.

O comportamento das derivadas (representadas pela soma destas - terceiro gráfico das figuras 35, 36, 37 e 38), também é avaliado em conjunto com as supra citadas variáveis: índice de desempenho pela raiz quadrada dos erros e taxa de aprendizado. A ocorrência de derivadas muito pequenas pode significar que ocorreu o estacionamento do processo, o que pode ser bom sinal, se as respostas desejadas situarem-se nos extremos, onde estas derivadas tendem a zero. Porém, se estes valores de derivadas forem muito pequenos e vierem acompanhados de taxas de aprendizado também muito pequenas, indicam que uma zona de saturação foi atingida, com estacionamento sem convergência (Pedrollo, 2007). Na figura 35, um exemplo gráfico de desempenho hipotético ótimo, no qual o índice de desempenho atinge os menores valores de erro, enquanto que a taxa de aprendizado é maximizada e a soma das derivadas tende a zero. Na figura 36 apresenta-se o comportamento dos indicadores de desempenho com um exemplo obtido a partir de dados reais.

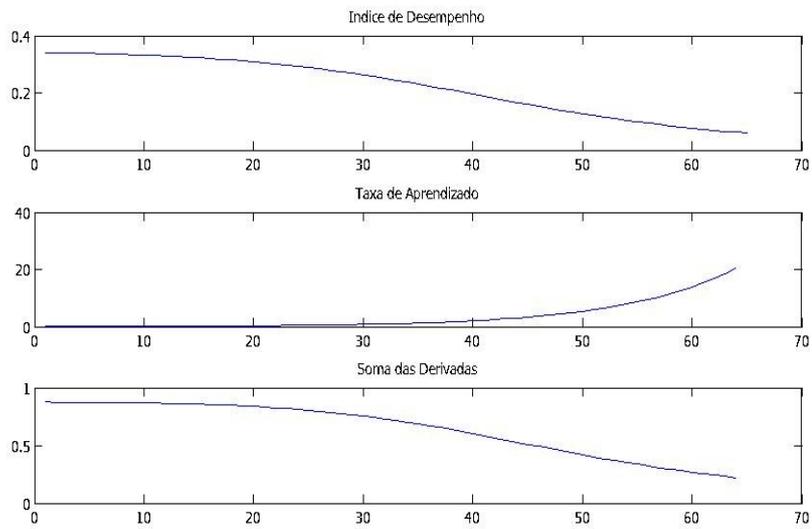


Figura 35 – Gráficos das avaliações da sequência de treinamento com o algoritmo desenvolvido para a tese.

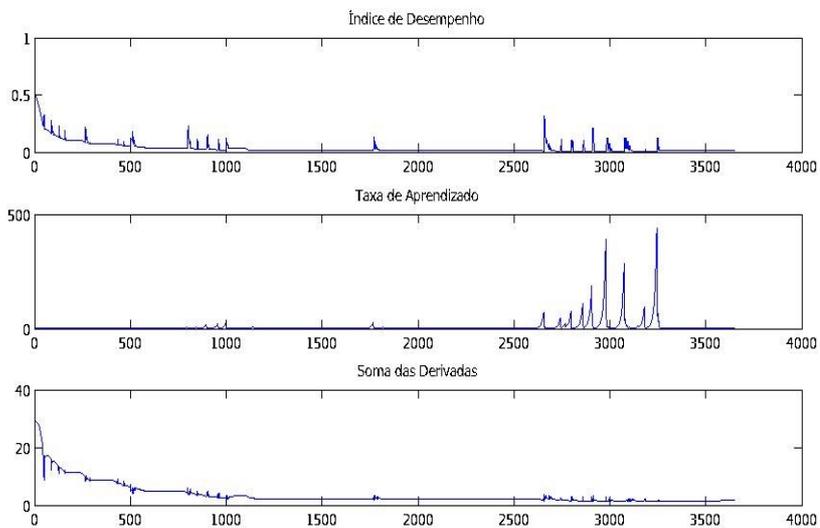


Figura 36 – Gráficos da sequência de treinamento com o algoritmo desenvolvido para a tese, validando uma série de dados reais. A parada do sistema ocorreu em 3650 ciclos com o limiar de precisão atingido.

Normalmente, o resultado de avaliação da rede neural artificial com os dados do conjunto de treinamento proporciona resultados cada vez melhores, a cada ciclo. O contrário ocorre com o conjunto de validação, no qual, o desempenho começa a ser

prejudicado a partir do ciclo correspondente ao início da ocorrência do superajustamento. O superajustamento ocorre quando a rede neural artificial “memoriza” os dados apresentados a rede, perdendo a capacidade de generalização. Na maioria das vezes, o superajustamento é causado pelo uso de uma rede neural artificial muito grande, com excesso de neurônios (Norving e Russel, 1995) ou também pode estar associado ao elevado número de iterações do treinamento (Dornelles et al., 2007).

Para cada ajuste dos pesos dos neurônios é calculado o erro da saída das amostras e, após a conclusão do treinamento, é criado um gráfico com os erros da amostra de treinamento e da amostra de validação. Estes erros são obtidos simultaneamente com o treinamento. A partir deste gráfico é possível identificar o número da iteração onde foi atingido o mínimo para a amostra de validação, e então os pesos sinápticos desta iteração são os eleitos para a rede (Dornelles et al., 2007).

No ciclo do início da divergência entre os conjuntos de dados (figura 37), ocorre o modelo com melhor capacidade de generalização, o melhor modelo, uma vez que, a partir deste, a banda aleatória (resultante dos erros na aquisição dos sinais, interferências ou outras incertezas) passa a afetar os resultados do treinamento (Pedrollo e Lanna, 2003). Um exemplo da não ocorrência de convergência, e a consequente incapacidade de generalização da rede neural artificial resultante do treinamento, pode ser visto no gráfico dos índices de desempenho da figura 38. Estes gráficos (figuras 37 e 38) representam o formato padrão utilizado neste trabalho para demonstrar os resultados das redes neurais artificiais, nos quais, no eixo das abcissas estão os ciclos de treinamento, nas ordenadas estão valores adimensionais da raiz quadrada dos erros (gráfico superior), da taxa de aprendizado (gráfico central) e da soma das derivadas (gráfico inferior).

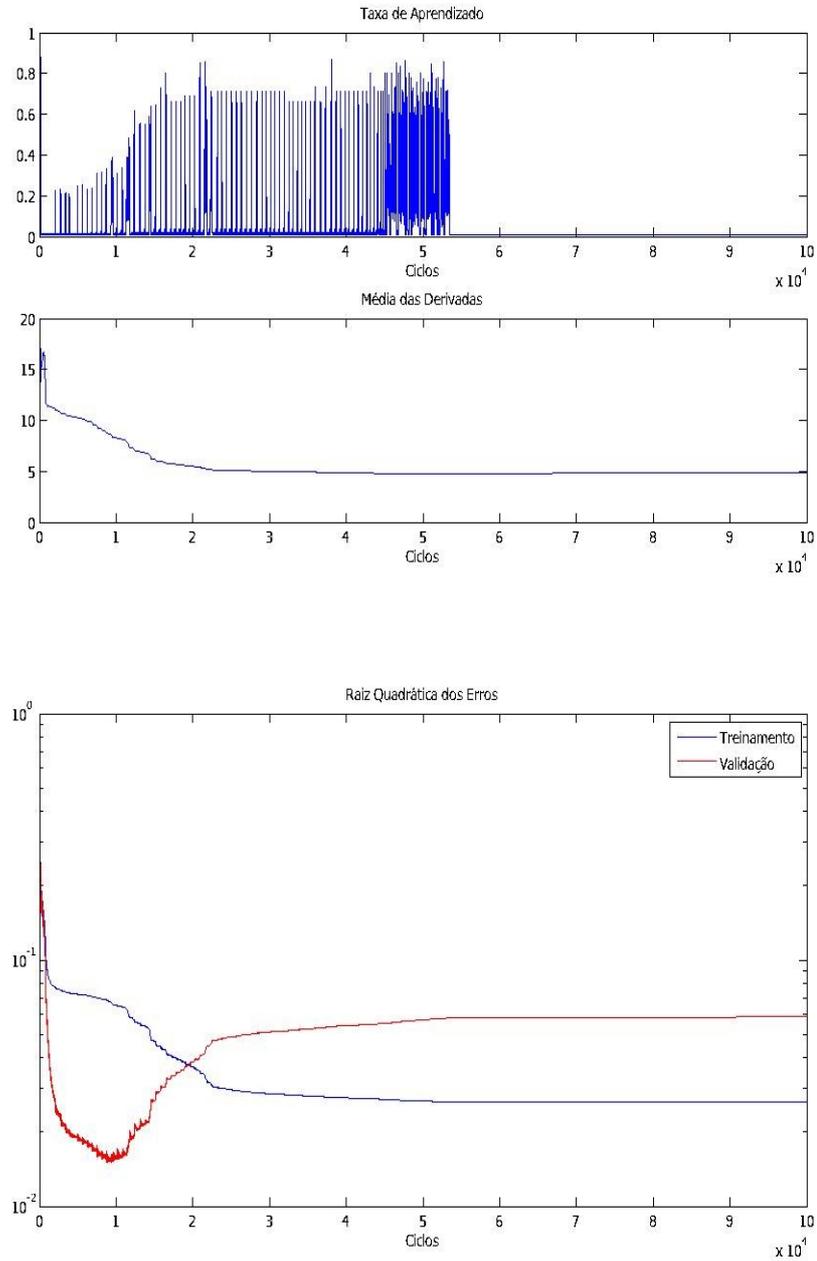


Figura 37 – Gráficos da sequência de treinamento ótimo com o algoritmo desenvolvido para a tese. No eixo das abcissas estão os ciclos de treinamento, nas ordenadas estão valores adimensionais representativos das magnitudes da raiz quadrada dos erros, da taxa de aprendizado e da soma das derivadas.

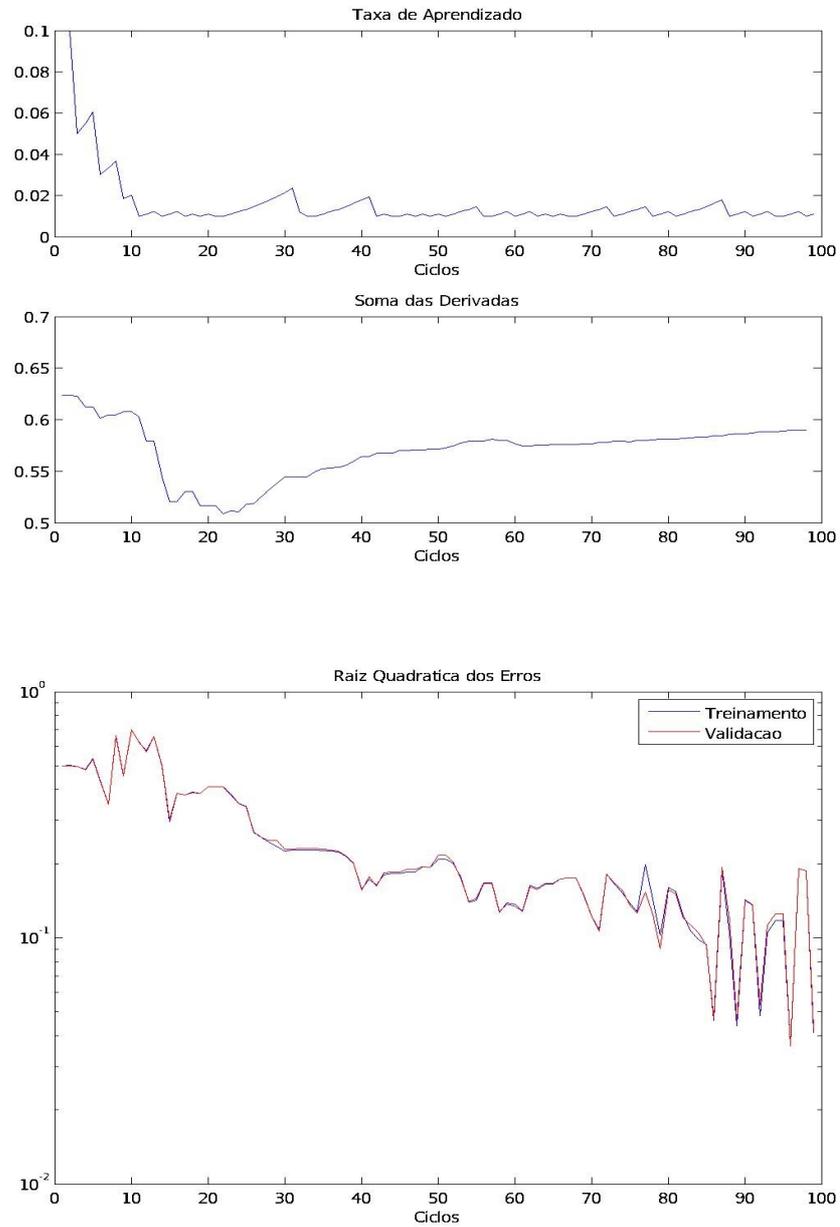


Figura 38 – Gráficos da sequência de treinamento não convergente.

A Arquitetura de uma rede neural constitui-se em suas definições quanto ao número e disposição das camadas e quanto ao número e características das unidades de processamento. O número de entradas e saídas é dependente da natureza do problema, não havendo, portanto, muita margem para escolhas (Pedrollo, 2007). O número de neurônios artificiais determina a capacidade da rede neural artificial em resolver problemas em determinada complexidade. Quanto maior o número de neurônios, maior a complexidade da rede e maior a sua abrangência em termos de soluções possíveis (Braga et al., 2007).

O problema básico da escolha do número de neurônios é a questão da complexidade, uma vez que, com poucos neurônios pode-se incorrer em deficiência de representação, porém, em número excessivo, estes provocam prejuízos à generalização. Pode-se adotar um procedimento heurístico para a determinação da complexidade ideal da rede. O número inicial de neurônios, totais e nas camadas intermediárias, pode ser escolhido em função do número de amostras disponíveis para treinamento (Pedrollo, 2007).

O número de neurônios artificiais da camada de entrada é usualmente determinado pela aplicação, complexidade e característica do objeto de estudo, em muitos casos, este número correspondente à dimensão dos sinais ou matrizes de dados (Pedrollo, 2007). O problema básico de dimensionamento envolve um ajuste entre a complexidade do modelo neural e a complexidade do problema a ser resolvido (Braga et al., 2007).

No caso das camadas internas, utiliza-se o menor número possível de neurônios para que a generalização não fique prejudicada. Se o número de neurônios das camadas internas for muito grande, a rede tende a memorizar os padrões apresentados durante o treinamento. Por outro lado, se a arquitetura das camadas internas possuir neurônios em número inferior ao necessário, o algoritmo retropropagativo, na maioria das vezes, não ajusta os pesos sinápticos adequadamente e inviabiliza as possibilidades de ocorrer convergência (Haykin, 2007). Na camada de saída o número de neurônios é estabelecido pela natureza do problema; em função da possibilidade binária de se codificar: um neurônio, duas possibilidades de respostas (1 neurônio, $2^1 = 2$); dois neurônios, quatro possibilidades de respostas (2 neurônios, $2^2 = 4$); três neurônios, oito possibilidades de

respostas (3 neurônios, $2^3 = 8$); quatro neurônios, dezesseis possibilidades de respostas (4 neurônios, $2^4 = 16$); e assim por diante.

A determinação do número de neurônios é, na verdade, o problema mais fundamental em aprendizado de redes neurais, e motiva boa parte das pesquisas na área. Não se pode dizer que haja na literatura uma regra geral que determine de forma precisa qual deve ser o número de neurônios de uma rede neural artificial para resolução de determinado problema (Braga et al., 2007).

1.5 OBJETIVOS

Diante do que foi desenvolvido no LFCE/INPA, cujos trabalhos resultaram na comprovação da aptidão das DOEs de gimnotiformes para compor sistemas de biomonitoramento, um passo fundamental para o progresso destas pesquisas seria a automatização do sistema ou a capacidade de se incorporar sistemas que auxiliem na tomada de decisão, ou que contribuam na comparação das DOEs antes e depois de expostas aos poluentes. Ou seja, existe a necessidade de desenvolver (bio)tecnologias para o cérebro do sistema de biomonitoramento com gimnotiformes como sensores.

1.5.1 Objetivo Geral

Pesquisa da aplicabilidade da interpretação da descarga de órgãos elétricos de gimnotiformes por redes neurais artificiais para o sensoriamento ambiental aquático.

1.5.2 Objetivos Específicos

- Pesquisa de uma metodologia de processamento e análise de sinais para caracterizar gimnotiformes como biossensores.
- Pesquisa de sistema em inteligência artificial com redes neurais artificiais para classificação de descargas dos órgãos elétricos de gimnotiformes.
- Pesquisa de tecnologia para o biomonitoramento da depleção de oxigênio dissolvido com gimnotiformes como biossensores.
- Pesquisa de tecnologia para o biomonitoramento de hidrocarbonetos de petróleo com gimnotiformes como biossensores.
- Analisar a aplicação dos recursos para integração em um sistema autônomo de alerta ambiental ou biomonitor da qualidade da água, com gimnotiformes como biossensores.

2 METODOLOGIA

Para o sensoriamento ambiental com gimnotiformes desenvolveu-se um sistema de inteligência artificial com redes neurais artificiais. Este sistema foi treinado para classificar de forma autônoma sinais das DOEs de gimnotiformes. Buscou-se uma rede neural artificial para classificar qualquer sinal de gimnotiformes entre pulsadores e onduladores. E, outra rede neural artificial para classificar sinais entre espécies de gimnotiformes onduladores. Com sinais das DOEs de uma espécie onduladora, desenvolveu-se estudos para obtenção de três redes neurais artificiais para o biomonitoramento, uma para acusar a depleção de oxigênio dissolvido (OD), outra para detecção da presença de hidrocarbonetos de petróleo na água, representados por BTEX, e, outra para classificação da detecção de hidrocarbonetos de petróleo na água em faixas de concentração de BTEX.

Para os estudos de biomonitoramento, utilizou-se uma espécie onduladora dentro da ordem Gymnotiformes. Foi escolhida a espécie *Parapteronotus hasemani* (Apteronotidae – Gymnotiformes; figura 39), pela abundância, regularidade de captura e maior facilidade de coleta nos ambientes próximos à Manaus; por esta espécie ser da Família Apteronotidae, com órgãos elétricos neurogênicos, que produzem DOEs estáveis, e; por existirem trabalhos já desenvolvidos no LFCE para o propósito de biomonitoramento, sendo relatada a sensibilidade desta espécie às alterações ambientais (Alves-Gomes et al., 2005; Schwertner, 2005; Rossoni, 2005).



Figura 39 – *Parapteronotus hasemani*.

2.1 CAPTURA DE GIMNOTIFORMES

2.1.1 Captura de Espécimes para Classificação de Sinais

Peixes da Ordem Gymnotiformes foram coletados em expedições do Laboratório de Fisiologia Comportamental e Evolução (LFCE/INPA) ao longo do rio Negro/AM e em excursões de campo ao complexo de lagos do Catalão – ilha Xiborena, ilha Marchantaria (Iranduba/AM) e região da Terra Nova e lago do Rei (Careiro da Várzea/AM), próximos à Manaus /AM.

Foram utilizados diferentes métodos para captura dos gimnotiformes, buscando-se diversidade de espécies:

- redes de arrasto de fundo em canais de grandes rios (rio Negro e rio Amazonas – com arrastos curtos de no máximo 3 minutos para não ferir os peixes coletados);
- redes de cerco com detecção de sinais por amplificador de campo em vegetações flutuantes às margens de rios, igarapés e lagos;
- rapichéis em igarapés e igapós rasos, com a detecção inicial de sinais por amplificador de campo.

Os peixes capturados em expedições foram amostrados nos barcos, sacrificados e preservados em álcool; os peixes capturados próximos à Manaus foram levados ao LFCE/INPA e mantidos em aquários de manutenção.

2.1.2 Captura de Espécimes para Biomonitoramento

Os peixes da espécie *P. hasemani* foram capturados em excursões de campo ao complexo de lagos do Catalão em Iranduba/AM, proximidades de Manaus/AM, utilizando-se rede de cerco com malha de 0,5 cm entre nós. Para detecção dos peixes elétricos utilizou-se um amplificador portátil (que converte as DOEs em som), com eletrodos acoplados em uma haste. Pela ocorrência e diferença de sons, de acordo com as frequências das DOEs, pôde-se localizar os indivíduos de interesse e a captura se tornou

mais objetiva e seletiva. Dos espécimes capturados, aqueles que apresentavam dimorfismo sexual evidente (Cox-Fernandes et al., 2002; Cox-Fernandes et al., 2004), foram soltos, optando-se prioritariamente por indivíduos com tamanhos de 180 ± 30 mm (comprimento total). Os peixes capturados foram transportados ao LFCE e mantidos em aquários coletivos (200 litros), sendo alimentados com *Artemia salina*, tenébrions (*Alphitobius* sp.) e enquitréia (*Enchytraeus albidus*).

Autorização para atividades com finalidade científica (MMA/ICMBio) número: 14834-4.

2.2 CLASSIFICAÇÃO DE SINAIS DE GIMNOTIFORMES

2.2.1 Aquisição e Pré-processamento de Sinais

Os sinais dos peixes coletados em expedições ao rio Negro foram gravados em laboratórios montados nos barcos de apoio das expedições. Os peixes capturados próximos de Manaus foram transportados ao LFCE e os sinais foram gravados no laboratório de equipamentos do LFCE.

Para aquisição dos sinais os peixes foram imobilizados, de acordo com o tamanho: peixes menores, em cápsulas plásticas perfuradas ou em telas plásticas no formato tubular; peixes maiores, em tubos de PVC perfurados com as extremidades fechadas por telas plásticas. Foram utilizados aquários experimentais de 10 l que ficavam no interior de uma Gaiola de Faraday. Foram utilizados 3 eletrodos (conjuntos de eletrodos de ouro ou conjuntos de eletrodos de prata/cloreto de prata) sob hastes especialmente desenvolvidas (figura 40) para o ajuste aos diferentes tamanhos de gimnotiformes utilizados. Seguiu-se os padrões de aquisição de sinais para Gymnotiformes com o eletrodo positivo (+) próximo à cabeça do peixe, o eletrodo negativo (-) próximo à cauda do peixe e o eletrodo diferencial ao centro, equidistante dos outros dois eletrodos. Os sinais foram amplificados com amplificador diferencial AC/DC (dois modelos de amplificador utilizados: A-MSystems Inc. 3000 e BMA-200 CWE Inc.;

ganho máximo utilizado de 1000x), com exceção dos sinais de *Electrophorus* que foram gravados diretamente, sem amplificação. Todos os sinais eram visualizados em osciloscópio (3 modelos utilizados: Tektronix TDS1000B, TDS2000 e TPS2000), para o ajuste de ganho. Os sinais amplificados foram convertidos de sinais analógicos para sinais digitais pelo conversor A/D Digidata 14400 e gravados por meio do software AxonScope[®]: sinais de no mínimo 30 segundos com 16 bits de resolução e 100 KHz de taxa de amostragem (100000 pontos por segundo).

A água utilizada nos aquários experimentais, durante as gravações, foi a mesma água onde o peixe estava aclimatado (ou da área de coleta, ou dos tanques de manutenção de peixes do LFCE), mantendo-se a temperatura entre 25-27 °C.

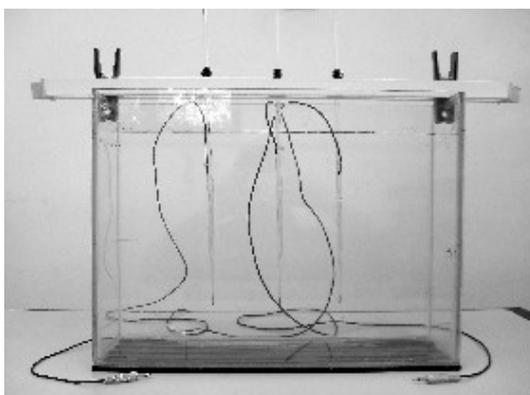


Figura 40 — Tanques experimentais e haste com eletrodos.

Os sinais foram convertidos do formato da Axon Instruments (.abf) para o formato do software MatLab[®] (.mat). Com o MatLab[®] foram calculados os valores da taxa de repetição e os valores do coeficiente de variação (desvio padrão dividido pela média) com algoritmo desenvolvido por Braun e Alves-Gomes (Anexo I). Também, no software MatLab[®], os sinais foram arranjados em três conjuntos de dados. Cada conjunto foi constituído por uma amostra com determinado tamanho de sinal de cada peixe gravado, com a amostra reunida em uma matriz de dados. Os conjuntos de dados foram utilizados como entradas da rede neural artificial (conjunto de treinamento - “p”, conjunto de validação - “v” e conjunto de teste - “t”).

2.2.2 Classificação de Gimnotiformes Pulsadores e Onduladores

Na classificação das DOEs em tipo “pulso” (peixes pulsadores) e tipo “onda” (peixes onduladores) com redes neurais artificiais, procurou-se utilizar DOEs de um espécime de cada Genero da Ordem Gymnotiformes. Para classificação de sinais de gimnotiformes entre pulso e onda foram avaliados pelas redes neurais artificiais 25 sinais de 23 Generos da Ordem Gymnotiformes. Segue lista, no quadro 01, dos gêneros utilizados em função da rarefação de captura:

Quadro 01 – Lista de Generos de Gymnotiformes avaliados.

<i>Adontosternarchus</i>
<i>Apteronotus</i>
<i>Brachyhypopomus</i>
<i>Distocyclus</i>
<i>Eigenmannia</i>
<i>Electrophorus</i>
<i>Gymnorhamphichthys</i>
<i>Gymnotus</i>
<i>Hypopygus</i>
<i>Microsternarchus</i>
<i>Orthosternarchus</i>
<i>Parapteronotus</i>
<i>Platyurosternarchus</i>
<i>Porotergus</i>
<i>Racenisia</i>
<i>Rhamphichthys</i>
<i>Steatogenys</i>
<i>Stegostenopus</i>
<i>Sternarchella</i>
<i>Sternarchogiton</i>
<i>Sternarchorhamphus</i>
<i>Sternarchorhynchus</i>
<i>Sternopygus</i>

Utilizou-se dois sinais do gênero *Brachyhypopomus* e dois sinais do gênero *Apteronotus*. Em função das condicionantes de captura não foram incluídos neste estudo os seguintes gêneros: *Archolaemus* (rio Tocantins, Albert, 2003); *Compsaraia* (rio Orinoco, Albert, 2003); *Megadontognathus* (rio Xingú, Albert, 2003); *Tembeassu* (rio

Paraná, Albert, 2003); *Hypopomus* (região das Guianas, Albert e Crampton, 2003); *Iracema* (rio Jauaperi, Ferraris Jr., 2003); *Magosternarchus* (rio Amazonas: calha de rio, Albert, 2003); *Pariosternarchus* (rio Amazonas: calha de rio, Albert, 2003).

Para a classificação das DOEs entre sinais de pulso e sinais de onda foi desenvolvido um algoritmo de treinamento retropropagativo para redes neurais artificiais supervisionadas, cujas rotinas computacionais (arquivos *m* em Anexo II) foram executadas com o programa MatLab[®].

Foram testadas redes neurais artificiais com uma camada de entrada, uma camada interna e uma camada de saída; com 64, 128 e 256 neurônios na camada interna. A camada de entrada foi correspondente ao tamanho dos vetores de entrada. Foram testados diferentes tamanhos de sinais com números de pontos em representação diádica de 2^{10} , 2^{11} , 2^{12} , 2^{13} , 2^{14} , 2^{15} (1024, 2048, 4096, 8192, 16384 e 32768 pontos; ou 0,01s, 0,02s, 0,04s, 0,08s, 0,16s e 0,32s de sinal, respectivamente). A camada de saída foi composta por 1 neurônio, correspondendo a um valor de saída, ou 0 (para DOEs tipo pulso), ou 1 (para DOEs tipo onda), saída binária [0 1]. Arquitetura das redes neurais artificiais avaliadas: 64-1; 128-1 e 256-1 (figura 41).

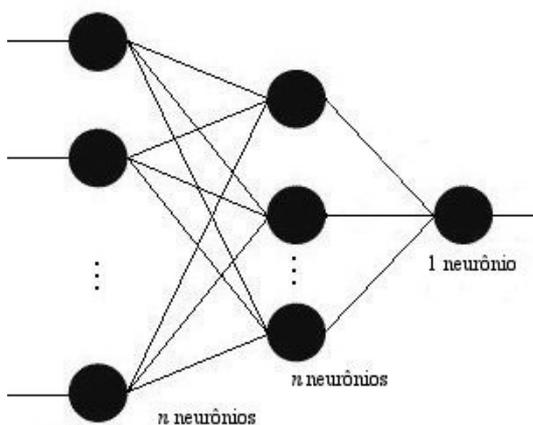


Figura 41 – Esquema de rede neural artificial para classificação de peixes pulsadores e ondulares.

2.2.3 Classificação de Gimnotiformes Onduladores

Foram reunidos sinais de gimnotiformes onduladores: 10 sinais de diferentes espécies da Família Apterontidae (órgão elétrico neurogênico), e mais 3 tipos de sinais de outras espécies de gimnotiformes onduladores (órgão elétrico miogênico). Segue lista das espécies utilizadas no quadro 02:

Quadro 02 – Lista de espécies de Gimnotiformes onduladores avaliados.

<p>- Família Apterontidae:</p> <p><i>Adontosternarchus balaneops</i> (sinais figura 43 C)</p> <p><i>Apteronotus albifrons</i> (sinais figura 44 A)</p> <p><i>Apteronotus bonapartii</i> (sinais figura 45 C)</p> <p><i>Orthosternarchus tamandua</i> (sinais figura 43 D)</p> <p><i>Parapteronotus hasemani</i> (sinais figura 42 D; 45 A e B)</p> <p><i>Platyrosternarchus macrostomus</i> (sinais figura 43 B)</p> <p><i>Porotergus gymnotus</i> (sinais figura 44 C)</p> <p><i>Sternarchella schotti</i> (sinais figura 44 D)</p> <p><i>Sternarchogiton nattereri</i> (sinais figura 44 B)</p> <p><i>Sternarchorhamphus muelleri</i> (sinais figura 45 D)</p> <p><i>Sternarchorhynchus roseni</i> (sinais figura 43 A)</p> <p>- Outras espécies onduladoras:</p> <p><i>Distocylus</i> sp. (sinais figura 42 B)</p> <p><i>Eigenmannia</i> sp. (sinais figura 42 C)</p> <p><i>Sternopygus</i> sp. (sinais figura 42 A)</p>

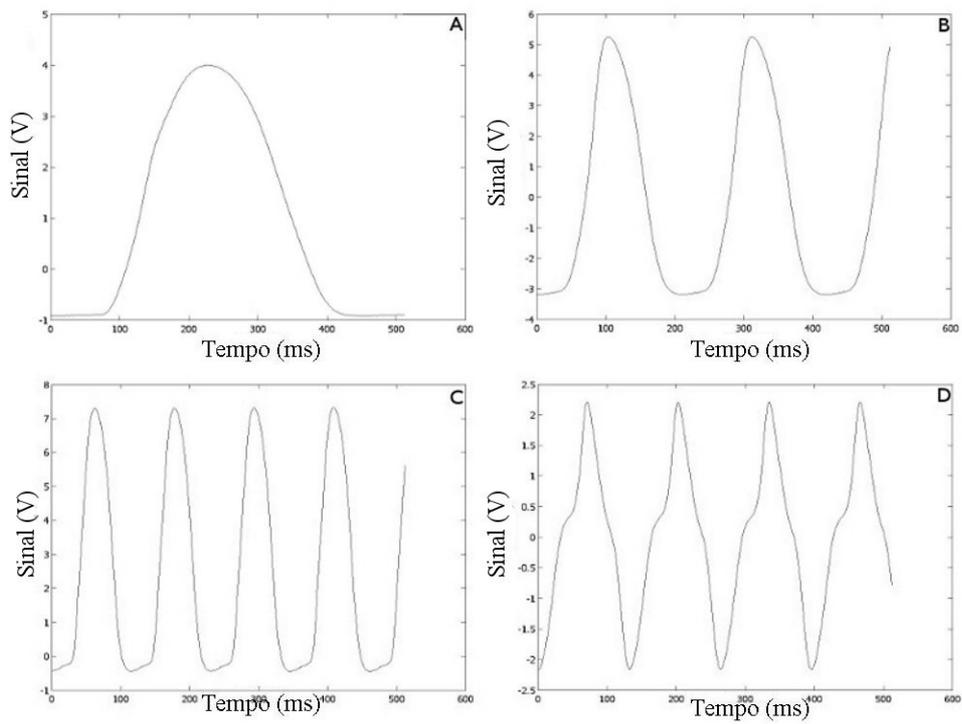


Figura 42 – Sinais de peixes elétricos onduladores:
 A) *Sternopygus* sp.; B) *Distocyclus* sp.; C) *Eigenmannia* sp.; D) *Parapteronotus hasemani*.

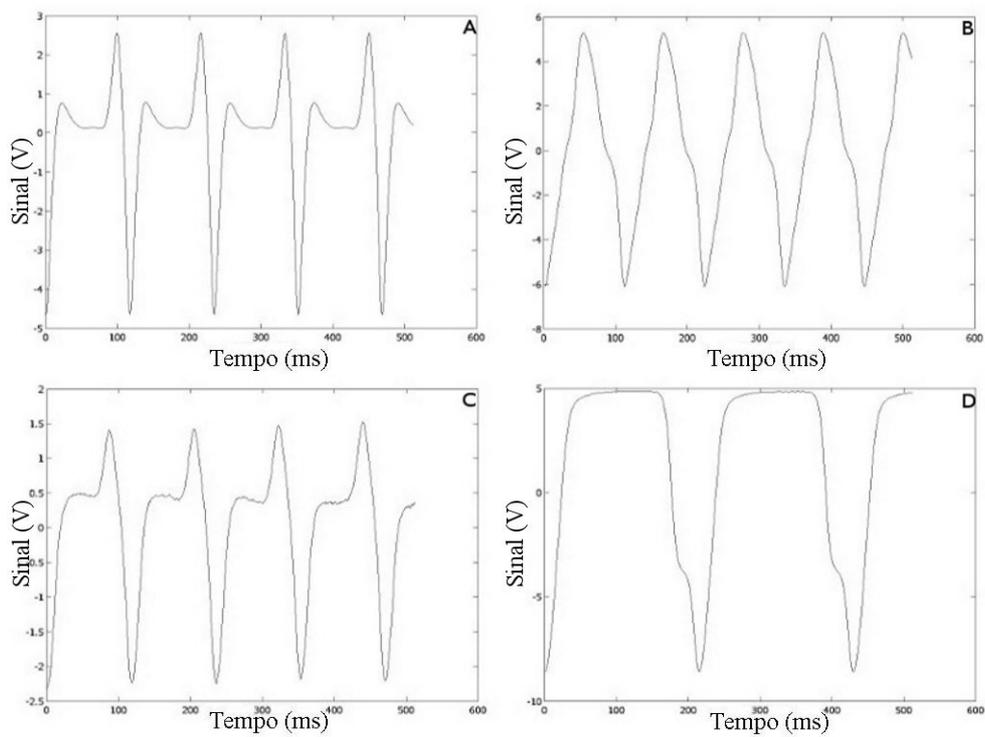


Figura 43 – Sinais de peixes elétricos onduladores:
 A) *Sternarchorhynchus roseni*; B) *Platyrosteronarchus macrostomus*; C) *Adontosternarchus balaneops*; D) *Orthosternarchus tamandua*.

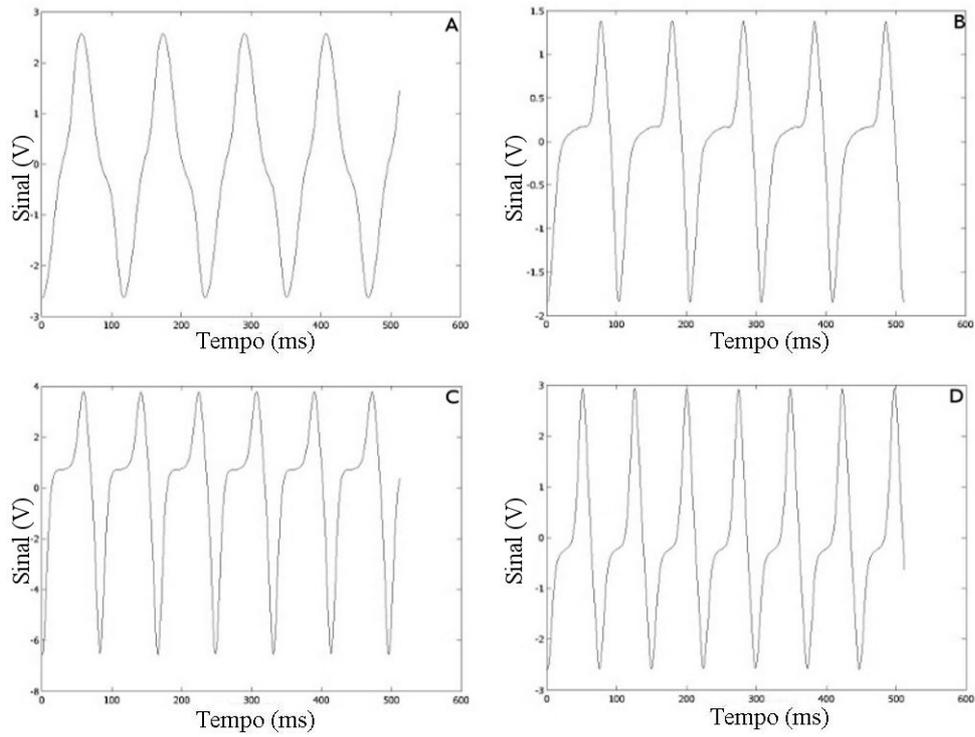


Figura 44 – Sinais de peixes elétricos onduladores:
 A) *Aptereronotus albifrons*; B) *Sternarchogiton nattereri*; C) *Porotergus gymnotus*; D) *Sternarchella schotti*.

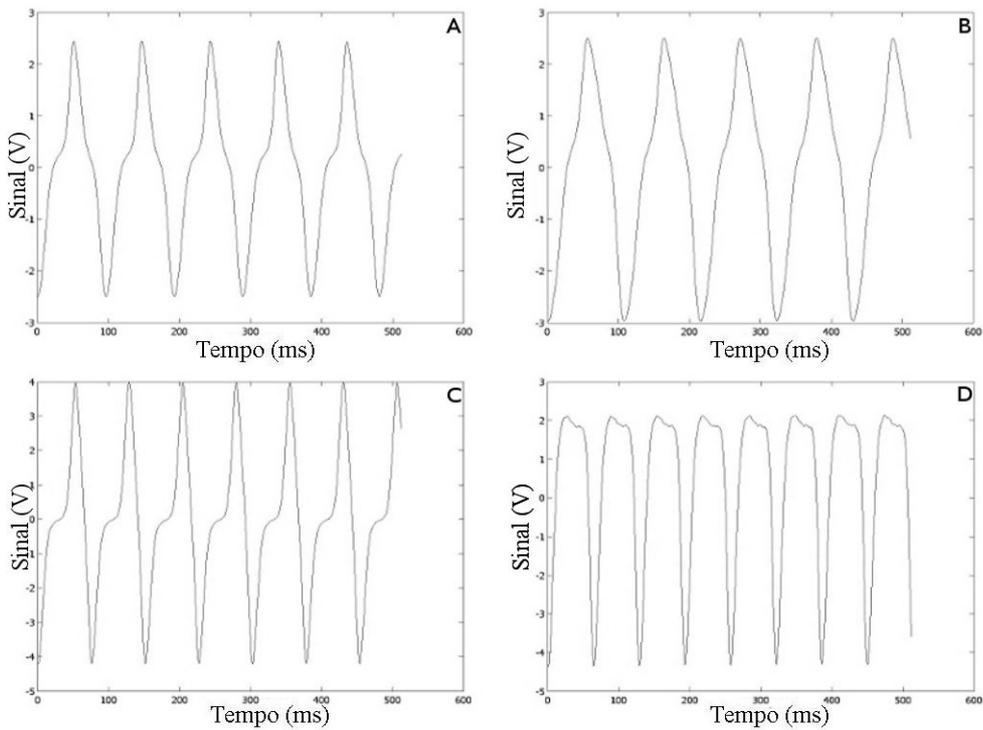


Figura 45 – Sinais de peixes elétricos onduladores:
 A) *Parapteronotus hasemani*; B) *P. hasemani*; C) *Aptereronotus bonapartii*; D) *Sternarchorhamphus muelleri*.

Foram utilizados sinais de mais peixes da espécie *P. hasemani* para aumentar a capacidade da rede neural artificial resultante em identificar os padrões das DOEs desta espécie.

Foi utilizado o algoritmo de redes neurais artificiais desenvolvido para esta tese, sendo treinadas redes neurais artificiais com uma camada de entrada, uma camada interna com 64 neurônios e uma camada de saída com 4 neurônios (arquitetura: 64-4; figura 46). Os sinais de entrada corresponderam aos tamanhos de 4096, 8192 e 16384 pontos (0,04s, 0,08s e 0,16s de sinal, respectivamente). A camada de saída, com 4 neurônios foi suficiente para a codificação binária com 16 possibilidades ($2^4 = 16$), para classificar as 14 diferentes espécies de peixes onduladores avaliadas, sendo adotados os seguintes códigos: [0 0 0 0]; [0 0 0 1]; [0 0 1 0]; [0 1 0 0]; [1 0 0 1]; [1 0 1 0]; [1 0 1 1]; [1 1 0 1]; [1 1 1 0]; [0 1 0 1]; [0 0 1 1]; [0 1 1 0]; [0 1 1 1]; [1 1 1 1].

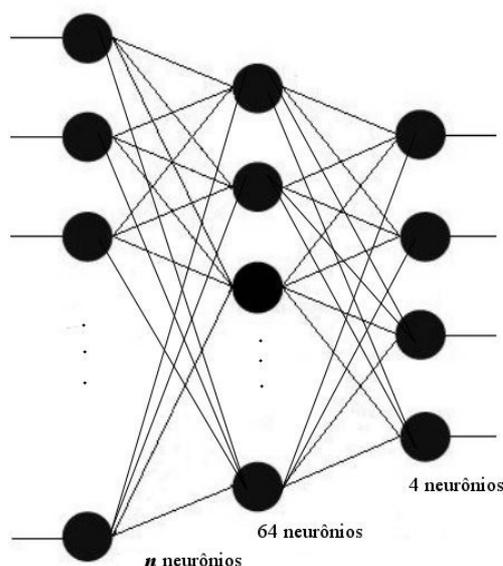


Figura 46 – Esquema de rede neural artificial para classificação de peixes onduladores.

2.3 BIOMONITORAMENTO COM GIMNOTIFORMES

2.3.1 Aquisição e Processamento de Sinais

Para os experimentos de biomonitoramento (depleção de oxigênio dissolvido e detecção de hidrocarbonetos de petróleo) com *P. hasemani*, os peixes permaneceram imobilizados em tubos experimentais de 750 mL (figura 37-A) e com aproximadamente 5 cm de diâmetro, que substituíram os tanques experimentais de 10 l, utilizados anteriormente. A estes tubos foram acoplados 3 eletrodos fixos (conjuntos de eletrodos de prata/cloreto de prata), seguindo-se o padrão utilizado nos estudos com peixes elétricos, com o eletrodo positivo (+) disposto próximo à cabeça do peixe, o eletrodo negativo (-) próximo à cauda do peixe (o eletrodo positivo fixado a 15 cm do eletrodo negativo) e o eletrodo diferencial ao centro.

Os sinais foram amplificados com amplificador diferencial AC/DC (BMA-200 CWE Inc., figura 47-B), com ganho máximo de 50x. Os sinais amplificados foram convertidos de sinais analógicos para sinais digitais pelo conversor A/D Axon Instruments Digidata 14400 (figura 47-D), visualizados em osciloscópio (Tektronix TDS2000, figura 47-E) e gravados por meio do software AxonScope[®] (sinais de 60 segundos, 16 bits de resolução e 100 KHz de taxa de amostragem) em computador (figura 47-F).

A água utilizada nas gravações era proveniente de onde o peixe estava aclimatado (tanques de manutenção de peixes do LFCE). Os aquários experimentais, bem como o amplificador, foram colocados em Gaiola de Faraday (figura 47-C e com tampa fechada figura 48) para obtenção de sinais com o mínimo de ruídos. Para esses experimentos foi considerado como padrão: temperatura $25\text{ }^{\circ}\text{C} \pm 1$, pH $6,0 \pm 0,5$, oxigênio dissolvido saturado (condição inicial/normal para os experimentos de depleção de oxigênio), condutividade $100 \pm 70\text{ }\mu\text{S/cm}$ (medidos por sonda multiparâmetros YSI 600) e iluminação constante. Os experimentos foram desenvolvidos em sala climatizada à $25\text{ }^{\circ}\text{C}$. Os peixes passaram por um período de duas horas de aclimação às condições experimentais iniciais (padrão).

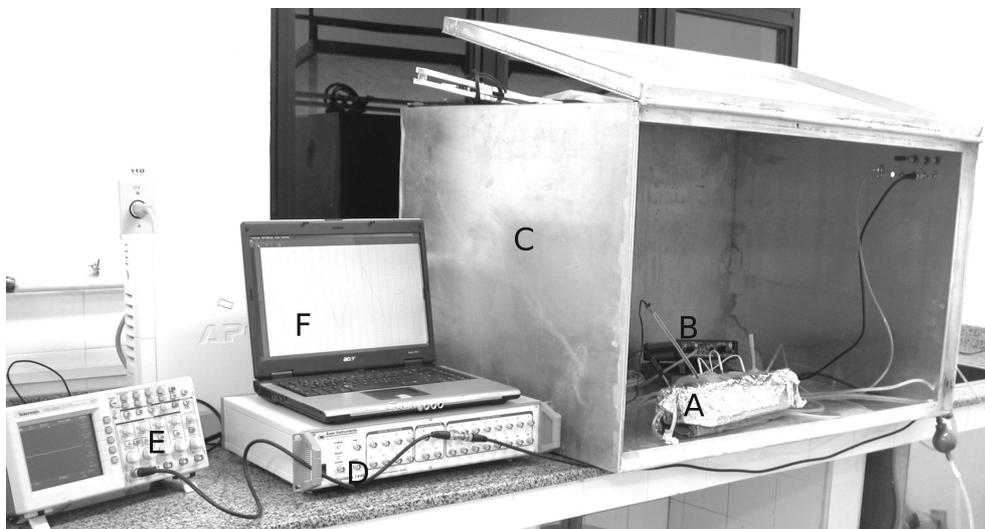


Figura 47 – Equipamentos de gravações. A) tubo experimental de 750 ml; B) amplificador diferencial AC/DC; C) gaiola de Faraday; D) conversor A/D; E) osciloscópio; F) computador.

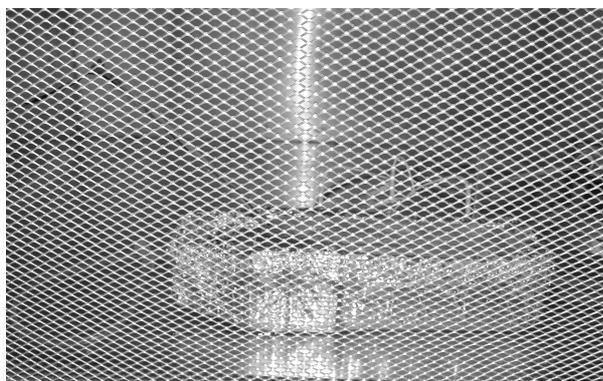


Figura 48 – Gaiola de Faraday fechada.

2.3.2 Experimento de Depleção de Oxigênio Dissolvido

O experimento de depleção de OD foi executado com 15 peixes da espécie *P. hasemani*. Para a aquisição dos sinais, os peixes foram colocados em tanques experimentais tubulares com 750 ml de capacidade (figura 49), hermeticamente fechados, com o próprio peixe levando o ambiente à hipoxia por consumo de oxigênio.

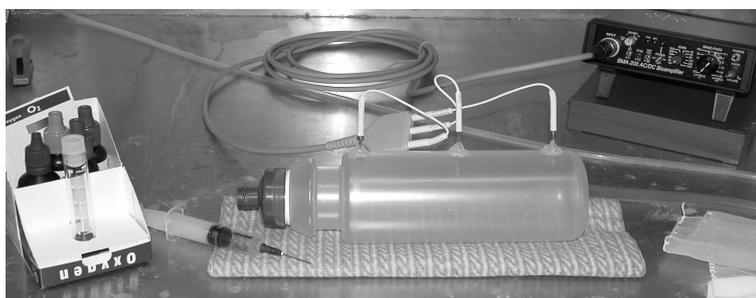


Figura 49 – Tubo experimental para oxigênio dissolvido (OD).

O comportamento dos sinais das DOEs foi constantemente monitorado em osciloscópio (Tektronix TDS2000) e também na forma de áudio, via placa de som do computador de gravação. A água do tubo experimental foi amostrada com uma seringa introduzida através de um êmbolo de borracha (amostras de 10 ml, figura 50).

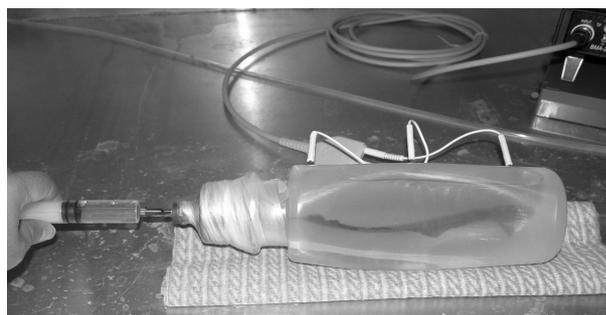


Figura 50 – Retirada de amostra do tubo experimental para oxigênio dissolvido (OD).

As gravações e amostragens de OD ocorreram da seguinte forma: após 2 horas de aclimação do peixe no tubo experimental, com oxímetro digital era confirmada a saturação de OD (por volta de 7,8 mg/l). Durante o tempo de aclimação, o tubo experimental (com peixe no interior e fechado por tela plástica) ficava dentro de um tanque com maior capacidade de água e oxigenação constante. Ao fim do período de aclimação, o tubo experimental era hermeticamente fechado, retirado do tanque e conduzido para a gaiola de Faraday. Imediatamente após a conexão dos eletrodos fixos do tubo experimental ao amplificador, o primeiro sinal (chamado de normal) era gravado. Após 20 e após 40 minutos, com o peixe no ambiente sem oxigenação, era retirada uma

amostra de água para testes colorimétricos de OD e gravava-se o sinal. Depois de 40 minutos com o peixe no tubo sem oxigenação, o OD apresentava-se com valores reduzidos. A partir deste tempo, começava-se a gravar sinais e a amostrar água para testes colorimétricos de 10 em 10 minutos, até a perda da forma/intensidade dos sinais (que supostamente caracteriza hipoxia). Imediatamente após a identificação de hipoxia (visual, no osciloscópio, e audível, na perda da amplitude/volume do sinal/som) foram gravados sinais das DOEs e a água amostrada.

Ao final do experimento, os peixes foram retirados do tubo experimental e colocados em um tanque de 10 l com OD saturado e a mesma água dos experimentos (mesmos pH, T° e CE), para recuperação fisiológica do peixe testado. A amostra final de água (10 ml) foi conduzida aos testes colorimétricos (dados aproximados de 1 em 1 mg/l) e, com a água restante no tubo experimental, foram feitas uma segunda medida do teor de OD final (em mg/l) em um oxímetro digital (YSI 550).

Foi utilizado o algoritmo de redes neurais artificiais desenvolvido para esta tese (Anexo II) para se obter uma rede neural artificial que relacione DOEs e depleção de OD. Foi testado o desempenho de redes neurais artificiais com uma camada de entrada, uma camada interna com 64 neurônios e a camada de saída com 1 neurônio (redes: 64-1; figura 51), correspondendo a um valor de saída, 0 para DOEs normais, ou 1 para DOEs de hipoxia (saída binária [0 1]). Os sinais de entrada foram de 8192 pontos (0,08s de sinal).

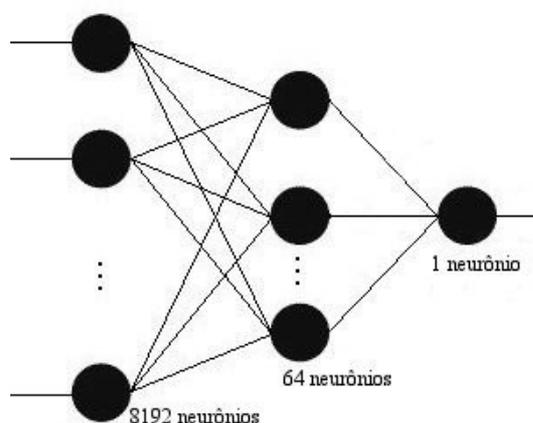


Figura 51 – Esquema de rede neural artificial para hipoxia.

2.3.3 Experimento para Detecção de Hidrocarbonetos de Petróleo

Nos experimentos para detecção de hidrocarbonetos de petróleo com gimnotiformes como biossensores, avaliou-se os efeitos causados pelos compostos BTEX nas DOEs de *Parapteronotus hasemani*. Nos testes com BTEX utilizou-se Xilol comercial (marca Merck) como representante elementar da presença da fração solúvel de petróleo em água (hidrocarbonetos aromáticos – BTEX). O Xilol é a mistura dos isômeros *o*-, *m*-, *p*-xileno e etilbenzeno, sendo seu maior constituinte o *m*-xileno (60 a 85%), com menores quantidades de benzeno (0,01%), de tolueno (0,01%) e de etilbenzeno (3%).

Os peixes foram colocados em tubos experimentais de 750 ml com sistema de aeração constante (figura 52). Após período de 2 horas de aclimação aos tubos experimentais, gravou-se uma amostra de sinal que foi considerado como o sinal normal (sem contaminação). Após a gravação dos sinais normais (no experimento piloto e no experimento para as redes neurais artificiais), o BTEX foi adicionado diretamente ao tubo experimental com o auxílio de micropipetas.



Figura 52 – Tubo experimental (750 ml) para BTEX com sistema de aeração constante.

Foi realizado um experimento piloto para se testar o funcionamento dos tubos experimentais com aeração constante à aplicação do BTEX. Também foram observadas as reações de espécimes *P. hasemani*, submetidos a diferentes concentrações de BTEX (5 mg/l, 7,5 mg/l, 10 mg/l, 25 mg/l, 50 mg/l, 100 mg/l, 250 mg/l e 500 mg/l). Para cada

concentração foi utilizado um espécime de *P. hasemani*. As gravações das DOEs ocorreram de 5 em 5 minutos até 30 minutos após aplicação de BTEX. Nas concentrações de 25 mg/l, 250 mg/l e 500 mg/l foram gravadas DOEs até 60 minutos após a aplicação de BTEX. Sempre ao final da última gravação, todos os peixes eram colocados em água sem BTEX e com os peixes nesta água sem BTEX foram gravadas DOEs para comparação.

Nos experimentos de aquisição de sinais para as avaliações com as redes neurais artificiais foram utilizadas as concentrações de 5 mg/l, 10 mg/l, 50 mg/l e 100 mg/l de BTEX. Foram avaliados 15 peixes para cada concentração de BTEX, perfazendo um total de 60 peixes. Sinais foram gravados imediatamente após aplicação de BTEX, 30 e 60 minutos após a aplicação do BTEX.

Ao final dos experimentos, os peixes foram sacrificados por choque térmico, e preservados em álcool 70%. As águas contaminadas foram armazenadas em galões para serem encaminhadas ao devido descarte.

Para as avaliações com as redes neurais artificiais foram utilizados como entradas os sinais normais e os sinais provenientes de gravações de 60 minutos após a aplicação de BTEX. Buscou-se uma rede neural artificial para avaliar a detecção de BTEX (presença ou não de BTEX) e outra rede neural artificial avaliadora de diferentes concentrações de BTEX (em 5 faixas: sem BTEX, 5 mg/l, 10 mg/l, 50 mg/l e 100 mg/l de BTEX). Ambas foram treinadas com as mesmas entradas e mesmo número de neurônios na camada interna, apenas com a camada de saída diferenciada.

Foi utilizado o algoritmo de redes neurais artificiais desenvolvido para esta tese (Anexo II), com redes neurais artificiais com uma camada interna com 64 neurônios. Para a rede neural artificial de detecção de BTEX a camada de saída teve 1 neurônio (redes: 64-1, figura 53), correspondendo a um valor de saída, ou 0 (para DOEs normal), ou 1 (para DOEs na presença de BTEX), saída binária [0 1].

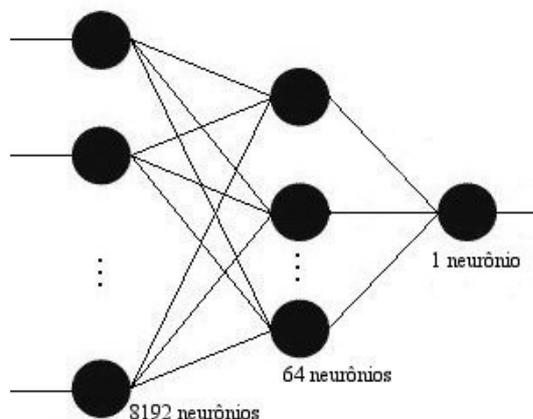


Figura 53 – Esquema de rede neural artificial para detecção de BTEX.

Para a rede neural artificial classificadora da concentração de BTEX, a camada de saída foi composta por 3 neurônios (redes: 64-3, figura 54), correspondendo aos valores de saída: [0 0 0] para 0 mg/l (DOEs normal), [0 1 1] para 5 mg/l de BTEX, [1 0 1] para 10 mg/l de BTEX, [1 1 0] para 50 mg/l de BTEX e [1 1 1] para 100 mg/l de BTEX. Os sinais de entrada tinham o tamanho de 8192 pontos (equivalente a 0,08s).

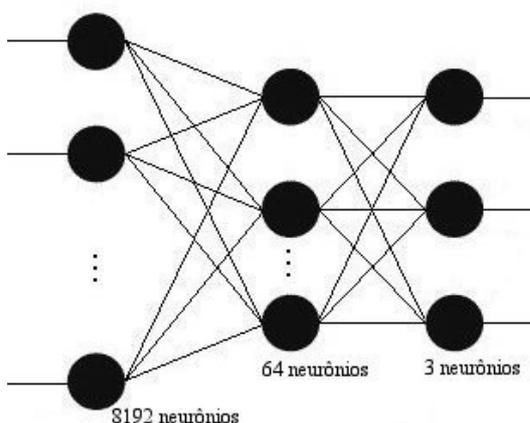


Figura 54 – Esquema de rede neural artificial para classificação de BTEX em diferentes concentrações.

2.4 REDES NEURAIS ARTIFICIAIS

Neste trabalho, foi adotada a arquitetura de rede neural artificial com três camadas: camada de entrada, camada interna e camada de saída. O número ideal de neurônios na camada interna foi determinado através da comparação do desempenho de modelos. Quanto ao número de neurônios das camadas das redes neurais artificiais treinadas seguiu-se as seguintes condições:

- Número de neurônios de entrada e de saída foram estabelecidos pela natureza do problema. As entradas de acordo com o tamanho amostrado dos sinais das DOEs: 1024, 2048, 4096, 8192, 16384 e 32768 pontos. As saídas em função da possibilidade binária de se codificar: um neurônio, duas possibilidades de respostas (1 neurônio, $2^1 = 2$); três neurônios, oito possibilidades de respostas (3 neurônios, $2^3 = 8$) e quatro neurônios, dezesseis possibilidades de respostas (4 neurônios, $2^4 = 16$), codificando a resposta desejada, exemplos, [0] para DOE de pulso, ou hipoxia; [111] para 100 mg/l de BTEX; [1010] para a espécie *Adontosternarchus balaneops*.

- Número de neurônios nas camadas internas: partindo-se do valor inteiro mais próximo da raiz quadrada do número de entradas, buscando-se reduzir o número de neurônios, quando possível.

Uma vez que o algoritmo retropropagativo é mais eficiente com o escalonamento prévio dos dados (Pedrollo, 2007), optou-se em escalonar os dados de entrada, para uniformizar a amplitude dos sinais, com intervalo entre 0 e 1, conseqüentemente a função de ativação sigmoide unipolar (figura 55) foi utilizada para ambas as camadas.

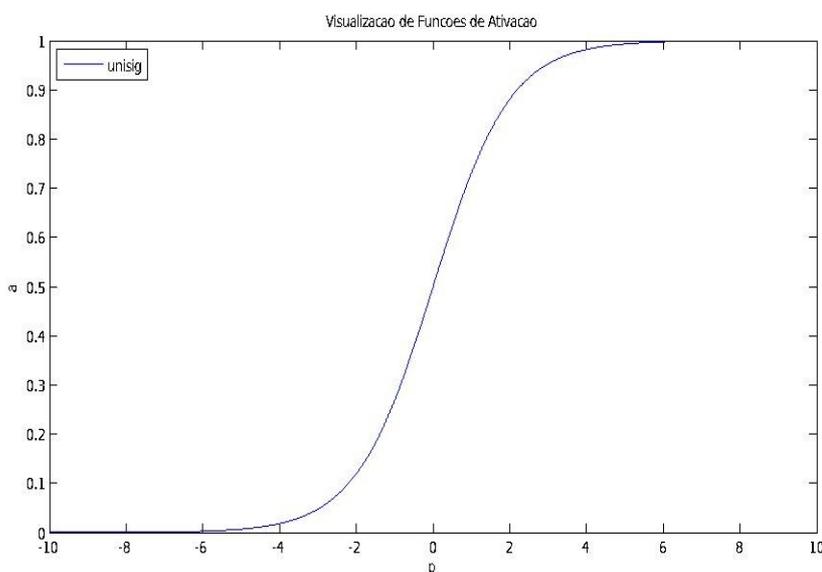


Figura 55 – Função de ativação sigmoide unipolar representada pela equação $unisig=1./(1 + \exp(-n))$.

Para conferir estabilidade ao processo de treinamento utilizou-se o termo de inércia (momento em 0,95).

O desempenho foi avaliado pela técnica de validação cruzada (Hagan et al., 1996; Haykin, 2007).

Para melhorar o desempenho nos treinamentos, optou-se em organizar os sinais de entrada com o início do sinal começando em um valor mínimo da amplitude do sinal.

No processo de verificação da capacidade de generalização, a rede neural artificial treinada foi testada com um conjunto de dados que não foi utilizado durante a aprendizagem (ou treinamento). O resultado do treinamento das redes neurais artificiais foi avaliado diretamente pelo número de acertos com relação aos valores de saída dos testes (com conjunto de dados não treinados) e os valores esperados de acordo com os dados de treinamento (valores alvo). Com este teste, verificou-se a capacidade de generalização das redes neurais artificiais de melhor desempenho, se os pesos sinápticos e tendências desta rede neural artificial correspondem em melhor desempenho e se estas redes neurais artificiais foram bem treinadas para reconhecerem os sinais de gimnotiformes apresentados.

Uma rede neural artificial com 100% de acertos foi a rede que avaliou corretamente a classificação das DOEs do conjunto de teste. Por exemplo, uma rede neural artificial para classificação de BTEX avaliando um sinal de *P. hasemani* sob 50 mg/l de BTEX (sinal que a rede não conhece, que não participou do treinamento), deverá fornecer a saída [1 1 0]. Esta saída corresponde a saída “alvo” do treinamento. No caso da rede neural para classificação de BTEX, esta deverá acertar pelo menos 120 sinais diferentes (60 sinais sem contaminação e outros 60 sinais para as 4 concentrações avaliadas).

Ao final do procedimento foi escolhida uma rede neural artificial, de cada experimento, que apresentou os melhores resultados nos desempenhos e verificações. Foram consideradas apenas as redes neurais artificiais que acertaram 100% dos testes de generalização.

3 RESULTADOS E DISCUSSÃO

3.1 CLASSIFICAÇÃO DE SINAIS DE GIMNOTIFORMES

3.1.1 Classificação de Gimnotiformes Pulsadores e Onduladores

Na tabela 01 estão os valores da taxa de repetição (em Hz) e tipo de DOE/órgão elétrico referentes aos sinais de cada Genero utilizado para compor o sistema de classificação de gimnotiformes pulsadores e onduladores.

Tabela 01 – Taxa de Repetição (Hz) das DOEs e tipos de órgãos elétricos dos gimnotiformes usados neste estudo. Tipo de DOE: P=pulsador, O=ondulador; Órgão elétrico (OE): M=miogênico, N=neurogênico.

GENERO	Hz	DOE/OE	GENERO	Hz	DOE/OE
<i>Electrophorus</i>	1,91	PM	<i>Orthosternarchus</i>	580,88	ON
<i>Gymnorhamphichthys</i>	25,22	PM	<i>Adontosternarchus</i>	853,45	ON
<i>Gymnotus</i>	39,70	PM	<i>Sternarchorhynchus</i>	854,42	ON
<i>Brachyhypopomus</i> II	45,56	PM	<i>Apteronotus</i> I	856,29	ON
<i>Stegostenopos</i>	50,01	PM	<i>Eigenmannia</i>	866,22	OM
<i>Brachyhypopomus</i> I	50,63	PM	<i>Platyurosternarchus</i>	897,08	ON
<i>Steatogenys</i>	56,25	PM	<i>Parapteronotus</i>	916,39	ON
<i>Rhamphichthys</i>	68,48	PM	<i>Sternarchogyton</i>	980,15	ON
<i>Microsternarchus</i>	80,21	PM	<i>Porotergus</i>	1210,10	ON
<i>Hypopygus</i>	86,20	PM	<i>Apteronotus</i> II	1325,00	ON
<i>Racenisia</i>	101,70	PM	<i>Sternarchella</i>	1344,40	ON
<i>Sternopygus</i>	225,51	OM	<i>Sternarchorhamphus</i>	1557,70	ON
<i>Distocyclus</i>	479,89	OM			

A classificação dos sinais de gimnotiformes pulsadores e onduladores com redes neurais artificiais foi bem sucedida. Na rede neural artificial de máxima eficiência para separar sinais de gimnotiformes pulsadores e onduladores foram utilizados 64 neurônios, com a camada de saída com 1 neurônio para gerar saída binária: [0], para sinais de pulso, ou [1], para sinais de onda; rede 64-1. A figura 56 apresenta gráficos de ciclos em função do erro quadrático, das variações da taxa de aprendizado e dos valores da soma das derivadas da rede 64-1 bem sucedida para classificação de gimnotiformes pulsadores e onduladores.

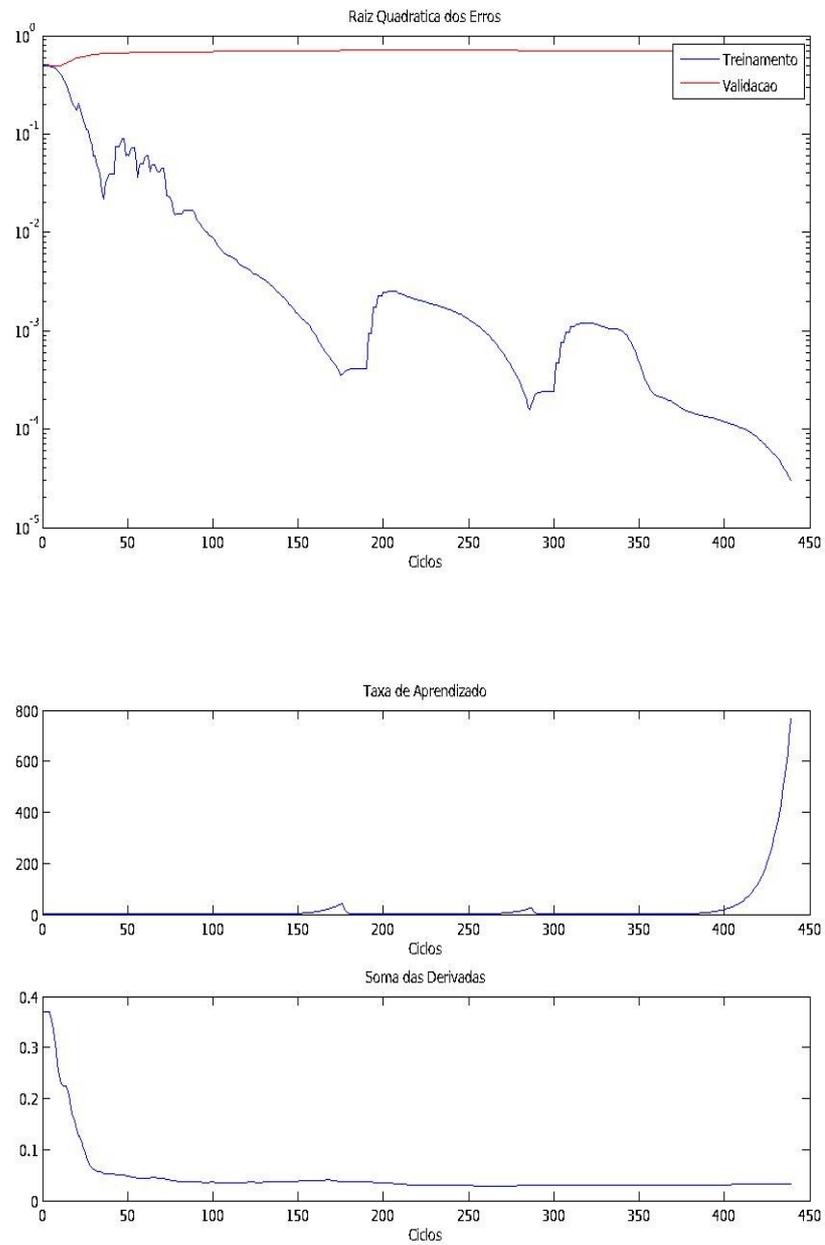


Figura 56 – Gráficos de desempenho da rede neural artificial 64-1 para classificação de gimnotiformes pulsadores e onduladores.

Os sinais de gimnotiformes são caracterizados por certa repetição. Redes neurais artificiais treinadas com estes sinais podem resultar em especialização extrema, com redes capazes de avaliar apenas os sinais treinados, sem a mínima capacidade de generalização. Para a separação de sinais de peixes pulsadores e onduladores, a capacidade de generalização deve ser maximizada.

Com a utilização das técnicas de validação cruzada propiciou-se robustez ao algoritmo de treinamento, resultando em treinamentos de redes neurais artificiais generalistas e eficientes. A rotina que foi desenvolvida possibilitou que durante o treinamento ocorresse a constante avaliação do desempenho da rede neural artificial com a série de validação, ou seja, o resultado obtido pela rede a partir dos sinais do conjunto de treinamento foram constantemente validados pelos sinais do conjunto de validação, ciclo a ciclo.

Outro fator que contribuiu para estes resultados foi a adequação das entradas em relação ao tamanho dos sinais. Com esta adequação dos sinais diminuiu o tempo de treinamento, comprovando que é significativo para resoluções com redes neurais artificiais a adequação das entradas (Hayking, 2007). O tamanho do sinal adequado a ser avaliado pelas redes neurais artificiais foi aquele que relativizou as diferenças entre as taxas de repetição das DOEs das diferentes espécies. Para os gimnotiformes, este determinante foi o mais baixo valor de taxa de repetição, que na Ordem Gymnotiformes, são das DOEs de *Electrophorus electricus* (vide tabela 01). Para as redes neurais artificiais deste trabalho, a melhor representação do tamanho do sinal foi com 16384 pontos (dentro de uma distribuição diádica: 2^{14}). Este grande sinal, com a taxa de amostragem de 100 KHz, representa aproximadamente 160 milissegundos de sinal. Com este tempo de amostragem total, pôde-se registrar o mínimo de uma DOE de *E. electricus* por conjunto de vetor amostrado (conjunto de treinamento, validação e teste).

Para os gimnotiformes com taxas de repetição das DOEs mais altas, grandes sinais poderiam contribuir para o superajustamento da rede neural artificial, pela quantidade recorrente de informações destas espécies com alta frequência das DOEs (espécies onduladoras), em detrimento às espécies com mais baixa taxa de repetição das DOEs (espécies pulsadoras). À grosso modo, pode-se inferir que esta característica da diversidade dos sinais de gimnotiformes foi a condição crítica das aplicações de redes

neurais artificiais para a classificação dos sinais de gimnotiformes pulsadores e onduladores com redes neurais artificiais.

Portanto, a utilização da técnica de validação cruzada e a preservação dos resultados de melhor desempenho ao longo das iterações possibilitou o treinamento suficiente via retropropagação dos parâmetros. O algoritmo foi robusto e capaz de obter uma rede neural artificial para classificar sinais de gimnotiformes com grande capacidade de generalização, minimizando a interferência de ruídos ou informações recorrentes na avaliação dos sinais.

3.1.2 Classificação de Gimnotiformes Onduladores

Com resultados positivos do algoritmo retropropagativo, com validação cruzada para separação de sinais de peixes pulsadores e onduladores, testou-se o mesmo algoritmo no desenvolvimento de redes neurais artificiais para classificação de sinais de peixes onduladores, priorizando-se a identificação das DOEs da espécie modelo *Parapteronotus hasemani* e da Família Aptereronotidae.

Utilizou-se redes neurais artificiais de uma camada interna com 64 neurônios, mas com a camada de saída com 4 neurônios para configurar o código binário que atendessem as 14 espécies (ou classes) avaliadas (tabela 02).

Tabela 02 – Taxa de Repetição (Hz), Coeficiente de Variação (CV) e codificação de saída de rede neural artificial (COD.) para DOEs de Gymnotiformes onduladores.

ESPÉCIES COM DOEs TIPO ONDA	Hz	COD.
<i>Sternopygus</i> sp.	225,52	[0 0 0 0]
<i>Distocyclus</i> sp.	479,86	[0 0 0 1]
<i>Eigenmannia</i> sp.	866,23	[0 0 1 0]
<i>Sternarchorhynchus roseni</i>	854,28	[0 1 0 0]
<i>Platyrosteronarchus macrostomus</i>	897,25	[1 0 0 1]
<i>Adontosternarchus balaneops</i>	851,38	[1 0 1 0]
<i>Apteronotus albifrons</i>	856,29	[1 0 1 1]
<i>Sternarchogytton nattereri</i>	980,27	[1 1 0 1]
<i>Porotergus gymnotus</i>	1210,30	[1 1 1 0]
<i>Apteronotus bonapartii</i>	1324,70	[0 1 0 1]
<i>Sternarchella schotti</i>	1344,40	[0 0 1 1]
<i>Sternarchorhamphus muelleri</i>	1557,70	[0 1 1 0]
<i>Orthosternarchus tamandua</i>	580,88	[0 1 1 1]
<i>Parapteronotus hasemani</i>	713,12	[1 1 1 1]
<i>Parapteronotus hasemani</i>	846,72	[1 1 1 1]
<i>Parapteronotus hasemani</i>	800,20	[1 1 1 1]
<i>Parapteronotus hasemani</i>	760,03	[1 1 1 1]
<i>Parapteronotus hasemani</i>	722,38	[1 1 1 1]
<i>Parapteronotus hasemani</i>	813,41	[1 1 1 1]
<i>Parapteronotus hasemani</i>	762,40	[1 1 1 1]
<i>Parapteronotus hasemani</i>	755,79	[1 1 1 1]
<i>Parapteronotus hasemani</i>	830,24	[1 1 1 1]
<i>Parapteronotus hasemani</i>	785,05	[1 1 1 1]
<i>Parapteronotus hasemani</i>	901,23	[1 1 1 1]
<i>Parapteronotus hasemani</i>	753,83	[1 1 1 1]
<i>Parapteronotus hasemani</i>	733,56	[1 1 1 1]
<i>Parapteronotus hasemani</i>	805,25	[1 1 1 1]
<i>Parapteronotus hasemani</i>	861,75	[1 1 1 1]
<i>Parapteronotus hasemani</i>	864,95	[1 1 1 1]
<i>Parapteronotus hasemani</i>	944,33	[1 1 1 1]
<i>Parapteronotus hasemani</i>	724,64	[1 1 1 1]
<i>Parapteronotus hasemani</i>	893,41	[1 1 1 1]
<i>Parapteronotus hasemani</i>	735,02	[1 1 1 1]
<i>Parapteronotus hasemani</i>	810,78	[1 1 1 1]
<i>Parapteronotus hasemani</i>	915,50	[1 1 1 1]
<i>Parapteronotus hasemani</i>	792,96	[1 1 1 1]
<i>Parapteronotus hasemani</i>	931,91	[1 1 1 1]
<i>Parapteronotus hasemani</i>	893,63	[1 1 1 1]
<i>Parapteronotus hasemani</i>	858,96	[1 1 1 1]
<i>Parapteronotus hasemani</i>	965,59	[1 1 1 1]
<i>Parapteronotus hasemani</i>	732,56	[1 1 1 1]
<i>Parapteronotus hasemani</i>	873,25	[1 1 1 1]
<i>Parapteronotus hasemani</i>	813,31	[1 1 1 1]
<i>Parapteronotus hasemani</i>	769,04	[1 1 1 1]
<i>Parapteronotus hasemani</i>	731,47	[1 1 1 1]
<i>Parapteronotus hasemani</i>	828,90	[1 1 1 1]
<i>Parapteronotus hasemani</i>	772,30	[1 1 1 1]
<i>Parapteronotus hasemani</i>	769,33	[1 1 1 1]
<i>Parapteronotus hasemani</i>	850,59	[1 1 1 1]
<i>Parapteronotus hasemani</i>	806,65	[1 1 1 1]
<i>Parapteronotus hasemani</i>	919,37	[1 1 1 1]
<i>Parapteronotus hasemani</i>	767,33	[1 1 1 1]
<i>Parapteronotus hasemani</i>	749,06	[1 1 1 1]
<i>Parapteronotus hasemani</i>	768,09	[1 1 1 1]
<i>Parapteronotus hasemani</i>	801,48	[1 1 1 1]
<i>Parapteronotus hasemani</i>	845,25	[1 1 1 1]
<i>Parapteronotus hasemani</i>	859,71	[1 1 1 1]
<i>Parapteronotus hasemani</i>	936,42	[1 1 1 1]
<i>Parapteronotus hasemani</i>	710,46	[1 1 1 1]
<i>Parapteronotus hasemani</i>	880,13	[1 1 1 1]
<i>Parapteronotus hasemani</i>	728,58	[1 1 1 1]
<i>Parapteronotus hasemani</i>	801,97	[1 1 1 1]
<i>Parapteronotus hasemani</i>	910,34	[1 1 1 1]
<i>Parapteronotus hasemani</i>	783,39	[1 1 1 1]
<i>Parapteronotus hasemani</i>	917,77	[1 1 1 1]
<i>Parapteronotus hasemani</i>	888,01	[1 1 1 1]
<i>Parapteronotus hasemani</i>	855,34	[1 1 1 1]
<i>Parapteronotus hasemani</i>	950,27	[1 1 1 1]

Neste caso da classificação de DOEs de gimnotiformes onduladores, sinais com 16384 pontos não corresponderam em melhores resultados do que vetores com metade deste tamanho, com 8192 pontos (esta redução no tamanho dos vetores resultou consideravelmente na diminuição do tempo de processamento computacional).

A rede neural artificial que obteve máxima eficiência para classificação de sinais de peixes onduladores apresentou boa convergência, mas não ficou evidenciado o ponto de divergência da validação cruzada, como pode ser observado na figura 57. A raiz quadrada dos erros decaiu continuamente ao longo dos ciclos de treinamento da rede neural artificial, sem praticamente ocorrer divergência entre o conjunto de treinamento e o conjunto de validação, com a taxa de aprendizado oscilando em valores mínimos. Nesta rede neural artificial, antes dos 4000 ciclos, ocorre evento importante entre os conjuntos de dados, que pode ser bem visualizado com o aumento significativo da taxa de aprendizado. Neste ponto ocorre a maior capacidade de generalização desta rede neural artificial e a evidência de treinamento suficiente. Os valores de pesos e tendências obtidos neste ciclo com maior taxa de aprendizado foram armazenados, tornando-se os parâmetros da rede neural artificial que foram conduzidos para o teste. O teste resultou em 100% da identificação dos sinais com relação às espécies.

Respostas semelhantes na divergência entre o conjunto de treinamento e o conjunto de validação ocorreram no treinamento de outras redes neurais artificiais bem sucedidas para classificação de peixes onduladores. Esta consistência retrata a robustez da rotina diante do conjunto de dados avaliados, ou seja, o algoritmo de treinamento foi adequado para DOEs de gimnotiformes.

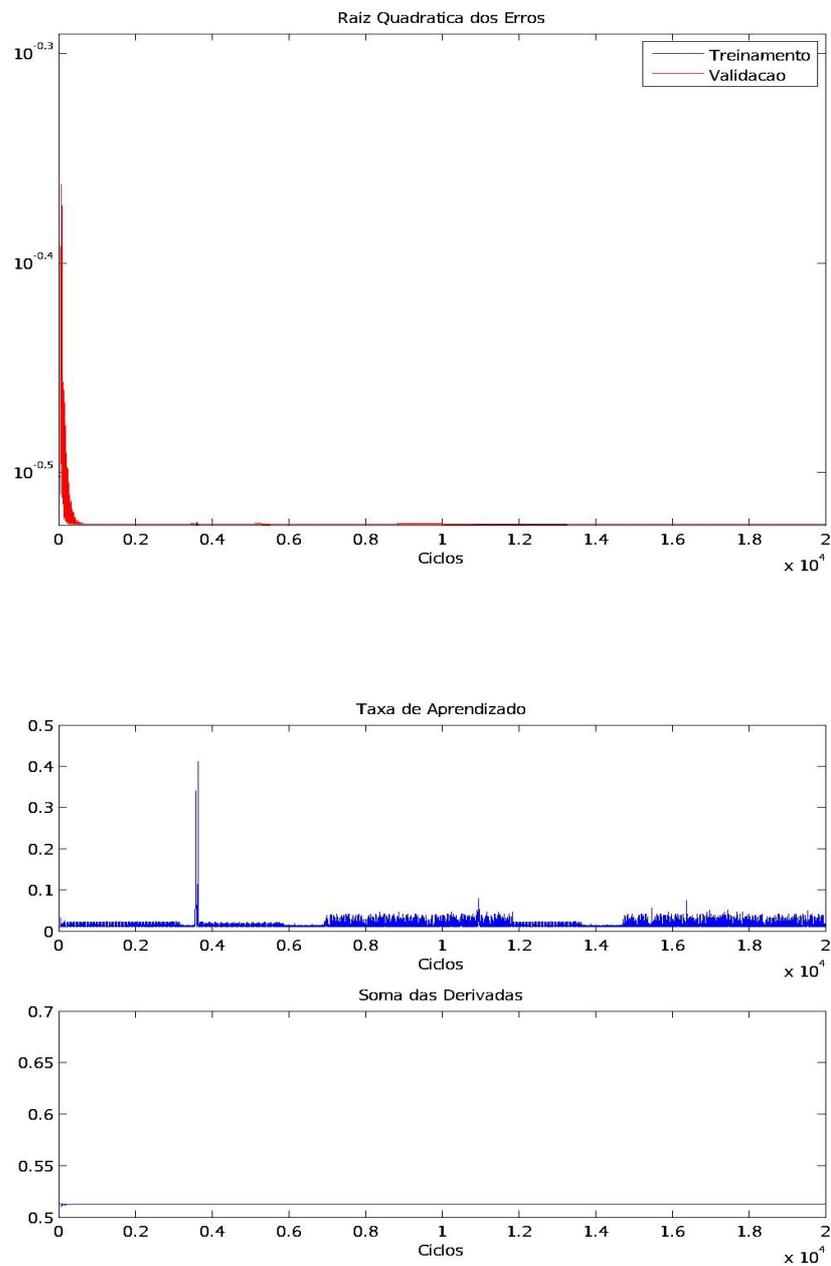


Figura 57 – Acompanhamento de treinamento e validação de rede neural artificial classificadora de peixes onduladores.

Dentre as diferentes espécies de gimnotiformes, os peixes onduladores da Família Apterontidae têm a peculiaridade de possuir órgãos elétricos neurogênicos. Os órgãos

elétricos neurogênicos capacitam os Apterontidae como os osciladores biológicos mais estáveis que se conhece (Mortgat et al., 2000), propiciando estabilidade das DOEs e condições fisiológicas para os Apterontidae gerarem descargas de mais altas frequências, podendo ir além de 2000 Hz (Alves-Gomes, 1997). As altas frequências e alta estabilidade das DOEs em Apterontidae ocorrem porque as sinapses envolvidas na DOE de um órgão neurogênico são elétricas (Bullock et al., 1979), com coeficientes de variação (desvio padrão dividido pela média) da ordem de 0,0002 (Mortgat et al., 2000).

O reconhecimento automático de padrões e a classificação por métodos de IA há muito tempo faz parte do cotidiano humano (Bishop, 1995), porém, ainda não houve aplicações para reconhecimento automático dos padrões das DOEs de gimnotiformes baseados nestes sistemas. Por outro lado, apesar dos esforços realizados nas últimas décadas, pouco se conhece sobre as DOEs da maioria das espécies de Apterontidae (de Santana, 2007), o que reforça a importância dos resultados obtidos. Kramer et al. (1981) relacionam várias espécies simpátricas de Apterontidae da Amazônia Central que apresentam formas de ondas semelhantes. E, segundo de Santana (2007), esta semelhança entre as formas de onda é a causa principal de não se utilizar as DOEs como ferramenta taxonômica em Apterontidae, mesmo que exista uma forte tendência em se fazer uso das DOEs em descrições e nas redescrições em Apterontidae. A utilização das DOEs está se tornando uma prática cada vez mais comum no estudo da sistemática em Gymnotiformes. A DOE de Apterontidae tem potencial para ser uma ferramenta útil na diagnose, bem como na geração de caracteres que possam ajudar na reconstrução da história evolutiva destes táxons (de Santana e Maldonado-Ocampo, 2004; de Santana e Crampton, 2006). Com a aplicação de técnicas de IA com as redes neurais artificiais, evidentemente, aumenta-se este potencial.

Com o estudo envolvendo 11 dos 16 Gêneros da Família Apterontidae é provável que no quesito Gênero, para apteronotídeos comumente capturados na Amazônia Central, estas redes neurais artificiais sejam uma ferramenta útil para a identificação, inclusive distinguindo bem DOEs de outras espécies onduladoras com similaridade e simpatria na taxa de repetição das DOEs (Heiligenberg e Bastian, 1981).

Com relação a outros Gêneros de Apterontidae, ou estão fora da região de coleta, ou são de difícil captura por habitarem as calhas profundas de grandes rios:

Compsaraia (Rio Orinoco); *Magosternarchus* (Rio Amazonas: calha de rio); *Megadontognathus* (Rio Xingú); *Pariosternarchus* (Rio Amazonas: calha de rio) e *Tembeassu* (Rio Paraná) (Albert, 2003).

Com o uso das técnicas de redes neurais artificiais inexistente a capacidade de extrapolação (Pedrollo, 2005), sendo assim, as redes neurais artificiais obtidas não poderiam auxiliar na classificação de peixes elétricos não amostrados. Porém, apresenta-se poderosa ferramenta para a classificação de sinais de gimnotiformes, que poderá ser melhorada. E, em casos específicos, além de outras DOEs de novas espécies, outras características poderiam ser acrescentadas a estas redes neurais artificiais, suprimindo um sistema especialista. Enfim, treinou-se redes neurais artificiais com um grupo representativo de peixes onduladores da Amazônia central (principalmente para espécies da Família Apterontidae), e, para estes, a rede neural artificial obtida foi funcional.

Complementarmente, pela alta taxa de repetição e estabilidade das DOEs, existe um interesse especial em se reconhecer automaticamente padrões em sinais de Apterontidae, na aplicação de modelos de biomonitoramento e/ou alerta ambiental. Sistemas de IA baseados em redes neurais artificiais possuem grande capacidade para solucionar os mais diversos problemas complexos (Haykin, 2007), sendo aplicados geralmente onde as técnicas tradicionais apresentam-se inadequadas, tal como na identificação de sinais de peixes onduladores (Gymnotiformes, Apterontidae).

Portanto, foi possível classificar sinais de gimnotiformes pulsadores e onduladores com uma rede neural artificial 64-1, e diferentes sinais de espécies de peixes onduladores com uma rede neural artificial 64-4, obtidas a partir do treinamento retropropagativo, com valores iniciais escalonados, função de ativação sigmoide unipolar, taxa de aprendizado variável com adaptação heurística, termo de inércia (0,95) e método de validação cruzada guardando melhor resultado.

3.2 SENSORIAMENTO DE OXIGÊNIO DISSOLVIDO

Nos experimentos sobre oxigênio dissolvido (OD), dos 15 peixes *P. hasemani* amostrados, nove peixes reduziram a amplitude das DOEs (suposta caracterização de hipoxia) aos 4 mg/l de OD, que corresponde aproximadamente a 50% de OD em água

doce à 25 °C. Nesta temperatura da água a concentração de saturação de OD é de aproximadamente 8 mg/l (Valente et al., 1997). Ao nível do mar um rio de água doce à 0 °C contém cerca de 14 mg/l e à 30 °C cerca de 7,5 mg/l (Derisio, 2007). Três peixes reduziram a amplitude das DOEs com 3 mg/l de OD e outros dois peixes com 5 mg/l. Apenas um indivíduo reduziu a amplitude das DOEs com 6-5 mg/l. Os valores da taxa de repetição das DOEs mantiveram-se praticamente estáveis para todos os peixes (tabela 3 contém valores da DOEs). Porém, a perda da capacidade de gerar potencial elétrico, ou a amplitude do sinal, foi evidente (figura 58).

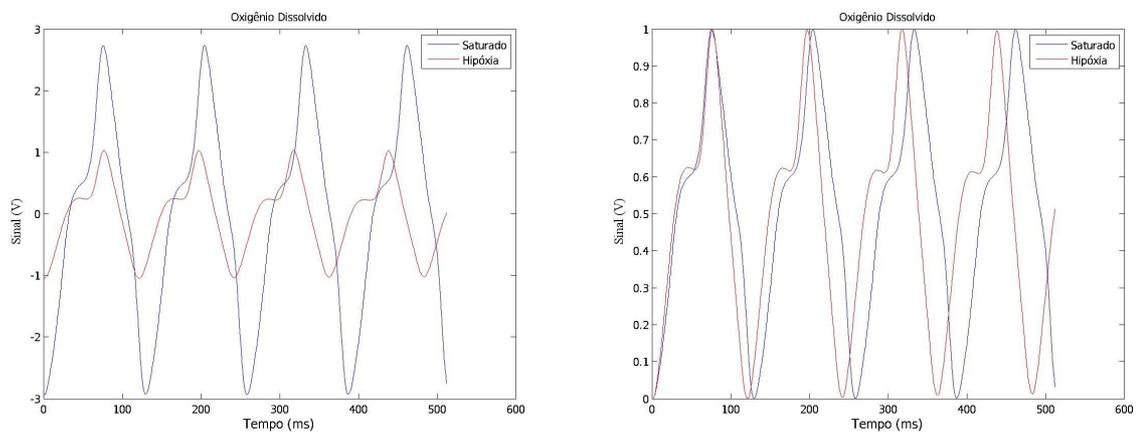


Figura 58 – Sinais normais (azul) e de hipóxia (vermelho); à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.

Tabela 03 – Taxa de repetição sinais normais (HzN) e sinais em pré-hipoxia (HzH) e Coeficiente de Variação (CVN e CVH, normais e pré-hipoxia, respectivamente) para DOEs de *Parapteronotus hasemani* do experimento de OD.

	HzN	HzH	CVN	CVH	Hipoxia
PEIXE 1					
Média	915,602	886,879	0,016	0,005	4mg/1 OD
Moda	913,350	886,590	0,018	0,004	
Desvio Padrão	4,293	0,739			
PEIXE 2					
Média	843,601	825,993	0,037	0,019	4mg/1 OD
Moda	843,230	825,880	0,037	0,019	
Desvio Padrão	1,222	0,361			
PEIXE 3					
Média	1058,539	1029,952	0,006	0,004	5mg/1 OD
Moda	1058,600	1029,200	0,005	0,004	
Desvio Padrão	0,854	0,676			
PEIXE 4					
Média	927,974	901,075	0,050	0,052	4mg/1 OD
Moda	927,820	899,940	0,050	0,052	
Desvio Padrão	0,377	0,898			
PEIXE 5					
Média	931,894	906,408	0,048	0,050	4mg/1 OD
Moda	931,950	907,030	0,049	0,049	
Desvio Padrão	0,283	0,833			
PEIXE 6					
Média	851,357	847,332	0,085	0,077	4mg/1 OD
Moda	850,640	847,370	0,085	0,077	
Desvio Padrão	0,595	0,236			
PEIXE 7					
Média	792,300	800,792	0,119	0,102	5mg/1 OD
Moda	792,190	800,690	0,119	0,102	
Desvio Padrão	0,333	0,298			
PEIXE 8					
Média	944,079	941,819	0,040	0,028	4mg/1 OD
Moda	943,600	941,920	0,040	0,028	
Desvio Padrão	0,857	0,473			
PEIXE 9					
Média	850,127	838,336	0,083	0,076	4mg/1 OD
Moda	849,720	838,570	0,083	0,075	
Desvio Padrão	0,642	0,477			
PEIXE 10					
Média	899,482	880,628	0,057	0,051	4mg/1 OD
Moda	899,300	880,230	0,057	0,052	
Desvio Padrão	0,216	0,367			
PEIXE 11					
Média	694,949	714,736	0,237	0,180	6mg/1 OD
Moda	694,330	714,530	0,237	0,180	
Desvio Padrão	0,467	0,299			
PEIXE 12					
Média	906,081	916,641	0,054	0,037	3mg/1 OD
Moda	905,930	915,430	0,054	0,039	
Desvio Padrão	0,348	2,167			
PEIXE 13					
Média	839,501	863,413	0,085	0,059	3mg/1 OD
Moda	839,600	863,130	0,086	0,058	
Desvio Padrão	0,276	0,327			
PEIXE 14					
Média	817,317	831,993	0,098	0,073	4mg/1 OD
Moda	816,250	831,930	0,098	0,073	
Desvio Padrão	0,899	0,303			
PEIXE 15					
Média	878,671	854,232	0,066	0,063	3mg/1 OD
Moda	878,270	854,270	0,066	0,063	
Desvio Padrão	0,526	0,325			

A hipoxia é uma das prováveis consequências do indesejado contato de petróleo com o meio aquático. Esta ocorrência repercute diretamente no metabolismo dos organismos aquáticos não adaptados a baixos teores de OD no meio (Duarte, 2005). Na perspectiva de qualificar gimnotiformes como biosensores para petróleo, a hipoxia vem a ser um importante fator modelado, pois os órgãos elétricos dos gimnotiformes são formados por células que demandam energia via oxigênio, ou seja, células musculares que perderam a capacidade de contração, mas que ainda disparam potenciais de ação da ordem de 100-120 milésimos de Volt (Chagas e Carvalho, 1961). No caso específico dos peixes onduladores da Família Apterontidae (a espécie *P. hasemani* como modelo), o órgão elétrico é resultante da degeneração destes órgãos elétricos miogênicos durante os primeiros dias de vida dos indivíduos, com as células neurais que o enervam se transformando no próprio órgão elétrico, neste caso, órgão elétrico neurogênico (Kirschbaum, 1983). Para a geração de DOEs existe a necessidade de energia, existe a necessidade de oxigênio. Ao nível celular a falta de oxigênio (hipóxia) resulta na perda da fosforilação oxidativa e da produção de ATP pelas mitocôndrias, e que isto reduz a capacidade de manutenção de energia nos organismos. E mais, com a atividade da ATPase Na^+/K^+ inibida ocorre a perda da homeostasia iônica da célula, impedindo a capacidade de regulação dos fluxos iônicos de Na^+/K^+ , conseqüentemente, para os gimnotiformes, resulta na perda da capacidade de geração de DOEs pelas células que compõem os órgãos elétricos. Pois são os fluxos dos íons sódio (Na^+) do espaço extracelular para a parte posterior das células que possibilitam os potenciais de ação nos eletrócitos. O Potássio (K^+) repolariza corrente na célula, fechando os canais de sódio, terminando assim o potencial de ação (Stoddard et al., 2006; Stoddard e Markhan, 2008). Ou seja, os desequilíbrios entre as relações Na^+/K^+ nos eletrócitos resultantes da hipoxia levam à incapacidade de geração de DOEs.

Segundo Crampton (1998a; 1998b), pela observação da diversidade dos sinais, os peixes elétricos com sinais tipo onda podem ter uma demanda energética total menos flexível, tornando-se mais sensíveis às mudanças ambientais. Pela relação direta à disponibilidade e demanda por oxigênio, Crampton (1998b) e Julian et al.(2003), observaram que espécies com maior taxa de repetição das DOEs (DOEs em tipo onda), possuem maior demanda energética e, conseqüentemente, maior demanda por oxigênio.

Portanto, espécies de gimnotiformes sem adaptações à hipoxia e com alta taxa de repetição das DOEs tendem a ser efetivos sensores ambientais para monitoramento de baixos níveis de OD na coluna d'água. E, *P. hasemani* foi uma espécie que apresentou sensibilidade às variações de OD.

Pelo fato dos espécimes da Família Apterontidae terem sido comumente capturados em ambientes mais oxigenados, e estes peixes ondulares com DOEs descarregando nas mais altas taxas de repetição entre os peixes elétricos Neotropicais (alta frequência – de 1 à 2 KHz), é provável que exijam maior demanda energética. Os resultados deste estudo corroboram com Crampton (1998b) e Julian et al.(2003), pois os *P. hasemani* avaliados perderam as funções fisiológicas em praticamente 50% de OD no meio. Tais experimentos não podem ser generalizados, pois outros Apterontidae que sobrevivem nas calhas dos rios, ou espécimes de maior porte, podem ter comportamento diferenciados. Porém, o experimento foi suficiente para compor os estudos com redes neurais artificiais, OD e *P. hasemani*.

Foi utilizado o algoritmo de treinamento de redes neurais artificiais dos estudos de classificação de sinais de Apterontidae, manteve-se os mesmos padrões de dimensão dos sinais que compõem as entradas para gimnotiformes ondulares, manteve-se o escalonamento, as equações de transferência, a heurística de renovação das taxas de aprendizado e a validação cruzada. Apenas a camada de saída foi diferenciada: [0] para normal/OD saturado e [1] para hipoxia. Arquitetura da rede neural artificial foi 64-1 (informações de desempenho da melhor rede figura 59).

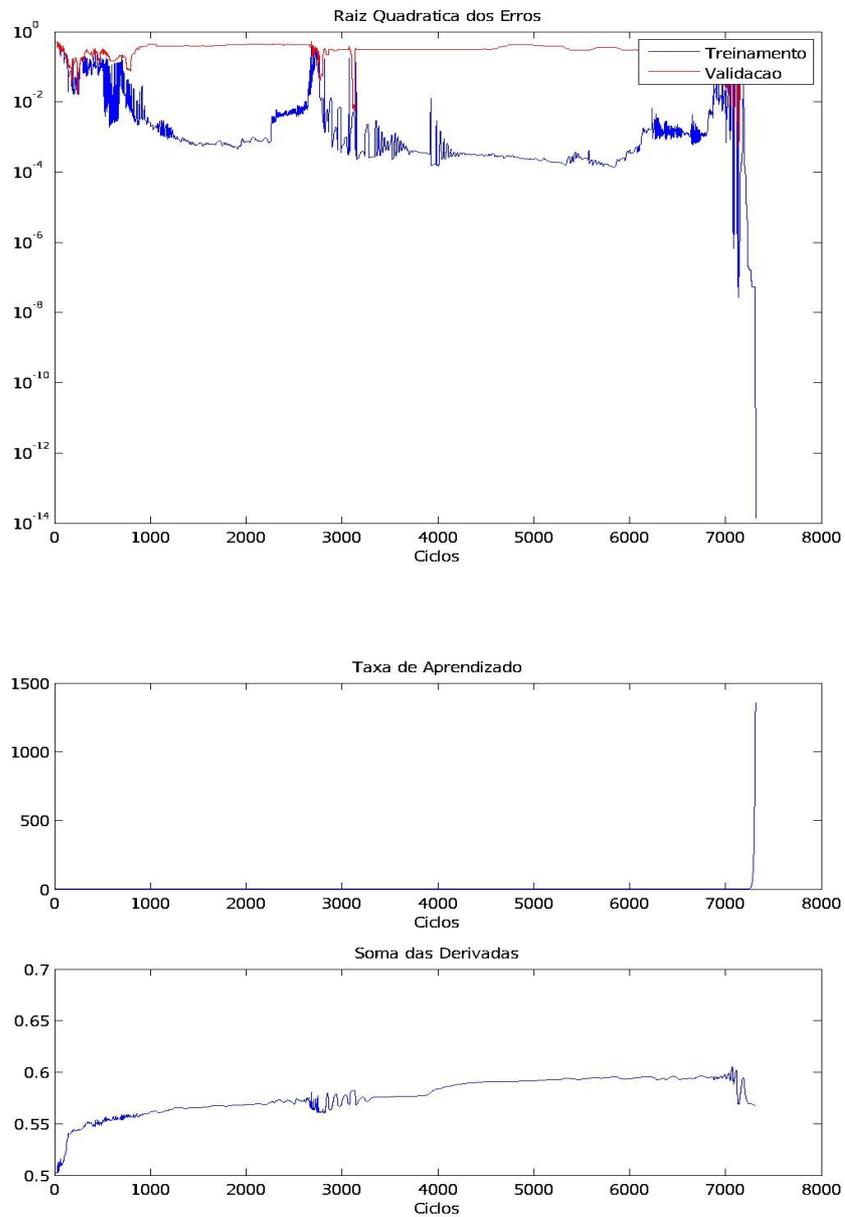


Figura 59 – Redes neurais artificiais 64-1 com 100% de acertos, taxa de aprendizado e soma das derivadas.

Portanto, com redes neurais artificiais 64-1 obteve-se máxima eficiência em separar sinais normais e sinais de hipoxia de *P. hasemani* (Apteronotidae - Gymnotiformes) a partir de algoritmo de retropropagação com validação cruzada especialmente desenvolvido para sinais de gimnotiformes (vide Anexo II), seguindo-se padrões sugeridos por Pedrollo (2005; 2007).

3.3 SENSORIAMENTO DE HIDROCARBONETOS DE PETRÓLEO

3.3.1 Experimento Piloto

O experimento piloto validou o uso dos tubos experimentais com um sistema de aeração constante para a utilização com BTEX. As reações de espécimes *P. hasemani* submetidos a diferentes concentrações de BTEX (5 mg/l, 7,5 mg/l, 10 mg/l, 25 mg/l, 50 mg/l, 100 mg/l, 250 mg/l e 500 mg/l) foram avaliadas pela taxa de repetição e o coeficiente de variação das DOEs (tabela 04).

Tabela 04 – Taxa de Repetição (Hz), Coeficiente de Variação (CV) para DOEs de *P. hasemani* do experimento piloto, sinais anteriores à aclimação (An. Aclim.), Normal, imediatamente após aplicação de BTEX (0'), de 5 min. a 60 min. e após experimento em água sem BTEX.

BTEX	An. Aclim.	Normal	0'	5'	10'	15'	20'	25'	30'	60'	Ap. s/	Ap. s/1h	Ap. s/ 24h
5 mg/l	Hz	762,37	713,18	714,16	717,99	718,76	719,6	720,15	722,5	720,54	771,69	761,71	
	CV	0,028511	0,01875	0,01833	0,15999	0,15723	0,15269	0,14931	0,13532	0,01426	0,038063	0,037939	
7,5 mg/l	Hz	818,43	780,9	791,21	788,07	783,07	782,11	779,63	775,85	774,59	781,35		
	CV	0,037484	0,03218	0,075136	0,075169	0,088065	0,090395	0,10175	0,10862	0,11455	0,009503		
10 mg/l	Hz	822,88	809,93	809,69	809,84	808,23	806,92	806,66	807,22	806,89	892,19		879,34
	CV	0,004112	0,045225	0,045315	0,045282	0,041504	0,029401	0,037959	0,033277	0,029329	0,026472		0,043688
25 mg/l	Hz	817,71	791,93	792,58	794,07	797,79	799,92	798,98	800,1	800,67	802,62	772,29	
	CV	0,037062	0,007163	0,067828	0,054986	0,005597	0,051484	0,049062	0,037185	0,036103	0,046655	0,11875	
50 mg/l	Hz	881,02	819,84	819,77	818,03	816,51	815,89	815,95	814,71	813,05	861,44	860,67	
	CV	0,044062	0,21479	0,21478	0,21872	0,22589	0,02288	0,22887	0,23383	0,23914	0,046436	0,005207	
100 mg/l	Hz	886,33	851,9	852,33	850,42	848,14	847,28	845,61	847,15	845,48	865,31	862,3	
	CV	0,033932	0,009262	0,091236	0,092485	0,095407	0,10031	0,10637	0,10087	0,10666	0,056235	0,047901	
250 mg/l	Hz	783,21	765,64	763,08	766,23	756,29	756,91	754,37	747,15	735,01	742,9	778,67	770,34
	CV	0,040414	0,049389	0,046791	0,050151	0,064744	0,061363	0,068096	0,078808	0,25137	0,093235	0,038647	0,025454
500 mg/l	Hz	860,63	796,33	795,12	793,55	782,41	453,62	324,94	329,93	336,79	302,21	759,63	768,93
	CV	0,033894	0,24109	0,24583	0,25056	0,29626	0,3322	0,51589	0,45836	0,51118	0,56142	0,48614	0,03713

Observou-se que a aclimação dos espécimes ao tubo experimental foi extremamente importante, pois foi notório que em todos os peixes avaliados existiu diferença na taxa de repetição das DOEs do momento de estresse da manipulação e após 2 horas de aclimação. Na concentração de 500 mg/l, os BTEX apresentaram-se depressores do Sistema Nervoso Central (SNC) para o gimnotiforme avaliado, corroborando com Schwertner et al. (2004) e Alves-Gomes et al. (2005) que relataram a queda brusca na taxa de repetição das DOEs de espécimes *P. hasemani* submetidos à 1000 ppm de BTEX.

Os resultados com baixas concentrações de BTEX foram semelhantes às avaliações de Schwertner (2005) que, observou que em concentrações 2 mg/l BTEX a taxa de repetição das DOEs é aumentada na presença de BTEX. Neste experimento piloto, ocorreu o aumento da taxa de repetição das DOEs com 5 mg/l de BTEX.

Importante observar que, após o experimento, com os espécimes em água boa (sem o BTEX), as DOEs foram restabelecidas, com valores próximos às taxas das condições das DOEs normal. Esta situação demonstrou que a presença de BTEX altera as DOEs de *P. hasemani*, qualificando estes peixes como biossensores para hidrocarbonetos de petróleo no meio aquático.

3.3.2 Experimento de Sensoriamento de BTEX

No experimento com BTEX para obtenção de dados de treinamento das redes neurais artificiais ficaram evidentes as diferenças nas DOEs (figuras 60, 61, 62 e 63), tanto em forma de onda como na taxa de repetição e CV (tabela 05), entre os sinais normais e os sinais com a presença de BTEX. Também ocorreram diferenças, com menor intensidade, nas concentrações de 5 mg/l e 10 mg/l de BTEX, e, de maior intensidade nas concentrações de 50 mg/l e 100 mg/l, entre as DOEs de *P. hasemani* na presença de BTEX entre os 30 minutos e 60 minutos de exposição, correspondendo ao que foi observado no experimento piloto. Foi notória a ocorrência de padrões, e estes padrões foram eficientemente reconhecidos por redes neurais artificiais. Foram utilizados os sinais provenientes de 60 minutos de exposição ao BTEX por apresentarem diferença maior em relação aos sinais normais.

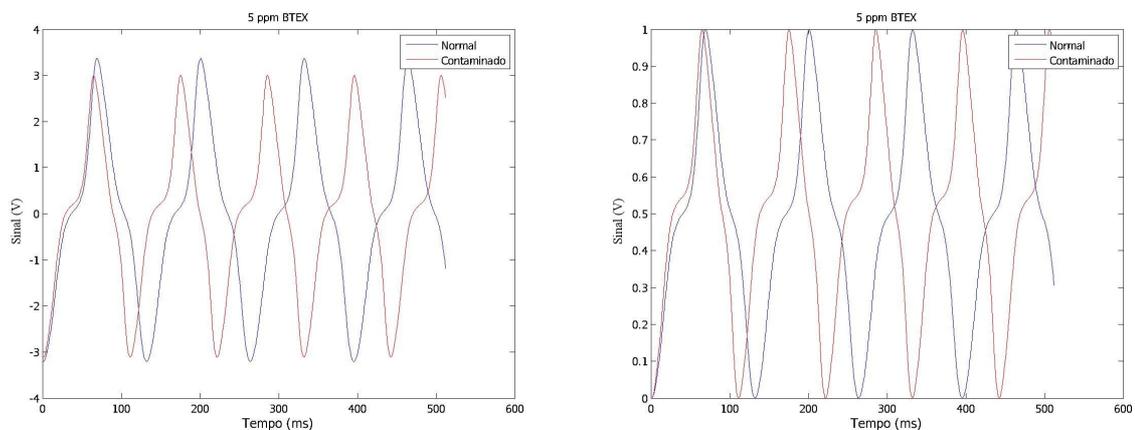


Figura 60 – DOEs Normal (em azul) e na presença de 5 mg/l de BTEX (em vermelho), à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.

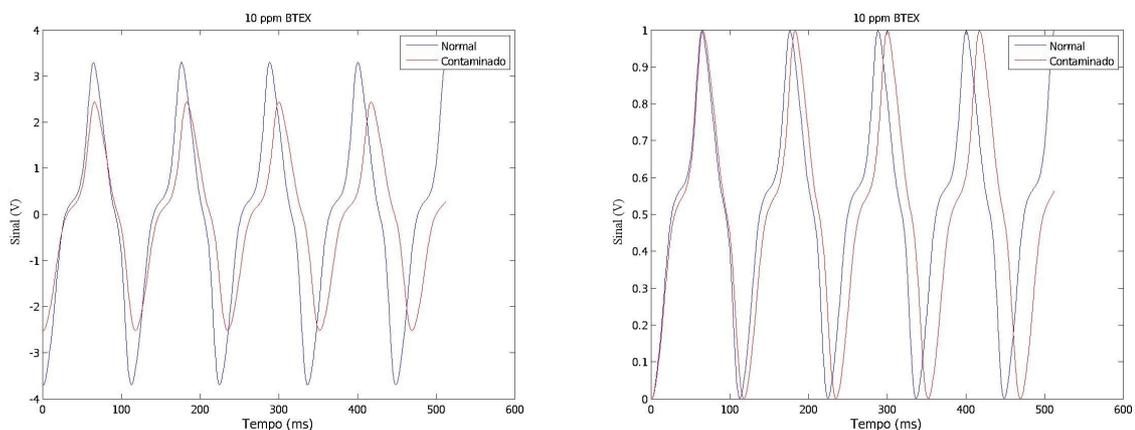


Figura 61 – DOEs Normal (em azul) e na presença de 10 mg/l de BTEX (em vermelho), à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.

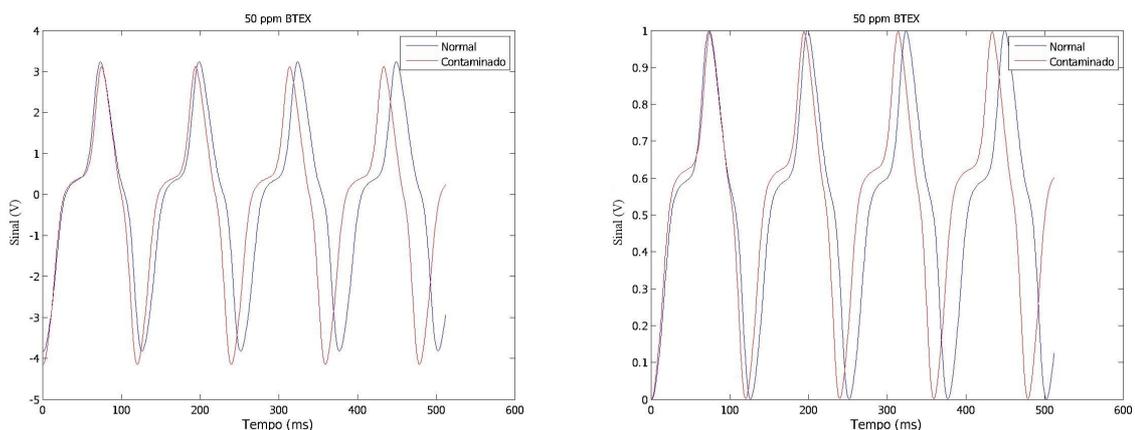


Figura 62 – DOEs Normal (em azul) e na presença de 50 mg/l de BTEX (em vermelho), à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.

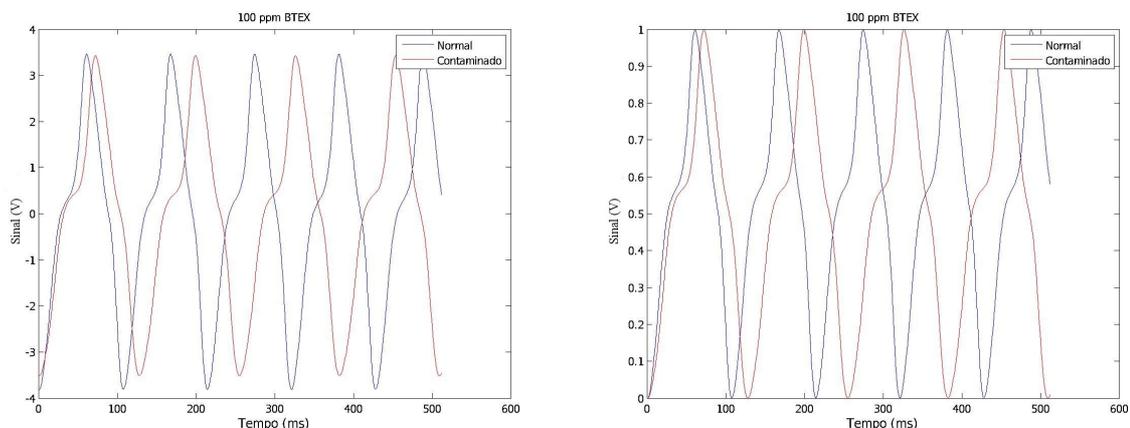


Figura 63 – DOEs Normal (em azul) e na presença de 100 mg/l de BTEX (em vermelho), à esquerda sinais não escalonados e à direita sinais escalonados entre 0 e 1.

Tabela 05 – Taxa de Repetição (Hz) e Coeficiente de Variação (CV) de DOEs de *Parapteronotus hasemani* do experimento com BTEX.

100 ppm			50 ppm			10 ppm			5 ppm			
	Hz	CV		Hz	CV		Hz	CV		Hz	CV	
Peixe 1	Normal	827,96	0,003	Normal	806,25	0,013	Normal	967,07	0,005	Normal	713,14	0,003
	BTEX 30'	813,95	0,003	BTEX 30'	799,09	0,028	BTEX 30'	960,14	0,003	BTEX 30'	728,50	0,032
	BTEX 60'	809,62	0,004	BTEX 60'	801,73	0,004	BTEX 60'	954,60	0,004	BTEX 60'	733,05	0,004
Peixe 2	Normal	819,87	0,002	Normal	861,34	0,003	Normal	885,35	0,028	Normal	846,63	0,003
	BTEX 30'	808,21	0,004	BTEX 30'	846,82	0,003	BTEX 30'	872,87	0,033	BTEX 30'	866,99	0,004
	BTEX 60'	813,31	0,002	BTEX 60'	845,38	0,004	BTEX 60'	871,41	0,029	BTEX 60'	873,31	0,004
Peixe 3	Normal	928,19	0,002	Normal	864,80	0,004	Normal	857,30	0,038	Normal	802,51	0,012
	BTEX 30'	908,43	0,002	BTEX 30'	855,61	0,003	BTEX 30'	847,32	0,045	BTEX 30'	812,02	0,018
	BTEX 60'	911,78	0,004	BTEX 60'	859,63	0,004	BTEX 60'	845,80	0,039	BTEX 60'	817,22	0,018
Peixe 4	Normal	818,97	0,055	Normal	944,21	0,003	Normal	911,40	0,015	Normal	765,90	0,026
	BTEX 30'	799,91	0,053	BTEX 30'	938,57	0,005	BTEX 30'	896,75	0,020	BTEX 30'	774,96	0,034
	BTEX 60'	802,08	0,048	BTEX 60'	936,42	0,004	BTEX 60'	896,55	0,016	BTEX 60'	777,83	0,032
Peixe 5	Normal	778,69	0,073	Normal	766,70	0,105	Normal	833,60	0,046	Normal	733,03	0,040
	BTEX 30'	759,53	0,077	BTEX 30'	755,27	0,130	BTEX 30'	821,15	0,056	BTEX 30'	742,95	0,050
	BTEX 60'	763,28	0,066	BTEX 60'	753,52	0,109	BTEX 60'	822,00	0,047	BTEX 60'	746,00	0,047
Peixe 6	Normal	861,78	0,032	Normal	896,39	0,013	Normal	899,46	0,018	Normal	812,43	0,009
	BTEX 30'	843,07	0,023	BTEX 30'	883,63	0,017	BTEX 30'	884,67	0,024	BTEX 30'	824,23	0,013
	BTEX 60'	844,85	0,022	BTEX 60'	882,28	0,014	BTEX 60'	883,80	0,023	BTEX 60'	832,26	0,016
Peixe 7	Normal	829,33	0,046	Normal	766,86	0,083	Normal	1060,70	0,043	Normal	768,37	0,024
	BTEX 30'	809,81	0,036	BTEX 30'	760,44	0,094	BTEX 30'	817,55	0,056	BTEX 30'	777,01	0,032
	BTEX 60'	814,71	0,038	BTEX 60'	759,77	0,081	BTEX 60'	814,62	0,049	BTEX 60'	781,85	0,037
Peixe 8	Normal	826,63	0,046	Normal	823,71	0,041	Normal	1089,80	0,042	Normal	763,19	0,029
	BTEX 30'	796,06	0,043	BTEX 30'	813,69	0,048	BTEX 30'	847,78	0,039	BTEX 30'	775,68	0,033
	BTEX 60'	827,42	0,029	BTEX 60'	814,84	0,040	BTEX 60'	847,27	0,032	BTEX 60'	779,19	0,038
Peixe 9	Normal	876,79	0,025	Normal	917,21	0,015	Normal	1078,40	0,043	Normal	830,42	0,004
	BTEX 30'	860,50	0,014	BTEX 30'	907,07	0,001	BTEX 30'	828,05	0,048	BTEX 30'	845,87	0,006
	BTEX 60'	866,41	0,012	BTEX 60'	911,66	0,006	BTEX 60'	829,96	0,040	BTEX 60'	851,52	0,006
Peixe 10	Normal	790,10	0,060	Normal	812,75	0,056	Normal	1058,90	0,432	Normal	788,30	0,015
	BTEX 30'	776,09	0,057	BTEX 30'	800,65	0,062	BTEX 30'	812,13	0,056	BTEX 30'	797,67	0,021
	BTEX 60'	781,75	0,050	BTEX 60'	801,43	0,054	BTEX 60'	811,57	0,048	BTEX 60'	809,86	0,016
Peixe 11	Normal	855,37	0,031	Normal	931,98	0,005	Normal	1060,40	0,043	Normal	901,01	0,003
	BTEX 30'	838,06	0,021	BTEX 30'	915,79	0,006	BTEX 30'	814,88	0,055	BTEX 30'	916,19	0,004
	BTEX 60'	840,91	0,020	BTEX 60'	917,99	0,003	BTEX 60'	812,75	0,047	BTEX 60'	920,13	0,004
Peixe 12	Normal	839,32	0,036	Normal	896,39	0,010	Normal	1103,70	0,042	Normal	777,56	0,069
	BTEX 30'	821,83	0,028	BTEX 30'	888,97	0,011	BTEX 30'	858,08	0,034	BTEX 30'	785,39	0,073
	BTEX 60'	826,54	0,024	BTEX 60'	889,72	0,010	BTEX 60'	856,67	0,029	BTEX 60'	789,56	0,066
Peixe 13	Normal	836,82	0,040	Normal	864,29	0,022	Normal	1083,90	0,042	Normal	760,38	0,078
	BTEX 30'	793,49	0,040	BTEX 30'	855,80	0,022	BTEX 30'	839,51	0,042	BTEX 30'	768,56	0,084
	BTEX 60'	805,31	0,032	BTEX 60'	859,53	0,018	BTEX 60'	837,99	0,035	BTEX 60'	774,31	0,073
Peixe 14	Normal	806,62	0,051	Normal	965,53	0,005	Normal	1143,70	0,040	Normal	776,74	0,070
	BTEX 30'	791,22	0,041	BTEX 30'	954,27	0,004	BTEX 30'	907,71	0,015	BTEX 30'	785,27	0,073
	BTEX 60'	791,44	0,039	BTEX 60'	950,27	0,004	BTEX 60'	907,50	0,012	BTEX 60'	789,77	0,066
Peixe 15	Normal	790,19	0,058	Normal	811,59	0,079	Normal	1085,90	0,041	Normal	798,45	0,052
	BTEX 30'	771,62	0,051	BTEX 30'	809,62	0,081	BTEX 30'	848,75	0,038	BTEX 30'	808,03	0,052
	BTEX 60'	774,87	0,047	BTEX 60'	797,68	0,078	BTEX 60'	846,77	0,033	BTEX 60'	811,95	0,047

Obteve-se uma rede neural artificial para avaliar alterações no sinal de *P. hasemani*, via resposta booleana, ou seja, ambiente com BTEX: saída [1], ou ambiente sem BTEX: saída [0]. Esta rede neural artificial foi treinada com o objetivo de compor um sistema de alerta ambiental. Outra rede neural artificial, mais sofisticada, foi treinada para classificar a contaminação por BTEX nas faixas de concentrações de 0 mg/l, 5 mg/l, 10 mg/l, 50 mg/l e 100 mg/l de BTEX. E mesmo com objetos de análise diferenciados foi utilizado eficientemente o algoritmo de redes neurais artificiais desenvolvido para esta tese (Anexo II). Esta intenção foi sustentada pelo sucesso dos treinamentos anteriores com DOEs de gimnotiformes.

Praticamente todos os procedimentos de treinamento para redes neurais artificiais aplicados anteriormente foram reproduzidos. Apenas ocorreu uma adequação por causa da matriz dos sinais resultantes destes experimentos com BTEX. O tamanho desta matriz de dados foi relativamente grande, com 120 colunas por 8192 linhas, o que resultou em uma considerável demanda de tempo para os treinamentos.

Portanto, foi possível detectar a presença de BTEX na água com *P. hasemani* como biossensor e uma rede neural artificial 64-1 (o desempenho da melhor rede neural artificial corresponde a figura 64). E classificar diferentes concentrações de BTEX com auxílio de uma rede neural artificial 64-3 e *P. hasemani* como biossensor (desempenho da melhor rede neural artificial corresponde à figura 65).

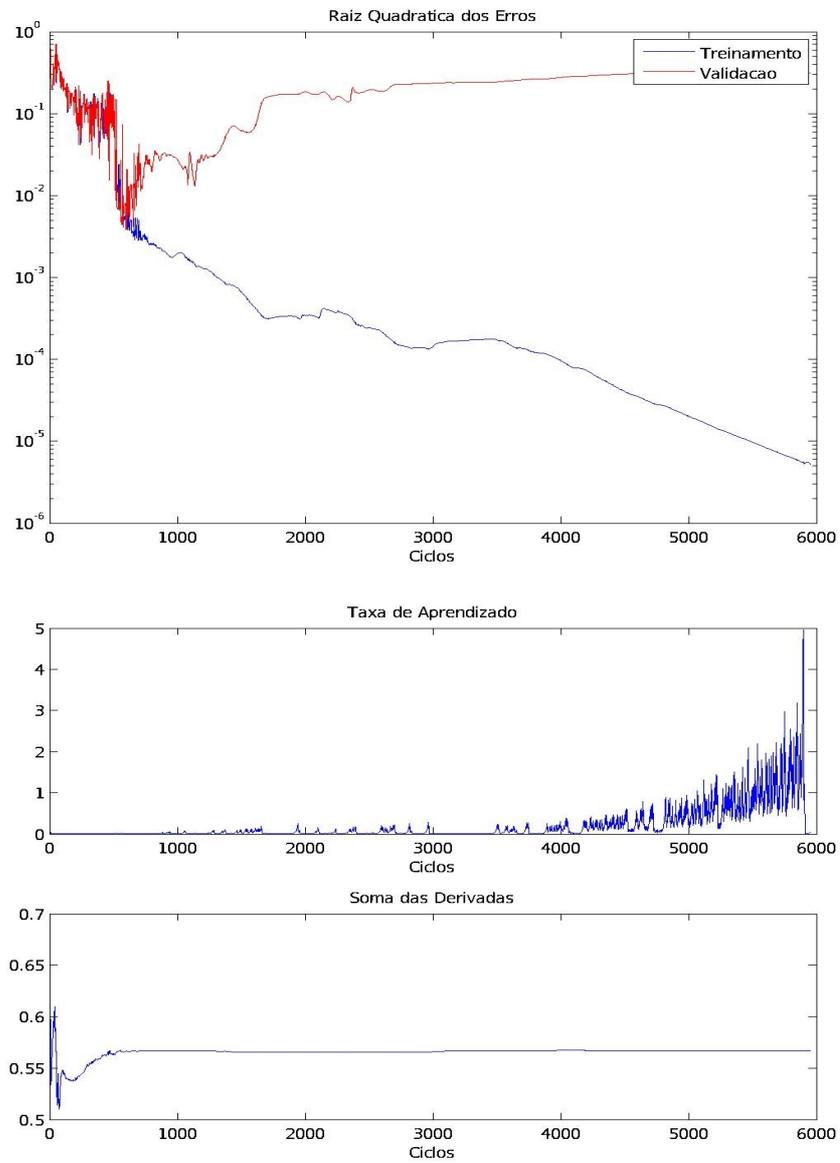


Figura 64 – Rede neural artificial 64-1 com 100% de acertos, taxa de aprendizado e soma das derivadas.

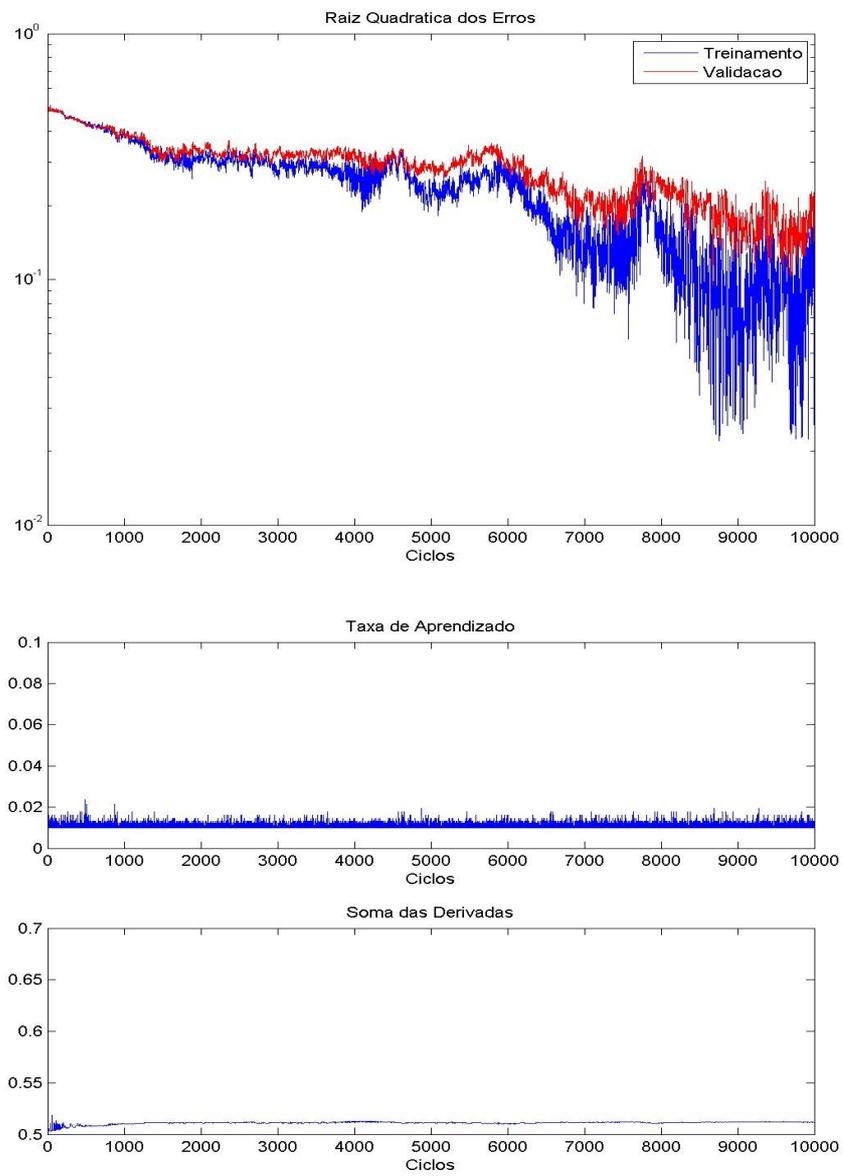


Figura 65 – Rede neural artificial 64-3 com 100% de acertos, taxa de aprendizado e soma das derivadas.

A eficiência apresentada por estas redes neurais artificiais, nas avaliações de DOEs de *P. hasemani*, qualificam gimnotiformes como biossensores via IA. Com estes resultados pode-se inferir que foram desenvolvidos subsídios para um sistema de alerta ambiental eficiente e de baixo custo para a Amazônia. O algoritmo desenvolvido foi robusto, atuando com eficiência no treinamento das mais diferentes possibilidades de classificação com redes neurais artificiais aplicadas às DOEs de gimnotiformes.

A principal constatação deste trabalho foi que as redes neurais artificiais constituem um recurso eficiente para a classificação e o reconhecimento de sinais de peixes elétricos (Gymnotiformes), desde que corretamente aplicadas, proporcionando um subsídio importante para o biomonitoramento.

O conjunto de redes neurais artificiais desenvolvidos pode formar um sistema capaz de avaliar sinais de gimnotiformes pulsadores e onduladores (figura 66 A). Selecionar os sinais que forem onduladores para outra rede neural artificial classificar ao nível de espécie, buscando a espécie de interesse *P. hasemani* (figura 66 B). Os sinais de *P. hasemani* passam pela avaliação de outras três redes neurais artificiais, resultando, ou na indicação de condições normais da água (água “boa”), ou ambiente aquático sob hipoxia (figura 66 C) e ou sob presença de BTEX (figura 66 D), e, com a detecção positiva de hidrocarboneto de petróleo na água, pode classificar em uma faixa de concentração de 5 mg/l, 10 mg/l, 50 mg/l ou 100 mg/l de BTEX (figura 66 E).

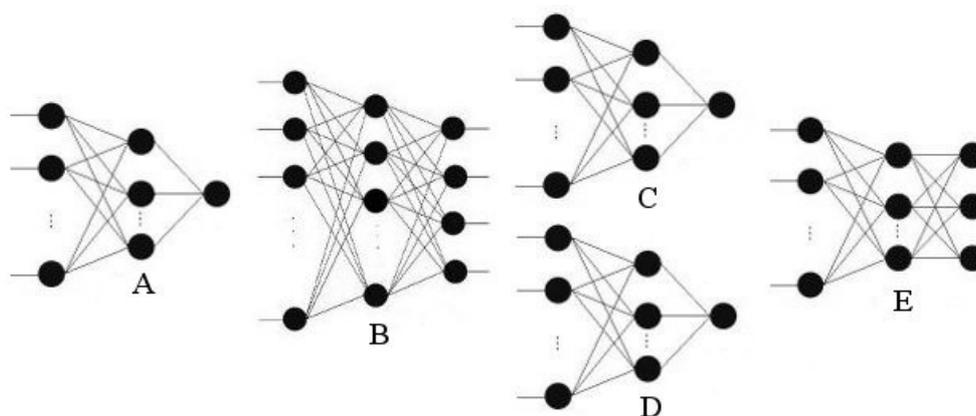


Figura 66 – Esquema de redes neurais artificiais: A) classificação de peixes pulsadores e onduladores, B) classificação de peixes onduladores, C) detecção de hipoxia, D) detecção de BTEX e E) classificação de BTEX em diferentes concentrações.

CONSIDERAÇÕES FINAIS

- Foi comprovada a aplicabilidade da interpretação das DOEs de gimnotiformes por redes neurais artificiais com os resultados obtidos nas pesquisas sobre a classificação de padrões em sinais de peixes pulsadores e de peixes ondulares e, também, com os resultados das pesquisas sobre a classificação de espécies para peixes ondulares.

- A eficiência apresentada pelas redes neurais artificiais nas avaliações de DOEs de *P. hasemani* com o desenvolvimento de tecnologia para o biomonitoramento da depleção de oxigênio dissolvido e de hidrocarbonetos de petróleo qualificam estes gimnotiformes como biossensores.

Com estes resultados pode-se inferir que foram desenvolvidos subsídios para um barato e eficiente sistema de alerta ambiental para Amazônia. Sendo que a principal constatação deste trabalho foi que as redes neurais artificiais constituem um recurso eficiente para a classificação e o reconhecimento de sinais de peixes elétricos (Gymnotiformes), desde que corretamente aplicadas, proporcionando um importante recurso tecnológico para sistemas de biomonitoramento. As redes neurais artificiais e a metodologia de processamento e análise de sinais desenvolvidas neste trabalho foram suficientes para caracterizar gimnotiformes como biossensores.

O propósito de biomonitoramento com peixes elétricos como biossensores apresenta peculiaridades vantajosas em relação a outras metodologias de monitoramento ambiental para a Amazônia. Essencialmente, porque na Amazônia Brasileira existe grande diversidade de peixes da Ordem Gymnotiformes, com espécies habitando os mais diferentes ambientes aquáticos. Além do que, estes peixes elétricos são muito estudados por causa da capacidade bioelétrica, o que propicia rápido desenvolvimento tecnológico para a utilização destes organismos como biossensores. Acrescentando-se o sucesso destas primeiras abordagens e aplicações de redes neurais artificiais no reconhecimento computacional de padrões e classificação de sinais de DOEs de gimnotiformes, as possibilidades ao encontro de novas tecnologias são realmente aumentadas.

Outra questão a ser considerada é a possibilidade do atendimento aos requisitos de Qualidade de Água, como por exemplo, a Resolução do CONAMA 357/05 (Brasil, 2005), além de outros IQAs (Índices de Qualidade de Água). O aumento da demanda por fiscalização e monitoramento ambiental, contribuiriam para a intensificação de estudos no sentido de se criar modelos de parâmetros correlacionados que visam extrapolar condições ambientais em função de medidas rápidas, *in situ* e em tempo real de apenas alguns parâmetros. Tais desenvolvimentos buscam resultados para se caracterizar corpos d'água através de alguns possíveis índices de qualidade, com o objetivo do enquadramento às Classes Legais (Derisio, 2007). Eis os gimnotiformes como sensores elétricos altamente especializados, capazes de fornecer informações do meio em que estão inseridos, de maneira sintetizada, sob a forma de um sinal elétrico. Tais sinais, quando conduzidos a sistemas de processamento em tempo real (por exemplo, sistemas de IA, com conjunto de redes neurais artificiais associados a sistemas especialistas), seriam capazes de fornecer parâmetros em IQA com uma só medida, sob a percepção do peixe elétrico traduzida em índice através de IA.

Por outro lado, fugindo-se das condicionantes científicas, perfilam outras vantagens aos peixes elétricos como biossensores. Principalmente, ao se tratar da Amazônia, com todas as características e condições inóspitas de sua natureza, pois, obviamente, estes peixes são capacitados para o auto-suprimento de energia, possuem mecanismos de auto-defesa, auto-reprodução e, o mais motivador, são “sensores elétricos” totalmente à prova d'água. Fazendo-se referência às dificuldades e custos de se dimensionar e desenvolver equipamentos eletrônicos para o sensoriamento ambiental em ambientes de difícil acesso ou remotos, muito úmidos, ou ambientes aquáticos e subaquáticos.

Seguindo-se este raciocínio, faz-se necessário o registro de sábias palavras compiladas do texto de apresentação do *II Workshop AmazonBOTS – caracterização ambiental por meios não convencionais: peixes elétricos e sistemas robóticos bioinspirados*, do Projeto COGNITUS - PETROBRAS, de autoria dos orientadores desta Tese, Dr. José Alves-Gomes e Dr. Roberto Tavares Filho, que seriam palavras perdidas sem o devido registro, e se ajustam muito bem às considerações abordadas, pois contextualizam o ideário em Tese:

– “Por ser um sistema dinâmico, a Amazônia é uma entidade que reage de diferentes formas aos diferentes estímulos que recebe, sejam estes, ações (e/ou agressões) antrópicas, eventos planetários ou mesmo desequilíbrios internos. Esta complexidade funcional gera um enorme e diverso conjunto de informações de difícil registro, processamento e interpretação, frente à nossa tecnologia atual. Por outro lado, estes 'sinais' ambientais certamente refletem, de forma detalhada as mudanças no sistema em função de alterações, em tempo de tomarmos medidas corretivas e preventivas, é preciso que saibamos registrar e interpretar os sinais e mensagens oriundos das matas e dos rios. Dentre as inúmeras formas de abordagens possíveis, pensamos que é preciso inovar, frente às novas possibilidades tecnológicas disponíveis. Neste sentido, sistemas de (bio)monitoramento ambiental podem se beneficiar tremendamente pela incorporação de sistemas eletro-eletrônicos, tecnologias robóticas e avanços recentes na capacidade de captura, armazenamento e processamento de informação. A fusão de modelos biológicos a tecnologias de ponta pode ser um diferencial estratégico para o estudo e conhecimento da Amazônia. Entre os modelos biológicos mais promissores na atualidade, encontram-se os peixes elétricos da América do Sul. Este grupo de peixes possui um tecido especializado, um órgão elétrico, capaz de gerar correntes alternadas continuamente, durante toda a vida do organismo. Paralelamente à capacidade bioeletrogênica, estes peixes também possuem um sofisticado sistema sensorial formado por eletrorreceptores, que os habilita a monitorar gradientes de voltagem no ambiente onde vivem. Trabalhando em conjunto, o órgão elétrico e os eletrorreceptores formam um sistema sensorio motor altamente especializado que funciona como uma mistura de tato, audição e visão. Pela natureza do sinal gerado, peixes elétricos constituem um dos elementos mais intrigantes e ao mesmo tempo mais fáceis de interagirem com dispositivos eletrônicos de aquisição de sinais e, por isso, são os primeiros candidatos a nos fornecerem informações sobre o ambiente aquático amazônico, nesta abordagem multidisciplinar.”

Pode-se seguramente inferir que o encontro de sistemas biológicos com sistemas tecnológicos, que sejam sistemas biotecnológicos, para o acompanhamento, monitoramento ou sensoriamento do ambiente, é um caminho promissor e eficaz para ampliar a capacidade de conhecimento e a capacidade de reação às questões do meio, que

seja, ambiente. Aplicações de técnicas de IA às DOEs de gimnotiformes, vão ao encontro de conceitos mais tecnológicos, mais cognitivos, para maior segurança das atividades humanas em prol do ambiente mais limpo e saudável.

Muitas possibilidades e soluções, além das apresentadas neste trabalho, existem: Mapas de Kohonen para classificação de sinais serviriam bem ao propósito de avaliações sistemáticas das DOEs; redes neurais artificiais de base radial para o incremento de parâmetros e as mais diferentes medidas ambientais avaliadas a partir de diferentes espécies de “gimnotiformes especialistas” em determinados padrões; redes neurais artificiais adaptativas capazes de se auto-corrigir ao longo do tempo e em diferentes condicionantes de adaptação, sejam variações de espécimes, de espécies ou condições de contorno, transmitindo o aprendizado anterior para refinamentos futuros.

Espera-se que este trabalho inspire o desenvolvimento e aprimoramento de sistemas de IA aplicados a estudos biotecnológicos e ambientais. E, do mesmo modo que ocorreram substanciais desenvolvimentos de sistemas de IA para o reconhecimento de padrões humanos (reconhecimentos automáticos de impressões digitais, voz, iris, biotipos...), que estes estudos dinamizem em rede, pois como dita Hebb (1949) em seu postulado de aprendizagem: *“a eficiência de uma sinapse variável entre dois neurônios é aumentada pela ativação repetida de um neurônio causada pelo outro neurônio, através daquela sinapse.”*

Enfim, Kohonen (1989), fazendo alusão às redes neurais artificiais, enfatiza que o principal objetivo de qualquer sistema nervoso é monitorar e controlar as condições de vida do organismo em relação ao meio no qual está inserido. Fazendo alusão aos gimnotiformes, Heiligenberg (1989) enfatiza que a maior “transparência” que se der aos sistemas simples, torna o estudo destes princípios mais viável, e com a exploração destes sistemas mais simples bem sucedida, pode-se melhorar a compreensão de sistemas mais complexos.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALBERT, J. S. Species diversity and phylogenetic systematics of American knifefishes (Gymnotiformes, Teleostei). *Miscellaneous Publications of the Museum of Zoology, University of Michigan*, 190: 1-127. 2001.
- ALBERT, J. S. Apterontidae (Ghost knifefishes). In: R. E. Reis, S. O. Kullander, C.J. Ferraris, Jr. (eds.) **Checklist of the Freshwater Fishes of South and Central America (CLOFFSCA)**. EDIPUCRS. Porto Alegre, RS. p. 497-502. 2003a.
- ALBERT, J. S. Family Sternopygidae (Glass knifefishes, Rattail knifefishes). In: R. E. Reis, S. O. Kullander, C.J. Ferraris, Jr. (eds.) **Checklist of the Freshwater Fishes of South and Central America (CLOFFSCA)**. EDIPUCRS. Porto Alegre, RS. p.493-497. 2003b.
- ALBERT, J. S. e CRAMPTON, W. G. R. Diversity and phylogeny of neotropical electric fishes (Gymnotiformes). In: Bullock, H., Hopkins, C. D., Popper, A. N., Fay, R. R. (eds.), **Electroreception**. Springer Handbook of Auditory Research, Volume 21, p. 360-409. 2005.
- ALBERT, J. S. e CRAMPTON, W. G. R. *Pariosternarchus amazonensis*: a new genus and species of Neotropical electric fish (Gymnotiformes: Apterontidae) from the Amazon River. *Ichthyological Exploration of Freshwaters*, 17: 267-274. 2006.
- ALBERT, J. S. e R. CAMPOS-DA-PAZ. Phylogenetic systematics of Gymnotiformes with diagnoses of 58 clades: a review of available data, p. 419–446. In: **Phylogeny and classification of Neotropical fishes**. L.R. Malabarba, R.E. Reis, R.P. Vari, Z.M.S. Lucena, C.A.S. Lucena (eds.). Edipucrs, Porto Alegre, Brazil. 1998.
- ALVES-GOMES, J. A. Informações preliminares sobre a bio-ecologia de peixes elétricos (Ordem Gymnotiformes) em Roraima. In: Barbosa R. I.; Ferreira E. J. e Costellón E. G. (eds.). **Homem, ambiente e Ecologia no Estado de Roraima**. Instituto Nacional de Pesquisas da Amazônia (INPA), Manaus, AM. 1997.
- ALVES-GOMES, J. A. Systematic biology of gymnotiform and mormyiform electric fishes: phylogenetic relationships. Molecular clocks and rates of evolution in the mitochondrial rRNA genes. *Journal of Experimental Biology*, 202: 1167-1183. 1999.
- ALVES-GOMES, J. A. The evolution of electroreception and bioelectrogenesis in teleost fish: a phylogenetic perspective. *The Journal of Fish Biology*, 58: 1489-1511. 2001.

- ALVES-GOMES, J. A.; ORTÍ, G.; HAYGOOD, M.; MEYER, M.; HEILIGENBERG, W. Phylogenetic analysis of the South American electric fishes (Order Gymnotiformes) and the evolution of their electrogenic system: A synthesis based on morphology, electrophysiology, and mitochondrial sequence data. *Molecular Biology and Evolution*, 12 (2): 298-318. 1995.
- ALVES-GOMES, J. A.; ROSSONI, D. M.; SCHWERTNER, G. Notas sobre a potencial utilização de peixes elétricos como bioindicadores de qualidade de água. In: *Bioindicadores de qualidade de água, Jaguariúna. Bioindicadores de qualidade de água*, 2004.
- ARDANAZ, J. L.; SILVA, A.; MACADAR, O. Temperature sensitivity of the electric organ discharge waveform in *Gymnotus carapo*. *Journal of Comparative Physiology A.*, 187: 853-864. 2001.
- ASSAD, C.; RASNOW, B.; STODDARD, P. K. Electric Organ Discharges and Electric Images during Electrolocation. *The Journal of Experimental Biology*, 202: 1185-1193. 1999.
- ATSDR - Agency for Toxic Substances and Disease Registry. Toxicological Profile for Xylene. Public Health Service. 1993.
- ATSDR - Agency for Toxic Substances and Disease Registry. Toxicological Profile for Benzene. Public Health Service. 1997.
- ATSDR - Agency for Toxic Substances and Disease Registry. Toxicological Profile for Total Petroleum Hydrocarbons (TPH). Public Health Service. 1999.
- ATSDR - Agency for Toxic Substances and Disease Registry. Toxicological Profile for Toluene. Public Health Service. 2000.
- BAIRD, C. *Química Ambiental*. 2 ed. Bookman, Porto Alegre. 622 p. 2002.
- BARLETTA, M. Estudo da comunidade de peixes bentônicos em três áreas do canal principal, próximo à confluência dos rios Negros e Solimões. In: **Projeto Piaba**, Instituto Nacional de Pesquisas da Amazônia (INPA), Manaus, AM. 1995.
- BASTIAN, J. Electrosensory organisms: By detecting weak electric fields from animate or inanimate sources, many aquatic animals acquire information used for orientation, communication and other critical behavior. *Physics Today*, p. 30-37. 1994.
- BENNETT, M. V. L. Electroreception. In: Hoar, W. S. e Randall, D. J. (eds.) **Fish Physiology**, vol. 5. New York, Academic Press. p. 493-574. 1971.

- BICHUETTE, M. E. e TRAJANO, E. Morphology and distribution of the cave *knifefish* *Eigenmannia vicentespelaea* Triques, 1996 (Gymnotiformes: Sternopygidae) from Central Brazil, with an expanded diagnosis and comments on subterranean evolution. *Neotropical Ichthyology*, 4(1): 99-105. 2006.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. Oxford University Press. 1995.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. Springer. 2006.
- BLECKMANN, H.; SCHMITZ, H.; VON DER EMDE, G. Nature as a model for technical sensors. *Journal of Comparative Physiology A.*, 190: 971-981. 2004.
- BRAGA, A.; CARVALHO, A.; LUDERMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**, 2 ed. Livro Técnico e Científico, Rio de Janeiro, 2007.
- BRASIL. CONAMA – Conselho Nacional do Meio Ambiente. 2005. Resolução N° 357 - 18 de março de 2005. Conselho Nacional do Meio Ambiente. Brasília, DF.
- BULLOCK, T. H. The future of Research on Electroreception and Electrocommunication, *The Journal of Experimental Biology*, 202: 1455-1458. 1999.
- BULLOCK, T. H. e HEILIGENBERG, W. F. **Electroreception**. New York: Wiley-Interscience 722 p. 1986.
- BULLOCK, T. H.; FERNANDES-SOUZA, N.; GRAF, W.; HELLIGENBERG, W.; LANGNER, G.; MEYER, D. L.; PIMENTEL-SOUZA, F.; SCHEICH, H.; VIANCOUR, T. A. Aspectos do uso da Descarga do Órgão Elétrico e Eletorrecepção nos *Gymnotoidei* e outros peixes Amazônicos. *Acta Amazonica*, 9 (3): 549-572. 1979.
- CAMPOS-DA-PAZ, R. New species of Megadontognathus from the Amazon basin, with phylogenetic and taxonomic discussions on the genus (Gymnotiformes: Apterontidae). *Copeia*, 1041-1049. 1999.
- CAMPOS-DA-PAZ, R. Family Gymnotidae (Naked-back knifefishes). In: R. E. Reis, S. O. Kullander and C.J. Ferraris, Jr. (eds.) **Checklist of the Freshwater Fishes of South and Central America (CLOFFSCA)**. EDIPUCRS. Porto Alegre, RS. p. 483-486. 2003.
- CHAGAS, C. e CARVALHO, A. P. **Bioelectrogenesis: a comparative survey of its mechanisms with particular emphasis on electric fishes**. Elsevier Publishing Company. 413p. 1961.

CHAO, N. L. The Fishery, Diversity, and Conservation of Ornamental Fishes in the Rio Negro Basin, Brazil – A review of Project Piaba (1989-99). p. 161-204. In: N. L. Chao; P. Petry; G. Prang; L. Sonneschien and M. Tlusty (eds.), **Conservation and Management of Ornamental Fish Resources of the Rio Negro Basin**, Amazonia, Brazil-Projeto Piaba. Manaus, EDUA, 310p. 2001.

CONCAWE – Conservation of Clean Air and Water in Europe. Ecotoxicology of Petroleum Products. A Review of Published Literature. Brussels: Office of Conservation of Clean Air and Water in Europe, *Report*, n. 88/60. 1988.

CONCAWE – Conservation of Clean Air and Water in Europe. Product Dossier. Brussels: Office of Conservation of Clean Air and Water in Europe, n. 92/103. 1992.

CONCAWE – Conservation of Clean Air and Water in Europe. Environmental Classification of Petroleum Substances – Summary data and rationale. Brussels: Petroleum Products Ecology Group, *Report*, n. 01/54. 2002.

CORSEUIL, H. X. e FERNANDES, M. Efeito do etanol no aumento da solubilidade de compostos aromáticos presentes na Gasolina brasileira. *Revista de Engenharia Sanitária e Ambiental*, 4 (1 e 2): 71-75. 1999.

COSTA, W. J. E. M. e CAMPOS-DA-PAZ, R. Description d'une nouvelle espèce de poisson électrique du genre néotropical *Hypopomus* (Siluriformes: Gymnotoidei: Hypopomidae) du sud-est du Brésil. *Revue Française d'Aquariologie*, 18 (4): 117-120. 1992.

COX-FERNANDES, C. **Diversity, distribution and community structure of electric fishes (Gymnotiformes) in the channels of the Amazon river system, Brazil**. Ph.D. Thesis. Duke University. North Carolina. 1995.

COX-FERNANDES, C. Sex-related morphological variation in two species of Apterontid fishes (Gymnotiformes) from Amazon River Basin. *Copeia*, 3: 730-735. 1998.

COX-FERNANDES, C.; LUNBERG, J. G.; RIGNOS, G. Largest of All Electric-Fish Snouts: Hypermorphous Facial Growth in Male *Apteronotus hasemani* and the Identity of *Apteronotus anas* (Gymnotiformes: Apterontidae). *Copeia*, 1: 52–61. 2002.

COX-FERNANDES, C.; PODOS, J.; LUNDBERG, J. G. Amazonian Ecology: Tributaries Enhance the Diversity of Electric Fishes. *Science*, 305: 1960-1962. 2004.

- CRAMPTON, W. G. R e ALBERT, J. S. Evolution of electric signal diversity in gymnotiform fishes, p. 641-725. In: **Fish communication**. B. G. Kapoor, F. Ladich, S. P. Collin, P. Moller (eds). Scientific Publisher, Inc. Enfield. New York. 2006.
- CRAMPTON, W. G. R. Gymnotiform fish: an important component of Amazonian flood plain fish communities. *Journal of Fish Biology*, 48: 298-301. 1996.
- CRAMPTON, W. G. R. Electric Signal Design and Habitat Preferences in a Species Rich Assemblage of Gymnotiformes Fishes from the Upper Amazon Basin. *Anais da Academia Brasileira de Ciências*, 70 (4): 805-847. 1998a.
- CRAMPTON, W. G. R. Effects of anoxia on the distribution, respiratory strategies and electric signal diversity of gymnotiform fishes. *Journal of Fish Biology*, 53 (Supplement A): 307-330. 1998b.
- CRAMPTON, W. G. R. e HOPKINS, C. D. Nesting and paternal care in the weakly electric fish *Gymnotus* (Gymnotiformes: Gymnotidae) with descriptions of larval and adult electric organ discharges of two species. *Copeia*, 2005(1): 48-60. 2005.
- de SANTANA, C. D. **“Apteronotus” sensu stricto (Gymnotiformes: Apteronotidae): monofiletismo, sistemática, e diversidade subestimada em peixes elétricos Neotropicais.** Dissertação de Mestrado, Universidade Federal de Pernambuco (UFPE), Pernambuco, Brasil. 394p. 2002.
- de SANTANA, C. D. *Apteronotus caudimaculosus* n. sp. (Gymnotiformes: Apteronotidae), a sexually dimorphic black ghost knifefish from the Pantanal, Western Brazil, with a note on the monophyly of the *A. albifrons* species complex. *Zootaxa*, 252: 1-11. 2003.
- de SANTANA, C. D. e CRAMPTON, W. G. R. *Sternarchorhynchus curumim* (Gymnotiformes: Apteronotidae), a new species of tube-snouted ghost electric knifefish from the lowland Amazon basin, Brazil. *Zootaxa*, 1166: 57-68. 2006.
- de SANTANA, C. D. e MALDONADO-OCAMPO, J. A. Redescription of *Apteronotus mariae* (Eigenmann & Fisher, 1914) and the taxonomic status of *Apteronotus jurubidae* (Fowler, 1944) (Gymnotiformes: Apteronotidae). *Zootaxa*, 632: 1-14. 2004.
- de SANTANA, C. D. **Sistemática e biogeografia da família Apteronotidae (Otophysi: Gymnotiformes).** Tese Doutorado, Programa de Pós-Graduação em Biologia Tropical e Recursos Naturais, Instituto Nacional de Pesquisas da Amazônia (INPA), Universidade Federal do Amazonas (UFAM), Amazonas, Brasil. 115p. 2007.

de SANTANA, C. D.; MALDONADO-OCAMPO, J. A.; CRAMPTON, W. G. R. *Apteronotus galvisi*, a new species of electric ghost knifefish from the Río Meta basin, Colombia (Gymnotiformes: Apteronotidae). *Ichthyological Exploration of Freshwaters*, v. 18, p. 117-124, 2007.

DEMUTH, H.; BEALE, M.; HAGAN, M. **Neural Network Toolbox™ 6**. User's Guide. The MathWorks™, Natick, MA, 907 p. 2008.

DERISIO, J. C. **Introdução ao controle de poluição ambiental**. São Paulo: Signus Editora, 2007. 3 ed.

DORNELLES, F. **Previsão contínua de níveis fluviais com redes neurais utilizando previsão de precipitação: investigação metodológica da técnica**. Dissertação - Universidade Federal do Rio Grande do Sul. Instituto de Pesquisas Hidráulicas. Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, Porto Alegre, BR-RS, Brasil. 99p. 2007.

DUARTE, R. M. **Respostas Ionoregulatórias do Tambaqui, *Colossoma macropomum*, ao Petróleo e sua Dispersão Química**. Dissertação de Mestrado, Instituto Nacional de Pesquisas da Amazônia (INPA), Universidade Federal do Amazonas (UFAM), Amazonas, Brasil. 81p. 2005.

FARHADIANA, M.; DUCHEZA, D.; VACHELARDA, C.; LARROCHEA, C. Monoaromatics removal from polluted water through bioreactors - A review. *Water Reserach*, 42: 1325 – 1341. 2008.

FERREIRA, D. J. **Utilização de *Microsternarchus bilineatus* (Ostariophysi, Gymnotiformes, Hypopomidae) como biomonitor: o efeito de combustíveis automotivos derivados do petróleo na descarga do órgão elétrico**. Dissertação (mestrado), Instituto Nacional de Pesquisas da Amazônia (INPA), Universidade Federal do Amazonas (UFAM), Amazonas, Brasil. 2008.

FRANCHINA, C. R. Ontogeny of the electric organ discharge and the electric organ in the weakly electric pulse fish *Brachyhypopomus pinnicaudatus* (Hipopomidae, Gymnotiformes). *Journal Comparative Physiology A*, vol. 181, p. 11-119. 1997.

FREEDMAN, B. **Environmental Ecology. The Impacts of Pollution and Stressors on Ecosystem Structure and Function**. Academic Press, San Diego, CA. 1989.

FREEMAN, J. e SKAPURA, D. M. 2000. **Neural Networks: Algorithms, Applications, and Programming Techniques**. Addison-Wesley Publishing, Reading, 401p. 1992.

- GARCIA, M. Aspectos ecológicos dos peixes das águas abertas de um lago no arquipélago das Anavilhanas, Rio Negro, AM. Dissertação de Mestrado. INPA/UFAM, Amazonas-Brasil. 95 p. 1995.
- GELLER, W. A toxicity warning monitor using the weakly electric fish “*Gnathonemus petresi*”. *Water Resources*, 18 (10): 1285 -1290. 1984.
- GROVE, P. e MOLLER, P. Electric Fishes as a Tool for Water Quality Assessment. *Transactions of the American Fisheries Society*, 108: 420-421. 1979.
- HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H. **Neural Network Design**, PWS Publishing Boston, MA, USA, 736 p. 1996.
- HAGEDORN, M. The ecology, courtship and mating of gymnotiform electric fish. In **Electroreception**. T. H. Bullock and W. Heiligenberg eds., p. 497-525. New York: Wiley. 1986.
- HAGEDORN, M. e HEILIGENBERG, W. F. Court and spark: electric signals in the courtship and mating of gymnotoid fish. *Animal Behaviour*, 33: 254-265.1985.
- HARTE, J.; HOLDREN, C.; SCHUEIDER, R.; SHIRLEY, C.; RUIVO, M. **Toxics A to Z: a guide to everyday pollution hazard**. Berkely: University of California Press, 576p. 1991.
- HAYKIN, S. **Redes Neurais: Princípios e práticas**. Bookman, 2 ed. 2007.
- HEBB, D. O. **The Organization of Behavior**. New York: Wiley, 1949.
- HEILIGENBERG, W. F. Coding and processing of electrosensory information in Gymnotiform fish. *Journal of Experimental Biology*, 146, 255-275. 1989.
- HEILIGENBERG, W. F. Eletrosensation. cap. 5, p.137 In: Evans, D. H. (Ed.). **The Physiology of Fishes**. Marine Science Series, Londres: Boca Raton, 592 p. 1993.
- HEILIGENBERG, W. F. e BASTIAN, J. Species specificity of Electric Organ Discharges in sympatric Gymnotoid fish of the Rio Negro. *Acta Biologica Venezuelica*, 10 (2): 187-203. 1980.
- HEILIGENBERG, W. F. e BASTIAN, J. Especificidade da descarga dos órgão elétrico em espécies de Gimnotóides simpátricos do rio Negro. *Acta Amazonica*, 11 (3): 429-437. 1981.
- HILTON, E. J. e COX-FERNANDES, C. Sexual Dimorphism in *Apteronotus bonapartii* (Gymnotiformes: Apteronotidae). *Copeia*, (4), pp. 826–833. 2006.
- HOPKINS, C. D. Convergent designs for electrogenesis and electroreception, *Current Opinion in Neurobiology*, 5 (6): 769-777. 1995.

HOPKINS, C. D.; HEILIGENBERG, W. F. Evolutionary designs for electric signals and electroreceptors in Gymnotoid fishes of Surinam. *Behavioral Ecology and Sociobiology*, vol. 3, p. 135-162. 1978.

IARC - International Agency for Research on Cancer. Monographs on the Evaluation of Carcinogenic Risks to Humans. Disponível em: <<http://www.iarc.fr>>. Acesso em: 25 jan. 2010.

JEFFREY, D. W. e MADDEN, B. **Bioindicators and environmental management**. London : Academic, c1991. xiii, 458 p. 1991.

JULIAN, D.; CRAMPTON, W. G. R.; WOHLGEMUTH, S. E.; ALBERT, J. S. Oxygen consumption in weakly electric Neotropical fishes. *Oecologia*, 442, 502 -511. 2003.

KASABOV, N.K. **Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering**. A Bradford Book, The MIT Press. 2 ed. 1998.

KAY, A. N. e LEWIS, J. W. Fish monitors and role of electric fish as potential indicators of water quality. *Journal of Applied Ichthyology*, 9: 110 – 114. 1993.

KIRSCHBAUM, F. Myogenic Electric Organ Precedes the Neurogenic Organ in Apterontoid Fish. *Naturwissenschaften*, 70: 205-206. 1983.

KIRSCHBAUM, F. Discharge types of gymnotiform fishes. Cap. 8.3 p171 In: Moller, P. **Electric Fishes – History and behavior**. Fish and Fisheries Series 17. 5 ed. New York: Chapman & Hall, 584p. 1995.

KNUDSEN, E. I. Behavioral thresholds to electric signals in high frequency Electric Fish. *Journal of Comparative Physiology*, 91: 333-353. 1974.

KNUDSEN, E. I. Spatial Aspects of the Electric Fields Generated by Weakly Electric Fish. *Journal of Comparative Physiology*, 99: 103-118. 1975.

KOHONEN, T. **Self Organization and Associative Memory**. Springer-Verlag. Berlin, 1989.

KRAMER, B.; KIRSCHBAUM, F.; MARKL, H. Species specificity of electric organ discharges in a sympatric group of gymnotoid fishes from Manaus (Amazonas). In: **Sensory Physiology of Aquatic Lower Vertebrates**, Szabo, T.; Czeh, G. (eds.). Akademiai Kiado, Pergamon, Budapest, pp. 195 – 219. 1981.

KRAMER, K. J. M.; BOTTERWEG, J. Aquatic biological early warning systems: an overview. In: Jeffrey, DJ; Madden, B, (eds.). **Bioindicators and environmental management**. London, UK: Academic Press, pp. 95-126. 1991.

- KUNZE, P. e WEZSTEIN, H. U. Apomorphine and haloperidol influence electric behaviour of a mormyrid fish. *Zeitschrift für Naturforschung*, 43, 105-107. 1987.
- LÊVÊQUE, C; OBERDORFF, T.; PAUGY, D.; STIASSNY, M. L. J.; TEDESCO, P. A. Global diversity of fish (Pisces) in freshwater. *Hydrobiologia*, 595:545–567. 2008.
- LEWIS J. W. e KAY A. N. The effect of Temperature on electric organ activity in 2 species of *Gnathonemus* (Family Mormyridae). *Environmental Technology*, 12 (9): 815-819. 1991.
- LEWIS, J. W.; KAY A. N.; HANNA, N. S. Responses of Electric Fish *Gnathonemus*-Tamandua (family Mormyridae) to Changes in pH. *Environmental Technology*, 13 (8): 701-705. 1992a.
- LEWIS, J. W.; KAY A. N.; HANNA, N. S. Responses of Electric Fish (family Mormyridae) to Chemical-Changes in Water-Quality .1. Cyanide. *Environmental Technology*, 13 (12): 1169-1174. 1992b.
- LEWIS, J. W.; KAY A. N.; HANNA, N. S. Responses of Electric Fish (family Mormyridae) to Chemical-Changes in Water-Quality .2. Pesticides. *Environmental Technology* 14 (12): 1171-1178. 1993.
- LEWIS, J. W.; KAY A. N.; HANNA, N. S. Responses of Electric Fish (family Mormyridae) to Chemical-Changes in Water-Quality .3. Heavy-Metals. *Environmental Technology*, 15 (10): 969-978. 1994.
- LEWIS, J. W.; KAY A. N.; HANNA, N. S. Responses of Electric Fish (family Mormyridae) to Inorganic Nutrients and Tributyltin Oxide. *Chemosphere*, 31 (7): 3753-3769. 1995.
- LUNDBERG, J. G., LEWIS, W. M.; SAUNDERS, J. F.; MAGIO-LECCIA, F. A major food web component in the Orinoco river channel: evidence from planktivorous electric fishes. *Science* 237: 81-83. 1987.
- MAGO-LECCIA, F. **Electric fishes of continental waters of America**. FUDECI. 207 p. 1994.
- MAIA, C. R. ; ALVES-GOMES, J. A. ; SCHMITT, R. Variabilidade genética de *Microsternarchus bilineatus* (Gymnotiformes: Hypopomidae) em diferentes tributários no rio Negro, Amazônia, Brasil. 54 Congresso Brasileiro de Genética. Salvador. 2008.
- MANAHAN, S. E. **Environmental Chemistry**. 7 ed. Florida: Lewis Publishers, 898 p. 2000.
- MARRERO, C. e TAPHORN, D. Notas sobre la historia natural y la distribucion de los peces Gymnotiformes en la cuenca del rio Apure y otros rios de la Orinoquia. *Biollania*, (8): 123-142. 1991.

- MCCULLOCH, W. e PITTS, W. A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics*, vol. 5, p. 115-133. 1943.
- MINSKY, M. e PAPERT, S. **Perceptrons**, Cambridge, MA: MIT Press, 1969.
- MOLLER, P. **Electric Fishes – History and behavior**. Fish and Fisheries Series 17, 5 ed. New York: Chapman & Hall, 584 p. 1995.
- MOLLER, P. Multinodal sensory integration in weakly electric fish: a behavior account. *Journal of Physiology - Paris*, 96: 547-556. 2002.
- MOORTGAT, K. T.; BULLOCK, T. H; SEJNOWSKI, T. J. Precision of the Pacemaker Nucleus in a Weakly Electric Fish: Network Versus Cellular Influences. *Journal of Neurophysiology*, 83: 971-983. 2000.
- NELSON, M. E. e MACIVER, M. A.; Coombs, S. 2002. Modeling Electrosensory and Mechanosensory Images during the predatory behavior of weakly electric fish, *Brain, Behavior and Evolution*, 59:199-210.
- NOGUEIRA, A. P. R. **Caracterização e análise do repertório eletrocomunicativo de *Microsternarchus cf. bilineatus* Fernández-Yépez, 1968 (Pisces: Gymnotiformes) durante a maturação sexual em cativeiro**. Dissertação (mestrado), Programa de Pós-Graduação em Biologia Tropical e Recursos Naturais, Instituto Nacional de Pesquisas da Amazônia (INPA), Universidade Federal do Amazonas (UFAM), Amazonas, Brasil. 80p. 2006.
- NORVING, S. e RUSSEL, P. **Artificial Intelligence: A Modern Approach**. Prentice-Hall, Saddle River, NJ, 1995.
- PEDROLLO, O. C. e LANNA, A. E. Previsão de cheias em tempo atual com sistema especialista difuso. *Revista Brasileira de Recursos Hídricos*. Porto Alegre, RS. v.8, n.1, p. 45-60. 2003.
- PEDROLLO, O. C. SIRENE I - Sistema de Redes Neurais Progressivas: Versão 1. Relatório de pesquisa IPH/UFRGS. 2007.
- PEDROLLO, O. C. Sistema de redes neurais progressivas aplicativo para a área hídrica e ambiental. 1º Simpósio de Recursos Hídricos do Sul - 1º Simpósio de Águas da AUGM, Santa Maria, 2005.
- PIMENTEL-SOUZA, F. e SIQUEIRA, A. L. Effect of external carbon dioxide concentration on the electric organ discharge frequency in the gymnotiform fish *Apteronotus albifrons*. *Brazilian Journal of Medical and Biological Research*, 25(2): 175-180. 1992.

- PLANQUETTE, P.; KEITH, P.; LEBAIL, P. Y. **Atlas des poissons d'eau douce de Guyane**. Vol. 1. Collection du Patrimoine Naturel, vol. 2. IEGB, MNHN, INRA, CSP, Ministère de l'Environnement. Paris. 329 p. 1996.
- RAPP-PY-DANIEL, L. H. e COX-FERNANDES, C. Dimorfismo sexual em Siluriformes e Gymnotiformes (Ostariophysi) da Amazônia. *Acta Amazonica*, vol.35, n.1, p. 97-110. 2005.
- RASNOW, B. The effects of simple objects on the electric field of *Apteronotus*. *Journal of Comparative Physiology A.*, 178: 397-411. 1996.
- RASNOW, B. e BOWER, J. M. 1996. The Electric Organ Discharge of the gymnotiform fishes: I. *Apteronotus leptorhyncus*. *Journal of Comparative Physiology A.*, 178: 383-396.
- RASNOW, B.; ASSAD, C.; BOWER, J. M. Phase and amplitude maps of the Electric Organ Discharge of the weakly electric fish, *Apteronotus leptorhyncus*. *Journal of Comparative Physiology A.*, 172: 481-491. 1993.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, vol. 65, p. 386. 1958.
- ROSSONI, D. M. **A utilização das Descargas dos Órgãos Elétricos de *Apteronotus hasemani* e *Apteronotus bonapartii* (Apteronotidae – Gymnotiformes) como Bioindicadores em Ambientes Aquáticos**. Dissertação (mestrado), Instituto Nacional de Pesquisas da Amazônia (INPA), Universidade Federal do Amazonas (UFAM), Amazonas, Brasil. 2005.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by back-propagating errors. *Nature*, vol. 323, p. 533-536. 1986.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning Internal Representations by Error Propagation. In.: **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**, Vol. 1, Cambridge, MA: MIT Press. 1986.
- SAUER, T. C. e BOEHM, P. D. Hydrocarbon chemistry analytical methods for oil spill assessments. Washington, DC: Marine Spill Response Corp. Technical Report Series 95-032. 114 p. 1995.
- SCHMITT, R. **Filogeografia de *Hypopygus lepturus* Hoedeman, 1962 (Gymnotiformes: Rhamphichthyidae) ao longo do médio rio Negro, Amazônia: notas sobre especiação em *Hypopygus***. Dissertação (mestrado), Programa de Pós-Graduação em Biologia Tropical e Recursos Naturais, Instituto Nacional de Pesquisas da Amazônia (INPA), Universidade Federal do Amazonas (UFAM), Amazonas, Brasil. 80p. 2005.

- SCHWERTNER, G. **Apteronotidae (Pisces: Gymnotiformes) como modelo de Biomonitor para compostos BTX**. Dissertação (mestrado), Instituto Nacional de Pesquisas da Amazônia (INPA), Universidade Federal do Amazonas (UFAM), Amazonas, Brasil. 118p. 2005.
- SCHWERTNER, G. e ALVES-GOMES, J. A. Peixes Elétricos da Amazônia (Gymnotiformes: Apteronotidae) como Potencial Bioindicadores de Qualidade de Água. II Simpósio Brasileiro de Engenharia Ambiental. Itajaí, SC. 2003.
- SCHWERTNER, G.; SCHWERTNER, A. B. S.; BUCKER, A.; ALVES-GOMES, J. ^a Investigação do Potencial de Contaminação Aguda por compostos BTX com Peixes Elétricos da Amazônia (*Apteronotus hasemani* – Gymnotiformes). III Simpósio Brasileiro de Engenharia Ambiental. Brasília, DF. 2004.
- STODDARD, P. K. ; ZAKON, H. H.; Markham, M. R.; McAnelly, L. Regulation and modulation of electric waveforms in gymnotiform electric fish. *Journal of Comparative Physiology A*. (2006) 192: 613–624.
- STODDARD, P. K. e MARKHAM, M. R. Signal Cloaking by Electric Fish. *BioScience*. vol. 58 No. 5. 2008.
- THOMAS, M. Integrating Physical, Chemical and Biological Monitoring. *Security of Public Water Supplies*, 107 – 114. 2000.
- THOMAS, M.; CHRÉTIEN, A.; FLORION, A.; TERVER, D. Real-time detection of potassium cyanide pollution in surface waters using electric organ discharges wave emitted by the tropical fish, *Apteronotus albifrons*. *Environmental Technology*, 17:561-574. 1996a.
- THOMAS, M.; FLORION, A.; CHRÉTIEN, A.; TERVER, D. Real-time biomonitoring of water contamination by cyanide based on analysis of the continuous electric signal emitted by a tropical fish: *Apteronotus albifrons*. *Water Research*, 30 (12): 3083-3091. 1996b.
- THOMAS, M.; FLORION, A.; CHRÉTIEN, D. The effect of pH and conductivity on the electric behaviour of *Apteronotus albifrons* (Family Apteronotidae) in a pollution monitoring system. *Environmental Technology*, 18: 1069 – 1083. 1997.
- THOMAS, M.; FLORION, A.; CHRÉTIEN, D. A new warning biomonitor using a weakly electric fish, *Apteronotus albifrons* (Gymnotiformes), and the effect of temperature on the bioelectric responses. *Environmental Monitoring and Assessment*, 51: 605 – 620. 1998.

- TIBURTIUS, E. R. L.; PERALTA-ZAMORA, P.; LEAL, E. S. Contamination of waters by BTXs and processes used in the remediation of contaminated sites. *Química Nova*, São Paulo, v. 27 n. 3, p. 441–446. 2004.
- TRIQUES, M. L. Filogenia dos gêneros de Gymnotiformes (Actinopterygii, Ostariophysi), com base em caracteres esqueléticos. *Comunicações do Museu de Ciências da PUCRS, série de zoologia*, 6: 85-130. 1993.
- TURNER, C. R.; DERYLO, M.; DE SANTANA C. D.; ALVES-GOMES J. A.; SMITH, G. T. Phylogenetic comparative analysis of electric communication signals in ghost knifefishes (Gymnotiformes: Apterontidae). *The Journal of Experimental Biology* 210, 4104-4122. 2007.
- VAL, A. L. e ALMEIDA-VAL, V. M. F. Fishes of the Amazon and their environment. *Zoophysiology*, Springer, vol. 32. New York. p. 224. 1995.
- VAL, A. L. e ALMEIDA-VAL, V. M. F. Effects of crude oil on respiratory aspects of some fish species of the Amazon. In: Val, A. L. e Almeida-Val, V. M. F. (Eds). **Biology of Tropical Fishes**. Instituto Nacional de Pesquisas da Amazônia (INPA), Manaus, AM. p. 277-291. 1999.
- VAL, A. L. Surviving low oxygen levels: Lessons from fishes of the Amazon. In: Val, A.L., Almeida-Val, V.M.F., e Randall, D.J. (eds.), **Physiology and Biochemistry of the Fishes of the Amazon**. Editora do INPA, Manaus, p. 59-74. 1996.
- VALENTE, J. P. S.; PADILHA, P. M.; SILVA, A. M. M. Oxigênio dissolvido (OD), demanda bioquímica de oxigênio (DBO) e demanda química de oxigênio (DQO) como parâmetros de poluição no ribeirão Lavapés/Botucatu – SP. *Eclética Química*. vol. 22. São Paulo, 1997.
- VOGL, T.P. MANGIS, J.K., ZIGLER, A.K., ZINK, W.I. ALKON, D.L. Accelerating the convergence of the backpropagation method. *Biological Cybernetics*, vol. 59, p. 256-264. 1988.
- WALKER, I. The pattern of distribution of two sibling species *Euryrhynchus amazoniensis* and *E. burchelli* (Decapoda, Palaemonidae) in the Central Amazonian blackwater stream Taruma-Mirim, and the problem of coexistence. *Amazoniana*, v. 16, p. 565-578, 2001.
- WERBOS, P. J. Backpropagation: basics and new developments. In: **The Handbook of Brain Theory and Neural Networks**. Arbib, M.A. (ed.). MIT, 2005.
- WINDROW, B. e HOFF, M. E. Adaptive switching circuits, In : IRE WESCON Convention Record, New York: IRE, part. 4, p. 96-104. 1960.

ZAKON, H. H. e UNGUEZ, G. A. Development and regeneration of the electric organ. *The Journal of Experimental Biology*, 202: 1427–1434. 1999.

ZUPANC, M. M.; ENGLER, G.; MIDSON, A.; OXBERRY, H.; HURST, L. A.; SYMON, M. R.; ZUPANC, G. K. H. Light–dark-controlled changes in modulations of the electric organ discharge in the teleost *Apteronotus leptorhynchus*. *Animal Behaviour*, 62: 1119-1128. 2001.

ANEXOS

ANEXO I – ARQUIVOS *m*

Cálculo da taxa de repetição e do coeficiente de variação:

```

function [hz st cv rm] = hzcvm(s)
%
% compilado de Cris Braun CBB 15sept07 / Jose Antonio Alves-Gomes JAG 18nov09
%
sr=100000;
ind=findpeaks(s);
num_intervals=length(ind)-1;
for i=1:num_intervals;
    intervals(i)=ind(i+1)-ind(i);
    intervals_s(i)=(intervals(i)/(sr));
end;
st=(1/std(intervals_s));
hz=(1/mean(intervals_s));
cv=(std(intervals)/(mean(intervals)));
rm= sqrt(mean(s.^2));
%rm= norm(s)/sqrt(length(s));
%rm= sqrt(sum(s.*conj(s))/size(s,1));
%rm= sqrt(sum((s.^2),1)/size((s),1));
return
%-----

function ind = findpeaks(varargin)
%
% FINDPEAKS Find peaks in the vector Y
% IND = FINDPEAKS(Y,THRES,WIN) finds the indices IND which are local maxima in the vetor Y.
% Inputs:
% Y: data (vector)
% THRES: threshold of the PEAK
% WIN: minimal distance between two peaks (takes the greatest in the case they are too close)
% Outputs:
% IND: indices of the peaks
% Marcos Duarte mduarte@usp.br 11oct1998
%
% Obs. I: alternativa para findpeaks.m do MatLab© (para o GNUOctave)GSF
%
% Obs. II: se utilizar findpeaks.m do MatLab© alterar a seguinte linha:
%
% Compare current data point with all neighbors
% if(all((Data(j) > temp+Th) && (Indx(j) ~1)&& (Indx(j)~=M)))
%
% por:
% Compare current data point with all neighbors
% if(all((Data(j) >= temp+Th) && (Indx(j) ~1)&& (Indx(j)~=M)))
% the >= sign allows to find flat peaks! Segundo JAG
%
%
if nargin, y = varargin{1}; else, return, end
if length(y) <= 2
    [y,ind]=max(y);
    return
end
if nargin == 1
    thres = min(y);
    win = 0;
    min_dist = 0;
elseif nargin == 2
    thres = varargin{2};
    win = 0;
    min_dist = 0;
elseif nargin == 3
    thres = varargin{2};
    win = varargin{3};
    min_dist = 0;
else
    thres = varargin{2};
    win = varargin{3};
    min_dist = varargin{4};
end
if isempty(thres), thres = min(y); end
if isempty(win), win = 1; end

```

```

if isempty(min_dist), min_dist = 0; end
if size(y,2)==1, y=y'; end
% find peaks:
dy = diff(y);
ind = find( ([dy 0]<0)&([0 dy]>=0) );
if ~isempty(ind) & ind(1) == 1, ind(1) = []; end
% selection by the threshold:
ind2 = find((y(ind)-thres)>=0);
ind = ind(ind2);
if ~win
    % elimination of redundant data (data closer than win)
    while ~isempty(find(diff(ind)<win))
        indw=find(diff(ind)<win);
        [first,ifirst]=max(y(ind(indw)));
        sec=y(ind(indw(ifirst)+1));
        [min1,tmp]=min([first sec]);
        ind(indw(ifirst)+tmp-1)=[];
    end
    if 0 %Do this in case your signal is stationary (constant distance between peaks)
        win = 0.5*median(diff(ind));
        % certifies if it is a local maximum:
        ind2 = [];
        win2 = floor(win);
        for i=1:length(ind)
            if ind(i) <= win2, a = 1; else a = ind(i) - win2; end
            if ind(i) >= length(y)-win2, b = length(y); else b = ind(i) + win2; end
            if y(ind(i))+eps >= max(y(a:b))
                ind2 = [ind2 i];
            end
        end
        ind = ind(ind2);
        % % REALLY certifies if it is a local maximum:
        win = 0.5*median(diff(ind));
        ind2 = [];
        win2 = floor(win);
        for i=1:length(ind)
            if ind(i) <= win2, a = 1; else a = ind(i) - win2; end
            if ind(i) >= length(y)-win2, b = length(y); else b = ind(i) + win2; end
            if y(ind(i))+eps >= max(y(a:b))
                ind2 = [ind2 i];
            end
        end
        ind = ind(ind2);
    end
end
end
%select the peaks which are separated by at least a minimum distance from
%the peak to the minimum between 2 successive peaks:
if min_dist
    for i=1:length(ind)-1
        [m,imin(i)] = min(y(ind(i):ind(i+1)));
        imin(i) = imin(i)+ind(i)-1;
    end
    indpm = sort([ind imin]);
    while ~isempty(find(abs(diff(y(indpm)))<min_dist))
        indpm2 = find(abs(diff(y(indpm)))<min_dist);
        indpm2(find(rem(indpm2,2)==0)) = indpm2(find(rem(indpm2,2)==0))+1;
        indpm2(find(diff(indpm2)==0)) = [];
        [tmp,ind] = min(y(indpm(indpm2)));
        ind = find(indpm == indpm(indpm2(ind)));
        if ind == 1
            ind = [ind 2];
        elseif ind == length(indpm)
            ind = [ind-1 ind];
        else
            if y(indpm(ind-1)) < y(indpm(ind+1))
                ind = [ind ind+1];
            else
                ind = [ind-1 ind];
            end
        end
        indpm(ind) = [];
    end
    ind = indpm(1:2:end);
end
%-----
%
```

ANEXO II – ARQUIVOS *m*

Rotina RN treinamento retropropagativo:

```
function rn_does(arq,np,A,nh,prc,cic,mom)
%
% Funcao rn_does.m
% Normaliza, prepara e salva dados da rede neural para DOEs de Gymnotiformes.
%
% Chamada: rn_does(arq,np,A,nh,prc,cic,mom) ;
%
% Entradas ( ):
% arq = nome do arquivo e extensao (ex. does.mat) que contenham os vetores p, v e t.
% np = numero de amostras.
% A = alvo (ex. A=[0 0;0 1;1 0;1 1])
% nh = numero de neuronios na camada interna.(ex. nh=64)
% prc = aproximacao aceitavel para o maior erro absoluto em um ciclo. (ex. prc=.0000001)
% cic = numero maximo de ciclos do procedimento iterativo. (ex. cic=20000)
% mom = taxa para o termo de inercia, que estabiliza o processo.(ex. mom=.95)
%
% Autor: Gilberto Schwertner Filho(gilberto.schwertner@gmail.com) GSF
% ultima atualizacao: 30/11/2009
unisig=inline('1./(1+exp(-n))');dunisig=inline('max(a.*(1-a),0.01)');
esclin=inline('(v-b*u)./(a*u)','v','a','b','u'); reclin=inline('(a*u).*s+b*u','s','a','b','u');
exern=inline('ativa(w*p+b *u)','p','ativa','w','b','u');
load(arq)
Ah=unisig; Dh=unisig; As=Ah; Ds=Dh; ZP=[];ZV=[];ZT=[];
for i=1:np
    x1=p(:,i); x1=x1';
    ax1=max(x1,[],2)-min(x1,[],2); bx1=min(x1,[],2); ux1=ones(1,size(x1,2));
    zx1=esclin(x1,ax1,bx1,ux1);
    x2=v(:,i); x2=x2';
    ax2=max(x2,[],2)-min(x2,[],2); bx2=min(x2,[],2); ux2=ones(1,size(x2,2));
    zx2=esclin(x2,ax2,bx2,ux2);
    x3=t(:,i); x3=x3';
    ax3=max(x3,[],2)-min(x3,[],2); bx3=min(x3,[],2); ux3=ones(1,size(x3,2));
    zx3=esclin(x3,ax3,bx3,ux3);
    ZP=[ZP;zx1]; ZV=[ZV;zx2]; ZT=[ZT;zx3];
end
A=A';
u=ones(1,size(A,2));p=ZP;v=ZV;t=ZT;
loop=1
while loop <= 100
    tic
    [wh,bh,ws,bs,J,Eq,Ev,Tx,De]=retrovcfn(p',A,v',A,Ah,Dh,As,Ds,nh,cic,prc,mom);
    toc
    yh=exern(p',Ah,wh,bh,u);ys=exern(yh,As,ws,bs,u);yp=round(ys);
    yrp=reclin(ys,ax1,bx1,1);ep=A-yrp;EQp=(sum(ep.^2)).^.5;EMp=max(max(ep));
    yh=exern(v',Ah,wh,bh,u);ys=exern(yh,As,ws,bs,u);yv=round(ys);
    yrv=reclin(ys,ax2,bx2,1);ev=A-yrv;EQv=(sum(ev.^2)).^.5;EMv=max(max(ev));
    yh=exern(t',Ah,wh,bh,u);ys=exern(yh,As,ws,bs,u);yt=round(ys);
    yrt=reclin(ys,ax3,bx3,1);et=A-yrt;EQt=(sum(et.^2)).^.5;EMt=max(max(et));
    arq=[num2str(loop) '_' arq(1:end-4) '.mat'];
    save(arq,'wh','ws','bh','bs','ep','ev','et','J','Eq','Ev','Tx','De','EQp','EQv','EQt','EMp','EMv','EM
t','yrv','yrt','yp','yv','yt');
    disp(['Numero de ciclos = ' int2str(size(De,2))])
    disp(['J = ' num2str(J)])
    loop=loop+1
end
%-----
%
function [wh,bh,ws,bs,J,Eq,Ev,Tx,De]=retrovcfn(p,t,pc,tc,Ah,Dh,As,Ds,nh,cic,prc,mom)
%
% Funcao retrovcfn.m
% Treinamento de redes de duas camadas
% Regra Delta nao Linear, com inercia e com validacao cruzada.
%
% Chamada: [wh,bh,ws,bs,Eq,Tx,De]=retrovcfn(p,t,pc,tc,Ah,Dh,As,Ds,nh,cic,prc,mom);
%
% Entradas ( ):
% p e pc = entradas, cada linha um atributo, cada coluna uma amostra.
% t e tc = saidas (alvo), cada linha um atributo, cada coluna uma amostra.
% Ah, Dh, As, Ds = "inlines" das ativacoes e respectivas derivadas, camadas interna (h) e externa (s).
% nh = numero de neuronios na camada interna.
```

```

% prc = aproximacao aceitavel para o maior erro absoluto em um ciclo.
% cic = numero maximo de ciclos do procedimento iterativo.
% mom = taxa para o termo de inercia, que estabiliza o processo.
%
% Saidas [ ]:
% wh, bh, ws e bs = pesos sinapticos e tendencias, das camadas interna (h) e externa (s).
% Eq, Tx e Dx = vetores com raizes dos erros quadraticos medios, taxas de aprendizado e
% medias das derivadas das funcoes de ativacao.
% J = numero do ciclo da melhor performance.
%
% Desenvolvido em HIP92/09 - L09
% Curso Redes Neurais Aplicadas a Area Hidrica e Ambiental/Pos-Grad. IPH-UFRGS - Prof.Olavo Pedrollo
% Autor: Gilberto Schwertner Filho (gilberto.schwertner@gmail.com) GSF
% ultima atualizacao: 26/11/2009
%
if nargin < 2, error('Erro nos argumentos de entrada. '), end
[atrib,amost_p]=size(p);
[dimen,amost_t]=size(t);
u=[ones(1,amost_t)];
uc=ones(1,size(tc,2));
ns=dimen;
tx=.1;
[wh,bh]=iniciaisfn(nh,p);
ws=rand(ns,(nh+1)).*(2/(nh+1))-ones(ns,(nh+1))./(nh+1);
bs=ws(:,end);ws(:,end)=[];
i=1;
h=Ah(wh*p+bh*u);
a=As(ws*h+bs*u);
e=t-a;
Tx=zeros(1,cic);
Eq=zeros(1,cic);
De=zeros(1,cic);
Ev=zeros(1,cic);
Eq(i)=sqrt(mean(mean(e.^2)));
Tx(i)=tx;
ec=tc-As(ws*Ah(wh*pc+bh*uc)+bs*uc);
Ev=sqrt(mean(mean(ec.^2)));
dwh=zeros(size(wh));
dbh=zeros(size(bh));
dws=zeros(size(ws));
dbs=zeros(size(bs));
while max(max(abs(e))) >= prc
    i=i+1;
    if i >= cic
        break
    end
    [Wh,Bh,Ws,Bs,D]=atualizafn(wh,bh,ws,bs,p,t,h,a,e,Dh,Ds,tx,u);
    De(i)=D;
    Wh=Wh+mom.*dwh;
    Bh=Bh+mom.*dbh;
    Ws=Ws+mom.*dws;
    Bs=Bs+mom.*dbs;
    H=Ah(Wh*p+Bh*u);
    A=As(Ws*H+Bs*u);
    E=t-A;
    Eq(i)=sqrt(mean(mean(E.^2)));
    Tx(i)=tx;
    if Eq(i)<=Eq(i-1)
        dwh=Wh-wh;
        dbh=Bh-bh;
        dws=Ws-ws;
        dbs=Bs-bs;
        [h,a,e,wh,bh,ws,bs]=deal(H,A,E,Wh,Bh,Ws,Bs);
        tx=tx*1.1;
    else
        tx=max(tx*0.5,0.01);
    end
    if max(abs(e))' <=prc,break,end
    ec=tc-As(Ws*Ah(Wh*pc+Bh*uc)+Bs*uc);
    Ev(i)=sqrt(mean(mean(ec.^2)));
    if Ev(i) < Ev(i-1)
        [Wx,Bx,Wy,By,J]=deal(Wh,Bh,Ws,Bs,i);
    end
end
[wh,bh,ws,bs]=deal(Wx,Bx,Wy,By);
nneu=(ns+nh)*amost_t;
De(1)=De(2);
Eq=nonzeros(Eq)';Tx=nonzeros(Tx)';De=nonzeros(De)';Ev=nonzeros(Ev)';
De=De./nneu;

```

```

-----
%
function [w,b]=iniciaisfn(n_neu,p)
%
% Chamada: [w,b]=iniciaisfn(n_neu,p)
% n_neu: numero de neuronios na camada
% p: serie amostral utilizada para o treinamento
%
% Autor: Olavo Pedrollo
% ultima atualizacao : 22/01/2008, as 17:00 horas
%
if size(p,2)>10,p=p(:,1:10);,end
[n_tributos,n_amostras]=size(p);
P=[p;ones(1,n_amostras)];
N=rand(n_neu,n_amostras).*2-1;
Nm=min(min(N));Nx=max(max(N));
N=2*(N-Nm)/(Nx-Nm)-1;
W=N/P;b=W(:,end);W(:,end)=[];w=W;
-----
%
function [Wh,Bh,Ws,Bs,De]=atualizafn(wh,bh,ws,bs,p,t,h,a,e,Dh,Ds,taxa,u)
%
% Funcao atualizafn.m
% Atualização dos pesos e tendencias (wh,bh,ws,bs) para rotina retrovcfn.m.
%
% Chamada: [Wh,Bh,Ws,Bs,De]=atualizafn(wh,bh,ws,bs,p,t,h,a,e,Dh,Ds,taxa,u)
% Desenvolvido em HIP92/09 - L09
% Curso Redes Neurais Aplicadas a Area Hidrica e Ambiental/Pos-Grad. IPH-UFRGS - Prof.Olavo Pedrollo
% Autor: Gilberto Schwertner Filho (gilberto.schwertner@gmail.com)
% ultima atualizacao: 26/11/2009
%
derivada_s=Ds(a); derivada_h=Dh(h);
delta_s=derivada_s.*e; delta_h=derivada_h.*(ws*delta_s);
Ws=ws+taxa*delta_s*h'; Bs=bs+taxa*delta_s*u';
Wh=wh+taxa*delta_h*p'; Bh=bh+taxa*delta_h*u';
De=sum(sum(derivada_s))+sum(sum(derivada_h));
-----
%

```

Teste:

```

function avalia_rn(arq,A)
%
% Funcao avalia_rn.m teste de redes neurais artificiais retropropagativas.
% Chamada: avalia_rn(arq,A);
% Entradas ( ):
% arq: arquivos resultantes do treinamento de redes neurais artificiais.
% A: vetor saida (ex.: A=[0 1])
% Autor: Gilberto Schwertner Filho (gilberto.schwertner@gmail.com) GSF
% ultima atualizacao: 12/12/2009
%
load(arq)
if A==yp,A==yv,A==yt
datafile=[arq(1:end-4) '_best.mat'];
save(datafile)
figure(1),semilogy(Eq,'b'),title('Raiz Quadratica dos Erros')
hold on,semilogy(Ev,'r'),xlabel('Ciclos'),legend('Treinamento','Validacao')
s=[arq(1:end-4) '_RaizQuadraticaErros.jpg'];saveas(gcf,s);
figure(2),subplot(2,1,1),plot(Tx),title('Taxa de Aprendizado'),xlabel('Ciclos')
subplot(2,1,2),plot(De),title('Soma das Derivadas'),xlabel('Ciclos')
s=[arq(1:end-4) '_ Taxa&SomaDerivadas.jpg'];saveas(gcf,s);
close all
else
disp(['Erro na RN ' arq(1:end-4)])
end
-----
%

```