



**UNIVERSIDADE
FEDERAL DO CEARÁ**

**CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

Leonardo da Silva Gomes

**REDES NEURAIAS ARTIFICIAIS APLICADAS À INFERÊNCIA DOS SINAIS DE
CONTROLE DE DOSAGEM DE COAGULANTES EM UMA ESTAÇÃO DE
TRATAMENTO DE ÁGUA POR FILTRAÇÃO RÁPIDA.**

Fortaleza

Março 2012

Leonardo da Silva Gomes

**REDES NEURAIS ARTIFICIAIS APLICADAS À INFERÊNCIA DOS SINAIS DE
CONTROLE DE DOSAGEM DE COAGULANTES EM UMA ESTAÇÃO DE
TRATAMENTO DE ÁGUA POR FILTRAÇÃO RÁPIDA.**

Dissertação submetida à Universidade Federal do Ceará
como parte dos requisitos para a obtenção do grau de Mestre
em Engenharia Elétrica.

Orientador:

Prof. Ricardo Silva Thé Pontes, Dr.

Co-orientador:

Prof. Otacílio da Mota Almeida, Dr.

Fortaleza

Março 2012

Folha de Aprovação

DEDICATÓRIA

À minha amada esposa Sandra, companheira fiel em cada momento, e que me apoiou incondicionalmente neste projeto. Às minhas filhas Gabrielle e Ester, pela compreensão quanto aos muitos momentos nos quais tive que privá-las da atenção merecida.

AGRADECIMENTOS

Ao meu Deus e Pai do meu Senhor e Salvador Jesus, o Único detentor de toda a glória, sabedoria, honra, poder e força eternos [*Apocalipse 7.12*], O qual me fez comparecer na presença dos príncipes [*Salmos 113.7-8*] como hoje se vê, e me adestrou para a batalha, capacitando-me ao longo deste trabalho [*Salmos 144.1*]. A Ele, toda a glória por este trabalho!

Aos meus superiores e colegas de trabalho da CAGECE, pelo apoio demonstrados.

Ao meu orientador neste projeto, o Prof. Dr. Ricardo Silva Thé Pontes, ao Grupo de Pesquisa em Saneamento Ambiental do Departamento de Engenharia Elétrica da UFC e ao Grupo de Pesquisa em Automação e Robótica, pela orientação e apoio dados durante o desenvolvimento de todo o trabalho.

Gomes, L. S., “Redes Neurais Artificiais aplicadas à inferência dos sinais de controle de dosagem de coagulantes em uma estação de tratamento de água por filtração rápida”, Universidade Federal do Ceará – UFC, 2012.

Considerando a importância do controle da coagulação química para o processo de tratamento de água por filtração rápida, esta dissertação propõe a aplicação de redes neurais artificiais para inferência dos sinais de controle de dosagem de coagulantes principal e auxiliar, no processo de coagulação química em uma estação de tratamento de água por filtração rápida. Para tanto, foi feita uma análise comparativa da aplicação de modelos baseados em redes neurais do tipo: alimentada adiante focada atrasada no tempo (FTLFN); alimentada adiante atrasada no tempo distribuída (DTLFN); recorrente de Elman (ERN) e auto-regressiva não-linear com entradas exógenas (NARX). Da análise comparativa, o modelo baseado em redes NARX apresentou melhores resultados, evidenciando o potencial do modelo para uso em casos reais, o que contribuirá para a viabilização de projetos desta natureza em estações de tratamento de água de pequeno porte.

Palavras-chave: Redes Neurais Supervisionadas Dinâmicas, Seleção de Variáveis e Atrasos, Redes Alimentadas Adiante Focada Atrasada no Tempo, Redes Alimentadas Adiante Atrasadas no Tempo Distribuídas, Rede Recorrente de Elman, Rede Auto-regressiva Não-linear com Entradas Exógenas, Coagulação Química no Processo de Tratamento de Água.

Gomes, L. S., “Artificial Neural Networks applied to the inference of dosage control signals of coagulants in a water treatment plant by direct filtration”, Universidade Federal do Ceará – UFC, 2012.

Considering the importance of the chemical coagulation control for the water treatment by direct filtration, this work proposes the application of artificial neural networks for inference of dosage control signals of principal and auxiliary coagulant, in the chemical coagulation process in a water treatment plant by direct filtration. To that end, was made a comparative analysis of the application of models based on neural networks, such as: Focused Time Lagged Feedforward Network (FTLFN); Distributed Time Lagged Feedforward Network (DTLFN); Elman Recurrent Network (ERN) and Non-linear Autoregressive with exogenous inputs (NARX). From the comparative analysis, the model based on NARX networks showed better results, demonstrating the potential of the model for use in real cases, which will contribute to the viability of projects of this nature in small size water treatment plants.

Key words: Dynamic Supervised Neural Networks, Variable Selection, Focused Time Lagged Feedforward Network, Distributed Time Lagged Feedforward Network, Elman Recurrent Network, Non-linear Autoregressive with exogenous inputs, Chemical Coagulation, Water Treatment.

SUMÁRIO

1. INTRODUÇÃO	1
1.1. CONTEXTUALIZAÇÃO	1
1.2. TRATAMENTO DE ÁGUA PARA CONSUMO HUMANO	2
1.3. BREVE HISTÓRICO DO ABASTECIMENTO DE ÁGUA NO BRASIL.....	3
1.4. BREVE HISTÓRICO DO ABASTECIMENTO DE ÁGUA NO CEARÁ	4
1.5. AUTOMAÇÃO	6
1.5.1. <i>UMA VISÃO GERAL</i>	6
1.5.2. <i>AUTOMAÇÃO DE ESTAÇÕES DE TRATAMENTO DE ÁGUA</i>	9
1.6. OBJETIVO	11
1.7. TRABALHOS EXISTENTES SOBRE APLICAÇÃO DE RNAs NO PROCESSO DE COAGULAÇÃO QUÍMICA	12
1.8. PRODUÇÃO CIENTÍFICA	13
1.9. DESENVOLVIMENTO DA PESQUISA E ORGANIZAÇÃO DO TRABALHO	14
2. ESTAÇÕES DE TRATAMENTO DE ÁGUA.....	15
2.1. QUALIDADE DAS ÁGUAS DESTINADAS AO CONSUMO HUMANO	15
2.1.1. <i>O PADRÃO BRASILEIRO DE POTABILIDADE</i>	16
2.1.2. <i>CARACTERÍSTICAS FÍSICAS DA ÁGUA</i>	17
TURBIDEZ.....	17
COR	18
TEMPERATURA.....	19
CONDUTIVIDADE	19
2.1.3. <i>CARACTERÍSTICAS QUÍMICAS DA ÁGUA</i>	19
ACIDEZ E ALCALINIDADE	21
2.1.4. <i>CARACTERÍSTICAS BIOLÓGICAS DA ÁGUA</i>	21
2.2. TECNOLOGIAS DE TRATAMENTO DE ÁGUA	22
2.2.1. <i>TECNOLOGIAS BASEADAS EM FILTRAÇÃO LENTA</i>	22
2.2.2. <i>TECNOLOGIAS BASEADAS EM FILTRAÇÃO RÁPIDA</i>	23
FILTRAÇÃO RÁPIDA ASCENDENTE.....	24
FILTRAÇÃO RÁPIDA DESCENDENTE	27
DUPLA FILTRAÇÃO.....	29
TRATAMENTO COMPLETO	30
2.3. O PROCESSO DE COAGULAÇÃO QUÍMICA	31
2.4. A ETA GAVIÃO	32
2.5. O ATUAL SISTEMA DE DOSAGEM DE COAGULANTES	35
2.5.1. <i>DETERMINAÇÃO DA VAZÃO DE DOSAGEM</i>	35
2.5.2. <i>BOMBAS DOSADORAS E O ACIONAMENTO POR ROTAÇÃO VARIÁVEL</i>	36
2.5.3. <i>AVALIAÇÃO DO CONTROLE MANUAL DE COAGULAÇÃO QUÍMICA</i>	37
2.6. ARQUITETURA CONVENCIONAL PARA CONTROLE AUTOMÁTICO DE DOSAGEM DE COAGULANTES	39
2.7. PROPOSTA DE UM MODELO NEURAL PARA INFERÊNCIA DOS SINAIS DE CONTROLE DE DOSAGEM DE COAGULANTES	40
2.7.1. <i>O MODELO</i>	41
3. REDES NEURAS ARTIFICIAIS SUPERVISIONADAS DINÂMICAS.....	43
3.1. REDES NEURAS ARTIFICIAIS	43
3.2. REDES NEURAS ARTIFICIAIS ESTÁTICAS	44
3.2.1. <i>PERCEPTRON DE MÚLTIPLAS CAMADAS</i>	46
3.2.2. <i>FUNÇÕES DE ATIVAÇÃO</i>	47
FUNÇÃO DE LIMIAR	47
FUNÇÃO LINEAR POR PARTES.....	48
FUNÇÃO SIGMÓIDE	48
3.3. REDES NEURAS DINÂMICAS	48
3.3.1. <i>REDES NEURAS DINÂMICAS NÃO RECORRENTES</i>	49
REDE ALIMENTADA ADIANTE COM ATRASO DE TEMPO FOCADO	49
REDE ALIMENTADA ADIANTE COM ATRASADO DE TEMPO DISTRIBUÍDO	51
3.3.2. <i>REDES NEURAS DINÂMICAS RECORRENTES</i>	52
REDES RECORRENTES DE ELMAN.....	53

REDE AUTO-REGRESSIVA NÃO-LINEAR COM ENTRADAS EXÓGENAS	54
4. IMPLEMENTAÇÃO DOS MODELOS A SEREM AVALIADOS	56
4.1. IMPLEMENTAÇÃO DOS MODELOS.....	56
4.1.1. SELEÇÃO DAS VARIÁVEIS DE ENTRADA	56
4.1.2. AJUSTE DAS VARIÁVEIS DE ENTRADA SELECIONADAS	56
4.1.3. SELEÇÃO DAS ESTRUTURAS DOS MODELOS	60
ESTRUTURA BÁSICA	60
QUANTIDADE DE NEURÔNIOS DA CAMADA ESCONDIDA.....	61
ALGORITMO DE TREINAMENTO	62
DETERMINAÇÃO DAS ENTRADAS, ATRASOS E NEURÔNIOS OCULTOS	63
4.2. MELHORES MODELOS SELECIONADOS PARA TESTE	70
4.2.1. INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC.....	70
4.2.2. INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL.....	71
5. RESULTADOS	72
5.1. RESULTADOS	73
5.1.1. RNA <i>FTLFN</i>	73
INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC	73
INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL	74
5.1.2. RNA <i>DTLFN</i>	75
INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC	75
INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL	76
5.1.3. RNA <i>ERN</i>	77
INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC	77
INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL	78
5.1.4. RNA <i>NARX</i>	79
INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC	79
INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL	80
5.2. GRÁFICOS DE DESEMPENHO DAS RNAs.....	81
5.2.1. RNA <i>FTLFN</i>	81
5.2.2. RNA <i>DTLFN</i>	82
5.2.3. RNA <i>ERN</i>	83
5.2.4. RNA <i>NARX</i>	84
5.3. AVALIAÇÃO DOS RESULTADOS	85
5.3.1. DESEMPENHO DAS RNAs NÃO RECORRENTES (<i>FTLFN</i> E <i>DTLFN</i>)	85
5.3.2. DESEMPENHO DAS RNAs RECORRENTES (<i>ERN</i> E <i>NARX</i>)	86
5.4. VALIDAÇÃO DO MODELO PARA INFERÊNCIA DOS SINAIS DE CONTROLE DE DOSAGEM DE PAC E POL	88
6. CONCLUSÕES E PERSPECTIVAS	90
REFERÊNCIAS.....	92
ANEXO A – PLANTAS GERAL E DE LAY-OUT DA ETA GAVIÃO.....	98

LISTA DE FIGURAS

Figura 1.1 – A Automação Industrial e a fusão com a Areal de Negócios.....	7
Figura 1.2 – Esquema básico de um Controlador Lógico Programável.....	8
Figura 1.3 – Diagrama básico do controle automático de um processo.....	8
Figura 1.4 – Automação de uma planta industrial – principais níveis.....	9
Figura 2.1 – Sequência de Processos das Tecnologias de Tratamento baseadas em Filtração Rápida Ascendente.	24
Figura 2.2 – Aspecto Construtivo Básico de um Filtro de Fluxo Ascendente.....	25
Figura 2.3 – Esquema básico de uma ETA de Filtração Rápida Ascendente.....	26
Figura 2.4 – Sequência de Processos das Tecnologias de Tratamento baseadas em Filtração Rápida Descendente.	28
Figura 2.5 – Aspectos Construtivos Básicos de um Filtro Descendente com Câmara de Flocculação Mecânica à Montante.....	28
Figura 2.6 – Esquema básico de uma ETA de Filtração Rápida Descendente com Floculador Chicana Vertical.	29
Figura 2.7 – Sequência de Processos da Tecnologia de Tratamento Completo.....	30
Figura 2.8 – Esquema básico de uma ETA de Tratamento Completo com Flotador (sem Pré-tratamento).....	31
Figura 2.9 – (a) Vista Geral da ETA Gavião; (b) Barragem; (c) Torre de Captação Gravitacional; (d) Floculadores; (e) Decantadores; (f) Decantador em Manutenção; (g) Mesa de Comando dos Filtros e Vista dos Filtros ao Fundo; (h) Vista Interna da Sala de Comando dos Filtros.....	33
Figura 2.10 – (a) Filtro em Operação; (b) Filtro em Processo de Lavagem; (c) Elevatória de Lavagem de Filtros; (d) Bombas da Elevatória de Lavagem de Filtros; (e) Vista Superior do Reservatório Apoiado de Água Tratada; (f) Elevatória de Água Tratada Gavião Novo; (g) Conjunto Motor Bomba do Gavião Novo; (h) Subestação.....	34
Figura 2.11 – Curvas características RPM x Vazão: (a) bomba dosadora de PAC, modelo 2NE20A; (b) bomba dosadora de Polímero Catiônico, modelo NMP11BY02S12B.....	36
Figura 2.12 – (a) Tanques de Armazenagem de PAC; (b) Bombas Dosadoras de Polímero Catiônico (esquerda) e de PAC (direita) e Painel Inversor ao meio; (c) Bomba Dosadora de PAC; (d) Painel dos Inversores com Vista Interna dos Inversores CFW-10.....	37
Figura 2.13 – Histórico mensal no período 2007 a 2009: (a) Vazões de Dosagem de PAC e POL; (b) Turbidez de Água Tratada.....	38
Figura 2.14 – Arquitetura convencional para controle automático de dosagem de coagulantes.....	39
Figura 2.15 – Localização do Modelo Neural Proposto na Planta de Controle de Coagulação da ETA Gavião.....	40
Figura 2.16 – Aprendizado Supervisionado do modelo proposto.....	41
Figura 3.1 – Diagrama Representativo da Aprendizagem Supervisionada.....	43
Figura 3.2 – Diagrama Esquemático Básico de uma MLP com uma camada escondida e uma camada de saída.	46
Figura 3.3 – Diagrama de blocos de uma rede neural dinâmica não recorrente.....	49
Figura 3.4 – Diagrama de blocos de uma rede neural dinâmica não recorrente.....	50
Figura 3.5 – Filtro de Resposta a Impulso Finito (FIR).....	52
Figura 3.6 – Filtro Neural de Múltiplas Entradas.....	52
Figura 3.7 – Arquitetura geral de uma Rede Recorrente Elman.....	53

Figura 3.8 – Arquitetura geral de uma Rede Recorrente NARX.	55
Figura 4.1 – Marcação dos <i>outliers</i> através dos intervalos de confiança do sinal residual: (a) Turbidez de Água Bruta; (b) Turbidez de Água Coagulada; (c) pH de Água Bruta; (d) pH de Água Coagulada.	58
Figura 4.2 – Dados de Entrada Ajustados (período de registro: 2007 a 2009): (a) Turbidez de Água Bruta; (b) Turbidez de Água Coagulada; (c) pH de Água Bruta e (d) pH de Água Coagulada.	60
Figura 4.3 – Arquitetura geral do Modelo Neural Proposto para Inferência dos Sinais de Controle de Dosagem de PAC e POL.	61
Figura 4.4 – Mapeamentos: (a) Modelo FTLFN PAC; (b) FTLFN POL; (c) DTLFN PAC; (d) DTLFN POL; (e) ERN PAC; (f) ERN POL; (g) NARX PAC; (h) NARX POL.	69
Figura 5.1 – Resultados da Inferência do sinal de controle de dosagem de PAC referente a 2009 (Rede FTLFN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.	73
Figura 5.2 – Resultados da Inferência do sinal de controle de dosagem de POL referente a 2009 (Rede FTLFN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.	74
Figura 5.3 – Resultados da Inferência do sinal de controle de dosagem de PAC referente a 2009 (Rede DTLFN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.	75
Figura 5.4 – Resultados da Inferência do sinal de controle de dosagem de POL referente a 2009 (Rede DTLFN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.	76
Figura 5.5 – Resultados da Inferência do sinal de controle de dosagem de PAC referente a 2009 (Rede ERN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.	77
Figura 5.6 – Resultados da Inferência do sinal de controle de dosagem de POL referente a 2009 (Rede ERN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.	78
Figura 5.7 – Resultados da Inferência do sinal de controle de dosagem de PAC referente a 2009 (Rede NARX) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.	79
Figura 5.8 – Resultados da Inferência do sinal de controle de dosagem de POL referente a 2009 (Rede NARX) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.	80
Figura 5.9 – Avaliação do desempenho da Rede FTLFN: (a) <i>MSE</i> inferência de PAC; (b) <i>MSE</i> inferência de POL; (c) Dispersão Sinal Real x Sinal Inferido de PAC; (d) Dispersão Sinal Real x Sinal Inferido de POL; (e) Histograma dos Residuais na fase de treinamento para a inferência de PAC; (f) Histograma dos Residuais na fase de treinamento para a inferência de POL.	81
Figura 5.10 – Avaliação do desempenho da Rede DTLFN: (a) <i>MSE</i> inferência de PAC; (b) <i>MSE</i> inferência de POL; (c) Dispersão Sinal Real x Sinal Inferido de PAC; (d) Dispersão Sinal Real x Sinal Inferido de POL; (e) Histograma dos Residuais na fase de treinamento para a inferência de PAC; (f) Histograma dos Residuais na fase de treinamento para a inferência de POL.	82
Figura 5.11 – Avaliação do desempenho da Rede ERN: (a) <i>MSE</i> inferência de PAC; (b) <i>MSE</i> inferência de POL; (c) Dispersão Sinal Real x Sinal Inferido de PAC; (d) Dispersão Sinal Real x Sinal Inferido de POL; (e) Histograma dos Residuais na fase de treinamento para a inferência de PAC; (f) Histograma dos Residuais na fase de treinamento para a inferência de POL.	83
Figura 5.12 – Avaliação do desempenho da Rede NARX: (a) <i>MSE</i> inferência de PAC; (b) <i>MSE</i> inferência de POL; (c) Dispersão Sinal Real x Sinal Inferido de PAC; (d) Dispersão Sinal Real x Sinal Inferido de POL; (e) Histograma dos Residuais na fase de treinamento para a inferência de PAC; (f) Histograma dos Residuais na fase de treinamento para a inferência de POL.	84

Figura 5.13 – Arquitetura Definitiva do Modelo Neural Proposto para Inferência dos Sinais de Controle de
Dosagem de PAC e POL88

LISTA DE TABELAS

Tabela 1.1 – Principais Processos Automatizados em uma ETA.....	10
Tabela 1.2 – Custo de Implantação de um Controle Automático local de Dosagem de Coagulantes.	11
Tabela 1.3 – Custo de Implantação de um Controle Automático local de Dosagem de Coagulantes, com aplicação de Redes Neurais Artificiais.....	12
Tabela 2.1 – Classificação das águas destinadas para consumo humano.	15
Tabela 2.2 – Padrão de turbidez para água na saída do tratamento.....	18
Tabela 2.3 – Padrão de potabilidade para substâncias químicas Inorgânicas da água para consumo humano.	19
Tabela 2.4 – Padrão de potabilidade para substâncias químicas (Cianotoxinas) da água para consumo humano.	20
Tabela 2.5 – Padrão de potabilidade para substâncias químicas Orgânicas da água para consumo humano.....	20
Tabela 2.6 – Padrão de potabilidade para substâncias químicas (Agrotóxicos) da água para consumo humano...20	
Tabela 2.7 – Padrão de potabilidade para substâncias químicas (Desinfetantes e produtos secundários da desinfecção) da água para consumo humano.	21
Tabela 2.8 – Padrão biológico de potabilidade da água para consumo humano.....	22
Tabela 2.9 – Qualidade da água bruta para tratamento com filtração lenta.	23
Tabela 2.10 – Qualidade da água bruta para tratamento com filtração rápida ascendente.	26
Tabela 2.11 – Qualidade da água bruta para tratamento com filtração rápida descendente.	27
Tabela 2.12 – Qualidade da água bruta para tratamento com dupla filtração.....	29
Tabela 4.1 – Algoritmo de Ajuste Robusto - <i>RLoess</i>	59
Tabela 4.2 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de PAC.	65
Tabela 4.3 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de POL.....	66
Tabela 4.4 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de PAC.	66
Tabela 4.5 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de POL.....	67
Tabela 4.6 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de PAC.	67
Tabela 4.7 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de POL.....	67
Tabela 4.8 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de PAC.	68
Tabela 4.9 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de POL.....	68
Tabela 4.10 – Configurações das redes selecionadas na Etapa de Seleção da Estrutura dos Modelos – Inferência do Sinal de Controle de Dosagem de PAC.....	70
Tabela 4.11 – Configurações das redes selecionadas na Etapa de Seleção da Estrutura dos Modelos – Inferência do Sinal de Controle de Dosagem de POL.....	71
Tabela 5.1 – Análise dos resultados apresentados nas Figuras 5.1 a 5.4 (RNAs FTLFN e DTLFN).....	85
Tabela 5.2 – Resumo da Análise do Desempenho das RNAs não-recorrentes avaliadas.....	86
Tabela 5.3 – Análise dos resultados apresentados nas Figuras 5.5 a 5.8 (RNAs ERN e NARX).	87
Tabela 5.4 – Resumo da Análise do Desempenho da RNA ERN avaliada	87
Tabela 5.5 – Resumo da Análise do Desempenho da RNA NARX avaliada	88

LISTA DE ABREVIATURAS E SIGLAS

CAENE	Companhia de Água e Esgoto do Nordeste.
CAGECE	Companhia de Água e Esgoto do Ceará.
CECOP	Centro de Controle Operacional do Sistema de Abastecimento de Água de Fortaleza.
CECOP-DEIBA	Centro de Controle Operacional do Sistema de Abastecimento de Água da Ibiapaba.
CENEPI	Centro Nacional de Epidemiologia.
CGVAM	Coordenação Geral de Vigilância Sanitária em Saúde Ambiental.
CLP	Controlador Lógico Programável.
CONAMA	Conselho Nacional de Meio Ambiente.
DNOCS	Departamento Nacional de Obras Contra as Secas.
DNOS	Departamento Nacional de Obras de Saneamento.
DTLFN	Rede Neural Alimentada Adiante Atrasada no Tempo Distribuída.
ERN	Rede Neural de Elman.
ETA	Estação de Tratamento de Água.
FIR	Filtro Neural de Resposta ao Impulso de Duração Finita.
FTLFN	Rede Neural Alimentada Adiante Focada Atrasada no Tempo.
FUNASA	Fundação Nacional de Saúde.
IBGE	Instituto Brasileiro de Geografia e Estatística.
MLP	Perceptron de Múltiplas Camadas.
MS	Ministério da Saúde.
NARX	Rede Neural Auto-regressiva Não-linear com Entradas Exógenas.
OMS	Organização Mundial da Saúde.
ONG	Organização Não Governamental.
PAC	Hidroxiclureto de Alumínio (coagulante principal).
pHAB	pH de Água Bruta.

pHAC	pH de Água Tratada.
PLANASA	Plano Nacional de Saneamento.
POL	Polímero Catiônico (coagulante auxiliar).
RMF	Região Metropolitana de Fortaleza.
RNA	Rede Neural Artificial.
SAA	Sistema de Abastecimento de Água.
SAAGEC	Sistema Autônomo de Água e Esgoto do Ceará.
SUDENE	Superintendência do Desenvolvimento do Nordeste
SUS	Sistema Único de Saúde.
SVS	Secretaria de Vigilância em Saúde.
THM	Trihalometanos.
TrbAB	Turbidez de Água Bruta.
TrbAC	Turbidez de Água Coagulada.

LISTA DE SIMBOLOS

a	Termo de inclinação da função sigmóide.
b	Constante aplicada à função sigmóide.
b_k	Bias aplicado aos neurônios da camada escondida em uma RNA.
b_l	Bias aplicado aos neurônios da camada de saída em uma RNA.
C	Concentração da solução de coagulante a ser aplicada.
C_p	Estatística de Mallow.
D	Dosagem de coagulante a ser aplicada.
d	Sinal real ou desejado. Aplicado no treinamento de uma RNA.
\mathbf{d}	Vetor de saída desejada. Aplicado no treinamento de uma RNA.
d_x	Distancia entre a variável preditora x e seu vizinho mais próximo. Utilizado no cálculo da regressão linear local polinômio quadrático.
e	Erro (residual) entre um sinal real (desejado) e um sinal inferido. Aplicado no treinamento de uma RNA.
M	Dimensão da saída de uma RNA.
m_0	Dimensão de entrada de um Filtro FIR.
MAD	Desvio mediano absoluto do sinal residual r_i .
m_j	Peso sináptico entre o j -ésimo neurônio da camada escondida e o único neurônio de saída em uma RNA.
MSE	Erro médio quadrático.
n	Instante discreto ou época de treinamento.
N	Quantidade de exemplos de treinamento.
o	Campo local induzido no neurônio de saída em uma RNA.
p	Dimensão do vetor padrão aplicado à entrada de uma RNA.
Q	Vazão de Entrada da Estação de Tratamento de Água.
q	Quantidade de neurônios da camada escondida em uma RNA.
q_d	Vazão de referência para dosagem de coagulantes.

R^2	Coeficiente de determinação.
r_i	Residual do i -ésimo ponto avaliado. Utilizado no método de ajuste robusto <i>RLoess</i> .
s	Saída do filtro FIR.
SSR	Soma dos quadrados dos residuais para um modelo total com T variáveis de entrada.
SSR_p	Soma dos quadrados dos residuais para um modelo neural reduzido com dimensão de entrada p .
S_x	Desvio padrão da amostra x .
t	Ordem da memória de curto prazo de linha de atraso
T	Dimensão máxima de entrada de um modelo neural.
\mathbf{u}	Vetor padrão aplicado à entrada de uma RNA.
v_j	Campo local induzido no j -ésimo neurônio da camada escondida em uma RNA.
W	Ponderação utilizada no cálculo de regressão local por polinômio quadrático.
$w_{i,j}$	Peso sináptico entre a i -ésima entrada e o j -ésimo neurônio da camada escondida em uma RNA.
x	Amostra pertencente ao vetor padrão aplicado à entrada de uma RNA.
y	Sinal inferido por uma RNA.
z_j	Saída do j -ésimo neurônio da camada escondida em uma RNA.
ϖ_i	Ponderação aplicada no método de ajuste robusto <i>RLoess</i> .
β_0 e β_1	Coeficientes utilizados no cálculo de regressão linear local por polinômio quadrático.
ε	Erro percentual máximo permitido no teste de uma RNA.
$\varphi_k(\cdot)$	Função de ativação dos neurônios da camada escondida de uma RNA.
$\varphi_l(\cdot)$	Função de ativação dos neurônios da camada de saída de uma RNA.

1. INTRODUÇÃO

Neste capítulo, apresenta-se o contexto em que está inserido o tema desta dissertação, no processo de coagulação química em uma Estação de Tratamento de Água (ETA) por filtração rápida. Para tanto, é apresentada uma visão introdutória sobre tratamento de água para consumo humano, bem como das técnicas utilizadas no Brasil para automação de processos de dosagem de coagulantes em ETAs.

O objetivo desta contextualização é evidenciar os benefícios decorrentes da aplicação de Redes Neurais Artificiais (RNA) na automação dos processos de dosagem de coagulantes, em comparação com as técnicas convencionais de automação geralmente utilizadas em ETAs de filtração rápida no Brasil.

1.1. CONTEXTUALIZAÇÃO

A disponibilidade de água de qualidade para consumo humano é uma exigência cada vez mais reivindicada pela sociedade [1], além de ser uma necessidade estratégica para a manutenção da saúde pública, em vista do crescimento desordenado dos centros urbanos. Este é o grande desafio para as companhias de saneamento, que tem como missão principal fornecer água dentro dos padrões de potabilidade.

Estes fatores, aliados à disponibilidade limitada e a crescente deterioração dos mananciais de abastecimento disponíveis [2], tem impelido as companhias de abastecimento à busca de tecnologias de tratamento adequadas, bem como à realização de esforços quanto a automatização de suas plantas de tratamento de água existentes, objetivando racionalizar a exploração dos mananciais de abastecimento e o uso de insumos envolvidos no processo de tratamento de água.

De forma geral, os custos envolvidos na automatização convencional de plantas de tratamento existentes são elevados, inviabilizando a implantação de tais sistemas de controle em ETAs de pequeno porte. Este problema se agrava no caso de plantas de tratamento que abastecem áreas populacionais que, devido à baixa condição econômica, não oferecem retorno financeiro que viabilize o fornecimento de água tratada. Isto acontece no Estado do Ceará, onde num esforço de beneficiar a população com a universalização do fornecimento de água potável, várias plantas de tratamento de pequeno porte são instaladas em localidades que não oferecem o retorno econômico-financeiro necessário.

Neste contexto, objetivando propor uma solução alternativa às técnicas convencionais de automatização de plantas de tratamento, em especial técnicas de controle de dosagem de coagulantes, com vistas a contribuir com a viabilização da automação de plantas de tratamento de água, foi desenvolvido um modelo baseado em Redes Neurais Artificiais (RNAs) supervisionadas, para inferência dos sinais de controle de dosagem de coagulante Hidroxi-cloreto de Alumínio (PAC) e de coagulante auxiliar Polímero Catiônico (POL).

A planta utilizada no desenvolvimento do modelo foi a ETA Gavião, pertencente à Companhia de Água e Esgoto do Ceará (CAGECE), e responsável pelo abastecimento de água tratada da Região Metropolitana de Fortaleza.

1.2. TRATAMENTO DE ÁGUA PARA CONSUMO HUMANO

Indiscutivelmente, a água tem suma importância para a sustentação da vida [3] e desenvolvimento das sociedades no contexto global [2]. Este fato, aliado a crescente deterioração e pouca disponibilidade global de mananciais para abastecimento humano [2], torna necessário o acesso da sociedade a água potável para a promoção da saúde pública [3].

Define-se sistema de abastecimento de água para consumo humano como:

“[...] instalação composta por conjunto de obras civis, materiais e equipamentos, destinados à produção e à distribuição canalizada de água potável para populações, sob a responsabilidade do poder público, mesmo que administrada em regime de concessão ou permissão.” [4]

Tal instalação deve assegurar regularidade de abastecimento e acessibilidade às populações em suas diversas áreas de atuação, respeitando os interesses de utilização dos mananciais por parte de outros usuários [2], com mínimo impacto ambiental. Nisto, é visível a interação entre abastecimento de água e o conceito de saneamento ambiental, definido como:

“[...] o conjunto de ações socioeconômicas que têm por objetivo alcançar Salubridade Ambiental, por meio de abastecimento de água potável, coleta e disposição sanitária de resíduos sólidos, líquidos e gasosos, promoção da disciplina sanitária de uso do solo, drenagem urbana, controle de doenças transmissíveis e demais serviços e obras especializadas, com a finalidade de proteger e melhorar as condições de vida urbana e rural.” [4]

Baseado neste conceito, os sistemas de abastecimento de água objetivam a promoção da salubridade ambiental, definida como:

“[...] o estado de higidez em que vive a população urbana e rural, tanto no que se refere a sua capacidade de inibir, prevenir ou impedir a ocorrência de endemias ou epidemias veiculadas pelo meio ambiente, como no tocante ao seu potencial de promover o aperfeiçoamento de condições mesológicas favoráveis ao pleno gozo de saúde e bem-estar.” [4].

A engenharia tem papel primordial neste contexto, no que diz respeito a planejamento, projeto, implantação, operação e manutenção de sistemas de abastecimento de água [2], tendo

sido responsável por diversas melhorias nas tecnologias de abastecimento de água existentes, bem como pela criação de novas técnicas. Tais melhorias contribuíram para a redução das taxas de mortalidade por doenças infecciosas e parasitárias, que tem como principal vetor de transmissão a água, visto que transporta agentes tais como: sais dissolvidos, partículas em suspensão e microorganismos [5]. O fornecimento de água livre desses agentes é primordial para a saúde pública, por beneficiar a população de modo geral através da disponibilidade das mesmas oportunidades de higiene para todas as camadas sociais abastecidas, proporcionando redução significativa da demanda por serviços públicos de saúde e, conseqüentemente, redução de gastos públicos com serviços de assistência médica pública. Como exemplo, citamos a estatística divulgada pelo Sistema Único de Saúde – SUS (Governo Federal do Brasil), referente à percentagem de óbitos causados por doenças infecciosas e parasitárias, que registra uma queda de 6,23% em 1996 para 4,75% em 2007 [6].

1.3. BREVE HISTÓRICO DO ABASTECIMENTO DE ÁGUA NO BRASIL

O histórico do abastecimento de água no Brasil remonta a 1561, quando Estácio de Sá escavou o primeiro poço, dando início ao primeiro sistema de abastecimento de água na cidade do Rio de Janeiro, que teve as instalações de adução concluídas somente em 1673, 112 anos após. Em 1723, com o crescimento da cidade, foi necessária a construção do primeiro archeduto para adução das águas do rio Carioca até o primeiro chafariz público construído. Em 1860, a cidade do Rio de Janeiro contava com mais de 20 chafarizes públicos, distribuindo um total aproximado de 8 milhões de litros por dia. Em 1876, foi contratado o primeiro projeto para implantação do sistema de água encanada no Rio de Janeiro [7].

Ao longo do século XIX, época onde dominava a linha de pensamento do saneamento privatista, foram implantados no Brasil por empresas privadas britânicas, canadenses e francesas [8], outros sistemas de abastecimento de água: Porto Alegre – Rio Grande do Sul, em 1861; Santos – São Paulo, em 1870; Campos – Rio de Janeiro, em 1880; Campinas – São Paulo, em 1891; Bofete – São Paulo, em 1892 e Belo Horizonte – Minas Gerais, em 1897 [7]. Somente no início do século XX, com o advento do pensamento do racionalismo administrativo, tais companhias foram adquiridas pelos governos municipais e estaduais [8], que passaram a administrá-las.

As décadas de 1930 e 1940 são marcadas pela criação do Ministério da Saúde e do Departamento nacional de Obras de Saneamento (DNOS). Porém, o evento que impulsionou a implantação de sistemas de abastecimento de água no cenário nacional foi o lançamento do Plano Nacional de Saneamento (PLANASA), na década de 1970, que permitiu o alcance de

níveis de atendimento de cerca de 90% da população urbana no final da década de 1980 [5], através da aplicação de recursos na ordem de US\$ 6,4 bilhões até o final da década de 1980 [9]. O PLANASA foi extinto em 1986, dando início a uma etapa histórica de 10 anos de falta de consenso de uma nova política de saneamento. Em 2007 ocorreram dois eventos marcantes para o saneamento no Brasil: o primeiro foi o advento da Lei No 11.445/07 [10], que estabelece diretrizes gerais para prestação de serviços em saneamento básico (incluindo aspectos de responsabilidades do titular dos serviços, contratos de prestação de serviços, planejamento e regulação dos serviços); o segundo foi o lançamento do Programa de Aceleração do Crescimento, que previa até o ano de 2010, o investimento total de R\$ 40 bilhões em saneamento básico [11].

Estes dois eventos possibilitaram ao Brasil o atendimento de grande parte dos municípios por serviços de abastecimento de água. Segundo a Pesquisa Nacional de Saneamento Básico realizada pelo Instituto Brasileiro de Geografia e Estatística – IBGE – informa que no Brasil, 99,4% dos municípios são atendidos com serviços de abastecimento de água por rede geral de distribuição [3]. O destaque estadual fica para a região Sudeste que conta com 100% dos municípios abastecidos por água tratada. A mesma pesquisa [3], porém, revela uma situação preocupante no cenário nacional: somente 78,6% dos domicílios são atendidos por serviços de abastecimento de água, revelando que uma considerável parte da sociedade ainda não tem acesso aos sistemas de abastecimento de água.

1.4. BREVE HISTÓRICO DO ABASTECIMENTO DE ÁGUA NO CEARÁ

O primeiro sistema de abastecimento de água no Ceará foi inaugurado em 29 de setembro de 1866, na cidade de Fortaleza, utilizando fontes do Sítio Benfica [12]. Ao longo da história vários fatos aconteceram, sendo os principais listados a seguir:

- 1912 a 1949: Construção do archeduto que ligava o açude Acarape a Fortaleza, com vazão nominal de 225 m³/h, para atender a uma população de 100.000 habitantes. O projeto foi elaborado pelo engenheiro cearense João Felipe Pereira [9]. Na época, o Estado era governado por Nogueira Acioli;
- 1950 a 1964: Entidades como a Fundação SESP (Serviço Especial de Saúde Pública, entidade criada no período pós-guerra, hoje FUNASA), CAENE (Companhia de Água e Esgoto do Nordeste, pertencente à SUDENE), DNOCS (Departamento Nacional de Obras Contra as Secas) e DNOS iniciam a implantação de vários sistemas de abastecimento de água no interior do Estado [9]. Na década de 1960, havia no Ceará um total de 85 sistemas de abastecimento de água: 25 sistemas

operados pelo SESP; 32 sistemas operados pela CAENE; 9 sistemas operados pelo DNOCS; e o sistema de abastecimento da cidade de Fortaleza, operado pela SAAGEC (Sistema Autônomo de Água e Esgoto do Ceará) e 18 sistemas independentes operados por suas respectivas prefeituras [9];

- 1965 a 1970: É perfurado um conjunto de 50 poços profundos no aluvião do rio Cocó em Fortaleza, trazendo um reforço de $160 \text{ m}^3/\text{h}$ ao abastecimento [9];
- 1971 a 1980: Com o advento do PLANASA, foi criada a CAGECE através da Lei 9.499 de 20 de julho de 1971. O objetivo da criação da companhia era prestar serviço público de abastecimento de água e esgotamento sanitário em todo o território estadual, mediante contratos de concessão firmados com os municípios [9];
- 1981 a 1989: Com o respaldo do PLANASA a CAGECE construiu o sistema Pacoti-Riachão-Gavião, para reforço do sistema Acarape. As três represas integraram uma capacidade total de 503 milhões de metros cúbicos, possibilitando uma vazão regularizada de $4,5 \text{ m}^3/\text{s}$ [9];
- 1990 a 1995: O início da década de 1990 foi marcada com a possibilidade de um colapso de abastecimento de água na Região Metropolitana de Fortaleza (RMF). Para resolver o problema foi construído pela CAGECE o açude Pacajus e o Canal do Trabalhador. Este último para captação de água bruta do rio Jaguaribe que, na época, era perenizado pelos açudes Orós e Banabuiú (hoje está integrado, também, o açude Castanhão), garantindo uma reserva de 750 milhões de metros cúbicos para a RMF [9]. Neste período foram investidos pela CAGECE um total de US\$ 167 milhões em obras estruturantes no setor de abastecimento de água [9];
- 1995 a 2005: Com o advento das atuais técnicas de supervisão remota e dos Controladores Lógico Programáveis (CLPs), foram montados na segunda metade da década de 1990, os Centros de Controle Operacional (CECOP) dos Sistemas de Abastecimento de Água (SAA) da RMF (CECOP Fortaleza) e da Chapada da Ibiapaba (CECOP DEIBA), este último beneficiando o abastecimento de 6 municípios. Estes sistemas são baseados nas filosofias de controle e supervisão remota digital, através de programa supervisorio, onde é feito o controle em tempo real de bombeamento, adução e reservação [9];
- 2006 até a atualidade: Na segunda metade da década de 2000, o sistema de adução de água tratada da RMF foi duplicado (adutora Gavião-Ancuri), para atender a crescente demanda de água tratada da região. Nesta operação foi duplicada a capacidade de tratamento da ETA Gavião, bem como o sistema de adução e

reservação, garantindo uma vazão regularizada de $9\text{m}^3/\text{s}$. Atualmente, a CAGECE atende a 150 municípios no Estado do Ceará [12];

1.5. AUTOMAÇÃO

1.5.1. UMA VISÃO GERAL

Nas últimas décadas, a necessidade do aumento da produtividade e da eficiência dos processos industriais, exigiu o advento de plantas fabris cada vez mais complexas, que necessitam de um maior número de mecanismos de controle, e rapidez no processamento das informações. Este fato provocou, a partir da segunda metade da década de 1960 [13], um avanço significativo nas tecnologias de automação para os diversos tipos de plantas industriais, inclusive as de saneamento [5].

A automação é primordial para a indústria moderna, pois possibilita economia de energia, mão de obra e matéria-prima, respondendo ao anseio da sociedade industrial que exige a maximização da produção. Isto é possível, pois a automação aproxima a produção real da capacidade nominal da planta industrial, resultando no aumento da eficiência dos processos e em segurança operacional – fato perceptível na diminuição das horas paradas e da quantidade de manutenções corretivas. Outro ponto muito forte, conforme representado na Figura 1.1, é o fato de a automação facilitar a fusão com os sistemas corporativos na esfera de negócios, possibilitando a troca de informações com sistemas do tipo Planejamento de Recursos Empresariais (ERP – *Enterprise Resource Planning*), que integram todas as informações internas e externas nas áreas operacional, financeira e comercial da indústria, possibilitando a gestão completa da planta [14].

Fisicamente, a automação de uma planta industrial envolve a integração de várias Unidades Terminais Remotas (UTR) distribuídas na planta, sendo cada uma responsável pela automação local de um determinado processo. Cada UTR é constituída por um hardware de controle; atuadores que interferem no processo a fim de manter as variáveis controladas dentro dos limites estabelecidos; e instrumentação (sensores) para medição das variáveis do processo.

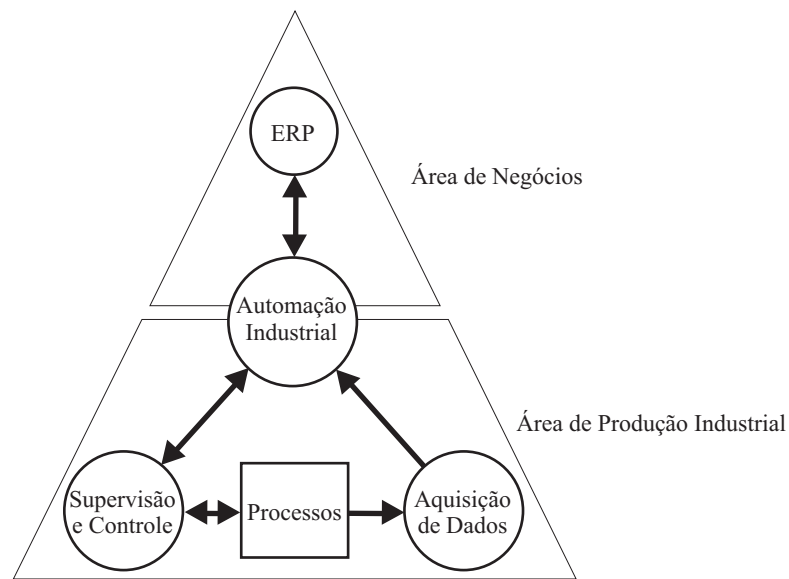


Figura 1.1 – A Automação Industrial e a fusão com a Área de Negócios.
Desenho do Autor

Convencionalmente, o hardware de controle utilizado nas UTRs é o Controlador Lógico Programável (CLP), que é constituído basicamente por: um Processador que executa os algoritmos de controle do processo; módulos de saída digital, que implementam a conexão e controle de atuadores da planta que possuem modo de funcionamento discreto (por exemplo: chaves de partida direta para motores e válvulas de controle aberto/fechado); módulos de entrada digital, que possibilitam a percepção do status de funcionamento (ligado, desligado, defeito, alarme, etc.) de atuadores e sensores que possuem modo de funcionamento discreto; módulos de saída analógica, que implementam a conexão e controle de atuadores que possuem status de funcionamento modulante (por exemplo: chaves de partida para motores com inversor de frequência, válvulas de controle de vazão e pressão), através de sinais de tensão ou corrente; módulos de entrada analógica, que permitem a conexão com os instrumentos do processo e a leitura das variáveis monitoradas pelos mesmos, através de sinais analógicos de tensão ou corrente; e módulos de comunicação, que permitem a conectividade com outros CLPs e equipamentos integrados ao processo através de protocolos de comunicação industrial. A Figura 1.2 ilustra o esquema básico de um CLP.

Com o advento dos protocolos de comunicação industrial de chão de fábrica, tais como o Profibus (DP e PA), Hart, AS-i, CAN e Fieldbus H1 [14], tornou-se possível a conexão direta entre o CLP e os instrumentos e atuadores da planta através dos módulos de comunicação, sem necessidade de uso de módulos de entrada e saída digital e analógica. Neste caso, os instrumentos e atuadores são conectados em uma única rede, através de um

único cabo, facilitando a instalação e contribuindo com a redução da manutenção e aumento da velocidade do tráfego de informações na planta.

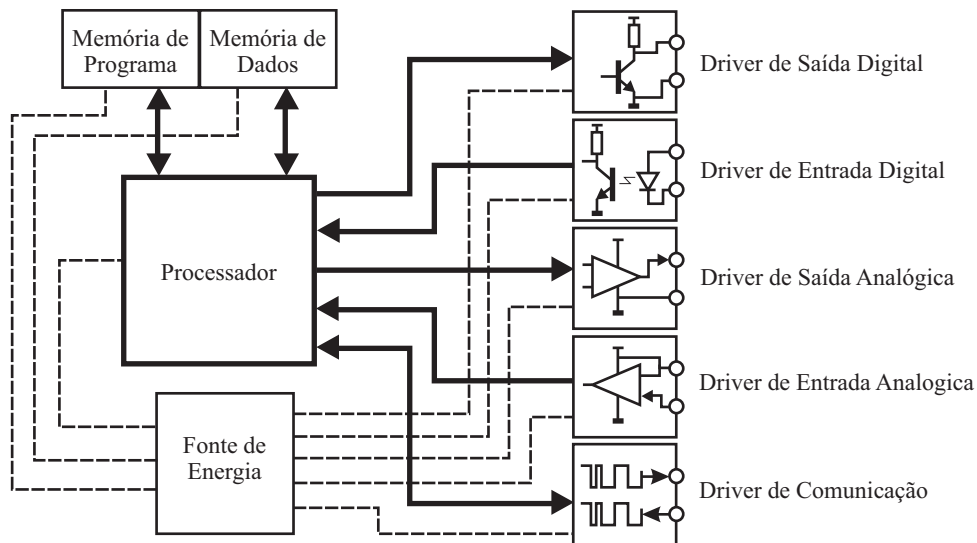


Figura 1.2 – Esquema básico de um Controlador Lógico Programável.
Desenho do Autor

Um diagrama de blocos básico do controle de uma UTR é ilustrado na Figura 1.3, onde o sinal d_n é a saída do processo em um instante discreto n . A malha de controle é fechada através de Instrumentação de Medição, que disponibiliza ao CLP um sinal h_n proporcional à saída d_n . O CLP gera, através do algoritmo de controle, o sinal de controle c_n , tomando como referência o residual entre h_n e o sinal de referência externa u_n . O sinal de controle c_n é então aplicado à entrada do atuador que manipula o processo a fim de manter a saída d_n dentro do limite estabelecido pelo sinal de referência externa u_n .




Figura 1.3 – Diagrama básico do controle automático de um processo.
Desenho do Autor

O sinal de referência externa u_n é geralmente estabelecido pelo Software de Controle Supervisório e Aquisição de Dados (SCADA – *Supervisory Control And Data Acquisition System*), responsável pela supervisão e o controle remoto de todas as UTRs distribuídas na planta. O software SCADA permite a concentração da supervisão, controle e historiamiento de dados de toda a planta em uma única interface de operação e supervisão centralizada [5], conforme ilustrado na Figura 1.4.

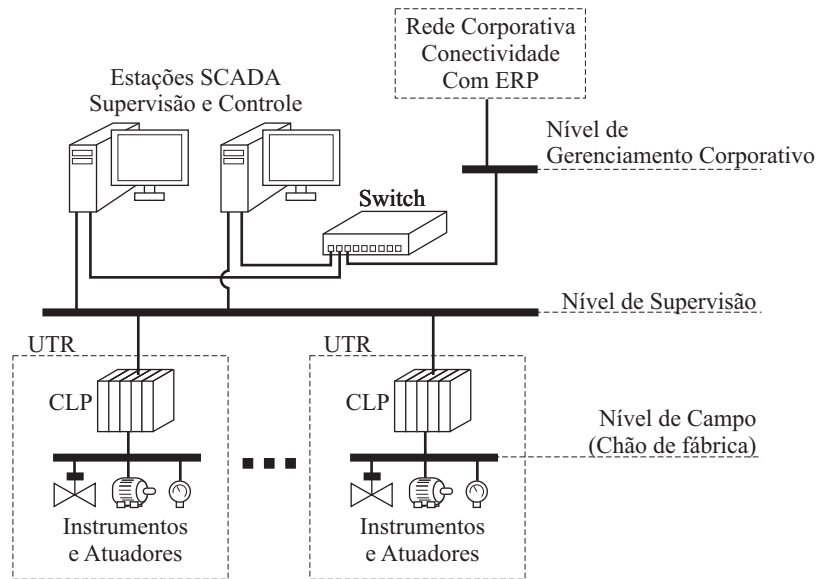


Figura 1.4 – Automação de uma planta industrial – principais níveis.
Desenho do Autor

O tráfego de controle e dados em uma planta industrial automatizada com uma arquitetura distribuída, flui em três níveis físicos principais, através dos seguintes protocolos de comunicação:

- Nível de Campo (conexão entre CLPs, instrumentos e atuadores): Fieldbus H1, CAN, Profibus (PA e DP), Hart e AS-i;
- Nível de Supervisão (conexão entre CLPs e as Estações SCADA): ControlNet, EthernetIP, Foundation-HSE, OPC, Modbus, Profibus (FMS e DP), Profinet;
- Nível de Gerenciamento Corporativo (conexão entre as Estações SCADA e a rede corporativa da industria): Ethernet-TCP/IP, OPC, DDE, DCOM;

1.5.2. AUTOMAÇÃO DE ESTAÇÕES DE TRATAMENTO DE ÁGUA

No Brasil, as aplicações de automação de sistemas de saneamento, incluindo plantas de tratamento de água, tomaram impulso muito tardiamente, somente a partir da segunda metade da década de 1990 [13]. Desde então, as companhias de saneamento no Brasil, tem dado

muita ênfase à automação dos processos de tratamento de água, com vistas à otimização operacional dos processos e insumos de produção envolvidos, bem como garantir água tratada de qualidade.

A automação de ETAs segue o mesmo princípio da automação de plantas industriais, descrito na seção anterior, onde os principais processos automatizados são mostrados na Tabela 1.1.

Tabela 1.1 – Principais Processos Automatizados em uma ETA.

Processo	Água	Produtos Dosados	Variáveis Medidas	Instrumentos (sensores)	Atuadores
Pré-dosagem	Bruta	Cloro	Residual de Cloro	Medidor de Cloro Residual	Bomba dosadora
		Flúor	Teor de Flúor	Medidor de Fluoreto	Bomba dosadora
		Alcalinizantes	pH	Medidor de pH	Bomba Dosadora
Parâmetros Analíticos de Qualidade	Bruta		Turbidez	Medidor de Turbidez	
			pH	Medidor de pH	
			Cor	Medidor de Cor	
Coagulação	Coagulada	Coagulantes	Nível de Coagulação	Monitor de Coagulação	Bomba Dosadora
Parâmetros Analíticos de Qualidade	Coagulada		Turbidez	Medidor de Turbidez	
			pH	Medidor de pH	
			Cor	Medidor de Cor	
Lavagem de Filtros	Filtrada		Turbidez	Medidor de Turbidez	Válvulas Borboleta com Atuador
			Perda de Carga	Medidor de Pressão Diferencial	
Pós-dosagem	Tratada	Cloro	Residual de Cloro	Medidor de Cloro Residual	Bomba dosadora
		Alcalinizantes	pH	Medidor de pH	Bomba dosadora
Parâmetros Analíticos de Qualidade	Tratada		Turbidez	Medidor de Turbidez	
			pH	Medidor de pH	
			Cor	Medidor de Cor	

Fonte: do autor.

A automação de ETAs traz inúmeros benefícios além da otimização operacional e da qualidade da água final, sendo os principais a economia de energia elétrica, a economia de produtos químicos de dosagem e a otimização de mão de obra humana. Porém, a decisão da montagem de um sistema de automação em uma ETA deve obedecer a critérios de viabilidade econômico-financeira, visto que os custos de implantação de tais sistemas são relativamente altos. Para se ter uma idéia, o custo de implantação de um sistema local de dosagem automática de coagulantes, sem controle remoto por software SCADA, custa em torno de R\$ 141.123,21 [15], conforme demonstrado na Tabela 1.2.

Tabela 1.2 – Custo de Implantação de um Controle Automático local de Dosagem de Coagulantes.

Item	Descrição	Unidade	Quantidade	Unitário	Total
1	Serviços				36.587,50
1.1	Projeto e configuração de hardware	unidade	1	15.056,36	15.056,36
1.2	Montagem	unidade	1	10.037,57	10.037,57
2	Material				100.375,71
2.1	Infraestrutura de Painéis	unidade	1	6.656,00	6.656,00
2.2	Infraestrutura UPS	unidade	1	2.496,00	2.496,00
2.3	Monitor de coagulação	unidade	1	52.962,51	52.962,51
2.4	Hardware de controle	unidade	1	8.320,00	8.320,00
2.5	Bombas dosadoras	unidade	2	13.945,60	27.891,20
2.6	Tubulações hidráulicas	unidade	1	450,00	450,00
2.7	Tubulações elétricas	unidade	1	750,00	750,00
2.8	Cabos	unidade	1	850,00	850,00
				TOTAL	125.469,64

Fonte: CAGECE, 2011.

1.6. OBJETIVO

Este trabalho objetiva desenvolver um modelo baseado em redes neurais artificiais para inferência dos sinais de controle de dosagem de coagulantes em uma ETA por filtração rápida, com vistas à substituição do sensoriamento do nível de coagulação – variável convencionalmente utilizada no controle de dosagem de coagulantes, e que tem custo relativamente alto – pelo sensoriamento de outras variáveis de custo menor.

Conforme a Tabela 1.2, o custo de implantação de um sistema convencional de controle de dosagem de coagulantes em uma ETA por filtração rápida, fica em torno de R\$ 125.469,64, o que inviabiliza este tipo de aplicação em ETAs de pequeno porte, principalmente. O uso do modelo proposto neste trabalho eliminaria os custos com o monitor de coagulação, com o hardware de controle e com os custos de projeto e configuração de hardware (itens 1.1, 2.3 e 2.4 da Tabela 1.1), sendo acrescentados custos com medição de Turbidez e pH e um hardware de interface digital/analógico simples, conforme a Tabela 1.3,

com custos relativamente menores. O custo final com a aplicação do modelo ficaria em torno de R\$ 79.991,18, o que representa uma redução em torno de 36%.

Tabela 1.3 – Custo de Implantação de um Controle Automático local de Dosagem de Coagulantes, com aplicação de Redes Neurais Artificiais.

Item	Descrição	Unidade	Quantidade	Unitário	Total
1	Serviços				4.527,80
1.2	Montagem	unidade	1	4.527,80	4.527,80
2	Material				75.463,38
2.1	Infraestrutura de Painéis	unidade	1	3.993,60	3.993,60
2.2	Infraestrutura UPS	unidade	1	1.664,00	1.664,00
2.3	Medidor de Turbidez de Água Bruta e Coagulada e pH de Água Coagulada	unidade	1	37.364,58	37.364,58
2.4	Hardware de Interface	unidade	1	2.500,00	2.500,00
2.5	Bombas dosadoras	unidade	2	13.945,60	27.891,20
2.6	Tubulações hidráulicas	unidade	1	450,00	450,00
2.7	Tubulações elétricas	unidade	1	750,00	750,00
2.8	Cabos	unidade	1	850,00	850,00
TOTAL					79.991,18

Desta forma, a aplicação de modelos baseados em redes neurais para inferência dos sinais de controle de dosagem de coagulantes contribuirá com a viabilização da automação de ETAs de pequeno porte, ou de ETAs que abastecem localidades de baixa condição econômica e que não teriam possibilidades de apresentar viabilidade econômico-financeira. Fica então evidenciado que a aplicação do modelo proposto neste trabalho contribuirá para a universalização dos serviços de abastecimento de água – um benefício muito propício para o Estado do Ceará.

1.7. TRABALHOS EXISTENTES SOBRE APLICAÇÃO DE RNAs NO PROCESSO DE COAGULAÇÃO QUÍMICA

Ao longo do desenvolvimento deste trabalho, foi realizada pesquisa bibliográfica sobre o tema, e foram encontrados sete artigos sobre predição e inferência da dosagem de coagulante Sulfato de Alumínio, no processo de tratamento de água, utilizando modelos baseados em RNAs.

A primeira referência foi o trabalho desenvolvido por Gagnon, Grandjean & Thibault [16], no qual foi utilizado um modelo neural do tipo Perceptron de Múltiplas Camadas (MLP) para previsão da dosagem de coagulante Sulfato de Alumínio em uma planta de tratamento de água. Como entradas do modelo neural foram considerados os parâmetros analíticos de qualidade de água bruta: pH, turbidez, temperatura e condutividade.

Trabalhos semelhantes ao desenvolvido por Gagnon, Grandjean & Thibault [16], foram produzidos por Joo, Choi & Park [17] e Deveughele & Do-Quang [18], onde foram utilizados modelos do tipo MLP para previsão da dosagem de Sulfato de Alumínio. A mesma estratégia foi usada por Maier, Morgan & Chow [19], ao utilizar uma MLP para predizer, além da dosagem do coagulante Sulfato de Alumínio, parâmetros analíticos de qualidade de água tratada a partir de parâmetros analíticos de qualidade água bruta.

Um modelo MLP e um Sistema de Inferência Adaptativo Neuro-Fuzzy (ANFIS) foram utilizados por Wu & Lo [20] para predição da dosagem de coagulante Sulfato de Alumínio, tendo como entradas parâmetros de qualidade de água bruta.

No trabalho produzido por Heddam, Bermad & Dechemi [21], foi feita uma comparação entre o desempenho de um modelo neural baseado em uma Função de Base Radial (RBF) e outro baseado em Regressão Generalizada, para predição da dosagem de coagulante Sulfato de Alumínio em uma estação de tratamento de água. Seis parâmetros analíticos de qualidade de água bruta foram utilizados como entrada dos modelos: turbidez, condutividade, temperatura, oxigênio dissolvido, absorvância de ultravioleta e o pH. Em um trabalho posterior, um estudo de caso da estação de tratamento de água de Boudouaou, Argélia, Heddam, Bermad & Dechemi [22] utilizaram um sistema ANFIS para predição da dosagem de coagulante Sulfato de Alumínio, utilizando as mesmas entradas do trabalho anterior [21].

Os trabalhos relacionados acima possuem características em comum: (1) na sua maioria utilizam redes neurais estáticas para o modelamento proposto; (2) foram selecionados como entradas do modelo parâmetros de qualidade de água bruta; e (3) é implementada a predição da dosagem de um único coagulante – o Sulfato de Alumínio.

Este trabalho, entretanto, diferentemente das aplicações desenvolvidas nos trabalhos citados acima, propõe a utilização de RNAs dinâmicas para a inferência dos sinais de controle de dosagem de coagulantes PAC (principal) e POL (auxiliar), no processo de tratamento de água, utilizando como variáveis de entrada para o modelo parâmetros analíticos de qualidade de água bruta e coagulada.

1.8. PRODUÇÃO CIENTÍFICA

Ao longo da pesquisa foi elaborado o artigo “MODELO NEURAL NARX APLICADO À INFERÊNCIA DOS SINAIS DE CONTROLE DE DOSAGEM DE COAGULANTES PRINCIPAL E AUXILIAR NO PROCESSO DE TRATAMENTO DE ÁGUA POR FILTRAÇÃO DIRETA” submetido e aceito para o X Congresso Brasileiro de Inteligência Computacional (CBIC-2011).

1.9. DESENVOLVIMENTO DA PESQUISA E ORGANIZAÇÃO DO TRABALHO

O desenvolvimento da pesquisa foi realizado em 6 etapas de estudo:

- **1ª Etapa** – Capítulo 2: Tem como objetivo contextualizar o tema principal da pesquisa à temática do abastecimento de água. Para tanto, foi realizado um estudo geral sobre estações de tratamento de água dando ênfase ao processo de coagulação química, abrangendo assuntos como: qualidade das águas; tecnologias de tratamento; e uma descrição operacional da ETA Gavião. Também é apresentada uma abordagem sobre a arquitetura convencional de controle de dosagem de coagulantes utilizada pelas companhias de saneamento no Brasil. Na última Seção é apresentada a proposta do modelo neural para inferência dos sinais de controle de dosagem de coagulantes;
- **2ª Etapa** – Capítulo 3: Apresentar um estudo geral sobre RNAs dando ênfase às arquiteturas de redes dinâmicas não-recorrentes e recorrentes. São apresentados 4 tipos de RNAs (2 não-recorrentes e 2 recorrentes) a serem testadas nas 3ª Etapa do trabalho;
- **3ª Etapa** – Capítulo 4: Descreve a implementação do modelo neural, abordando a configuração das 4 RNAs apresentadas na 2ª Etapa. A implementação do modelo contempla a seleção e ajuste de variáveis de entrada, seleção de atrasos e seleção das estruturas das RNAs a serem testadas;
- **4ª Etapa** – Capítulo 5: Relata os testes realizados com as RNAs configuradas na 3ª Etapa. Este Capítulo define quais RNAs apresentadas na 2ª Etapa são utilizadas no modelo neural proposto;
- **5ª Etapa** – Capítulo 6: Conclusões e perspectivas.

2. ESTAÇÕES DE TRATAMENTO DE ÁGUA

Este Capítulo apresenta uma abordagem teórica sobre as tecnologias de tratamento de água, dando ênfase ao processo de coagulação química. É também apresentada uma descrição dos processos de tratamento da ETA Gavião, bem como uma explanação da arquitetura convencional de controle automático de coagulação química empregada em ETAs de filtração rápida ou tratamento completo no Brasil. Por fim, é apresentada a proposta do modelo neural para inferência dos sinais de controle de coagulantes em ETAs de filtração rápida.

2.1. QUALIDADE DAS ÁGUAS DESTINADAS AO CONSUMO HUMANO

A qualidade das águas de abastecimento é um fator preliminar na concepção de instalações de tratamento de água, pois influi na escolha da tecnologia adequada de tratamento, bem como dos custos envolvidos nas montagens das instalações de tratamento [1]. Um fator preocupante é o pequeno percentual de volume total de água adequada ao consumo humano existente na natureza e sua acessibilidade aos sistemas de tratamento. Outro fato igualmente preocupante é a degradação das águas por poluição, o que dificulta a aplicação de técnicas de tratamento, bem como contribui para o aumento de riscos à saúde humana [1]. A Organização Mundial da Saúde (OMS) estimou em 1996 que, a cada ano, mais de 5 milhões de pessoas morrem devido a doenças causadas por consumo de água contaminada por falta de saneamento [2], daí a importância do saneamento básico no contexto global, bem como, conseqüentemente, a disponibilização de água adequada para consumo à sociedade.

O conceito de qualidade de água é relativo ao tipo de uso a qual se destina. O Conselho Nacional do Meio Ambiente (CONAMA) publicou em 2005 a Resolução 357 que classifica as águas quanto aos seus diversos usos, determinando qual o tipo de tratamento aplicável. Na Tabela 2.1, é apresentado a classificação das águas utilizadas para o abastecimento humano e o tipo de tratamento adequado [23].

Tabela 2.1 – Classificação das águas destinadas para consumo humano.

Destinação	Salinidade	Classificação	Tipo de Tratamento Aplicável
Abastecimento para consumo humano	Doce	Classe Especial	Desinfecção
		Classe 1	Tratamento Simplificado
		Classe 2	Tratamento Convencional
		Classe 3	Tratamento Convencional ou Avançado
	Salobra	Classe 1	Tratamento Convencional ou Avançado
	Salina	Não se Aplica	Não se aplica

Fonte: CONAMA (2005)

A caracterização da qualidade da água é primordial para a determinação da situação do manancial de abastecimento e, conseqüentemente, da tecnologia adequada de tratamento a ser aplicada. Em sistemas de tratamento de água já implantados o acompanhamento sanitário periódico para levantamento da caracterização da água é essencial para a detecção de alterações na qualidade da água bruta bem como para a avaliação da eficiência da tecnologia de tratamento aplicada [2].

Quanto ao consumo humano, atualmente no Brasil, a água potável tem suas características normatizadas através da Portaria 2.914 do Ministério da Saúde, de 12 de dezembro de 2011. Porém, como este trabalho foi desenvolvido até julho de 2011, utilizando dados históricos de 2007 a 2009, foi considerado como padrão de potabilidade a Portaria 518/2004 do Ministério da Saúde (revogada pela portaria 2.914/2011 e vigente até 11 dezembro de 2011). Desta forma, os padrões de potabilidade considerados nesta dissertação (características físicas, químicas, biológicas e radioativas) são os da Portaria 518/2004 [24], a qual será exposta de forma resumida nas próximas Seções. Também será feita a exposição das principais características normatizadas pela portaria 518/2004, dando ênfase às que tem relação com o processo de coagulação química.

2.1.1. O PADRÃO BRASILEIRO DE POTABILIDADE

No Brasil, a primeira ação governamental na área de qualidade das águas de abastecimento humano, ocorreu no ano de 1977, quando foi publicada a Portaria 56/BSB do Ministério da Saúde, através do Decreto Federal 79637 de 09 de março de 1977, que padronizava a potabilidade da água para todo o território nacional. Esta Portaria esteve vigente até janeiro de 1992, quando entrou em vigor a Portaria 36/GM [25].

Em 29 de dezembro de 2000 a Portaria 36/GM foi revogada, quando da publicação da Portaria 1469, através da atuação da FUNASA, da Coordenação Geral de Vigilância em Saúde Ambiental (CGVAM) e do Centro Nacional de Epidemiologia (CENEPI). A Portaria 1469 foi elaborada com a contribuição de profissionais, representantes de diversas entidades do setor público, do setor privado e ONGs. O documento na sua versão final foi fechado após a realização da consulta pública, aberta a toda a sociedade, publicada no DOU em 13 de outubro de 2000.

Em junho de 2003, após a reestruturação do MS e a instituição da Secretaria de Vigilância em Saúde (SVS/MS), foi revogada a Portaria 1469, entrando em vigor a Portaria 518/2004, que estabelece, além do padrão de potabilidade considerando os parâmetros microbiológicos, físicos e químicos, as responsabilidades das empresas produtoras de água,

quanto à obrigação de exercer o controle de qualidade da água, e das autoridades fiscalizadoras, pertencentes à esfera governamental. Outro ponto importante da Portaria é a determinação da quantidade e periodicidade das análises de qualidade de amostras em vários pontos do sistema de abastecimento [24]. Dentre os parâmetros microbiológicos e físicos destacam-se a quantidade aceitável para coliformes totais e a turbidez máxima aceitável, respectivamente. Dentre os parâmetros químicos, destacam-se as quantidades máximas aceitáveis para substâncias inorgânicas, orgânicas, agrotóxicos, cianotoxinas e trihalometanos.

A importância de tal regulamentação é imprescindível, levando-se em consideração que os mananciais de abastecimento são ecossistemas com comportamento sazonal, na sua grande maioria. Por isto, mesmo com o avanço das tecnologias de tratamento de água, incluindo as técnicas de instrumentação eletrônica e controle de processos, é necessário, para a determinação da tecnologia de tratamento adequada, a realização de estudos detalhados da qualidade da água bruta a ser tratada, incluindo análise de comportamento histórico, bem como, em alguns casos, de pesquisas desenvolvidas em instalações piloto [1].

Outro fator importante na determinação da tecnologia adequada para o tratamento da água bruta é o potencial de geração de cianotoxinas e trihalometanos – substâncias químicas comprovadamente nocivas à saúde humana [26] e referenciadas na Portaria 518/2004 com quantidades aceitáveis significativamente pequenas [24].

2.1.2. CARACTERÍSTICAS FÍSICAS DA ÁGUA

As principais características físicas utilizadas para avaliar a qualidade das águas de abastecimento humano são: Turbidez, Cor, Temperatura e Condutividade. Como será visto, na descrição resumida a seguir, tais características tem influência direta no processo de coagulação química, e conseqüentemente no modelo neural a ser proposto.

TURBIDEZ

A turbidez expressa a transparência das águas de abastecimento [2], sendo correlacionada [27] com a presença de partículas coloidais em suspensão, matéria orgânica e inorgânica, plâncton e outros micro-organismos [1], o que fundamenta o uso do princípio da nefelometria a laser no desenvolvimento de instrumentação analítica para medição de turbidez [28]. A turbidez é uma variável determinante, visto que a distribuição de tamanho das partículas suspensas influi na eficiência da coagulação química [1].

A Portaria 518/2004 determina o valor máximo aceitável para turbidez na saída de tratamento, conforme mostrado na Tabela 2.2 [24]. Para a água potável de consumo final, a Portaria 518/2004 [24] estabelece o valor máximo aceitável de 5,0 UT.

Tabela 2.2 – Padrão de turbidez para água na saída do tratamento.

Tipo de Tratamento	Origem da água	Valor Máximo Permitido
Desinfecção	Subterrânea	1,0 UT
Filtração Rápida (tratamento completo ou filtração rápida)	Outros mananciais	1,0 UT
Filtração Lenta	Outros mananciais	2,0 UT em 95% das amostras

Fonte: SVS (2004)

COR

A cor das águas de abastecimento é decorrente da presença de matéria orgânica, geralmente ácidos fulvicos e húmicos [2] resultantes da degradação natural de plantas e animais [1]. Outros componentes influem na coloração da água: o ferro e outros metais ou contaminação por efluentes industriais. Este último caso pode ser indício de uma situação perigosa para a saúde humana [2].

A análise da cor da água é um parâmetro indispensável no processo de tratamento de água, visto que o contato do cloro livre com as substâncias causadoras da cor resulta na formação de trihalometanos (THM) [1].

A medição da cor pode ser feita manualmente através da comparação visual com cores padronizadas, ou através de tecnologias eletrônicas de medição, baseadas em métodos espectrofotométricos que determinam a cor indiretamente através da correlação com a absorvância da amostra [29]. Define-se cor verdadeira, a cor medida de uma amostra que teve as partículas suspensas na água removidas, por centrifugação ou filtração. A cor aparente é a cor medida sem a remoção das partículas suspensas na água. A Portaria 518/2004 [24] estabelece o limite máximo aceitável de 15 μ H para o parâmetro cor aparente [24].

Um fato relevante para esta pesquisa é a correlação existente entre a cor verdadeira e o pH da amostra [2], visto que o pH está diretamente relacionado com o tamanho das moléculas de substâncias húmicas [1]. A remoção da cor através das tecnologias de filtração rápida, depende do sucesso da coagulação química, que, por sua vez, ocorre a valores de pH baixos [2].

TEMPERATURA

A temperatura é determinante no processo de formação das espécies hidrolisadas no processo de coagulação química. Daí a importância do monitoramento da temperatura no processo de tratamento. Outro fator importante à pesquisa, quanto à coagulação química e conseqüentemente ao modelo neural, é que a temperatura influi no desempenho das unidades de mistura rápida [1].

CONDUTIVIDADE

A condutividade é um fator importante para a eficiência do processo de coagulação química, visto que tem relação direta com a quantidade de sólidos dissolvidos, que influi diretamente na cinética deste processo [1].

2.1.3. CARACTERÍSTICAS QUÍMICAS DA ÁGUA

A análise das características químicas da água é indispensável para o sucesso das tecnologias de tratamento, bem como para a avaliação do grau de poluição do manancial utilizado. Devido sua propriedade em provocar menos efeitos agudos que os provocados por contaminantes microbiológicos, as características químicas são colocadas em uma categoria de menor prioridade em relação às características biológicas [2].

As demais características químicas (Tabela 2.3) estão relacionadas diretamente com a saúde humana, tendo influência nociva se consumidas fora dos padrões de potabilidade [2, 24]. Para tais características é indispensável o monitoramento periódico a fim de manter a confiabilidade das águas de abastecimento e a saúde da população abastecida [2].

Tabela 2.3 – Padrão de potabilidade para substâncias químicas Inorgânicas da água para consumo humano.

Parâmetro	Unidade	Valor Máximo Permitido
Antimônio	mg/L	0,005
Arsênio	mg/L	0,01
Bário	mg/L	0,7
Cádmio	mg/L	0,005
Cianeto	mg/L	0,07
Chumbo	mg/L	0,01
Cobre	mg/L	2,0
Cromo	mg/L	0,05
Fluoreto	mg/L	1,5
Mercúrio	mg/L	0,001
Nitrato	mg/L	10
Nitrito	mg/L	1
Selênio	mg/L	0,01

Fonte: SVS (2004)

Tabela 2.4 – Padrão de potabilidade para substâncias químicas (Cianotoxinas) da água para consumo humano.

Parâmetro	Unidade	Valor Máximo Permitido
Microcistinas	µ/L	1,0

Fonte: SVS (2004)

Tabela 2.5 – Padrão de potabilidade para substâncias químicas Orgânicas da água para consumo humano.

Parâmetro	Unidade	Valor Máximo Permitido
Acrilamida	µ/L	0,5
Benzeno	µ/L	5,0
Benzo[a]pireno	µ/L	0,7
Cloreto de Vinila	µ/L	5,0
1,2 Dicloroetano	µ/L	10,0
1,1 Dicloroetano	µ/L	30,0
Diclorometano	µ/L	20,0
Estireno	µ/L	20,0
Tetracloroeto de Carbono	µ/L	2,0
Tetracloroetano	µ/L	40,0
Triclorobenzenos	µ/L	20,0
Tricloroetano	µ/L	70,0

Fonte: SVS (2004)

Tabela 2.6 – Padrão de potabilidade para substâncias químicas (Agrotóxicos) da água para consumo humano.

Parâmetro	Unidade	Valor Máximo Permitido
Alaclor	µ/L	20,0
Aldrin e Dieldrin	µ/L	0,03
Atrazina	µ/L	2,0
Bentazona	µ/L	300,0
Clordano (isômeros)	µ/L	0,2
2,4 D	µ/L	30,0
DDT (isômeros)	µ/L	2,0
Endossulfan	µ/L	20,0
Endrin	µ/L	0,6
Glifosato	µ/L	500,0
Heptacloro e Heptacloro epóxico	µ/L	0,03
Hexaclorobenzeno	µ/L	1,0
Lindano (γ-BHC)	µ/L	2,0
Metolacloro	µ/L	10,0
Metoxicloro	µ/L	20,0
Molinato	µ/L	6,0
Pendimetalina	µ/L	20,0
Pentaclorofenol	µ/L	9,0
Permetrina	µ/L	20,0
Propanil	µ/L	20,0
Simazina	µ/L	2,0
Trifluralina	µ/L	20,0

Fonte: SVS (2004)

Tabela 2.7 – Padrão de potabilidade para substâncias químicas (Desinfetantes e produtos secundários da desinfecção) da água para consumo humano.

Parâmetro	Unidade	Valor Máximo Permitido
Bromato	mg/L	0,025
Clorito	mg/L	0,2
Cloro Livre	mg/L	5,0
Monocloramina	mg/L	3,0
2, 4, 6 Triclorofenol	mg/L	0,2
Trihalometanos Total	mg/L	0,1

Fonte: SVS (2004)

A seguir, é apresentado o resumo descritivo da característica Acidez e Alcalinidade, que tem influência direta no processo de coagulação química [1].

ACIDEZ E ALCALINIDADE

A acidez da água é relacionada com a presença de ácidos minerais fortes, ácidos fracos, ácidos fúlvicos, ácidos húmicos e sais de metais hidrolisados. A análise da acidez da água em uma planta de tratamento é importante, pois seu valor pode exigir a dosagem de alcalinizantes para manter o carbonato de cálcio estável, objetivando diminuir os efeitos de corrosão e incrustações em tubulações do sistema de distribuição [2].

A alcalinidade da água é relacionada com a presença de carbonatos, bicarbonatos, hidróxidos e outras substâncias básicas como os boratos, fosfatos e silicatos. A alcalinidade influi diretamente no processo de coagulação química, pois tem influência direta na propriedade física Cor.

2.1.4. CARACTERÍSTICAS BIOLÓGICAS DA ÁGUA

A presença de microorganismos nas águas de abastecimento é a causa mais comum de doenças relacionadas ao consumo de água pela população. Do ponto de vista epidemiológico, a água apresenta-se como potencial meio de transmissão de doenças tais como: cólera, febre tifóide, febres paratífóides, disenteria bacilar, amebíase, giardíase, esquistossomose e diversas outras doenças que atingem o trato respiratório e digestivo humano [1]. Desta forma, é de essencial importância o acompanhamento analítico da qualidade da água quanto aos parâmetros biológicos, conforme estabelecido na Portaria 518/2004 [24].

A quantidade de coliformes totais tem sido utilizada como padrão indicativo de poluição [1] sendo um dos parâmetros estabelecidos pela Portaria 518/2004 [24]. A literatura técnica afirma a correlação entre a quantidade de coliformes totais e a turbidez, evidenciando que quanto menor a turbidez da água na saída dos filtros, no processo de tratamento por filtração rápida, mais eficiente será o processo de desinfecção, resultando em menor

quantidade de coliformes totais [1]. Desta forma, um fato relevante para este trabalho é que os processos de coagulação química e filtração devem ser bem ajustados (controlados) a fim de assegurar baixa turbidez na saída dos filtros.

A Portaria 518/2004 [24] estabelece os padrões de potabilidade quanto às características biológicas da água para consumo humano, conforme mostrado na Tabela 2.8.

Tabela 2.8 – Padrão biológico de potabilidade da água para consumo humano.

Parâmetro	Valor Máximo Permitido
Água para consumo humano	
Escherichia Coli ou coliformes termotolerantes	Ausência em 100 ml
Água na saída do tratamento	
Coliformes totais	Ausência em 100 ml
Sistema de distribuição (reservatórios e tubulações)	
Escherichia Coli ou coliformes termotolerantes	Ausência em 100 ml
Coliformes totais	Sistemas que analisam 40 ou mais amostras por mês: Ausência em 100 ml em 95% das amostras examinadas no mês. Sistemas que analisam menos de 40 amostras por mês: Apenas uma amostra poderá apresentar mensalmente resultado positivo em 100 ml.

Fonte: SVS (2004)

2.2. TECNOLOGIAS DE TRATAMENTO DE ÁGUA

Uma etapa primordial das tecnologias de tratamento de água é a filtração, visto que é nesta etapa onde são removidas a maior parte das partículas coloidais suspensas e microorganismos em geral, de forma a tornar o processo de desinfecção eficiente. Desta forma, as tecnologias utilizadas para o tratamento de água para consumo humano são divididas entre as que utilizam o processo de filtração lenta e as que utilizam o processo de filtração rápida. As tecnologias baseadas em filtração lenta não utilizam o processo de coagulação química, enquanto que as tecnologias baseadas em filtração rápida utilizam este processo. A seguir é feito um resumo a respeito de cada tecnologia, dando ênfase às de filtração rápida.

2.2.1. TECNOLOGIAS BASEADAS EM FILTRAÇÃO LENTA

As tecnologias baseadas em filtração lenta, consideradas como não convencionais, são extremamente simplificadas e simulam os mecanismos naturais de purificação das águas em seu percurso descendente pelo subsolo, onde são removidos microorganismos, partículas, substâncias químicas e componentes biológicos. Esta tecnologia teve aplicação privilegiada

no Brasil até a década de 1960. A partir da década de 1970, devido a influências da cultura técnica norte-americana e a acelerada deterioração da qualidade das águas dos mananciais e falta de mão de obra qualificada para operar as plantas de tratamento, esta tecnologia deixou de ser empregada no Brasil [30]. O mecanismo da filtração lenta é biológico, não havendo necessidade do processo de coagulação química. Uma característica importante é a menor frequência de limpeza dos filtros, o que simplifica a operação e a manutenção [31].

Tabela 2.9 – Qualidade da água bruta para tratamento com filtração lenta.

Características da Água	Valor Máximo Permitido				
	Arquitetura				
	1	2	3	4	5
Turbidez [UT]	10	10	25	50	100
Cor Verdadeira [μH]	5	5	5	5	10
Ferro [mg/L]	1	1	3	3	3
Manganês [mg/L]	0,2	0,2	0,3	0,3	0,5
Algas [UPA/ml]	250	250	1000	1000	2000
Coliformes Totais [/100mL]	1000	2000	5000	10000	20000

Fonte: Bernardo, L. D., Ângela D. B. (2005)

A vantagem da filtração lenta é a simplicidade do projeto, moderado custo de implantação e baixo custo de operação e manutenção. A desvantagem principal é o aumento dos custos de operação e manutenção em sistemas cujos mananciais não atendem aos limites estabelecidos na Tabela 2.9, quanto à qualidade da água bruta, principalmente em mananciais com cor verdadeira acima de 10 μ H. Isto evidencia a baixa eficiência destas tecnologias na remoção de cor verdadeira, sendo mais propício nos casos em que isto é necessário, o uso de tecnologias com processo de coagulação química [25].

2.2.2. TECNOLOGIAS BASEADAS EM FILTRAÇÃO RÁPIDA

As tecnologias baseadas em filtração rápida utilizam o processo de coagulação química antes da filtração, podendo ser do tipo filtração rápida ascendente, filtração rápida descendente, dupla filtração e tratamento completo. A coagulação ocorre na câmara de mistura rápida (local destinado a dispersar os coagulantes na água a ser tratada). Nestas tecnologias, os filtros rápidos são as únicas unidades responsáveis pela remoção dos sólidos suspensos [1].

Estas tecnologias trazem algumas vantagens em relação à filtração lenta:

- Maior capacidade de filtração de material dissolvido e de sólidos suspensos presentes na água bruta, o que implica em maior capacidade de remoção de cor verdadeira [31];

- Necessidade de uma área menor para instalação da planta.

Quanto as desvantagens, as principais são:

- Menor duração das carreiras de filtração. Enquanto a carreira de filtração de um filtro lento dura alguns meses, em geral, a carreira de filtração de um filtro rápido dura de 20 a 50 h, ou menos [31];
- Maior custo de implantação, de operação e manutenção;

FILTRAÇÃO RÁPIDA ASCENDENTE

Utilizada desde o século XIX, a tecnologia de filtração rápida ascendente pode ocorrer em 3 tecnologias, de acordo com a qualidade da água bruta, tal como apresentado na Figura 2.1. Tal tecnologia foi introduzida no Brasil na década de 1960, porém, somente na década de 1970 é que foi amplamente estudada e aplicada em diversas comunidades no interior do Brasil [1]. Nesta tecnologia, a água percorre o leito filtrante de baixo para cima [31].

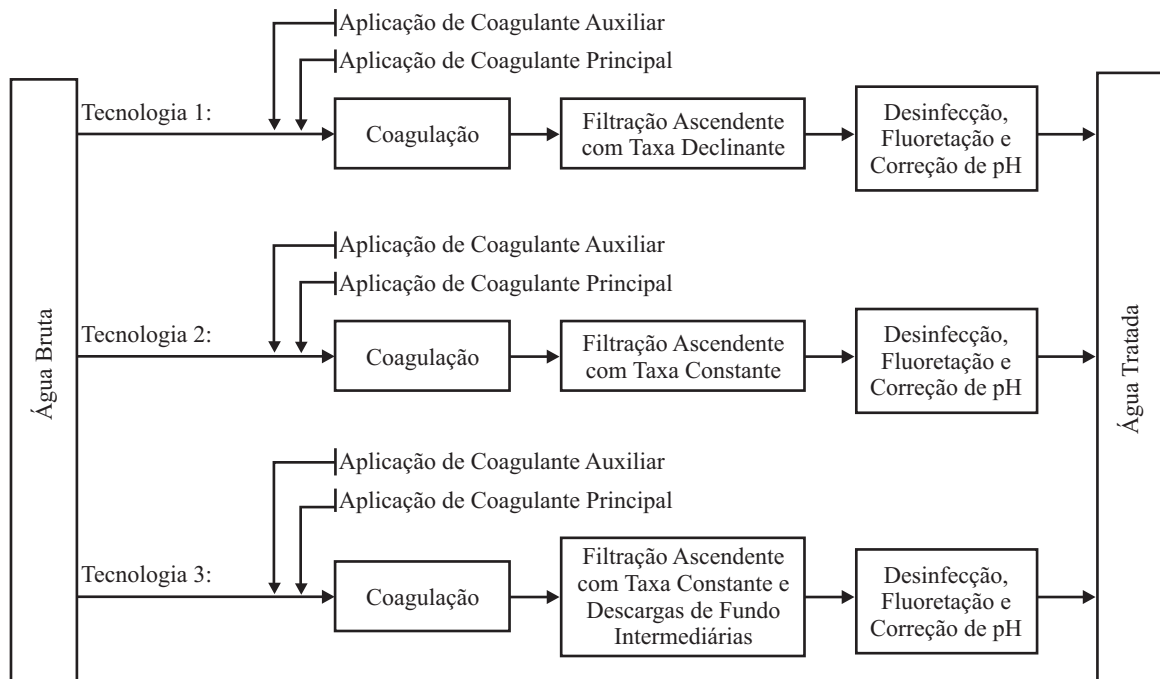


Figura 2.1 – Sequência de Processos das Tecnologias de Tratamento baseadas em Filtração Rápida Ascendente.
Fonte: Bernardo, L. D., Ângela D. (2005)

O leito filtrante, bem como nas demais tecnologias de filtração rápida, é constituído por uma camada de suporte e uma camada de areia de média granulometria. A camada suporte é constituída por até 5 camadas de pedregulho de tamanhos decrescentes no sentido ascendente. A Figura 2.2 ilustra os aspectos construtivos básicos de um filtro de fluxo ascendente.




Figura 2.2 – Aspecto Construtivo Básico de um Filtro de Fluxo Ascendente.
Fonte: PROSAB (2003)

Uma das características desta tecnologia é a existência de dois processos de lavagem: a lavagem de interface e a lavagem completa. Conforme a Figura 2.3, No processo de lavagem completa, os registros R3 e R5 são abertos e os demais fechados, possibilitando a lavagem de todo o leito filtrante, de baixo para cima, através de uma carga hidráulica maior que a da torre de carga, provida pela elevatória de lavagem de filtros.

Neste processo, o fluxo ascendente de lavagem expande o meio filtrante provocando sua estratificação, onde os grãos de areia menores se posicionam na parte superior do leito filtrante. O efluente de lavagem sai pela parte de cima do filtro, no mesmo caminho da água filtrada.

No processo de lavagem de interface, os registros R4 e R6 são abertos e os demais fechados, possibilitando que apenas a camada suporte no ponto de divisão com o leito filtrante seja lavada, sob pressão da elevatória de lavagem de filtros. Este processo consome menos água tratada e possibilita o aumento da carreira de filtração. Neste caso, o efluente de lavagem sai pela parte inferior do filtro, no mesmo caminho da entrada de água coagulada. No processo de filtração, os registros R1 e R2 são abertos e os demais fechados, possibilitando a filtração rápida da água coagulada.

As vantagens desta tecnologia, em relação às outras de filtração rápida são [25]:

- A filtração ocorre no sentido decrescente da porosidade do leito filtrante, ou seja, a água coagulada percorre primeiro a camada suporte de pedregulho (porosidade maior) e depois atravessa a camada de areia (porosidade menor);
- Utiliza todo o leito filtrante para remoção das partículas em suspensão;
- Apresenta carreiras de filtração mais longas;
- Aproveita melhor a carga hidráulica disponível;




Figura 2.3 – Esquema básico de uma ETA de Filtração Rápida Ascendente.

Fonte: Do Autor

Os limites da qualidade da água bruta, para cada arquitetura apresentada na Figura 2.1, são mostrados na Tabela 2.10 [18].

Tabela 2.10 – Qualidade da água bruta para tratamento com filtração rápida ascendente.

Características da Água	Valor Máximo Permitido		
	Arquitetura		
	1	2	3
Turbidez [UT]	20	20	100
Cor Verdadeira [μH]	20	20	100
Ferro [mg/L]	2,5	2,5	15
Manganês [mg/L]	0,2	0,2	1,5
Algas [UPA/ml]	500	500	2500
Coliformes Totais [/100mL]	2500	2500	5000

Fonte: Bernardo, L. D., Ângela D. B. (2005)

Conforme esta tabela, para águas com turbidez maior que 20 UT, até o valor máximo de 100 UT, a operação da ETA de filtração rápida ascendente deverá ser feita com descargas de fundo intermediárias às lavagens completas, recomendando-se, no mínimo, 4 lavagens de interface por dia [1].

A principal desvantagem em relação às outras tecnologias de filtração rápida é a possibilidade de mistura da água de lavagem com a água filtrada, devido o fato de que o sentido do fluxo de água no processo de lavagem completa é também ascendente [18].

FILTRAÇÃO RÁPIDA DESCENDENTE

A tecnologia de filtração rápida descendente tem um poder menor de filtração comparado com a tecnologia de filtração rápida ascendente. Comparando os valores máximos permitidos para as tecnologias de filtração ascendente e filtração descendente, conforme as Tabelas 2.10 e 2.11 [1] respectivamente, nota-se que a primeira tecnologia é apta para tratamento de águas com turbidez até 100 UT, enquanto que a segunda é apta para águas com turbidez até 50 UT. Isto torna o projeto de ETAs com esta tecnologia uma tarefa difícil, visto que é necessário o levantamento e análise de diversos parâmetros de qualidade de água bruta que influem no processo de tratamento. Este problema pode ser contornado através do estudo e análise experimental da operação de plantas piloto [1].

Tabela 2.11 – Qualidade da água bruta para tratamento com filtração rápida descendente.

Características da Água	Valor Máximo Permitido	
	Arquitetura	
	1	2
Turbidez [UT]	25	50
Cor Verdadeira [μH]	25	50
Algas [UPA/ml]	500	1000
Coliformes Totais [/100mL]	2500	5000

Fonte: Bernardo, L. D., Ângela D. B. (2005)

A Figura 2.4, ilustra as duas arquiteturas usuais desta tecnologia. A segunda arquitetura é utilizada no tratamento de águas cuja turbidez está na faixa entre 25 e 50 UT (Tabela 2.11). Neste caso, é necessário o uso de floculação, processo pelo qual a água coagulada é agitada de forma relativamente lenta, para que haja o choque e a aglomeração das impurezas suspensas e a formação de flocos [1].

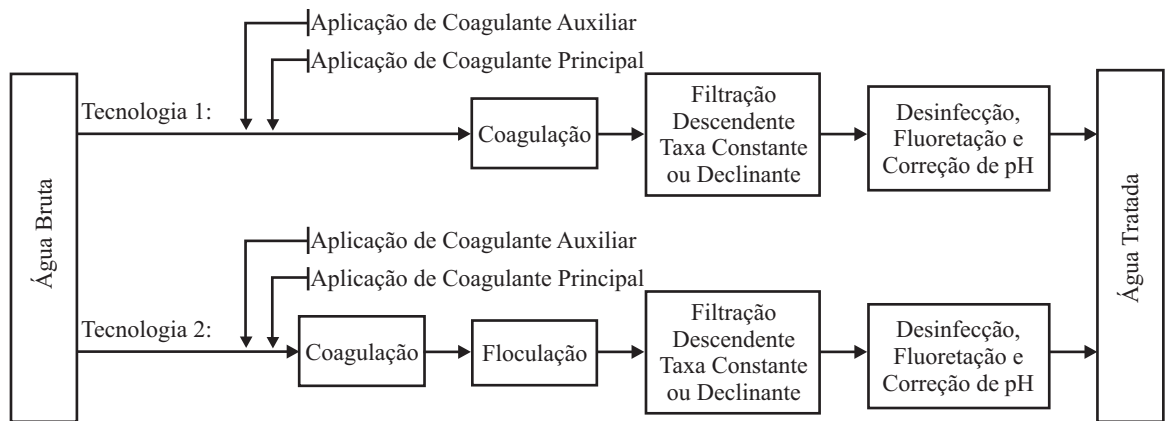


Figura 2.4 – Sequência de Processos das Tecnologias de Tratamento baseadas em Filtração Rápida Descendente.
Fonte: Bernardo, L. D., Ângela D. B. (2005)




Figura 2.5 – Aspectos Construtivos Básicos de um Filtro Descendente com Câmara de Floculação Mecânica à Montante.
Fonte: PROSAB (2003)

Os principais sistemas hidráulicos de floculação são: chicanas de escoamento vertical; chicanas de escoamento horizontal; helicoidal; tipo albana e meio granular. São utilizados também sistemas de floculação mecanizados, que podem ser do tipo: paletas giratórias; turbina e fluxo axial [1]. Os aspectos construtivos básicos de um filtro descendente são ilustrados nas Figuras 2.5. A Figura 2.6 mostra o esquema geral de uma ETA de filtração rápida descendente.

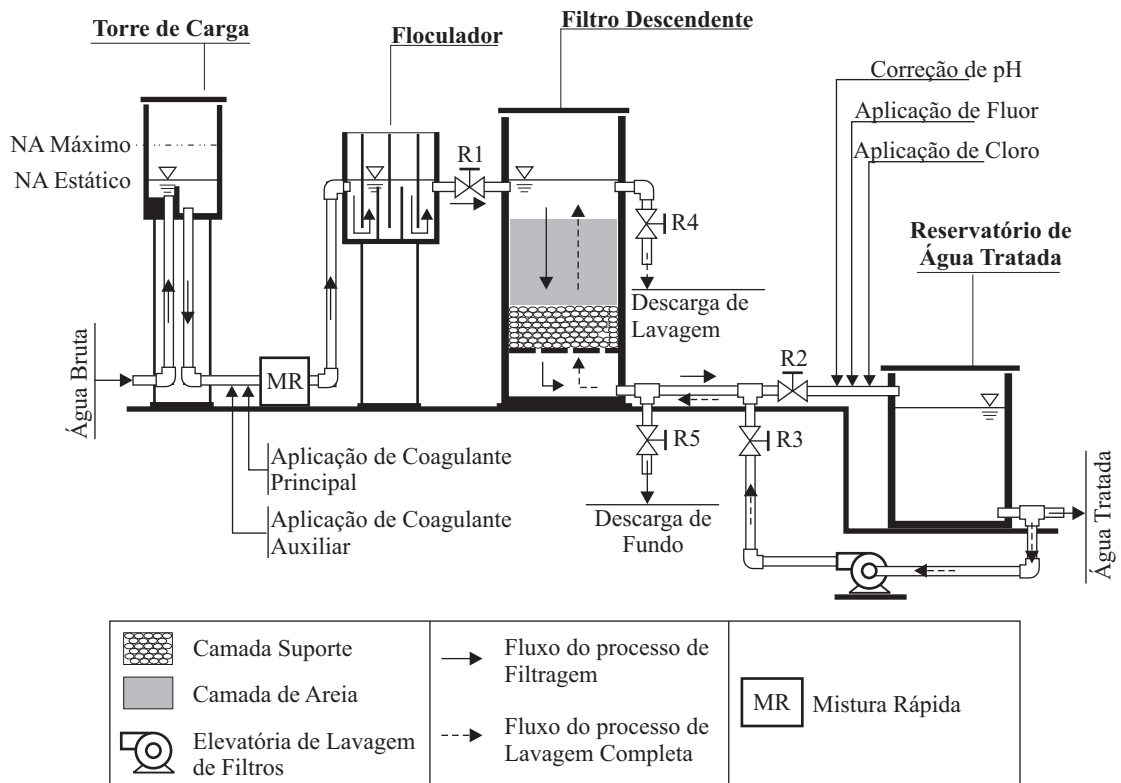


Figura 2.6 – Esquema básico de uma ETA de Filtração Rápida Descendente com Floculador Chicana Vertical.
Fonte: Do Autor

DUPLA FILTRAÇÃO

A tecnologia de dupla filtração é uma variante da terceira arquitetura da tecnologia de filtração rápida ascendente, conforme a Figura 2.1, onde é acrescentada, entre a filtração rápida ascendente e o pós-tratamento, uma etapa de filtração rápida descendente com taxa constante ou declinante. Esta tecnologia apresenta bons resultados em sistemas pertencentes a regiões onde são freqüentes casos de doenças infecciosas que tem a água como principal veículo de transmissão. Os limites aceitáveis para a água bruta são mostrados na Tabela 2.12 [1].

Tabela 2.12 – Qualidade da água bruta para tratamento com dupla filtração.

Características da Água Bruta	Valor Máximo Permitido
Turbidez [UT]	200
Cor Verdadeira [μH]	150
Algas [UPA/ml]	5000
Coliformes Totais [/100mL]	20000

Fonte: Bernardo, L. D., Ângela D. B. (2005)

TRATAMENTO COMPLETO

Nos sistemas cuja água bruta não atende aos limites máximos aceitáveis para as tecnologias citadas acima, ou seja, para limites maiores que os estabelecidos na Tabela 2.12, a tecnologia de tratamento deverá ser do tipo completo. Esta tecnologia possui as etapas ilustradas na Figura 2.7 e utiliza filtração rápida descendente [1].

O processo de pré-tratamento consiste no uso de técnicas de adsorção e oxidação, necessárias quando a qualidade da água bruta é comprometida devido a lançamentos de águas residuais sanitárias e industriais, tratadas ou não, no manancial de abastecimento.

O tratamento de águas com alto grau de turbidez e cor verdadeira é possível pelo uso do processo de decantação ou flotação, onde, respectivamente, os flocos formados pela coagulação sedimentam no fundo do decantador ou flutuam na superfície da água no flotador. Estes processos permitem a remoção de grande parte das partículas suspensas no efluente, aumentando a eficiência do processo de filtração [31].

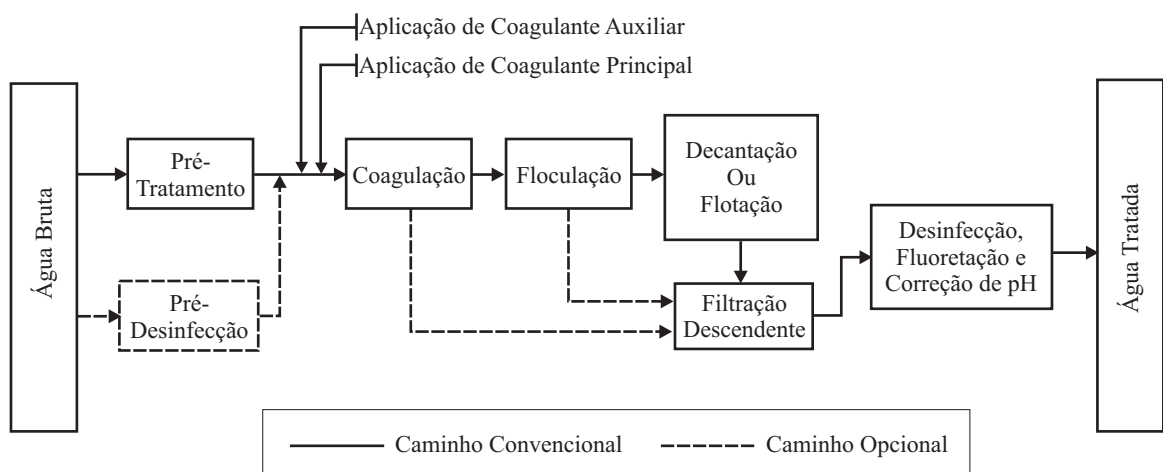


Figura 2.7 – Sequência de Processos da Tecnologia de Tratamento Completo.

Fonte: Bernardo, L. D., Ângela D. B. (2005)

Em mananciais com água bruta de baixa turbidez, cor verdadeira alta e/ou elevada concentração de algas, os flocos formados tem baixa velocidade de sedimentação, o que pode provocar sobrecarga de sólidos nos filtros e baixa eficiência de filtração. Neste caso é recomendado o uso de técnicas de flotação ao invés de decantação. A flotação utiliza o princípio da injeção, no fundo do flotador, de bolhas de ar dissolvidas em água sob alta pressão que deslocam os flocos para a superfície, de onde são removidos por processos mecânicos de rastelo [31].

A Figura 2.8 mostra o esquema básico de uma ETA de tratamento completo com flotor.

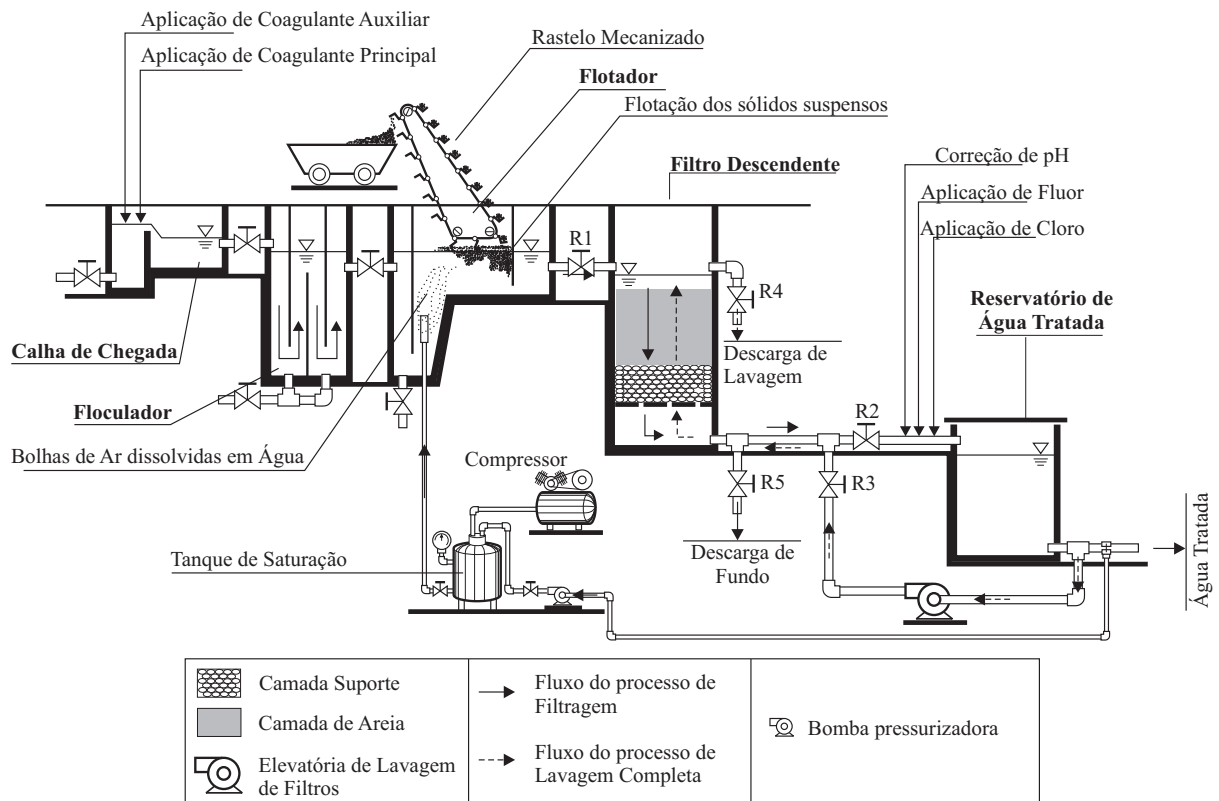


Figura 2.8 – Esquema básico de uma ETA de Tratamento Completo com Flotador (sem Pré-tratamento).
Fonte: Do Autor

Se a qualidade da água bruta em ETAs de tratamento completo enquadrar-se, mesmo sazonalmente, dentro dos limites determinados pela Tabela 2.11, os caminhos opcionais ilustrados na Figura 2.7 poderão ser utilizados. Nisto, a planta de tratamento completo é adaptada para uma planta de filtração rápida descendente. Neste procedimento, ocorre o direcionamento da água coagulada ou da água floculada diretamente para os filtros, sem passar pelo processo de decantação, possibilitando significativa redução do consumo de produtos químicos no processo de coagulação [1].

2.3. O PROCESSO DE COAGULAÇÃO QUÍMICA

A água bruta contém uma variedade de impurezas, destacando-se as partículas coloidais, substâncias húmicas e microorganismos em geral [1]. Parâmetros tais como a cor verdadeira [30], turbidez, sabor, odor e diversos tipos de contaminantes orgânicos e inorgânicos presentes na água estão, geralmente, associados às partículas suspensas ou dissolvidas [32].

A remoção destas impurezas dá-se através de coagulação química, através de dosagem de sais de alumínio e ferro (coagulantes). A coagulação é o resultado de dois fenômenos: (i) formação de espécies hidrolisadas com carga positiva e, (ii) contato entre as espécies hidrolisadas e as impurezas presentes na água [1].

O primeiro fenômeno é caracterizado pela reação entre o coagulante e a água. No segundo fenômeno, o contato das cargas hidrolisadas positivas com as partículas de impurezas provoca a neutralização de parte da carga superficial destas, provocando uma desestabilização [33] que promove a aglomeração (coagulação) das impurezas, facilitando sua remoção através de sedimentação, flotação ou filtração rápida.

O nível de coagulação pode ser medido através do parâmetro Potencial Zeta, que mede a carga elétrica da superfície das impurezas [32]. Uma técnica alternativa e de custo relativamente mais baixo para a medição do nível de coagulação, é o monitoramento da corrente de fluxo nas superfícies das impurezas, valor diretamente relacionado com o Potencial Zeta [34].

Os principais mecanismos de coagulação são: (i) Compressão da Dupla-Camada (Camada Difusa); (ii) Neutralização de Cargas; (iii) Formação de Pontes e (iv) Varredura [33]. O mecanismo mais adequado para as tecnologias de tratamento por filtração rápida é o mecanismo de Neutralização de Cargas, por não formar flocos grandes e sim partículas desestabilizadas para serem retidas no filtro [32].

Uma informação relevante para este trabalho é que o ponto ótimo de coagulação, caracterizado pela neutralização das cargas superficiais das partículas coloidais (Potencial Zeta está próximo de Zero), depende do pH da água da mistura (água coagulada) [35].

2.4. A ETA GAVIÃO

A ETA Gavião é uma estação de tratamento completo com decantação, que opera na configuração de filtração rápida descendente, em vista da qualidade da água bruta enquadrar-se nos limites estabelecidos na Tabela 2.11.

As Figuras 2.9 e 2.10 ilustram fotos das principais etapas e equipamentos constituintes do processo de tratamento da ETA. As etapas do processo de tratamento são apresentadas na planta geral de lay-out e no esquema de funcionamento da ETA Gavião (Anexo A).



(a)



(b)



(c)



(d)




(e)



(f)



(g)



(h)

Figura 2.9 – (a) Vista Geral da ETA Gavião; (b) Barragem; (c) Torre de Captação Gravitacional; (d) Floculadores; (e) Decantadores; (f) Decantador em Manutenção; (g) Mesa de Comando dos Filtros e Vista dos Filtros ao Fundo; (h) Vista Interna da Sala de Comando dos Filtros.

Fonte: CAGECE (2011)



(a)



(b)



(c)



(d)



(e)



(f)



(g)



(h)

Figura 2.10 – (a) Filtro em Operação; (b) Filtro em Processo de Lavagem; (c) Elevatória de Lavagem de Filtros; (d) Bombas da Elevatória de Lavagem de Filtros; (e) Vista Superior do Reservatório Apoiado de Água Tratada; (f) Elevatória de Água Tratada Gavião Novo; (g) Conjunto Motor Bomba do Gavião Novo; (h) Subestação.

Fonte: CAGECE (2011)

O processo de coagulação química consiste na aplicação de coagulante principal PAC e de coagulante auxiliar Polímero Catiônico através de bombas dosadoras [36]. As demais etapas do processo de tratamento da ETA Gavião são listadas abaixo [37]:

- Pré-oxidação: aplicação de Dióxido de Cloro na câmara de mistura rápida, para eliminação de microorganismos que poderiam prejudicar a eficiência da filtração;
- Fluoretação: aplicação de Ácido Fluossilisico ou Fluossilicato de Sódio na câmara de mistura rápida;
- Filtração: A estrutura de filtração é composta de 16 filtros descendentes de alta taxa de filtração, que perfazem um total de 2.240 m² de área filtrante;
- Desinfecção: Aplicação de Cloro Gasoso no canal de água filtrada, na saída dos filtros.

2.5. O ATUAL SISTEMA DE DOSAGEM DE COAGULANTES

2.5.1. DETERMINAÇÃO DA VAZÃO DE DOSAGEM

O controle da coagulação química existente na ETA Gavião é manual, através da atuação de operador humano, e tem como objetivo principal manter a turbidez da água produzida dentro do padrão exigido pela Portaria 518 [24, 38].

Os valores referenciais das vazões de dosagem (em L/h) de PAC e Polímero Catiônico são determinados através da Equação 2.1 [1, 36], onde Q é a vazão da ETA (em m³/h), D é a dosagem desejada do coagulante na água bruta (em mg/L), a fim de se obter coagulação dentro de uma faixa aceitável, e C é a concentração da solução de coagulante a ser aplicada.

$$q_d = \frac{Q \times D}{10 \times C} \quad (2.1)$$

O valor da dosagem D é determinado por ensaios realizados na instalação piloto da ETA, podendo variar de acordo com a qualidade da água bruta a ser tratada [36]. Desta forma, torna-se necessário a realização de ensaios periódicos ou sempre que foram detectadas variações consideráveis na qualidade da água bruta.

No processo de tratamento da ETA Gavião os coagulantes principal e auxiliar aplicados têm concentração $C = 100\%$.

2.5.2. BOMBAS DOSADORAS E O ACIONAMENTO POR ROTAÇÃO VARIÁVEL

As bombas dosadoras utilizadas para aplicação dos coagulantes principal e auxiliar são de fabricação da NETZSCH, do tipo NEMO, de fluxo contínuo sem pulsação, cujas curvas são caracterizadas pela linearidade entre a vazão de recalque e a rotação da bomba [39, 40], conforme apresentado na Figura 2.11.




Figura 2.11 – Curvas características RPM x Vazão: (a) bomba dosadora de PAC, modelo 2NE20A; (b) bomba dosadora de Polímero Catiônico, modelo NMP11BY02S12B.

Fonte: NETZSCH (2011)

As curvas lineares das bombas permitem a operação com ajuste preciso das vazões de dosagem através da variação da rotação das bombas, individualmente, por meio de inversores de frequência.

A Figura 2.12 mostra a atual disposição das bombas dosadoras de PAC e POL, na casa de dosagem de coagulantes da ETA Gavião, bem como a vista interna do painel dos inversores de frequência utilizados no ajuste da vazão de dosagem.

Os inversores utilizados são do modelo CFW-10 [41], de fabricação WEG, ambos com interface frontal para ajuste de parâmetros e entrada analógica de corrente (4-20 mA) para controle remoto de rotação.



(a)



(b)



(c)



(d)

Figura 2.12 – (a) Tanques de Armazenagem de PAC; (b) Bombas Dosadoras de Polímero Catiônico (esquerda) e de PAC (direita) e Painel Inversor ao meio; (c) Bomba Dosadora de PAC; (d) Painel dos Inversores com Vista Interna dos Inversores CFW-10.

Fonte: CAGECE (2011)

2.5.3. AVALIAÇÃO DO CONTROLE MANUAL DE COAGULAÇÃO QUÍMICA

Os gráficos da Figura 2.13 mostram os históricos das vazões de dosagem de coagulantes e da turbidez de água tratada (parâmetro utilizado para medir a eficiência do processo de dosagem na ETA Gavião) entre janeiro de 2007 e dezembro de 2009 [38]. Para os gráficos apresentados, as variáveis foram medidas a cada 2 horas.

Nota-se pela Figura 2.13b, conforme a Tabela 2.2, que o controle manual implementado na ETA é bem ajustado, atendendo ao exigido pela Portaria 518 [24], mantendo a turbidez da água tratada dentro dos padrões aceitáveis.




Figura 2.13 – Histórico mensal no período 2007 a 2009: (a) Vazões de Dosagem de PAC e POL; (b) Turbidez de Água Tratada.

Fonte: CAGECE (2010)

Para isto, a CAGECE mantém, durante as 24 horas, turnos de equipes constituídas de químicos laboratoristas e biólogos especializados, em trabalho contínuo, na realização de análises laboratoriais periódicas [38] dos parâmetros físicos, químicos e micro-biológicos de qualidade de água exigidos pela Portaria 518 [24], conforme as Tabelas 2.3 a 2.8. São realizadas análises periódicas (no máximo a cada 2 horas) não apenas na água tratada, mas também na água bruta, coagulada e filtrada, a fim de obter um ajuste ótimo nos processos de dosagem e operação do conjunto de filtros.

Porém, mesmo diante do bom ajuste do controle manual da ETA Gavião, o controle manual traz o inconveniente da resposta lenta às mudanças da qualidade da água bruta. Outro inconveniente é que o controle manual torna o sistema difícil de operar, exigindo a atenção constante da equipe de operação, expondo o sistema a falhas que podem acarretar desperdício de produtos químicos e eventuais quedas na qualidade da água tratada.

Estes problemas também podem ocorrer em ETAs de pequeno porte operadas manualmente. Portanto, é proposto na seção 2.7 a automação do processo de coagulação química com a utilização alternativa de RNAs, como alternativa à arquitetura convencional apresentada na próxima seção, com vistas a redução de custos de implantação, contribuindo para a viabilidade de implantação de sistemas deste tipo em ETAs de pequeno porte.

2.6. ARQUITETURA CONVENCIONAL PARA CONTROLE AUTOMÁTICO DE DOSAGEM DE COAGULANTES

A arquitetura convencional utilizada para o controle automático da dosagem de coagulantes em plantas de tratamento de água, no Brasil, é ilustrada na Figura 2.14.

Nesta arquitetura, a vazão de dosagem q (Equação 2.1), para os coagulantes principal e auxiliar, é determinada diretamente através de instrumentos de medição de nível de coagulação ou potencial zeta (monitor de coagulação) [34], não sendo necessária a realização de testes em instalações piloto para determinação da dosagem D (Equação 2.1). Em sistemas deste tipo, uma malha de controle é fechada entre os instrumentos de medição de nível de coagulação ou potencial zeta e as bombas dosadoras, que possuem entradas analógicas de controle. Os sinais de controle das vazões de dosagem são gerados, geralmente, por um controlador lógico programável.

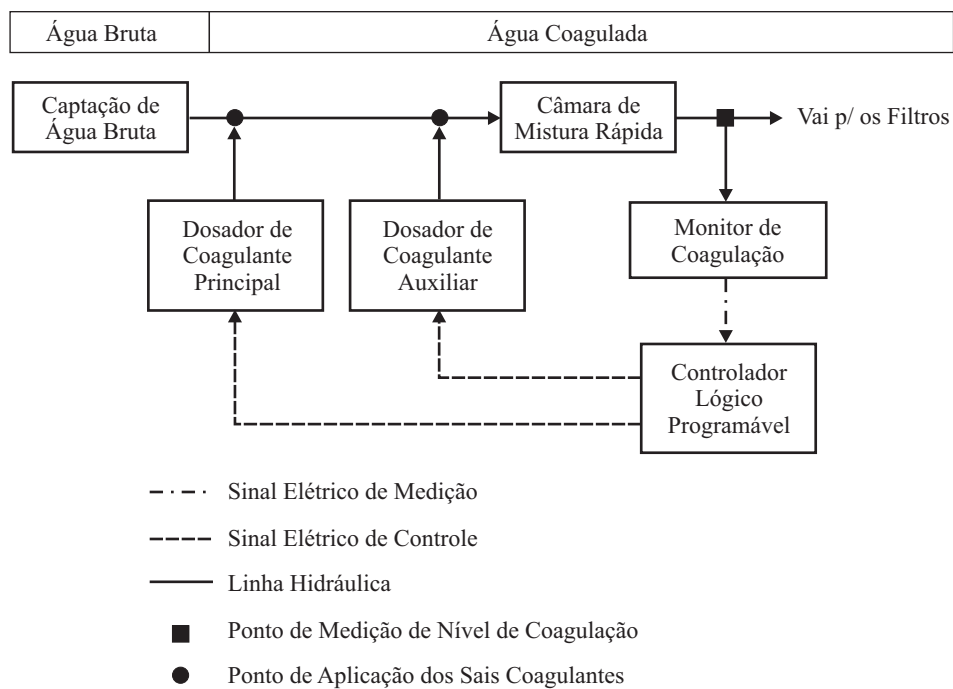


Figura 2.14 – Arquitetura convencional para controle automático de dosagem de coagulantes.

Fonte: Do autor

Esta arquitetura é bastante difundida no Brasil e produz bons resultados quanto à otimização do processo de dosagem, gerando economia de produtos químicos e melhoria da qualidade da água tratada final. A desvantagem é o elevado custo de implantação, conforme demonstrado na Seção 1.5, o que inviabiliza projetos deste tipo em ETAs de pequeno porte.

2.7. PROPOSTA DE UM MODELO NEURAL PARA INFERÊNCIA DOS SINAIS DE CONTROLE DE DOSAGEM DE COAGULANTES

Com o objetivo de propor uma solução alternativa à arquitetura convencional de controle de dosagem de coagulantes, é proposto o desenvolvimento de um modelo baseado em RNAs para inferência dos sinais de controle de dosagem de coagulantes. O modelo foi desenvolvido tomando como base os dados operacionais de uma planta de filtração rápida de grande porte – a ETA Gavião – porém poderá ser utilizado em ETAs de filtração rápida de pequeno porte.

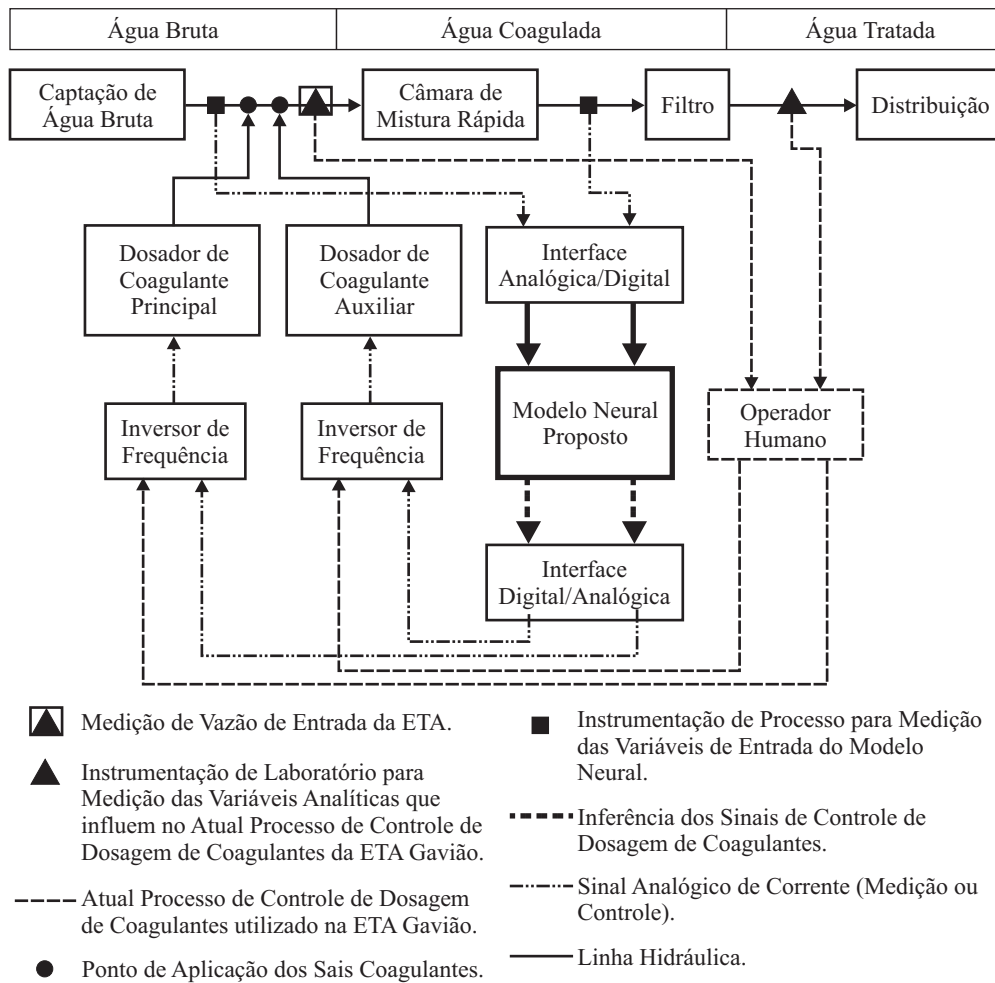


Figura 2.15 – Localização do Modelo Neural Proposto na Planta de Controle de Coagulação da ETA Gavião.

Conforme a Figura 2.15, o modelo terá como entrada, variáveis do processo que indicam a qualidade da água bruta e da água coagulada, medidas por instrumentação de baixo custo, tendo como saída a inferência direta dos sinais de controle de dosagem de coagulantes.

2.7.1. O MODELO

O controle de uma planta ou processo pode ser classificado como uma tarefa de aprendizagem [42], pois em sua operação produz ações (saídas) que atuam no sistema e que dependem de um estímulo de entrada a partir de variáveis extraídas do processo. Isto torna possível o uso de RNAs em tarefas de controle, em substituição aos sistemas convencionais, ou em aplicações paralelas para melhoria do desempenho dos mesmos.

A Figura 2.15 mostra um bloco representativo do modelo neural proposto e sua localização na planta do processo de controle de coagulação da ETA Gavião. A referida Figura dá ênfase ao controle manual da coagulação química, conforme explicado na Seção 2.5. A intervenção do operador humano consiste no ajuste manual da vazão de dosagem dos coagulantes principal e auxiliar, variando-se da rotação das bombas dosadoras por meio de inversor de frequência. A atuação do modelo neural possibilitará a automatização deste processo, pois os sinais de controle de dosagem inferidos serão aplicados nas entradas analógicas de controle dos inversores de frequência existentes, proporcionando o ajuste da vazão das bombas dosadoras.

O aprendizado do modelo neural proposto é representado de forma básica na Figura 2.16, constituindo no ajuste dos parâmetros livres do modelo para aproximação da função $F(\cdot)$ à função $f(\cdot)$, que descrevem o mapeamento entrada-saída do modelo neural e do sistema de controle a ser modelado (existente), respectivamente.

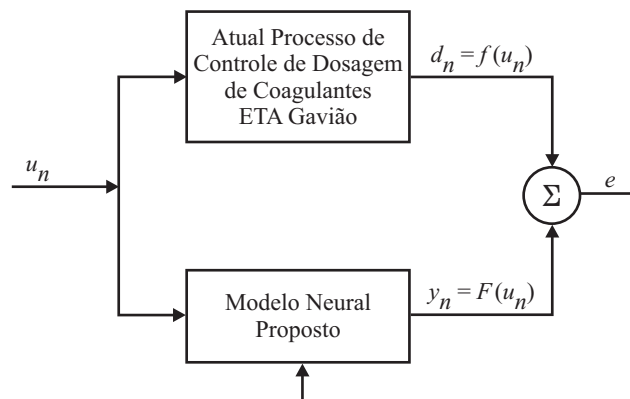


Figura 2.16 – Aprendizado Supervisionado do modelo proposto.
Desenho do Autor

O aprendizado é realizado por meio da apresentação dos pares de treinamento entrada-saída $\{u_n, d_n\}$, retirados do banco de dados histórico do processo modelado [36, 38]. O termo e é o sinal de erro entre o sinal de saída real d_n e o inferido y_n , utilizado no processo de aprendizagem para ajuste dos parâmetros livres da RNA do modelo neural.

Os resultados obtidos demonstram que o modelo proposto poderá ser aplicado para automatização do processo de controle de coagulação química na ETA Gavião, apresentando a possibilidade de garantia da qualidade da água tratada dentro dos padrões estabelecidos pela portaria 518/2004 [24]. A validação da aplicação do modelo proposto, também contribuirá com a redução de custos de implantação de sistemas convencionais de controle automático para dosagem de coagulantes em plantas de tratamento, em vista do custo elevado de implantação, viabilizando projetos desta natureza em ETAs de pequeno porte.

3. REDES NEURAIIS ARTIFICIAIS SUPERVISIONADAS DINÂMICAS

Este capítulo tem como objetivo a apresentação básica da teoria de RNAs, dando ênfase às RNAs supervisionadas dinâmicas, que serão utilizadas na implementação do modelo neural proposto. Os algoritmos de treinamento utilizados serão descritos no capítulo 4.

3.1. REDES NEURAIIS ARTIFICIAIS

A característica chave das RNAs é sua capacidade de aprender a partir de um conjunto de dados apresentado à mesma, que caracteriza uma tarefa realizada por um determinado processo a ser modelado. A aprendizagem das RNAs é caracterizada pelo ajuste dos parâmetros livres (pesos das conexões sinápticas) a fim de proporcionar uma resposta condizente com o conjunto de dados apresentado, os quais devem ser representativos da tarefa que a RNA deve aprender.

O poder de aprendizado das RNAs é claramente visível na sua capacidade de auto-organização, de processamento temporal e de responder a estados desconhecidos do ambiente (generalização), dentro das expectativas desejadas. Isto torna as RNAs excelentes mapeadores universais e ferramentas poderosas para solução de problemas complexos [43], como a modelagem de sistemas lineares e não-lineares.

Em geral, as RNAs podem ser classificadas em dois tipos, quanto ao paradigma de aprendizagem: (1) aprendizagem supervisionada (com professor) e (2) aprendizagem não-supervisionada (sem professor). A Figura 3.1 mostra um esquema ilustrativo do paradigma de aprendizagem supervisionada.

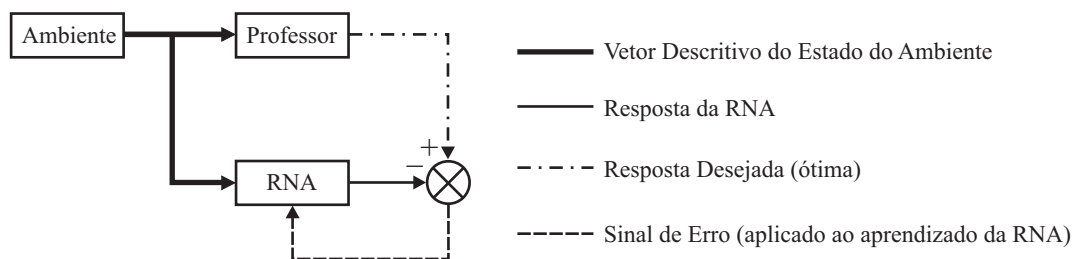


Figura 3.1 – Diagrama Representativo da Aprendizagem Supervisionada.

Fonte: do autor.

Neste paradigma de aprendizagem há a presença de um professor (ou supervisor) que tem conhecimento sobre os estados do ambiente, porém o ambiente é desconhecido pela RNA. Um vetor descritivo do estado do ambiente é apresentado à RNA e ao professor,

estimulando-os a apresentarem respostas condizentes com o estado apresentado. Por não conhecer o ambiente, a RNA não dará de imediato uma resposta condizente com a realidade do mesmo. Por sua vez, o professor dará uma resposta ótima (saída desejada para a RNA) devido seu conhecimento prévio do ambiente [42].

Considerando um passo iterativo n do processo de ajuste dos pesos sinápticos (treinamento) e as respostas do professor e da RNA como grandezas escalares, será gerado um sinal de erro conforme a Expressão 3.1, onde d é a resposta do professor (ou saída desejada) e y é a resposta (ou saída) da RNA.

$$e(n) = d(n) - y(n). \quad (3.1)$$

Este sinal de erro é então utilizado num processo de ajuste dos pesos sinápticos da RNA, através do algoritmo de aprendizado, com o objetivo de fazer a rede emular o professor. Após sucessivas apresentações dos pares (estado do ambiente, saída desejada), quando a emulação torna-se ótima num sentido estatístico, pode-se afirmar que o conhecimento do professor a respeito do ambiente foi assimilado pela RNA da forma mais completa possível. Neste momento, supõe-se que a RNA “aprendeu” o mapeamento entre os estados do ambiente e as saídas desejadas, podendo a mesma interagir com o ambiente sem o auxílio do professor.

Na aprendizagem não-supervisionada, as regularidades dos estímulos de entrada são extraídos pela rede de forma autônoma, tornando estas arquiteturas mais próximas ao cérebro humano. A extração de tais regularidades dá-se através dos mecanismos de competição e correlação. Na competição, os componentes da estrutura neural competem entre si pelo direito de responder a um determinado estímulo de entrada. Na correlação, os componentes da estrutura neural se auto-organizam de forma a apresentar uma informação relevante ao estímulo dado [44]. O mecanismo de correlação é também chamado de aprendizado hebbiano [45].

Na Seção seguinte será apresentada uma descrição básica sobre RNAs estáticas, que são a estrutura básica das RNAs dinâmicas, que serão descritas na Seção 3.3.

3.2. REDES NEURAIS ARTIFICIAIS ESTÁTICAS

As RNAs possuem a propriedade de armazenar conhecimento experimental e usá-lo na realização de tarefas complexas, apresentando vantagens tais como [42]: (1) resolução de problemas cujas saídas são geradas por sistemas físicos não-lineares; (2) mapeamento de entrada-saída; (3) capacidade de adaptação a modificações sofridas pelo ambiente; e (4) tolerância a falhas.

Estas vantagens dão-se principalmente pela natureza distribuída do processamento da informação armazenada na rede. Outra vantagem geral das redes neurais é a uniformidade de análise de projeto, caracterizada pela universalidade do modelo de neurônios utilizados, o que facilita o compartilhamento de algoritmos de treinamento e modularidade na montagem de redes em diferentes aplicações [42].

Uma rede neural estática, como toda rede neural supervisionada, conforme a Figura 3.1, necessita de um conjunto de informações que forneça as características do problema a ser resolvido. Este conjunto de informações é constituído de um par de vetores $\{\mathbf{u}(n), \mathbf{d}(n)\}$, onde $n = 1, 2, \dots, N$, é um passo iterativo no processo de ajuste dos pesos sinápticos e N é o número de pares apresentados à RNA, $\mathbf{u}(n) \in \mathbb{R}^{(p+1)}$ é o vetor de entrada no passo iterativo n , e $\mathbf{d}(n) \in \mathbb{R}^m$ é o vetor de saídas desejadas, ou seja, conhecidas e indicadas pelo professor (supervisor). No processo de aprendizado, a apresentação dos N pares de aprendizado $\{\mathbf{u}(n), \mathbf{d}(n)\}$, caracteriza uma época de treinamento.

A representação matricial dos pares de aprendizado é apresentada como:

$$\mathbf{u}(n) = \begin{bmatrix} u_0(n) \\ u_1(n) \\ \vdots \\ u_p(n) \end{bmatrix}, \quad \mathbf{d}(n) = \begin{bmatrix} d_1(n) \\ d_2(n) \\ \vdots \\ d_m(n) \end{bmatrix}, \quad (3.2)$$

sendo: p a quantidade de entradas e m a quantidade de saídas desejadas.

Ao vetor $\mathbf{u}(n)$ é acrescentado mais um elemento, o elemento u_0 , que não é propriamente uma variável de entrada e tem valor fixo para permitir o ajuste dos limiares de ativação dos neurônios, sendo denominado de *bias*. O valor fixado para o *bias* na maioria dos casos práticos, é -1 ou +1.

Como o par de vetores $\{\mathbf{u}(n), \mathbf{d}(n)\}$ caracteriza o problema, é válido afirmar que há uma relação $F(\cdot)$ entre eles, conhecida pelo supervisor. Desta forma,

$$\mathbf{d}(n) = F(\mathbf{u}(n)). \quad (3.3)$$

A rede neural não conhece a relação $F(\cdot)$, porém ajusta seus parâmetros livres (pesos sinápticos) através de um algoritmo de aprendizagem a fim de emular o comportamento desta relação, gerando um modelo aproximado de $F(\cdot)$ denominado de $\hat{F}(\cdot)$. A saída da rede neural no passo iterativo de treinamento n é então representada pela Expressão 3.4, sendo válida a

afirmação de que a rede neural gera em sua saída um vetor $\mathbf{y}(n)$ cujos elementos são próximos aos elementos de $\mathbf{d}(n)$.

$$\mathbf{y}(n) = \hat{\mathbf{F}}(\mathbf{u}(n)). \quad (3.4)$$

Desta equação, conclui-se que redes neurais alimentadas adiante são aproximadores universais de funções [46], capazes de aproximar mapeamentos contínuos ou descontínuos de entrada-saída não lineares, com precisão arbitrária. Este é o motivo pelo qual redes neurais alimentadas adiante obtiveram grande aceitação na resolução de problemas de reconhecimento de padrões e aproximação de funções [47]. Na próxima Seção, será apresentada a rede neural estática perceptron de múltiplas camadas (MLP), utilizada largamente em diversas aplicações [47] e que será aplicada neste trabalho como estrutura básica das redes neurais dinâmicas não-recorrentes e recorrentes.

3.2.1. PERCEPTRON DE MÚLTIPLAS CAMADAS

Neste trabalho, será utilizada como estrutura básica das redes neurais supervisionadas dinâmicas avaliadas, uma rede MLP com uma camada escondida e uma camada de saída, devido sua maior capacidade de generalização [48].

A Figura 3.2 mostra a arquitetura básica de uma MLP com uma camada escondida k de q neurônios e uma camada de saída l de um neurônio.

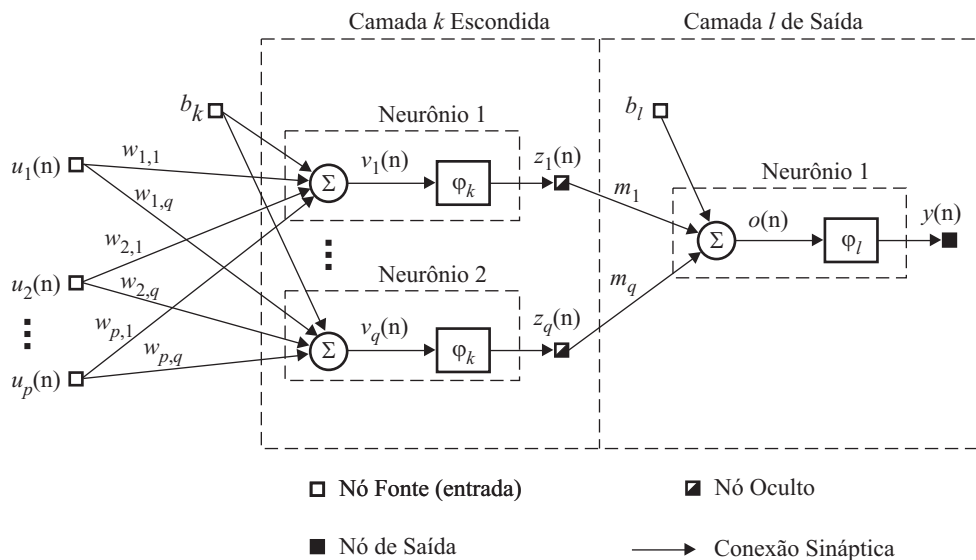


Figura 3.2 – Diagrama Esquemático Básico de uma MLP com uma camada escondida e uma camada de saída.
Fonte: Gomes, L. S. (2011).

O vetor de saídas da camada k é dado pela Expressão 3.5, onde $\varphi_k(\cdot)$ é a função de ativação de cada neurônio desta camada. No n -ésimo passo iterativo de treinamento, o termo $v_j(n)$, dado pela Expressão 3.6, representa o campo local induzido [42] no j -ésimo neurônio da camada k . O termo $w_{i,j}$ é o peso sináptico entre o i -ésimo nó de entrada e o neurônio j da camada escondida.

$$z_j = \varphi(v_j(n)), \quad j = 1, 2, \dots, q. \quad (3.5)$$

$$v_j(n) = \sum_{i=1}^p (w_{i,j} \times u_i(n)) + b_k, \quad j = 1, 2, \dots, q. \quad (3.6)$$

A saída $y(n)$ inferida pela rede, no n -ésimo passo iterativo de treinamento, é calculada através da Expressão 3.7, onde $\varphi_l(\cdot)$ é a função de ativação do neurônio da camada de saída l . Na Expressão 3.8, o termo $o(n)$ é o campo local induzido [42] no neurônio da camada de saída l . O termo m_j é o peso sináptico entre o j -ésimo neurônio da camada escondida k e neurônio da camada de saída l . O termo b_l é o bias da camada de saída.

$$y(n) = \varphi_l(o(n)). \quad (3.7)$$

$$o(n) = \sum_{j=1}^q (m_j \times z_j(n)) + b_l. \quad (3.8)$$

Uma visão geral do algoritmo de aprendizagem é explanada no Capítulo 5. Na Seção 3.2.2, a seguir, são descritas resumidamente os tipos de função de ativação mais usuais.

3.2.2. FUNÇÕES DE ATIVAÇÃO

FUNÇÃO DE LIMIAR

A função de limiar descreve a propriedade tudo-ou-nada do modelo de McCulloch e Pitts [49], sendo definida conforme a Expressão 3.9, onde v é o campo local induzido em um neurônio, conforme a Expressão 3.6.

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (3.9)$$

Às vezes é desejável que esta função tenha uma forma anti-simétrica em relação à origem, caracterizando uma função ímpar [42]. Esta nova forma é dada pela Expressão 3.10.

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (3.10)$$

FUNÇÃO LINEAR POR PARTES

Na função linear por partes, o valor de $\varphi(v)$ assume uma forma linear se o valor de v estiver no intervalo entre $-1/2$ e $+1/2$ [42], sendo dado pela Expressão 3.11.

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq +\frac{1}{2} \\ v + \frac{1}{2} & \text{se } +\frac{1}{2} > v > -\frac{1}{2} \\ 0 & \text{se } v \leq -\frac{1}{2} \end{cases} \quad (3.11)$$

FUNÇÃO SIGMÓIDE

A função sigmóide logística é dada pela Expressão 3.12, onde a é o termo de inclinação da função. Outra função sigmóide muito utilizada é a tangente hiperbólica, dada pela Expressão 3.13, onde b é uma constante.

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (3.12)$$

$$\varphi(v) = a \times \tanh(b \times v) \quad (3.13)$$

3.3. REDES NEURAS DINÂMICAS

Redes neurais dinâmicas são estruturas baseadas em uma rede neural estática, geralmente uma rede MLP, capazes de modelar a dinâmica de um processo caracterizado

geralmente por não-linearidade. Este modelamento é basicamente uma aproximação de funções conforme a Expressão 3.4 [47].

De forma geral, as RNAs dinâmicas tem sua utilização em aplicações que exigem tratamento de informações temporais, ou seja, processamento de padrões que evoluem no tempo [42]. Nestas aplicações, a resposta em um determinado instante de tempo, depende não somente do valor presente da entrada, mas também das entradas passadas, e em alguns casos das entradas e saídas passadas.

As RNAs dinâmicas são classificadas em dois tipos quanto à sua estrutura: (1) as que não possuem laços de realimentação, denominadas RNAs dinâmicas não recorrentes ou alimentadas adiante; e (2) as que possuem tais laços, denominadas RNAs dinâmicas recorrentes [47]. Estes dois tipos são apresentadas nas Seções seguintes.

3.3.1. REDES NEURAS DINÂMICAS NÃO RECORRENTES

A Figura 3.3 ilustra um diagrama em blocos de uma rede neural dinâmica não recorrente. No n -ésimo passo iterativo de treinamento, o sinal $\mathbf{u}(n)$ é o vetor que representa a informação passada do processo em atrasos de tempo determinados [50], extraído por uma estrutura denominada de memória de curto prazo.




Figura 3.3 – Diagrama de blocos de uma rede neural dinâmica não recorrente.

Fonte: do autor.

Neste trabalho iremos avaliar o uso de dois tipos de redes neurais dinâmicas não-recorrentes para a solução do problema proposto: (1) Rede Alimentada Adiante com Atraso de Tempo Focado e (2) Rede Alimentada Adiante com Atraso de Tempo Distribuído.

REDE ALIMENTADA ADIANTE COM ATRASO DE TEMPO FOCADO

Uma das características de processos dinâmicos [47] é que a resposta em um determinado instante de tempo depende não apenas da informação atual na entrada do processo, mas também de informações passadas [42]. Desta forma, para o modelamento de

processos dinâmicos através de RNAs, faz-se necessário a implementação de memórias de curto prazo, que ao serem excitadas pela informação ou estado atual, extraem informações passadas do processo.

A Figura 3.4 ilustra o esquema detalhado de uma Rede Alimentada Adiante com Atraso de Tempo Focado (FTLFN, *Focused Time Lagged Feedforward Network*) [42], constituída de uma rede neural MLP com uma camada escondida de q neurônios e uma camada de saída de 1 neurônio, equipada com uma memória de curto prazo de linha de atraso derivada de ordem t , conforme a arquitetura ilustrada na Figura 3.3. Para simplificar o esquema, considera-se que em cada neurônio representado, está embutido o modelo geral de um neurônio, conforme a Figura 3.2.

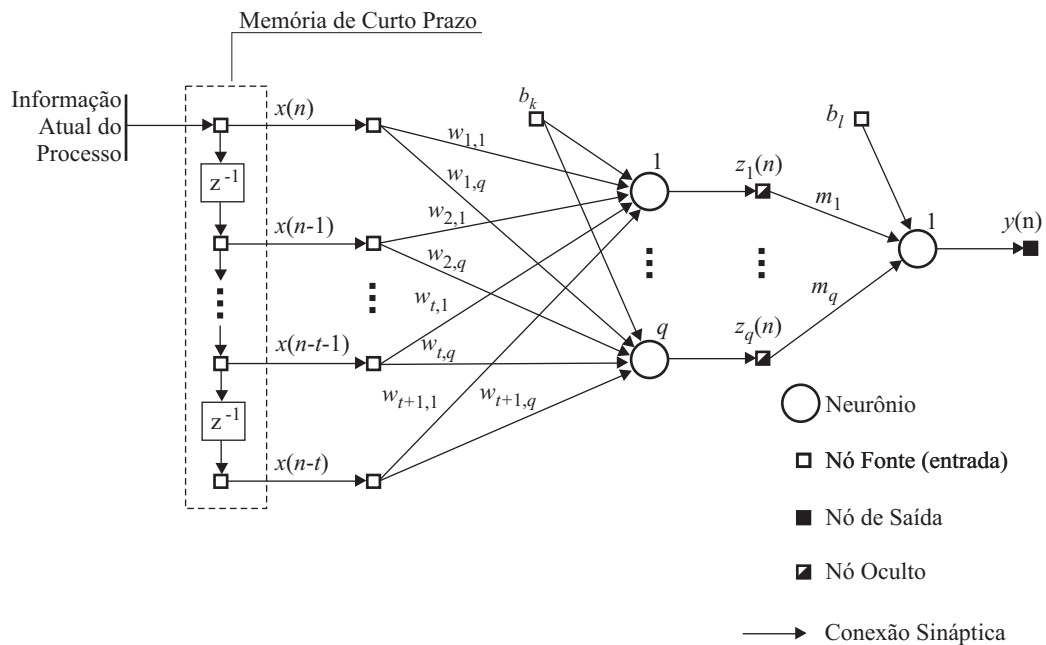


Figura 3.4 – Diagrama de blocos de uma rede neural dinâmica não recorrente.
Fonte: do autor.

Da Figura 3.4, considerando-se o n -ésimo passo iterativo de treinamento, o padrão de entrada apresentado à entrada da rede é dado pelo vetor da Expressão 3.14.

$$\mathbf{u}(n) = [x(n) \quad x(n-1) \quad \dots \quad x(n-t)]. \quad (3.14)$$

A matriz \mathbf{W} e o vetor \mathbf{m} , pesos sinápticos que incidem nos neurônios da camada escondida k e no neurônio da camada de saída l , respectivamente, no n -ésimo passo iterativo de treinamento, são dados por:

$$\mathbf{W}(n) = \begin{bmatrix} w_{1,1} & \cdots & w_{1,q} \\ \vdots & \ddots & \vdots \\ w_{t+1,1} & \cdots & w_{t+1,q} \end{bmatrix}, \quad \mathbf{m}(n) = \begin{bmatrix} m_1 \\ \vdots \\ m_q \end{bmatrix}. \quad (3.15)$$

De forma matricial, a saída da FTLFN (Figura 3.4) será dada por:

$$y(n) = \varphi_l \left[\varphi_k \left[\mathbf{u}(n) \times \mathbf{W}(n) + b_k \right] \times \mathbf{m}(n) + b_l \right]. \quad (3.16)$$

De forma escalar temos:

$$y(n) = \varphi_l \left[\sum_{j=1}^q \left[\varphi_k \left(\sum_{i=1}^{t+1} [x(n-i+1) \times w_{i,j}(n) + b_k] \right) \times m_j + b_l \right] \right]. \quad (3.17)$$

Conforme o teorema do mapeamento míope universal [42, 51], o uso das FTLFNs é adequado somente a processos invariantes no tempo, ou seja: se $y(n)$ é a resposta da rede devido à entrada $x(n)$, a resposta $y(n-n_0)$ é devida à entrada $x(n-n_0)$, o que restringe a utilização das FTLFNs em diversas aplicações dinâmicas.

REDE ALIMENTADA ADIANTE COM ATRASADO DE TEMPO DISTRIBUÍDO

Uma forma de contornar a limitação do uso de FTLFNs em processos variantes no tempo é distribuir a influência implícita do tempo na estrutura da rede, através de uma Rede Alimentada Adiante com Atrasado de Tempo Distribuído (DTLFN, *Distributed Time Lagged Feedforward Network*) [42].

Isto é possível, pois o modelo dos neurônios da estrutura de uma DTLFN tem características espaço-temporais, baseados no modelo do filtro neural de múltiplas entradas, mostrado na Figura 3.6, onde é aplicado um conjunto de m_0 entradas características do processo: $\{x_1(n), x_2(n), \dots, x_{m_0}(n)\}$. Neste modelo, há m_0 blocos denominados Filtros FIR (*Finite Impulse Response* – Filtro de Resposta a Impulso de Duração Finita), cuja arquitetura é apresentada na Figura 3.5, que caracterizam sinapses primárias conectadas às m_0 entradas, responsáveis pela dimensão espacial do processamento [42]. Cada FIR é constituído por uma memória de curto prazo de ordem t , com $t+1$ sinapses denominadas sinapses secundárias, responsáveis pela dimensão temporal do processamento.




Figura 3.5 – Filtro de Resposta a Impulso Finito (FIR).
Fonte: Haykin (2001).

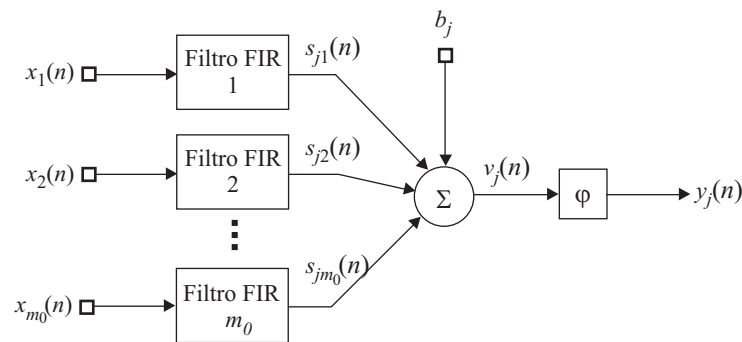


Figura 3.6 – Filtro Neural de Múltiplas Entradas.
Fonte: Haykin (2001).

Considerando o filtro neural de múltiplas camadas da Figura 3.6 como o j -ésimo neurônio da camada escondida da rede DTLFN, temos que sua saída no n -ésimo passo iterativo treinamento será dada por:

$$y_j(n) = \varphi \left(\sum_{i=1}^{m_0} s_{ji}(n) + b_j \right) \quad (3.18)$$

Onde, considerando a Figura 3.5, o termo $s_{ji}(n)$ é dado por:

$$s_{ji}(n) = \sum_{l=0}^t w_{ji}(l) \times x_i(n-l) \quad (3.19)$$

3.3.2. REDES NEURAIIS DINÂMICAS RECORRENTES

Uma rede neural dinâmica recorrente contém laços de realimentação que operam como uma memória de curta duração. As conexões recorrentes podem assumir as seguintes configurações [47]:

- Local: a saída de um neurônio é conectada na entrada dele mesmo;

- Não-Local: é um tipo especial de conexão local, porém é estabelecida entre neurônios distintos e da mesma camada;
- Global: neste caso, a saída de um neurônio de uma camada é conectada à entrada de um neurônio de uma camada anterior.

Neste trabalho iremos avaliar o uso de dois tipos de redes neurais dinâmicas recorrentes para a solução do problema proposto: (1) Rede Recorrente de Elman e (2) Rede Auto-Regressiva Não-Linear com Entradas Exógenas.

REDES RECORRENTES DE ELMAN

A Rede Recorrente de Elman (ERN, *Elman Recurrent Network*) [52] é uma rede neural, geralmente com uma camada oculta, onde as saídas desta camada são realimentadas através de uma estrutura de contexto constituída de atrasos unitários, responsável pela armazenagem das saídas da camada oculta por um passo de tempo [42]. Portanto, esta arquitetura possibilita o registro das ativações passadas da camada oculta, tornando-a apta para mapear padrões que evoluem no tempo [42, 53].

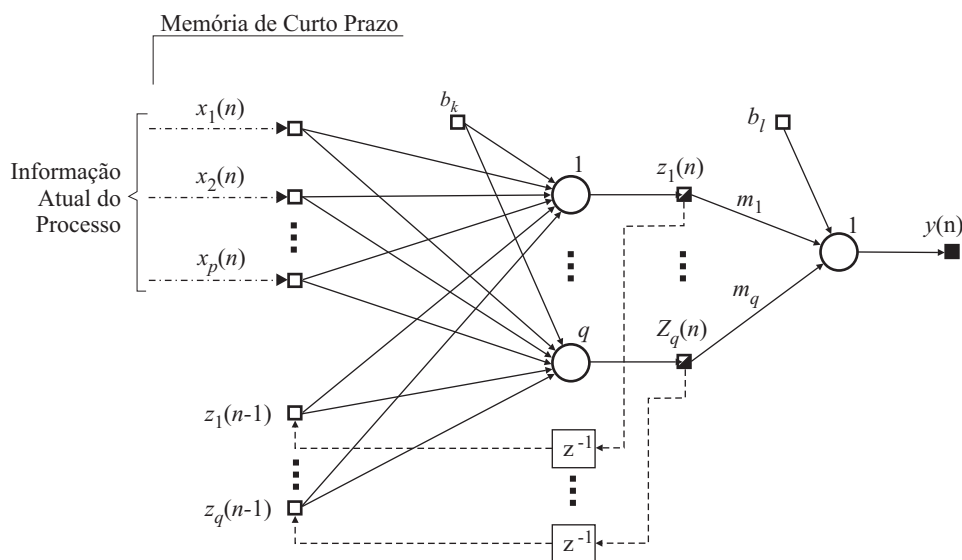


Figura 3.7 – Arquitetura geral de uma Rede Recorrente Elman.
Fonte: do autor.

A Figura 3.7 ilustra o esquema de uma ERN montada a partir de uma rede MLP com uma camada escondida de q neurônios e uma de saída de um neurônio. As funções de ativação geralmente utilizadas para os neurônios das camadas escondidas e de saída, são a tangente hiperbólica e linear, respectivamente – configuração que contribui na aproximação funções com precisão arbitrária [53].

Conforme a Figura 3.7, o vetor de entrada no n -ésimo passo iterativo de treinamento será dado pela Expressão 3.20, constituído de $(p+q)$ termos, onde p é a ordem dos padrões de entrada apresentados à rede e q é a quantidade de neurônios da camada oculta.

$$\mathbf{u}(n) = [x_1(n) \quad x_2(n) \quad \dots \quad x_p(n) \quad z_1(n-1) \quad z_2(n-1) \quad \dots \quad z_q(n-1)] \quad (3.20)$$

A matriz de pesos sinápticos será dada pela Expressão 3.21.

$$\mathbf{W}(n) = \begin{bmatrix} w_{1,1} & \dots & w_{1,q} \\ \vdots & \ddots & \vdots \\ w_{p+q,1} & \dots & w_{p+q,q} \end{bmatrix}. \quad (3.21)$$

Como a estrutura básica da ERN é uma rede MLP, a saída será calculada conforme a Expressão 3.16, resultando a forma escalar dada pela Expressão 3.22.

$$y(n) = \varphi_l \left[\sum_{j=1}^q \left[\varphi_k \left(\sum_{i=1}^{p+q} [u_i(n) \times w_{i,j}(n) + b_k] \right) \times m_j + b_l \right] \right], \quad (3.22)$$

com a Expressão 3.20 sendo reescrita da forma:

$$\mathbf{u}(n) = [u_1(n) \quad u_2(n) \quad \dots \quad u_{p+q}(n)]. \quad (3.23)$$

REDE AUTO-REGRESSIVA NÃO-LINEAR COM ENTRADAS EXÓGENAS

As redes auto-regressivas não-lineares com entradas exógenas (NARX, *Nonlinear Autoregressive with Exogenous Inputs*) [42] vem sendo utilizadas com sucesso em um amplo conjunto de aplicações de modelagem entrada-saída, demonstrando melhor desempenho que as RNAs recorrentes padrão, apresentando convergência mais rápida e maior capacidade de generalização [54]. Dentre estas aplicações citamos o modelamento de processos de troca de calor, tratamento de esgotos, transformação catalítica e refinamento de petróleo [55]. A Figura 3.8 ilustra o esquema básico de uma rede NARX.

Na Figura, no n -ésimo passo iterativo de treinamento, a saída $y(n)$ é dada pela Expressão 3.24, onde $F(\cdot)$ é uma função não-linear nos seus argumentos, e t e t_0 são os tamanhos das memórias de curto prazo aplicadas à entrada $x(n)$ e à saída $y(n)$.

$$y(n) = F(y(n-1), y(n-2), \dots, y(n-t_0), x(n), x(n-1), \dots, x(n-t)), \quad (3.24)$$

Com: $\mathbf{u}(n) = [y(n-1) \ y(n-2) \ \dots \ y(n-t_0) \ x(n) \ x(n-1) \ \dots \ x(n-t)]$,
 ou: $\mathbf{u}(n) = [u_1(n) \ \dots \ u_{t+t_0+1}(n)]$. (3.25)

De forma semelhante à Expressão 3.23, a saída da rede NARX será dada por:

$$y(n) = \varphi_l \left[\sum_{j=1}^q \left[\varphi_k \left(\sum_{i=1}^{t+t_0+1} [u_i(n) \times w_{i,j}(n) + b_k] \right) \times m_j + b_l \right] \right]. \quad (3.27)$$

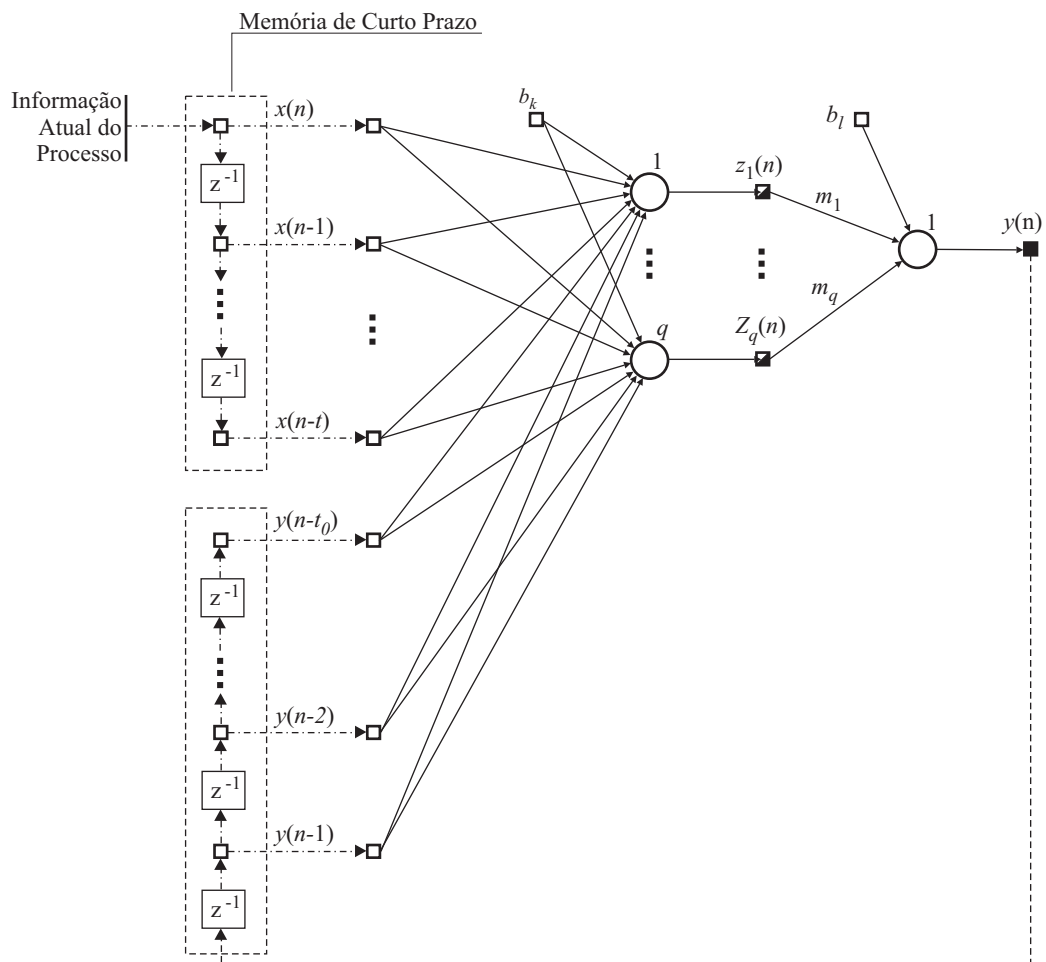


Figura 3.8 – Arquitetura geral de uma Rede Recorrente NARX.
 Fonte: do autor.

Os modelos neurais dinâmicos apresentados nesta Seção, bem como os apresentados na Seção 3.3.1, serão implementados no próximo Capítulo. Estes modelos serão posteriormente avaliados quanto a tarefa de realizar a inferência dos sinais de controle de dosagem de coagulantes em uma ETA por filtração rápida.

4. IMPLEMENTAÇÃO DOS MODELOS A SEREM AVALIADOS

Este Capítulo aborda a implementação dos modelos neurais dinâmicos apresentados no Capítulo anterior. A implementação seguiu três etapas [56]: (1) Seleção das variáveis de entrada; (2) Ajuste das variáveis de entrada selecionadas e (3) Seleção das estruturas dos modelos. Cada etapa é descrita com detalhes neste Capítulo.

Para o ajuste dos modelos foi utilizado um conjunto de dados históricos da ETA Gavião, cedidos pela CAGECE, correspondendo aos boletins de controle de dosagem de produtos químicos e análises dos parâmetros de qualidade da água bruta (Turbidez, pH, Cor e Oxigênio Consumido), no período de 2007 a 2009 [36, 38].

4.1. IMPLEMENTAÇÃO DOS MODELOS

4.1.1. SELEÇÃO DAS VARIÁVEIS DE ENTRADA

A etapa fundamental para o desenvolvimento de modelos de inferência é a análise crítica dos dados históricos que representam a dinâmica da planta avaliada, quanto às variáveis que influenciam as saídas (ou respostas) do processo [56].

Seguindo este fundamento, foram realizadas consultas aos especialistas que operam a planta da ETA Gavião, que concordaram com a literatura técnica quanto ao fato da dependência do desempenho do processo de coagulação química em relação ao pH [1, 33] de água bruta e coagulada, pHAB e pHAC respectivamente; e a turbidez [30] da água bruta e coagulada, TrbAB e TrbAC respectivamente. Tais variáveis foram selecionadas como candidatas a entradas para o modelo a ser implementado.

Como o objetivo desta dissertação é propor um modelo neural que possibilite a redução dos custos de implantação de sistemas de controle automático de dosagem de coagulantes, a redução da quantidade de instrumentos de medição (sensores que fornecem as variáveis de entrada ao modelo neural) é primordial. Desta forma, é aplicada na Seção 4.2.3 a estatística C_p de *Mallow* [57] para realizar uma seleção entre as variáveis candidatas elencadas acima, a fim de obter um modelo reduzido com o menor número de variáveis de entrada possíveis.

4.1.2. AJUSTE DAS VARIÁVEIS DE ENTRADA SELECIONADAS

A planta da ETA Gavião é controlada manualmente, o que torna o registro das variáveis de processo muito vulnerável à falhas. Por sua vez, falhas de registro provocam o

aparecimento de dados espúrios (*outliers*), que podem dificultar o processamento neural dos modelos, impossibilitando, em muitos casos, a convergência do ajuste dos parâmetros livres da rede [56]. Portanto, diminuir os efeitos provocados pela presença de *outliers* é primordial para o modelamento de qualquer processo. Isto é possível com a aplicação de técnicas de ajuste (suavização) robusto de dados, baseados em métodos de regressão resistentes à influência de *outliers*.

Será utilizada uma técnica de ajuste robusto denominada *RLoess* [58], que identifica e elimina a influência dos *outliers* presentes no conjunto de dados (variáveis candidatas como entrada) [59]. Para efeito explicativo nesta Seção, cada variável candidata será representada pelo vetor $\mathbf{x} = [x_1, x_2, \dots, x_\lambda]$. A técnica *RLoess* deriva do método de suavização por espalhamento local ponderado *Loess* (*locally weighted scatter plot smooth*) [60], que implementa regressão por polinômio linear ou quadrático.

A ponderação deste método de ajuste robusto é calculada conforme a Expressão 4.1, onde r_i é o residual do i -ésimo ponto ajustado $x_i \in \mathbf{x}$, e MAD é o desvio mediano absoluto do sinal residual dado pela Expressão 4.2, sendo \hat{y}_i o valor ajustado do ponto x_i . O ponto x_i é também denominado de variável preditora.

A identificação e eliminação da influência dos dados espúrios são possibilitadas através do termo $6 \times MAD$, que determina o intervalo de confiança de cada dado registrado [58].

$$\varpi_i = \begin{cases} \left[1 - \left(\frac{r_i}{6 \times MAD} \right)^2 \right]^2 & \text{se } |r_i| < 6 \times MAD \\ 0 & \text{se } |r_i| \geq 6 \times MAD \end{cases} \quad (4.1)$$

$$r_i = x_i - \hat{y}_i \quad (4.2)$$

Devido a Expressão 5.1 ser baseada no sinal residual, faz-se necessário um pré-ajuste dos dados através do método *Loess*. Conclui-se que, se o intervalo de confiança definido por $6 \times MAD$ for muito maior que o módulo do residual do i -ésimo ponto avaliado, o peso ϖ_i se aproximará da unidade, mantendo o dado ajustado conforme o pré-ajuste já realizado. Se o intervalo de confiança $6 \times MAD$ for muito menor ou igual ao módulo do residual do i -ésimo ponto avaliado, o peso ϖ_i será nulo, possibilitando a identificação do i -ésimo ponto avaliado como um *outlier*. Identificado o *outlier*, fica possível a eliminação de sua influência no ajuste do dado histórico.

Os gráficos mostrados na Figura 4.1, indicam a marcação dos outliers do conjunto de dados de entrada, registrados do ano de 2007 a 2009. No gráfico são visíveis, também, os intervalos de confiança determinados por $6 \times MAD$, em volta de cada ponto. Os dados cujos intervalos de confiança não tocam o eixo 0 horizontal são considerados espúrios [56], tendo sua influência eliminada do processo de ajuste, conforme a Expressão 4.1.

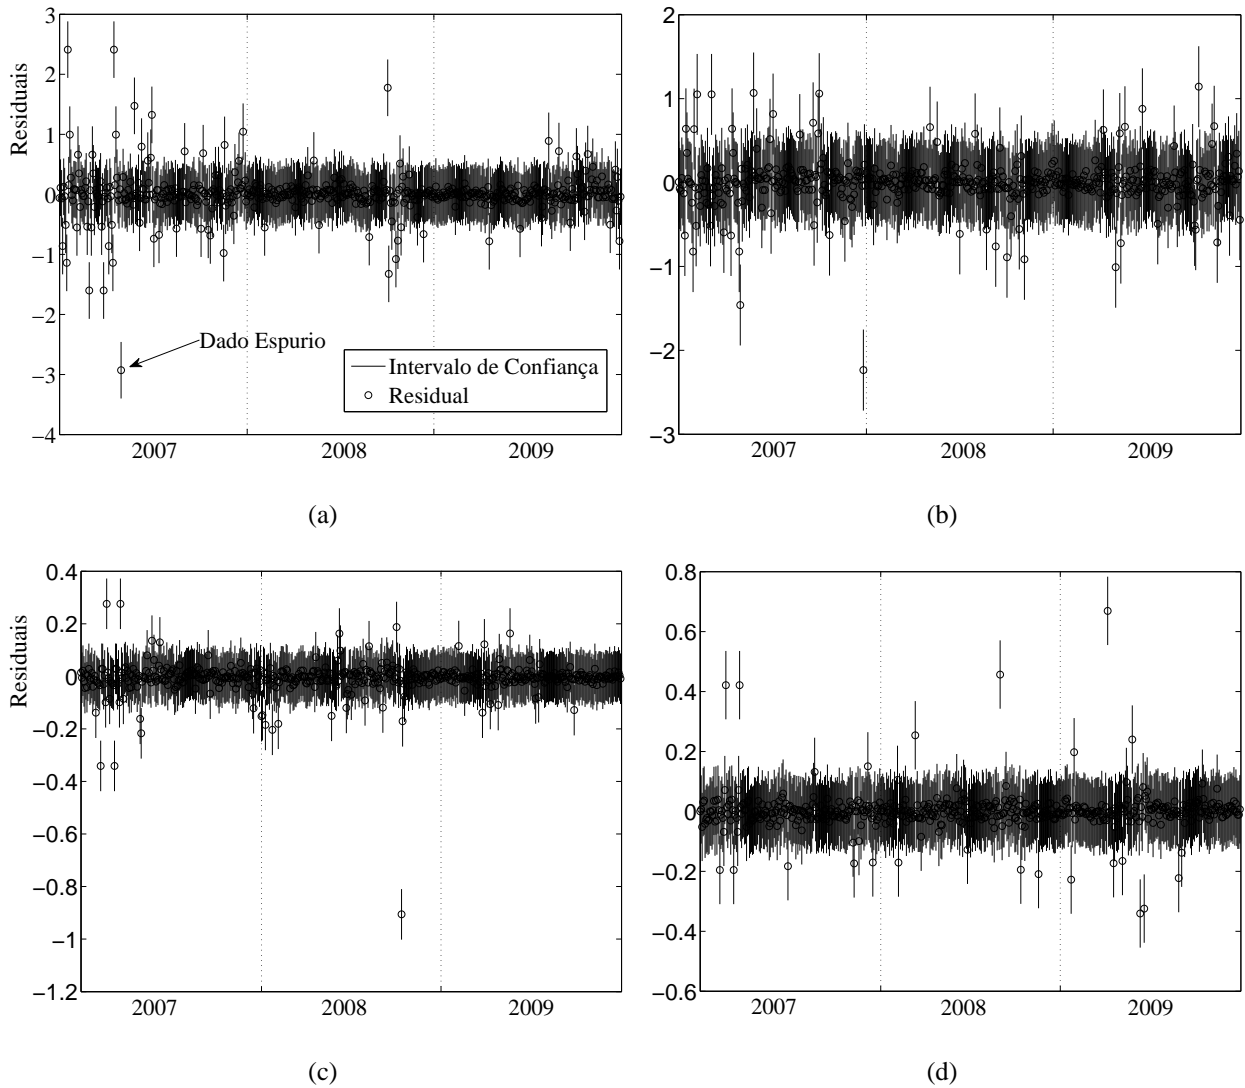


Figura 4.1 – Marcação dos *outliers* através dos intervalos de confiança do sinal residual: (a) Turbidez de Água Bruta; (b) Turbidez de Água Coagulada; (c) pH de Água Bruta; (d) pH de Água Coagulada.
Fonte: CAGECE (2010)

É mostrado na Tabela 4.1 o algoritmo de ajuste pelo método *RLowess* [58, 60] implementado nesta Dissertação. No algoritmo, y_i é o valor do ajuste (resposta) do ponto x_i . No caso desta aplicação, como o objetivo é implementar um ajuste em uma variável de processo registrada em um conjunto de dados, sem tomar outra variável como referência de predição à mesma, a resposta é a própria variável preditora, ou seja, $y_i = x_i$. Nisto, é válido

dizer que: $\exists \mathbf{y} \mid \mathbf{y} = \mathbf{x}$. Os dados ajustados que serão utilizados como entradas do modelo, em comparação com os dados registrados, são mostrados nos gráficos da Figura 4.2.

Tabela 4.1 – Algoritmo de Ajuste Robusto - *RLoess*.

1. Ajuste Preliminar dos dados através do método *Loess* [60]

- 1.1. Para cada ponto do conjunto de dados, calcular a distância entre a variável preditora x_i e seu vizinho mais próximo x_j :

$$dx_i(x_i, x_j) = \frac{x_i - x_j}{s_x}, \text{ com } i \neq j \quad (4.3)$$

sendo s_x o desvio padrão da amostra da variável preditora.

- 1.2. Para cada ponto do conjunto de dados, calcular a função de ponderação para uma determinada vizinhança do preditor x_i :

$$W_i = \begin{cases} (1 - u_i^3)^3 & \text{se } 0 \leq u_i \leq 1, \\ 0 & \text{se } 0 > u_i > 1 \end{cases}, \text{ com: } u_i = \frac{dx_i(x_i, x_j)}{h_k}, \quad (4.4)$$

sendo h_k a menor distância dx_i , para $i = 1, \dots, \lambda$.

- 1.3. Calcular os coeficientes β_0 e β_1 do polinômio linear do modelo de regressão local:

$$\beta_1 = \frac{\sum_{i=1}^{\lambda} W_i \times (x_i - \bar{x}) \times (y_i - \bar{y})}{\sum_{i=1}^{\lambda} W_i \times (x_i - \bar{x})}; \quad (4.5)$$

$$\beta_0 = \bar{y} - \beta_1 \times \bar{x}, \quad (4.6)$$

sendo \bar{x} e \bar{y} , as médias dos conjuntos de dados (vetores) \mathbf{x} e \mathbf{y} , respectivamente.

- 1.4. Calcular o valor ajustado de cada ponto x_i , através do polinômio linear (regressão local):

$$\hat{y}_i(x) = \beta_0 + \beta_1 \times x_i \quad (4.7)$$

2. Cálculo do sinal residual

- 2.1. Para cada ponto, calcular o residual conforme a Expressão 4.2.

3. Ajuste Robusto [58]

- 3.1. Calcular a ponderação robusta para cada ponto do conjunto de dados, considerando o sinal residual, conforme a Expressão 4.1;

- 3.2. Ajustar os dados novamente utilizando os pesos do ajuste robusto;

- 3.3. Repita os passos 3.1 e 3.2, por mais cinco vezes;

Fonte: Mason, R. L., Gunst, R. F., Hess, J. L. (2003); Curve Fitting Toolbox (2002).

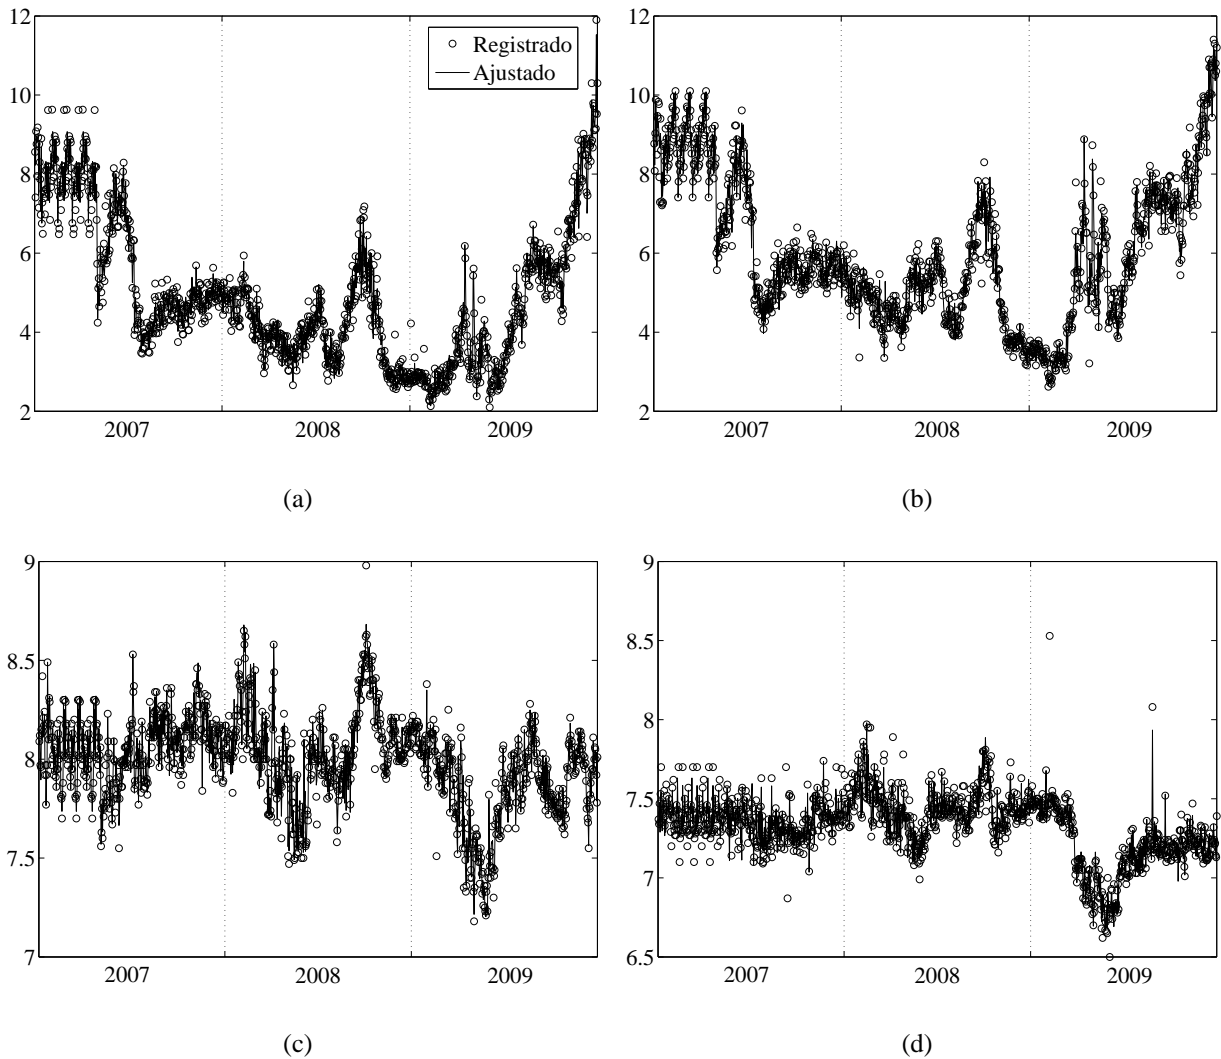


Figura 4.2 – Dados de Entrada Ajustados (período de registro: 2007 a 2009): (a) Turbidez de Água Bruta; (b) Turbidez de Água Coagulada; (c) pH de Água Bruta e (d) pH de Água Coagulada.

4.1.3. SELEÇÃO DAS ESTRUTURAS DOS MODELOS

Esta Seção abordará a seleção da estrutura de cada modelo neural, dinâmico não-recorrente e recorrente, elencado no Capítulo 4, quanto a: (1) estrutura básica (definição da rede neural estática); (2) quantidade de neurônios da camada escondida; (3) algoritmo de treinamento e (4) determinação dos atrasos e entradas. Ao final, serão resumidas as configurações selecionadas.

ESTRUTURA BÁSICA

Como especificado no Capítulo 3, a estrutura básica das redes neurais supervisionadas dinâmicas a serem avaliadas como modelo de inferência dos sinais de controle de dosagem de coagulantes, será uma rede do tipo MLP com uma camada escondida e uma camada de saída.

As funções de ativação utilizadas para a camada escondida e de saída foram a tangente hiperbólica e a linear, respectivamente. A utilização da tangente hiperbólica como ativação da camada escondida foi motivada pelo fato da mesma ser uma função ímpar, o que torna a convergência do treinamento mais rápida do que quando se utiliza a função logística [61].

Com o objetivo de obter maior precisão nos sinais inferidos pelos modelos, optou-se pelo desenvolvimento, para cada caso avaliado, de dois modelos distintos para inferência dos sinais de controle de dosagem de PAC e POL individualmente. Esta configuração permitirá a aplicação de diferentes combinações das entradas e atrasos nas entradas de cada rede, visto que o nível de dosagem de PAC e POL são influenciados distintamente em relação às variáveis de entrada selecionadas, otimizando o ajuste final de cada modelo [62]. A Figura 4.3 ilustra o diagrama de blocos do modelo proposto.

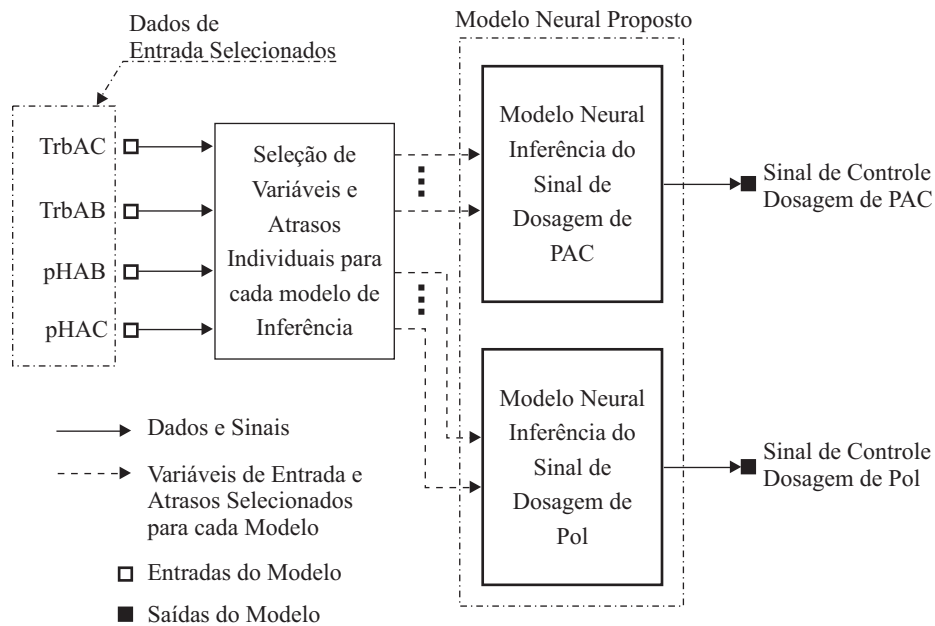


Figura 4.3 – Arquitetura geral do Modelo Neural Proposto para Inferência dos Sinais de Controle de Dosagem de PAC e POL.

Fonte: do autor.

QUANTIDADE DE NEURÔNIOS DA CAMADA ESCONDIDA

O número de neurônios da camada escondida de uma rede do tipo MLP depende de uma série de fatores, dentre os quais destacamos [61]: (1) Quantidade de dados disponíveis para treinamento e teste da rede; (2) Qualidade dos dados disponíveis para treinamento, quanto a presença de ruído, falhas de registro, erros de registro, etc.; (3) Quantidade de parâmetros ajustáveis da rede; (4) Nível de complexidade da aplicação a ser modelada, quanto a não-linearidade, descontinuidade, etc.

Alguns destes fatores, tais como a qualidade dos dados e o nível de complexidade da aplicação, não são totalmente controláveis, o que faz da determinação da quantidade de neurônios escondidos uma tarefa consideravelmente difícil. Devido a isto, os métodos para a determinação da quantidade de neurônios escondidos, na maioria dos casos, são baseados em tentativa e erro [61].

A determinação da quantidade de neurônios escondidos é de primordial importância para o desempenho do processamento da RNA. Como exemplo, uma quantidade elevada de neurônios na camada escondida promove bom desempenho nos testes com os dados de treinamento; porém, o resultado não será muito bom para testes com dados nunca vistos pela RNA. No outro extremo, uma RNA com poucos neurônios escondidos também não terá bom desempenho para testes com dados de treinamento. Daí a importância da busca do equilíbrio, ou da quantidade ideal de neurônios escondidos, que produzam bom desempenho tanto para dados de treinamento como para dados nunca vistos pela rede [61].

Nesta dissertação é proposto o uso da Expressão 4.8 [61, 63] para a determinação da quantidade de neurônios escondidos (q), onde N é o número de padrões de treinamento apresentados à rede, M é o número de saídas da rede. O parâmetro ε é o erro percentual máximo aceitável na etapa de teste da rede. Nesta dissertação, foi considerado $\varepsilon = 0.01$. O parâmetro p é o tamanho do padrão de entrada apresentado à rede.

$$q = \left\lceil \frac{\varepsilon \times N - M}{p + M + 1} \right\rceil. \quad (4.8)$$

O uso de tal equação é recomendado visto que considera não somente aspectos estruturais da rede, mas também aspectos indispensáveis ao bom desempenho do processamento da rede, tais como o erro máximo tolerado no teste e a quantidade de padrões disponíveis para treinamento [61].

ALGORITMO DE TREINAMENTO

O algoritmo de treinamento utilizado para todos os modelos avaliados foi o *Levenberg-Marquardt* devido sua convergência rápida [64]. Para cada modelo foram implementadas rotinas para inicialização de pesos sinápticos, configuração dos parâmetros de treinamento e normalização dos exemplos de entrada. Na época de treinamento n , a normalização do i -ésimo elemento de entrada $u_i(n)$, pertencente ao exemplo de treinamento $\mathbf{u}(n)$, dentro do intervalo $[-1, +1]$, foi implementada conforme a Expressão 4.9 [61, 65].

$$u_i^*(n) = 2 \times \left(\frac{u_i(n) - u_{\min}}{u_{\max} - u_{\min}} \right) - 1, \text{ com } u_{\min} = \min_{\forall n} \{\mathbf{u}\} \text{ e } u_{\max} = \max_{\forall n} \{\mathbf{u}\} \quad (4.9)$$

O conjunto de dados selecionado como entrada do modelo foi dividido em dois conjuntos: o primeiro, com 67% dos registros (8723 registros), e designado para treinamento; o segundo, com 33% dos registros (4320 registros), foi designado para os testes finais dos modelos. Os dados do conjunto de testes finais não foram apresentados às redes na fase de treinamento, e equivalem aos dados registrados para o ano de 2009. Os testes finais foram realizados mês a mês, considerando o ano de 2009, tomando como treinamento os 8723 registros anteriores.

O critério de parada utilizado foi o da Parada Prematura [61], conforme o método da Validação Cruzada [42], no qual o conjunto de treinamento é dividido em dois subconjuntos: o primeiro para o treinamento propriamente dito, com 70% dos registros do conjunto de treinamento; e o segundo para validação do treinamento, com 30% dos registros do conjunto de treinamento.

Na etapa de validação do treinamento, os pesos sinápticos ajustados na etapa de treinamento propriamente dito são utilizados para determinar a saída da rede devida aos exemplos do subconjunto de validação. O critério de parada é satisfeito quando o erro médio quadrático (*MSE*) (Expressão 4.10), na etapa de validação, assume uma tendência crescente. O ponto ótimo do treinamento é determinado pela época cujo *MSE* é mínimo.

Na época de treinamento τ , o *MSE* de uma RNA com um único nó de saída é calculado conforme a Expressão 4.10, sendo $e(n)$ o sinal residual entre a saída desejada (alvo do teste) e a saída inferida pelo modelo (Expressão 3.1) devida ao r -ésimo exemplo de treinamento apresentado à rede. O termo N é o número total de exemplos de entrada do subconjunto de validação.

$$MSE(\tau) = \frac{1}{2N} \sum_{n=1}^N e^2(n) \quad (4.10)$$

DETERMINAÇÃO DAS ENTRADAS, ATRASOS E NEURÔNIOS OCULTOS

Como a arquitetura geral do modelo neural proposto será composta de duas RNAs distintas para inferência dos sinais de controle de dosagem de PAC e POL (Figura 4.3), faz-se necessário uma seleção de variáveis, dentre as 4 variáveis candidatas elencadas na Seção

4.1.1, e de atrasos a serem aplicadas às mesmas distintamente, a fim de se obter um modelo que contenha o menor conjunto de variáveis de entrada para as duas RNAs [66].

Portanto, é proposto nesta dissertação a implementação de um modelo reduzido, que não utilize todas as variáveis candidatas como entrada do modelo. Isto trará benefícios quanto ao custo computacional do treinamento da RNA [42], bem como quanto à redução do custo financeiro para implantação física do modelo, visto que a redução das variáveis de entrada implica na redução da quantidade de instrumentos físicos de medição. Nisto, a implementação de um modelo reduzido contribuirá com a diminuição dos custos de implantação de sistemas automáticos de dosagem de coagulantes em ETAs de filtração rápida – um dos objetivos principais desta dissertação.

Para realizar esta tarefa de seleção para redução do modelo, será utilizada a estatística C_p de *Mallow* [57], indicada para aplicações em modelos não-lineares [56]. Esta estatística é uma medida da média quadrática total do erro para o modelo de inferência, calculada conforme a Expressão 4.11 [66].

$$C_p = \frac{SSR_p}{SSR} - (T - 2 \times p) \quad (4.11)$$

Nesta Expressão, SSR_p é a soma do quadrado dos residuais para o modelo reduzido, ou seja, o modelo cujo padrão de entrada possui p elementos, e SSR é a soma do quadrado dos residuais para o modelo total, ou seja, o modelo cujo padrão de entrada possui todos os T elementos possíveis [56].

A avaliação dos modelos reduzidos (com no máximo 3 variáveis de entrada) é feita através dos pares (p, C_p) mostrados nos mapeamentos das Tabelas 4.2 a 4.9. O modelo ótimo para cada caso é caracterizado pela proximidade do par (p, C_p) à reta $C_p = p$ [56], conforme ilustrado na Figura 4.4.

Em cada mapeamento, a quantidade dos neurônios da camada escondida das RNAs avaliadas (FTLFN, DTLFN, ERN e NARX), foi configurada conforme a Expressão 4.8, tendo sido considerado um máximo de seis atrasos para cada variável de entrada aplicada à RNA, e no caso do modelo NARX, aplicados também ao laço de realimentação da saída. Cada rede avaliada foi configurada como tendo: (1) uma camada escondida e uma de saída; (2) função de ativação tangente hiperbólica para os neurônios da camada escondida; (3) função de ativação linear para os neurônios da camada de saída; (4) treinamento pelo algoritmo *Levenberg-Marquardt*, com no máximo 1000 épocas, *MSE* mínimo no teste de 0.01, gradiente mínimo de 0.00001, e parada prematura.

Para todos os mapeamentos foi utilizado um total de 8640 registros como entrada de cada modelo avaliado, equivalente a dois anos de operação da planta. O motivo de tal metodologia tem como objetivo o desenvolvimento de um modelo caracterizado por um esforço computacional aceitável que solucione o problema num curto espaço de tempo com otimização do uso da memória, visto a aplicabilidade prática da solução.

A seguir, são mostrados os mapeamentos realizados, onde são indicados o par (p, Cp) que indicam a melhor configuração para cada modelo reduzido avaliado. Após a apresentação das tabelas, é mostrado na Figura 4.4 o mapeamento gráfico onde são visualizados a reta $Cp = p$ e os pontos referentes aos mapeamentos mostrados nas tabelas abaixo (nota: por conveniência e para facilitar a visualização, foram plotados nos gráficos apenas os pontos com estatística Cp positiva).

MAPEAMENTO ENTRADA-SAÍDA DO MODELO FTLFN

Tabela 4.2 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de PAC.

Atraso	x1	x2	x3	x4	x1x2	x1x3	x1x4
1	(2,-2.9)	(2,-3.2)	(2,-3.01)	(2,-3)	(4,0.83)	(4,1.09)	(4,1.14)
2	(3,-4.9)	(3,-5.16)	(3,-5.02)	(3,-5.04)	(6,0.87)	(6,1.32)	(6,1.15)
3	(4,-6.77)	(4,-7.06)	(4,-6.87)	(4,-6.9)	(8,0.9)	(8,1.39)	(8,1.03)
4	(5,-8.68)	(5,-9.1)	(5,-8.89)	(5,-8.76)	(10,0.95)	(10,1.33)	(10,1.08)
5	(6,-10.96)	(6,-11.26)	(6,-11.1)	(6,-10.99)	(12,0.7)	(12,1.04)	(12,0.83)
6	(7,-12.8)	(7,-13.12)	(7,-13.01)	(7,-12.81)	(14,0.98)	(14,1.09)	(14,0.9)
Atraso	x2x3	x2x4	x3x4	x1x2x3	x1x2x4	x1x3x4	x2x3x4
1	(4,0.8)	(4,0.82)	(4,0.9)	(6,4.88)	(6,4.91)	(6,5.04)	(6,4.82)
2	(6,0.98)	(6,0.97)	(6,1.01)	(9,6.79)	(9,6.92)	(9,7.11)	(9,6.83)
3	(8,0.91)	(8,0.94)	(8,0.99)	(12,9.1)	(12,9.06)	(12,9.1)	(12,8.94)
4	(10,0.88)	(10,0.94)	(10,1.01)	(15,10.98)	(15,10.92)	(15,11.19)	(15,10.92)
5	(12,0.83)	(12,0.72)	(12,0.75)	(18,12.7)	(18,13.19)	(18,12.92)	(18,12.71)
6	(14,0.82)	(14,0.86)	(14,0.86)	(21,14.93)	(21,14.92)	(21,15.18)	(21,14.81)

Para a Tabela considerar: **x1** = TrbAB; **x2** = TrbAC; **x3** = pHAB; **x4** = pHAC

Tabela 4.3 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de POL.

Atraso	x1	x2	x3	x4	x1x2	x1x3	x1x4
1	(2,-1.67)	(2,-3.35)	(2,-1.18)	(2,-0.75)	(4,0.77)	(4,1.6)	(4,2.26)
2	(3,-3.08)	(3,-4.79)	(3,-1.88)	(3,-3.14)	(6,0.7)	(6,2.22)	(6,1.97)
3	(4,-4.14)	(4,-7.1)	(4,-2.84)	(4,-2.94)	(8,1.14)	(8,3.84)	(8,2.5)
4	(5,-4.37)	(5,-8.91)	(5,-6.49)	(5,-7.01)	(10,0.86)	(10,2.09)	(10,2.2)
5	(6,-2.15)	(6,-7.71)	(6,2.78)	(6,2.53)	(12,4.47)	(12,11.17)	(12,10.88)
6	(7,-5.32)	(7,-13.16)	(7,-8.66)	(7,-9.84)	(14,0.98)	(14,3.2)	(14,2.11)
Atraso	x2x3	x2x4	x3x4	x1x2x3	x1x2x4	x1x3x4	x2x3x4
1	(4,0.87)	(4,0.73)	(4,2.19)	(6,4.89)	(6,4.38)	(6,5.39)	(6,4.88)
2	(6,0.47)	(6,1.04)	(6,2.43)	(9,6.66)	(9,6.8)	(9,7.83)	(9,8.01)
3	(8,1.43)	(8,1.36)	(8,2.63)	(12,9.12)	(12,9.02)	(12,11.51)	(12,9.51)
4	(10,0.87)	(10,0.97)	(10,2.84)	(15,10.82)	(15,10.74)	(15,12)	(15,11.54)
5	(12,5.39)	(12,6.99)	(12,12.58)	(18,16)	(18,13.3)	(18,18.5)	(18,14.05)
6	(14,2)	(14,1.04)	(14,2.32)	(21,14.57)	(21,15.24)	(21,17.25)	(21,15.22)

MAPEAMENTO ENTRADA-SAÍDA DO MODELO DTLFN

Tabela 4.4 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de PAC.

Atraso	x1	x2	x3	x4	x1x2	x1x3	x1x4
1	(2,-2.48)	(2,-2.67)	(2,0.34)	(2,-2.34)	(4,0.92)	(4,18.04)	(4,1.21)
2	(3,-4.38)	(3,-4.9)	(3,-4.83)	(3,-4.58)	(6,1.01)	(6,1.4)	(6,3.87)
3	(4,-6.88)	(4,-6.22)	(4,-7.09)	(4,-6.86)	(8,0.91)	(8,2.99)	(8,1.21)
4	(5,-8.42)	(5,8)	(5,-9.21)	(5,-8.92)	(10,0.7)	(10,1.1)	(10,0.83)
5	(6,-10.81)	(6,-10.68)	(6,-10)	(6,-6.6)	(12,0.98)	(12,1.26)	(12,1.17)
6	(7,-11.96)	(7,-9.69)	(7,-12.89)	(7,-9.99)	(14,1.36)	(14,1)	(14,1.41)
Atraso	x2x3	x2x4	x3x4	x1x2x3	x1x2x4	x1x3x4	x2x3x4
1	(4,0.99)	(4,1.17)	(4,1.04)	(6,5.01)	(6,4.96)	(6,5.49)	(6,5.06)
2	(6,1.14)	(6,1.26)	(6,1.94)	(9,7.06)	(9,7.39)	(9,7.73)	(9,7.04)
3	(8,0.95)	(8,0.9)	(8,0.86)	(12,8.81)	(12,9)	(12,9.22)	(12,8.86)
4	(10,1.29)	(10,0.7)	(10,0.74)	(15,10.63)	(15,10.77)	(15,10.91)	(15,10.72)
5	(12,0.9)	(12,1.23)	(12,29.49)	(18,12.76)	(18,13.07)	(18,13.07)	(18,13.22)
6	(14,1.01)	(14,1.26)	(14,1.13)	(21,14.93)	(21,17.2)	(21,15.2)	(21,14.85)

Tabela 4.5 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de POL.

Atraso	x1	x2	x3	x4	x1x2	x1x3	x1x4
1	(2,-0.01)	(2,-3.43)	(2,2.67)	(2,0.49)	(4,1.41)	(4,14)	(4,2.81)
2	(3,-5.62)	(3,-5.69)	(3,-5.2)	(3,-5.2)	(6,0.13)	(6,0.74)	(6,0.34)
3	(4,-2.13)	(4,-6.41)	(4,0.01)	(4,0.93)	(8,1.87)	(8,5.59)	(8,4.75)
4	(5,-8.03)	(5,-4.06)	(5,-5.92)	(5,-5.72)	(10,0.66)	(10,3.06)	(10,2.07)
5	(6,-7.22)	(6,-10.62)	(6,-5.62)	(6,-6.09)	(12,0.67)	(12,2.82)	(12,2.28)
6	(7,-8.46)	(7,-12.48)	(7,-9.1)	(7,-9.39)	(14,0.81)	(14,1)	(14,1.51)
Atraso	x2x3	x2x4	x3x4	x1x2x3	x1x2x4	x1x3x4	x2x3x4
1	(4,1.36)	(4,1.04)	(4,3.21)	(6,4.97)	(6,4.77)	(6,6.37)	(6,5.72)
2	(6,0.25)	(6,0.26)	(6,0.55)	(9,6.2)	(9,6.14)	(9,6.51)	(9,6.37)
3	(8,3.54)	(8,3.2)	(8,5.85)	(12,9.19)	(12,10.41)	(12,13.12)	(12,11.11)
4	(10,1.6)	(10,1.85)	(10,5.2)	(15,11.86)	(15,10.57)	(15,11.76)	(15,10.99)
5	(12,1.28)	(12,1.1)	(12,3.52)	(18,13.19)	(18,12.57)	(18,15.2)	(18,13.2)
6	(14,1.08)	(14,0.56)	(14,5.29)	(21,14.78)	(21,14.75)	(21,16.68)	(21,14.57)

MAPEAMENTO ENTRADA-SAÍDA DO MODELO ERN

Tabela 4.6 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de PAC.

Atraso	x1	x2	x3	x4	x1x2	x1x3	x1x4
0	(1,3)	(1,2.14)	(1,5)	(1,4.02)	(2,0.27)	(2,1.18)	(2,1.18)
Atraso	x2x3	x2x4	x3x4	x1x2x3	x1x2x4	x1x3x4	x2x3x4
0	(2,1.71)	(2,1.34)	(2,2.13)	(3,3.08)	(3,3.51)	(3,3.44)	(3,4.9)

Tabela 4.7 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de POL.

Atraso	x1	x2	x3	x4	x1x2	x1x3	x1x4
0	(1,2)	(1,0.42)	(1,3)	(1,10.41)	(2,1)	(2,3)	(2,7.98)
Atraso	x2x3	x2x4	x3x4	x1x2x3	x1x2x4	x1x3x4	x2x3x4
0	(2,5)	(2,6.6)	(2,4)	(3,2.87)	(3,4)	(3,2)	(3,1)

MAPEAMENTO ENTRADA-SAÍDA DO MODELO NARX

Tabela 4.8 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de PAC.

Atraso	x1	x2	x3	x4	x1x2	x1x3	x1x4
1	(3,-1.93)	(3,-1.94)	(3,-1.93)	(3,-1.92)	(5,2.02)	(5,2.02)	(5,2.11)
2	(5,-2.96)	(5,-3.03)	(5,-2.96)	(5,-2.89)	(8,3)	(8,2.95)	(8,2.98)
3	(7,-4.06)	(7,-4.07)	(7,-4.11)	(7,-3.91)	(11,3.94)	(11,3.89)	(11,3.86)
4	(9,-5.05)	(9,-5.03)	(9,-5.07)	(9,-5.03)	(14,4.98)	(14,5.03)	(14,5.04)
5	(11,-6.05)	(11,-6.05)	(11,-6)	(11,-6.04)	(17,6.05)	(17,6)	(17,5.93)
6	(13,-7)	(13,-6.97)	(13,-6.99)	(13,-7.14)	(20,7.06)	(20,7)	(20,7.02)
Atraso	x2x3	x2x4	x3x4	x1x2x3	x1x2x4	x1x3x4	x2x3x4
1	(5,2.03)	(5,2.05)	(5,2.05)	(7,6)	(7,6.1)	(7,6.06)	(7,6.04)
2	(8,3.12)	(8,2.98)	(8,3.06)	(11,8.94)	(11,8.99)	(11,9.01)	(11,9.09)
3	(11,4.03)	(11,3.94)	(11,3.94)	(15,11.95)	(15,11.9)	(15,11.93)	(15,12.09)
4	(14,4.96)	(14,5.09)	(14,4.94)	(19,14.96)	(19,15.05)	(19,15.06)	(19,15.16)
5	(17,6.04)	(17,6.06)	(17,6.03)	(23,18.01)	(23,18.03)	(23,18.01)	(23,18.04)
6	(20,7)	(20,7.02)	(20,7)	(27,20.86)	(27,21)	(27,20.99)	(27,20.85)

Tabela 4.9 – Mapeamento e avaliação do par (p, Cp) – Inferência do sinal de controle de dosagem de POL.

Atraso	x1	x2	x3	x4	x1x2	x1x3	x1x4
1	(3,-2.02)	(3,-2.04)	(3,-2.04)	(3,-1.99)	(5,1.98)	(5,1.96)	(5,2.03)
2	(5,-3)	(5,-2.98)	(5,-2.96)	(5,-2.94)	(8,3.1)	(8,3.05)	(8,3.13)
3	(7,-4.1)	(7,-4.03)	(7,-3.95)	(7,-4.06)	(11,3.99)	(11,4.07)	(11,4.05)
4	(9,-5.1)	(9,-5.01)	(9,-5.08)	(9,-5.01)	(14,5.03)	(14,4.95)	(14,5.01)
5	(11,-5.72)	(11,-5.97)	(11,-5.91)	(11,-5.98)	(17,6.15)	(17,6.06)	(17,6.12)
6	(13,-7.17)	(13,-7.2)	(13,-7.21)	(13,-6.82)	(20,6.91)	(20,6.89)	(20,6.91)
Atraso	x2x3	x2x4	x3x4	x1x2x3	x1x2x4	x1x3x4	x2x3x4
1	(5,1.98)	(5,1.99)	(5,1.99)	(7,6)	(7,6.05)	(7,5.98)	(7,5.97)
2	(8,3.08)	(8,3.04)	(8,3.02)	(11,9.01)	(11,9.02)	(11,8.99)	(11,9.07)
3	(11,4.07)	(11,3.99)	(11,3.99)	(15,12.07)	(15,12.1)	(15,12.04)	(15,12.09)
4	(14,4.89)	(14,5.03)	(14,4.89)	(19,14.99)	(19,14.93)	(19,14.97)	(19,14.97)
5	(17,6.07)	(17,5.97)	(17,6.03)	(23,18.01)	(23,17.99)	(23,18.11)	(23,18.4)
6	(20,6.81)	(20,6.88)	(20,6.96)	(27,21.01)	(27,20.9)	(27,20.79)	(27,20.9)

RESUMO GRÁFICO DOS MAPEAMENTOS

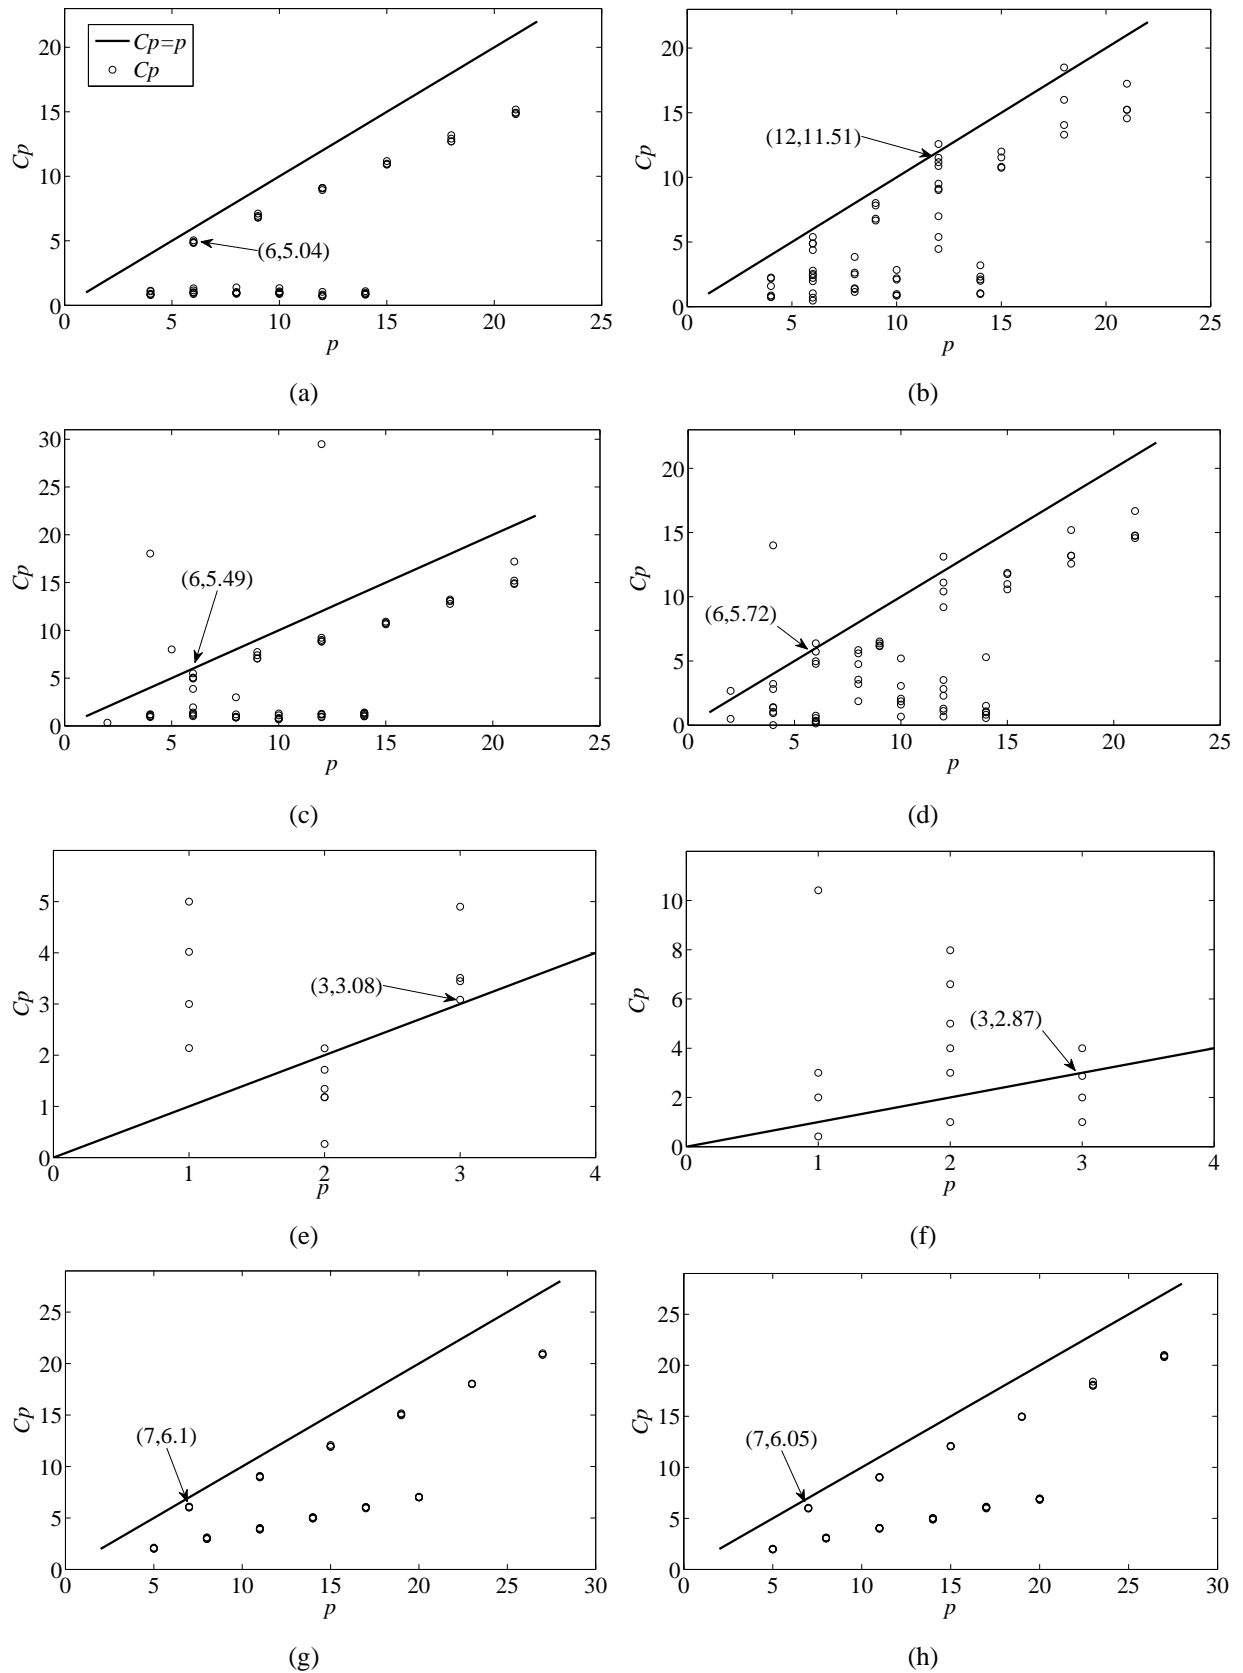


Figura 4.4 – Mapeamentos: (a) Modelo FTLFN PAC; (b) FTLFN POL; (c) DTLFN PAC; (d) DTLFN POL; (e) ERN PAC; (f) ERN POL; (g) NARX PAC; (h) NARX POL.

4.2. MELHORES MODELOS SELECIONADOS PARA TESTE

Do mapeamento realizado para as redes FTLFN, DTLFN, ERN e NARX, chegou-se às configurações de rede mostradas nas Tabelas 4.10 e 4.11.

A implementação das redes especificadas nas Tabelas 4.10 e 4.11 foi feita em MATLAB por meio do ToolBox de RNAs [53].

4.2.1. INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC

Tabela 4.10 – Configurações das redes selecionadas na Etapa de Seleção da Estrutura dos Modelos – Inferência do Sinal de Controle de Dosagem de PAC.

1. Redes Dinâmicas não recursivas	
1.1. Rede FTLFN (Max Épocas: 1000; MSE _{MIN} : 0.01; Gradiente _{MIN} : 0.00001)	Configuração
1.1.1. Variáveis de Entrada	TrbAB, pHAB, pHAC
1.1.2. Tamanho Padrão de Entrada x Neurônios Escondidos ($p \times q$)	6 x 6
1.1.3. Atrasos Aplicados às Entradas	1
1.2. Rede DTLFN (Max de Épocas: 1000; MSE _{MIN} : 0.01; Gradiente _{MIN} : 0.00001)	Configuração
1.2.1. Variáveis de Entrada	TrbAB, pHAB, pHAC
1.2.2. Tamanho Padrão de Entrada x Neurônios Escondidos ($p \times q$)	6 x 6
1.2.3. Atrasos Aplicados às Entradas	1
2. Redes Dinâmicas Recursivas	
2.1. Rede ERN (Max de Épocas: 1000; MSE _{MIN} : 0.01; Gradiente _{MIN} : 0.00001)	Configuração
2.1.1. Variáveis de Entrada	TrbAB, TrbAC, pHAB
2.1.2. Tamanho Padrão de Entrada x Neurônios Escondidos ($p \times q$)	3 x 9
2.1.3. Atrasos Aplicados às Entradas	0
2.2. Rede NARX (Max de Épocas: 1000; MSE _{MIN} : 0.01; Gradiente _{MIN} : 0.00001)	Configuração
2.2.1. Variáveis de Entrada	TrbAB, TrbAC, pHAC
2.2.2. Tamanho Padrão de Entrada x Neurônios Escondidos ($p \times q$)	7 x 5
2.2.3. Atrasos Aplicados às Entradas	1

4.2.2. INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL

Tabela 4.11 – Configurações das redes selecionadas na Etapa de Seleção da Estrutura dos Modelos – Inferência do Sinal de Controle de Dosagem de POL.

1. Redes Dinâmicas não recursivas	
1.1. Rede FTLFN (Max Épocas: 1000; MSE _{MIN} : 0.01; Gradiente _{MIN} : 0.00001)	Configuração
1.1.1. Variáveis de Entrada	TrbAB, pHAB, pHAC
1.1.2. Tamanho Padrão de Entrada x Neurônios Escondidos ($p \times q$)	12 x 4
1.1.3. Atrasos Aplicados às Entradas	3
1.2. Rede DTLFN (Max de Épocas: 1000; MSE _{MIN} : 0.01; Gradiente _{MIN} : 0.00001)	Configuração
1.2.1. Variáveis de Entrada	TrbAC, pHAB, pHAC
1.2.2. Tamanho Padrão de Entrada x Neurônios Escondidos ($p \times q$)	6 x 6
1.2.3. Atrasos Aplicados às Entradas	1
2. Redes Dinâmicas Recursivas	
2.1. Rede ERN (Max de Épocas: 1000; MSE _{MIN} : 0.01; Gradiente _{MIN} : 0.00001)	Configuração
2.1.1. Variáveis de Entrada	TrbAB, TrbAC, pHAB
2.1.2. Tamanho Padrão de Entrada x Neurônios Escondidos ($p \times q$)	3 x 9
2.1.3. Atrasos Aplicados às Entradas	0
2.2. Rede NARX (Max de Épocas: 1000; MSE _{MIN} : 0.01; Gradiente _{MIN} : 0.00001)	Configuração
2.2.1. Variáveis de Entrada	TrbAB, TrbAC, pHAC
2.2.2. Tamanho Padrão de Entrada x Neurônios Escondidos ($p \times q$)	7 x 5
2.2.3. Atrasos Aplicados às Entradas	1

Estas configurações serão testadas no Capítulo 5 para a seleção das RNAs que mais se adequam à aplicação proposta. Os resultados dos testes serão avaliados através de métodos gráficos e estatísticos. As RNAs que apresentarem melhor performance quanto a inferência dos sinais de controle de dosagem de PAC e POL, serão as selecionadas para comporem o modelo neural proposto.

5. RESULTADOS

Após o embasamento teórico apresentado nos Capítulos 2 e 3 sobre técnicas de tratamento de água por filtração rápida e RNAs supervisionadas dinâmicas e a possibilidade de sua aplicabilidade no processo de controle da coagulação química, este Capítulo tem como objetivo principal apresentar os resultados obtidos a partir dos testes realizados com as RNAs configuradas no Capítulo anterior (Seção 4.2, Tabelas 4.10 e 4.11), com vistas a validar as RNAs que mais se adéquam à inferência dos sinais de controle de dosagem de PAC e POL, para comporem o modelo neural final, conforme a Figura 4.3. Os dados de entrada a serem aplicados a estas RNAs, bem como os atrasos aplicados a estes dados, são os selecionados no Capítulo anterior.

Com vistas a selecionar as RNAs que resolvam bem o problema proposto, com mínimo custo computacional, não foram feitas simulações exaustivas, com grande quantidade de exemplos de entrada. Desta forma, as RNAs foram treinadas com os dados referentes aos 24 últimos meses (um total de 8640 registros) para inferência dos sinais de controle de dosagem dos dois meses subsequentes (um total de 720 registros). Os dados registrados utilizados nos testes (exemplos de entrada e saídas desejadas) foram cedidos pela CAGECE [36, 38], referentes ao ano 2009. Nesta metodologia de testes, foram feitas 6 simulações para cada RNA (equivalente a 12 meses).

Os resultados para cada RNA foram avaliados através dos gráficos analíticos: evolução do *MSE* por época de treinamento; dispersão da saída inferida em relação à saída desejada; e o histograma dos residuais da saída. Foi utilizado também, como técnica de avaliação complementar, o Coeficiente de Determinação R^2 [59] entre as saídas inferidas e saídas alvo. Nesta última técnica de avaliação, o melhor modelo é caracterizado por um Coeficiente de Determinação próximo da unidade.

Ao final do Capítulo são apresentadas as RNAs mais adequadas dentre as avaliadas, e que comporão o modelo neural final, a ser aplicado na prática na instalação piloto da ETA Gavião [67], para início de uma fase de testes e ajustes para uso do mesmo em uma aplicação real em ETAs de pequeno porte.

Os resultados são apresentados na Seção seguinte.

5.1. RESULTADOS

5.1.1. RNA FTLFN

INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC

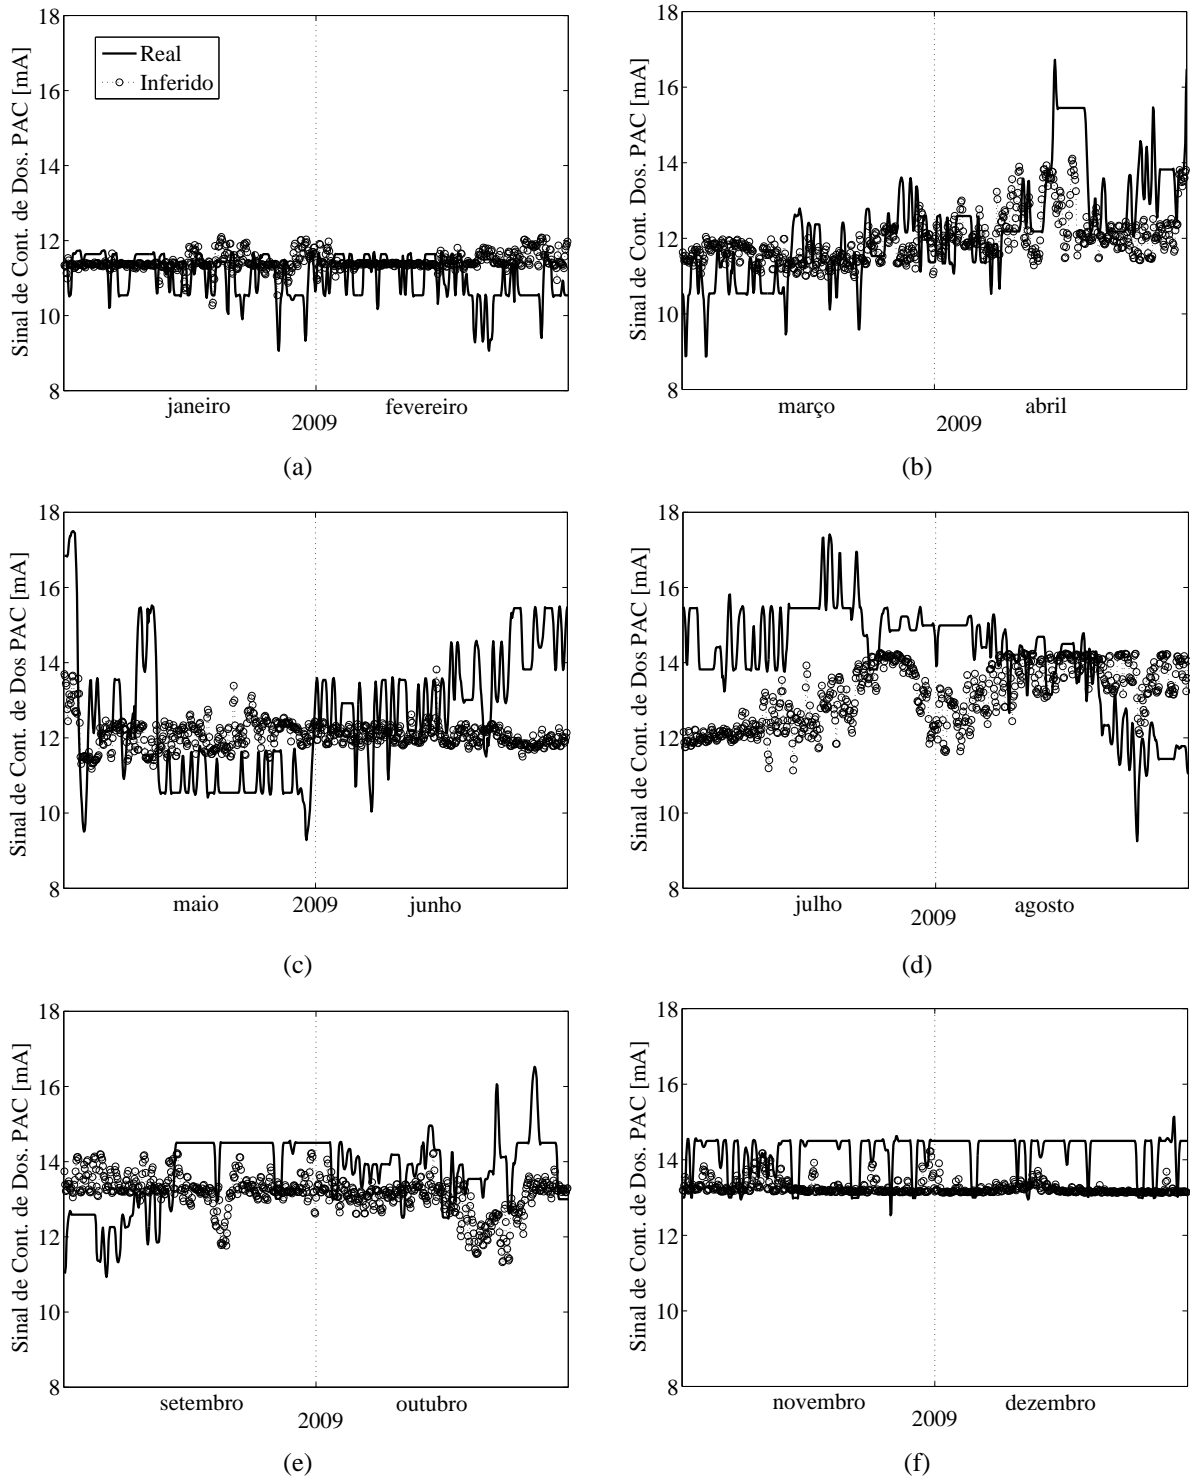


Figura 5.1 – Resultados da Inferência do sinal de controle de dosagem de PAC referente a 2009 (Rede FTLFN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.

INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL

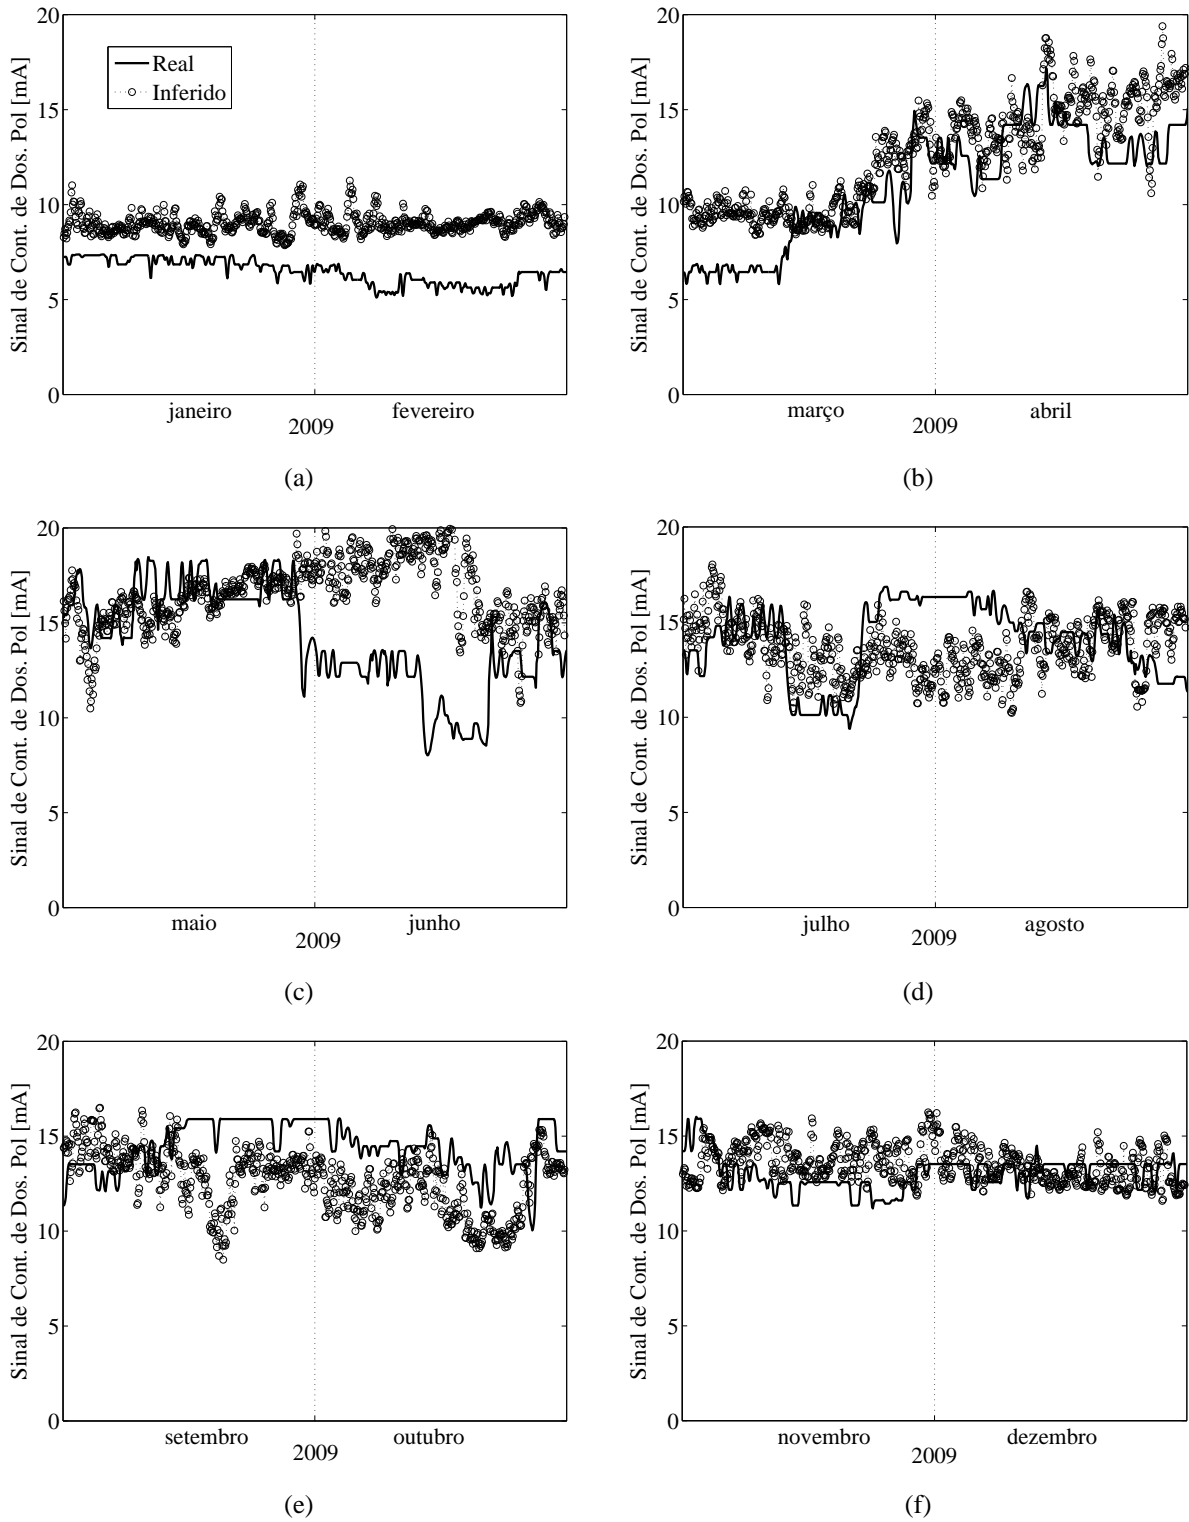


Figura 5.2 – Resultados da Inferência do sinal de controle de dosagem de POL referente a 2009 (Rede FTLFN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.

5.1.2. RNA DTLFN

INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC

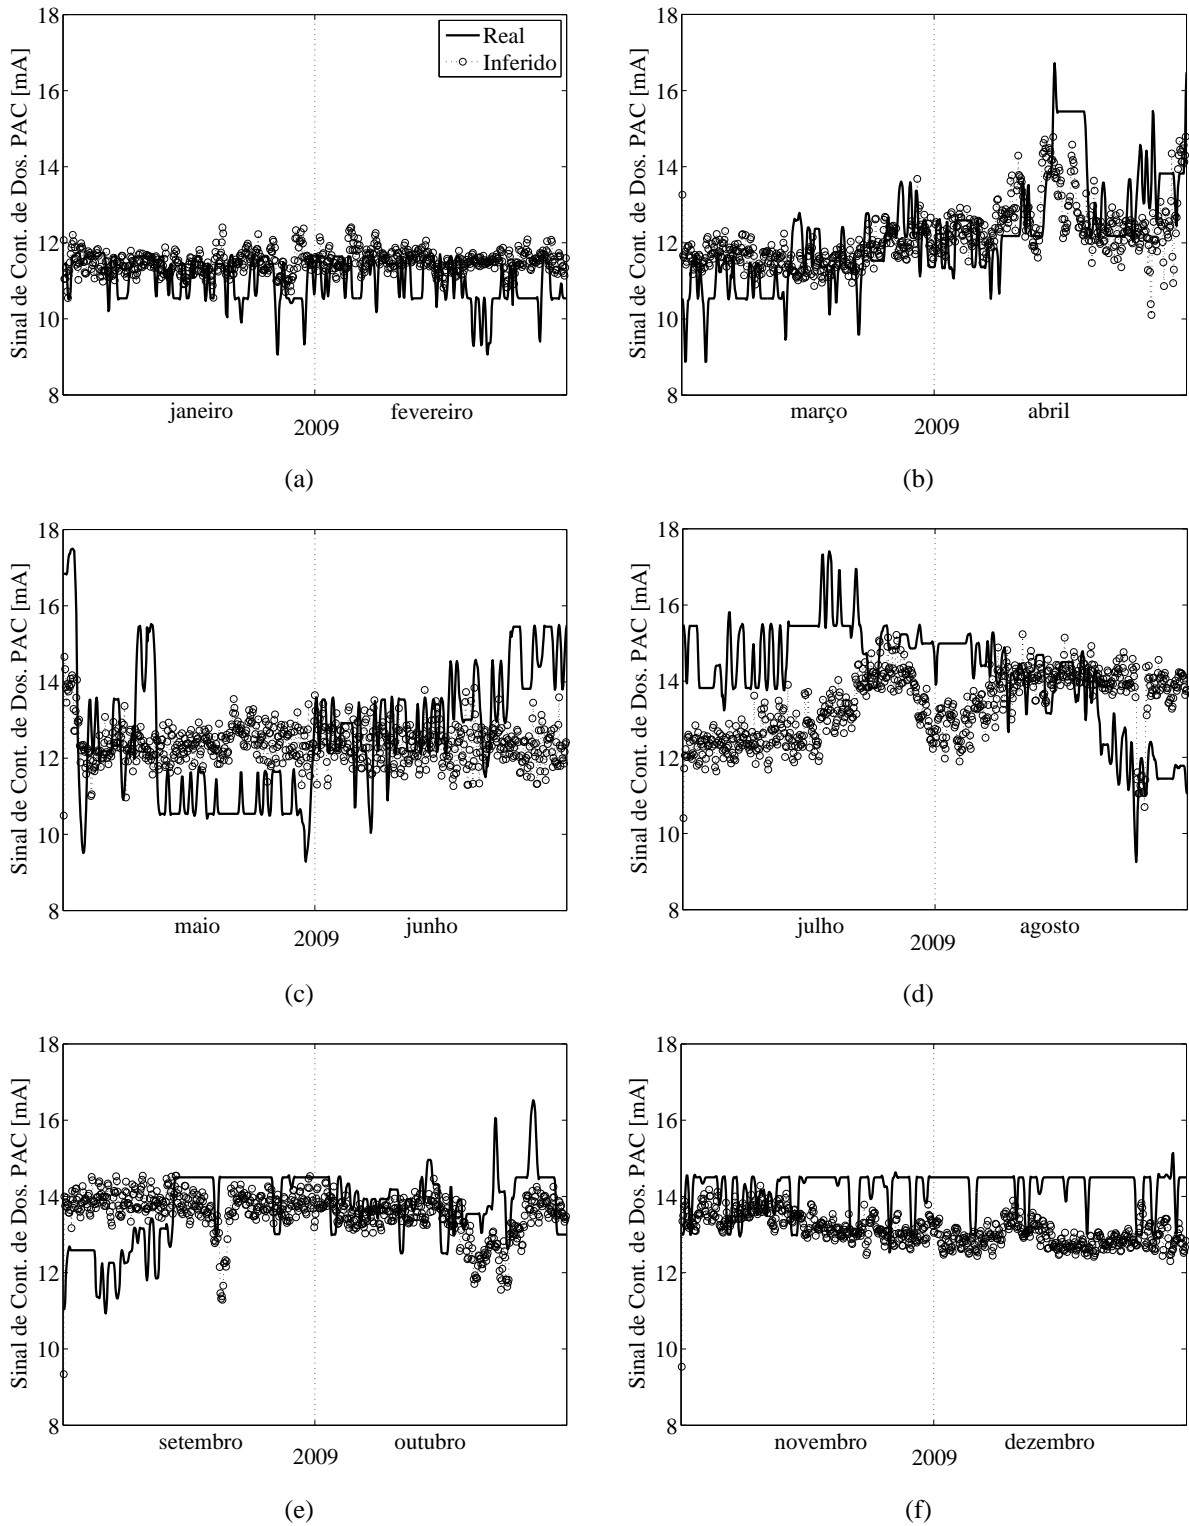


Figura 5.3 – Resultados da Inferência do sinal de controle de dosagem de PAC referente a 2009 (Rede DTLFN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.

INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL

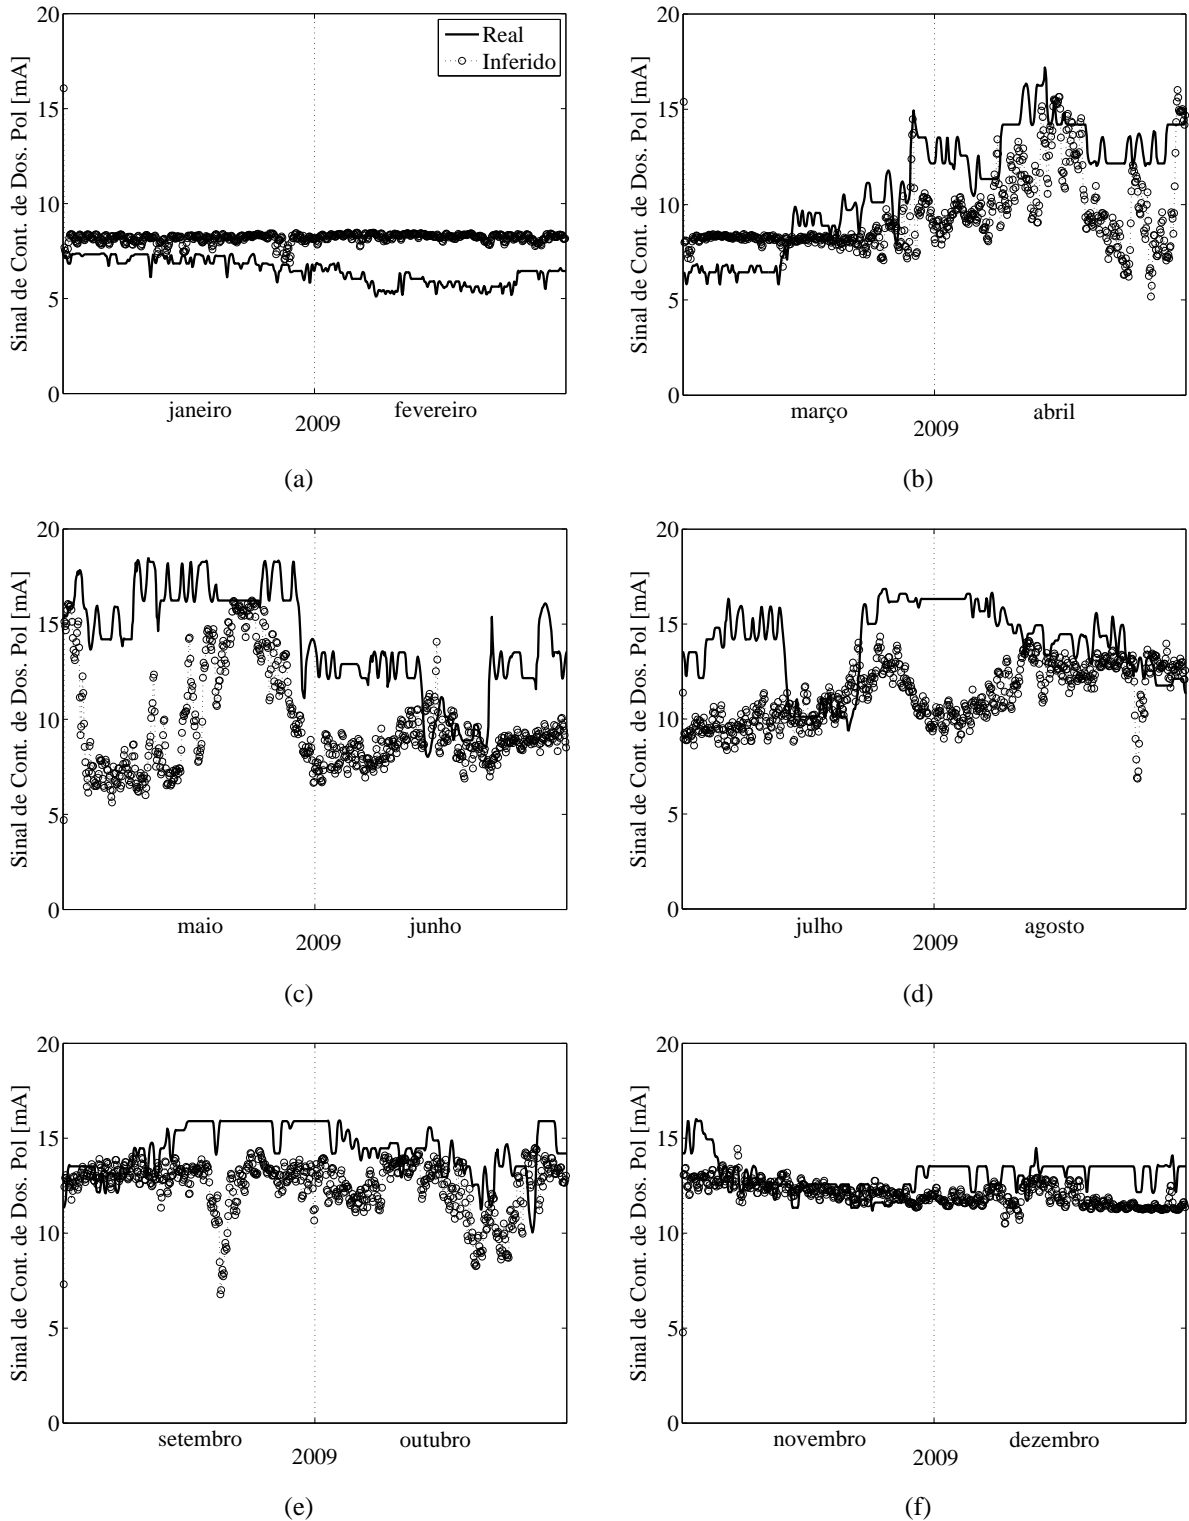


Figura 5.4 – Resultados da Inferência do sinal de controle de dosagem de POL referente a 2009 (Rede DTLFN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.

5.1.3. RNA ERN

INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC

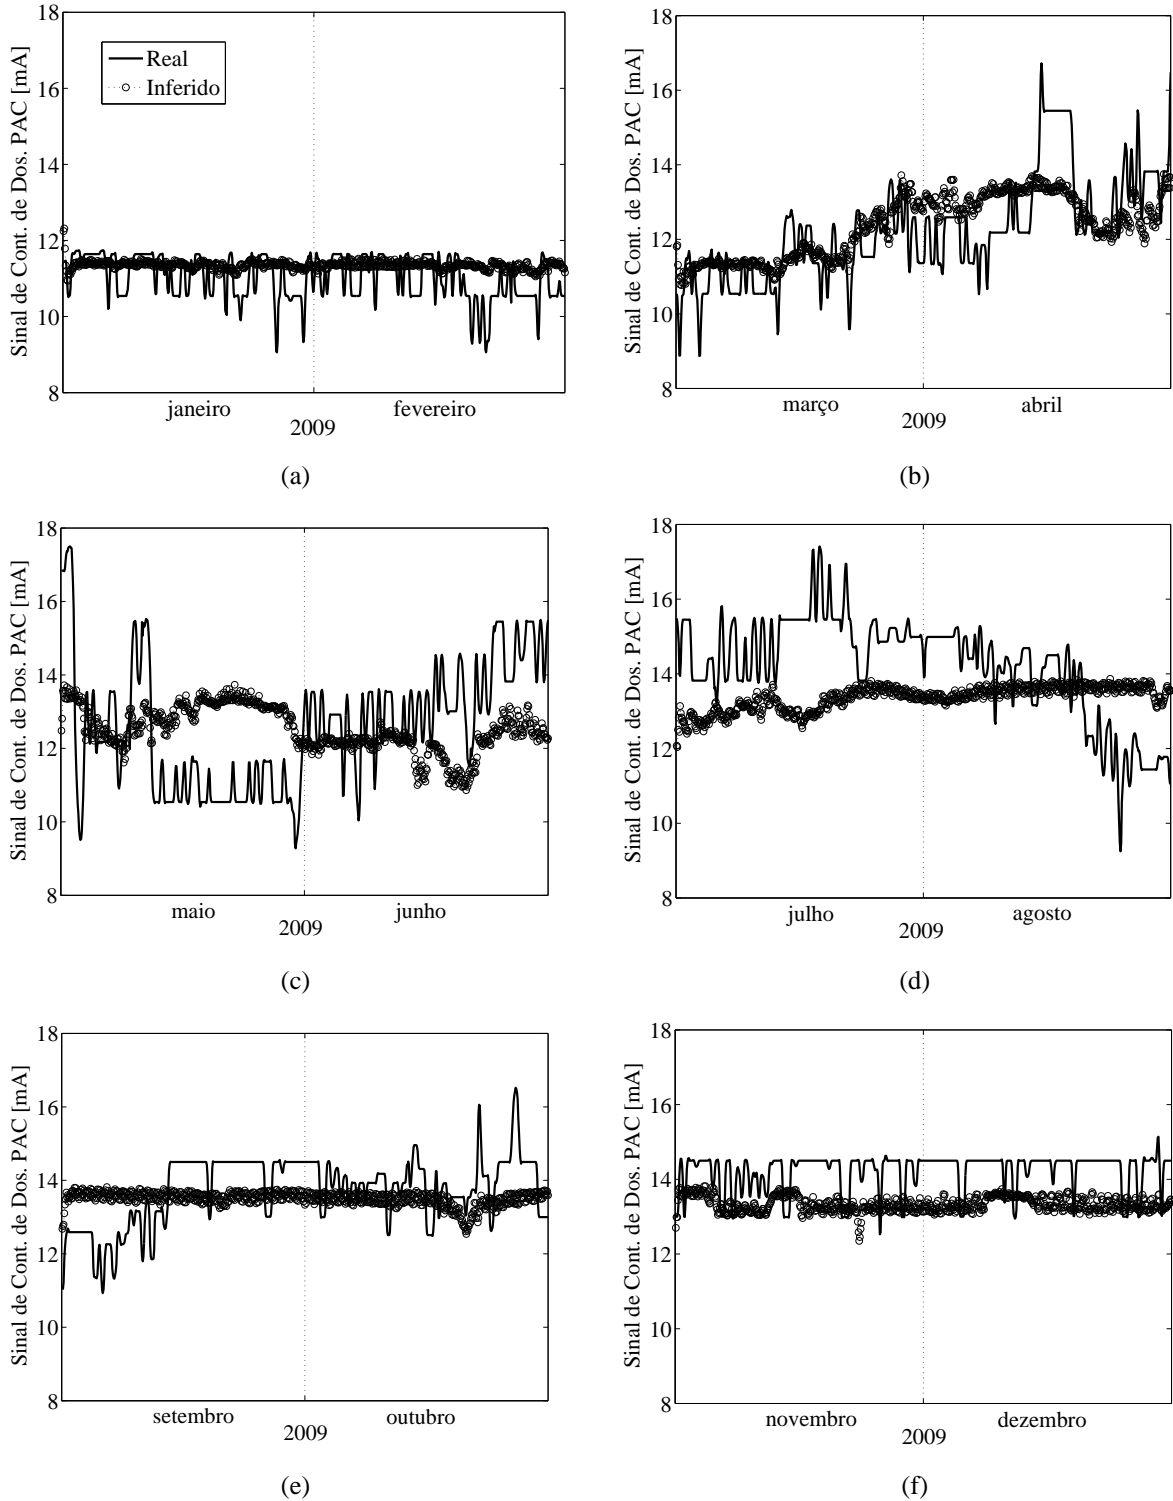




Figura 5.5 – Resultados da Inferência do sinal de controle de dosagem de PAC referente a 2009 (Rede ERN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.


INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL




(a)




(b)



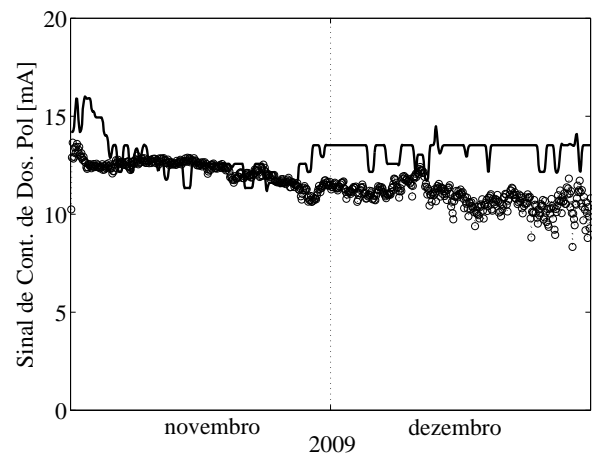
(c)



(d)



(e)



(f)

Figura 5.6 – Resultados da Inferência do sinal de controle de dosagem de POL referente a 2009 (Rede ERN) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.

5.1.4. RNA NARX

INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE PAC

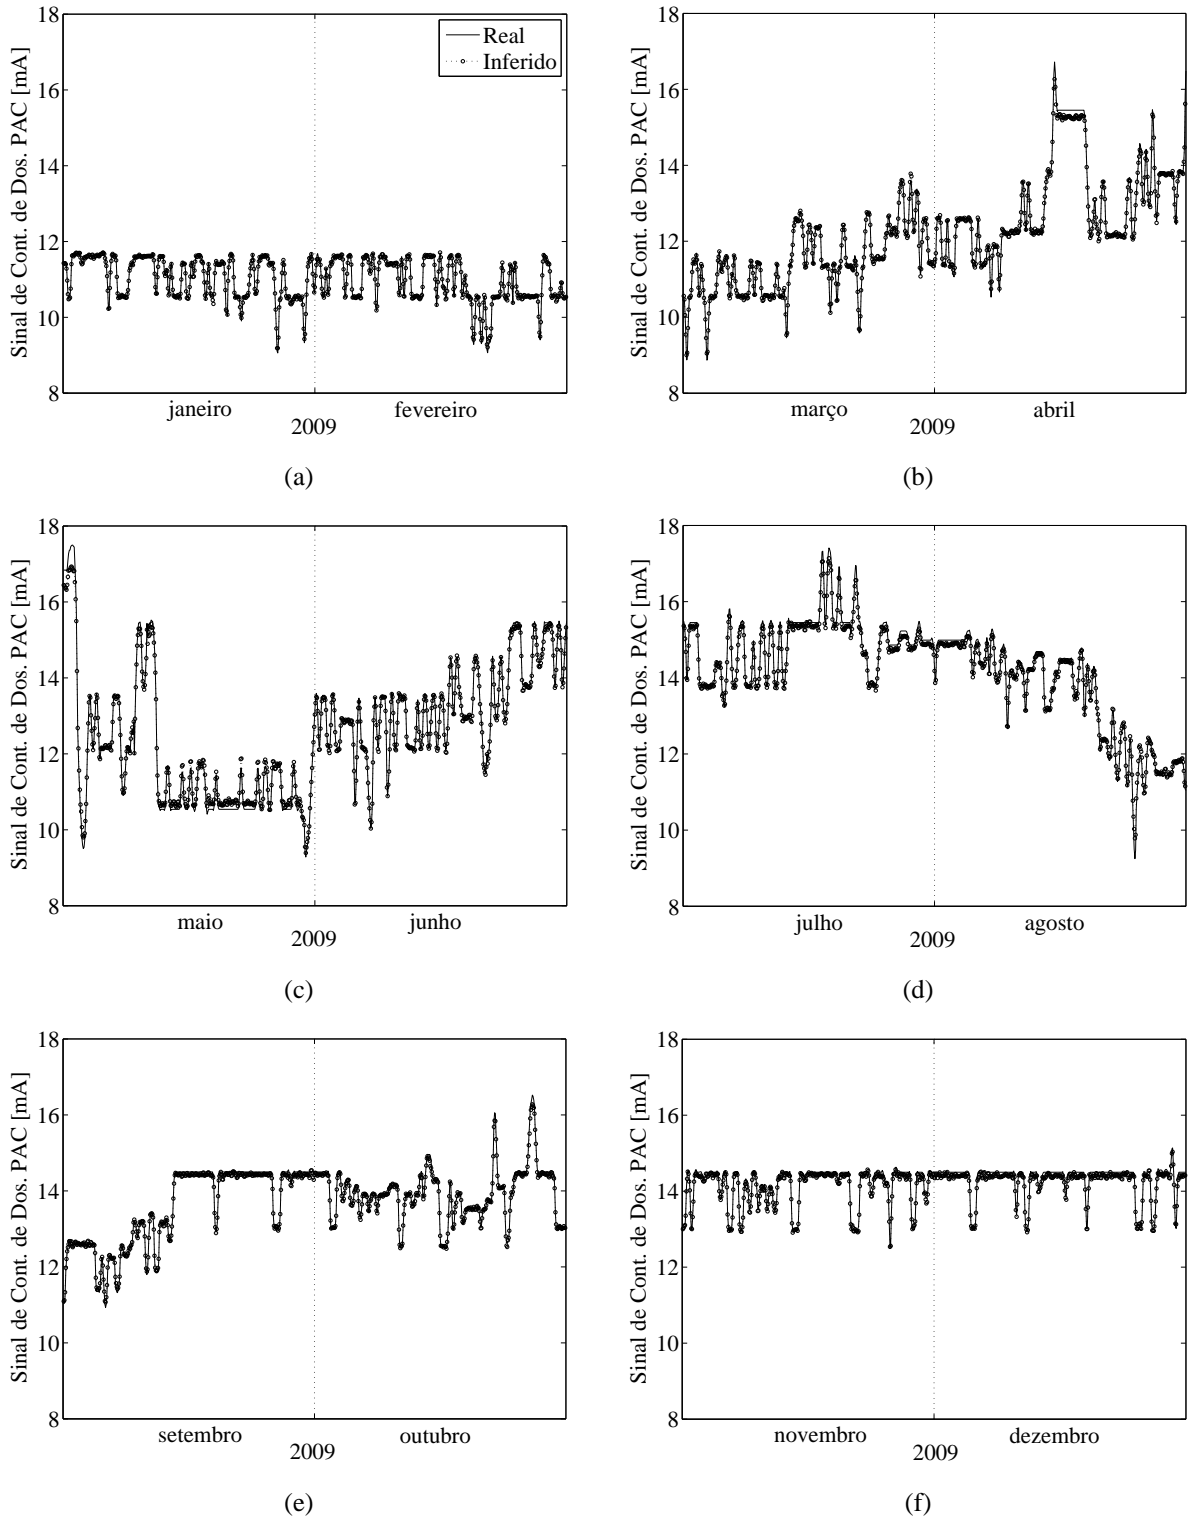


Figura 5.7 – Resultados da Inferência do sinal de controle de dosagem de PAC referente a 2009 (Rede NARX) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.

INFERÊNCIA DO SINAL DE CONTROLE DE DOSAGEM DE POL

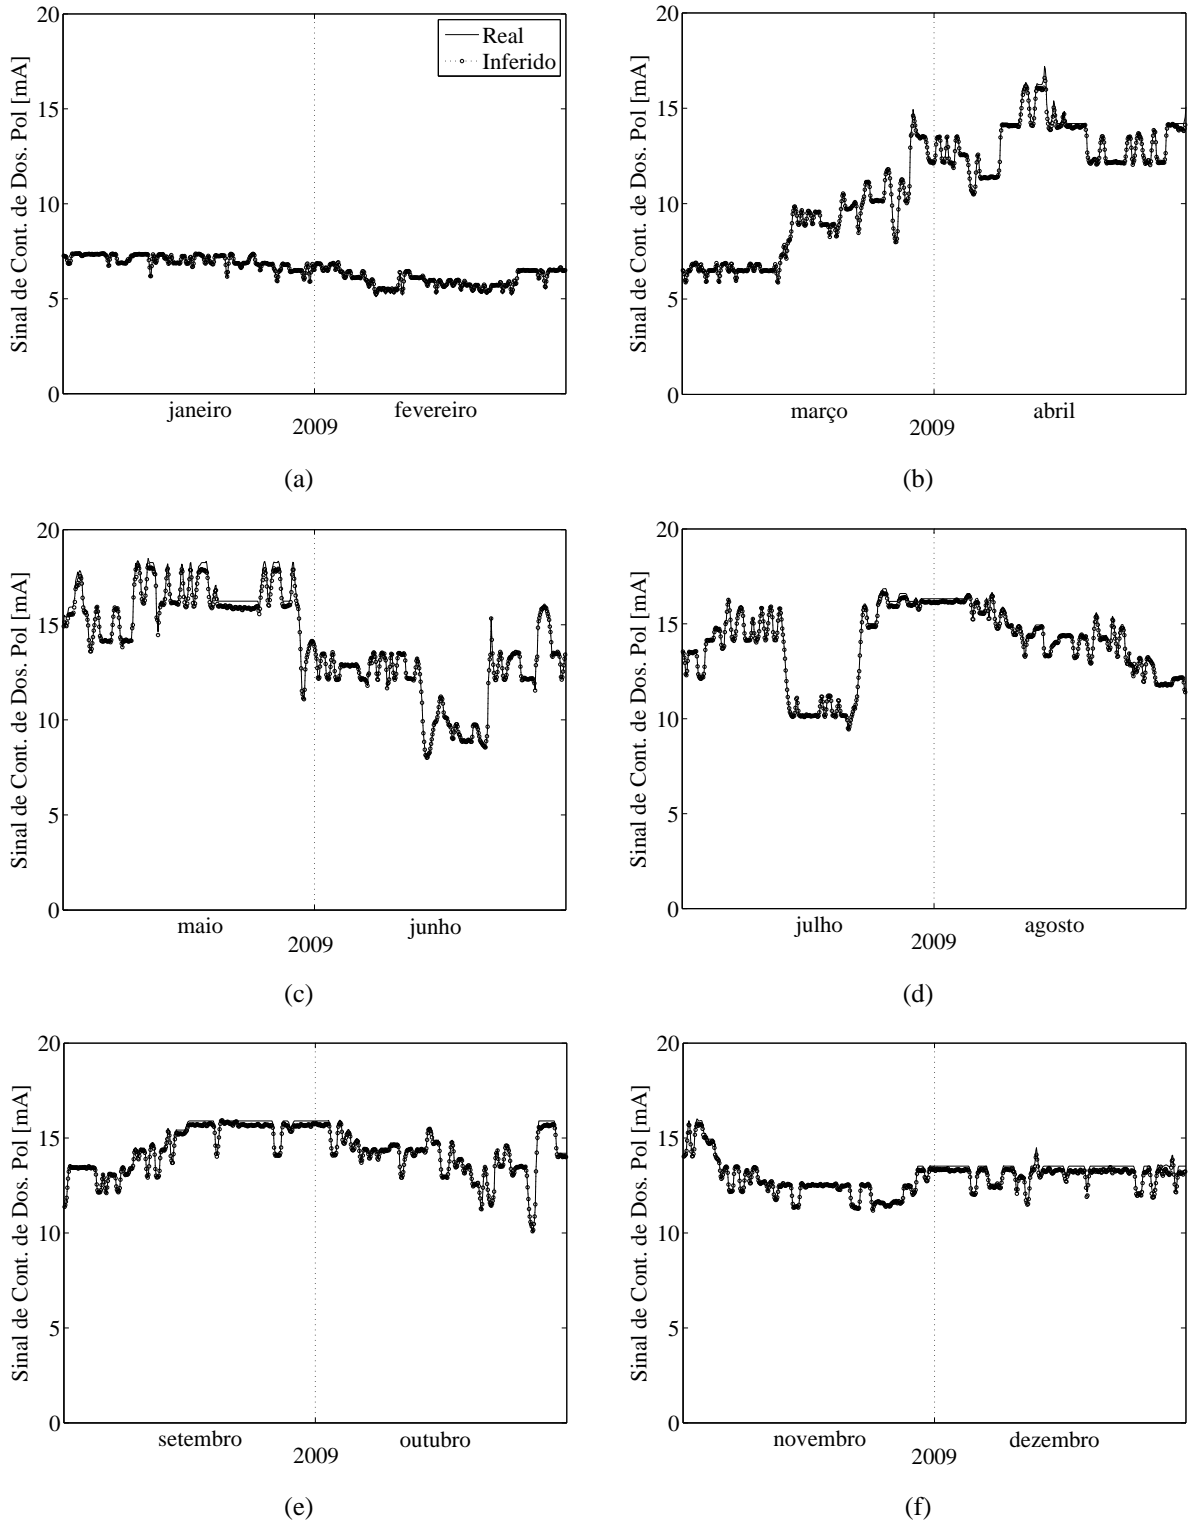


Figura 5.8 – Resultados da Inferência do sinal de controle de dosagem de POL referente a 2009 (Rede NARX) nos períodos: (a) janeiro a fevereiro; (b) março a abril; (c) maio a junho; (d) julho a agosto; (e) setembro a outubro; (f) novembro a dezembro.

5.2. GRÁFICOS DE DESEMPENHO DAS RNAs

5.2.1. RNA FTLFN

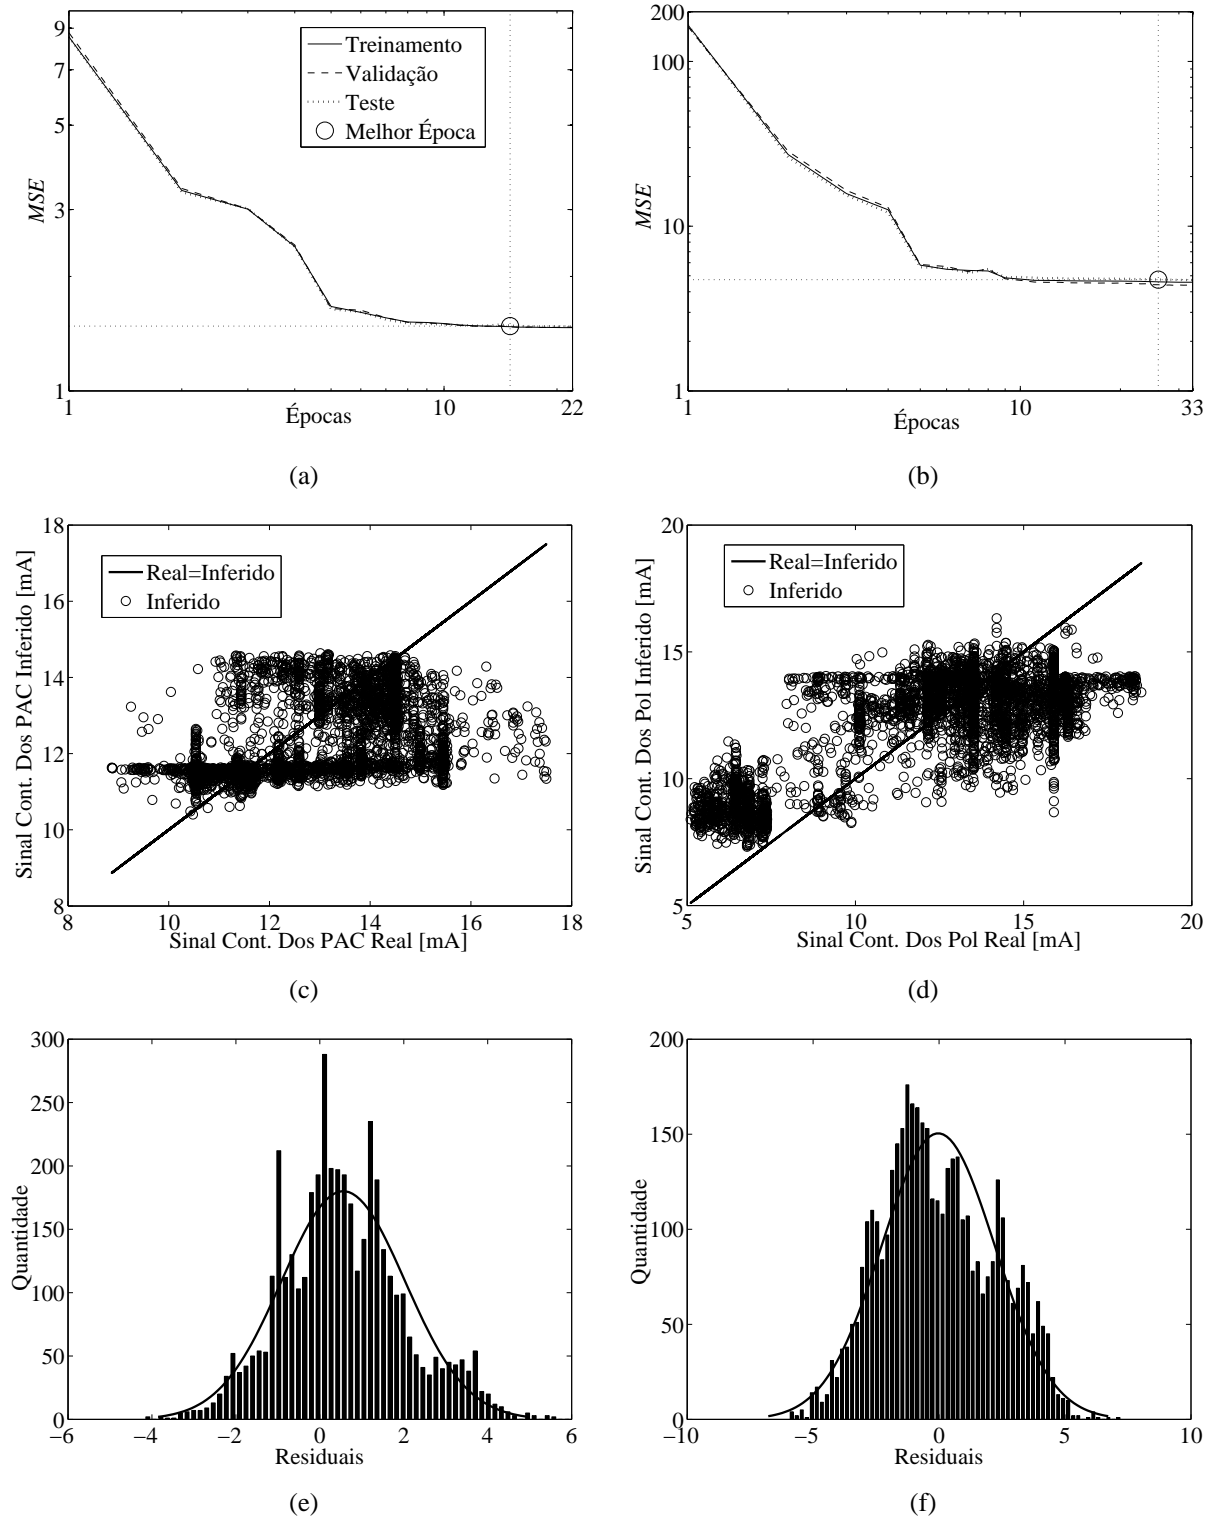


Figura 5.9 – Avaliação do desempenho da Rede FTLFN: (a) *MSE* inferência de PAC; (b) *MSE* inferência de POL; (c) Dispersão Sinal Real x Sinal Inferido de PAC; (d) Dispersão Sinal Real x Sinal Inferido de POL; (e) Histograma dos Residuais na fase de treinamento para a inferência de PAC; (f) Histograma dos Residuais na fase de treinamento para a inferência de POL.

5.2.2. RNA DTLFN

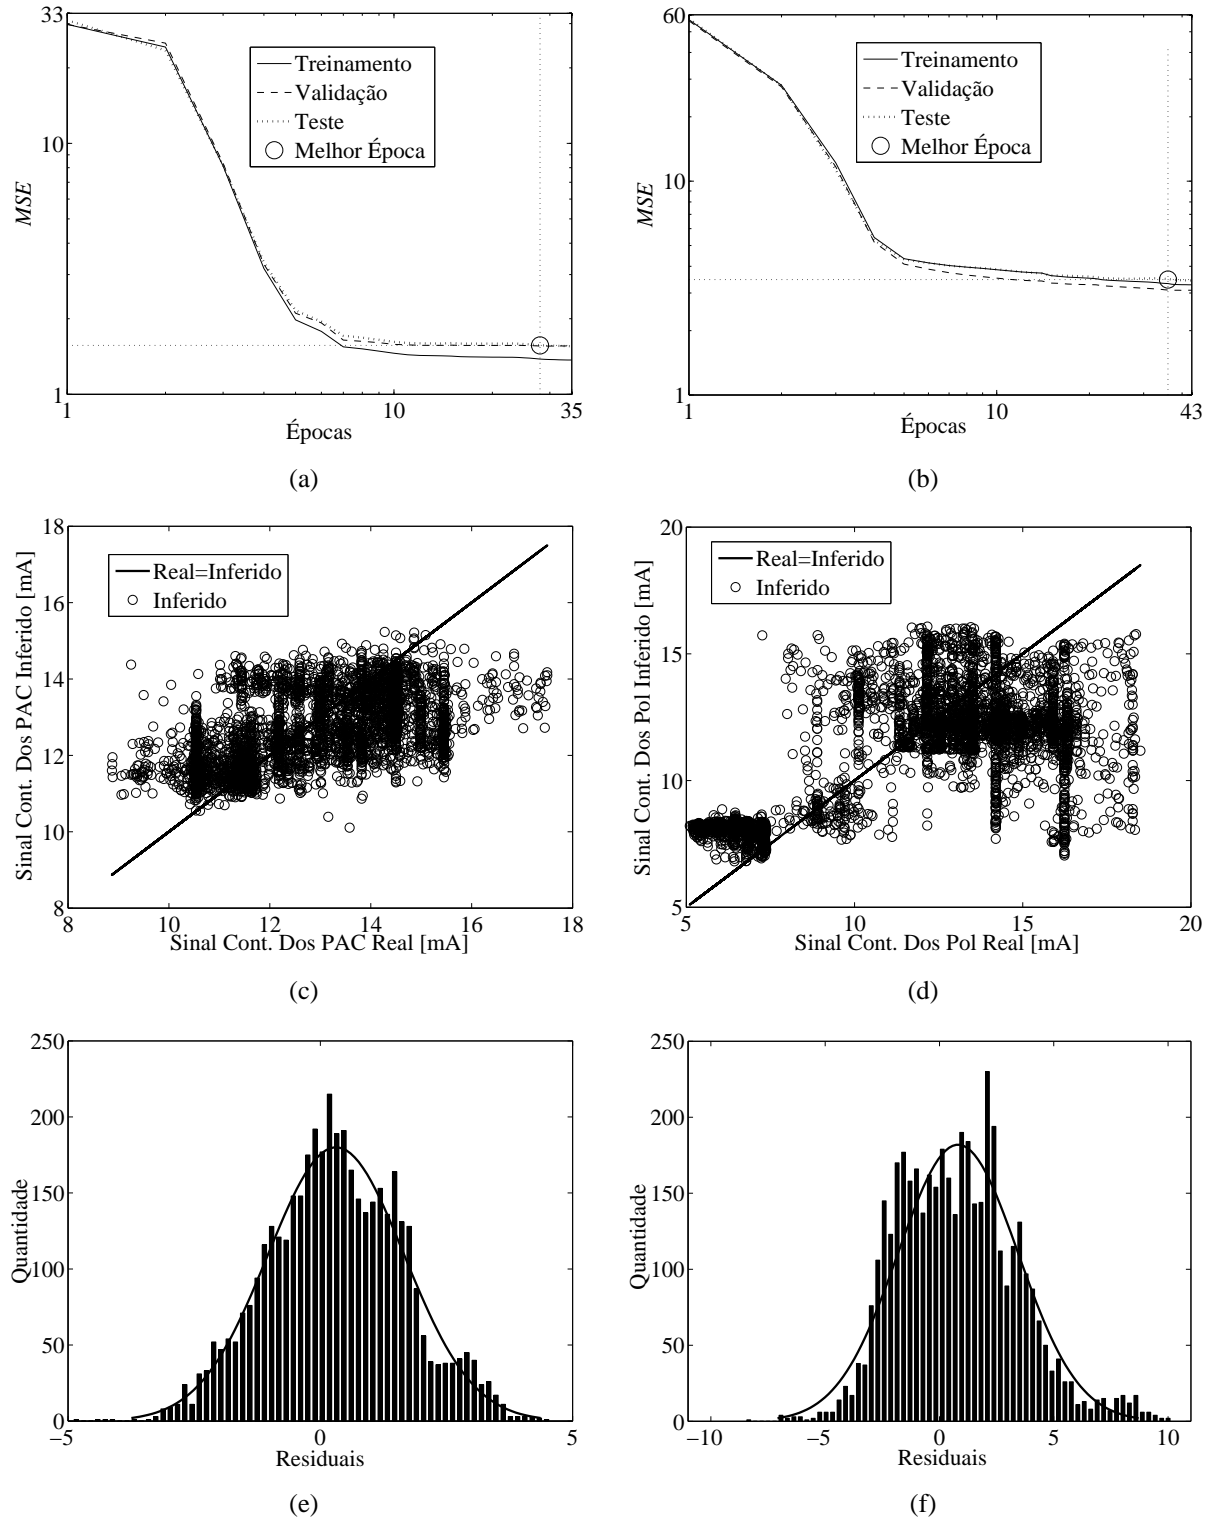


Figura 5.10 – Avaliação do desempenho da Rede DTLFN: (a) *MSE* inferência de PAC; (b) *MSE* inferência de POL; (c) Dispersão Sinal Real x Sinal Inferido de PAC; (d) Dispersão Sinal Real x Sinal Inferido de POL; (e) Histograma dos Residuais na fase de treinamento para a inferência de PAC; (f) Histograma dos Residuais na fase de treinamento para a inferência de POL.

5.2.3. RNA ERN

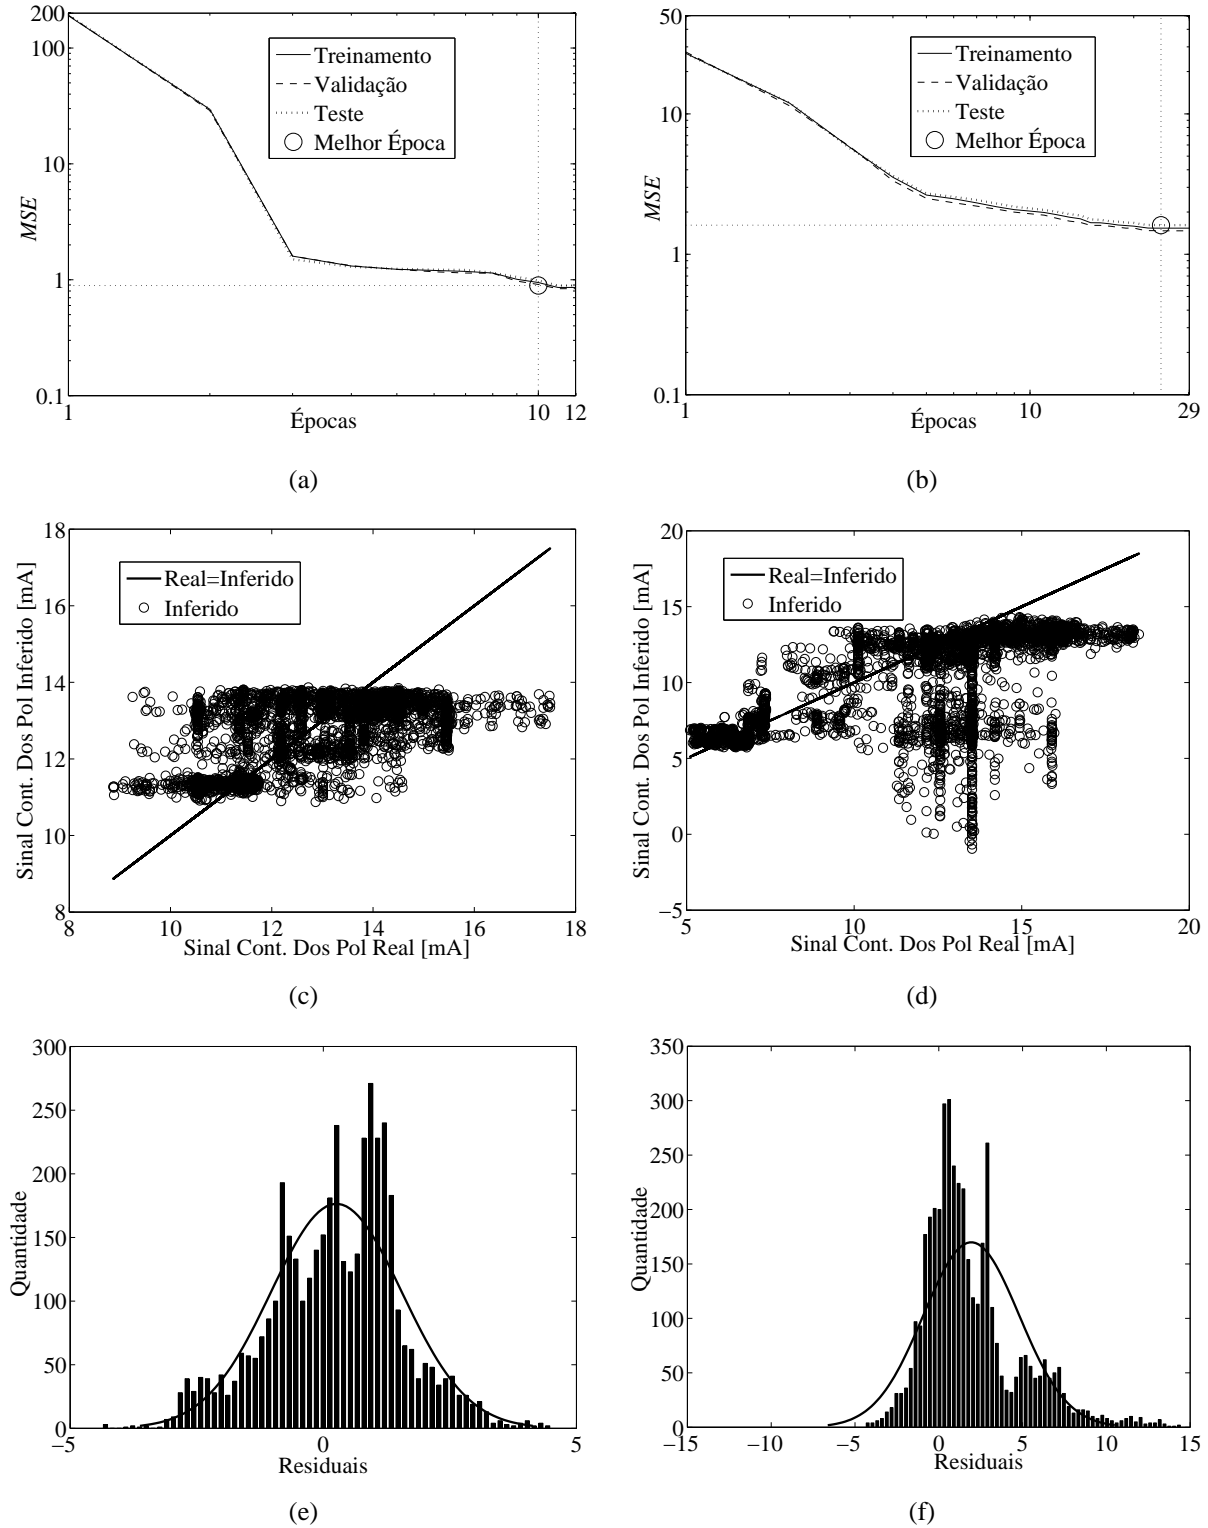


Figura 5.11 – Avaliação do desempenho da Rede ERN: (a) *MSE* inferência de PAC; (b) *MSE* inferência de POL; (c) Dispersão Sinal Real x Sinal Inferido de PAC; (d) Dispersão Sinal Real x Sinal Inferido de POL; (e) Histograma dos Residuais na fase de treinamento para a inferência de PAC; (f) Histograma dos Residuais na fase de treinamento para a inferência de POL.

5.2.4. RNA NARX

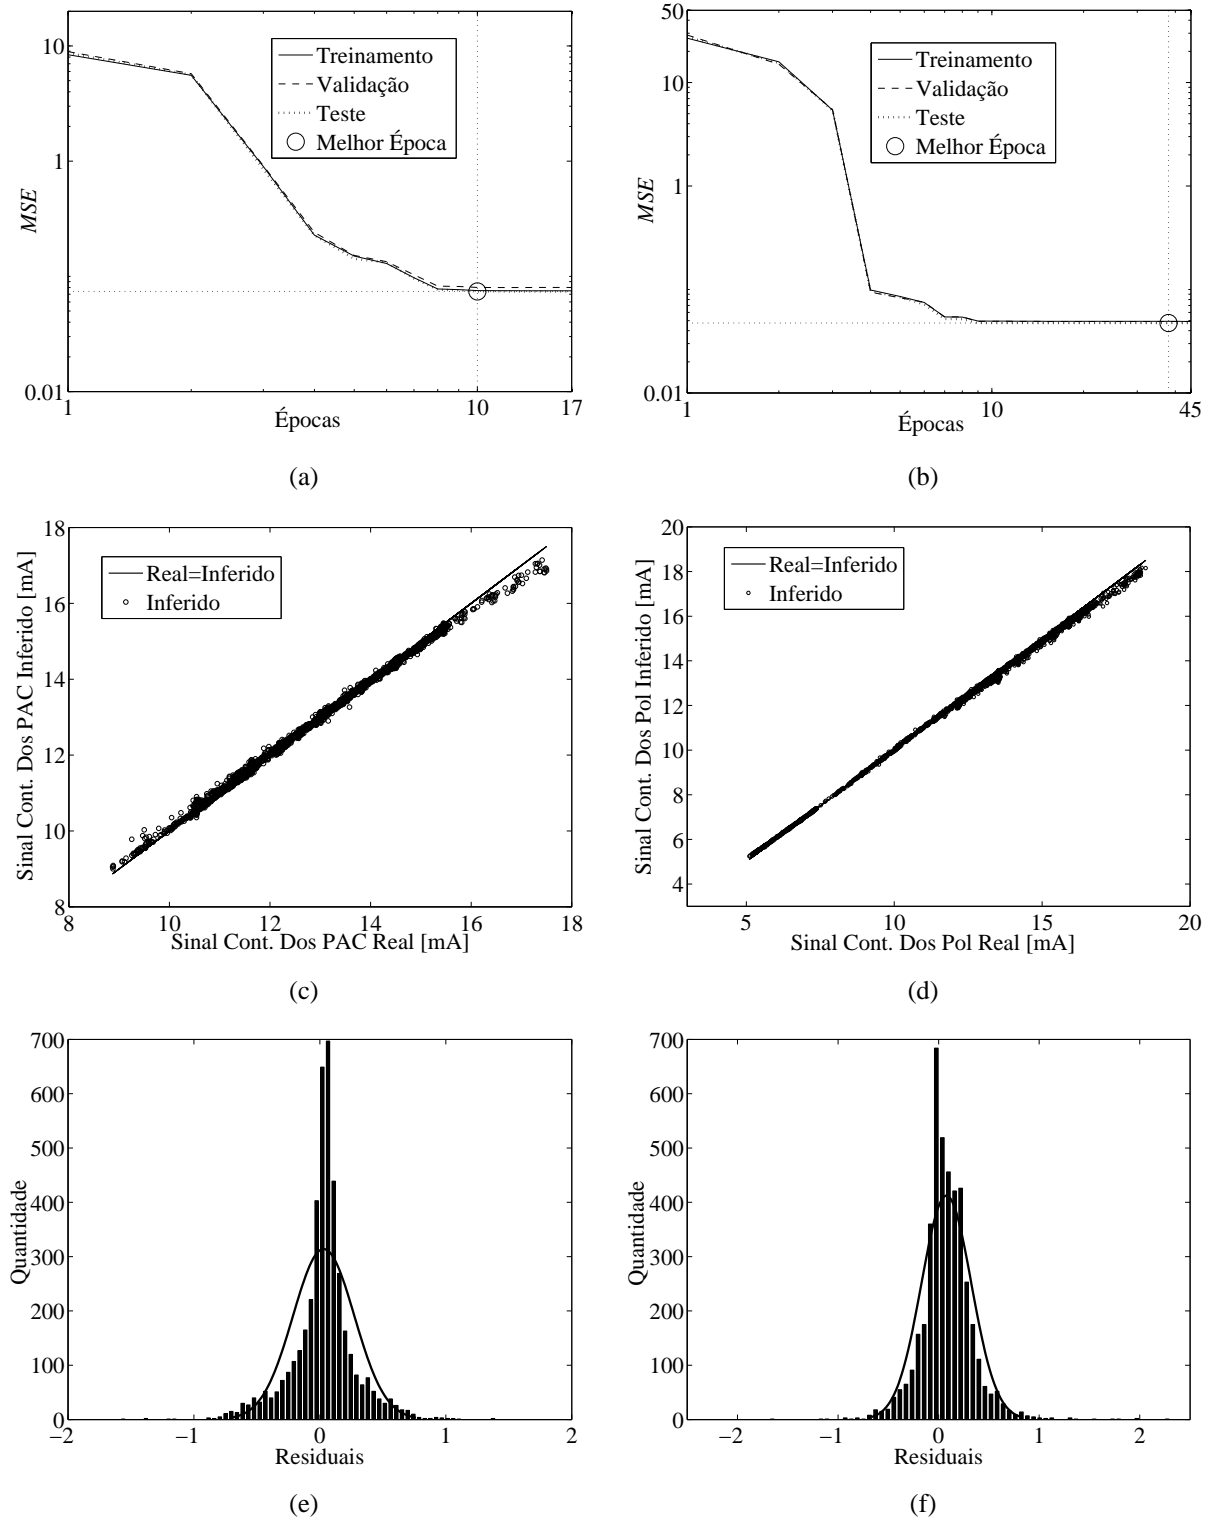


Figura 5.12 – Avaliação do desempenho da Rede NARX: (a) *MSE* inferência de PAC; (b) *MSE* inferência de POL; (c) Dispersão Sinal Real x Sinal Inferido de PAC; (d) Dispersão Sinal Real x Sinal Inferido de POL; (e) Histograma dos Residuais na fase de treinamento para a inferência de PAC; (f) Histograma dos Residuais na fase de treinamento para a inferência de POL.

5.3. AVALIAÇÃO DOS RESULTADOS

Nesta Seção, além da avaliação dos gráficos das Figuras 5.1 a 5.12, será feita uma avaliação utilizando o Coeficiente de Determinação R^2 , calculado conforme a Expressão 5.1 [57].

O Coeficiente de Determinação assume um valor próximo da unidade quando o sinal inferido está próximo do sinal real (alvo desejado). Este Coeficiente representa o quadrado da correlação entre a saída real e a inferida, onde y_i é a i -ésima saída inferida pelo modelo e \mathbf{d} é o vetor de saída desejada com T elementos dado por: $\mathbf{d} = [d_1, d_2, \dots, d_T]$. O vetor de padrões de entrada apresentado aos modelos neurais, referente aos dados cedidos pela CAGECE [36, 38] para o ano 2009, possui tamanho T .

$$R^2 = \frac{\sum_{i=1}^T (y_i - \bar{\mathbf{d}})^2}{\sum_{i=1}^T (d_i - \bar{\mathbf{d}})^2}. \quad (5.1)$$

5.3.1. DESEMPENHO DAS RNAs NÃO RECORRENTES (FTLFN E DTLFN)

Conforme as Figuras 5.1 a 5.4 nota-se que as RNAs não recorrentes testadas (FTLFN e DTLFN) apresentaram resultados razoáveis apenas nos períodos mostrados na Tabela 5.1. Nos demais períodos os resultados foram ruins.

Tabela 5.1 – Análise dos resultados apresentados nas Figuras 5.1 a 5.4 (RNAs FTLFN e DTLFN).

RNA	Resultados bons apresentados	
	Sinal de Controle de Dosagem de PAC	Sinal de Controle de Dosagem de POL
FTLFN	Janeiro Primeira metade mês de fevereiro Março Abril Primeira metade mês de maio Primeira metade mês de junho	Segunda metade mês de março Primeira metade mês Abril Maio Parte de julho Primeira metade mês de agosto Segunda metade mês de dezembro
DTLFN	Janeiro Primeira metade mês de fevereiro Segunda metade mês de março Primeira metade mês de abril Primeira metade mês de maio Primeira metade mês de junho Primeira metade mês de outubro Primeira metade mês de novembro	Primeira metade mês de setembro Segunda metade mês de outubro Novembro

Coincidentemente, a maioria dos meses onde se apresentaram resultados razoáveis correspondeu à época da quadra chuvosa no Estado do Ceará no ano 2009 [68]. Na quadra chuvosa, os açúdes sofrem aumento de cargas orgânicas e de substâncias húmicas. Na quadra de estiagem, onde não foram apresentados bons resultados pelas RNAs não recorrentes, ocorre o aumento da quantidade de algas no manancial.

Esta dinâmica da qualidade de água do manancial, que depende do clima e outros fatores externos, provoca mudanças nos parâmetros físicos, químicos e microbiológicos da água bruta [1], exigindo uma dinâmica de ajuste dos parâmetros de controle dos processos de tratamento da ETA. Nisto, a hipótese mais provável quanto aos resultados apresentados, é que as RNAs não recorrentes (FTLFN e DTLFN) não se adaptaram devidamente à dinâmica da qualidade do manancial, bem como à dinâmica do ajuste do processo de coagulação química no período de estiagem de chuvas.

O mau desempenho das RNAs não recorrentes testadas é perceptível também nos gráficos das Figuras 5.9 e 5.10, onde a parada do treinamento ocorreu com um *MSE* maior que a unidade. Isto evidencia, juntamente com os gráficos de dispersão entre os sinais real e inferido, e o histograma dos residuais no treinamento, a grande quantidade de residuais fora do intervalo $-1 < e(n) < +1$, com $n = 1, \dots, T$, demonstrando a baixa performance das RNAs não recorrentes testadas no cumprimento da tarefa de inferência dos sinais de dosagem de PAC e POL. Na análise de desempenho utilizando o Coeficiente R^2 , notou-se também o baixo desempenho das RNAs não recorrentes testadas, conforme mostrado na Tabela 5.2.

Tabela 5.2 – Resumo da Análise do Desempenho das RNAs não-recorrentes avaliadas

RNA	Sinal	Época Ótima	MSE Ótimo Treinamento	R^2
FTLFN	PAC	17	1.4	0.5121
	POL	27	4.7	0.7228
DTLFN	PAC	28	1.6	0.3625
	POL	37	3.4	0.4844

5.3.2. DESEMPENHO DAS RNAs RECORRENTES (ERN E NARX)

Conforme as Figuras 5.5 e 5.6, a RNA ERN apresentou resultados semelhantes aos apresentados pelas RNAs não recorrentes. Porém, os resultados apresentados pela RNA NARX (Figuras 5.7 e 5.8) foram excelentes, evidenciando a característica de evolução temporal do processo de dosagem de coagulantes.

A Tabela 5.3 mostra os períodos onde as RNAs recorrentes testadas apresentaram bom resultado. Para os demais períodos, no caso da RNA ERN, os resultados foram ruins.

Tabela 5.3 – Análise dos resultados apresentados nas Figuras 5.5 a 5.8 (RNAs ERN e NARX).

RNA	Resultados bons apresentados	
	Sinal de Controle de Dosagem de PAC	Sinal de Controle de Dosagem de POL
ERN	Janeiro Fevereiro Março Primeira metade mês de maio Primeira metade mês de junho	Segunda metade mês de janeiro Segunda metade mês de fevereiro Segunda metade mês de março Abril Junho
NARX	Todos os resultados, para todos os meses do ano 2009, foram excelentes.	Todos os resultados, para todos os meses do ano 2009, foram excelentes.

Conforme a Tabela 5.3, de forma semelhante às RNAs não-recorrentes, a RNA ERN não se adaptou bem ao período de estiagem apresentado no ano 2009 [68].

Da mesma forma como ocorrido com as RNAs não-recorrentes, a Figura 5.11 demonstra um valor próximo da unidade para o MSE na parada do treinamento, bem como a grande quantidade de residuais fora do intervalo $-1 < e(n) < +1$, com $n = 1, \dots, T$, evidenciando o baixo desempenho da RNA ERN testada no cumprimento da tarefa de inferência dos sinais de dosagem de PAC e POL. Este fato é reforçado na análise do desempenho através do coeficiente R^2 , mostrado na Tabela 5.4

Tabela 5.4 – Resumo da Análise do Desempenho da RNA ERN avaliada

RNA	Sinal	Época Ótima	MSE Ótimo Treinamento	R^2
ERN	PAC	10	0.9	0.5035
	POL	24	1.6	0.6070

Quanto a RNA NARX, os resultados mostrados na Figura 5.12, demonstram o excelente desempenho da rede, evidenciando que o processo de dosagem de coagulantes possui características temporais onde a inferência de um estado seguinte depende dos valores inferidos passados. Os gráficos de evolução do MSE , dispersão entre o sinal real e o inferido, e o histograma de residuais no treinamento, mostram a grande quantidade de residuais dentro do intervalo $-1 < e(n) < +1$, com $n = 1, \dots, T$, evidenciando a o ótimo desempenho da RNA NARX no cumprimento da tarefa de inferência dos sinais de dosagem de PAC e POL. Este fato é também evidenciado na análise do desempenho utilizando o coeficiente R^2 , conforme a Tabela 5.5.

Tabela 5.5 – Resumo da Análise do Desempenho da RNA NARX avaliada

RNA	Sinal	Época Ótima	MSE Ótimo Treinamento	R^2
NARX	PAC	10	0.073	0,9114
	POL	38	0.038	0.9483

5.4. VALIDAÇÃO DO MODELO PARA INFERÊNCIA DOS SINAIS DE CONTROLE DE DOSAGEM DE PAC E POL

De acordo com os resultados e as avaliações apresentadas, as RNAs NARX apresentaram melhor desempenho na modelagem proposta (inferência dos sinais de controle de dosagem de PAC e POL) do que as redes não-recorrentes FTLFN, DTLFN e a recorrente ERN.

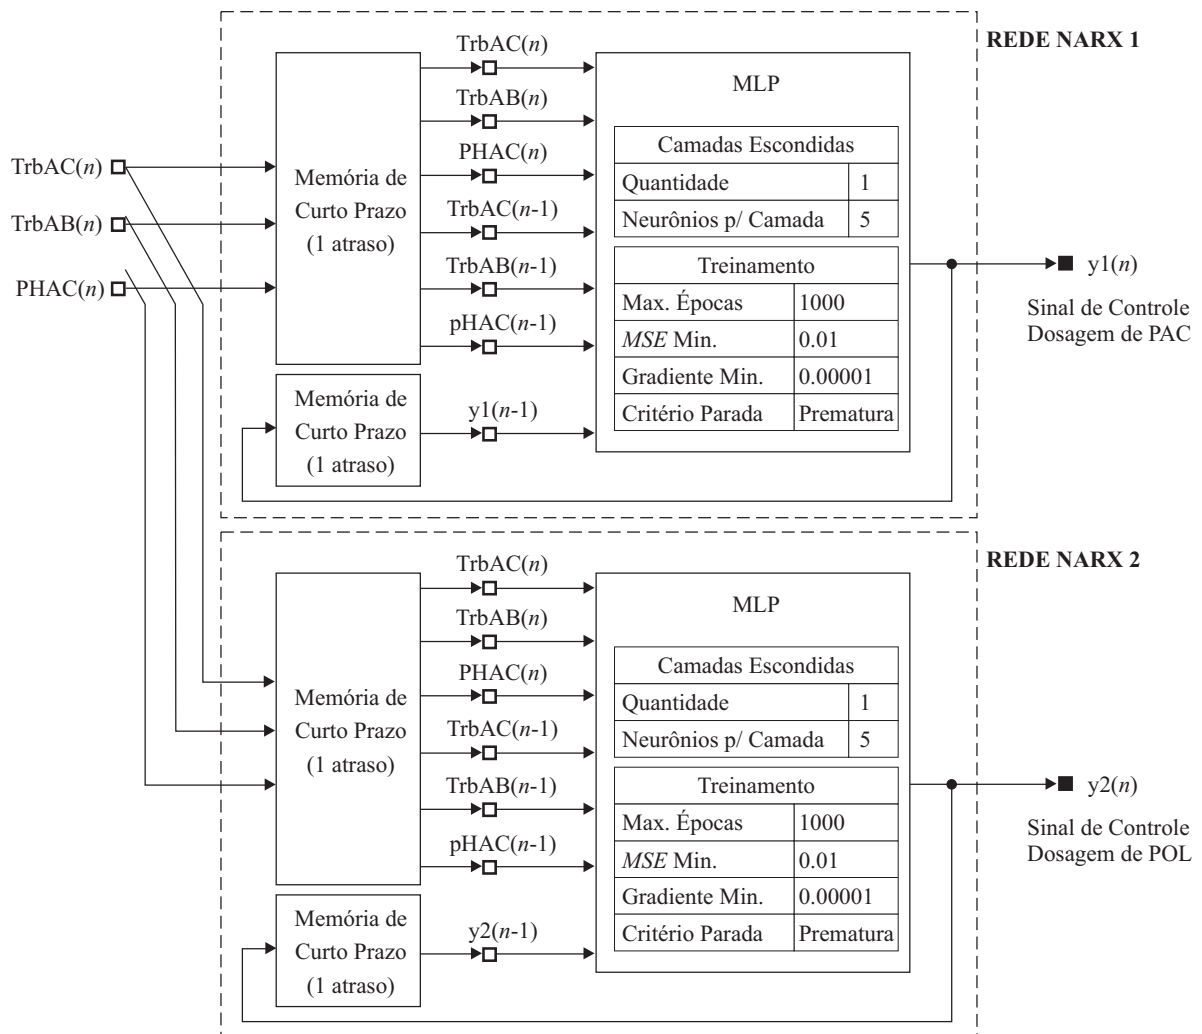


Figura 5.13 – Arquitetura Definitiva do Modelo Neural Proposto para Inferência dos Sinais de Controle de Dosagem de PAC e POL.

Fonte: do autor.

Desta forma, o modelo neural proposto nesta dissertação (Figura 4.3) será composto de duas RNAs NARX configuradas conforme as Tabelas 4.10 e 4.11. A Figura 5.13 mostra o diagrama esquemático do modelo final proposto para inferência dos sinais de controle de dosagem de coagulantes PAC e POL, numa ETA de filtração rápida.

O modelo será utilizado na instalação piloto da ETA Gavião, numa fase de testes práticos e ajustes, a fim de ser utilizado em ETAs de pequeno porte pertencentes a CAGECE, no interior do Estado do Ceará.

6. CONCLUSÕES E PERSPECTIVAS

O estudo relatado nesta dissertação teve como objetivo a avaliação da aplicação de RNAs supervisionadas dinâmicas na tarefa de inferência dos sinais de controle de dosagem de PAC e POL no processo de coagulação química em uma ETA de filtração rápida.

O motivo principal da proposta do desenvolvimento de um modelo neural para realização desta tarefa foi o desenvolvimento de um sistema de controle de dosagem de coagulantes com custo relativamente menor que os convencionalmente utilizados no Brasil, que possibilitasse a eliminação do hardware de controle utilizado no controle do processo, bem como a substituição da instrumentação utilizada (geralmente de custo elevado) por outra de menor custo. O objetivo da busca desta redução de custos é contribuir com a viabilização da implantação de sistemas de dosagem automática de coagulantes em ETAs de pequeno porte, contribuindo com a otimização do tratamento, a redução de custos com insumos envolvidos no processo (energia, produtos químicos e mão-de-obra) e o principal: a universalização dos serviços de abastecimento de água no Estado do Ceará.

Para o desenvolvimento do modelo neural proposto era necessário o conhecimento teórico básico do processo de coagulação química em ETAs de filtração rápida, daí a necessidade do desenvolvimento no Capítulo 2 de um estudo a respeito de tratamento de água para consumo humano, dando ênfase ao processo de coagulação química.

De posse da compreensão básica a respeito do processo de coagulação química, foi feito um estudo sobre RNAs no Capítulo 4, dando ênfase às redes dinâmicas não-recorrentes FTLFN e DTLFN, e às redes dinâmicas recorrentes ERN e NARX, cujas estruturas para teste foram desenvolvidas no Capítulo 4. O objetivo era testar estas arquiteturas a fim de selecionar as RNAs que mais se adequassem ao problema, a fim de comporem o modelo proposto.

Os testes para selecionar as RNAs adequadas ao problema proposto foram realizados no Capítulo 5, onde se concluiu que as redes NARX apresentaram excelentes resultados quanto a aplicação, sendo estas selecionadas para comporem o modelo neural final.

De fato, mostrou-se nesta dissertação, que o modelo neural proposto pode tornar possível a realização da tarefa desempenhada pelo hardware de controle e a instrumentação convencionalmente utilizados no controle de dosagem de coagulantes. O modelo, conforme os resultados mostrados nas Figuras 5.7 e 5.8, mostrou-se capaz de desempenhar a função de um controlador, substituindo o operador humano (no caso da ETA Gavião), utilizando para isto a medição de três variáveis comuns ao processo (Turbidez de Água Bruta, Turbidez de Água

Coagulada, pH de Água Coagulada) cuja instrumentação de medição tem custo 29,45% menor que a instrumentação convencional utilizada (monitor de coagulação), conforme comparação de custos entre as Tabelas 1.2 e 1.3.

Quanto aos custos totais de implantação de sistemas automáticos de dosagem de coagulantes, a aplicação do modelo neural proposto possibilitará, conforme demonstrado na Seção 1.6, uma redução de 36% em relação ao custo de sistemas convencionais, contribuindo com a viabilização de projetos desta natureza em ETAs de pequeno porte.

Outro fato marcante dos resultados obtidos é o ótimo desempenho do modelo proposto na realização da tarefa de inferência dos sinais de controle de dosagem de PAC e POL, conforme apresentado na Figura 5.12. O período de realização das simulações do modelo (um ano completo) evidenciam a robustez do modelo e a garantia da manutenção da qualidade da água tratada.

O ótimo resultado apresentado pelo modelo proposto nesta dissertação, abre a perspectiva de uso do mesmo numa aplicação real de controle de dosagem de coagulantes em uma ETA de filtração rápida. Isto torna possível uma próxima etapa para o trabalho: a validação do modelo em campo na bancada piloto da ETA Gavião. Esta validação prática do modelo será através de Convênio [67] firmado entre a CAGECE e UFC para desenvolvimento de um sistema modular para automatização de ETAs, que tem como objetivo principal o desenvolvimento de tecnologia de baixo custo para o controle dos processos de tratamento.

Nesta etapa prática, também será conveniente o teste de modelos neurais semelhantes ao desenvolvido nesta dissertação, em aplicações de sensoriamento virtual [56], ou seja, na inferência de determinadas variáveis analíticas do processo de tratamento, geralmente de alto custo de projeto e implantação. Isto evidencia a possibilidade da melhoria deste trabalho, e a abertura de outros projetos de pesquisa relacionados aos processos de tratamento de água.

REFERÊNCIAS

- [1] Bernardo, L. D., Ângela D., Métodos e Técnicas de Tratamento de Água, Rima, 2ª Edição, vol. 1, 2005.
- [2] Heller, L., Valter, L. P., Abastecimento de Água para Consumo Humano, Editora UFMJ, 2ª Edição, vol. 1, 2010.
- [3] IBGE, “Pesquisa Nacional de Saneamento Básico”, Ministério das Cidades – Governo Federal do Brasil, 2008.
- [4] FUNASA, “Manual de Saneamento”, Ministério da Saúde – Governo Federal do Brasil, 3ª Edição, 2004.
- [5] Tsutiya, M. T., Abastecimento de Água, Dep. de Eng. Hidráulica e Sanitária da Escola Politécnica da USP, 1ª Edição, pp. 2-8, 2004.
- [6] DATASUS, “Informações sobre Saúde”, SUS – Governo Federal do Brasil, 2009.
- [7] Netto, A., “Cronologia do Abastecimento de Água”, DAE, vol. 44, pp. 106-111, 1984.
- [8] SANASA, “Panorama do Saneamento Básico no Brasil”, Ministério das Cidades – Governo Federal do Brasil, vol. 1, 2011.
- [9] CAGECE, “Marcos da História do Saneamento Básico no Ceará”, Companhia de Água e Esgoto do Ceará, disponível na intranet da CAGECE, acessado em 20 de julho de 2011.
- [10] Casa Civil, “Lei N° 11.445”, Presidência da República – Governo Federal do Brasil, 2007.
- [11] INSTITUTO TRATA BRASIL, “Um Ano de Acompanhamento do PAC Saneamento”, 2010.
- [12] CAGECE, “História da Companhia”, Companhia de Água e Esgoto do Ceará, 2010.
- [13] Holanda, A., Santos, C., Automação de olho no futuro, SANEAS – Associação dos Engenheiros da Sabesp, Revista, vol. 02, num. 24, 2006.
- [14] Cassiolato, César. “Redes Industriais”, Artigo Técnico, SMAR Automação, 2011.

- [15] Gomes, Leonaldo da S., “Projeto de Automação da ETA de Graça”, Projeto Executivo, Companhia de Água e Esgoto do Ceará, GCOPE, 2011.
- [16] Gagnon C., Grandjean B. P., Thibault J., “Modelling of coagulant dosage in a water treatment plant”, *Artificial Intelligence in Engineering*, vol 11, no 4, pp 401-404, 1997.
- [17] Joo D. S., Choi D. J., Park H., “The effects of data preprocessing in the determination of coagulant dosing rate”, *Water Research*, vol 34, no 13, pp 3295-3302, 2000.
- [18] Deveughele S., Do-Quang Z., “Neural networks: na efficient approach to predict on-line the optimal coagulant dose”, *Water Suplly*, vol 4, no 5-6, pp 87-94, 2005.
- [19] Maier H. R., Morgan N., Chow C. W., “Use of artificial neural networks for predicting optimal alum doses and treated water quality parameters”, *Environmental Modelling & Software*, vol 19, no 5, pp 485-494, 2004.
- [20] Wu G. D., Lo S. L., “Predicting real-time coagulant dosage in water treatment by artificial neural networks and adaptive network-based fuzzy inference system”, *Engineering Applications of Artificial Intelligence*, vol 21, no 8, pp 1189-1195, 2008.
- [21] Heddam S., Bermad A., Dechemi N., “Applications of radial-basis function and generalized regression neural networks for modeling of coagulant dosage in a drinking water-treatment plant: Comparative study”, *Journal of Environmental Engineering*, vol 137, no 12, pp 1-6, 2011.
- [22] Heddam S., Bermad A., Dechemi N., “Anfis-based modelling for coagulant dosage in drinking water treatment plant: a case study”, *Environmental Monitoring and Assessment*, vol 184, pp 1953-1971, 2012.
- [23] CONAMA, “Resolução 357”, Ministério do Meio Ambiente – Governo Federal do Brasil, 2005.
- [24] SVS, “Portaria 518”, Ministério da Saúde – Governo Federal do Brasil, 2004.
- [25] Bernardo, L. D., Ângela D., *Métodos e Técnicas de Tratamento de Água*, Rima, 2ª Edição, vol. 2, 2005.

- [26] PROSAB, Manual para estudo de cianobactérias planctônicas em mananciais de abastecimento público: caso da represa Lomba do Sabão e lago Guaíba, Porto Alegre, Rio Grande do Sul, PROSAB, 1ª Edição, 2006.
- [27] Teixeira E. C., Senhorelo A. P., “Avaliação de Correlação entre Turbidez e Concentração de Sólidos Suspensos em Bacias Hidrográficas com uso e Ocupação Diferenciada.”, ABES, XXVII CIESA, 2000.
- [28] Hach Company, “Filter Trak™ 660sc, User Manual”, 2008.
- [29] OPTEK, “C4000 Photometric Converter Data-Sheet”, 2011.
- [30] Bernardo, L. D., Brandão, C. S., Heller, L., Tratamento de Águas de Abastecimento por Filtração em Múltiplas Etapas, PROSAB, 1ª Edição, 1999.
- [31] Heller, L., Valter, L. P., Abastecimento de Água para Consumo Humano, Editora UFMJ, 2ª Edição, vol. 2, 2010.
- [32] PROSAB, Filtração rápida Aplicada a Pequenas Comunidades, PROSAB, 1ª Edição, 2003.
- [33] Tchobanoglous, G., Schoroeder, E. D., Water Quality – Characteristics, Modeling, Modification, Addison-Wesley Publishing Company, 1nd Edition, 1985.
- [34] CHEMTRAC, “SCM2500XRD Streaming Current Monitor & Streaming Current Controller with Dura-Trac™ Remote Sensor”, 2011.
- [35] Amirtharajah, A. & Mills, K. M., “Rapid-Mix Design for Mechanisms of Alum Coagulation”, J. AWWA, vol. 74, no. 4, pp. 20-216, 1982.
- [36] CAGECE, “Boletim Diário de Controle de Dosagem de Produtos Químicos”, Companhia de Água e Esgoto do Ceará – GPROD, 2010.
- [37] CAGECE, “Esquema de Funcionamento da ETA Gavião”, Companhia de Água e Esgoto do Ceará – GPROD, 2009.
- [38] CAGECE, “Boletim Diário de Controle da Qualidade de Tratamento”, Companhia de Água e Esgoto do Ceará – GPROD, 2010.

- [39] NETZSCH, “Bombas NEMO 2N320A e NM011_02S – Catálogo”, 2006.
- [40] NETZSCH, “Curvas Características bombas NEMO 2NE20A e NM011_02S - Catálogo”, 2011.
- [41] WEG, “Inversor de Freqüência CFW-10 Manual do Usuário”, 2007.
- [42] Haykin, S., Redes Neurais – Princípios e Prática, Bookman, 2ª edição, 2001.
- [43] Braga, A. P., Ludemir, T. B., Carvalho, A. C. P. L. F., Redes Neurais Artificiais – Teoria e Aplicações, LCT, 1ª Edição, 2000.
- [44] Barreto, G. A., “Redes Neurais Não-Supervisionadas para Processamento de Sequências Temporais”, Dissertação de Mestrado, Universidade de São Paulo – USP, 1998.
- [45] Hebb, D.O., The organization of behavior, Wiley, 1949.
- [46] Hornik, K., Stinchcombe, M., White, H., “Multilayer feedforward networks are universal approximators”, Neural Networks, vol. 2, pp. 359-366, 1989.
- [47] Júnior, J. M. P. de M., “Redes Neurais Dinâmicas para Predição e Modelagem Não-Linear de Séries Temporais”, Dissertação de Mestrado, Universidade Federal do Ceará – UFC, 2006.
- [48] Zanata, D. R. P., “Desenvolvimento De Sensor Virtual Empregando Redes Neurais Para Medição Da Composição Em Uma Coluna De Destilação”, Dissertação de Mestrado, Universidade de São Paulo – USP, 2005.
- [49] McCulloch, S., Pitts, W., “A logical calculus of the ideas immanent in nervous activity”, Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133, 1943.
- [50] Mozer, M. C., “Neural network architectures for temporal pattern processing”, Addison-Wesley Publishing, A. S. Weigend & N. A. Gershenfeld, Time series prediction: Forecasting the future and understanding the past. Redwood City, CA: Sante Fe Institute Studies in the Sciences of Complexity, Proceedings Volume XVII, pp. 243-264, 1993.
- [51] Sandberg, I. W., L. Xu, “Uniform approximation of multidimensional myopic maps”, IEEE Transactions on Circuits and Systems, vol. 44, pp. 477-485, 1997.

- [52] Elman, J. L., "Finding structure in time", *Cognitive Science*, vol. 14, pp. 179-211, 1990.
- [53] MathWorks, Inc, "Neural Network Toolbox, User's Guide", section 10, 2010.
- [54] Lin, T., Horne, B. G., Tino, P., Giles, C. L., "Learning long-term dependencies in NARX recurrent neural networks", *IEEE Transactions on Neural Networks*, vol. 7, N° 6, pp. 1424-1438, 1996.
- [55] Lin, T., Horne, B. G., Giles, C. L., "How embedded memory in recurrent neural network architectures helps learning log-term temporal dependencies", *Neural Networks*, vol. 11, N° 5, pp. 861-868, 1998.
- [56] Fortuna, L., Graziani, S., Rizzo A., Xibilia, M. G., *Soft Sensors for Monitoring and Control of Industrial Processes*, Springer, 2007.
- [57] Warne, K. P., G. Rezvani, S. Maguire, L., *Statistical and computational intelligence techniques for inferential model development: a comparative evaluation and a novel proposition for fusion*, *Engineering Applications of Artificial Intelligence*, vol. 17, 2004.
- [58] MathWorks, Inc, "Curve Fitting Toolbox, User's Guide", section 2, 2002.
- [59] Johnson R. A., Wichern D. W., *Applied Multivariate Statistical Analysis*, Prentice Hall, 6nd Edition, 2007.
- [60] Mason, R. L., Gunst, R. F., Hess, J. L., *Statistical Design and Analysis of Experiments*, Wiley Interscience, 2nd Edition, 2003.
- [61] Barreto, G. de A., "Perceptron Multicamadas e o Algoritmo de Retropropagação do Erro", Departamento de Teleinformática – UFC, Notas de Aula, 2007.
- [62] Gomes, L. S., "Modelo Neural NARX Aplicado à Inferência dos Sinais de Controle de Dosagem de Coagulantes Principal e Auxiliar no Processo de Tratamento de Água por Filtração Direta", X Congresso Brasileiro de Inteligência Computacional – CBIC, 2011.
- [63] Baum, E. B., Haussler, d., "What size net gives valid generalization?", *Neural Computation*, MIT Press, vol. 1, pp. 151-160, 1989.

- [64] Hagan, M.T. Menhaj, M.B., “Training Feedforward Networks with the Marquardt Algorithm”, **Neural Networks**, IEEE Transactions On Neural Networks, vol. 5, pp. 989-993, 1994.
- [65] Basheer, I. A., Haimeer, M., “Artificial neural networks: fundamentals, computing, desing, and application”, *Journal of Microbiological Methods*, vol. 43, pp. 3-31, 2000.
- [66] Montgomery D. C., Runger G. C., *Estatística Aplicada e Probabilidade para Engenheiros*, LTC, 2ª Edição, 2003.
- [67] CAGECE, “Convênio 0025 CAGECE / UFC”, Companhia de Água e Esgoto do Ceará – GEPED, 2010.
- [68] FUNCEME, “Série Histórica do Posto Pluviométrico de Pacatuba”, 2009.

ANEXO A – PLANTAS GERAL E DE LAY-OUT DA ETA GAVIÃO