



UNIVERSIDADE ESTADUAL DA PARAÍBA
CENTRO DE CIÊNCIA E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA AMBIENTAL

**MODELAGEM E SIMULAÇÃO DE UM SISTEMA DE TRATAMENTO DE ESGOTO
SANITÁRIO USANDO REDE NEURAL ARTIFICIAL**

PEDRO NOGUEIRA DA SILVA NETO

CAMPINA GRANDE - PB

MAIO - 2015

PEDRO NOGUEIRA DA SILVA NETO

**MODELAGEM E SIMULAÇÃO DE UM SISTEMA DE TRATAMENTO DE ESGOTO
SANITÁRIO USANDO REDE NEURAL ARTIFICIAL**

Dissertação de mestrado apresentado ao Programa de Pós-Graduação em Ciência e Tecnologia Ambiental da Universidade Estadual da Paraíba, como parte dos requisitos para obtenção do título de Mestre em Ciência e Tecnologia Ambiental

Sub-área: Tecnologias de tratamento de água e resíduos

Orientador: Prof. Dr. Fernando Fernandes Vieira

CAMPINA GRANDE - PB

MAIO- 2015

É expressamente proibida a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano da dissertação.

S586m Silva Neto, Pedro Nogueira da.
Modelagem e simulação de um sistema de tratamento de esgoto sanitário usando Rede Neural Artificial [manuscrito] / Pedro Nogueira da Silva Neto. - 2015.
69 p. : il. color.

Digitado.
Dissertação (Mestrado em Ciência e Tecnologia Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2015.
"Orientação: Prof. Dr. Fernando Fernandes Vieira, Departamento de Engenharia Sanitária e Ambiental".

1. Tratamento de esgoto. 2. Matéria orgânica. 3. MATLAB.
4. Redes Neurais Artificiais. I. Título.

21. ed. CDD 628.3

PEDRO NOGUEIRA DA SILVA NETO

**MODELAGEM E SIMULAÇÃO DE UM SISTEMA DE TRATAMENTO DE
ESGOTO SANITÁRIO USANDO REDE NEURAL ARTIFICIAL**

Dissertação de mestrado apresentado ao Programa de Pós-Graduação em Ciência e Tecnologia Ambiental (PPGCTA) da Universidade Estadual da Paraíba, como parte dos requisitos para obtenção do título de Mestre em Ciência e Tecnologia Ambiental

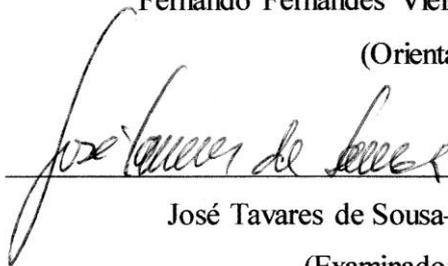
Data: 28/05/2015

Banca examinadora



Fernando Fernandes Vieira– DESA/CCT/UEPB

(Orientador)



José Tavares de Sousa– DESA/CCT/UEPB

(Examinador interno)



Enivaldo Santos Barbosa – UAEM/CCT/UFCG

(Examinador externo)

“Que os vossos esforços desafiem as impossibilidades, lembrai-vos de que as grandes coisas do homem foram conquistadas do que parecia impossível.”

Charles Chaplin

AGRADECIMENTOS

A Deus pela realização de mais uma conquista na minha vida.

A minha mãe Laudeci Nogueira, a minha irmã Laís Helena e a minha sobrinha Ana Beatriz pelo amor incondicional, apoio e incentivo a minha formação profissional e pessoal.

A minha avó Helena Gomes pela dedicação a minha educação e pelos momentos de carinho, amor e felicidade.

A Polyana de Brito, pelo amor, compreensão e incentivo durante toda jornada dessa pesquisa, sendo meu suporte em todos os momentos e instrumento fundamental para que este trabalho fosse concluído.

Ao exemplo de profissional, meu orientador Fernando Fernandes, pelas valiosas discussões, confiança, orientação, acessibilidade, incentivo e amizade.

Ao prof. Rui de Oliveira por contribuir com valiosas orientações e conhecimentos para elaboração deste trabalho, sendo uma inspiração para minha carreira docente.

Aos colegas do Programa de Ciência e Tecnologia ambiental, em especial, Dennis Dantas, pelos conhecimentos compartilhados, momentos de alegria, convivência, apoio e incentivo. Agradeço também a Jácina Tábita pelo suporte na modelagem e sua disponibilidade em tirar minhas dúvidas.

Ao IFPB pela compreensão nos momentos de flexibilidade para qualificação profissional, bem como, pelo suporte computacional através da licença do software MATLAB.

Enfim, a todos aqueles que participaram desta realização direta ou indiretamente, na amizade, no auxílio e nas críticas, contribuindo assim para a conclusão dessa pesquisa.

RESUMO

O aumento populacional nas cidades, e em paralelo, a intensificação das atividades agrícolas e pecuárias, além do desenvolvimento industrial e agroindustrial são as principais causas para o aumento do lançamento de esgotos, muitas vezes dispostos em lagos, mares e rios na sua forma bruta ou com tratamento insuficiente. Reatores Upflow Anaerobic Sludge Blanket (UASB) surgem como uma possibilidade para tratamento de vários tipos de águas residuárias, sendo bastante difundido e bem mais aplicado do que os outros e, tendo como aspecto essencial do processo a natureza da biomassa ativa. As Redes Neurais Artificiais (RNA's) constituem um tipo de modelo matemático da área da Inteligência Artificial são uma técnica de modelagem baseada nas relações entrada-saída (estruturas black-box) que tem recebido grande interesse da comunidade científica, sendo realizadas pesquisas de forma multidisciplinar. Assim, esta pesquisa se estrutura com o objetivo de modelar e simular um reator UASB, afim de avaliar e estabelecer parâmetros de controle, através de Redes Neurais Artificiais (RNA). O conjunto de dados, referentes aos 13 parâmetros analisados, foi subdividido de três formas diferentes e com o uso de uma camada oculta e com duas camadas ocultas com variação do número de neurônios em quantidades de 5, 10 e 15. Além disso, as funções de ativação sofreram modificação com o intuito de obter flutuações das redes. Dessa forma, concluiu-se que quando se utiliza uma única camada intermediária, a melhor função de ativação foi a Logsig e a melhor distribuição de dados apresentou-se quando foi combinado 80% dos dados usados para treinamento, 10 % para teste e 10 % para validação. Paralelamente, é possível concluir que quanto maior é o número de neurônio usado na camada oculta, melhores coeficientes de determinação são encontrados. Nesta circunstância, o R^2 foi de 0,9985, valor considerado muito satisfatório para predição dos parâmetros analisados. Quando modelada com 2 camadas ocultas, os resultados assemelharam-se bastante com as simulações de uma camada oculta, visto os melhores resultados terem sido obtidos na distribuição de dados , 80%, 10% , 10%, respectivamente para treinamento, teste e validação. O melhor coeficiente de determinação foi obtido com a combinação das funções de ativação Tansig na camada oculta 1 e Logsig na camada oculta 2, obtivendo um R^2 de 0,9912, considerado excelente para a predição dos dados.

Palavras-chave: Tratamento de esgoto, matéria orgânica, MATLAB, função de ativação, coeficiente de determinação

ABSTRACT

The population growth in cities, and in parallel, the intensification of agricultural and livestock activities, in addition to industrial and agro-industrial development are the main causes for the increase in the dumping of sewage, often arranged in lakes, seas and rivers in its raw form or with insufficient treatment. Upflow Anaerobic Sludge Blanket (UASB) reactors appear as an option for treatment of various types of wastewater, widespread and well being applied more than the other, and having as an essential aspect of the process the nature of the active biomass. The Artificial Neural Networks (ANN) are a type of mathematical model of the area of Artificial Intelligence are a modeling technique based on input-output relations (black-box structures) that has received great interest from the scientific community, being carried out research in a multidisciplinary way. Thus, this research is structured in order to model and simulate a UASB reactor in order to evaluate and establish control parameters, using Artificial Neural Networks (ANN). The set of data relating to the 13 analyzed parameters, has been subdivided in three different forms and the use of a hidden layer and two hidden layers with varying number of neurons in amounts of 5, 10 and 15. In addition, the functions activation were modified in order to obtain fluctuations networks. Thus, it was found that when using a single intermediate layer, the best activation function was Logsig and better distribution data is presented when it was combined 80% of the data used for training, 10% for trial and 10% for validation. At the same time, one can conclude that the greater the number of neurons used in the hidden layer, best determination coefficients are found. In this circumstance, the R^2 was 0.9985, which was considered most suitable for predicting the parameters analyzed. When patterned with 2 hidden layers, the results resembled well with the simulation of a hidden layer, since the best results have been obtained for distributing data, 80%, 10%, 10% respectively to training, testing and validation. The best determination coefficient was obtained with the combination of Tansig activation functions in the hidden layer 1 and Logsig in the hidden layer 2, obtivendo an R^2 of 0.9912, considered excellent for predicting the data

Key-words: Sewage treatment, organic matter, MATLAB®, activation function, determination coefficient

LISTA DE FIGURAS

Figura 1-	Reator em batelada, em sequência operacional.....	21
Figura 2-	Reator de fluxo em pistão.....	21
Figura 3 -	Reator de mistura completa.....	22
Figura 4-	Reator de fluxo disperso ou arbitrário.....	22
Figura 5 -	Reator com enchimento, em fluxo ascendente	23
Figura 6 -	Representação de um neurônio biológico.....	28
Figura 7 -	Representação de um neurônio artificial.....	29
Figura 8 -	Representação de um neurônio artificial McCullochs-Pitt.....	29
Figura 9 -	Representação dos tipos de função de ativação: a) função linear; b) função Sigmoidal; c) função Tangente hiperbólica.....	31
Figura 10 -	Representação de uma rede neural de camada única.....	32
Figura 11 -	Representação de uma rede neural de camada múltipla.....	32
Figura 12 -	Esquema geral do sistema composto por reatores UASB e SBR seguidos de coluna de desnitrificação.....	39
Figura 13 -	Representação da arquitetura da rede neural com uma camada oculta.....	45
Figura 14 -	Representação da arquitetura da rede com duas camadas ocultas	46
Figura 15 -	Gráficos <i>Box Plot</i> da concentração de ácidos voláteis na entrada e saída do reator UASB.....	47
Figura 16 -	Gráficos <i>Box Plot</i> da concentração de alcalinidade total, na entrada e saída do reator UASB.....	47
Figura 17-	Gráficos <i>Box Plot</i> da concentração de DQO bruta na entrada e saída do reator UASB.....	48
Figura 18 -	Gráficos <i>Box Plot</i> da concentração de DQO filtrada na entrada e saída do reator UASB.....	48
Figura 19 -	Gráficos <i>Box Plot</i> da concentração de Fósforo na entrada e saída do reator UASB.....	48
Figura 20 -	Gráficos <i>Box Plot</i> da concentração de Nitrogênio amoniacal, na entrada e saída do reator UASB.....	49
Figura 21-	Gráficos <i>Box Plot</i> da concentração de Nitrogênio orgânico, na entrada e saída do reator UASB.....	49
Figura 22-	Gráficos <i>Box Plot</i> da concentração de Nitrogênio Kjeldahl na entrada e	

	saída do reator UASB.....	49
Figura 23-	Gráficos <i>Box Plot</i> da concentração de potencial Hidrogeniônico na entrada e saída do reator UASB.....	50
Figura 24-	Gráficos <i>Box Plot</i> da concentração de sólidos suspensos fixos na entrada e saída do reator UASB.....	50
Figura 25-	Gráficos <i>Box Plot</i> da concentração de sólidos suspensos voláteis na entrada e saída do reator UASB.....	50
Figura 26-	Gráficos <i>Box Plot</i> da concentração de sólidos suspensos totais na entrada e saída do reator UASB.....	51
Figura 27-	Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 30ª semana de operação.....	55
Figura 28-	Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 19ª semana de operação.....	56
Figura 29-	Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 7ª semana de operação.....	56
Figura 30-	Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 10ª semana de operação.....	56
Figura 31-	Representação gráfica de valores experimentais e simulados, usando o conjunto 60.20.20 para 38ª semana de operação.....	57
Figura 32-	Representação gráfica de valores experimentais e simulados, usando o conjunto 60.20.20 para 39ª semana de operação.....	57
Figura 33-	Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 39ª semana de operação.....	58
Figura 34-	Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 49ª semana de operação.....	58
Figura 35-	Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 29ª semana de operação.....	59
Figura 36-	Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 40ª semana de operação.....	59
Figura 37-	Representação gráfica de valores experimentais e simulados, usando o conjunto 60.20.20 para 28ª semana de operação.....	60
Figura 38 -	Representação gráfica de valores experimentais e simulados, usando o conjunto 60.20.20 para 53ª semana de operação.....	60

LISTA DE TABELAS

Tabela1-	Funções de ativação, equação e função correspondente no software MATLAB.....	31
Tabela 2-	Condições operacionais da coluna de desnitrificação à 30° C.....	42
Tabela 3-	Parâmetros analisados, métodos e frequência das análises.....	42
Tabela 4-	Representação da concentração média de todos os parâmetros na entrada e saída do reator UASB.....	53
Tabela 5-	Coefficiente de determinação em função da subdivisão do conjunto de dados e do número de neurônios da camada oculta.....	54
Tabela 6-	Coefficiente de determinação em função da subdivisão do conjunto de dados e do número de neurônios da camada oculta.....	54

LISTA DE ABREVIATURAS E SIGLAS

ABNT – Associação Brasileira de Normas Técnicas
BPNN – Rede Neural com Back-Propagation
DBO – Demanda Bioquímica de Oxigênio
DQO – Demanda Química de Oxigênio
EQM – Erro Quadrático Médio
FLN- Redes Neurais Functional-link
GA-NN – Rede Neural com algoritmo genético
GSS – *Gas-SolidSeparator*
IBGE – Instituto Brasileiro de Geografia e Estatística
MCP – Rede Neural de McCullochPitts
MLP – *MultiLayerPerceptron*
MLR- Regressão Linear Multivariada
NN- Número de neurônios
N-NH₄⁺ - Nitrogênio Amoniacal
N-ORG – Nitrogênio Orgânico
NTK- Nitrogênio Kjeldahl Total
PCR-Regressão por Componentes Principais
pH- potencial Hidrogeniônico
PLSR-Regressão por Mínimos Quadrados Parciais
PVC – Policloreto de Vinila
RNA – Rede Neural Artificial
RMS- Root Mean Square
SBR –Reator Sequencial em Batelada
SS- Sólidos Suspensos
SSF- Sólidos Suspensos Fixos
SST – Sólidos Suspensos Totais
SSV – Sólidos Suspensos Voláteis
TDH – Tempo de Detenção Hidráulica
TOC- Carbono Orgânico Total
UASB - *UpflowAnaerobicSlugdeBlanket*

SUMÁRIO

1. INTRODUÇÃO	14
1.1 Objetivos do trabalho.....	15
1.1.1 Objetivo geral	15
1.1.2 Objetivos específicos.....	15
2. REVISÃO BIBLIOGRÁFICA	16
2.1. Esgotos sanitários.....	16
2.1.1. Tratamento de esgotos.....	17
2.1.1.1 Reatores básicos.....	21
2.1.1.1.1 Reator anaeróbio UASB	24
2.1.1.2 Associação entre sistemas de tratamento de esgoto.....	25
2.1.1.2.1 Lodo ativado para desnitrificação.....	26
2.2 Redes Neurais Artificiais.....	26
2.2.1 Introdução.....	26
2.2.2 Breve histórico das redes neurais artificiais.....	27
2.2.3 Neurônio natural.....	28
2.2.4 Neurônio artificial.....	29
2.2.5 Arquitetura de rede.....	32
3. ESTADO DA ARTE	34
4. METODOLOGIA	40
4.1 Introdução.....	40
4.2 Procedimentos no sistema de tratamento de esgoto sanitário.....	40
4.3 Preparação dos dados.....	43
5. RESULTADOS E DISCUSSÃO	47
5.1 Estatística descritiva dos dados.....	47
5.2 Arquitetura da Rede Neural.....	53
5.2.1 Análise da influência do número de neurônios.....	53
5.2.1.1 Rede Neural com uma camada oculta.....	54
5.2.1.2 Rede Neural com duas camadas ocultas.....	54
5.2.2 Simulação do reator UASB usando RNA.....	
5.2.2.1 Simulação usando RNA com uma camada oculta.....	55
5.2.2.2 Simulação usando RNA com duas camadas ocultas.....	57
6. CONSIDERAÇÕES FINAIS	61

7. REFERÊNCIAS BIBLIOGRÁFICAS.....	63
APÊNDICE.....	66

1 INTRODUÇÃO

O aumento populacional nas cidades, e em paralelo, a intensificação das atividades agrícolas e pecuárias, para atender à demanda crescente de alimentos, além do desenvolvimento industrial e agroindustrial são as principais causas para o aumento do lançamento de esgotos, muitas vezes dispostos em lagos, mares e rios na sua forma bruta ou com tratamento insuficiente.

Segundo Leme (2014), um sistema de esgotamento sanitário é um conjunto de obras e instalações destinadas a realizar coleta, afastamento, tratamento e disposição final dos esgotos. A melhoria das condições sanitárias locais, a proteção e conservação dos recursos hídricos, a eliminação de focos de poluição e contaminação, como também de aspectos estéticos desagradáveis são os principais objetivos para construção de um sistema de esgotamento.

Uma unidade de tratamento de esgotos deverá promover a remoção de poluentes de maior concentração presente nos efluentes, como por exemplo: matéria orgânica, sólidos em suspensão, Nitrogênio e Fósforo, compostos tóxicos e não biodegradáveis. A legislação ambiental vigente (CONAMA 357/2005) estabelece os padrões, normas e procedimentos para o seu tratamento e lançamento nos recursos hídricos.

Por outro lado, as Redes Neurais Artificiais (RNA's) constituem um tipo de modelo matemático da área da Inteligência Artificial. Este instrumento, objeto de estudo deste trabalho, é uma técnica de modelagem baseada nas relações entrada-saída (estruturas black-box). Este enfoque tem recebido grande interesse da comunidade científica (LJUNG, 1994), sendo realizadas pesquisas de forma multidisciplinar. Dentre os ramos do conhecimento interessados neste tipo de abordagem, podem ser citados: neurociência, engenharia (de uma maneira geral), ciência da computação, matemática, filosofia, física e psicologia.

Na área de engenharia ambiental há uma intensificação nos estudos que se utilizam de RNA para tomada de decisões. Com a função de minimização dos impactos ambientais e agilidade nas decisões é crescente a utilização das redes para soluções que visem o desenvolvimento sustentável.

Para o enquadramento dos efluentes nos padrões para lançamentos exigidos pela legislação são necessárias diversas análises físicas, químicas e biológicas, o que demanda tempo e custos. A principal motivação desse trabalho foi contribuir com a predição dos resultados dessas análises, visto que as RNA, diferente das demais técnicas de modelagem tradicionais, são capazes de representar relações lineares e não lineares pelo processo de

aprendizagem, mesmo conhecendo pouco sobre o processo, desde que a estrutura de correlação do processo não mude.

Assim, esse estudo apresenta a modelagem e simulação de um reator *UASB*, utilizando o software computacional MATLAB®, para redes com uma e duas camadas ocultas, analisando a influência da função de ativação e do número de neurônios para a formação da rede.

1.1 Objetivos do trabalho

1.1.1 Objetivo Geral

Modelar e simular um reator *UASB*, afim de avaliar e estabelecer parâmetros de controle, através de Redes Neurais Artificiais (RNA).

1.1.2 Objetivos Específicos

- a. Realizar a estatística descritiva dos dados experimentais, afim de atestar o êxito do funcionamento do reator *UASB*;
- b. Analisar dados quantitativos a respeito do funcionamento de um sistema de tratamento em consonância com RNA;
- c. Avaliar as variáveis de entrada, arquitetura da rede neural, a distribuição dos dados e o desempenho dos algoritmos de otimização utilizados;
- d. Desenvolver uma estrutura neural para o reator *UASB* baseada nos parâmetros físicos e químicos selecionados;
- e. Simular o reator *UASB* usando a RNA e avaliar a qualidade do modelo obtido.

2 REVISÃO BIBLIOGRÁFICA

2.1 Esgotos sanitários

A disposição de esgotos brutos ou com tratamento insuficiente no solo ou em corpos hídricos, como lagos, mares e rios, é uma prática bastante antiga e ainda muito intensa, o que faz os impactos gerados pelo lançamento desses esgotos serem motivo de grande preocupação, não só no Brasil, mas na maioria dos países.

Dentre os municípios brasileiros, 3069 apresentam coleta de esgoto sanitário, sendo que 1587 municípios recebem tratamento, ou seja, segundo dados do IBGE(2008), 55,10% dos municípios brasileiros têm coleta de esgoto e apenas 28,49% recebem tratamento. Há de ressaltar que, a pesquisa considera o município em que pelo menos um distrito, ou parte dele, tenha coleta de esgoto e, dentre estes, que tenha tratamento, o que torna esses dados mais otimistas.

Segundo Gonçalves *et al.* (2003), várias regiões brasileiras apresentam grande deficiência no esgotamento sanitário, sendo o volume de esgoto, bruto ou insuficiente tratado, lançado nos corpos receptores significativamente expressivo no que diz respeito à contaminação por organismos patogênicos. E mesmo em locais com estações de tratamento, os riscos de contaminação das pessoas em contato direto ou indireto com os efluentes são reais, refletindo nos indicadores de saúde.

Esgoto sanitário é o despejo líquido constituído de esgotos domésticos, industriais, água de infiltração e a contribuição pluvial parasitária (ABNT, 1987).

De acordo com Braga (2002), a parcela mais significativa dos esgotos sanitários são os esgotos domésticos e suas características variam em função dos costumes, hábitos higiênicos e condições socioeconômicas da população. Os esgotos domésticos provêm, principalmente, de residências, edificações públicas e comerciais e são compostos basicamente de águas de banho, urina, fezes, restos de comida, sabões, detergentes e águas de lavagens.

Em virtude da menor fração do esgoto, a parte sólida, é que esgotos precisam ser tratados, haja vista que, nela estão inclusos sólidos orgânicos, inorgânicos e organismos como bactérias, vírus, vermes e protozoários.

Por este motivo, a disposição inadequada dos esgotos podem causar diversas infecções através da água, alimentos, utensílios domésticos, mãos ou solo contaminados.

Conforme Leme (2014), diversos agentes patogênicos transmissores de doenças para o homem estão presentes nos esgotos, entre eles: *Ascaris spp* e *Enterobius spp*, causadores das

verminoses; *Ancylostomaspp*, causadores do amarelão; *Bacillus anthracis*, causador do antraz; *Brucellasp*, causadores da brucelose, *Entamoebahistolyticae* *Giardiaspp*, causadores da diarreia; *Leptospiraspp*, causadores da leptospirose; *Mycobacterium tuberculosis*, causador da tuberculose, *Salmonellaspp*, causadoras de febre tifoide e paratifoide, *Schistosomaspp*, causadores de esquistossomose, *Vibriocholerae*, causador da cólera; evírus, causadores da poliomielite, hepatite infecciosa e outros.

Além dos problemas relacionados à saúde pública, a preservação do meio ambiente também é um motivo importante para tratar os esgotos, visto que, a matéria orgânica presente pode causar o consumo excessivo do oxigênio dissolvido, ocasionando assim, a morte de peixes e demais organismos aquáticos aeróbios.

Os nutrientes, como Fósforo e Nitrogênio, presente nos esgotos, provocam a eutrofização, processo ocasionado pela multiplicação das algas que formam uma camada densa na superfície da água, impedindo a passagem da luminosidade, fator fundamental para a atividade fotossintética.

De acordo com Mota e Von Sperling (2009), a eutrofização pode ocasionar, aos corpos receptores, problemas estéticos e recreacionais, condições anaeróbias no fundo do corpo d'água com um todo, eventuais mortandade de peixes, maior dificuldade e aumento nos custos do tratamento da água, problemas com abastecimento de águas industriais, toxicidade das algas, redução na navegação e capacidade de transporte. No que se refere a águas subterrâneas, o nitrato é uma grande preocupação, pois pode contaminar águas utilizadas para abastecimento, podendo causar problemas de saúde pública, como a Metemoglobinemia.

Parte-se do princípio que, o meio ambiente teria condições de receber e decompor os contaminantes de forma que não causassem problemas ao ecossistema local e circunvizinho, realizando assim, o tratamento biológico dos esgotos, através da autodepuração obtida pela ação dos microrganismos que transformam a matéria orgânica em compostos mais simples na busca por alimento e energia. Entretanto, esse tratamento depende da carga orgânica lançada e das condições ambientais existentes na água e no solo. Desse modo, o que ocorre frequentemente, é a sobrecarga desses corpos receptores causando a contaminação dos mesmos.

2.1.1 Tratamento de esgotos

O tratamento biológico de esgotos é um fenômeno natural presente no solo ou na água, mas para que ocorra é necessário que as condições sejam adequadas. Assim, as estações de

tratamento de esgotos são sistemas que exploram os métodos utilizados pelos microrganismos do solo e da água, com o intuito de otimizar esses processos e reduzir os custos, buscando a maior eficiência.

Segundo Von Sperling (2005), para a concepção de um sistema de tratamento são considerados aspectos, como: o impacto ambiental do lançamento no corpo receptor, os objetivos do tratamento, o nível do tratamento e a eficiência de remoção desejada. De acordo com o autor, o tratamento dos esgotos é classificado nos seguintes níveis:

- Tratamento preliminar – através de mecanismos físicos, objetiva apenas a remoção de sólidos grosseiros;
- Tratamento primário – também através de mecanismos físicos, objetiva a remoção dos sólidos sedimentáveis e parte da matéria orgânica;
- Tratamento secundário – a partir de mecanismos biológicos, objetiva remoção de matéria orgânica e casualmente nutrientes como Fósforo e Nitrogênio;
- Tratamento terciário – esse ocorre apenas eventualmente quando os poluentes não são suficientemente removidos no processo secundário, objetiva remoção de poluentes específicos como tóxicos ou compostos não biodegradáveis.

O Quadro 1 apresenta alguns dos principais sistemas de tratamento de esgotos domésticos em nível secundário, esses sistemas expostos, como também as lagoas de estabilização e o sistema de disposição no solo, são mais frequentes em países de clima quente.

Quadro 1 - Descrição sucinta de alguns sistemas de tratamento de esgoto em nível secundário

SISTEMAS ANAERÓBIOS	
Filtro anaeróbio	A DBO é convertida anaerobiamente por bactérias aderidas a um meio suporte, em geral pedras, no reator. O tanque trabalha submerso, e o fluxo é ascendente. O sistema necessita de decantação primária, frequentemente fossas sépticas. A produção de lodo é baixa e o lodo já sai estabilizado.
Reator anaeróbio de manta de lodo e fluxo ascendente (UASB)	A sigla <i>UASB</i> advém de <i>UpflowAnaerobicSludgeBlanket</i> . A DBO é convertida anaerobiamente por bactérias dispersas no reator. O fluxo do líquido é ascendente. A parte superior do reator é dividida nas zonas de sedimentação e de coleta de gás. A zona de sedimentação permite a saída do efluente clarificado e o retorno dos sólidos (biomassa) ao sistema aumentando sua concentração no reator. Um dos gases formados é o metano. O sistema dispensa a decantação primária. A produção de lodo é baixa e o lodo já sai adensado e estabilizado.
Reator anaeróbio – Pós-tratamento	Os reatores <i>UASB</i> usualmente não produzem um efluente que se adeque à maior parte dos padrões de lançamento. Por isso, frequentemente é necessária a incorporação de um pós-tratamento que pode ser biológico (aeróbico ou anaeróbico) ou físico-químico (com adição de coagulantes). Praticamente todos os processos de tratamento podem ser usados como pós-tratamento do reator <i>UASB</i> . A eficiência global do sistema é usualmente similar à que seria alcançada se o processo de pós-tratamento fosse aplicado ao esgoto bruto. Porém, os requisitos de área, volume e energia como também a produção de lodo são bem menores.
LODOS ATIVADOS	
Lodos ativados convencional	A etapa biológica compreende duas unidades: o reator biológico (tanque de aeração) e o decantador secundário. A concentração da biomassa no reator é bastante elevada, devido a recirculação dos sólidos sedimentados no fundo do decantador secundário. A biomassa permanece mais tempo no sistema do que o líquido, garantindo uma elevada eficiência na remoção de DBO. Há necessidade remover uma quantidade de lodo equivalente à que é produzida, necessitando também ser estabilizado na etapa de tratamento de lodo. O fornecimento de oxigênio é através de aeradores mecânicos ou ar difuso. A montante do reator, há um decantador primário para remover os sólidos sedimentáveis do esgoto bruto.
Lodos ativados por aeração prolongada	Similar ao sistema de Lodos convencional, com a diferença que a biomassa permanece mais tempo no sistema, os tanques de aeração são maiores. Havendo com isso menos substrato (DBO) para as bactérias, fazendo com que elas se utilizem da matéria orgânica do próprio material celular para sua manutenção. Consequentemente, o lodo excedente já sai estabilizado. Em geral, não incluem unidades de decantação primária.
Lodos ativados de fluxo intermitente	A operação do sistema é intermitente. Desse modo, no mesmo tanque ocorrem, em fases diferentes, as etapas de reação (aeradores ligados) e sedimentação (aeradores desligados). No momento em que os aeradores estão ligados, os sólidos sedimentam e o efluente (sobrenadante) é retirado. Ao se religar os aeradores, os sólidos sedimentados retornam a massa líquida, o que dispensa as elevatórias de recirculação. Não há decantadores secundários, pode ser na modalidade convencional ou aeração prolongada.

Continua

Continuação

Lodos ativados com remoção biológica de nitrogênio	O reator incorpora uma zona anóxica (ausente de oxigênio, mas com presença de nitratos). A zona anóxica pode estar a montante e/ou a jusante da zona aerada. Os nitratos formados pela nitrificação ocorrida na zona aeróbia são utilizados na respiração dos microrganismos facultativos nas zonas anóxicas, sendo reduzidos a nitrogênio gasoso que escapa para a atmosfera.
Lodos ativados com remoção biológica de nitrogênio e fósforo	Além das zonas aeróbias e anóxicas, o reator biológico incorpora ainda uma zona anaeróbia, situada na extremidade de montante. Recirculações internas fazem com que a biomassa esteja sucessivamente exposta a condições aeróbias e anaeróbias. Com esta alternância, um certo grupo de microrganismos absorve o fósforo do meio líquido em quantidades bem superiores às que seriam normalmente necessárias para seu metabolismo. A retirada destes organismos com o lodo excedente implica, dessa forma, na retirada de fósforo do reator biológico.
REATORES AERÓBIOS COM BIOFILMES	
Filtro de baixa carga	A DBO é estabilizada aerobiamente por bactérias que crescem aderidas a um meio suporte (material plástico ou pedras). O esgoto é aplicado na superfície do tanque através de distribuidores rotativos. O líquido percola pelo tanque, saindo pelo fundo, ao passo que a matéria orgânica fica retida, sendo posteriormente estabilizada pelas bactérias. Os espaços livres são vazios, permitindo a circulação de ar. No sistema de baixa carga, há pouca disponibilidade de DBO para as bactérias, fazendo com que elas sofram autodigestão, saindo estabilizadas do sistema. As placas de bactérias que se despregam das pedras são removidas do decantador secundário. O sistema necessita de decantação primária.
Filtro de alta carga	Similar ao sistema de Filtro de baixa carga, com a diferença de que a carga de DBO aplicada é maior. As bactérias (lodo excedente) necessitam de estabilização no tratamento do lodo. O efluente do decantador secundário é recirculado para o filtro, de forma a diluir o afluente e garantir uma carga hidráulica homogênea.
Biofiltro aerado submerso	O sistema é constituído por um tanque preenchido por um material poroso (usualmente submerso), através do qual esgoto e ar fluem permanentemente. O fluxo de ar no biofiltro é sempre ascendente, ao passo que o fluxo do líquido pode ser ascendente ou descendente. Os biofiltros com meios granulares realizam, no mesmo reator, a remoção de compostos orgânicos solúveis e de partículas em suspensão presentes nos esgotos. Além de servir de meio suporte para os microrganismos, o material granular se constitui em meio filtrante. São necessárias periódicas lavagens para eliminação do excesso de biomassa acumulada, reduzindo as perdas de carga hidráulica através do meio.
Biodisco	A biomassa cresce aderida a um meio suporte, o qual é constituído por discos. Os discos, parcialmente submersos no líquido, giram ora expondo a superfície ao líquido, ora ao ar.

Fonte: Adaptado de Von Sperling (2005).

Todos processos apresentados no Quadro 1 podem também ser utilizados como pós-tratamento de reatores anaeróbios, principalmente os reatores *UASB*. Esse tipo de projeto tem se tornado uma grande tendência nos novos projetos de estações de tratamento de esgotos. Dessa forma, os sistemas que apresentam decantadores primários ou tanques sépticos podem ser substituídos, com vantagens, por reatores *UASB*. Outra maneira de combinar as tecnologias de tratamento é ter uma primeira etapa com reatores *UASB*, ao invés do esgoto bruto entrar diretamente na unidade de tratamento secundário.

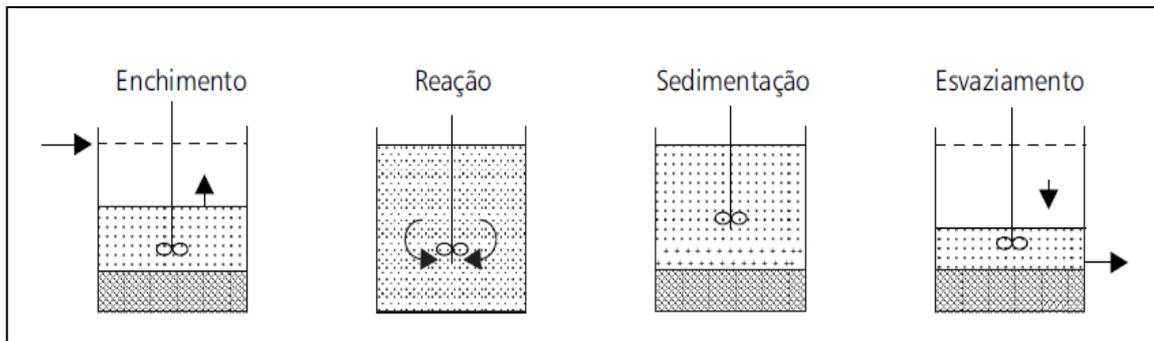
2.1.1.1 Reatores básicos

Segundo Campos (1999), as estações de tratamento de esgotos podem ter um ou mais reatores biológicos, em seus arranjos. A forma como se configura a seleção dos reatores dependem da disponibilidade de área, da variação das vazões, da operação e manutenção, dos custos, do consumo de energia, do uso de equipamentos, da mão-de-obra disponível, dos impactos ambientais, entre outros. Para escolher se o reator será aeróbio ou anaeróbio será analisado, principalmente, a velocidade das reações (cinética), tendo como aspectos determinantes: a mistura hidráulica e a retenção da biomassa.

As características hidráulicas de fluxo e mistura determinam as configurações dos reatores. Segundo Von Sperling (1996) com relação a fluxo eles serão de fluxo intermitente (entrada e saída descontínua) ou fluxo contínuo (entrada e saída contínuas), podendo serem classificados, basicamente, da seguinte forma:

- Reator em Batelada – nesse tipo de reator não há fluxo de esgoto entrando e saindo, o reator é preenchido no início e esvaziado no final. O conteúdo do reator é misturado completamente, permitindo um bom contato esgoto-biomassa. O tempo do tratamento é igual ao tempo de permanência do substrato no reator. Entretanto, esse reator se comporta com um volume discretizado num reator de fluxo em pistão. A Figura 01 esquematiza o reator em batelada, na sua sequência operacional.

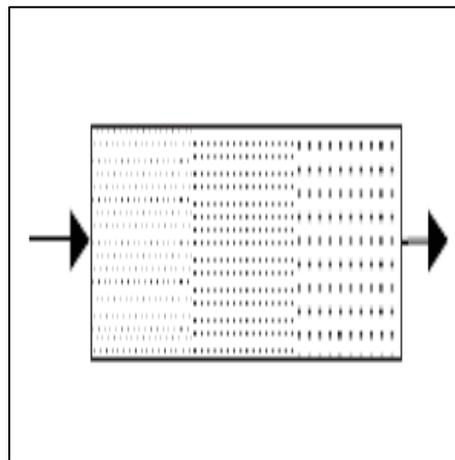
Figura 01 – Reator em batelada, em seqüência operacional.



Fonte: Campos (1999).

- Reator de fluxo em pistão – nesse tipo de reator o esgoto entra continuamente em uma extremidade do tanque, passam pelo interior do mesmo e são descarregadas na outra extremidade (esquematizado na Figura 02). O fluxo se processa com um êmbolo, não havendo misturas longitudinais. Por isso, esses reatores são reproduzidos em tanques longos, com elevada relação comprimento-largura, no qual a dispersão longitudinal é mínima.

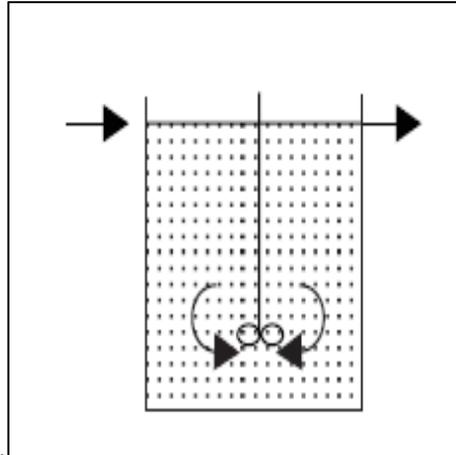
Figura 02 – Reator de fluxo em pistão.



Fonte: Campos (1999).

- Reator de mistura completa – as partículas que entram no tanque são imediatamente dispersas em todo o corpo do reator, sendo o fluxo de entrada e saída contínuo. A mistura completa é obtida em tanques circulares ou quadrados, quando o conteúdo do tanque é uniformemente distribuído. A Figura 03 apresenta o esquema desse tipo de reator:

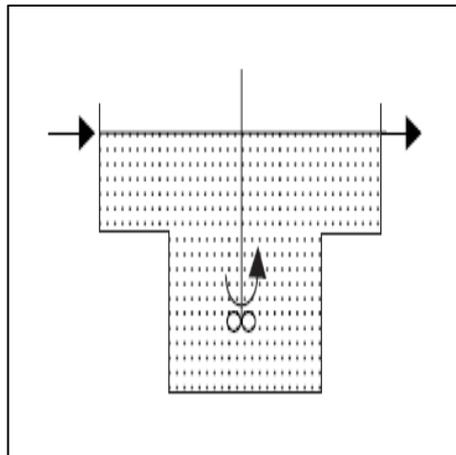
Figura 03 – Reator de mistura completa



Fonte: Campos (1999).

- Reator de fluxo disperso ou arbitrário – esse reator apresenta um grau de mistura intermediário entre os dois extremos idealizados (de fluxo em pistão e de mistura completa). Devido à dificuldade na modelagem dos ideais, são feitas aproximações para um dos modelos. Sendo assim, a maior parte dos reatores são de fluxo disperso (Figura 04).

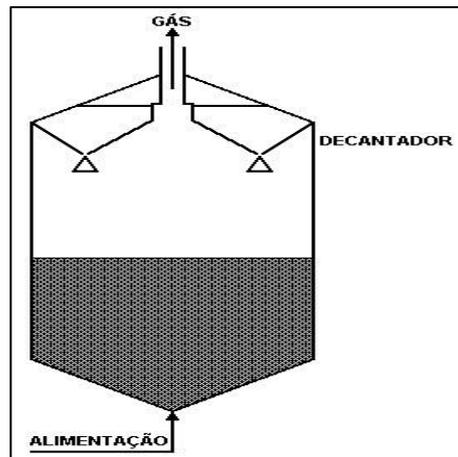
Figura 04– Reator de fluxo disperso ou arbitrário



Fonte: Campos (1999).

- Reator com enchimento – esse tipo de reator possui um meio de enchimento (pedra, plástico, cerâmica e outros). No que se refere ao fluxo e saturação, podem ser submersos com volume de poros saturados (filtro anaeróbico e biofiltro aerado) ou com dosagem intermitente, com os poros não saturados (filtro biológico). Podendo seu fluxo ser ascendente (Figura 05) ou descendente.

Figura 05 – Reator com enchimento, em fluxo ascendente.



Fonte: Cetesb (2014).

2.1.1.1.1 Reator anaeróbio *UASB*

Segundo Fernandes (2000), o reator anaeróbio *UASB* foi desenvolvido na década de 70 pelo professor Lettinga e sua equipe da Universidade de Wageningen, na Holanda. A tecnologia foi pensada inicialmente, para o tratamento de efluentes industriais, os testes para o tratamento de efluentes domésticos começaram em 1976 e aos poucos, esse estudo foi se desenvolvendo, especialmente, para condições tropicais.

Atualmente, este tipo de reator encontra-se bastante difundido, sendo bem mais aplicado do que os outros e para tratamento de vários tipos de águas residuárias, tendo como aspecto essencial do processo a natureza da biomassa ativa.

Utilizado como pré-tratamento, o *UASB* deve prever o gradeamento e a remoção de areia e gordura. Nuvolari (2003) observa que esse tipo de reator possui as mesmas limitações inerentes aos processos anaeróbios, como baixa eficiência e em alguns casos, difícil controle operacional. Entretanto, resulta em áreas bastante reduzidas, tornando atrativo quando comparado com outros sistemas para tratamento de efluente com alta carga orgânica.

Conforme Fernandes (2000), o reator *UASB* consiste de um leito de lodo (*sludgebed*), uma zona de sedimentação (*sludgeblanket*) e o separador de fase (*gas-solidseparator* – *GSS*). O *GSS* é um dispositivo típico do *UASB* com a finalidade de dividir a zona de digestão (parte inferior) e a zona de sedimentação (parte superior).

A água residuária após entrar e ser distribuída pelo fundo do reator *UASB*, flui pela zona de digestão, onde se encontra o leito de lodo, ocorrendo a mistura do material orgânico nela presente com o lodo. Os sólidos orgânicos suspensos são quebrados, biodegradados e digeridos através de uma transformação anaeróbia, resultando na produção de biogás e no crescimento da biomassa bacteriana. O biogás segue em trajetória ascendente com o líquido, após este ultrapassar a camada de lodo, em direção ao separador de fases (FERNANDES, 2000, p.56).

De acordo com Nuvolari (2003), um dos maiores problemas do *UASB*, é que a direção ascendente do fluxo conflita com a sedimentação do material mais fino que é carregado no sentido do fluxo. Esse aspecto pode ser melhorado através da operação intermitente e da instalação de disposição que possibilitem a sedimentação dos sólidos e a separação dos gases formados.

Segundo Fernandes (2000), os primeiros reatores, aplicado ao tratamento de esgotos industriais, tinham estrutura cilíndricas ou prismáticas-retangulares, em que as áreas dos compartimentos de digestão e decantação eram iguais (reatores de parede verticais). A medida que, os reatores foram sendo utilizados para esgotos domésticos tem levado a diferentes configurações para estes reatores.

Com relação à forma, os reatores (em planta) podem ser circulares ou retangulares. Sendo estes primeiros mais econômicos do ponto de vista estrutural, são bastante utilizados para pequenas populações. Enquanto que, para maiores populações são indicados os de seção retangulares, pois uma parede pode servir a dois módulos contíguos.

2.1.1.2 Associação entre sistemas de tratamento de esgotos

Muitas vezes, a utilização de um único sistema de tratamento não atende, na sua totalidade, os padrões estabelecidos pela legislação ambiental responsável pelo lançamento de efluentes. Por isso, a associação entre sistemas diferentes de tratamento torna-se vantajoso, considerando as particularidades de cada sistema e a características do esgoto a ser tratado e o uso preponderante que será dado a tal efluente.

De acordo com Machado (1997), no que concerne à disposição final do efluente, os principais objetivos do pós-tratamento podem ser: a remoção complementar de matéria orgânica, removendo resíduos de DQO, DBO e SST e a remoção de nutrientes e patogênicos. Lagoas facultativas, lagoas de alta taxa, lagoas aeradas, filtro biológico, filtro lento de areia

intermitente, filtro anaeróbio, lagoa de maturação, biofiltros aerados submersos e lodos ativados são alternativas para o pós-tratamento de esgotos.

Segundo Mota e Von Sperling (2009), os tratamentos anaeróbios em reatores *UASB* e outros reatores não removem, de forma significativa, os principais nutrientes do esgoto. Enquanto, os processos biológicos aeróbios mecanizados (lodos ativados, lagoas aeradas e filtros biológicos) fornecem efluentes mais clarificados, ou seja, livres de matéria orgânica em suspensão ou em estado coloidal, mais bem condicionados para desinfecção e com grande nível de remoção de nutrientes, principalmente nos sistemas que promovem remoção de nitrogênio por meio de nitrificação e desnitrificação.

2.1.1.2.1 Lodos ativados para desnitrificação

Os sistemas de lodos ativados são bastante utilizados, mundialmente, quando se deseja uma elevada qualidade de efluente dispondo de baixos requisitos de áreas. Entretanto, a complexidade operacional e o consumo energético são elevados. De forma geral, existem diversas variantes do sistema de lodos ativados e são classificados de acordo com a idade do lodo, com o fluxo dos reatores e com os objetivos do tratamento.

Conforme Von Sperling (2005), nos sistemas de lodos ativados a remoção biológica de nitrogênio é alcançada em condições de ausência de Oxigênio, porém, na presença de nitratos (condições anóxicas). Nesse processo denominado de desnitrificação, um grupo de bactéria utiliza nitratos na respiração, transformando-os em nitrogênio gasoso que é liberado na atmosfera. Para que o sistema de lodo ativado possa alcançar o processo de desnitrificação são necessárias modificações como a criação de zonas anóxicas e possíveis recirculações internas.

2.2 Redes Neurais Artificiais

2.2.1 Introdução

Nesta parte da revisão de literatura, procura-se detalhar a parte conceitual, afim de que possamos imprimir uma visão geral, mas intimista do conexionismo para leitores que estejam ingressando nesta área. Os estudos de RNAs são relativamente recentes, data-se dos estudos inovadores de Warren Mc Culloch e Walter Pitts, com prosseguimento nas mais diversas áreas da Ciência, como as Engenharias, biologia e genética.

2.2.2 Breve histórico das redes neurais artificiais

Um psicólogo e neurofisiologista chamado McCulloch e um matemático recém-graduado, Pitts, são os cientistas que em 1943 através de seu renomado estudo intitulado “*A logical Calculus of the Ideas Immanent in Nervous Activity*”, deram início ao primeiro modelo artificial de um neurônio biológico. Este trabalho formou as bases da neurocomputação, estabelecendo a descrição de um modelo artificial de um neurônio, apresentando suas capacidades computacionais, a partir do desenvolvimento de procedimentos matemáticos similares ao mecanismo de funcionamento do neurônio biológico. No entanto, os cientistas não propuseram aplicações práticas para o seu trabalho, restringindo ao aspecto conceitual, preterindo as técnicas de aprendizado.

O biólogo Donald Hebb deu continuidade aos estudos de Pitt e McCulloch aperfeiçoando seus estudos através da proposição de pesos de entrada nos neurônios, baseada no reforço das ligações sinápticas entre neurônios excitados, criando assim um modelo de aprendizado.

O pesquisador norte americano, Frank Rosenblatt, conseguiu demonstrar em 1957, que se fossem acrescentadas de sinapses ajustáveis as RNA's com neurônios MCP poderiam ser treinadas para classificar certos tipos de padrões. Esse modelo foi denominado Perceptron. Este possui três camadas: a primeira recebe as camadas do exterior, a segunda recebe impulsos da primeira através de conexões cujo peso é ajustável e que por conseguinte saídas para a última camada, a de resposta. Rosenblatt estabeleceu os a base para a Inteligência Artificial, justamente a partir do primeiro modelo de Rede Neural Artificial.

Nos meados da década de 60, Widrow e Hoff desenvolveram uma regra de aprendizado que ainda possui aplicabilidade na atualidade, conhecido por Regra Widrow-Hoff, ou regra Delta. Bernard Widrow fundou a primeira empresa de circuitos neurais digitais, a Memistor Corporation, responsável por produzir um elemento que realizava o ajuste de pesos de uma RNA.

Um dos pioneiros nos estudos as robótica, Marvin Minsky escreveu um livro denominado Perceptron, apontando as falhas que o Perceptron simples descrito por Rosenblatt possuía, visto este modelo estar limitado a resolução de problemas linearmente separáveis. Através de uma análise rigorosa foi possível comprovar o baixo poder computacional dos modelos neurais usados na época.

Assim, durante mais de uma década, as pesquisas nesta área do conhecimento ficaram restritas a poucos pesquisadores, sendo esse período conhecido como “era perdida no campo

das redes neurais”. No entanto, no início da década de 80, a partir dos estudos do físico John Hopfield, houve uma explosão de interesse pela comunidade acadêmica internacional sobre Redes Neurais. Em seu estudo, Hopfield demonstrou a importância das propriedades associativas das RNA's, relacionando-as com sistemas físicos. Outro fator preponderante para o “boom” nas pesquisas foi o avanço tecnológico, principalmente na microeletrônica, permitindo a realização física de modelos de neurônios e sua interconexão, algo que antes era impraticável.

Em 1986, um estudioso da psicologia cognitiva, David Humelhart, desenvolveu o algoritmo *back-propagation* nos anos seguintes as pesquisas concentraram-se na possibilidade de algoritmos com maior possibilidade convergência.

Atualmente, a busca concentra-se na procura por algoritmos com maior controle de generalização e integração com outros paradigmas da IA, tornando fascinante e excitante essas possibilidades nos estudos das RNA's.

2.2.3 Neurônio natural

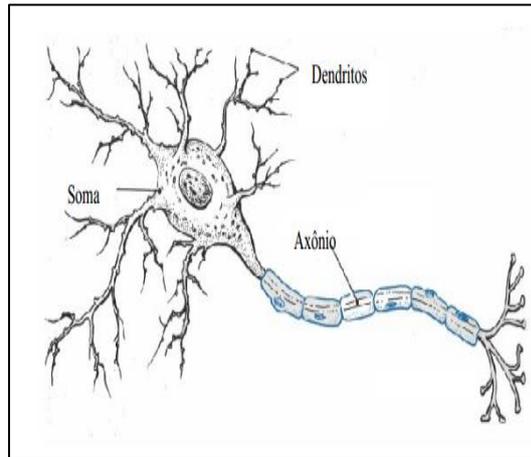
Segundo Rezende (2008), o Sistema Nervoso é o local onde se enraízam a sensibilidade consciente, a mobilidade espontânea e a inteligência. Por este motivo é analisado como o centro nervoso mais respeitável de todo o sistema. Nada escapa a ele e ao desenvolvimento integral do ser humano. Segundo Braga *et al.* (2007), o cérebro humano contém aproximadamente 10^{11} neurônios (Figura 07). Estes neurônios se auto conectam com outros milhares de neurônios de maneira contínua e em paralelo.

Relva nos diz que:

“O sistema nervoso detecta estímulos externos e internos, tanto físico quanto químico, e desencadeia respostas musculares e glandulares. Ele é formado, basicamente, por células nervosas, que se interconectam de forma específica e precisa, formando os circuitos (redes) neurais” (2005, p.33)

Isso nos possibilita inferir que essa extensa rede que é formada a partir das conexões, é norteio das bases de estudo das RNA's, inclusive por sua topologia e estrutura comportamental.

Figura 06 - Representação de um neurônio biológico



Fonte: Carlson (1992)

Basicamente, o neurônio é dividido em três componentes básicos: o soma – referente ao corpo celular, os dendritos e o axônio. Cada parte possui a sua especificidade, no entanto agindo de maneira complementar. Os dendritos recebem os impulsos nervosos vindos de outro neurônio e conduzem a informação até o corpo celular. Neste momento, a informação é processada e são gerados novos impulsos. Assim sendo, o impulso é transmitido a outro neurônio, pelo axônio até o dendrito da célula seguinte, acontecendo o que chamamos de SINAPSE. Segundo Araújo (2008), a forma de conduzir essas informações ocorre por meio de alterações do potencial elétrico que existe entre as superfícies interna e externa da membrana celular dos neurônios.

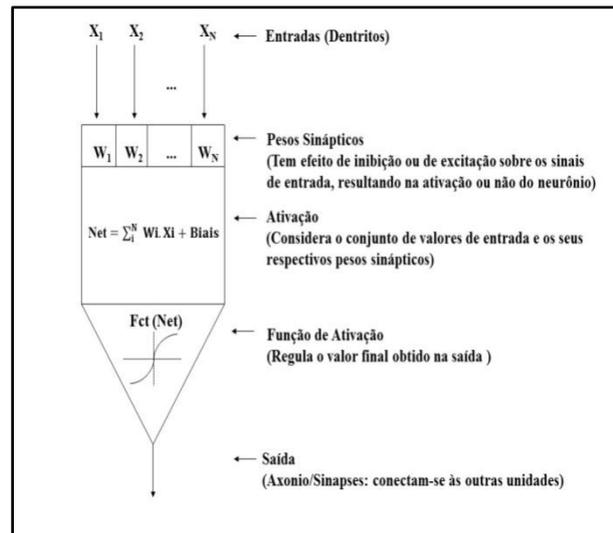
Se analisarmos a estrutura morfológica da celular nervosa, veremos que há muitas entradas formadas através da conexão sináptica que conecta os dendritos de uma célula ao axônio de outra.

2.2.4 Neurônio artificial

A estrutura de um neurônio artificial (Figura 07) perpassa pela concepção de neurônio biológico. Tal estrutura é a unidade fundamental de processamento de uma rede neural artificial. Entre os de sinônimos mais conhecidos estão elementos de processamento, nó e nodo. Cada elemento de processamento se une a outra para formar uma rede neural artificial. Segundo Santos (2011), as RNA's podem ser entendidas como conjuntos bem estruturados de unidades de processamento, interligadas por um canal de comunicação, cada qual tendo um determinado peso correspondente a um valor numérico. Elas consistem de várias unidades de

processamento (neurônio artificial), interconectadas entre si, formando uma determinada disposição estrutural de camadas (entradas, intermediárias e saída) e conexões entre as camadas. Para cada neurônio existe um determinado número de entradas (X) e para cada entrada existe um peso específico (W) associado, referente a sua importância.

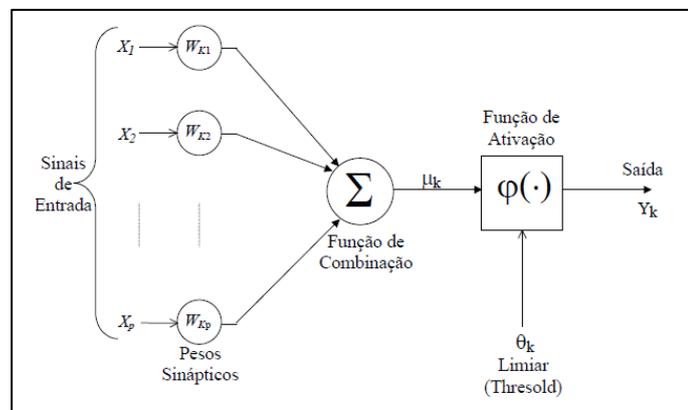
Figura 7 - Representação de um neurônio artificial.



Fonte: Adaptação de Santos (2011)

A função de ativação é responsável pela intensidade do sinal a ser transmitido pelas conexões para os neurônios das camadas adjacentes. Na Figura 8 é possível observar a representação de um neurônio artificial de McCulloch-Pitts, nela destaca-se a inclusão de uma função limiar, θ_k (Threshold), responsável por diminuir a entrada líquida para a função de ativação.

Figura 8 - Representação de um neurônio artificial de McCullots-Pitt.



Fonte: Adaptado de Haykin (2001)

Assim, ao observarmos a estrutura desse neurônio é possível traduzir em equações matemáticas a atuação dessas estruturas. Desta maneira, matematicamente, podemos descrever que para o neurônio k , teremos:

$$\mu_k = \sum_{j=1}^p w_{kj} x_j \quad (1)$$

e

$$y_k = \varphi(\mu_k - \theta_k) \quad (2)$$

Sendo,

x_1, x_2 e $x_p \rightarrow$ Sinais de entrada

w_{k1}, w_{k2} e $w_{kp} \rightarrow$ Pesos sinápticos

$\mu_k \rightarrow$ Saída da combinação linear

$\theta_k \rightarrow$ Limiar (threshold)

$\varphi \rightarrow$ Função de ativação

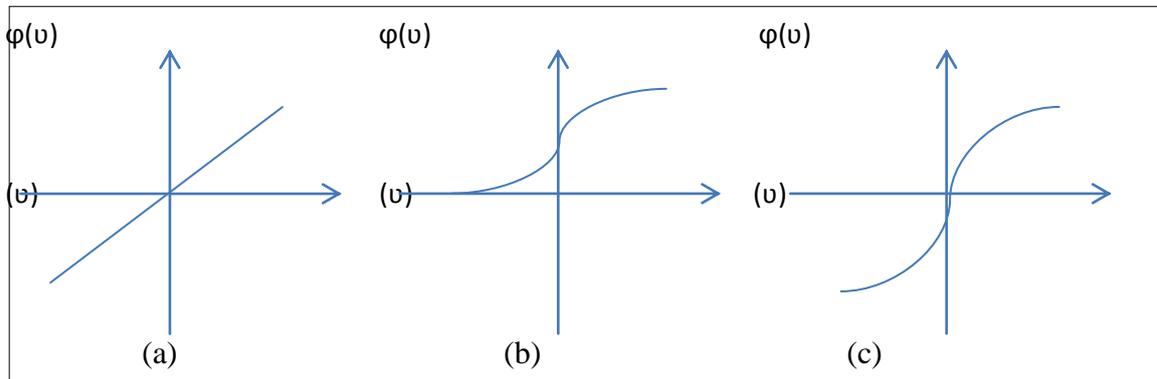
$y_k \rightarrow$ Sinal de saída do neurônio

No que tange a função de ativação, Haykin (2001), define a saída de um neurônio de acordo com o nível de atividade de sua entrada. Ele identifica três tipos básicos, conforme Tabela 01.

Tabela 1- Funções de ativação, equação e função correspondente no software MATLAB

FUNÇÃO	EQUAÇÃO	MATLAB
Linear	$\varphi(v) = kv$, onde $k = \text{constante}$	PURELIN
Logística (sigmoide)	$\varphi(v) = \frac{1}{1 + \exp(-av)}$	LOGSIG
Tangente Hiperbólica	$\varphi(v) = \text{tg}\left(\frac{v}{2}\right)$ $= \frac{1 - \exp(-v)}{1 + \exp(-v)}$	TANGSIG

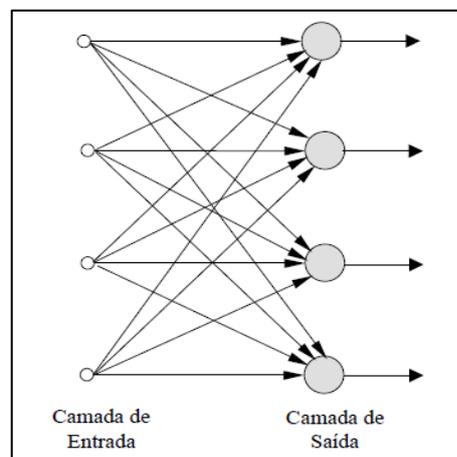
Figura 9 – Representação dos tipos de função de ativação: a) Função linear; b) Função Sigmoidal; c) Função Tangente hiperbólica



2.2.5 Arquitetura de rede

A escolha da arquitetura de uma rede neural artificial é uma fase decisiva para a eficácia do processo, visto seu arranjo depender do problema a ser tratado. Desta forma, a arquitetura delimita o tipo de aplicação da mesma. Sua estrutura é definida por quatro critérios principais: números de camada da rede, número de nós em cada camada, tipo de conexão entre os nós, topologia da rede. Quanto ao número de camadas a rede neural pode ser classificada como: Rede de camada única e Rede de camada múltipla. As redes de uma única camada (Figura 10) são constituídas por um único grupamento de neurônios que recebem a informação diretamente. Existe apenas um elemento de processamento entre qualquer entrada e qualquer saída da rede. Segundo Haykin (2001), um exemplo de arquitetura com este número de camadas é a Memória Associativa Linear. Nesta situação a rede associa um padrão de entrada (vetor) a um de saída e a informação é armazenada na rede em virtude das modificações realizadas nos pesos sinápticos.

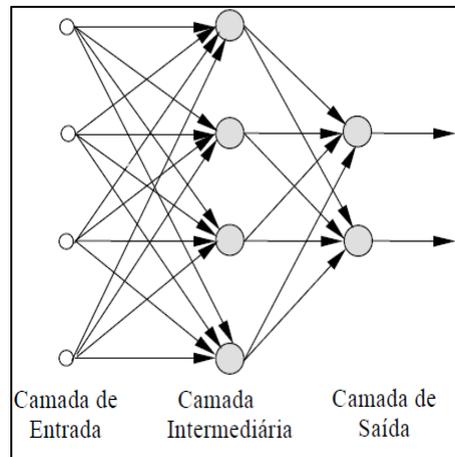
Figura 10 - Representação de uma rede neural de camada única



Fonte: Haykin (2001)

Nas redes de múltipla camada (Fig. 11) existe mais de um neurônio entre uma entrada e uma saída de rede.

Figura 11- Representação de uma rede neural de camada múltipla



Fonte: Haykin (2001)

No tocante ao tipo de conexão, os neurônios podem se unir de duas maneiras distintas: *Feedforward* ou *Feedback*. A conexão do tipo *Feedforward* engloba aqueles onde o fluxo do sinal é unidirecional, ou seja, trata-se de uma conexão acíclica. Cada nó de uma camada recebe suas entradas a partir de uma camada precedente e assim envia os sinais de saída em direção à camada posterior. As conexões *Feedback*, são caracterizadas por serem cíclicas, assim elas passam por um processo de loop e os nós são conectados diretamente às entradas externas. É importante ressaltar que estas unidades também podem funcionar como saída de rede.

Qualquer rede neural artificial usada para resolver um problema perpassa necessariamente pela fase de aprendizagem para que possa extrair informações importantes de padrões de informação apresentados gerando uma representação característica do problema. Tal situação ocorre através de um processo iterativo de ajuste relacionado ao peso, denominado treinamento.

Haykin resalta que:

“Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando, sendo o tipo específico de aprendizagem realizada definido pela maneira particular como ocorrem os ajustes realizados nos parâmetros.”(2001, p.75)

3 ESTADO DA ARTE

Cada vez mais se intensifica os estudos sobre o uso de RNA aplicada na resolução de problemas de engenharia ambiental. Estes estudos promovem melhoria dos processos através da previsão de algumas características.

Gontarski *et al.* (2000), utilizaram as redes neurais back-propagation para prever a eliminação do carbono orgânico total (TOC) na estação de tratamento, utilizando o algoritmo delta-bar-delta para estimativa de pesos e sigmóides. O overfitting, típico das redes neurais back-propagation foi verificado testando os resultados de comparação com um conjunto teste. Sendo esse tipo de rede treinada com conexões suficientes, o erro RMS no conjunto de dados teste diminui no início e depois atinge um ponto mínimo. A rede é salva no ponto mínimo a ser utilizada. Como resultados, o trabalho citado obteve a identificação das principais variáveis para a formação dos processos e a análise de sensibilidade ofereceu algumas informações interessantes. Para esse efeito, a variação em comparação com o índice de correlação entre o observado e os valores calculados da variável j th (R_j) foi calculado predito pela rede. A partir do trabalho desenvolvido concluiu-se que as redes neurais representam a possibilidade de contribuição para operações de previsão de perturbações e para a possibilidade de agir proativamente para minimizar as flutuações de determinado produto.

Hamed *et al.* (2003), desenvolveram dois modelos baseados em RNA para prever concentrações da Demanda Bioquímica de Oxigênio (DBO) e Sólidos Suspensos (SS) para uma grande estação de tratamento de efluentes com vazão de 1 milhão de m^3 /dia, localizada no Distrito de Cairo, no Egito. Os modelos desenvolvidos foram treinados e testados utilizando medições diárias de diferentes fases do processos, e conseqüentemente em diferentes concentrações, ao longo de dez meses. Foram realizadas análises exploratórias dos dados para detectar relações entre eles e avaliar sua dependência. A limitação dos dados é de bastante relevância, visto que a medida que mais dados são recolhidos, menos ruídos aparecerão na modelagem, bem como, se os parâmetros adicionais (pH, temperatura, etc.) forem medidos resultará numa melhoria na capacidade de previsão da rede. Assim, o erro de predição variou ligeiramente, e sem problemas para toda a gama de dados, visto a arquitetura apropriada ter sido determinada por várias etapas de treinamento e teste. Concluindo-se que, os modelos baseados nas redes neurais artificiais oferecem uma solução eficaz e uma ferramenta bastante robusta para a predição da performance das estações de tratamento de esgoto.

Em sua tese, RodriguesEsquerre (2003), desenvolveu modelos dinâmicos e estacionários para fornecer previsões com acurácia da DBO de entrada e saída da lagoa aerada da InternationalPaperofBrazil, por meio de redes neurais artificiais e de regressão linear multivariada. Foram escolhidas três técnicas estatísticas clássicas e duas de redes neurais para a construção dos modelos de previsão da demanda bioquímica de oxigênio da lagoa aerada, a DBO é um dos parâmetros mais importantes e de medição mais demorada. As técnicas foram: regressão linear multivariada (MLR); regressão por mínimos quadrados parciais (PLSR); regressão por componentes principais (PCR); redes neurais perceptron de múltiplas camadas (MLP); e redes neurais functional-link (FLN). Concluiu-se com esse trabalho que apesar das redes MLP apresentarem uma etapa tediosa e demorada de definição da sua topologia, seus modelos apresentam resultados de previsão superiores aos obtidos por meio das demais técnicas e são bastante satisfatórios tanto na previsão da DBO de entrada como de saída. Os modelos MLR desenvolvidos com auxílio do método *stepwise* para seleção de variáveis obtiveram resultados similares ou levemente superiores aos das FLN, mesmo utilizando variáveis latentes com *inputs*, ou funções de transferência reversíveis para auxiliar o seu mapeamento. Conclui-se também que o número de dados e seu grau de representatividade do processo são fundamentais para obtenção de um modelo satisfatório com redes neurais. Quando utilizado um menor número de dados, a técnica PLSR se mostrou essencialmente necessária para minimizar as entradas de redes, principalmente para a previsão da DBO de saída. Os modelos MLR e PLSR mostraram-se mais eficientes na previsão da DBO de entrada e saída, respectivamente para este caso.

Em estudo realizado por Enginet *al.* (2004), as redes neurais artificiais foram utilizadas para determinar a relação entre a demanda bioquímica de oxigênio (DBO) e os odores produzidos pelas estações de tratamento de esgoto. Para isso, foi utilizado um nariz eletrônico (Equipamento NEOTRONICS Olfativo SensingModel-D), ou seja, uma simulação eletrônica do sistema olfativo humano para caracterização dos odores e amostras de efluentes coletadas na entrada, nos tanques de decantação, nas unidades de tratamento biológico e no emissário, selecionando a DBO como marcador chave para caracterizar a composição bioquímica do esgoto. O nariz produziu 12 saídas a partir da sua matriz de sensores em cada amostragem, o nariz exposto às amostras de esgoto coletado de diferentes locais da estação, resultando em 12 elementos cada um com seu sensor correspondente. Esses dados foram analisados usando redes neurais, a fim de avaliar a capacidade do nariz na resposta às amostras de esgoto. Uma rede neural do tipo feed-forward foi treinada com o algoritmo back-propagation utilizando o pacote Qnet (Vesta Services, 2000) que permite selecionar vários

parâmetros de rede e projetar arquiteturas de redes neurais flexíveis. O desenvolvimento do modelo foi realizado do seguinte modo: divisão de dados e de pré-processamento, seleção de *inputs* do modelo, seleção do modelo de geometria, treinamento do modelo e validação do modelo. Observou-se que as RNA como uma técnica de reconhecimento de padrões oferece um método valioso para a classificação de esgoto e de detecção de DBO em sequência, constituindo assim, um método muito rápido e reprodutível para controlar o teor biológico dos esgotos em relação às análises convencionais de consumo de oxigênio. Um problema, nesse trabalho, é a variabilidade inerente do produto em análise, pois odores de esgoto não são facilmente caracterizado ou quantificado e, portanto, representam um problema particular, sendo difícil produzir uma correlação fiel entre odor de esgoto e DBO. Acredita-se que, com mais dados, melhores resultados poderiam ser alcançados, no entanto, mesmo com uma quantidade limitada de dados, os resultados com RNA foram bastante satisfatórios. A correlação de odores de esgoto e os seus correspondentes valores de DBO foi superior a 90%, e para a classificação de amostras de esgoto, a correlação foi tão alta quanto, 99%.

Mijalliet *al.* (2006), aplicaram redes neurais artificiais para predição do desempenho de uma estação de tratamento. Para tal estudo, duas topologias de entrada do software MATLAB® foram consideradas. Na primeira abordagem, cada uma das variáveis do afluente (DBO, SST, etc.) foi utilizada para prever cada uma as variáveis do efluente. Na segunda aproximação, multi-entradas variáveis foram utilizadas para prever a saída das variáveis correspondente na corrente do efluente. Os dados de entrada e saída foram agrupados em dois vetores (um entrada e um saída) para a primeira abordagem e quatro vetores (três entradas e um saída) para a segunda abordagem. Cada conjunto de dados de vetores foi subdividido em três grupos: treinamento, validação e teste, numa proporção de 4: 2: 1, respectivamente. Cada estrutura de rede foi testada para explorar a formação da velocidade e tempo de resposta de estruturas diferentes. Para manter a estrutura de rede o mais simples possível, três camadas foram utilizadas em todas as redes de entrada única (uma camada de entrada, uma camada oculta e uma camada de saída) e quatro camadas são usados para o caso multi-entrada (duas camadas ocultas). Com relação ao número de neurônios na camada de saída é limitado ao número de saídas. Por outro lado, o número de neurônios das duas primeiras camadas foi selecionado depois de testar o desempenho das redes em diferentes combinações. As estruturas selecionadas asseguraram treinamento com velocidade razoável e tempo de simulação curto para um específico desempenho da rede. Os tipos de neurônios foram levados para a função de ativação tan-sigmoidal. Portanto, a primeira abordagem gerou melhores estimativas quando a demanda de oxigênio consumido foi usada como uma entrada de rede.

Por outro lado, a segunda abordagem teve resultados razoáveis para todas as variáveis previstas. A técnica de modelagem em redes neurais artificiais tem muitas características favoráveis como a eficiência, generalização e simplicidade, o que a torna uma opção atraente para modelagem complexa de sistemas, tais como processos de tratamento de águas residuais.

O estudo realizado por Mu e Yu (2007) utilizou-se de um modelo de combinação de um algoritmo genético com rede neural (GA-NN) para simulação da produção de hidrogênio (H_2) num reator UASB. Nesse modelo, a rede neural foi construída utilizando um conjunto de amostras de treinamento para atribuir pesos sinápticos. Em seguida, o algoritmo genético foi empregado para explorar a melhor solução entre o universo de soluções. Quando encontrada a melhor solução, a rede neural foi utilizada para determinar a aptidão do algoritmo e continuar o processo de pesquisa. Os resultados obtidos nesse trabalho demonstraram que a rede aprendeu bem a relação entre a entrada e saída, como também os coeficientes de determinação alcançados para concentração de H_2 no biogás (0,719), H_2 taxa de produção (0,806), rendimento de H_2 (0,843) e TOC efluente (0,854) sugeriram que o modelo GA-NN treinados não mostraram sistemática super ou sub-predição em relação às variáveis de saída. Sendo assim, o modelo foi adequado para prever a saída do reator UASB.

Em seu trabalho, Morais (2011) construiu modelos de predição da quantidade de matéria orgânica, por meio da DQO, de uma lagoa aerada de uma empresa de produção de papel e celulose, e comparou o desempenho dos modelos quando utilizada a técnica de análise de componentes principais (PCA) para o pré-processamento dos dados, com o objetivo de reduzir, dimensionalmente, o conjunto de dados. Foram formados cinco conjuntos de dados para comparar o desempenho das RNA com e sem aplicação de PCA, além disso, a utilização da DQO como unidade de concentração (mg de DQO. L^{-1} e como carga orgânica (kg de DQO. dia^{-1}). O desempenho foi avaliado pelo erro quadrático médio (EQM), índice de correlação (R^2), índice de correlação ajustado ($R^2_{ajustado}$) e a complexidade da rede (C_n). Com os resultados do trabalho, foi possível observar que a PCA quando aplicada para reduzir a dimensão do conjunto de dados por seleção das componentes principais, embora não melhorasse o desempenho do modelo, foi eficiente no aprendizado da rede, reduzindo o número de parâmetros a serem ajustados, e contribuindo assim para a formação de um modelo mais robusto. Entretanto, quando era aplicada para exclusão de possíveis *outliers* nenhuma informação adicional era identificada. A PCA aplicada para descarte de variáveis eliminava duas medições de entrada da Perceptron de Múltiplas Camadas (MLP), EC e pH sendo a vazão (Q) função da DQO entrada, resultando um modelo com quatro variáveis dependentes: DQO entrada, Cor, Q papel e Q celulose. A temperatura (T) foi dispensada, pois, apresentou

peso sináptico zero para a configuração adotada. Desta forma, o último modelo gerado (M4) além de simples também era econômico, já que dispensava três medições desnecessárias de variáveis, duas determinadas pela PCA e uma pelo próprio modelo MLP, sendo também o modelo que apresentou o menor EQM.

Nasret *al* (2012) publicaram um estudo que trata da previsão de três parâmetros: DBO, DQO e SST, através da aplicação da técnica de Redes Neurais em uma Estação de Tratamento de Água no Egito. Foram coletados dados durante um ano e em seguida, foi utilizado o algoritmo padrão Levenberg-Marquardt para o treinamento da rede. A aplicação dividiu, aleatoriamente, vetores de entrada e vetores de saída em três conjuntos do seguinte modo: 60% para a treinamento; 20% para validar se a rede está generalizando e parar de treinar antes que ocorra apenas a memorização dos dados de entrada e a rede perca a capacidade de generalização; e os restantes 20% foram utilizados como um teste completamente independente de generalização da rede. Observou-se que a saída reproduziu de forma satisfatória os dados de entrada para treinamento (valor de $R = 0,93004$), validação (valor- $R = 0,86323$), e teste (valor- $R = 0,86289$). Estes valores podem ser equivalente a uma resposta total do valor de $R = 0,90317$. Neste caso, a resposta da rede é satisfatória, e podem ser utilizada como simulação para introduzir novos insumos. Os resultados deste estudo indicaram coeficiente de correlação alto (Valor R) entre as variáveis de saída medidas e previstas, chegando a 0,9. Portanto, o modelo desenvolvido nesse trabalho tem uma capacidade de generalização aceitável e preciso. Como resultado, a modelagem da rede neural poderia efetivamente simular e prever o desempenho de EL-Agamy ETAR.

Em outro trabalho Nasret *al* (2012), centraram-se na simulação do Biogest/El-Agamy Reator sequencial em batelada (SBR) utilizando um simulador de software GPS-X para investigar o desempenho de uma estação de tratamento entre seis cenários de diferentes durações de preenchimento. O Modelo Lodo Ativado (ASM1) foi usado para os processos biológicos, e o modelo influente base da demanda bioquímica do oxigênio foi utilizado para a caracterização do afluente. Este estudo de caso foi aplicado ao processo de desnitrificação via condições anóxicas que remove nitratos e nitritos, que é tóxico aos animais aquáticos e perigosos para a saúde humana. Além disso, o processo de desnitrificação fornece uma possibilidade de opção para evitar o volume de lodo, considerado um dos principais problemas em El-Agamy ETAR, bem como, diminuir a energia de arejamento global do tempo do ciclo. Depois de simular o modelo através do simulador GPS-X que usa uma avançada interface gráfica do usuário (GUI) para facilitar a modelagem dinâmica e simulação foram obtidos seis cenários distintos. O preenchimento misto sem gás, em condições

anóxicas, é um processo importante na operação de um SBR e é altamente recomendável à ELAGAMY-ETAR para a remoção de nitratos e nitritos de águas residuais. Além disso, no local, o controle deve ser desenvolvido durante a operação de unidades de SBR como processo de desnitrificação, visto ser afetada por muitos parâmetros de controle tais como o pH, temperatura, relação de Nitrogênio.

Em estudo realizado por Srideviet *al.* (2014) investigou-se a biodegradação e a produção do biohidrogênio num reator híbrido de fluxo ascendente com manta de lodo anaeróbio usado para águas residuais de substrato de destilaria, com uma taxa máxima de produção de hidrogênio igual a 1300 ml.d^{-1} . Foi desenvolvido e validado uma rede neural back-propagation com topologia de rede de 4-20-1 por meio do algoritmo Levenberg-Marquardt, utilizando um total de 231 pontos de dados para analisar o desempenho do reator em fase de aclimação e operação. Os atributos dos modelos estatísticos de redes neurais back-propagation (BPNN) foram significativos devido ao elevado coeficiente de correlação, R^2 que foram, respectivamente, de 0,602, 0,823, 0,97 e 0,870 da eficiência de remoção de DQO, da taxa de produção biohidrogênio para aclimação e da fase de operação. Como também foi alcançado, um menor erro médio absoluto entre o experimental e os dados simulados. Com cargas orgânicas $10,2 \text{ kg de DQO.m}^{-3}\text{d}^{-1}$, a eficiência da remoção de DQO máxima de 87,35% e a taxa de produção de 1300 ml d^{-1} de biohidrogênio foram obtidas, o estudo mostrou que o treinamento de dados experimentais de degradação associado com a produção de biohidrogênio nesse tipo de reator usando uma destilaria de águas residuais com o modelo BPNN é viável.

4METODOLOGIA

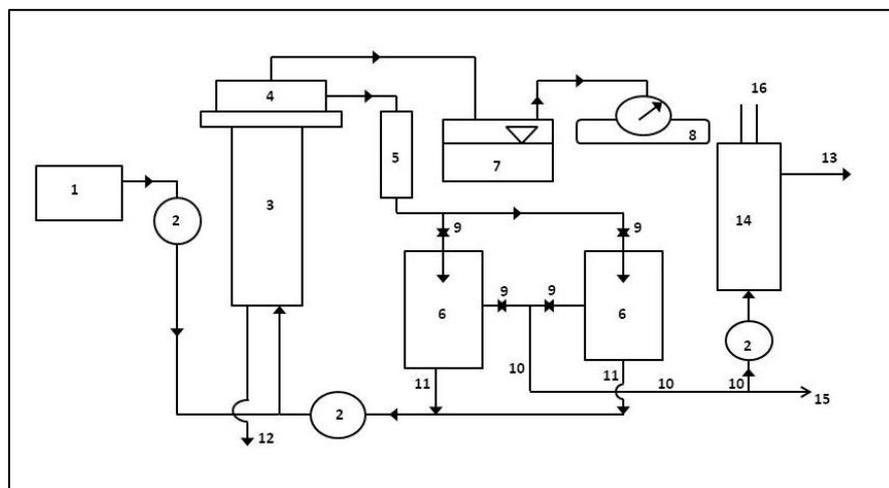
4.1 Introdução

O trabalho baseia sua execução nos dados da pesquisa de Sousa (1996). A execução efetiva é através do uso da técnica de RNA para modelagem e simulação do reator UASB através do software computacional MATLAB®.

4.2 Procedimentos no sistema de tratamento de esgoto sanitário

Para obtenção dos dados foi construído e instalado na Escola de Engenharia de São Carlos na USP, um sistema de tratamento de esgoto sanitário (Figura 12) constituído de 3 partes fundamentais: reator de fluxo ascendente com manta de lodo (UASB), dois reatores em batelada (SBRs) em paralelo e uma coluna de desnitrificação de fluxo ascendente.

Figura 12 – Esquema geral do sistema composto por reatores UASB e SBR seguidos de coluna de desnitrificação



- 1- Tanque de alimentação; 2- Bomba dosadora; 3- UASB; 4- Coletor de gás; 5- Coletor de efluente do UASB; 6- SBR; 7- Selo hídrico; 8- Medidor de gás; 9- Válvula solenoide; 10- Descarga do efluente; 11- Lodo de excesso do SBR; 12- Lodo de excesso do UASB; 13- Efluente final desnitrificado; 14- Coluna de desnitrificação; 15- Efluente nitrificado; 16- Gás liberado na desnitrificação

Foi usado um substrato sintético com composição similar ao esgoto sanitário composto basicamente de extrato de carne, sacarose, amido comercial, celulose em pó e óleo de soja. Apesar da presença de sais minerais no extrato de carne optou-se pela adição ainda

uma solução de sais minerais para maior similaridade ao esgoto sanitário. Em virtude do uso de extrato de carne no substrato, ricas em Fósforo e Sulfato, foram monitoradas as concentrações destes parâmetros através de espectrofotômetro de absorção atômica.

Para controle e caracterização do esgoto sanitário sintético foram feitas determinações de parâmetros como Fósforo, Nitrogênio, sólidos, alcalinidade, ácidos e DQO durante 54 semanas e para Sulfato durante 5 semanas. Assim, o sistema operacional foi dividido em duas fases. Na primeira fase, durante 16 semanas o sistema foi formado por um reator *UASB* seguido de dois reatores sequenciais em batelada aeróbios. A etapa seguinte compreende o período de 38 semanas, quando o sistema composto por *UASB* e SBR atingiu o regime de equilíbrio dinâmico, sendo adicionado ainda uma coluna de desnitrificação.

Inicialmente, com o auxílio de uma bomba peristáltica, o reator *UASB* foi inoculado com três litros de lodo granulado com 58 % de sólidos suspensos voláteis. Inicialmente foi operado com vazão média de 20,4 L / dia, dando suporte a uma carga orgânica volumétrica média de 2,25 Kg.m⁻³. dia⁻¹ e tempo de detenção hidráulica médio de 4,7 horas. Na segunda fase, houve uma diminuição no TDH, passando este a ser operado com 4 horas, carga orgânica volumétrica de 2,53 Kg.m⁻³. dia⁻¹ e vazão de entrada de 24 L. dia⁻¹.

No que tange o SBR, foi usado como alimentação deste reator, o efluente advindo do reator de fluxo ascendente, cujo líquido foi obtido através de um tubo de PVC de volume 2 L, durante 2 horas, passando por gravidade para o reator em batelada. Fatores como vazão, tempo de aeração e descarga do sobrenadante foram controlados por um temporizador programado por circuitos eletrônicos. Para o processo de preenchimento do primeiro reator em batelada, o procedimento ocorreu através de duas ações simultâneas: a abertura da válvula de alimentação por aproximadamente 0,2 horas e o acionamento da bomba de aeração por um período de 2 horas, logo após este período os sólidos em suspensão foram separados por sedimentação e a parte sobrenadante foi possível ser descartada. Para o preenchimento do segundo reator, os procedimentos foram os mesmos, contados a partir do fim do tempo de aeração e liberação automática de uma válvula de alimentação. O tempo de duração do ciclo operacional foi de 4 horas, separadas da seguinte maneira:

1. Reação – 2 horas de duração - equivalente a 50 % do tempo do ciclo;
2. Sedimentação – 1,2 horas de duração – equivalente a 30 % do tempo do ciclo;
3. Descarga – 0,4 horas de duração – equivalente a 10 % do tempo do ciclo;
4. Repouso – 0,4 horas de duração – equivalente a 10 % do tempo do ciclo.

No tocante a coluna de desnitrificação, apenas 40 % do efluente advindo do SBR, ou seja, $9,6 \text{ L.d}^{-1}$, foi bombeado para esta parte do tratamento. Durante as 38 semanas de operação, o estudo foi dividido em cinco fases diferentes, conforme Tabela 2 mostrada a seguir.

Tabela 2 – Condições operacionais da coluna de desnitrificação à 30°C

Fase de operação	Origem do lodo	Volume de lodo na coluna (L)	Massa de lodo (g SST)	SSV (%)	Altura de lodo na coluna (m)
1	Reator <i>UASB</i> tratando água de pocilga. O lodo estava armazenado à baixas temperaturas.	0,65	33,93	86,2	0,325
2	Reator <i>UASB</i> em operação, tratando água de pocilga.	0,65	41,77	79,5	0,325
3	Reator <i>UASB</i> em operação no próprio sistema.	0,60	52,74	48,9	0,3
4	Reator <i>UASB</i> em operação no próprio sistema.	0,28	7,02	52,2	0,14
5	Reator <i>UASB</i> em operação no próprio sistema.	0,5	28,24	55,9	0,25

Adaptação de Sousa (1996)

Quanto a metodologia de análise e periodicidade de acompanhamento e monitoramento, a Tabela 3 analisa detalhadamente o andamento do sistema de tratamento.

Tabela 3 - Parâmetros analisados, métodos e frequência das análises

Parâmetro	Método	Periodicidade	Suporte Técnico de métodos analíticos
pH	Potenciométrico	Diária	_____
Alcalinidade	Titulométrico	Semanal	DILALLO & ALBERTSON (1961), BROVKO & CHEN (1977), MACKERETH et al (1978),
Alc. Voláteis	Titulométrico	Semanal	DILALLO & ALBERTSON (1961), BROVKO & CHEN (1977), MACKERETH et al (1978), UAEPA (1975)
DQO total	Espectrofotométrico	2 / Semana	_____
DQO solúvel	Espectrofotométrico	2 / Semana	_____
N-NTK	Titulométrico	Semanal	STANDARD METHODS FOR THE EXAMINATION OF WATER AND WASTERWATER (1985)

Continua

Continuação

N-NH ₄ ⁺	Titulométrico	Semanal	STANDARD METHODS FOR THE EXAMINATION OF WATER AND WASTERWATER (1985)
N-NO ₂ ⁻	Espectrofotométrico	Semanal	DILALLO & ALBERTSON (1961), BROVKO & CHEN (1977), MACKERETH et al (1978), UAEPA (1975)
N-NO ₃ ⁻	Espectrofotométrico	Semanal	DILALLO & ALBERTSON (1961), BROVKO & CHEN (1977), MACKERETH et al (1978), UAEPA (1975)
P	Espectrofotométrico	2 / Semana	_____
SST	Gravimétrico	2 / Semana	STANDARD METHODS FOR THE EXAMINATION OF WATER AND WASTERWATER (1985)
SSV	Gravimétrico	2 / Semana	STANDARD METHODS FOR THE EXAMINATION OF WATER AND WASTERWATER (1985)
Composição do gás	Cromatográfico	Semanal	_____
Taxa de consumo de Oxigênio do lodo aerado	Potenciométrico	Semanal	_____
SSV do lodo de excesso anaeróbio	Gravimétrico	Semanal	_____
SSV do lodo de excesso aeróbio	Gravimétrico	2 / Semana	_____

Adaptação SOUSA (1996)

4.3 Preparação dos dados

Segundo Bação (2006) apud Almeida João (2009) o objetivo principal do pré-processamento dos dados é facilitar e simplificar o problema a ser tratado sem que haja exclusão ou danifique informação importante para a modelagem e entendimento do problema.

Para tanto, os dados que estavam dispostos em formato de texto tabelado, foram transcritos para o software EXCEL, afim de que estes pudessem ser importados para o software MATLAB. Neste processo de transcrição dos dados, de forma a minimizar a perda de informação e maximizar a obtenção dos resultados, o conjunto de dados referentes a entrada do reator UASB, excetuando-se o parâmetro pH, tiveram mudança, passando a ser expresso em Carga Volumétrica ao invés de concentração. Esse processo ocorreu mediante experiência anterior de Morais (2011) que verificou em seu estudo que a utilização da DQO como carga, ao invés de concentração, melhor representar a quantidade de matéria orgânica dissolvida no efluente. Para tanto, foi considerado os valores de vazão nas duas fases do reator UASB, ou seja, até a 16ª semana a vazão foi de 20,4 L/dia e na segunda fase, até a 54ª semana, a vazão foi de 24L/dia.

A princípio, após a distribuição dos dados no Excel e transformação dos dados de entrada no reator, os dados foram dispostos no Software STATISTICA para que fosse feita uma estatística descritiva dos dados obtidos experimentalmente, através da obtenção de dados da distribuição de cada um dos parâmetros ao longo das 54 semanas de estudo.

Em seguida, no processo de construção da RNA os dados foram separados em três subconjuntos, a saber:

- Treinamento – usado para estimar os parâmetros do modelo;
- Validação – Usado para verificar a generalização do modelo em comparação a amostras independentes do conjunto de treinamento;
- Teste – Usado para validar o modelo usando novas amostras.

No presente trabalho o conjunto de dados foi subdividido de 3 formas diferentes:

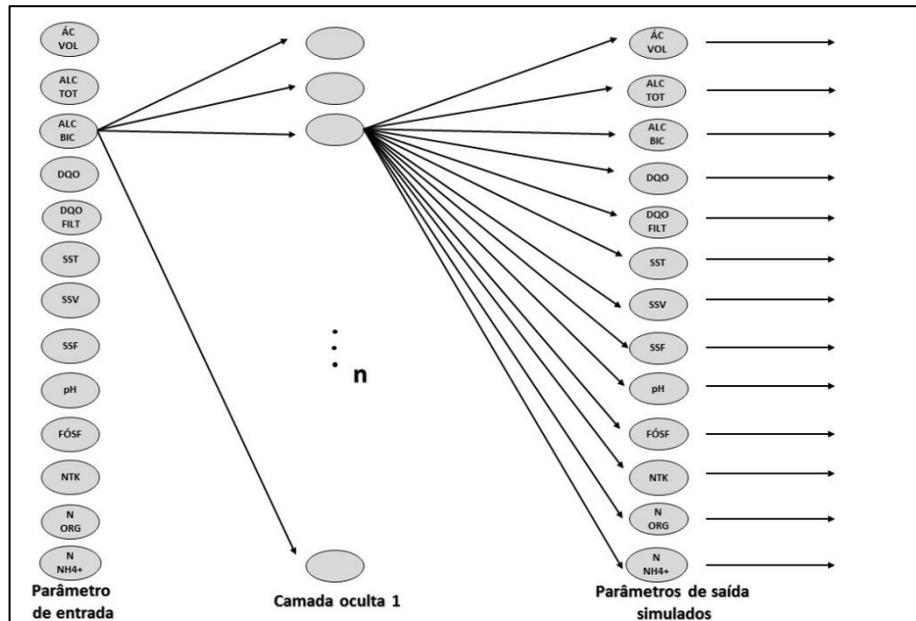
- a) 80 % dos dados para treinamento, 10 % para teste e 10 % para validação.
- b) 70 % dos dados para treinamento, 15 % para teste e 15 % para validação.
- c) 60 % dos dados para treinamento, 20 % para teste e 20 % para validação.

Para execução da modelagem e simulação o modelo de rede neural escolhido foi o de tipo MLP com algoritmo de aprendizagem Levenberg-Marquardt, uma adaptação do algoritmo backpropagation. Alguns aspectos permaneceram fixos a exemplo da taxa de aprendizagem fixa em 0,05 e a função de ativação da saída como Purelin. No entanto, alguns parâmetros da rede foram modificados com o intuito de se encontrar um modelo com o resultado mais satisfatório possível. Assim apresentadas:

- I. Número de camadas ocultas: as arquiteturas foram modificadas com até 2 camadas intermediárias;
- II. Número de neurônios da primeira camada oculta: foram variadas nas quantidades de 5, 10 e 15 neurônios;
- III. Número de neurônios da segunda camada oculta: foram variadas nas quantidades de 5, 10 e 15 neurônios;
- IV. Tipo de função de ativação: a primeira camada oculta foi variada ora na função Logsig, ora na função Tansig, bem como a segunda camada intermediária.

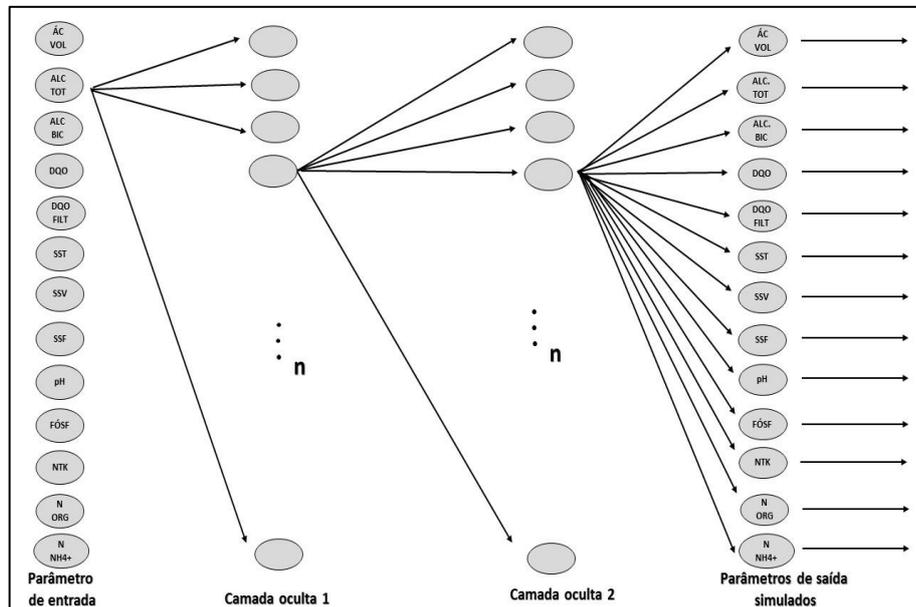
Desta maneira, os modelos das redes neurais foram estruturados em 13 parâmetros de entrada, correspondente ao número de neurônios, uma camada oculta (Figura 13) ou com duas camadas ocultas (Figura 14) e 13 camadas de saída, que representam a simulação de todos os parâmetros utilizados no reator UASB.

Figura 13 - Representação da arquitetura da rede com uma camada oculta



Fonte: autor (2014)

Figura 14 - Representação da arquitetura da rede com duas camadas ocultas



Fonte: autor (2014)

Durante o processo de treinamento, os pesos e as bias foram ajustadas de maneira iterativa, para minimizar a função de performance utilizada, o erro quadrático médio (MSE). É importante ressaltar que o software computacional Matlab traz seu próprio algoritmos de aleatorização utilizado para construção dos modelos, evitando algum resultado tendencioso e aumentando a eficiência do modelo estatístico.

Para avaliação da eficiência das RNA's, valores reais de cada um dos parâmetros foram comparados com os valores preditos pelo modelo de RNA. Segundo Hamed, Khalafallah e Hassanien (2004); Aratos, Papaspyros e Tsihrintzis (2008) apud Morais (2011), e Oliveira-Esquerre *et al.*, (2004), os métodos de avaliação mais citados na literatura são Erro Quadrático Médio e Coeficiente de Determinação. No presente trabalho foi utilizado o coeficiente de determinação de Treinamento como balizador para a avaliação.

No que se refere ao processo de simulação do reator uasb, os parâmetros foram enumerados nas figuras da seguinte maneira: 1- DQO bruta; 2- DQO filtrada; 3- SST; 4- SSV; 5- SSF; 6- Alcalinidade total; 7- Alcalinidade a bicarbonatos; 8- Ácidos voláteis; 9- pH; 10- Fósforo; 11- NTK; 12- N-ORG; 13- N-amoniacal.

5 RESULTADOS E DISCUSSÃO

5.1 Estatística descritiva dos dados

Nas Figuras 15 a 26 pode-se observar a representação dos dados na forma de gráficos boxplot das seguintes variáveis: Ácidos voláteis, Alcalinidade total, Alcalinidade a Bicarbonatos, DQO bruta, DQO filtrada, Fósforo, Nitrogênio Kjeldahl Total, Nitrogênio Amoniacal, Nitrogênio orgânico, potencial Hidrogeniônico, Sólidos Suspensos Totais, Sólidos Suspenso Fixos e Sólidos Suspensos Voláteis.

Com gráficos *boxplot* obtém-se informações sobre a mediana dos dados e dos quartis inferiores e superiores, fornecendo detalhes da distribuição das amostras e da presença de *outliers* ou suspeitos de *outliers*. Além disso, é possível indicar se os dados são simétricos ou assimétricos a partir equidistância no interior do interquartil.

Figura 15 - Gráficos *Box Plot* da concentração de ácidos voláteis na entrada e saída do reator UASB

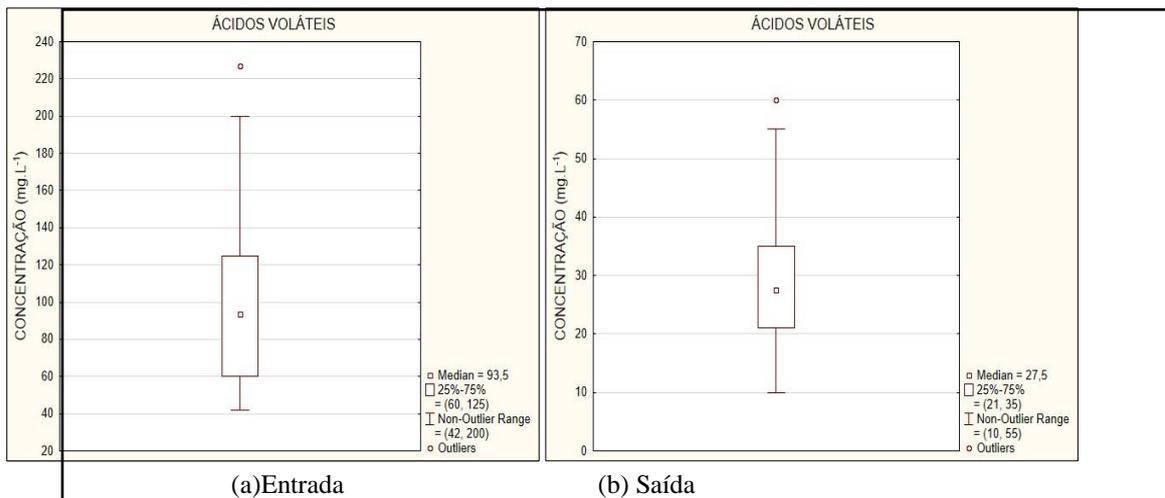


Figura 16 - Gráficos *Box Plot* da concentração de alcalinidade total, na entrada e saída do reator UASB

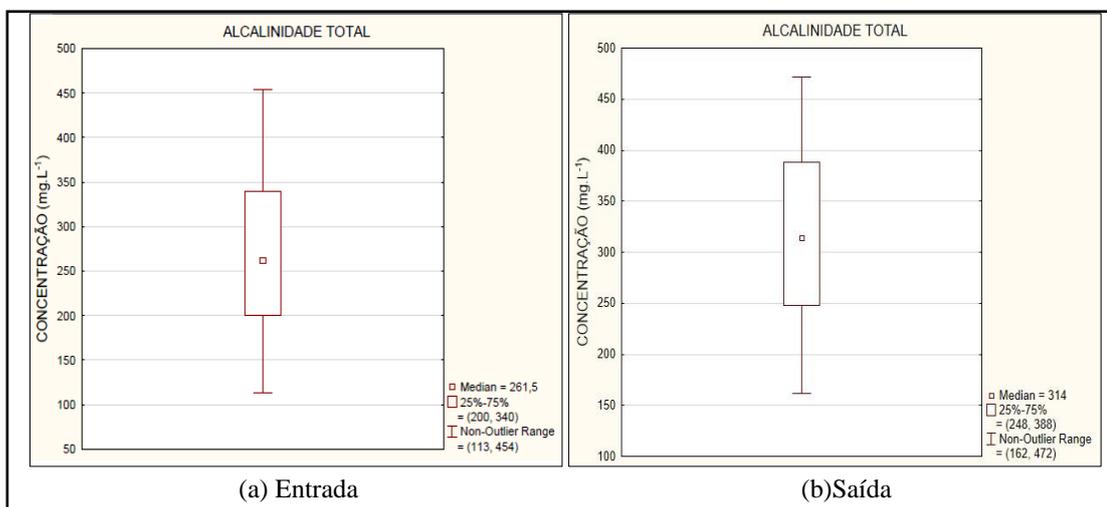


Figura 17 - Gráficos *Box Plot* da concentração de DQO bruta na entrada e saída do reator UASB.

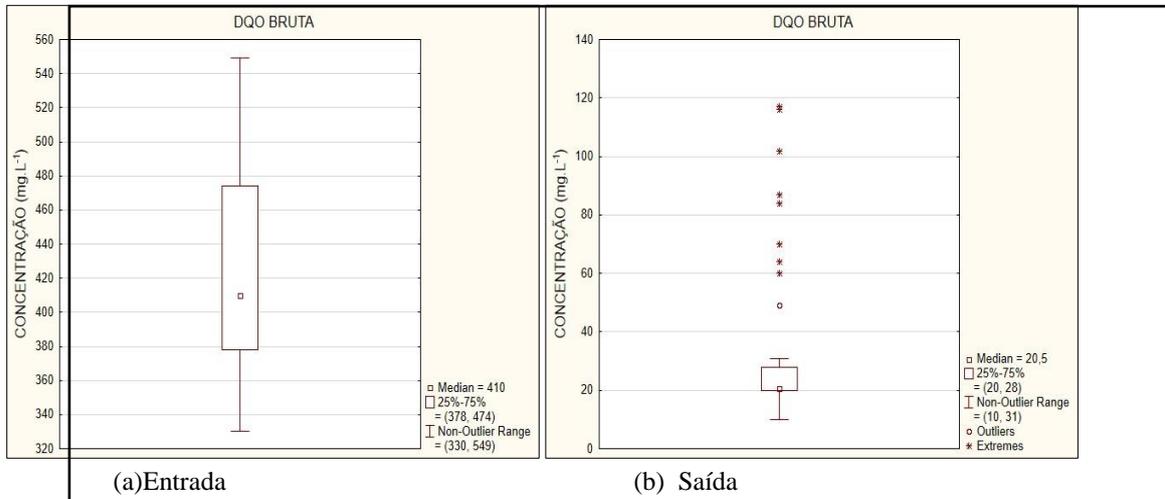


Figura 18 - Gráficos *Box Plot* da concentração de DQO filtrada na entrada e saída do reator UASB

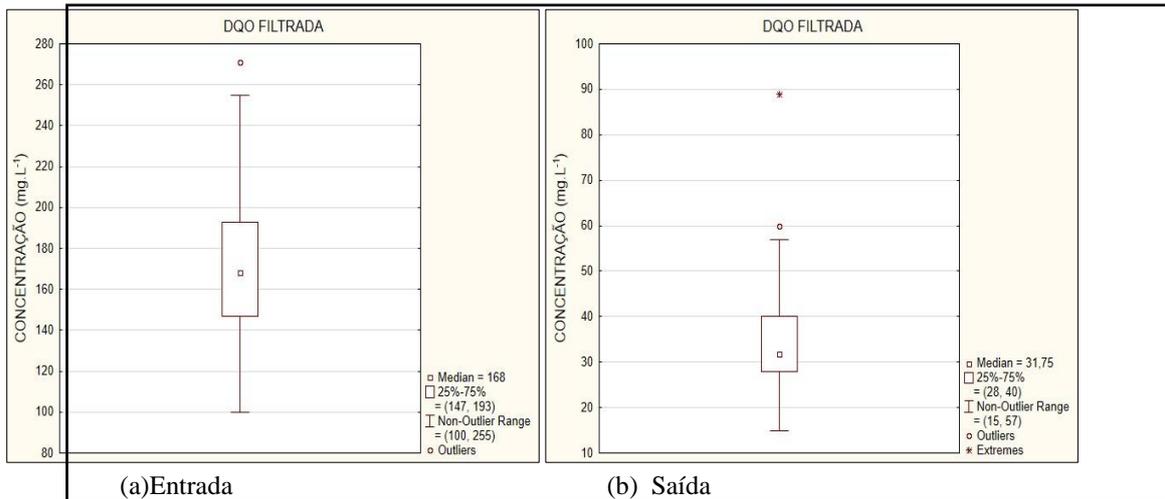


Figura 19 - Gráficos *Box Plot* da concentração de Fósforo na entrada e saída do reator UASB

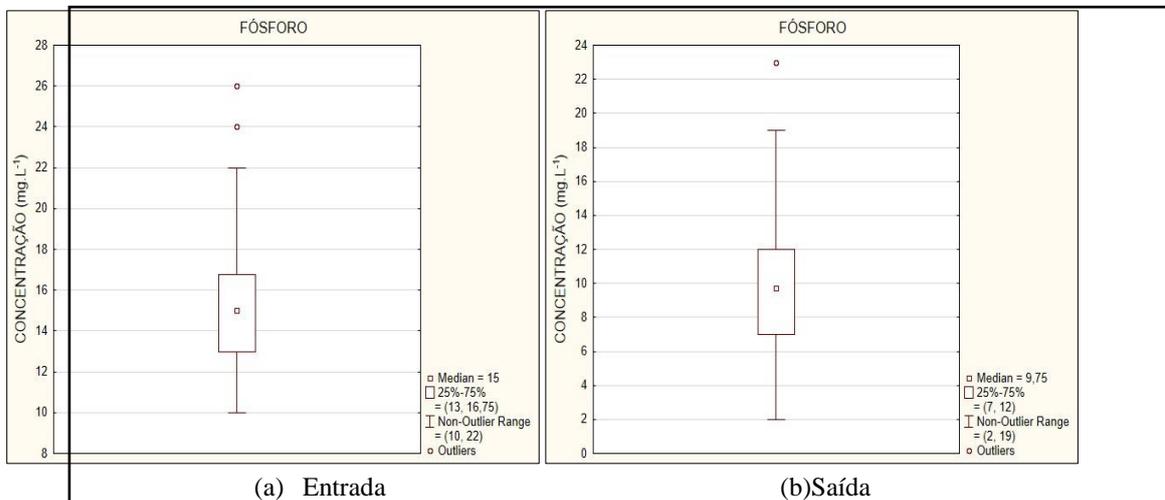


Figura20- GráficosBox Plotda concentração de nitrogênio amoniacal, na entrada e saída do reator UASB

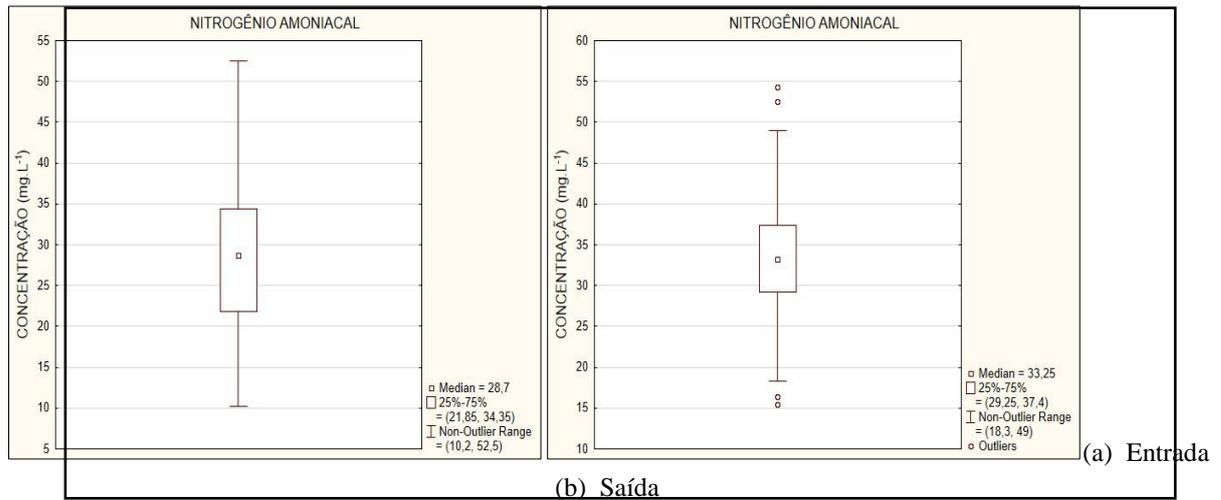


Figura 21- GráficosBox Plotda concentração de nitrogênio orgânico, na entrada e saída do reator UASB

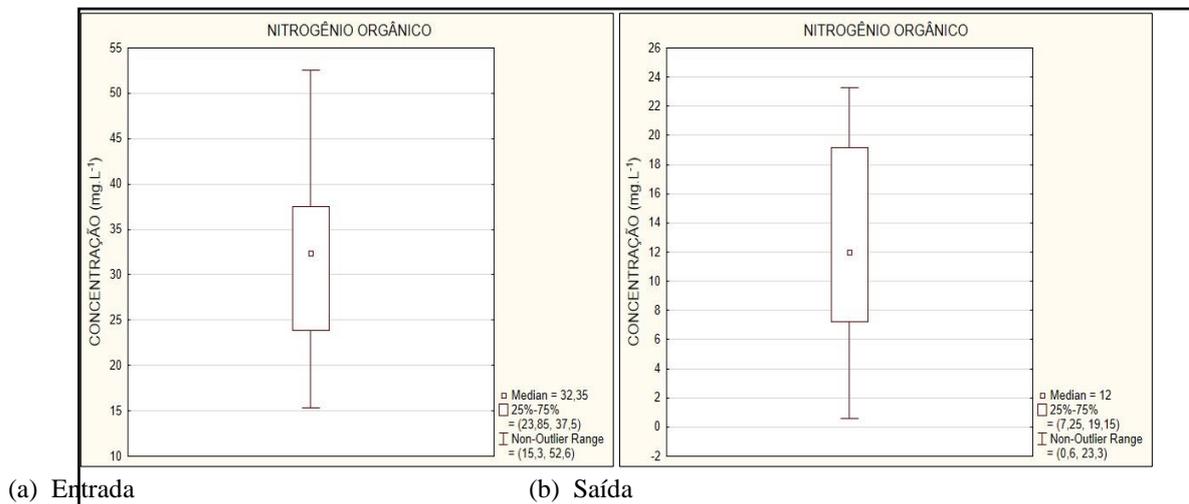


Figura 22- GráficosBox Plotda concentração de Nitrogênio Kjeldahl na entrada e saída do reator UASB

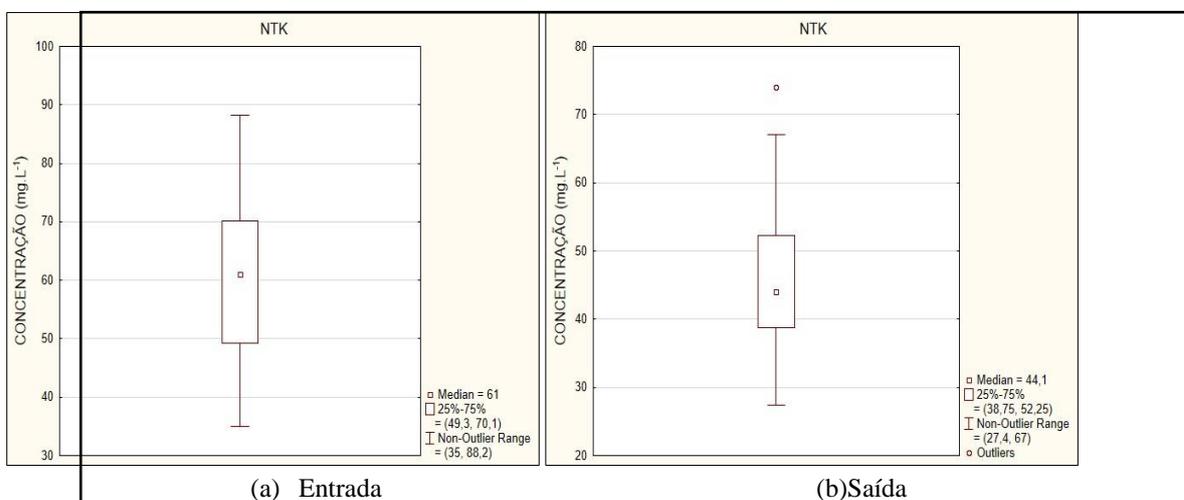


Figura 23- Gráficos *Box Plot* da concentração de potencial Hidrogeniônico na entrada e saída do reator UASB

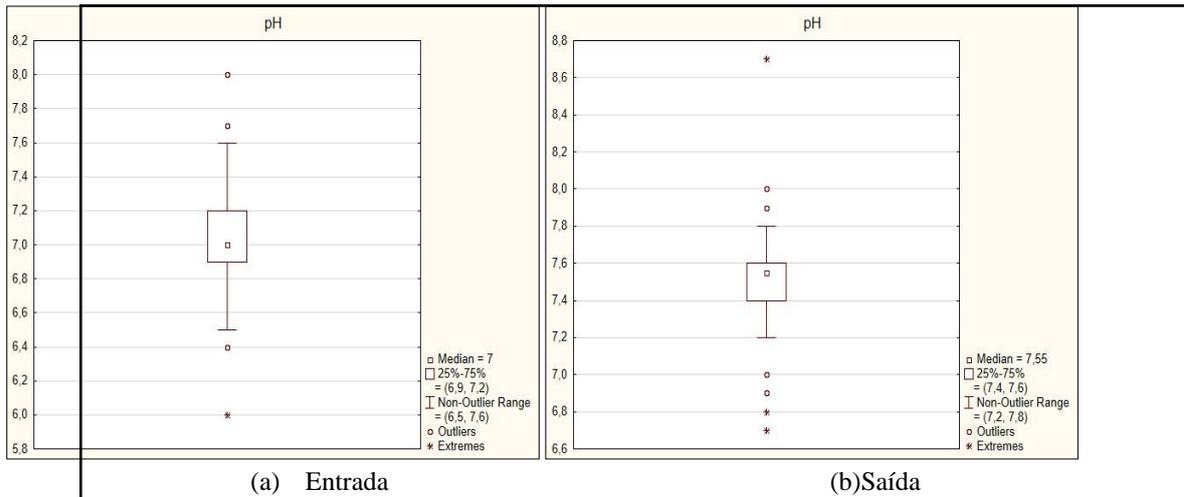


Figura 24- Gráficos *Box Plot* da concentração de sólidos suspensos fixos na entrada e saída do reator UASB

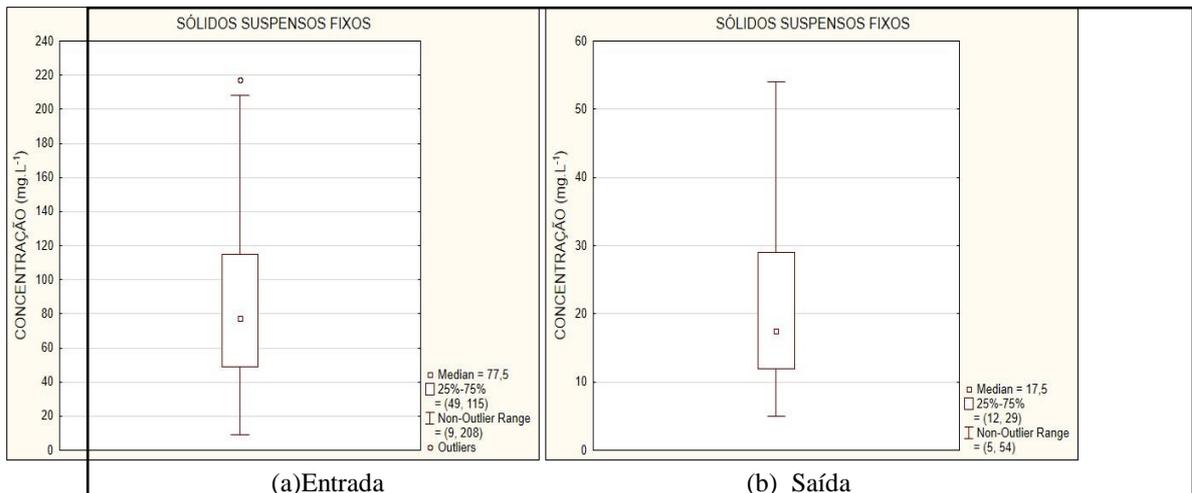


Figura 25- Gráficos *Box Plot* da concentração de sólidos suspensos voláteis na entrada e saída do reator UASB

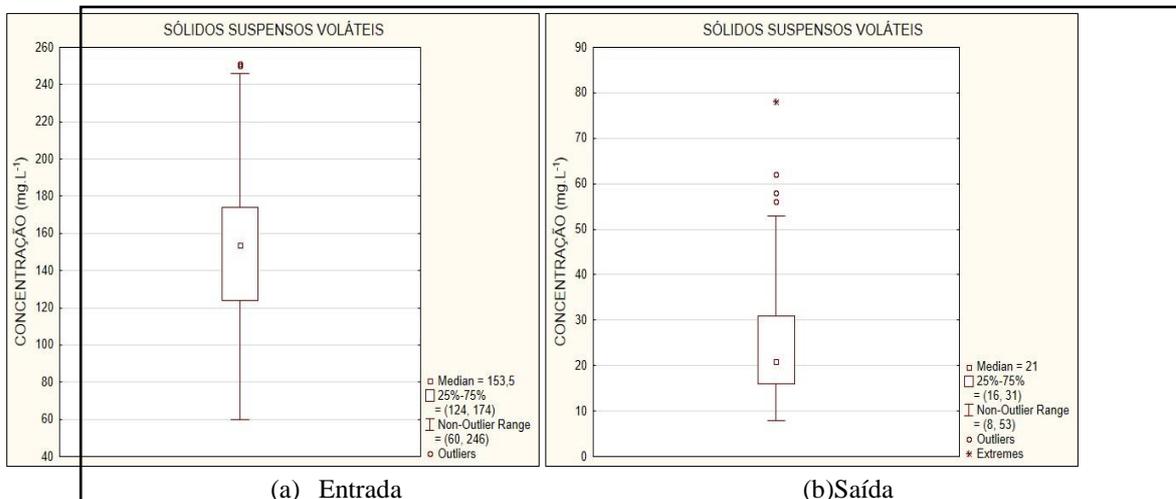
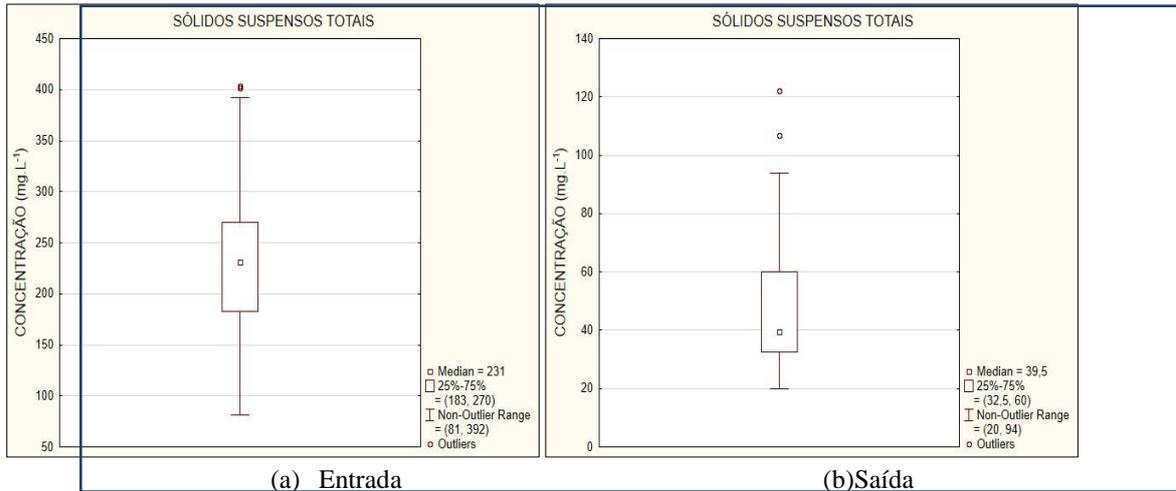


Figura 26- Gráficos *Box Plot* da concentração de sólidos suspensos totais na entrada e saída do reator UASB



Os parâmetros ácidos voláteis (Figura 15) e alcalinidade (Figura 16) possuem intensa relação entre eles, que pode ser justificada pelo fato de que durante o processo de digestão anaeróbia ocorre aumento de alcalinidade devido a remoção de ácidos graxos voláteis. O resultado médio de ácidos voláteis obtidos no afluente foi de 93,81 mg/L, com o interquartil entre 60 mg/L a 125 mg/L. Com relação a alcalinidade total o valor médio do afluente foi de 270,96 mg/L com 50% das amostras entre 200 e 340 mg/L. No efluente do reator o valor médio da alcalinidade total 317,79 mg/L, com 50 % das amostras entre 248 mg/L e 388 mg/L. Com relação a ácidos voláteis, o valor médio foi de 29,15 mg/L, com interquartil entre 21 mg/L e 35 mg/L.

No experimento de Sousa (1996), a concentração média de DQO bruta foi de 428 mg/L na entrada do reator, com 50% das amostras entre 378 mg/L e 474 mg/L, valor mínimo de 330 mg/L e máximo 548 mg/L, conforme pode ser observado na Figura 17. Enquanto que na saída do reator, a média chegou a 32,5 mg/L, com 50% das amostras entre 20 mg/L e 28 mg/L e mediana em 20,5 mg/L, o que demonstra a assimetria dos dados. Contudo, obteve-se uma remoção média de 92 % da DQO bruta.

Estes resultados obtidos são compatíveis com Rodrigues (2009) que estudou o desempenho de um reator UASB no tratamento de águas residuárias provenientes da suinocultura, quando a remoção de DQO foi de 93%. Esta redução pode ser explicada porque este tipo de reator biológico durante o processo de digestão anaeróbica na fase de acetogênese, cerca de 50 % de matéria orgânica carbonácea biodegradável são convertidos a acetato e Hidrogênio pelas bactérias acetogênicas. Segundo Van Haandel e Lettinga(1994), cerca de 70% da DQO originalmente presente é convertida em ácido acético. Pode ser observado na Figura 18 que a DQO filtrada apresenta 50% de suas amostras entre 147 mg/L e

193 mg/L na entrada do reator e na saída do reator, com 50% de suas amostras entre 28 mg/L e 40 mg/L. A DQO filtrada teve uma redução média de 80 % (Tabela 4).

A eficácia na produção de gás metano se dá mediante manutenção do potencial Hidrogeniônico numa faixa de neutralidade, variando entre 6,3 e 7,8. Desta forma, o experimento em estudo apresentou boa estabilidade do pH, visto que durante todo o monitoramento do sistema experimental o pH manteve-se dentro da faixa ideal para metanogênese, tanto na entrada do reator UASB quando apresentou média de 7,0 como na sua saída, com média de 7,5, conforme pode ser observado na Tabela 4.

Segundo Sousa (1996), tratar da eficiência da remoção de Nitrogênio levando em consideração apenas a concentração do afluente e efluente pode não ser um método adequado porque podem acontecer transformações bioquímicas produzindo ou consumindo formas de Nitrogênio. Assim, é possível explicar o aumento na concentração de Nitrogênio amoniacal. Pode ser observado na Tabela 4 que ocorreu um aumento de 14 % na concentração, justificável também porque pode acontecer amonificação com a reabilitação de N-amoniacal para o meio. A concentração de Nitrogênio orgânico teve uma remoção de 61%, fazendo com que a remoção de NTK se mantivesse em 24,8%, o que é considerada alta para os padrões de digestão anaeróbia.

Paralelamente, obteve-se uma redução da concentração de fósforo em 36 % na média, na entrada os valores estavam entre 10 mg/L e 22 mg/L, sendo 50% das amostras de 13 mg/L a 16,75 mg/L e na saída as concentrações reduziram para 2 mg/L (mínimo) a 19 mg/L (máximo), com 50% das amostras entre 7 mg/L e 12 mg/L.

De acordo com Mostert *et al.*, 1989; Rustrian *et al.*, 1998 apud Saraiva *et al.* (2002), as reações envolvendo nutrientes, como a desnitrificação e liberação ou absorção de fósforo acompanham um consumo significativo de matéria orgânica na forma de ácidos graxos voláteis de baixo peso molecular, que são compostos intermediários gerado, o que pode ser observado na Figura 19.

Os sólidos fixos (Figura 24) que apresentavam de 9,0 mg/L (mínimo) a 208,0 mg/L (máximo) na entrada passaram a apresentar uma concentração de 5 mg/L (mínimo) a 54 mg/L (máximo). Com relação aos sólidos voláteis (Figura 25), estes apresentavam concentrações de 60 mg/L a 246 mg/L na entrada passaram a apresentar concentrações de 8,0 mg/L a 53 mg/L na saída.

Como pode ser observado na Figura 26, os sólidos totais na entrada do reator, apresentaram mínimo de 81 mg/L e máximo de 392 mg/L, sendo 50% das amostras entre 183 mg/L a 270 mg/L, enquanto na saída 50% das

amostras apresentavam concentrações de 32,5 a 60 mg/L e valores mínimo e máximo de 20 mg/L e 94 mg/L, respectivamente. Conferindo uma remoção média de 80% para SST, de 82% para SSV, de 75% para SSF.

Tabela 4- Representação da concentração média de todos os parâmetros na entrada e saída do reator UASB

PARÂMETRO	ENTRADA (mg/L) *	SAÍDA(mg/ L) *	Eficiência média de remoção (%)
DQO bruta	428	32	92
DQO filtrada	173	34	80
SST	236	46	80
SSV	152	26	82
SSF	83	20	75
ALCALINIDADE TOTAL	270	317	-17
ALCALINIDADE (BICARBONATOS)	201	297	-47
ÁCIDOS VOLÁTEIS	97	29	70
pH	7	7,5	-6
FÓSFORO	15	9	36
NTK	60	45	24
NITROGÊNIO ORGÂNICO	31	12	61
NITROGÊNIO AMONICAL	29	33	-14

* Exceto o parâmetro pH

5.2 Arquitetura da Rede Neural

5.2.1 - Análise da influência do número de neurônios

Neste tópico é feita a análise da influência do número de neurônios nas camadas ocultas sobre a qualidade do ajuste obtido entre os dados experimentais e a Rede Neural Artificial. Esta análise foi feita usando-se as melhores combinações de funções de ativação estudadas no tópico anterior.

5.2.1.1 – Rede Neural com uma camada oculta

Na Tabela 5 pode-se observar a influência do número de neurônios na camada oculta sobre o coeficiente de determinação, mantendo-se constante a subdivisão do conjunto de dados experimentais. Nos três casos estudados, é possível constatar que a medida que aumenta-se o número de neurônios, eleva-se também o coeficiente de determinação. Fato que vai ao encontro do trabalho de Gonçalves *et al.* (2013) que constatou em seu estudo que com o aumento do número de neurônio o coeficiente de determinação aumentava também.

Tabela 5- Coeficiente de determinação em função da subdivisão do conjunto de dados e do número de neurônios (NN) da camada oculta na função LOGSIG

Divisão dos dados experimentais	Coeficiente de determinação (R^2)		
	NN = 5	NN = 10	NN = 15
80.10.10	0,9677	0,9821	0,9985
70.15.15	0,9768	0,9522	0,9808
60.20.20	0,9718	0,9316	0,9754

5.2.1.2 – Rede Neural com duas camadas ocultas

Na Tabela 6 pode-se observar os coeficientes de determinação para as melhores combinações de funções de ativação para cada forma como foi dividido o conjunto de dados experimentais. Pode-se inferir que com o aumento do número de neurônios nas camadas ocultas, acontece um aumento do valor do coeficiente de determinação, alcançando maiores valores quando o número de neurônios em cada camada oculta for igual a 15 (Vide Apêndice).

Tabela 6- Coeficiente de determinação em função da subdivisão do conjunto de dados e do número de neurônios (NN) da camada oculta.

Divisão dos dados experimentais	Combinação das funções de ativação	Coeficiente de determinação (R^2)		
		NN = 5	NN = 10	NN = 15
80.10.10	Tansig-Logsig	0,9677	0,9505	0,9912
70.15.15	Logsig-Tansig	0,9729	0,9546	0,9771
60.20.20	Tansig-Tansig	0,9564	0,9620	0,9549

5.2.2 – Simulação do reator UASB usando RNA

Neste tópico serão apresentados os resultados experimentais e os simulados, através da aplicação da RNA. A simulação do comportamento do reator UASB foi realizada usando-se a melhor arquitetura obtida nas análises anteriores (Subseção 5.2.1.1 e 5.2.1.2). Nas figuras apresentadas a seguir, no eixo das abcissas estão representados os parâmetros que foram utilizados para construção da rede e no eixo das coordenadas a concentração em mg/L de todos os parâmetros, exceto o pH.

5.2.2.1 – Simulação do UASB, usando uma RNA com uma camada oculta

Nas Figuras 27 e 28, pode ser observada comparação entre os dados experimentais e os resultados simulados, quando o conjunto de dados experimentais usados foi subdividido em 80% para treinamento, 10 % para validação e 10 % para teste. Observando-se estas figuras pode-se constatar que houve uma boa concordância entre os valores experimentais e os simulados pelo modelo de RNA, visto que o coeficiente de determinação médio para este caso foi igual a 0,9985 (Tabela 5) Ressalta-se que resultados semelhantes foram obtidos por Morais (2011).

Figura 27- Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 30ª semana de operação.

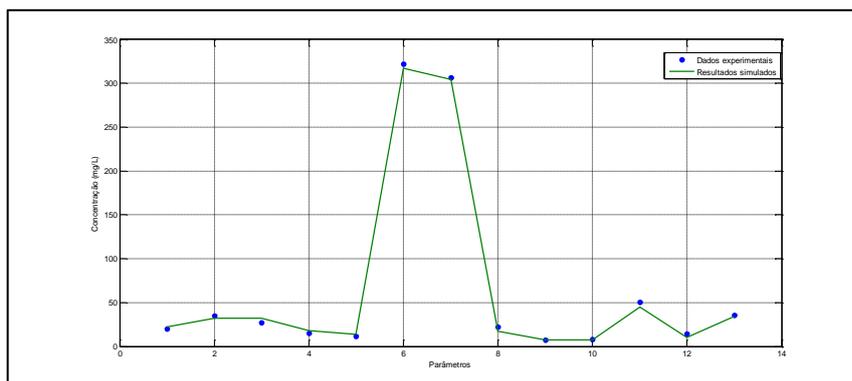
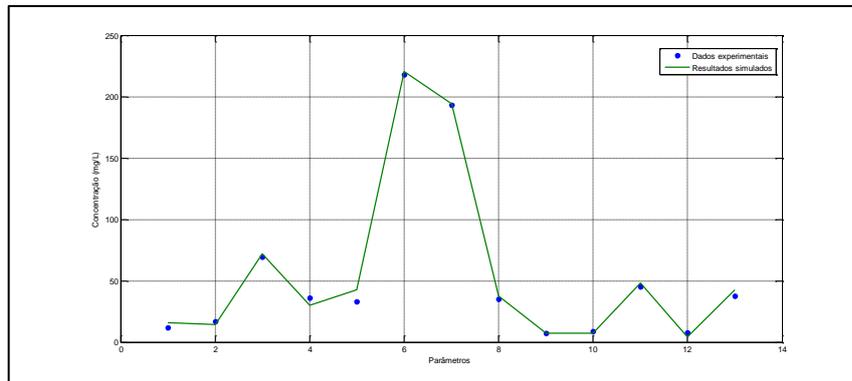


Figura 28- Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 19ª semana de operação



Nas figuras 29 e 30 está representada a comparação entre os dados experimentais e os resultados simulados, quando o conjunto de dados experimentais usados foi subdividido em 70% para treinamento, 15 % para validação e 15 % para teste (Tabela 5). Da mesma forma que a situação apresentada anteriormente (80% - 10% - 10%), a concordância entre os dados experimentais e os preditos pelo modelo pode ser considerada satisfatória, tendo em vista que o coeficiente de determinação para esse caso foi igual a 0,9808 (Tabela 5).

Figura 29- Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 7ª semana de operação.

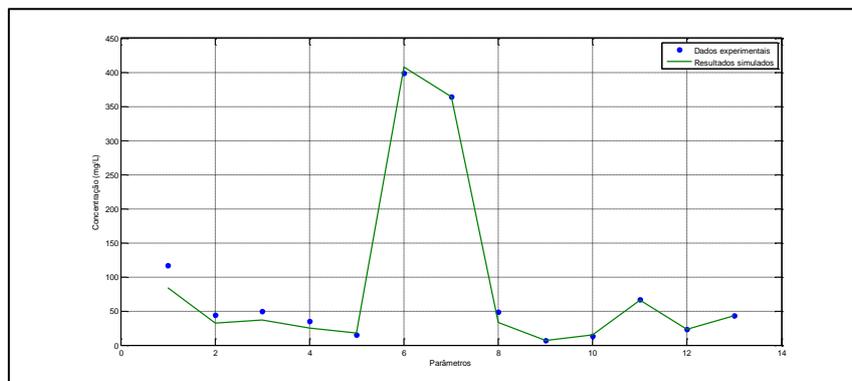
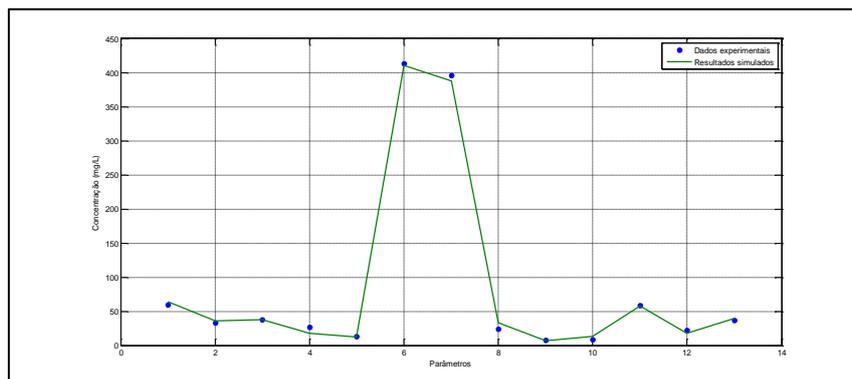


Figura 30- Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 10ª semana de operação.



Para a construção das Figuras 31 e 32, o conjunto de dados experimentais foi subdividido em 60% para treinamento, 20 % para validação e 20 % para teste. Da mesma forma que as situações mostradas anteriormente, a concordância entre os dados experimentais e os preditos pelo modelo pode ser considerada satisfatória. No entanto pode-se constatar que a medida que foi diminuindo o percentual de dados usados no treinamento, o coeficiente de determinação também foi diminuindo, conforme é possível observar na Tabela 5.

Figura 31- Representação gráfica de valores experimentais e simulados, usando o conjunto 60.20.20 para 38ª semana de operação

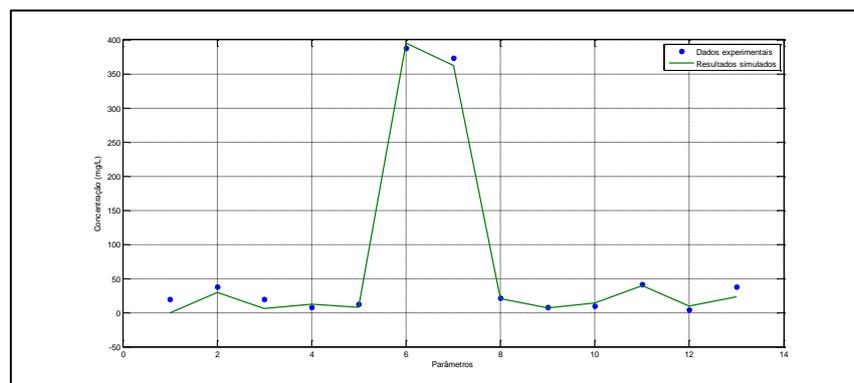
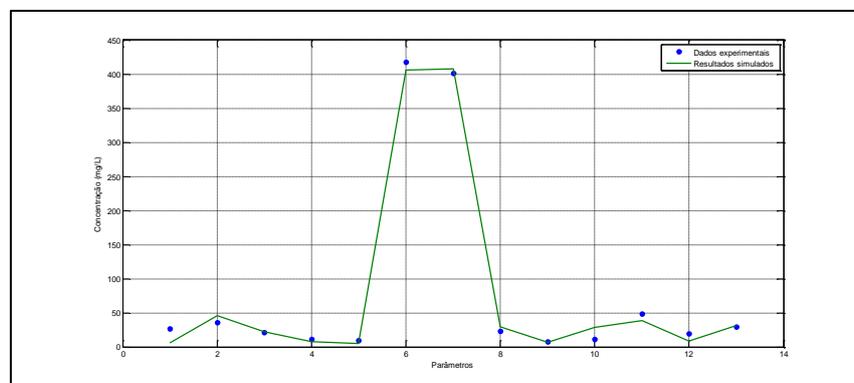


Figura 32- Representação gráfica de valores experimentais e simulados, usando o conjunto 60.20.20 para 39ª semana de operação



5.2.2.2 – Simulação do UASB, usando uma RNA com duas camadas ocultas

Nas Figuras 33 e 34 pode ser observado comparação entre os dados experimentais e os resultados simulados, quando o conjunto de dados experimentais usados foi subdividido em 80% para treinamento, 10 % para validação e 10 % para teste (Tabela 6). Constata-se que há uma relação considerável entre os dados experimentais e os resultados simulados para todos os parâmetros, fator evidenciado ainda pelo alto valor do coeficiente de determinação, 0,9912.

Figura 33- Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 39^a semana de operação.

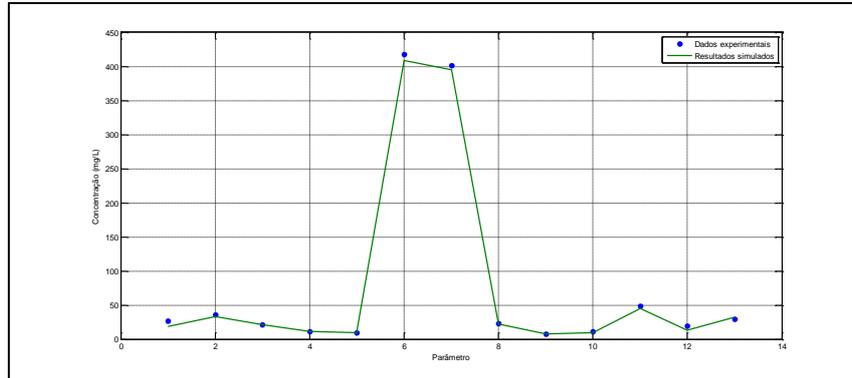
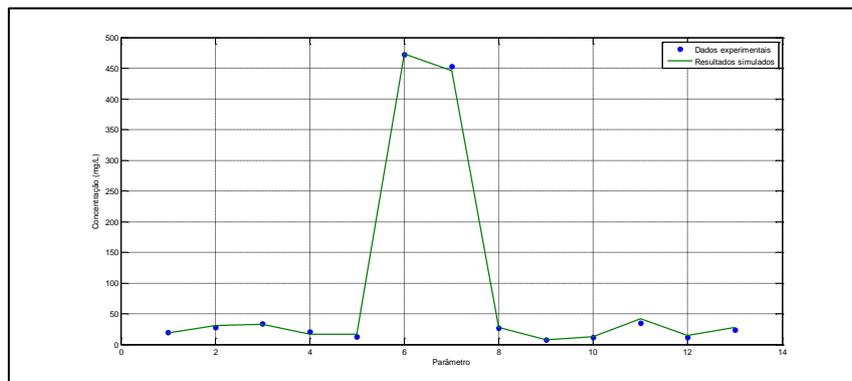


Figura 34- Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 49^a semana de operação.



Nas Figuras 35 e 36 está representada a comparação entre os dados experimentais e os resultados simulados, para as 29^a e 40^a semanas. A representação destas figuras foi obtida quando o conjunto de dados experimentais usados foi subdividido em 70% para treinamento, 15 % para validação e 15 % para teste. Apesar do alto coeficiente de determinação, os ajustes semanais de cada parâmetro não obtiveram ajustes perfeitos para os parâmetros DQO bruta, SST, Alcalinidade total e alcalinidade a bicarbonatos, conforme Figura 35. Já na Figura 36, o único parâmetro que destoava e teve discordância com os dados simulados foi o de Alcalinidade total.

Figura 35- Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 29^a semana de operação.

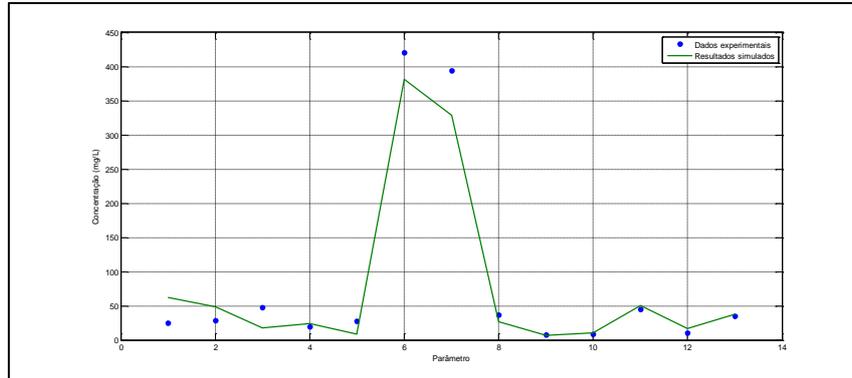
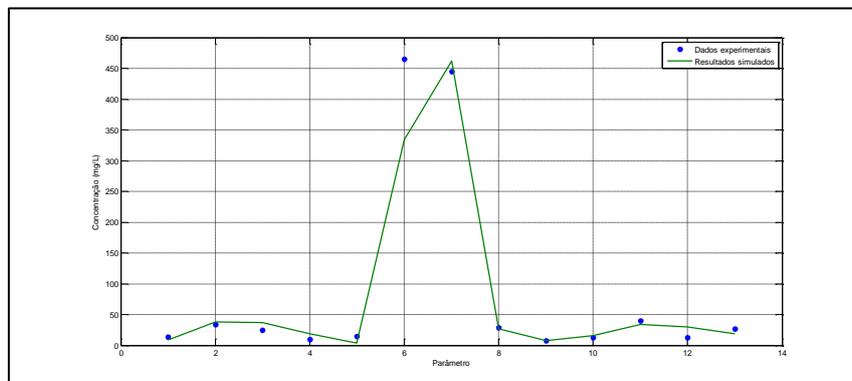


Figura 36- Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 40^a semana de operação.



Por fim, foi utilizado a subdivisão do conjunto de dados em 60% para treinamento, 20% para validação e 20 % para teste. Assim, observa-se nas Figuras 37e 38 que existe concordância direta do predito pelo modelo com os dados que foram testados experimentalmente, quando foi encontrado um R^2 igual a 0,9549 (Tabela 6). Este resultado é compatível com Nasret *al* (2012) que obteve um coeficiente de determinação de 0,93. É importante ressaltar que, da mesma maneira que aconteceu com a construção da RNA com uma camada oculta, o coeficiente de determinação tendeu a diminuir à medida que o conjunto de dados usados para treinamento diminuía.

Figura 37- Representação gráfica de valores experimentais e simulados, usando o conjunto 60.20.20 para 28ª semana de operação.

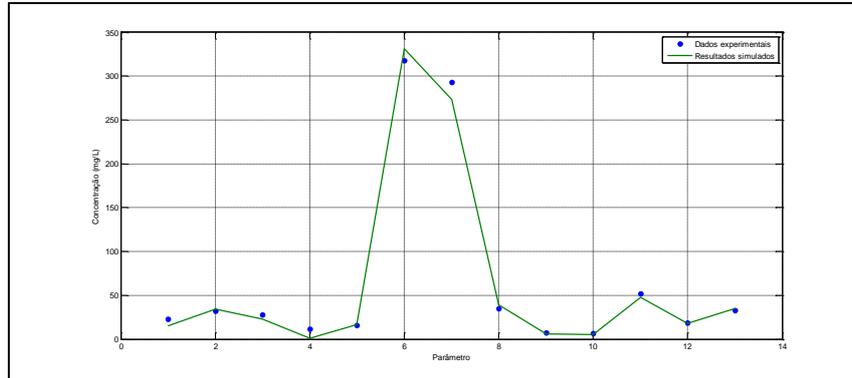
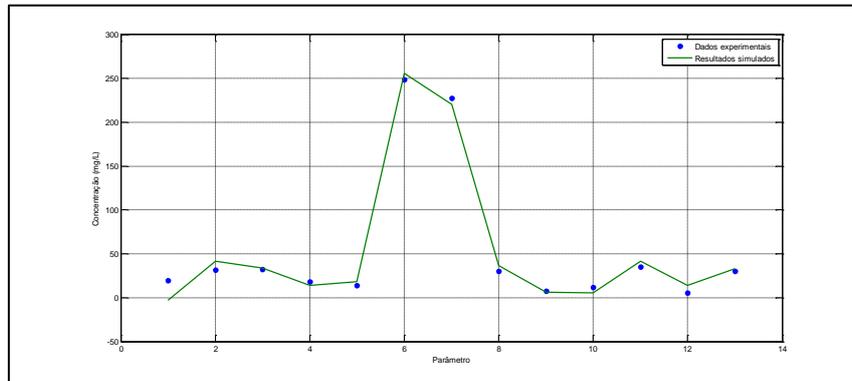


Figura 38- Representação gráfica de valores experimentais e simulados, usando o conjunto 60.20.20 para 53ª semana de operação.



6 CONSIDERAÇÕES FINAIS

A partir da escolha desse tema para desenvolvimento da dissertação de mestrado, pretendia-se modelar e simular um reator UASB utilizado em um sistema de tratamento de esgoto sanitário através da aplicação de uma das técnicas mais difundidas atualmente no meio acadêmico para a tomada de decisões, as Redes Neurais Artificiais. Para tanto, foram construídos modelos de redes neurais artificiais baseadas nos parâmetros físicos e químicos selecionados que permitisse o fornecimento de informações possíveis para avaliar as variáveis de entrada, arquitetura da rede neural, a distribuição dos dados e o desempenho dos algoritmos de otimização utilizados.

Assim, por meio da variação das funções de ativação utilizadas, Logsig e Tansig, através da variação da quantidade de camadas ocultas e pela mudança na distribuição do conjunto de dados usados para treinamento, validação e teste da rede, foi possível obter flutuações das redes, de modo a estabelecer-se a melhor rede para cada simulação.

Dessa forma, concluiu-se que quando se utiliza uma única camada intermediária, a melhor função de ativação foi a Logsig e a melhor distribuição de dados apresentou-se quando foi combinado 80% dos dados usados para treinamento, 10 % para teste e 10 % para validação. Paralelamente, é possível concluir que quanto maior é o número de neurônio usado na camada oculta, melhores coeficientes de determinação são encontrados. Nesta circunstância, o R^2 foi de 0,9985, valor considerado muito satisfatório para predição dos parâmetros analisados.

Quando modelada com 2 camadas ocultas, os resultados assemelharam-se bastante com as simulações de uma camada oculta, visto os melhores resultados terem sido obtidos na distribuição de dados, 80%, 10%, 10%, respectivamente para treinamento, teste e validação. O melhor coeficiente de determinação foi obtido com a combinação das funções de ativação Tansig na camada oculta 1 e Logsig na camada oculta 2, obtendo um R^2 de 0,9912, considerado excelente para a predição.

Simultaneamente, foi feita uma análise dos dados experimentais para atestar o êxito do funcionamento do reator UASB, parâmetro a parâmetro e evidenciou-se o bom funcionamento do reator, especialmente como removedor de DQO quando atingiu o valor de 92 % e de Sólidos Suspensos Totais com remoção média de 80%.

Sugere-se ainda como uma continuação deste trabalho uma investigação mais profunda no que se refere ao uso de outras arquiteturas como a de Base Radial, além do

aumento de camadas ocultas e a aplicação da técnica de análise de componentes principais com o intuito de diminuir as variáveis de entrada.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- ARAÚJO, A. F. de. **Inteligência Computacional na Indústria - Etapa 5: Implementação de um Modelo Matemático para um Conversor de Aço tipo LD**. Belo Horizonte, Junho 2008
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT), **Lixiviação de Resíduos - Procedimento - NBR 10.005**. Rio de Janeiro, 1987b.
- BAÇÃO, F.; LOBO, V.; PAINHO, M. **Self-organization maps as substitutes for k-means clustering**. In: International conference on computational Science, 2005, 476-483
- BRAGA, A. de P.; CARVALHO, A. C. P. de Leon Ferreira de; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007.
- BRAGA, B.; HESPANHOL, I.; CONEJO, J. G. L.; MIERZWA, J. C.; BARROS, M. T. L.; SPENCER, M.; PORTO, M.; NUCCI, N.; JULIANO, N.; EIGER, S. **Introdução à engenharia ambiental**. 2. ed. São Paulo: Pearson Prentice Hall, 2005. 313 p.
- CAMPOS, J.R.; **Tratamento de esgotos sanitários por processo anaeróbio e disposição controlada no solo**. Rio de Janeiro: ABES, 1999. p. 464
- CARLSON, R.D, **Fine structure and blood brain barrier properties of the central nervous system of a dipterium larva**. J. Comp Neurol, 324;343-352. 1992
- ENGIN, G., Demir, Ibrahim, and ENGIN, S. N., **'Determination of the Relationship between Sewage Odor and BOD by Neural Networks'**, Environmental Modeling & Software, 843-850p, 2005.
- FERNANDES, C. - **Esgotos Sanitários**, Ed. Univ./UFPB, João Pessoa, 1997, 435p. Reimpressão Jan/2000
- GONÇALVES, R. F. (Coord.) **Desinfecção de efluentes sanitários**. Rio de Janeiro: ABES/RiMa, 2003. 438 p.
- GONÇALVES, D.N.S; LOPES, L.A.S; SILVA, M.A.V; **Uso da técnica de redes neurais artificiais como modelo de distribuição de viagens o caso do açúcar para a exportação**. In: In: XXVIII Congresso de Pesquisa e Ensino em Transportes - ANPET, 2014, Curitiba. Anais do XXVIII Congresso ANPET 2014 - Curitiba/Paraná, 2014. v. 29
- GONTARSKI, C. A., RODRIGUES, P. R., MORI, M., PRENEM, L. F. (2000). **Simulation of an industrial wastewater treatment plant using artificial neural networks**. Comput. Chem. Eng., 24, 1719.
- HAMED, M M; KHALAFALLAH, M G; HASSANIEN, E A (2004). **Prediction of wastewater treatment plant performance using artificial neural networks**. Environmental Modelling and Software, 19: 919 -928.
- HAYKIN, S., **Redes neurais: princípios e prática**, 2º Ed., Porto Alegre: BOOKMAN, 2001. 696p

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Pesquisa Nacional de Saneamento Básico** – 2008. Rio de Janeiro, p.119, 2010

LEME, E. J. A. **Manual prático de tratamento de águas residuária**. 2ª edição. São Carlos: Ed.UFSCar, 2014. 599 p.

LJUNG, L. **System Identification in a MIC perspective. Modeling, Identification and Control**, v.15, n.3, p. 153-159.1994

MACHADO, Rosângela Moreira Gurgel. M149e **Estudo da associação em série de reator UASB e filtros anaeróbicos para o tratamento de esgotos sanitários**,1997.

MJALLI, F.S., AL-ASHEH,S., ALFADALAH.E, **Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance**, J. Environ. Manage. 83 (2007) 329–338.

MORAIS, J.T.G., **Modelagem de um sistema de membranas de microfiltração para água produzida de petróleo**. Dissertação (Mestrado em Programa de Engenharia Industrial (PEI)) - Universidade Federal da Bahia,2011.

MOTA, Francisco Suetonio Bastos, Von Sperling, Marcos (Coord) **Nutrientes de esgoto sanitário: utilização e remoção**. Rio de Janeiro. ABES - Associação brasileira de Engenharia Sanitária e Ambiental, 2009, v. , p. 52-173

Mu, Y.,Yu, H.Q., **Simulation of biological hydrogen production in a UASB reactor using neural network and genetic algorithm**, Int J Hydrogen Energy, Vol. 32, pp. 3308-3314, 2007

NASR, M. S., Moustafa M.A.E., Seif, H.A.E., Kobrosy, G. E. **Modelling and simulation of German IOGEST/ELAGAMY wastewater treatment plants – Egypt using GPS-X simulator**,AEJ - Alexandria Engineering Journal 01/2012; 50(4):351-357

NUVOLARI, A. (Coord.). et al. **Esgoto Sanitário – Coleta, Transporte, Tratamento e Reúso Agrícola**. 2ª ed. São Paulo: EdgardBlücher, 2003.520p

OLIVEIRA-ESQUERRE, K.P. ; Mori, M. ; Bruns, R.E. . **Simulation of an industrial wastewater treatment plant using artificial neural networks and principal components analysis**. *Brazilian Journal of Chemical Engineering* (Impresso) , v. 19, p. 365, 2004

SARAIVA, L. B.¹; KOETZ, P.R. **Avaliação da remoção de nutrientes em efluente de parboilização de arroz**, Revista brasileira de Agrociência, v. 8, n. 3, p. 00-, set-dez, 2002

RODRIGUES, S.S.M. **Modelização matemática do fenómeno de dispersão em sistemas de fluxo de interface única**. Faculdade de Farmácia- Universidade do Porto-Portugal,2009

SANTOS, C. C. dos. **Modelagem de bacias urbanas com redes neurais artificiais**. 2001. 104 f. Dissertação (Mestrado em Engenharia) - Escola Politécnica, São Paulo, 2001

SOUSA, J.T. de. **Pós-tratamento de efluente de reator anaeróbio de fluxo ascendente em reator aeróbio seqüencial em batelada e coluna de lodo anaeróbio para desnitrificação.** São Carlos: USP, 1996, 256p. Tese Doutorado

SPERLING, Marcos Von. **Introdução à qualidade das águas e ao tratamento de esgotos.** 2. ed. Departamento de Engenharia Sanitária e Ambiental – DESA, BeloHorizonte, Universidade Federal de Minas Gerais, vol 1, 2005 a. 243 p.

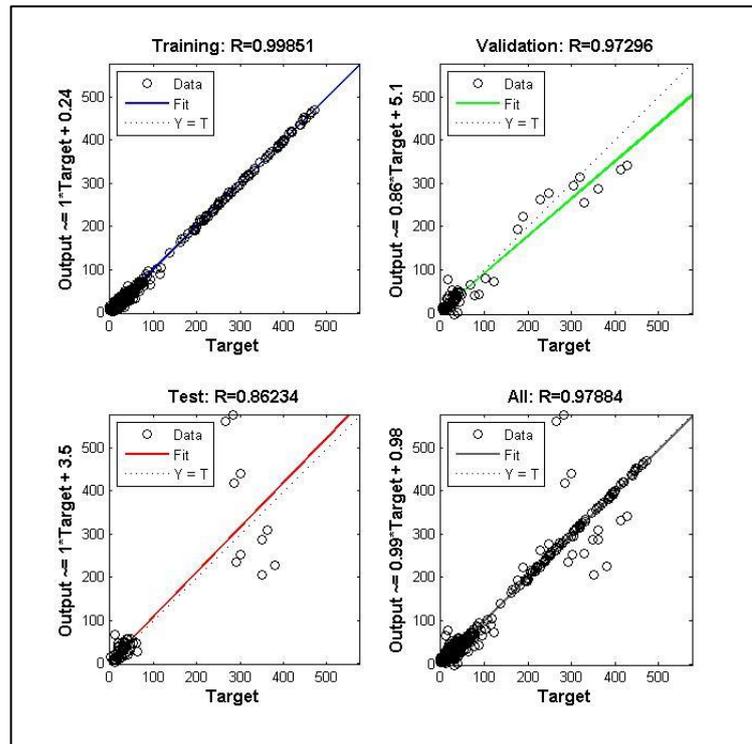
SPERLING, Marcos Von. **Princípios básicos do tratamento de esgotos.** 2. ed. Minas Gerais. Departamento de Engenharia Sanitária e Ambiental, UFMG, 2006. v. 1, 211 p

SRIDEVI, K., SIVARAMAN, E., MULLA, P., **Back propagation neural network modelling of biodegradation and fermentative biohydrogen production using distillery wastewater in a hybrid upflow anaerobic sludge blanket reactor,**In BIORESOUR
CE TECHNOLOGY; 165; 233-240; byElsevier Science B.V., Amsterdam, 2014.

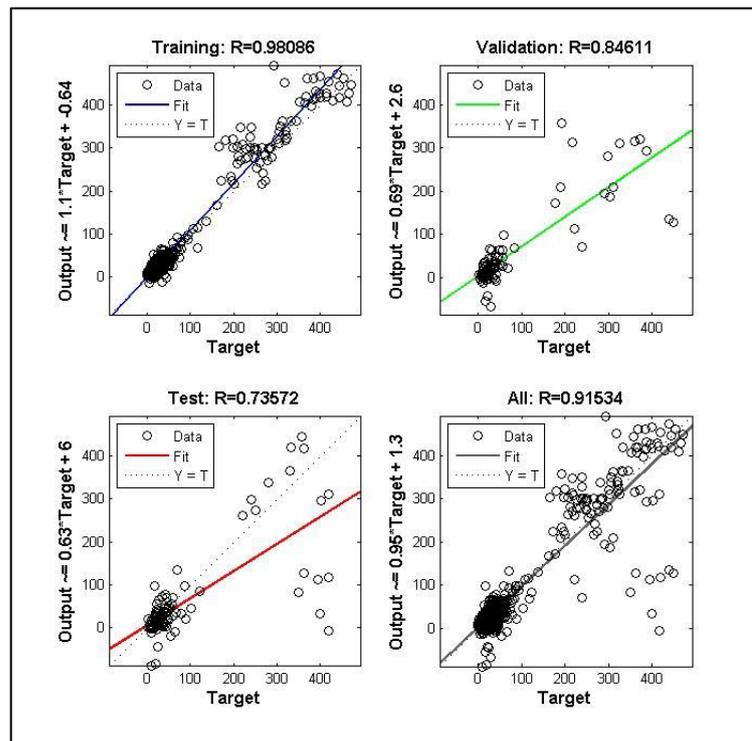
VAN HAANDEL, A.C. e LETTINGA, G. **Tratamento anaeróbio de esgotos: Um manual para regiões de clima quente,** Campina Grande - Paraíba, 240p,1994.

APÊNDICE

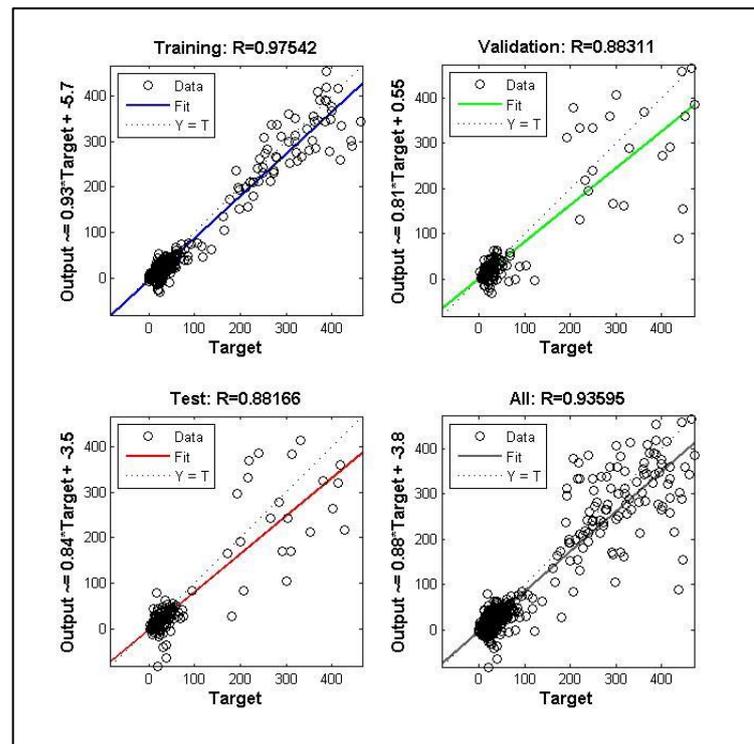
Arquitetura Neural com uma camada oculta, com 15 neurônios, função de ativação na camada oculta Logsig e combinação 80% treinamento, 10 % teste e 10 % validação



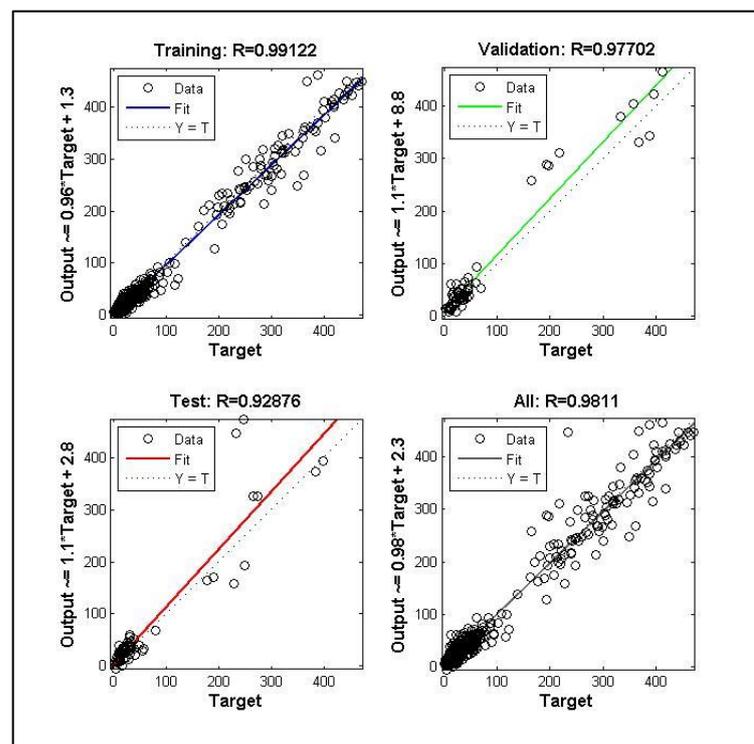
Arquitetura Neural com uma camada oculta, com 15 neurônios, função de ativação na camada oculta Logsig e combinação 70% treinamento, 15 % teste e 15 % validação



Arquitetura Neural com uma camada oculta, com 15 neurônios, função de ativação na camada oculta Logsig e combinação 60% treinamento, 20 % teste e 20 % validação.



Arquitetura Neural com duas camadas ocultas, com 15 neurônios cada, função de ativação na camada oculta Logsig e combinação 80% treinamento, 10 % teste e 10 % validação



Arquitetura Neural com duas camadas ocultas, com 15 neurônios cada, função de ativação na camada oculta Logsig e combinação 60% treinamento, 20 % teste e 20 % validação

