



UNICAMP

UNIVERSIDADE ESTADUAL DE CAMPINAS

Faculdade de Engenharia Química

CAROLINA FONSECA SILVESTRE

**INFLUÊNCIA DAS CONDIÇÕES OPERACIONAIS EM UMA PLANTA
PILOTO DE FLOTAÇÃO POR AR DISSOLVIDO (FAD)**

**INFLUENCE OF OPERATING CONDITIONS IN A DISSOLVED AIR
FLOTATION (DAF) PILOT PLANT**

Campinas, São Paulo.

Abril de 2018

CAROLINA FONSECA SILVESTRE

**INFLUÊNCIA DAS CONDIÇÕES OPERACIONAIS EM UMA PLANTA
PILOTO DE FLOTAÇÃO POR AR DISSOLVIDO (FAD)**

**INFLUENCE OF OPERATING CONDITIONS IN A DISSOLVED AIR
FLOTATION (DAF) PILOT PLANT**

*Dissertação de mestrado apresentada à
Faculdade de Engenharia Química da
Universidade Estadual de Campinas como
parte dos requisitos exigidos para a
obtenção do título de Mestra em
Engenharia Química.*

Orientador: Prof. Dr. Flávio Vasconcelos da Silva

ESTE EXEMPLAR CORRESPONDE À
VERSÃO FINAL DA DISSERTAÇÃO
DEFENDIDA PELA ALUNA
CAROLINA FONSECA SILVESTRE E
ORIENTADA PELO PROF. DR.
FLÁVIO VASCONCELOS DA SILVA.

Campinas, São Paulo.

Abril de 2018

Agência(s) de fomento e nº(s) de processo(s): CAPES, 33003017034P8; FAPESP, 2015/05207-8
ORCID: 0000-0003-2716-1261

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Luciana Pietrosanto Milla - CRB 8/8129

Si39i Silvestre, Carolina Fonseca, 1993-
Influência das condições operacionais em uma planta piloto de Flotação por Ar Dissolvido (FAD) / Carolina Fonseca Silvestre. – Campinas, SP : [s.n.], 2018.

Orientador: Flávio Vasconcelos da Silva.
Coorientador: Ana Maria Frattini Fileti.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Flotação. 2. Planejamento de experimentos. 3. Redes neurais (Computação). 4. Aprendizado de máquina. 5. Água - Purificação - Coagulação. I. Silva, Flávio Vasconcelos da, 1971-. II. Fileti, Ana Maria Frattini, 1965-. III. Universidade Estadual de Campinas. Faculdade de Engenharia Química. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: Influence of operating conditions in a Dissolved Air Flotation (DAF) pilot plant

Palavras-chave em inglês:

Flotation

Experimental design

Neural networks (Computing)

Machine learning

Water - Purification - Coagulation

Área de concentração: Engenharia Química

Titulação: Mestra em Engenharia Química **Banca examinadora:**

Flavio Vasconcelos da Silva

Edson Aparecido Abdul Nour

Douglas Fernandes Barbin

Data de defesa: 25-04-2018

Programa de Pós-Graduação: Engenharia Química

Dissertação de Mestrado defendida por Carolina Fonseca Silvestre e aprovada em 25 de Abril de 2018 pela banca examinadora constituída pelos doutores:

Prof. Dr. Flavio Vasconcelos da Silva (Orientador)

Prof. Dr. Edson Aparecido Abdul Nour

Prof. Dr. Douglas Fernandes Barbin

A ATA da Defesa com as respectivas assinaturas dos membros da banca examinadora encontra-se no processo de vida acadêmica do aluno.

*“nosso trabalho deve preparar
a próxima geração de mulheres
para nos superar em todas as áreas
esse é o legado que vamos deixar”*

- progresso

(Rupi Kaur)

Agradecimentos

Agradeço primeiramente aos meus pais e ao meu querido irmão que, apesar da distância, sempre me incentivaram em todos os meus desafios e sempre fizeram de tudo para que eu possa realizar meus sonhos.

Às grandes amizades feitas em Campinas que se tornaram uma verdadeira família ao longo desses dois anos. Em especial a Daniel, Izabela, Virna e Guilherme.

Ao meu orientador Prof. Dr. Flávio V. da Silva e minha coorientadora Prof.^a Dra. Ana Maria Frattini Fileti pela oportunidade de fazer parte da sua equipe e pelos preciosos ensinamentos.

Aos amigos do LCAP que de alguma forma me ajudaram durante os dois anos de mestrado, em especial a Ana Cláudia, Luís e Thompson.

Aos amigos e professores que fiz durante minha experiência no exterior, em especial a Takase-sensei, Hongo-sensei, Ito-sensei, Terada-sensei e Kinh-san.

À CAPES, FAPESP e JASSO pelo apoio financeiro.

Resumo

A flotação por ar dissolvido (FAD) é um processo amplamente utilizado em tratamento de água e efluentes. Nela, as partículas em suspensão têm sua densidade aparente reduzida a partir da adesão de microbolhas de ar, o que provoca a separação de tais partículas. Esse processo, deve ser precedido por um pré-tratamento: coagulação e/ou floculação; tais etapas, garantem uma melhor eficiência da flotação. Um protótipo de FAD foi montado, instrumentado e automatizado no Laboratório de Controle e Automação de Processos (LCAP) na Unicamp. Por ser um protótipo novo, faz-se necessário um estudo que defina quais são as melhores condições de processo. Dessa forma, esse trabalho investigou as condições de processo que viabilizam a melhor qualidade de água clarificada possível utilizando a ferramenta de planejamento de experimentos aliada à inteligência artificial e aprendizado de máquina. Foi possível obter remoções de turbidez de até 98,8% apenas com a etapa de floculação. Além disso, a partir das análises por planejamento de experimento concluiu-se que a vazão de tanino é a variável de entrada com maior efeito na turbidez removida. A RNA para predição da turbidez apresentou alta capacidade de generalização, entretanto não foi capaz de prever casos extremos testados nos experimentos. O modelo por regressão logística possibilitou a predição da efetividade da etapa de flotação com acurácia de 82%. Já o gerado pela rede neural classificatória obteve acurácia de 100% para os dados gerados nos ensaios.

Palavras-chave: flotação; planejamento de experimentos; redes neurais; aprendizado de máquina; coagulação.

Abstract

Dissolved air flotation (DAF) is a worldwide flotation process applied in water and wastewater treatment. The suspended particles have its density reduced by the aggregation to air micro bubbles, which causes the particles to separate. Flotation process must be preceded by a flocculation and/or coagulation pretreatment, since these processes ensure a more efficient flotation. A DAF prototype was built, instrumented and automated in the Laboratory of Process Control and Automation (LCAP) at Unicamp. Since this is a new prototype, a study that defines which are the best processes conditions is extremely necessary. Thereby, this work will investigate the processes conditions that makes the best clarified water quality possible using experimental design and artificial intelligence and machine learning tools. Turbidity removals of up to 98.8% were obtained only with the flocculation step. In addition, from the analysis by experimental design it was found that the tannin flow is the inlet variable with the greatest effect on the turbidity removal. The ANN for turbidity prediction presented high generalization capacity, however it was not able to predict extreme cases tested in the experiments. The logistic regression model enabled the prediction of the effectiveness of the flotation step with accuracy of 82%. The model generated by the classifying neural network on the other hand obtained 100% accuracy for the data generated in the experiments.

Key-words: flotation; experimental design; neural networks; machine learning; coagulation.

Lista de Figuras

FIGURA 4.1. MECANISMO DE ADESÃO BOLHA-PARTÍCULA EM FAD. (A) PARTÍCULA-BOLHA COLISÃO E ADESÃO; (B) FORMAÇÃO DA BOLHA NA SUPERFÍCIE DA PARTÍCULA; (C) APRISIONAMENTO DAS PARTÍCULAS EM AGREGADOS; (D) ARRASTAMENTO DAS BOLHAS POR AGREGADOS.	20
FIGURA 4.2. DIAGRAMA COM MODO CORRENTE EM MODO DE RECIRCULAÇÃO PRESSURIZADA.	22
FIGURA 4.3. TRÊS POSSÍVEIS SISTEMAS DE FAD EM FUNÇÃO DO MODO DE ALIMENTAÇÃO DO VASO SATURADOR.	23
FIGURA 4.4. PROVÁVEL ESTRUTURA QUÍMICA DO TANFLOC®.	25
FIGURA 4.5. ESQUEMA DO TANQUE DE FLOTAÇÃO DE UM SISTEMA DE FAD.	26
FIGURA 5.1. TANQUE FLOCULADOR COM AGITADORES MECÂNICOS ACOPLADOS.	36
FIGURA 5.2. VASO SATURADOR INSTRUMENTADO.	38
FIGURA 5.3. TANQUE FLOTADOR COM RASPADOR E CALHA COLETORA DE MATERIAL FLOTADO.	39
FIGURA 5.4. TURBIDÍMETRO ONLINE MODELO MICROTOL4 TURBIDIMETER 200064.	40
FIGURA 5.5. FILTRO DE CILÍNDRICO DE AREIA.	40
FIGURA 5.6. ESQUEMA DO PLANEJAMENTO DE EXPERIMENTOS DO PROTÓTIPO DE FLOTAÇÃO POR AR DISSOLVIDO.	43
FIGURA 5.7. TOPOLOGIA DA REDE NEURAL ARTIFICIAL PARA O SISTEMA DE FAD EM ESTUDO.	47
FIGURA 5.8. MATRIZ DE CONFUSÃO ONDE CADA QUADRADO REPRESENTA UM PARÂMETRO DE PERFORMANCE DO MODELO GERADO.	50
FIGURA 5.9. EXEMPLO DE CURVA ROC.	51
FIGURA 6.1. GRÁFICO DE PARETO.	59
FIGURA 6.2. GRÁFICO DOS VALORES DE TURBIDEZ REMOVIDA OBSERVADA E PREDITA PELO PLANEJAMENTO DE EXPERIMENTOS PARA CADA ENSAIO REALIZADO.	62
FIGURA 6.3. SUPERFÍCIE DE RESPOSTA PARA REMOÇÃO DA TURBIDEZ EM FUNÇÃO PRESSÃO E TURBIDEZ DE ENTRADA.	64
FIGURA 6.4. SUPERFÍCIE DE RESPOSTA PARA REMOÇÃO DA TURBIDEZ EM FUNÇÃO DA VAZÃO DE TANINO E RAZÃO DE RECICLO.	64
FIGURA 6.5. SUPERFÍCIE DE RESPOSTA PARA REMOÇÃO DA TURBIDEZ EM FUNÇÃO DA TURBIDEZ DE ENTRADA E VAZÃO DE EFLUENTE TOTAL.	65
FIGURA 6.6. SUPERFÍCIE DE RESPOSTA PARA REMOÇÃO DA TURBIDEZ EM FUNÇÃO DA VAZÃO DE EFLUENTE TOTAL E PRESSÃO.	66
FIGURA 6.7. SUPERFÍCIE DE RESPOSTA PARA REMOÇÃO DA TURBIDEZ EM FUNÇÃO DA VAZÃO DE TANINO E VAZÃO DE EFLUENTE TOTAL.	67
FIGURA 6.8. SUPERFÍCIE DE RESPOSTA PARA REMOÇÃO DA TURBIDEZ EM FUNÇÃO DA VAZÃO DE TANINO E TURBIDEZ DE ENTRADA.	67

FIGURA 6.9. DIAGRAMA DA RNA COM 1 CAMADA INTERMEDIÁRIA E 5 NEURÔNIOS UTILIZADA PARA O BANCO DE DADOS COM 45 LINHAS.....	68
FIGURA 6.10. DIAGRAMA DA RNA COM 1 CAMADA INTERMEDIÁRIA E 10 NEURÔNIOS UTILIZADA PARA O BANCO DE DADOS COM 150.000 LINHAS.	70
FIGURA 6.11. GRÁFICOS DE REGRESSÃO DA RNA PROPOSTA PARA O BANCO COM 150.000 LINHAS. (A) TREINAMENTO. (B) VALIDAÇÃO. (C) TESTE. (D) TOTAL.....	71
FIGURA 6.12. GRÁFICO DE REGRESSÃO PARA O TESTE REALIZADO COM A MATRIZ DE DADOS DE 52.106 LINHAS.	72
FIGURA 6.13. GRÁFICO DOS VALORES DE TURBIDEZ REMOVIDA OBSERVADA E PREDITA PELO PLANEJAMENTO DE EXPERIMENTOS E RNA PARA CADA ENSAIO REALIZADO.	73
FIGURA 6.14. ENSAIO 45 ONDE HOUVE FLOTAÇÃO.....	74
FIGURA 6.15. ENSAIO 39, ONDE NÃO HOUVE FLOTAÇÃO.	74
FIGURA 6.16. VALIDAÇÃO PARA SELEÇÃO DO MELHOR PARÂMETRO DE REGULARIZAÇÃO.....	75
FIGURA 6.17. CURVAS DE APRENDIZADO PARA $\lambda = 0,1$	76
FIGURA 6.18. MATRIZ DE CONFUSÃO DE RESULTADOS GERADO PELA REGRESSÃO LOGÍSTICA.....	77
FIGURA 6.19. DIAGRAMA DA RNA COM 1 CAMADA INTERMEDIÁRIA E 5 NEURÔNIOS UTILIZADA PARA O BANCO DE DADOS COM 150.000 LINHAS.....	79
FIGURA 6.20. MATRIZ DE CONFUSÃO DE RESULTADOS GERADO PELA RNA CLASSIFICATÓRIA.	79
FIGURA 6.21. CURVAS ROC PARA TODAS AS ETAPAS DA CONSTRUÇÃO DA RNA CLASSIFICATÓRIA.	81
FIGURA 6.22. FIGURA 33. MATRIZ DE CONFUSÃO DE RESULTADOS DO TESTE DA RNA CLASSIFICATÓRIA.	82
FIGURA 6.23. CURVA ROC PARA O TESTE DA RNA CLASSIFICATÓRIA.....	82
FIGURA A. 1. DIAGRAMA DE BLOCOS REPRESENTANDO AS ETAPAS DA PLANTA PILOTO DE FAD.....	93
FIGURA A. 2. DIAGRAMA P&ID DO PROTÓTIPO DE FAD.....	94

Lista de Tabelas

TABELA 5.1. LISTA DE ATUADORES, EQUIPAMENTOS E INSTRUMENTOS DA PLANTA DE FAD.....	33
TABELA 5.2. NÍVEIS DO PLANEJAMENTO EXPERIMENTAL COMPOSTO CENTRAL DAS VARIÁVEIS DE PROCESSO ESTUDADAS.....	43
TABELA 5.3. MATRIZ DO PLANEJAMENTO COMPOSTO CENTRAL DOS ENSAIOS REALIZADOS.....	44
TABELA 6.1. RESULTADOS DOS <i>JAR TESTS</i> PARA EFLUENTES COM TURBIDEZ INICIAL DE 4,9; 32,5; 52,5; 72,5 E 100,1 NTU.	53
TABELA 6.2. MATRIZ DE PLANEJAMENTO NAS VARIÁVEIS ORIGINAIS E COM RESULTADOS DE TURBIDEZ REMOVIDA.	55
TABELA 6.3. MATRIZ DE EFEITOS COMPLETA E COM EFEITOS SIGNIFICATIVOS DESTACADOS PARA 95% DE CONFIANÇA.....	57
TABELA 6.4. RESULTADOS DA BACKWARD ELIMINATION.	60
TABELA 6.5. MATRIZ DE EFEITOS REDUZIDA APÓS BACKWARD ELIMINATION.	60
TABELA 6.6. TABELA ANOVA DO MODELO PROPOSTO.....	61
TABELA 6.7. PARÂMETROS DE PERFORMANCE PARA RNA COM 5 NEURÔNIOS NA CAMADA INTERMEDIÁRIA (BANCO DE DADOS COM 45 LINHAS).....	68
TABELA 6.8. MÉDIA DOS PARÂMETROS DE PERFORMANCE PARA RNAs COM DIFERENTES NÚMEROS DE NEURÔNIOS NA CAMADA INTERMEDIÁRIA (BANCO DE DADOS COM 150.000 LINHAS).	70
TABELA 6.9. PARÂMETROS DO MODELO DE REGRESSÃO LOGÍSTICA.....	76
TABELA 6.10. PARÂMETROS DE PERFORMANCE DO MODELO GERADO PELA REGRESSÃO LOGÍSTICA.	77
TABELA 6.11. MÉDIA DOS PARÂMETROS DE PERFORMANCE PARA RNAs CLASSIFICATÓRIAS COM DIFERENTES NÚMEROS DE NEURÔNIOS NA CAMADA INTERMEDIÁRIA (BANCO DE DADOS COM 150.000 LINHAS).	79

Lista de abreviaturas e siglas

ANN	<i>Artificial Neural Networks</i>
ANOVA	Análise de variância
BFD	Diagrama de blocos
CLP	Computador Lógico Programável
DQO	Demanda Química de Oxigênio
ETA	Estação de Tratamento de Água
ETE	Estação de Tratamento de Efluente
FAD	Flotação por Ar Dissolvido
FN	Falsos Negativos
FP	Falsos Positivos
IAE	<i>Integral of Absolute Error</i>
MSR	Metodologia de Superfície de Resposta
NTU	<i>Nephelometric Turbidity Unit</i>
P&ID	Diagrama de instrumentação e processo
ROC	Característica de Operação do Receptor
RNA	Redes Neurais Artificiais
VN	Verdadeiros Negativos
VP	Verdadeiros Positivos
%E	Porcentagem de Erro

Lista de símbolos

$h_{\theta}(X)$	Função hipótese
IAE	<i>Integral of Absolute Error</i>
$J(\theta)$	Função custo
λ	Parâmetro de regularização
m	Número de amostras utilizadas no treinamento da regressão logística
MQ	Soma Quadrática
MSE	Média dos Erros Quadrados
NTU_e	Turbidez de efluente a ser tratado [NTU]
NTU_s	Turbidez de efluente clarificado [NTU]
P	Pressão no vaso saturador [bar]
Q_{tanino}	Vazão de floculante [mL/min]
Q_r	Vazão de reciclo [mL/min]
Q_{total}	Vazão de água a ser tratada [L/min]
R	Razão de reciclo do efluente clarificado [%]
R	Coefficiente de correlação
R^2	Coefficiente de determinação
θ	Parâmetros do modelo de regressão logística
TR	Turbidez Removida [%]

Sumário

Agradecimentos	6
Resumo	7
Abstract.....	8
Lista de Figuras	9
Lista de Tabelas	11
Lista de abreviaturas e siglas	12
Lista de símbolos	13
1 Introdução	16
2 Hipótese	18
3 Objetivo	18
3.1 Objetivos Específicos	18
4 Fundamentação Teórica e Revisão Bibliográfica.....	19
4.1 Flotação.....	19
4.1.1 Flotação por Ar Dissolvido	20
4.2 Planejamento de Experimentos.....	28
4.3 Inteligência Artificial: o uso de Redes Neurais Artificiais	29
5 Materiais e Métodos	32
5.1 Descrição da planta piloto e procedimentos de operação	32
5.1.1 Armazenamento de água bruta (sistema simulado).....	34
5.1.2 <i>Jar tests</i>	35
5.1.3 Floculador.....	36
5.1.4 Vaso saturador	37
5.1.5 Flotador.....	38
5.1.6 Limpeza do filtro	41
5.1.7 Controlador Lógico Programável e Sistema Supervisório	41
5.1.8 <i>Start-up</i> da planta	41

5.2	Planejamento de Experimentos.....	42
5.3	Modelos de predição por Redes Neurais Artificiais e regressão logística.....	45
5.3.1	RNA para predição da turbidez removida.....	46
5.3.2	Regressão logística.....	48
5.3.3	RNA classificatória para flotação.....	50
6	Resultados e Discussão.....	53
6.1	Padronização do tratamento físico-químico do efluente.....	53
6.2	Análise da turbidez removida.....	54
6.2.1	Predição da Turbidez Removida utilizando regressão linear e Planejamento de Experimentos.....	55
6.2.2	Predição da Turbidez Removida utilizando Redes Neurais Artificiais.....	68
6.2.3	Análise comparativa entre os resultados do modelo do Planejamento de Experimentos e do modelo de RNA.....	72
6.3	Análise da efetividade da etapa de flotação.....	73
6.3.1	Predição da flotação utilizando modelo por Regressão Logística.....	74
6.3.2	Predição da flotação utilizando Redes Neurais Artificiais Classificadorias.....	78
7	Considerações finais.....	84
8	Conclusões.....	87
8.1	Sugestões para trabalhos futuros.....	87
9	Referências Bibliográficas.....	89
	Apêndice A – Detalhes da Planta de FAD.....	92
	Apêndice B – Dados dos <i>Jar tests</i>	95
	Apêndice C – Detalhes da RNA para predição da turbidez removida.....	102
	Apêndice D – Detalhes da RNA para predição da flotação.....	87

1 Introdução

Essencial para a vida na Terra, a água compõe a maior parte do planeta. Presente nos três estados físicos, sólido na forma de geleiras; líquido na forma de oceanos, mares, rios, lagos e lagoas; e gasoso de forma dispersa na atmosfera, a água sempre foi sinônimo de vida. Isso pode ser exemplificado a partir da formação das primeiras civilizações humanas, que em todos os casos se deram às margens de importantes mananciais.

Infelizmente, a medida que a sociedade evolui tecnologicamente, esse recurso vem se tornando cada vez mais escasso. Dessa forma, a partir do momento em que se percebeu que a água potável é um recurso finito, alternativas para o seu tratamento e reuso vem sendo desenvolvidas. Atualmente, há diversas esferas para o tratamento de água: desde o tratamento para tratar a água coletada na natureza para uso humano até o tratamento para devolução da água utilizada à natureza. As estações de tratamento de água e efluente (ETA e ETE, respectivamente) são fonte de inúmeros estudos e desenvolvimento tecnológico para profissionais da área da ecologia, química, gestão ambiental, engenharia sanitária, engenharia ambiental, engenharia química, entre outros.

Apesar do reconhecimento da importância da água para a humanidade, o que garante o seu tratamento e uso racional, muitas vezes, é a legislação ambiental. Com objetivo de proteger os seus recursos, cada país conta com leis ambientais específicas que variam de acordo com a disponibilidade e consciência quanto ao uso da água em cada cultura. No Brasil, tem-se duas principais resoluções redigidas pelo Conselho Nacional do Meio Ambiente – CONAMA: a nº 357 e a nº 430. A resolução nº 357 dispõe sobre a classificação dos corpos de água, como enquadrá-los e quais são os padrões de lançamento de efluentes. Já a nº 430 foi criada com objetivo de complementar a nº 357. Além disso, outras portarias também são utilizadas como referência para o tratamento de água, como, por exemplo, a Portaria de consolidação nº 5 (2017), do Ministério da Saúde, que define o seu padrão de potabilidade.

Nesse contexto, a flotação por ar dissolvido (FAD) torna-se uma alternativa viável para o tratamento de águas de abastecimento e efluentes industriais. A FAD é o método de flotação mais utilizado no tratamento de efluentes industriais (RUBIO et al., 2002). Ela consiste em injetar microbolhas de ar no afluente, o que promove o arraste das partículas em suspensão, reduzindo sua densidade aparente e promovendo o acúmulo das mesmas na superfície do líquido. Sendo enquadrada como um processo de clarificação, a FAD é empregada na remoção de partículas em estações de tratamento de efluente através de filtração em meio granular

(EDZWALD, 2010). Apesar de ser amplamente utilizada, quase não há relatos do uso de instrumentação e automação de tal processo na literatura. Como o tratamento de águas para abastecimento público e efluentes faz parte de uma gama de processos que está sujeito a variações de condições de operações a todo tempo, sempre se mostrando algo imprevisível, o uso de automação e controle garante confiança e repetibilidade para cumprimento dos padrões exigidos por lei. Além disso, a automação do processo permite a otimização de vários parâmetros como, por exemplo, o consumo de energia, visto que esse é um dos principais gastos em um processo industrial.

Apesar de ser o método de flotação mais utilizado na indústria, é comum surgir a dúvida sobre suas vantagens em relação ao processo de sedimentação. Dentre as vantagens comprovadas na literatura estão, principalmente, o menor tempo de partida e necessidade de espaço físico da FAD. Assim, investir em desenvolvimento de novas tecnologias nesse tipo de flotação mostra-se como algo com muito potencial, visto a maior flexibilidade que esse tipo de processo apresenta em relação a sedimentação.

Portanto, este trabalho teve por objetivo avaliar o processo de uma planta de FAD automatizada, assim como determinar quais as melhores condições de operação que garantiram um tratamento de água mais eficiente possível para no futuro sugerir modificações em sua automação. Por ter sido um projeto muito recente no Laboratório de Controle e Automação de Processos da Unicamp, esse trabalho apresentou alto caráter exploratório, tendo em vista que se havia, até então, poucas informações sobre o protótipo criado. Dessa forma, foi necessário estudar quais foram as possíveis e melhores faixas de operação para que, a partir disso, modelos fenomenológicos e estudos de controle e automação mais avançados possam ser realizados.

2 Hipótese

A pressão do vaso saturador, a vazão de floculante na entrada do tanque floculador, a razão de reciclo do efluente clarificado, vazão de água a ser tratada e a turbidez de entrada do efluente são variáveis manipuladas que influenciam diretamente a qualidade do tratamento de água em um protótipo de flotação por ar dissolvido.

3 Objetivo

Este trabalho teve por objetivos gerais:

- Investigar a influência das variáveis manipuladas de um sistema de flotação por ar dissolvido na variável resposta diretamente relacionada à eficiência do tratamento: turbidez removida do efluente final;
- Desenvolver um modelo que descreva a turbidez removida em função das condições de operação;
- Desenvolver uma ferramenta computacional capaz de definir se a etapa de flotação será bem-sucedida ou não em função das condições de operação;

3.1 Objetivos Específicos

Para viabilizar o cumprimento dos objetivos gerais, os objetivos específicos foram:

- Definir quais são as faixas de operação das variáveis manipuladas utilizadas no planejamento de experimentos;
- Adequar o protótipo de flotação por ar dissolvido para atender as necessidades deste projeto;
- Definir as dosagens de coagulante e floculante na etapa de floculação através de ensaios *Jar test*.

4 Fundamentação Teórica e Revisão Bibliográfica

A investigação das condições de processo que viabilizem a melhor qualidade de água clarificada possível em um sistema de FAD envolve conhecimentos de técnicas de floculação e flotação. Dessa forma, é necessária uma fundamentação teórica sobre tais conteúdos, assim como uma contextualização dentro dos últimos avanços tecnológicos em cada um dos assuntos.

4.1 Flotação

Os primeiros relatos de uso de flotação para o tratamento de água potável são da década de 1920, contudo, apenas em 1960 países como Suécia, Finlândia, África do Sul e Reino Unido voltaram a mostrar interesse no assunto (HAARHOFF, 2008). Atualmente, a flotação utilizada em tratamento de água é um processo amplamente difundido, desde estações em pequenas comunidades até estações de porte industrial, como uma construída na cidade de Nova York com $1,1 \cdot 10^6$ m³/dia (CROSSLEY; VALADE, 2006).

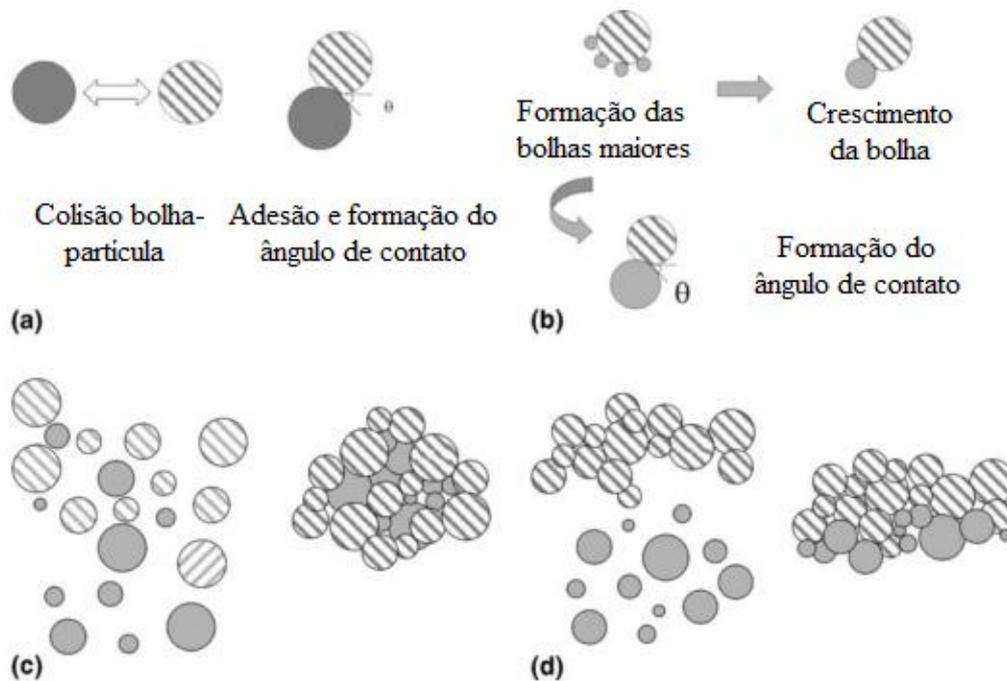
O principal conceito envolvido na flotação está relacionado com a separação de materiais hidrofílicos de hidrofóbicos. Dessa forma, tal processo apresenta as mais diversas aplicações como na indústria de minério, produção e tratamento de petróleo, reciclagem de papel, indústria alimentícia, bioengenharia e tratamento de efluentes e água potável. A medida que os processos se diferenciam, as técnicas de flotação também se distinguem. No tratamento de minérios, por exemplo, a flotação por coluna é amplamente usada, enquanto em tratamento de efluentes, os tanques de flotação são mais utilizados.

Em termos de formação de bolhas, existem três principais formas de flotação: eletrolítica, por ar disperso e por ar dissolvido (EDZWALD; HAARHOFF, 2011). A flotação eletrolítica ocorre a partir da aplicação de corrente entre dois eletrodos inseridos em soluções aquosas diluídas, formando bolhas de oxigênio e nitrogênio. Já na flotação por ar disperso, as bolhas são formadas de forma mecânica pela passagem de ar através de difusores porosos ou por aeração através de turbinas. Finalmente, na flotação por ar dissolvido, as bolhas são formadas pela redução de pressão da mistura de água saturada com ar. Ainda segundo Edzwald e Haarhoff (2011), entre os três tipos de flotação com formação de bolhas, apenas a FAD é adequada para tratamento de água. Dentre os diversos fatores que explicam essa vantagem, pode-se citar o menor tamanho das bolhas geradas (entre 10 e 100 μ m), o fato da FAD não gerar subprodutos contaminantes para o uso em tratamento de água potável e o baixo custo energético e operacional para a sua operação quando comparada a flotação por ar disperso e eletrolítica.

4.1.1 Flotação por Ar Dissolvido

A flotação por ar dissolvido ocorre a partir da adesão de microbolhas de ar em partículas sólidas suspensas na água diminuindo a sua densidade aparente fazendo com que, dessa maneira, o complexo microbolhas-sólidos se acumule na superfície do líquido utilizado. (Figura 4.1). Mais detalhadamente, de início, a partícula a ser separada colide e é aderida as microbolhas de ar geradas no processo; em seguida há a formação de microbolhas maiores na superfície da partícula a partir da coalescência das bolhas de ar descritas na etapa anterior; depois, as microbolhas aprisionam as partículas em agregados; por fim, esses agregados são arrastados para a superfície da água (RUBIO et al., 2002).

Figura 4.1. Mecanismo de adesão bolha-partícula em FAD. (a) partícula-bolha colisão e adesão; (b) formação da bolha na superfície da partícula; (c) aprisionamento das partículas em agregados; (d) arrastamento das bolhas por agregados.



Fonte: adaptado de Rubio et al. (2002)

De acordo com Edzwald (2010), existem quatro tipos de forças ou interações bolha-bolha que afetam o comportamento das microbolhas em termos de coalescência: forças de London-Van der Waals, eletrostática, forças atrativas de longo alcance e interação hidrofóbica

e repulsão hidrodinâmica. Descrever tais forças é relativamente simples, quando comparado a quantificação das mesmas.

Em termos operacionais, uma planta de FAD funciona, resumidamente, a partir da dissolução de ar a alta pressão na água a ser tratada e, em seguida, essa solução é inserida no fundo de um tanque clarificador. A queda de pressão que ocorre no tanque clarificador é o que proporciona a separação e clarificação da água. Os agregados flocos-bolhas são coletados no topo do clarificador (BICKERTON, 2012).

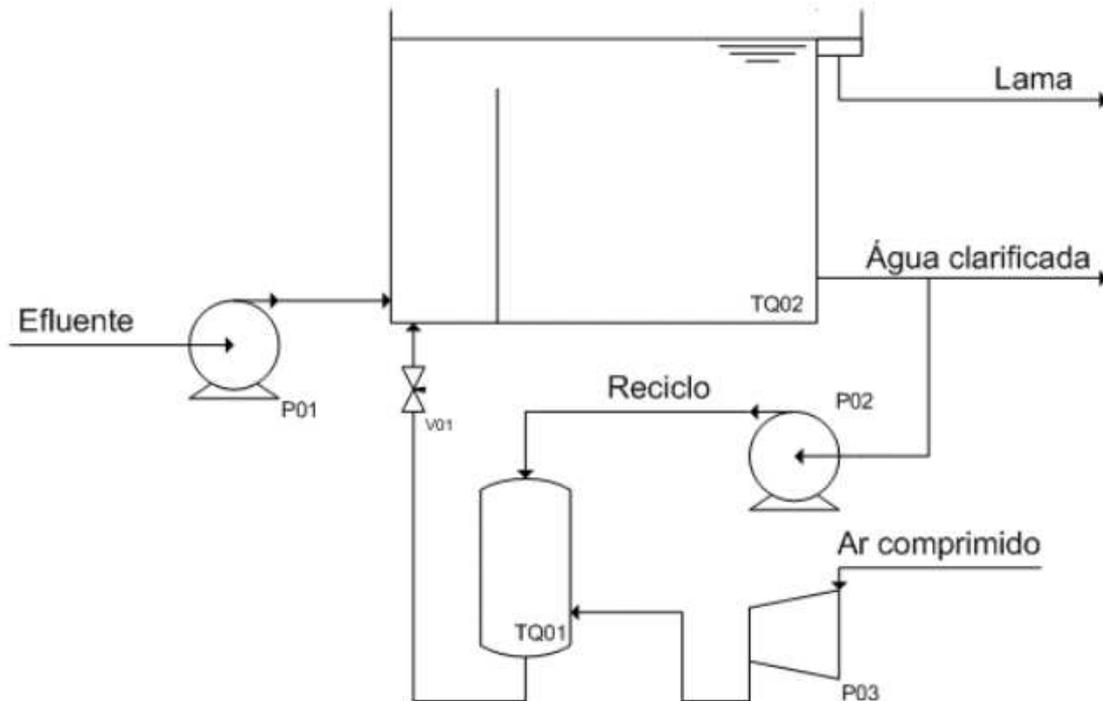
Segundo Edzwald e Haarhoff (2011), existem três formas de reduzir a pressão da água saturada para nucleação de microbolhas: flotação a vácuo, injeção direta de ar na água a ser tratada seguida por pressurização utilizando bombas ou coluna hidráulica e pressurização da água através de um vaso saturador. Na flotação a vácuo, a água a ser tratada é saturada com ar sob pressão atmosférica e, em seguida, as microbolhas são formadas pela aplicação de vácuo no tanque de flotação. Além de ter a limitação de operar em bateladas, esse tipo de formação de microbolhas também reduz a dissolução de oxigênio na água tratada, o que é uma grande limitação para sua aplicação em tratamento de água potável (EDZWALD; HAARHOFF, 2011).

Na flotação com injeção direta de ar, o ar é adicionado diretamente à água a ser tratada e, em seguida, essa mistura de fluidos é pressurizada para que o ar seja dissolvido e depois injetado na zona de contato (mais detalhes sobre as zonas do tanque de flotação serão discutidos na sessão Tanque de flotação e Vaso de Saturação). A pressurização pode se dar através do uso de bombas centrífugas ou simplesmente por grandes diferenças de altura entre o ponto de mistura de ar e água e o ponto de injeção na zona de contato. De acordo com Edzwald e Haarhoff (2011), não há nenhuma aplicação desse tipo de formação de microbolhas em processos de tratamento de água potável.

Já na flotação por ar dissolvido utilizando saturadores a água é pressurizada na presença de ar até que a mesma seja saturada e em seguida é injetada no tanque de flotação utilizando válvulas de redução de pressão, o que permite a nucleação de bolhas de 10 a 100 μm (EDZWALD; HAARHOFF, 2011). As principais etapas em uma planta desse tipo de flotação são a mistura de coagulantes e/ou floculantes com a água bruta a ser tratada, seguida pela flotação em si, que ocorre no tanque de flotação. Parte da água tratada é reciclada, pressurizada e saturada com ar em um vaso de saturação. Em seguida, a água reciclada é introduzida à água floculada através de uma válvula de injeção. Por ela, a pressão é reduzida para pressão atmosférica, o que permite a liberação de microbolhas de ar no tanque de floclação. As

microbolhas sofrem coalescência e se aderem aos flocos, formando aglomerados que sobem até a superfície do tanque formando um lodo que é removido apenas pelo fluxo natural do líquido ou por um raspador mecânico (ZABEL, 1985). Esse é o modo de operação de FAD mais utilizado em ETAs e é denominado recirculação pressurizada (FONSECA, 2017) (Figura 4.2).

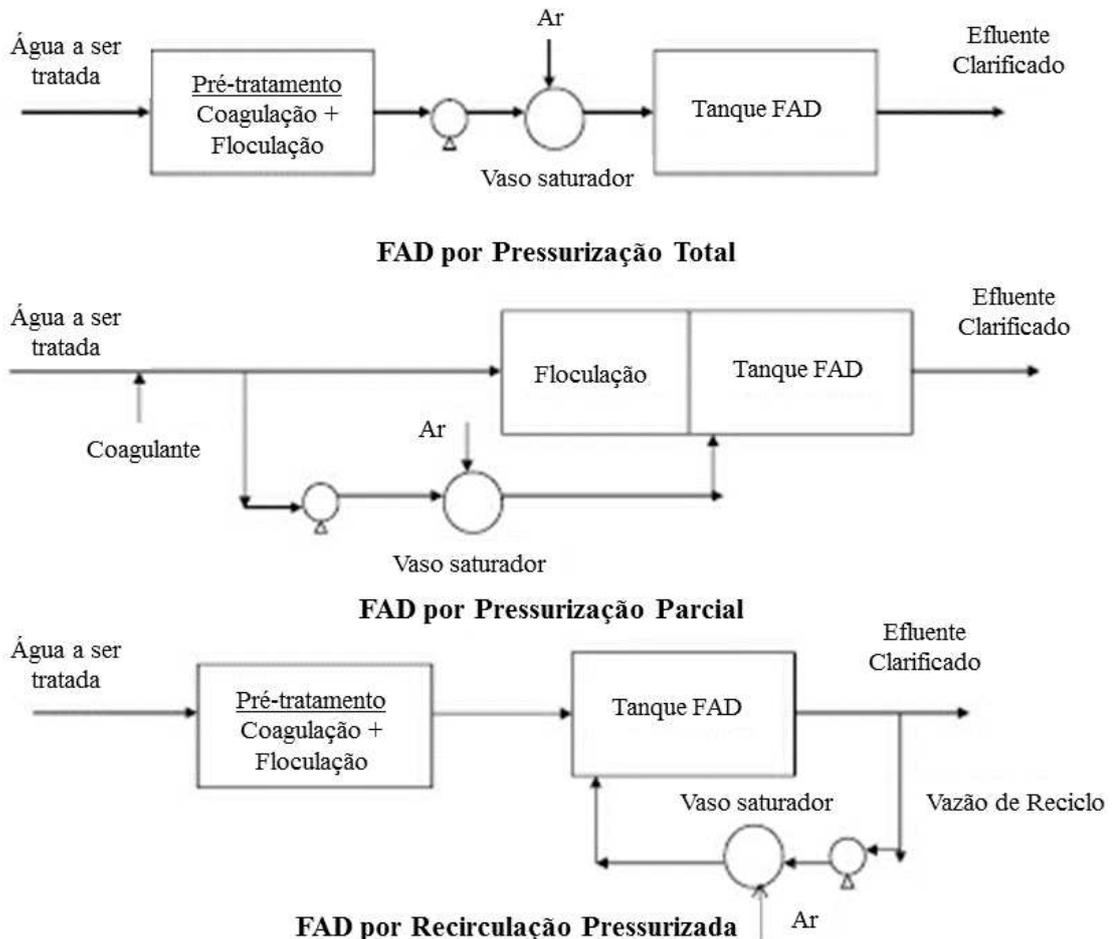
Figura 4.2. Diagrama com modo corrente em modo de recirculação pressurizada.



Fonte: Fonseca (2017).

Além da recirculação pressurizada, há dois outros modos de operação de FAD em termos do modo de alimentação do vaso saturador (Figura 4.3). Um deles é denominado pressurização total e o outro, pressurização parcial (REALI, 1991). No primeiro, toda a água a ser tratada é enviada para o vaso saturador e em seguida para o tanque flotor. Já na pressurização parcial, uma parte do efluente a ser tratado é enviado para o saturador enquanto o restante segue direto para o flotor. Em ambos os casos o uso de vasos de saturação com recheio é desaconselhável, visto que esses podem ser entupidos com sólidos suspensos. Além disso, a produção de flocos a montante do processo pela etapa de floculação também seria em vão, visto que os flocos seriam facilmente fragmentados.

Figura 4.3. Três possíveis sistemas de FAD em função do modo de alimentação do vaso saturador.



Fonte: adaptado de Edzwald e Haarhoff (2011).

A principal aplicação da FAD consiste no tratamento de água e efluentes. Dentre os vários exemplos citados por Rubio et al (2002), estão: flotação de gordura, graxas e sólidos suspensos de efluentes alimentícios e sanitários, tratamento de água potável e espessamento de lodo e tratamento de efluentes em fábricas de papel. Segundo Edzwald (2010), a flotação por ar dissolvido também pode ser utilizada em pré-tratamentos de dessalinização de água de estuários e mar.

Em projetos de estações de tratamento de água, é comum deparar-se com a dúvida na escolha entre flotação e sedimentação. Apesar de ambos serem processos de separação física, a flotação se mostra superior em vários aspectos. O primeiro deles é a superioridade na remoção de protozoários patogênicos como os cistos de *Giardia lamblia* (EDZWALD et al., 2000). Outra

vantagem da FAD em relação a sedimentação é que a primeira apresenta melhor performance em águas muito frias como as encontradas na Escandinávia, norte dos Estados Unidos e Canadá (CROSSLEY; VALADE, 2006). Além disso, outras vantagens são listadas de acordo com Zabel (1985):

- Maior flexibilidade;
- Menor tempo de partida;
- Maior facilidade em lidar com o lodo gerado;
- Os tanques construídos são rasos;
- Apresenta tamanho compacto.

Assim sendo, com os principais conceitos relacionados a FAD detalhados, é possível entrar em detalhes como o pré-tratamento que deve ser oferecido ao efluente a ser tratado e informações sobre o tanque de flotação e vaso saturador.

4.1.1.1 Pré-tratamento

Por mais eficiente que seja em relação à sedimentação, a FAD demanda um pré-tratamento seja ele coagulação ou floculação. A coagulação e floculação são pré-tratamentos que garantem a clarificação da água a ser tratada, dessa forma, são tão importantes quanto o projeto do clarificador (HAARHOFF, 2008). A coagulação ocorre antes da floculação e é um processo que permite que partículas e componentes dissolvidos precipitem e se agreguem em complexos maiores chamados de flocos. Já a floculação é a formação de agregados de flocos ainda maiores que possibilitam uma separação sólido-líquido via clarificação ou filtração ainda mais efetiva (BICKERTON, 2012). Polieletrólitos são constantemente utilizados na estabilização química e mecânica do floco, os mesmos são estruturas poliméricas e atuam na etapa de floculação.

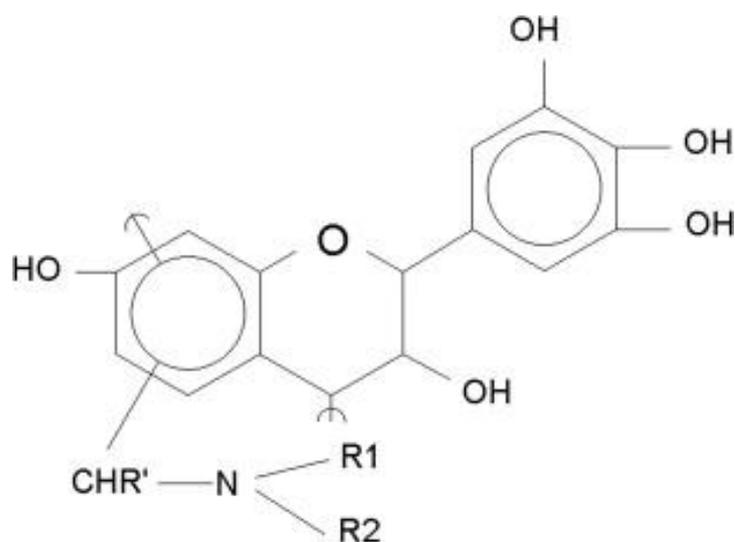
O uso da floculação não seguida por flotação é limitado, pois, dentre os vários pontos negativos, o volume de lodo formado e a quantidade de água presente no mesmo são enormes, assim como é difícil filtrar esse tipo de efluente, dado que suas partículas são extremamente finas (RUBIO et al., 2002). Em alguns casos, somente o uso da coagulação é o suficiente para proporcionar uma boa separação sólido-líquido da água a ser tratada.

Para determinar as dosagens ideais de coagulante e floculante são feitos testes de bancada do tipo *Jar test*. Esses são completamente empíricos, dependendo exclusivamente das

características iniciais da água a ser tratada. Com objetivo de medir a eficiência da remoção de partículas, a turbidez é medida tanto no início como no final de cada teste. Tal parâmetro indica uma medida indireta da quantidade de partículas sólidas em uma amostra (EDZWALD; HAARHOFF, 2011). Além da turbidez, o pH deve ser cuidadosamente controlado, visto que diferentes tipos de coagulantes e floculantes atuam de forma ótima em diferentes faixas de pH. Uma vez que as dosagens de produtos são determinadas pelo *Jar test*, é possível ampliar a escala desses valores para testes em plantas piloto ou mesmo plantas de porte real.

Entre os coagulantes mais utilizados, estão os sais de alumínio e ferro (HAMEED et al., 2016). Já entre os polieletrólitos, o uso de compostos biodegradáveis vem crescendo consideravelmente nos últimos tempos. Isso se dá pela sua não toxicidade, biodegradabilidade e pela sua abundância nos mais diversos tipos de plantas (ÖZACAR; ŞENGİL, 2003). Entre os polieletrólitos biodegradáveis amplamente utilizado em estações de tratamento de efluentes e de água em geral, encontra-se o tanino. Ele é um polímero orgânico-catiônico de baixo peso molecular conhecido comercialmente como Tanfloc[®]. Suas maiores fontes são as árvores do tipo *Acacia mearnsii de wild*, *Schinopsis balancae*, e *Castania sativa* e, por ser extraído de diferentes fontes, a determinação da sua estrutura química exata é muito complicada (HAMEED et al., 2016). Entretanto, sua provável estrutura foi apresentada por Sánchez-Martín et al. (2010) na Figura 4.4.

Figura 4.4. Provável estrutura química do Tanfloc[®].



Fonte: Sánchez-Martín et al. (2010).

Em Fonseca (2017), demonstrou-se que o uso do aluminato de sódio (NaAlO_2) como coagulante e tanino SG como biopolieletrólito no tratamento de um efluente de 40 NTU composto por água de abastecimento e terra vermelha permitiu remoções de turbidez de até

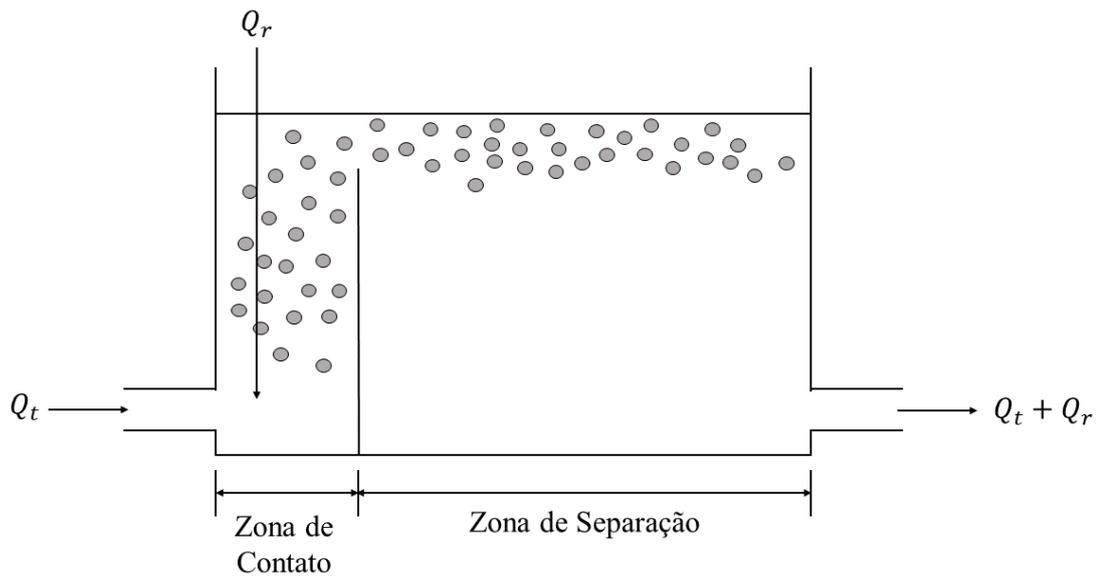
96%. Para tratar 1 L de efluente, foram utilizados 11 mL de uma solução de NaAlO_2 a 1% de concentração e 6,4 mL de uma solução de tanino SG a 5% de concentração para um pH de floculação de aproximadamente 8,1. Ainda nesse mesmo trabalho, percebeu-se que a dosagem em excesso do biopolieletrólito em relação ao aluminato de sódio gera uma perda de eficiência na remoção de turbidez. Os mesmos resultados em relação ao excesso de tanino também foram percebidos por Hameed et al. (2016).

Dessa forma, pode-se concluir que, na etapa de pré-tratamento da FAD, os valores da turbidez do efluente a ser tratado, a dosagem de coagulante e polieletrólito e o pH da floculação são parâmetros essenciais para garantir que flocos formados garantam melhores resultados para clarificação final da água.

4.1.1.2 Tanque de flotação e Vaso de Saturação

Uma vez que o efluente a ser tratado passa pelo pré-tratamento, a flotação propriamente dita pode ser realizada. Seguindo para o tanque de flotação, o efluente colide com as microbolhas oriundas do vaso saturador numa região denominada zona de contato (Figura 4.5). Nela, os flocos se chocam contra as microbolhas, formando agregados de densidade aparente menor que a da água, o que permite que os mesmos flutuem (Figura 4.1). Quando em operação, é possível perceber que a água presente na zona de contato apresenta aspecto leitoso devido ao tamanho das microbolhas (EDZWALD, 2010). Após a zona de contato, os agregados bolha-flocos seguem para a zona de separação, que consiste na parte superior do tanque de separação. Com o tempo, a camada dos agregados bolha-flocos é concentrada, formando um lodo que pode ser coletado e removido através de raspadores ou pelo próprio fluxo do efluente (EDZWALD; HAARHOFF, 2011). O efluente clarificado é retirado da parte inferior do tanque de flotação e, usualmente, segue para uma etapa de filtração para remover qualquer partícula que não tenha sido flotada.

Figura 4.5. Esquema do tanque de flotação de um sistema de FAD.



Considerando a FAD por recirculação pressurizada, parte do efluente clarificado segue para o vaso saturador onde é misturado com ar sob pressões que podem variar entre 4 e 6 bar segundo Edzwald (2010). Outro parâmetro muito importante quando se trata de recirculação pressurizada é a razão de reciclo, ou seja, a vazão de água saturada que seguirá para a zona de contato do tanque flutuador. Ainda de acordo com Edzwald (2010), os valores da razão de reciclo (R) podem variar entre 6 e 12% e são calculados segundo a Equação (1). Sendo Q_r a vazão de reciclo que sai do vaso saturador e Q_{total} a vazão total de água a ser tratada entrando no processo.

$$R = \frac{Q_r}{Q_{total}} \times 100\% \quad (1)$$

No Brasil, a legislação exige que companhias de distribuição de água monitorem a turbidez no tratamento de água potável para atingir os padrões de segurança (FONSECA et al., 2017). Dessa forma, a turbidez costuma ser um parâmetro comumente medido em estações de tratamento de água e esgoto que utilizam flotação. Para verificar a eficiência de remoção de turbidez do tratamento, ela pode ser medida tanto na entrada como na saída do processo.

Assim sendo, pode-se afirmar que os parâmetros pressão, razão de reciclo, vazão de reciclo, vazão total de entrada e turbidez de saída são essenciais para o acompanhamento e avaliação de eficiência em uma planta de flotação.

4.2 Planejamento de Experimentos

Segundo Coutinho (2007), embora os princípios básicos de funcionamento da FAD sejam simples, essa depende de um cuidadoso controle dos parâmetros de projeto, determinados em função das características do afluente a ser tratado. Logo no início do processo, os primeiros parâmetros a serem definidos são de coagulação e/ou floculação, tais como: pH, gradiente de velocidade, tempo de detenção, dosagem dos coagulantes (COUTINHO, 2007) e grau de agitação da floculação. Em seguida, é necessário definir o tempo de detenção no tanque de flotação, os tamanhos das microbolhas, a taxa de recirculação do líquido pressurizado com ar, pressão da câmara de saturação e quantidade de ar fornecida em relação à massa de sólidos em suspensão no líquido (COUTINHO, 2007).

Tendo em vista a vastidão de parâmetros a serem definidos, o uso de planejamento de experimentos para avaliação de significância de cada variável é uma boa ferramenta que auxilia no estudo de um projeto de FAD. Em Couto et al. (2014) um planejamento fatorial 2^k foi utilizado para avaliar as variáveis de processos na FAD realizada em uma coluna. Mesmo que tal flotação utilize uma coluna ao invés de um tanque, o princípio de planejamento de experimentos seria praticamente o mesmo em uma planta com um tanque de flotação. Os parâmetros estudados foram a concentração de coagulante, concentração de floculante, razão de reciclo e eficiência de separação da FAD. Para isso, as variáveis foram investigadas em dois níveis, com experimentos em triplicatas em torno de um ponto central. Na primeira série de experimentos, o coagulante e floculante foram adicionados diretamente à coluna de flotação (após a formação das microbolhas). Já na segunda, foram adicionados ao tanque saturador de ar (antes da geração de microbolhas) e se mostrou como configuração de tratamento mais efetiva.

Já em Adlan et al. (2011) a metodologia de superfície de resposta (MSR) em um planejamento composto central foi utilizada para otimizar uma unidade de coagulação e FAD combinadas em uma única célula de escala de bancada. A influência de cinco fatores de entrada (pressão de saturação, vazão de entrada, dosagem de coagulante - FeCl_3 , pH e tempo de injeção de microbolhas) foram modeladas e otimizadas para maximizar a remoção de quatro índices de saída (turbidez, demanda química de oxigênio – DQO, cor e nitrogênio amoniacal – $\text{NH}_3\text{-N}$). O efluente utilizado foi um lixiviado proveniente de um aterro sanitário da Malásia. As condições ótimas encontradas foram: 599,22 mg/L de FeCl_3 , pH 4,76, 600 kPa de pressão de saturação, 6 L/min de vazão de entrada e 101 s de tempo de injeção. Com essas condições, os resultados de remoção de turbidez, DQO, cor e $\text{NH}_3\text{-N}$ foram de 53%, 72%, 94% e 43%

respectivamente. Percebe-se que o pior resultado foi o para o modelo da turbidez. Além disso, os fatores de entrada pressão e vazão mostraram-se os menos significantes para remoção de poluentes, entretanto, concluiu-se que ambos são fundamentais para maximizar a performance de um sistema de FAD, visto que são importantes para uma saturação eficiente, maior concentração de bolhas e menor tamanho de bolhas. Os fatores pH e vazão de coagulante se mostraram extremamente significantes para remoção de turbidez, DQO e cor. Além da MSR, foram utilizadas análises de variância para avaliar a qualidade dos modelos gerados e gráficos de perturbação para identificação dos fatores mais significativos para o tratamento do lixiviado.

No caso da flotação por ar dissolvido empregado na planta piloto analisada neste trabalho, o uso de um planejamento de experimentos inspirado no utilizado por Couto et al (2014) e Adlan et al. (2011) permitiu a determinação das condições de processo que viabilizam a melhor qualidade de água tratada possível.

4.3 Inteligência Artificial: o uso de Redes Neurais Artificiais

A existência de tantos parâmetros a serem monitorados, sugere o uso de malhas de controle com o objetivo de padronizar a qualidade da água tratada, reduzir custos operacionais e promover a economia de energia consumida, principalmente, pelo vaso saturador. Usualmente, as plantas em operação utilizam simples controles ON-OFF, sem relacionar as variáveis do processo através de uma lógica de controle. De acordo com Shean e Cilliers (2011), a transferência de tecnologias de controle e automação em colunas de flotação para aplicações industriais tem sido um fracasso. Um dos principais motivos para isso acontecer é a não linearidade e complexidade do comportamento geral de um sistema de flotação, fazendo com que o projeto de sistemas de controle seja difícil. Tendo em vista essa complexidade para geração de modelos, o uso de inteligência artificial através da lógica *Fuzzy* se torna uma boa alternativa para solução do problema. Carvalho e Durão (2002) utilizaram a lógica *Fuzzy* para controle de uma coluna de flotação. O conhecimento do controlador foi adquirido heurísticamente e o mesmo apresenta uma estrutura do tipo *Mamdani*, com regras linguísticas que possibilitam ações específicas a partir das relações entre variáveis de entrada e saída.

Um dos primeiros trabalhos onde foram desenvolvidos sistemas de controle e automação para FAD foi realizado por Fonseca (2017). Um protótipo totalmente automatizado foi construído e malhas de controle utilizando recursos de inteligência artificial foram implementadas para manipular as condições de operação do sistema de flotação com o objetivo

de regular a turbidez da água clarificada na saída do flotador. Além de padronizar resultados, esse trabalho buscou minimizar o consumo de energia nos equipamentos e o esforço de controle nos atuadores. Seus resultados mostraram que a estratégia *Fuzzy* atuando na fração de reciclo para regular a turbidez de saída da água tratada permitiu uma melhoria de 70,6% no critério IAE em relação à estratégia com um controlador PI atuando na pressão do vaso saturador para corrigir a turbidez de saída. O consumo de energia não foi reduzido na planta automatizada em comparação à sua operação em malha aberta, contudo, a padronização dos resultados assim como a menor saturação do filtro de areia com flocos que decantaram configuraram resultados positivos para um primeiro trabalho envolvendo controle e automação em FAD. Os resultados positivos envolvendo controladores *Fuzzy* ressaltam o potencial do uso de tal ferramenta de controle turbidez em sistemas de flotação por ar dissolvido em escala industrial e abrem uma vasta gama de opções para futuros trabalhos na área.

Outra maneira de determinar as melhores condições de operação de um processo e, conseqüentemente, controlá-lo com maior eficiência, sem conhecer todos os fenômenos que ocorrem nele é utilizando Redes Neurais Artificiais (RNA). Inspiradas no sistema nervoso de seres vivos, as RNA são modelos computacionais com alta capacidade de aquisição e manutenção de conhecimento (SILVA et al., 2010). Dentre suas vastas qualidades, as redes neurais se destacam por serem eficientes na extração do relacionamento existente entre as variáveis que constituem a aplicação, apresentando grandes habilidades em mapear sistemas não-lineares (SILVA et al., 2010).

Ainda segundo Silva et al. (2010), dentre as potenciais áreas de aplicação das RNA estão:

- Na aproximação universal de funções;
- No controle de processos;
- No reconhecimento e classificação de padrões;
- No agrupamento de dados (clusterização);
- Em sistemas de previsão;
- Na otimização de sistemas;
- Em projetos que utilizam memórias associativas.

Em Zhang, Stanley (1999) um sistema de controle utilizando redes neurais foi proposto para um processo de tratamento de água composto de etapas de coagulação, floculação e sedimentação. Como tal processo envolve fenômenos químicos e físicos de alta complexidade,

desenvolver estratégias de controle tradicionais é um grande desafio. Dessa forma, com aproximadamente 2000 dados de processo, uma RNA foi construída para predição da dosagem ótima de alume e carvão ativado em pó de acordo com as características da água a ser tratada. Devido o sucesso do projeto, com algumas modificações esse exemplo também pode ser usado para construção de outras estratégias de controle em diferentes tipos de tratamento de água.

Segundo Labidi et al. (2007), é possível obter um modelo que determine a condição ótima de operação em uma célula de flotação no processo de reciclagem de papel e, também, simular a sua operação utilizando RNA. A remoção de tinta do papel faz parte do seu processo de reciclagem e apresenta a flotação como uma de suas etapas. Além da difícil determinação dos agentes poluentes presentes no papel, a dificuldade em expressar o processo de flotação em termos fenomenológicos contribui para a alta complexidade do processo de remoção de tinta do papel. Dessa forma, a construção de RNA surge como uma alternativa para solucionar esse problema.

A determinação das condições de processo que viabilizem a melhor qualidade de água clarificada possível apresenta-se cada vez mais necessária, tendo em vista o aumento da escassez de água potável no mundo inteiro. Após uma profunda busca na literatura, não foi possível encontrar trabalhos que determinem quais são as melhores condições de operação num processo de FAD completamente instrumentado e automatizado utilizando ferramentas como planejamento de experimentos ou redes neurais. Dessa forma, o trabalho se mostra atual e indispensável para o avanço dos conhecimentos na flotação por ar dissolvido.

5 Materiais e Métodos

Neste projeto, um protótipo de flotação por ar dissolvido completamente automatizado e monitorado via SCADA (Sistema Supervisório) foi utilizado para o ajuste das condições de processo com objetivo de obter a melhor qualidade de água possível. Inicialmente, o aparato experimental e os seus procedimentos de operação serão descritos com detalhes e em seguida, a metodologia de planejamento experimental utilizada para definir os ensaios que foram realizados será explicada detalhadamente, assim como os métodos para criação de redes neurais artificiais e regressão logística para prever as variáveis de saída desejadas.

5.1 Descrição da planta piloto e procedimentos de operação

A planta piloto utilizada neste projeto está montada no Laboratório de Controle e Automação de Processos (LCAP) da faculdade de Engenharia Química da Unicamp. Para armazenar a água a ser flotada é utilizado um reservatório (IBC) com capacidade de 1000 L. A água a ser tratada é enviada para o floculador e, em seguida, para o flotador. Um vaso de saturação capaz de suportar até 7,4 bar de pressão está posicionado entre as etapas de floculação e flotação e promove a pressurização da água. As microbolhas são geradas através de uma válvula agulha que promove uma queda de pressão após o efluente passar pelo vaso saturador. Posteriormente à flotação, a água passa por um filtro de areia cilíndrico, que promove um tratamento mais refinado e permite que parte seja descartada e outra parte seja reciclada para o vaso saturador. Para automatizar o processo, o protótipo conta com instrumentos medidores de pH, vazão, temperatura, pressão e turbidez, assim como um Controlador Lógico Programável (CLP), inversores de frequência e válvulas de controle. Bombas magnéticas e de engrenagem garantem a circulação de água pela planta e conexões de engate rápido e tubulação em poliuretano de 12 mm de diâmetro configuram os fluxos das correntes de processo. Para melhor compreensão das etapas do processo de flotação por ar dissolvido presentes nessa planta, um diagrama de blocos (BFD) e um diagrama de instrumentação (P&ID) se fazem presentes nas Figura A. 1 e Figura A. 2 do Apêndice A – Detalhes da Planta de FAD, respectivamente. Além disso, a Tabela 5.1 apresenta os detalhes dos atuadores, equipamentos e instrumentos da planta de FAD.

Existem três principais formas de operação do sistema de flotação em questão. A primeira delas é aquela em que parte da água clarificada que sai do flotador é reciclada para saturação com ar comprimido e, em seguida, misturada com a água a ser tratada na entrada do

flotador (recirculação pressurizada). A segunda forma de operação utiliza parte da água a ser tratada proveniente do tanque de floculação para abastecer o vaso saturador, enquanto a outra parte segue para o tanque flotador (pressurização parcial). Por último, na terceira configuração de operação, toda a vazão de água a ser tratada proveniente do tanque floculador abastece o vaso saturador (pressurização total). Neste projeto, a primeira configuração, isto é, com reciclo de água clarificada e mistura com água a ser tratada na entrada do flotador, foi escolhida na realização dos ensaios. A razão de reciclo consiste na divisão da vazão de água saturada que entra no flotador pela vazão de água a ser tratada na entrada do processo.

Tabela 5.1. Lista de atuadores, equipamentos e instrumentos da planta de FAD.

Equipamentos			
Equipamento	Modelo	Marca	Características
Floculador (TQ01)	-	-	Volume de 30 L
Flotador (TQ02)	-	-	Volume de 67,2 L
Filtro de areia (TQ03)	-	-	Volume de 5,65 L
Tanque Água Filtrada (TQ04)	-	-	Volume de 25 L
Vaso saturador (TQ05)	-	-	Volume de 4,4 L
Tanque de Efluente (TQ06)	-	-	Volume de 1 m ³
Tanque de NaAlO ₂ (TQ07)	-	-	Volume de 0,5 L
Tanque de Tanino (TQ08)	-	-	Volume de 0,5 L
Válv. agulha (V01a)	SS-4MG2	Swagelok [®]	Cv = 0,03
Válv. agulha (V01b)	SS-ORM2	Swagelok [®]	Cv = 0,09
Válv. solenoide (V04)	20BF073TF	Parker [®]	0 a 4,8 L/min
Motos de passo (MP)	DMX-K-DRV-23	Arcus [®]	32000 passos
Agitador pá tipo hélice (M01)	712	Fisatom [®]	0 a 2000 rpm
Agitador pá tipo hélice (M02)	RZR2051	Heidolph [®]	0 a 1000 rpm
Motor de 24 Vcc (M03)	-	-	0 a 300 rpm
Bomba de engrenagem (P01)	GC-M23-JVS-6	Micropump [®]	3 L/min
Bomba centrífuga (P02)	Hydrobloc P500T	KSB [®]	3600 L/h
Bomba diafragma (P03)	PD64	Sodi Scientifica [®]	60 L/h
Bomba dosadora (P04)	Pump controller 7014-52	Masterflex [®]	130 mL/min

Continuação

Equipamento	Modelo	Marca	Características
Bomba dosadora (P05)	Pump controller 7016-52	Masterflex®	120 mL/min
CLP (YC103)	X20 CP1585	B&R®	-
Atuadores			
Inversor de frequência (SY104)	VLT Micro Drive	Danfoss®	0 - 60 Hz
Inversor de frequência (SY102)	VLT 2800	Danfoss®	0 - 60 Hz
Inversor de frequência (SY107)	CFW 10 Easydrive	WEG®	0 - 60 Hz
Mod. Largura de pulso (SY106)	-	-	0 - 100 %
Mod. Largura de pulso	-	D.A.L.®	0 - 100 %
Válvula reguladora de pressão (V02)	P3HPA12AD2VD1 A	Parker®	0 - 10 bar
Controlador do driver (ZY103)	ACE-SXC 485	Arcus®	-
Sensores			
pHmetro online (AIT103b)	HI 8614L	Hanna®	0 - 14
Turbidímetro online (AIT103a)	Microtol 4	HF Scientific®	0 - 1000 NTU
pHmetro off-line	HI96107	Hanna®	0 - 14
Turbidímetro off-line	AP2000	Policontrol®	0 - 1000 NTU
Med. Vaz. Eletromag. (FIT104)	VMS Pro 1000	Incontrol®	0 - 10 m/s
Med. Vaz. Turbina (FIT 103a)	FLR1009ST-I	Omega®	0,05 - 0,5 L/min
Med. Va. Turbina (FIT 103b)	VTP-L110	Incontrol®	0,4 - 13 L/min
Transm. Pressão abs. (PT100)	NP430D	Novus®	0 - 20 bar
Transm. Pressão dif. (LT102)	692900007141	Huba control®	0 - 100 mbar
Pt-100 com Tx-Block (TT103)	TxMiniBlock	Novus®	-200 - 650 _C
Transd. De potência ativa	3000W420A24VDC	Secon®	0 - 3 kW

Fonte: adaptado de Fonseca (2017).

5.1.1 Armazenamento de água bruta (sistema simulado)

A principal aplicação visada para esse protótipo construído é a clarificação de água de abastecimento que é oriunda, principalmente, de rios. Dessa forma, a água a ser tratada utilizada

nos experimentos foi preparada a partir de água fornecida pela empresa distribuidora da cidade de Campinas e terra proveniente do solo característico da região.

Em um recipiente de 10 L foi dissolvida terra vermelha previamente peneirada. O sobrenadante dessa solução constitui em um líquido com alto teor de sólidos suspensos e, conseqüentemente, alta turbidez. Essa solução concentrada era adicionada ao IBC com capacidade de 1000 L (TQ06) já cheio de água limpa até que a água a ser tratada atingisse a turbidez desejada para cada ensaio (mais detalhes serão discutidos no tópico Planejamento de Experimentos). Para garantir que a água a ser tratada tivesse uma turbidez constante ao longo do ensaio, um agitador foi construído e utilizado em todos os experimentos (M03). Quando a planta estava em funcionamento, a água a ser tratada era enviada para o floculador através de uma bomba centrífuga (P02).

5.1.2 *Jar tests*

Os ensaios de *Jar test* foram realizados para determinação das dosagens específicas de agente coagulante aluminato de sódio ($NaAlO_2$) e o biopolieletrólito floculante tanino SG para a etapa de floculação. Para isso, inicialmente as soluções de aluminato de sódio e tanino SG eram preparadas, assim como as amostras de água a ser tratada com índices de turbidez determinado. Depois, o mesmo volume de efluente era adicionado em diferentes recipientes, seguido da adição em diferentes quantidades de agente coagulante em cada um desses recipientes. Essa mistura era homogeneizada sob rotação de hastes do tipo pás a 150 rpm por 2 minutos. Em seguida, o pH de cada amostra era registrado. Posteriormente, a mesma quantidade de floculante foi adicionada em cada recipiente e a mistura submetida a rotação a 50 rpm durante 5 minutos. O pH da floculação também foi registrado. Por fim, as soluções testes passaram 5 minutos em repouso para sedimentação dos flocos formados, em seguida, uma alíquota do sobrenadante de cada recipiente foi retirada e teve sua turbidez medida. A dosagem de aluminato de sódio e tanino SG escolhida foi a que proporcionou sobrenadante com menor turbidez. No segundo teste, os volumes de coagulante adicionados foram fixados para o valor escolhido como melhor no teste anterior, enquanto as quantidades de floculante adicionadas foram alteradas. O resultado final de dosagem de coagulante também foi escolhido pelo teste que proporcionasse menor turbidez possível na alíquota sobrenadante.

5.1.3 Floculador

O tanque floculador (TQ01) foi projetado em três seções com o objetivo de promover uma mistura homogênea entre o coagulante e a água a ser tratada. O mesmo apresenta dimensões de 50×30×20 cm (comprimento × altura × profundidade). No protótipo, foram instalados dois agitadores mecânicos, um na primeira seção do floculador (M01) e o outro na terceira seção (M02). Na primeira etapa do floculador o efluente é misturado com o aluminato de sódio ($NaAlO_2$) e tanino SG que são bombeados por meio das bombas peristálticas P04 e P05. Essa agitação precisa ser mais vigorosa que a da terceira seção do floculador, visto que nessa última, os flocos gerados podem ser quebrados ao se chocar com as pás do agitador, quando o objetivo principal do segundo agitador é somente evitar que os flocos decantem. As hastes utilizadas em ambos agitadores são do tipo de pás hélices, para evitar a quebra dos flocos.

O valor de pH ideal para a floculação utilizando-se o tanino SG varia de 8,0 a 8,5. Como será mostrado nos Resultados e Discussão, apenas a dosagem de aluminato de sódio e tanino foram capazes de garantir tal condição de pH e permitir a flotação do material particulado. O pH foi medido ao longo dos ensaios através de um pHmetro online (AIT103b) e um off-line, de bancada.

Figura 5.1. Tanque floculador com agitadores mecânicos acoplados.

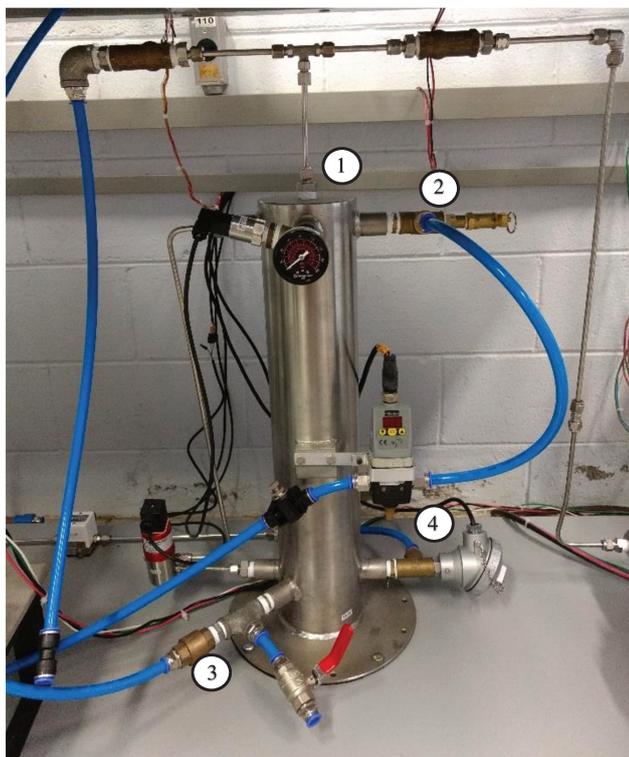


5.1.4 Vaso saturador

O vaso saturador (TQ05) tem a função de misturar a água clarificada e ar, além de submeter tal mistura a elevadas pressões (Figura 5.2). Dessa forma, o vaso construído nesse piloto suporta até 10 bar de pressão, contudo ele foi submetido a pressões de pico de, no máximo, 8 bar e operado continuamente em, no máximo, 7,4 bar para evitar desgaste dos equipamentos. Em casos de pressões superiores a 7,5 bar, uma válvula de segurança se abre para alívio (V03). O equipamento é feito em aço inox com dimensões de 10,6×50 cm (diâmetro × altura), resultando em um volume útil de 4,4 L (THOMPSON JR., 2013). Para solubilizar o ar comprimido na água clarificada, uma válvula reguladora de pressão (V02) foi utilizada. O vaso apresenta pontos de admissão de água clarificada, água a ser tratada, ar comprimido e um ponto de retirada da água saturada. Os pontos de admissão de água clarificada e ar ficam no topo (pontos 1 e 2, respectivamente, na Figura 5.2), enquanto os de admissão de água a ser tratada e retirada de água saturada ficam na parte inferior do vaso (pontos 3 e 4, respectivamente, na Figura 5.2). No caso do modo de operação de Recirculação Pressurizada, apenas os pontos 1, 2 e 4 são utilizados.

Para evitar que a água de alimentação do vaso saturador volte para a bomba de engrenagem (P01) que o abastece, há uma válvula de retenção (V05). Além disso, o vaso saturador possui um transmissor de temperatura (TT103), um manômetro indicador de pressão e um transmissor de nível por pressão diferencial (LT102). O efluente do vaso saturador sai pela sua parte inferior e passa por um medidor de vazão (FIT103a). Em seguida, esse efluente segue para o flutador, que será descrito no próximo item.

Figura 5.2. Vaso saturador instrumentado.



5.1.5 Flotador

O flotador (TQ02) é um tanque onde ocorre a separação dos sólidos suspensos da água pela ação de microbolhas. Este foi construído em acrílico transparente, o que proporciona melhor visualização da separação (Figura 5.3). O tanque consta de três principais zonas: zona de contato, zona de separação e calha coletora do sólido flotado. Além disso, há um raspador acoplado no topo do flotador que tem o objetivo de acelerar a remoção do material flotado levando-o para a calha coletora. O flotador apresenta dimensões 56×30×40 cm (comprimento × altura × profundidade).

O efluente vindo do vaso saturador é admitido na parte inferior da zona de contato através de cinco orifícios com engate rápido. Para geração das microbolhas, uma válvula agulha (V01) foi instalada na tubulação próxima ao flotador, proporcionando queda de pressão e evitando a coalescência dessas microbolhas. Parte da água tratada que sai do tanque de flotação é enviada para um filtro de areia cilíndrico (TQ03) e parte para um turbidímetro (AIT103a). O turbidímetro online foi instalado com objetivo de medir o efeito da presença de sólidos em suspensão para que, em seguida, seja avaliada a eficiência da mesma (Figura 5.4). A água tratada que sai do turbidímetro é descartada. Já o filtro de areia, serve para reter qualquer partícula sólida que, por ventura, não tenha sido retirada na flotação, permitindo que a água de reciclo seja de melhor qualidade possível (Figura 5.5).

Após passar pelo filtro de areia, a água tratada é armazenada em um tanque. Dentro desse tanque há uma chave de nível intertravada com uma válvula solenoide (V04). Caso o nível ultrapasse o limite do tanque, ela abre e libera a água em excesso para descarte. Além da válvula, o tanque também está ligado a uma bomba de engrenagem que envia a água tratada para o vaso saturador (P01).

Figura 5.3. Tanque flutuador com raspador e calha coletora de material flotado.

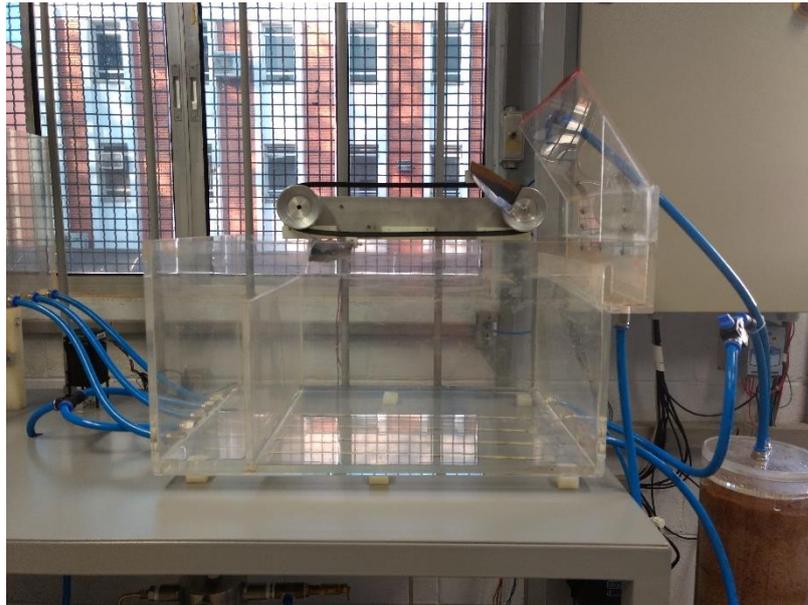


Figura 5.4. Turbidímetro online modelo MicroTOL4 Turbidimeter 200064.



Figura 5.5. Filtro de cilíndrico de areia.



5.1.6 Limpeza do filtro

A medida que ensaios eram realizados, o filtro de areia ficava saturado com material retido. Assim, aproximadamente, a cada 3 ensaios o mesmo era limpo. Apesar de em uma estação de tratamento comum esse tipo de filtro ser lavado por retro-lavagem, devido as suas características construtivas nesse protótipo, sua limpeza foi realizada com a retirada do meio filtrante e seu enxague com água. Durante o período de realização dos ensaios, o filtro foi lavado duas vezes com uma solução de hipoclorito de sódio para uma possível oxidação de algas formadas.

5.1.7 Controlador Lógico Programável e Sistema Supervisório

O protótipo é completamente instrumentado com sensores e atuadores e automatizado com CLP (YC103) e sistema supervisório SCADA utilizando o *software* Simulink[®]. Os sensores de pH, pressão, temperatura, turbidez e vazão apresentam comunicação 4-20 mA e comunicam-se através de placas de I/O com o CLP. Este se comunica via Ethernet com um microcomputador com o sistema SCADA e *software* MatLab[®] devidamente instalados e com lógicas de controle definidas. As variáveis de processo são armazenadas em tempo real em uma planilha de dados vinculada ao SCADA. O trabalho do Fonseca (2017) apresenta detalhes das estratégias de controle aplicadas a FAD

5.1.8 Start-up da planta

Antes de iniciar a operação do protótipo, a água a ser tratada foi preparada com a turbidez desejada para cada ensaio, assim como as soluções de aluminato de sódio e tanino SG. As bombas dosadoras de coagulante P05 e floculante P04 foram ajustadas para as vazões específicas de cada ensaio. Além disso, o tanque pulmão TQ04 e o flotador TQ02 foram preenchidos com água limpa. No caso do TQ04 para abastecer o vaso saturador e no TQ02 para minimizar o tempo até o regime permanente.

Com todas as etapas de pré-operação realizadas, procedeu-se comunicação entre o CLP do protótipo e o SCADA. Os primeiros equipamentos automaticamente ligados foram a bomba P01 para alimentar o vaso saturador e a P02 para regular a vazão de água a ser tratada. Manualmente, as bombas P04 e P05 foram ligadas, para iniciar a floculação do efluente.

Como o objetivo desse trabalho foi avaliar as condições de operação da planta da FAD, os ensaios foram realizados sempre em malha aberta, sem considerar as lógicas de controle previamente criadas por Fonseca (2017). Dessa forma, os parâmetros escolhidos para serem avaliados (pressão do vaso saturador, vazão de tanino, razão de reciclo, vazão total e turbidez de entrada) foram fixados e o comportamento do protótipo foi avaliado por 2 horas de ensaio.

5.2 Planejamento de Experimentos

Considerando-se que o protótipo de FAD montado e instrumentado apresenta diferentes perturbações e diversas variáveis manipuladas, uma maneira de se verificar as variáveis mais significativas e quais as condições de operação geram a melhor água clarificada foi utilizando planejamento de experimentos.

A variável resposta analisada foi a turbidez removida (TR) da água tratada, indicando a qualidade da flotação. Apesar da variável medida diretamente na planta de FAD ser a turbidez de saída, utilizar tal parâmetro como resposta induziu a erros de interpretação pois, por exemplo, em algumas situações, percebeu-se uma baixa turbidez de resposta decorrente da baixa turbidez de entrada, e não da efetividade do tratamento em si. Por outro lado, em outros ensaios houve altos índices de turbidez de resposta, contudo, ao comparar-se com a turbidez de entrada, o processo teve se mostrado relativamente eficiente. Dessa forma, para avaliar a eficiência do processo, foi escolhido trabalhar-se com a turbidez removida no processo (Equação (2)).

$$TR = \frac{NTU_e - NTU_s}{NTU_e} \times 100\% \quad (2)$$

Já as variáveis de entrada foram a pressão no vaso saturador (P), a vazão de floculante na entrada do tanque floclador (Q_{tanino}), a razão de reciclo do efluente clarificado (R), a vazão total de água a ser tratada (Q_{total}) e a turbidez de entrada do efluente a ser tratado (NTU_e) (Figura 5.6). O objetivo foi criar um modelo que descrevesse a turbidez removida em função das variáveis de entrada.

Figura 5.6. Esquema do planejamento de experimentos do protótipo de flotação por ar dissolvido.



Os níveis das variáveis de entrada são apresentados na Tabela 5.2 e a matriz planejamento na Tabela 5.3. Os níveis das variáveis de entrada foram em parte definidos pelos limites de operação do protótipo e parte pela experiência já adquirida à medida que a planta foi construída e utilizada em experimentos prévios.

Tabela 5.2. Níveis do planejamento experimental composto central das variáveis de processo estudadas.

Níveis	P (bar)	Q_{tanino} (mL/min)	R (%)	Q_{total} (L/min)	NTU_e (NTU)
$-\sqrt[4]{2^5}$	3,6	0,8	9,6	0,42	4,9
-1	4,7	10,8	11,3	1,45	32,5
0	5,5	18	12,5	2,2	52,5
1	6,3	25,2	13,7	2,95	72,5
$+\sqrt[4]{2^5}$	7,4	35,2	15,4	3,98	100,1

Apesar do limite superior pressão de operação do vaso ser 8 bar, a pressão de 7,4 bar garante que os equipamentos não sofram desgastes excessivos. O limite inferior de P foi escolhido tendo em vista o conhecimento prévio da impossibilidade de geração de microbolhas para pressões inferiores a 3,5 bar. A vazão de coagulante foi aproximada a partir dos *Jar tests* realizados assim como respeitando os limites de operação das bombas dosadoras P04 e P05. Apesar de neste planejamento só estar explícita a vazão de tanino, por essa ter sido escolhida

como variável para o planejamento, cada vazão de tanino apresenta uma vazão de aluminato de sódio correspondente também definida pelo *Jar test*.

A razão de reciclo, por sua vez, foi aproximada para os valores médios previamente utilizados nos primeiros testes com a planta. Já, a vazão de água a ser tratada, teve seus limites escolhidos a partir dos limites de operação do medidor de vazão de reciclo (FIT103a), que são de 50 a 500 mL/min e da razão de reciclo. Dessa forma, os limites de Q_{total} foram definidos considerando os possíveis valores de R e $Q_{reciclo}$ na Equação (1), para se ter certeza que nenhum limite de operação dos equipamentos seria ultrapassado.

Finalmente, os valores de turbidez de entrada foram escolhidos com objetivo de seguir os padrões impostos pela CONAMA nº 357, que determina que a água doce pode ter até 100 NTU para ser passível de tratamento e tornar-se água de abastecimento. Assim, tendo em vista que a qualidade da água de abastecimento varia de acordo com o período de chuvas, o uso de diferentes índices de turbidez permitiu que as águas barrentas de rios de abastecimento fossem simuladas desde as melhores condições (4,9 NTU) até às mais turvas (100,1 NTU).

Como um planejamento composto central (ou estrela) é o que requer menos ensaios para se propor um modelo quadrático confiável, este foi escolhido para o projeto. Ele foi utilizado com três repetições no ponto central para evitar a realização de repetições em todos os ensaios e mesmo assim garantir o cálculo do erro puro. Além disso, com auxílio do *software* Statistica®, as variáveis significativas foram determinadas com 95% de confiança. Por fim, para avaliar a significância estatística do modelo, isto é, se ele descreve bem os dados experimentais, foi feita uma análise de variância ANOVA, assim como análises de significância das variáveis pelo p-value, t-value e determinação das superfícies de resposta.

Tabela 5.3. Matriz do planejamento composto central dos ensaios realizados.

Ensaio	P (bar)	Q_{tanino} (mL/min)	R (%)	Q_{total} (L/min)	NTU_e (NTU)
1	-1	-1	-1	-1	-1
2	-1	-1	-1	-1	1
3	-1	-1	-1	1	-1
4	-1	-1	-1	1	1
5	-1	-1	1	-1	-1
6	-1	-1	1	-1	1
7	-1	-1	1	1	-1
8	-1	-1	1	1	1
9	-1	1	-1	-1	-1
10	-1	1	-1	-1	1

Continuação

Ensaio	P (bar)	Q_{tanino} (mL/min)	R (%)	Q_{total} (L/min)	NTU_e (NTU)
11	-1	1	-1	1	-1
12	-1	1	-1	1	1
13	-1	1	1	-1	-1
14	-1	1	1	-1	1
15	-1	1	1	1	-1
16	-1	1	1	1	1
17	1	-1	-1	-1	-1
18	1	-1	-1	-1	1
19	1	-1	-1	1	-1
20	1	-1	-1	1	1
21	1	-1	1	-1	-1
22	1	-1	1	-1	1
23	1	-1	1	1	-1
24	1	-1	1	1	1
25	1	1	-1	-1	-1
26	1	1	-1	-1	1
27	1	1	-1	1	-1
28	1	1	-1	1	1
29	1	1	1	-1	-1
30	1	1	1	-1	1
31	1	1	1	1	-1
32	1	1	1	1	1
33	-2,37841	0	0	0	0
34	2,37841	0	0	0	0
35	0	-2,37841	0	0	0
36	0	2,37841	0	0	0
37	0	0	-2,37841	0	0
38	0	0	2,37841	0	0
39	0	0	0	-2,37841	0
40	0	0	0	2,37841	0
41	0	0	0	0	-2,37841
42	0	0	0	0	2,37841
43 ©	0	0	0	0	0
44 ©	0	0	0	0	0
45 ©	0	0	0	0	0

5.3 Modelos de predição por Redes Neurais Artificiais e regressão logística

Uma vez que os ensaios foram realizados e um banco de dados foi obtido, também foi possível realizar estudos utilizando redes neurais e regressão logística. Primeiramente, uma rede para prever a turbidez removida a partir das variáveis de entrada (as mesmas utilizadas no Planejamento de Experimentos). Em seguida, um modelo de regressão logística foi construído para prever se o processo de flotação seria efetivo ou não (isto é, uma resposta qualitativa do

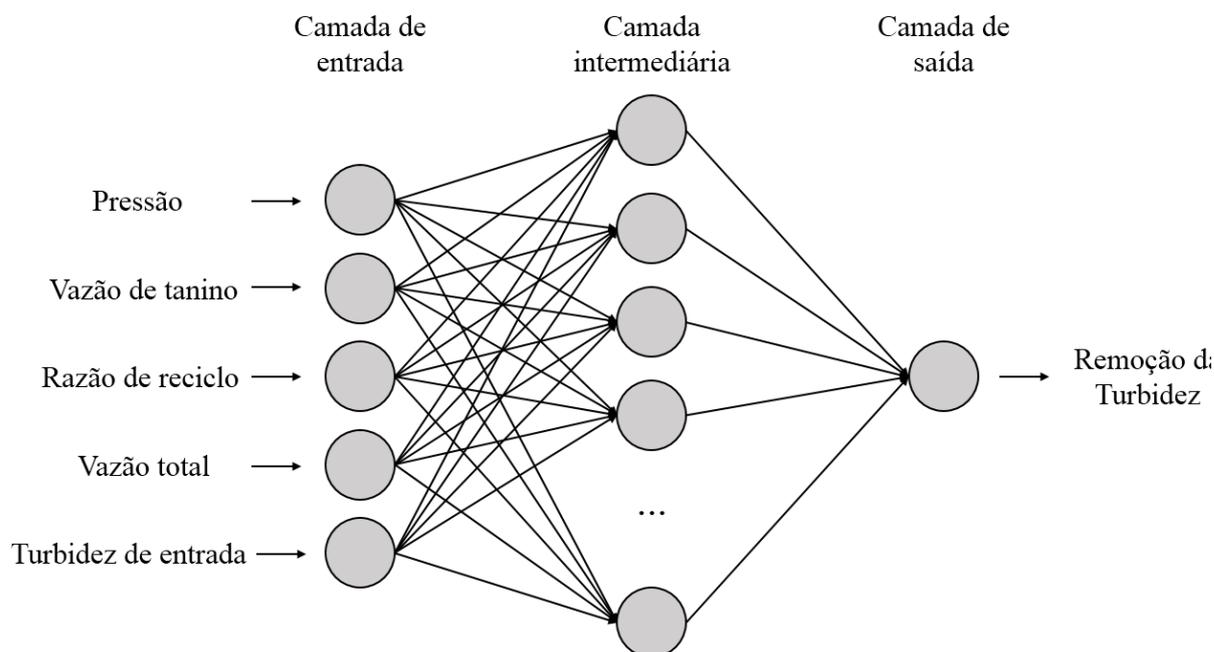
tipo “não flutuou”, correspondendo a 0 e “flutuou”, a 1) também a partir das variáveis de entrada. Por fim, uma RNA classificatória foi feita também para prever a efetividade da flotação.

5.3.1 RNA para predição da turbidez removida

No caso da RNA para predição da remoção da turbidez, uma rede neural com arquitetura *feedforward* de duas camadas foi utilizada. Assim, os neurônios de entrada foram as variáveis de entrada P , Q_{tanino} , R , Q_{total} e NTU_e nas faixas estudadas, enquanto o neurônio de saída foi a remoção da turbidez, como esquematizado na Figura 5.7. Para construir as redes neurais que foram testadas a *toolbox Neural Network Fitting* do *software* Matlab® foi utilizada. Os neurônios da camada intermediária apresentaram função de ativação sigmoidal enquanto os de saída, linear. O método de treinamento utilizado foi o *Levenberg-Marquardt* (*trainlm*).

Inicialmente, o banco de dados foi aleatorizado e separado em um conjunto para treinamento e testes preliminares e em outro conjunto para testes complementares independentes. Certificou-se que os dados usados no teste a parte estavam dentro do limites máximos e mínimos dos dados usados para treinar a rede, para não haver o risco de extrapolação ao usar a RNA criada para prever os resultados do teste independente.

Figura 5.7. Topologia da rede neural artificial para o sistema de FAD em estudo.



Na criação das redes, 70% dos dados foram utilizados para o treinamento das mesmas, onde os pesos foram ajustados de acordo com os erros encontrados; 15% para validação, que garantiu a medição da capacidade de generalização da rede e para o treinamento no momento em que essa capacidade deixou de ser aprimorada e 15% para o teste sem efeitos no treinamento, onde houve uma medição independente da performance da rede durante e depois do treinamento.

Os parâmetros MSE e R foram utilizados para avaliar a performance de cada rede criada. O primeiro é a diferença média quadrada entre as saídas fornecidas pelo modelo e alvos reais. Quanto mais baixo for o valor de MSE, melhor. MSEs nulos significam ausência de erros. Por outro lado, o parâmetro R mede a correlação entre os valores encontrados pelo modelo e os alvos. Um valor de R próximo a 1 significa que há uma correlação próxima de linear entre os valores calculados e os reais, já um valor próximo a 0 significa que não há uma correlação entre os valores calculados pelo modelo e os reais.

Vários testes com diferentes números de neurônios na camada oculta foram realizados. Para cada alteração nesse número, cinco testes eram realizados e a média dos valores de MSE e R encontrados era considerada para exprimir os resultados de cada configuração diferente. Por fim, os valores de MSE e R entre RNAs com diferentes números de neurônios foram comparados para escolher a melhor configuração de rede a ser escolhida.

Para testar e, possivelmente, comprovar a capacidade preditiva da RNA encontrada, o teste com o banco de dados independente foi realizado e mais uma vez os parâmetros MSE e R foram utilizados para avaliar a performance da rede.

5.3.2 Regressão logística

A regressão logística para predição da efetividade da flotação consiste em um modelo qualitativo, onde as entradas são a P , Q_{tanino} , R , Q_{total} e NTU_e e a saída é a resposta “flotou” (1) ou “não flotou” (0). O modelo é representado por uma função hipótese sigmoidal (Equação (3)) que fornece a probabilidade da saída ser 1, ou seja, a probabilidade daqueles valores das variáveis de entrada possibilitarem a flotação ($y = 1$ na Equação (4)). A probabilidade do processo não flotar é o complemento da probabilidade dele flotar, ou seja, um menos a probabilidade de quando $y = 1$.

$$h_{\theta}(X) = \frac{1}{1 + e^{-\theta^T \cdot X}} \quad (3)$$

$$h_{\theta}(X) = P(y = 1|X; \theta) \quad (4)$$

Para descobrir os melhores valores de Θ , isto é, otimizar os parâmetros do modelo, foi utilizado o método de gradiente descendente a partir da minimização da função custo. A Equação (5) corresponde a função custo onde m é o número de amostras utilizada no treinamento e λ é o parâmetro de regularização, responsável por reduzir os valores de Θ , deixando a curva de treinamento mais suave e evitando *overfitting*.

$$J(\theta) = -\frac{1}{m} \cdot (-y^T \log(h) - (1 - y)^T \log(1 - h)) + \frac{\lambda}{2 \cdot m} \cdot \theta^2 \quad (5)$$

Dessa forma, após encontrar esses parâmetros, a função de hipótese passou a ter o formato da Equação (6).

$$h_{\theta}(X) = P(y = 1|X; \theta) = \frac{1}{1 + e^{-(\theta_0 + \theta_1 \cdot P + \theta_2 \cdot Q_{tanino} + \theta_3 \cdot R + \theta_4 \cdot Q_{total} + \theta_5 \cdot NTU_e)}} \quad (6)$$

Para obter um modelo por regressão logística, o banco de dados foi separado em 60% para o treinamento, 20% para a validação e 20% para o teste. Para descobrir qual é o valor de

λ mais adequado, uma curva de erros dos treinamento e validação versus diferentes valores do parâmetro de regularização foi plotada. O valor de λ que proporcionar os menores erro, é o que deve ser escolhido para ser usado na otimização do modelo. Uma vez escolhido o parâmetro de regularização, o modelo obtido foi avaliado plotando-se um gráfico dos erros de treinamento e validação versus diferentes tamanhos de conjunto de dados. Quanto melhor for o modelo, mais facilmente os valores dos erros de predição convergirão para um valor constante à medida que o tamanho do conjunto de treinamento aumenta. Ainda, uma boa capacidade preditiva do modelo encontrado reflete em valores muito próximos dos erros de treinamento e validação.

Uma vez encontrado um modelo, foram realizados testes com o mesmo utilizando os 20% do banco de dados previamente separados. Uma forma visual de interpretar a performance do modelo é a partir da matriz de confusão (Figura 5.8). Nela, os conceitos de verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN) são essenciais para o seu entendimento. Os VP são número de predições positivas corretas, já os VN são as predições negativas corretas. Seguindo o mesmo raciocínio, os FP são o número de predições positivas realizadas incorretamente, enquanto FN são as predições negativas incorretas.

Espera-se que os casos positivos sejam classificados como positivos e os negativos como negativos, isto é, que as taxas de sucesso para o VP e VN sejam altas e as taxas de FP e FN sejam baixas. Dessa forma, os parâmetros especificidade, sensibilidade, precisão e acurácia são fundamentais para chegar-se as conclusões sobre a performance da rede. A especificidade é a razão entre verdadeiros negativos e o número total de classificações negativas, ela responde a pergunta “*do número total de amostras que não flotaram, quantas o modelo foi capaz de prever corretamente?*”. Já a sensibilidade tem o mesmo significado que a especificidade, mas relacionando as predições positivas, ou seja, ela responde a pergunta “*do número total de amostras que flotaram, quantas o modelo foi capaz de prever corretamente?*”.

A precisão, por sua vez, é a razão entre os verdadeiros positivos e o número total de predições positivas, e está relacionada com um baixo número de falsos positivos. Quanto maior a precisão, menor é o número de falsos positivos. O parâmetro valor predito negativo segue o mesmo princípio, mas para medir o número de verdadeiros negativos. Quanto maior ele for, menor é o número de falsos negativos. Finalmente, a acurácia é um parâmetro que mede a performance geral das predições, significando a razão entre o número total de predições corretas e o número total de predições. Quanto maior forem todos esses parâmetros, melhor é a

capacidade de predição do modelo. Além disso, avaliando cada parâmetro separadamente é possível perceber quais são os pontos fracos e fortes do mesmo.

Figura 5.8. Matriz de Confusão onde cada quadrado representa um parâmetro de performance do modelo gerado.

Matriz de Confusão

Classe verdadeira (por análise)	0	VN	FP	Especificidade
	1	FN	VP	Sensibilidade
		Valor predito negativo	Precisão	Acurácia
		0	1	Classe predita (pelo modelo)

5.3.3 RNA classificatória para flotação

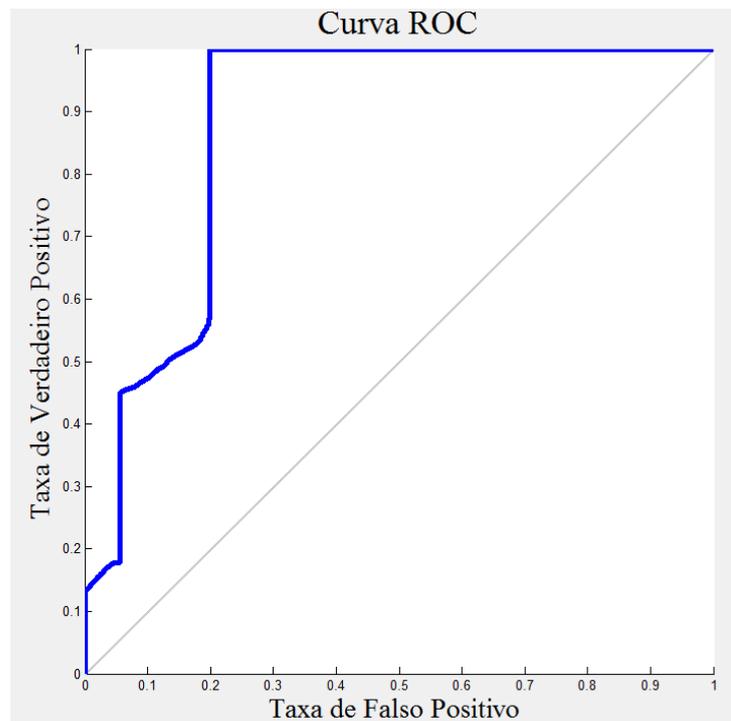
Para a RNA da predição da efetividade da flotação, foi utilizada uma rede neural com arquitetura *feedforward* de duas camadas. Os neurônios de entrada foram os mesmos da RNA para predição da remoção da turbidez, enquanto a saída correspondeu a variável qualitativa “flotou” (1) ou “não flotou” (0). Tanto para os neurônios da camada intermediária como para os da camada de saída foram utilizadas as funções de ativação sigmoideal. A construção das redes testadas se deu através da *toolbox Neural Network Pattern Recognition* do software Matlab®. Além disso, o método de treinamento utilizado foi o gradiente conjugado escalonado (*trainscg*).

O banco de dados para treinamentos e testes independentes foi aleatorizado e separado da mesma forma que para rede da predição da remoção da turbidez. A única diferença, nesse caso, foram as respostas que passaram a ser qualitativas.

Para avaliar a performance das redes criadas foram utilizados o MSE e %E (porcentagem de erro) em cada teste com diferentes números de neurônios na camada intermediária. O MSE para esse tipo de erro tem a mesma interpretação que já foi explicada anteriormente. O %E indica a fração de amostras que foi classificada de forma errada pelo modelo criado. Assim, quando %E é nulo significa que não houve classificações incorretas, por outro lado, quando vale 100, significa que todas as classificações foram incorretas. Cada configuração de rede com diferentes números de neurônios na cada intermediária foi testada 5 vezes e uma média de seus MSE e %E foi realizada para título de comparação. A rede com menor MSE e %E foi escolhida.

Uma vez escolhida a melhor configuração de RNA classificatória, a matriz de confusão e a curva ROC. (Característica de Operação do Receptor) foram plotadas para melhor visualização da sua performance. A curva ROC é um gráfico da taxa de verdadeiros positivos (sensibilidade) versus a taxa de falsos positivos, na Figura 5.9 é possível visualizar um exemplo desse tipo de gráfico.

Figura 5.9. Exemplo de curva ROC.



Geralmente, os resultados de sistemas de classificação variam entre 0 e 1, ou seja, são contínuos. Dessa forma, é necessário definir o ponto de corte para a classificação e contabilização de uma determinada resposta como positiva ou negativa. Uma forma de fazer isso é estudar o efeitos de seleção de diversos limiares sobre a saída dos dados (SOUZA, 2009). A linha cinza diagonal do gráfico presente na Figura 5.9 representa um modelo com classificações positivas e negativas aleatórias, ou seja, não é confiável. Um modelo classificador perfeito apresenta a linha azul rente à lateral vertical esquerda e horizontal superior.

6 Resultados e Discussão

Considerando-se que a planta piloto de FAD operou em modo de recirculação pressurizada, a influência da pressão do vaso saturador, vazão de tanino na entrada do tanque floculador, razão de reciclo do efluente clarificado e vazão e turbidez de entrada de água a ser tratada na qualidade do tratamento de água foram avaliadas utilizando-se quatro técnicas diferentes. Inicialmente, os efeitos de tais variáveis no sistema foram avaliados com o uso da ferramenta de planejamento de experimentos e um modelo para prever a eficiência de turbidez removida foi proposto. Em seguida, com objetivo de encontrar melhores resultados para predição da remoção da turbidez, uma rede neural artificial foi construída. Para entender em quais condições de operação o protótipo obtém êxito na etapa de flotação, foi proposto um modelo por regressão logística e, em seguida, uma rede neural artificial classificatória.

6.1 Padronização do tratamento físico-químico do efluente

Antes de iniciar os ensaios foi necessária a determinação das quantidades de aluminato de sódio e tanino que seriam adicionadas na etapa de floculação do processo. Para isso, diversos *Jar tests* foram realizados (Apêndice B – Dados dos *Jar tests*). Os efluentes testados foram preparados com água e terra vermelha com índices de turbidez de 4,9; 32,5; 52,5; 72,5 e 100,1 NTU sendo utilizado 500 mL em cada teste. Após múltiplos testes para cada turbidez de efluente, foram obtidos os resultados apresentados na Tabela 6.1.

Tabela 6.1. Resultados dos *Jar tests* para efluentes com turbidez inicial de 4,9; 32,5; 52,5; 72,5 e 100,1 NTU.

Turbidez inicial	(NTU)	4,9	32,5	52,5	72,5	100,1
$NaAlO_2$ (2% v/v)	(mL)	0,5	1,0	1,4	1,4	2,0
Tanino (5% v/v)	(mL)	0,6	1,2	1,6	1,9	2,4
pH de coagulação	-	7,7	8,1	8,5	8,2	8,8
pH de floculação	-	7,7	7,8	8,0	7,8	8,4
Turbidez Final	(NTU)	1,29	1,13	2,05	1,97	1,13
Turbidez removida	(%)	74,2	96,5	96,1	97,3	98,9
Razão $NaAlO_2$ /Tanino	-	0,83	0,83	0,88	0,74	0,83

Após os diversos testes realizados, foi possível perceber que a turbidez removida em efluentes de baixa turbidez de entrada é mais complicada que em efluentes de alta turbidez. Para um efluente com 4,9 NTU de turbidez o melhor resultado obtido foi de 74,2%. Enquanto que no efluente com 100,1 NTU, foi possível obter 98,9% de remoção. Apesar do primeiro resultado ter tido uma eficiência menos satisfatória que os de outros índices de turbidez de entrada, uma vez que a etapa de flotação está bem ajustada é possível remover quase 100% da turbidez após a etapa de filtração. Além disso, nas aplicações práticas da FAD para tratamento de água e efluentes, são raras as ocasiões em que a água a ser tratada apresenta índices de turbidez baixos como 4,9 NTU. Neste caso, essa turbidez foi avaliada nesse trabalho por questões de geração de banco de dados e mais informações sobre o funcionamento do protótipo sob diferentes condições de operação.

Com os resultados dos *Jar tests* também se notou que a razão entre aluminato de sódio e tanino variou na faixa de 0,82. Dessa forma, uma vez fixada a vazão de tanino para um determinado ensaio, a vazão de aluminato foi definida a partir dessa razão. Além disso, o pH da floculação variou na faixa de 8,1, pH este capaz de garantir o bom funcionamento do tanino, permitindo a floculação do material particulado.

Apesar dos testes para o tratamento físico-químico terem sido realizados com aluminato de sódio a 2% v/v e tanino a 5% v/v, os experimentos realizados na planta de FAD utilizaram tais coagulante e floculante com concentrações reduzidas pela metade, isto é, com 1% para o aluminato de sódio e 2,5% para o tanino. Assim, os volumes necessários para que a floculação ocorresse de forma satisfatória precisaram ser dobrados. Essa medida precisou ser tomada frente os limites de operação das bombas dosadoras de coagulante e floculante. Caso fosse utilizada a mesma concentração testada nos *Jar tests*, as vazões necessárias seriam inferiores aos limites de operação de tais bombas.

6.2 Análise da turbidez removida

Com objetivo de avaliar como as variáveis de entrada influenciam na turbidez removida na planta de FAD, um planejamento composto central foi realizado, analisado e teve seus resultados explicados no tópico a seguir. Para tentar aprimorar os resultados e gerar um modelo com melhores performances preditivas, uma RNA foi gerada e testada.

6.2.1 Predição da Turbidez Removida utilizando regressão linear e Planejamento de Experimentos

Nos experimentos realizados na planta de FAD o processo foi avaliado por cerca de duas horas em cada ensaio. Como todas as variáveis medidas pelo sistema foram monitoradas com um período de amostragem de 1s (um segundo), gerou-se um vasto banco de dados. De acordo com o planejamento composto central descrito na sessão de Materiais e Métodos, foram realizados 45 experimentos e em cada um desses ensaios, um banco de dados de duas horas foi gerado.

Tendo em vista que em um Planejamento de Experimentos cada experimento realizado precisa apresentar um valor único para a variável de saída analisada, foi necessário definir apenas um valor de turbidez de saída em cada ensaio. Para isso, os dados foram divididos em ensaios em que a microbolhas foram geradas e a flotação, de fato, aconteceu e ensaios em que não houve a formação de microbolhas e, conseqüentemente, não houve flotação. No primeiro caso, foi feita uma média dos valores de turbidez de saída a partir do momento em que o processo entrava em regime permanente até um pouco antes do fim do ensaio em cada um dos experimentos. Já para os casos em que não houve flotação, assim que o regime entrava em regime permanente, os primeiros dados de turbidez de saída foram armazenados e sua média utilizada como valor final, isso porque, nesses casos, a medida que o ensaio progride, a queda da turbidez se dá por decantação e não por flotação. Como o objetivo do trabalho é avaliar a flotação, o restante dos dados não foi levado em consideração. Dessa forma, a matriz de planejamento presente na Tabela 6.2 foi obtida. Vale lembrar que o dado de turbidez de saída foi substituído pela eficiência de turbidez removida.

Tabela 6.2. Matriz de planejamento nas variáveis originais e com resultados de turbidez removida.

Ensaio	P (bar)	Q_{tanino} (mL/min)	R (%)	Q_{total} (L/min)	NTU_e (NTU)	TR (%)
1	4,7	10,8	11,3	1,45	32,5	91,26
2	4,7	10,8	11,3	1,45	72,5	90,65
3	4,7	10,8	11,3	2,95	32,5	64,09
4	4,7	10,8	11,3	2,95	72,5	82,19
5	4,7	10,8	13,7	1,45	32,5	90,74
6	4,7	10,8	13,7	1,45	72,5	92,51
7	4,7	10,8	13,7	2,95	32,5	72,40
8	4,7	10,8	13,7	2,95	72,5	79,61
9	4,7	25,2	11,3	1,45	32,5	94,18

Continuação						
Ensaio	P	Q_{tanino}	R	Q_{total}	NTU_e	TR
	(bar)	(mL/min)	(%)	(L/min)	(NTU)	(%)
10	4,7	25,2	11,3	1,45	72,5	94,34
11	4,7	25,2	11,3	2,95	32,5	90,55
12	4,7	25,2	11,3	2,95	72,5	89,50
13	4,7	25,2	13,7	1,45	32,5	94,68
14	4,7	25,2	13,7	1,45	72,5	94,36
15	4,7	25,2	13,7	2,95	32,5	91,35
16	4,7	25,2	13,7	2,95	72,5	89,10
17	6,3	10,8	11,3	1,45	32,5	91,66
18	6,3	10,8	11,3	1,45	72,5	91,63
19	6,3	10,8	11,3	2,95	32,5	80,55
20	6,3	10,8	11,3	2,95	72,5	88,68
21	6,3	10,8	13,7	1,45	32,5	90,03
22	6,3	10,8	13,7	1,45	72,5	92,69
23	6,3	10,8	13,7	2,95	32,5	85,02
24	6,3	10,8	13,7	2,95	72,5	84,98
25	6,3	25,2	11,3	1,45	32,5	95,05
26	6,3	25,2	11,3	1,45	72,5	92,84
27	6,3	25,2	11,3	2,95	32,5	91,97
28	6,3	25,2	11,3	2,95	72,5	87,19
29	6,3	25,2	13,7	1,45	32,5	93,63
30	6,3	25,2	13,7	1,45	72,5	94,51
31	6,3	25,2	13,7	2,95	32,5	93,17
32	6,3	25,2	13,7	2,95	72,5	92,39
33	3,6	18,0	12,5	2,20	52,5	93,14
34	7,4	18,0	12,5	2,20	52,5	92,17
35	5,5	0,9	12,5	2,20	52,5	25,39
36	5,5	35,1	12,5	2,20	52,5	95,60
37	5,5	18,0	9,6	2,20	52,5	92,46
38	5,5	18,0	15,4	2,20	52,5	90,78
39	5,5	18,0	12,5	0,42	52,5	89,62
40	5,5	18,0	12,5	3,98	52,5	71,24
41	5,5	18,0	12,5	2,20	4,9	58,43
42	5,5	18,0	12,5	2,20	100,1	93,61
43 (c)	5,5	18,0	12,5	2,20	52,5	92,42
44 (c)	5,5	18,0	12,5	2,20	52,5	95,05
45 (c)	5,5	18,0	12,5	2,20	52,5	92,42

A partir dos dados obtidos no planejamento a matriz de efeitos completa foi gerada (Tabela 6.3). Com objetivo de avaliar o processo qualitativamente e gerar um modelo de regressão linear mais completo, na medida do possível, foram considerados os efeitos quadráticos e as interações entre dois fatores. Partindo-se do princípio que 95% de confiança

significa a porcentagem de probabilidade de um valor obtido estar contido no intervalo considerado, o *p-valor* indica qual é a probabilidade de erro ao aceitar um valor obtido como válido. Como o intervalo escolhido foi de 95% de confiança, o valor de probabilidade do valor observado não ser válido é de 5% ($p = 0,05$). Dessa forma, efeitos que apresentaram *p-valor* maiores que 0,05 não foram considerados significativos. Portanto, um efeito foi dito significativo quando o valor de *p* calculado for menor que 0,05. Os fatores que apresentaram *p-valor* menor que 0,05 foram: Q_{tanino} , Q_{tanino}^2 , Q_{total} , Q_{total}^2 , NTU_e , NTU_e^2 , $P \cdot Q_{tanino}$, $P \cdot Q_{total}$, $Q_{tanino} \cdot Q_{total}$ e $Q_{tanino} \cdot NTU_e$.

Tabela 6.3. Matriz de efeitos completa e com efeitos significativos destacados para 95% de confiança.

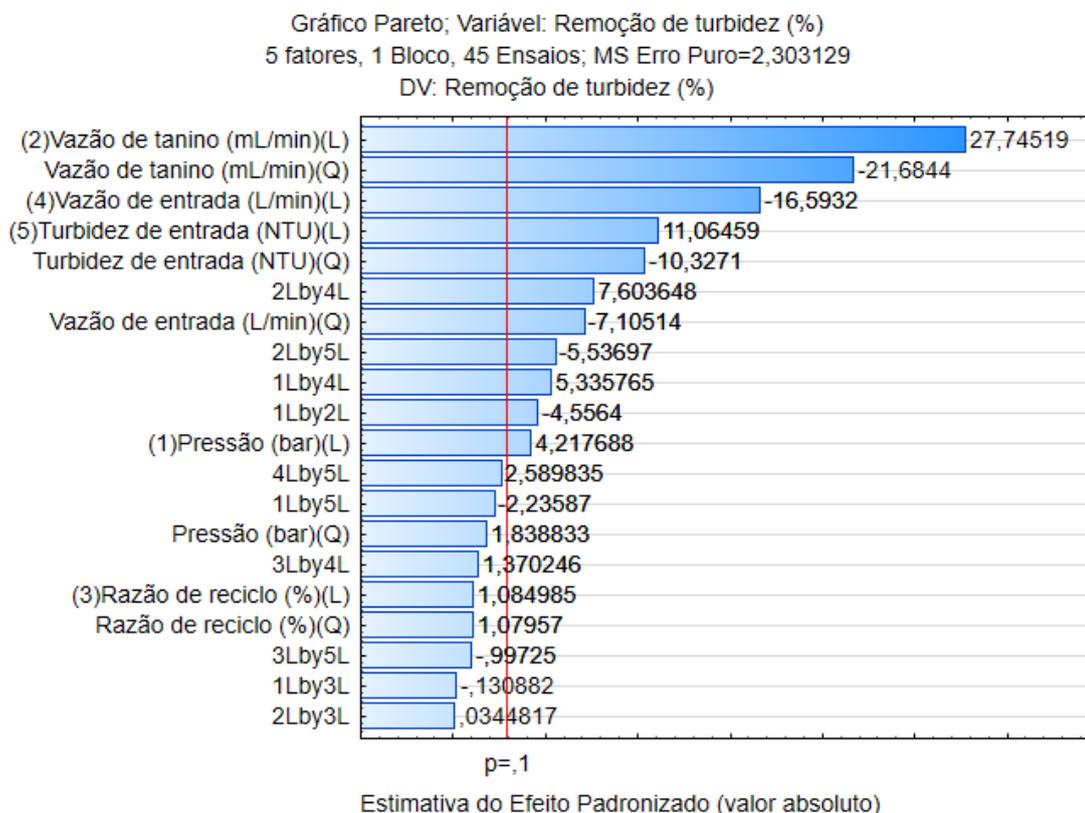
Efeito	Efeito	Erro Puro Padrão	t de Student calculado (2)	<i>p-valor</i>	Coefficiente de regressão
Constante	95,7510	0,858725	111,5037	0,000080	95,75098
<i>P</i>	1,9451	0,461186	4,2177	0,051879	0,97257
<i>P</i> ²	0,8889	0,483393	1,8388	0,207319	0,44444
<i>Q</i>_{tanino}	12,7957	0,461186	27,7452	0,001297	6,39785
<i>Q</i>_{tanino}²	-10,4821	0,483393	-21,6844	0,002120	-5,24104
<i>R</i>	0,5004	0,461186	1,0850	0,391302	0,25019
<i>R</i> ²	0,5219	0,483393	1,0796	0,393219	0,26093
<i>Q</i>_{total}	-7,6526	0,461186	-16,5932	0,003612	-3,82628
<i>Q</i>_{total}²	-3,4346	0,483393	-7,1051	0,019239	-1,71729
<i>NTU</i>_e	5,1028	0,461186	11,0646	0,008070	2,55142
<i>NTU</i>_e²	-4,9921	0,483393	-10,3271	0,009247	-2,49603
<i>P</i> · <i>Q</i>_{tanino}	-2,4448	0,536555	-4,5564	0,044945	-1,22238
<i>P</i> · <i>R</i>	-0,0702	0,536555	-0,1309	0,907846	-0,03511
<i>P</i> · <i>Q</i>_{total}	2,8629	0,536555	5,3358	0,033376	1,43147
<i>P</i> · <i>NTU</i> _e	-1,1997	0,536555	-2,2359	0,154867	-0,59983
<i>Q</i> _{tanino} · <i>R</i>	0,0185	0,536555	0,0345	0,975625	0,00925
<i>Q</i>_{tanino} · <i>Q</i>_{total}	4,0798	0,536555	7,6036	0,016860	2,03989
<i>Q</i>_{tanino} · <i>NTU</i>_e	-2,9709	0,536555	-5,5370	0,031104	-1,48544
<i>R</i> · <i>Q</i> _{total}	0,7352	0,536555	1,3702	0,304145	0,36761
<i>R</i> · <i>NTU</i> _e	-0,5351	0,536555	-0,9973	0,423710	-0,26754
<i>Q</i> _{total} · <i>NTU</i> _e	1,3896	0,536555	2,5898	0,122329	0,69479

Por apresentar um *p-valor* muito próximo de 0,05 restou a dúvida se a *P* pode ou não ser considerada um fator significativo. Diminuindo-se a confiança para 90%, *P* passa a ser

considerada um fator significativo, visto que seu *p*-valor é 0,051879, ou seja, menor que 0,1. Esse resultado, a princípio, pode fazer mais sentido em termos de processo, visto que espera-se que a pressão tenha um efeito importante na produção de microbolhas e, conseqüentemente, na redução de turbidez de saída. Entretanto, é necessário realizar mais algumas análises para se ter certeza se a pressão é ou não um fator importante na construção do modelo para remoção da turbidez. A melhor hipótese encontrada para explicar esse comportamento da pressão é o fato de que a floculação mostrou-se em maior evidência em relação a flotação (o próprio fato da vazão de coagulante ter sido o efeito mais significativo demonstra isso). Assim, é difícil perceber os efeitos das variáveis manipuladas apenas na flotação. Portanto, para avaliar o real efeito da pressão na flotação por ar dissolvido desse protótipo, o ideal seria realizar diversos testes para definir quais são as melhores condições de operação que fornecem o melhor resultado de floculação e partir disso realizar testes exclusivos para as variáveis de flotação, possibilitando, dessa forma, a avaliação de quais são as variáveis que realmente influenciam nessa etapa. Ao conduzir o estudo dessa maneira, é capaz que a pressão passe a ser significativa.

Para facilitar a visualização e interpretação dos dados quanto às suas significâncias um gráfico *Pareto* foi construído (Figura 6.1). Nele, os valores de *t* de *Student* calculados para os fatores e interações foram plotados. A linha vermelha tracejada indica o valor de *t* de *Student* tabelado na Literatura. Quando uma faixa ultrapassa essa linha, ou seja, quando o valor de *t* de *Student* calculado de um efeito é maior que o módulo de *t* de *Student* tabelado um fator é considerado significativo.

Figura 6.1. Gráfico de Pareto.



Além de mostrar quais efeitos foram significantes, o gráfico *Pareto* também facilitou a visualização para realização do método de *Backward Elimination*, que tem por objetivo encontrar o modelo que apresente maior valor do coeficiente de determinação ajustado (R^2 ajustado). Mesmo que alguns termos não tenham influência na variável resposta, quanto mais termos um modelo tiver, maior será o valor de R^2 . Dessa forma, o modelo completo sempre se mostrará melhor quando apenas o R^2 é avaliado. A melhor forma de analisar a eficácia de um modelo com menos termos em relação ao completo é avaliando o R^2 ajustado. O valor de R^2 ajustado só aumenta caso o termo eliminado não seja significativo para descrição da resposta e diminui quando o mesmo é significativo. Assim, foi preciso escolher o modelo que apresentou o maior valor de R^2 ajustado. A metodologia de *Backward Elimination* consiste em eliminar do modelo completo um coeficiente de cada vez, partindo do menos significativo (último valor do gráfico *Pareto*) para o mais significativo (topo do gráfico *Pareto*) sempre comparando os valores de R^2 ajustado dos diferentes modelos. Após realizar tal procedimento (Tabela 6.4), foi possível perceber que os fatores $P \cdot Q_{tanino}$ e P , antes considerados significantes para o modelo, foram excluídos do modelo final com melhor R^2 ajustado. Independente dos valores

de R^2 e R^2 ajustado, o objetivo principal do planejamento de experimentos neste trabalho é possibilitar uma avaliação qualitativa das variáveis manipuladas na turbidez removida.

Tabela 6.4. Resultados da Backward Elimination.

Fator removido	R^2	R^2 ajustado
Modelo completo	0,69256	0,43636
$Q_{tanino} \cdot R$	0,69256	0,4589
$P \cdot R$	0,69255	0,4797
$R \cdot NTU_e$	0,69221	0,49842
R^2	0,69182	0,51572
R	0,69142	0,53181
$R \cdot Q_{total}$	0,69078	0,54648
P^2	0,68998	0,55997
$P \cdot NTU_e$	0,68828	0,57139
$Q_{total} \cdot NTU_e$	0,68601	0,58134
P	0,67998	0,58585
$P \cdot Q_{tanino}$	0,67294	0,58883
$P \cdot Q_{total}$	0,66328	0,58846

Dessa forma, a matriz de efeitos enxuta foi gerada na Tabela 6.5 e o modelo para turbidez removida encontrado está na Equação (7). O seu R^2 vale 0,67294 enquanto o R^2 ajustado 0,58883.

$$\begin{aligned}
 TR = & 96,99502 + 6,39785 \cdot Q_{tanino} - 5,43674 \cdot Q_{tanino}^2 - 3,82628 \cdot Q_{total} \\
 & - 1,91299 \cdot Q_{total}^2 + 2,55142 \cdot NTU_e - 2,69173 \cdot NTU_e^2 + 1,43147 \\
 & \cdot P \cdot Q_{total} + 2,03989 \cdot Q_{tanino} \cdot Q_{total} - 1,48544 \cdot Q_{tanino} \cdot NTU_e
 \end{aligned} \quad (7)$$

Tabela 6.5. Matriz de efeitos reduzida após Backward Elimination.

Efeito	Efeito	Erro Puro Padrão	t de Student calculado (2)	p-valor	Coefficiente de regressão
Constante	96,9950	0,484200	200,3201	0,000025	96,99502
Q_{tanino}	12,7957	0,461186	27,7452	0,001297	6,39785
Q_{tanino}^2	-10,8735	0,428815	-25,3570	0,001552	-5,43674
Q_{total}	-7,6526	0,461186	-16,5932	0,003612	-3,82628
Q_{total}^2	-3,8260	0,428815	-8,9222	0,012330	-1,91299
NTU_e	5,1028	0,461186	11,0646	0,008070	2,55142
NTU_e^2	-5,3835	0,428815	-12,5543	0,006285	-2,69173
$P \cdot Q_{total}$	2,8629	0,536555	5,3358	0,033376	1,43147
$Q_{tanino} \cdot Q_{total}$	4,0798	0,536555	7,6036	0,016860	2,03989
$Q_{tanino} \cdot NTU_e$	-2,9709	0,536555	-5,5370	0,031104	-1,48544

A melhor forma de analisar numericamente a qualidade do ajuste encontrado foi examinando os resíduos deixados pelo modelo. Isso pode ser realizado a partir da análise de variância (ANOVA), que descreveu como os dados experimentais afastaram-se da sua média (Tabela 6.6).

Tabela 6.6. Tabela ANOVA do modelo proposto.

Fonte de variação	Soma quadrática	Número de graus de liberdade	Média quadrática
Regressão	4570,889	9	507,88
Resíduo	2221,56	35	63,47
Falta de ajuste	2216,954	33	67,18
Erro puro	4,606	2	2,30
Total	6792,449	44	
% de variação explicada:	67,29%		
% máxima de variação explicável:	99,93%		

Da análise da Tabela 6.6:

$$F_{\text{tabelado}}(9,35) = 1,81$$

$$F_{\text{calculado}}(9,35) = \frac{MQ_{\text{regressão}}}{MQ_{\text{resíduo}}} = 8,00$$

$$\frac{F_{\text{calculado}}(9,35)}{F_{\text{tabelado}}(9,35)} = 4,42$$

De acordo com Barros Neto et al. (2001), pode-se considerar a regressão realizada como satisfatória se $F_{\text{calculado}}$ for cerca de dez vezes o valor de F_{tabelado} . Como a razão $\frac{F_{\text{calculado}}(9,35)}{F_{\text{tabelado}}(9,35)}$ foi maior que 1 e menor que 10, o modelo pode ser considerado adequado, mas pouco preditivo.

$$F_{\text{tabelado}}(33,2) = 9,46$$

$$F_{\text{calculado}}(33,2) = \frac{MQ_{\text{falta de ajuste}}}{MQ_{\text{erro puro}}} = 29,17$$

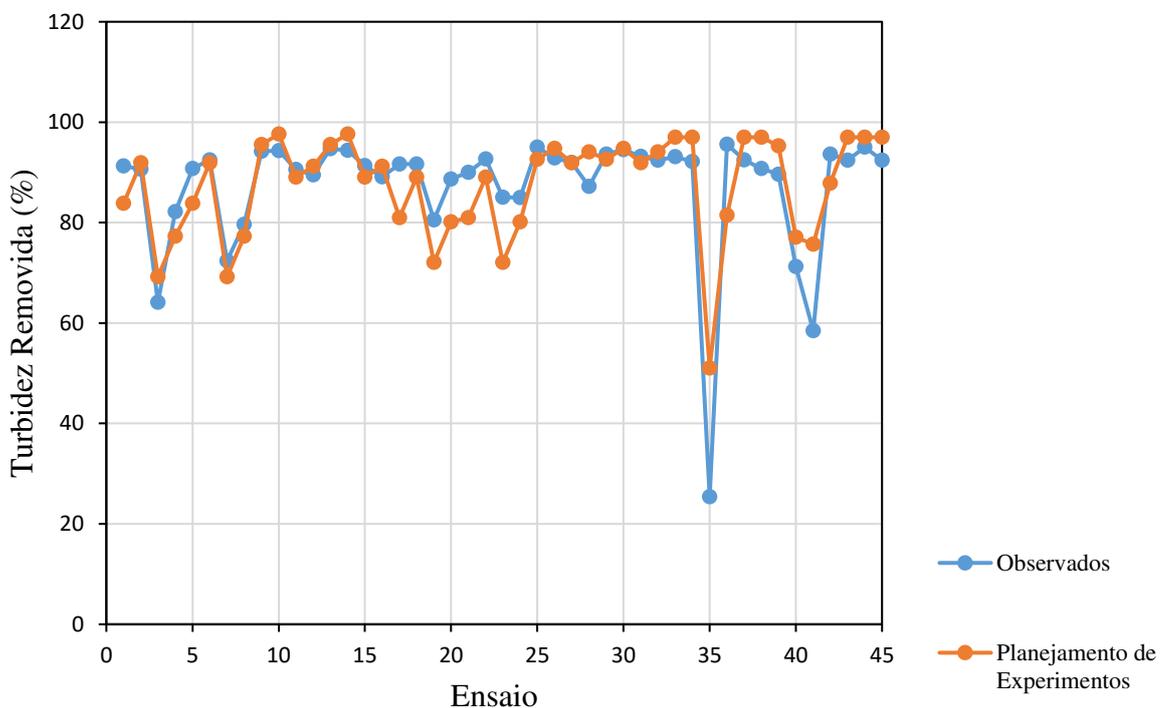
$$\frac{F_{\text{calculado}}(33,2)}{F_{\text{tabelado}}(33,2)} = 3,08$$

No caso do segundo teste F, o fato do $F_{\text{calculado}}$ ser muito maior que o F_{tabelado} gerou um alto valor na razão entre os F, sugerindo que a falta de ajuste foi muito significativa e, portanto, o modelo foi pouco preditivo. Como foram feitas apenas repetições no ponto central,

o erro puro foi muito baixo e houve a possibilidade que a sua estimativa não tenha sido representativa do erro experimental do processo, fazendo com que isso levasse $F_{calculado}$ a um valor superestimado. É importante frisar que propor um modelo preciso não é o objetivo principal e sim avaliar a influência das variáveis manipuladas na remoção da turbidez.

Observando o gráfico da turbidez removida para cada ensaio (Figura 6.2), foi possível notar que o modelo proposto apresentou um desempenho razoável, uma vez que os valores de turbidez removida preditos e observados encontram-se relativamente próximos. De acordo com o manual do turbidímetro online, o erro de medição do equipamento vale $\pm 2\%$. O erro médio da predição da turbidez é aproximadamente 7,6%, assim, as variações no valor final da turbidez não são tão significativas para determinar a qualidade da água ou a eficiência do processo de flotação. Além do mais, a partir do modelo gerado e da análise dos efeitos significativos, foi possível entender quais fatores influenciam na remoção da turbidez.

Figura 6.2. Gráfico dos valores de turbidez removida observada e predita pelo planejamento de experimentos para cada ensaio realizado.



Com um modelo e os efeitos significativos definidos é possível partir para algumas considerações sobre os resultados. A vazão de tanino foi a variável de entrada com maior efeito na turbidez e tal descoberta pode ser explicada pelo fato de que quanto melhor a etapa da

floculação, menor é a turbidez de saída do efluente, mesmo que a flotação em si não ocorra. Também se constatou que a vazão total de água a ser tratada é muito importante para remoção da turbidez, apesar de apresentar efeito negativo. O efeito negativo representa a relação inversamente proporcional com a turbidez removida, o que faz sentido, visto que altas vazões de entrada não permitem que as etapas de floculação e flotação ocorram de forma eficiente, gerando baixa turbidez removida pelo processo. A turbidez de entrada é o fator mais significativo seguinte. Isso mostra que a turbidez de saída tende a permanecer a mesma em experimentos com condições operacionais diferentes e, quando a turbidez de entrada é mais alta, o parâmetro turbidez removida acaba se tornando maior.

Os efeitos de interação significativos foram a pressão com a vazão total de entrada, a vazão de tanino com a vazão total e a vazão de tanino com a turbidez de entrada. A pressão e a vazão total podem ser explicadas pela necessidade de ajustar pressões para valores maiores quando a vazão total é alta, visto que ao aumentar-se a vazão total (para uma dada razão de reciclo constante) a vazão de água adentrando o vaso saturador, é maior. Com uma alta vazão de efluente adentrando o vaso saturador, é necessária maior pressão para solubilizar a mesma quantidade de ar que quando a baixas vazões e, conseqüentemente, afetar a turbidez de saída. Já a vazão de tanino e a vazão total tem uma relação direta devido a necessidade de maiores vazões de floculante quanto maiores forem as vazões de entrada para a formação de flocos satisfatórios e a redução da turbidez de saída. Finalmente, a vazão de tanino e a turbidez de entrada também estão diretamente ligadas visto que quanto maior for a turbidez de entrada, maior a concentração de sólidos dissolvidos e mais floculante é necessário para a formação de flocos satisfatórios, o que também contribui diretamente para a turbidez de saída.

Para avaliar em qual nível de cada fator de entrada a turbidez removida foi maximizada, foram construídas superfícies de resposta que possibilitaram uma boa visualização. Com a Figura 6.3 foi possível perceber que a turbidez removida foi maximizada quando a turbidez de entrada permaneceu no nível intermediário 0, enquanto mudanças na pressão do vaso saturador não influenciaram na turbidez removida. Já a partir da Figura 6.4, constatou-se que a razão de reciclo não teve influência direta na turbidez removida, enquanto a vazão de tanino pode maximizar a mesma quando está entre os níveis 0 e +1. A vazão de efluente, por sua vez, maximizou a turbidez removida quando estava entre os níveis -2 e 0, como mostrado na Figura 6.5. Tais constatações estão de acordo com o modelo obtido onde pode ser visto que nem a pressão no vaso saturador e nem a razão de reciclo influenciam fortemente na variável de resposta turbidez removida.

Figura 6.3. Superfície de resposta para Remoção da Turbidez em função Pressão e Turbidez de entrada.

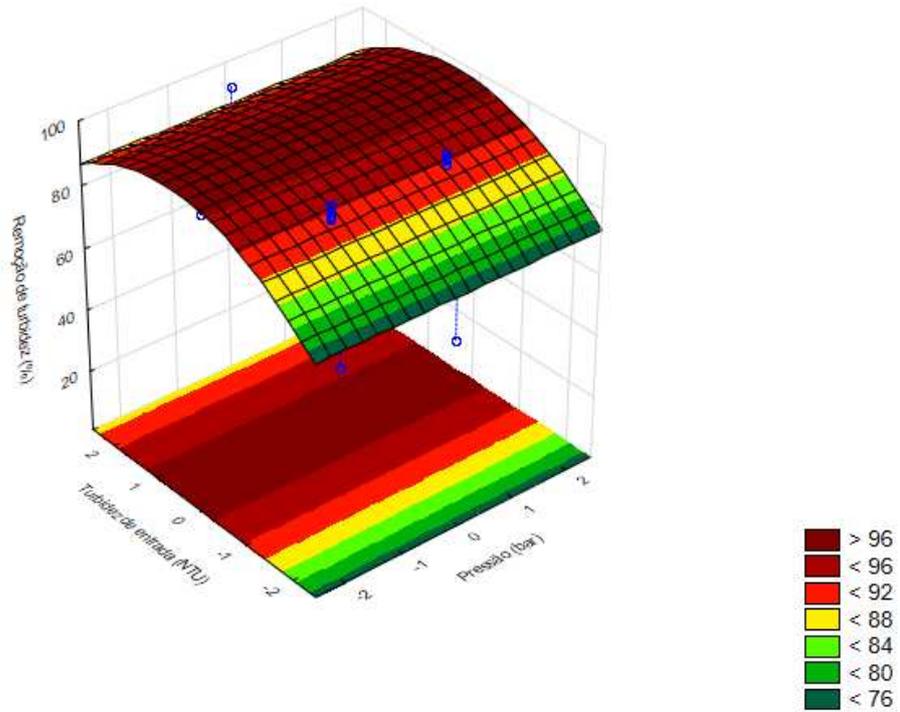


Figura 6.4. Superfície de resposta para Remoção da Turbidez em função da Vazão de tanino e Razão de reciclo.

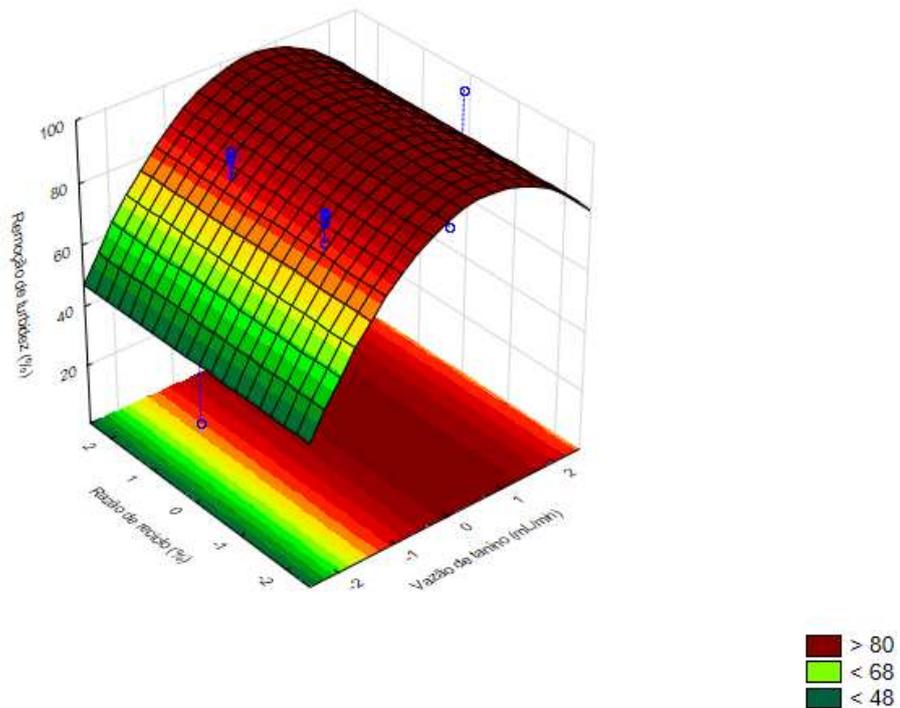
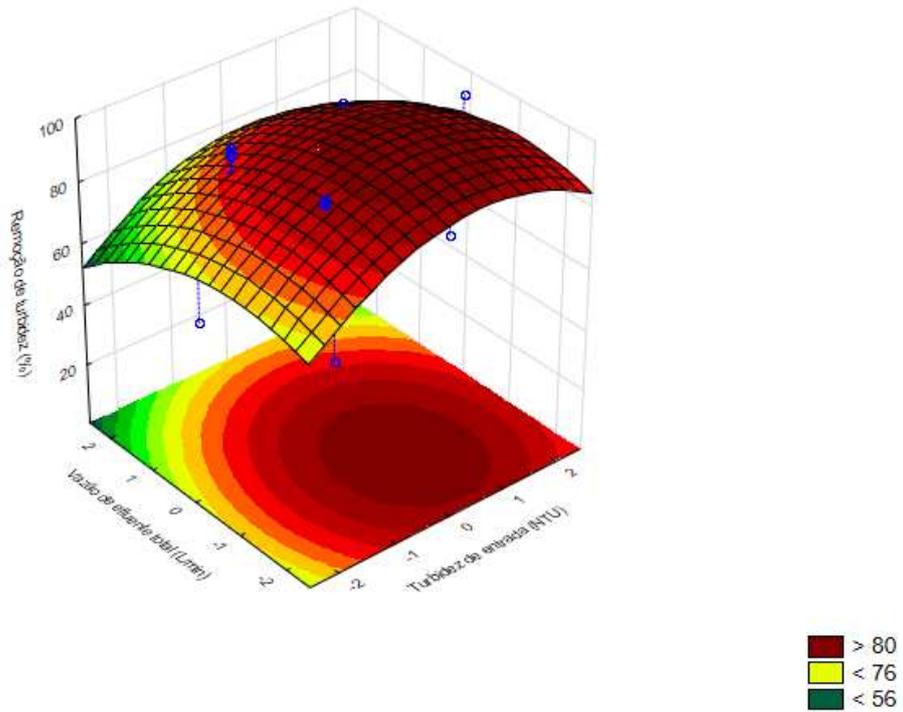
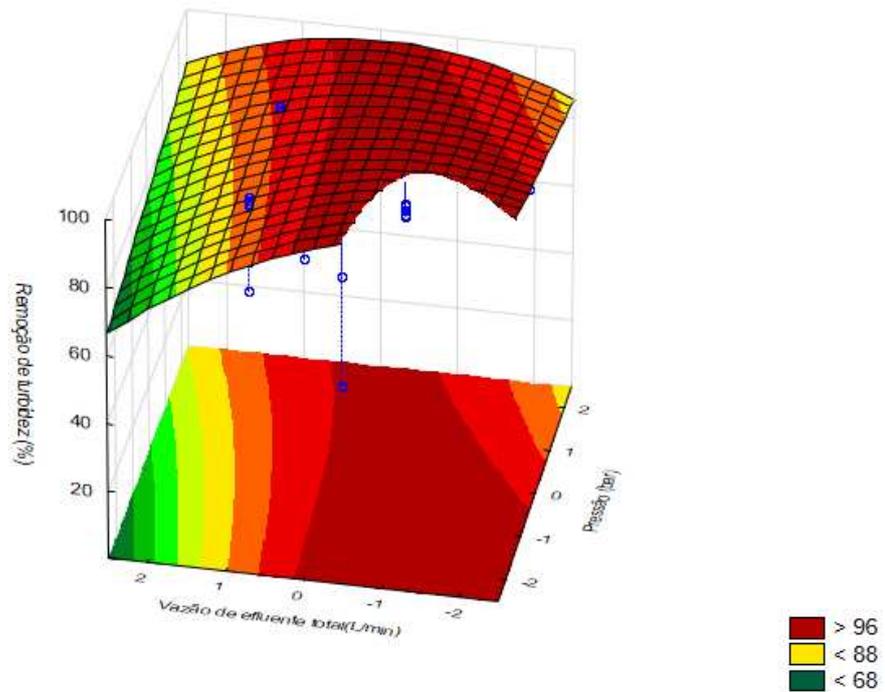


Figura 6.5. Superfície de resposta para Remoção da Turbidez em função da Turbidez de entrada e Vazão de efluente total.



No gráfico presente na Figura 6.6, foi possível perceber como a pressão pode influenciar a remoção da turbidez quando combinada a vazão de efluente total, assim como apresentado no modelo, com o termo $P \cdot Q_{total}$. Quando a pressão estava em níveis inferiores a -0,5 e a vazão de efluente em níveis inferiores a 0, a turbidez removida foi maximizada.

Figura 6.6. Superfície de resposta para Remoção da Turbidez em função da Vazão de efluente total e Pressão.



As Figura 6.7 e Figura 6.8 confirmaram que a turbidez foi maximizada quando a vazão de efluente total esteve entre os níveis -2 e 0, a vazão de tanino entre os níveis 0 e 1 e a turbidez de entrada entre os níveis 0 e 1.

Figura 6.7. Superfície de resposta para Remoção da Turbidez em função da Vazão de tanino e Vazão de efluente total.

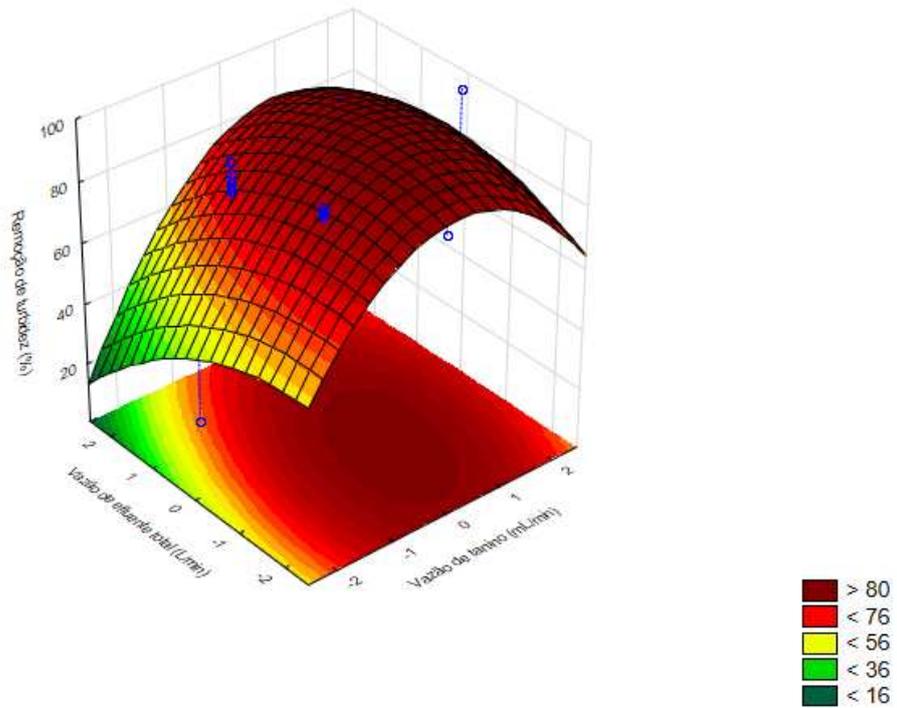
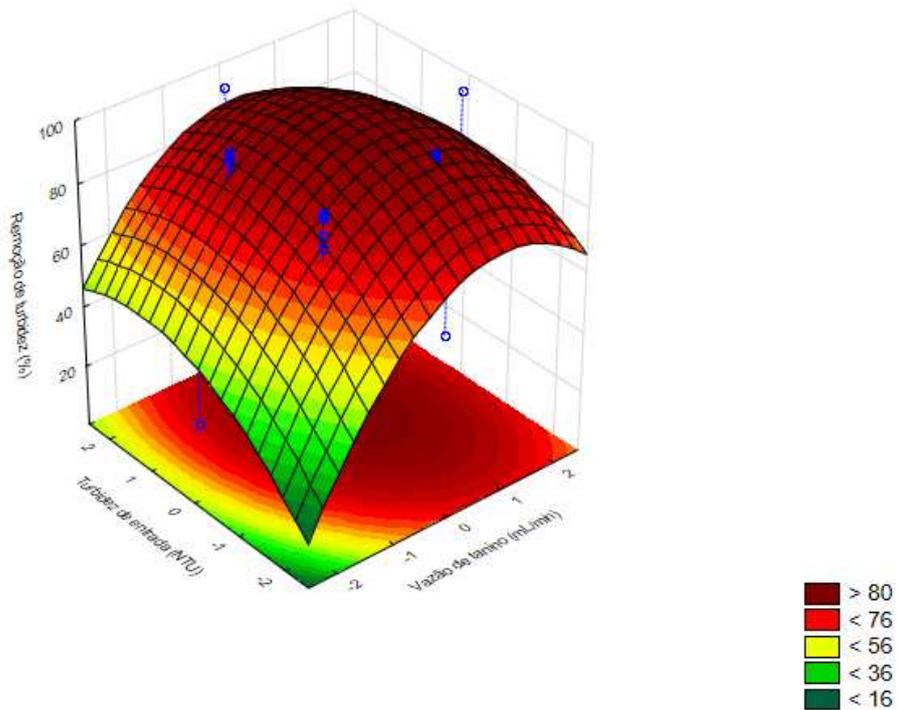


Figura 6.8. Superfície de resposta para Remoção da Turbidez em função da Vazão de tanino e Turbidez de entrada.



6.2.2 Predição da Turbidez Removida utilizando Redes Neurais Artificiais

Com o objetivo de encontrar um modelo para predição da turbidez removida com poder de predição maior ainda, o uso de Redes Neurais Artificiais (RNA) para ajuste de função foi explorado como uma possível sugestão.

Inicialmente, os mesmos dados utilizados no Planejamento de Experimentos (Tabela 6.2) foram usados para a configuração da primeira RNA. Dessa forma, uma matriz com 45 linhas foi inserida no *toolbox Neural Network Fitting Tool (nftool)* e 70% dos dados foram utilizados para a etapa de treinamento (o que corresponde a 31 amostras), enquanto 15% para a validação e 15% para o teste (7 amostras para cada uma das etapas). Após diversos testes e comparações dos valores de $MSE_{\text{treinamento}}$, $MSE_{\text{validação}}$ e MSE_{teste} , e escolhendo a configuração com os menores valores, chegou-se à melhor configuração de rede contendo uma camada intermediária com cinco neurônios (Figura 6.9). Os resultados das redes neurais com esse limitado banco de dados apresentaram-se tão limitados quanto os resultados obtidos no Planejamento de Experimentos. Devido à reduzida quantidade de dados para avaliações, os ajustes propostos frequentemente apresentaram resultados insatisfatórios na etapa de validação e teste, como pode ser visto na Tabela 6.7.

Figura 6.9. Diagrama da RNA com 1 camada intermediária e 5 neurônios utilizada para o banco de dados com 45 linhas.

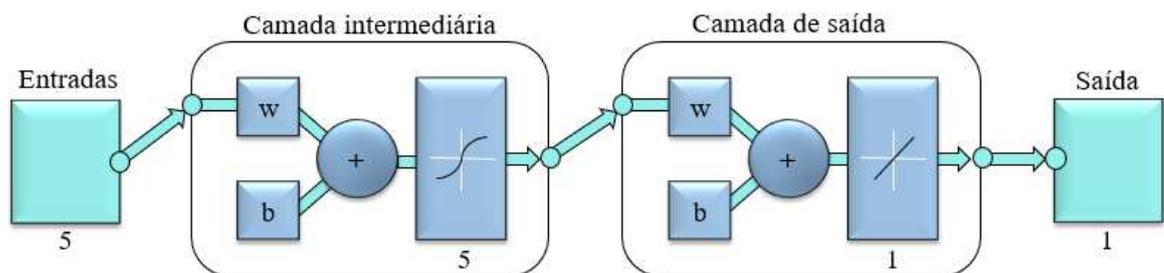


Tabela 6.7. Parâmetros de performance para RNA com 5 neurônios na camada intermediária (banco de dados com 45 linhas).

Teste	5 neurônios						
	$MSE_{\text{treinamento}}$	$MSE_{\text{validação}}$	MSE_{teste}	$R_{\text{treinamento}}$	$R_{\text{validação}}$	R_{teste}	R_{total}
1	95,3616	155,6307	70,6311	0,6804	0,4823	0,1162	0,6100
2	2,3402	1,4091	596,1012	0,9852	0,5761	0,5163	0,6199
3	5,6772	4,837	61,1238	0,9986	0,9544	-0,4010	0,9688
4	133,1353	57,8174	31,5804	0,5801	0,5817	0,1609	0,5690

5	14,4116	16,9767	434,9340	0,9123	0,8314	0,9808	0,7113
---	---------	---------	----------	--------	--------	--------	--------

Sabe-se que redes neurais artificiais aprendem comportamentos de processos a partir de informações (medidas, amostras ou padrões) obtidas. Dessa forma, geralmente, quanto maior a diversidade e a vastidão dos dados, melhores são os modelos gerados. Com isso, uma nova RNA foi proposta utilizando praticamente todos os dados de cada experimento realizado. Ao invés de se calcular a média da turbidez de saída para cada um dos 45 ensaios como foi feito no planejamento de experimentos e no primeiro tipo de RNA construída, todos esses valores foram utilizados, assim como suas respectivas pressões, vazões de tanino, razões de reciclo, vazões totais e turbidez de entrada adquiridos ao longo do experimento. Ou seja, os dados obtidos segundo a segundo em cada experimento foram unidos em um único banco de dados. Assim, após o tratamento de dados, um vasto banco foi gerado (com 202.106 linhas). Esse banco foi separado em um conjunto utilizado para o treinamento, validação e teste da rede (150.000 linhas) e outro conjunto para testes adicionais de performance (52.106 linhas).

Após vários testes com diferentes números de neurônios, os resultados de desempenho obtidos foram resumidos na

Tabela 6.8. As diferenças de parâmetros entre as RNAs com 5 neurônios na camada intermediária e as com 10 foram de 16,5% no $MSE_{\text{treinamento}}$, 13,9% no $MSE_{\text{validação}}$ e 19,2% no MSE_{teste} . Enquanto isso, as diferenças nos mesmos parâmetros entre a rede com 10 e 15 neurônios foram de 5,1%, 5,4% e 1,4% para o $MSE_{\text{treinamento}}$, $MSE_{\text{validação}}$ e MSE_{teste} , respectivamente. Considerando que essas últimas diferenças não foram expressivas e visando minimizar o esforço computacional, optou-se por escolher a RNA com 10 neurônios na camada intermediária (Figura 6.10).

Como é possível observar na

Tabela 6.8, tanto os erros calculados para o treinamento como para a validação e teste permaneceram baixos, o que indica que não houve sobreajuste (*overfitting*) e que o modelo teve uma boa capacidade de generalização na etapa de testes. Além disso, os gráficos presentes na Figura 6.11, explicitam como os ajustes gerados nessa etapa de construção da rede foram satisfatórios.

Tabela 6.8. Média dos parâmetros de performance para RNAs com diferentes números de neurônios na camada intermediária (banco de dados com 150.000 linhas).

Neurônios na Camada intermediária	$MSE_{\text{treinamento}}$	$MSE_{\text{validação}}$	MSE_{teste}	$R_{\text{treinamento}}$	$R_{\text{validação}}$	R_{teste}
5	3,0933	3,0327	3,1314	0,9740	0,9746	0,9732
10	2,5825	2,6117	2,5310	0,9783	0,9785	0,9784
15	2,4500	2,4696	2,4951	0,9794	0,9793	0,9789

Figura 6.10. Diagrama da RNA com 1 camada intermediária e 10 neurônios utilizada para o banco de dados com 150.000 linhas.

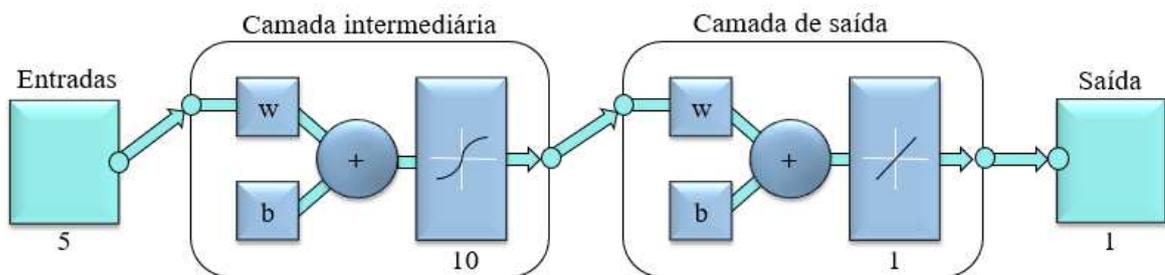
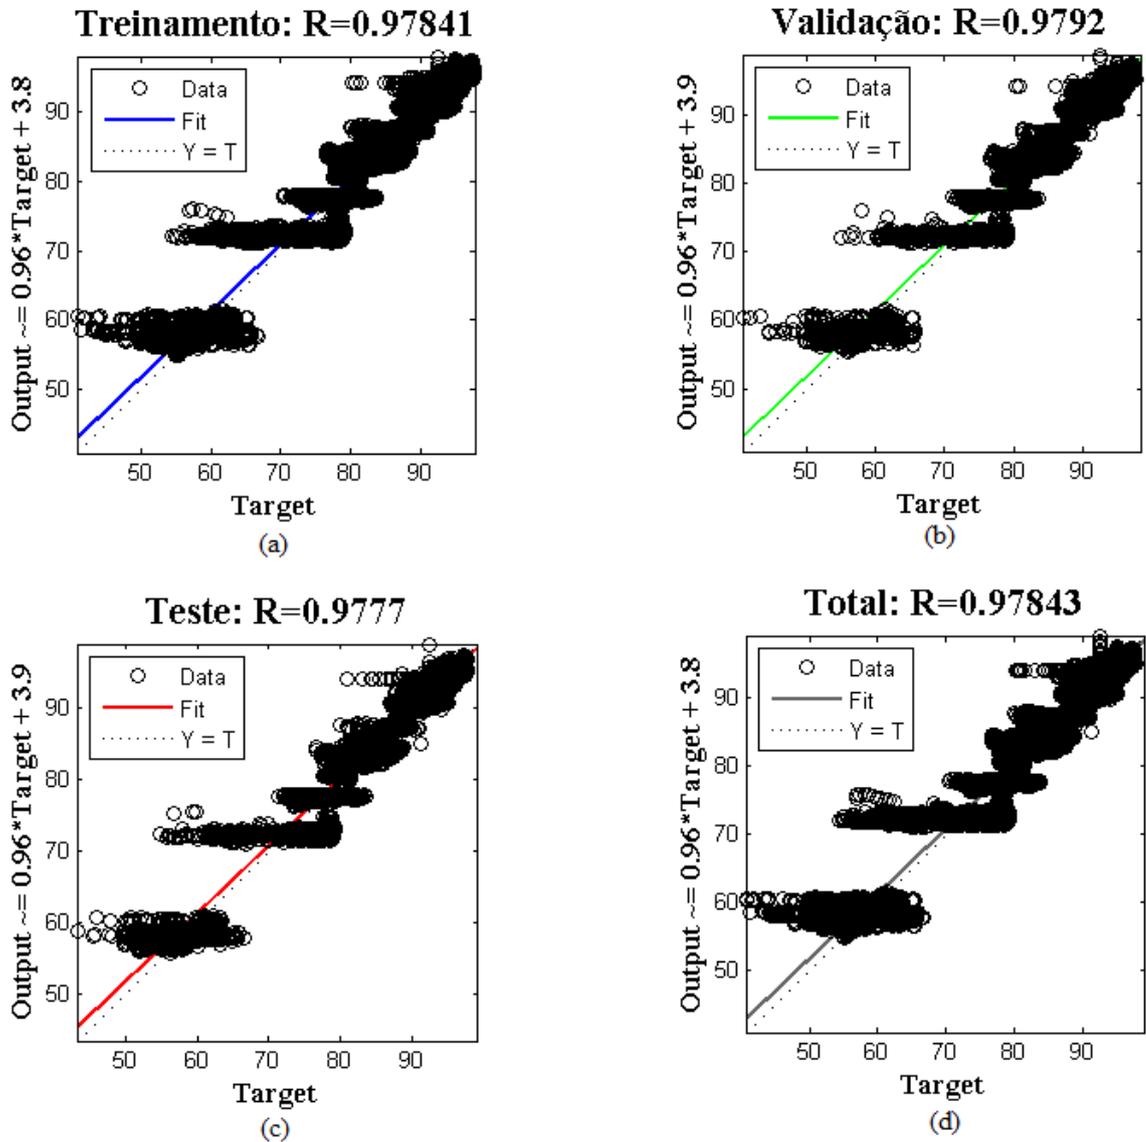
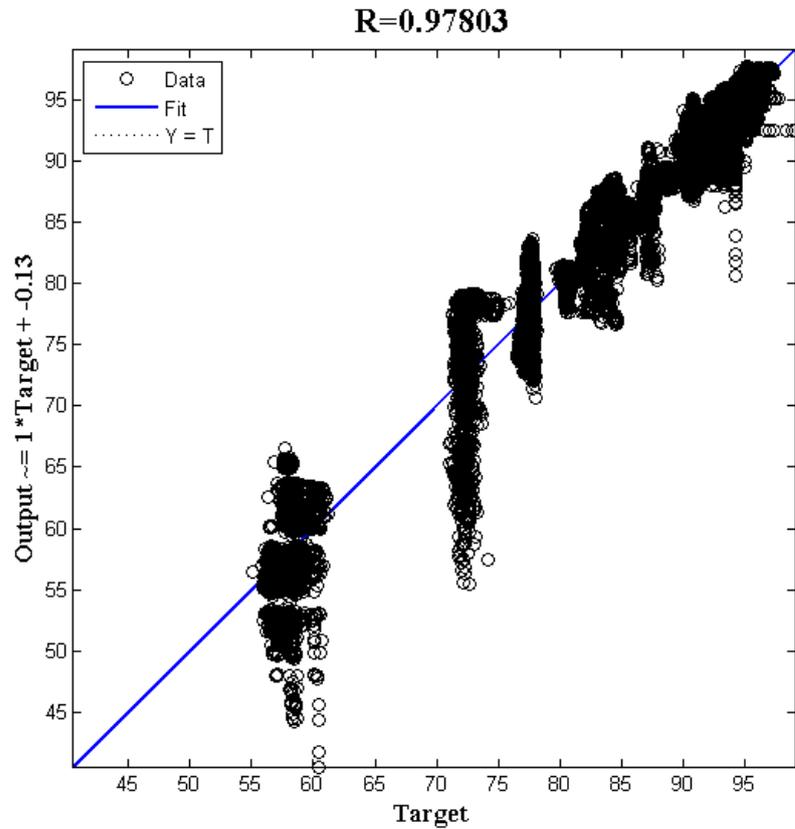


Figura 6.11. Gráficos de regressão da RNA proposta para o banco com 150.000 linhas. (a) Treinamento. (b) Validação. (c) Teste. (d) Total.



O conjunto de dados separados para o teste adicional da melhor RNA gerada foi utilizado e confirmou a alta capacidade de generalização da rede. Tal teste teve MSE médio de 2,5831. A correlação entre a turbidez removida prevista pelo modelo e a turbidez removida observada experimentalmente é muito próxima de linear, visto que o R foi de 0,9780 (Figura 6.12).

Figura 6.12. Gráfico de regressão para o teste realizado com a matriz de dados de 52.106 linhas.

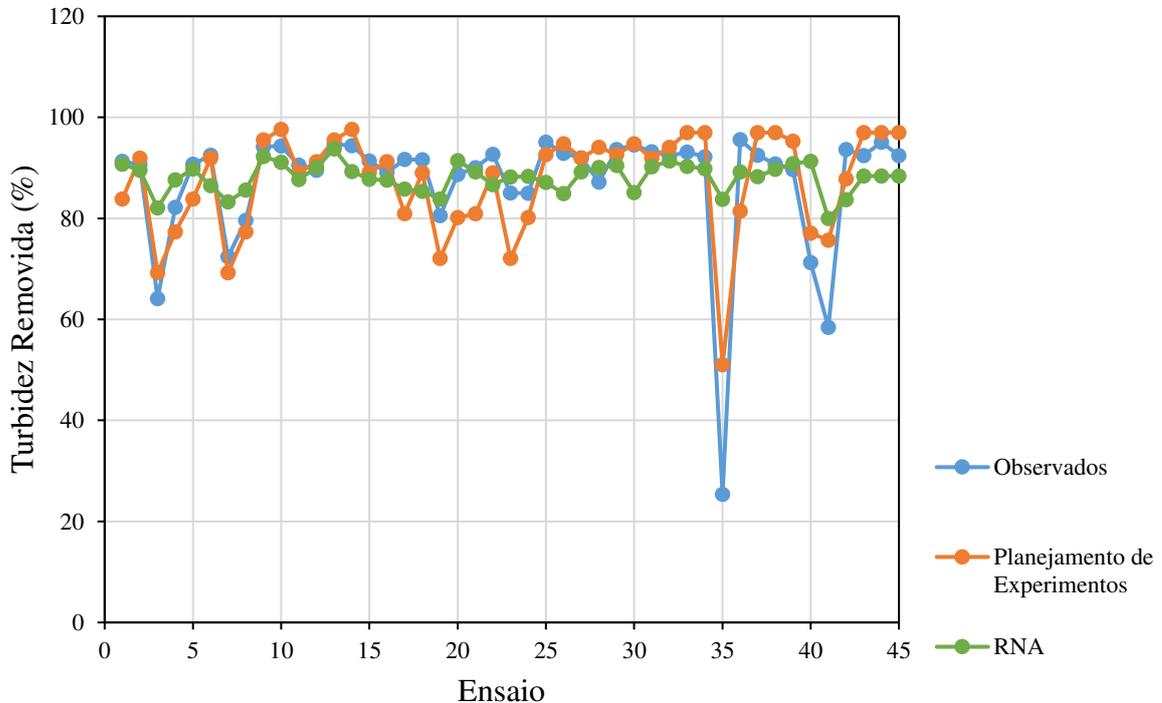


Os pesos de entrada, saída e bias se encontram no Apêndice C – Detalhes da RNA para predição da turbidez removida.

6.2.3 Análise comparativa entre os resultados do modelo do Planejamento de Experimentos e do modelo de RNA

Ao comparar os resultados obtidos pela regressão linear do Planejamento de Experimentos com os do modelo encontrado pela RNA é possível perceber que a RNA apresentou alta capacidade de generalização. Isso está explicitado nos pontos e linha de tendência verdes do gráfico da Figura 6.13, que ficaram entre os valores observados nos experimentos e os valores preditos pela regressão linear. A alta capacidade de generalização é o que se espera de uma boa RNA, entretanto, o ideal é que ela também seja capaz de prever casos destoantes dos centrais como o do ensaio 35, por exemplo (em que a vazão de tanino foi baixíssima, de 0,9 mL/min).

Figura 6.13. Gráfico dos valores de turbidez removida observada e predita pelo planejamento de experimentos e RNA para cada ensaio realizado.



Para garantir a construção de uma RNA com alta capacidade de tanto generalizar como prever casos extremos, o ideal seria que, em trabalhos futuros, as condições de operação que geraram pontos de turbidez removida fora da faixa central sejam exploradas com mais detalhes. Assim, os resultados obtidos nesse trabalho servem para nortear trabalhos futuros no protótipo quanto a faixas de operação e comportamento das variáveis de entrada. Para gerar modelos mais precisos será necessário realizar mais experimentos avaliando outras faixas de operação.

6.3 Análise da efetividade da etapa de flotação

Nem todas as condições de operação propiciaram a geração de microbolhas no sistema de FAD e, portanto, possibilitaram a flotação do material floculado. Tendo em vista essa limitação, um modelo por regressão logística foi proposto para prever em quais condições de operação a planta obtém êxito na flotação. Com objetivo de melhorar os resultados preditivos, uma RNA classificatória foi gerada e testada.

Tanto para o modelo por regressão logística quanto para RNA classificatória, o mesmo banco de dados utilizado para RNA de predição da turbidez removida foi utilizado (com 202.106 linhas). A diferença consistiu na variável de saída, que ao invés de remoção da

turbidez, passou a ser a variável qualitativa “flotou” ou “não flotou”. Para os ensaios em que houve flotação, a resposta dessa variável foi tida como 1, enquanto nos casos negativos, 0. Na Figura 6.14 é possível visualizar um caso de experimento em que houve flotação. Já na Figura 6.15, um em que não houve.

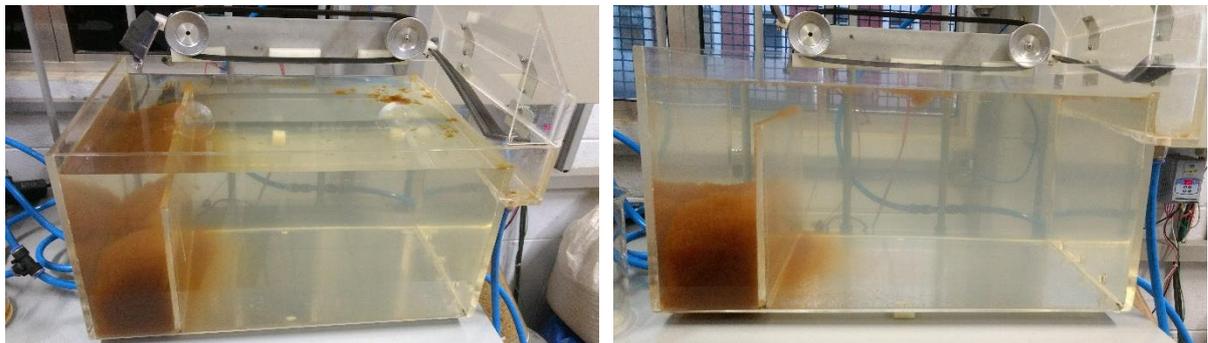
Figura 6.14. Ensaio 45 onde houve flotação.



(a) Vista superior do tanque de flotação.

(b) Vista lateral da camada de lodo formada.

Figura 6.15. Ensaio 39, onde não houve flotação.



(a) Vista superior do tanque de flotação.

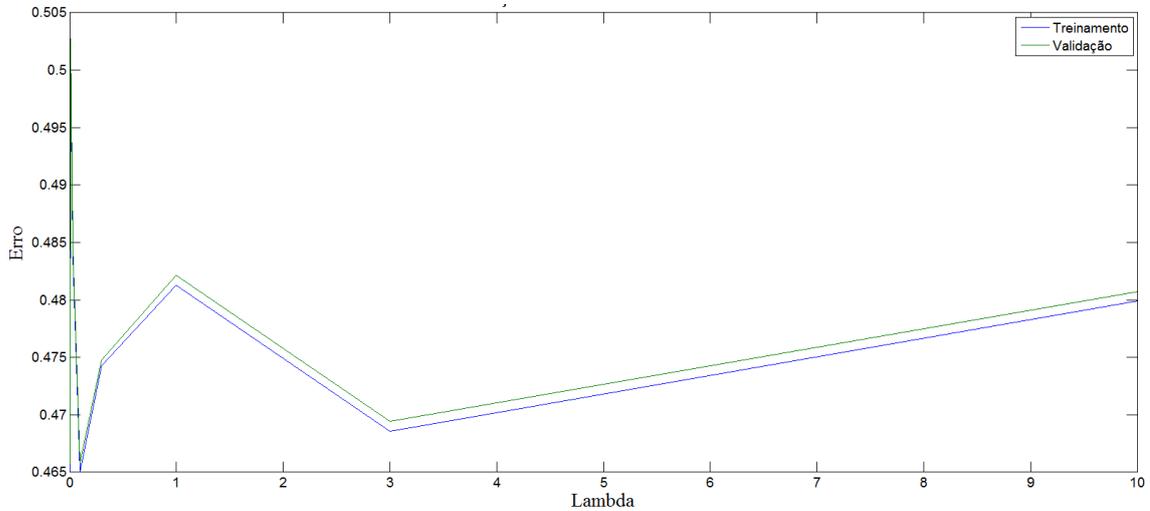
(b) Vista lateral do lodo decantado.

6.3.1 Predição da flotação utilizando modelo por Regressão Logística

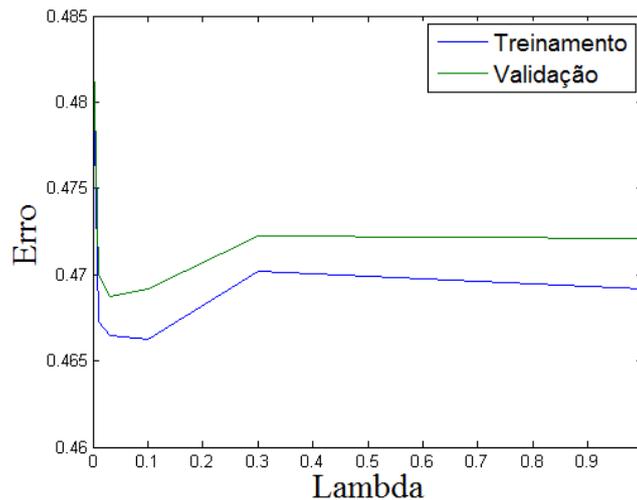
Após a construção de um algoritmo gerador de modelos por regressão logística, a primeira dúvida que surgiu foi qual valor usar para o parâmetro de regularização (λ). Valores muito baixos de λ geralmente causam problemas de *overfitting* no modelo, isto é, o mesmo se ajusta muito bem ao conjunto de dados do treinamento, entretanto não apresenta capacidade para generalização quando testado com o conjunto de dados de validação e de teste. Por outro lado, valores muito altos de λ frequentemente implicam em problemas de *underfitting*, ou seja, modelos com pouca capacidade preditiva, visto que os coeficientes do modelo (Θ) tendem a apresentar valores muito pequenos e gerarem uma função que não representa os dados do problema. A melhor forma de encontrar qual foi o melhor valor de λ foi gerando um gráfico

dos erros de treinamento e validação para diferentes valores do parâmetro de regularização (Figura 6.16). Geralmente, o erro da validação tende a ser levemente maior que o do treinamento. A partir desse gráfico, percebeu-se que as diferenças nos valores dos erros não foram expressivamente significativas quando se variou o valor de λ . Entretanto, $\lambda = 0,1$ mostrou-se como o valor onde tanto o erro da validação como o do treinamento foram mínimos. Além disso, esse gráfico apresentou o comportamento esperado para os erros do treinamento e da validação.

Figura 6.16. Validação para seleção do melhor parâmetro de regularização.



(a) Gráfico de $\lambda = 0$ a $\lambda = 10$.

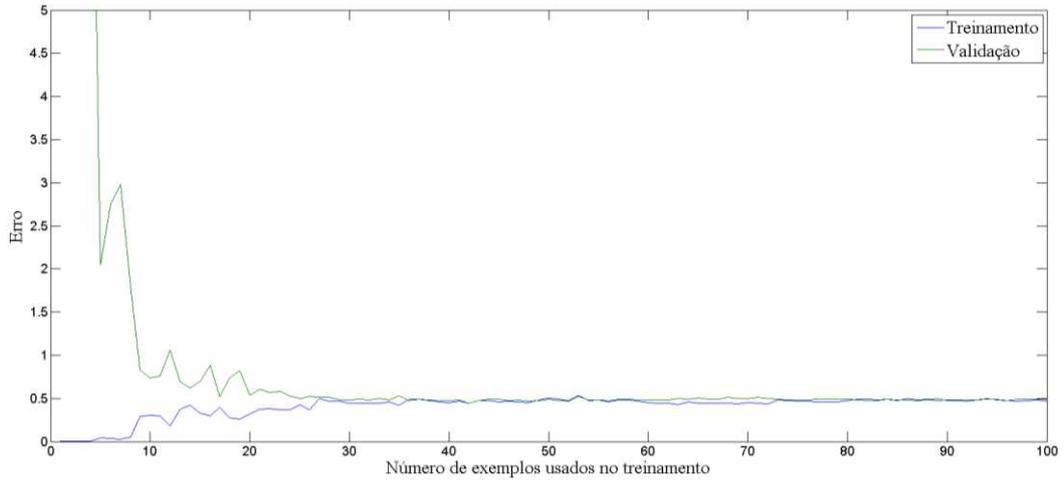


(a) Gráfico de $\lambda = 0$ a $\lambda = 1$.

Outra maneira de avaliar o comportamento do modelo foi gerar um gráfico dos erros de treinamento e validação versus diferentes tamanhos de conjunto de dados. Um bom modelo

apresenta valores de erros praticamente constantes a medida que o tamanho do conjunto de treinamento aumenta. Além disso, quando o parâmetro de regularização é bem escolhido, os valores do erro de treinamento e de validação são muito próximos, indicando que o modelo apresenta boa capacidade preditiva para dados diferentes do treinamento. Com a Figura 6.17 foi possível perceber que o modelo encontrado satisfaz essas duas qualidades mencionadas.

Figura 6.17. Curvas de aprendizado para $\lambda = 0,1$.



Após análises de λ e curvas de aprendizado, o modelo final proposto apresentou os coeficientes presentes na Tabela 6.9, que quando escritos na forma da função de hipótese sigmoidal pode ser representado como na Equação (8). A pressão utilizada no vaso saturador e a vazão total de entrada são os fatores de maior peso na determinação do sucesso da etapa de flotação. No caso da pressão, sua importância se dá pela influência na geração de microbolhas que são determinantes na flotação do efluente. Já a vazão de entrada, influencia diretamente na vazão de reciclo (para uma dada razão de reciclo constante) que, quando submetida a pressões ideais, possibilita a maior geração de microbolhas quanto maior ela for.

Tabela 6.9. Parâmetros do modelo de regressão logística.

Teste	θ_0	θ_1	θ_2	θ_3	θ_4	θ_5
1	-0,1407	0,9382	0,0911	-0,4453	1,0122	-0,0622
2	-0,1554	0,9463	0,0863	-0,464	1,0228	-0,0571
3	-0,1707	0,95	0,0988	-0,4935	1,1003	-0,0581
Média	-0,1556	0,944833	0,092067	-0,4676	1,0451	-0,05913

$$h_{\theta}(X) = \frac{1}{1 + e^{-(-0,1556 + 0,944833P + 0,092067Q_{\text{tanino}} - 0,4676R + 1,0451Q_{\text{total}} - 0,05913NTU_e)}} \quad (8)$$

O modelo foi proposto utilizando-se 60% do banco de dados. Dos 40% restante, metade foi utilizado na validação e a outra metade na etapa de teste. Finalmente, foram obtidos os resultados presentes na Tabela 6.10.

Tabela 6.10. Parâmetros de performance do modelo gerado pela regressão logística.

Parâmetros	
Acurácia	0,8206
Sensibilidade	0,8171
Especificidade	0,8239
Precisão	0,8167

Para exemplificar a capacidade preditiva do modelo com os dados da Tabela 6.10, uma matriz de confusão foi gerada com os resultados obtidos em um dos testes (Figura 6.18). A partir dela foi possível perceber que as duas primeiras células diagonais em verde expressaram o número de classificações corretas pelo modelo. Foram previstos 16.993 casos verdadeiros negativos, ou seja, os que foram corretamente classificados como “não flotou”, o que corresponde a 42,04% de todos os casos. Similarmente, para os verdadeiros positivos, 16.176 foram corretamente classificados como “flotou”, correspondendo a 40,02% de todos os casos.

As células diagonais vermelhas expressam o número de classificações incorretas do modelo. Nos falsos positivos, 3.631 dos casos “não flotou” foram classificados incorretamente como “flotou”, ou seja, 8,98% de todos os dados. Já no caso dos falsos negativos, 3621 casos “flotou” foram considerados “não flotou”, correspondendo também a 8,96% dos dados totais. Dessa forma, a especificidade mostra que dos 20624 casos “não flotou”, 82,39% foram classificados corretamente e 17,61% incorretamente. Analogamente, a sensibilidade mostra que dos 19794 casos “flotou”, 81,71% foram classificados corretamente enquanto 18,29% incorretamente. Por outro lado, dos 20.614 dos casos “não flotou”, 82,43% foram corretamente preditos. Já para os 19807 “flotou” casos, 81,67% foram corretamente preditos. Finalmente, como acurácia para todos os dados, 82,06% dos casos foram preditos corretamente e 17,94% incorretamente.

Figura 6.18. Matriz de confusão de resultados gerado pela regressão logística.

Matriz de Confusão

Classe verdadeira (por análise)	0	1	
	0	1	2
0	16993 42,04%	3631 8,98%	82,39% 17,61%
1	3621 8,96%	16176 40,02%	81,71% 18,29%
	82,43% 17,57%	81,67% 18,33%	82,06% 17,94%
	0	1	
	Classe predita (pelo modelo)		

Considerando-se que todos os parâmetros que medem o desempenho do modelo encontrado são maiores que 0,8, o modelo mostrou-se com boa capacidade de generalização. Tendo em vista que a regressão logística é a forma mais simples de prever resultados qualitativos, o modelo proposto apresentou resultados extremamente satisfatórios.

6.3.2 Predição da flotação utilizando Redes Neurais Artificiais Classificadoras

A mesma configuração de banco de dados utilizada na criação da RNA para predição da remoção da turbidez foi utilizada na criação das RNAs classificatórias. Dessa forma, para criação e treinamento das redes o banco de dados com 150.000 linhas foi empregado, onde as entradas corresponderam às cinco variáveis utilizadas nos modelos anteriores e a saída à mesma variável qualitativa “flotou” e “não flotou” empregada na regressão logística. Mais uma vez, 70% desses dados foram utilizados para o treinamento da rede, enquanto 15% para a validação e os outros 15% restantes para o teste. Os testes adicionais realizados também usaram o banco de dados com 52.106 linhas.

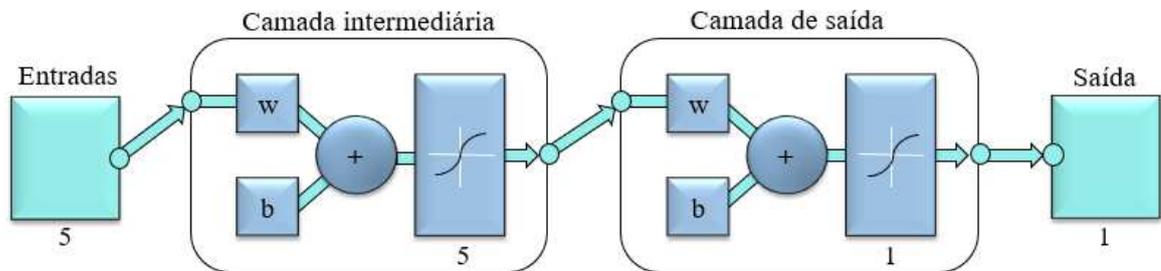
Depois de diversos testes com diferentes números de neurônios, os resultados médios de desempenho obtidos estão resumidos na Tabela 6.11. Apesar dos resultados com 3 neurônios

na camada intermediária já terem fornecidos resultados satisfatórios, ao realizar testes com 5 neurônios foi possível obter erros nulos em todos os testes realizados. Portanto, optou-se por escolher a RNA com uma camada intermediária com 5 neurônios (Figura 6.19).

Tabela 6.11. Média dos parâmetros de performance para RNAs classificatórias com diferentes números de neurônios na camada intermediária (banco de dados com 150.000 linhas).

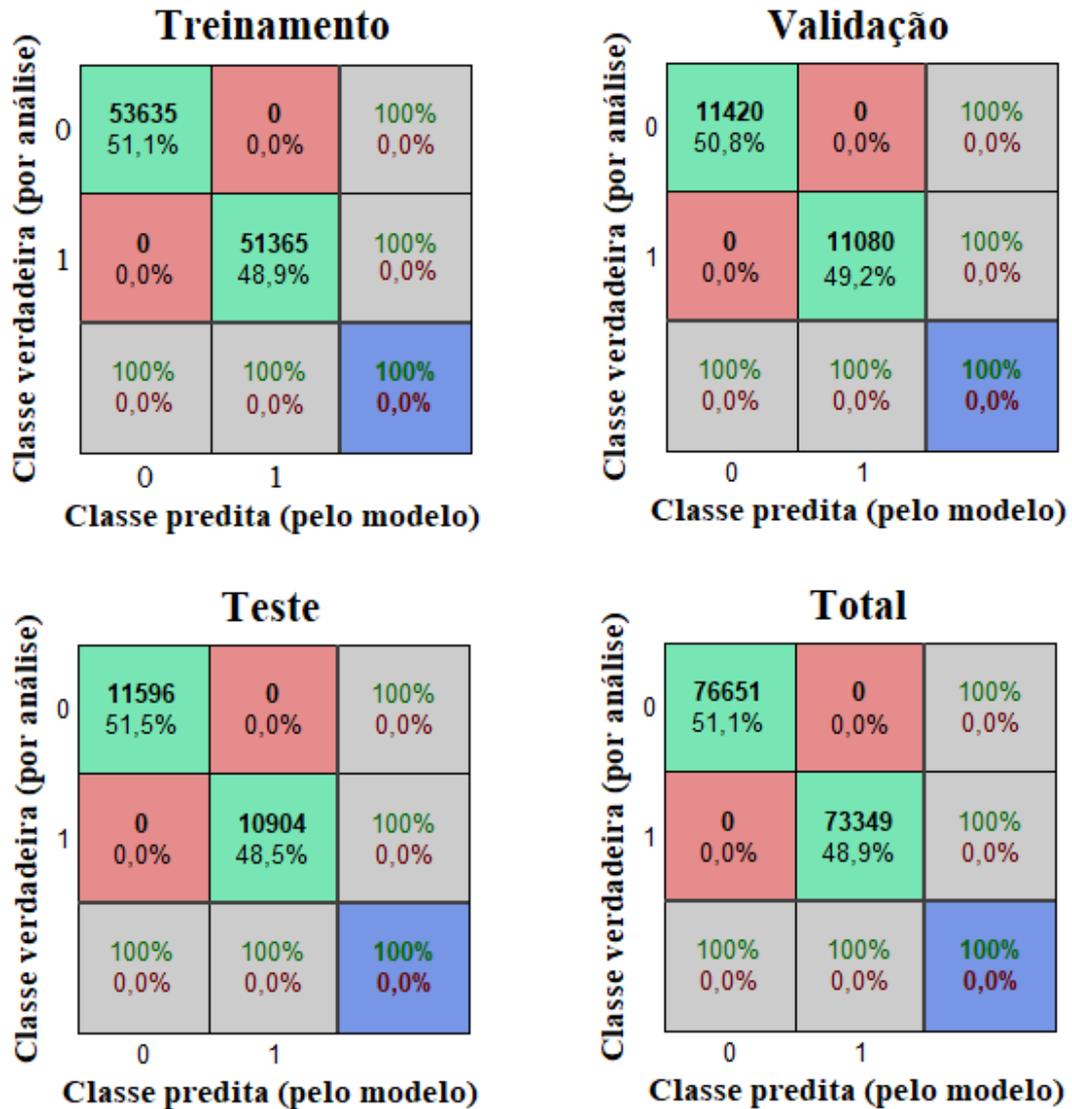
Neurônios na Camada intermediária	MSE _{treinamento}	MSE _{validação}	MSE _{teste}	%E _{treinamento}	%E _{validação}	E% _{teste}
1	0,0859	0,0850	0,0852	10,4181	10,2933	10,2978
2	0,0528	0,0545	0,0518	9,4495	9,9867	9,4622
3	0,0024	0,0023	0,0023	0,3025	0,2836	0,2800
4	0,0117	0,0120	0,0116	1,1695	1,1947	1,1582
5	2,9025E-07	3,6328E-07	2,3314E-07	0,0000	0,0000	0,0000

Figura 6.19. Diagrama da RNA com 1 camada intermediária e 5 neurônios utilizada para o banco de dados com 150.000 linhas.



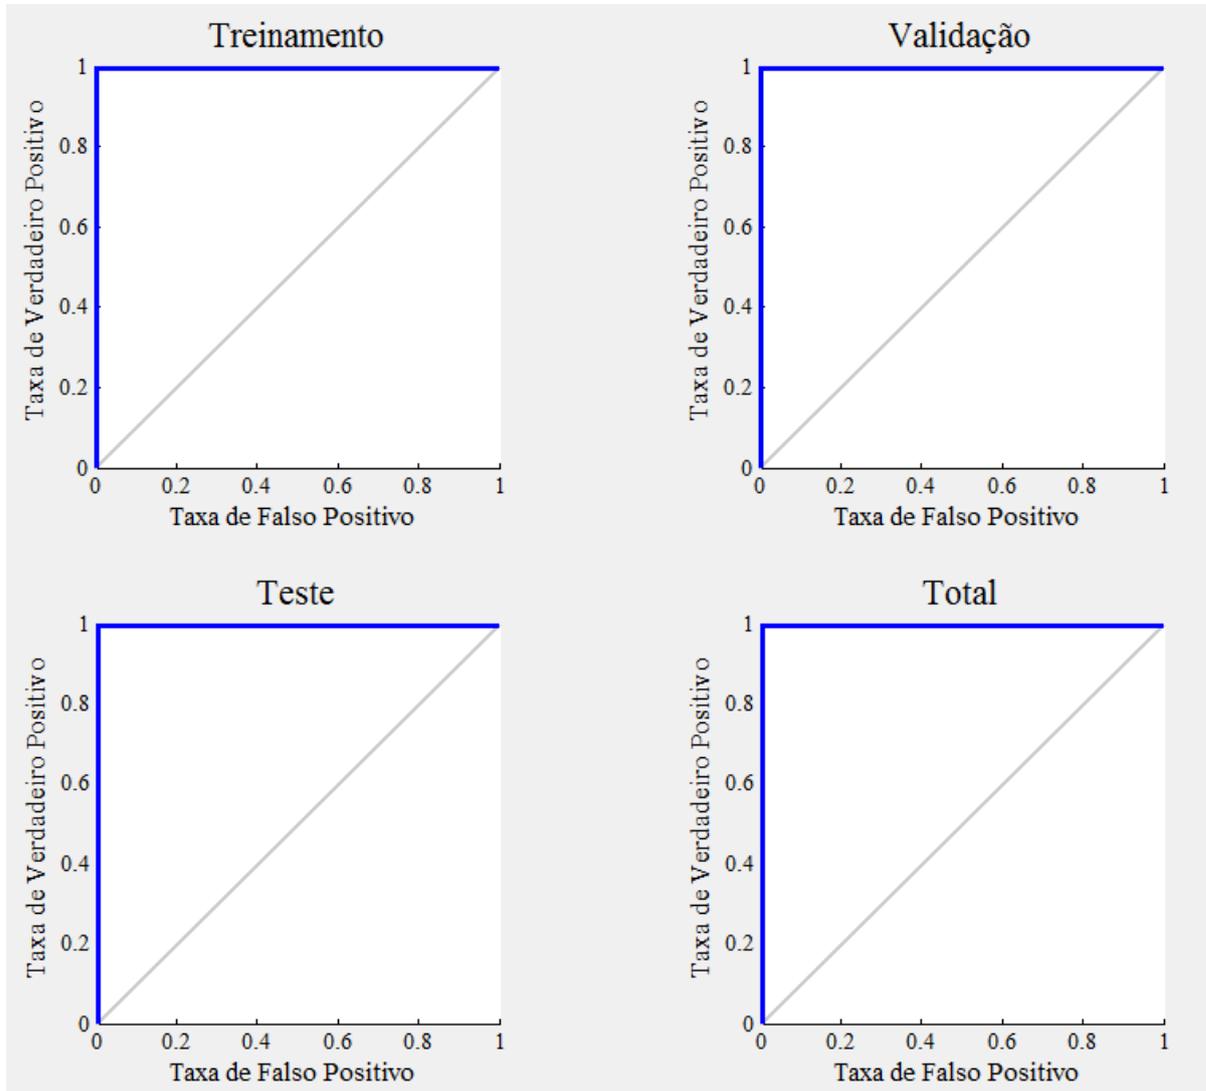
Como é possível notar na Tabela 6.11, tanto os erros calculados para o treinamento como para a validação e teste permaneceram baixos, o que indicou que o modelo teve uma boa capacidade de generalização na etapa de testes. Ainda, as matrizes de confusão de cada etapa da construção da RNA presentes na Figura 6.20 explicitaram como a seletividade, especificidade, precisão e acurácia dos modelos se apresentaram extremamente satisfatórios, pois indicaram 100% de acerto da rede na classificação de “flotou” e “não flotou”.

Figura 6.20. Matriz de confusão de resultados gerado pela RNA classificatória.



Outra maneira de analisar o desempenho da RNA classificatória foi através das curvas ROC. Quanto mais próxima a curva gerada acompanhar o eixo vertical esquerdo e o horizontal superior, melhor é a acurácia da rede construída. Dessa forma, como também mostrar os gráficos presente da Figura 6.21, a RNA criada apresentou ótimos resultados em todas as suas etapas de construção.

Figura 6.21. Curvas ROC para todas as etapas da construção da RNA classificatória.



Para se confirmar que a rede gerada não apresentou bons resultados apenas para os dados do treinamento, testes de performance adicionais foram executados e também apresentaram resultados extremamente satisfatórios. Após vários testes, foi possível obter um $MSE_{\text{médio}}$ de $1,9731 \times 10^{-7}$ e erro nulo. Assim, tanto a matriz de confusão (Figura 6.22) como a curva ROC (Figura 6.23) também apresentaram resultados iguais aos da etapa de construção da RNA, provando que a rede gerada apresentou alta capacidade preditiva para dados diferentes dos utilizados na sua criação.

Figura 6.22. Figura 33. Matriz de confusão de resultados do teste da RNA classificatória.

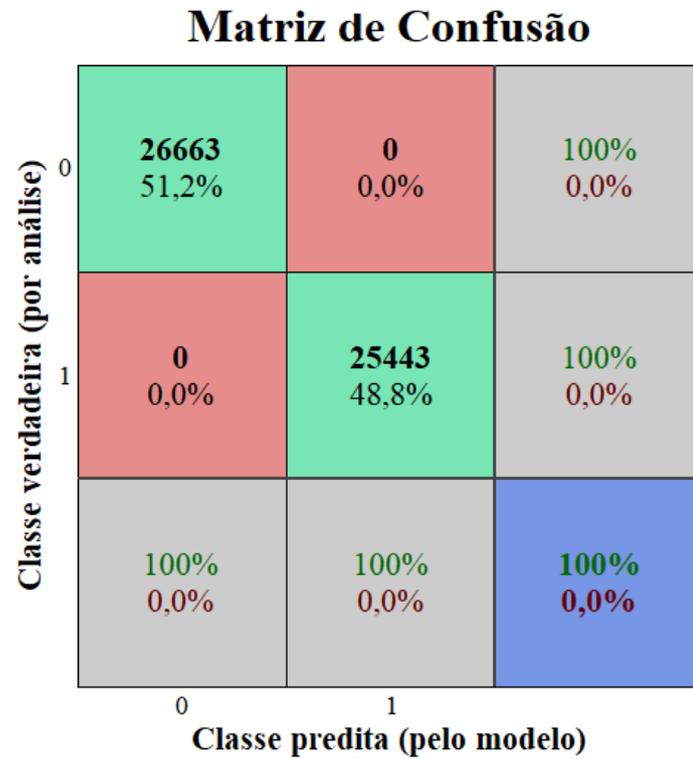
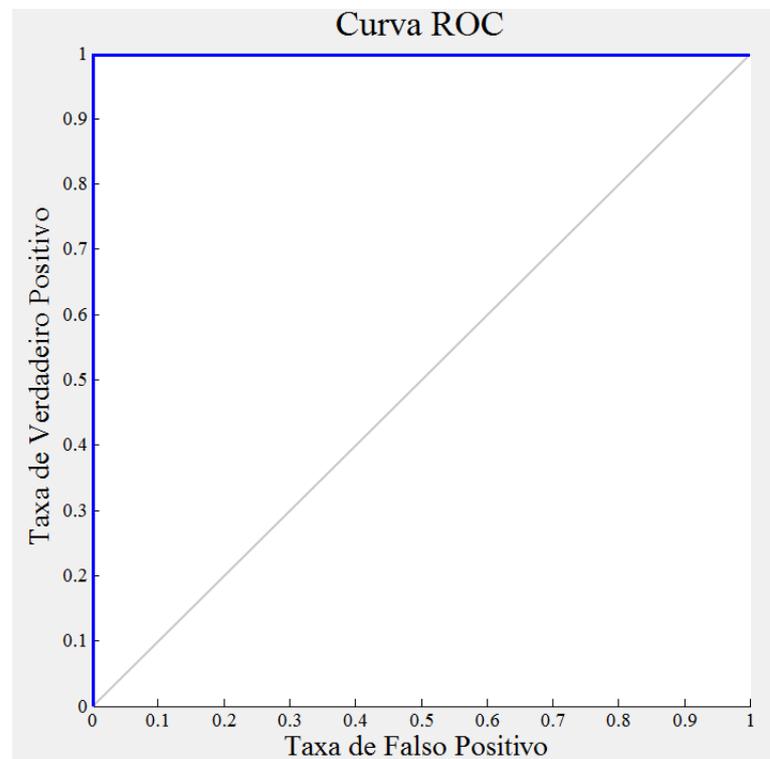


Figura 6.23. Curva ROC para o teste da RNA classificatória



Finalmente, foi possível perceber que os resultados encontrados para a análise da efetividade da etapa de flotação a partir da construção de uma RNA foram superiores aos encontrados através do modelo por regressão logística. Mais detalhes dessa rede criada (pesos de entrada, saída e bias) se encontram no Apêndice D – Detalhes da RNA para predição da flotação.

7 Considerações finais

Neste projeto uma planta de flotação por ar dissolvido (FAD) foi avaliada em diferentes condições de operação com o objetivo de adquirir mais informações e experiência no protótipo criado em um trabalho anterior e desenvolver novas tecnologias para tal processo. Devido à escassez de informações sobre o mesmo, uma série de experimentos foi realizada e um vasto banco de dados para novas configurações de operação foi criado. As variáveis de entrada escolhidas foram a pressão do vaso saturador, a vazão de floculante na entrada do tanque floculador, a razão de reciclo do efluente clarificado, vazão de água a ser tratada e a turbidez de entrada do efluente. Enquanto as de saída foram a turbidez removida pelo processo e a efetividade da etapa de flotação ou não. Logo antes do início dos experimentos, o primeiro objetivo específico foi alcançado, ou seja, as faixas de operação das variáveis manipuladas utilizadas no planejamento de experimentos precisaram ser definidas.

Visando permitir que os experimentos fossem realizados com mais precisão e praticidade, foram executadas alterações no protótipo a fim de atender as necessidades deste projeto, cumprindo, assim, com o segundo objetivo específico do trabalho. Dentre as alterações realizadas estão a instalação de bombas dosadoras de coagulante e floculante de maior precisão, a instalação de um agitador mecânico no tanque de água ser tratada para manter a turbidez de entrada constante e a instalação de um suporte no tanque pulmão de abastecimento do vaso saturador que permitisse seu abastecimento com água limpa de forma mais rápida e segura (em casos em que esse mesmo tanque, por algum problema, esvaziasse).

Para dar início aos experimentos na planta de FAD e atingir o terceiro objetivo específico (de definir a dosagem de coagulante e floculante necessária nos índices de turbidez que foram estudados), foi preciso realizar diversos *Jar tests*. Com isso, foi possível obter vários resultados de dosagens ideais, contribuindo tanto para o trabalho em questão como para nortear futuros projetos que também trabalharão com diferentes valores de turbidez de entrada. Concluiu-se que a razão de dosagem entre o aluminato de sódio a 1% de concentração v/v e o tanino SG a 2,5% de concentração v/v é de, aproximadamente, 0,8. Além disso, o pH de operação ótimo para o bom funcionamento do tanino variou na faixa de 8,1. Foi possível obter remoções de turbidez de até 98,8% apenas com a etapa de floculação.

A partir do banco de dados criado com os experimentos realizados, foi possível realizar diversos tipos de análises de resultados. Dentre elas, estão a geração de um modelo por regressão linear para prever a turbidez removida do processo, a criação de redes neurais

artificiais (RNA) para predição da remoção da turbidez do processo, a construção de um modelo por regressão logística para prever o sucesso da etapa de flotação e a geração de redes neurais artificiais classificatórias também para predição da flotação. Com essas análises, os objetivos gerais de desenvolver um modelo para turbidez removida em função das condições de operação e o de desenvolver uma ferramenta computacional para definir a efetividade da etapa de flotação também em função das condições de operação foram atingidos.

Antes da geração do modelo para remoção da turbidez por regressão linear, um planejamento de experimentos foi realizado para avaliar os efeitos das variáveis escolhidas para o trabalho. Assim, o último objetivo geral restante de investigar a influência das variáveis manipuladas de um sistema de FAD na variável resposta turbidez removida, foi alcançado. Foi possível concluir que a vazão de tanino é a variável de entrada com maior efeito na turbidez removida. Também se constatou que a vazão total de água a ser tratada é de extrema importância para remoção da turbidez, entretanto, a mesma apresenta efeito negativo. A turbidez de entrada vem como o próximo fator mais significativo. Os efeitos de interação significativos foram a pressão com a vazão total de entrada, a vazão de tanino com a vazão total e a vazão de tanino com a turbidez de entrada.

O modelo criado por regressão linear para a remoção da turbidez em função das variáveis de entrada apresentou R^2 de 0,67294 e a partir dos testes F foi possível concluir que ele é pouco preditivo e, conseqüentemente, não apresenta um bom desempenho. Para tentar obter resultados melhores na predição da remoção da turbidez, uma RNA foi proposta. Seus resultados se mostraram altamente satisfatórios, com uma grande capacidade de generalização e coeficientes de correlação superiores a 0,97, entretanto não foi capaz de prever casos extremos testados nos experimentos. Assim, as análises proporcionadas pelo Planejamento de Experimentos foram importantes para se ter uma noção da importância dos fatores escolhidos e os resultados da RNA se mostraram complementares nessa análise da predição da remoção da turbidez. Entretanto, para construção de modelos de predição ainda mais precisos é necessário que mais faixas de operação sejam exploradas.

O sucesso da etapa de flotação previsto pelo modelo de regressão logística possibilitou acúria de 82%. A partir desse modelo foi possível entender quais fatores influenciam a flotação de maneira mais efetiva através da avaliação dos valores dos seus coeficientes. Concluiu-se a pressão utilizada no vaso saturador e a vazão total de entrada são os fatores de maior peso na determinação do sucesso da etapa de flotação.

Os resultados da rede neural classificatória mostraram acurácia de 100% para os dados gerados nos ensaios. Essa excelente performance se dá pela alta capacidade de ajuste dos pesos pela etapa de treinamento e pela grande e diversa quantidade de dados fornecidos a mesma. Ao comparar esse resultado com o obtido pelo modelo de regressão logística, é possível explicar a pior performance desse último devido a sua maior simplicidade.

8 Conclusões

As conclusões desse trabalho foram:

- A razão entre o aluminato de sódio e tanino vale 0,8; o pH de operação flocculação está na faixa de 8,1 e foi possível obter remoções de turbidez de até 98,8% com etapa de flocculação;
- A vazão de tanino é a variável de entrada com maior efeito na turbidez removida;
- A RNA para turbidez removida apresentou alta capacidade de generalização;
- Para construir modelos de predição da turbidez removida mais precisos é necessário que mais faixas de operação sejam exploradas;
- A predição da flotação com regressão logística gerou resultados com 82% de acurácia. A pressão e vazão total de entrada são os fatores de maior peso na determinação do sucesso da flotação;
- A RNA para predição da flotação gerou resultados com 100% de acurácia. A alta capacidade de ajuste dos pesos na etapa de treinamento e grande quantidade de dados fornecidos podem justificar esse resultado.

8.1 Sugestões para trabalhos futuros

Os resultados obtidos na investigação da influência das variáveis manipuladas do sistema de FAD na turbidez removida e no sucesso da etapa de flotação foram promissores e instigam a realização de trabalhos futuros. Alguns desses trabalhos, inclusive, já foram iniciados.

- Testes utilizando outros efluentes e agentes coagulantes e flocculantes;
- Construção de modelos fenomenológicos para o tanque de flotação utilizando-se o AspenOne;
- Uso de técnicas de redes neurais para gerar modelos caixa-preta para predição da dosagem de flocculante e coagulante;
- Projeto de malha de controle do pH de flocculação atuando nas vazões de coagulantes e flocculante para padronizar as condições de flocculação;

- Uso de análise de imagens da zona de contato para avaliar a formação de microbolhas e, conseqüentemente, a eficiência da flotação.

9 Referências Bibliográficas

ADLAN, M. N.; PALANIANDY, P.; AZIZ, H. A. Optimization of coagulation and dissolved air flotation (DAF) treatment of semi-aerobic landfill leachate using response surface methodology (RSM). **Desalination**, v. 277, n. 1–3, p. 74–82, 2011. Elsevier B.V. Disponível em: <<http://dx.doi.org/10.1016/j.desal.2011.04.006>>. .

BARROS NETO, B. .; SCARMINIO, I. S. .; BRUNS, R. E. **Como fazer experimentos: Pesquisa e desenvolvimento na ciência e na indústria**. 2001.

BICKERTON, B. J. **Optimization of Dissolved Air Flotation for Drinking Water Treatment**, 2012. Dalhousie University.

CARVALHO, M. T.; DURÃO, F. Control of a flotation column using fuzzy logic inference. **Fuzzy Sets and Systems**, v. 125, n. 1, p. 121–133, 2002.

COUTINHO, W. **Emprego da flotação a ar dissolvido no tratamento de cursos d'água**, 2007. Universidade Federal de Minas Gerais.

COUTO, H.; FRANÇA, S.; BARBOSA, R. The use of DAF (dissolved air flotation) as an alternative treatment for red mud wastewater. **Impc 2014**, v. 430, p. 1–10, 2014.

CROSSLEY, I. A.; VALADE, M. T. A review of the technological developments of dissolved air flotation. **Journal of Water Supply: Research and Tchnology - AQUA**, v. 55.7-8, p. 479–491, 2006.

EDZWALD, J. K. Dissolved air flotation and me. **Water Research**, v. 44, n. 7, p. 2077–2106, 2010. Elsevier Ltd.

EDZWALD, J. K.; HAARHOFF, J. **Dissolved Air Flotation For Water Clarification**. 1 edition ed. McGraw-Hill Education, 2011.

EDZWALD, J. K.; TOBIASON, J. E.; PARENTO, L. M.; et al. Giardia and Cryptosporidium removals by clarification and filtration under challenge conditions. **Journal / American Water Works Association**, v. 92, n. 12, p. 70–84, 2000.

FONSECA, R. R. **Monitoramento e Controle Avançado Aplicados à Flotação por Ar Dissolvido**, 2017. Universidade Estadual de Campinas.

FONSECA, R. R.; THOMPSON, J. P.; FRANCO, I. C.; FLÁVIO, V. Automation and Control of a Dissolved Air Flotation Pilot Plant. , p. 3972–3977, 2017.

HAARHOFF, J. Dissolved air flotation: progress and prospects for drinking water treatment. **Journal of Water Supply: Research and Technology - Aqua**, v. 57, n. 8, p. 555 LP-567, 2008. Disponível em: <<http://aqua.iwaponline.com/content/57/8/555.abstract>>. .

HAMEED, Y. T.; IDRIS, A.; HUSSAIN, S. A.; ABDULLAH, N. A tannin-based agent for coagulation and flocculation of municipal wastewater: Chemical composition, performance assessment compared to Polyaluminum chloride, and application in a pilot plant. **Journal of Environmental Management**, v. 184, p. 494–503, 2016.

LABIDI, J.; PÈLACH, M. À.; TURON, X.; MUTJÉ, P. Predicting flotation efficiency using neural networks. **Chemical Engineering and Processing: Process Intensification**, v. 46, n. 4, p. 314–322, 2007.

ÖZACAR, M.; ŞENGİL, İ. A. Evaluation of tannin biopolymer as a coagulant aid for coagulation of colloidal particles. **Colloids and Surfaces A: Physicochemical and Engineering Aspects**, v. 229, n. 1, p. 85–96, 2003. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S092777570300462X>>. Acesso em: 7/4/2017.

REALI, M. A. P. **Avaliação de um sistema original compacto para clarificação de águas de abastecimento utilizando o processo de flotação e filtração com taxa declinante**, 1991. Universidade de São Paulo, São Carlos.

RUBIO, J.; SOUZA, M. L.; SMITH, R. W. Overview of flotation as a wastewater treatment technique. **Minerals Engineering**, v. 15, n. 3, p. 139–155, 2002.

SÁNCHEZ-MARTÍN, J.; BELTRÁN-HEREDIA, J.; SOLERA-HERNÁNDEZ, C. Surface water and wastewater treatment using a new tannin-based coagulant. Pilot plant trials. **Journal of Environmental Management**, v. 91, n. 10, p. 2051–2058, 2010. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.jenvman.2010.05.013>>. .

SHEAN, B. J.; CILLIERS, J. J. A review of froth flotation control. **International Journal of Mineral Processing**, v. 100, n. 3–4, p. 57–71, 2011.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais Artificiais Para Engenharia e Ciências Aplicadas - Fundamentos Teóricos e Aspectos Práticos**. 2^a ed. São Paulo: Artliber Editora Ltda, 2010.

SOUZA, C. Análise de Poder Discriminativo Através de Curvas ROC. Disponível em:

<<http://crsouza.com/2009/07/13/analise-de-poder-discriminativo-atraves-de-curvas-roc/>>.

Acesso em: 12/12/2017.

THOMPSON JR, J. P. **Investigação da flotação por ar dissolvido no tratamento de efluente de lavanderia industrial utilizando coagulante de fonte renovável: Tanino**, 2013. Universidade Federal de Uberlândia.

ZABEL, T. The Advantages of Dissolved-air Flotation for Water Treatment. **American Water Works Association**, v. 77, n. 5, p. 42–46, 1985.

ZHANG, Q.; STANLEY, S. J. Real-time water treatment process control with artificial neural networks. **Journal of Environmental Engineering**, v. 125, n. 2, p. 153–160, 1999.

Apêndice A – Detalhes da Planta de FAD

Figura A. 1. Diagrama de blocos representando as etapas da planta piloto de FAD.

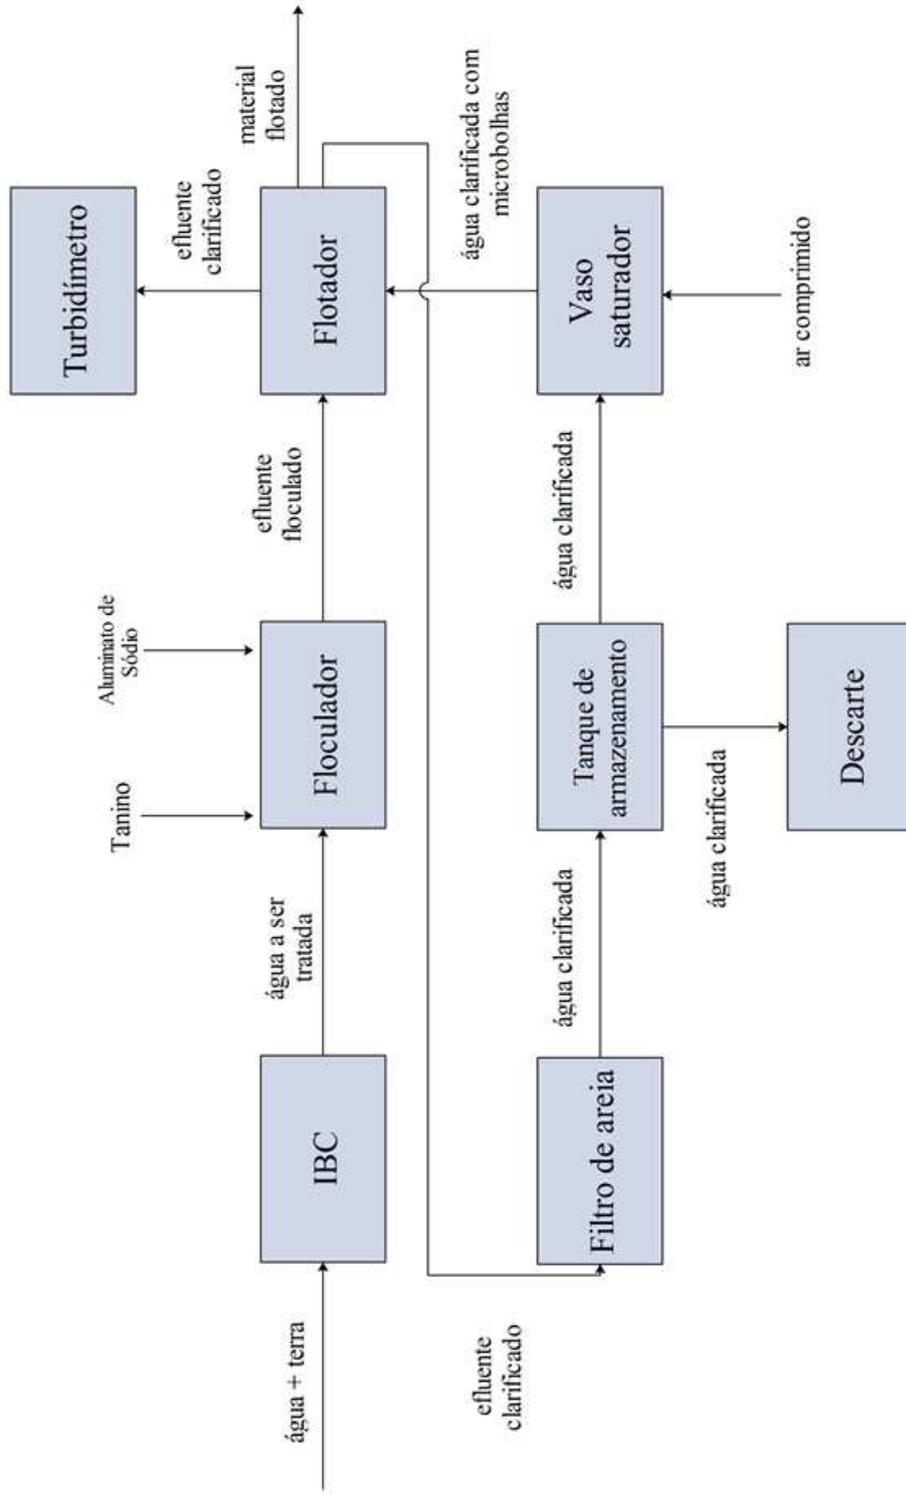
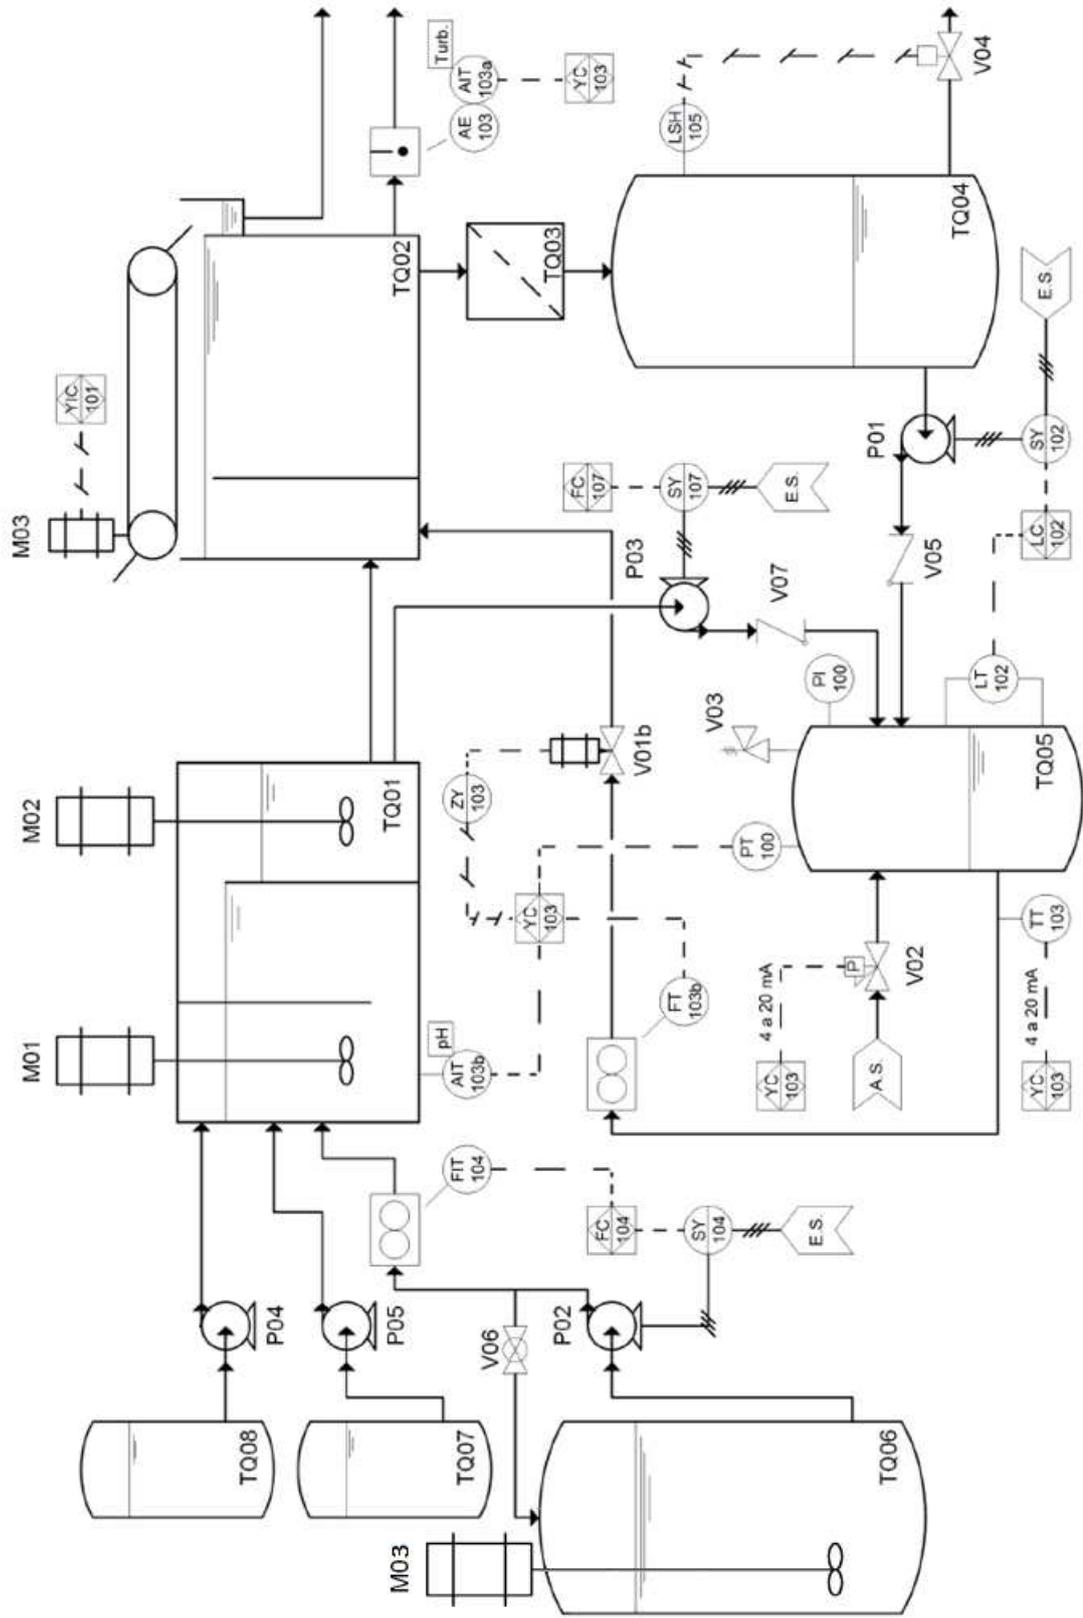


Figura A. 2. Diagrama P&ID do protótipo de FAD.



Fonte: adaptado de Fonseca (2017).

Apêndice B – Dados dos *Jar tests*

5 NTU							
Data	12/04/2017						
Volume (mL)	500						
Turbidez (NTU)	4.55	Ensaio					
Reagentes	% v/v	1	2	3	4	5	6
		mL	mL	mL	mL	mL	mL
<i>NaAlO₂</i>	2	0,5	0,5	0,5	0,5	0,5	0,5
Tanino	5	0,2	0,4	0,6	0,8	0,4	0,6
pH (coagulação)		7,8	7,8	7,9	7,9	7,8	7,9
pH (floculação)		7,7	7,7	7,8	7,4	7,7	7,8
Turbidez (NTU)		4,36	9,19	5,11	3,39	6,02	6,07
Data	18/04/2017						
Volume (mL)	500						
Turbidez (NTU)	5	Ensaio					
Reagentes	% v/v	1	2	3	4	5	6
		mL	mL	mL	mL	mL	mL
<i>NaAlO₂</i>	2	0,5	0,5	0,5	0,5	0,5	0,5
Tanino	5	0,2	0,4	0,6	0,8	1	1,2
pH (coagulação)		7,7	7,7	7,7	7,7	7,7	7,7
pH (floculação)		7,8	7,8	7,7	7,8	7,7	7,6
Turbidez (NTU)		5,25	1,42	1,29	1,24	9,04	8,62
Data	18/04/2017						
Volume (mL)	500						
Turbidez (NTU)	5	Ensaio					
Reagentes	% v/v	1	2	3	4	5	6
		mL	mL	mL	mL	mL	mL
<i>NaAlO₂</i>	2	0,2	0,4	0,5	0,6	0,8	1
Tanino	5	0,6	0,6	0,6	0,6	0,6	0,6
pH (coagulação)		7,3	7,4	7,5	7,6	7,8	7,8
pH (floculação)		7,8	7,7	7,7	7,8	7,8	7,7
Turbidez (NTU)		7,88	2,54	1,62	2,33	1,7	1,72

32,5 NTU							
Data	25/04/2017						
Volume (mL)	500						
Turbidez (NTU)	32,5						
		Ensaio					
Reagentes	% v/v	1	2	3	4	5	6
		mL	mL	mL	mL	mL	mL
$NaAlO_2$	2	1	1	1	1	1	1
Tanino	5	0,2	0,5	1	1,5	2	2,5
pH (coagulação)		8,3	8,2	8,2	8,2	8,2	8,2
pH (floculação)		8,2	8	7,8	7,6	7,6	7,5
Turbidez (NTU)		26,6	4,37	1,9	1,82	12,5	31
Data	25/04/2017						
Volume (mL)	500						
Turbidez (NTU)	32,5						
		Ensaio					
Reagentes	% v/v	1	2	3	4	5	6
		mL	mL	mL	mL	mL	mL
$NaAlO_2$	2	1	1	1	1	1	1
Tanino	5	1	1,1	1,2	1,3	1,4	1,5
pH (coagulação)		8	8,1	8,1	8,1	8,1	8,1
pH (floculação)		7,8	7,7	7,8	7,7	7,7	7,7
Turbidez (NTU)		1,57	1,35	1,13	1,24	1,64	1,66
Data	25/04/2017						
Volume (mL)	500						
Turbidez (NTU)	32,5						
		Ensaio					
Reagentes	% v/v	1	2	3	4	5	6
		mL	mL	mL	mL	mL	mL
$NaAlO_2$	2	0,9	1	1,1	1,2	1,3	
Tanino	5	1,2	1,2	1,2	1,2	1,2	
pH (coagulação)		7,7	7,9	8	8,1	8,2	
pH (floculação)		7,7	7,7	7,7	7,6	7,7	
Turbidez (NTU)		2,39	1,94	1,99	2,23	2,32	

52,5 NTU							
Data	20/04/2017						
Volume (mL)	500						
Turbidez (NTU)	52,5						
				Ensaio			
Reagentes	% v/v	1	2	3	4	5	6
		mL	mL	mL	mL	mL	mL
<i>NaAlO₂</i>	2	1,5	1,5	1,5	1,5	1,5	1,5
Tanino	5	1	1,2	1,4	1,6	1,8	2
pH (coagulação)		8,6	8,7	8,6	8,6	8,6	8,7
pH (floculação)		8	7,9	8	8	7,9	7,9
Turbidez (NTU)		4,99	3,54	3,41	3,08	3,43	3,33
Data	20/04/2017						
Volume (mL)	500						
Turbidez (NTU)	52,5						
				Ensaio			
Reagentes	% v/v	1	2	3	4	5	6
		mL	mL	mL	mL	mL	mL
<i>NaAlO₂</i>	2	1,3	1,4	1,5	1,6	1,7	1,8
Tanino	5	1,6	1,6	1,6	1,6	1,6	1,6
pH (coagulação)		8,4	8,4	8,5	8,7	8,9	8,9
pH (floculação)		8	8	8,1	8,1	8,2	8,2
Turbidez (NTU)		2,13	2,05	2,39	2,7	2,77	2,79

72,5 NTU									
Data	26/04/2017								
Volume (mL)	500								
Turbidez (NTU)	73								
		Ensaio							
Reagentes	% v/v	1	2	3	4	5	6		
		mL	mL	mL	mL	mL	mL		
<i>NaAlO₂</i>	2	1,5	1,5	1,5	1,5	1,5	1,5		
Tanino	5	1,4	1,5	1,6	1,7	1,8	1,9		
pH (coagulação)		8,6	8,7	8,6	8,5	8,7	8,6		
pH (floculação)		7,3	7,5	7,6	7,7	7,7	7,7		
Turbidez (NTU)		2,87	3,35	4,61	3,46	3,11	2,84		
Data	26/04/2017								
Volume (mL)	500								
Turbidez (NTU)	72,5								
		Ensaio							
Reagentes	% v/v	1	2	3	4	5	6		
		mL	mL	mL	mL	mL	mL		
<i>NaAlO₂</i>	2	1,4	1,5	1,6	1,7	1,8	1,9		
Tanino	5	1,9	1,9	1,9	1,9	1,9	1,9		
pH (coagulação)		8,2	8,3	8,4	8,5	8,6	8,7		
pH (floculação)		7,8	7,9	7,9	8	8	8,1		
Turbidez (NTU)		1,97	2,06	2,2	2,44	2,8	2,38		
Data	26/04/2017								
Volume (mL)	500								
Turbidez (NTU)	73								
		Ensaio							
Reagentes	% v/v	1	2	3	4	5	6	7	8
		mL	mL	mL	mL	mL	mL	mL	mL
<i>NaAlO₂</i>	2	1,4	1,4	1,4	1,4	1,4	1,4	1,4	1,4
Tanino	5	1,3	1,4	1,5	1,6	1,7	1,8	1,9	2
pH (coagulação)		8,6	8,6	8,5	8,5	8,6	8,6	8,5	8,5
pH (floculação)		7,7	7,8	7,8	7,9	7,9	7,9	8	8
Turbidez (NTU)		3,47	3,22	3,16	3,23	2,76	2,75	4,27	4,37
Data	26/04/2017								
Volume (mL)	500								
Turbidez (NTU)	73								
		Ensaio							
Reagentes	% v/v	1	2	3	4	5	6		
		mL	mL	mL	mL	mL	mL		
<i>NaAlO₂</i>	2	1,4	1,5	1,6	1,7	1,8	1,9		
Tanino	5	1,8	1,8	1,8	1,8	1,8	1,8		
pH (coagulação)		8,3	8,5	8,6	8,7	8,8	8,9		
pH (floculação)		8	8	8,1	8,1	8,2	8,2		
Turbidez (NTU)		4,57	4,35	4,66	5,55	5,53	5,77		

100,1 NTU								
Data	06/04/2017							
Volume (mL)	500							
Turbidez (NTU)	100							
pH	8.2							
					Ensaio			
Reagentes	% v/v	1	2	3	4	5	6	7
		mL	mL	mL	mL	mL	mL	mL
$NaAlO_2$	2	2	2	2	2	2	2	2
Tanino	5	2	3	4	5	2	3	4
pH (coagulação)		8.8	9.1	9.1	9	9	9	9
pH (floculação)		8.6	8.5	8.4	8.5	8.7	8.6	8.5
Turbidez (NTU)		8.2	3.83	11	12.1	14.8	1.38	5.41
Data	06/04/2017							
Volume (mL)	500							
Turbidez (NTU)	100							
pH	8.1							
					Ensaio			
Reagentes	% v/v	1	2	3	4			
		mL	mL	mL	mL			
$NaAlO_2$	2	1	2	3	4			
Tanino	5	3	3	3	3			
pH (coagulação)		8.4	8.8	9.1	9.6			
pH (floculação)		7.9	8.4	8.7	9.1			
Turbidez (NTU)		37.7	3.96	9.4	14.7			
Data	10/04/2017							
Volume (mL)	500							
Turbidez (NTU)	100.1							
pH	7.7							
					Ensaio			
Reagentes	% v/v	1	2	3	4	5	6	
		mL	mL	mL	mL	mL	mL	
$NaAlO_2$	2	2	2	2	2	2	2	
Tanino	5	2	2.2	2.4	2.6	2.8	3	
pH (coagulação)		8.9	9	8.8	9.1	8.8	9.1	
pH (floculação)		8.2	8.6	8.4	8.5	8.4	8.5	
Turbidez (NTU)		2.39	2.34	1.13	1.89	1.48	3.25	
Data	10/04/2017							
Volume (mL)	500							
Turbidez (NTU)	101							
pH	7.8							
					Ensaio			
Reagentes	% v/v	1	2	3	4			
		mL	mL	mL	mL			
$NaAlO_2$	2	2	2.2	2.4	2.6			
Tanino	5	2.4	2.4	2.4	2.4			
pH (coagulação)		9.1	9.2	9.3	9.5			

pH (floculação)	8.5	8.8	8.7	9
Turbidez (NTU)	2.4	1.65	3.63	6.46

Apêndice C – Detalhes da RNA para predição da turbidez removida

Pesos da camada de entrada					
Neurônios	P	Q_{tanino}	R	Q_{total}	NTU_e
1	-0,40078	2,284165	1,696948	-1,22384	4,786199
2	7,647454	-6,57215	4,54594	-3,65571	6,021465
3	-10,1724	-9,19266	11,46258	-8,19644	-2,33639
4	-0,37518	0,071628	0,096497	-0,57161	2,433916
5	1,715281	6,052088	-19,5102	0,889357	14,30268
6	5,940704	-8,82127	13,40408	-7,26746	-6,05721
7	-0,58451	2,519856	-1,15599	-0,79714	1,694232
8	-0,45551	0,174528	0,190369	-0,38359	2,205362
9	-2,79581	-2,12248	2,189249	0,447917	0,624712
10	-11,0348	3,79948	-2,94028	-19,13	0,531127

Pesos da camada de saída										
Neurônios	1	2	3	4	5	6	7	8	9	10
	0.812607	0.10791	-0,03097	-3,49654	0,077957	0,058028	-0,3136	3,672827	-0,29351	0,198594

Camadas intermediárias		Camada de saída
Neurônios	Bias	Bias
1	5,67246	
2	-13,8376	
3	7,067573	0,0109
4	-1,25321	

5	-6,05286
6	-8,21008
7	-1,18355
8	-1,11011
9	-1,43608
10	-9,16083

Apêndice D – Detalhes da RNA para predição da flotação

Pesos da camada de entrada					
Neurônios	P	Q_{tanino}	R	Q_{total}	NTU_e
1	-0,84946	0,751869	-1,2845	-0,67125	-1,2375
2	-2,655	1,810434	3,90984	1,877167	0,413022
3	3,155083	-0,74235	-0,10293	1,305261	-4,443
4	2,932422	4,223469	-2,77198	-0,23798	1,606166
5	-3,05782	1,739878	1,753892	-0,49388	1,339703

Pesos da camada de saída					
Neurônios	1	2	3	4	5
	-2,17999	5,093221	4,943404	4,9159	-5,372

Neurônios	Bias
1	2,032955
2	2,85448
3	3,607104
4	2,607264
5	2,885535