

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
TECNOLOGIA EM GESTÃO AMBIENTAL**

ANDRÉ HOFFMANN PINTO

**DESENVOLVIMENTO DE UM MODELO EM REDES NEURAS
ARTIFICIAIS PARA CONTROLE DE UM REATOR DE FLUXO
CONTÍNUO DESTINADO A ELETROFLOCULAÇÃO DE EFLUENTE
DE MATADOURO E FRIGORÍFICO DE SUÍNOS**

TRABALHO DE CONCLUSÃO DE CURSO

MEDIANEIRA

2016

ANDRÉ HOFFMANN PINTO

**DESENVOLVIMENTO DE UM MODELO EM REDES NEURAIAS
ARTIFICIAIS PARA CONTROLE DE UM REATOR DE FLUXO
CONTÍNUO DESTINADO A ELETROFLOCULAÇÃO DE EFLUENTE
DE MATADOURO E FRIGORÍFICO DE SUÍNOS**

Trabalho de Conclusão de Curso
apresentado como requisito parcial à
obtenção do título de Tecnólogo em
Gestão Ambiental, da Universidade
Tecnológica Federal do Paraná.

Orientador: Prof. Me. Fábio Orssatto.

MEDIANEIRA

2016



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Câmpus Medianeira
Diretoria de Graduação e Educação Profissional
Coordenação do Curso de Tecnologia em Gestão
Ambiental



TERMO DE APROVAÇÃO

DESENVOLVIMENTO DE UM MODELO EM REDES NEURAIS ARTIFICIAIS PARA
CONTROLE DE UM REATOR DE FLUXO CONTÍNUO DESTINADO A
ELETROFLOCULAÇÃO DE EFLUENTE DE MATADOURO E FRIGORÍFICO DE
SUÍNOS

por

ANDRÉ HOFFMANN PINTO

Este Trabalho de Conclusão de Curso (TCC) foi apresentado às 18h40min do dia 24 de novembro de 2016, como requisito parcial para a obtenção do título de TECNÓLOGO em Gestão Ambiental. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Me. Fábio Orssatto
Orientador

Prof. Dr. Eduardo Eyng
Membro titular

Prof. Dr. Laercio Mantovani Frare
Membro titular

- O Termo de Aprovação assinado encontra-se na Coordenação do Curso

AGRADECIMENTOS

A Deus pelo dom da vida, pela fé e perseverança para vencer os obstáculos.

Aos meus pais, pela orientação, dedicação e incentivo nessa fase do curso de graduação e durante toda minha vida.

Há minha esposa Maritssani e filhas, Karoline, Karine, Adryelly e Dalila, as quais tiveram muita paciência e compreensão comigo, pois tive que privá-las de atenção e momentos de lazer devido às horas de dedicação para concluir essa graduação.

Ao meu orientador e amigo professor Me. Fábio Orssatto pelas orientações ao longo do desenvolvimento da pesquisa.

Agradeço aos professores do curso de tecnologia em Gestão Ambiental, Campus Medianeira.

Agradeço aos colegas e amigos que fiz durante essa caminhada.

Enfim, sou grato a todos que contribuíram de forma direta ou indireta para realização deste trabalho.

“Olhe fundo na natureza, e então você entenderá tudo melhor.”

Albert Einstein.

RESUMO

PINTO, André Hoffmann. **Desenvolvimento de um modelo em redes neurais artificiais para controle de um reator de fluxo contínuo destinado a eletrofloculação de efluente de matadouro e frigorífico de suínos.** 2016. 41 folhas. Trabalho de Conclusão de Curso (Tecnologia em Gestão Ambiental) - Universidade Tecnológica Federal do Paraná. Medianeira, 2016.

O processamento de carne empregado em matadouros e frigoríficos gera uma grande quantidade de efluentes os quais são constituídos de proteína, gordura, sais, entre outras substâncias. Dessa maneira, este rejeito possui alto grau poluidor com elevados teores de matéria orgânica, óleos e graxas, nutrientes e sólidos totais. Para evitar problemas ambientais e sociais, as indústrias que abatem e industrializam a carne de animais tratam seus efluentes, diminuindo assim sua carga poluidora a fim de atender a legislação ambiental. Os sistemas convencionais para tratamento desse efluente são considerados eficientes, entretanto essas estações de tratamento ocupam grandes áreas e podem causar maus odores, causando desconforto à circunvizinhança da empresa. Uma tecnologia que utiliza uma pequena área para tratar grandes volumes de efluentes e não gera odor é a eletrofloculação. Também conhecida como eletrocoagulação e eletroflotação, essa técnica se baseia na utilização de corrente elétrica envolvendo reatores eletroquímicos, nos quais são gerados coagulantes *in situ*, por oxidação eletrolítica de um material apropriado no ânodo. Como todo processo para obter bons resultados é necessário que seja controlado, o objetivo desse trabalho foi implementar um controle baseado em Redes Neurais Artificiais (RNA's) em um sistema de tratamento de efluente de matadouro e frigorífico por meio da eletrofloculação em reator de fluxo contínuo. A escolha do Delineamento Composto Central Rotacional (DCCR) deu-se por abranger o espaço experimental utilizando um número reduzido de ensaios. A partir desse delineamento foram executados 11 ensaios para análise estatística a qual validou o modelo matemático gerado. Com base nesse modelo foram gerados os bancos de dados de treinamento e validação da RNA que foi implementada no software *Matlab*. Testes empíricos definiram a arquitetura da RNA baseado no desempenho do treinamento com a configuração 2 camadas sendo 1 oculta com 11 neurônios e 1 na camada de saída. O controle foi do tipo *feedforward*, mas devido à impossibilidade de leitura de turbidez *in line* a ação *feedback* foi fornecida pelo modelo matemático preditivo. A predição obtida para a variável controlada fornecida pela RNA comparada com a fornecida pelo modelo matemático empírico mostrou-se eficiente fornecendo valores com erros considerados baixos para esse tipo de experimento que variaram entre 0,0043 A e 0,5418 A com um valor médio de 0,1227 A os quais demonstraram a validade dessa ferramenta computacional em controlar processos.

Palavras chave: Eletrofloculação. Controle de processos. Redes neurais artificiais.

ABSTRACT

PINTO, André Hoffmann. **Development of a model in artificial neural networks for control of a continuous flow reactor intended for eletrofloculation of effluent of slaughterhouses and refrigerator.** 2016. 41 folhas. Trabalho de Conclusão de Curso (Tecnologia em Gestão Ambiental) - Universidade Tecnológica Federal do Paraná. Medianeira, 2016.

The processing of meat used in slaughterhouses and refrigerator generates a great amount of effluents which are constituted of protein, fat, salts, among other substances. Thus, this waste has a high pollutant degree with high organic matter content, oils and greases, nutrients and total solids. To avoid environmental and social problems, industries that slaughter and industrialize animal meat treat their effluents, thereby reducing their pollutant burden and complying with environmental legislation. Conventional systems for treatment of this effluent are considered efficient, however these treatment plants occupy large areas and can cause bad smells, causing discomfort to the surrounding area. One technology that uses a small area to treat large volumes of effluents and does not generate odor is electro-flocculation. Also known as electrocoagulation and electroflotation, this technique is based on the use of electric current involving electrochemical reactors, in which coagulants are generated in situ by electrolytic oxidation of an appropriate material at the anode. As the whole process to obtain good results is necessary to be controlled, the objective of this work was to implement a control based on Artificial Neural Networks (ANN) in a slaughterhouse and refrigerator effluent treatment system by means of electro-flocculation in a continuous flow reactor. The choice of Central Composite Rotational Design (CCRD) was to cover the entire experimental space using a smaller number of tests. From this design were carried out 11 tests for statistical analysis which validated the mathematical model generated. Based on this model, the ANN training and validation databases that were implemented in *Matlab* software were generated. Empirical tests defined the ANN architecture based on training performance with the 2-layer configuration being 1 hidden with 11 neurons and 1 in the output layer. The control used feedforward type, but due to the impossibility of reading in-line turbidity the feedback action was provided by the predictive mathematical model. The prediction obtained for the controlled variable provided by ANN compared to that provided by the empirical mathematical model proved to be efficient providing values with errors considered low for this type of experiment that ranged from 0.0043 A to 0.5418 A with a average value of 0.1277 A which demonstrated the validity of this computational tool in controlling processes

Keywords: Electroflocculation. Process control. Artificial Neural Networks.

LISTA DE TABELAS

Tabela 1 - Valores reais correspondentes aos codificados (variáveis em estudo)	22
Tabela 2- Número de ensaios com os valores codificados e reais.....	23
Tabela 3- Variáveis de Entrada e Saída do Controlador RNA.	24
Tabela 4 - Matriz do delineamento experimental, valores codificados e reais.	30
Tabela 5 - Estatística descritiva da eficiência de remoção de turbidez.	30
Tabela 6 - Coeficientes de regressão para a variável resposta remoção de turbidez.	31
Tabela 7 - ANOVA para a remoção de turbidez.	31
Tabela 8- Testes para escolha da arquitetura da RNA.	33
Tabela 9 -Valores de respostas do modelo matemático e da RNA frente às perturbações	35

SUMÁRIO

1 INTRODUÇÃO	10
2 OBJETIVOS	12
2.1 OBJETIVO GERAL	12
2.2 OBJETIVOS ESPECÍFICOS	12
3 REVISÃO BIBLIOGRÁFICA	13
3.1 GERAÇÃO DO EFLUENTE DE MATADOURO E FRIGORÍFICO	13
3.2 CARACTERÍSTICAS DO EFLUENTE	13
3.3 IMPACTOS CAUSADOS PELO LANÇAMENTO DO EFLUENTE	14
3.4 CONTROLE DE PROCESSOS	14
3.4.1 Redes Neurais Artificiais (RNA's)	15
3.4.2 Treinamento da RNA	16
3.4.2.1 Algoritmo da retropropagação - (<i>backpropagation</i>)	17
3.4.2.2 Redes neurais no tratamento de efluentes	18
3.5 ARQUITETURA DA REDE NEURAL	19
4 MATERIAL E MÉTODOS	20
4.1 EFLUENTE DE FRIGORÍFICO E MATADOURO DE SUÍNO	20
4.2 MÓDULO DE TRATAMENTO	20
4.2.1 Codificação dos valores reais da matriz experimental.	22
4.2.2 Procedimentos dos ensaios	23
4.3 ESTRATÉGIA DE CONTROLE	23
4.3.1 Classificação do problema a ser estudado	24
4.4 VARIÁVEIS DO SISTEMA DE CONTROLE	24
4.4.1 Dinâmica do controle e suas variáveis	25
4.5 DESENVOLVIMENTO DA REDE NEURAL ARTIFICIAL PARA CONTROLE DO SISTEMA	25
4.5.1 Bancos de dados de treinamento e validação da RNA	26
4.5.2.1 Software utilizado	27
4.5.2.2 Tipo de RNA utilizada	27
5 RESULTADOS E DISCUSSÃO	29
5.1 ENSAIOS DA MATRIZ DO DELINEAMENTO EXPERIMENTAL	29
5.2. ANÁLISE ESTATÍSTICA.	30
5.3 IMPLEMENTAÇÃO E TREINAMENTO DA RNA	32
5.3.1 Bancos de dados de treinamento e validação da RNA	32
5.3.2 Testes para escolha da arquitetura da RNA	32
6 CONSIDERAÇÕES FINAIS	37
7 REFERÊNCIAS	38

1 INTRODUÇÃO

Os matadouros e frigoríficos de suínos geram uma grande quantidade de efluentes os quais são constituídos de proteína, gordura, sais, entre outras substâncias. Dessa maneira, este rejeito possui alto grau poluidor com elevados teores de matéria orgânica, óleos e graxas, nutrientes e sólidos totais.

Várias são as tecnologias aplicadas ao tratamento desses efluentes. No Brasil é costume utilizar sistemas de lagoas para tal, entretanto essas estações de tratamento ocupam grandes áreas e podem causar maus odores, causando desconforto a circunvizinhança da empresa.

Uma tecnologia que utiliza uma pequena área para tratar grandes volumes de efluentes e não gera odor é a eletrofloculação.

Também conhecida como eletrocoagulação e eletroflotação, essa técnica se baseia na utilização de corrente elétrica envolvendo reatores eletroquímicos, nos quais são gerados coagulantes *in situ*, por oxidação eletrolítica de um material apropriado no ânodo. Geralmente, na região anódica emprega-se ferro ou alumínio, pois são materiais de baixo custo, eficazes e prontamente disponíveis no mercado. A geração de íons metálicos ocorre no ânodo, enquanto que a de gás hidrogênio ocorre no cátodo (GOBBI, 2013).

Segundo CRESPILO e REZENDE (2004) a eletrofloculação ocorre em quatro etapas: a geração eletroquímica do agente coagulante, a eletrocoagulação, eletrofloculação e a flotação das impurezas.

A geração eletroquímica do agente coagulante ocorre a partir da dissolução do ânodo de eletrodos de alumínio submetido a uma corrente elétrica obtida (CERQUEIRA et al, 2011). Além da corrente elétrica, outros fatores devem ser considerados como a condutividade da solução, a resistividade do meio e o potencial aplicado entre os eletrodos. De modo geral, todos esses fatores estão relacionados entre si, e, uma vez controlados, a geração do agente coagulante passa a ser monitorada pela corrente obtida (CRESPILO & REZENDE, 2004).

Na eletrocoagulação, o material de carga positiva pode reagir com as cargas negativas da solução, ocorrendo à hidrólise que libera hidróxido de alumínio, responsável pelo tratamento do efluente submetido ao processo (BRITO et al, 2012).

Neste contexto, Ciardelli e Ranieri (2001) mostraram que a eletrofloculação pode ser um método promissor no processo de reciclagem da água, uma vez que

combina a oxidação parcial do poluente, por via eletrolítica, com a precipitação físico-química ou eletroquímica do lodo.

Como a eletrofloculação é um método de tratamento de águas residuárias que faz uso de corrente elétrica, é notório que essa corrente aplicada aos eletrodos de sacrifício deva ser controlada para que não haja desperdício energético. Nesse sentido as Redes Neurais Artificiais (RNAs) demonstram ao longo de estudos serem uma ferramenta cada vez mais utilizada no auxílio do controle de processos.

De acordo com Eyng (2008) como alguns sistemas de tratamento podem ser caracterizados por relações não-lineares entre suas variáveis, as RNA's superam o controle Proporcional Integral Derivativo (PID) e tornam-se uma opção atrativa, pois possuem características não lineares inerentes ao mapeamento entre as camadas de RNAs *feedforward* tornando-se uma poderosa ferramenta para controle visto a atual capacidade de processamento computacional.

O estudo sobre a eletrofloculação e o controle de processos via RNA servirão para assegurar que as perdas serão minimizadas e a eficiência de tratamento garantida. Por isso faz-se necessário um controle no processo tendo em vista minimizar as perdas decorrentes das oscilações nas cargas afluentes.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Implementar um controle baseado em Redes Neurais Artificiais (RNA's) para controlar um sistema de tratamento por eletrofloculação para redução do parâmetro Turbidez (T) de um efluente de matadouro e frigorífico de suínos.

2.2 OBJETIVOS ESPECÍFICOS

Elaborar um programa computacional destinado ao controle via RNA, do sistema de tratamento.

Avaliar o desempenho do controlador frente a perturbações no tempo de detenção hidráulica (TDH).

3 REVISÃO BIBLIOGRÁFICA

3.1 GERAÇÃO DO EFLUENTE DE MATADOURO E FRIGORÍFICO

Em frigoríficos, assim como em vários tipos de indústrias, o alto consumo de água acarreta grandes volumes de efluentes - 80 a 95% da água consumida é descarregada como efluente líquido (UNEP; DEPA; COWI, 2000).

Para Mees et al. (2009) diferentes setores industriais geram mensalmente, grandes volumes de efluentes líquidos. As agroindústrias estão entre as maiores fontes poluidoras do Brasil, isto em função das grandes quantidades de resíduos ricos em substâncias orgânicas, nutrientes sólidos (sobretudo nitrogênio e fósforo) e óleos e graxas.

O setor cárneo nacional, após alto investimento nos elos da cadeia produtiva, sofreu acelerada expansão na criação e conseqüentemente no aumento do despejo de resíduos provenientes das indústrias de processamento de carne (PACHECO, 2008).

3.2 CARACTERÍSTICAS DO EFLUENTE

Para Aguilar (2002) o efluente dos matadouros possui uma grande carga de sólidos em suspensão, nitrogênio orgânico, com uma Demanda Bioquímica de Oxigênio (DBO) em torno de 4.200 mg.L^{-1} dependendo do sistema de abate.

Estes efluentes de matadouro animal caracterizam-se principalmente por:

Alta carga orgânica, alto teor de gordura, flutuações de pH em função do uso de agentes de limpeza ácidos e básicos, altos conteúdos de nitrogênio, fósforo e sal e flutuações de temperatura (uso de água quente e fria) (PACHECO, 2008).

De acordo com Kreutz (2012) e Massé e Masse (2000) os efluentes proveniente de matadouros possuem águas residuais contendo sangue, sendo ele um dos principais poluentes, apresentando uma DQO de $375.000 \text{ mg L}^{-1}$, além de gordura, excrementos, substâncias contidas no trato digestivo dos animais, fragmentos de tecidos, entre outros, resultando em um efluente com uma DQO que pode variar de 1100 a 10400 mg L^{-1} , DBO de 600 a 6700 mg L^{-1} e nitrogênio total de 90 a 3000 mg L^{-1} , sendo que essas características variam de acordo com a planta industrial, tipo de processo, instalações, entre outros fatores.

Assim, Oliveira et al. (2015) descreve que este tipo de efluente quando disposto no meio ambiente sem tratamento, ocasiona graves problemas aos corpos receptores, podendo ocorrer proliferação de insetos, emissão de gases, odores e ainda eutrofização dos cursos d'água.

3.3 IMPACTOS CAUSADOS PELO LANÇAMENTO DO EFLUENTE

Segundo Von Sperling, (2005). “Um dos mais importantes aspectos de poluição das águas é aquele relacionado com o fator higiênico, associado às doenças de veiculação hídrica”....

Ainda, “Um corpo d'água receptor do lançamento de efluentes pode incorporar a si toda uma ampla gama de agentes transmissores de doenças. Este fato não gera um impacto á biota do corpo d'água em si, mas afeta alguns dos usos preponderantes a ele destinados, tais como abastecimento de água potável e balneabilidade”.

O lançamento de efluentes nos corpos d'água, sem tratamento ou tratamento inadequado pode causar vários inconvenientes, que se apresentam com maior ou menor importância, de acordo com os efeitos adversos que podem causar aos usos benéficos das águas. Assim a poluição causada aos corpos d'água pelo lançamento de efluentes, ou apenas parcialmente tratados, é função das alterações da qualidade ocasionadas no corpo receptor, e das implicações relativas às limitações aos usos da água. (JORDÃO; PESSOA, 1995).

Para Lange et al. (2002) e Veras e Povinelli (2004) os matadouros, frigoríficos e abatedouros, são agroindústrias com alta concentração e despejos de resíduos sólidos, sendo que há necessidade de grandes áreas em que se possam receber os resíduos gerados por estas indústrias, o que representa problema para o meio ambiente.

3.4 CONTROLE DE PROCESSOS

Na busca de um sistema de controle compatível com a complexidade da maioria dos processos industriais, várias pesquisas têm sido elaboradas de acordo com o desenvolvimento de novas ferramentas e tecnologias.

Alves (2010) descreve que no início do século XX, a operação dos processos era feita de forma manual. A partir da metade do século, os sistemas de controle foram automatizados de uma forma empírica, os quais foram aprimorados a partir da elaboração da teoria de controle e análise dinâmica, a partir da década de 60. Nas duas décadas seguintes, foi introduzido o controle na forma digital, a partir do desenvolvimento de algoritmos, e no final do século, o foco era a aplicação de técnicas de inteligência artificial ao controle.

Para Alves (2010) a teoria de controle moderno está baseada na análise do domínio do tempo em sistemas de equações diferenciais.

Segundo Nise (2012) “um sistema de controle consiste em *subsistemas* e *processos* (ou *plantas*) construídos com o objetivo de se obter uma *saída* desejada com um *desempenho* desejado, dada uma *entrada* específica”.

3.4.1 Redes Neurais Artificiais (RNA's)

O cérebro humano é considerado o mais fascinante processador baseado em carbono existente, sendo composto por aproximadamente 10 bilhões neurônios. Todas as funções e movimentos do organismo estão relacionados ao funcionamento destas pequenas células. Os neurônios estão conectados uns aos outros através de sinapses, e juntos formam uma grande rede, chamada rede neural (BRAGA, 2000).

Para Braga (2000) a ideia principal de desenvolver a redes neurais artificiais era de simular sistemas naturais utilizando-se de estruturas análogas redes neurais biológicas. A complexidade com que os neurônios interagem através das sinapses é responsável pela característica atribuída à inteligência.

De acordo com Kovács (2006) o primeiro trabalho sobre RNA aconteceu na década de 40, pelo neurofisiologista McCulloch e o matemático Pitts, sendo um trabalho pioneiro considerado ingênuo, pois sustentava a premissa que redes relativamente simples com alguns neurônios implementariam máquinas booleanas no sistema nervoso.

Dando sequência em seus estudos, McCulloch e Pitts publicaram o artigo “*A Logical Calculus of the ideas Immanent in Nervous Activity*” em 1943, onde estabeleceram uma analogia entre os processos de comunicação das células nervosas vivas e os processos de comunicação elétrica.

Em 1947, eles conseguiram demonstrar que era possível conectar neurônios formais e criar uma rede capaz de executar funções complexas.

No final da década de 50, *FRANK ROSENBLAT* prosseguiu com as ideias de *McCULLOCH* e criou uma rede de múltiplos neurônios do tipo *discriminadores lineares* chamando de rede de *perceptron*, que consiste em neurônios dispostos em várias camadas.

A rede *perceptron* teve sua credibilidade abalada em 1969 com a publicação do livro "*perceptron*", por *MARVIN MINSKY* e *SEYMOUR PAPERT*, os quais fizeram duras críticas às redes neurais argumentando que os perceptrons possuíam muitas limitações em suas aplicações, não possuíam capacidade de aprendizado e não possuíam sustentação matemática. Ainda provaram formalmente que uma rede formada de uma única camada só era capaz de resolver problemas de associação de padrões linearmente separáveis. Com isso os avanços em relação às RNA's foram deixados de lado por décadas.

Em 1986 a incapacidade da RNA's de resolver problemas não lineares foi resolvida por *RUMELHART* et al.(1986) e sua solução foi a "*Generalized Delta Rule*" conhecida como "*Backpropagation Error Correction Algorithm*", onde as funções de ativação foram substituídas por funções contínuas sigmoidais.

Braga et al. (2000) define as RNA's como sendo sistemas paralelos distribuídos, compostos de unidades simples de processamento, que calculam determinadas funções matemáticas. Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões.

3.4.2 Treinamento da RNA

Para se utilizar uma RNA para um determinado fim sua eficiência está vinculada diretamente com a capacidade que ela possui de fornecer respostas próximas, o suficiente, dos dados de saída reais. Para tanto, o neurônio artificial deve ser capaz de aprender uma determinada tarefa.

Eyng (2009) descreve que na fase de treinamento, a rede extrai informações relevantes de padrões de informação apresentados a ela, criando assim uma representação própria do problema.

Nesta etapa, portanto, há o ajuste dos parâmetros da rede, que são caracterizados pelos pesos das conexões entre as unidades de processamento. Deste modo, ao final do processo de treinamento, a rede terá adquirido conhecimento sobre o ambiente em que esta operando, sendo este, “armazenado” em seus parâmetros EYNG (2009).

3.4.2.1 Algoritmo da retropropagação - (*backpropagation*)

Existem vários métodos para realizar o treinamento de uma RNA, porém, quando estas são aplicadas na modelagem de processos, utiliza-se o aprendizado supervisionado. Neste trabalho o método de treinamento utilizado foi o da retropropagação (*backpropagation*).

De acordo com Eyng (2009), o aprendizado é efetuado com base no erro incluso na resposta fornecida pela rede, o que significa que a diferença entre a resposta atual da simulação e a desejada deve ser minimizada, sendo necessário, portanto, o ajuste dos pesos sinápticos associados às entradas dos neurônios. Assim, o erro calculado na camada de saída é retropropagado às camadas anteriores, servindo de base para a modificação de todos os pesos, até que a resposta obtida pela rede seja satisfatória.

Segundo Demuth e Beale (2002), pelo fato do algoritmo *backpropagation* apresentar um processo de convergência lento, foram desenvolvidos métodos alternativos que convergem a uma velocidade maior que aquele.

Dentre estes métodos de otimização para treinamento de redes neurais, se destaca o algoritmo de Levenberg-Marquardt. De acordo com Kernani et al. (2005), este algoritmo representa a combinação entre o método Gauss-Newton e o de gradiente descendente. O primeiro método possui uma velocidade de convergência muito alta, devida a suas propriedades quadráticas, tendo como problema dependência elevada dos valores iniciais dos pesos e bias, cujas estimativas podem ser muito difíceis em uma aplicação em um sistema real. Já o segundo método citado, apresenta uma maior precisão quando a região próxima ao mínimo da função objetivo é alcançada. Porém, sua velocidade de convergência é baixa, pois minimiza a função objetivo de maneira linear.

De acordo com Eyng (2009) combinando os atributos positivos dos dois métodos, o algoritmo de Levenberg-Marquardt faz uso de uma técnica de otimização híbrida, a qual pode ser aplicada no tratamento de muitos problemas reais.

3.4.2.2 Redes neurais no tratamento de efluentes

Para Moraes (2016), diversas técnicas avançadas vêm sendo adotada em plantas de tratamento de efluentes industriais com o propósito de melhorar o monitoramento e controle operacional a fim de garantir a qualidade do efluente tratado antes de descartá-lo. Dentre estas técnicas, as redes neurais artificiais (RNAs) têm sido utilizadas com sucesso na modelagem destes sistemas.

Em sua pesquisa Moraes (2016) construiu modelos de predição da quantidade de matéria orgânica, medida por DQO, de uma lagoa aerada de uma empresa de produção de papel e celulose, e comparou o desempenho dos modelos construídos quando utilizada a técnica de análise de componentes principais (PCA) para pré-processamento dos dados. Os conjuntos de dados foram formados para comparar o desempenho das RNAs com e sem aplicação de PCA. Esse desempenho foi avaliado pelo erro quadrático médio, índice de correlação (R^2), índice de correlação ajustado e a complexidade da rede. A verificação da adequação do modelo foi através da análise residual. A PCA mostrou-se capaz de facilitar o processo de aprendizagem da rede neural e reduzir os custos operacionais pelo descarte de variáveis originais.

Valente et al. (2013) utilizaram a técnica de eletrocoagulação para redução da demanda química de oxigênio de efluente de uma indústria de laticínios. Uma rede neural artificial foi construída para modelar a demanda química de oxigênio após a operação de eletrocoagulação, como resultado a rede neural artificial foi capaz de prever o valor da demanda química de oxigênio após o tratamento por eletrocoagulação, a RNA demonstrou que com sua utilização haverá uma economia de tempo e redução no custo operacional, pois permitiu simular o sistema de tratamento por eletrocoagulação para as características do efluente e com isso ajustou as condições operacionais adequadas para obter os melhores resultados que eram menores valores de DQO final.

3.4.3 Estratégia do Controle

França (2005) comenta que para se definir a estratégia do controle e posterior construção de uma Rede Neural Artificial é necessário que se observe alguns conceitos para a definição do modelo a ser utilizado (direto / inverso).

Para Eyng (2009), o modelo inverso difere do direto na variável predita pela rede, o mesmo descreve que a utilização do modelo direto implica na necessidade de um processo de otimização para a obtenção da ação de controle, desta maneira, a rede neural prevê a variável controlada para um dado valor da variável manipulada. Ao receber o valor predito da variável controlada, o otimizador avalia o erro propiciado por esta ação de controle, e caso este erro seja superior a um valor pré-determinado, a ação é descartada e uma nova é calculada. Esse procedimento é repetido até que o erro gerado pela ação de controle seja tão pequeno quanto o desejável.

Neste contexto Eyng (2009) descreve que no modelo inverso, ao contrário do direto, não necessita de um processo de otimização para definir a ação de controle, o que lhe confere a vantagem de exigir menor esforço computacional. Deste modo, a ação de controle é determinada pela própria rede neural, conferindo assim, uma maior agilidade ao sistema de controle, fator importante na implementação *on line* do controlador.

3.5 ARQUITETURA DA REDE NEURAL

Eyng (2009) comenta que a determinação da arquitetura da rede depende de vários fatores, entre eles o número de variáveis de entrada e saída. Desta forma, a arquitetura da rede pode ser representada por $(x:n:Ne:1)$, para o problema regulatório proposto, onde “x” é o número de variáveis de entrada, “n” e “Ne” correspondem ao número de camadas escondidas e ao número de neurônios em cada camada, respectivamente. Sendo que a determinação destes valores é efetuada de modo a propiciar uma rede que forneça bons resultados sem que haja um esforço computacional excessivo.

4 MATERIAL E MÉTODOS

4.1 EFLUENTE DE FRIGORÍFICO E MATADOURO DE SUÍNO

O efluente utilizado no estudo provém de um matadouro e frigorífico de suínos localizado na região Oeste do Paraná. Essa indústria abate aproximadamente 6.500 animais, produzindo uma vazão de 5.200 m³ de efluente por dia.

O efluente utilizado para os ensaios de eletrofloculação foi coletado (uma única vez) após a saída dos decantadores/caixa de gordura, observando o parâmetro turbidez o qual sua o valor bruto foi de 380 UNT (unidade nefelométrica de turbidez). A Figura 1 apresenta o fluxograma da estação de tratamento de efluente da indústria.

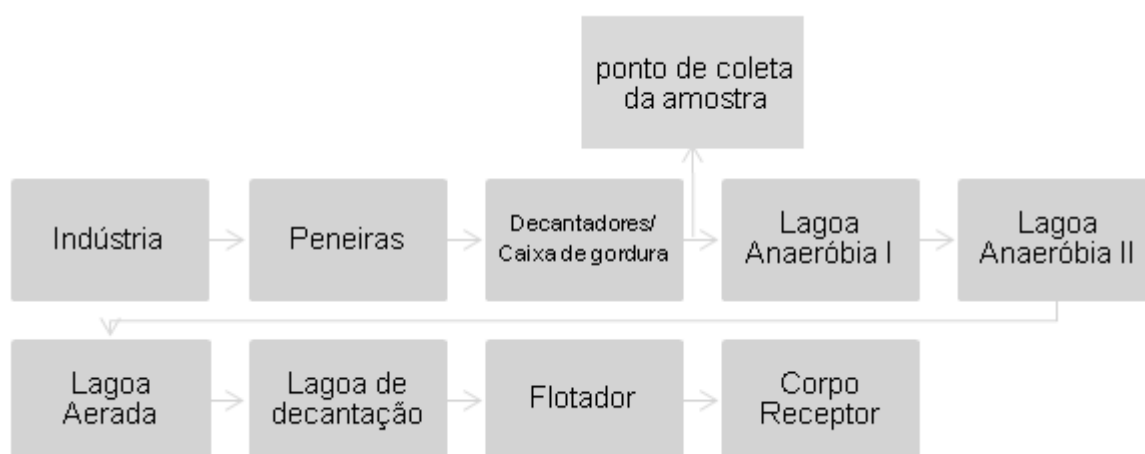


Figura 1 - Fluxograma da estação de tratamento de efluente do frigorífico.

4.2 MÓDULO DE TRATAMENTO

A pesquisa foi realizada na cidade de Medianeira situada a Oeste do Estado do Paraná, Brasil nos laboratórios da Universidade Tecnológica Federal do Paraná – UTFPR, O sistema de tratamento da eletrofloculação consiste em um reator de fluxo contínuo, o qual comportou os eletrodos de sacrifício de alumínio assim como o efluente a ser tratado. Os eletrodos por sua vez foram conectados a uma fonte de corrente contínua de modo a viabilizar a eletrofloculação.

O par de eletrodos foi disposto no reator a uma distância de 8 cm e cada placa possuía 20 cm de comprimento e 5 cm de largura, totalizando uma área igual a 100 cm², entretanto, a área do eletrodo imerso foi de 90 cm².

O reator consiste em um cilindro de policloreto de vinila, com 100 mm de diâmetro e volume útil igual a 1,61 l. O efluente adentrou ao reator na parte inferior, onde foi submetido as reações eletrolíticas e então saiu pela parte lateral superior do reator e encaminhado ao defletor o qual foi confeccionado de vidro e com as dimensões de 37 cm de comprimento, 12 cm de altura e 10 cm de largura com um volume útil igual a 3,12 L teve a função de separar o lodo gerado do efluente tratado.

O efluente foi armazenado em um reservatório de 20 l e para garantir a sua homogeneização, utilizou-se uma bomba submersa da marca *BOYU FPI 350*, modelo *submersible PUMP* e com vazão de 350 l. h⁻¹. Para alimentar o reator com o efluente foi utilizada uma bomba da marca *EXATTA*, modelo EX e com capacidade de vazão de até 20 l. h⁻¹.

Na figura 2 está demonstrado o módulo experimental para o tratamento de efluente por eletrofloculação.




Figura 2 - Módulo experimental para o tratamento de efluente por eletrofloculação.

O delineamento utilizado foi o DCCR (delineamento composto central rotacional). Como foram trabalhadas 2 variáveis independentes (corrente elétrica aplicada no sistema (I) e tempo de detenção hidráulica (TDH)), realizou-se um fatorial completo 2², incluindo 4 pontos axiais e 3 repetições no ponto central, totalizando 11 ensaios.

Os valores reais e codificados, correspondentes à faixa de estudo das variáveis, são apresentados na Tabela 1.

Tabela 1 - Valores reais correspondentes aos codificados (variáveis em estudo)					
	-1,41	-1	0	+1	+1,41
I (A)	0,3	0,47	0,9	1,32	1,5
TDH (min)	10'	12'55"	20	27'05"	30'

4.2.1 Codificação dos valores reais da matriz experimental.

Para codificar os valores reais da matriz experimental é necessário calcular os valores correspondentes a cada valor real das variáveis, esses cálculos estão demonstrados a seguir, sendo:

X1 o valor codificado para os valores de intensidade de corrente elétrica aplicada no sistema (I) (Eq.1).

X2 é o valor codificado para a o Tempo de detenção hidráulica (TDH) (Eq.2).

$$\frac{X1 - (-1,41)}{I - 0,3} = \frac{1,41 - (-1,41)}{1,5 - 0,3} \quad \text{Eq. 1}$$

$$\frac{X2 - (-1,41)}{TDH - 10} = \frac{1,41 - (-1,4)}{30 - 10} \quad \text{Eq. 2}$$

O modelo matemático a ser ajustado é apresentado na Eq.3. Os coeficientes (a1, a2, ... a6) do modelo codificado, são obtidos por regressão.

$$\text{Remoção de turbidez} = a1 + a2.x1 + a3.x2 + a4.x1.x2 + a5(x1)^2 + a6(x2)^2 \quad \text{Eq. 3}$$

Na Tabela 2, estão demonstrados os valores da matriz de ensaios experimentais com seus valores codificados e valores reais.

Tabela 2- Número de ensaios com os valores codificados e reais.

Ensaio	Corrente elétrica	Tempo de detenção hidráulica (TDH)
	(l) Cod / Real	(min) Cod / Real
1	-1 (0,47)	-1 (12'55")
2	+1 (1,32)	-1 (12'55")
3	-1 (0,47)	+1 (27'05")
4	+1 (1,32)	+1 (27'05")
5	0 (0,9)	0 (20)
6	0 (0,9)	0 (20)
7	0 (0,9)	0 (20)
8	-1,41 (0,3)	0 (20)
9	+1,41 (1,5)	0 (20)
10	0 (0,9)	-1,41 (10)
11	0 (0,9)	+1,41 (30)

4.2.2 Procedimentos dos ensaios

Para todos os ensaios da matriz do delineamento experimental foram ajustados os valores e com a ajuda de um cronômetro após decorridos 2 TDH's, foram coletadas as amostras para leitura de turbidez.

4.3 ESTRATÉGIA DE CONTROLE

O sistema de controle a ser empregado no sistema de tratamento consiste na utilização de um controlador *feedforward* - *pseudo feedback* baseado em modelo inverso de redes neurais.

Devido à impossibilidade de leitura de turbidez *in line*, e a necessidade da RNA de receber essa informação de saída do tratamento (*feedback*) esse valor foi estimado pelo modelo matemático empírico. Levando em consideração esse fato, optou-se por classificar o controlador como *feedforward*, pois recebe informações da turbidez na entrada do módulo e *pseudo-feedback* (apesar de não ser medida a turbidez efluente, esta é estimada).

4.3.1 Classificação do problema a ser estudado

O sistema proposto é caracterizado com regulatório, pois sua tarefa é compensar os efeitos de perturbações externas, a fim de manter a saída no seu ponto de ajuste constante.

4.4 VARIÁVEIS DO SISTEMA DE CONTROLE

As variáveis de entrada e de saída do controlador são apresentadas na Tabela 3.

Tabela 3- Variáveis de Entrada e Saída do Controlador RNA.

Variáveis de entradas	Variáveis de saída
TDH _k	
TDH _{k+1}	I _{k+1}
Tur.sp _{k+1}	
Tur(%) _{k+1}	
I _k	
Tur(%) _k	

Sendo:

$TDH |_k$ = O tempo de detenção hidráulica do módulo de tratamento.

$Tur (%) |_k$ = o valor de remoção de turbidez em percentual na saída do módulo de tratamento.

$I |_k$ = A corrente elétrica aplicada no eletrodo de alumínio do sistema de eletrofloculação.

$Tur.(%)sp |_k$ = O valor de remoção de turbidez em percentual na saída do módulo de tratamento utilizado com Setpoint para o controle.

O instante K refere-se ao instante de tempo onde não há perturbação no tempo de detenção hidráulica (TDH), já o instante de tempo K+1 refere-se ao futuro, ou seja, o instante onde a perturbação passa a ser detectada, sendo este referencial

temporal utilizado pela RNA para predizer o valor da intensidade de corrente a ser implementado no sistema de tratamento.

4.4.1 Dinâmica do controle e suas variáveis

As variáveis do sistema proposto podem ser definidas como:

- Variável controlada - É a variável resposta a qual o sistema de controle busca manter o seu valor desejável, ou seja, no trabalho proposto o valor da remoção de turbidez na saída do modulo de tratamento.
- Variável manipulada - É a variável no qual o controle busca atuar para manter a variável resposta, nesse trabalho a intensidade de corrente elétrica aplicada aos eletrodos no tratamento.
- Set point (SP) - É o valor pré-estabelecido o qual o controle deve manter como resposta do sistema, nesse trabalho a remoção de turbidez ($Tur_{(\%)}sp$).
- Perturbações - Em geral, os processos estão sujeitos à ação de outras entradas externas que não podem ser manipuladas e que são denominadas de perturbações, neste caso as mudanças foram inseridas intencionalmente no TDH para que o sistema de controle se adapte e responda de maneira satisfatória, alcançando o set point.

O controle teve como informação inicial uma situação de tratamento onde os valores de $(TDH | k)$ e $(I | k)$ eram conhecidos e a variável controlada $(Tur_{(\%)} | k)$ teve seu valor estimado utilizando o modelo resultante da análise dos dados do DCCR.

Logo após, foi inserido uma perturbação na variável de entrada $(TDH |_{k+1})$, com esse distúrbio houve uma nova resposta $(Tur_{(\%)} |_{k+1})$, visto que a corrente elétrica ainda era a do instante anterior $(I | k)$, esse valor foi utilizado como entrada para a rede, que comparando com o valor estabelecido de set point, informasse o novo valor da variável manipulada para que o valor de set point fosse alcançado.

4.5 DESENVOLVIMENTO DA REDE NEURAL ARTIFICIAL PARA CONTROLE DO SISTEMA

4.5.1 Bancos de dados de treinamento e validação da RNA

Para se construir uma rede neural artificial satisfatória é necessário que se construa um banco de dados representativo do sistema, para isso é necessário que se possua um quantidade de dados que contemple toda a gama em que se queira que a RNA atue.

Para esse trabalho a fim de gerar os dados para composição do banco de dados de treinamento da rede e posterior validação da mesma, utilizou-se de um software utilizando a linguagem de programação Delphi construído a partir do modelo matemático empírico obtido pelo DCCR, com o intuito de gerar todas as possíveis combinações de variáveis nesse sistema.

Com o auxílio do software as condições iniciais de $(TDH | k)$, $(I | k)$ foram definidas arbitrariamente de modo a proporcionar uma saída $(Tur.(%) | k)$ próxima ao set point definido na etapa preliminar de determinação da relação entre as variáveis de perturbação, manipuladas e controladas, obtidas com base em experimentos (DCCR)

Assim, os valores de $(TDH | k)$, utilizados, contemplaram toda a faixa de estudo do DCCR, iniciando-se em -1,41 (valor codificado), até o valor de +1,41(valor codificado) com incremento de + 0,10 para as variáveis $(TDH | k)$, $(I | k)$.

Os dados utilizados foram selecionados em função dos valores que contemplaram a faixa de $\pm 9\%$ o valor de setpoint para a composição do banco de treinamento da RNA.

Na Figura 3 pode-se observar a interface do software gerador de dados.

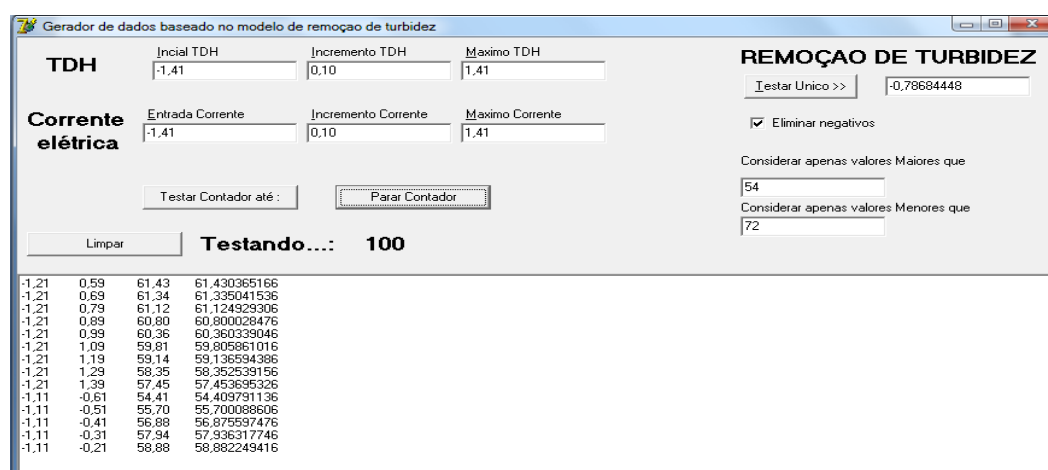


Figura 3 - Software gerador dos dados para construção do banco de treinamento.

A partir do software gerador de dados foram introduzidos os valores das perturbações em TDH ($TDH |_{k+1}$), assim novos valores de saída ($Tur.(%) |_{k+1}$) foram obtidos visto que os valores de corrente ainda eram o tempo anterior ($I |_k$), com isso o valor de ($Tur.(%) |_{k+1}$) se distanciava do setpoint, para isso novos valores de ($I |_{k+1}$) foram gerados com o objetivo minimizar o impacto gerado pela perturbação e restaurar o valor de setpoint na saída do tratamento ($Tur.(%).sp |_{k+1}$).

Do total de conjunto de dados gerados, 70% foram destinados ao banco de dados de treinamento da RNA, enquanto que os 30% restantes foram destinados ao banco de dados de validação.

4.5.2 Detalhamento da RNA

4.5.2.1 Software utilizado

O software utilizado para desenvolver a RNA foi o MATLAB ®, versão R2012a. De acordo com Farina e Posser (1999) o MATLAB é um software computacional conhecido mundialmente como uma excelente ferramenta para soluções de problemas matemáticos, científicos e tecnológicos, que possui comandos muito próximos da forma como escrevemos as expressões matemáticas, ainda pode-se dizer que o MATLAB é um ambiente de programação de alto nível, possuindo características de aplicativo (facilidade para o usuário) e de linguagem de programação (flexibilidade).

4.5.2.2 Tipo de RNA utilizada

A rede escolhida foi a rede do tipo direta ou rede *feedforward* de múltiplas camadas.

De Castro e Zuben (2001) descrevem sobre a rede *feedforward* como sendo redes que possuem uma ou mais camadas intermediárias ou escondidas, e que se adicionando camadas intermediárias não lineares, é possível aumentar a capacidade de processamento de uma rede *feedforward*.

A saída de cada camada intermediária é utilizada como entrada para a próxima camada. Cada camada se conecta à próxima camada, porém não há

caminho de volta. Todas as conexões, portanto, tem a mesma direção, partindo da camada de entrada rumo à camada de saída.

A figura 4 demonstra uma rede do tipo direta ou rede *feedforward* de múltiplas camadas.




Figura 4 - Arquitetura de uma RNA do tipo direta (Feedforward) Fonte: FIORIN (2011).

5 RESULTADOS E DISCUSSÃO

5.1 ENSAIOS DA MATRIZ DO DELINEAMENTO EXPERIMENTAL

Na Figura 5 são apresentados os resultados dos ensaios da matriz do delineamento experimental, demonstrando a remoção de turbidez em percentual, assim como a eficiência de tratamento, para as diversas condições testadas.

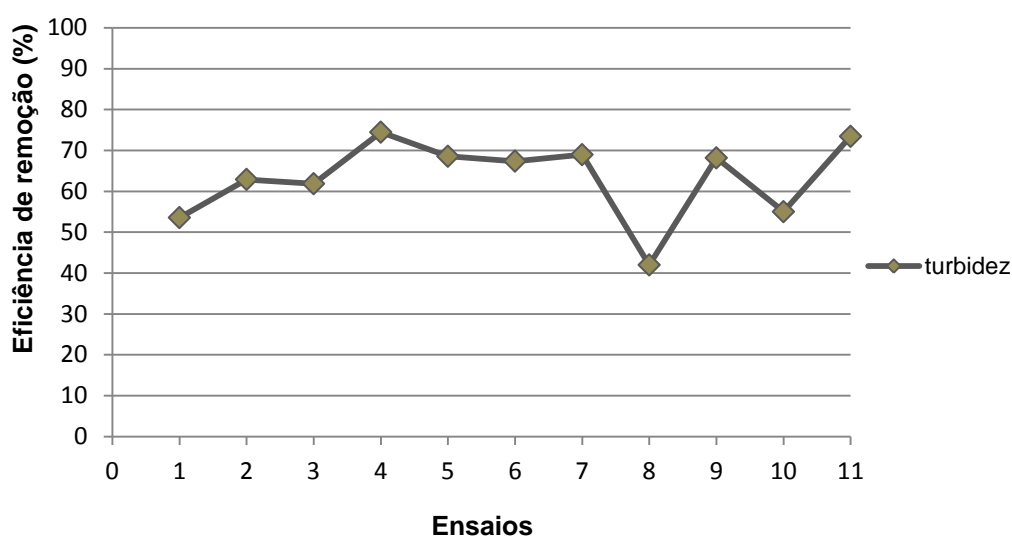


Figura 5 - Eficiência de remoção do parâmetro turbidez.

Observa-se que os valores de remoção de turbidez variaram entre o ensaio 1 e o ensaio 11 com valores respectivos demonstrados na Tabela 4 onde observam-se os valores da variável resposta remoção de turbidez percentual na saída do módulo tratamento (Tur. (%)).

Tabela 4 - Matriz do delineamento experimental, valores codificados e reais.

Ensaio	Corrente elétrica	Tempo de detenção	Remoção de
	(I) Cod / Real	hidráulica (TDH) (min) Cod / Real	Turbidez (%)
1	-1 (0,47)	-1 (12'55")	53,55
2	+1 (1,32)	-1 (12'55")	62,89
3	-1 (0,47)	+1 (27'05")	61,84
4	+1 (1,32)	+1 (27'05")	74,44
5	0 (0,9)	0 (20)	68,55
6	0 (0,9)	0 (20)	67,36
7	0 (0,9)	0 (20)	68,94
8	-1,41 (0,3)	0 (20)	41,97
9	+1,41 (1,5)	0 (20)	68,15
10	0 (0,9)	-1,41 (10)	55
11	0 (0,9)	+1,41 (30)	73,42

A Tabela 5 apresenta a estatística descritiva das eficiências de remoção para os parâmetros analisados.

Tabela 5 - Estatística descritiva da eficiência de remoção de turbidez.

Parâmetro	Média	Desvio padrão	Mínimo	Máximo
Turbidez	63,29	9,73	41,97	74,44

Observando os valores de remoção de turbidez dos ensaios da matriz de delineamento experimental observa-se que os valores variaram entre 41,97% no ensaio 8 (valor mínimo de remoção) e 74,44% no ensaio 4 (valor máximo de remoção) e com um valor médio entre todos os ensaios de 63,29%, valor esse o qual optou-se por 63% e adotou-se com valor de setpoint para o sistema de controle .

5.2. ANÁLISE ESTATÍSTICA.

Através dos resultados obtidos demonstrados nas Tabelas 4 e 5 foram calculados os coeficientes de regressão apresentados.

Na Tabela 6, estão demonstrados os coeficientes do modelo de regressão a partir da matriz codificada, os termos lineares estão associados à letra L e os termos quadráticos a letra Q.

Tabela 6 - Coeficientes de regressão para a variável resposta remoção de turbidez.

Fatores	Coeficiente de regressão	Erro Padrão	p – valor
Média	68,27520	2,012917	0,00000
X1 (L)	7,38034	2,469014	0,00188
X1(Q)	-5,73943	2,946176	0,01145
X2 (L)	5,74406	2,469014	0,00557
X2 (Q)	-1,13970	2,946176	0,47409
X1.X2	0,81579	3,486515	0,65949

Para a variável resposta remoção de turbidez, os valores de p - valor menores que 0,05 nos demonstram quais parâmetros foram significativos a 5% de significância que foram a corrente (L), TDH (L) e a corrente (Q), porém optou-se por manter todos os termos no modelo, mesmo os que não se mostraram significativos a 5% de significância, devido ao fato de os mesmos explicarem uma pequena parcela do fenômeno contribuindo para o coeficiente de determinação (R^2).

O modelo codificado obtido a partir dos coeficientes de regressão está demonstrado na equação 4.

$$\text{Rem. de Turbidez} = 68,2752 + 7,38034.X1 + 5,74406.X2 + 0,81579.X1.X2 - 5,73943.(X1)^2 - 1,1397.(X2)^2 \quad \text{Eq. 4}$$

Para realização do teste F e consequente avaliação da validade do modelo é necessário à análise de variância (ANOVA) para a resposta remoção de turbidez, conforme é observada na Tabela 7.

Tabela 7 - ANOVA para a remoção de turbidez.

Fonte de Variação	SQ	GL	MQ	Fcalculado	Ftabelado	p-valor
Regressão	892,095	5	178,419	14,678	5,05	0,0052
Resíduos	60,779	5	12,156			
Total	952,874	10				

% variação explicada (R^2) 93,584%.

A análise de variância ANOVA é a mais utilizada para se avaliar numericamente a qualidade do ajuste de um modelo, para isso, fazendo um exame dos resíduos. De acordo com os dados, o coeficiente de determinação (R^2) explica 93,584% da variação total das respostas, o valor de Fcalculado é maior que o

Ftabelado determinando a validade do modelo a 95% de confiança, o que também pode ser observado pelo fato do p-valor ser menor que 0,05.

5.3 IMPLEMENTAÇÃO E TREINAMENTO DA RNA

5.3.1 Bancos de dados de treinamento e validação da RNA

Para a construção dos bancos de treinamento e validação da RNA os dados foram obtidos a partir do programa gerador, onde se configurou o programa para fornecer as combinações possíveis para (I) a partir de todos os TDH's entre (-1,41 a 1,41) valores codificados, com incremento de (0,10) que fornecesse uma (Tur%) entre 54% e 72% ($63\% \pm 9\%$)

Os dados analisados e selecionados resultaram em 547 linhas de combinações as quais foram submetidas a perturbações arbitrárias positivas e negativas em relação a condição inicial de TDH, com isso o valor da (Tur%) se distanciava do set point. Para essa nova condição novos valores de (I |_{k+1}) eram fornecidos pelo gerador para alcançar o valor de set point, visto que o modelo forneceu mais de um valor de corrente o qual a Tur% mantinha-se entre o valor aceitável de 54% a 72%, foi escolhido o valor de corrente que mais se aproximava de 60% de Tur%. Depois de completadas as linhas com as perturbações e suas novas condições, 70% desses dados compuseram o banco de dados de treinamento e os 30% restantes foram utilizados no banco de dados de validação da RNA.

5.3.2 Testes para escolha da arquitetura da RNA

Na Tabela 8 são apresentados os valores observados dos testes para obtenção da melhor arquitetura da RNA.

A letra "A" representa a quantidade de camadas ocultas em que a RNA foi testada. As letras "b" e "c" representam o número de neurônio por camada.

Para cada arquitetura testada empiricamente observou-se o motivo da parada de treinamento, informação importante na escolha da melhor arquitetura para a RNA que será utilizada. O motivo de parada esperado é o de "*performance*" pois significa que a rede atingiu o nível de desempenho esperado, de acordo com a

função objetivo pré-estabelecida. O motivo de parada “MU” significa que o valor máximo de gradiente foi atingido, considerado um resultado ruim, pois informa que a rede não conseguiu convergir para um conjunto de valores de pesos sinápticos que proporcionassem o atendimento da função objetivo de treinamento.

O motivo de parada por “época” significa que a quantidade de iterações estabelecidas para a rede foi alcançada e a mesma não obteve seu melhor desempenho. O cálculo do erro percentual médio, para corrente, está demonstrado na equação 5.

$$Erro\ percentual\ médio = \sum_{i=1}^n \frac{\left(\frac{|Y_{RNAi} - Y_{REALi}|}{|Y_{REALi}|} \right) \times 100}{N} \quad Eq. 5$$

Tabela 8- Testes para escolha da arquitetura da RNA.

A; (b,c)	Época	Performance	Parâmetros	Motivo	Erro (l)%
1;(5)	511	0.0506	37.8/41	MU	3,63
1;(6)	667	0.0575	46.4/49	MU	10,83
1;(8)	2000	0.0166	61.5/65	época	34,38
1; (11)	658	1.00 ⁻⁰⁵	85/89	<i>performance</i>	0,48
1; (13)	594	9.86e ⁻⁰⁶	99.1/105	<i>performance</i>	2,95
1; (15)	403	9.82e ⁻⁰⁶	114/121	<i>performance</i>	2,17
1; (17)	295	9.93e ⁻⁰⁶	128/137	<i>performance</i>	4,54
1; (18)	361	7.10e ⁻⁰⁶	138/147	<i>performance</i>	12,11
1; (19)	265	9.87e ⁻⁰⁶	143/153	<i>performance</i>	11,43
2; (8,9)	819	9.98e ⁻⁰⁶	107/147	<i>performance</i>	2,04
2; (8,11)	284	9.76e ⁻⁰⁶	93.5/167	<i>performance</i>	3,08
2; (8,13)	351	9.64e ⁻⁰⁶	97.9/187	<i>performance</i>	1,16
2; (8,15)	313	9.91e ⁻⁰⁶	104/207	<i>performance</i>	1,18
2; (8,17)	306	9.73e ⁻⁰⁶	100/227	<i>performance</i>	2,83

Analisando os valores dos testes, observa-se que a RNA teve um melhor desempenho a partir de uma camada oculta com onze neurônios, pois o motivo de parada do treinamento da Rede Neural Artificial foi o de *performance*, a partir dessa configuração todas as configurações testadas tiveram o mesmo motivo de parada de treinamento. A escolha da configuração pautou-se então por aquela que forneceu o

menor erro percentual na corrente elétrica e que, devido ter uma camada oculta a menos que as outras exigiu um menor esforço computacional.

A Tabela 9 demonstra os valores de corrente (I) obtidos pelo modelo matemático frente às variações inseridas em TDH para que se se alcance o valor de setpoint e os valores de corrente (I) preditos pela RNA.

Tabela 9 -Valores de respostas do modelo matemático e da RNA frente às perturbações

TDH. (Cod.)	Modelo (Cod.)	RNA (Cod.)	Modelo (Real) (I)	RNA (Real) (I)	Erro predição (Real) (I)	Desvio Padrão (\pm)
-1,41	0,79	1,36	1,2397	1,4848	0,2451	0,1733
-1,4	0,49	1,34	1,1107	1,4762	0,3655	0,2584
-1,35	0,39	1,21	1,0677	1,4203	0,3526	0,2493
-1,3	0,39	1,05	1,0677	1,3515	0,2838	0,2006
-1,27	0,59	0,93	1,1537	1,2999	0,1462	0,1033
-1,25	0,59	0,87	1,1537	1,2741	0,1204	0,0851
-1,2	-0,51	0,75	0,6807	1,2225	0,5418	0,3831
-1,17	0,09	0,69	0,9387	1,1967	0,2580	0,1824
-1,15	0,09	0,65	0,9387	1,1795	0,2408	0,1702
-1,05	0,59	0,61	1,1537	1,1623	0,0086	0,0060
-1	-0,11	0,62	0,8527	1,1666	0,3139	0,2219
-0,9	-0,21	0,63	0,8097	1,1709	0,3612	0,2554
-0,7	-0,31	0,52	0,7667	1,1236	0,3569	0,2523
-0,45	-0,51	0,06	0,6807	0,9258	0,2451	0,1733
0	-0,51	-0,63	0,6807	0,6291	-0,0516	0,0364
0,3	-0,71	-0,78	0,5947	0,5646	-0,0301	0,0212
0,5	-0,71	-0,76	0,5947	0,5732	-0,0215	0,0152
0,55	-0,81	-0,73	0,5517	0,5861	0,0344	0,0243
0,8	-0,91	-0,77	0,5087	0,5689	0,0602	0,0425
0,85	-0,91	-0,78	0,5087	0,5646	0,0559	0,0395
0,95	-0,91	-0,82	0,5087	0,5474	0,0387	0,0273
1	-0,91	-0,84	0,5087	0,5388	0,0301	0,0212
1,05	-0,91	-0,85	0,5087	0,5345	0,0258	0,0182
1,1	-0,91	-0,87	0,5087	0,5259	0,0172	0,0121
1,15	-0,91	-0,88	0,5087	0,5216	0,0129	0,0091
1,18	-0,91	-0,89	0,5087	0,5173	0,0086	0,0060
1,23	-0,91	-0,89	0,5087	0,5173	0,0086	0,0060
1,28	-0,91	-0,9	0,5087	0,513	0,0043	0,0030
1,29	-0,91	-0,9	0,5087	0,513	0,0043	0,0030
1,3	-0,91	-0,9	0,5087	0,513	0,0043	0,0030
1,33	-0,91	-0,9	0,5087	0,513	0,0043	0,0030
1,35	-0,91	-0,9	0,5087	0,513	0,0043	0,0030
1,41	-0,91	-0,91	0,5087	0,5087	0	0

A Figura 6 demonstra os valores obtidos e demonstrados na Tabela 9 para melhor visualização e discussão dos resultados.

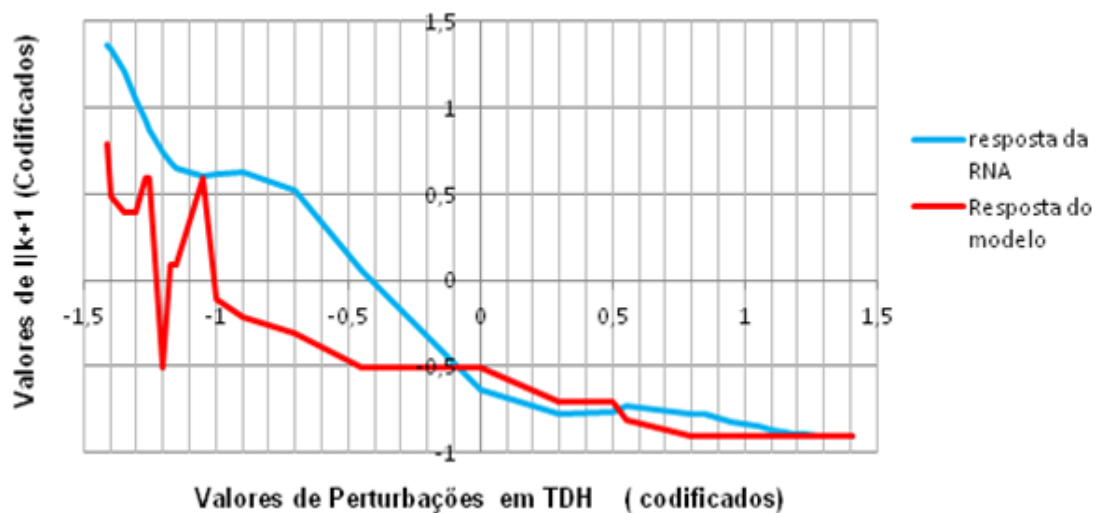


Figura 6 - Comparativo entre as respostas do modelo matemático e a RNA.

Observa-se que no decorrer das perturbações em TDH entre o menor valor codificado (-1,41) e o ponto central codificado (0) que o modelo matemático empírico e a RNA tiveram diferenças entre 0,0086 A e 0,5418 A sendo essa última o maior valor de diferença entre ambas e com um valor médio de 0,1227 A, valor esse considerado baixo para esse tipo de experimento.

As perturbações a partir do ponto central da matriz de delineamento o erro no valor predito pela RNA em relação à resposta do modelo matemático manteve-se muito baixo e no decorrer das perturbações positivas em TDH (maiores que (0) até o ponto máximo de +1,41), (valores codificados) esse erro entre ambas mantiveram-se próximo de zero.

6 CONSIDERAÇÕES FINAIS

Levando em consideração os resultados obtidos a partir dos ensaios do delineamento experimental e a análise estatística conclui-se que foi possível estabelecer uma relação entre a variável de entrada do controle com a variável de saída comprovada com a validade do modelo obtido.

O tratamento por eletrofloculação para remoção de turbidez de efluente de matadouro e frigorífico mostrou-se eficiente com valores que variaram entre 41,97% (valor mínimo de remoção) e 74,44% (valor máximo de remoção) e com um valor médio entre todos os ensaios de 63,29%, valor esse que foi adotado como valor de setpoint para remoção de turbidez.

Pode-se concluir também que a predição da RNA em relação aos valores estimados pelo modelo matemático empírico foi satisfatória, com erros que variaram entre 0,0043 A e 0,5418 A com um valor médio de 0,1227 A, comprovando assim a utilidade dessa ferramenta de controle para o tratamento proposto.

Embora a RNA mostrou-se eficiente na predição, para melhores respostas do sistema sugere-se para trabalhos futuros que se obtenha a medida da turbidez na saída do módulo para alimentar a RNA, “*in line*” o que evitaria possíveis erros devido à estimativa promovida pelo modelo ajustado para este fim.

7 REFERÊNCIAS

AGUILAR, M. I. **Nutrient removal and sludge production in the coagulation-flocculation process.** *Water Research*, v.36, p. 2910 - 2919, 2002. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0043135401005085>, acesso em 18 jul.2016, 13:30.

ALVES, J. L. L. **Instrumentação, controle e automação de processos** . 2. ed. Rio de Janeiro, RJ: LTC, 2010. x, 201 p.

BRAGA, A. de P.; CARVALHO, A. C. P. de L. F.; LUDERNIR, T. B. **Redes Neurais Artificiais Teoria e Aplicações.** LTC, 2000.

BRITO, J. F.; FERREIRA, L. O.; SILVA, J. P. Tratamento da água de purificação do biodiesel utilizando eletrofloculação. *Química Nova*. v. 35, n.4, p. 728 – 732, 2012.

CERQUEIRA, A. A.; MARQUES, M. R. C.; RUSSO, C. Avaliação do processo eletrolítico em corrente alternada no tratamento de água de produção. *Química Nova*. v. 34, n. 1, p. 59 – 63, 2011.

CIARDELLI, G.; RANIERI, N. **The treatment and reuse of wastewater in the textile industry by means of ozonation and electroflocculation.** Volume 35, Issue 2, p. 567–572, 2001. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0043135400002864>, acesso em 12 jul. 2016, 13:30.

CRESPILHO, F. N.; REZENDE, M. O. O. **Eletroflotação: Princípios e aplicações.** 1. ed. São Carlos: Rima, 2004.

DE CASTRO, L. N., ZUBEN, F. J. V. "**Redes neurais artificiais.**" *Porto Alegre, RS: Pontifícia Universidade Católica do Rio Grande do Sul* (2001).

DEMUTH, H., BEALE, M., **Neural Network Toolbox User's Guide for Use with MATLAB®.** Version 4, Reading: Hagan, M., 2002 Cap. 5: *Backpropagation*. Disponível em: <http://www.mathworks.com/support/product/NN/>. Acesso em 15 JUL 2016, 09:00.

EYNG, E. **Controle feedforward-feedback aplicado às colunas de absorção do processo de produção de etanol por fermentação.** 2008. 177 f. Tese (doutorado em Engenharia Química) – Faculdade de Engenharia Química, Universidade Estadual de Campinas, Campinas – SP, 2008

EYNG, E. et al. **Neural Network Based Control of an Absorption Column in the Process of Bioethanol Production.** 2009. *Brazilian Archives of Biology and Technology*, v. 52, p. 961-972, 2009. Disponível em: http://www.scielo.br/scielo.Php?script=sci_arttext&pid=S1516-89132009000400020, acesso em 16 set 2014,19:00.

FARINA, L. A. e POSSER, M. S. **'MATLAB - Ferramenta matemática para Engenharia**. UFRGS, Depto de Engenharia Química, SAENQ, 1999.

FRANÇA, Thiago Valle. **Estudo da predição da circularidade e rugosidade de peças retificadas utilizando as redes neurais artificiais**. 2005. 171 f. Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Engenharia, 2005. Disponível em: <<http://hdl.handle.net/11449/90809>>.

FIORIN, Daniel V. et al . **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. Rev. Bras. Ensino Fís., São Paulo , v. 33, n. 1, p. 01-20, Mar. 2011 . Available from <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-11172011000100009&lng=en&nrm=iso>. access on 21 Oct. 2016. <http://dx.doi.org/10.1590/S1806-11172011000100009>.

GOBBI, L. C. A. **Tratamento de água oleosa por eletrofloculação**. Dissertação (Mestrado em Energia). Universidade Federal do Espírito Santo, UFES, São Mateus, 2013.

IMHOFF, K.; IMHOFF, K. R. **Manual de tratamento de águas residuárias**. 26ª Edição. editora: Edgard Blucher Ltda. Saõ Paulo 1998.

JORDÃO, Eduardo P.; PESSÔA, Constantino A. **Tratamento de esgotos domésticos**. 3 ed, Rio de janeiro: ABES,1995

KERNANI, B. G., SCHIFFMAN, S. S., NAGLE, H. T., **Performance of the Levenberg-Marquardt neural network training method in electronic nose applications**. Sensors and Actuators B, Elsevier B. V., 2005. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0925400505000961>. Acesso em: 15 fev.2016.

KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações: um texto básico** - Zsolt L. Kovács - 4 ed. Ver.- São Paulo: Editora Livraria da Física, 2006

KREUTZ, C.; **Comportamento de reator anaeróbio-aeróbio no tratamento de efluente bovino**. Tese (Doutorado em Engenharia Agrícola), Universidade Estadual do Oeste do Paraná, Cascavel, 2012. Disponível em <http://tede.unioeste.br/tede/tdearquivos/1/TDE-2013-01-28T132229Z-896/Publico/Cristiane.pdf>. Acesso em: 16 de agosto de 2016.

LANGE, L. C.; SIMÕES, G. F.; FERREIRA, C. F. A.; SANTANA, D. W. E. A.; GARCIA, L. N. **Estudo comparativo de metodologias para análise físicoquímicas de resíduos sólidos urbanos**. Congresso Interamericano de Ingeniera Sanitaria y Ambiental, México, 2002.

MASSÉ, D. I; MASSE, L. **Characterization of wastewater from hog slaughterhouses in Eastern Canada and evolution of their in-plant wastewater treatment systems**. Canadian Agricultural Engineering, v. 42, n. 3, 2000. Disponível em <https://signage16.files.wordpress.com/2009/05/slaughterhouse-wastewater.pdf>. Acesso em:: 16 de agosto de 2016.

MEES, J. B. R. et al. **Removal of organic matter and nutrients from slaughterhouse wastewater by using Eichhornia crassipes and evaluation of the generated biomass composting.** Engenharia Agrícola, v. 29, p. 466-473, 2009. Disponível em <http://www.scielo.br/pdf/eagri/v29n3/a13v29n3.pdf>. Data: 16 de agosto de 2016.

MIRANDA, F. A.; FREITAS, S. R. C.; FAGGION, P. L. **Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de RNA e krigagem.** Boletim de Ciências Geodésicas, v.15, n.3, p. 428-443, 2009.

OLIVEIRA, R. F.; et al. **Avaliação da eficiência de remoção de poluentes presentes em efluentes de um abatedouro-frigorífico por tratamento biológico.** VI Congresso Brasileiro de Gestão Ambiental Porto Alegre/RS – Brasil. 2015. Disponível em: <http://www.ibeas.org.br/congresso/Trabalhos2015/II-016.pdf> , Acesso em : 16 de agosto de 2016.

PACHECO, J. W.; **Guia técnico ambiental de frigoríficos - industrialização de carnes (bovina e suína)** / - São Paulo : CETESB, 2008. 85p. (1 CD) : il. ; 30 cm. - (Série P + L) Disponível em: <http://docplayer.com.br/1195714-Guia-tecnico-ambiental-de-frigorificos-industrializacao-de-carne-bovina-e-suino-serie-p-l-frigorificos-industrializacao-carne-suina.html>

RUMELHART, D. E.; HINTON, G.E.; WILLIAMS, R.J. **Learning representations by back-propagating errors.** Nature, 323, pp.533-536, 1986.

SANTOS, Fernanda Abreu dos; PIRES, Marçal Jose Rodrigues; CANTELLI, Marlize. **Tratamento de efluente de galvanoplastia por meio da biossorção de cromo e ferro com escamas da pinha da Araucaria angustifolia.** Rem: Rev. Esc. Minas, Ouro Preto , v. 64, n. 4, p. 499-504, Dec. 2011 . Disponível em:<http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0370-44672011000500016&lng=en&nrm=iso>. Acesso em: 24 Ago. 2016. <http://dx.doi.org/10.1590/S0370-44672011000500016>.

UNEP – UNITED NATIONS ENVIRONMENT PROGRAMME; DEPA – DANISH ENVIRONMENTAL PROTECTION AGENCY; COWI CONSULTING ENGINEERS AND PLANNERS AS, Denmark. **cleaner production assessment in meat processing.** Paris: UNEP,2000. Disponível em: <http://www.unep.fr/shared/publications/pdf/2482-CPmeat.pdf>, Acesso em 18 jul. 2016, 17:50

VALENTE, Gerson de Freitas Silva et al. **Predição da demanda química de oxigênio em efluente líquido de uma indústria de laticínios tratado por eletrocoagulação usando redes neurais artificiais.**(2013), III Simpósio Internacional sobre Gerenciamento de Resíduos Agropecuários e Agroindustriais – São Pedro - SP.

VAZ, Luiz Gustavo de Lima et al . **Avaliação da eficiência de diferentes agentes coagulantes na remoção de cor e turbidez em efluente de galvanoplastia.** Eclet. Quím., São Paulo , v. 35, n. 4, p. 45-54, 2010. Disponível em: <<http://www.scielo.br/scielo.php?script=sciarttext&pid=S010046702010000400006&lng=en&nrm=iso>>. Acesso em: 24 Set. 2016. <http://dx.doi.org/10.1590/S0100-46702010000400006>.

VERAS, L. R. V.; POVINELLI, J. A. **Vermicompostagem do lodo das lagoas de tratamento de efluentes industriais consorciada com composto de lixo urbano.** Engenharia Sanitária e Ambiental. v. 9, n 3, p.218-224. 2004.

VON SPERLING, M. **Introdução à qualidade das águas e ao tratamento de esgotos.** 3. ed. DESA, UFMG: Belo Horizonte, 2005.

MORAIS, Jácina Tábita Gurgel. "Análise de componentes principais integrada a redes neurais artificiais para predição de matéria orgânica." (2016).

NISE, Norman S. **Engenharia de sistemas de controle.** 6. ed. Rio de Janeiro: LTC, 2012. 745 p.