



**UNIVERSIDADE ESTADUAL DA PARAÍBA
CENTRO DE CIÊNCIA E TECNOLOGIA
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA
MESTRADO EM CIÊNCIA E TECNOLOGIA AMBIENTAL**

JAYNE COSME ALBUQUERQUE

**MODELAGEM DO PROCESSO DE TRATAMENTO DO LIXIVIADO DE UM
ATERRO SANITÁRIO USANDO PROCESSOS OXIDATIVOS AVANÇADOS, VIA
REDES NEURAS ARTIFICIAIS**

CAMPINA GRANDE-PB

2019

JAYNE COSME ALBUQUERQUE

**MODELAGEM DO PROCESSO DE TRATAMENTO DOLIXIVIADO DE UM
ATERRO SANITÁRIO USANDO PROCESSOS OXIDATIVOS AVANÇADOS,
VIA REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada ao Programa de
Pós- Graduação em Ciência e Tecnologia
Ambiental

- PPGCTA, em cumprimento às exigências
necessárias para obtenção do título de
Mestra em Ciência e Tecnologia Ambiental.

Linha de Pesquisa: Tecnologias de
Tratamento de Água e Resíduos.

Orientador: Prof. Dr. Fernando Fernandes Vieira

**CAMPINA GRANDE-PB
2019**

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

A345m Albuquerque, Jayne Cosme.

Modelagem do processo de tratamento do lixiviado de um aterro sanitário usando processos oxidativos avançados, via Redes Neurais Artificiais [manuscrito] / Jayne Cosme Albuquerque. - 2019.

69 p.

Digitado.

Dissertação (Mestrado em Ciência e Tecnologia Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2019.

"Orientação : Prof. Dr. Fernando Fernandes Vieira, Coordenação do Curso de Engenharia Sanitária e Ambiental - CCT."

1. Redes Neurais Artificiais. 2. Sistema de tratamento de lixiviado. 3. Foto-Fenton. 4. Aterro sanitário. I. Título

21. ed. CDD 628.3

JAYNE COSME ALBUQUERQUE

**MODELAGEM DO PROCESSO DE TRATAMENTO DO
LIXIVIADO DE UM ATERRO SANITÁRIO USANDO PROCESSOS
OXIDATIVOS AVANÇADOS, VIA REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós- Graduação em Ciência e Tecnologia Ambiental- PPGCTA, em cumprimento às exigências necessárias para obtenção do título de Mestra em Ciência e Tecnologia Ambiental.

Linha de Pesquisa: Tecnologias de Tratamento de Água e Resíduos.

Aprovada em, 28 de 02 de 2019.

BANCA EXAMINADORA



Prof. Dr. Fernando Fernandes Vieira (orientador)

Universidade Estadual da Paraíba – PPGCTA/UEPB



Prof. Dr. William de Paiva

Universidade Estadual da Paraíba -PPGCTA/UEPB



Prof. Dr. Aldre Jorge Morais Barros

Universidade Federal de Campina Grande- CDSA/UFCG

CAMPINA GRANDE-PB

2019

DEDICATÓRIA

Dedico este trabalho primeiramente a Deus, por ser essencial em minha vida, autor de meu destino, meu guia, socorro presente na hora da angústia, minha mãe Maria do Carmo e aos meus irmãos, DEDICO.

Minha energia é o desafio, minha motivação é o impossível, e é por isso que eu preciso ser, à força e a esmo, inabalável.

Augusto Branco.

AGRADECIMENTOS

À Deus por ter me dado saúde e força para superar as dificuldades.

À esta universidade, seu corpo docente, direção e administração que oportunizaram a janela que hoje enxergo um horizonte superior. À CAPES pelo apoio financeiro, possibilitando a realização deste trabalho.

Ao meu orientador Fernando Fernandes Vieira, pelo suporte no pouco tempo que lhe coube, pelas suas correções e incentivos.

Ao grupo de pesquisa NUTES coordenado pela prof. Dra. Kátia Elizabete Galdino que gentilmente permitiu o uso do software Matlab para a realização deste trabalho.

À minha família, pelo amor, incentivo e apoio incondicional.

E a todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigado.

RESUMO

As Redes Neurais Artificiais (RNA's) é uma abordagem alternativa aos métodos estatísticos tradicionais no mapeamento de um sistema linear como também não linear. São modelos que vêm sendo desenvolvidos nos últimos anos, e tem como metáfora o funcionamento do cérebro humano. Estes modelos tomam como base as redes neurais biológicas associadas ao processamento paralelo do cérebro humano, constituído por elementos de processamento interconectados, chamados de neurônios, os quais estão dispostos em camadas e são responsáveis pela não-linearidade e pela memória da rede. Este trabalho tem como objetivo modelar um sistema de tratamento de lixiviado com os processos oxidativos avançados usando Redes Neurais Artificiais. Os dados que foram utilizados neste trabalho foi proveniente da pesquisa desenvolvida por Martins (2014). Com um sistema experimental que foi instalado e monitorado nas dependências físicas do laboratório da Estação Experimental de Tratamentos Biológicos de Esgotos Sanitário (EXTRABES) da Universidade Estadual da Paraíba- UEPB. No tratamento do lixiviado foi utilizado dois tipos de processos oxidativos avançados o Foto-Fenton e a fotólise de H_2O_2/UV . Para o sistema Foto-Fenton foi considerado às variáveis concentração de H_2SO_4 , concentração de H_2O_2 , tempo e taxa de radiação Ultravioleta. No sistema H_2O_2/UV concentração de H_2O_2 , tempo e taxa radiação ultravioleta. Estes parâmetros que foram utilizados para monitorar os processos oxidativos avançados serão usados como sendo as variáveis de entrada na elaboração das redes neurais artificiais. Para o treinamento e validação da rede foi utilizado um código computacional no *software* Matlab. O melhor algoritmo de minimização do erro foi o *Levenberg Marquardt* com uma configuração de RNA com o gradiente igual a $2,39.10^{-5}$ e erro médio quadrático (MSE) igual a 1.10^{-6} . Utilizou-se no treinamento destas redes uma camada oculta contendo 10 neurônios e funções de ativação sigmóide tangente e purelin. No sistema H_2O_2/UV o melhor desempenho nas etapas de treinamento e validação foi a RNA com uma camada oculta com 25 neurônios, apresentando um coeficiente de determinação acima de 0,97. No sistema Foto-Fenton com uma arquitetura com duas camadas ocultas contendo em cada camada oculta 5 e 25 neurônios, respectivamente, apresentou resultados significantes como coeficientes de determinação de treinamento e validação acima de 0,95.

Palavras-chave : Peróxido de hidrogênio com radiação Ultravioleta, neurônio artificial, Foto- Fenton, camada oculta

ABSTRACT

Artificial Neural Networks (ANNs) is an alternative approach to traditional statistical methods in mapping a nonlinear system. They are models that have been developed in recent years, and has as a metaphor the functioning of the human brain. These models are based on biological neural networks associated with the parallel processing of the human brain, consisting of interconnected processing elements, called neurons, which are arranged in layers and are responsible for nonlinearity and network memory. This work aims to model a leachate treatment system with advanced oxidative processes using Artificial Neural Networks. The data that were used in this work came from the research developed by Martins (2014). With an experimental system that was installed and monitored in the physical facilities of the Laboratory of the Experimental Station of Biological Treatments of Sanitary Sewage (EXTRABES) of the State University of Paraíba - UEPB. In the treatment of leachate, two types of advanced oxidative processes were used: Photo-Fenton and H_2O_2 / UV photolysis. For the Photo-Fenton system, the variables concentration of H_2SO_4 , concentration of H_2O_2 , time and rate of ultraviolet radiation were considered. In the H_2O_2 / UV system H_2O_2 concentration, time and ultraviolet radiation rate. These parameters that were used to monitor the advanced oxidative processes will be used as input variables in the elaboration of artificial neural networks. For the training and validation of the network, a computational code was used in Matlab software. The best error-mining algorithm was the Levenberg Marquardt with an RNA configuration with a gradient of $2.39 \cdot 10^{-5}$ and a mean square error (MSE) of $1 \cdot 10^{-6}$. A hidden layer containing 10 neurons and tangent and purelin sigmoid activation functions were used in the training of these networks. In the H_2O_2 / UV system the best performance in the training and validation stages was RNA with a hidden layer with 25 neurons presenting a coefficient of determination above 0.97. In the Photo-Fenton system with an architecture with two hidden layers containing in each hidden layer 5 and 25 neurons respectively presented significant results as coefficients of training determination and validation above 0.95.

Key words: Hydrogen peroxide with ultraviolet radiation, artificial neuron, Photo-Fenton, hidden layer.

LISTA DE FIGURAS

Figura 1- Modelo genérico da RNA	21
Figura 2- Arquitetura FeedFoward de camada simples.....	23
Figura 3- Arquitetura Feed Fordward de camadas Múltiplas.....	24
Figura 4- Arquitetura Realimentada.....	24
Figura 5- Câmara de Radiação.....	34
Figura 6- Representação da rede com uma camada oculta.....	36
Figura 7- Representação da RNA com duas camadas ocultas.....	37
Figura 8 - Gráfico do ajuste dos dados de DQO no treinamento e Validação da RNA.....	41
Figura 9- Gráfico de regressão do treinamento/validação.....	46
Figura 10- Gráfico de Resíduos de uma camada oculta.....	45
Figura 11- Valores de DQO experimental e do modelo.....	
Figura 12- Valores de DQO experimental e do modelo.....	48
Figura 13- Gráfico de resíduos das duas camadas ocultas.....	49
Figura 14- Valores da DQO Experimental com os valores da RNA.....	51
Figura 15- Teste de Tukey uma camada oculta.....	50
Figura 16- Gráfico de intervalos de confiança com uma camada oculta	51
Figura 17- Teste Tukey com duas camadas ocultas.....	51
Figura 18- Gráfico de intervalos de confiança com duas camadas ocultas.....	52
Figura 19- Comparação entre os valores do ruído com os originais.....	53
Figura 20- Comparação dos dados de ruído com o valores originais.....	54
Figura 22- Gráfico de Resíduos.....	58
Figura 23- Dados experimentais e os dados do modelo.....	58
Figura 24- Ajuste linear do treinamento e da validação da RNA.....	61
Figura 25- Gráfico de resíduos com duas camadas ocultas.....	61
Figura 26- Valores de DQO experimental com o do modelo.....	62

LISTA DE TABELAS

Tabela 1- Esquematização dos experimentos H_2O_2/UV	36
Tabela 2- Esquematização dos experimentos Foto-Fenton	36
Tabela 3- Divisão de dados para treinamento e validação da RNA	38
Tabela 4- Coeficientes de Determinação dos Algoritmos	40
Tabela 5- Coeficiente de determinação para o treinamento	42
Tabela 6- Coeficiente de determinação para Validação	43
Tabela 7- ANOVA de uma RNA com uma camada oculta.....	44
Tabela 8- Duas camadas ocultas de treinamento da RNA.....	46
Tabela 9- Duas camadas ocultas da Validação da RNA	47
Tabela 10- ANOVA de uma RNA com duas camadas ocultas	47
Tabela 11- ANOVA de uma RNA com duas camadas ocultas	52
Tabela 12- Divisão dos dados com uma camada oculta.....	54
Tabela 13- Divisão dos dados com duas camadas ocultas	55
Tabela 14- Coeficientes de determinação de treinamento.....	56
Tabela 15- Coeficientes de determinação de Validação.....	57
Tabela 16- Tabela ANOVA com uma camada oculta.....	58
Tabela 17- Coeficientes de determinação de treinamento.....	59
Tabela 18- Coeficientes de determinação de Validação.....	60
Tabela 19- Coeficientes de determinação de Validação.....	60

SUMÁRIO

1.	INTRODUÇÃO	12
2.	OBJETIVOS	14
	2.1 OBJETIVO GERAL	14
	2.2 OBJETIVOS ESPECÍFICOS	14
3.	FUNDAMENTAÇÃO TEÓRICA.....	15
	3.1 RESÍDUOS SÓLIDOS URBANOS	15
	3.2 DESTINAÇÃO INADEQUADA DE RSU	15
	3.3 ATERRO SANITÁRIO	16
	3.4 LIXIVIADO DE ATERROS SANITÁRIOS	17
	3.5 PROCESSOS OXIDATIVOS AVANÇADOS	18
	3.5.1 H ₂ O ₂ /UV	19
	3.5.2 Foto-Fenton	19
	3.6 REDE NEURAL ARTIFICIAL.....	20
	3.6.1 Definição	20
	3.6.2 Função de Ativação	22
	3.6.3 Arquiteturas de RNAs	22
	3.6.4 Aprendizado de RNAs.....	25
	3.6.5 Algoritmo de Aprendizado	26
	3.6.6 Regra Delta	27
	3.6.7 Aplicação de Rede Neurais Artificiais	30
4.	METODOLOGIA	34
	4.1 ORIGEM DOS DADOS	34
	4.2 ANÁLISE PRELIMINAR	35
	4.3 CRIAÇÃO DA REDE NEURAL ARTIFICIAL	36
	4.6 TREINAMENTO E VALIDAÇÃO.....	38
	4.7 ALEATORIZAÇÃO DOS DADOS	39
	4.8 FERRAMENTA COMPUTACIONAL.....	39
5.	RESULTADOS E DISCUSSÃO.....	40
	5.1 PROCESSO H ₂ O ₂ /UV	40
	5.1.1 Escolha do Algoritmo.....	40
	5.1.2.1 Rede neural artificial com uma camada oculta	42

5.1.2.2 Rede neural artificial com duas camadas ocultas.....	46
5.1.3 Análise Estatística	49
5.1.3.1 RNA com uma camada oculta	50
5.1.3.2 RNA com duas camadas ocultas.....	51
5.1.4 Análise do ruído na RNA	52
5.1.4.1 RNA com uma camada oculta	52
5.1.4.2 RNA com duas camadas ocultas.....	53
5.1.5 Divisão do conjunto de dados.....	54
5.1.5.1 RNA uma camada oculta	54
5.1.5.2 RNA com duas camadas ocultas.....	55
5.2 PROCESSO FOTO- FENTON.....	55
5.2.1 Análise da arquitetura da RNA.....	55
5.2.1.1 Rede neural artificial (RNA) com uma camada oculta	56
5.2.1.2 Rede neural artificial (RNA) com duas camadas ocultas	59
6. CONCLUSÃO	63
REFERÊNCIAS BIBLIOGRÁFICAS	64

1. INTRODUÇÃO

A crescente geração de resíduos sólidos tem sido um dos maiores problemas enfrentados pela sociedade nos tempos modernos. Tais resíduos, provenientes das mais diversas atividades humanas (produção industrial, atividades domésticas, comércio, etc.) necessitam de grandes áreas para sua disposição e acarretam inúmeros prejuízos ao meio ambiente, e à população, a exemplo dos problemas de saúde decorrentes principalmente da poluição do ar, da água e do solo (SOUTO *et al.*, 2013).

Os aterros sanitários se assemelham a grandes reatores biológicos. Os processos de transformações físico-químicas e biológicas decorrentes da decomposição da matéria orgânica resultam na produção de líquidos (lixiviado) e gases (biogás), que precisam ser coletados e tratados (ZUQUETTE *et al.*, 2015).

Define-se lixiviado de aterro sanitário como sendo o efluente produzido pela ação enzimática dos microrganismos sobre a matéria orgânica depositada em células de resíduos (NASCENTES *et al.*, 2015). O volume gerado desse subproduto, depende de fatores como o teor de umidade presente inicialmente nos RSU a serem aterrados, o volume de águas pluviais infiltradas e a água gerada interiormente pelo processo de biodegradação dos Resíduos Sólidos Orgânicos (RSO) (BAUN *et al.*, 2003).

Dentre os processos oxidativos avançados, pode-se citar a fotólise do peróxido de hidrogênio e o processo Foto-Fenton, os quais são comumente utilizados em tratamento de lixiviados para remoção de compostos recalcitrantes (NOGUEIRA *et al.*, 2007). Uma das desvantagens da aplicação desses sistemas é o consumo de energia elétrica provenientes das lâmpadas que promovem a incidência de radiação nos sistemas, quando estes sistemas são aplicados em grande escala promove um consumo significativo. Portanto, é necessário buscar novas alternativas, tecnologicamente e economicamente viáveis, para a remoção eficiente de contaminantes. Estudos com a aplicação dos Processos Oxidativos Avançados com o uso radiação solar vêm sendo desenvolvidos, como por exemplo, o trabalho realizado por Gala (2017), que utilizou a aplicação dos processos oxidativos avançados com a radiação solar para a remoção do antibiótico tinidazol obtendo um aumento na eficiência do processo e na redução dos custos operacionais.

A adoção da técnica de simulação na área acadêmica tem gerado diversos benefícios como: a previsão de resultados na execução de uma determinada ação; redução de riscos na tomada decisão; identificação de problemas antes mesmo de suas ocorrências;

redução de custos com o emprego de recursos (mão-de-obra, energia, água e estrutura física); revelação da integridade e viabilidade de um determinado projeto em termos técnicos e econômicos (SILVA, 2005).

Silva (2005) expõe que a simulação é uma das técnicas mais gerais usadas em Pesquisa Operacional (PO), que permite a formação de cenários, onde através destes, pode-se orientar o processo de tomada de decisão, preceder análises e avaliações de sistemas e propor soluções para a melhoria de desempenho.

Entre as técnicas existentes para simulação de sistemas operacionais, as Redes Neurais Artificiais é uma abordagem alternativa aos métodos estatísticos tradicionais no mapeamento de um sistema não linear. São modelos que vêm sendo desenvolvidos nos últimos anos, e tem como metáfora o funcionamento do cérebro humano. Estes modelos tomam como base as redes neurais biológicas associadas ao processamento paralelo do cérebro humano, constituído por elementos de processamento interconectados, chamados de neurônios, os quais estão dispostos em camadas e são responsáveis pela não-linearidade e pela memória da rede (VALENÇA, 2005).

Este trabalho tem como objetivo modelar um sistema de tratamento de efluente com os processos oxidativos avançados usando Redes Neurais Artificiais. Para o treinamento e validação da rede será utilizado um código computacional no software Matlab.

2. OBJETIVOS

2.1 OBJETIVO GERAL

Desenvolver um modelo empírico usando Rede Neurais Artificiais (RNA) para modelagem do processo de tratamento do lixiviado do aterro sanitário da cidade de João Pessoa-PB, usando Processos Oxidativos Avançados.

2.2 OBJETIVOS ESPECÍFICOS

- Avaliar o processo de treinamento da RNA, usando os algoritmos do gradiente descendente com momento e taxa de aprendizagem adaptativa e o de Levenberg-Marquardt;
- Investigar a influência do número de camadas ocultas e número de neurônios por camada, sobre o desempenho da RNA;
- Analisar a influência da aleatorização dos dados de entrada, sobre o desempenho da RNA;
- Averiguar a interferência de 10% e 20% de ruído nos dados experimentais do sistema H_2O_2/UV ;
- Estimar a influência da quantidade de dados usados no treinamento/validação, sobre o desempenho da RNA.

3. FUNDAMENTAÇÃO TEÓRICA

3.1 RESÍDUOS SÓLIDOS URBANOS

De acordo com a Política Nacional de Resíduos Sólidos (PNRS), os Resíduos Sólidos Urbanos (RSU) formam-se dos resíduos sólidos de origem domiciliar e de limpeza urbana. São basicamente resíduos originados em atividades residenciais, comerciais e institucionais, contendo uma fração significativa de resíduos orgânicos putrescíveis, papel, plásticos e metais, tendo sua composição variável, que depende da situação socioeconômica, cultural e dos hábitos de vida de cada população (BRASIL, 2010).

A disposição final de RSU em aterros brasileiros não obedece a hierarquia de gerenciamento dos resíduos composta por a não geração, redução, reutilização, reciclagem, tratamento de resíduos sólidos e disposição final ambientalmente adequada dos rejeitos como preconizada a Política Nacional dos Resíduos Sólidos (BRASIL, 2010). De acordo com os dados da Associação Brasileira das Empresas de Limpeza Pública e Resíduos Especiais (ABRELPE, 2017), durante o ano de 2017 foram gerados aproximadamente 78,4 milhões de toneladas no país de RSU. Desse total, mais de 6,9 milhões de toneladas deixaram de ser coletadas e, conseqüentemente, tiveram destino impróprio (lagos, rios, galerias pluviais e terrenos baldios), e dos resíduos coletados (71,6 milhões de toneladas), a grande maioria, 59,1%, foi depositada em aterros sanitários. Esta quantidade de Resíduos Sólidos que não são destinados ao aterro sanitário não tratados adequadamente causam efeitos adversos à saúde pública e ao meio ambiente.

3.2 DESTINAÇÃO INADEQUADA DE RSU

Vários destinos podem ser dados à disposição final dos RSU's, todavia, um deles é o "lixão", resultante da simples descarga de lixo sobre o solo, sem critérios técnicos e medidas de proteção ao meio ambiente ou à saúde pública. As áreas dos lixões ou vazadouros, segundo Pereira Neto (2007), criam condições favoráveis (habitats) à proliferação de vetores (moscas, baratas, ratos e mosquitos), que se multiplicam de forma rápida em razão da grande quantidade de alimento, da facilidade de abrigo. Esses vetores chegam às residências causando doenças, além de facilitarem a contaminação de animais domésticos que ali vivem. O lixo acumulado produz um líquido denominado de lixiviado

que possui coloração escura com cheiro desagradável e atinge as águas subterrâneas (ARAÚJO *et al.*, 2013).

Além disso, ocorre os impactos ambientais do solo, do ar, visuais, sociais e o desequilíbrio da fauna e flora. O resultado desse conjunto de impactos gera a degradação, que diminui ou impede a capacidade dos recursos ambientais de restabelecer-se naturalmente. Os dados da Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais (ABRELPE, 2017), revelam que 3.352 municípios ainda fazem usos de locais impróprios para destinação final de resíduos.

Em 02 de agosto de 2010 foi promulgada no Brasil a Política Nacional de Resíduos Sólidos (PNRS) pela Lei Federal nº 12.305/2010, na qual se determinam as responsabilidades dos geradores, do poder público e aos instrumentos econômicos aplicáveis, sobre a gestão integrada e ao gerenciamento de resíduos sólidos, e se obriga que, no ano de 2014, todos os lixões do Brasil sejam desativados e substituídos por aterros sanitários.

3.3 ATERRO SANITÁRIO

É uma prática comum no mundo a disposição final de RSU em aterros sanitários em função dos custos reduzidos quando comparados com outras tecnologias de tratamento e da disponibilidade de uma área para implantação (JUNIOR, A.B *et al.*, 2010).

Os aterros sanitários também podem ser considerados uma obra geotécnica e de saneamento básico, que tem a finalidade de reduzir e minimizar impactos ambientais no solo, corpos hídricos (superficiais e subterrâneos) e no ar atmosférico. Essa técnica utiliza princípios de engenharia para confinar os Resíduos Sólidos Urbanos (RSU) em camadas cobertas com material inerte, geralmente solo, seguindo normas operacionais específicas, de modo que seja utilizada a menor área possível e evitados danos à saúde pública e ao meio ambiente (PHILIPPI Jr., 2005).

Quando os RSU's são depositados em células de aterros sanitários, ocorre uma série de processos físicos, químicos e biológicos que dão origem ao processo natural de degradação, decomposição ou estabilização da massa de resíduos aterrada. Dentre os processos citados, os biológicos são dominantes e controlam grande parte dos demais (MCBEAN *et al.*, 1995).

À medida que os RSU's são aterrados ocorre biodegradação dos mesmos, geram-se subprodutos, como o lixiviado, que pode apresentar uma carga orgânica entre 10 e 75 vezes maior que a dos esgotos domésticos (TCHOBONOGLIOUS, THIENSEN e VIGIL, 1993; VON SPERLING, 2005).

3.4 LIXIVIADO DE ATERROS SANITÁRIOS

Define-se lixiviado de aterro sanitário como sendo o efluente produzido pela ação enzimática dos microrganismos sobre a matéria orgânica depositada em células de resíduos (NASCENTES *et al.*, 2015). O volume gerado desse subproduto, depende de fatores como o teor de umidade presente inicialmente nos RSU a serem aterrados, o volume de águas pluviais infiltradas e a água gerada interiormente pelo processo de biodegradação dos Resíduos Sólidos Orgânicos (RSO) (BAUN *et al.*, 2003).

Cada lixiviado tem sua composição dependente da origem do aterro sanitário. Na Tabela 1 pode ser observado a caracterização físico química do lixiviado bruto proveniente do aterro sanitário da cidade de João Pessoa-PB. Este lixiviado apresenta pH próximo de neutro, concentrações de Demanda Bioquímica de Oxigênio (DBO₅) e Demanda Química de Oxigênio (DQO) elevadas.

Tabela 1: Características físicas e químicas do lixiviado da cidade de João Pessoa-PB.

Parâmetros físico-químicos	Unidade	Média
pH		7,8
Nitrogênio Amoniacal	mg.L ⁻¹	2.100
DQO Total	mgO ₂ .L ⁻¹	18.000
DBO ₅	mgO ₂ .L ⁻¹	5.000
Alcalinidade Total	mgCaCO ₃ .L ⁻¹	9.000
AGV	mgH-Ac.L ⁻¹	3.300
Fósforo Total	mg.L ⁻¹	11
Ortofosfato	mg.L ⁻¹	6
Sólidos Suspensos Voláteis	mg.L ⁻¹	400
Sólidos Suspensos Totais	mg.L ⁻¹	900

Fonte: Adaptado Risoneide, (2014)

Os dois principais fatores que caracterizam os lixiviados do aterro são o volume gerado e a composição. Ambos os fatores são dependentes de uma variedade de parâmetros, como tipo de resíduo depositado, condições climáticas e modo de operação no local. Além disso, a

composição do lixiviado é fortemente influenciada pela idade do aterro (KULIKOWSKA *et al.*, 2008). Com o passar dos anos há uma redução significativa da biodegradabilidade devido à conversão em gás metano e CO₂ de parte dos componentes biodegradáveis (SÁ *et al.*, 2012).

A digestão da matéria orgânica presente nos RSU em aterros sanitários ocorre em duas fases distintas: a primeira envolve a presença de oxigênio (fase aeróbia); e a segunda acontece na ausência deste gás (fase anaeróbia) e se subdivide em quatro etapas. Entretanto, Chernicharo (2000), menciona uma quinta etapa na fase anaeróbia, conhecida por sulfetogênese. À medida que cada uma destas fases ocorre no interior do aterro, o lixiviado gerado apresenta características diferentes.

As técnicas utilizadas para o tratamento de lixiviados são as fundamentadas em processos biológicos, sendo que estas têm se mostrado insuficientes para o atendimento aos padrões de lançamento estabelecidos pela legislação nacional (Resolução CONAMA nº 357, de 17/3/2005), principalmente no caso de lixiviados de aterro sanitário estabilizado em relação aos parâmetros referentes à matéria orgânica, cor, nutrientes, cloretos e alcalinidade. Estudo sobre técnica de tratamento de lixiviado reportados na literatura, em escala demonstrativa, pode-se citar o emprego de filtros anaeróbios conjugados com lagoa facultativa com lixiviado do aterro sanitário de Belo Horizonte, (MORAVIA *et al.*, 2011).

As concentrações de substâncias orgânicas tóxicas e recalcitrantes presentes no lixiviado estão entre os obstáculos mais comuns ao uso de processos tradicionais de tratamento, como processos biológicos (AMOR, 2015). Uma alternativa são os tratamentos baseados em processos químicos capazes de promover a degradação ou, até mesmo, a mineralização da matéria poluente refratária, podendo haver a combinação entre diferentes técnicas ou serem conjugados com processos biológicos (MORAVIA *et al.*, 2011).

3.5 PROCESSOS OXIDATIVOS AVANÇADOS

Os Processos Oxidativos Avançados (POA's) são fundamentados na geração de espécies radiculares, principalmente radical hidroxila ($\bullet\text{OH}$). Esse radical apresenta uma elevada capacidade de degradação oxidativa devido ao seu elevado potencial padrão de redução ($E^\circ = 2,8 \text{ v}$), uma vez reagindo com uma extensa variedade de compostos orgânicos promove uma completa mineralização desses compostos (ANDREOZZI *et al.*, 1999).

Por meio dos POA's as possibilidades de aplicação dos processos químicos por oxidação são ampliadas consideravelmente em relação aos procedimentos clássicos. Podem transformar muitas substâncias persistentes, como por exemplo, hidrocarboneto clorado, policloreto de bifenila, defensivos agrícolas, adsorventes de organohalogenados e DQO refratária, em substâncias ecologicamente inofensivas, biologicamente degradáveis e podendo obter no meio reacional à total mineralização dos compostos apresentando nos produtos finais CO₂, H₂O e íons inorgânicos (FIGAWA, 1997; HICARASHI *et al.*, 2000).

De acordo com a EPA (1998) os Processos Oxidativos Avançados são classificados em fotoquímicos e não fotoquímicos. Os fotoquímicos envolvem a geração de •OH por meio da fotólise por UV de oxidantes convencionais, incluindo o peróxido de hidrogênio (H₂O₂) exemplos desses sistemas são H₂O₂/UV e o Foto-Fenton.

3.5.1 H₂O₂/UV

A fotólise do peróxido de hidrogênio por irradiação UV é um processo que pode ocorrer naturalmente, constituindo em uma alternativa para degradar compostos orgânicos tóxicos. O H₂O₂ pode ser fotolisado por irradiação UV em comprimentos de onda de 200 a 300 nm (representado como $h\nu$) ocasionando a quebra da ligação O-O da molécula de H₂O₂ gerando radicais hidroxila (•HO) (Equação 1) que agem na degradação de espécies orgânicas (Hernandez *et al.*, 2002).




3.5.2 Foto-Fenton

Entre os Processos Oxidativos Avançados, grande destaque tem sido dado ao uso do peróxido de hidrogênio em presença de sais de ferro, conhecido como processo Fenton, devido principalmente ao seu custo e alta eficiência na degradação dos compostos recalcitrantes. O processo Fenton consiste em um conjunto de reações cíclicas, que utilizam íons Fe⁺² e Fe⁺³ como catalisadores, para decompor o peróxido de hidrogênio e produzir radicais de hidroxila. O íon ferroso (Fe⁺²) inicia e catalisa decomposição do H₂O₂ (Equação 2) (Araujo *et al.*, 2011).



Além do processo Fenton tradicional existem processos que utilizam a radiação ultravioleta, como o processo Foto-Fenton. No Foto-Fenton a fonte de radiação atua aumentando a regeneração de Fe^{+2} e a produção adicional de radicais de hidroxilas (Equações 3 e 4) (COSTA, *et al.*, 2014).



3.6 REDE NEURAL ARTIFICIAL

3.6.1 Definição

O uso das Redes Neurais Artificiais (RNA), comumente chamadas de “redes neurais”, é pelo reconhecimento de que o cérebro processa informações de uma forma diferente dos computadores convencionais. O cérebro é um computador (sistema de processamento) altamente complexo, não-linear e paralelo, com capacidade de organizar estruturalmente os neurônios de forma a realizar funções como o reconhecimento de padrões e percepção, muito mais rápido que qualquer computador existente. O computador tem um processamento rápido e preciso na execução de sequência de instruções porém é muito mais lento que o cérebro, por exemplo, no reconhecimento de padrões. A rede neural é uma máquina que modela a maneira como um cérebro realiza determinadas tarefas ou funções de interesse. Uma rede neural pode ser implementada com componentes eletrônicos ou por programação em um computador (BRAGA *et al.*, 2000).

Segundo Braga *et al.*, (2005) as características básicas das redes neurais são:

- ❖ Procura paralela e endereçamento pelo Conteúdo – O cérebro não possui endereço de memória e não procura a informação sequencialmente;
- ❖ Aprendizado – A rede aprende por experiência, não precisando explicitar os algoritmos para executar uma determinada tarefa;
- ❖ Associação – Capacidade da rede em fazer associações entre padrões diferentes;
- ❖ Generalização – A rede neural produz saídas adequadas para entradas que não

estavam presentes durante o treinamento (aprendizagem);

- ❖ Robustez e Degradação – Devido à natureza distribuída da informação armazenada na rede, o seu desempenho se degrada suavemente sob condições de operações adversas,


tal como a perda de elementos processadores ou conexões sinápticas. Para que a resposta da rede seja degradada seriamente, o dano deve ser extenso.

De acordo com Palmiere (2016), pode-se definir uma Rede Neural Artificial (RNA) como sendo um modelo computacional inspirado no sistema nervoso de seres vivos, e que adquire conhecimento através da experiência.

É formada basicamente por um conjunto de unidades de processamento (neurônios artificiais) que são interligados por um enorme número de interconexões (sinapses artificiais) representadas por vetores de peso sináptico. As principais partes do neurônio artificial genérico são as sinapses, função somadora e a função de ativação.

O neurônio artificial é uma unidade fundamental para a operação de uma rede neural. Seu modelo foi inspirado na estrutura neural biológica (PALMIERE, 2016). A Figura 1 ilustra uma forma de um tipo comum de neurônio artificial. Uma rede neural pode ter centenas ou milhares de neurônios artificiais, já o cérebro de um mamífero poder ter bilhões de neurônios.

Figura 1: Modelo genérico da RNA



Fonte: Silva et al., (2010).

A camada de entrada é responsável pelo recebimento das informações que serão analisadas na rede. A camada oculta tem por finalidade extrair as informações associadas a camada de entrada, sendo também responsável pela maior parte do processamento destes

dados. Já a camada de saída agrega os dados das camadas anteriores e ativa uma resposta adequada (SILVA *et al.*, 2010).

3.6.2 Função de Ativação

O modelo de cada unidade da rede pode incluir uma não-linearidade na sua saída, a qual deve ser reduzida. A função de ativação representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade. Segundo Haykin (2001) existem diversos tipos de funções de ativação, sendo as mais utilizadas:

- ❖ Função limiar: normalmente restringe a saída da RNA em valores binários [0,1]. A saída do neurônio assume valor 0 quando seu resultado for negativo, e 1 caso contrário, sendo representada por:

$$f(u) = \begin{cases} 0, & \text{se } u \leq 0 \\ 1, & \text{se } u \geq 0 \end{cases} \quad (5)$$

- ❖ Função sigmoideal: trata-se da função mais comum. É definida como uma função crescente com balanceamento adequado entre o comportamento linear e não linear e assume um intervalo de variação entre 0 e 1. Um exemplo de função sigmóide é a função logística, definida por:

$$f(u) = \frac{1}{1 + \exp(-au)} \quad (6)$$

- ❖ Função tangente hiperbólica: pelo fato da função logística apresentar valores de ativação apenas no intervalo (0, 1), em muitos casos ela é substituída pela função tangente hiperbólica, que preserva a forma sigmoideal da função logística, mas assume valores positivos e negativos. Para a forma correspondente de uma função sigmóide, podemos utilizar a função tangente hiperbólica, dada por:

$$f(u) = \tanh(u) \quad (7)$$


3.6.3 Arquiteturas de RNAs

De acordo com Harkin (2001) a maneira pela qual os neurônios de uma rede estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar

a rede. Uma das maiores dificuldades encontradas no uso das redes neurais é a escolha da melhor arquitetura, uma vez que esse processo é experimental e demanda um grande tempo de execução. Na prática, o processo deve ser aplicado com o intuito de testar vários métodos de aprendizado e as diferentes configurações que uma rede possa ter para a resolução de um problema em específico (MIRANDA *et al.*, 2009). De acordo com Silva *et al.*, (2010) as arquiteturas mais usuais das RNAs são:

❖ **FeedForward de Camada Simples:** Uma camada de entrada diretamente associada a um ou mais neurônios que vão gerar a resposta de saída (Figura 2). O fluxo de dados segue em direção à camada de saída. São empregadas em problemas de classificação de padrões e filtragem.


Figura 2: Arquitetura FeedForward de camada simples



Fonte: Silva *et al.*, (2010).

❖ **FeedForward de Camadas Múltiplas:** Constituída por uma ou mais camadas escondidas de neurônios (Figura 3). São empregadas em problemas de aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica e controle de processos.


Figura 3: Arquitetura Feed Forward de camadas Múltiplas



Fonte: Silva et al., (2010).

- ❖ **Realimentada:** Suas saídas são realimentadas como sinais de entrada para outros neurônios, sendo assim empregadas para o processamento de sistemas variantes no tempo (Figura 4). São empregadas em previsões de séries temporais, otimização, identificação de sistemas e controle de processos.

Figura 4: Arquitetura Realimentada



Fonte: Silva et al., (2010).

De acordo com Amardeep *et al.*, (2017) as RNAs são importantes ferramentas de mineração de dados usadas para classificação e agrupamento. O critério de aprendizagem é por exemplos. Quando fornecido com exemplos suficientes, realiza a classificação e até mesmo descobre novas tendências ou padrões nos dados. No mínimo uma RNAs é

composta por três camadas, entrada, oculta e de saída . Cada camada estão conectadas uma com as outras através de nós.

3.6.4 Aprendizado de RNAs

A maneira pela qual as redes neurais adquirem conhecimento é chamado de algoritmo de aprendizagem, que tem como função modificar, através de um processo iterativo, os pesos sinápticos da rede (treinamento), de modo a alcançar um objetivo desejado (BRAGA *et al.*, 2005).

Segundo Braga e colaboradores (2000) a utilização de uma Rede Neural Artificial na solução de uma tarefa passa inicialmente por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões de informação apresentados pela rede, criando uma representação do problema. Uma definição geral do que vem a ser aprendizagem pode ser expressa da seguinte forma:

Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando, sendo o tipo específico de aprendizagem realizada definido pela maneira particular com ocorrem os ajustes realizados nos parâmetros (BRAGA *et al.*,2000. p.15).

A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando. As RNAs podem ser diferenciadas quanto à forma de aprendizagem, usando os seguintes paradigmas (BISHOP, 1995):

- ❖ **Aprendizado supervisionado:** um supervisor externo fornece à RNA a saída desejada em relação a um padrão de entrada. Com isso, é possível comparar a saída da RNA com a saída desejada, obtendo-se o erro referente à resposta atual. A partir disso, os pesos sinápticos são ajustados de forma a minimizar o erro. A minimização do erro é incremental, pois a cada resposta gerada pela rede, são efetuados pequenos ajustes nos pesos das conexões.
- ❖ **Aprendizado não supervisionado:** não existe um supervisor acompanhando o processo de aprendizagem. Diante disso, a RNA deve procurar algum tipo de correlação ou redundância nos dados de entrada.

Quando as RNAs são utilizadas na modelagem de processos, é usual utilizar-se o aprendizado supervisionado. A implementação deste método, pode ser feita off-line ou on-line. No primeiro caso, os dados do conjunto de treinamento não mudam, e caso seja necessário à inclusão de novos dados, um novo banco de dados destinado ao treinamento deve ser elaborado, contendo os dados antigos e novos. No segundo caso, a rede opera em constante processo de adaptação, sendo atualizada constantemente (BRAGA *et al.*, 2000).

3.6.5 Algoritmo de Aprendizado

Existem vários algoritmos de treinamento para RNAs, com suas vantagens e desvantagens. O algoritmo de back-propagation que, segundo Braga (2000) é um dos mais conhecidos em treinamentos de RNAs por ser um algoritmo supervisionado que o torna mais vantajoso quando se utiliza um especialista do domínio. O algoritmo de treinamento back-propagation baseia-se na retropropagação, ajustando os pesos das unidades das camadas intermediárias, através dos erros identificados na camada de saída (FARACO, 1998).

O algoritmo *backpropagation* procura minimizar o erro obtido pela rede ajustando pesos e limiares para que correspondam às coordenadas dos pontos mais baixos da superfície de erro. Para isto, se utiliza um método de gradiente descendente. O gradiente de uma função está na direção e sentido em que a função tem taxa de variação máxima. Isto garante que a rede percorra na superfície que vai reduzir mais o erro mínimo. O algoritmo *back-propagation* fornece uma aproximação da trajetória no espaço de pesos calculado pelo método do gradiente descendente (BRAGA, 2000).

Para determinar o ponto de erro mínimo global na superfície é necessário uma seleção de parâmetros de treinamento como números de dados, taxa de aprendizagem, função de ativação. Como também adotar critérios de parada como encerrar o treinamento após n ciclos, o erro quadrático médio fica abaixo de uma constante α . No decorrer do treinamento o algoritmo pode convergir para mínimos locais, que são pontos na superfície de erro que apresenta uma solução estável mas não necessariamente a solução desejada (BRAGA, 2000). Alguns técnicas são utilizadas para acelerar o desempenho o algoritmo *backpropagation* como também reduzir a incidência de mínimos locais:

- ❖ Utilizar taxa de aprendizado decrescente;

- ❖ Adicionar nós intermediários;
- ❖ Utilizar um termo *momentum*.

3.6.6 Regra Delta

De acordo com Baughmam (1995) uma limitação do algoritmo *back propagation* é a demanda de tempo para o treinamento da rede, dependendo do tamanho da rede neural, o treinamento pode durar horas ou até dias dependendo da velocidade do processamento de dados do computador. Para sanar esta limitação pesquisadores investigaram novos procedimentos de treinamento. Desta forma, um destes procedimentos é utilizar o algoritmo *vanilla back propagation*, baseado no aprendizado de gradiente descendente (Equação 8).

$$w + 1 = w_a + lr \times e \times t \quad (8)$$

Onde:

w = peso;

w_a = peso anterior;

lr = taxa de aprendizagem;

e=entrada de variáveis;

t=tempo de correção do gradiente descendente.

Outro método de treinamento usando o aprendizado de gradiente descendente é a regra delta, um método iterativo que minimiza o erro de média quadrática. Este algoritmo é semelhante ao algoritmo de *vanilla back propagation*, mas possui várias diferenças entre elas pode -se citar a adição de um *momentum* (Equação 9). O parâmetro momento é um peso extra adicionado aos fatores de peso quando esses são ajustados. Este parâmetro é adicionado ao treinamento com o objetivo de acelerar o treinamento da rede uma vez que quando se muda os fatores do peso melhora-se o rendimento do treinamento da rede (BAUGHMAM *et al.*, 1995).

$$w + 1 = w_a + lr \times t + tm \times [ap] \quad (9)$$

Onde :

tm = termo *momentum*;

ap = ajuste de peso.

Nas resoluções das equações não lineares da RNA o uso do método do gradiente descendente com o *back propagation vanilla*, pode ocorrer desse algoritmo não alcançar a soma do erro médio quadrático mínimo. Assim, se faz necessário a adição de um termo *momentum*.

Algoritmo Levenberg-Marquardt

Segundo Batista (2012) esse método é aplicável em uma função de custo que é expressa como a soma de erros quadráticos (Equação 10).

$$f(w) = \sum_{i=1}^k e^2(i) \quad (10)$$

O sinal do erro $e(i)$ é uma função do vetor de pesos ajustável (w). Dado um ponto de operação $w(n)$, linearizamos a dependência de $e(i)$ em relação a w escrevendo a Equação 11:

$$e'(i, w) = e(i) + \frac{\partial e(i)}{\partial w} (w - w^k) \quad (11)$$

Onde:

$(w - w^k), i=1,2,3,\dots,k$.

Pode-se escrever a Equação 11 matricialmente como:

$$e'(k) = e(k) + J(k) (w - w^k) \quad (12)$$

Onde $e(k)$ é o vetor igual:

$e(k) = [e(1), e(2), \dots, e(k)]^T$

E $J(k)$ (Equação 12) é a matriz jacobiana k por m de $e(k)$:

$$J(k) = \begin{bmatrix} \frac{\partial e(1)}{\partial w_1} & \dots & \frac{\partial e(1)}{\partial w_m} \\ \frac{\partial e(k)}{\partial w_1} & \dots & \frac{\partial e(k)}{\partial w_m} \end{bmatrix} \quad (13)$$

A matriz jacobiana e transporta da matriz de gradiente m por k $\nabla e(k)$, Equação 14:

$$\nabla e(k) = [\nabla e(1), \nabla e(2), \dots, \nabla e(k)] \quad (14)$$

O vetor peso atualizado $w(k+1)$ é assim definido na Equação 15:

$$w(k+1) = \underset{w}{\operatorname{argmin}} \frac{1}{2} e'(n, w)^2 \quad (15)$$

Usando a Equação 15 para calcular a norma euclidiana quadrática de $e'(k, w)$ é obtido a Equação 19:

$$\frac{1}{2} e'(k, w)^2 = \frac{1}{2} e'(k)^2 + e^T(k) J^T(k) \Delta w + \frac{1}{2} \Delta w^T J^T(k) J(k) \Delta w \quad (16)$$

Onde $\Delta w = (w - w(k))$

A fim de minimizar esta expressão diferencia-se a mesma em relação a w e iguala-se o resultado a zero, daí obtêm-se a Equação 17:

$$J^T(k) e(k) + J^T(k) J(k) \Delta w = 0 \quad (17)$$

Resolvendo esta equação para w , pode-se então escrever a Equação 18:

$$w(k+1) = w(k) - J^T(k) J(k)^{-1} J^T(k) e(k) \quad (18)$$

A Equação 18 descreve a forma para o método de Gauss-Newton, porém para que a interação deste método seja compatível, a matriz $J^T(k) J(k)$ deve ser não singular. Então para assegurar esta não singularidade da matriz produto $J^T(k) J(k)$ tem-se como prática atual a adição da matriz diagonal μI . Onde o I é a matriz identidade e μ é um parâmetro que ajusta a taxa de convergência do algoritmo.

Então o método é implementado da forma ligeiramente modificada conhecida como o método de Levenberg Marquardt (Equação 19):

$$w(k+1) = w(k) + (J^T(k) J(k) + \mu I)^{-1} J^T(k) e(k) \quad (19)$$

Esse método, diferentemente do método de Newton, requer apenas o cálculo da matriz Jacobiana do vetor de erro $e(k)$, o que o torna um método de mais fácil implementação, pois a determinação da matriz Jacobiana é muito mais simples que a

determinação da matriz Hessiana. Esse método apresenta convergência em menos iterações, mas requer mais cálculos por iteração devido ao cálculo de matrizes inversas.

3.6.7 Aplicação de Rede Neurais Artificiais

Durán e outros autores (2006) estudaram a degradação de diferentes soluções do corante *Reactive Blue 4* para avaliar o uso do reagente Fenton sob irradiação de luz ultravioleta. A eficiência da degradação fotocatalítica foi determinada a partir da análise dos parâmetros como teor de carbono orgânico total, cor, sulfatos e nitratos. Dados experimentais foram ajustados usando redes neurais.

Um modelo de rede neural artificial foi desenvolvido por Aleboye *et al.*, (2007) para prever a descoloração fotoquímica da solução laranja-ácido 7 por uma combinação de UV e peróxido de hidrogênio. As concentrações iniciais de corante e peróxido de hidrogênio, o pH da solução e o tempo de irradiação UV foram empregados como entrada para a rede; a saída da rede era a eficiência de descoloração. Os dados utilizados neste estudo foram obtidos de nossos trabalhos anteriores. As redes de *feed-forward* multicamadas foram treinadas por 114 conjuntos de padrões de entrada de saída usando um algoritmo de retropropagação.

Dias *et al.*, (2013) pesquisaram a degradação do corante Remazol preto-B 5 utilizando o processo de oxidação avançada Foto-Fenton com radiação UV-A, visando o reuso de água e redução dos custos de produção. Foi realizado um planejamento experimental 2^3 utilizando o H_2O_2 , Fe^{2+} e o corante RB₅ como variáveis independentes e a conversão de carbono orgânico total como a variável resposta. Foi desenvolvido um modelo de redes neurais artificiais (RNA) com a utilização do software Statistica 8.0 que possibilitou a modelagem e a otimização do processo.

Conforme Cavalcanti *et al.*, (2014) no trabalho intitulado como modelagem neural e análise estatística do processo de degradação de chorume por Foto-Fenton solar, tendo como um modelo neural em conjunto com análises estatísticas que representassem a degradação do chorume *in natura* pelo processo Foto-Fenton solar, em função da redução da demanda química de oxigênio. Redes neurais apresentam-se como uma alternativa para a modelagem de processos não-lineares como os processos oxidativos avançados, que envolvem um grande número de variáveis de controle e complexas reações envolvidas. O processo fotocatalítico foi otimizado por um planejamento fatorial fracionado (2^{4-1}) em

duplicata e triplicata no ponto central. Utilizaram como ferramenta computacional para o treinamento o pacote toolbox NNtool do software Matlab.

Roudi *et al.*, (2018) utilizaram a técnica de rede neural artificial (RNA) para derivar um modelo empírico para prever e otimizar o tratamento do lixiviado. Os impactos da razão H_2O_2 : Fe^{2+} , concentração de Fe^{2+} , pH e tempo de reação do processo foram analisados. Amostras de chorume foram coletadas em *Jeram Landfill*, localizado em uma plantação de dendezeiros em *Kuala Selangor*, Malásia. Para avaliar e otimizar o processo de Fenton, foi escolhido um delineamento experimental aleatório para avaliação em escala laboratorial. Algumas variáveis como pH, concentração de Fe^{2+} , tempo de reação e razão H_2O_2 : Fe^{2+} foram consideradas. A ferramenta computacional utilizada para o treinamento da rede foi o software Matlab.

Napoleão *et al.*, (2016) fizeram uma abordagem do tratamento do lixiviado por processo oxidativo avançado via Fenton e modelagem do processo pelas redes neurais artificiais. Foi desenvolvido um planejamento fatorial fracional (2^{3-1}), com triplicata no ponto central e duplicatas aleatórias e as variáveis de entrada foram: quantidade de H_2O_2 . O processo foi modelado via rede neural do tipo feedforward e backpropagation. Ambiente computacional utilizado foi o software de rede Matlab, onde os parâmetros de rede utilizados podem ser verificados.

Na pesquisa de Martins (2014) intitulada como Aplicação de processos oxidativos avançados no tratamento de lixiviado de aterro sanitário foi construído um sistema de tratamento de efluentes em escala de bancada, onde foram analisados dois processos oxidativos a fotólise do H_2O_2 /UV e o Foto-Fenton de modo a avaliar a eficiência dos processos. Através de um planejamento fatorial em sistema de batelada avaliou-se as variáveis independentes: concentração de peróxido de hidrogênio, Tempo e taxa de radiação UV para o processo H_2O_2 /UV; e pH, concentrações peróxido de hidrogênio e ferro para o processo Foto Fenton, analisadas em planejamento fatorial 2^3 com 3 pontos centrais.

A resposta estudada foi a quantidade de matéria orgânica degradada representada pela DQO. Observou-se que os experimentos utilizando tratamento de lixiviados por estes processos, apresentaram significativa eficiência de remoção da DQO do lixiviado.

Zamora *et al.*, (2005) estudaram dois processos oxidativos avançados o Foto-Fenton e a fotólise que foram utilizados para o pré-tratamento de lixiviados de aterro maduro com o objetivo de melhorar sua biodegradabilidade global, avaliados em termos de

DBO₅, até um valor compatível com o tratamento biológico. Em condições experimentais otimizadas (2000 mg L⁻¹ de H₂O₂ e 10 mg L⁻¹ de Fe²⁺ para o sistema foto-Fenton, e 3000 mg.L⁻¹ de H₂O₂ para o sistema H₂O₂/UV). A biodegradabilidade foi significativamente melhorada DBO₅/ DQO de 0,13 a 0,37. Como também ambos os métodos mostraram adequação para remoção parcial da demanda química de oxigênio (DQO), carbono orgânico total (COT) e cor.

Salari e colaboradores (2005) na pesquisa intitulada como aplicação de redes neurais artificiais para modelagem do tratamento de águas residuárias contaminadas com metil terc-butil éter (MTBE) por processo de H₂O₂/UV estudaram a influência dos parâmetros operacionais básicos, como a concentração inicial de H₂O₂ e o tempo de irradiação na fotodegradação do MTBE. Os resultados mostraram que o MTBE pode ser tratado com facilidade e eficácia com o processo UV / H₂O₂ com valor de EEO de 80kWh / m³ / ordem. O modelo proposto baseado na rede neural artificial (RNA) poderia prever a concentração de MTBE durante o tempo de irradiação em condições otimizadas. Uma comparação entre os resultados previstos do modelo de RNA projetado e os dados experimentais também foi realizada.

Utilizando uma rede neural artificial de três camadas Das et al., (2014) pesquisaram sobre a degradação fotocatalítica da carbamazepina. A Titânia-zircônia e o tempo de irradiação UV foram empregados como entrada para o modelo de rede neural artificial e a saída da rede foi a eficiência de degradação da carbamazepina. As redes de feed-forward multicamadas com o algoritmo de treinamento backpropagation Levenberg-Marquardt (trainlm) foram utilizadas para o treinamento da rede. O menor erro quadrático médio foi obtido para a rede de três camadas com a função de transferência de "logsig" e cinco neurônios na camada oculta deram os melhores resultados. Uma comparação entre os valores previstos e dados experimentais seletivos de eficiência de degradação mostrou um alto coeficiente de correlação (R²) de 0,997.

Biglarijoo *et al.*, (2016) no trabalho intitulado como avaliação de parâmetros efetivos em tratamento de lixiviação e otimização do processo utilizando redes neurais, algoritmo genético e metodologia de superfície de resposta.

Neste trabalho, o processo de Fenton foi encontrado para ser uma técnica eficaz para tratar lixiviados quando os inconvenientes deste processo foram minimizados pela escolha de catalisador adequado, considerando parâmetros eficazes e introduzindo condições ótimas. As variáveis efetivas incluíram pH, [H₂O₂] [Fe²⁺], dosagem de Fe²⁺ e

concentração inicial de DQO enquanto remoção de DQO. Por fim, a metodologia de superfície de resposta (MSR) e o algoritmo genético (AG) foram utilizados para otimização do processo. De acordo com os resultados da análise foi alcançado altas eficiências de remoção de DQO quando o lodo gerado ainda é baixo. Assim, os resultados de MSR e AG indicaram que ambos os métodos propunham condições operacionais aproximadas semelhantes. No final, uma fórmula prática foi proposta para o aumento da relação DBO_5 / DQO para cada lixiviado.

4. METODOLOGIA

4.1 ORIGEM DOS DADOS

Os dados que foram utilizados neste trabalho foi proveniente da pesquisa desenvolvida por Martins (2014). Com um sistema experimental que foi instalado e monitorado nas dependências físicas do laboratório da Estação Experimental de Tratamentos Biológicos de Esgotos Sanitário (EXTRABES) da Universidade Estadual da Paraíba- UEPB, localizado no Bairro do Catolé na cidade de Campina Grande-PB. Em uma pesquisa realizada no Programa de Pós-Graduação em Ciência e Tecnologia Ambiental da UEPB.

O lixiviado foi coletado do aterro sanitário da cidade de João Pessoa- PB, que está localizado no Engenho Mussuré, Distrito Industrial, a 5 Km da BR-101, o qual recebe os resíduos do Consórcio de Desenvolvimento Intermunicipal da Região Metropolitana de João Pessoa-PB.

O sistema experimental era formado por uma câmara de radiação como pode ser observado na Figura 5. No interior da câmara foram acopladas três lâmpadas germicidas que emitiam radiação ultravioleta. O lixiviado foi colocado em um Becker de 1000 mL, o qual foi colocado um agitador magnético.

Figura 5: Câmara de Radiação



Fonte: Martins, (2014)

No tratamento do lixiviado foi utilizado dois tipos de processos oxidativos avançados o Foto-Fenton e a fotólise de H_2O_2/UV . Para o sistema Foto-Fenton foi considerado as variáveis concentração de H_2SO_4 , concentração de H_2O_2 , tempo e taxa de

radiação Ultravioleta. No sistema H_2O_2/UV concentração de H_2O_2 , tempo, e taxa radiação Ultravioleta.

Estes parâmetros que foram utilizados para monitorar os processos oxidativos avançados serão usados como sendo as variáveis de entrada na elaboração das redes neurais artificiais.

4.2 ANÁLISE PRELIMINAR

Para construção da rede neural artificial foi considerado um conjunto de 120 dados experimentais referente ao sistema H_2O_2/UV . O conjunto de dados experimentais foi organizado com 3 variáveis independentes peróxido de hidrogênio (H_2O_2), radiação ultravioleta (UV) e tempo uma variável dependente Demanda Química de Oxigênio relativa (DQO) que é a divisão do DQO em intervalo variável pela DQO em um instante inicial. Na Tabela 1 pode-se observar a esquematização dos experimentos de 1 até 10.

Tabela 1: Esquematização dos experimentos H_2O_2/UV

EXP	UV (W)	H_2O_2 (mg/L)	TEMPO (minutos)	DQO (relativa)
1	20	20	15	0,9292
2	20	40	15	0,8377
3	20	60	15	0,7462
4	20	80	15	0,6547
5	20	100	15	0,5632
6	40	20	15	0,8260
7	40	40	15	0,7509
8	40	60	15	0,6758
9	40	80	15	0,6007
10	40	100	15	0,5256

Fonte: Próprio autor, (2019)

Referente ao sistema Foto-Fenton foi construído uma RNA considerando quatro camadas de entrada, uma camada de saída. Na camada oculta variou-se entre uma e duas camadas. Na camada de entrada foi formada por quatro variáveis como pH, tempo, concentração de H_2O_2 e concentração de ferro. Na camada de saída foi formada pela

variável independente DQO relativa. Na Tabela 2 pode-se ser observado a descrição das variáveis consideradas na construção da RNA dos primeiros 10 experimentos.

Tabela 2: Esquematização dos experimentos Foto-Fenton.


Experimentos	H ₂ O ₂ mg/L	FERRO mg/L	pH.	TEMPO Minutos	DQO Relativa
1	3000	200	2	30	0,9322
2	3000	300	2	30	0,9206
3	3000	400	2	30	0,9094
4	3000	500	2	30	0,8986
5	3000	200	3	30	0,907
6	3000	300	3	30	0,8968
7	3000	400	3	30	0,887
8	3000	500	3	30	0,8776
9	3000	200	4	30	0,8846
10	3000	300	4	30	0,8757

Fonte: Próprio autor (2019)

4.3 CRIAÇÃO DA REDE NEURAL ARTIFICIAL

Para criação da Rede Neural Artificial (RNA) dos processos oxidativos avançados tanto o sistema H₂O₂/UV quanto o sistema Foto-Fenton, foi considerado uma arquitetura do tipo Feed Forward múltiplas camadas. Na Figura 6 foi representada uma RNA com uma camada oculta do sistema H₂O₂/UV e do sistema Foto-Fenton nesta camada foi variado o número de neurônios entre 5,10,15,20 e 25.

Figura 6: Representação da rede com uma camada oculta.




Fonte: Próprio autor, (2019)

Foi realizada uma estrutura de RNA com duas camadas ocultas para os processos H_2O_2/UV e do Foto-Fenton (Na Figura 7). Na primeira camada oculta variou-se o número de neurônios entre 5, 10, 15, 20 e 25.

Assim como a primeira camada oculta também variou-se o número de neurônios entre 5, 10, 15, 20 e 25. O conjunto de ensaios que foram implementados no código Matlab foram organizados em subconjuntos mantendo a primeira camada fixa e variando o número de neurônios na segunda camada oculta. Como por exemplo a primeira camada fixa com 5 neurônios e a segunda camada variando entre 5, 10, 15, 20 e 25.

Figura 7: Representação da RNA com duas camadas ocultas



Fonte: Próprio autor, (2019)

4.4 TESTANDO OS ALGORITMOS DE TREINAMENTO

No treinamento da rede, foi utilizado dois tipos de algoritmos o gradiente descendente com *momentum* e a taxa de aprendizagem adaptativa e o *Levenberg Marquardt*. A estrutura da RNA para determinar o melhor algoritmo de treinamento foi uma camada de entrada com três neurônios, uma camada oculta com 10 neurônios e camada de saída com um neurônio conforme descrito na Figura 6. A função de ativação considerada foi a função tangente sigmoide entre as camadas de entrada e a camada oculta e a purelin entre a camada oculta e camada de saída. A divisão dos dados foram 70% dos dados para treinamento e 30% dos dados para validação. Foi usada a mesma estrutura da RNA tanto para o gradiente descendente quanto *Levenberg Marquardt* e foram implementados no *software Matlab*.

4.5 NÚMERO DE CAMADAS OCULTAS E NEURÔNIOS

Com o algoritmo de treinamento *Levenberg-Marquardt* com uma configuração de rede com uma função de ativação tangente sigmoide e purelin. E com a divisão de dados de 70% e 30% para treinamento e validação. Para análise da variação do número de camadas ocultas e de neurônios utilizou-se dois tipos de RNAs uma com uma camada oculta e outra com duas camadas ocultas. Em cada camada oculta variou-se o número de neurônios entre 5, 10, 15, 20 e 25 mantendo as demais camadas de entrada (3 neurônios) e de saída (1 neurônio) fixas.

Com o auxílio do *software* Matlab calculou-se o coeficiente de determinação (R^2) para treinamento, validação e global para analisar o desempenho da rede em simular o processo H_2O_2/UV . Com auxílio do *software* Minitab fez-se uma análise estatística para encontrar o melhor desempenho da RNA. Com a ferramenta Excel plotou-se gráficos de ajuste linear, resíduos e com os dados reais e previstos.

4.6 TREINAMENTO E VALIDAÇÃO

Para avaliar a influência divisão dos dados no desempenho da RNA dividiu-se o conjunto de 120 dados experimentais do trabalho de Martins (2014) em dois subconjuntos conforme pode ser observado na Tabela 2 para o processo H_2O_2/UV . No processo Foto-Fenton dividiu-se os 288 dados experimentais provenientes da pesquisa de Martins (2014) conforme Tabela 3.

Tabela 3: Divisão de dados para treinamento e validação da RNA

Divisão dos Dados	Número de Neurônios	Função de Ativação
70/30	25	Tangente sigmoide
60/40	25	Tangente sigmoide
50/50	25	Tangente sigmoide

Fonte:Próprio autor,(2019)

Variou-se a divisão dos dados no *software* Matlab com um código computacional. Calculou-se o coeficiente de determinação e o erro de treinamento, validação e global

repetindo o mesmo código 20 vezes. Com os resultados realizou-se o ajuste dos dados no *software* Excel entre os dados experimentais com os dados simulados no *software* Matlab.

4.7 ALEATORIZAÇÃO DOS DADOS

Utilizando o *software* Matlab repetindo o mesmo código para treinamento, validação e global 20 vezes. Foi utilizada uma topologia de RNA com uma camada oculta e outra com duas camadas ocultas conforme discutido no tópico 4.3. Com a divisão dos dados de 70% dos dados para treinamento e 30% para validação. Função de ativação tangente sigmoide e purelin. Calculou-se o coeficiente de determinação de treinamento, validação e global e o erro.

Com o auxílio do *software* Minitab foi feito uma análise estatística com os resultados das RNAs para verificar a aleatoriedade do *software* Matlab se interfere nos resultados das RNAs. Foi feito o teste tukey para esta verificação como também foi construído gráficos de intervalos de confiança para os valores de treinamento e validação das RNAs.

4.8 FERRAMENTA COMPUTACIONAL

Com o auxílio do *software* Matlab calculou-se o coeficiente de determinação (R^2) para treinamento, validação e global para analisar o desempenho da rede em simular o processo H_2O_2/UV como também o processo Foto-Fenton. Com auxílio do *software* Minitab fez-se análise estatística para encontrar o melhor desempenho da RNA e para observar se as variáveis de entrada da RNA são assertivas. Com a ferramenta Excel plotou-se gráficos de ajuste linear, resíduos e os dados reais e previstos.

5 RESULTADOS E DISCUSSÃO

Os resultados das RNA's foi gerado utilizando um código computacional com o *software* Matlab repetindo o mesmo código 20 vezes com a finalidade de realizar o treinamento e validação da RNA obtendo o menor erro entre os dados experimentais e os simulados com maior confiabilidade. Considerando o algoritmo de treinamento *backpropagation*.

5.1 PROCESSO H₂O₂/UV

Para obtenção dos resultados do processo H₂O₂/UV foi considerado um conjunto de 120 dados experimentais conforme discutido no tópico metodologia. Foi criada uma RNA com três neurônios na camada de entrada, número de neurônios variável nas camadas ocultas e um neurônio na camada de saída.

5.1.1 Escolha do Algoritmo

A escolha do algoritmo para minização do erro das RNA's para encontrar um melhor modelo empírico do sistema H₂O₂/UV (Tabela 4) foi baseada nos melhores resultados dos coeficientes de determinação de treinamento e validação dos algoritmos gradiente descendente com momento e taxa de aprendizagem adaptativa (GDX) e o Levenberg Marquardt (LM). Para análise foi considerada uma camada oculta com 10 neurônios.

Conforme é observado no trabalho de Salari *et al.*, (2005) intitulado como aplicação de redes neurais artificiais do tratamento de águas residuárias contaminadas com metil terc-butil éter por processo H₂O₂/UV. Utilizou uma topologia de rede com quatro variáveis na camada de entrada, oito neurônios ocultos e um neurônios na camada de saída.

Tabela 4: Coeficientes de Determinação dos Algoritmos

Topologia	Algoritmo	R ² treinamento	R ² validação
3-10-1	GDX	0,7490	0,7279
3-10-1	LM	0,9634	0,9479


De acordo com a Tabela 4 pode-se observar que o melhor algoritmo de minimização do erro foi o *Levenberg Marquardt* com uma configuração de RNA com número de época igual a 10, gradiente igual a $2,39.10^{-5}$ e erro médio quadrático (MSE) igual a 1.10^{-6} .

Utilizou-se no treinamento destas redes uma camada oculta contendo 10 neurônios e funções de ativação sigmoide tangente e purelin.

Na pesquisa intitulada a degradação fotocatalítica da carbamazepina e a predição por redes neurais artificiais de Das *et al.*, (2014) com uma rede multicamadas com o algoritmo de treinamento de backpropagation de Levenberg-Marquardt em comparação entre os valores previstos e os dados experimentais obtiveram o coeficiente de determinação de 0,9970.

Apresentando o coeficiente de determinação de treinamento (R^2_t) de 0,9634 indicando que a rede neural artificial alcançou um desempenho significativo no processo de aprendizagem quando fornecido um conjunto de exemplos do processo simulado. O coeficiente de determinação de validação (R^2_v) de 0,9479 significa que a RNA com os algoritmo de *Levenberg Marquardt* adquiriu conhecimento acerca do processo simulado podendo reproduzir-lo. Com o algoritmo *Levenberg Marquardt* plotou-se o gráfico (Figura 8).

Figura 8: Gráfico do ajuste dos dados de DQO no treinamento e Validação da RNA.



5.1.2 Análise da Arquitetura da RNA

Para análise da melhor arquitetura da RNA foi considerado dois tipos de rede com uma camada oculta e outra com duas camadas. Conforme discutido na metodologia.

5.1.2.1 Rede neural artificial com uma camada oculta

Para avaliar a influência do número de camadas ocultas no desempenho da rede utilizou-se uma camada oculta. Na Tabela 5 estão os valores de treinamento da RNA com uma camada oculta com 5, 10, 15, 20 e 25 neurônios do sistema H₂O₂/UV.

Tabela 5: Coeficientes de determinação da RNA para o treinamento na camada oculta

Experimentos	Neurônios				
	5	10	15	20	25
1	0,9233	0,9656	0,9476	0,9702	0,9644
2	0,934	0,9563	0,9579	0,9371	0,9586
3	0,9424	0,9769	0,9492	0,9498	0,988
4	0,9593	0,9793	0,9679	0,9448	0,9603
5	0,9721	0,9597	0,9758	0,958	0,977
6	0,9791	0,9487	0,9641	0,9556	0,9659
7	0,9478	0,9756	0,9441	0,983	0,9622
8	0,9511	0,9367	0,9829	0,9625	0,9852
9	0,9833	0,969	0,9406	0,9717	0,9834
10	0,9707	0,9663	0,9632	0,9141	0,9741
11	0,9816	0,9571	0,9541	0,9597	0,9771
12	0,9589	0,9747	0,9608	0,9678	0,9803
13	0,968	0,959	0,9704	0,9665	0,9751
14	0,9673	0,969	0,9562	0,9747	0,9793
15	0,9275	0,9636	0,9808	0,9648	0,9573
16	0,952	0,946	0,9668	0,956	0,9611
17	0,966	0,9767	0,9449	0,9726	0,9644
18	0,973	0,9742	0,9795	0,9793	0,9711
19	0,9489	0,9542	0,9518	0,9464	0,9861
20	0,9776	0,9587	0,9838	0,9862	0,9748
Média	0,9592	0,96337	0,96212	0,96104	0,97229

Fonte: Próprio autor, (2019)

De acordo com a Tabela 5 pode-se concluir que o melhor desempenho na etapa de treinamento foi a RNA com uma camada oculta com 25 neurônios. Dessa forma a RNA com 70% dos dados utilizado no treinamento adquiriu conhecimento das informações das variáveis da entrada. Napoleão *et al.*, (2016) na pesquisa com tratamento do lixiviado por processo oxidativo via Fenton e modelagem do processo pela rede neural artificial encontra o número ideal de neurônios na camada oculta baseado nos coeficientes de determinação dos

conjuntos de treino e previsão variando o número de neurônios de 1 a 25. A fase de treinamento mostrou um coeficiente de correlação entre dados reais e previstos com um valor de 0,99. Na Tabela 6 estão descritas os valores de coeficiente de determinação de validação para uma RNA com uma camada oculta. Com variação de neurônios de 5, 10, 15, 20 e 25.

Tabela 6: Coeficientes de determinação para Validação da RNA com uma camada oculta

Neurônios					
Experimentos	5	10	15	20	25
1	0,8845	0,8975	0,9157	0,9668	0,9677
2	0,8876	0,96	0,978	0,9346	0,9389
3	0,8888	0,9256	0,9217	0,9078	0,9893
4	0,9681	0,9647	0,8824	0,7877	0,9729
5	0,9239	0,9325	0,9684	0,9381	0,9809
6	0,9391	0,925	0,9552	0,9158	0,9432
7	0,9708	0,9557	0,9443	0,9727	0,9718
8	0,9656	0,9124	0,9648	0,8905	0,9765
9	0,986	0,9612	0,9177	0,8901	0,9793
10	0,9434	0,8796	0,9858	0,96	0,992
11	0,9826	0,9579	0,966	0,9798	0,9774
12	0,923	0,9813	0,8996	0,902	0,976
13	0,9386	0,9824	0,9774	0,9533	0,9606
14	0,9568	0,9735	0,9603	0,9615	0,9834
15	0,9516	0,9592	0,922	0,9395	0,9473
16	0,953	0,9636	0,9582	0,941	0,9703
17	0,9013	0,9432	0,9305	0,8951	0,9571
18	0,9063	0,9745	0,9371	0,9571	0,9644
19	0,8531	0,9539	0,9554	0,9753	0,9883
20	0,9661	0,9539	0,941	0,9743	0,974
Média	0,93451	0,94788	0,94408	0,93215	0,97057

Fonte: Próprio autor,(2019)

De acordo com a Tabela 6 o melhor desempenho da RNA no critério validação foi a RNA com uma camada oculta com 25 neurônios. Napoleão *et al.*, (2016) também na etapa de previsão, em que é avaliado o poder de generalização da rede, para dados conhecidos, foi obtido um coeficiente de correlação de 0,9958. Na Tabela 7 pode ser observado a análise da variância

Da RNA com uma camada oculta. Fazendo o teste F para avaliar a correlação das variáveis dos valores ajustados temos que as variáveis tem uma relação significativa uma vez que o

valor do $F_{\text{calculado}}$ é maior do que o F_{tabelado} significa que o modelo proposto é estatisticamente significativo.


Tabela 7: Análise de Variância (ANOVA) de uma RNA com uma camada oculta

	Grau de Liberdade	Soma Quadrática	Média Quadrática	$F_{\text{calculado}}$	F_{tabelado}	P-valor
Regressão	1	1,71745092	1,7174509	10235,838	3,922	0,00041441
Resíduo	118	0,01979899	0,0001678			1,19785E-88
Total	119	1,7372499				

Fonte: Próprio autor, (2019)


No gráfico descrito na Figura 9 pode-se observar o ajuste dos dados experimentais e simulados. Pode-se analisar neste gráfico que tanto os dados de treinamento quanto os dados de validação estão ajustados a uma reta. Dessa forma, a RNA com uma camada oculta apresenta uma representatividade na obtenção de conhecimento como também de memorização.

Figura 9: Gráfico de regressão do treinamento e da validação



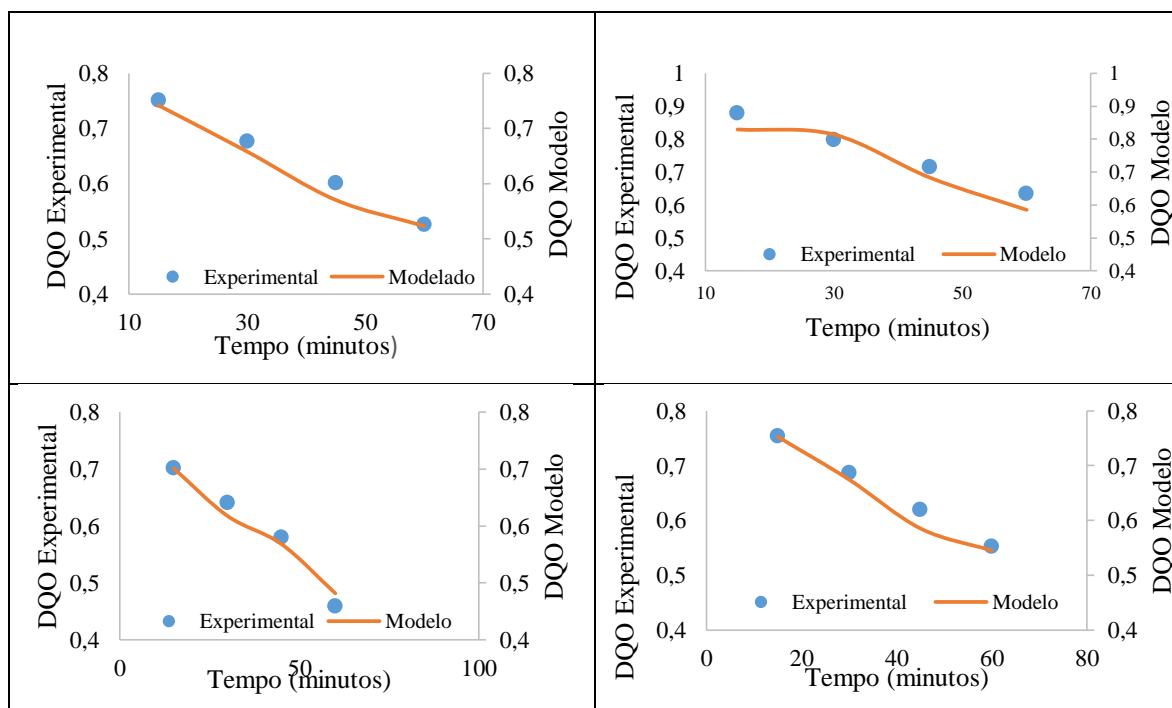
Na Figura 10 pode ser observado a descrição do gráfico de resíduos. Neste gráfico os dados de resíduos apresentam uma variância constante como também se concentram em torno do zero indicando uma normalidade do dados do modelo linear. A distribuição dos erros está entre os valores -0,06 e 0,04 e seguem um padrão aleatório, indicando que o modelo é adequado para prever a variável de saída.

Figura 10: Gráfico de resíduos



Na Figura 11 está plotado quatro gráficos que relaciona os dados das RNAs com uma camada oculta com os dados experimentais do processo H_2O_2/UV . Pode-se averiguar que a linha do modelo passa entre os pontos experimentais. Dessa forma o modelo da RNA com uma camada oculta contendo 25 neurônios representa os dados experimentais do sistema H_2O_2/UV .

Figura 11: Valores Experimentais e modelado



5.1.2.2 Rede neural artificial com duas camadas ocultas

Tabela 8: Coeficientes de determinação com duas camadas ocultas de treinamento da RNA

Experimentos	Neurônios				
	20-5	20-10	20-15	20-20	20-25
1	0,9515	0,96553	0,96456	0,9548	0,96826
2	0,95235	0,90862	0,9623	0,94042	0,96825
3	0,94732	0,96332	0,97777	0,94744	0,94802
4	0,98453	0,86656	0,9419	0,95401	0,94112
5	0,98236	0,9761	0,97936	0,96988	0,97321
6	0,98357	0,95741	0,974	0,98974	0,97163
7	0,9493	0,9751	0,94722	0,94237	0,92627
8	0,96557	0,94799	0,97342	0,9052	0,96666
9	0,95715	0,95405	0,94672	0,96701	0,94797
10	0,96642	0,94331	0,96748	0,94047	0,88059
11	0,97991	0,9892	0,9694	0,94013	0,96655
12	0,97334	0,98433	0,91894	0,97057	0,9222
13	0,98981	0,99401	0,97398	0,94206	0,95064
14	0,97798	0,95705	0,98359	0,96517	0,96734
15	0,97207	0,93372	0,96943	0,93136	0,96071
16	0,97993	0,97941	0,92564	0,96779	0,94142
17	0,9677	0,95289	0,97189	0,88146	0,90279
18	0,95347	0,96331	0,97072	0,98387	0,97414
19	0,9511	0,98385	0,95494	0,97361	0,97233
20	0,97632	0,99163	0,97049	0,94483	0,94008
Média	0,96808	0,95937	0,96219	0,95061	0,94951

Na Tabela 8 e 9 apresenta-se os melhores resultados obtidos na análise dos resultados para das combinações nas camadas ocultas conforme discutido no tópico metodologia. Os resultados dos coeficientes de determinação da RNA com duas camadas ocultas estão descritos na Tabela 8 para os dados de treinamento e na Tabela 9 para os dados de validação.

Na Tabela 8 pode-se observar os melhores resultados das duas camadas ocultas no critério treinamento. Sendo a melhor com duas camadas uma camada oculta com 20 neurônios e outra camada oculta com 5 neurônios. Na Tabela 9 estão os valores de coeficientes de determinação de validação. Nesta Tabela 9 pode-se averiguar que o melhor desempenho foi a uma RNA com duas camadas ocultas com uma camada oculta com 20 neurônios e outra com 5 neurônios.

Tabela 9: Duas camadas ocultas da Validação da RNA.

Experimentos	Neurônios				
	20-5	20-10	20-15	20-20	20-25
1	0,89	0,97152	0,9763	0,96474	0,9631
2	0,9585	0,92595	0,9641	0,95847	0,9799
3	0,9368	0,96338	0,984	0,93601	0,924
4	0,9708	0,86248	0,9564	0,94696	0,9512
5	0,9808	0,97011	0,9784	0,91258	0,9723
6	0,9861	0,95514	0,9628	0,97468	0,9709
7	0,975	0,98279	0,9412	0,96803	0,9252
8	0,9699	0,94968	0,9761	0,9492	0,9185
9	0,9219	0,95456	0,8151	0,98144	0,9679
10	0,9666	0,92325	0,9787	0,95055	0,9139
11	0,9706	0,97882	0,9714	0,91107	0,9789
12	0,9886	0,97439	0,9539	0,91876	0,9619
13	0,9863	0,99482	0,9533	0,92647	0,9603
14	0,9878	0,95304	0,9907	0,97269	0,9845
15	0,9519	0,92549	0,9644	0,92086	0,9156
16	0,9752	0,97542	0,8652	0,9152	0,8734
17	0,9687	0,97833	0,966	0,93639	0,904
18	0,9508	0,97891	0,9729	0,98666	0,9028
19	0,9498	0,98232	0,9774	0,97288	0,9709
20	0,96	0,99216	0,9151	0,93236	0,9764
Média	0,9623	0,95963	0,9532	0,9468	0,9458

Na Tabela 10 pode-se observar a análise da variância entre os dados experimentais e os simulados. Fazendo um teste F, comparando o F calculado com o F tabelado temos que o F calculado é maior do que o F tabelado indicando dessa forma que as variáveis utilizadas no modelo são estatisticamente significativa. O modelo da rede neural artificial tanto é significativo como também preditivo.

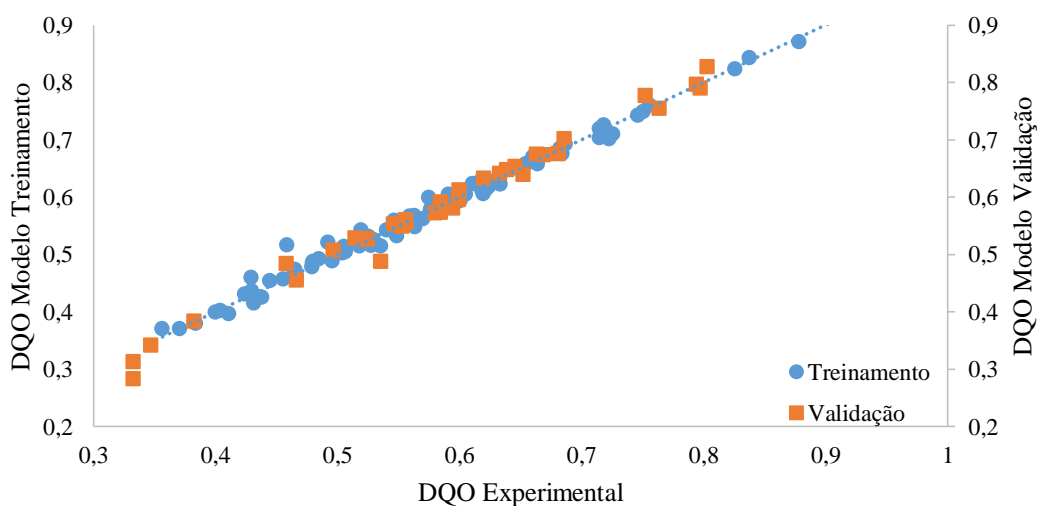
Tabela 10: ANOVA de uma RNA com duas camadas ocultas

	Grau de liberdade	Soma quadrática	Média quadrática	F _{calculado}	F _{tabelado}	Valor -P
Regressão	1	1,62582	1,62582	10002,17	3,922	0,001504
Resíduo	118	0,019181	0,000163			
Total	119	1,645001				

Fonte: Próprio autor, (2019)

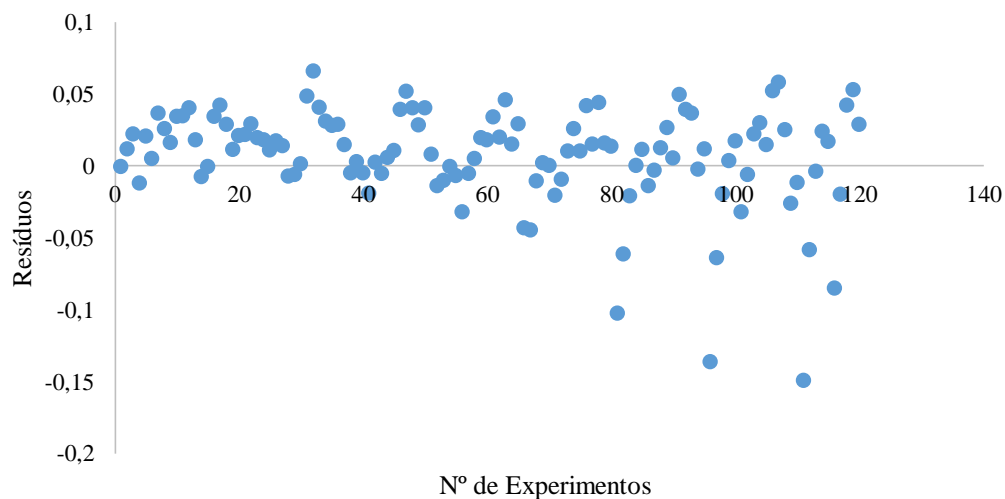
No gráfico de ajuste linear na Figura 16 pode-se ressaltar a linearidade dos dados de treinamento e validação da RNA. Dessa forma pode-se concluir que uma rede neural com duas camadas ocultas uma 20 neurônios na primeira camada e 5 neurônios na segunda camada oculta tanto obteve um conhecimento no processo de treinamento como também memória no processo de validação.

Figura 12: Valores de DQO experimental e do modelo de treinamento e validação



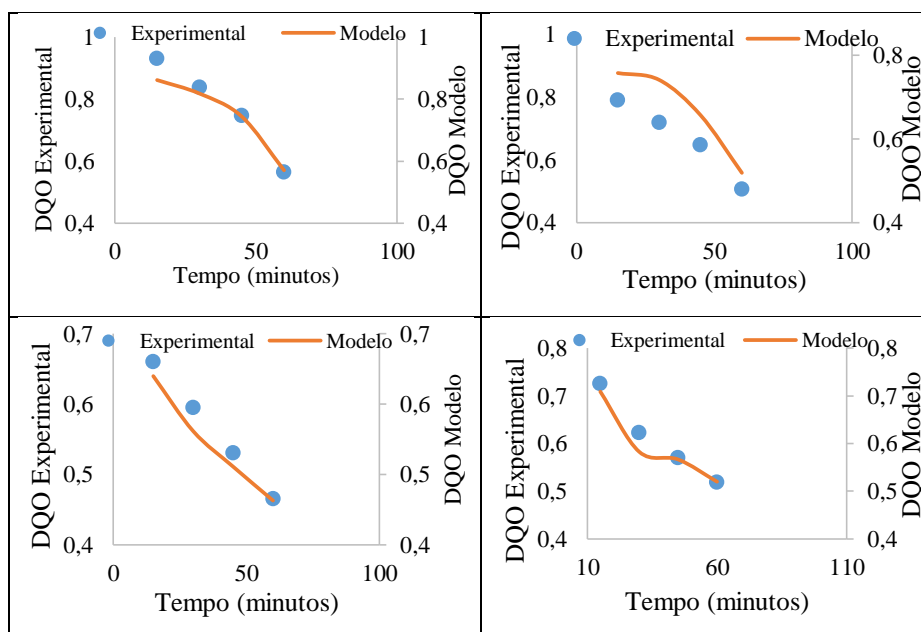
No gráfico de resíduos (Figura 13) está descrito distribuído próximo a linha do zero indicando que existe uma mínima diferença entre os valores experimentais e o predito. Também pode-se analisar neste gráfico que existe uma variabilidade constante entre os lados das ordenadas variando entre -0,015 até 0,05.

Figura 13: Gráfico de resíduos das duas camadas ocultas



Na Figura 14 ilustra quatro gráficos da suposição entre os dados experimentais e os dados simulados do sistema H_2O_2/UV . Pode-se analisar que o modelo da RNA se ajusta aos dados experimentais.

Figura 14: Valores da DQO experimental com os valores da RNA



Fonte: Próprio autor,(2019)

5.1.3 Análise Estatística


Fez-se uma análise do teste de Tukey para comparar a influência do número de neurônios em uma camada oculta como em duas camadas ocultas do sistema H_2O_2/UV .

Como também plotou-se um gráfico de intervalo para determinar um intervalo onde se encontra os valores mínimo e máximo dos coeficientes de determinação.

5.1.3.1 RNA com uma camada oculta

No gráfico (Figura 15) está descrito o resultado do teste de Tukey com nível de confiança de 95%. Como também obteve-se os intervalos de confiança para uma rede neural artificial com três camadas, sendo uma camada de entrada com três neurônios, uma camada oculta contendo 25 neurônios e uma camada de saída com um neurônio.


Figura 15: Teste de Tukey uma camada oculta



Fonte: Próprio autor, (2019)

Fazendo um comparativo entre as camadas ocultas com 5, 10, 15, 20 e 25 neurônios através do teste de Tukey pode-se observar que os valores das médias correspondentes das camadas ocultas são estatisticamente iguais. A diferença entre estes valores dos coeficientes de determinação justifica-se pela influência causada pelo *software Matlab* no fluxo de dados que no sistema operacional que resultada em valores diferentes para mesma situação. Que no funcionamento do *software* não segue uma sequência consecutiva dos dados mas uma captura de dados de forma aleatória. Na Figura 20 está descrita o gráfico de intervalos de confiança dos coeficientes de determinação.

Figura 16: Gráfico de intervalos de confiança com uma camada oculta

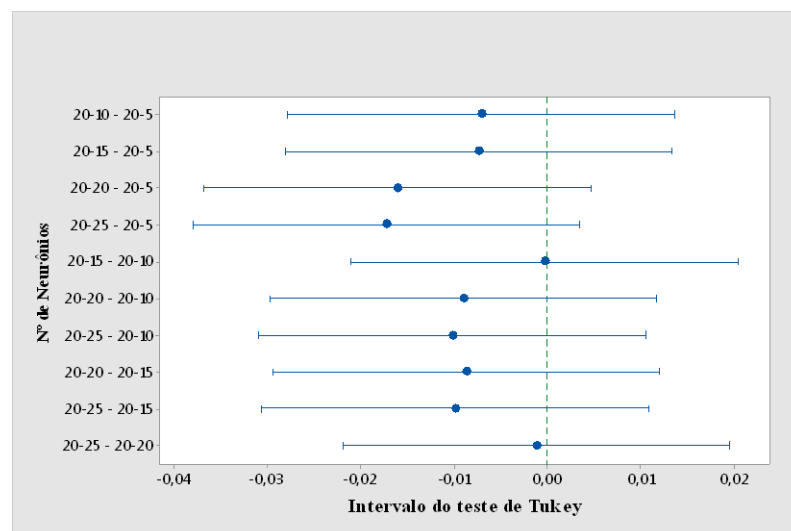


Pode-se analisar neste gráfico a faixa de valores mínimo e máximo para cada camada oculta. Como pode ser observado na camada oculta com 5 neurônios com um intervalo de confiança de aproximadamente de 0,9570 até 0,9680.

5.1.3.2 RNA com duas camadas ocultas

Conforme discutido no item arquitetura com duas camadas ocultas. Nesta análise estatística considerou-se o melhor desempenho da arquitetura para duas camadas ocultas. Com a primeira camada oculta com 20 neurônios fixos e variando o número de neurônios na segunda camada oculta entre 5, 10, 15, 20 e 25. Na Figura 21 está descrito o gráfico do teste de Tukey. pode-se concluir com este gráfico que as camadas ocultas.


Figura 17: Teste Tukey com duas camadas ocultas



Pode-se concluir com este gráfico que as duas camadas ocultas com uma camada fixa e outra variando (Figura 17) são iguais estatisticamente. Os valores dos coeficientes de

determinação são diferentes pelo fato como o software Matlab funciona. Na Figura 18 tem-se o gráfico de intervalos para duas camadas ocultas. Estes valores de intervalos varia entre 0,940 até 0,9800 e projetando uma reta horizontalmente neste gráfico verifica-se que todos os intervalos passam pela reta dando mais um indicativo que estas camadas ocultas são iguais estatisticamente.

Figura 18: Gráfico de intervalos de confiança com duas camadas ocultas



Fonte: Próprio autor, 2019

5.1.4 Análise do ruído na RNA

Usando os 120 dados experimentais de DQO fez uma análise estatística do ruído com 10% e 20% dos dados originais. Calculou-se os valores de ruído de 10% e 20% usando um cálculo com um valor mínimo somado mais a diferença entre o valor máximo e mínimo vezes um aleatório (neste caso considerou-se como valor aleatório 0,1).

5.1.4.1 RNA com uma camada oculta

Com uma uma camada oculta com 25 neurônios avaliou-se a influência dos dados com ruído de 10% e 20%. Na Tabela 5.6 está descrito os valores dos coeficientes de determinação de treinamento (R^2T), validação (R^2V) e global (R^2G).

Tabela 11: Coeficientes de determinação de uma RNA com dados originais e com ruído

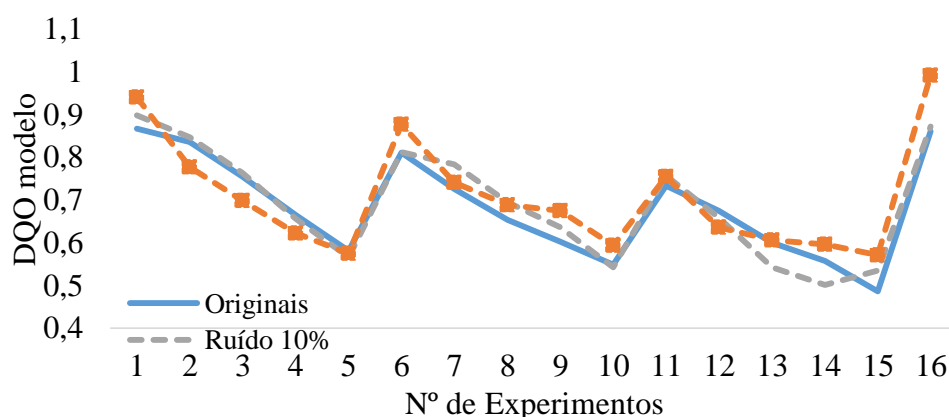
Ruído	R^2 Treinamento	R^2 Validação	R^2 Global
Originais	0,97229	0,97057	0,9717
10%	0,92349	0,92085	0,92301
20%	0,76467	0,71405	0,75191

Fonte: Próprio autor, 2019

Nesta Tabela 11 pode-se observar em comparação com os valores originais temos que com o aumento do ruído nos dados originais em 10% e 20% diminui-se a eficiência do desempenho da RNA.

Na Figura 19 pode-se analisar o decaimento do desempenho da RNA justificado pelo aumento de ruído nos originais. Pode-se analisar também a comprovação descrita na Tabela 11 com a diminuição do coeficiente de determinação da rede neural artificial com o aumento do ruído de 10% e 20%.

Figura 19: Comparação entre os valores do ruído com os originais



Fonte: Próprio autor, 2019

5.1.4.2 RNA com duas camadas ocultas

Considerando uma topologia com duas camadas ocultas com 20 neurônios na primeira camada oculta e 5 neurônios na segunda camada oculta como sendo a melhor conforme visto no item arquitetura com duas camadas (5. 1. 3. 2).

Tabela 12: Coeficientes de determinação valores de ruído com duas camadas ocultas.

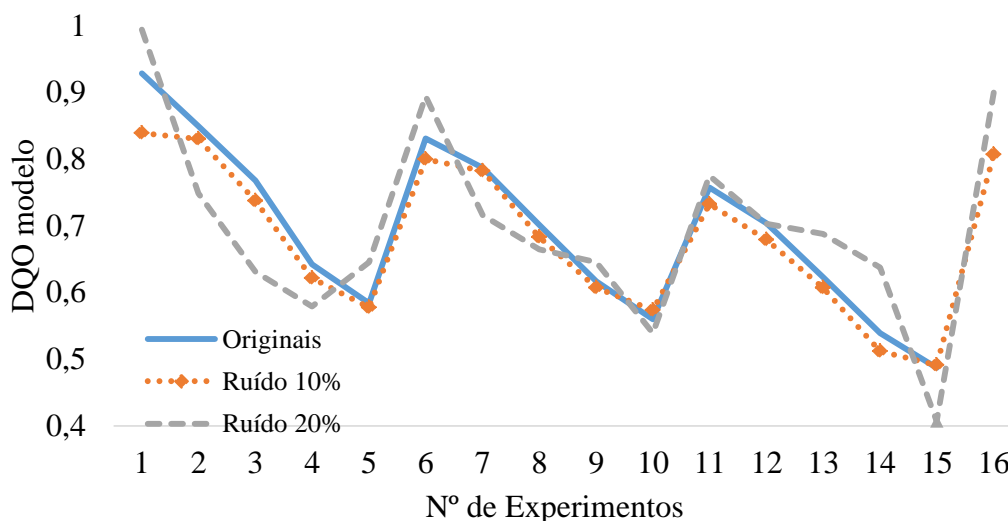
	R ² Treinamento	R ² Validação	R ² Global
Originais	0,96808	0,96231	0,96628
Ruído 10%	0,89718	0,88976	0,89515
Ruído 20%	0,70909	0,73953	0,71898

Fonte: Próprio autor, 2019

Nesta Tabela 12 pode-se observar em comparação com os valores originais temos que com o aumento do ruído nos dados originais em 10% e 20% diminui-se a eficiência

do desempenho da RNA. Na Figura 20 pode-se analisar os valores dos dados originais em comparação com os dados com ruído de 10% e 20%. E verificar assim como na Figura 19 perda da eficiência no desempenho da RNA devido a soma de erro presentes nos dados experimentais.

Figura 20: Comparação dos dados de ruído com o valores originais



Fonte: Próprio autor, 2019

5.1.5 Divisão do conjunto de dados

O conjunto de dados foi dividido em dois subconjuntos, um subconjunto de dados para treinamento e outro subconjunto para validação.

5.1.5.1 RNA uma camada oculta

Na Tabela 12 está os valores das médias da divisão dos 120 provenientes do tratamento de H_2O_2/UV com lixiviado.

Tabela 12: Divisão dos dados experimentais numa RNA com uma camada oculta

Treinamento-Validação	Treinamento R^2	Validação R^2	Global R^2
Divisão Dos dados	Média	Média	Média
70%-30%	0,9690	0,9679	0,9688
60%-40%	0,9693	0,9680	0,9692
80%-20%	0,9678	0,9672	0,9671

Fonte: Próprio autor, 2019

De acordo com a Tabela 12 com a divisão de dados com 60% para treinamento e 40% para validação foi a divisão da RNA que apresentou o melhor desempenho para uma arquitetura de RNA com uma camada oculta.

5.1.5.2 RNA com duas camadas ocultas

Na Tabela 13 está os valores da divisão dos dados com 70%, 60% e 80% para treinamento e 30%, 40% e 20% para validação.

Tabela 13: Divisão dos dados com duas camadas ocultas

Divisão dos Dados	Treinamento R ²	Validação R ²	Global R ²
70%-30%	0,968	0,9623	0,9663
60%-40%	0,9674	0,9637	0,9651
80%-20%	0,9588	0,9625	0,96

Fonte: Próprio autor, 2019

Pode-se verificar com a Tabela 13 que o melhor desempenho para uma RNA com duas camadas é a divisão dos dados com 70% para treinamento e 30% para validação. A mudança da arquitetura de uma camada oculta para duas ocultas interferiu no efeito da divisão dos dados no processo H₂O₂/UV.

5.2 PROCESSO FOTO- FENTON

Nos resultados do processo Foto-Fenton foi considerado um conjunto de 288 dados experimentais conforme discutido no tópico metodologia. Foi criada uma RNA com quatro neurônios na camada de entrada, um número de neurônios variável um neurônio na camada de saída.

5.2.1 Análise da arquitetura da RNA

Assim como no processo H₂O₂/UV analisou-se a arquitetura das RNA's com uma camada oculta e outra duas camadas ocultas. Com o número de neurônios nestas camadas ocultas variável.

5.2.1.1 Rede neural artificial (RNA) com uma camada oculta

Utilizando o processo oxidativo avançado Foto-Fenton fez-se uma varredura com uma camada oculta na topologia da RNA com número de neurônios variando entre 5, 10, 15, 20 e 25. Os resultados dos coeficientes de determinação de treinamento estão exposto na Tabela 14.


Tabela 14: Coeficientes de determinação de treinamento com uma camada oculta

Experimentos	Neurônios				
	5	10	15	20	25
1	0,9691	0,9607	0,9867	0,9655	0,9682
2	0,987	0,976	0,969	0,9732	0,9716
3	0,9935	0,9708	0,9624	0,9518	0,9668
4	0,9848	0,9649	0,9767	0,9719	0,9722
5	0,9909	0,9678	0,9726	0,9727	0,9719
6	0,969	0,97	0,9737	0,962	0,9756
7	0,9801	0,9624	0,958	0,973	0,9566
8	0,9835	0,9683	0,9756	0,9555	0,9696
9	0,9696	0,9756	0,9867	0,9712	0,9792
10	0,9816	0,9782	0,9606	0,9586	0,974
11	0,9747	0,9759	0,979	0,9565	0,9876
12	0,9613	0,9595	0,9643	0,9842	0,9476
13	0,9514	0,9778	0,9605	0,9539	0,9721
14	0,9615	0,9677	0,9657	0,9849	0,9809
15	0,9795	0,9633	0,9854	0,9773	0,9808
16	0,9701	0,96	0,948	0,9741	0,9672
17	0,9813	0,9553	0,9734	0,9809	0,9612
18	0,9544	0,9547	0,9618	0,9615	0,9788
19	0,98	0,9769	0,9565	0,9555	0,9697
20	0,9466	0,9375	0,9608	0,9795	0,9876
MÉDIA	0,9735	0,9662	0,9689	0,9682	0,972

Fonte: Próprio autor, 2019

Na Figura 21 está descrita o ajuste linear dos dados de treinamento e validação dos dados experimentais com os dados de treinamento e validação do modelo.

Figura 21: Ajuste linear dos dados de treinamento e Validação da RNA.



Fonte: Próprio autor, 2019

De acordo com a Tabela 14 pode-se observar que o melhor desempenho foi a RNA com uma camada oculta com 5 neurônios por apresentar média maior do coeficiente de determinação de treinamento. Na Tabela 15 estão os valores dos coeficientes de determinação de validação da RNA com uma camada oculta contendo 5 neurônios.

Tabela 15: Coeficientes de determinação de Validação com uma camada oculta

Experimentos	Neurônios				
	5	10	15	20	25
1	0,9802	0,9576	0,9883	0,9668	0,97229
2	0,9853	0,9815	0,9681	0,9731	0,9648
3	0,9938	0,968	0,9665	0,9478	0,97803
4	0,9899	0,9667	0,9858	0,979	0,97463
5	0,992	0,9715	0,9711	0,9561	0,97609
6	0,9749	0,9706	0,9705	0,949	0,97569
7	0,9887	0,9558	0,9605	0,9637	0,95978
8	0,9917	0,9713	0,9787	0,957	0,96988
9	0,9693	0,9769	0,9876	0,9701	0,97646
10	0,9876	0,984	0,9544	0,9634	0,97563
11	0,9618	0,97	0,971	0,9578	0,98727
12	0,9659	0,9679	0,9613	0,9825	0,95853
13	0,9583	0,9752	0,9625	0,9717	0,96815
14	0,9371	0,9682	0,9575	0,9898	0,97993
15	0,9795	0,9654	0,9867	0,9718	0,97842
16	0,9556	0,949	0,9611	0,9699	0,97456
17	0,9851	0,9515	0,9606	0,9837	0,96656
18	0,9489	0,9593	0,9547	0,9651	0,97621
19	0,98	0,9738	0,9458	0,9694	0,94673
20	0,9638	0,9531	0,9724	0,9746	0,98246
MÉDIA	0,9745	0,9669	0,9683	0,9681	0,9721

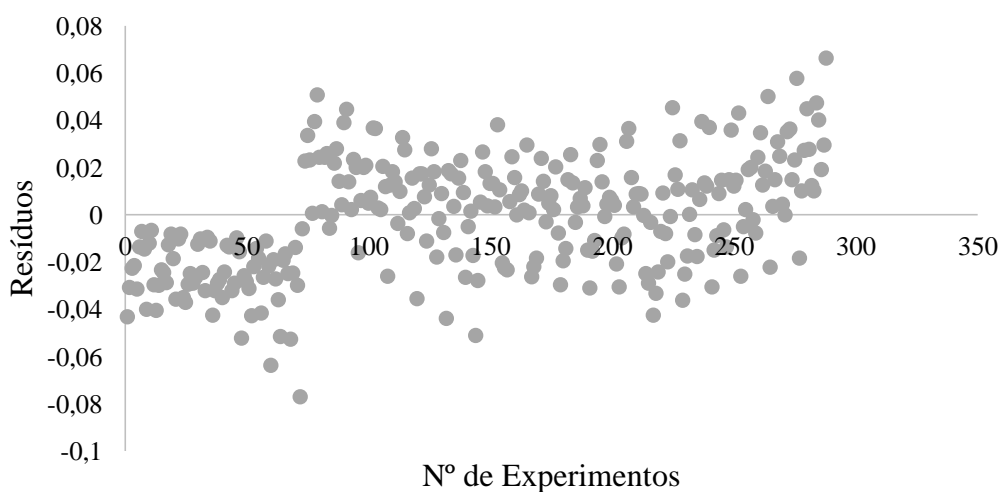
Na Tabela 16 está descrita a análise da variância da RNA com uma camada oculta com 5 neurônios fazendo a análise de variância dos dados reais e previstos pode-se analisar através do teste F e valor-P que o modelo linear proveniente dos da RNA com 5 neurônios é estatisticamente significativo como preditivo.

Tabela 16: Tabela da Análise de Variância (ANOVA) para uma RNA com uma camada oculta

	Grau de Liberdade	Soma Quadrática	Média Quadrática	$F_{\text{calculado}}$	F_{tabelado}	Valor-P
Regressão	1	5,563242	5,563242	45529,02	3,84	$9,68 \cdot 10^{-18}$
Resíduo	286	0,034947	0,000122			
Total	287	5,598189				

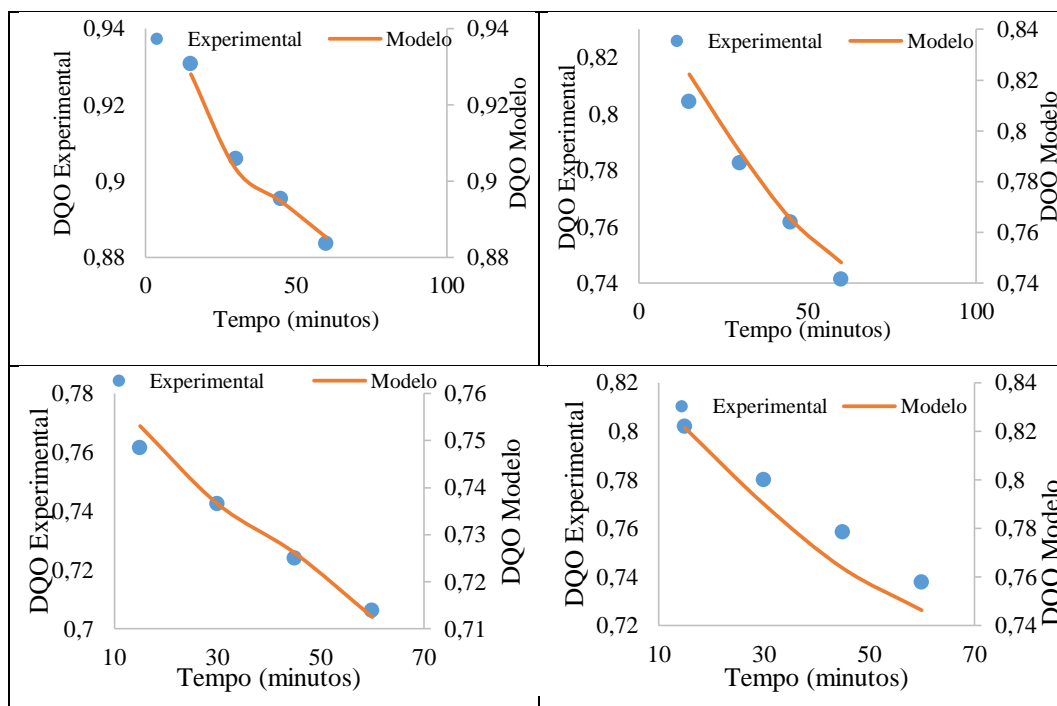
Fonte: Próprio autor, 2019

Figura 22: Gráfico de Resíduos com uma camada oculta



Biglarjoo *et al.*, (2016) verificaram que uma RNA proporcionou maior capacidade preditiva enquanto ambos os modelos eram estatisticamente adequados com coeficiente de determinação acima 0,90. Na Figura 22 está descrita o gráfico de resíduos tem-se que os dados provenientes dos erros calculado entre os dados reais e previstos estão distribuído de forma constante e uniforme na extremidade superior e inferior e próximo de zero indicando que os valores previstos pela RNA estão próximo dos reais.

Figura 23: Dados experimentais e os dados do modelo com uma camada oculta



5.2.1.2 Rede neural artificial (RNA) com duas camadas ocultas

Tabela 17: Coeficientes de determinação de treinamento com duas camadas ocultas

Experimentos	Neurônios				
	5-5	5-10	5-15	5-20	5-25
1	0,98303	0,9707	0,98069	0,991	0,99616
2	0,98501	0,98725	0,99035	0,99178	0,98455
3	0,94037	0,9609	0,97861	0,97513	0,97868
4	0,9699	0,99882	0,95413	0,96382	0,98262
5	0,99409	0,97499	0,99136	0,96649	0,98856
6	0,98811	0,98769	0,99194	0,98435	0,97125
7	0,96073	0,97926	0,96223	0,98989	0,99282
8	0,99643	0,99077	0,97758	0,95212	0,99103
9	0,99651	0,9814	0,96089	0,94036	0,97708
10	0,98143	0,96853	0,98823	0,97022	0,9832
11	0,98875	0,96918	0,9828	0,97975	0,98821
12	0,9564	0,98313	0,98057	0,98554	0,97258
13	0,94258	0,99225	0,98933	0,99582	0,96346
14	0,9839	0,98659	0,98646	0,9812	0,99793
15	0,98581	0,98116	0,99346	0,97675	0,98795
16	0,97237	0,96973	0,97683	0,9658	0,99402
17	0,96298	0,99275	0,98854	0,96382	0,98915
18	0,98388	0,98452	0,97401	0,98756	0,98258
19	0,96269	0,98121	0,98953	0,96608	0,98746
20	0,93617	0,95609	0,96744	0,98724	0,97321
MÉDIA	0,97356	0,97985	0,98025	0,97574	0,98413

Fazendo um comparativo com os melhores de resultados das camadas ocultas das RNAs variando os números de neurônios tanto na primeira camada oculta como na segunda camada oculta encontrou-se o melhor desempenho para duas nas camadas ocultas. Desta forma manteve-se a primeira camada oculta fixa com 5 neurônios e variou-se o número de neurônios entre 5, 10, 15, 20 e 25 na Tabela 17.

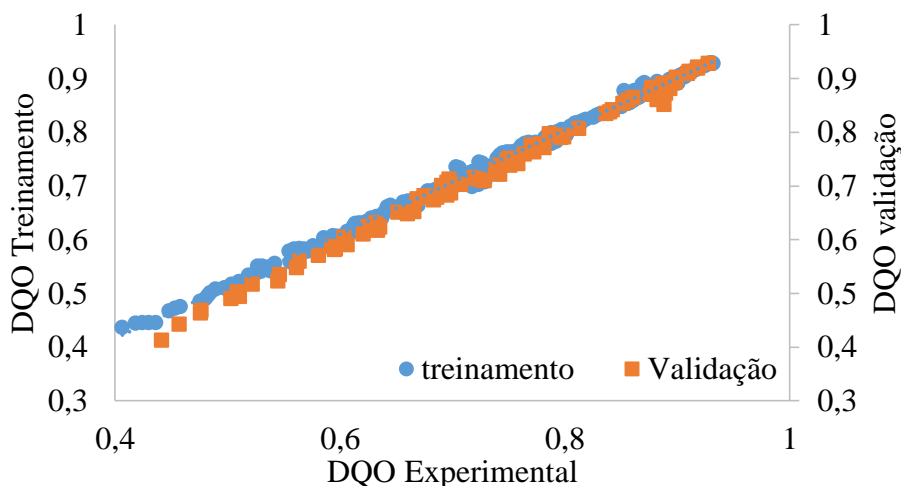
De acordo com a Tabela 17 duas camadas ocultas com 5 neurônios na primeira camada oculta 25 neurônios na segunda camada oculta. Na Tabela 18 estão os coeficientes de determinação de validação.

Tabela 18: Coeficientes de determinação de Validação com duas camadas ocultas

Experimentos	Neurônios				
	5-5	5-10	5-15	5-20	5-25
1	0,98303	0,9707	0,98069	0,991	0,99616
2	0,98501	0,98725	0,99035	0,99178	0,98455
3	0,94037	0,9609	0,97861	0,97513	0,97868
4	0,9699	0,99882	0,95413	0,96382	0,98262
5	0,99409	0,97499	0,99136	0,96649	0,98856
6	0,98811	0,98769	0,99194	0,98435	0,97125
7	0,96073	0,97926	0,96223	0,98989	0,99282
8	0,99643	0,99077	0,97758	0,95212	0,99103
9	0,99651	0,9814	0,96089	0,94036	0,97708
10	0,98143	0,96853	0,98823	0,97022	0,9832
11	0,98875	0,96918	0,9828	0,97975	0,98821
12	0,9564	0,98313	0,98057	0,98554	0,97258
13	0,94258	0,99225	0,98933	0,99582	0,96346
14	0,9839	0,98659	0,98646	0,9812	0,99793
15	0,98581	0,98116	0,99346	0,97675	0,98795
16	0,97237	0,96973	0,97683	0,9658	0,99402
17	0,96298	0,99275	0,98854	0,96382	0,98915
18	0,98388	0,98452	0,97401	0,98756	0,98258
19	0,96269	0,98121	0,98953	0,96608	0,98746
20	0,93617	0,95609	0,96744	0,98724	0,97321
MÉDIA	0,97356	0,97985	0,98025	0,97574	0,98413

Assim como na Tabela 17 a Tabela 18 o melhor desempenho foi de uma RNA com duas camadas ocultas com 5 neurônios na primeira camada e 25 neurônios na segunda camada oculta no critério validação.

Figura 24: Ajuste linear do treinamento e da validação da RNA



Na Figura 24 pode-se observar o ajuste linear dos coeficientes de determinação de treinamento e validação do sistema Foto-Fenton apresenta um desempenho significativo.

Fazendo um comparativo entre uma RNA com uma camada oculta e uma RNA com duas camadas ocultas pode-se concluir que a melhor RNA para realização do treinamento e validação é com duas camadas ocultas com 5 neurônios na primeira camada oculta e 25 na segunda camada oculta.

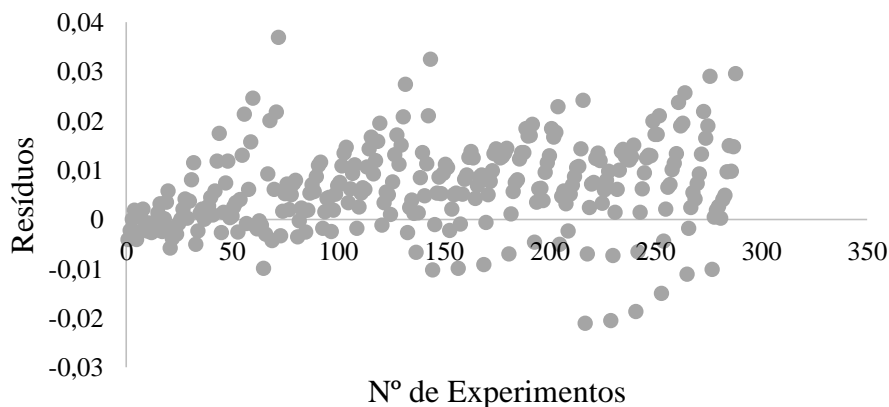
Tabela 19: Coeficientes de determinação de Validação

	Grau de Liberdade	Soma Quadrática	Média Quadrática	$F_{\text{calculado}}$ F_{tabelado}	Valor-P
Regressão	1	5,040765	5,040765294	3,84	$4,83 \cdot 10^{-26}$
Resíduo	286	0,01637	5,72371E-05		
Total	287	5,057135			

Fonte: Próprio autor, 2019

Conforme a Tabela 19 pode-se verificar na análise de variância entre os valores de reais e previstos que o modelo da RNA de acordo com as variáveis estatísticas o teste F e o valor-P menor que 0,05 tem-se que o modelo linear proveniente da RNA é significativo e preditivo e que as variáveis de entrada utilizadas para a construção da RNA foram assertivas.

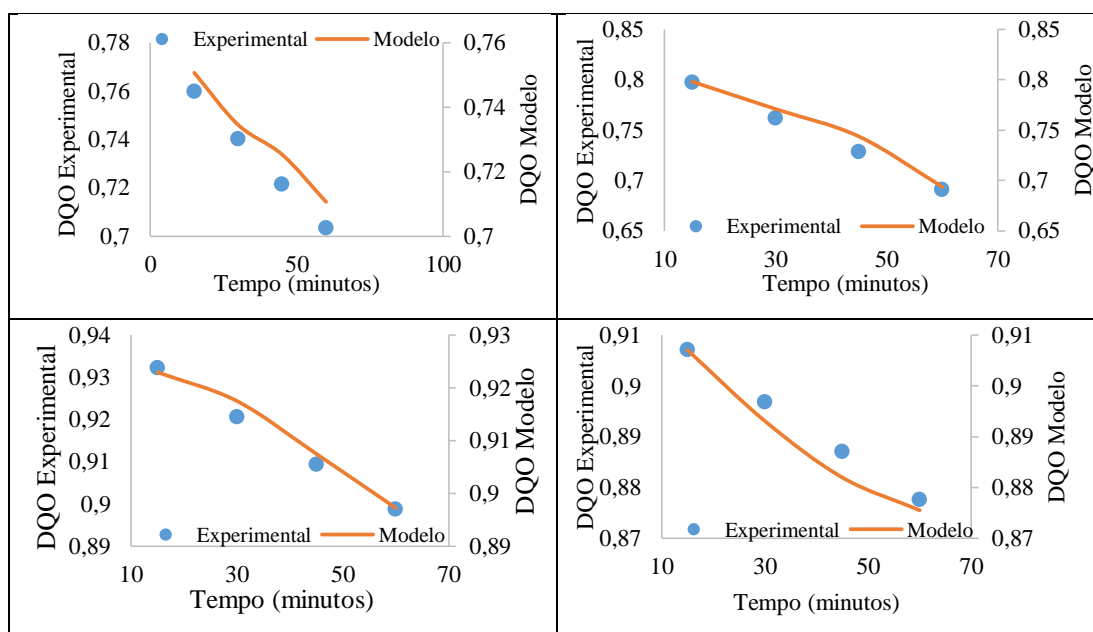
Figura 25: Gráfico de resíduos com duas camadas ocultas



Fonte: Próprio autor, 2019

Na Figura 30 ilustra quatro gráficos da suposição entre os dados experimentais e os dados simulados do sistema Foto- Fenton. Pode-se analisar que o modelo da RNA se ajusta aos dados experimentais. Haja vista que tanto os dados reais quanto os previstos estão próximos.

Figura 8: Valores de DQO experimental com o do modelo



Fonte: Próprio autor, 2019

Fazendo um comparativo entre uma RNA com uma camada oculta e uma RNA com duas camadas ocultas pode-se verificar que a melhor RNA para realização do treinamento e validação é com duas camadas ocultas com 5 neurônios na primeira camada oculta e 25 na segunda camada oculta.

6. CONCLUSÃO

Aplicando-se as Redes Neurais Artificiais (RNA) na modelagem empírica de dados oriundos do tratamento de lixiviado de aterro sanitário, foi possível obter as seguintes conclusões:

1. Usando os algoritmos de minimização de erros do gradiente descendente com momento de taxa de aprendizagem adaptativa e o *Levenberg Marquardt*, o melhor algoritmo para treinar a rede neural artificial (RNA) foi o *Levenbeg Marquardt* onde apresentou coeficientes de determinação acima de 0,95.
2. No sistema H_2O_2/UV uma RNA com uma camada oculta com vinte e cinco neurônios apresentou melhor resultado. No sistema Foto-Fenton foi uma RNA com uma camada oculta com cinco neurônios. Para os diferentes processos o melhor desempenho foi observado em arquitetura de redes diferentes.
3. Com duas camadas ocultas no sistema H_2O_2/UV o melhor desempenho foi observado na RNA com a primeira camada oculta com vinte neurônios e na segunda camada oculta com cinco neurônios. No sistema Foto-Fenton o melhor desempenho com duas camadas ocultas foi analisado em uma RNA com cinco neurônios na primeira camada oculta e vinte e cinco neurônios na segunda camada oculta.
4. Tanto no treinamento quanto na validação nos processos oxidativos avançados os valores dos coeficientes de determinação são estatisticamente iguais. Nas análises optou-se pelo maior número do coeficiente de determinação para maior representação do modelo.
5. Com relação a presença de ruído nos dados de DQO, foi comprovado que os mesmos causam perda na eficiência da RNA. Quanto maior o ruído nestes dados menor o desempenho da rede em simular os dados experimentais.
6. Com a divisão dos dados da RNA no processo oxidativo avançado H_2O_2/UV com 60% dos dados para treinamento e 40% dos dados para validação apresentou resultados significantes indicando que as variáveis de entrada considerado na criação da rede neural artificial foi assertivo.

REFERÊNCIAS

ALEBOYEH.A, KASIRI.M.B, OLYA.M.E, ALEBOYEH.H.**Prediction of azo dye decolorization by UV/H₂O₂ using artificial neural networks.** Dyes and Pigments, p.288-294. 2007.

AMARDEEP, R. SWAMY, T. IJECS. **Training Feed forward Neural Network With Backpropogation Algorithm.**v.6,p.19860-19866, Janeiro. 2017.

AMOR, C., TORRESSOCIA, E., PERES, A., MALDONADO, LM., OLLER, I., MALATO,S., LUCAS, MS. **Tratamento de lixiviados de aterro maduro por coagulação / floculação combinado com processos Fenton e foto-Fenton solar.** J. Hazard Mater, p. 261 – 268. 2015.

ANDREOZZI, R., CAPRIO, V, INSOLA, A., MAROTTA, R. **Advanced oxidation processes (AOP) for water purification and recovery.** Catalysis Today. V.53, p. 51-59, 1999.

ROUDI, A.M., CHELLIAPAN, S., MOHTAR,W.H.M.W. **Prediction and Optimization of the Fenton Process for the Treatment of Landfill Leachate Using an Artificial Neural Network.**Water. 2018.

ARAUJO, F. V. F.; YOKOYAMA, L.; TEIXEIRA, L. A. C.; CAMPOS, J. C. **Heterogeneous fenton process using the mineral hematite for the discolouration of a reactive dye solution.** Brazilian Journal of Chemical Engineering, v. 28, p. 605-616, 2011.

ARAÚJO, B. G. P.; OLIVEIRA JÚNIOR, E. F.; VIEIRA JUNIOR, A. S. **Resíduos Sólidos Urbanos: análise sobre a situação do conjunto Albano Franco – Riachão do Dantas–SE.** 2013.

ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE LIMPEZA PÚBLICA (ABRELPE).**Panorama dos Resíduos Sólidos no Brasil 2013.**Disponível em :<<http://www.abrelpe.org.br/Panorama/panorama2013.pdf>> Acesso em 20 de março de 2018.

ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE LIMPEZA PÚBLICA (ABRELPE). **Panorama dos Resíduos Sólidos no Brasil 2015**. Disponível em :<<http://www.abrelpe.org.br/Panorama/panorama2015.pdf>> Acesso em 20 de março de 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 8.419**: Apresentação de projetos de aterros sanitários de resíduos sólidos. Rio de Janeiro, 2002.

BATISTA, B.C. F. **Soluções de Equações Diferenciais Usando Redes Neurais de Múltiplas camadas com os métodos da Descida mais íngreme e Levenberg-Marquardt**. Dissertação. Universidade Federal do Pará. 2012.

BAUN, A.; REITZEL, L.A.; LEDIN, A.; CHRISTENSEN, T.H.; BJERG, P.L. **Natural attenuation of xenobiotic organic compounds in a landfill leachate plume (Vejen, Denmark)**. *Journal of Contaminant Hydrology*, v. 65, p. 269-291, 2003.

BISHOP, C.M. **Neural Networks for Pattern Recognition**. Department of Computer Science and Applied Mathematics Aston University Birmingham, UK.1995.

BRAGA, A.P; CARVALHO, A.C.P.L.F.; Ludermir, T.B. **Redes Neurais Artificiais: Teoria e aplicações**. LTC. Rio de Janeiro. 2000.

BRASIL. **Lei n.12.305, de 2 de agosto de 2010**. Institui a política do resíduo sólido; Altera a lei 9.605, de 12 de fevereiro de 1998; e da outras providenciais.

BRASIL. **Resolução n. 357, DE 17 DE MARÇO DE 2005**. Dispõe sobre a classificação dos corpos de água e diretrizes ambientais para o seu enquadramento, bem como estabelece as condições e padrões de lançamento de efluentes, e dá outras providências.

CAVALCANTI, A.S; FILHO, M.J.I; GUIMARÃES, O.L.C; SIQUEIRA, A.F. **Modelagem neural e análise estatística do processo de degradação de chorume por foto-Fenton solar**. *Ambiente & Água*.v.10, n.1. 2014.

CHERNICHARO, C. A. L. **Princípio do tratamento biológico de águas residuárias: reatores anaeróbios**. 5 ed. Minas Gerais: Ed. Desa/EEUFMG. 2000.

COSTA, F. M.; CAMPOS, J.C.; FONSECA, F.V.; BILA, D.M. **Tratamento de lixiviados de aterros de resíduos sólidos utilizando Processos Fenton e Foto-Fenton Solar.** Ambiente & Água. 2014.

DIAS, F.F.S., LIRA, R. J., CHIAVONE, F.O., CARVALHO, J.G. Pacheco. Degradação de corante Reative Black 5 via processo fotoFenton em reator PTC com modelagem e otimização utilizando RNA. SCIENTIA PLENA, v. 9, n.10. 2013.

DURA'N, MONTEAGUDO.J.M, MOHEDANO.M. **Neural networks simulation of photo-Fenton degradation of Reactive Blue 4.** Applied Catalysis, p.127-134. 2006.

EPA – ENVIROMENTAL PROTECTION AGENCY. **Handbook on Advanced Photochemical Oxidation Processes.** EPA/625/R-98/004, Washington, DC 20460, p.97, 1998.

FARACO, R.A. L.; COSTA JR, P. P.; CRUZ, F. B. **Minimização do erro no algoritmo Back-Propagation aplicado ao problema de manutenção de motores.** Pesquisa Operacional, Belo Horizonte-MG, v.18, n. 1, jun de 1998.

FIGAWA – Associação Federal das Empresas do Setor de Gás e Água da Alemanha. **Grupo de Trabalho Oxidação por Via Úmida.** Comunicado Técnico Nº19 (1997).

HAYKIN, S. **Redes Neurais: Princípios e prática (2 edição ed.).** Porto Alegre: Bookman, 2001.

HERNANDEZ, R.; ZAPPI, M.; COLLUCI, F.; JONES, R. **Comparing the performance of various advanced oxidation process for treatment of acetone contaminated water.** Journal Hazardous Materials, v. 92, p. 33-50, 2002.

HIGARASHI, M. M.; MOREIRA, J. C.; OLIVEIRA, A. S.; FERREIRA, L. F. V. – A. **Utilização de Processos Oxidativos Avançados na Descontaminação do Meio Ambiente.** Química - Boletim SPQ, Lisboa,n.79, p.16-20.2000.

VELO-GALA, J.A, PIRÁN-MONTAÑO,J.,RIVERA-UTRILLA,J.,SÁNCHEZ-POLO,M., ANTONIO,J.M. Advanced Oxidation Processes based on the use of UVC and simulated solar radiation to remove the antibiotic tinidazole from water. Chemical Engineering Journal. 2017.

JUNIOR, A.B.; DALSSASSO, R.L.; ROHERS, F. **Pré-tratamento de lixiviados de aterros sanitários por filtração direta ascendente e coluna de carvão ativado.** Eng .Sanit.Ambiental,v.15, n.4, Rio de Janeiro. 2010.

KULIKOWSKA, D., KLIMIUK, E. **O efeito da idade do aterro na composição do lixiviado municipal.** Bioresour. Technol, p. 5891 –5895. 2008.

MARTINS, P.M. **Aplicação de Processos Oxidativos Avançados no Tratamento de Lixiviado de Aterro Sanitário.** Dissertação. Universidade Estadual da Paraíba. Campina Grande. 2014.

MAUS, V.W., COSTA, A. B., RIGHERS, A. **A.Tratamento do lixiviado de aterro de resíduos sólidos urbanos por processo Fenton.** TECNO-LÓGICA, Santa Cruz do Sul, v.13, n.1, p.52-59, jan./jun. 2009.

MCBEAN, E. A.; ROVERS, F. A.; FARQUAHAR, G. J. **Solid waste landfill: engineering and design.** Englewood Cliffs, New Jersey, p.521,1995.

MORAVIA, W.G; LANGE, L. C;AMARAL, M.C.S. **Avaliação de Processo Oxidativo Avançado pelo reagente de Fenton em condições otimizadas no tratamento de lixiviado de Aterro Sanitário com Ênfase em Parâmetros Coletivos e Caracterização do Lodo Gerado.** Quim. Nova, v. 34, n. 8, p.1370-1377, 2011.

NAPOLEÃO, D.A.S; CEZAR, F.S; FILHO, H.J.I;GUIMARÃES, O.L.C. **Treatment of Leachate by Oxidative Process via Fenton and Modeling of the Process by Neural Networks.** HIKARI Ltd, v.4, n. 1, p. 1 – 13. 2016.

NASCENTES, A. L. **Tratamento combinado de lixiviado de aterro sanitário e esgoto doméstico: aspectos operacionais e microbiológicos.** Revista TECCEN, v. 6, n. 1, p. 05-12, 2015.

NOGUEIRA, R. F. P.; TROVÓ, A. G.; SILVA, M. R. A.; VILLA, R. D.; OLIVEIRA, M. C. de. Química Nova. **Fundamentos e aplicações ambientais dos processos Fenton e Foto-Fenton**. v. 30, p. 400-408, 2007.

PALMIERE, S.E. **Arquiteturas e Topologia de Redes Neurais Artificiais**. Disponível em : <https://www.embarcados.com.br/redes-neurais-artificiais/> .Acesso em : 15 Jan. 2018.

PEREIRA NETO, J. T. **Gerenciamento do lixo urbano: Aspecto técnicos e operacionais**. 1. ed. Minas Gerais: Miro Saraiva, p. 13 – 51, 2007.

PHILIPPI Jr., A. **Saneamento, Saúde e Meio Ambiente: fundamentos para um desenvolvimento**. Barueri: Manole, p.842, 2005.

SÁ, L.F; JUCÁ, J.F.T; MOTTA SOBRINHO, M.A. **Tratamento do lixiviado de aterro sanitário usando destilador solar. Ambi-água**. Taubaté, V.7, p.204-207, 2012.

SILVA, E.M. et al. **Pesquisa Operacional. Para cursos de: economia, administração e ciências contábeis**. São Paulo: Atlas, 1998.

SILVA, I.N.; S.H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. Artliber, 2010.

SILVA, R.B. **Tratamento conjugado de lixiviado do aterro sanitário e esgoto doméstico por processo anaeróbio**. Dissertação. Universidade Estadual da Paraíba. Campina Grande. 2014.

SOUTO, G. D. B.; POVINELLI, J. **Engenharia Ambiental: Conceitos, Tecnologia e Gestão**. Rio de Janeiro: Elsevier, 2013.

SOUZA, G. **Monitoramento de parâmetros qualitativos e quantitativos de líquidos percolados de aterros sanitários: estudo em piloto experimental**. 2005. 86f. Dissertação (Mestrado em Engenharia Ambiental) - Universidade Federal de Santa Catarina, Florianópolis, 2005.

TCHOBANOGLIOUS, G.; THEISEN, H.; VIGIL. **Integrated solid waste management: engineering principle and management issues**. McGraw-Hill Science Engineering, p.978, Math.1993.

VELO-GALA, J.A, PIRÁN-MONTAÑO,J.,RIVERA-UTRILLA,J.,SÁNCHEZ-POLO,M., ANTONIO,J.M.Advanced Oxidation Processes based on the use of UVC and simulated solar radiation to remove the antibiotic tinidazole from water. Chemical Engineering Journal. 2017.

VON SPERLING, M. **Introdução à Qualidade das Águas e ao Tratamento de Esgotos**. 3 ed. Belo Horizonte: Ed. DESA/UFMG, p.452, 2005.

ZAMORA, P. P. MORAIS, J. L. **Uso de processos avançados de oxidação para melhorar a biodegradabilidade de lixiviados de aterros maduros**. Jornal de Materiais Perigosos, v.123, p.181-186, agosto. 2005.

ZUQUETTE, L. V. **Geotecnia Ambiental**. 1ª ed. Elsevier. Rio de Janeiro, RJ.399 p.2015