



**UNIVERSIDADE ESTADUAL DA PARAÍBA**  
**CENTRO DE CIÊNCIAS E TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA SANITÁRIA E AMBIENTAL**  
**CURSO DE ENGENHARIA SANITÁRIA E AMBIENTAL**

**RONNAN BARBOSA DOS SANTOS**

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DOS  
PARÂMETROS DE COR E TURBIDEZ NO PROCESSO DE COAGULAÇÃO**

**CAMPINA GRANDE – PB**  
**2018**

**RONNAN BARBOSA DOS SANTOS**

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DOS  
PARÂMETROS DE COR E TURBIDEZ NO PROCESSO DE COAGULAÇÃO**

Monografia apresentada como Trabalho de Conclusão de Curso (TCC), a Coordenação do curso de Engenharia Sanitária e Ambiental da Universidade Estadual da Paraíba como exigência para obtenção do título de Engenheiro Sanitarista e Ambiental.

Orientador(a): Prof.(a) Dr. FERNANDO FERNANDES VIEIRA  
Co-orientador(a): Prof.(a) Dra. WERUSKA BRASILEIRO FERREIRA

**CAMPINA GRANDE – PB  
2018**

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.

S237a Santos, Ronnan Barbosa dos.

Aplicação de redes neurais artificiais na predição dos parâmetros de cor e turbidez no processo de coagulação [manuscrito] : / Ronnan Barbosa dos Santos. - 2018.

50 p. : il. colorido.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia , 2018.

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

1. Tratamento de água. 2. Tratamento convencional. 3. Padrões de potabilidade. 4. Modelagem matemática.

21. ed. CDD 628.162





**RONNAN BARBOSA DOS SANTOS**

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DOS  
PARÂMETROS DE COR E TURBIDEZ NO PROCESSO DE COAGULAÇÃO**

Monografia apresentada como Trabalho de Conclusão de Curso (TCC), a Coordenação do curso de Engenharia Sanitária e Ambiental da Universidade Estadual da Paraíba como exigência para obtenção do título de Engenheiro Sanitarista e Ambiental.

Aprovada em: 26.06.2018.

Nota: 9,2 (nove, dois)

Prof. Dr. Fernando Fernandes Vieira /UEPB  
Orientador(a)

Prof. Dra. Wêruska Brasileiro Ferreira /UEPB  
Co-orientador(a)

Prof. Dr. William de Paiva /UEPB  
Examinador

Prof. Dr. Marcelo Maia de Almeida /UEPB  
Examinador

## AGRADECIMENTOS

A Deus por toda proteção e força para superar todas as barreiras diárias, pois através dele tive toda paciência e discernimento para superar essas adversidades.

Aos meus pais, Ana, Ronaldo e ao meu irmão Ronald, por acreditar e depositar toda sua e esperança para me tornar uma pessoa melhor e me fazer lutar por todos os meus objetivos.

A minha esposa Claudinara e meu filho Vicente, por me tornar uma pessoa com princípios e me apoiar em todas as lutas diárias.

Aos meus mestres, Fernando Fernandes Vieira que me orientou nesta pesquisa disponibilizando todo seu conhecimento referente ao assunto proposto, Weruska Brasileiro Ferreira, William de Paiva e Marcelo Maia de Almeida por todo o conhecimento e fonte de inspiração durante esses 5 anos de curso, acrescentando em minha vida profissional e pessoal.

Ao grupo “Poison” formado por Antônio, Luan e Carolina por todo o companheirismo dividindo momentos de lutas e glórias.

Ao Laboratório Referência em Tecnologia de Águas da Universidade Estadual da Paraíba (LARTECA) que subsidiou a pesquisa.

A professora Kátia Elizabete Galdino e ao Núcleo de Tecnologias Estratégicas em Saúde (NUTES), pela disponibilização de ferramentas computacionais para efetivação deste trabalho.

Ao meu amigo de todas as horas Antônio Cavalcante, por toda ajuda diária não só em assuntos acadêmicos, mas conselhos e parcerias, cujas habilidades me subsidiaram a experiência atual.

A todos os docentes e funcionários que compõem o Departamento de Engenharia Sanitária e Ambiental, cujas o compartilhamento de conhecimento e experiências que auxiliaram na minha formação profissional.

E, por fim, a todos que contribuíram de forma direta e indireta para o êxito do título de Bacharel em Engenharia Sanitária e Ambiental.

*“O fim determina o valor do esforço.”*

*Textos Judaicos*

## RESUMO

A água é um dos recursos naturais mais utilizados, devido ao crescimento populacional e o aumento da utilização em processos industriais, resultando em um aumento da demanda deste bem. Sabendo disso, os mananciais que abastecem esta demanda vêm sofrendo com a intensa contaminação, pelo lançamento de águas residuárias, disposição inadequada de resíduos sólidos e manejo incorreto do solo. Logo, tecnologias de tratamento são utilizadas para garantir a potabilidade da mesma, dentre as tecnologias o tratamento convencional é o mais utilizado abordando as etapas de coagulação, sedimentação, filtração e desinfecção. Sendo a etapa de coagulação a mais importante, pois a ineficiência da coagulação afeta a formação de flocos que não irão decantar e serão carregados para o filtro, colmatando os filtros num intervalo menor e causando o recrudescimento de microrganismos na desinfecção. Portanto, para o controle destas etapas do tratamento é necessário ensaios de tratabilidade que envolvem procedimentos laboratoriais denominados *Jar Test*. Estes equipamentos tem a finalidade de simular e otimizar as variáveis hidráulicas e dosagens de produtos químicos. Porém, este método demonstra diversas desvantagens, tais como: elevado tempo na efetivação do processo, necessidade de intervenções manuais, elevada probabilidade de erros e resposta lentas às mudanças de características da água bruta. Assim, têm-se notado a necessidade da otimização do experimento, para isso é proposto o uso da modelagem matemática, mais precisamente as Redes Neurais Artificiais (RNA's). As RNA's são sistemas computacionais que têm propensão natural para armazenar conhecimento experimental. Logo o objetivo da pesquisa foi estudar a aplicabilidade de uma RNA, mais precisamente a rede do tipo *feedforward* com *backpropagation* aplicando os algoritmos de treinamento Gradiente Descendente com Momento e Taxa de Aprendizagem Adaptativa (GDX) e *Levenberg – Maquardt* (LM), para a predição dos parâmetros de cor e turbidez da água tratada, como ferramenta de suporte no processo de coagulação. Para isso foram utilizados dados provenientes de diagramas de coagulação que avaliavam a performance de coagulantes inorgânicos (sulfato de alumínio e cloreto férrico) através do software MATLAB®. As redes testadas apresentavam 5 neurônios de entrada constituída das variáveis cor, pH e turbidez da água bruta; dosagem de coagulante inorgânico (sulfato de alumínio ou cloreto férrico), e pH de coagulação. Uma camada oculta e 2 neurônios de saída constituídos pela cor e turbidez da água tratada. Resultados apontam que para o processo de coagulação com sulfato de alumínio a arquitetura composta por 5 neurônios de entrada, 15 na camada oculta e 2 de saída demonstraram resultados de ajustes significativos comprovando a eficiência do modelo para a predição dos parâmetros propostos. Por sua vez ao coagulante cloreto férrico, a topologia de 5 neurônios de entrada, 15 na primeira camada oculta, 15 na segunda camada oculta e 2 de saída demonstraram uma melhora significativa, refletindo diretamente na eficiente capacidade de generalização da RNA.

**Palavras-chave:** Tratamento de água. Tratamento convencional. Padrões de potabilidade. Modelagem matemática.

## ABSTRACT

Water is one of the most widely used natural resources in the world, as a result of population growth and increased industrial processes utilization, there is an increased demand for this good. Knowing this, sources that supply this demand are suffering from the intense contamination by the wastewater discharge, inadequate solid waste disposal and incorrect soil management. Therefore, treatment technologies are used to ensure its potability, among them, the conventional treatment is the most used approach, this include the steps of coagulation, sedimentation, filtration and disinfection. Since the coagulation step is the most important one in this process, its step inefficiency affects the formation of particles that will not settle and will be carried to the filter, filling the filters in a smaller time interval and causing the microorganisms protection against disinfection. Subsequently, for the control of these treatment stages it is necessary treatability tests that involve laboratory procedures denominated Jar Test. This equipment has the purpose of simulating and optimizing the hydraulic variables and chemical products dosages. However, this method demonstrates several disadvantages, such as: high time in process execution, manual interventions need, high errors probability and slow response to changes in raw water characteristics. Thus, we have noticed the experiment, optimize need so it is proposed the mathematical modeling, more precisely Artificial Neural Networks (ANNs). RNA's are computational systems that have the natural propensity to store experimental knowledge. Consequently, the research objective was to evaluate the RNA applicability, more precisely the feedforward type network with backpropagation, applying the training algorithms Gradient Descent with Momentum and Adaptive Learning Rate (GDX) and Levenberg - Maquardt (LM), for the prediction of color and turbidity parameters from treated water, as a support tool in the coagulation process. For this, we used coagulation diagrams data that evaluated the performance of inorganic coagulants (aluminum sulfate and ferric chloride) using MATLAB® software. The RNA tested had 5 input neurons consisting of the variables raw water color, pH and turbidity; dosage of inorganic coagulant (aluminum sulphate or ferric chloride) and coagulation pH. One hidden layer and 2 output neurons constituted by treated water color and turbidity. Results show that for the aluminum sulfate coagulation process the architecture composed of 5 input neurons, 15 in the hidden layer and 2 in the output layer, showed significant adjustments results proving the model efficiency for the proposed parameters prediction. In addition to the coagulant ferric chloride, the topology of 5 input neurons, 15 in the first hidden layer, 15 in the second hidden layer and 2 in the output layer showed a significant improvement, directly reflecting the efficient RNA generalization capacity.

**Keywords:** Water Treatment. Conventional Treatment. Potability Standards. Mathematical Modeling.

## LISTA DE FIGURAS

Figura 3.1: Representação em diagrama em blocos do sistema nervoso .....	21
Figura 3.2: Neurônio Biológico.....	22
Figura 3.3: Modelo do Neurônio Artificial .....	22
Figura 3.4: Representação da função linear.....	223
Figura 3.5: Representação da função logística sigmóide .....	24
Figura 3.6: Representação da função tangente hiperólica .....	24
Figura 3.7: Representação de uma RNA em camada única e múltiplas camadas, respectivamente. ....	25
Figura 3.8: Fluxo de processamento do algoritmo <i>backpropagation</i> .....	27
Figura 4.1: Topologia da rede neurais com 5 neurônio na camada oculta .....	35
Figura 5.1: Valores de $R^2$ versus número de neurônios.....	39
Figura 5.2: Valores de $R^2$ versus número de camadas ocultas .....	40
Figura 5.3: Valores preditos versus resultados reais de turbidez .....	41
Figura 5.4: Valores preditos versus resultados reais de cor .....	41
Figura 5.5: Valores de $R^2$ versus número de neurônios.....	43
Figura 5.6: Valores de $R^2$ versus número de camadas ocultas .....	44
Figura 5.7: Valores preditos versus resultados reais de turbidez .....	45
Figura 5.8: Valores preditos versus resultados reais de cor .....	46

## LISTA DE TABELAS

Tabela 5.1: Valores do coeficiente de determinação em função do algoritmo de treinamento (Sulfato de Alumínio) .....	37
Tabela 5.2: Valores do coeficiente de determinação em função da arquitetura da RNA (Sulfato de Alumínio).....	38
Tabela 5.3: Valores do coeficiente de determinação em função do número de camadas ocultas da RNA (Sulfato de Alumínio) .....	39
Tabela 5.4: Valores do coeficiente de determinação em função do algoritmo de treinamento (Cloreto férrico) .....	42
Tabela 5.5: Valores do coeficiente de determinação em função da arquitetura da RNA (Cloreto férrico).....	42
Tabela 5.6: Valores do coeficiente de determinação em função do número de camadas ocultas da RNA (Cloreto férrico) .....	44

## LISTA DE ABREVIATURAS E/OU SIGLAS

MS	Ministério da Saúde
RNA's	Redes Neurais Artificiais
ETA	Estação de Tratamento de Água
OMS	Organização Mundial de Saúde
$x_j$	Sinais de entrada
$k$	Neurônio
$w_{kj}$	Peso sinápticos do neurônio
$\varphi$	Função de ativação
$y_k$	Sinal de saída do neurônio
$u_k$	Saída da combinação linear
$b_k$	Bias
RMC	Redes múltiplas camadas
$d_k$	Saída desejada para o neurônio
$E$	Erro total
$\eta$	Taxa de aprendizagem
$\beta$	Constante de momento
$y_i$	Saída fornecida pela rede
$y_{ei}$	Valor exato da saída da rede
$\mu(n)$	Constante do método de Levenberg- Marquardt
$T_i$	Valor da série temporal em uma instância
$N_i$	Valor normalizado da série temporal
(máx) (T)	Valor máximo da série temporal
(min) (T)	Valor mínimo da série temporal
GDX adaptativa	Algoritmo Gradiente descendente com momento e taxa de aprendizagem adaptativa
LM	Algoritmo Levenberg - Marquardt



## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	<b>12</b>
<b>2. OBJETIVOS</b> .....	<b>15</b>
<b>2.1 Objetivo geral</b> .....	15
<b>2.2 Objetivos específicos</b> .....	15
<b>3. FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>16</b>
<b>3.1 Recursos Hídricos e Contaminação</b> .....	16
<b>3.2 Tratamento de água</b> .....	16
3.2.1 Padrões de potabilidade e parâmetros de controle de uma ETA.....	16
3.2.2 Etapas do Tratamento convencional .....	17
3.2.2.1 Coagulação .....	17
3.2.2.2 Decantação.....	19
3.2.2.3 Filtração .....	19
3.2.2.4 Desinfecção .....	19
<b>3.3 Redes neurais artificiais</b> .....	20
3.3.1 Neurônios Biológicos.....	20
3.3.2 Neurônio Artificial .....	22
3.3.2.1 Funções de ativação.....	23
3.3.3 Arquitetura das RNA'S .....	25
3.3.4 Processo de aprendizagem das RNA'S .....	26
3.3.4.1 Algoritmo <i>backpropagation</i> .....	26
3.3.4.1.1 Algoritmo do Gradiente descendente com momentum .....	29
3.3.4.1.2 Algoritmo de Levenberg – Marquardt .....	30
3.3.5 Redes neurais artificiais no controle do processo de coagulação – Estado da arte ...	31
<b>4. METODOLOGIA</b> .....	<b>33</b>
<b>4.1 Coleta e análise dos dados</b> .....	33
4.1.1 Pré-Tratamento dos dados experimentais .....	33
4.1.2 Subdivisão do conjunto de dados experimentais .....	34
<b>4.2 Processo de modelagem</b> .....	34
4.2.1 Algoritmo de treinamento .....	35
4.2.2 Número dos neurônios .....	35
4.2.3 Número de camadas .....	35
<b>5. RESULTADOS E DISCUSSÃO</b> .....	<b>37</b>
<b>5.1 Coagulação com Sulfato de alumínio</b> .....	37
5.1.1 Escolha do algoritmo de treinamento.....	37
5.1.2 Otimização do número de neurônios da camada oculta .....	38
5.1.3 Otimização do número de neurônios nas camadas ocultas .....	39
5.1.4 Resultados Globais.....	40
<b>5.2 Coagulação com Cloreto férrico</b> .....	42
5.2.1 Escolha do algoritmo de treinamento.....	42

5.2.2 Otimização do número de neurônios da camada oculta .....	42
5.2.3 Otimização do número de neurônios nas camadas ocultas .....	43
5.2.4 Resultados Globais .....	45
<b>6. CONCLUSÃO.....</b>	<b>47</b>
<b>REFERÊNCIAS .....</b>	<b>48</b>

## 1. INTRODUÇÃO

A água é um dos recursos naturais que está sendo mais utilizado, devido ao crescimento populacional e o aumento da utilização em processos industriais. Como reflexo deste cenário há um aumento da demanda deste bem, podendo ser para uso direto (abastecimento público, agricultura) ou indireto (hidroelétricas).

Em contrapartida, os mananciais que abastecem esta demanda vêm sofrendo com a intensa contaminação, pelo lançamento de águas residuárias, disposição inadequada de resíduos sólidos e manejo incorreto do solo. Deste modo, para a água se adequar aos padrões de potabilidade, é necessário a aplicação de técnicas de tratamento visando disponibilizar uma água de qualidade para a população.

O tratamento de água de abastecimento mais utilizado é o convencional, onde o mesmo aborda as etapas de coagulação, sedimentação, filtração e desinfecção. Todas estas etapas têm como finalidade adequar a água para atender os parâmetros preconizados nas normas, tais como a Portaria de Consolidação nº 5/2017, que asseguram a sua qualidade para consumo humano.

Para o controle destas etapas do tratamento é necessário ensaios de tratabilidade que envolvem procedimentos laboratoriais, realizados em reatores estáticos *Jar Test*. Estes equipamentos tem a finalidade de simular e otimizar as variáveis hidráulicas e dosagens de produtos químicos presentes em uma estação de tratamento de água, visando o aumento da eficiência da remoção de cor e turbidez, desestabilização das partículas, velocidade de sedimentação. Porém, este método demonstra diversas desvantagens devido ao elevado tempo na efetivação do processo, a necessidade de intervenções manuais constantes, elevada probabilidade de erros e resposta lentas às mudanças de características da água bruta a ser tratada. (SINGH *et al.*, 2015; GOMES *et al.*, 2015)

Desta forma, devido aos problemas supracitados tem-se notado a necessidade da otimização do experimento *Jar Test* por técnicas mais rápidas e com menor probabilidade de erro, para isso é proposto o uso da modelagem matemática.

Portanto, a modelagem matemática fornece uma representação de cenários físicos através de métodos e formulações matemáticas. Deste modo, em sistemas ambientais, tais como o tratamento de água, a modelagem constitui uma ferramenta imprescindível para a representação eficaz das variações do meio. Sendo possível caracterizar e simular cenários sem haver a necessidade de sua reprodução imediata no meio físico.

Cada situação possui um grau de complexidade intrinsecamente envolvido. Entretanto, mais especificamente para questões relacionadas ao tratamento de água, existem variáveis constituintes para tais processos que se tornam sobretudo difíceis para serem reproduzidos através de valores em modelos matemáticos clássicos, exigindo um tratamento mais complexo para solução destes problemas.

Deste modo, a modelagem computacional mais precisamente as RNA's são sistemas computacionais que têm propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN,2001).

A partir disso, é possível utilizar os modelos de RNA's com a finalidade de otimizar processos que envolvem sistemas de tratamento de água visando a predição de parâmetros de controle de uma ETA. Principalmente para a substituição ou apoio aos dados fornecidos pelos ensaios de *Jar Test*.

Diante do exposto, nota-se a importância inerente aos ensaios de coagulação e das problemáticas associadas aos procedimentos relativos à metodologia convencional, a proposição de um modelo de RNA's que faça a predição dos parâmetros de cor e turbidez.

## **2. OBJETIVOS**

### **2.1 Objetivo geral**

Estudar a aplicabilidade de RNA's do tipo *feedforward* com *backpropagation* para a predição dos parâmetros de cor e turbidez da água tratada, como ferramenta de suporte no processo de coagulação.

### **2.2 Objetivos específicos**

- Fazer um estudo para definir qual o melhor algoritmo de treinamento a ser usado com o conjunto de dados experimentais disponíveis;
- Verificar a influência do número de neurônios e o número de camadas na camada oculta do modelo;
- Analisar o desempenho da rede em função do número de experimentos usados no treinamento, validação e teste.

### **3. FUNDAMENTAÇÃO TEÓRICA**

#### **3.1 Recursos Hídricos e Contaminação**

Extensiva atenção mundial está voltada para os recursos hídricos, pois observa-se um grande crescimento populacional interligado a uma ampla exploração deste recurso natural não renovável nos atuais modelos de consumo. Complementarmente, nota-se que este consumo está sendo feito de forma desordenada por diversos setores que demandam deste bem finito, afetando assim o seu balanço hídrico. Dessa forma uma preocupação geral está voltada a temática água e sua potabilização para seus usos múltiplos. Embora 2/3 Terra seja coberto por água, 97,5% encontram-se nos mares e oceanos e não se prestam para a maioria das atividades agrícolas e dessedentação humana e animal, devido aos elevados teores de sais. A água doce, correspondem às geleiras e calotas polares situadas em regiões montanhosas; 29,9% são águas subterrâneas; 0,9% compõe a umidade do solo e pântanos e apenas 0,3% constitui a água doce armazenada nos rios e lagos, efetivamente disponível para uso em diferentes atividades (Shiklomanov, 1998, apud Tundisi, 2003).

Apesar do cenário crítico de disponibilidade, os mananciais vêm sofrendo cada vez mais pressões pela presença de contaminantes ou poluentes, pelo uso indevido do solo das bacias hidrográficas, lançamento de águas residuais e disposição inadequada de resíduos sólidos (DI BERNARDO e SABOGAL PAZ, 2008). Desta forma fica cada vez mais difícil da água se enquadrar nos padrões de consumo, tendo em vista esta problemática vem sendo desenvolvidas tecnologias de tratamento para adequação em padrões de potabilidade estabelecidos por legislações, tais como a brasileira MS 2914/2011 (BRASIL,2011).

#### **3.2 Tratamento de água**

##### **3.2.1 Padrões de potabilidade e parâmetros de controle de uma ETA**

A água possui diversas características químicas, físicas e microbiológicas as quais são utilizadas para definição do tratamento correspondente, a fim que a mesma se torne adequada ao consumo humano. Essas por sua vez devem obedecer a parâmetros de qualidade ou padrões de potabilidade específicos para cada país, tais como a Portaria de Consolidação nº 5/2017, a

qual define um conjunto de valores permitidos como parâmetro da qualidade da água para consumo humano.

No Brasil, os padrões de potabilidade da água para o consumo humano, são compostos pelos parâmetros microbiológicos como: Turbidez para água pós-filtrada ou pré-desinfetada, padrões para substâncias químicas (inorgânicas, orgânicas, agrotóxicos, desinfetantes) e padrões de radioatividade e de aceitação para o consumo. Para analisar essa potabilidade é feita a aferição pelos valores permissíveis de alguns parâmetros de maior relevância para a vigilância e o controle da qualidade da água por análises microbiológicas e físico-químicas (BRASIL, 2004).

Além do controle da água que deve ser fornecida a população, ou seja, a água potabilizada na ETA. Também é necessário o controle de variáveis mutáveis dentro de todo o processo de tratamento que quando modificadas, podem afetar o principal mecanismo de tratamento, a coagulação. Sendo definida como a principal etapa no tratamento convencional da água, que por sua vez, na sua ineficiência podem vir comprometer todas as etapas subsequentes do tratamento. Dessa forma, turbidez e cor (água bruta e tratada) servem para o controle da eficiência do processo de coagulação e avaliação dos parâmetros básicos para o controle da qualidade, sendo eles: os coliformes totais, *Escherichia coli*, concentração de cloro residual livre (REIS, 2016).

### 3.2.2 Etapas do Tratamento convencional

O tratamento de água visa adequar a água bruta aos padrões de potabilidade da água para consumo humano, buscando ser feito com o menor custo possível. Sendo o principal método de tratamento de água o convencional, ele é composto, mais detalhadamente das seguintes etapas: mistura rápida/coagulação, mistura lenta/floculação, decantação, filtração e desinfecção. Onde cada etapa possui função para remoção ou inertização de impurezas ali presentes.

#### 3.2.2.1 Coagulação

A coagulação pode ser definida como um processo de combinação de partículas pequenas em agregados maiores (flocos) de modo a adsorver matéria orgânica dissolvida em agregados particulados, que se encontram em suspensão fina, estado coloidal e dissolvidas.

Esses agregados são compostos de substâncias húmicas, microrganismos e outros contaminantes presentes na água bruta. Logo, através da adição de um agente coagulante, geralmente um sal de ferro ou alumínio, e a consequente reação química entre o coagulante com a água ocorre a formação de espécies hidrolisadas e posterior transporte destas espécies. Formando assim aglomerados gelatinosos que se reúnem produzindo os flocos (floculação), de forma que essas impurezas possam ser removidas em processos subsequentes de separação sólido/líquido (decantação, sedimentação e filtração) (DI BERNARDO E DANTAS, 2005; BRASIL, 2014; JIANG, 2015).

Segundo a OMS (2004), o pré-tratamento químico da coagulação é o fator mais importante para garantir a remoção eficiente de micróbios por coagulação, floculação, decantação e pela filtração em meio granular. Pois a não eficiência da coagulação afeta a formação de flocos que não irão decantar e serão carregados para o filtro, colmatando os filtros num intervalo menor, causando o recrudescimento de microrganismos na desinfecção, afetando assim o tratamento de água em uma ETA como todo.

Sabendo disso é necessária precaução na definição de variáveis extremamente mutáveis responsáveis para obtenção de uma coagulação efetiva. Sendo elas a dosagem ótima de coagulante, pH utilizado na coagulação e a variação de cor e turbidez da água bruta.

Para simular a coagulação química em escala de bancada é feito o teste de jarros com a água bruta de cada ETA, sendo desenvolvido por Amirtharajah e Mills (1982). Este equipamento é composto de jarros de igual volume, com agitadores dispostos em cada jarro, com rotação controlável. Com isso é possível mimetizar as etapas de tratamento de água, tais como a otimização de dosagens de produtos químicos e parâmetros hidráulicos visando o aumento da eficiência da remoção de cor e turbidez, desestabilização das partículas, velocidade de sedimentação.

Porém, este método demonstra diversas desvantagens devido ao elevado tempo na efetivação do processo, a necessidade de intervenções manuais constantes, elevada probabilidade de erros e resposta lentas às mudanças de características da água bruta a ser tratada. Desta forma, tem-se notado a necessidade da otimização do experimento *Jar Test* por técnicas mais rápidas e com menor probabilidade de erro, para isso é proposto o uso da modelagem matemática, mais precisamente o uso de redes neurais artificiais. Que através dos modelos empírico estimam variáveis de difícil mensuração, tais como se apresentam no processo de coagulação (BAXTER *et al.*, 1999; MAIER *et al.*, 2004).



### 3.2.2.2 Decantação

Logo após a coagulação/floculação a decantação pode ser situada. Sendo esse um fenômeno físico que consiste na separação de uma mistura heterogênea pela sedimentação do componente mais denso. Em uma ETA são as partículas suspensas na água que, em movimento descendente, propiciam a separação das fases (RECESA, 2008). Em outras palavras, a decantação é um processo em que se promove a sedimentação dos flocos formados, retirando, assim, parte das impurezas contidas na água, promovendo assim um tempo de carreira maior para as unidades subsequentes, os filtros.

### 3.2.2.3 Filtração

As unidades subsequentes aos decantadores denominadas filtros, realizam o processo físico-químico de filtração definido como processo de separação ou remoção de partículas sólidas, microrganismos ou gotículas de um líquido ou gás, depositando-os em um meio filtrante, que é essencialmente permeável a apenas a fase fluida da mistura sendo separada (RIPPERGER, GÖSELE e ALT, 2012). No caso do tratamento de água, o meio filtrante na maioria das vezes é areia nas suas diversas granulometrias, combinada em alguns casos com carvão mineral (antracito).

### 3.2.2.4 Desinfecção

Em uma estação de tratamento convencional tem-se a desinfecção que é responsável pela desativação ou morte de microrganismos patogênicos através da aplicação de um oxidante. Os microrganismos são destruídos ou desativados, resultando no término do crescimento e reprodução (OKPARA, OPARAKU E IBETO, 2011). No Brasil o agente oxidante utilizado para garantir a desinfecção é o cloro, pois o mesmo garante a presença de residual na água, mesmo após sua aplicação. Pois é preconizado na norma MS 2914/2011 a cloração como uma garantia da segurança hídrica da água tratada.

### 3.3 Redes neurais artificiais

As RNA's são um conjunto de procedimentos que buscam simular o comportamento do cérebro humano de modo que se possam representar cenários complexos de aprendizagem e caracterização de padrões baseado em uma ótica neurocomputacional (FREITAS,2012).

Esses modelos não-lineares apresentam características de adaptabilidade, generalização e tolerância a falhas. Sendo definido por Haykin (2001) como “um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso”.

Essa semelhança com o cérebro humano é baseada em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; as forças de conexão entre os neurônios, conhecidos como pesos sinápticos, são armazenados o conhecimento adquirido. Baseado nisto as RNA's se tornaram uma ferramenta de vasta utilização e tem raízes nas mais diversas disciplinas: neurociência, matemática, estatística, física, ciência da computação e engenharia (HAYKIN, 2001).

Além disto, as RNA's estão sendo aplicadas em problemas de otimização, classificação, categorização de dados, aproximação, previsão e controle linear das mais diversas áreas do conhecimento (BRAGA *et al.*, 2007).


#### 3.3.1 Neurônios Biológicos

Para a compreensão do funcionamento de uma RNA, é necessário entender o princípio do funcionamento do sistema nervoso humano, mais precisamente do neurônio biológico.

O cérebro é o centro do sistema, que é responsável pelo processamento da grande quantidade de informações que o corpo envia a todo momento, essas informações que são enviadas continuamente são recebidas pela rede neural (nervosa) visando a tomada de decisões apropriadas. A representação desse processo é apresentada na Figura 3.1, onde seu funcionamento possui três estágios divididos: Receptores, redes neurais cerebrais e atuadores. As setas que apontam da esquerda para a direita indicam a transmissão do sinal portador da informação no decorrer do sistema, já as setas da direita para a esquerda demonstram o processo de retroalimentação no sistema. Os receptores transformam os estímulos do corpo humano ou

do ambiente externo em impulsos elétricos que transmitem a informação para a rede neural, em seguida os atuadores convertem esses impulsos gerados na rede em respostas como saídas da rede.

**Figura 3.1:** Representação em diagrama em blocos do sistema nervoso

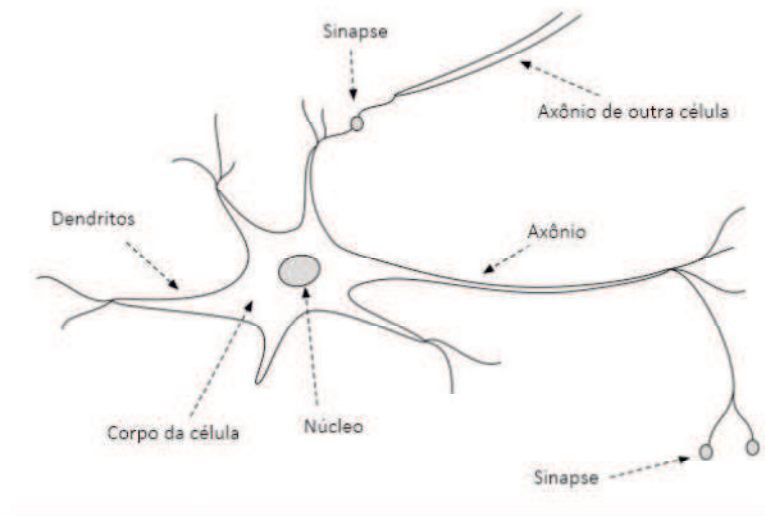


Fonte: *Adaptado de* Haykin (2001)

Sendo assim, a busca incessante de compreender o cérebro teve um grande avanço devido aos estudos de Santiago Ramón y Cajal, em 1891, que introduziu a ideia dos neurônios como constituintes estruturais do cérebro (DELGADO-GARCÍA, 2015). Proporcionando dois resultados importantes, como a adoção do sistema nervoso postulado através da comunicação entre as células pela sinapse e a interconexão entre neurônios altamente específica e estruturada. Descrevendo diversas estruturas cerebrais, com pesquisas não só voltadas para a estrutura dos neurônios, mas também para o desconhecido campo das muitas estruturas neuronais (BARRETO, 2002).

Portanto, Braga *et al.*, (2007) define o neurônio biológico de maneira simplificada em três seções: o corpo celular, os dendritos, o axônio e suas conexões (sinapses), onde cada qual tem estrutura e funções específicas, como pode ser observado na Figura 3.2. Suas funções são definidas da seguinte maneira: os dendritos são responsáveis por captar os impulsos emitidos pelo corpo e encaminhá-los para o destino correto, o axônio tem a função de ligar os impulsos de saída de um neurônio a outro pelos terminais do axônio, as sinapses são responsáveis pela conexão dos dendritos e o axônio e por fim o núcleo é responsável pelo somatório de todas as entradas dos dendritos.

**Figura 3.2:** Neurônio Biológico




Fonte: Adaptado de Patterson e Gibson (2017)

### 3.3.2 Neurônio Artificial

O neurônio artificial é a base para o funcionamento das RNA's, onde o mesmo é composto por uma unidade de processamento matemático simples, que recebe uma ou mais entradas e as transforma em saída. O neurônio artificial proposto por McCulloch e Pitts em 1943, foi o primeiro modelo de neurônio artificial, baseado em uma modelagem matemática que buscou reproduzir o neurônio biológico. Ele era composto por terminais de entrada, sinapses, junção aditiva, função de ativação e um terminal de saída, como pode ser observado na Figura 3.3:

**Figura 3.3:** Modelo do Neurônio Artificial



Fonte: Lourencetti (2011)

O modelo faz a soma dos sinais de entrada  $x_j$  conectado ao neurônio  $k$  multiplicado pelo peso  $w_{kj}$  e através da aplicação da função de ativação  $\phi$  dispara o sinal de saída  $y_k$  numa

amplitude admissível para a função de ativação utilizada. O bias é o limiar do neurônio representado por uma conexão sináptica com uma entrada fixada em +1, e tem o efeito de aumentar ou diminuir a entrada da função de ativação, dependendo se esse é positivo ou negativo, respectivamente (HAYKIN, 2001).

Em notação matemática, podemos representar o neurônio  $k$  pelas Equações (1) e (2), respectivamente:

$$u_k = \sum_{j=1}^n w_{kj} \cdot x_j + b_k \quad (1)$$

$$y_k = \varphi(u_k) \quad (2)$$

Sendo  $x_1, x_2, \dots, x_n$  os sinais de entrada;  $w_{k1}, w_{k2}, \dots, w_{kj}$ , são os pesos sinápticos do neurônio  $k$ ;  $u_k$  é a saída da combinação linear;  $b_k$  é o bias e;  $y_k$  é o sinal da saída do neurônio.


### 3.3.2.1 Funções de ativação

A função de ativação  $\varphi$ , define a saída do neurônio em termos de nível da atividade do mesmo. Dentre as funções mais utilizadas pode-se citar:

1. Função linear (*purelin*) – os neurônios com essa função podem ser utilizados como aproximadores lineares e não apresentam limitação (Equação 3). Onde seu comportamento pode ser descrito na Figura 3.4.

$$\varphi(v) = v \quad (3)$$

**Figura 3.4:** Representação da função linear




Fonte: Patterson e Gibson (2017)

2. Função logística sigmoideal (*logsig*) – possui um intervalo contínuo de variação entre 0 e 1 (Figura 3.5), esta função é geralmente aplicada em redes neurais, devido apresentar continuidade, não linear, estritamente crescente e ser diferenciável em qualquer ponto (Equação 4).

$$\varphi(v) = \frac{1}{1+e^{(-av)}} \quad (4)$$

**Figura 3.5:** Representação da função logística sigmoide




Fonte: Patterson e Gibson (2017)

3. Função tangente hiperbólica (*tansig*) – apresenta características análogas da função sigmoideal, entretanto, demonstra uma variação de intervalo entre -1 a +1 (Figura 3.6), admitindo que as saídas sejam simétricas (Equação 5).

$$\varphi(v) = \tanh\left(\frac{v}{2}\right) = \frac{1-e^{(-v)}}{1+e^{(-v)}} \quad (5)$$

**Figura 3.6:** Representação da função tangente hiperbólica



Fonte: Patterson e Gibson (2017)

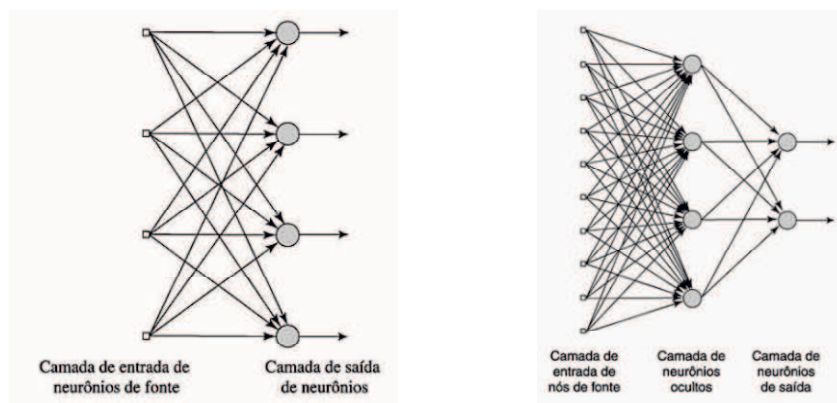
### 3.3.3 Arquitetura das RNA'S

A estrutura de uma RNA determina as funções para as quais a rede melhor se aplica. Segundo Braga *et al.* (2007), na configuração de uma RNA considera-se o número de camadas da rede, o tipo de conexão entre os neurônios, o método de aprendizado e o número de neurônios.

Quanto ao número de camadas, (Figuras 3.7), a rede pode ser classificada como:

- Redes de camada única: apresentam apenas neurônios de entrada e camada de neurônios de saída, em outras palavras, não existem camadas ocultas;
- Redes múltiplas camadas (RMC): apresentam camadas ocultas entre os neurônios de entrada e camada de saída.

**Figura 3.7:** Representação de uma RNA em camada única e múltiplas camadas, respectivamente.



Fonte: Haykin (2001)

Quanto à conexão entre os nós a rede pode ser classificada como:

- *Feedforward* ou acíclica: onde os sinais projetados sempre para a frente. Portanto, a saída de um neurônio é a entrada para um neurônio localizado em camadas posteriores.
- *Feedback* ou recorrente: ocorre retorno dos sinais através da retroalimentação das conexões entre camadas ou camadas anteriores.



Quanto ao comportamento:

- Estáticas: a estrutura de camadas e neurônios definida não é alterada no decorrer do treinamento, ocorrendo alterações somente nos pesos sinápticos;
- Dinâmicas: nesta configuração de rede ocorrem alterações tanto no número de neurônios como no de ligações.

A arquitetura a ser aplicada depende do tipo de problema que deseja solucionar, podendo ser problemas de classificação, de aproximação de funções, séries temporais, entre outros.

### 3.3.4 Processo de aprendizagem das RNA'S

Uma definição geral do que venha a ser o processo de aprendizagem, é a que foi adotada por Braga *et al.* (2000), onde a aprendizagem é o processo de apresentação dos parâmetros de uma rede neural, os quais são ajustados de acordo com os estímulos do ambiente ao seu entorno.

Seu principal atrativo seria a capacidade de extrair informações e melhorar seu desempenho, por meio do treinamento, onde os pesos de suas conexões são ajustados em função dos padrões apresentados (CAVALCANTE,2018). Portanto, através destas adequações o sinal de entrada se transforma em um sinal de saída desejado ou consistente.

O método de aprendizado recebe duas classificações quanto ao modo de operação: supervisionado ou não supervisionado. No aprendizado supervisionado as entradas e saídas esperadas para a rede são fornecidas por uma agente externo (professor), tem grande aplicação na previsão de resultados, mas tem como desvantagem a dependência desse agente externo para se adaptar às novas situações não treinadas. Não obstante, o aprendizado não supervisionado não apresenta conhecimento das saídas da rede, funcionando como meio de distinguir padrões e classes diferentes. Logo, este tipo de treinamento é caracterizado pela comparação entre os próprios sinais de entrada.

#### 3.3.4.1 Algoritmo *backpropagation*

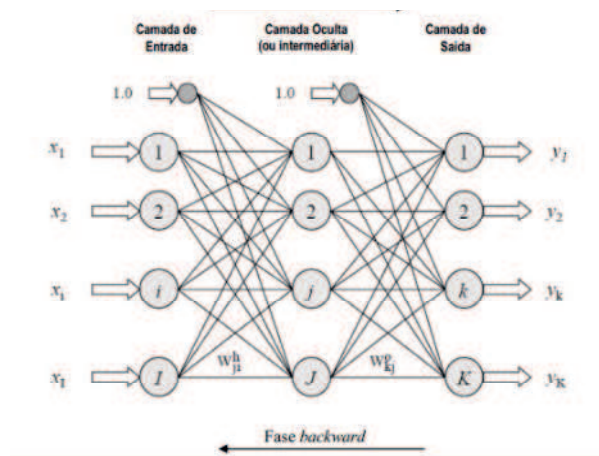
Este processo de treinamento foi apresentado por Rumelhart e McClelland (1986), onde o mesmo é amplamente utilizado e constituído de um aprendizado supervisionado que visa



através de interações a mínima diferença entre as saídas desejadas e as saídas obtidas, executando, assim, a retropropagação dos erros encontrados em cada interação.

O treinamento deste algoritmo ocorre em duas fases nas quais cada fase percorre a rede em um sentido, sendo as fases *forward* e *backward*. Lourencetti (2011) diz que a fase *forward* é utilizada para definir a saída da rede para um determinado padrão de entrada. Já a fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. A Figura 3.8 ilustra estas duas fases:

**Figura 3.8:** Fluxo de processamento do algoritmo *backpropagation*.



Fonte: Lourencetti (2011)

Este processo pode ser descrito da seguinte maneira: o algoritmo de *backpropagation* inicializa os parâmetros, onde para cada padrão de treinamento calculam-se as saídas da rede através da fase *forward*, comparam-se as saídas produzidas com as saídas desejadas e atualizam-se os pesos dos neurônios através da fase *backward*. Após a rede apresentar todos os padrões, uma nova iteração é realizada voltando para o padrão de treinamento, findando as iterações até que o erro seja mínimo ou que o número de iterações seja alcançado.

O sinal de erro na saída do neurônio  $k$ , a interação  $n$ , é definido por:

$$e_k(n) = d_k(n) - y_k(n) \quad (6)$$

onde  $d_k$  é a saída desejada para o neurônio  $k$  e  $y_k$  é dado pela Equação (2).

Embora o erro total ( $E$ ) seja definido como a soma dos erros dos neurônios da camada de saída para todos os padrões contidos no conjunto de treinamento, será considerada, sem

perda de generalidade, que a minimização do erro para cada padrão individualmente levará a minimização do erro total. Assim o erro passa a ser definido pela Equação (7):

$$E(n) = \frac{1}{2} \sum_{k=1}^L e_k^2(n) \quad (7)$$

O algoritmo de *backpropagation* aplica uma correção  $\Delta w_{jk}(n)$ , definida pela regra delta demonstrado nas Equações (8) e (9):

$$\Delta w_{jk}(n) = -\eta \frac{\partial E(n)}{\partial w_{jk}(n)} \quad (8)$$

ou

$$w_{jk}(n+1) = w_{jk}(n) - \eta \frac{\partial E(n)}{\partial w_{jk}(n)} \quad (9)$$

sendo  $\eta$  denominado taxa de aprendizagem. O uso do sinal negativo na Equação (8) indica a busca de uma direção para a mudança de pesos que reduza o valor de  $E(n)$ . De acordo com Lourencetti (2011) quanto menor for  $\eta$ , mais suaves serão as variações dos pesos sinápticos da rede, de uma iteração a outra. Por outro lado, se  $\eta$  for grande, para acelerar a taxa de aprendizagem, as grandes modificações nos pesos sinápticos podem tornar a rede instável.

Portanto, em resumo pode-se dizer que o algoritmo de *backpropagation* procura minimizar o erro obtido pela rede ajustando pesos e bias para que eles correspondam às coordenadas dos pontos mais baixos da superfície de erro. Apresenta como vantagem a sua simplicidade, permitindo que seja implementado rapidamente e desvantagem a sua demora de convergência, podendo pior caso os parâmetros da rede forem configurados inadequadamente (ALMEIDA,2012).

Visando uma aplicação mais ampla, muitas técnicas têm sido discutidas para acelerar o desempenho do *backpropagation*, oferecendo maior flexibilidade e uma avaliação computacional mais rápida. Segundo Silva, Spatti e Flauzino (2010) diversas variações do método *backpropagation* têm sido propostas com o objetivo de tornar o processo de convergência mais eficiente. Entre tais aperfeiçoamentos, tem-se o método de inserção do termo de *momentum* e o *Levenberg-Marquardt*.

### 3.3.4.1.1 Algoritmo do Gradiente descendente com momentum

Esse algoritmo busca minimizar o erro quadrático, que é expresso em função dos pesos, de modo a se obter um conjunto de pesos otimizado, que encerrará o processo de treinamento, tornando a rede apta a produzir padrões de saída aceitáveis.

Por se tratar de um problema de otimização, torna-se necessária a determinação do gradiente do erro em relação aos pesos, processo este que pode ser inviabilizado devido ao tamanho do vetor de entrada, principalmente nos problemas de engenharia que, na maioria dos casos, engloba um grande número de variáveis.

A minimização do erro quadrático pode ser obtida utilizando o processo conhecido por regra delta. De acordo com essa regra, sendo  $w(k)$  um ponto sobre a superfície de erro, o ajuste a ser aplicado a esse ponto é expresso (10):

$$\Delta W(k) = \eta \frac{\partial E_R(W)}{\partial W} \quad (10)$$

onde  $\eta$  é a taxa de aprendizagem.

Efetuada o processo de ajuste, o valor do peso atualizado é descrito por (11):

$$w(K + 1) = W(k) - DW(k) \quad (11)$$

A determinação do parâmetro  $\eta$  é extrema importância pois ele é o responsável direto pela efetividade do processo de aprendizado. O algoritmo *backpropagation* provê uma aproximação da trajetória de movimento sobre a superfície de erro, a qual, a cada ponto da superfície, segue a direção do ponto mais íngreme em busca do ponto de mínimo global. Sendo assim quanto menor for a taxa de aprendizado, menores vão ser as correções a serem aplicadas aos pesos entre cada iteração, resultando em um processo de convergência lento. Caso contrário, se o valor desse parâmetro for alto, pode-se obter uma aceleração no processo de convergência, mas pode-se tornar o algoritmo instável pela oscilação em torno de um ponto de mínimo local.

Para garantir a estabilidade e acelerar a convergência utiliza-se o algoritmo *backpropagation* tradicional acrescida do fator momento, com demonstrado na Equação (12):

$$\Delta W(k) = \beta \Delta W(k-1) + \eta \frac{\partial E_R(W)}{\partial W} \quad (12)$$

sendo  $\beta$  denominado constante de momento podendo variar entre 0 e 1. A inserção deste termo se configura como uma das variações mais simples de ser efetuada no algoritmo, pois, basta inserir um único parâmetro visando ponderar o quão as matrizes sinápticas foram alteradas entre duas iterações (SILVA, SPATTI e FLAUZINO, 2010). Além disto, esta constante tem o objetivo de aumentar a velocidade na direção do ponto mínimo, visando a redução do tempo de treinamento, conseqüentemente melhorando a estabilidade do processo, aumentando assim, a possibilidade de encontrar o mínimo global.

### 3.3.4.1.2 Algoritmo de Levenberg – Marquardt

O algoritmo *Levenberg-Marquardt*, desenvolvido independentemente por *Kenneth Levenberg* e *Donald Marquardt*, fornece uma solução numérica para o problema de minimizar uma função não linear. Ele é rápido e tem convergência estável. No campo de redes neurais artificiais, esse algoritmo é adequado para treinar problemas de pequeno e médio porte (WILAMOWSIKI e YU, 2010).

*Levenberg-Marquardt* propôs um algoritmo baseado no método de otimização de Newton que consiste na determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos, para aceleração do treinamento. O algoritmo proposto faz uma aproximação para essa matriz, apresentada na Equação (13), determinada em função da matriz Jacobiana, que contém as primeiras derivadas dos pesos em função dos pesos sinápticos, expressa na Equação (14):

(13)

$$H = \frac{\partial^2 E_R(W)}{\partial W^2}$$

(14)

$$J = \frac{\partial e(W)}{\partial W}$$

onde  $E_R$  erro quadrático médio  $e(W)$  podem ser definidos conforme a expressão (15) e (16):

$$E_R = \frac{1}{n} \sum_{i=1}^n (y_i - y_{ei})^2 \quad (15)$$

$$e(W) = \sum_{i=1}^n (y_i - y_{ei}) \quad (16)$$

onde  $y_i$  é a saída fornecida pela rede e  $y_{ei}$  é o valor exato correspondente à saída da rede.

Como em redes neurais, a performance do treinamento é representada em função da soma dos erros quadráticos, a matriz Hessiana poder ser descrita pela Equação (17):

$$H = J^T (W) \cdot J(W) \quad (17)$$

o método de Newton atualiza os pesos de acordo com a Equação (18):

$$W(k + 1) = W(k) - H^{-1} \cdot g_k \quad (18)$$

onde  $g_k$  pode ser descrito conforme a equação (19):

$$g_k = 2j^T \cdot e(W) \quad (19)$$

O algoritmo de *Levenberg - Marquardt* procede a atualização dos pesos baseado na mesma expressão do método de Newton (18), realizando as modificações para a determinação da matriz Hessiana, mostrada em (20):

$$\Delta w(k + 1) = W(k) - [J^T (w) \cdot J(w) + \mu(n)I]^{-1} [J^T (w)] \cdot [e(w)] \quad (20)$$

onde  $I$  é a matriz identidade e  $\mu(n)$  é a constante do método de *Levenberg-Marquardt*.

O método é dito mais rápido porque  $\mu$  é ajustado com um fator variante (maior ou menor que 1) de acordo com o resultado da função erro para cada iteração, o que pode conduzir a convergência mais rapidamente. No entanto, demanda mais cálculos por iteração, a depender da complexidade das funções de ativação e do problema a ser analisado. De acordo com Saini e Soni (2002) a utilização torna-se pouco prática quando se trabalha com número elevado de iterações. E apesar do grande esforço computacional no sentido de se trabalhar a formulação, ele segue sendo o algoritmo de treinamento mais rápido para Redes Neurais.

### 3.3.5 Redes neurais artificiais no controle do processo de coagulação – Estado da arte

Os primeiros usos da capacidade de aprendizado de redes neurais em tratamento de água e efluentes datam de 1992 com estudos de Boger (BOGER, 1992), no qual ele realizava uma breve descrição sobre a temática, além de apresentar aplicações na previsão das concentrações de turbidez, nitrato-nitrito e amônia em uma ETE.

Em 2002, Baxter *et al.*, define que a rede neural é uma tecnologia robusta de inteligência artificial que pode manipular a natureza complexa e dinâmica dos processos de tratamento. Onde o mesmo apresentou uma metodologia robusta detalhada para o desenvolvimento de

modelos bem-sucedidos de RNA para processos de unidades de tratamento de água potável. De modo que as interações e relações entre as variáveis de entradas e saídas do processo de tratamento de água sejam facilmente entendidas e quantificadas.

Dessa forma, diversos são os estudos que utilizam redes neurais na predição de variáveis para otimização de dosagens de coagulantes (SANTOS,2017); na predição de turbidez após um processo de tratamento de água, com a utilização de parâmetros físico-químicos sendo as variáveis de entrada (ADAM, 2013) ou até mesmo para a predição das características dos parâmetros influentes (dureza total, sólidos dissolvidos totais, alcalinidade e condutividade elétrica) na estação de tratamento de água (SOLAIMANY-AMINABAD, MALEKI, HADI, 2013).

Atualmente, apresenta-se uma grande aplicação de redes neurais artificiais visando a estimativa de dosagens de coagulante nos ensaios de Jar test visando a otimização da etapa de coagulação das ETA's. Os trabalhos apresentados na literatura, geralmente apresentam modelos de perceptron de multicamadas para a predição das características de qualidade da água e das doses ótimas dos coagulantes. As variáveis de entrada englobam as entradas de água (turbidez, alcalinidade, temperatura e pH), a quantidade de coagulante, as entradas do modelo e a qualidade da água de saída (turbidez, temperatura, alcalinidade e pH. (HAGHIRI, S.; DAGHIGHI, A.; E MOHARRAMZADEH, 2018)

Outra aplicação foi realizada para predição da turbidez da água tratada utilizando as variáveis de entrada: turbidez, pH e tipos e concentrações de coagulantes, com arquitetura de rede de 2 camadas ocultas e neurônios variando de 0-10 em ambas (ZANGOOEI, DELNAVAZ, ASADOLLAHFARDI, 2016). Por fim, Kennedy, Gandomi e Miller (2015), desenvolveram uma pesquisa com o objetivo de criar modelos robustos que podem ser utilizados para avaliar turbidez e matéria orgânica dissolvida removido durante a coagulação em Estação de Tratamento de Água Akron (Akron, Ohio, EUA), onde as variáveis de entrada foram pH e alcalinidade da água bruta e dosagens de produtos químicos (sulfato de alumínio, permanganato de potássio e dióxido de cloro).

Dessa forma pode ser percebida a aplicação de RNA's em metodologias para predição de variáveis mutáveis em estação de tratamento de água.

## 4. METODOLOGIA

### 4.1 Coleta e análise dos dados

Os dados foram obtidos a partir de um banco de dados composto por 166 resultados experimentais fornecidos pelo Laboratório Referência em Tecnologia de Águas da Universidade Estadual da Paraíba, provenientes de ensaios de *Jar Test* da água do manancial Epitácio Pessoa – PB, onde foram testados os coagulantes Sulfato de alumínio e Cloreto férrico.

O procedimento experimental consistiu na efetivação de ensaios de *Jar Test* que consideraram concentrações de coagulantes variando de 10 a 80 mg/L em intervalos de 10 mg/L e faixas de pH que compreenderam de 4,5 a 9,5, variando em intervalos de 0,5. Para a estabilização do pH foram adicionadas soluções de ácidos clorídrico (0,1N) e hidróxido de sódio (0,1 N), sendo toleradas variações de  $\pm 0,1$ .

Após o término de todas as etapas, para ambos coagulantes foi coletada uma amostra de aproximadamente 100 mL de cada compartimento do *Jar Test*, para medição de cor e turbidez averiguando a eficiência do procedimento.

#### 4.1.1 Pré-Tratamento dos dados experimentais

A partir dos dados disponíveis foram definidas as variáveis de entrada e saída da RNA, sendo as variáveis de entrada os parâmetros de cor, pH, turbidez da água bruta, dosagem de coagulante inorgânico (sulfato de alumínio ou cloreto férrico) e pH definido durante o processo de coagulação (pH de coagulação). Adicionalmente as variáveis de saída compreenderam cor e turbidez da água tratada. Os mesmos foram normalizados e depois categorizados antes de serem introduzidos na modelagem da RNA.

A normalização de dados é uma estratégia de pré-processamento que transforma a série temporal em um intervalo especificado, normalmente entre [0, 1] ou [-1, 1]. No qual garante a qualidade dos dados antes de serem alimentados em um algoritmo de aprendizado. Na literatura existem muitas técnicas como min-máx, escalonamento decimal, teste Z, que podem ser utilizados para normalizar dados. Neste trabalho utilizou-se a técnica de normalização min-máx para transformar a série temporal em um intervalo [0, 1], que é definido da seguinte forma:



$$N_i = \frac{T_i - \min(T)}{\max(T) - \min(T)} \quad (20)$$

onde  $T_i$  é o valor da série temporal em uma instância;  $N_i$  é o valor normalizado da série temporal;  $\max(T)$  valor máximo da série temporal e  $\min(T)$  valor mínimo da série temporal.

#### 4.1.2 Subdivisão do conjunto de dados experimentais


Geralmente em modelagens de RNA's costuma-se fazer a divisão dos dados em grupos, abordando o treinamento, validação e teste da rede. Os dados destinados para o treinamento são utilizados no ajuste dos pesos, onde simultaneamente os dados propostos a validação acompanham o treinamento determinando o seu fim. Já o grupo destinado ao teste avalia a habilidade de generalização da rede, aplicando um conjunto de dados que não foram usados nas etapas de treinamento e validação. Dessa forma, os respectivos dados foram definidos de forma aleatória no software MATLAB® com uma ferramenta de aleatorização dos dados, visando uma melhor adaptação da rede referente aos mesmos.

## 4.2 Processo de modelagem

O processo de modelagem da rede neural artificial foi implementado no software MATLAB®. As redes testadas apresentavam 5 neurônios de entrada constituída das variáveis cor, pH e turbidez da água bruta; dosagem de coagulante inorgânico (sulfato de alumínio ou cloreto férrico), e pH de coagulação. Uma camada oculta e 2 neurônios de saída constituídos pela cor e turbidez da água tratada, representada na figura 4.1:



**Figura 4.1:** Topologia da rede neural com 5 neurônios na camada



Fonte: Autor (2018)

#### 4.2.1 Algoritmo de treinamento

Para a definição de qual algoritmo se adaptou melhor aos dados disponíveis, foram feitos testes que compreenderam uma topologia da rede constituída de 5 neurônios de entrada, 10 neurônios na camada oculta e 2 neurônios de saída. Onde foram aplicados os algoritmos de treinamento Gradiente descendente com momento e taxa de aprendizagem adaptativa e o *Levenberg- Marquardt*, onde foi fixado a função de ativação tangente hiperbólica com o objetivo de avaliar o coeficiente de determinação das etapas de treinamento e validação da presente rede neural artificial.

#### 4.2.2 Número dos neurônios

Após a escolha do algoritmo de treinamento que melhor se adaptou tanto para o treinamento quanto para a validação dos dados, foram realizados testes variando o número de neurônios na camada oculta da rede, essa variação compreendeu o intervalo de 5 a 30 neurônios variando de 5 em 5. Esta variação teve como objetivo avaliar se com o aumento do número de neurônios na camada oculta o desempenho da RNA poderia ser influenciado, aumentando assim sua capacidade de processamento.

#### 4.2.3 Número de camadas

Determinado o número ideal de neurônios da camada oculta, foi testado o acréscimo de mais uma camada. Nesta etapa as camadas ocultas foram determinadas da seguinte maneira: a

camada 1 fixou-se o número de neurônios que se comportou melhor no teste anterior e a camada 2 variou-se o número de neurônios no intervalo de 5 a 30 neurônios, variando de 5 em 5. Neste procedimento utilizou-se a função de ativação tangente hiperbólica (*tansig*) em ambas as camadas, avaliando assim a influência do acréscimo de mais uma camada oculta na rede para a otimização do processo de predição dos parâmetros escolhidos sem afetar diretamente o custo computacional da rede.

## 5. RESULTADOS E DISCUSSÃO

A seguir, serão apresentados os resultados referentes ao modelo desenvolvido para a predição dos parâmetros de cor e turbidez, onde os mesmos serão separados em função dos coagulantes aplicados no processo.

### 5.1 Coagulação com Sulfato de alumínio

#### 5.1.1 Escolha do algoritmo de treinamento

O primeiro teste refere-se à definição do melhor algoritmo de treinamento em função do coeficiente de determinação das etapas de treinamento e validação, como pode ser observado na Tabela 5.1:

**Tabela 5.1:** Valores do coeficiente de determinação em função do algoritmo de treinamento (Sulfato de Alumínio)

Algoritmo	R <sup>2</sup>	
	Treinamento	Validação
GDX	0,96321	0,94114
<b>LM</b>	<b>0,96516</b>	<b>0,96097</b>

Fonte: Autor (2018)

Observa-se que os melhores resultados levaram para a escolha do algoritmo de treinamento Levenberg- Marquardt (LM), comparado ao gradiente descendente com momento e taxa de aprendizado adaptativo (GDX). Este fato pode ser justificativo devido aos coeficientes de determinação de treinamento e validação apresentarem uma melhor capacidade de aprendizagem e generalização da rede. Como afirma Tebaldi (2007), este método apresenta convergência em menos iterações, mas requer mais cálculos por iteração devido ao cálculo de matrizes inversas. Apesar do grande esforço computacional, ele segue sendo o algoritmo de treinamento mais rápido para redes neurais.

### 5.1.2 Otimização do número de neurônios da camada oculta

Após a determinação da melhor configuração foi realizado testes variando o número de neurônios na camada oculta, compreendendo um intervalo de 5 a 30 neurônios, com escalonamento de 5 neurônios, conforme pode ser observado na tabela 5.2:

**Tabela 5.2:** Valores do coeficiente de determinação em função da arquitetura da RNA (Sulfato de Alumínio)

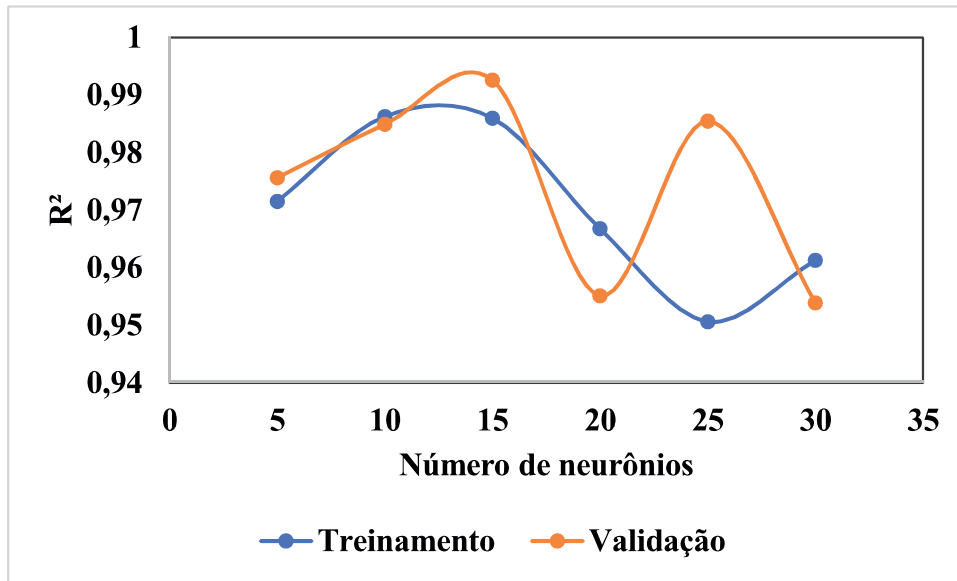
Arquitetura	R <sup>2</sup>	
	Treinamento	Validação
5	0,97153	0,97566
10	0,98627	0,98491
<b>15</b>	<b>0,986</b>	<b>0,99261</b>
20	0,96679	0,95515
25	0,95065	0,98549
30	0,96131	0,95388

Fonte: Autor (2018)

Pode ser observado na Tabela 5.2 que os resultados favoráveis em todas as variações de neurônios, onde pode-se destacar o significativo resultado da RNA composta de 15 neurônios na camada oculta. Podendo destacar a grande capacidade de generalização da rede referente aos dados disponíveis, pois a validação acompanha a evolução do aprendizado e o treinamento é interrompido, quando o erro de validação começa a crescer, evitando assim a especialização da rede para o conjunto de dados do treinamento.

A Figura 5.1 contém a representação gráfica da rede demonstrando o número de neurônios em função do coeficiente de determinação, abordando as etapas de treinamento e validação. Nota-se que para ambas as etapas a rede composta de 15 neurônios na camada oculta se ajustou melhor aos dados experimentais.

**Figura 5.1:** Valores de  $R^2$  versus número de neurônios.



Fonte: Autor (2018)

### 5.1.3 Otimização do número de neurônios nas camadas ocultas

Foi introduzido uma segunda camada oculta no modelo, onde em ambas as camadas foram utilizadas a função tangente hiperbólica e função linear na camada de saída (Tabela 5.3).


**Tabela 5.3:** Valores do coeficiente de determinação em função do número de camadas ocultas da RNA (Sulfato de Alumínio)

Arquitetura	$R^2$	
	Treinamento	Validação
15:5	0,97347	0,93487
15:10	0,98558	0,96399
15:15	0,96446	0,97991
15:20	0,97601	0,95818
15:25	0,98034	0,96225
<b>15:30</b>	<b>0,9808</b>	<b>0,98766</b>

Fonte: Autor (2018)

Para tais resultados os coeficientes se apresentaram de maneira favorável referente aos seus ajustes, entretanto, com o aumento de mais uma camada e variação de neurônios na segunda camada oculta a rede apresentou oscilações nítidas, como pode ser visto no gráfico 5.2:

**Figura 5.2:** Valores de  $R^2$  versus número de camadas ocultas




Fonte: Autor (2018)

Nota-se que associando duas camadas ocultas o ajuste na configuração 5:15:30:2 foi a que teve uma representação melhor na predição dos parâmetros de cor e turbidez. Entretanto, considerando o aumento da velocidade de processamento e a diminuição do custo computacional indica-se a aplicação da configuração de 5:15:10:2.

#### 5.1.4 Resultados Globais

Para avaliar a capacidade de predição do modelo composto por 5:15:2, foram plotados gráficos dos valores reais em função dos valores preditos (figuras 5.3 e 5.4), utilizando os dados globais referentes aos resultados de todos os experimentos realizados.

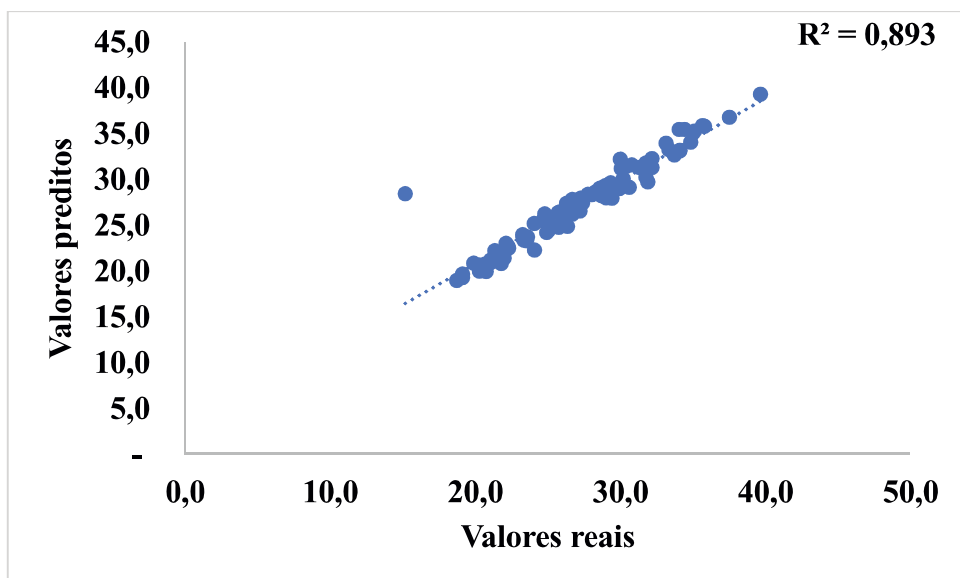
**Figura 5.3:** Valores preditos versus resultados reais de turbidez



Fonte: Autor (2018)

Associando os dados globais que envolvem os dados de treinamento (70%), validação (15%) e testes (15%), percebe-se que ocorreu uma excelente generalização dos dados alcançado pela RNA, tendo em vista a proximidade dos valores reais aos preditos referente a predição do parâmetro de turbidez.

**Figura 5.4:** Valores preditos versus resultados reais de cor



Fonte: Autor (2018)

Já referente a predição de cor, não se obteve um bom resultado se comparado com a turbidez, onde este fato pode ser justificado devido a rede não ter tido a capacidade satisfatória para a generalizar os dados referentes a mesma, prejudicando assim seu desempenho.

## 5.2 Coagulação com Cloreto férrico

A mesma metodologia utilizada para predição dos parâmetros de turbidez e cor com o sulfato de alumínio, foi utilizado com o agente químico cloreto férrico. No qual foi proporcionado os seguintes resultados (Tabela 5.4):

### 5.2.1 Escolha do algoritmo de treinamento

**Tabela 5.4:** Valores do coeficiente de determinação em função do algoritmo de treinamento (Cloreto férrico)

Algoritmo	R <sup>2</sup>	
	Treinamento	Validação
GDX	0,97546	0,98486
<b>LM</b>	<b>0,9898</b>	<b>0,99134</b>

Fonte: Autor (2018)

Diante do exposto, o algoritmo de treinamento que mais se adaptou aos dados foi o LM, onde o mesmo denota resultados excelentes tanto para o treinamento como para a validação, demonstrando que a rede proposta previu de forma efetiva os parâmetros de cor e turbidez.

### 5.2.2 Otimização do número de neurônios da camada oculta

Após a determinação da melhor configuração foi realizado testes variando o número de neurônios na camada oculta, compreendendo o intervalo de 5 a 30 neurônios variando de 5 em 5, como atestado na Tabela 5.5:

**Tabela 5.5 -** Valores do coeficiente de determinação em função da arquitetura da RNA (Cloreto férrico)

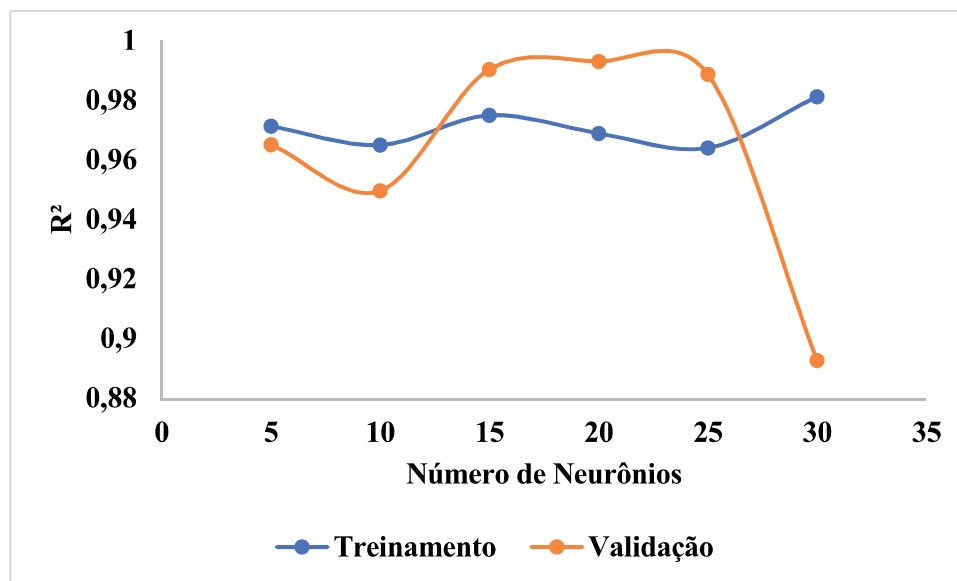
Arquitetura	R <sup>2</sup>	
	Treinamento	Validação
5	0,97129	0,96507
10	0,96489	0,94951
<b>15</b>	<b>0,97491</b>	<b>0,99029</b>
20	0,96884	0,99295
25	0,96391	0,98868
30	0,98116	0,8926

Fonte: Autor (2018)



Percebe-se mediante a análise de tais valores que em todas as variações no número de neurônios na camada oculta os dados tiveram ajustes satisfatórios, ocorrendo uma pequena divergência entre ambos. Entretanto, a configuração 5:15:2 apresentou os melhores resultados comprovando a eficiência do modelo para a predição dos parâmetros propostos.

**Figura 5.5:** Valores de  $R^2$  versus número de neurônios.



Fonte: Autor (2018)

Através deste gráfico percebeu-se que mesmo ocorrendo a variação na quantidade de neurônios da camada oculta, a capacidade de aprendizagem do modelo se comportou de maneira similar, não ocorrendo grandes oscilações, o que não pode ser dito referente a capacidade de generalização dos mesmos.

### 5.2.3 Otimização do número de neurônios nas camadas ocultas

A Tabela 5.6 denota os valores relativos aos coeficientes de determinação de treinamento e validação em função do número de camadas ocultas, onde ambas compreendem a função de ativação tangente hiperbólica.


**Tabela 5.6:** Valores do coeficiente de determinação em função do número de camadas ocultas da RNA (Cloreto férrico)

Arquitetura	R <sup>2</sup>	
	Treinamento	Validação
15:5	0,98834	0,95346
15:10	0,98959	0,95461
<b>15:15</b>	<b>0,99387</b>	<b>0,99909</b>
15:20	0,99876	0,89498
15:25	0,94484	0,95327
15:30	0,98167	0,97997

Fonte: Autor (2018)

Os valores delineados na Tabela 5.6 demonstram claramente que a introdução de mais uma camada oculta na rede, reflete diretamente na capacidade da RNA prever os dos parâmetros de cor e turbidez no processo de coagulação envolvendo o cloreto férrico. Onde os resultados corroboraram para a escolha da topologia que abrange 5:15:15:2 neurônios em cada camada oculta, como pode-se confirmar através da Figura 5.6.

**Figura 5.6:** Valores de R<sup>2</sup> versus número de camadas ocultas



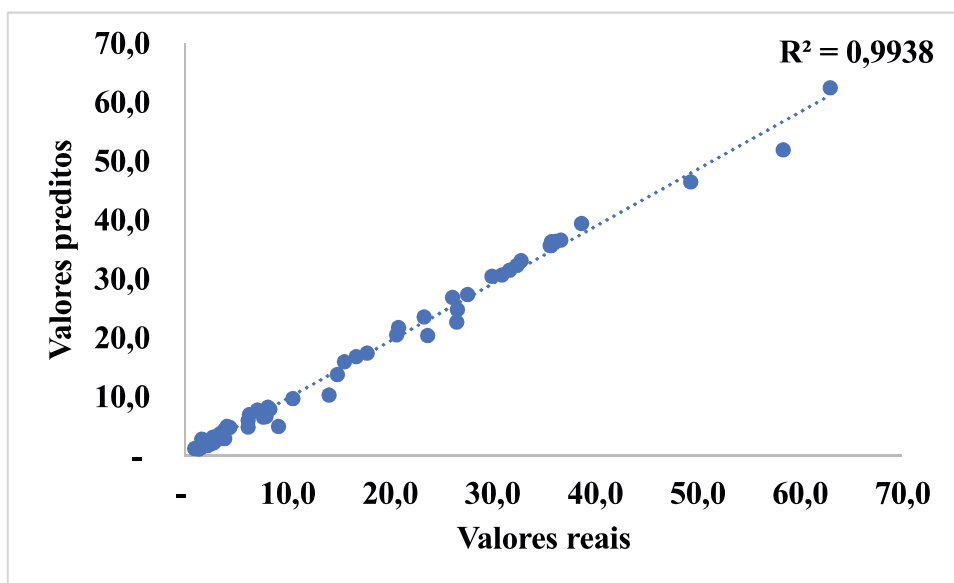
Fonte: Autor (2018)

Observa-se também que nas três primeiras variações de neurônios não ocorre oscilações críticas entre os coeficientes de treinamento e validação só acontecendo quando adiciona-se 20 neurônios na segunda camada oculta.

#### 5.2.4 Resultados Globais

Após a determinação da melhor configuração representada pela topologia composta por duas camadas ocultas com 5:15:15:2 neurônios, foram plotados gráficos dos valores reais em função dos valores preditos (Figuras 5.7 e 5.8), utilizando os dados globais referentes aos resultados de todos os experimentos realizados.

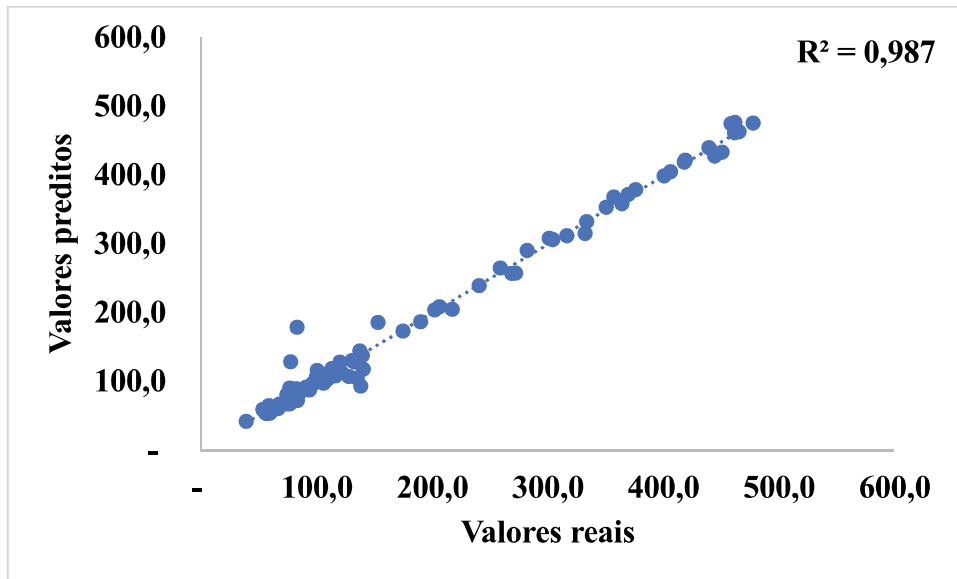
**Figura 5.7:** Valores preditos versus resultados reais de turbidez



Fonte: Autor (2018)

O gráfico sugere uma eficiente generalização alcançada pela simulação via RNA, tendo em vista a proximidade dos valores observados e simulados para o parâmetro de turbidez, sendo confirmado pelo ajuste dos dados em relação a linha de tendência resultando em um coeficiente de determinação representativo.

**Figura 5.8:** Valores preditos versus resultados reais de cor



Fonte: Autor (2018)

A Figura 5.8 contém a representação gráfica demonstrando os coeficientes de determinação dos dados globais referentes ao parâmetro de cor. Ocorrendo um ajuste satisfatório dos dados preditos em função dos dados reais, comprovando que o modelo proposto é aplicável para a situação de prever parâmetros de cor e turbidez.

## 6. CONCLUSÃO

Este trabalho propôs o desenvolvimento de modelos via redes neurais, visando a predição dos parâmetros de cor e turbidez da água tratada, como ferramenta de suporte no processo de coagulação. Foram realizadas simulações visando a escolha do algoritmo de treinamento que mais se adaptou aos dados propostos, a variação do número de neurônios na camada oculta do modelo e a inserção de mais uma camada oculta com o propósito de melhorar o desempenho do modelo no processo de predição.

Notou-se que em ambos os coagulantes o algoritmo de treinamento que mais se adaptou aos dados foi o *Levenberg - Marquardt* (LM), onde o mesmo apresentou coeficientes de determinação (treinamento e validação) com capacidade de aprendizagem e generalização superiores comparados ao método do gradiente descendente com momento e taxa de aprendizado adaptativo (GDX).

Em relação a variação do número de neurônios na camada oculta concluiu-se que para o processo de coagulação com sulfato de alumínio a arquitetura composta por 5:15:2 demonstrou resultados de ajustes exímios comprovando a eficiência do modelo para a predição dos parâmetros propostos. Além da redução do custo computacional quando comparada com a configuração 5:15:15:2 que também apresentou excelentes resultados.

O acréscimo de mais uma camada oculta ao modelo apresentou melhor comportamento ao coagulante cloreto férrico, constituída de uma topologia de 5:15:15:2 a demonstrou uma melhora significativa, refletindo diretamente na eficiente capacidade de generalização da RNA para a predição dos parâmetros de cor e turbidez.

Recomenda-se para os próximos trabalhos RNA's que otimizem a determinação de outros parâmetros de qualidade de água que em seu processo são passíveis de otimização, investigação da influência da variação das funções de ativação nas camadas ocultas e realização de experimentos devidamente planejados para obtenção de um banco de dados com melhor qualidade para modelagem.

## REFERÊNCIAS

- ALMEIDA, R. L. F. Aplicação de Redes Neurais Artificiais para Aproximar o Comportamento de Estruturas. **Dissertação (Mestrado)** - Faculdade Ciencia e Tecnologia, Universidade Nova de Lisboa, 2012.
- AMIRTHARAJAH, A.; MILLS, K. L. Rapid-mix design for mechanisms of alum coagulation. **JAWWA**, v. 74, n. 4, p. 20, 1982.
- BARRETO, J. M. **Inteligência Artificial no Limiar do Século XXI**, 3. ed. Edições Florianópolis, 2002.
- BAXTER, C.W.; STANLEY, S. J.; ZHANG, Q.; SMITH, D.W. Developing artificial neural network models of water treatment processes: a guide for utilities. **Journal of Environmental Engineering and Science** 2002 v.1:3, p.201-211, 2002.
- BAXTER, C. W.; ZHANG, Q.; STANLEY, S. J.; SHARIFF, R.; TUPAS, R.-R. T.; STARK, H. L. Drinking water quality and treatment: the use of artificial neural networks. **Canadian Journal of Civil Engineering**, v.28, p. 26–35, 2001.
- BERNARDO, L. D.; DANTAS, A. D. B. **Métodos e Técnicas de Tratamento de Água**. 2. ed. São Carlos: Rima Editora, v. 2,2005.
- BOGER, Z. Application of neural networks to water and wastewater treatment plant operation. **Instrument Society of America Transactions**, v.31, p. 25-33, 1992.
- BRAGA, A. P.; CARVALHO, A. C.; LUDERMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**. 2ª edição. São Carlos: LTC, 2007
- BRASIL, **Manual de controle da qualidade da água para técnicos que trabalham em ETAS**. Ministério da Saúde, Fundação Nacional de Saúde (FUNASA). – Brasília: Funasa, 2014.
- CAVALCANTE, W. M. Redes Neurais Artificiais como ferramenta de auxílio na operação e controle da Estação de Tratamento de Água de Palmeira dos Índios. 76 f. il. 2018. **Dissertação (Mestrado)** – Programa de Pós-Graduação em Engenharia Industrial (PEI), Escola Politécnica, Universidade Federal da Bahia, Salvador, 2018.
- DELGADO-GARCÍA, J. M. Cajal and the Conceptual Weakness of Neural Sciences. **Frontiers in Neuroanatomy**. v.9 (128) p.1-9,2015.
- DI BERNARDO, L.; SABOGAL PAZ, L. P. **Seleção de Tecnologias de Tratamento de Água**. v.1. São Carlos: Editora LDIBE LTDA, 2008.
- FREITAS, C. C. de. Aplicação de redes neurais artificiais na modelagem de reatores fotoquímicos. 2012. 45f. **Trabalho de Conclusão de Curso** (Graduação em Engenharia Sanitária e Ambiental). Universidade Estadual da Paraíba, Campina Grande, 2012.

GOMES, L. S.; SOUZA, S. A. A.; PONTES, T. R. A.; NETO, F. R.. Coagulant dosage determination in a water treatment plant using dynamic neural network models, **International Journal of Computational Intelligence and Applications**, 2015.

HAGHIRI, S.; DAGHIGHI, A.; AND MOHARRAMZADEH, S. Optimum coagulant forecasting by modeling jar test experiments using ANNs. **Drinking. Water Engineering. Science.**, v.11, p.1-8, 2018.

HAYKIN, S. **Redes neurais: princípios e prática**. Trad, Paulo Martins Engel. 2.ed. Porto Alegre:Bookman., 2001.

JIANG, J. The role of coagulation in water treatment. **Current Opinion in Chemical Engineering**, v. 8, p. 36-44, 2015.

LOURENCETTI, F. H. L892e Estudo de reprodução do comportamento hidráulico de sistemas de abastecimento de água via redes neurais artificiais (RNAs). **Tese de doutorado** / Fernando Henrique Lourencetti; orientador Luisa Fernanda Ribeiro Reis. São Carlos, 2011.

LUDWIG Jr., O. e COSTA, E.M.M. **Redes Neurais: Fundamentos e Aplicações com Programas em C**. Rio de Janeiro :Ciência Moderna, 2007.

KENNEDY, M. J.; GANDOMI, A. H.; MILLER, C.M.Coagulation modeling using artificial neural networks to predict both turbidity and DOM-PARAFAC component removal, **Journal of Environmental Chemical Engineering**, v.3 (4), p. 2829-2838,2015.

OMS, Organização Mundial da Saúde (World Health Organization). **Water Treatment and Pathogen Control: Process Efficiency in Achieving Safe Drinking Water**. Edited by Mark W LeChevallier and Kwok-Keung Au. ISBN: 1 84339 069 8. Published by IWA Publishing, London, UK,2004.

OKPARA, C.G.; OPARAKU, N. F.; IBETO, C.N. An Overview of Water Disinfection in Developing Countries and Potentials of Renewable Energy. **Journal of Environmental Science and Technology**, 4: 18-30, 2011.

PATTERSON, J.; GIBSON, A. **Deep Learning A Practitioner's Approach. In: Foundations of Neural Networks and Deep Learning**. 1. ed. Califórnia: O'Reilly Media, Inc, 2017.

RAK, A. Water turbidity modelling during water treatment processes using artificial neural networks. **International Journal of Water Sciences**, v.2 p.1-10, 2013.

REIS, C. G. Análise dos Processos de Clarificação e Filtração da Água para Consumo Humano Estações de Tratamento de Água do Rio Grande do Sul. Universidade Federal Do Rio Grande Do Sul, **trabalho de diplomação em Engenharia Química**. Porto Alegre, 2016.

RIPPERGER, S.; GÖSELE, W.; ALT, C. Filtration Ullmann's Encyclopedia of Industrial Chemistry, Fundamentals, 1. **Wiley-VCH Verlag GmbH & Co. KgaA, Weinheim**, 2012.

RUMELHART, D. E. & McCLELLAND, D. E. (1986). Parallel Distributed Processing, vol 1 **MIT Press**, Cambridge, MA.

ReCESA, Operação e manutenção de estações de abastecimento de água: guia do profissional em treinamento nível 1. **Secretaria Nacional de Saneamento Ambiental (org.)**. – Belo Horizonte. 80 p, 2008.

SAINI, L.M.; SONI, M.K. Artificial Neural Network Based Peak Load Forecasting Using Levenberg-Marquardt and Quasi-Newton Methods. **IEE Proceedings on Generation Transmission, Distribution**, Vol.149, N.5, p. 578- 584, 2002.

SANTOS, F. C. R.; LIBRANTZ, A. F. H.; DIAS, C. G; RODRIGUES, S. G. Intelligent system for improving dosage control. **Acta Scientiarum: Technology**. v. 39, n. 1, p. 33-38, 2017.

SILVA, I. N.; SPATTI, S. H.; FLAUZINO, R. A. Redes neurais artificiais: para engenharia e ciências aplicadas. São Paulo: **Artliber**, 2010. 399 p.

SINGH. K. M. P.; UDAYABHANU, G.; GOURICHARAN B & T., Comparative Studies on the Settling Behavior of Indian Noncoking Coal Fines by Standard Jar Test and Instrument, **International Journal of Coal Preparation and Utilization**, Taylor & Francis Group, p 65–74, 2015.

TEBALDI, F. B. e. Estudo de redes neurais artificiais para verificação de assinaturas através de imagens. 2007. **Monografia (Bacharelado em Ciência da Computação)** – Centro Universitário Eurípides de Marília, Fundação de Ensino Eurípides Soares da Rocha, Marília, 2007.

TUNDISI, J. G. Água no século XXI: enfrentando a escassez. São Carlos, SP: **RiMa**, 2003. 248 p.

WILAMOWSIKI, B. M.; YU, H. Levenberg-Marquardt Training. **IEEE Transactions on Neural Networks**, v.21, n.6, p.1-15, 2010

ZANGOUEI, H.; Mohammad, D.; Gholamreza, A. Prediction of coagulation and flocculation processes using ANN models and fuzzy regression. **Water Science and Technology**, v. 74(6), p. 1296-1311, 2015.