

**UNIVERSIDADE DE CAXIAS DO SUL – UCS  
CAMPUS UNIVERSITÁRIO DA REGIÃO DOS VINHEDOS – CARVI  
ÁREA DE CONHECIMENTO DE CIÊNCIAS EXATAS E ENGENHARIAS**

**TIAGO BAUERMANN STAUDT**

**PREDIÇÃO DO VOLUME DE BIOGÁS PRODUZIDO EM SISTEMAS DE  
BIODIGESTÃO UTILIZANDO REDES NEURAIS ARTIFICIAIS**

**BENTO GONÇALVES  
2019**

**TIAGO BAUERMANN STAUDT**

**PREDIÇÃO DO VOLUME DE BIOGÁS PRODUZIDO EM SISTEMAS DE  
BIODIGESTÃO UTILIZANDO REDES NEURAS ARTIFICIAIS**

Monografia do Trabalho de Conclusão II de graduação em Engenharia Elétrica, apresentado a área do Conhecimento de Ciências Exatas e Engenharias, como requisito parcial para obtenção do título de Engenheiro Eletricista.

Orientador: Prof. Me. Ricardo Becker

**BENTO GONÇALVES**

**2019**

**TIAGO BAUERMANN STAUDT**

**PREDIÇÃO DO VOLUME DE BIOGÁS PRODUZIDO EM SISTEMAS DE  
BIODIGESTÃO UTILIZANDO REDES NEURAS ARTIFICIAIS**

Monografia do Trabalho de Conclusão II de graduação em Engenharia Elétrica, apresentado a área do Conhecimento de Ciências Exatas e Engenharias, como requisito parcial para obtenção do título de Engenheiro Eletricista.

**Aprovado em** \_\_\_\_\_ de \_\_\_\_\_ de \_\_\_\_\_.

*Banca examinadora:*

---

Prof. Me. Ricardo Becker  
Universidade de Caxias do Sul - UCS

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Vania Elisabete Schneider  
Universidade de Caxias do Sul - UCS

---

Prof. Me. Angelo Zerbetto Neto  
Universidade de Caxias do Sul - UCS

## **AGRADECIMENTOS**

A Deus. A minha amada esposa Michele pelo apoio incondicional e paciência ao longo desta jornada. A minha querida filha Mariana que tão pouco sabe ainda sobre a vida e suas dificuldades, mas que já soube a importância deste trabalho na vida de nossa família e por isso teve paciência para que eu chegasse ao final dele e agora conviver mais em família.

Aos meus amados pais Waldemar e Marlene que sempre me incentivaram a estudar mesmo em momentos de dificuldade. Ao meu querido irmão que me incentivou para que eu concluísse a graduação.

Ao mestre Ricardo Becker. Pelo apoio e suporte dados durante a orientação deste trabalho e pela confiança em mim depositada.

Aos membros da banca examinadora. Doutora Vania e Mestre Ângelo. Pela disponibilidade e contribuições dadas ao trabalho.

Aos demais professores e colegas de graduação, pelo conhecimento e experiências de vida compartilhados ao longo dos anos.

Aos amigos Fabio e Camila. Pelas importantes contribuições e pelo apoio dados a este trabalho.

*“Não importa o quão devagar você vá, desde que não pare.”*

**CONFÚCIO**

## RESUMO

Este trabalho apresenta a implementação de uma Rede Neural Artificial (RNA) desenvolvida na ferramenta computacional MATLAB, com a capacidade de prever de forma estimada o volume de biogás e de metano, produzido em um sistema de biodigestão anaeróbia. Para isso, a RNA desenvolvida, utiliza como entrada de dados, parâmetros físico-químicos da matéria orgânica a ter o seu potencial de produção de biogás inferido, sem que haja a necessidade da realização de experimentos em laboratório. Partindo da premissa de que a forma mais comumente utilizada para avaliação do potencial de produção de biogás é a realização de inúmeros testes em laboratório, que levam de alguns dias até mesmo meses para aferir este potencial, a RNA foi elaborada para trazer maior agilidade ao processo. Essa agilidade também deve servir como ferramenta de apoio para tomada de decisão quanto a viabilidade de projetos que usam biogás e metano para geração de energia elétrica e térmica. É então apresentado um modelo desenvolvido sobre um banco de dados de experimentos de biodigestão realizados em laboratório, onde diferentes matérias orgânicas foram testadas e tiveram resultados de desempenho compilados. Deste banco de dados, parâmetros físico-químicos foram extraídos para serem usados como entrada no processo de treinamento e validação do modelo de rede neural desenvolvido. A RNA foi então submetida ao treinamento, validação e testes fazendo uso de um grupo de dados com 93 amostras, onde teve avaliado sua capacidade de estimação através do índice de correlação e também através do erro quadrático médio obtidos, além de ter seus resultados equiparados as referências. Após essas etapas a rede foi submetida a inferir a produção de biogás e de metano de dois diferentes grupos de dados os quais, possuíam características físico-químicas diferente dos dados usados em seu desenvolvimento. Ao final os resultados mostraram que a RNA desenvolvida tinha aptidão para estimação do grupo usado para o treinamento, assim como apresentado pelas referências, contudo apresentou resultados inconsistentes quando submetida a dados diferentes dos utilizados em seu treinamento, evidenciando a necessidade de um maior desenvolvimento.

**Palavras-chave:** Redes Neurais Artificiais. Matlab. Biogás. Metano. Energia elétrica renovável.

## ABSTRACT

This work presents the implementation of an Artificial Neural Network (ANN) developed on the computational tool MATLAB, with the ability to predict, in an estimated way, the volume of biogas and methane produced in an anaerobic biodigestion system. The ANN developed, uses as input data, physicochemical parameters of organic matter to have its potential for production of inferred biogas, without the need to carry out laboratory experiments. On the assumption that the most commonly way used to evaluate the potential of biogas production is to carry out numerous laboratory experiments which takes a few weeks or even months to gauge this potential, then ANN was designed to bring more agility to the process. This agility can also serve as a support tool for decision making regarding the feasibility of projects that uses biogas and methane for electric and thermal energy generation. A model developed in database of biodigestion experiments, conducted in the laboratory, is then presented, where were tested different organic matters and the results of performance were compiled. From this database, physicochemical parameters were extracted to be used as input into training and validation process of the developed neural network model. ANN was then submitted to training, validation and testing using data group of 93 samples. Its capacity of estimation was evaluated through the correlation index and also through the mean square error obtained. In addition, the results were equated with the references. After these steps, the network was submitted to infer the biogas and methane production of two different data groups, which had different physicochemical characteristics from those used in its development. To conclude, the results showed that the ANN developed had the ability to estimate the group used for the training, as presented by references. However, it presented inconsistent results when submitted to different data from those used in their training, evidencing the need for further development.

**Keywords:** Artificial Neural Network. MATLAB. Biogas. Methane. Renewable electricity.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Fases do Processo de Digestão Anaeróbia .....	21
Figura 2 – Fontes de produção e aplicações para o biogás .....	26
Figura 3 – Representação em diagrama de blocos do sistema nervoso central .....	44
Figura 4 – Representação de um neurônio biológico .....	44
Figura 5 – Representação de um neurônio artificial .....	45
Figura 6 – Algumas das arquiteturas de redes neurais artificiais .....	46
Figura 7 – Diagrama de blocos comparando um sistema de biodigestão convencional e outro que utiliza RNA .....	50
Figura 8 – Interface da aplicação nntool do Matlab, onde a RNA é desenvolvida.....	65
Figura 9 – Interface de criação das redes neurais através da GUI do MATLAB .....	66
Figura 10 – Interface inicial (GUI) da aplicação nntool.....	67
Figura 11 – Gráfico do índice de correlação e melhor performance obtida quanto ao MSE .....	74
Figura 12 - Gráfico do índice de correlação e melhor performance obtida quanto ao MSE .....	76
Figura 13 –Gráfico de regressão linear e índice de correlação R .....	77
Figura 14 – Gráfico de regressão linear das 93 amostras usadas no desenvolvimento da RNA A .....	78
Figura 15 – Gráfico de dispersão que da diferença entre valores reais e valores de predição .....	78
Figura 16 – Histograma dos erros obtidos pela RNA A 8 na etapa de treinamento ..	79
Figura 17 – Imagem do gráfico de regressão linear do índice de correlação R .....	80
Figura 18 – Gráfico de dispersão do volume de biogás real versus os volumes previstos pela RNA B .....	81
Figura 19 - Histograma da frequência de erros obtidos para o volume de biometano pela RNA B 15 na etapa de treinamento.....	82
Figura 20 – Gráfico de dispersão relacionando os volumes reais e previstos de Metano pela RNA B.....	83
Figura 21 - Histograma dos erros obtidos pela RNA B 15 na etapa de treinamento .	84
Figura 22 – Gráfico de dispersão relacionando volumes reais e preditos pela RNA A para o GRUPO B.....	86

Figura 23 – Histograma de distribuição de erros da RNA A com dados do GRUPO B .....	87
Figura 24 – Gráfico de dispersão relacionando volumes reais e preditos para o GRUPO C.....	87
Figura 25 – Distribuição dos erros da RNA A na estimação do volume de biogás do GRUPO C.....	88
Figura 26 – gráfico de dispersão dos volumes de biogás (targets) versus volumes estimados pela RNA B .....	89
Figura 27 – Histograma com distribuição de erros da RNA B e GRUPO B para Biogás .....	90
Figura 28 – Gráfico de dispersão das amostras do grupo B para estimação de Metano .....	91
Figura 29 – Histograma com distribuição de erros da RNA B das amostras do GRUPO B para Metano.....	91
Figura 30 – Gráfico de dispersão das amostras do GRUPO C para estimação do volume de biogás .....	92
Figura 31 – Distribuição dos erros da RNA B na estimação do volume de biogás do GRUPO C.....	93
Figura 32 – Gráfico de dispersão das amostras do GRUPO C para previsão de volume de metano .....	93
Figura 33 – Distribuição dos erros da RNA B na estimativa do volume de metano do GRUPO C.....	94

## LISTA DE QUADROS

Quadro 1 – Características descritas com aplicações de redes neurais artificiais.....43

## LISTA DE TABELAS

Tabela 1 - Alguns dos métodos utilizados para avaliação da produção de biogás ...	28
Tabela 2 – Principais parâmetros citados e utilizados para monitoramento do processo de biodigestão .....	33
Tabela 3 – Modelos de previsão e otimização propostos por diversos autores	41
Tabela 4 – Modelos de previsão e otimização propostos por diversos autores. (continua) .....	<b>Erro! Indicador não definido.</b>
Tabela 5 – Topologias utilizadas pelos autores citados ao longo do trabalho.....	54
Tabela 6 – substratos que compõe o banco de dados e suas principais características .....	61
Tabela 7 – Arquitetura e parâmetros de treinamento adotados na RNA A .....	68
Tabela 8 – Arquitetura e parâmetros de treinamento adotados na RNA B .....	69
Tabela 9 – Resultados de $R$ e $MSE$ , além de outros, da etapa de treinamento obtidos pela RNA A.....	72
Tabela 10 – Resultados de $R$ e $MSE$ , entre outros, obtidos na etapa de treinamento pela RNA B.....	75
Tabela 11 – Tabela que compara o $MSE$ e o $R$ obtido ao das referências .....	95
Tabela 12 – Tabela que compara o $MSE$ e o $R$ obtido ao das referências .....	96
Tabela 13 – Tabela de substratos e parâmetros usados no desenvolvimento da RNA (continua).....	107
Tabela 14 - Tabela de substratos e parâmetros usados em testes da RNA desenvolvida .....	114
Tabela 15 – Insumos de diferentes origens e seus respectivos parâmetros (continua) .....	116
Tabela 16 – Resultados obtidos para cada topologia da RNA A nas etapas de treinamento, validação e testes.....	118
Tabela 17 – Resultados obtidos para cada topologia testada para RNA B, nas etapas de treinamento, validação e testes.....	119

## LISTA DE ABREVIATURAS E SIGLAS

ABIOGAS	Associação Brasileira do Biogás.
ALK	Alcalinidade
AME	Avaliação Metanogênica Específica
BTL	<i>Biogas to Liquid</i>
$CH_4$	Metano
$CO_2$	Dióxido de Carbono
DBO	Demanda Biológica de Oxigênio
DQO	Demanda Química de Oxigênio
ETE	Estação de Tratamento de Efluentes
GLP	Gás Liquefeito de Petróleo
$H_2$	Hidrogênio Molecular
$H_2S$	Gás Sulfídrico
kWh	Quilo Watt hora
MATLAB	<i>Matrix Laboratory</i>
MLP	<i>Multi Layer Perceptron</i>
MW	Mega Watt
$N_2$	Nitrogênio
NA	Não se Aplica.
$NH_3$	Amoníaco
$O_2$	Oxigênio
PCCR	Planejamento Composto Central Rotacional
pH	Potencial Hidrogênico
PPB	Potencial de Produção de Biogás
PPM	Potencial de Produção de Metano
RNA	Rede Neural Artificial.
SF	Sólidos Fixos
ST	Sólidos Totais
SV	Sólidos Voláteis
TRH	Tempo de Retenção Hidráulica
TVA	Ácidos Voláteis Totais
UCS	Universidade de Caxias do Sul
UNIVATES	Universidade do Vale do Taquari

VB	Volume de Biogás
VM	Volume de Metano

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>15</b>
1.1 CONTEXTUALIZAÇÃO E JUSTIFICATIVA .....	15
1.2 SITUAÇÃO PROBLEMA.....	17
1.3 OBJETIVO GERAL .....	18
1.4 OBJETIVOS ESPECÍFICOS.....	18
1.5 RESTRIÇÕES .....	19
<b>2 REFERENCIAL TEÓRICO</b> .....	<b>21</b>
2.1 O PROCESSO DE BIODIGESTÃO ANAERÓBIA .....	21
2.2 PRODUÇÃO DE METANO E DO BIOGÁS .....	23
2.3 AVALIAÇÃO DO DESEMPENHO EM PROCESSOS DE BIODIGESTÃO .....	26
2.4 A INTERFERÊNCIA DA MATÉRIA ORGÂNICA E DO SUBSTRATO NO VOLUME DE BIOGÁS E METANO PRODUZIDO .....	28
2.5 VARIÁVEIS QUE INTERFEREM NA PRODUÇÃO DE BIOGÁS.....	30
2.6 A UTILIZAÇÃO DO BIOGÁS .....	33
2.7 APLICAÇÃO DO BIOGÁS PARA GERAÇÃO DE ENERGIA ELÉTRICA.....	35
2.8 TECNOLOGIAS DE CONVERSÃO .....	36
2.9 ESTADO DA ARTE .....	36
2.10 REDES NEURAIS ARTIFICIAIS E SUA APLICAÇÃO COMO MÉTODO DE PREVISÃO E OTIMIZAÇÃO EM SISTEMAS DE BIODIGESTÃO .....	42
<b>3 METODOLOGIA</b> .....	<b>49</b>
3.1 DEFINIÇÃO DA BASE DE DADOS E ESTRUTURAÇÃO DAS AMOSTRAS ..	51
3.2 DEFINIÇÃO DO MODELO MATEMÁTICO APLICADO A ESTIMAÇÃO .....	52
3.3 DESENVOLVIMENTO DA REDE NEURAL .....	53
3.4 VALIDAÇÃO E TESTES FUNCIONAIS.....	56
3.5 AVALIAÇÃO DE DESEMPENHO QUANTO A CAPACIDADE DE ESTIMAÇÃO.....	58
<b>4 IMPLEMENTAÇÃO DO PROJETO</b> .....	<b>59</b>
4.1 BASE DE DADOS PARA TREINAMENTO E VALIDAÇÃO DA RNA .....	59
4.2 REDE NEURAL ARTIFICIAL .....	63
<b>4.2.1 Rede Neural A</b> .....	<b>68</b>
<b>4.2.2 Rede Neural B</b> .....	<b>69</b>
<b>5 RESULTADOS</b> .....	<b>71</b>

5.1	TREINAMENTO DAS REDES .....	71
5.1.1	Rede Neural A .....	71
5.1.2	Rede Neural B .....	74
5.2	VALIDAÇÃO E TESTES DE FUNCIONALIDADE .....	76
5.2.1	Validação E Teste Funcional Da RNA A .....	77
5.2.2	Validação E Teste Funcional Da RNA B .....	80
5.3	AVALIAÇÃO DE DESEMPENHO E CAPACIDADE DE ESTIMAÇÃO .....	85
5.3.1	Capacidade de Estimação e Generalização da RNA A.....	85
5.3.2	Capacidade de Estimação e Generalização da RNA B .....	88
5.4	COMPARAÇÃO DE RESULTADOS .....	94
5.4.1	Comparação de Resultados da RNA A .....	95
5.4.2	Comparação de Resultados da RNA B .....	96
6	CONSIDERAÇÕES FINAIS .....	98
	REFERÊNCIAS.....	101
	ANEXO A – TABELA DOS INSUMOS E SEUS RESPECTIVOS PARÂMETROS USADOS NO DESENVOLVIMENTO DA RNA NAS ETAPAS DE TREINAMENTO E VALIDAÇÃO – GRUPO A .....	107
	ANEXO B – TABELA DE INSUMOS E SEUS RESPECTIVOS PARÂMETROS USADOS NA ETAPA DE VALIDAÇÃO E TESTES DA RNA DESENVOLVIDA – GRUPO B.....	114
	ANEXO C – TABELA DE INSUMOS E SEUS RESPECTIVOS PARÂMETROS, COM DIFERENTES ORIGENS, USADOS NO PROCESSO DE TESTES E AVALIAÇÃO DA CAPACIDADE DE GENERALIZAÇÃO DA RNA DESENVOLVIDA – GRUPO C.....	116
	APÊNDICE A .....	118
	APÊNDICE B .....	119

# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO E JUSTIFICATIVA

O biogás é uma mistura de gases composta principalmente por metano e dióxido de carbono, os quais são obtidos através do processo de digestão anaeróbia da matéria orgânica de diversas origens. A digestão anaeróbica é um processo biológico em que a matéria orgânica é depositada em um local sem oxigênio, onde é convertida em diversos gases, dentre os quais o metano é o gás de maior importância, devido ao seu poder calorífico.

O biogás é, principalmente, utilizado para geração de energia elétrica e de calor. No entanto, muitos países que já possuem esta tecnologia difundida estão utilizando o biogás como combustível veicular e injetando-o na rede de gás natural. Para permitir a injeção de biometano à rede de gás natural ou o uso como combustível para veículos, deve ser removido o dióxido de carbono a fim de que a fração de metano seja superior a 96%, além de atender as normas de qualidade para substituir o gás natural (BLEY, 2015).

O Brasil passou por uma experiência com biogás na década de 1980 como forma de saneamento, não como fonte de energia. No campo ainda há biodigestores (lagoas cobertas por lonas) instalados, mas são, em sua maioria, equipamentos de baixa tecnologia voltados para o tratamento de resíduos e também para a redução da carga orgânica das atividades das propriedades. Além disso, não ocorreram treinamentos e capacitações de quem lidava com esses equipamentos no dia a dia e, à medida que estes mesmos equipamentos mostravam necessidade de manutenção, as pessoas não sabiam o que fazer e as instalações foram sendo desativadas.

Esse histórico foi negativo para o biogás no país, especialmente no setor rural, que apresenta a maior possibilidade de uso das novas tecnologias de aproveitamento energético.

De forma geral, existe um desconhecimento no Brasil a respeito de quanto a tecnologia evoluiu, como o biogás tem sido importante no resto do mundo e como o país tem potencial para produção de biogás.

Em 2013, foi criada a Associação Brasileira de Biogás e Biometano (ABiogás), que tem se empenhado em mostrar o potencial do país para a produção de energia e combustível a partir de resíduos, tanto da agricultura quanto de aterros, além de

efluentes sanitários (esgoto) e dejetos resultantes da criação de animais em abatedouros e laticínios.

Uma pesquisa feita pela ABiogás (2015) identificou que o país desperdiça, por ano, mais de uma Itaipu e meia em energia que poderia ser obtida com biogás. Hoje, o país deixa de gerar cerca de 115 mil gigawatts-hora de energia com o não aproveitamento dos rejeitos urbanos da pecuária e da agroindústria. Esse volume poderia ter abastecido cerca de 25% de toda energia elétrica consumida em 2015, aliviando a pressão sobre o setor (BLEY, 2015).

Porém, o potencial energético do biogás pode ter variações. Essas variações dependem tanto dos insumos quanto de variáveis aplicadas no controle do processo de biodigestão. A determinação da melhor combinação de insumos e controle do processo de produção do biogás acontece, em alguns casos, pelo método de tentativa e erro. Em geral, são testadas diferentes combinações de insumo com diferentes controles para o processo, até que se alcance algum resultado. Esse processo de testes é custoso do ponto de vista financeiro e de tempo, uma vez que pode levar meses e normalmente precisa ser repetido para a validação dos resultados.

Atualmente, diferentes modelos matemáticos são comumente utilizados como ferramenta de apoio para a determinação do potencial de biogás, tornando o processo de testes mais rápido. Modelos baseados em inteligência artificial tem se mostrado eficazes como ferramenta de predição quando utilizados em sistema biológicos, onde o comportamento não linear traz dificuldades para a previsão de resultados.

Baseado nas informações até aqui expostas, a proposta de predição e otimização de sistemas de produção de biogás justifica-se, uma vez que poderia ser implementada em sistemas de biodigestão, inclusive em sistemas existentes já construídos.

Um sistema de predição tem como premissa antever o desempenho de um determinado processo de biodigestão, trazendo atratividade e permitindo avaliar a viabilidade do projeto antes mesmo de sua concepção.

Dessa forma, o investimento pode ser pago através da geração de energia elétrica e energia térmica em sistemas de cogeração, sendo a energia para utilização própria, ou até mesmo para comercializá-la junto ao mercado livre de energia na forma de energia 100% incentivada.

Além de uma solução ambiental no que diz respeito a questão do tratamento de resíduos, a ferramenta poderá ser uma solução para sistemas de geração de energia a biogás.

## 1.2 SITUAÇÃO PROBLEMA

Pensando em um viés comercial quanto à viabilidade de geração de energia elétrica a partir da produção de biogás, a escolha do material e das variáveis do processo são extremamente importantes e podem impactar diretamente na viabilidade do projeto.

Em publicação recente, Karlsson et al. (2014) cita que o material fornecido a um processo de biogás e o tipo de substrato a ser utilizado afetam a estabilidade e a eficiência do processo. A composição do substrato é importante para a quantificação e a qualidade do biogás, o que está diretamente ligado à quantidade de nutrientes e contaminantes potenciais (metais, patógenos, contaminantes orgânicos contidos na matéria orgânica).

Ainda segundo Karlsson et al. (2014), a escolha do material gera influência no resultado do processo, na maximização da produção de energia e na qualidade de biogás.

A composição do substrato é importante para os microrganismos do processo e, portanto, também para a estabilidade e a produção de gás. O substrato deve atender às necessidades nutricionais dos microrganismos, ou seja, contém energia e componentes necessários para os reproduzir (KARLSSON et al., 2014).

No contexto apresentado, o problema é que a escolha deste material a ser inserido no processo depende basicamente de testes realizados em laboratório, onde diversos reatores em pequena escala devem ser utilizados para realização de diferentes tipos de testes de composição e variáveis do processo, buscando a melhor combinação de substratos e de variáveis para o melhor desempenho da produção de biogás e metano.

Karlsson et al. (2014) fala que experiências devem ser realizadas em escala laboratorial para avaliar o potencial de geração de distintos substratos, onde cita a relevância ao permitir avaliar, de forma confiável, a quantidade de biogás que determinada composição de substrato pode gerar para que posteriormente se pense em instalar uma planta de biogás em larga escala.

Estes testes podem levar dias ou semanas, além de serem realizados por poucos laboratórios, que normalmente se encontram em ambientes acadêmicos e de pesquisa, tornando sua utilização restrita por parte da população.

Visando facilitar a análise de viabilidade de um projeto de geração de energia com a utilização de biogás, este trabalho traz como principal proposta a avaliação da utilização de ferramentas baseadas em inteligência artificial como forma de selecionar as melhores condições de processo e a melhor combinação de matéria orgânica visando a otimização da produção de biogás.

### 1.3 OBJETIVO GERAL

O objetivo do trabalho é desenvolver um algoritmo baseado em Redes Neurais Artificiais (RNA) que tenha capacidade de prever ou estimar o volume de produção de biogás a partir de uma determinada combinação de insumos, usando como dados de entrada alguns dos parâmetros físico-químicos das matérias orgânicas usadas no processo de biodigestão.

### 1.4 OBJETIVOS ESPECÍFICOS

Como forma de tornar tangível o objetivo geral deste trabalho, pode-se destacar os seguintes objetivos específicos:

- i. Compilar parâmetros físico-químicos de um banco de dados de experimentos realizados em laboratório, para utilização no processo de desenvolvimento da RNA;
- ii. Avaliar topologias de RNA baseado nas referências apresentadas e selecionar a que melhor se adequa ao escopo do trabalho, desenvolvendo-a para que tenha capacidade de prever o volume de biogás de um sistema de biodigestão;
- iii. Selecionar um conjunto de amostras de resultados já catalogados e anteriormente avaliados em laboratório, para o processo de treinamento e validação do modelo de RNA desenvolvido;
- iv. Comparar os resultados obtidos com as referências utilizadas ao longo do trabalho, avaliando o desempenho do algoritmo frente a dados e parâmetros não utilizados no processo de desenvolvimento da RNA;

- v. Avaliar o desempenho e a capacidade de generalização da RNA desenvolvida comparando as referências.

## 1.5 RESTRIÇÕES

Algumas restrições devem ser impostas e alguns riscos devem ser avaliados, uma vez que o desenvolvimento do trabalho deve se limitar aos objetivos anteriormente especificados.

Inicialmente, cabe ressaltar que a RNA desenvolvida compõe um modelo matemático computacional baseado em inteligência artificial para previsão e otimização de resultados, que utiliza dados de experimentos de biodigestão anteriormente já realizados em laboratório.

Os dados disponibilizados para serem utilizados foram compilados e validados pela Universidade do Vale do Taquari (UNIVATES) através do laboratório de bioreatores. As diferentes combinações de matéria orgânica foram limitadas e fornecidas por uma empresa produtora de ovos, a qual possui parceria com a UNIVATES para estes testes e que determina quais combinações de alimentação devem ser testadas e validadas.

Para a realização dos testes e obtenção dos dados, uma série de reatores de escala laboratorial, acondicionados em uma estufa com temperatura controlada, foram alimentados com inóculo oriundo de um sistema de tratamento anaeróbico de efluentes da empresa anteriormente citada, e cada um deles recebeu uma combinação de diferentes matérias orgânicas como alimento. Os testes foram realizados utilizando como referência a norma VDI4630<sup>1</sup>, que estabelece procedimentos e critérios específicos para avaliação de processos de biodigestão.

A origem dos dados do processo de biodigestão testados são ensaios físico-químicos de cada matéria orgânica testada, onde parâmetros como sólidos, pH, relação carbono Nitrogênio, DQO, DBO e medições de temperatura são realizadas ao longo dos testes. O volume de produção de biogás foi inferido através de um sistema

---

<sup>1</sup> VDI4630 – Norma alemã que estabelece regras e procedimentos para determinação da performance de sistemas de biodigestão e que é utilizada como base para avaliação e melhoria da performance da produção de biogás. Disponível em: [https://m.vdi.eu/uploads/tx\\_vdirili/pdf/2385990.pdf](https://m.vdi.eu/uploads/tx_vdirili/pdf/2385990.pdf). Acesso em: 04 abr. 2019.

de medição de tubos de vidro em “U” por deslocamento de coluna d’água com volume graduado.

O sistema se limitará a propor somente a melhor combinação de entrada de dados, não controlando outras variáveis do processo e tão pouco recebendo informações em tempo real do comportamento do sistema.

A entrada de dados levará somente em consideração algumas das características físico-químicas da matéria orgânica a ser inserida no processo de biodigestão, ficando limitada aos dados disponíveis presentes no banco de dados da empresa.

## 2 REFERENCIAL TEÓRICO

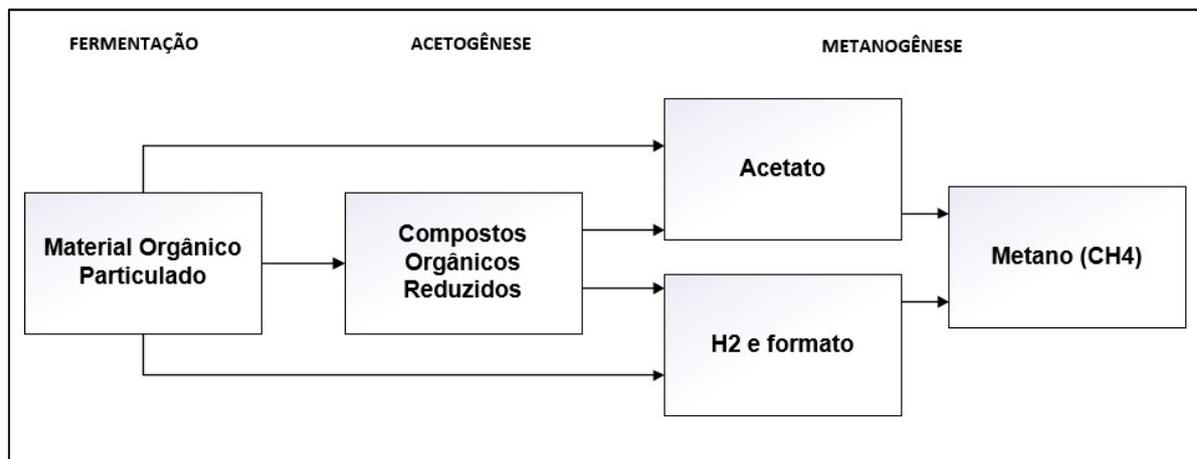
Com a finalidade de fundamentar a metodologia utilizada para a realização deste trabalho, serão apresentados conceitos teóricos e práticos para compreensão dos assuntos necessários a elaboração do modelo baseado em inteligência artificial para previsão e otimização da produção de biogás.

### 2.1 O PROCESSO DE BIODIGESTÃO ANAERÓBIA

A biodigestão anaeróbia pode ser definida como um processo biológico natural que ocorre na ausência de oxigênio molecular, no qual um consórcio de diferentes tipos de microrganismos interage estreitamente para promover a transformação de compostos orgânicos complexos em produtos mais simples resultando, principalmente, nos gases metano e dióxido de carbono (TOERIEN et al., 1969, apud FORESTI et al., 1999).

A digestão anaeróbia pelo processo de anaerobiose, mostrado na figura 1, obedecendo às seguintes fases (CLASSEN et al. apud COSTA, 2006). Os microrganismos responsáveis pela decomposição anaeróbia são compostos de três grupos de bactérias: fermentativas, acetogênicas e metanogênicas (POLPRASERT, 2007).

Figura 1 - Fases do Processo de Digestão Anaeróbia



Fonte: Retirado de Classen et al. apud Costa (2006)

Na fermentação, os polímeros (estruturas complexas), tais como proteínas, gorduras, carboidratos, entre outros, são quebrados em monômeros (estruturas

simples) por meio de reações de hidrólise na presença de enzimas extracelulares, constituindo-se em componentes simples e solúveis. Nas reações, as proteínas são convertidas em aminoácidos, os carboidratos em açúcares simples e as gorduras em ácidos graxos voláteis. Fatores como tipo de substrato, concentrações bacterianas, temperatura e pH afetam diretamente o ritmo das reações de hidrólise.

Na acetogênese, as bactérias produtoras de hidrogênio transformam os monômeros liberados (aminoácidos, açúcares, ácidos graxos voláteis e álcoois) pela quebra hidrolítica na etapa anterior em acetato, H<sub>2</sub> e CO<sub>2</sub>, essenciais à metanogênese.

Na metanogênese, ocorre efetivamente a produção do metano sendo, portanto, a principal etapa do processo de digestão anaeróbia. O acetato é o responsável por 70% da produção, considerado o precursor primário do produto final. O metano restante vem do H<sub>2</sub> e CO<sub>2</sub>. As bactérias metanogênicas, essencialmente anaeróbias, são divididas em função do substrato utilizado como:

- Acetoclásticas – utilizadoras de acetato;
- Hidrogenotróficas – utilizadoras de hidrogênio.

A eficiência do processo está condicionada às condições propícias ao desempenho das bactérias metanogênicas. Caso contrário, haverá pouca produção de CH<sub>4</sub> e a estabilização do digestor não ocorrerá. Em condições ótimas, os metanogênicos regulam e neutralizam o pH do digestor convertendo os ácidos graxos voláteis em CH<sub>4</sub> e outros gases.

Em processos de biodigestão anaeróbia, procura-se acelerar o processo da digestão, criando-se condições favoráveis para o processo microbiano.

O processo de biodigestão pode ser influenciado por uma série de fatores favorecendo, ou não, sua inicialização, a degradação do substrato, o crescimento e declínio dos microrganismos envolvidos e a produção de biogás. Entre esses fatores, pode-se citar a temperatura, o pH, a presença de inóculo<sup>2</sup>, de nutrientes, a composição do substrato, o teor de sólidos totais e, como consequência destes, a interação entre os microrganismos envolvidos no processo (STEIL, 2001).

A temperatura é um fator importante na digestão anaeróbia, uma vez que influencia na velocidade do metabolismo bacteriano, no equilíbrio iônico e na

---

<sup>2</sup> Inóculo é uma composição de biomassa seletiva já adaptada ao processo, proveniente de digestores anaeróbios em funcionamento contendo bactérias adaptadas ao meio (BACKES, 2011).

solubilidade dos substratos (FORESTI et al., 1999). O efeito da temperatura sobre o processo de digestão anaeróbia tem sido estudado por diversos autores nas faixas psicrófila<sup>3</sup>, abaixo de 20°C (MASSÉ; DROSTE, 2000), mesofílica, entre 20°C e 45°C (CHEN; SHYU, 1998), e termofílica, entre 50°C e 70°C (LEPISTO; RINTALA, 1996).

A disponibilidade de certos nutrientes é essencial para o crescimento e atividade microbiana. Carbono, nitrogênio e fósforo são essenciais para todos os processos biológicos (FORESTI et al., 1999).

A quantidade de nitrogênio e fósforo necessária para a degradação da matéria orgânica presente depende da eficiência dos microrganismos em obter energia para a síntese a partir de reações bioquímicas de oxidação do substrato orgânico (FORESTI et al., 1999).

## 2.2 PRODUÇÃO DE METANO E DO BIOGÁS

Biogás é o nome comum dado a uma mistura de gases que foi produzido pela decomposição biológica da matéria orgânica na ausência de oxigênio. Normalmente consiste em uma mistura gasosa composta principalmente de gás metano (CH<sub>4</sub>) e gás carbônico (CO<sub>2</sub>), com pequenas quantidades de gás sulfídrico (H<sub>2</sub>S) e umidade (MACHADO, 2013).

A produção de biogás ocorre naturalmente em qualquer local submerso em que o oxigênio atmosférico não consiga penetrar, como em pântanos, no fundo de corpos d'água, intestino de animais ou de forma antrópica como em aterros sanitários e usinas de biogás (EDUCALINGO. Biogás [on-line]<sup>4</sup>).

O biogás se caracteriza por ser o produto final da biodigestão anaeróbia, e é composto principalmente de metano e dióxido de carbono com pequenas quantidades de sulfeto de hidrogênio. Pode ser utilizado em diversas aplicações na propriedade rural, tais como em chocadeiras, incubadoras, geradores de energia elétrica, além do consumo doméstico (CAEEB, 1981).

---

<sup>3</sup> Psicrófila é uma faixa de temperatura de 0 °C a 20 °C, em que bactérias são capazes de viver e de se reproduzir. Da mesma forma são a mesofílica e a termofílica, porém com diferentes faixas de temperatura, sendo a mesofílica entre 20 °C e 45°C e a termofílica que fica entre 50 °C e 70 °C.

<sup>4</sup>Disponível em: <<https://educalingo.com/pt/dic-pt/biogas>>. Acesso em: 8 set. 2018.

Ademais, essa mistura de gases pode ser classificada como biocombustível por ser uma fonte de energia renovável, sendo uma forma de obter energia que pode auxiliar o ser humano a se emancipar da dependência dos combustíveis fósseis.

A biomassa é, principal fonte para o biogás, sendo considerada um resíduo sólido encontrado de diversas formas, tais como: restos de alimentos, resíduos de madeira, palha do arroz, bagaço da cana de açúcar, esterco de animais, entre outros. De acordo com Ortiz (2005), biomassa é a matéria orgânica que pode ser utilizada como recurso energético a partir de diferentes processos: biogás por queima, biogás por decomposição e biocombustíveis por extração e transformação.

O biogás foi descoberto por Shirley, em 1667. No entanto, foi só um século mais tarde, em 1788, que Volta reconheceu a presença de metano no gás dos pântanos. Já no século XIX, Ulysse Gayon, aluno de Louis Pasteur, realizou a fermentação anaeróbia de uma mistura de estrume e água, a 35 °C, conseguindo obter 100 litros de gás por m<sup>3</sup> de matéria. Em 1884, Louis Pasteur, ao apresentar à Academia das Ciências os trabalhos do seu aluno, considerou que esta fermentação poderia constituir uma fonte de energia para aquecimento e iluminação devido a presença de metano, o hidrocarboneto de menor cadeia (1 átomo de carbono), principal componente do gás natural e de elevado poder calorífico (CLASSEN et al.,1999).

Atualmente, esse processo vem se difundindo como uma forma de tratamento de resíduos por vários países. A recuperação de energia gerada pelos processos anaeróbios, tiveram grande impulso com a crise do petróleo, onde diversos países buscaram alternativas para a sua substituição. Entretanto, como descreve Nogueira (1986), as soluções para os problemas de desenvolvimento devem ser apropriadas às necessidades, às capacidades e recursos humanos, aos recursos financeiros e à cultura. Assim, o impulso recebido no período de crise não chegou a constituir um sólido movimento de substituição dos recursos não renováveis por outras fontes renováveis.

Durante a digestão anaeróbia, a energia química presente na composição orgânica é largamente conservada, principalmente como metano. Segundo Chernicharo (1997), a composição do biogás é difícil de ser definida, pois depende do material orgânico utilizado e do tipo de tratamento anaeróbio que sofre. Contudo, em linhas gerais, o biogás é uma mistura gasosa composta principalmente por:

- Metano (CH<sub>4</sub>): 50% – 70% do volume de gás produzido;

- Dióxido de carbono (gás carbônico, CO<sub>2</sub>): 25% – 50% do volume de gás produzido;
- Hidrogênio (H<sub>2</sub>): 0% – 1% do volume;
- Gás sulfídrico (H<sub>2</sub>S): 0% – 3% do volume;
- Oxigênio (O<sub>2</sub>): 0% – 2% do volume;
- Amoníaco (NH<sub>3</sub>): 0% – 1% do volume;
- Nitrogênio (N<sub>2</sub>): 0% – 7% do volume.

A produção de metano, na natureza, ocorre normalmente de diversas formas. Entre elas, vale citar:

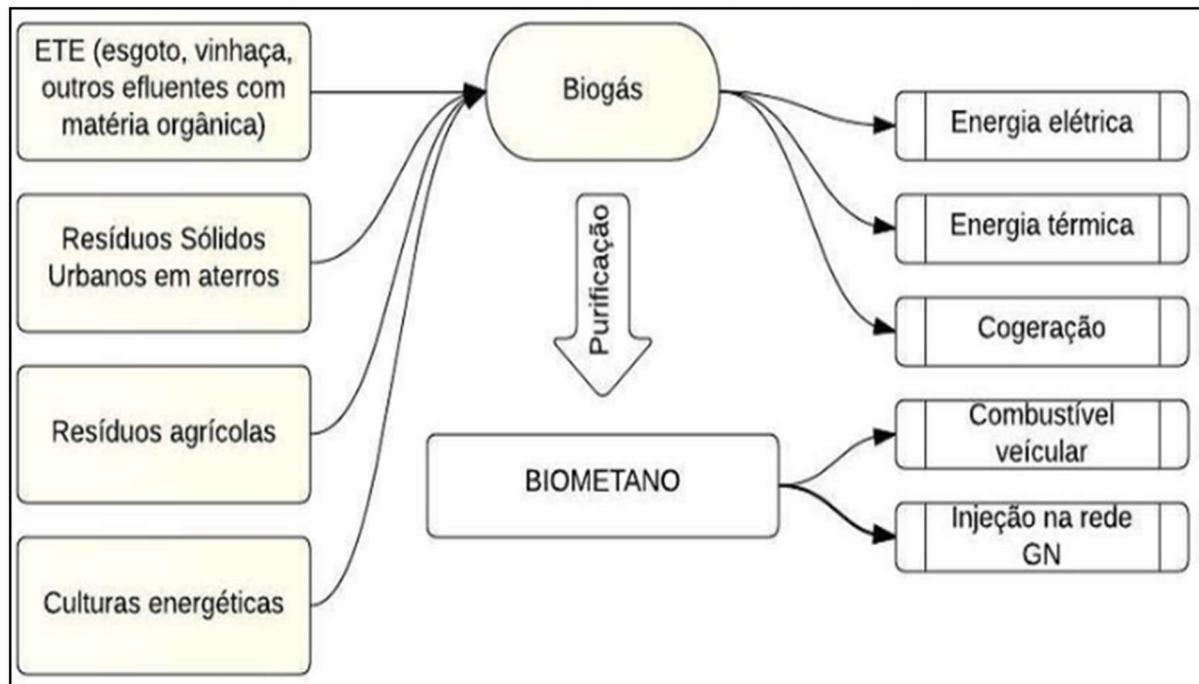
- Decomposição de resíduos sólidos orgânicos ou esgoto na ausência de oxigênio;
- Digestão de animais herbívoros, carnívoros e onívoros;
- Metabolismo de certos tipos de bactérias;
- Vulcões de lama e falhas geológicas;
- Extração de combustíveis minerais em especial o petróleo;
- Aquecimento ou aquecimento de biomassa anaeróbica.

Conforme afirma Zanette (2009), o biogás pode ser usado como gás combustível em substituição ao gás natural ou Gás Liquefeito de Petróleo (GLP), ambos extraídos de fontes de recursos não-renováveis. Também pode ser utilizado na geração de energia elétrica, através de geradores, como energia térmica na produção rural, por exemplo, no aquecimento de instalações para animais sensíveis ao frio ou no aquecimento de estufas de produção vegetal. O biogás também pode ser usado para gerar energia elétrica.

Dentre a diversidade de funções que apresenta, o biogás ainda pode ser purificado para a geração de biometano, que tem se destacado cada vez mais no mercado. Produtoras de automóveis, caminhões e veículos de utilidade pública investem em frotas que podem ser abastecidas em postos de biogás por toda Europa (CANAL..., 2019).

A figura 2 mostra diferentes fontes de produção de biogás com distintas origens, evidenciando que ele pode ser purificado tornando-se biometano com maior poder calorífico. Mostra, ainda, diferentes formas de aproveitá-lo, sendo para geração de energia elétrica ou até mesmo como combustível para queima em diferentes processos.

Figura 2 – Fontes de produção e aplicações para o biogás



Fonte: Veiga e Mercedes (2015)

A purificação pode ser feita com uso de água ou com uso de produtos químicos, uma vez que a tecnologia varia de acordo com as condições da planta da usina e com a quantidade de biogás disponível. Qualquer que seja a tecnologia aplicada para a purificação, o rendimento e a eficiência do processo pode chegar a 99%. O biometano tem o mesmo poder calorífico da gasolina, 1 m<sup>3</sup> de biometano equivale a 1 l de gasolina (WALSH et. al., 1988).

### 2.3 AVALIAÇÃO DO DESEMPENHO EM PROCESSOS DE BIODIGESTÃO

Diversas são as técnicas e ferramentas utilizadas para avaliação do desempenho em sistemas de biodigestão anaeróbia. Algumas dessas técnicas trazem resultados consistentes, contudo normalmente precisam de um tempo longo para trazer respostas. Atualmente, uma das técnicas mais utilizadas é baseada na norma VDI 4630 (2006). Para a avaliação da eficiência em processos de biodigestão, são necessários experimentos que seguem essa normativa alemã que estabelece condições para a realização de ensaios de potencial de produção de biogás e metano.

Conforme citado no tópico introdutório sobre a situação problema, Karlson, et. al. (2014) falam sobre a necessidade da realização de experimentos com propósito de avaliar o potencial de produção do biogás baseado no volume produzido ao longo

do experimento. Isto pode, então, balizar ou não a instalação de um reator em larga escala.

Outra forma de avaliação é através da Atividade Metanogênica Específica (AME), que pode ser definida como a capacidade máxima de produção de metano por um consórcio de microrganismos anaeróbios, realizada em condições controladas de laboratório para viabilizar a atividade bioquímica máxima de conversão de substratos orgânicos a biogás (AQUINO et. al., 2007).

A AME pode ser utilizada como um parâmetro de monitoramento da "eficiência" da população metanogênica presente em um reator biológico e, como tal, constitui-se ainda em uma importante ferramenta para o controle operacional de reatores anaeróbios (AQUINO et al., 2007).

O Planejamento Composto Central Rotacional (PCCR), segundo Mattietto et. al. (2002 apud BOX, 1978, p. 145), se trata de uma ferramenta matemática baseada em estatística que é utilizada para otimização de experimentos na área da química e da biologia e traz uma importante evolução quanto à otimização. Esse método foi desenvolvido para otimizar a realização de experimentos, trazendo resultados com um menor número de testes, já que faz uso de estimação baseado em estatística de resultados já obtidos.

Atualmente, a busca por outras técnicas para avaliação do desempenho de sistemas de biodigestão que tragam resultados mais rápidos ou precisos está fazendo uso de ferramentas matemáticas baseadas em inteligência artificial. Essas ferramentas têm como premissa prever resultados e até mesmo melhorá-los, baseados em dados históricos ou ainda no comportamento desses sistemas e de suas saídas ou respostas.

Sobre o uso de inteligência artificial, Palaniswamy (2016) fala que ferramentas como RNA's e outras técnicas como lógica *fuzzy* ou algoritmos genéticos, tem se mostrado promissores como ferramentas de otimização.

A tabela 1 mostra alguns dos métodos utilizados para determinação do potencial de produção de biogás, passando pelos métodos tradicionais que envolvem a realização de experimentos e procedimentos em laboratório, até os métodos baseados em inteligência artificial que hoje tem sido estudados.

Tabela 1 - Alguns dos métodos utilizados para avaliação da produção de biogás

Técnica ou método	Descrição
Norma VDI4630	Norma da Associação de engenharia da Alemanha, que estabelece um método de avaliação para caracterizar o substrato, formas de amostragens, coleta de dados, testes de biodigestão e avaliação de desempenho através de ensaios realizados em laboratório, através de reatores do tipo batelada.
AME	Definida como a capacidade máxima de produção de metano por um consórcio de microrganismos anaeróbios, realizada em condições controladas de laboratório, para viabilizar a atividade bioquímica máxima de conversão de substratos orgânicos a biogás.
Planejamento Composto Central Rotacional (PCCR)	O PCCR é capaz de estudar o efeito dos fatores e suas interações na variável resposta (produção de biogás), com menor número de experimentos, e possibilita a construção de uma superfície de resposta para otimização das condições testadas.
Técnicas baseadas em inteligência artificial	Utilização de lógica nebulosa (Fuzzy), redes neurais artificiais ou algoritmos genéticos, são algumas das ferramentas atualmente utilizadas para otimização e predição de resultados em sistemas químicos e biológicos

Fonte: Elaborado pelo autor (2018)

## 2.4 A INTERFERÊNCIA DA MATÉRIA ORGÂNICA E DO SUBSTRATO NO VOLUME DE BIOGÁS E METANO PRODUZIDO

A escolha da matéria orgânica e o tipo de substrato afetam a estabilidade e, conseqüentemente, a eficiência do sistema de biodigestão.

A composição do substrato pode causar impactos no volume e na qualidade do biogás devido a quantidade de nutrientes presentes na mistura, bem como possíveis contaminantes como metais, patógenos, contaminantes orgânicos contidos na matéria orgânica. A escolha do material certo influencia na maximização da produção de energia e na qualidade de biogás (KARLSSON et al., 2014).

Karlsson et al. (2014) afirma que diversos materiais orgânicos podem ser decompostos em um biodigestor e que existem alguns materiais que têm mais

potencial do que outros. Isso se dá devido a fatores que devem ser levados em consideração, como a quantidade de substrato, a temperatura do processo de biodigestão, o tempo de retenção, entre outros, influenciando no pré-tratamento ao qual o material foi submetido na geração de biogás (KARLSSON et al., 2014).

A geração de biogás é resultante da decomposição biológica da matéria orgânica. Se nenhum novo material é adicionado, o processo irá cessar. A carga é um termo que indica a quantidade de material novo agregado no processo por unidade de tempo, normalmente chamado de carga orgânica.

É importante saber o teor de Sólidos Totais (ST) e de Sólidos Voláteis (SV) contidos no substrato, a fim de fornecer a carga orgânica ideal para o processo de biogás. ST's é o material que resta quando ocorre a evaporação da água do substrato, e SV's especifica a parte orgânica da matéria seca (KARLSSON et al., 2014).

Karlsson et al. (2014) fala que na produção de biogás, um fator que deve ser levado em consideração é a relação carbono/nitrogênio (C/N) onde se recomenda que essa relação não esteja baixa e que a proporção de nitrogênio seja inferior à de carbono. Ele ainda fala que a presença de substâncias tóxicas e lignina<sup>5</sup>, por sua vez, não são metabolizadas em um processo de digestão anaeróbia, e também são limitantes na produção de biogás.

Ainda conforme Karlsson et al. (2014) a composição do substrato é importante para os microrganismos do processo e, portanto, também para a estabilidade do processo de biodigestão e para a produção de biogás. O substrato deve atender às necessidades nutricionais dos microrganismos, ou seja, contém energia e componentes necessários para que possam se reproduzir. O processo pode ser afetado, ainda, em razão da inibição das bactérias causada pela liberação de amônia, causando deficiência de nitrogênio no processo (KARLSSON et al., 2014).

A proporção ideal de carbono e nitrogênio dependerá de cada tipo de substrato ou de sua combinação, bem como das condições do processo de biodigestão impostas pelo controle feito sobre a planta ao longo do processo de decomposição da matéria orgânica (KARLSSON et al., 2014).

---

<sup>5</sup> Polímero aromático e tridimensional de elevado peso molecular, normalmente considerado indigestível e também inibidor da digestibilidade (TRUGILHO et al., 1996; FUKUSHIMA et al., 2000).

## 2.5 VARIÁVEIS QUE INTERFEREM NA PRODUÇÃO DE BIOGÁS

Além da matéria orgânica utilizada para alimentar um biodigestor e a composição do substrato contida em seu interior, outras variáveis do processo tem influência no processo de biodigestão e conseqüentemente no volume de biogás e metano produzidos. Pinto (1999) afirma que muitos fatores podem alterar a produtividade e composição do biogás, tais como: pH, faixa de temperatura de operação, adaptação do microrganismo e agitação. Dentro do biodigestor, a matéria orgânica é processada por bactérias. São elas as responsáveis pela produção do biogás e o biofertilizante de qualidade. Contudo, para que isto ocorra de forma adequada, deve-se criar um ambiente propício para as bactérias em termos de temperatura, alimentos disponíveis, pH e alguns outros parâmetros que precisam ser controlados para um melhor resultado.

A temperatura é uma das variáveis que influenciam no processo de biodigestão. Dentre os diversos parâmetros que afetam a biodegradação anaeróbia, esta tem papel importante no resultado do processo. Esse parâmetro atua diretamente sobre a atividade das enzimas e coenzimas e interfere na produção de metano e na qualidade do digestado (EL-MASHAD et al., 2003).

As bactérias podem ser divididas em três grupos: psicofílicas (0 a 20°C); mesofílica (20 a 42°C) e termofílicas (42 a 75 °C). No campo de atuação das mesófilas, a velocidade de decomposição cai pela metade a cada diminuição de 10°C quando abaixo dos 35°C (RAJESHWARI et al., 2000). A digestão anaeróbia convencional é realizada na faixa de temperatura mesofílica, entre 35 e 37°C (KIM et al., 2006). Apesar disso, a performance do processo aumenta com a elevação da temperatura, operando em faixa termofílica (SÁNCHEZ et al., 2001; VINDIS et al., 2009).

Outra variável a ser considerada e que precisa de atenção é o potencial hidrogênico ou pH. Karlsson et al. (2014) citam que a atividade das bactérias metanogênicas, produtoras de biogás, tem um rendimento ótimo na faixa de pH entre 6,6 e 7,4. O autor observa ainda que valores abaixo de 6,0 ou acima de 8,0 diminuem consideravelmente a produção do biogás, podendo inibir por completo a produção do mesmo. Pode-se observar, em alguns casos, que mesmo com o pH ácido ou básico há produção de biogás pelo biodigestor, mas não há produção de metano, que possui poder de queima. Observa-se, nestes casos, uma grande concentração de gás carbônico e pouco metano.

Conforme citado anteriormente, entre os parâmetros que afetam a digestão anaeróbia, o pH está entre os principais. Em estudo realizado por Kerroum et al. (2014), reatores anaeróbios de tratamento de resíduo líquido de laticínio, em temperatura de 55°C e sob quatro condições de pH, resultaram em taxas consideravelmente, maiores de produção de metano e de taxa de decomposição da matéria orgânica com pH igual a 7,0. Lay et al. (1997) obtiveram valores ótimos de crescimento dos organismos metanogênicos sob pH igual a 6,8. Estercos de animais nos digestores (principalmente uma mistura de esterco de vacas e suínos) possuem alta capacidade tampão<sup>6</sup> e um teor elevado de amônia, o que torna o pH estável em torno de 7,5-8,0 (PIND et al., 2003).

Ainda sobre variáveis que influenciam no processo de biodigestão e produção de biogás, deve se considerar a relação carbono/nitrogênio da matéria orgânica. A relação mássica carbono/nitrogênio está associada à eficiência do processo de biodegradação anaeróbia. “Uma ótima relação C/N é necessária para propiciar o balanço apropriado de nutrientes requerido pelas bactérias, bem como a manutenção de um ambiente estável. Geralmente, a relação C/N na faixa de 20 a 30 é considerada ótima para o processo de biodigestão anaeróbia” (LI et al., 2011, apud MATOS 2017, p. 15).

Wang et al. (2012 apud MATOS, 2017) realizaram a codigestão anaeróbia de três tipos de material orgânico (resíduo de laticínio, esterco de galinha e palha de trigo), encontrando a máxima produção de metano com relação C/N igual a 27,2, com pH estável e baixa concentração de nitrogênio amoniacal. Resultado similar foi encontrado por Zeshan e Visvanathan (2012), que realizaram codigestão de diferentes tipos de resíduos vegetais e papel, encontrando o resultado de maior produção de biogás e 30% menos amônia nos digestores com relação C/N igual a 27,2, em comparação aos digestores com relação C/N igual a 32.

A relação C/N imprópria pode resultar no aumento da concentração de nitrogênio amoniacal e/ou acumulação de ácidos graxos voláteis no reator. Ambos são importantes produtos intermediários, contudo são potenciais inibidores do processo devido ao fato da alta concentração desses dois elementos no reator conduzir ao decaimento da atividade metanogênica (PARKIN; OWEN, 1986).

---

<sup>6</sup> Solução tampão é uma solução aquosa capaz de resistir a mudanças de pH quando ácidos ou bases são adicionados. Sistemas tampões são extremamente importantes em fluidos biológicos (MARCONATO et al., 2004).

Os nutrientes presentes na matéria orgânica também precisam ser avaliados, já que podem interferir no processo de degradação. O processo de fermentação é realizado por microrganismos. Várias bactérias transformam as substâncias contidas no substrato de fermentação em seu metabolismo. Os microrganismos possuem exigências individuais e necessitam de diferentes nutrientes (BRAUN, 1982). Estes podem ser discriminados em macro e micronutrientes. Os micronutrientes incluem elementos como o boro (B), ferro (Fe), cobalto (Co), cobre (Cu), níquel (Ni), manganês (Mn), molibdênio (Mo) e selênio (Se).

“O rendimento de metano é variável a partir do substrato utilizado e dependente das proporções de proteínas, gorduras e carboidratos, que são os macronutrientes. Estes representam a maior parte da biomassa degradável” (BISCHOFBERGER et al., 2005 apud BACKES, 2011, p. 40).

Em termos de desempenho na produção, parâmetros como ST's e SV's são frequentemente relacionados.

O tipo de substrato e composições determinam diretamente a produção de biogás. A entrada anaeróbia de substrato é frequentemente medida em termos de DQO, que é uma medida da concentração de material orgânico no efluente ou sólidos voláteis. (BATSTONE et al., 2002b, apud BACKES, 2011, p. 40).

“Os esterco, que contém alta quantidade de água e frações recalcitrantes, têm menor rendimento em metano por sólidos voláteis ou DQO do que substratos facilmente degradáveis, como outros resíduos orgânicos” (MÖLLER et al., 2004, apud BACKES, 2011, p. 39). “Quanto maior a concentração de sólidos voláteis na alimentação diária do biodigestor, maior será a produção de biogás e, conseqüentemente, a produção de energia” (LIMA, 2007, apud MATOS, 2017, p. 17).

Logo, a qualidade e o volume de biogás produzido estão diretamente ligados à quantidade de matéria orgânica existente no dejetos e sua tipologia, sendo por isto importante o conhecimento da quantidade de sólidos totais voláteis existentes no substrato a ser utilizado (MATOS, 2017).

A agitação também possui papel importante no processo de biodigestão. Dentro do biodigestor ocorrem dois processos que justificam a agitação. O primeiro, é que as bactérias formam colônias isoladas, ou seja, como a concentração de matéria orgânica não é uniforme, as bactérias se reúnem e se multiplicam onde existem mais alimentos. O segundo, é que o biogás produzido pelas bactérias fica preso ao seu

redor, e quando há biogás em sua volta, inibe-se a produção de biogás. A agitação, quando realizada adequadamente, faz com que o biogás que está preso ao redor das bactérias seja liberado, permitindo a formação de novas colônias de bactérias e colocando-as novamente em contato com toda a matéria orgânica.

Na tabela 2, alguns dos principais parâmetros normalmente utilizados para avaliação dos sistemas de biodigestão e que causam interferência na performance de produção ou nas características do biogás são mostrados.

Tabela 2 – Principais parâmetros citados e utilizados para monitoramento do processo de biodigestão

<b>Parâmetros</b>	<b>Descrição</b>
Temperatura	Temperatura do substrato durante o processo de biodigestão
Pressão	Pressão interna do biodigestor na fase de degradação da matéria orgânica
pH	Escala que mede a acidez ou basicidade da matéria orgânica ou do inóculo
Alcalinidade	Capacidade de neutralização de ácidos em um meio aquoso
CH <sub>4</sub>	Percentual de gás metano presente no biogás
Biogás	Volume de biogás produzido
ST	Sólidos totais contidos da matéria orgânica
SV	Percentual de Sólidos Voláteis presente na matéria orgânica
SF	Sólidos Fixos presentes na matéria orgânica
C:N	Relação Carbono Nitrogênio da matéria orgânica
DBO	Demanda biológica de oxigênio é a quantidade de oxigênio necessária para oxidar a matéria orgânica biodegradável.
DQO	Demanda química de Oxigênio mede a quantidade de matéria orgânica suscetível a ser oxidada por meios químicos
TRH	Tempo de retenção hidráulica, é o tempo que o substrato fica dentro do biodigestor até ser substituído ou resposto

Fonte: Elaborado pelo autor (2018)

## 2.6 A UTILIZAÇÃO DO BIOGÁS

Biogás é um combustível de alta qualidade, pois com teor de metano ao redor de 60%, possui um valor calorífico de cerca de 6 kWh/m<sup>3</sup> (GUBLER, 2006; ROBRA,

2006). O biogás pode ser usado de algumas maneiras e com alta eficiência, principalmente para geração de energia, no cozimento, no aquecimento de água, secagem e arrefecimento (GUBLER, 2006).

Atualmente, o biogás é utilizado em termoelétricas e como biocombustível, mas a sua facilidade de queima pode fornecer calor, sendo que esta energia térmica pode ser convertida em energia elétrica por alguns sistemas de conversão mecânica, como caldeiras e geradores (TOLMASQUIM, 2003).

A produção combinada de calor e energia é entendida como a produção simultânea de eletricidade (energia) e de calor. Para isso, é quase sempre usado um sistema de cogeração com motores de combustão interna, que são acoplados a um gerador. Os motores funcionam a uma velocidade constante de modo que o gerador acoplado possa fornecer energia elétrica compatível com a frequência (FNR, 2005).

O uso do calor gerado em uma central de cogeração pode ser um fator decisivo para a eficiência das usinas de biogás. Em uma produção combinada de calor e energia, o excesso de calor pode ser aproveitado no verão. Com este tipo de uso, é obtida a refrigeração a partir do calor pelo processo de absorção (GUBLER, 2006).

Há também a possibilidade de aproveitamento térmico do biogás, alimentação na rede de fornecimento de gás natural e a produção de combustível para veículos ou *Biomass to Liquid* (BTL). A alimentação em um sistema de redes de gás natural abre novas perspectivas para o futuro. Para isso, seria necessário purificar o biogás à gás natural, (ou seja, retirar todo ácido sulfídrico, dióxido de carbono e vapor de água) assim como um aumento na pressão do biogás a ser injetado. Na Suíça, Holanda e Suécia já existem estes sistemas. Na Suíça e na Suécia, o biogás é utilizado há algum tempo como combustível para ônibus e caminhões (FNR, 2005; EDER; SCHULZ, 2007).

Fazendo-se se uma equivalência em termos de produção de biogás com outros tipos de combustíveis, para 1 m<sup>3</sup> de biogás produzido tem-se aproximadamente: 0,613 l de gasolina; 0,579 l de querosene; 0,553 l de óleo diesel; 0,454 l de GLP; 1,536 kg de lenha; 0,790 l de álcool hidratado; 1,428 kW de eletricidade (OLIVER et al., 2008). Essa quantidade de gás corresponde a ¼ de um botijão de gás de 13 kg, e pode ser obtida com a produção de esterco de 20 a 24 bovinos (DEGANUTTI et al., 2002).

Segundo Deganutti et al. (2002), para uma família de 5 (cinco) pessoas em termos de uso caseiro diário tem-se:

- Para cozinha ..... 2,10 m<sup>3</sup>;
- Para iluminação ..... 0,63 m<sup>3</sup>;
- Para geladeira..... 2,20 m<sup>3</sup>;
- Para banho quente ..... 4,00 m<sup>3</sup>;
- Total de biogás necessário por dia ..... 8,93 m<sup>3</sup>.

## 2.7 APLICAÇÃO DO BIOGÁS PARA GERAÇÃO DE ENERGIA ELÉTRICA

O uso da energia de biogás é uma das melhores opções para gestão de resíduos no país, embora não solucione todos os problemas existentes (COSTA, 2006 apud DOS SANTOS, 2009).

Em se tratando do setor de saneamento, Salomon e Lora (2005) citam alguns benefícios relacionados à produção de energia elétrica a partir de biogás, tais como:

- Descentralização de geração de energia;
- Proximidade com o mercado consumidor;
- Destinação nobre à biomassa potencialmente energética tratada como resíduo;
- Redução do custo com energia elétrica;
- Redução das emissões de metano à atmosfera mitigando o efeito estufa;
- Possibilidade de obtenção de créditos de carbono.

No caso do esgotamento sanitário, o projeto desenvolvido na ETE de Barueri, concebido para gerar 2 a 2,8 MW, serve como exemplo do potencial dos esgotos na geração de energia elétrica. Com investimentos da Companhia de Saneamento Básico do Estado de São Paulo (SABESP), em parceria com outros órgãos de fomento, foi possível demonstrar a viabilidade econômica e os ganhos ambientais do projeto (COSTA, 2006 apud DOS SANTOS, 2009).

Outros exemplos citados por Costa, (2006 apud DOS SANTOS, 2009) são os aterros Bandeirantes, em São Paulo, destacando-se mundialmente pela capacidade de gerar energia elétrica durante 10 anos para abastecer uma população de 400 mil habitantes. Nova Iguaçu, no Rio de Janeiro, é pioneira em vendas de créditos de carbono à Holanda, correspondendo a 5 milhões de euros. Segundo o Cenbio<sup>7</sup> (2001), países como a Alemanha, Itália, Inglaterra e Espanha incentivam a geração de energia

<sup>7</sup> Cenbio - centro nacional de referência em biomassa. Disponível em: <http://143.107.4.241/download/atlasbiomassa2012.pdf>. Acesso em: 24 set, 2018.

elétrica a partir do biogás por meio de políticas favoráveis ao desenvolvimento sustentável.

## 2.8 TECNOLOGIAS DE CONVERSÃO

Das tecnologias disponíveis para geração de energia elétrica que utilizam o biogás, destacam-se as turbinas a gás e os grupos de geradores de combustão interna. Ambas têm o papel de transformar a energia química do gás em energia mecânica que impulsionará um alternador para conversão em energia elétrica (COSTA, 2001 apud DOS SANTOS 2009).

As turbinas a gás (Ciclo Brayton) funcionam sob alta pressão injetando ar comprimido em uma câmara de combustão e provendo o sistema do oxigênio necessário para a queima. O gás resultante pressiona um compressor e um gerador. O processo será tão mais eficiente quanto maior for a temperatura e pressão de entrada e menor for a temperatura de exaustão (DOS SANTOS, 2009).

As turbinas a gás são classificadas em relação à potência em:

- a) Microturbinas – até 100 kW;
- b) Turbinas de médio e grande porte – de 100 kW até 300 MW;
- c) Turbinas a vapor – utilizam um sistema de cogeração para conversão de energia térmica em energia mecânica.

Já os grupos de geradores de combustão interna (Ciclos Diesel e Otto) geram a energia elétrica pela conexão de um gerador ao motor.

Os equipamentos disponíveis no mercado para geração de energia elétrica utilizando biogás inicialmente foram fabricados visando o aproveitamento dos dejetos de animais. Para aplicação em esgotos, será necessário verificar o teor de metano da matéria orgânica e, a partir de então, selecionar a potência adequada a fim de obter a melhor eficiência do gerador (FOCKINK, 2009 apud DOS SANTOS, 2009).

## 2.9 ESTADO DA ARTE

Com a demanda por energia elétrica cada vez maior, uma maior preocupação com a eficiência de biodigestores é tema recorrente em diversos trabalhos e pesquisas realizadas por diversos autores.

Diferentes abordagens e ferramentas já foram utilizadas ao longo dos anos, e algumas técnicas e aplicações baseadas em inteligência artificial tem se mostrado eficazes como modelo de previsão e otimização de sistemas biológicos para a produção de biogás. Alguns dos trabalhos com foco em previsão e otimização destes sistemas serão apresentados, bem como expostas suas principais características e resultados obtidos.

O trabalho de Waewsak et al. (2010) propôs um sistema baseado em rede neural e lógica *fuzzy*, que foi denominado pelos autores de *neural-fuzzy* para controle e monitoramento do processo de biodigestão anaeróbia de um reator híbrido para o tratamento de águas residuais e produção de biogás. A proposta previa a utilização, de forma simultânea, de uma rede neural artificial e de lógica *fuzzy* com intenção de prever e controlar o comportamento do reator e com isso aumentar a eficiência do tratamento de efluentes e, conseqüentemente, a produção de biogás. A rede neural era responsável pela previsão de pH, alcalinidade (Alk) e dos Ácidos Voláteis Totais (TVA) presentes nas amostras, que eram coletadas todos os dias durante o período de biodigestão. A lógica *fuzzy* era encarregada de prever e calcular a taxa de alimentação diária do reator, evitando que o mesmo recebesse pouco ou excesso de matéria orgânica para digestão.

Os testes foram realizados para três diferentes comportamentos de alimentação, sendo a primeira etapa a fase de inicialização, a segunda etapa a fase de sobrecarga e a terceira a fase de recuperação. A rede neural usou as variáveis PH, Alk e TVA como entrada em uma configuração de quatro camadas no modelo *feedforward*, onde 1 das camadas era a de entrada, 2 eram camadas ocultas e a última era a camada de saída, baseado no algoritmo *backpropagation* de previsão das variáveis de entrada.

Os autores concluíram que, mesmo na etapa 2 de alimentação em sobrecarga, o sistema conseguiu ter controle sobre as variáveis de entrada somente controlando a taxa de alimentação de matéria orgânica, tendo como resultado final uma média de remoção de 80% da matéria orgânica ou Demanda Química de Oxigênio (DQO) e uma taxa de produção de biogás e Metano elevada, com estabilidade no comportamento do sistema.

Restritos apenas a prever diferentes traços de componentes que fazem parte do biogás, Strik et al. (2004) propuseram um algoritmo de previsão dos diferentes componentes presentes no biogás utilizando a aplicação do MATLAB *Neural Network*

*Toolbox*. A proposta tinha como principal premissa a utilização do biogás em células de combustível, onde o seu desempenho está diretamente relacionado com o traço dos componentes presentes no Biogás. Alguns destes componentes, como amônia e sulfeto de hidrogênio, causam o envenenamento das células, deixando-as com baixa eficiência. A possibilidade de previsão destes componentes poderia evitar esse envenenamento, fazendo com que o sistema produzisse mais energia. Para o desenvolvimento os autores montaram, em laboratório, dois reatores iguais, onde coletavam amostras do biogás produzido e o analisavam buscando traços dos componentes que poderiam prejudicar as células de combustível.

Para a coleta de dados referentes aos componentes de interesse no estudo, a alimentação dos reatores foi controlada forçando a produção destes componentes e permitindo a coleta de dados sobre suas respectivas presenças nas amostragens realizadas ao longo do período de digestão. Com os dados em mãos, os mesmos foram dispostos em tabelas que serviram de base de entrada para o treinamento e validação do algoritmo da rede neural.

Ao final, o resultado obtido permitia que ao controlar a carga máxima de matéria orgânica e de nitrogênio presente na alimentação do biodigestor fosse possível prever, diminuir e até mesmo evitar com que amônia ou sulfeto de hidrogênio estivessem presentes no biogás, validando o modelo proposto e tornando-o viável como forma de aumentar a eficiência de células de combustível a biogás.

Nos estudos de Ozkaya et al. (2006), os autores propuseram um algoritmo de previsão do percentual de Metano presente no biogás em uma usina de biogás de aterro sanitário. Os autores monitoraram, ao longo de 34 meses, parâmetros do chorume e do Biogás de aterro para utilizar estes dados no aprendizado do algoritmo da rede neural desenvolvida no MATLAB.

A rede neural implementada levou em consideração o modelo de *Levenberg-Marquardt*, com três camadas e função de transferência sigmoïdal, sendo a primeira camada com as 8 variáveis de entrada, a segunda camada oculta com 12 neurônios e a última camada a de saída, onde obtinha-se o percentual de Metano presente no Biogás de aterro. A proposta ainda contemplava a comparação de dois diferentes sistemas de degradação de matéria orgânica, onde o primeiro era um circuito aberto onde o chorume produzido era descartado e o segundo onde o chorume era recirculado a um certo percentual como forma de estabelecer um comparativo no desempenho dos dois sistemas.

Em Qdais et al. (2009), os autores propuseram um modelo híbrido utilizando RNA e algoritmo genético para simulação e previsão da produção de biogás em um biodigestor na Jordânia. O modelo proposto utilizava uma rede neural de múltiplas camadas, sendo duas delas ocultas, onde a camada de entrada era alimentada com parâmetros da matéria orgânica que era inserida no processo de biodigestão como pH, temperatura, ST's e SV's.

Os dados foram coletados ao longo de 177 dias operacionais do sistema e utilizados para o treinamento e para validação do modelo de previsão. Outros dados coletados ao longo de 50 dias foram utilizados. Com o modelo de previsão tendo uma eficácia com um coeficiente de correlação de 0,87, um algoritmo genético foi utilizado para otimizar a produção de Metano da planta. Ao final, resultados promissores foram encontrados quando determinados parâmetros eram mantidos sob controle, como pH de 6,4, temperatura de 36 °C, teor de ST's na casa de 6,6% e teor de SV's de 52,8%, onde foi possível um incremento no percentual de metano se comparado aos dados históricos coletados. A produção de biogás teve um incremento, bem como o Metano, que passou de 71% para 77% da composição do biogás, elevando o potencial energético do biogás produzido.

Sabendo a importância de ter controle sobre a matéria orgânica inserida em um sistema de biodigestão e o impacto causado no volume de biogás produzido quando a correta combinação de variáveis de entrada é utilizada, Gueguim et al. (2012) propuseram que era possível potencializar a produção de biogás em um sistema desde que a correta combinação de diferentes matérias orgânicas fossem inseridas no mesmo.

Para isso, 25 reatores foram ensaiados em laboratório sob as mesmas condições de processo, temperatura, taxa de alimentação e agitação, tendo somente sua alimentação com diferentes combinações percentuais dos resíduos de origem orgânica pré-selecionados. Usando uma rede na topologia 5-2-1 de camadas e adotando uma função de transferência sigmoide, a taxa de produção de saída computada de biogás foi monitorada.

Para o treinamento da rede foram usados 20 dos reatores e para validação os 5 restantes. Ainda sob o treinamento, os autores utilizaram o método *backpropagation*, onde citam uma diminuição significativa do erro quadrado médio da saída, minimizando erros. Para otimização da produção utilizaram um algoritmo genético, onde após a otimização a melhora da performance foi significativa, antecipando o

início da produção de biogás de 8 para 3 dias após o início do experimento, conseguindo manter o pH dentro de uma faixa considerada ótima, na ordem de 6,5, e por fim obteve ainda um acréscimo no volume de biogás produzido se comparado aos resultados obtidos pela rede neural somente.

Com uma grande preocupação sobre o impacto causado por restos de comida depositados no meio ambiente de forma incorreta e sabendo de seu potencial como matéria orgânica para produção de biogás, Palaniswamy et al. (2016) propuseram um algoritmo de previsão utilizando RNA's no modelo *backpropagation*. Para o modelo proposto, utilizaram restos de comida oriundos de um restaurante universitário misturado com esterco de vaca em diferentes proporções.

Os ensaios foram realizados em 21 reatores em escala laboratorial, onde todos foram mantidos sob as mesmas condições. A rede foi configurada em 3 camadas, onde os dados de entrada inseridos na rede foram o da proporção percentual entre resto de comida e esterco de vaca da mistura, o tempo de produção de biogás do reator, a temperatura do reator e o pH do substrato.

Diferentes quantidades de 3 a 31 neurônios na camada oculta foram testados, até que o menor erro de saída fosse encontrado, quando a quantidade de neurônios nesta camada era de 17. Os autores obtiveram uma variação de  $\pm 4\%$  no valor estimado de biogás para 98,97% das amostras testadas, evidenciando a eficácia da RNA desenvolvida. Ao final, obtiveram a melhor combinação no reator de número 17, obtendo 375 ml/g de sólidos voláteis com 25 dias de digestão na proporção de 80% de restos de comida com 20% de esterco de vaca.

Souwalak et al. (2014), assim como alguns dos autores até aqui citados, buscou inferir a potencial produção de biogás bem como a fração de metano presente neste biogás, com uma topologia de 3 camadas do tipo *MLP*. As variáveis de entrada eram a proporção da mistura de alimentação de chorume com bagaço de abacaxi, teor de sólidos, pH e a Demanda Química de Oxigênio (DQO). Os autores obtiveram resultados de índice de correlação  $R$  de 0.9944 em treinamento, 0.9942 em validação, 0.9800 em teste e de 0.9924 como resultado geral, evidenciando a capacidade de prever de forma estimada os volumes de biogás e Metano produzidos pelo sistema de biodigestão. A tabela 3 apresenta um resumo de trabalhos com diferentes abordagens e técnicas de inteligência artificial, os quais buscam prever o volume de biogás produzido ou otimizar o processo de biodigestão utilizando principalmente RNA.

Tabela 3 – Modelos de previsão e otimização propostos por diversos autores

Autor	Proposta	Ferramenta utilizada	Parâmetros e variáveis monitoradas
Waewsak et al. (2010)	Controle e monitoramento de variáveis para avaliação do impacto causado na produção de biogás, por diferentes condições do processo de biodigestão em tratamento de efluentes	Rede neural e lógica Fuzzy	pH, Alcalinidade, ácidos voláteis totais, DQO e volume de Biogás
Ozkaya et al. (2006)	Predição do percentual de metano presente no Biogás produzido a partir de reatores de aterro sanitário	Rede Neural artificial	pH, Alcalinidade, DQO, Sulfatos, Cloro, condutividade e percentual de Metano
Srik et al. (2004)	Prever a composição de gases presentes no biogás produzido	Rede Neural artificial	Ácido sulfídrico, Sulfatos, DQO, sulfetos, Nitrogênio, Amônia, Amônio, volume de biogás
Qdais et al. (2009)	Modelar e otimizar a produção de biogás.	Rede Neural artificial e Algoritmo Genético	Sólidos Totais, Sólidos Voláteis, pH, temperatura e volume de biogás produzido
Gueguim et al. (2012)	Modelagem e otimização da produção de biogás utilizando serragem e outros resíduos	RNA e Algoritmo Genético	Diferentes combinações em proporções percentuais diferentes de cada uma das matérias orgânicas testadas e volume de biogás produzido.
Palaniswamy et al. (2016)	Otimização da produção de biogás usando restos de comida, com utilização de redes neurais artificiais	Rede Neural Artificial	Diferentes combinações de resto de comida, temperatura, pH e tempo de retenção hidráulica (TRH)
Souwalak et al. (2014)	Modelagem de RNA para predição do volume de biogás e metano produzidos com chorume e resíduos de frutas	Rede Neural Artificial	pH, Sólidos Voláteis, Sólidos Totais, proporção dos resíduos, DBO, volume de biogás e volume de metano.

Fonte: Elaborado pelo autor (2019)

No caso de Palaniswamy et al. (2016), a RNA foi capaz de prever o volume de gás produzido pelas amostras usadas no processo de validação, com uma média de 0,036% de erro de saída médio quadrático. Ainda foi possível verificar que uma faixa

de pH entre 6 e 8 trazia melhores resultados de performance e também que temperaturas mais elevadas, dentro de uma faixa de 35 °C a 45 °C, melhoravam a produção de diferentes reatores.

Para chegar ao modelo de RNA ideal, Palaniswamy et al. (2016) realizaram o processo de treinamento por várias vezes, mas com diferentes configurações de camadas ocultas e quantidade de neurônios nestas camadas, podendo selecionar a combinação que melhor precisão tinha nas respostas de sua saída. A configuração que melhores respostas apresentou ao final foi uma RNA do tipo *multilayer perceptron* 4-17-1, correspondente as entradas, neurônios da camada oculta e saída, respectivamente, com algoritmo de aprendizagem *resilient backpropagation*.

Gueguim et al. (2012) passaram pelo processo de testes de diferentes topologias de RNA para encontrar a que melhores resultados trazia, quando comparado aos resultados de laboratório. Chegaram, ao final, a uma topologia de RNA de 5 neurônios para entrada de parâmetros, 2 neurônios na camada oculta e 1 neurônio de saída.

Em cada um dos trabalhos abordados, diferentes parâmetros foram monitorados. Cada parâmetro, dependendo da proposta, tinha um determinado grau de importância para o estudo realizado.

## 2.10 REDES NEURAIS ARTIFICIAIS E SUA APLICAÇÃO COMO MÉTODO DE PREVISÃO E OTIMIZAÇÃO EM SISTEMAS DE BIODIGESTÃO

Para Silva et al. (2010), redes neurais representam uma metáfora do cérebro para processamento da informação. Esses modelos são biologicamente inspirados e não são uma réplica exata de como o cérebro realmente funciona. Possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações) e podem ser definidas como conjuntos de unidade de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões chamadas de sinapses artificiais, sendo estas representadas por vetores/matrizes de pesos sinápticos.

A estrutura individual dos neurônios, a topologia de suas conexões e o comportamento conjunto desses elementos de processamento naturais formam a base para o estudo das RNA's (HAYKIN, 2001). No Quadro 1, podem-se verificar as

características mais relevantes envolvidas com aplicação de RNA as quais são abordadas ao longo desta monografia.

Quadro 1 – Características descritas com aplicações de redes neurais artificiais

Adaptação por experiência	São ajustadas a partir da apresentação sucessiva de exemplos relacionados ao comportamento do processo, possibilitando a aquisição do conhecimento por experimentação.
Capacidade de aprendizado	Por intermédio da aplicação de um método de treinamento da rede, essa é capaz de generalizar o conhecimento adquirido, possibilitando estimar soluções que eram até então desconhecidas.
Habilidade de generalização	Após o processo de treinamento da rede, essa é capaz de generalizar o conhecimento adquirido, possibilitando estimar soluções que eram até então desconhecidas.
Organização de dados	A rede é capaz e realizar sua organização interna visando possibilitar o agrupamento de padrões que apresentam particularidades em comum.
Tolerância a falhas	Devido ao elevado nível de interconexões entre os neurônios artificiais, a rede neural torna-se um sistema tolerante a falhas quando parte de sua estrutura interna é sensivelmente corrompida.
Armazenamento distribuído	O conhecimento a respeito do comportamento de determinado processo dentro da arquitetura neural é realizado de forma distribuída entre as diversas sinapses de seus neurônios artificiais, permitindo um incremento da robustez da arquitetura frente a eventuais neurônios que se tornaram inoperantes.
Facilidade de prototipagem	A implementação da maioria das arquiteturas neurais pode ser facilmente, dependendo da especificidade da aplicação, prototipada em hardware ou em software, pois, após o processo de treinamento, os seus resultados são normalmente obtidos por algumas operações matemáticas elementares.

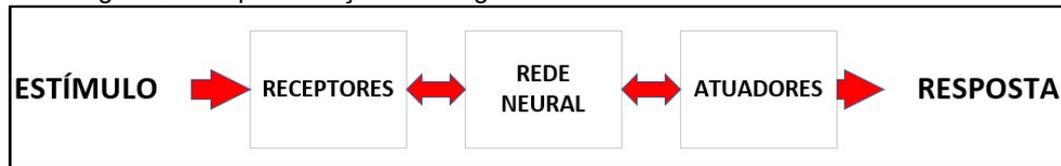
Fonte: Adaptado de Silva et al. (2010)

Tendo em vista a relação entre RNA's com neurônios biológicos, para que se possa compreender seu comportamento é necessário analisar antes o comportamento do cérebro humano.

Segundo Haykin (2001), o sistema nervoso humano pode ser visto como um sistema de três estágios, como mostrado na Figura 3. O centro do sistema é o cérebro, representado pela rede neural, que recebe continuamente a informação, percebe-a e toma decisões apropriadas. Dois conjuntos de setas são mostrados na figura 3. Aquelas que apontam da esquerda para a direita indicam a transmissão para frente do sinal portador da informação, por meio do sistema. As setas apontando para

esquerda indicam a presença de realimentação no sistema. Os receptores convertem estímulos do corpo humano ou do ambiente externo em impulsos elétricos que transmitem informação para rede neural. Os atuadores convertem impulsos elétricos gerados pela rede neural em respostas discerníveis como saídas do sistema.

Figura 3 – Representação em diagrama de blocos do sistema nervoso central

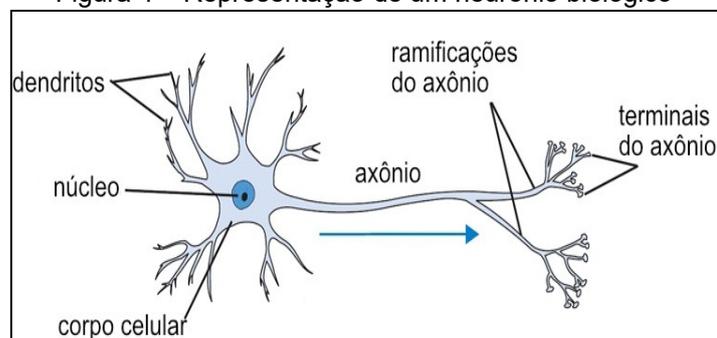


Fonte: (HAYKIN, 2001)

Pode-se dizer que o neurônio natural é um sistema biológico com conjunto de entradas chamadas sinapses<sup>8</sup>. A partir dos impulsos elétricos, sinais pulsados que chegam por meio das sinapses, o neurônio consegue fazer uma combinação, linear ou não linear, das intensidades de alguma informação, que são representadas pela frequência dos impulsos e também pelo sincronismo dos impulsos. Por meio da combinação de informações, quando um mínimo de excitação é excedido, esse neurônio gera um único pulso que sai por uma única saída que é chamada de axônio. O axônio possui terminações que comunicam com outros neurônios.

De acordo com Silva et al. (2010), o neurônio pode ser dividido em três partes principais, sendo elas os dendritos, no corpo celular (conhecido como soma) e no axônio. Os dendritos são constituídos por vários finos prolongamentos que formam a árvore dendrital, como pode ser visto na figura 4.

Figura 4 – Representação de um neurônio biológico



Fonte: (SILVA et al. 2010)

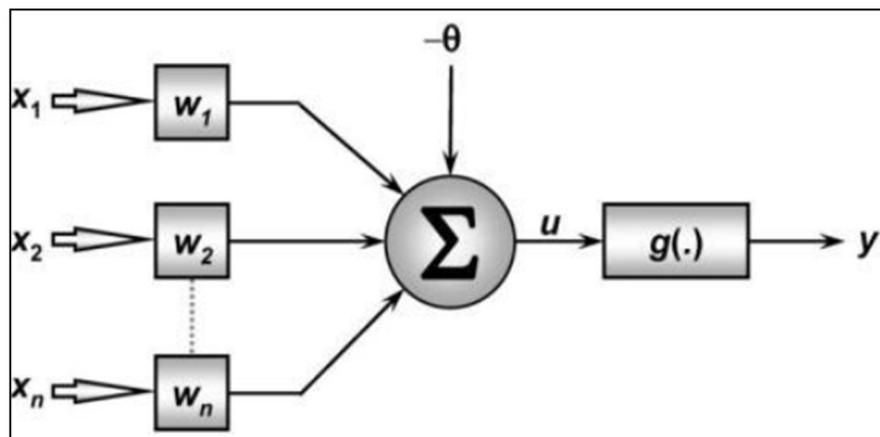
<sup>8</sup> As sinapses são junções entre a terminação de um neurônio e a membrana de outro neurônio. São elas que fazem a conexão entre células vizinhas, dando continuidade à propagação do impulso nervoso por toda a rede neuronal.

A função dos dendritos é captar, de forma contínua, os estímulos vindos de outros neurônios (conectores). O corpo celular é incumbido de processar informações advindas dos dendritos a fim de produzir um potencial de ativação que indicará se o neurônio poderá disparar um impulso elétrico ao longo de seu axônio. O axônio é constituído por um único prolongamento, cuja missão é conduzir os impulsos elétricos para outros neurônios.

O modelo de neurônio artificial, proposto por McCulloch e Pitts (apud BRAGA; CARVALHO; LUDEMIR, 2011), é uma simplificação do que se sabia na época a respeito do neurônio biológico. Sua descrição matemática resultou em um modelo com  $n$  terminais de entrada (dendritos) que percebem os valores  $x_1, x_2, \dots, x_n$  (que representam as ativações dos neurônios anteriores) e apenas um terminal de saída  $y$  (representando o axônio).

Para representar o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados  $w_1, w_2, \dots, w_n$ , cujos valores podem ser positivos ou negativos, dependendo das sinapses correspondentes serem inibitórias ou excitatórias. O efeito de uma sinapse particular  $i$  no neurônio pós-sináptico é dado por  $x_i w_i$ . Os pesos determinam “em que grau” o neurônio deve considerar sinais de disparo que ocorrem naquela conexão. Uma descrição do modelo está ilustrada na Figura 5.

Figura 5 – Representação de um neurônio artificial



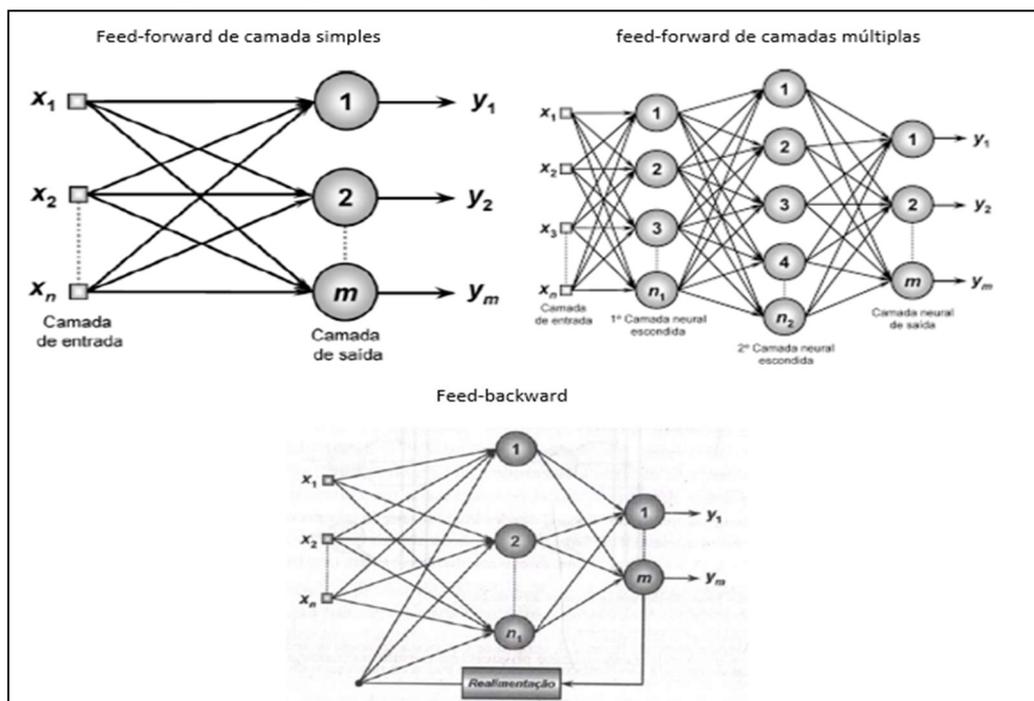
Fonte: (SILVA et al., 2010)

Conforme resumido por Oliveira (2005), sendo o neurônio uma unidade de processamento de informação fundamental para a operação de uma rede neural, pode-se identificar três elementos básicos em seu modelo:

- Sinapse: Conexão caracterizada por um “peso” ou “força própria”. Uma sinapse  $m$ , que está conectada a um neurônio  $k$ , recebe um sinal  $xm$  que, por sua vez, é multiplicado pelo peso sináptico  $wkm$ . No caso de modelagem de neurônios artificiais, os valores dos pesos podem ser também negativos se as sinapses forem inibitórias, ou positivos, se as sinapses forem excitatórias. Os pesos sinápticos têm a função de determinar a importância dos sinais de determinada região.
- Somador: Combinador linear que realiza o somatório das entradas do neurônio, ponderadas pela ação dos respectivos pesos sinápticos.
- Função de Ativação: Função que restringe a amplitude do sinal de saída ao condicionar a ativação do sinal à ultrapassagem de um determinado limiar pelo valor da soma ponderada das entradas. Os intervalos típicos de normalização de saída são  $[0,1]$  e  $[-1,1]$ .

As principais arquiteturas de redes artificiais são: as redes *feedforward* de camada simples, redes *feedforward* de camadas múltiplas e as redes recorrentes ou *feedbackward*. A figura 6 mostra estas diferentes arquiteturas.

Figura 6 – Algumas das arquiteturas de redes neurais artificiais



Fonte: adaptado de Silva et al. (2010)

A arquitetura de uma RNA é descrita, por Silva et al. (2010), como a forma como os seus diversos neurônios estão arranjados ou dispostos uns em relação aos outros. Estes arranjos são essencialmente estruturados por meio do direcionamento das conexões sinápticas dos neurônios. Dependendo da escolha da rede, poderão se alcançar diversidades de resultados, tais como: número de camadas, número de nós, tipo de conexões entre os nós e a topologia da rede.

Redes neurais têm se revelado sistemas muito promissores em muitas aplicações de previsão e de classificação devido a sua capacidade de “aprender” a partir dos dados, sua natureza não paramétrica e sua capacidade de generalizar (HAYKIN, 2001).

As RNA's foram criadas para assimilar matematicamente o comportamento de um neurônio biológico e assim auxiliar na resolução de problemas complexos e simular a inteligência humana. Com grande poder de aproximação, predição, classificação e regressão, o uso de RNA's é grande para a resolução de problemas (HAYKIN, 2001).

Do ponto de vista de modelagens de sistemas biológicos, as RNA's tem sido grande objeto de estudo. A sua utilização deve tomar alguns cuidados, como a sua arquitetura, função de ativação, parâmetros de treinamento, entre outros, visto que o comportamento não linear dos sistemas biológicos traz grandes desafios quanto a capacidade de generalização de resultados obtidos por uma RNA (HAYKIN, 2001).

A RNA é uma poderosa ferramenta para modelagem de processos não lineares complexos e com múltiplas variáveis, utilizada em processos da engenharia química, processos biológicos e tratamento aeróbio de águas residuais. É especialmente utilizada em estudos e aplicações em sistemas de digestão anaeróbia como ferramenta de predição e otimização destes sistemas (WAEWSAK, 2010).

Como alternativa a modelos de previsão baseados em experimentos laboratoriais ou modelos matemáticos puramente estatísticos, algumas ferramentas baseadas em inteligência artificial, como é o caso das redes neurais, tem surgido como uma importante ferramenta no que diz respeito à capacidade de predição e otimização de sistemas de digestão anaeróbia (GUEGUIM, 2012).

Ao longo do desenvolvimento dessa monografia, um maior detalhamento sobre redes neurais será apresentado, onde um aprofundamento sobre o tema se faz

necessário, uma vez que é a ferramenta utilizada para o desenvolvimento do trabalho proposto.

### 3 METODOLOGIA

Considerando os objetivos do trabalho e tendo como base o referencial teórico apresentado, evidenciam-se as dificuldades impostas pelo processo de biodigestão quanto à avaliação do potencial energético baseado em experimentos laboratoriais para determinação do volume de biogás produzido, bem como o volume de metano presente neste biogás.

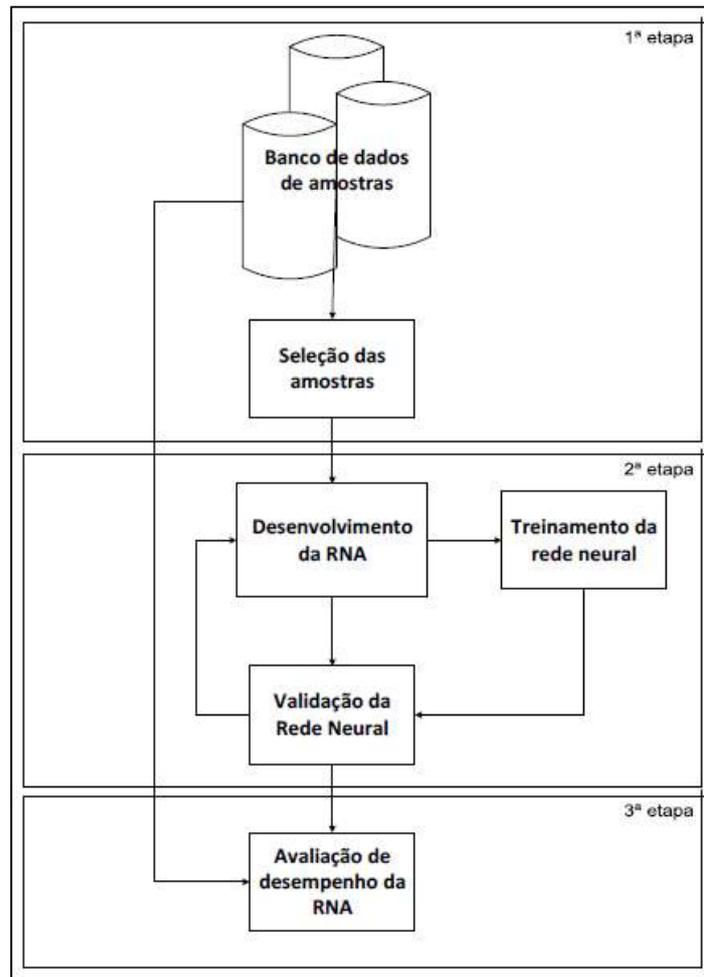
Assim, o presente trabalho contempla a implementação de uma RNA, de forma a permitir a inferência sobre o potencial de produção de biogás de diferentes combinações de matérias orgânicas, bem como diferentes parâmetros do processo. O objetivo é prever, com maior agilidade, o volume de produção de biogás usando somente alguns destes parâmetros. Pode-se destacar os trabalhos de Waewsak et al. (2010), que fizeram uso de lógica fuzzy e de Qdais (2009), que utilizaram algoritmo genético, ambos os casos associados a RNA, obtendo resultados satisfatórios quanto à previsão e otimização e mostrando a eficiência das RNA's desenvolvidas conforme suas propostas.

Devido ao interesse do potencial energético do biogás produzido, a quantidade de metano presente no biogás se torna igualmente importante, fazendo com que seu percentual presente na composição do biogás também seja avaliado neste estudo. Desta forma, a implementação de uma RNA com capacidade de prever não só o volume de biogás, mas também o volume de metano presente nas amostras, será considerada no presente trabalho.

Entre os trabalhos anteriormente citados na tabela 3, pode ser destacado o trabalho de Palaniswamy et al. (2016), que obtiveram um resultado promissor quanto a previsão e a análise de potencial de produção de biogás, fazendo uso de diferentes combinações de insumos. Palaniswamy et al. (2016) fazem uso somente de RNA com configurações diferentes dos autores anteriormente citados, obtendo mesmo assim resultados igualmente promissores. Já o trabalho de Souwalak et al. (2014), que também utilizaram somente RNA's como ferramenta, além da predição do volume de biogás utilizando RNA's, buscaram prever a fração de metano presente no biogás, obtendo resultados considerados satisfatórios ao levarem em consideração as condições particulares e o comportamento não linear de sistemas de biodigestão anaeróbia.

Um diagrama contendo as etapas a serem seguidas e implementadas para o desenvolvimento de uma RNA com capacidade para previsão de produção de biogás e também do volume de metano presente nas amostras, bem como a avaliação de melhorias visando um melhor desempenho, é apresentado na figura 7.

Figura 7 – Diagrama de blocos comparando um sistema de biodigestão convencional e outro que utiliza RNA



Fonte: Elaborado pelo autor (2019)

O diagrama da figura 7 mostra inicialmente o banco de dados a ser compilado, a etapa de seleção das amostras utilizadas no processo de treinamento e validação da RNA e ao final a etapa de testes, onde os resultados deverão ser equiparados aos dados do próprio banco de dados, mas não utilizados nos processos de treinamento e validação. Isto servirá para verificar a eficácia e convergência da rede desenvolvida, isto é, sua capacidade de generalização dos resultados quando submetida a entradas ainda não conhecidas.

Tendo como base as referências citadas até aqui, nas quais os autores fazem uso combinado de diferentes técnicas de inteligência artificial associadas à RNA e, em alguns casos, somente utilizando RNA, a opção por utilizar um modelo de RNA pode ser embasada e tida como uma escolha consistente para o desenvolvimento do trabalho. Seguindo com os objetivos anteriormente traçados, o processo de implementação é definido tendo por base o estado da arte e a metodologia proposta.

### 3.1 DEFINIÇÃO DA BASE DE DADOS E ESTRUTURAÇÃO DAS AMOSTRAS

A etapa inicial consiste em realizar um apanhado de informações de um banco de dados existente com parâmetros de cada matéria orgânica a ser usada. A escolha da matéria orgânica a ser introduzida como fonte de alimento para as bactérias digerirem, convertendo em biogás, é parte fundamental para a eficiência do biodigestor.

O desenvolvimento iniciou-se através da formatação de um banco de dados de experimentos de biodigestão realizados em laboratório sob condições controladas, onde a norma alemã VDI 4630 foi utilizada como referência para a validação dos resultados obtidos. Este banco de dados foi formatado para que o algoritmo da RNA desenvolvido pudesse captar essas informações como vetores ou matrizes, e assim utilizar, no processo de treinamento, validação e testes desta rede. Os dados disponíveis foram divididos em três grupos, sendo: GRUPO A composto por 93 amostras de diferentes composições de matérias orgânicas oriundas do processo industrial da empresa produtora de ovos, GRUPO B composto por 21 amostras do mesmo processo, porém com diferentes composições e resultados e GRUPO C composto por 33 amostras de resíduos de diferentes origens e composições dos grupos anteriormente citados.

Para o desenvolvimento da RNA, 70% dos dados do GRUPO A foram usados no processo de treinamento e desenvolvimento da rede. Os demais 30% deste grupo foram usados na validação e testes funcionais das redes. Já os dados dos GRUPOS B e C, respectivamente, foram usados para avaliação do desempenho quanto à capacidade de estimação da produção de biogás e metano quando submetidas a novas amostras com características e origens diferentes, mostrando sua real capacidade de generalização de resultados. Detalhes sobre a formatação de cada um dos grupos serão expostos ao longo do capítulo de implementação desta monografia.

### 3.2 DEFINIÇÃO DO MODELO MATEMÁTICO APLICADO A ESTIMAÇÃO

Baseado nas referências teóricas até o momento estudadas, onde diferentes metodologias são utilizadas como ferramenta de avaliação da capacidade de produção de biogás, a escolha do modelo a ser seguido tem como principal premissa a utilização de uma ferramenta que traga agilidade a esse processo e, ao mesmo tempo, confiabilidade, servindo como ferramenta apoio e análise quanto ao potencial de geração de biogás de determinadas matérias orgânicas ou de suas combinações.

Como foi visto na tabela 3 mostrada no tópico do estado da arte, a combinação de técnicas como *fuzzy* ou algoritmo genético, juntamente com RNA, normalmente estão atreladas a necessidade não só de prever, mas também de otimizar o processo. Já nos casos em que somente uma RNA foi utilizada, o resultado procurado foi a predição, fazendo esse fato sugerir que essa técnica seja suficiente para a proposta desta monografia. É importante salientar que isso não impossibilita que haja otimização no processo, uma vez que a agilidade pretendida permitirá que uma quantidade maior de testes possam ser realizados, ajudando na escolha da melhor combinação de insumos e, conseqüentemente, otimizando a produção de biogás em um processo de biodigestão.

Opções como realização de ensaios em laboratório utilizando a norma VDI 4630 e a AME, que avalia a capacidade de produção de metano também de forma experimental, mostram a necessidade e a importância de se desenvolver uma ferramenta computacional de apoio que traga agilidade e confiabilidade. Esta agilidade poderá servir para propor uma mudança em um processo de biodigestão que possa aumentar sua eficiência de produção de biogás e, conseqüentemente, na geração de energia elétrica caso esse biogás seja utilizado em um sistema de cogeração.

Tendo como base as referências e a disponibilidade de dados e seus respectivos parâmetros, o projeto de implementação deste trabalho contemplou o desenvolvimento de um algoritmo baseado exclusivamente em uma RNA que tivesse capacidade de prever o volume de biogás em um sistema de biodigestão anaeróbia, utilizando como dados de entrada parâmetros físico-químicos como ST, SV, SF e pH.

Devido a disponibilidade de acesso ao volume de metano produzidos pelas amostras, além do volume de biogás produzido, o percentual de metano presente neste biogás também foi utilizado como alvo a ser atingido por uma das topologias de

RNA que será testada. Desta forma, duas diferentes topologias são propostas, permitindo manter a proposta original, mas possibilitando avaliar, em paralelo, um modelo com capacidade de estimação não só de biogás, mas também de metano, que entre os gases da composição é o de maior potencial energético, justificando sua avaliação.

### 3.3 DESENVOLVIMENTO DA REDE NEURAL

Uma RNA é construída com base em um neurônio biológico e utilizada para resolver problemas de inteligência artificial (IA). Um sistema de IA deve ter capacidade para armazenar conhecimento, aplicar o conhecimento armazenado e adquirir novo conhecimento com base na experiência devendo, portanto, possuir essencialmente a representação, o raciocínio e a aprendizagem como seus elementos (SAGE, 1990 apud HAYKIN, 2001).

Nos últimos anos, a RNA tem sido aplicada com sucesso em bioprocessos não-lineares multivariados como uma ferramenta útil para construir modelos e prever resultados com precisão para novos conjuntos de dados de entrada (HAIDER et al., 2008; VIJAY; RINTU, 2010).

Vários algoritmos de aprendizagem foram testados por Ozkaya et al (2006), com intuito de avaliar qual deles teria o melhor desempenho quanto a capacidade de predição e convergência da rede. Foram testados 10 diferentes algoritmos, onde os de melhor desempenho quanto ao coeficiente de correlação  $R$  e ao erro quadrático médio  $MSE$  foram o *Resilient Backpropagation (trainrp)*, o *Gradient descent with momentum and adaptive learning rate BP (traingdm)* e o *Levenberg-Marquardt (trainlm)*, este último tendo o melhor desempenho e o menor número de iterações necessárias até sua convergência.

Nessa etapa, foi definida a topologia da RNA, seguindo como referência algumas das topologias de previsão e otimização que podem ser visualizados na tabela 5 ilustrada na sequência.

Palaniswamy et al. (2016) obtiveram resultados convincentes configurando sua RNA como *multilayer perceptron (MLP)*, com três camadas e com algoritmo de aprendizagem do tipo *Levenberg-Marquardt*. Da mesma forma, Gueguim (2010) e Qdais (2006) obtiveram resultados satisfatórios utilizando topologias semelhantes,

alterando basicamente a quantidade de neurônios de cada camada ou o número de camadas da rede.

Tabela 4 – Topologias utilizadas pelos autores citados ao longo do trabalho

<b>Diferentes arquiteturas e topologias de RNA</b>					
	Ozkaya et al. (2006)	Qdais et al. (2009)	Gueguim et al. (2012)	Souwalak et al. (2014)	Palaniswamy et al. (2016)
Nº de amostras	238	177	125	130	546
Nº de camadas	3	4	3	3	3
Nº camadas ocultas	1	2	1	1	1
Nº neurônios camada oculta	12 a 15 testados	25 e 25	2	8	4 a 25
Nº entradas	8	8	5	5	4
Nº saídas	1	1	1	3	1
Algoritmo de treinamento supervisionado	<i>back-propagation</i>	<i>back-propagation</i>	<i>back-propagation</i>	<i>back-propagation</i>	<i>back-propagation</i>
Função de ativação camada oculta	TANSIG (sigmoidal)	TANSIG (sigmoidal)	TANSIG (sigmoidal)	TANSIG (sigmoidal)	TANSIG (sigmoidal)
Função de ativação camada saída	LIN (função linear)	LIN (função linear)	LIN (função linear)	LIN (função linear)	LIN (função linear)
Algoritmo de otimização de aprendizagem	10 diferentes algoritmos	<i>Levenberg-Marquardt</i>	<i>Levenberg-Marquardt</i>	<i>Levenberg-Marquardt</i>	<i>Levenberg-Marquardt</i>
Índice de correlação $R$	0.951	0.8703	0.895	0.9942	0.9985
MSE (erro médio quadrático)	0.0026	n/a	n/a	0.0107	0.0401
Nº iterações (épocas)	12	100	531	n/a	n/a

Fonte: Elaborado pelo autor (2019)

Martinez et al. (2012 apud PALANISWAMY et al. 2016) e Wichern et al. (2009) dizem que modelos matemáticos são úteis no fornecimento de informações sobre o comportamento de diferentes fatores em processos de biodigestão.

Usando como base algumas das referências da tabela 5 anteriormente citadas, duas redes neurais denominadas, respectivamente, de RNA A e RNA B, foram desenvolvidas. As topologias utilizadas por Palaniswamy (2016), Gueguim (2012) e Souwalak (2014) foram utilizadas com pequenas modificações necessárias para a adequação dos dados disponíveis, a fim de avaliar seus respectivos desempenhos. Ambas utilizavam redes do tipo MLP (*multilayer perceptron*) de 3 camadas com função de transferência de ativação sigmoide na camada oculta e função de transferência linear na camada de saída. Os autores obtiveram melhores desempenhos ao utilizar como algoritmo de retropropagação dos erros *Levenberg-Marquardt* para o processo de aprendizagem da rede. Levando em consideração estes resultados, o algoritmo de aprendizagem *Levenberg-Marquardt* foi utilizado para a etapa de treinamento no desenvolvimento da rede.

O objetivo do *backpropagation* é otimizar os pesos para que a rede neural possa aprender a mapear corretamente as entradas para as saídas. O algoritmo *backpropagation* se trata de um algoritmo de reconhecimento de padrões não linearmente separáveis, que consiste basicamente em duas fases. A primeira fase é conhecida como *forward pass* ou passo à frente, onde as entradas são passadas a frente para obtenção das saídas. A segunda fase é chamada de *backward pass*, onde se calcula o gradiente da função de perda na camada final de saída da rede e usamos esse gradiente para aplicar recursivamente a regra da cadeia (*chain rule*) para atualizar os pesos da rede neural (etapa também conhecida como fase de atualização de pesos ou retro-propagação) (DATA..., 2019).

Já o algoritmo *Levenberg-Marquardt* é um método de otimização e aceleração da convergência do algoritmo *backpropagation*, sendo mais poderoso do que a técnica convencional do gradiente descendente. Enquanto o algoritmo *back-propagation* padrão utiliza a descida de gradiente como método de aproximação da função erro, o algoritmo de *Levenberg-Marquardt* (LM) utiliza uma aproximação pelo método de Gauss-Newton (HAGAN; MENHAJ, 1994 apud SOUWALAK et al. 2014).

Posteriormente, a topologia inicial foi sendo alterada buscando melhores desempenhos. Para a criação das diferentes topologias, foram utilizadas as aplicações *nntool* e *nftool* presentes no *software* MATLAB, que é a ferramenta base para o desenvolvimento de todo o trabalho. A aplicação *nftool* se trata de uma ferramenta para desenvolvimento de redes neurais específicas para problemas com

soluções não lineares, usada para mapear um conjunto de dados numéricos na entrada, buscando dados numérico nos alvos ou saídas.

O número de neurônios da camada de entrada foi fixado em 4 (quatro) em ambas as redes, uma vez que é a quantidade de parâmetros disponíveis no banco de dados, sendo eles ST, SV, SF e pH e também devido ao fato de serem parâmetros comumente utilizados tanto em avaliações laboratoriais como no desenvolvimento de algumas das redes testadas pelas referências utilizadas nesta monografia. O número de parâmetros de saída é de 1 (um) na RNA A, sendo ele o volume de biogás, e 2 (dois) na RNA B, sendo eles volume de biogás e volume de metano presentes no biogás, buscando o melhor resultado de desempenho das RNA's. A mudança básica realizada ao longo do trabalho foi quanto ao número de neurônios da camada oculta, variando de 4 a 25 neurônios, uma vez que ao longo dos testes a busca por melhores resultados de convergência foi ser fator determinante para tomada de decisão quanto a estas definições.

Para o processo de desenvolvimento, onde a rede foi treinada, 70% das amostras de resultados de experimentos do GRUPO A, contidas na tabela 13 (ANEXO A), foram utilizadas. A seleção destes 70% dentro dos 100% de amostras foi feita de forma aleatória automática pelo algoritmo de treinamento contido na aplicação do MATLAB®.

Parâmetros como condição para a parada de treinamento, número de ciclos de treinamento ou épocas e a taxa de variação do erro médio quadrático também foram estabelecidas, e inicialmente usaram como base as referências anteriormente já citadas. O projeto com redes neurais envolve um processo de tentativa e erro, pois quando a rede não apresenta um desempenho satisfatório torna-se necessário refazer todo o projeto, alterando o número de neurônios, conexões, taxa de aprendizado, funções de ativação e adição ou remoção de parâmetros (ARTERO, 2009).

Como já dito, as configurações e topologias iniciais propostas e descritas são baseadas nas referências bibliográficas e sofreram alterações. As mudanças realizadas serão apresentadas durante as etapas de implementação do projeto.

### 3.4 VALIDAÇÃO E TESTES FUNCIONAIS

Na etapa de validação e de testes funcionais, algumas premissas foram estabelecidas e atendidas de modo a satisfazer a proposta inicial do trabalho. Nesta

etapa de testes, a intenção foi demonstrar sua funcionalidade quanto ao seu uso como método de estimação e predição, relacionando aos resultados obtidos na literatura.

Nesta etapa, para que a RNA fosse considerada eficiente, ela deve obter resultados de correlação  $R$  superiores a 0,8 sendo considerados melhores, ainda, resultados próximos a 1 (um). Além disso, as redes devem possuir índices de correlação semelhantes aos obtidos pelas referências usadas no trabalho.

Segundo Pereira (2004), o termo correlação descreve a associação entre duas variáveis e o grau de relacionamento entre elas é medido pelo coeficiente de correlação, que pode oscilar de “zero” a “um”, de forma positiva ou negativa, sendo valores próximos a “zero” considerados resultados ruins e valores próximos a “um” considerados bons resultados. Neste caso, os valores de  $R$  farão a correlação entre os valores de predição e os valores reais usados somente na etapa de treinamento da rede. O coeficiente de correlação é obtido através da equação 1, que relaciona os desvios padrões das variáveis  $X$  e  $Y$  e a covariância entre elas.

$$R = \frac{\frac{\sum_{i=1}^n (X_i - \bar{X}) * (Y_i - \bar{Y})}{n-1}}{S_x * S_y} \quad (1)$$

O outro critério de avaliação foi o  $MSE$  (*mean square error*), que também é chamado de EQM ou erro quadrático médio. O valor buscado foi próximo a zero, igualmente sendo equiparado às referências. Souwalak et al. (2014) falam que o  $MSE$  é comumente usado como critério de performance das RNA's, já que se trata de um valor estimado da diferença ou erro médio quadrático entre as saídas de predição e os alvos da rede. O erro quadrático médio (EQM ou  $MSE$ ) é comumente utilizado como medida de erro de previsão. Ele é determinado somando os erros de previsão ao quadrado e dividido pelo número de erros usados no cálculo. Ele pode ser obtido através da equação 2:

$$EQM \text{ ou } MSE = \frac{\sum_{t=1}^n e_t^2}{n} \quad (2)$$

Para a validação e testes funcionais, foram considerados o desempenho da rede quando submetida aos 30% dos dados do GRUPO A não utilizados no processo de treinamento. A etapa de validação e testes fez uso de informações adquiridas

através de matrizes e vetores que foram compilados do banco de dados que está disposto na tabela 13 contida no Anexo A.

O resultado esperado ao final dos testes é que as redes RNA A e RNA B apresentem desempenho semelhante aos das referências quanto ao índice de correlação  $R$  e que obtenham um nível de erro tendendo a zero mostrando, de fato, sua capacidade como modelo de previsão e estimação. Assim sendo, estarão aptas a receberem dados de amostras de diferentes origens e de diferentes características físico-químicas, buscando obter resultados de estimação próximos aos resultados obtidos nos experimentos laboratoriais aos quais se teve acesso para este desenvolvimento.

### 3.5 AVALIAÇÃO DE DESEMPENHO QUANTO A CAPACIDADE DE ESTIMAÇÃO

Como forma de avaliação de desempenho das redes quanto a sua capacidade de estimação da produção de biogás e de metano, as duas topologias desenvolvidas já treinadas e testadas receberam como entrada dados de parâmetros de dois grupos de amostras, sendo os grupos B e C, respectivamente, não usados nos treinamentos. O GRUPO B contém 21 amostras de resíduos de mesma origem do GRUPO A, mas com diferentes combinações de insumos e diferentes resultados de saída. Já as amostras do GRUPO C contém 33 combinações de matérias orgânicas com origem e características diferentes do que as dos demais grupos.

A avaliação de desempenho das redes RNA A e RNA B com os melhores resultados de performance visa mostrar que os resultados de estimação e predição tendem a ser próximos dos resultados reais obtidos nos experimentos realizados em laboratório, mostrando uma ampla capacidade de estimação. Os valores obtidos pelas saídas de ambas as redes foram expostos na forma de gráficos de dispersão e de distribuição de frequência, de forma a deixar os resultados mais claros.

## 4 IMPLEMENTAÇÃO DO PROJETO

Com base nas premissas levantadas ao longo do referencial teórico, justifica-se a implementação de uma RNA como ferramenta de estimação e previsão para otimização da produção de biogás em sistemas de biodigestão anaeróbio, onde diferentes combinações de diferentes matérias orgânicas serão utilizadas no processo de treinamento e validação da rede neural.

Seguindo as definições e a metodologia até o momento expostas, pode-se estabelecer uma sequência lógica de etapas a serem desenvolvidas para implementação da RNA proposta nessa monografia. São, então, apresentadas as etapas de implementação das bases de dados, a definição da arquitetura e topologia das redes para posterior etapa de treinamento e testes das mesmas.

### 4.1 BASE DE DADOS PARA TREINAMENTO E VALIDAÇÃO DA RNA

Para possibilitar a implementação do modelo, inicialmente faz-se necessário a obtenção e formatação de um banco de dados, onde diversas combinações de materiais orgânicos e suas características já foram levantadas e testadas.

Para a compilação deste banco de dados, são usados resultados obtidos ao longo de alguns anos em experimentos de biodigestão realizados em parceria entre uma empresa produtora e industrializadora de ovos e o laboratório de bioreatores da UNIVATES.

Diferentes resíduos foram usados nestes experimentos como efluentes brutos provenientes da limpeza de máquinas e equipamentos, resíduos de ovos como gema e clara, esterco de aves de postura comercial, além de outros resíduos utilizados no processo de compostagem dos resíduos orgânicos da empresa. Além destes já citados, alguns resíduos advindos de outros processos industriais de fora da empresa anteriormente citada também foram testados.

Estes resíduos tinham como premissa a suplementação por possuir alto teor de Carbono e tinham a intenção de potencializar a biodigestão, promovendo uma maior produção de biogás, já que o Carbono, segundo Foresti et al. (1999), é de extrema importância para os microrganismos presentes nos biodigestores.

Kumar et al. (2009 apud PALANISWAMY et al. 2016) e Lai et al. (2009) afirmam que saber dados como a natureza genética da matéria orgânica, condições

fisiológicas, fatores de fermentação e a natureza do substrato do reator são importantes para uma eficiente produção de biogás. Devido a somente alguns dos principais parâmetros que interferem na produção de biogás terem sido avaliados nos testes realizados em laboratório, o desenvolvimento da rede ficou restrito a utilização destes como parâmetros de entrada e saída para o algoritmo da RNA. Foram, portanto, definidos como entrada os dados de ST's, SV's, SF's, pH e Volume de Biogás (VB) como parâmetro de saída ou *target* da rede.

Dados como Tempo de Retenção Hidráulica (TRH) e temperatura, também mensurados e obtidos no banco de dados, foram suprimidos, pois descaracterizariam o processo de treinamento da rede. A temperatura durante os testes foi sempre constante, mantida em 35 °C, que é uma temperatura considerada ideal para processos de biodigestão e, portanto, não traria resultados diferentes para o desenvolvimento da RNA. O TRH por sua vez, teve seus dados suprimidos por necessitar de uma maior base de dados. Além disso, pelo método de biodigestão nas avaliações realizadas ser do tipo batelada, fazia com que o TRH não tivesse variações em alguns experimentos devido ao critério de estabilização estabelecido pela VDI 4630, que determinava com base no declínio da produção de biogás o fim da contabilização de dados e do próprio experimento.

É sabido que outros parâmetros já apontados no referencial teórico e avaliados por alguns dos autores estudados e utilizados como referência também são importantes quanto aos seus impactos causados no volume de produção de biogás e na sua composição. Contudo, muitos destes não foram mensurados durante os experimentos aos quais se teve acesso para formação do banco de dados e, portanto, não puderam ser usados no processo de desenvolvimento deste trabalho. Parâmetros como alcalinidade, DBO, DQO, relação dos nutrientes ou ainda a biota, não eram alvo de estudo durante os testes de desempenho realizados no laboratório e, por isso, não puderam ser utilizados como parâmetros no desenvolvimento desta rede neural.

A relação C/N só passou a ser avaliada nos experimentos laboratoriais em um período recente, por solicitação da empresa produtora de ovos devido aos custos atrelados a sua análise, não havendo quantidade de dados suficientes para que uma RNA pudesse ser treinada levando em conta este parâmetro, mesmo sabendo de sua importância na interferência da produção de biogás e metano.

Os valores percentuais de sólidos SV, ST, SF e pH das amostras do GRUPO A estão especificados na tabela 11, apresentada no Anexo A, que trata da relação

completa de dados usados na etapa de treinamento, validação e testes durante o desenvolvimento das redes e que contém 93 diferentes experimentos realizados em laboratório. Os demais dados usados no processo de avaliação de desempenho das redes RNA A e B desenvolvidas encontram-se na tabela 14, apresentada no Anexo B e na tabela 15 do Anexo C. As principais matérias orgânicas usadas no processo de treinamento, validação e testes, além de algumas de suas principais características, podem ser visualizadas na tabela 6 de forma parcial.

Tabela 5 – substratos que compõe o banco de dados e suas principais características

<b>Substratos</b>	<b>Sólidos Totais (%)</b>	<b>Sólidos Voláteis (%)</b>	<b>Sólidos Fixos (%)</b>	<b>pH</b>
Dejeto de aves de postura	28,27	67,21	32,79	7,81
Efluente bruto (água de lavagem de ovos e equipamentos)	0,37	86,34	13,66	6,41
Efluente de lagoa aeróbia	0,32	83,27	16,73	7,45
Efluente de lagoa anaeróbia	0,26	56,86	43,14	7,31
Resíduo de ovos (clara e gema)	16,68	94,96	5,04	6,47
Borra de glicerina	97,93	99,71	0,28	7,69
Glicerina	78,49	96,08	3,92	5,76
Lisogoma	36,32	95,26	4,74	4,92
Celulose	93,91	99,91	0,09	6,97

Fonte: Elaborado pelo autor (2019)

Como mencionado anteriormente, foram avaliados materiais e resíduos advindos de outras fontes como forma de suplementação ou complementação, sempre buscando um melhor resultado no volume de Biogás produzido e até mesmo um Biogás com maior teor de metano, o que traz um benefício devido ao aumento do poder calorífico do gás.

Hanreich (2013), Labatut et al. (2014), Sitorus et al. (2014) e Trisakti et al. (2015) colocam que conhecer a concentração e a composição do substrato e da matéria orgânica a ser utilizada, o nível pH e a temperatura de fermentação dentro do reator são fatores determinantes no controle e previsão da produção do biogás.

Para o processo de treinamento e desenvolvimento da rede, onde todas as variáveis utilizadas no processo de aprendizagem e validação são acessadas pelo algoritmo da RNA, os dados do GRUPO A foram subdivididos em 3 (três) partes. A primeira parte é usada na etapa de treinamento das RNA's, o segundo e o terceiro grupos são usados para validar e testar o funcionamento e eficiência da rede durante a etapa de treinamento da mesma.

Essa divisão dos dados pode ser realizada de forma automática pela aplicação do MATLAB, mas também permite alterar os percentuais usados em cada etapa do processo de treinamento, neste caso ficando definido que 70% das amostras (65 amostras) sejam usadas no processo de treinamento da rede e os demais 30% subdivididos, sendo 15% (14 amostras) no processo de validação e os demais 15% (14 amostras) usados nos testes das RNA's desenvolvidas. Os testes e validação realizados nesta etapa fazem parte do desenvolvimento da rede.

Os dados da tabela 13 com o GRUPO A contém, de forma subdividida, os parâmetros de entrada, denominados de *input*, e os parâmetros de saída, que são denominados de *targets*. Para a inserção junto ao algoritmo, devido a característica de funcionamento do MATLAB que trabalha tendo por base matrizes e vetores, os dados precisaram ser compilados em formato exclusivamente numérico, onde as amostras ou *samples* são divididas em linhas e cada parâmetro destas amostras ocupa uma coluna. Assim, a tabela com os dados de *input* (entrada) ficou com formato de 4 linhas (parâmetros) x 93 colunas (amostras), enquanto que a tabela contendo os *targets* (dados de saída), ficou com formato de 1 linha x 93 colunas.

Os outros dados apresentados nas tabelas 14 (ANEXO B) e 15 (ANEXO C), respectivamente, denominadas GRUPO B contendo 21 amostras e GRUPO C contendo 33 amostras, foram usados na avaliação de desempenho além da capacidade de generalização da rede. Ambas contêm a mesma formatação e parâmetros do GRUPO A, contudo, as do GRUPO B contém amostras de resíduos de mesma origem do GRUPO A, mas não foram usadas na etapa de treinamento, possuindo diferentes combinações de matérias orgânicas além de diferentes resultados, e as do GRUPO C, que contém matérias orgânicas de origens diferentes e com características diferentes das dos grupos A e B, foram usadas no processo de desenvolvimento da RNA.

Devido à natureza e as suas características diferentes, os dados de entrada das redes neurais precisaram passar pelo processo de normalização, que tem como

finalidade adaptar os dados de entrada à faixa dinâmica das funções de ativação da rede neural. No caso deste projeto, a tangente hiperbólica (na camada intermediária) e a função linear (na camada de saída). Este processo tem por finalidade evitar com que a função de ativação tangente sigmoideal opere na região de saturação, que compreende valores inferiores a -1 e superiores a 1. O processo de normalização dos dados foi feito através do MATLAB, através da função *mapminmax*, levando em consideração a seguinte equação 3:

$$x_N = \frac{(x_{Nmax} - x_{Nmin})(x - x_{min})}{x_{max} - x_{min}} + x_{Nmin} \quad (3)$$

onde  $x_N$  é o valor normalizado,  $x_{Nmax}$  e  $x_{Nmin}$  são iguais aos extremos do intervalo de normalização, +1 e -1 e  $x_{ma}$  e  $x_{min}$  são os valores máximo e mínimo de cada atributo relativos aos dados das amostras do treinamento.

A normalização foi aplicada, inicialmente, ao conjunto de treinamento e, em seguida, estendida aos conjuntos de teste, onde foi adotado o mesmo fator de normalização. Findada a etapa de formatação dos dados, a etapa de implementação das redes pôde ser iniciada.

## 4.2 REDE NEURAL ARTIFICIAL

Uma vez definidos os parâmetros de entrada e com o banco de dados já compilado, chega o momento de utilizar estes dados para alimentar o algoritmo da RNA. Com isso, a etapa de desenvolvimento das RNA's e o processamento dos dados é iniciado.

Para a implementação e exposição dos resultados obtidos pelas topologias das redes neurais A e B, uma sequência lógica foi estabelecida visando uma melhor organização do trabalho. Esta sequência está descrita nos tópicos relacionados e mostrados a seguir:

- Criação das redes RNA A e RNA B, cada uma com diferentes versões para camada oculta e camada de saída através da aplicação *nntool* e *nftool* do MATLAB® 2016;

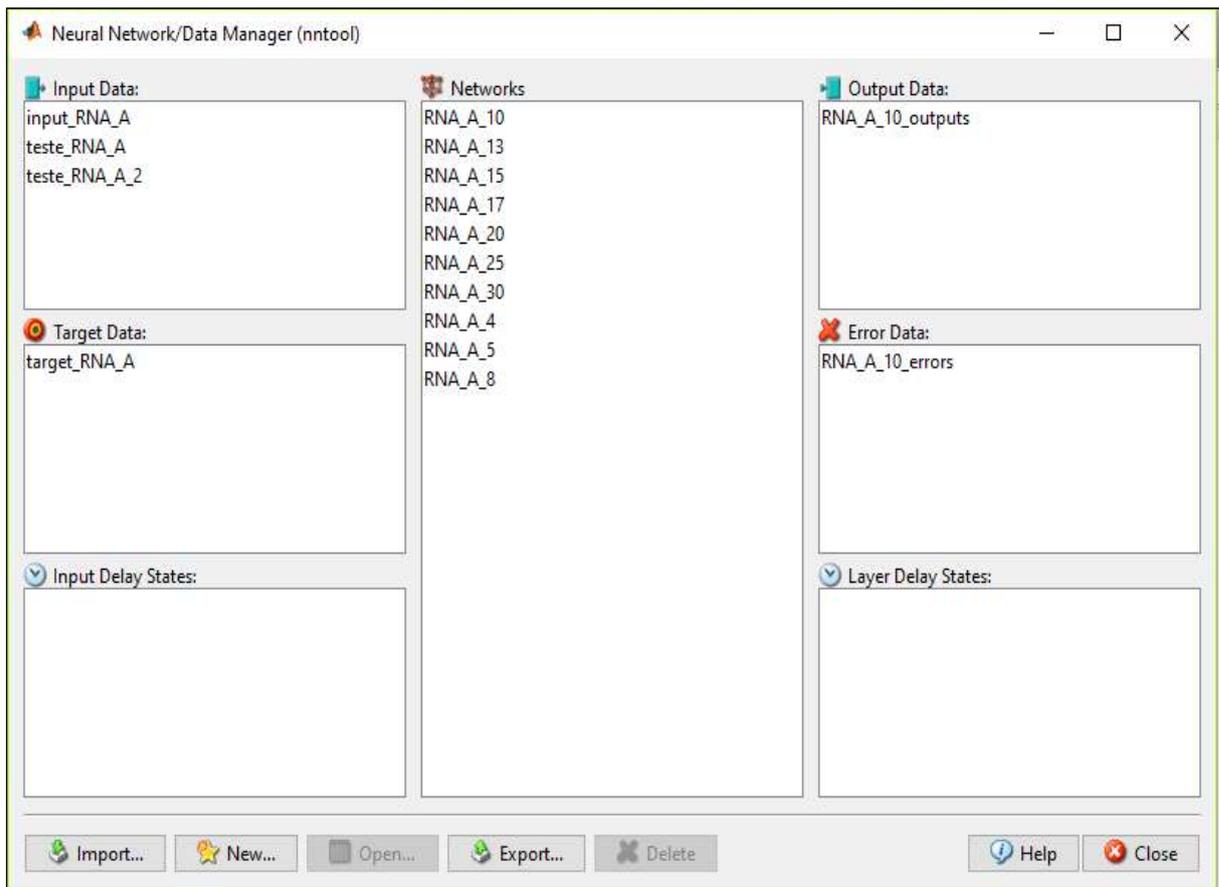
- Importação do banco de dados do GRUPO A, sendo dados de entrada (*input*) e saída (*target*) para treinamento, validação e testes;
- Ajustes dos parâmetros de treinamento e critérios de parada para cada uma das versões das redes, através da interface da aplicação;
- Treinamento das redes RNA A e RNA B com 70% dos dados do GRUPO A;
- Validação e testes funcionais das redes RNA A e RNA B com os 30% restante dos dados do GRUPO A;
- Avaliação dos melhores índices de correlação alcançados e dos menores erros quadráticos médios para selecionar a melhor topologia da RNA A e da RNA B, que serão usadas na avaliação de desempenho quanto às suas capacidades de estimação e generalização.

Tomando como base as topologias usadas como referência, onde Palaniswamy et al. (2016), Gueguim et al. (2012) e Souwalak et al. (2014) usaram RNA *multilayer perceptron* com algoritmo de aprendizagem do tipo *backpropagation Levenberg-Marquardt*, a RNA para testes iniciais pôde ser implementada.

Para a construção da rede, são utilizadas as aplicações do MATLAB denominadas *Neural Network Tool* ou *nntool* e a *Neural fitting tool* ou *nftool*, que se tratam de ferramentas gráficas acessadas pelo *Graphical User Interface* (GUI). Essas aplicações são específicas para desenvolvimento de RNA's, as quais necessitam ser alimentadas com informações das entradas e saídas através de tabelas que são transformadas em vetores ou matrizes pelas aplicações. Além das ferramentas gráficas anteriormente citadas, algumas das funções e parâmetros da RNA foram desenvolvidas ou alteradas diretamente no algoritmo através de um *script* criado para cada RNA.

A primeira etapa para a criação das redes neurais inicia no *Command Window* do MATLAB, onde são criados os vetores e as matrizes com os dados de *input* e *target* de cada um dos grupos de amostras. Na sequência, os dados passam pelo processo de normalização já comentado na seção anterior. Feito isso, através do comando *nntool*, a interface da aplicação mostrada na figura 8 é iniciada, permitindo a importação das entradas e saídas através das matrizes criadas através do *Command Window* e salvas no *workspace* do MATLAB, bem como a criação de cada uma das redes e a configuração de suas respectivas arquiteturas.

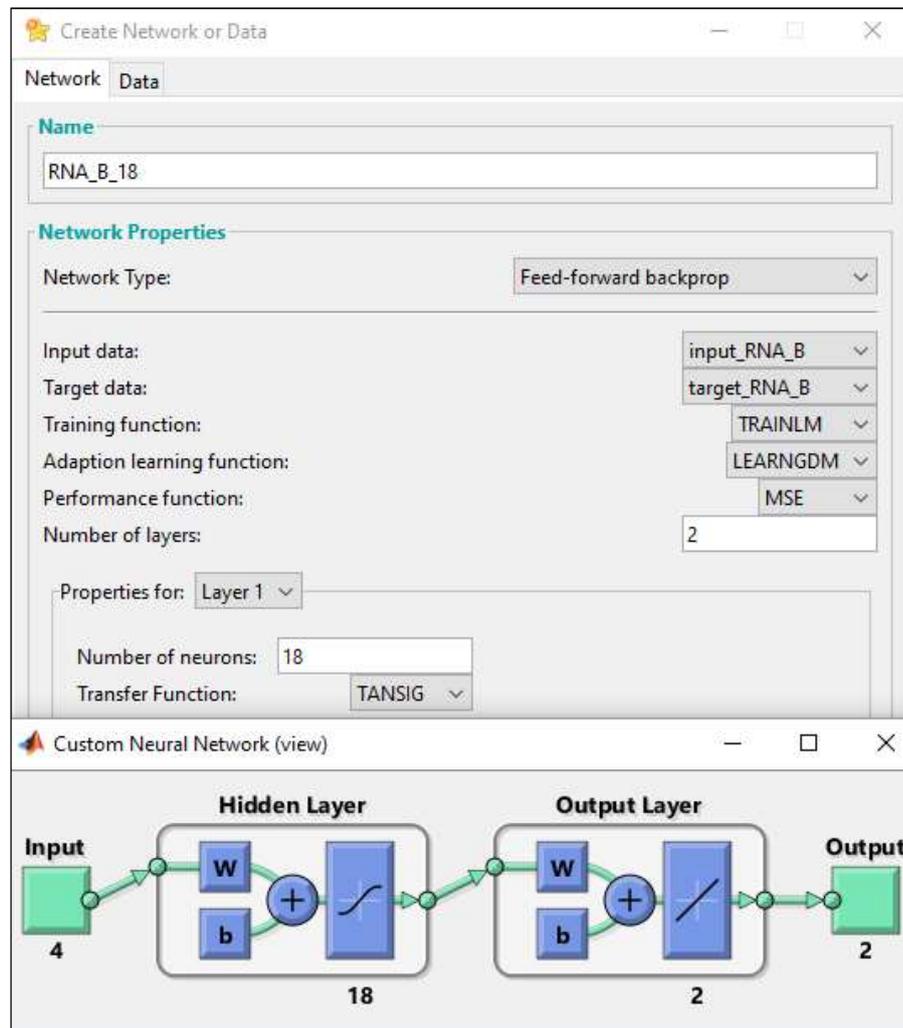
Figura 8 – Interface da aplicação *nntool* do Matlab, onde a RNA é desenvolvida



Fonte: Elaborado pelo autor (2018)

A figura 8 apresenta a tela de interface da ferramenta *nntool*, onde algumas informações devem ser inseridas e que também apresenta os resultados de saída e os erros obtidos. Inicialmente, o usuário deve realizar a importação das matrizes e vetores contendo os dados de entrada e de saída. Na sequência, deve criar cada uma das redes com suas respectivas arquiteturas e topologias através da *interface* mostrada na figura 9. Nesta etapa o usuário inicia dando um nome para a identificação da RNA, seleciona o tipo de rede, os dados que serão usados como entrada e como alvos da rede, o algoritmo de treinamento e a função de adaptação de aprendizagem. Além disso, escolhe a função para o critério de performance, determina o número de camadas e as propriedades de cada camada, como o número de neurônios e a função de transferência de cada camada, assim concluindo a criação das redes. Ao final da configuração o usuário pode ainda fazer a pré-visualização da topologia montada antes de salvar a nova RNA criada.

Figura 9 – Interface de criação das redes neurais através da GUI do MATLAB



Fonte: Elaborado pelo autor (2019)

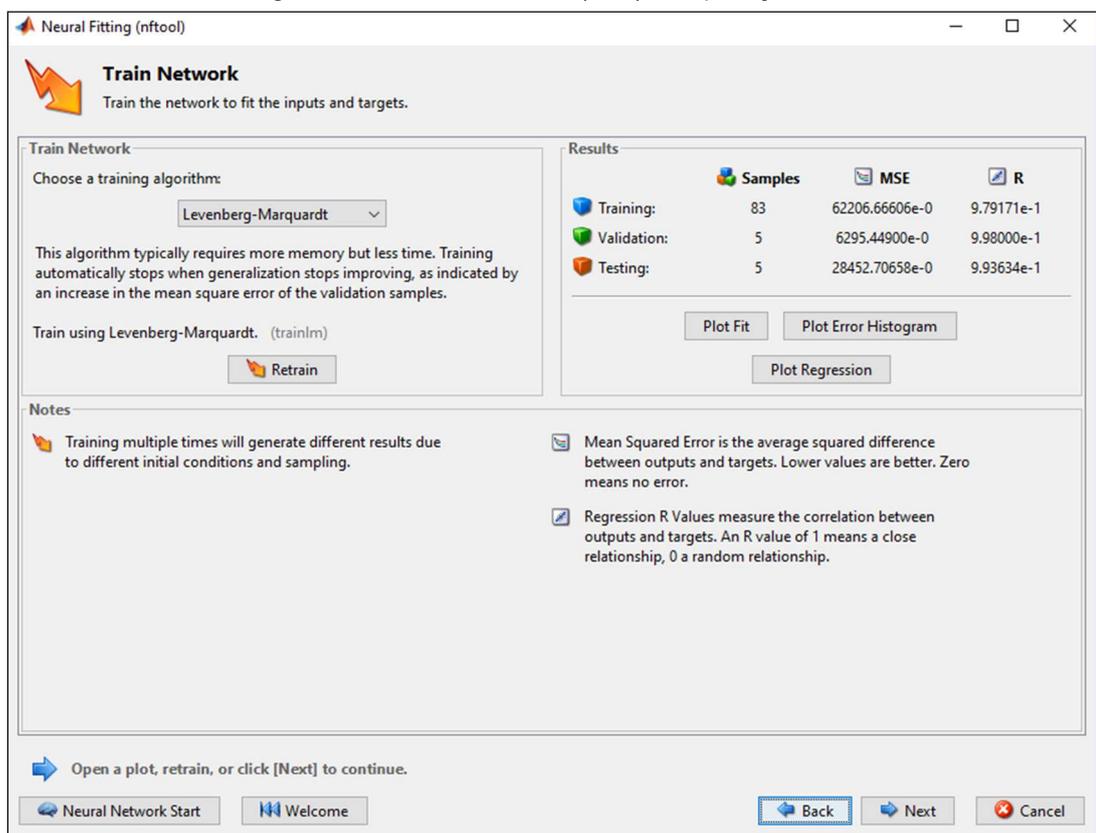
A figura 9 mostra ainda a topologia na forma de pré-visualização, onde é possível ver as camadas, quantidades de parâmetros de entrada e saída, quantidade de neurônios da camada oculta e as funções de ativação da camada oculta e de saída.

Já a aplicação *nftool* se trata de uma ferramenta específica para desenvolvimento de RNA dedicada à problemas de aproximação, onde se utiliza um conjunto numérico de dados de entrada e saída que possui uma arquitetura e topologia pré-definida, utilizando o algoritmo de aprendizagem *Levenberg-Marquardt* por padrão, mas permitindo alterá-lo diretamente no *script* ou código de programação através da função “*net.trainFcn*”, onde diferentes funções de treinamento podem ser estipuladas.

Esta aplicação, possui as mesmas características da aplicação *nntool*. Porém, não permite alguns ajustes diretamente na *interface* que são fixos, como as funções

de transferência das camadas oculta e de saída, os pesos sinápticos dos neurônios artificiais e os parâmetros de treinamento que poderiam permitir um ajuste fino da RNA desenvolvida. Contudo, ela permite que um *script* seja gerado e por meio dele as alterações anteriormente mencionadas como fixas na aplicação possam ser alteradas diretamente no código do algoritmo. Esta aplicação possui por padrão como critérios de avaliação dos resultados, o índice de correlação  $R$  e o erro médio quadrático ou MSE, que também podem ser visualizados diretamente na interface mostrada na figura 10 e que são os principais critérios alvos de comparação e avaliação desta monografia.

Figura 10 – Interface inicial (GUI) da aplicação *nftool*



Fonte: Elaborado pelo autor (2019)

Definidas as ferramentas, iniciou-se pela construção das RNA's e suas respectivas arquiteturas e topologias. Os parâmetros selecionados para cada uma das topologias criadas serão apresentadas na sequência, sendo a RNA A como uma rede para predição de volume de biogás de forma estimada e a RNA B como uma rede que, além de biogás, estime também o volume de metano neste biogás, ambas

utilizando como referência os autores estudados no estado da arte e ao longo desta monografia.

#### 4.2.1 Rede Neural A

A arquitetura e topologia da RNA A, bem como seus parâmetros, foram baseadas nas topologias das redes descritas por Palaniswamy et al. (2016) e Gueguim et al. (2012), que buscavam inferir o potencial de produção de biogás em sistemas de biodigestão anaeróbia e ainda avaliar seu desempenho. Algumas pequenas modificações foram necessárias de modo a adequar a topologia à disponibilidade de dados e características do problema proposto, uma vez que cada um dos autores referenciados possuía diferentes parâmetros monitorados, usados como entrada e saída da rede. A arquitetura adotada é apresentada na tabela 7.

Tabela 6 – Arquitetura e parâmetros de treinamento adotados na RNA A

<b>Arquitetura</b>	Tipo de rede neural	<i>Feed-forward backpropagation</i>
	Número de camadas	3
	Número de neurônios	entrada: 4 oculta: 4 a 25 saída: 1
	Função de transferência (ativação)	oculta: TANSIG saída: PURELIN
	Função adaptativa de aprendizagem	<i>Gradient descendente with Momentum</i>
	Algoritmo de aprendizagem	<i>Levenberg-Marquardt</i>
	Função de performance	<i>MSE</i>
<b>Parâmetros de treinamento</b>	Valor inicial do <i>bias</i> (pesos)	0.01
	Taxa de aprendizagem	1
	Nº máximo de iterações	10000
	Nº máximo de tentativas	1000

Fonte: Elaborado pelo autor (2019)

Como critério de parada, o algoritmo utiliza o critério que primeiro for alcançado, podendo ser o número máximo de iterações necessárias para atingir a melhor performance ou o número de tentativas para se atingir a melhor performance. Uma vez atingido algum dos limites estabelecidos, a melhor performance é armazenada,

bem como os pesos sinápticos e demais parâmetros da rede para posterior utilização nos testes de funcionalidade, validação e avaliação de performance.

#### 4.2.2 Rede Neural B

A arquitetura e topologia da RNA B, mostrada na tabela 8, bem como seus parâmetros, foi baseada na topologia de Souwalak et al. (2014), que além de buscar prever o volume de biogás também buscou prever o volume de metano presente nas amostras, além de avaliar seu desempenho. A diferença básica em relação a topologia da RNA A é a quantidade de saídas, que passou para 2, onde além da predição do volume de biogás buscou-se prever o volume de metano presente no biogás. Mais uma vez, pequenas modificações foram necessárias de modo a adequar a topologia à disponibilidade de dados e características do problema proposto.

Tabela 7 – Arquitetura e parâmetros de treinamento adotados na RNA B

<b>Arquitetura</b>	Tipo de rede neural	<i>Feed-forward backpropagation</i>
	Número de camadas	3
	Número de neurônios	entrada: 4 oculta: 4 a 25 saída: 2
	Função de transferência (ativação)	oculta: TANSIG saída: PURELIN
	Função adaptativa de aprendizagem	<i>Gradient descendente with Momentum</i>
	Algoritmo de aprendizagem	<i>Levenberg-Marquardt</i>
	Função de performance	<i>MSE</i>
<b>Parâmetros de treinamento</b>	Valor inicial do <i>bias</i> (pesos)	0.01
	Taxa de aprendizagem	1
	Nº máximo de iterações	10000
	Nº máximo de tentativas	1000

Fonte: Elaborado pelo autor (2019)

Variando-se a quantidade de neurônios da camada oculta foi possível verificar qual das topologias obteria o melhor desempenho. Foi estabelecido como critério de treinamento que cada uma das topologias seria treinada uma única vez, porém com uma quantidade adequada de épocas, possibilitando o maior número de iterações possíveis e garantindo a convergência da RNA. Ao final, os desempenhos das redes

foram comparados uma com a outra e também aos resultados obtidos pelos autores referenciados.

Os resultados de performance, correlação, tempo de treinamento e erro médio quadrático serão apresentados nos tópicos de treinamento, validação e testes. Por final, serão apresentados nos tópicos seguintes sobre os testes de validação e resultados finais. O resultado de tempo de convergência está atrelado à capacidade de *hardware* e da versão da ferramenta que está sendo utilizada.

No caso deste trabalho, o mesmo foi desenvolvido em um computador com processador de 7 núcleos Intel® core i7-7500U, 2,7 GHZ e 16 GB de memória RAM, com placa de processamento gráfico dedicada NVIDIA® GeForce® 940MX e com 4GB de memória. A versão do MATLAB® usada foi a R2016A.

## 5 RESULTADOS

Neste capítulo, são apresentados os resultados obtidos a partir da metodologia proposta e da implementação das redes neurais. Os resultados são apresentados seguindo a sequência definida na metodologia, iniciando pelos resultados obtidos na etapa de treinamento das duas diferentes topologias implementadas e na sequência apresentando os resultados obtidos nas etapas de validação e testes funcionais. Por fim, uma avaliação sobre a performance das redes com melhor desempenho é apresentada, onde é mostrada a capacidade de estimação das redes ao serem submetidas a dados de amostras de diferentes origens e características das que foram usadas no treinamento de ambas as topologias. Posteriormente, os resultados encontrados são equiparados aos resultados obtidos pelas referências e avaliados quanto ao seu desempenho e capacidade de predição.

### 5.1 TREINAMENTO DAS REDES

Com as arquiteturas das redes definidas anteriormente, foi possível iniciar a etapa de treinamento das mesmas. Nesta etapa, as diferentes topologias são testadas uma a uma a fim de obter a com melhor resposta quanto ao índice de correlação  $R$ , que mostra o nível de aproximação entre o valor do alvo e o valor de predição. Ainda, busca-se obter o menor erro médio quadrático (MSE), que juntamente com o  $R$  serão as principais métricas avaliadas e equiparadas às referências. Os resultados são apresentados em tabelas e gráficos.

#### 5.1.1 Rede Neural A

Como definido na etapa de implementação, a rede neural denominada RNA A possui uma camada de entrada com 4 parâmetros denominados *inputs*, uma camada oculta que variou de 4 a 25 neurônios e uma camada de saída, com um único parâmetro denominado *target*, que é o volume de biogás das amostras testadas em laboratório. Na etapa de treinamento, basicamente foram alteradas as quantidades de neurônios da camada oculta, iniciando com 4 neurônios e elevando de forma intercalada até 25 neurônios. Essas quantidades de neurônios foram também usadas pelas referências, que buscaram encontrar resultados de convergência dentro destas

faixas e que, ao final da etapa de treinamento, avaliavam a RNA de melhor performance também nas etapas de testes de funcionalidade e validação. Ao final, o resultado buscado era a topologia com melhor desempenho e que mostrasse ser capaz de obter resultados estimados próximos dos resultados reais usados como *targets* pela rede.

Nesta primeira etapa, todas as redes passaram pelo processo de treinamento usando os mesmos critérios e parâmetros de treinamento de modo que todas possuísem os mesmos critérios de parada. Os resultados obtidos foram tabelados e encontram-se de forma completa na tabela 16 do Apêndice A. A tabela 9 mostra os resultados parciais das topologias com os melhores índices de correlação  $R$  obtidos nas etapas de treinamento, bem como os erros quadráticos médios  $MSE$  de cada uma delas, tempo de treinamento e número de épocas ou iterações ao atingir a melhor performance, entre outros.

Tabela 8 – Resultados de  $R$  e  $MSE$ , além de outros, da etapa de treinamento obtidos pela RNA A

	RNA_A_8	RNA_A_10	RNA_A_15	RNA_A_18	RNA_A_22
Total de épocas	1096	1108	1047	541	449
Tempo de treinamento	3 s	3 s	3 s	1 s	1 s
Performance (MSE)	1,59E-03	1,62E-04	2,42E-07	1,42E-05	5,16E-05
Gradiente	1,69E-05	2,44E-04	9,90E-04	3,12E-11	4,07E-10
Momentum (MU)	1,00E-08	1,00E-06	1,00E-07	1,00E-11	1,00E-10
Tentativas de validação	1000 (máx)	1000 (máx)	1000 (máx)	368	414
Critério de parada	Tentativas de validação	Tentativas de validação	Tentativas de validação	Gradiente	Gradiente
Melhor Performance de validação (MSE)	4,29E-03	2,24E-02	1,41E-02	6,41E-03	1,59E-02
Nº de épocas no melhor MSE	96	108	47	173	35
$R$ =Treinamento (70% amostras)	0,99152	0,99258	0,99627	0,99878	0,99639

Fonte: Elaborado pelo autor (2019)

A maioria das topologias testadas finalizaram o treinamento pelo critério de tentativas de validação, onde após o limite de tentativas pré-estabelecido ser atingido, que era de 1000, a rede cessa o treinamento e adota os melhores pesos sinápticos e

unidades de polarização para posterior utilização, onde validação e testes são realizados. Os pesos sinápticos (*weight*) e as unidades de polarização (*bias*), servem de limite para a função de ativação adotada. Algumas delas pararam com o critério do gradiente descendente *momentum*, que se trata de uma espécie de impulso que se comporta como um filtro passa baixa que serve para ignorar pequenos desvios e erros, fazendo com que o treinamento não seja parado de forma inadequada evitando o *underfitting*<sup>9</sup> e o *overfitting*<sup>10</sup> da rede (HAGAN, DEMUTH, BEALE, 1996).

Ainda segundo Hagan, Demuth e Beale (1996), a quantidade de neurônios da camada oculta e alguns dos parâmetros de treinamento das redes tem influência direta quanto à possibilidade de uma rede ter um subajuste (*underfitting*) ou um sobreajuste (*overfitting*). Redes com uma quantidade muito pequena de neurônios na camada oculta podem sofrer um subajuste e ter pouco preparo. Já redes com muitos neurônios na camada oculta podem sofrer com o sobreajuste, prejudicando a rede no desempenho quando submetida a testes e validação.

Levando em consideração os resultados de desempenho obtidos quanto ao índice de correlação  $R$  na etapa de treinamento mostrados na tabela 9, a RNA A com 18 neurônios na camada oculta foi a rede com melhor índice de correlação obtido durante o treinamento. Contudo, ao ser testada com uma fração dos dados do próprio GRUPO A na etapa de testes, que terá seus resultados mostrados na sequência, mostrou um índice de correlação  $R=0,91541$ , bem abaixo do  $R=0,99878$  obtido no treinamento, mostrando um possível sobreajuste da rede devido a maior quantidade de neurônios na camada oculta.

Considerando este fato, a RNA A 8, com 8 neurônios na camada oculta, foi quem obteve o melhor desempenho. Ela obteve um  $R=0,99152$  em treinamento e um  $R=0,98198$  ao ser testada, mostrando ser a melhor topologia para a etapa de testes. A mesma obteve ainda um  $MSE=0,0042924$ , valor próximo a zero, mostrando que a diferença do erro médio quadrático entre os valores usados como alvos e os valores de saída da rede são próximos a zero, o que conforme a literatura é considerado um resultado adequado a uma rede neural desenvolvida para o processo de predição.

---

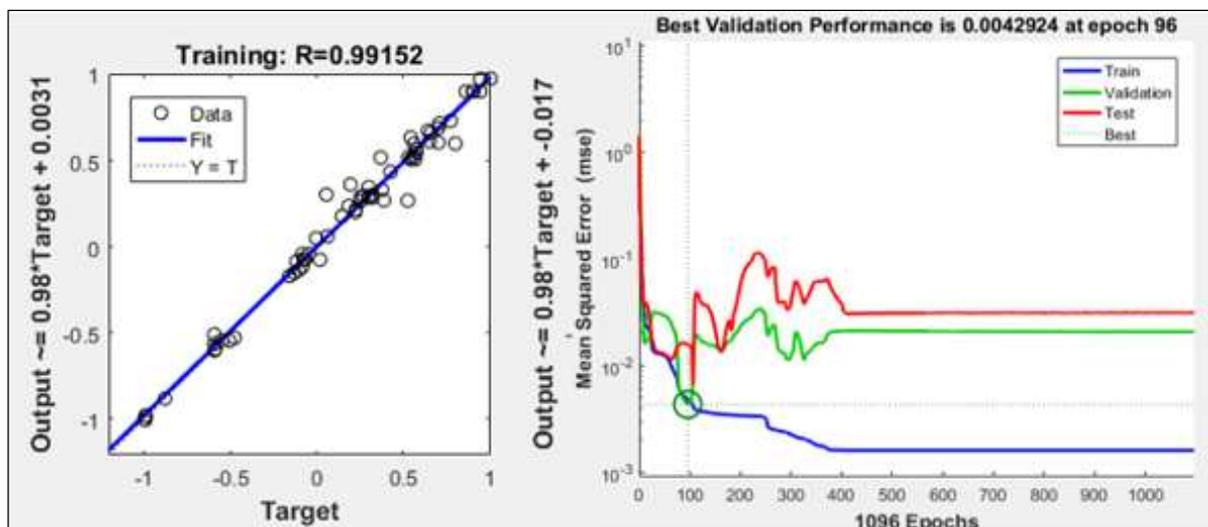
<sup>9</sup> *Underfitting* de uma rede neural ocorre quando a mesma não possui resultados de treinamentos considerados insatisfatórios e mesmo assim quando submetida a um conjunto de dados de testes, consegue ter um baixo nível de erros e bons resultados de saída. (HAGAN; DEMUTH; BEALE, 1996)

<sup>10</sup> *Overfitting* de uma rede neural ocorre quando a mesma possui resultados de treinamentos satisfatórios, contudo, não consegue bons resultados de saída, possuindo erros elevados se comparados aos erros da etapa de treinamento. (HAGAN; DEMUTH; BEALE, 1996)

Os tempos de treinamento diminuíram conforme a quantidade de neurônios da camada oculta ia aumentando, mostrando que uma maior quantidade de neurônios leva a uma convergência mais rápida da rede. Isso também pode ser visto pelo número de iterações necessárias para essa convergência, que ia diminuindo, mostrando novamente que uma quantidade maior de neurônios na camada oculta torna a convergência mais rápida. Contudo, a rápida convergência não garante um melhor desempenho, já que a medida que uma maior quantidade de neurônios era adicionada à camada oculta o MSE encontrado passava a aumentar, comprovando o *overfitting* da rede e evidenciando que não necessariamente uma grande quantidade de neurônios na camada oculta era necessária para um bom desempenho.

Os resultados podem ser melhor visualizados através do gráfico de regressão da etapa de treinamento e também pelo gráfico de melhor performance, mostrados na figura 11, onde  $R=0,99152$  foi obtido em treinamento e um *MSE* mais próximo a zero (0) foi obtido na 96ª iteração ou época.

Figura 11 – Gráfico do índice de correlação e melhor performance obtida quanto ao MSE



Fonte: Elaborado pelo autor (2019)

### 5.1.2 Rede Neural B

Seguindo a sequência implementada, a topologia da rede neural denominada RNA B possui uma camada de entrada com 4 parâmetros, uma camada oculta e uma camada de saída com dois parâmetros, que são volume de biogás e o volume de metano das amostras. Novamente na etapa de treinamento foi alterada a quantidade

de neurônios da camada oculta, iniciando com 4 neurônios e elevando de forma intercalada até 25 neurônios.

Na etapa de treinamento da RNA B, que deve prever, além do volume de biogás, também o volume de metano das amostras, entre todas as topologias testadas o melhor índice de correlação obtido foi da rede RNA B com 15 neurônios na camada oculta, obtendo  $R=0,99481$  como mostra a tabela 10, que ilustra ainda o  $MSE=0,00909$ , além de mais alguns parâmetros. São mostrados, de forma parcial, os resultados de algumas das topologias testadas e que tiveram desempenhos considerados satisfatórios quanto ao índice de correlação. Os resultados completos podem ser visualizados na tabela 17, no Apêndice B.

Tabela 9 – Resultados de R e MSE, entre outros, obtidos na etapa de treinamento pela RNA B

	RNA_B_15	RNA_B_18	RNA_B_20	RNA_B_22
Total de épocas	1047	1018	1005	1025
Tempo de treinamento	3 s	3 s	4 s	4 s
Performance (MSE)	4,21E-04	1,42E-04	1,83E-04	1,04E-05
Gradiente	4,01E-04	2,46E-04	9,99E-05	1,71E-04
Momentum (MU)	1,00E-06	1,00E-07	1,00E-06	1,00E-07
Tentativas de validação	1000 (máx)	1000 (máx)	1000 (máx)	1000 (máx)
Critério de parada	Tentativas de Validação	Tentativas de Validação	Tentativas de Validação	Tentativas de Validação
Melhor Performance de validação (MSE)	9,09E-03	1,78E-02	2,35E-02	1,03E-02
Nº de épocas no melhor MSE	47	18	5	25
R=Treinamento (70% amostras)	0,99481	0,98729	0,98247	0,99056

Fonte: Elaborado pelo autor (2019)

Assim como pode ser observado no treinamento da RNA A, a RNA B mostrou que a variação na quantidade de neurônios da camada oculta traz uma mudança significativa nos resultados produzidos. O tempo de treinamento desta vez aumentou a medida que uma maior quantidade de neurônios era adicionada. Isso pode ser explicado, uma vez que por possuir 2 parâmetros como *targets* a rede necessita de um maior tempo de treinamento até convergir.

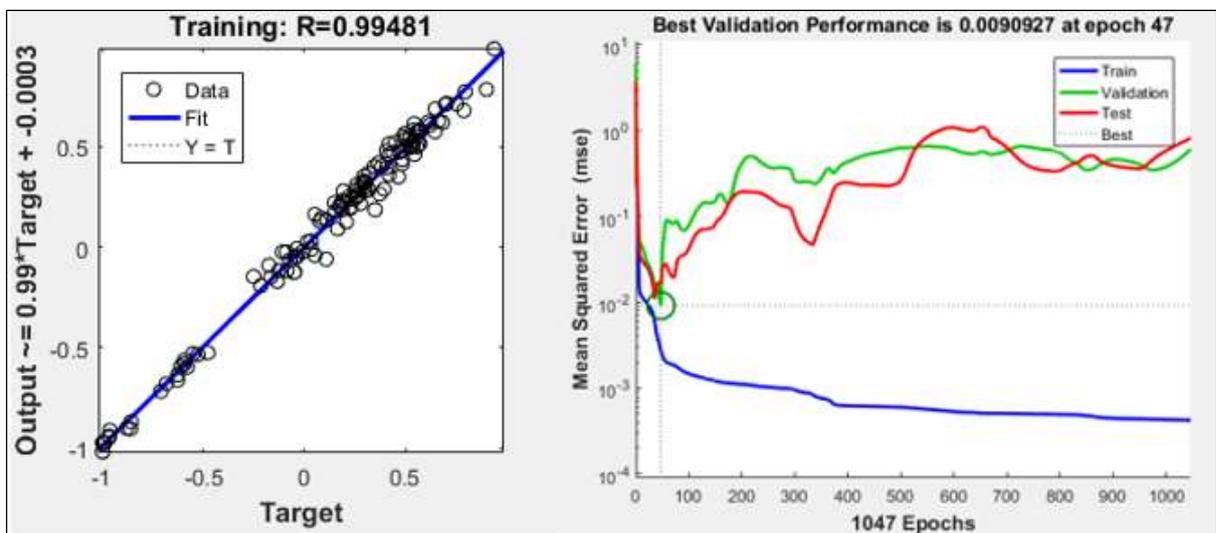
A quantidade de iterações passou a diminuir com o incremento de neurônios na camada oculta, da mesma forma como obtido no treinamento da RNA A. As

topologias da RNA B tiveram todas, como critério de parada, o limite máximo de tentativas de validação, o que mostra que sua melhor performance já havia sido alcançada e o treinamento não necessitava se estender.

O resultado de melhor performance obtido através do erro médio quadrático mostrou um limite quanto a melhoria dos resultados produzidos. O *MSE*, obtido pela RNA B de 4 neurônios que era de  $MSE=0,01947$ , foi diminuindo até um  $MSE=0,00909$ , obtido pela RNA B com 15 neurônios. Após isso, a medida que mais neurônios eram adicionados a camada oculta, o erro passou a aumentar, chegando a um  $MSE=0,1687$  na RNA B com 25 neurônios, mostrando que uma maior quantidade de neurônios na camada oculta não torna a rede neural mais eficiente, como já evidenciado no processo de treinamento da RNA A.

O melhor erro médio quadrático de saída obtido pela RNA B com 15 neurônios na camada oculta, bem como o melhor índice de correlação obtido pela mesma topologia, pode ser observado na figura 12.

Figura 12 - Gráfico do índice de correlação e melhor performance obtida quanto ao MSE



Fonte: Elaborado pelo autor (2019)

## 5.2 VALIDAÇÃO E TESTES DE FUNCIONALIDADE

A validação e o teste de funcionalidade levam em consideração os resultados do índice de correlação obtidos na etapa de desenvolvimento da rede, onde se buscou índices *R* próximos a 1, valor este também buscado pelas referências anteriormente já citadas e que comprovariam a capacidade de estimar resultados das redes. Os

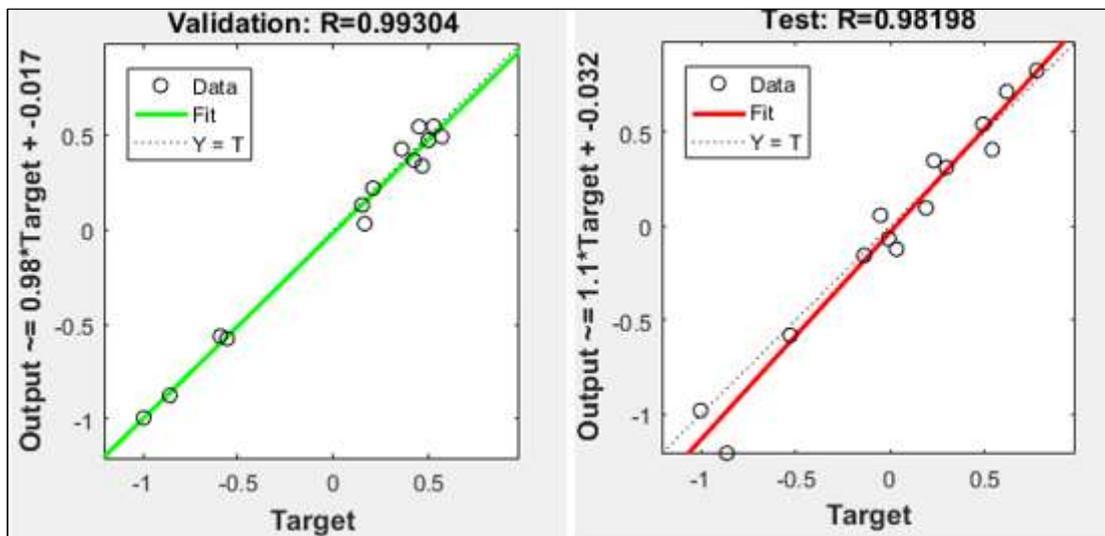
testes de validação e de funcionalidade levaram em consideração os resultados obtidos com os 30% restantes dos dados das amostras do GRUPO A não utilizados na etapa de treinamento.

### 5.2.1 Validação e Teste Funcional da Rede Neural A

A validação, bem como a funcionalidade da rede RNA A com 8 neurônios na camada oculta, inicialmente é avaliada pelo índice de correlação  $R$  obtido. Os resultados levam em consideração os 30% do total de 93 amostras do GRUPO A.

Os resultados são expostos através de dois gráficos mostrados na figura 13, que expõe os índices de correlação obtidos nas etapas de validação e testes da rede de melhor desempenho na etapa de treinamento (RNA\_A\_8). Pode-se observar, pelos eixos X (*targets*) e Y (*outputs*), que os valores de predição de ambas as etapas ficaram muito próximos uns aos outros, mostrando uma aproximação dos resultados de estimação aos resultados reais das amostras.

Figura 13 –Gráfico de regressão linear e índice de correlação  $R$

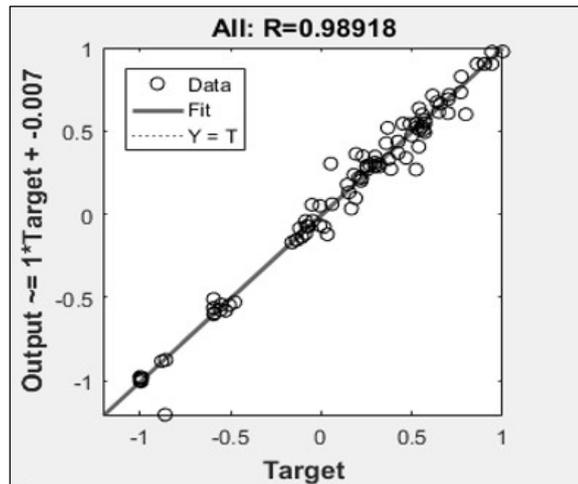


Fonte: Elaborado pelo autor (2019)

O coeficiente de correlação na validação foi  $R=0,99304$ , enquanto que no teste de funcionalidade foi de  $R=0,98198$ , em ambos os casos provando a aproximação entre os valores usados como *targets* e os valores de saída obtidos pela RNA A. Um coeficiente médio final  $R=0,98918$  foi obtido considerando todas as etapas do desenvolvimento, sendo estas treinamento, validação e testes, considerando os resultados para as 93 amostras usadas no desenvolvimento da rede e mostradas na

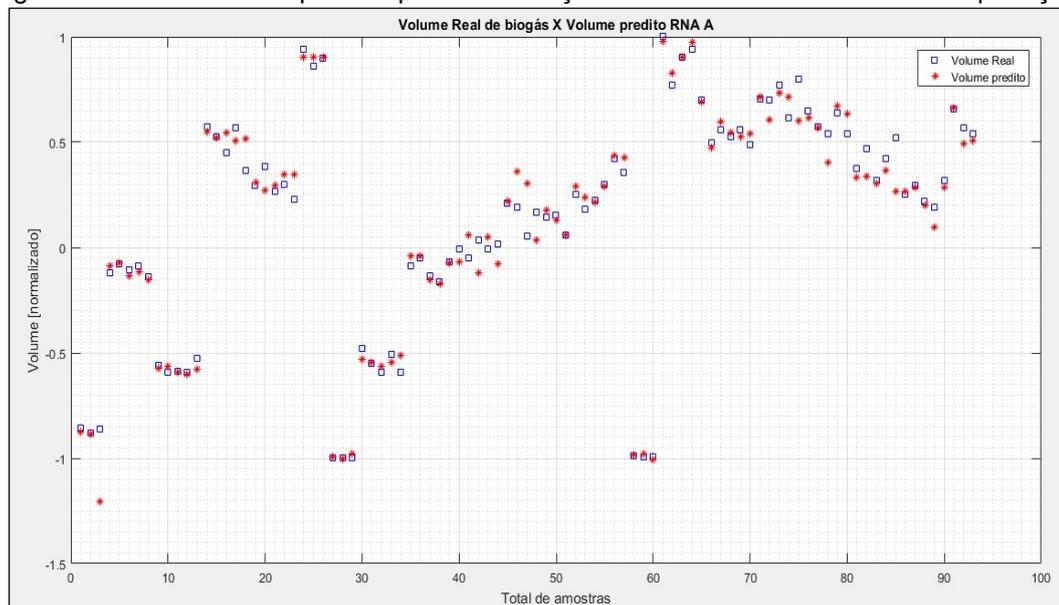
figura 14 através de um gráfico de regressão linear. Os resultados de estimação, bem como os valores usados como alvos, serão mostrados no gráfico de dispersão da figura 15 na sequência.

Figura 14 – Gráfico de regressão linear das 93 amostras usadas no desenvolvimento da RNA A



Fonte: Elaborado pelo autor (2019)

Figura 15 – Gráfico de dispersão que da diferença entre valores reais e valores de predição



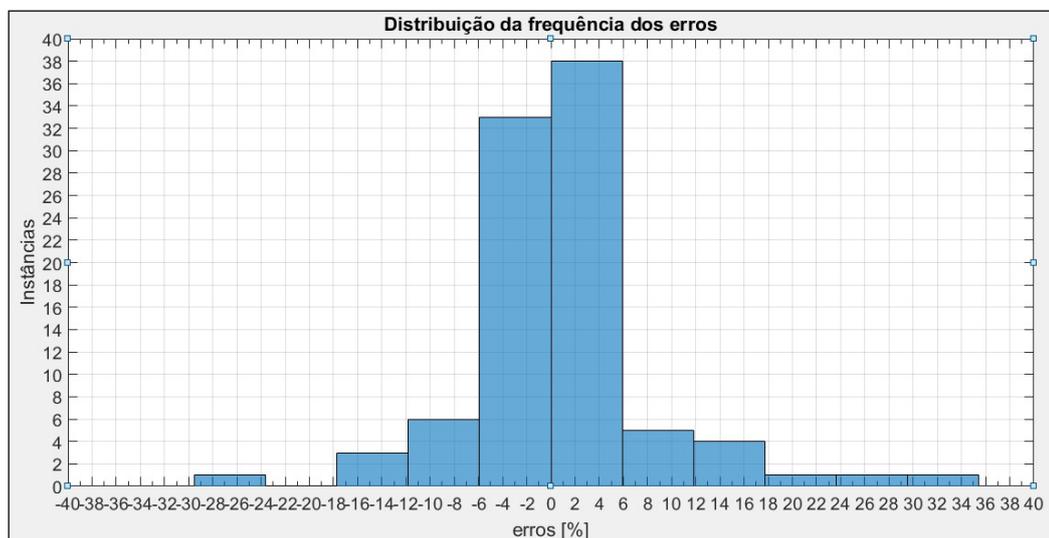
Fonte: Elaborado pelo autor (2019)

No gráfico de dispersão da figura 15 mostrado anteriormente os resultados de todas as 93 amostras usadas no desenvolvimento podem ser melhor avaliados, onde os valores reais normalizados estão sendo relacionados aos valores estimados de predição, mostrando as diferenças encontradas entre eles. Os quadrados azuis representam os volumes das amostras usados com *targets* na etapa de treinamento,

validação e testes. Já os asteriscos vermelhos, representam os volumes previstos pela RNA\_A, que foram estimados com base no aprendizado da rede nestas mesmas etapas. Pode-se observar, ainda pelo gráfico, que existe uma aproximação considerável entre os resultados de saída obtidos pela predição da rede e os alvos usados na etapa de treinamento.

Os erros encontrados e expostos anteriormente no gráfico de dispersão, que se tratam da diferença entre os resultados de saída produzidos pela RNA A durante o treinamento, validação e testes, bem como os alvos usados nesta mesma etapa, podem ser melhor analisados através de um gráfico de distribuição de frequência de erros mostrado na figura 16, na sequência. Pode-se observar que a maior frequência de instâncias se encontra próxima aos valores de erro próximos a zero, o que mostra um resultado consistente quanto à proposta e as referências citadas ao longo do trabalho. Mesmo mostrando alguns desvios maiores quanto ao erro de saída, os valores estimados mostraram uma tendência de obtenção de resultados aproximados de produção de biogás, mostrando que a rede tem a capacidade de convergência esperada e proposta por esta monografia.

Figura 16 – Histograma dos erros obtidos pela RNA A 8 na etapa de treinamento



Fonte: Elaborado pelo autor (2019)

A figura 16 expõe a frequência de distribuição dos erros através de um histograma da etapa de treinamento, considerando o conjunto completo de amostras. Das 93 amostras usadas no processo de desenvolvimento da RNA A, 82 (88,17% das

amostras) delas apresentaram erros máximos de  $\pm 12\%$  e 71 amostras (76,34% das amostras) apresentaram erros máximos de  $\pm 6\%$ .

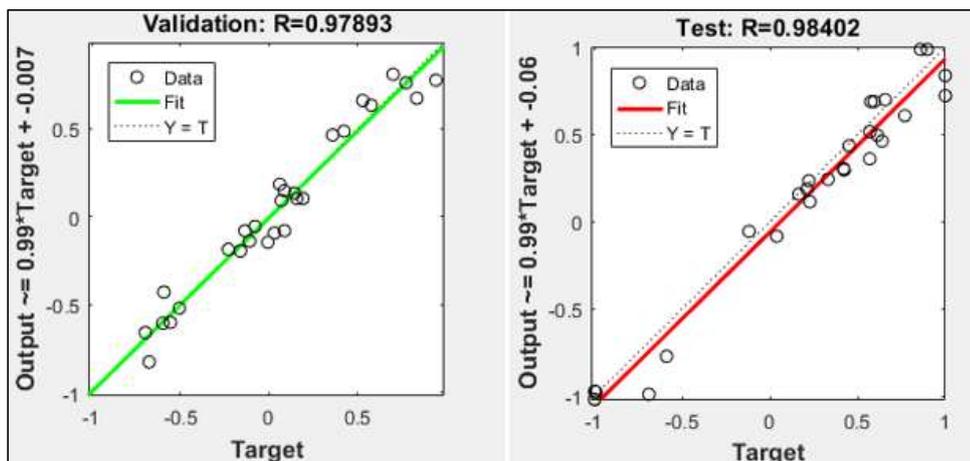
Alguns valores de erros acima de 12% foram encontrados, porém em uma frequência baixa, não trazendo impactos significativos aos resultados buscados. Ainda foi possível observar que a distribuição de erros tem uma certa uniformidade, mostrando que algumas das amostras podem ter seu potencial estimado tanto para uma maior produção, quanto para uma menor produção de biogás.

### 5.2.2 Validação e Teste Funcional da RNA B

Os testes de validação e de funcionalidade da RNA B levaram em consideração os resultados obtidos durante a etapa de desenvolvimento, que também utilizou as 93 amostras do GRUPO A, porém adicionando o metano como parâmetro extra de saída, além do biogás anteriormente utilizado.

Novamente, dois gráficos que mostram os índices de correlação obtidos na validação e testes durante a etapa de treinamento da rede de melhor desempenho (RNA B 15) são mostrados na figura 17. Pode-se observar, pelos eixos X (*targets*) e Y (*outputs*), que os valores de estimacão na etapa de validação ficaram próximos uns aos outros. Da mesma forma na etapa de testes, inclusive mostrando uma pequena melhora se comparado ao resultado da validação.

Figura 17 – Imagem do gráfico de regressão linear do índice de correlação  $R$



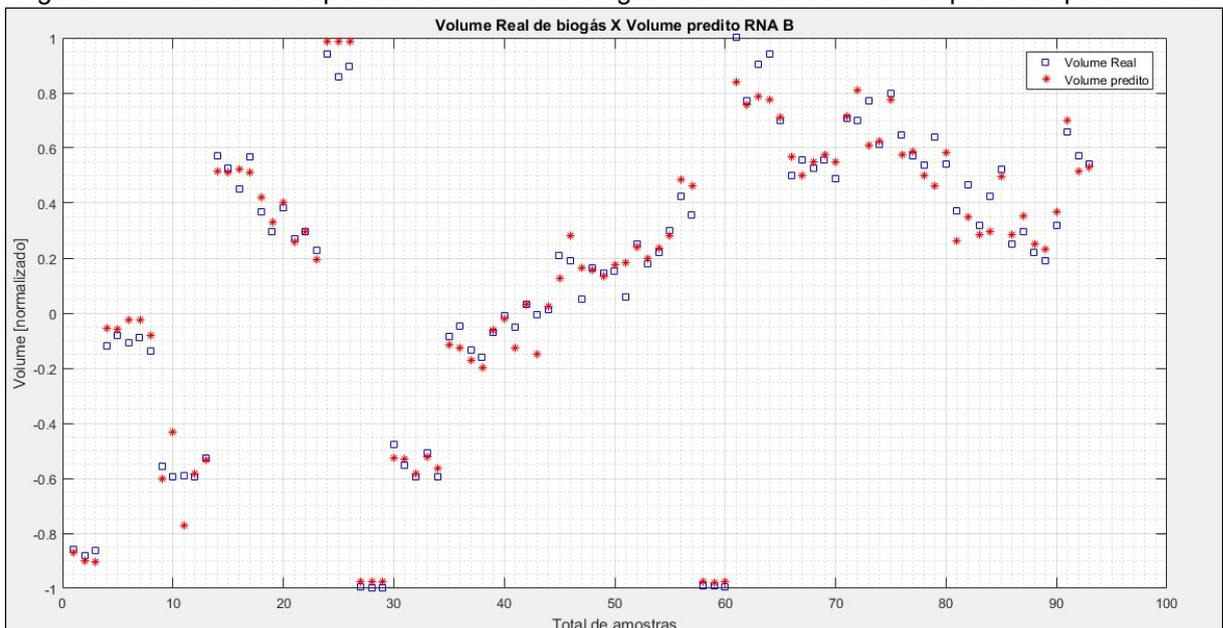
Fonte: Elaborado pelo autor (2019)

O coeficiente de correlação  $R=0,97893$ , encontrado durante a validação, mostra uma boa aproximação dos resultados de saída obtidos pela rede. No teste feito

com 15% das amostras do GRUPO A, este índice teve um pequeno aumento, representando  $R=0,98402$  e mostrando uma convergência entre a validação e os testes. Um coeficiente médio final  $R=0,98979$  foi obtido, onde os resultados de estimação foram computados em sua totalidade, levando em consideração todas as amostras e seus respectivos resultados das etapas de treinamento, validação e testes.

Para uma melhor avaliação, os resultados de predição obtidos pela saída da rede RNA B 15 foram divididos entre saída de biogás e saída de metano, onde cada resultado de estimação foi individualmente avaliado. Os resultados de saída obtidos para o biogás podem ser melhor visualizados no gráfico de dispersão da figura 18, que mostra os valores reais usados como alvos, comparados aos valores estimados da etapa de treinamento e validação. Os quadrados azuis representam os volumes de biogás das amostras usados com *targets* nas etapas de treinamento, validação e testes. Já os asteriscos vermelhos representam os volumes previstos pela RNA\_B 15 nestas mesmas etapas. Novamente, os dados passaram pelo processo de normalização devido a necessidade de não saturação da função de transferência sigmoideal, como já exposto anteriormente.

Figura 18 – Gráfico de dispersão do volume de biogás real versus os volumes previstos pela RNA B



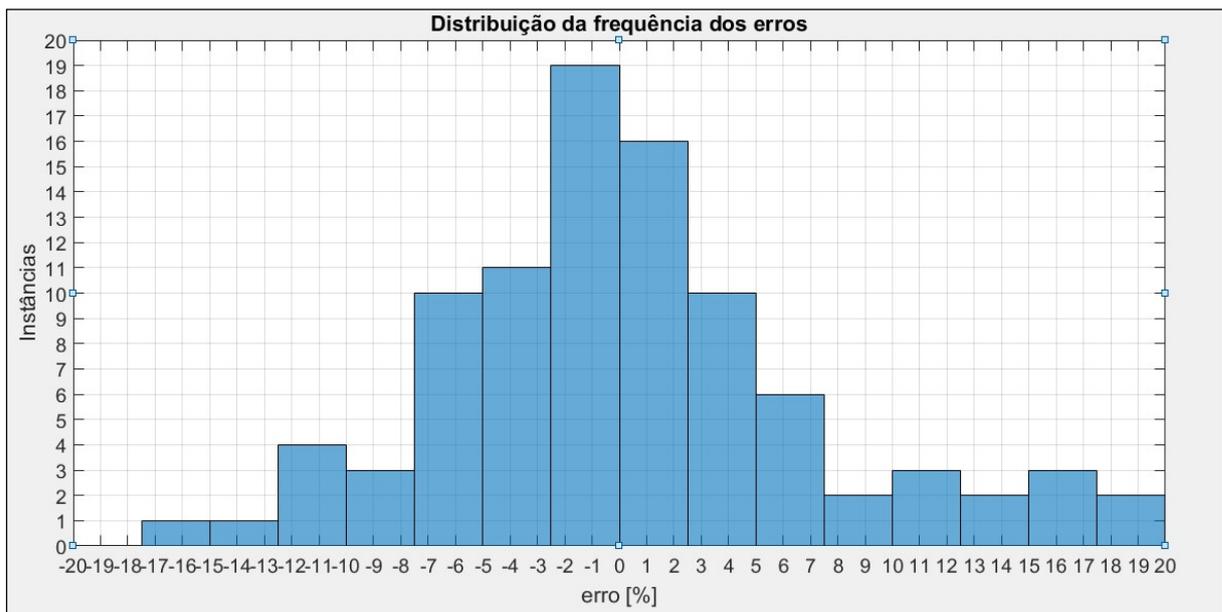
Fonte: Elaborado pelo autor (2019)

Assim como observado na topologia da RNA A, pode-se observar pelo gráfico da figura 18 que existe uma aproximação considerável entre os resultados de saída

para o biogás, obtidos pela predição da rede, e os alvos usados na etapa de treinamento.

A diferença entre os resultados de saída produzidos pela RNA B para o biogás durante o treinamento e os alvos usados nesta mesma etapa, podem ser melhor visualizados através de um gráfico de distribuição de frequência de erros, mostrados através do histograma da figura 19. Pode-se observar que a maior frequência de instâncias se encontra próximo a faixa de valores que tendem ao erro zero, o que mostra um resultado que pode ser considerado satisfatório nesta etapa. Assim como na RNA A, na RNA B alguns desvios foram encontrados, mostrando que a rede desenvolvida poderá mostrar resultados com erros que podem ser julgados inapropriados em determinadas condições de uso.

Figura 19 - Histograma da frequência de erros obtidos para o volume de biometano pela RNA B 15 na etapa de treinamento



Fonte: Elaborado pelo autor (2019)

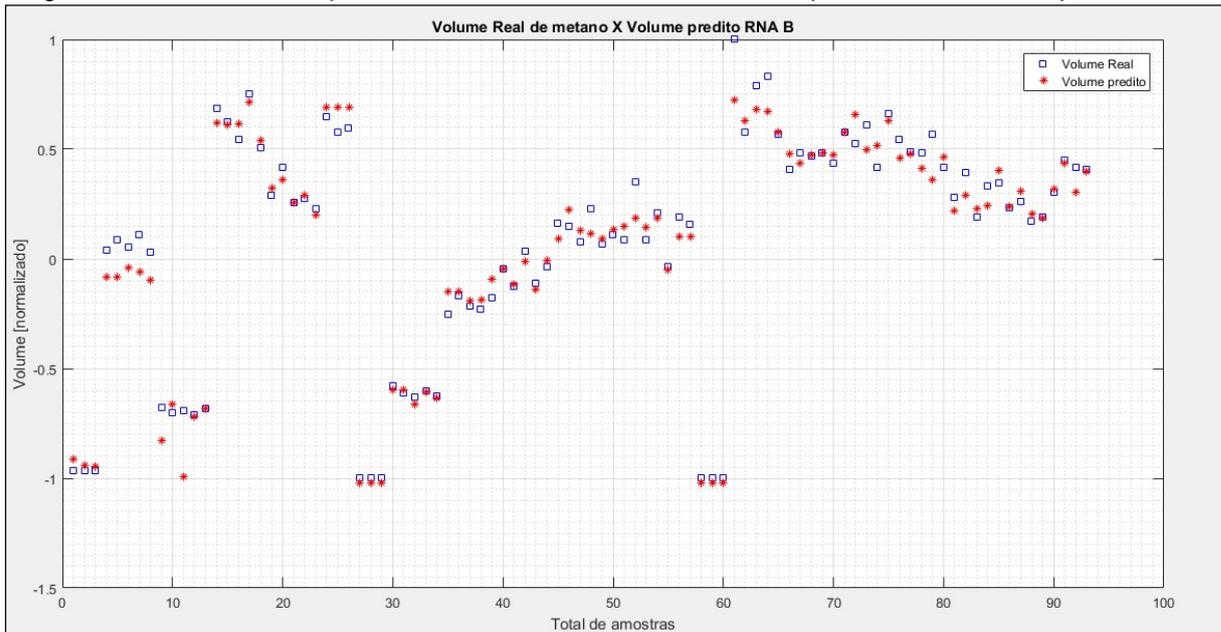
O histograma mostra a frequência de distribuição dos erros quanto ao volume de biogás predito da etapa de treinamento, considerando o conjunto completo de 93 amostras. Das 93 amostras usadas no treinamento, 78 (84,95% das amostras) delas, apresentaram erros máximos de  $\pm 10\%$  e 57 amostras (61,29% das amostras) apresentaram erros máximos de  $\pm 5\%$ .

Nota-se que há uma maior distribuição de erros se comparado aos resultados obtidos pela RNA A, evidenciando que a topologia da RNA B que contém duas saídas

tem mais dificuldades quanto a estimação dos valores de biogás, tendo uma maior quantidade de amostras com erros superiores  $\pm 5\%$ .

Na figura 20, o gráfico de dispersão mostra a relação entre os volumes de Metano presentes no biogás produzido pelas amostras e o volume de predição apresentado pela RNA B 15 na etapa de treinamento e validação.

Figura 20 – Gráfico de dispersão relacionando os volumes reais e previstos de Metano pela RNA B



Fonte: Elaborado pelo autor (2019)

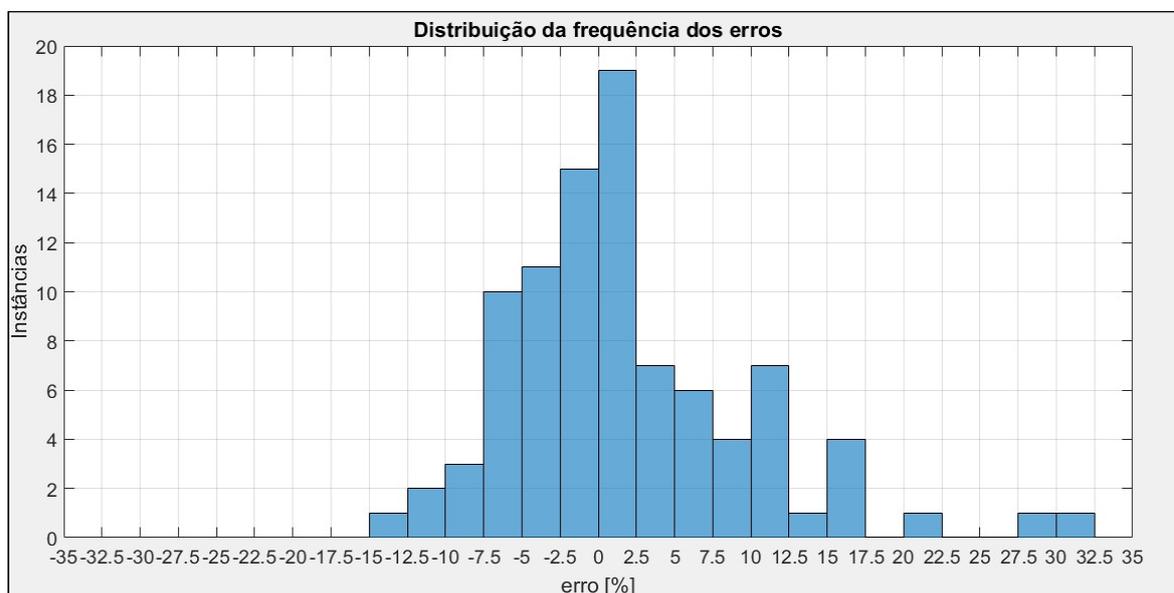
Assim como observado no gráfico de dispersão do volume de biogás mostrado na figura 18, pode-se observar pelo gráfico da figura 20 que existe uma aproximação considerável entre os resultados de saída para o biogás obtidos pela predição da rede e os alvos usados na etapa de treinamento. Contudo, é perceptível que existe uma maior quantidade de amostras que apresentam desvio nos resultados de predição assim como na predição do volume de biogás desta mesma rede.

A diferença entre os resultados de saída produzidos pela RNA B para a predição de metano durante o treinamento e os alvos usados nesta mesma etapa podem ser melhor visualizados através de um gráfico de distribuição de frequência de erros, mostrado através do histograma da figura 21, na sequência. Mais uma vez, observa-se que a maior frequência de instâncias se encontra próxima ao erro zero, o que mostra um resultado que pode ser considerado satisfatório nesta etapa. Assim como visto com a predição do volume de biogás da RNA B 15, alguns desvios foram

encontrados, mostrando que a rede desenvolvida poderá mostrar resultados com erros que podem ser julgados inapropriados em determinadas condições de uso.

O histograma mostra a frequência de distribuição dos erros da etapa de treinamento considerando somente o volume de metano do conjunto completo de 93 amostras. Das 93 amostras usadas no treinamento, 75 (80,64% das amostras) delas apresentaram erros máximos de  $\pm 10\%$  e 52 amostras (55,91% das amostras) apresentaram erros máximos de  $\pm 5\%$ , como pode ser visto na figura 21.

Figura 21 - Histograma dos erros obtidos pela RNA B 15 na etapa de treinamento



Fonte: Elaborado pelo autor (2019)

Assim como para a predição do volume de biogás, nota-se que há uma distribuição de erros maior para a predição do volume de metano. A proporção de amostras com erros de saída maiores do que 0% (zero) aumenta de forma significativa, mostrando que a predição de metano possui uma complexidade maior quando associada à predição do volume de biogás.

Através da análise dos resultados apresentados nos gráficos de regressão linear, apresentados na figura 17, onde a RNA B 15 teve sua funcionalidade validada e testada com uma fração dos dados utilizados no treinamento, pode-se verificar que ela manteve, nestes testes, a mesma ordem do índice de correlação obtido durante o processo de treinamento, mostrando ser funcional.

Observa-se, pelos gráficos de regressão linear na figura 17 que mesmo com alguns erros apresentados durante a predição dos resultados a rede manteve

coerência ao manter os valores estimados em proximidade aos alvos, trazendo confiabilidade à direção dos movimentos de incremento ou decréscimo de produção de biogás e de metano. Em contraponto, verifica-se uma maior dificuldade para manter as taxas de erro próximo a zero, mostrando que a rede tem maior dificuldade de prever duas variáveis na saída.

### 5.3 AVALIAÇÃO DE DESEMPENHO E CAPACIDADE DE ESTIMAÇÃO

A avaliação de desempenho e capacidade de estimação apresentadas neste tópico tem como principal premissa avaliar a capacidade de generalização das redes quando submetidas à entradas de amostras desconhecidas pelas arquiteturas desenvolvidas. Mediante os resultados anteriormente apresentados nas etapas de treinamento, validação e testes das duas topologias de redes neurais criadas, a avaliação de desempenho evidencia, por seus resultados mostrados na sequência, que as redes neurais desenvolvidas podem, de forma aproximada em alguns casos específicos, estimar os volumes de biogás e metano quando as amostras testadas possuem características semelhantes das usadas no treinamento.

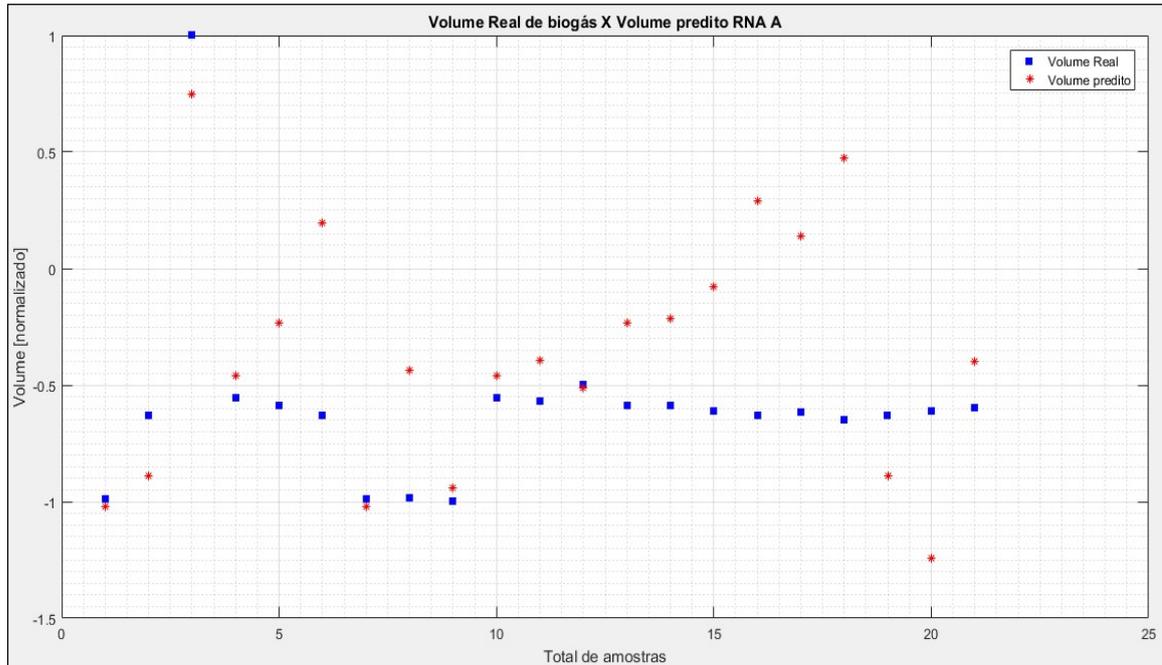
#### 5.3.1 Capacidade de Estimação e Generalização da RNA A

A capacidade de estimação da RNA A 8 leva em consideração o erro de saída produzido pela rede quando submetida aos conjuntos de amostras não utilizados no treinamento da rede. Os resultados mostram, inicialmente, as saídas estimadas produzidas para as 22 amostras do GRUPO B e, na sequência, para as 33 amostras do GRUPO C.

Os resultados de saída encontrados pela RNA A com 8 neurônios na camada oculta, quando solicitada para previsão de produção de biogás das amostras do GRUPO B, mostram uma grande variação nos erros de saída. Enquanto que alguns dos resultados de predição ficaram próximos aos resultados reais com erros na faixa de 0% a 5%, outros apresentaram resultados com erros maiores, onde em alguns casos a estimação de volume de biogás superou em mais de 100% o valor do alvo, evidenciando que a origem dos dados, bem como suas características, influencia diretamente nos resultados de predição.

O gráfico de dispersão na figura 22 mostra os resultados de predição para o GRUPO B, que contém 21 amostras, representados pelos asteriscos vermelhos. Os quadrados azuis representam os valores reais de biogás deste conjunto de amostras.

Figura 22 – Gráfico de dispersão relacionando volumes reais e preditos pela RNA A para o GRUPO B



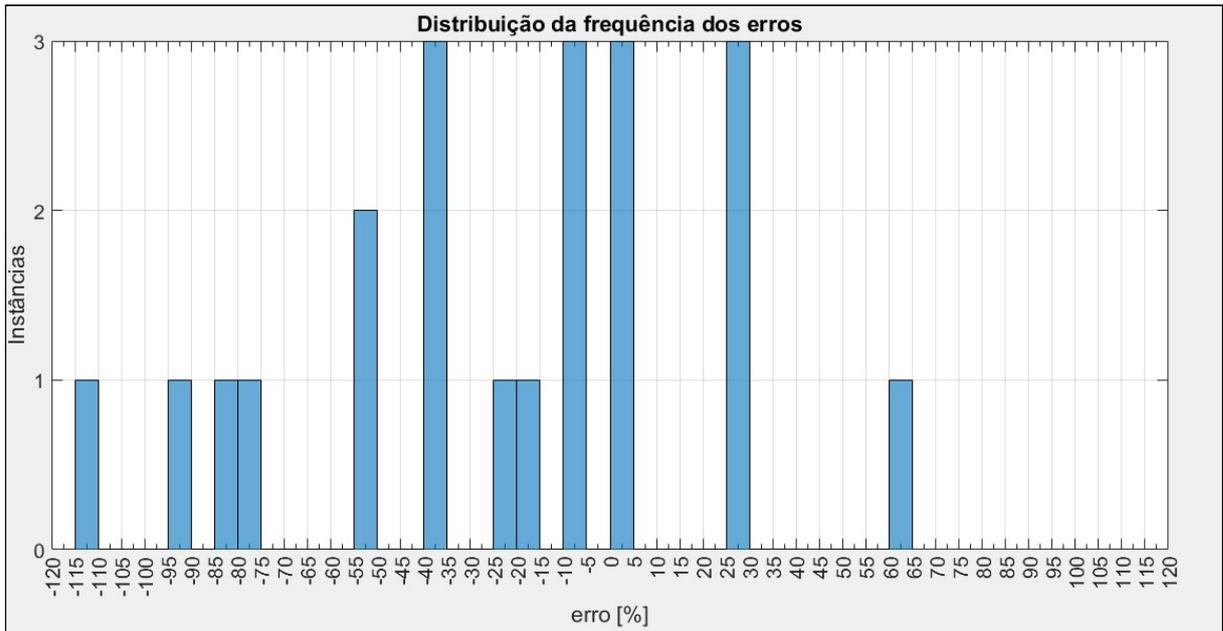
Fonte: Elaborado pelo autor (2019)

Somente 8 das 21 amostras testadas tiveram erros inferiores a 20%. Outro dado importante é que 7 amostras tiveram resultados de estimação abaixo dos volumes usados como alvos e 14 amostras mostraram valores superiores aos alvos.

Em um primeiro momento, fica evidente que a rede não adquiriu conhecimento suficiente para estimação deste grupo de dados quando comparada aos resultados obtidos pela mesma rede nas etapas de validação e testes do GRUPO A, mostrando uma necessidade maior de treinamento ou da utilização de uma maior quantidade de amostras, além de diferentes características usadas como entrada no processo de treinamento.

A variação dos erros, bem como sua distribuição são melhor visualizados no histograma da figura 23, que mostra uma distribuição de frequência dos erros dispersa quando comparada aos resultados obtidos na estimação de volumes dos conjuntos de amostras usados no treinamento da RNA.

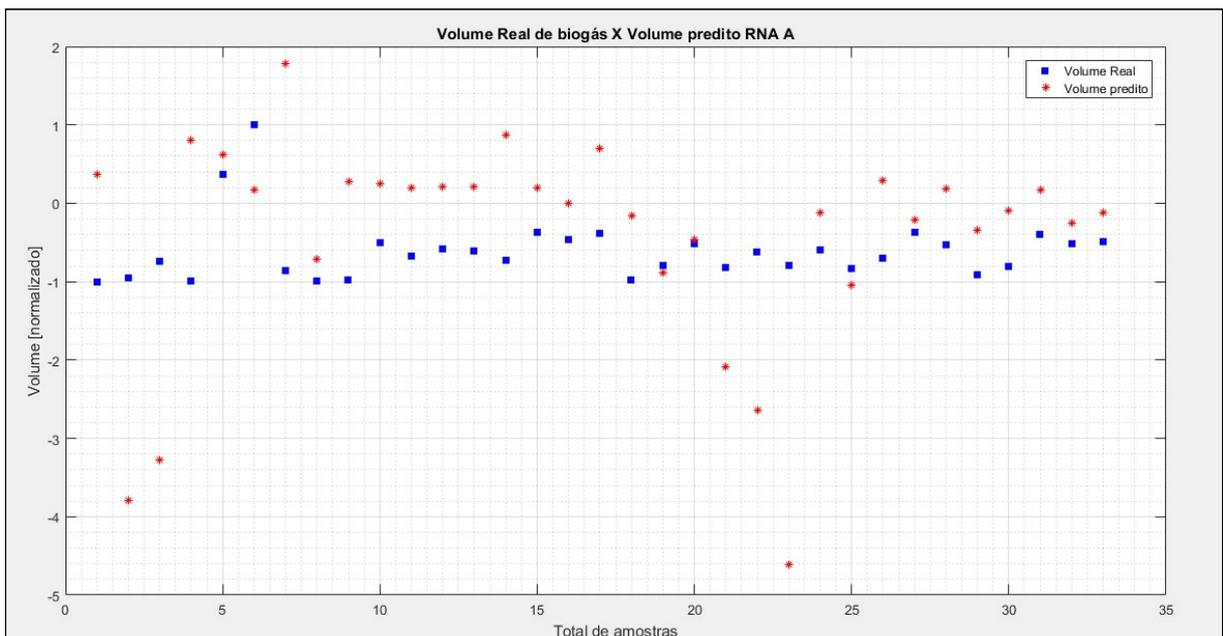
Figura 23 – Histograma de distribuição de erros da RNA A com dados do GRUPO B



Fonte: Elaborado pelo autor (2019)

Na sequência, a mesma rede foi submetida às entradas vindas das 33 amostras do GRUPO C, que possui em sua base resíduos oriundos de outros processos industriais diferentes dos resíduos usados no treinamento da rede neural. Os resultados são ilustrados no gráfico de dispersão da figura 24.

Figura 24 – Gráfico de dispersão relacionando volumes reais e preditos para o GRUPO C

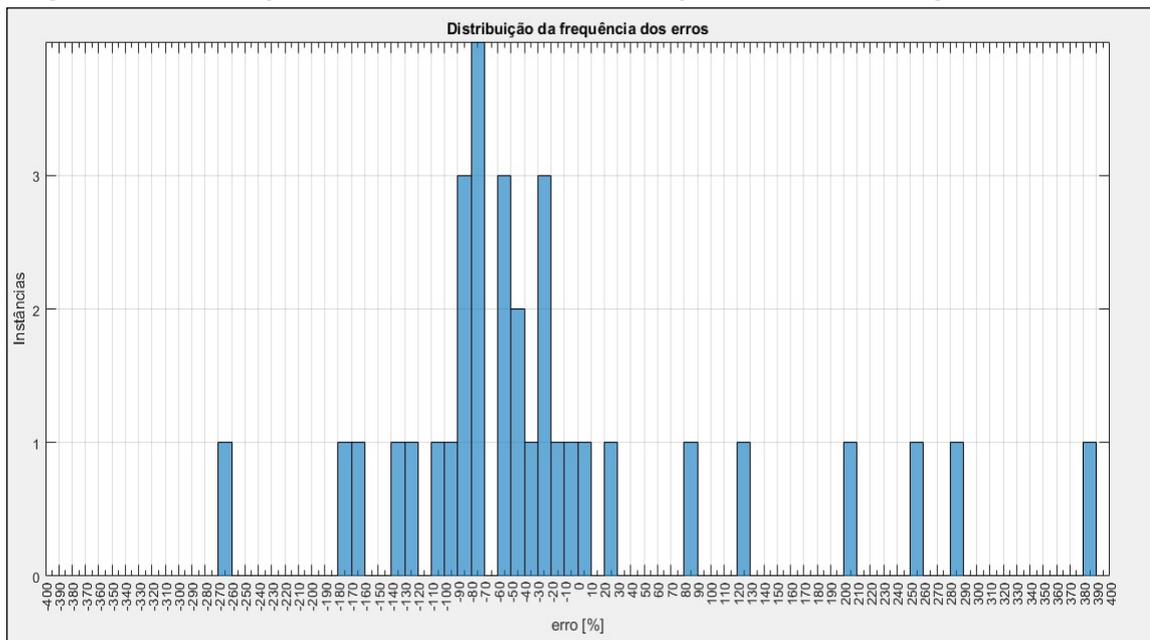


Fonte: Elaborado pelo autor (2019)

O gráfico de dispersão mostrado pela figura 24 aponta, como já ocorrido com a estimação do GRUPO B, que ocorre uma variação considerável nos erros de saída obtidos pela rede. Enquanto que algumas amostras se aproximavam dos valores buscados como alvos, outras, sendo elas a maioria, apresentavam erros de saída maiores e superiores a 100% e até mesmo 300%. Com isso, evidencia-se a incapacidade de estimar de forma precisa e de generalizar resultados de saída quando submetidos a entradas de matérias orgânicas de outras origens.

Assim como realizado anteriormente, um histograma contendo a distribuição de erros é apresentado na figura 25, onde mais uma vez é possível visualizar que uma maior quantidade de amostras tem resultados de estimação com erros que partem de zero aumentando de forma significativa. A distribuição de erros mostra que a rede não consegue generalizar resultados para amostras com características muito diferentes do que as que foram usadas para o seu treinamento.

Figura 25 – Distribuição dos erros da RNA A na estimação do volume de biogás do GRUPO C



Fonte: Elaborado pelo autor (2019)

### 5.3.2 Capacidade de Estimação e Generalização da RNA B

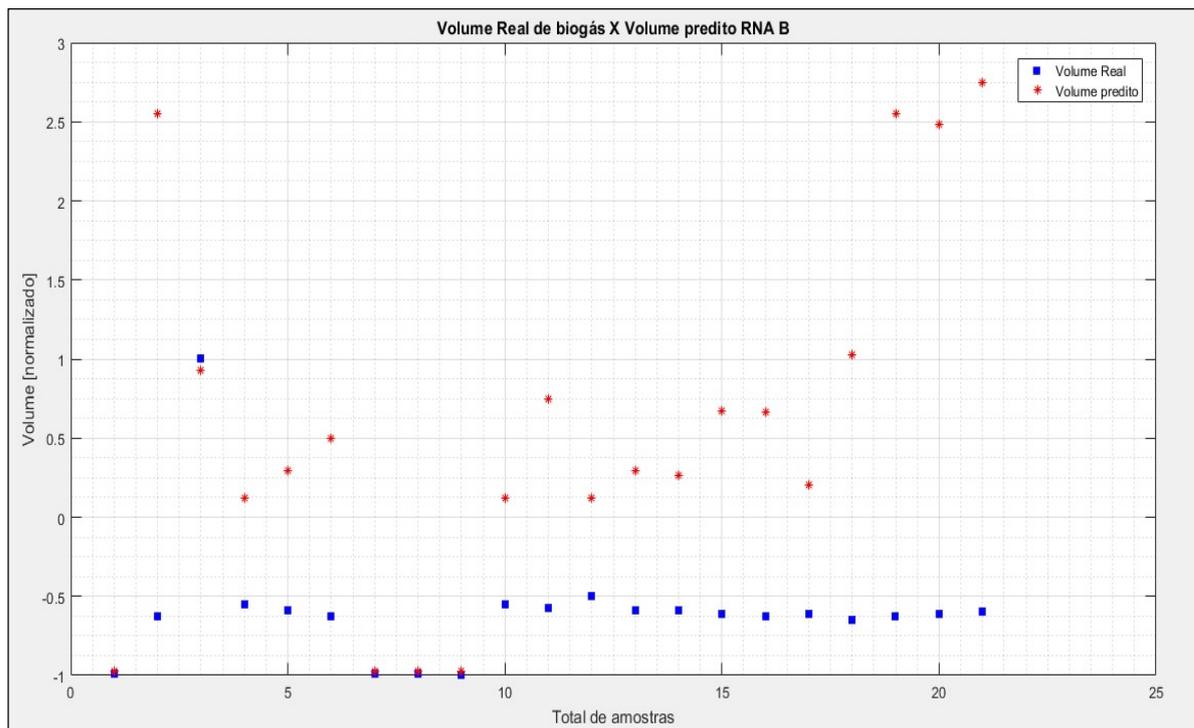
O processo de validação da RNA B 15, assim como realizado para a RNA A avaliada anteriormente, leva em consideração o erro de saída produzido pela rede quando submetida aos conjuntos de amostras não utilizados no treinamento da rede.

Os resultados mostram, inicialmente, as saídas estimadas produzidas para as 22 amostras do GRUPO B e, na sequência, para as 33 amostras do GRUPO C. Os resultados produzidos foram mais uma vez separados entre estimação de biogás e de Metano com intuito de facilitar a análise dos dados obtidos.

Os resultados de saída encontrados pela RNA B com 15 neurônios na camada oculta, quando solicitada para previsão de produção de biogás das amostras do GRUPO B, mostram uma grande variação nos erros de saída, assim como já havia sido evidenciado pela RNA A para o mesmo grupo de dados.

O gráfico de dispersão na figura 26 mostra os resultados de previsão de biogás para o GRUPO B que contém 21 amostras, representados pelos asteriscos vermelhos. Os quadrados azuis representam os valores reais de biogás deste conjunto de amostras.

Figura 26 – gráfico de dispersão dos volumes de biogás (*targets*) versus volumes estimados pela RNA B

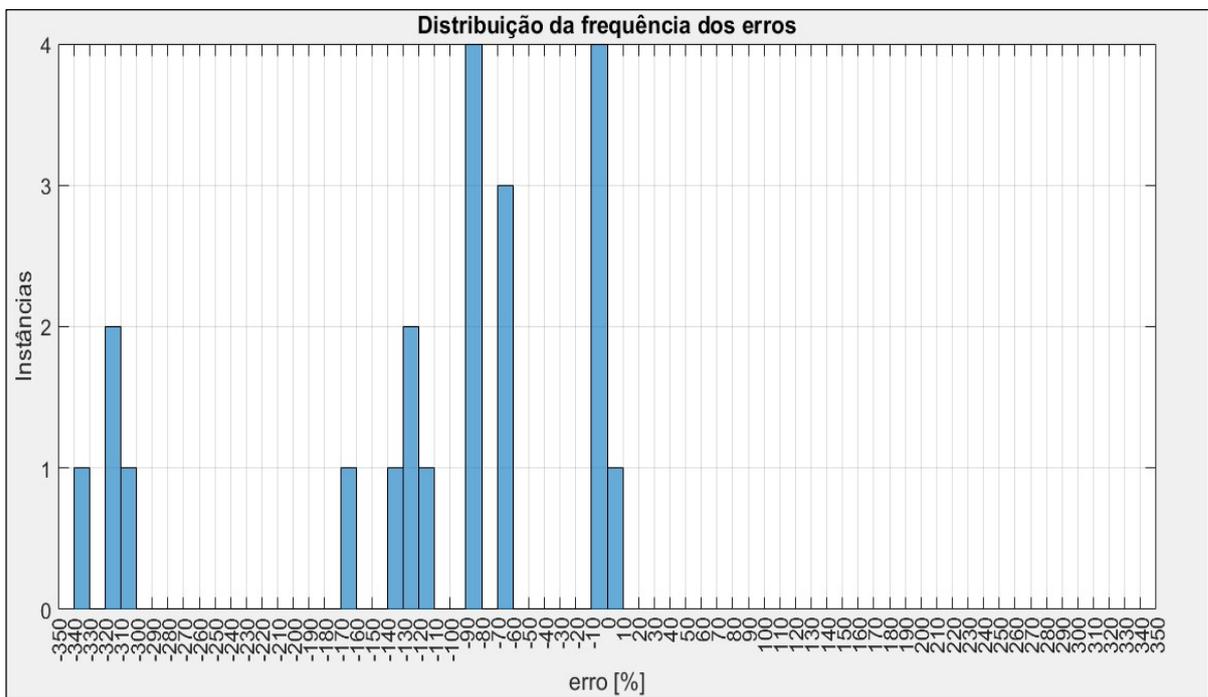


Fonte: Elaborado pelo autor (2019)

Ainda pode-se observar pelo gráfico de dispersão da figura 26 que a rede previu um volume de biogás maior do que os volumes dos alvos em 20 das 21 amostras avaliadas. Algumas saídas obtidas tiveram erros superiores a 300%, como também pode ser visto no histograma.

Nota-se que em somente 5 das amostras a estimaco se aproximaram do volume real de biogs, ficando com erro de at  $\pm 10\%$  na estimaco do volume, o que tambm pode ser visto no histograma da figura 27. O resultado destas 5 amostras com menor erro entre volume real e volume estimado, pode ser explicado ao se realizar um comparativo entre as caractersticas das amostras do GRUPO A e do GRUPO B, que eram semelhantes e haviam produzido resultados de sada aproximados, tornando a convergncia possvel com um menor erro de sada.

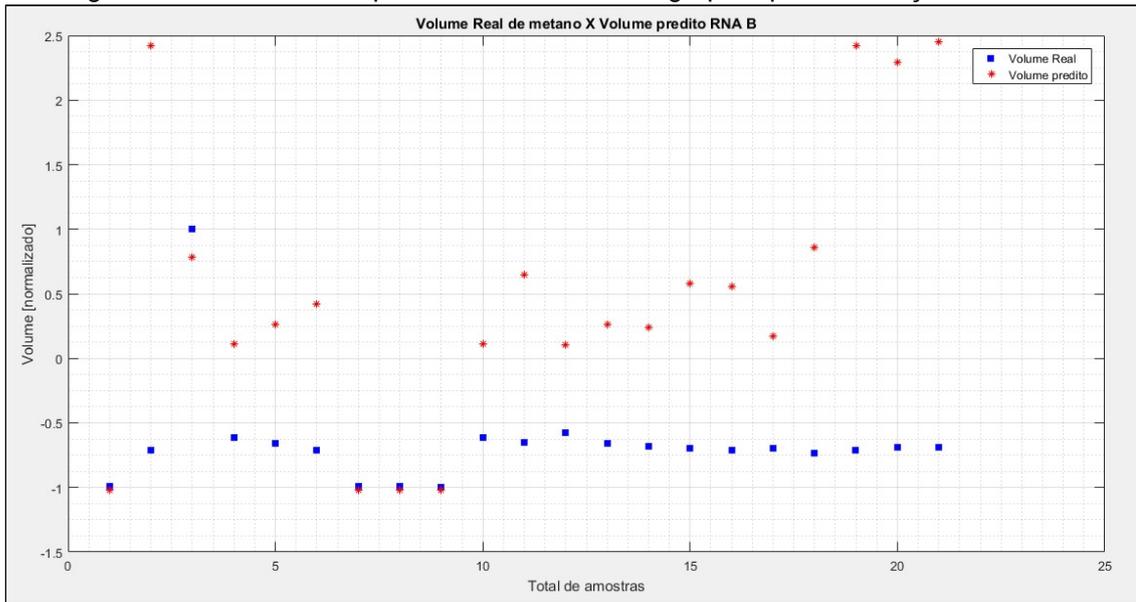
Figura 27 – Histograma com distribuco de erros da RNA B e GRUPO B para Biogs



Fonte: Elaborado pelo autor (2019)

Os resultados obtidos para a estimaco de volume de metano basicamente se repetiram aos resultados do volume de biogs anteriormente avaliado. A produco de metano foi superestimada em 16 das 21 amostras, enquanto que 5 amostras tiveram resultados aproximados aos reais, ficando dentro de uma faixa de  $\pm 10\%$ . Os resultados podem ser vistos no grfico da figura 28. Ainda pode-se observar pelo grfico de disperso que a rede previu um volume maior do que os volumes dos alvos em 14 das 21 amostras avaliadas.

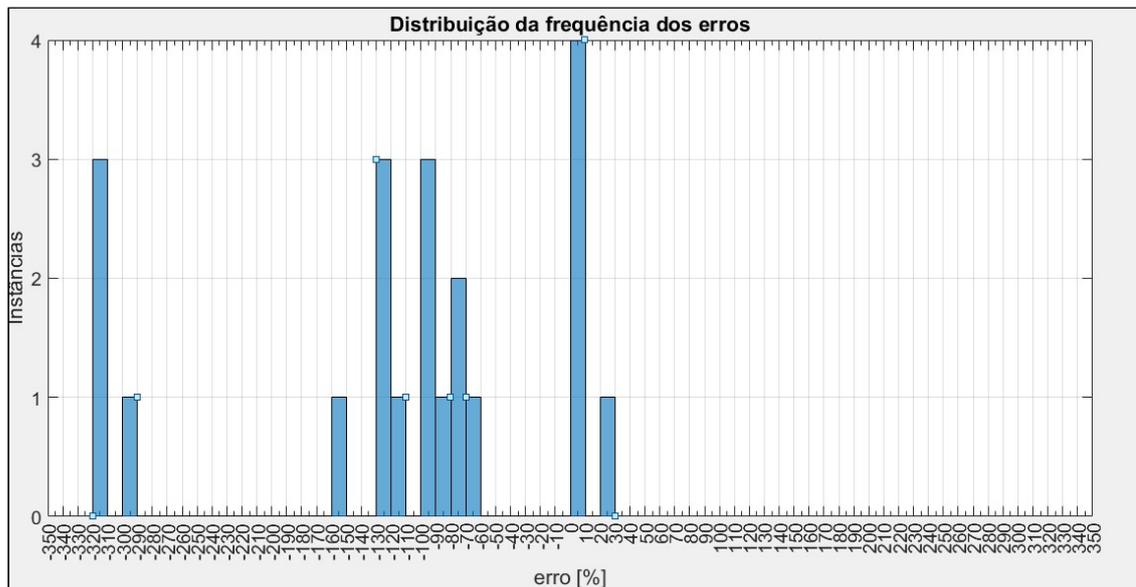
Figura 28 – Gráfico de dispersão das amostras do grupo B para estimação de Metano



Fonte: Elaborado pelo autor (2019)

A variação dos erros bem como sua distribuição, são melhor visualizados no histograma de distribuição de frequência da figura 29, que mostra resultados semelhantes aos obtidos para o volume de biogás já avaliado.

Figura 29 – Histograma com distribuição de erros da RNA B das amostras do GRUPO B para Metano

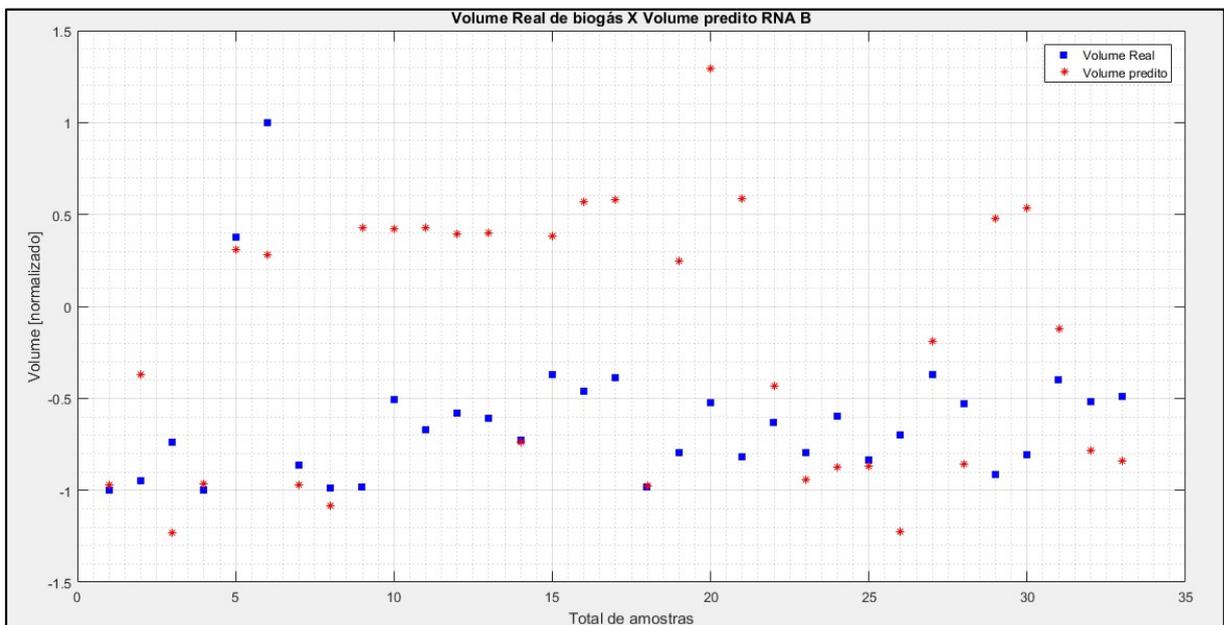


Fonte: Elaborado pelo autor (2019)

Na sequência, a mesma rede foi então submetida às entradas vindas das 33 amostras do GRUPO C, que possui em sua base resíduos oriundos de outros processos industriais diferentes dos resíduos usados no treinamento da rede neural.

O gráfico de dispersão ilustrado pela figura 30 mostra como já ocorrido com a estimação do GRUPO B, que ocorre uma maior variação nos erros de saída obtidos pela rede. Um pouco diferente dos resultados extraídos do GRUPO B, o GRUPO C mostrou uma maior aproximação dos resultados em uma quantidade maior de amostras, mas ao mesmo tempo manteve saídas com erros acima de 50% onde em alguns casos, o volume estimado ultrapassou a escala mínima e máxima dos valores usados em treinamento que era de  $\pm 1$ , valor este que representava os parâmetros de entrada e os volumes de biogás e de Metano de forma normalizada devido as funções de transferência das camadas oculta e de saída da RNA.

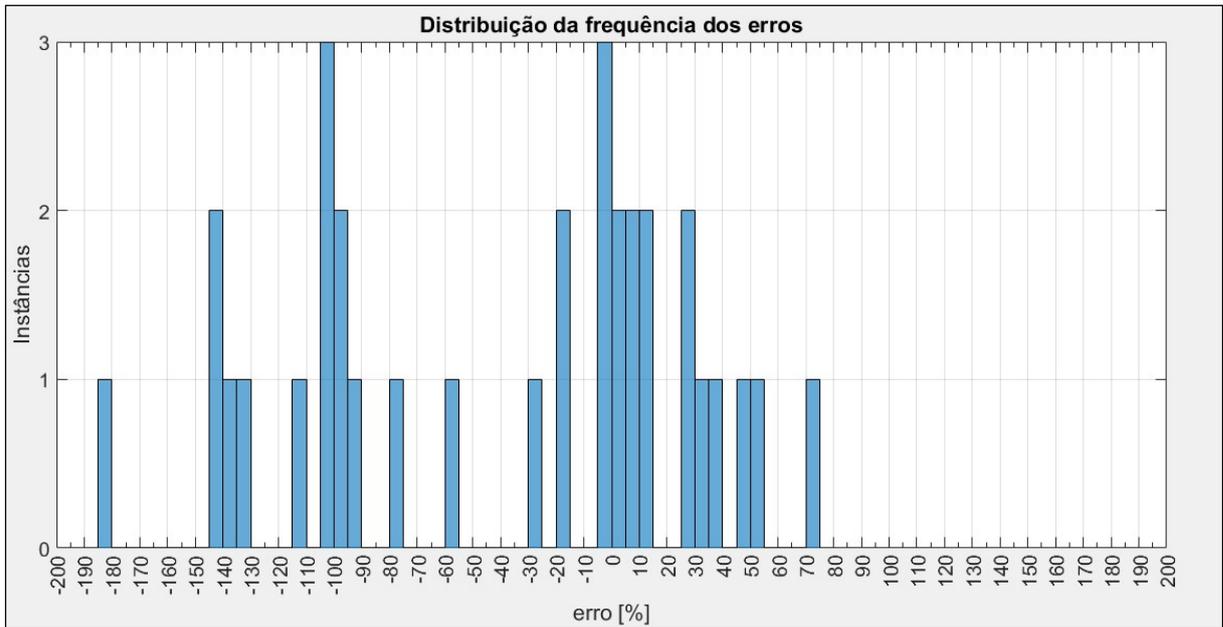
Figura 30 – Gráfico de dispersão das amostras do GRUPO C para estimação do volume de biogás



Fonte: Elaborado pelo autor (2019)

Assim como realizado anteriormente, um histograma contendo a distribuição de erros é apresentado na figura 31, onde é possível visualizar que 5 amostras (15,15%) tiveram erros de saída de  $\pm 5\%$ , se aproximando dos resultados obtidos pela RNA ao estimar volume de biogás das amostras do GRUPO A. Do total de 33 amostras 15 amostras (45,45%) tiveram valores de erro dentro de uma faixa de  $\pm 50\%$ , enquanto que as demais excediam esta faixa, com uma distribuição entre 50% e 185% de erro de estimação.

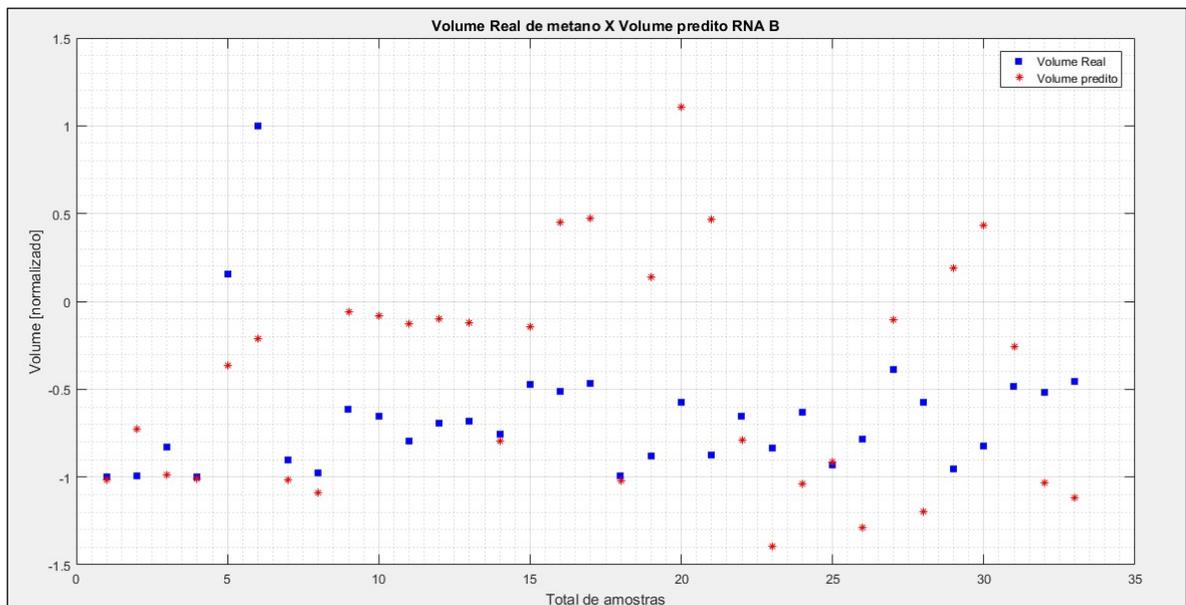
Figura 31 – Distribuição dos erros da RNA B na estimação do volume de biogás do GRUPO C



Fonte: Elaborado pelo autor (2019)

Para a previsão de volume de metano do GRUPO C, o gráfico de dispersão mostrado pela figura 32 aponta como já ocorrido com a estimação do biogás deste mesmo grupo, que ocorre uma maior variação nos erros de saída obtidos pela rede, mais uma vez mantendo coerência com os resultados até aqui apresentados sobre a capacidade de generalização das redes.

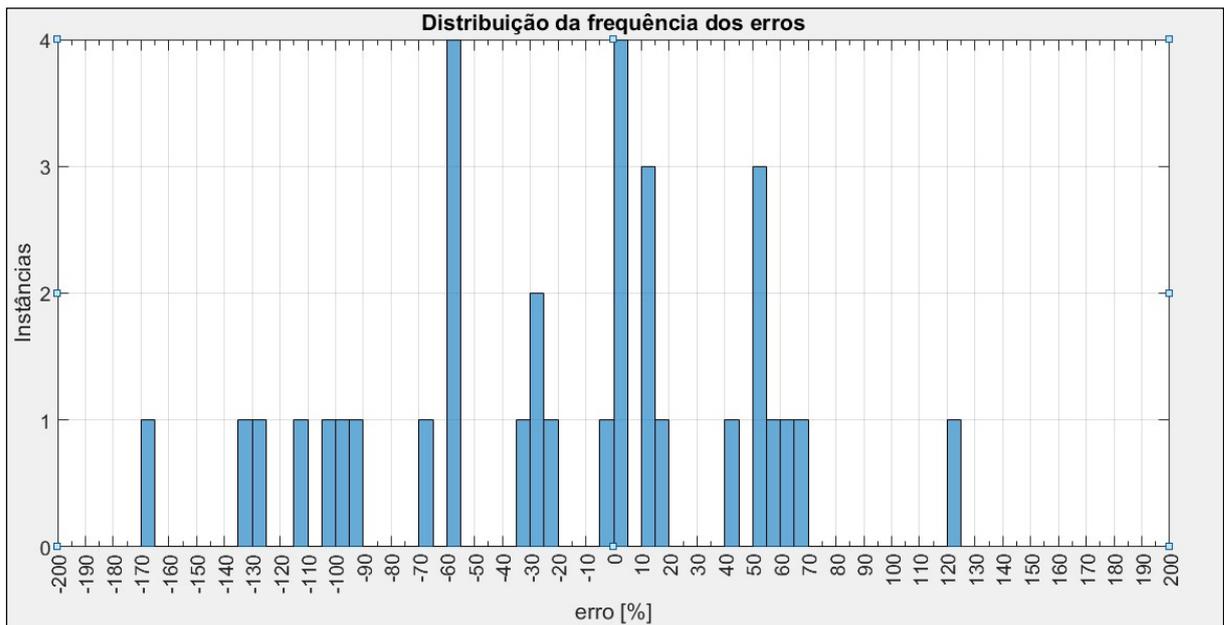
Figura 32 – Gráfico de dispersão das amostras do GRUPO C para previsão de volume de metano



Fonte: Elaborado pelo autor (2019)

Novamente, um histograma contendo a distribuição de erros é apresentado na figura 33, onde mais uma vez é possível visualizar que uma maior quantidade de amostras tem resultados de estimação com erros superiores, que se afastam da faixa de zero. A distribuição de erros mostra que a rede não consegue de uma maneira geral, estimar resultados para amostras com características diferentes do que as que foram usadas para o seu treinamento.

Figura 33 – Distribuição dos erros da RNA B na estimativa do volume de metano do GRUPO C



Fonte: Elaborado pelo autor (2019)

#### 5.4 COMPARAÇÃO DE RESULTADOS

Uma comparação dos resultados obtidos nas etapas de treinamento, validação e testes é mostrada na sequência. Tendo como principal premissa para esta monografia a obtenção de uma ferramenta de IA com base em uma RNA, os resultados obtidos foram então comparados às referências usadas ao longo do desenvolvimento deste trabalho. A comparação teve início pelos resultados obtidos pela RNA A 8, avaliando os índices de correlação e erro quadrático médio durante o desenvolvimento da topologia e, na sequência, pela RNA B 15 que teve os mesmos critérios abordados nas comparações.

### 5.4.1 Comparação de Resultados da RNA A

Através da análise dos resultados apresentados nos gráficos de regressão linear mostrados nas figuras 11,13 e 14 apresentados anteriormente na seção 5, nos subitens 5.1 e 5.2 e fazendo uso dos resultados compilados na tabela 9, onde a RNA A 8 foi treinada, validada e testada com 93 amostras de um banco de dados, pode-se verificar que ela manteve, nestas etapas, a mesma ordem do índice de correlação. Os resultados podem ainda ser comparados aos resultados obtidos pelas referências mostrados na tabela 11 abaixo.

Tabela 10 – Tabela que compara o MSE e o  $R$  obtido ao das referências

Parâmetros	RNA_A_8	Palaniswamy et al. (2016)	Gueguim et al. (2012)
Topologia adotada	4 - 8 - 1	4 - 17 - 1	5 - 2 - 1
Total de iterações	1096	1000	531
Melhor Performance de validação (MSE)	4,29E-03	6,00E-06	1,00E-02
Nº de iterações no melhor MSE	96	100	531
$R$ = Treinamento	0,99152	Não disponível	Não disponível
$R$ = Validação	0,99304	Não disponível	Não disponível
$R$ = Teste	0,98198	0,99600	Não disponível
$R$ = Total	0,98918	0,99850	0,89500

Fonte: Elaborado pelo autor (2019)

Entre as diferentes topologias, a com menor erro médio quadrático de saída foi a de Palaniswamy et al. (2016), que também apresentou o coeficiente de correlação mais próximo a 1 (um). O índice de correlação  $R$  total, obtido pela RNA A 8 desenvolvida neste trabalho, superou o resultado obtido por Gueguim et al. (2012), mas se mostrou inferior ao resultado de Palaniswamy et al. (2016). O mesmo ocorreu quanto ao MSE, mantendo a mesma relação.

Entre as referências utilizadas, cabe ressaltar que Palaniswamy et al. (2016) obtiveram 98,3% das amostras testadas com uma variação de  $\pm 4\%$  de erro de saída. Já o resultado obtido por este trabalho mostrou que 66,6% das amostras testadas tiveram erros variando em  $\pm 5\%$ , evidenciando uma menor eficiência.

Há de se ressaltar o fato de que cada um dos autores acima citados, possuía diferentes parâmetros de entrada quando comparados a este trabalho, além de uma

quantidade de amostras também diferentes. Gueguim et al. (2012), buscaram avaliar dentre 5 diferentes matérias orgânicas, a proporção de mistura entre elas que produziria o maior volume de biogás, usando como parâmetro de entrada somente a concentração de cada uma destas matérias orgânicas, deixando de utilizar parâmetros físico-químicos. Já Palaniswamy et al. (2016), também avaliou as combinações de mistura com melhor desempenho de produção, contudo utilizou como entrada para a RNA não só a proporção de mistura, mas também a temperatura do biodigestor, o pH e o TRH.

Os resultados obtidos na etapa de avaliação de desempenho, onde a topologia desenvolvida foi submetida a estimar resultados de volume de biogás de amostras diferentes das usadas em seu treinamento, não foi foco de comparação, uma vez que a proposta dos autores anteriormente citados era de somente treinar, validar e testar suas redes neurais dentro de um grupo de amostras com as mesmas características, não sendo possível uma comparação.

#### 5.4.2 Comparação de Resultados da RNA B

Através da análise dos resultados apresentados nos gráficos de regressão linear apresentados anteriormente na seção 5, subitem 5.1 e 5.2, fazendo uso dos resultados compilados na tabela 10 e mostrados nas figuras 12 e 17, onde a RNA B 15 foi treinada, validada e testada com 93 amostras de um banco de dados, pode-se verificar que ela manteve nestas etapas a mesma ordem do índice de correlação. Os resultados podem ainda ser comparados aos resultados obtidos pelas referências mostrados na tabela 12.

Tabela 11 – Tabela que compara o MSE e o *R* obtido ao das referências

<b>Parâmetros</b>	<b>RNA_B_15</b>	<b>Qdais et al. (2009)</b>	<b>Souwalak et al. (2014)</b>
Topologia adotada	4 - 15 - 2	4 - 3 - 3 - 1	5 - 8 - 3
Total de iterações	1047	100	-
Melhor Performance de validação(MSE)	9,09E-03	6,11E-05	4,01E-02
Nº de iterações no melhor MSE	47	100	100
<i>R</i> = Teste	0,98402	Não fornecido	Não fornecido
<i>R</i> = Total	0,98918	0,87030	0,99850

Fonte: Elaborado pelo autor (2019)

Os resultados obtidos pela topologia da RNA B com 15 neurônios desenvolvida, quando comparada a de Souwalak et al. (2014), mostra um desempenho um pouco superior quanto ao erro quadrático médio obtido pelas saídas. Por outro lado, o índice de correlação total final obtido apresentou um resultado levemente inferior ao da referência acima citada.

Na comparação com os resultados obtidos por Qdais et al. (2009), a RNA B 15 obteve um índice de correlação superior ao encontrado pelas referências. Com uma topologia com duas camadas ocultas, Qdais et al. (2009), obtiveram um melhor resultado quanto ao erro quadrático médio de saída na comparação com a topologia desenvolvida neste trabalho. Os autores consideram seus resultados promissores já que uma aproximação por meio de estimação através de uma RNA foi possível.

Novamente uma comparação fidedigna não pode ser realizada, uma vez que diferentes parâmetros e configurações foram aplicados em cada um dos trabalhos. No entanto, levando em consideração somente os valores de correlação  $R$  e de EQM, a topologia RNA B 15 mostrou ter capacidade de estimar volumes de biogás e de metano quando submetida a treinamento, validação e testes de um determinado grupo de amostras.

Os resultados obtidos na etapa de avaliação de desempenho, onde a topologia desenvolvida foi testada quanto a capacidade de generalização, não foi alvo de comparação de resultados, ficando somente como estudo realizado.

## 6 CONSIDERAÇÕES FINAIS

O trabalho proposto nesta monografia consistiu no desenvolvimento de uma ferramenta matemática baseada em RNA's com capacidade de prever, de forma estimada e ágil, os volumes de produção de biogás e metano em um processo de biodigestão, servindo como instrumento de apoio na tomada de decisão de investimentos na área de energias renováveis.

A partir do que foi exposto e dos resultados apresentados, cabe destacar a necessidade de agrupar uma grande quantidade de dados de experimentos, além de determinar os parâmetros que deveriam ser usados no processo de desenvolvimento. A disponibilidade limitada de amostras, bem como a delimitação dos parâmetros também por disponibilidade, foram fatores determinantes quanto à escolha das topologias adotadas e das possibilidades de desenvolvimento das redes neurais.

Foi possível observar que a quantidade de dados disponíveis para a etapa de treinamento, validação e testes foi suficiente. Contudo, devido à grande possibilidade de variações e combinações dos parâmetros de entrada, as redes ficaram com precisão limitada à grupos de amostras com as mesmas características do grupo de amostras usados no desenvolvimento das topologias criadas. Ainda pode-se destacar a limitação ao acesso de diferentes parâmetros usados como entrada das RNA's, já que não só os teores de sólidos e o pH das amostras são fatores que influenciam na produção de biogás e na proporção de metano presente neste biogás. A falta destes parâmetros no processo de treinamento das redes não possibilitou uma melhor avaliação quanto aos seus impactos nos volumes produzidos e tão pouco quanto as estimativas previstas pelas redes quando submetidas a diferentes matérias orgânicas.

Esses fatos citados podem ser observados a partir dos resultados de estimativas das redes RNA A e RNA B, quando submetidas a entrada de parâmetros com características e origens diferentes das que foram usadas no desenvolvimento das redes. Na etapa de treinamento, ao utilizar dados do GRUPO A, o índice de correlação  $R$  obtido por ambas as topologias quando comparado às referências foi considerado satisfatório. Já quando submetido aos dados do GRUPO B e GRUPO C, este índice caiu drasticamente, evidenciando que a origem diferente dos dados possui grande influência na capacidade de predição das redes.

Também há de se destacar as diferentes propostas dos autores, onde cada um deles utilizou diferentes parâmetros como entrada das redes, evidenciando que uma

quantidade maior de parâmetros era necessária quanto a possibilidade de treinar as redes neurais para que pudessem generalizar resultados de estimativa de volume de qualquer matéria orgânica que quisesse ser testada. Essa possibilidade de variações vai ao encontro dos diferentes resultados que um sistema biológico pode produzir por não ter um comportamento linear.

Nenhum dos autores referenciados buscou submeter sua rede neural a um novo conjunto de amostras, como realizado nesta monografia, ficando limitados a um conjunto que permitia à rede o conhecimento necessário para que fosse apta a prever resultados de saída. Esse fato trouxe um desafio a este trabalho, já que o mesmo passou por estes testes e mostrou resultados que não puderam ser comparados às referências. Tendo como base este fato, fica evidente uma potencial oportunidade de continuidade deste trabalho e que o mesmo passa a servir de referência para estudos nesta área, levando em consideração que uma ferramenta como as RNA's, se corretamente implementadas tem capacidade de estimar resultados de amostras de qualquer origem.

Com isso, trabalhos futuros podem ser sugeridos aplicando uma metodologia semelhante, mas com algumas melhorias que podem trazer resultados mais promissores. Uma maior base de dados é de extrema importância para que uma rede neural possa ser desenvolvida, o que traria um conhecimento mais amplo à rede.

Parâmetros citados no referencial teórico e usados por alguns dos trabalhos de referência tem impacto significativo no desempenho de processos de biodigestão, tornando-os imprescindíveis para o desenvolvimento de uma rede neural mais assertiva quando submetida a um conjunto de dados desconhecidos, o que pode ser proposto na continuidade dos estudos futuros sobre este trabalho. Cabe destacar a relação Carbono/Nitrogênio, a temperatura, o tempo de retenção hidráulica, a alcalinidade e até mesmo a proporção da mistura de diferentes matérias orgânicas. A combinação destes parâmetros tem influência direta não só sobre a produção de biogás, mas também sobre o percentual de metano presentes neste biogás.

Ainda sobre a evolução do tema desta monografia, caberia uma implementação com monitoramento em tempo real de algumas das variáveis, o que poderia controlar o desempenho de um sistema de biodigestão. O monitoramento poderia antever combinações de parâmetros prejudiciais a biota, atuando sobre o controle da planta de modo a evitar essas condições. Da mesma forma, o sistema com controle em tempo real poderia propor, em tempo integral, a melhor combinação de entradas e

parâmetros, buscando sempre o ponto de maior eficiência do sistema e com isso, produzindo a maior quantidade de biogás e o maior percentual possível de Metano.

No que tange as questões ambientais, a possibilidade de avaliação de uma potencial produção de biogás da decomposição de resíduos de qualquer origem, tema proposto por esta monografia, poderia contribuir no aumento de possíveis sistemas de biodigestão para tratamento de resíduos. Boa parte dos sistemas de biodigestão atual tem como principal premissa, o tratamento de resíduos e deixam de lado seu potencial energético. Esse potencial poderia ser explorado viabilizando uma maior implementação de sistemas de biodigestão, aumentando assim o tratamento de resíduos e desta forma contribuindo com o meio ambiente.

Outra questão que pode ser colocada é que determinados resíduos que hoje são destinados a aterros, desde que caracterizados como próprios para processos de decomposição, poderiam ser agregados a processos de biodigestão aumentando o potencial energético além de resolver o problema da disposição incorreta destes resíduos, ajudando o meio ambiente e reduzindo custos operacionais com destinação inapropriada.

## REFERÊNCIAS

- AQUINO S. F.; CHERNICHARO, C. A. L. Acúmulo de ácidos graxos voláteis (AGVs) em reatores anaeróbios sob estresse: causas e estratégias de controle. **Engenharia Sanitária e Ambiental**, v. 10, n.2, p. 152-161, 2005.
- ARTERO, A. O. **Inteligência Artificial Teórica e Prática**. São Paulo: Livraria da Física, 2009.
- BACKES, G. M. **Avaliação do processo de digestão anaeróbia na geração de energia a partir de dejetos suínos e bovinos de leite com suplementação de glicerina residual bruta oriunda da produção de biodiesel**. 2014. 108f. Centro Universitário Univates. Programa de pós-graduação stricto sensu. Mestrado em ambiente e desenvolvimento. Universidade do Vale do Taquari. Lajeado, 2014.
- BATSTONE, D. J. et al. **The IWA Anaerobic digestion model No 1. (ADM1)**. Journal Water Science and Technology, v.45, n.10, 65-73.mai. 2002.
- BIOGÁS TEM POTENCIAL EQUIVALENTE A 25% DA ENERGIA DO PAÍS, APONTA ABIOGÁS**. Disponível em: < <https://www.abiogas.org.br/potencial-biogas-canal-energia> >. Acesso em: 10 out. 2018.
- BISCHOFBERGER, W. et al. **Anaerobtechnik**. Verlag Springer: Berlin Heidelberg, 2005.
- BLEY JR, C. **Biogás: a energia invisível**. 2. ed. São Paulo: CIBiogás; Foz do Iguaçu: ITAIPU Binacional, 2015.
- BOE, K., et al. State indicators for monitoring the anaerobic digestion process. **Journal Water Research**, v. 44, n. 20, p. 5973-5980, dez. 2010.
- BOX, G. E. P. et al. **Statistics for experimenters**. An introduction to design, data analysis and model building. Nova York: Editora Wiley, 1978.
- BRAUN, P. and HUBER, J. **Ammonia toxicity in liquid piggery manure digestion**. Journal Biotechnoly Letters, Vol. 3, ed. 4, p. 159-164.Austria 1981.
- CANAL Jornal da Bioenergia – **Uso de biometano em frotas de veículos pesados**, publicado em 08 de Março de 2019. Disponível em: <http://www.canalbioenergia.com.br/uso-de-biometano-em-frota-de-veiculos/> acesso: Junho de 2019.
- CENBIO. Nota Técnica VII – **Geração de energia a partir do biogás gerado por resíduos urbanos e industriais**. Florianópolis, SC, 2001. Disponível em: [http://cenbio.iee.usp.br/download/documentos/notatecnica\\_vii.pdf](http://cenbio.iee.usp.br/download/documentos/notatecnica_vii.pdf). Acesso em: out. 2018.
- CENBIO. **Medidas mitigadoras para a redução de emissões de gases de efeito estufa na geração termelétrica**. Brasília: Aneel. 2001.

CHEN, T. H.; SHYU, W. H., **Chemical characterization of anaerobic digestion treatment of poultry mortalities**. Journal Bioresource Technology, v. 63, ed. 1, p. 37-48. Taiwan 1998.

CHERNICHARO, C.A.L. **Princípios do tratamento biológico de águas residuárias: reatores anaeróbios**. Belo Horizonte: Departamento de Engenharia Sanitária e Ambiental, Universidade Federal de Minas Gerais, 1997.

CLAASSEN et al. **Utilization of biomass for supply of energy carrier**. Journal Applied microbiology and biotechnology, v.52, ed. 6, p. 741-755, nov. 1999.

COSTA, D. F. da. **Geração de energia elétrica a partir do biogás de tratamento de esgoto**. São Paulo. 194p, 2006.

DATA Science Academy. **Deep Learning Book**, 2019. Disponível em: <<http://www.deeplearningbook.com.br/>>. Acesso em: 01 de Julho de 2019.

DEGANUTTI, R. et al. **Biodigestores rurais: modelos indiano, chinês e batelada**. 2002. Disponível em: [http://www.agencia.cnptia.embrapa.br/Repositorio/Biodigestores\\_000g76qdzev02wx5ok0wtedt3spdi71p.pdf](http://www.agencia.cnptia.embrapa.br/Repositorio/Biodigestores_000g76qdzev02wx5ok0wtedt3spdi71p.pdf). Acesso em: outubro de 2018.

DOS SANTOS, et al. Esterqueiras: Avaliação Físico-Química e microbiológica do dejetos suíno armazenado. **Eng. Agríc. [online]**, 2007, v.27, n.2, nov. p.537-543. Santa Catarina-SC, 2006.

DROSTE R. L. MASSÉ D. I., **Comprehensive model of anaerobic digestion of swine manure slurry in a sequencing batch Reactor**. Canadá: Elsevier Science, 2000.

EDER, B.; SCHULZ, H. **Biogas Praxis**. Grundlagen, Planung, Anlagenbau, Beispiele, Wirtschaftlichkeit. Verlag Ökobuch: Staufen bei Freiburg, 2007.

FNR, Fachagentur Nachwachsende Rohstoffe. **Handreichung, Biogasgewinnung und nutzung**. Fachagentur Nachwachsende Rohstoffe: Gülzow. 2005.

FORESTI, E. et al. **Tratamento de esgotos sanitários por processo anaeróbio e disposição controlada no solo**. Rio de Janeiro: ABES, 1999.

GUBLER, N. **Erfolgsfaktoren für Biogasanlagen - ein europäischer Vergleich**. Diplomarbeit an der Eidgenössischen Technischen Hochschule Zürich. Institut für Agrarwirtschaft: Zürich, 2006.

GUEGUIM K. E. B. et al. **Modeling and optimization of biogas production on saw dust and other co-substrates using Artificial Neural network and Genetic Algorithm**. Journal Renewable Energy v46, 276-281. 2012.

HAGAN, M.T. H.B.; DEMUTH, M.H. BEALE. **Neural Network Design**, Boston, MA: PWS Publishing, 1996.

HAIDER M.A. et al. **Artificial neural network genetic algorithm approach to optimize media constituents for enhancing lipase production by a soil microorganism**. Journal Applied Biochemistry and Biotechnology 144(3): p. 225–235, jul., 2007.

HAYKIN, Simon. **Redes Neurais: princípios e práticas**. 2. ed. Porto Alegre: Bookman, 2001.

HANREICH A. et al. Metagenome and metaproteome analyses of microbial communities in mesophilic biogas-producing anaerobic batch fermentation indicate concerted plant carbohydrate degradation. **Systematic and Applied Microbiology**, v. 36, n. 5, p. 330–338. 2013

KARLSSON T. et al. **Manual Básico de Biogás**. 1. Ed. Lajeado: Ed. da Univates, 2014. 70p.

KERROUM D. et al. Production of bio-energy from organic waste: effect of temperature and substrate composition. **International journal of energy research**, v. 38, n. 2., p. 270-276. Algeria 2014.

KIM, J. et al. Relationships between analytical methods utilized as tools in the evaluation of landfill waste stability. **Waste Management**, v. 26, n. 12, p. 1349-1356, 2006.

KUMAR YS, et al. Optimisation of fermentation conditions for mango wine production by employing response surface methodology. **International Journal of Food Science and Technology**. 44(11): 2320–2327. 2009.

LABATUT RA, et al. **Conventional mesophilic vs. thermophilic anaerobic digestion: a trade-off between performance stability**. Water Research 53: 249–258. 2014

LAI C.M. et al. **Potentials of food wastes for power generation and energy conservation in Taiwan**. Renewable Energy 34(1): 1913–1915. 2009

LAY J. J. et al. Influences of pH and moisture content on the methane production in high-solids sludge digestion. **Water research**. v. 31 n. 6, p. 1518-1524. 1997

LEPISTO R.; RINTALA J. The effect of extreme temperatures (70–80 °C) on the effluent quality and sludge characteristics of UASB reactors. **Department of Biology and Environmental Science: University of Jyväskylä, Finlândia**, 1996, p. 325-332.

LI, H. et al. Optimized alkaline pretreatment of sludge before anaerobic digestion. **Bioresource Technology**, v.123 p. 189-194, 2012.

MACHAD-EL et. al. **Anaerobic digestion of solid animal waste in an accumulation system at mesophilic and thermophilic conditions, start up**. Department of Agricultural Technology: The Netherlands. 2003

MACHADO G. B., **Biodigestor da cooperativa de Gottingen**, 2013. Disponível em:

<http://www.portaldobiogas.com/biodigestor-da-cooperativa-agricola-degottingen>. Acesso em: 5 out. 2018.

MARCONATO, J.C.; FRANCHETTI, S.M.M.; PEDRO, R.J. Solução tampão: uma proposta experimental usando materiais de baixo custo. **Química Nova na Escola**, n. 20, p. 59-62, 2004.

MARTINEZ E. et al. **Mathematical model of a laboratoryscale plant for slaughterhouse effluents biodigestion for biogas production**. Applied Energy 95: p. 210–219. 2012

MASSÉ, D. I.; DROSTE, R. L. Microbial interaction during the anaerobic treatment of swine manure slurry in a sequencing batch reactor. **Canadian Agricultural Engineering**, v. 39, n. 1, p. 35-41, 1997.

MATOS, C. F. et al. Produção de biogás a partir de dejetos de bovinos de leite, sob sistema orgânico e convencional de produção. **Revista engenharia agrícola**, v. 37, n. 6. 2017.

MOLLER, H. B. et al. Methane productivity of manure, straw and solid fraction of manure. **Biomass and Bioenergy**, 26, p. 485-495. 2004.

NOGUEIRA, L. A. H. Biodigestão: **A alternativa energética**. 1.ed. São Paulo: Nobel, 1986. 93p.

OLIVER, A. P. M. et al. **Training manual on biodigestion**. USAID, Winrokinternational Brasil e Energia e desenvolvimento. Brasil. Versão 2.0. Fevereiro, 2008. Disponível em: <[https://www.academia.edu/6686420/MANUAL\\_DE\\_TREINAMENTO\\_EM\\_BIODIGEST%C3%83O](https://www.academia.edu/6686420/MANUAL_DE_TREINAMENTO_EM_BIODIGEST%C3%83O)> Acesso em: set. 2018.

ORTIZ, L. S. **Energias renováveis sustentáveis: uso e gestão participativa no meio rural**. Porto Alegre: Núcleo Amigos da Terra Brasil, 2005. 67 p.

OZKAYA B. et al. **Neural network prediction model for the methane fraction in biogas from field-scale landfill bioreactors**. Environmental Modelling & Software 22 (2007) 815e822. Disponível em: <http://www.sciencedirect.com>. Acesso em: 5 out. 2018.

PALANISWAMY D. et al. **Optimising biogas from food waste using a neural network model**. Proceedings of the Institution of Civil Engineers Municipal Engineer v. 170 Issue ME4. p. 221–229. 2016.

PARKIN, G. e OWEN, W.F. Fundamentals of anaerobic digestion of wastewater sludges. **Journal of Environmental Engineering**, 112(5), p. 867-920. 1986.

PIND, P. F. et al. Monitoring and control of anaerobic reactors. **Springer Biomethanation II - Advances in biochemical engineering/biotechnology**, v. 82, p. 135-182. 2003

PINTO, C. P. **Tecnologia da digestão anaeróbia da vinhaça e desenvolvimento sustentável**. 1999. 147 f. Dissertação (Mestrado) – Universidade Estadual de Campinas, Campinas, 1999.

POLPRASERT, C. **Organic Waste Recycling**. 3. ed. London: IWA Publishing 2007.

PRAKASHAM R.S. et al. Biohydrogen production from renewable agriculture waste blend: optimization using mixer design. **International Journal of Hydrogen Energy** 34: p. 6143–6148. 2009

QDAIS A. H. et al. **Modeling and optimization of biogás production from a waste digester using artificial neural network and genetic algorithm**. Resources, Conservation and Recycling: 54: p. 359-363. 2010.

RAJESHWARI, K.V. et al. **Stateof-the-art of anaerobic digestion technology for industrial wastewater treatment**. Renewable and Sustainable Energy Reviews, v. 4, p. 135-156, 2000.

ROBRA, S. **Uso da glicerina bruta em biodigestão anaeróbica: aspectos tecnológicos, ambientais e ecológicos**. 120f. Dissertação (Mestrado em Desenvolvimento Regional e Meio Ambiente) – Universidade Estadual de Santa Cruz, Ilhéus, 2006.

SALOMON; K R; LORA, E. E. S. **Estimativa do potencial de geração de energia elétrica para diferentes fontes de biogás no Brasil**. Disponível em: [http://florestasenergeticas.com/arquivos/p\\_estimativa\\_brasil\\_17864.pdf](http://florestasenergeticas.com/arquivos/p_estimativa_brasil_17864.pdf). Acesso em: set. 2018.

SÁNCHEZ, E. et al. Effect of substrate concentration and temperature on the anaerobic digestion of piggery waste in a tropical climate. **Process Biochemistry**, v. 37, p. 483-489, 2001.

SITORUS B. et al. Biogas recovery from anaerobic digestion process of mixed fruit–vegetable wastes. **Energy Procedia** 32: p. 176–182. 2013

STEIL, L. **Avaliação do uso de inóculos na biodigestão anaeróbia de resíduos de aves de postura, frangos de corte e suínos**. 2001. 109p. Dissertação (Mestrado em Biotecnologia) - Instituto de Química, Universidade Estadual Paulista, Araraquara, 2001.

STRIK D. et al. Prediction of trace compounds in biogás from anaerobic digestion using the matlab neural network toolbox. **Environmental Modelling & Software**, 20: p. 803–810, 2004

TOERIEN, D. F.; HATTINGH, W. H. J. The microbiology of anaerobic digestion. **Water Research**, 3, p. 385-416, 1969.

TOLMASQUIM, M. T. **Fontes renováveis de energia no Brasil**. Rio de Janeiro: CENERGIA, 2003.

TRISAKTI B, et al. Acidogenesis of palm oil mill effluent to produce biogas: effect of hydraulic retention time and pH. **Procedia Social and Behavioral Sciences** 195: p. 2466–2474, 2015.

VDI 4630. **Fermentation of organic materials. Characterization of the substrate, sampling**, collection of material data, fermentation tests. Germany: Verein Deutscher Ingenieure – VDI, 2006. 92p.

VEIGA A. P. B.; MERCEDES S. S. **Biometano de gás de aterros no brasil: potencial e perspectivas**. Programa de Pós-Graduação em Energia, Instituto de Energia e Ambiente, Universidade de São Paulo (IEE/USP). Butantã – São Paulo/SP. 2015.

VIJAY K.G.; RINTU B. Evolutionary and swarm intelligence-based approaches for optimization of lipase extraction from fermented broth. **Engineering in Life Sciences** 10(3): p. 265–273. 2010.

VINDIS P. et al. **The impact of mesophilic and thermophilic anaerobic digestion on biogas production**. Manufacturing and processing: JAMME, 2009.

ZANETTE, A. L. **Potencial de Aproveitamento Energético do Biogás no Brasil – Dissertação (Mestrado) –Programa de Planejamento Energético Rio de Janeiro: UFRJ/COPPE, 2009. VIII, 97 p.**

ZESHAN, et al. Effect of C/N ratio and ammonia-N accumulation in a pilot-scale thermophilic dry anaerobic digester. **Bioresource Technology**, v. 113, p. 294-302. 2012.

ZHANG C. et al. The anaerobic co-digestion of food waste and cattle manure. **Bioresource technology**, v.129, p. 170-176, 2013.

WAEWSAK C. et al. Neural-fuzzy control system application for monitoring process response and control of anaerobic hybrid reactor in wastewater treatment and biogas production. **Journal of Environmental Sciences**, 22(12) p. 1883–1890, 2010.

WALSH J. L. JR. et al. **Handbook on Biogas utilization**. U.S. Department of Energy. Atlanta: Geórgia, 1988. 156p.

WICHERN, M. et al. Mono fermentation of grass silage under mesophilic conditions: measurements and mathematical modeling with ADM. **Bioresource Technology** 100: p. 1675–1681, 2009.

**ANEXO A – TABELA DOS INSUMOS E SEUS RESPECTIVOS PARÂMETROS, USADOS NO DESENVOLVIMENTO DA RNA  
NAS ETAPAS DE TREINAMENTO E VALIDAÇÃO – GRUPO A**

Tabela 13 construída a partir de um banco de dados fornecido por empresa produtora de ovos em parceria com a Univates, com uma parcela de substratos já testados e avaliados como potenciais matérias orgânicas para produção de biogás em larga escala.

Tabela 12 – Tabela de substratos e parâmetros usados no desenvolvimento da RNA

(continua)

<b>Substrato - composição</b>		<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
Dejeto de aves. efluente de lavagem de ovos IV	Tripl. I - Inóculo - reator 1	6.34	43.70	56.30	7.16	21.00	375.27	46.55
	Tripl. I - Inóculo - reator 2	6.25	42.46	57.54	7.11	21.00	324.56	42.13
	Tripl. I - Inóculo - reator 3	6.31	43.81	56.19	7.24	21.00	366.78	43.55
	Tripl. II - Dejeto de aves - reator 1	28.27	67.21	32.79	7.81	21.00	2089.45	1309.89
	Tripl. II - Dejeto de aves - reator 2	27.45	68.47	31.53	7.78	21.00	2179.36	1368.54
	Tripl. II - Dejeto de aves - reator 3	28.12	67.05	32.95	7.70	21.00	2116	1326.9
	Tripl. II - Dejeto de aves - reator 4	26.63	68.12	31.88	7.84	21.00	2163.25	1397.2
	Tripl. II - Dejeto de aves - reator 5	29.54	65.23	34.77	7.67	21.00	2047.38	1298.34
	Tripl. III - Efluente lavagem de ovo - reator 1	0.37	86.34	13.66	6.41	21.00	1072.25	407.35
	Tripl. III - Efluente lavagem de ovo - reator 2	0.34	85.68	14.32	6.31	21.00	987.66	379.24
	Tripl. III - Efluente lavagem de ovo - reator 3	0.37	87.51	12.49	6.54	21.00	998.54	390.25

<b>Substrato - composição</b>	<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
Tripl. III - Efluente lavagem de ovo - reator 4	0.39	84.89	15.11	6.80	21.00	989.69	364.25
Tripl. III - Efluente lavagem de ovo - reator 5	0.30	88.27	11.73	6.34	21.00	1142.61	398.89
Tripl. IV - Resíduo de ovo - reator 1	16.68	94.96	5.04	6.47	21.00	3691.47	2123.94
Tripl. IV - Resíduo de ovo - reator 2	15.32	93.47	6.53	6.34	21.00	3587.65	2046.33
Tripl. IV - Resíduo de ovo - reator 3	16.49	95.68	4.32	6.47	21.00	3410.22	1946.68
Tripl. IV - Resíduo de ovo - reator 4	16.68	95.24	4.76	6.61	21.00	3678.24	2211.2
Tripl. IV - Resíduo de ovo - reator 5	17.12	93.58	6.42	6.57	21.00	3215.36	1897.54
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos (40x60)- reator 1	10.54	71.39	28.61	6.48	21.00	3051.23	1627.5
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos (40x60)- reator 2	9.87	72.98	27.02	6.38	21.00	3255.2	1789.36
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos (40x60)- reator 3	10.27	71.24	28.76	6.49	21.00	2987.58	1587.31
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos (40x60)- reator 4	10.98	70.40	29.60	6.29	21.00	3054.36	1610.31
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos (40x60)- reator 5	11.27	69.87	30.13	6.48	21.00	2897.34	1548.68
Tripl. VI - Celulose Microcristalina - reator 1	93.91	99.91	0.09	6.97	21.00	4546.62	2078.09
Tripl. VI - Celulose Microcristalina - reator 2	93.91	99.91	0.09	6.97	21.00	4356.69	1986.47
Tripl. VI - Celulose Microcristalina - reator 3	93.91	99.91	0.09	6.97	21.00	4446.99	2010.33

Substrato - composição		sólidos totais [%]	sólidos voláteis [%]	sólidos fixos [%]	pH	TRH [dias]	volume de biogás [ml]	volume de metano [ml]
Dejeto de aves. efluente de lavagem de ovos V	Tripl. I - Inóculo (Material CEBER) - reator 1	3.86	43.31	56.69	8.38	21.00	56.39	0.71
	Tripl. I - Inóculo (Material CEBER) - reator 2	3.84	43.45	56.55	8.41	21.00	48.56	0.5
	Tripl. I - Inóculo (Material CEBER) - reator 3	3.86	43.51	56.49	8.38	21.00	47.11	0.48
	Tripl. II - Efluente lavagem de ovo - reator 1	0.32	83.27	16.73	7.45	21.00	1256.25	529.88
	Tripl. II - Efluente lavagem de ovo - reator 2	0.31	83.47	16.53	7.40	21.00	1087	489.23
	Tripl. II - Efluente lavagem de ovo - reator 3	0.32	85.14	14.86	7.38	21.00	987.45	468.69
	Tripl. II - Efluente lavagem de ovo - reator 4	0.29	84.78	15.22	7.45	21.00	1189.36	504.12
	Tripl. II - Efluente lavagem de ovo - reator 5	0.35	82.17	17.83	7.49	21.00	987.36	470.58
	Tripl. III - Dejeto de aves - reator 1	27.93	68.70	31.30	7.87	21.00	2164.92	943.96
	Tripl. III - Dejeto de aves - reator 2	26.87	69.56	30.44	7.81	21.00	2254.77	1050.36
	Tripl. III - Dejeto de aves - reator 3	29.14	64.25	35.75	7.74	21.00	2054.65	987.87
	Tripl. III - Dejeto de aves - reator 4	27.93	70.12	29.88	7.64	21.00	1989.54	970.54
	Tripl. III - Dejeto de aves - reator 5	26.98	68.79	31.21	7.79	21.00	2201.33	1040.16
	Tripl. IV - Mix Dejeto de Aves + Efluente de Ovos 20x80% - reator 1	4.46	78.62	21.38	7.12	21.00	2346.4	1205.85
	Tripl. IV - Mix Dejeto de Aves + Efluente de Ovos 20x80% - reator 2	5.12	74.56	25.44	7.08	21.00	2246.33	1101.54

<b>Substrato - composição</b>	<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
Tripl. IV - Mix Dejeito de Aves + Efluente de Ovos 20x80% - reator 3	4.12	79.68	20.32	7.12	21.00	2442.65	1304.32
Tripl. IV - Mix Dejeito de Aves + Efluente de Ovos 20x80% - reator 4	4.78	75.65	24.35	7.15	21.00	2347.97	1120.56
Tripl. IV - Mix Dejeito de Aves + Efluente de Ovos 20x80% - reator 5	4.46	79.11	20.89	7.12	21.00	2399.23	1213.1
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos 30x70% - reator 1	6.73	77.04	22.96	7.18	21.00	2847.62	1467.84
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos 30x70% - reator 2	6.78	76.68	23.32	7.31	21.00	2810.87	1449.99
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos 30x70% - reator 3	6.73	75.67	24.33	7.23	21.00	2487.35	1357.59
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos 30x70% - reator 4	6.12	78.10	21.90	6.98	21.00	2748.65	1547.68
Tripl. V - Mix Dejeito de Aves + Efluente de Ovos 30x70% - reator 5	6.45	77.88	22.12	7.18	21.00	2698.56	1347.87
Tripl. VI - Mix Dejeito de Aves + Efluente de Ovos 40x60% - reator 1	10.02	71.46	28.54	7.39	21.00	2717.28	1402.59
Tripl. VI - Mix Dejeito de Aves + Efluente de Ovos 40x60% - reator 2	10.15	70.48	29.52	7.39	21.00	2502.68	1368.54
Tripl. VI - Mix Dejeito de Aves + Efluente de Ovos 40x60% - reator 3	9.78	72.84	27.16	7.28	21.00	2946.54	1702.63
Tripl. VI - Mix Dejeito de Aves + Efluente de Ovos 40x60% - reator 4	9.87	73.15	26.85	7.35	21.00	2784.65	1367.59
Tripl. VI - Mix Dejeito de Aves + Efluente de Ovos 40x60% - reator 5	10.02	71.12	28.88	7.30	21.00	2879.35	1525.68

<b>Substrato - composição</b>		<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
	Tripl. VII - Celulose Microcristalina - reator 1	95.65	99.05	0.95	7.39	21.00	3059.78	1215.49
	Tripl. VII - Celulose Microcristalina - reator 2	94.11	99.95	0.05	7.31	21.00	3346.25	1501
	Tripl. VII - Celulose Microcristalina - reator 3	95.06	99.45	0.55	7.29	21.00	3195.44	1457.5
Dejeto de aves. efluente de lavagem de ovos VI	Tripl. I - Inóculo (Material CEBER) - reator 1	6.09	41.15	58.85	8.16	21.00	71.23	1.07
	Tripl. I - Inóculo (Material CEBER) - reator 2	6.01	41.29	58.71	8.10	21.00	64.23	0.85
	Tripl. I - Inóculo (Material CEBER) - reator 3	6.20	40.58	59.42	8.21	21.00	59.54	0.81
	Tripl. II - Mix Dejeto de Aves + Efluentes de Ovos 20x80 - reator 1	2.88	74.57	25.43	8.30	21.00	4685	2521.68
	Tripl. II - Mix Dejeto de Aves + Efluentes de Ovos 20x80 - reator 2	3.10	72.47	27.53	8.28	21.00	4156.45	1987.31
	Tripl. II - Mix Dejeto de Aves + Efluentes de Ovos 20x80 - reator 3	2.98	73.87	26.13	8.10	21.00	4457.66	2256.25
	Tripl. II - Mix Dejeto de Aves + Efluentes de Ovos 20x80 - reator 4	2.88	75.56	24.44	8.30	21.00	4547.36	2311.21
	Tripl. II - Mix Dejeto de Aves + Efluentes de Ovos 20x80 - reator 5	3.21	71.78	28.22	8.34	21.00	3987.98	1978.47
	Tripl. III - Mix Dejeto de Aves + Efluentes de Ovos 25x75 - reator 1	4.26	74.21	25.79	8.01	21.00	3523.07	1772.71
	Tripl. III - Mix Dejeto de Aves + Efluentes de Ovos 25x75 - reator 2	4.10	76.34	23.66	7.89	21.00	3657.98	1872.32

<b>Substrato - composição</b>	<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
Tripl. III - Mix Dejeito de Aves + Efluentes de Ovos 25x75 - reator 3	3.98	75.68	24.32	8.05	21.00	3587.47	1854.11
Tripl. III - Mix Dejeito de Aves + Efluentes de Ovos 25x75 - reator 4	4.35	73.10	26.90	7.91	21.00	3657.98	1872.32
Tripl. III - Mix Dejeito de Aves + Efluentes de Ovos 25x75 - reator 5	4.26	74.68	25.32	7.95	21.00	3501.23	1812.35
Tripl. VI - Mix Dejeito de Aves + Efluentes de Ovos 35x65 - reator 1	6.32	74.61	25.39	7.58	21.00	4001.72	1987.07
Tripl. VI - Mix Dejeito de Aves + Efluentes de Ovos 35x65 - reator 2	6.23	73.59	26.41	7.44	21.00	3987.59	1926.31
Tripl. VI - Mix Dejeito de Aves + Efluentes de Ovos 35x65 - reator 3	6.01	75.46	24.54	7.67	21.00	4150.5	2032.22
Tripl. VI - Mix Dejeito de Aves + Efluentes de Ovos 35x65 - reator 4	6.51	71.25	28.75	7.58	21.00	3789.47	1789.35
Tripl. VI - Mix Dejeito de Aves + Efluentes de Ovos 35x65 - reator 5	6.37	76.23	23.77	7.50	21.00	4213.35	2098.73
Tripl. VII - Mix Dejeito de Aves + Efluentes de Ovos 40x60 - reator 1	7.70	72.50	27.50	7.44	21.00	3866.17	1949.27
Tripl. VII - Mix Dejeito de Aves + Efluentes de Ovos 40x60 - reator 2	7.89	71.10	28.90	7.34	21.00	3689.65	1875.59
Tripl. VII - Mix Dejeito de Aves + Efluentes de Ovos 40x60 - reator 3	7.98	70.12	29.88	7.59	21.00	3612.54	1871.56
Tripl. VII - Mix Dejeito de Aves + Efluentes de Ovos 40x60 - reator 4	7.10	75.45	24.55	7.64	21.00	3847.23	1978.12
Tripl. VII - Mix Dejeito de Aves + Efluentes de Ovos 40x60 - reator 5	7.45	73.65	26.35	7.48	21.00	3617.25	1789.54

<b>Substrato - composição</b>	<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
Tripl. VIII- Mix Dejeito de Aves + Efluentes de Ovos 45x55 - reator 1	9.45	73.57	26.43	7.18	21.00	3229.43	1612.26
Tripl. VIII- Mix Dejeito de Aves + Efluentes de Ovos 45x55 - reator 2	9.12	75.65	24.35	7.23	21.00	3448	1758.54
Tripl. VIII- Mix Dejeito de Aves + Efluentes de Ovos 45x55 - reator 3	9.56	71.25	28.75	7.35	21.00	3105.77	1498.67
Tripl. VIII- Mix Dejeito de Aves + Efluentes de Ovos 45x55 - reator 4	9.19	72.15	27.85	7.18	21.00	3346.58	1678.64
Tripl. VIII- Mix Dejeito de Aves + Efluentes de Ovos 45x55 - reator 5	9.45	77.68	22.32	7.09	21.00	3578.14	1698.7
Tripl. X - Mix Dejetos de Aves + Efluentes de Ovos 50x50 - reator 1	10.25	73.00	27.00	7.11	21.00	2949.29	1553.58
Tripl. X - Mix Dejetos de Aves + Efluentes de Ovos 50x50 - reator 2	10.01	73.98	26.02	7.05	21.00	3050.68	1587.61
Tripl. X - Mix Dejetos de Aves + Efluentes de Ovos 50x50 - reator 3	10.54	71.29	28.71	7.16	21.00	2874.31	1478.35
Tripl. X - Mix Dejetos de Aves + Efluentes de Ovos 50x50 - reator 4	11.02	70.57	29.43	7.15	21.00	2804.16	1498.33
Tripl. X - Mix Dejetos de Aves + Efluentes de Ovos 50x50 - reator 5	9.92	74.57	25.43	7.10	21.00	3105.68	1645.23
Tripl. XI - Celulose Microcristalina – reat 1	95.12	99.97	0.03	7.10	21.00	3889.43	1829.3
Tripl. XI - Celulose Microcristalina – reat. 2	96.05	99.10	0.90	7.15	21.00	3687.56	1789.49
Tripl. XI - Celulose Microcristalina – reat. 3	97.00	98.98	1.02	7.10	21.00	3621.58	1774.15

Fonte: Elaborado pelo autor (2019)

**ANEXO B – TABELA DE INSUMOS E SEUS RESPECTIVOS PARÂMETROS USADOS NA ETAPA DE VALIDAÇÃO E TESTES DA RNA DESENVOLVIDA – GRUPO B**

Tabela 14 construída a partir de um banco de dados fornecido por empresa produtora de ovos em parceria com a Univates, com dados de matérias orgânicas diversas diferentes dos resíduos já mencionados no ANEXO A.

Tabela 13 - Tabela de substratos e parâmetros usados em testes da RNA desenvolvida

<b>Substrato - composição</b>		<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
	Inóculo	3.72	49.72	50.28	8.71	19.00	475.89	272.19
	Celulose Microcristalina	94.42	99.84	0.16	7.21	19.00	3626.04	1916.47
	Borra de glicerina	93.82	99.58	0.42	7.69	19.00	17958.46	11892.32
	Mix 20-80: Efluente de ovos e dejetos de aves+aliment. Glicerina	3.58	74.87	25.13	7.69	19.00	4282.93	2458.07
Mix Dejetos e Efluente Alimentado com Borra de Glicerina	Mix 30-70: Efluente de ovos e dejetos de aves+aliment. Glicerina	5.23	74.38	25.62	7.69	19.00	4012.28	2219.03
	Mix 40-60: Efluente de ovos e dejetos de aves+aliment. Glicerina	7.85	74.41	25.59	7.79	19.00	3626.35	1892.26
	Tripl. I - Inóculo (Fim de Experimentos anteriores Naturovos) - reator 1	3.72	49.72	50.28	8.71	19.00	475.89	272.19
	Tripl. I - Inóculo (Fim de Experimentos anteriores Naturovos) - reator 2	3.64	51.12	48.88	8.60	19.00	498.57	287.36
	Tripl. I - Inóculo (Fim de Experimentos anteriores Naturovos) - reator 3	3.98	47.56	52.44	8.59	19.00	375.69	215.65

<b>Substrato - composição</b>	<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
Tripl. II - Mix Dejeito de Aves + Efluentes de Ovos 20x80 - reator 1	3.58	74.87	25.13	7.69	19.00	4282.93	2458.07
Tripl. II - Mix Dejeito de Aves + Efluentes de Ovos 20x80 - reator 2	3.78	73.45	26.55	7.77	19.00	4147.33	2259.98
Tripl. II - Mix Dejeito de Aves + Efluentes de Ovos 20x80 - reator 3	3.15	76.44	23.56	7.81	19.00	4766.57	2687.67
Tripl. III - Mix Dejeito de Aves + Efluentes de Ovos 30x70 - reator 1	5.23	74.38	25.62	7.69	19.00	4012.28	2219.03
Tripl. III - Mix Dejeito de Aves + Efluentes de Ovos 30x70 - reator 2	5.64	73.58	26.42	7.61	19.00	3987.34	2057.33
Tripl. III - Mix Dejeito de Aves + Efluentes de Ovos 30x70 - reator 3	5.87	72.85	27.15	7.74	19.00	3789.64	1987.68
Tripl. IV - Mix Dejeito de Aves + Efluente de Ovos 40x60 - reator 1	7.85	74.41	25.59	7.85	19.00	3626.35	1892.26
Tripl. IV - Mix Dejeito de Aves + Efluente de Ovos 40x60 - reator 2	7.66	76.45	23.55	7.81	19.00	3759.35	1964.35
Tripl. IV - Mix Dejeito de Aves + Efluente de Ovos 40x60 - reator 3	8.00	72.12	27.88	7.89	19.00	3466.55	1784.13
Tripl. V - Celulose Microcristalina - reator 1	94.42	99.84	0.16	7.21	19.00	3626.04	1916.47
Tripl. V - Celulose Microcristalina - reator 2	93.56	99.91	0.09	7.20	19.00	3791.1	2006.34
Tripl. V - Celulose Microcristalina - reator 3	93.12	99.95	0.05	7.28	19.00	3897.62	2018.39

Fonte: Elaborado pelo autor (2019)

**ANEXO C – TABELA DE INSUMOS E SEUS RESPECTIVOS PARÂMETROS, COM DIFERENTES ORIGENS, USADOS NO PROCESSO DE TESTES E AVALIAÇÃO DA CAPACIDADE DE GENERALIZAÇÃO DA RNA DESENVOLVIDA – GRUPO C**

Tabela 15 construída a partir de um banco de dados fornecido pela Univates, com dados de matérias orgânicas diversas diferentes dos resíduos usados no desenvolvimento da RNA.

Tabela 14 – Insumos de diferentes origens e seus respectivos parâmetros

(continua)

<b>Substrato - composição</b>		<b>sólidos totais [%]</b>	<b>sólidos voláteis [%]</b>	<b>sólidos fixos [%]</b>	<b>pH</b>	<b>TRH [dias]</b>	<b>volume de biogás [ml]</b>	<b>volume de metano [ml]</b>
Celulose	Tripl. I - Inóculo (Material CEBER)	4.01	45.59	54.40	7.13	28.00	122.17	0.17
	Tripl. II - Celulose (Polpa de Celulose hidrolisada quimicamente)	21.12	99.15	0.85	7.69	28.00	569.44	43.72
	Tripl. III - Celulose (Rejeito de processo da planta de celulose)	23.31	63.66	36.34	6.01	28.00	2479.69	1012.30
Glicerina e Borra de Glicerina	Tripl. I - Inóculo (Material CEBER)	3,43	48,00	52.00	7.37	68.00	142.73	14.58
	Tripl II - Glicerina Ceber	79.94	96.54	3.75	6.66	68.00	12477.41	6955.29
	Tripl. III - Borra de Glicerina	97.93	99.71	0.28	7.69	68.00	18117.14	12026.72
Lodo de Curtume	Tripl. I – Inóculo	1.55	42.64	57.36	6.80	31.00	1371.18	567.74
	Tripl. II - Lodo de Curtume	28.88	47.91	52.09	7.27	31.00	243.04	135.53
	Tripl. III - Celulose Microcristalina	93.92	99.91	0.09	6.83	31.00	300.89	2310.56
Celulose	Tripl. VI - Celulose Microcristalina	93.91	99.91	0.09	6.97	21.00	4546.62	2078.09
	Tripl. VII - Celulose Microcristalina	94,11	99,95	0.04	7.39	21.00	3059.78	1215.49
	Tripl. XI - Celulose Microcristalina	95,12	99,97	0.03	7.10	21.00	3889.43	1829.3
	Tripl. V - Celulose Microcristalina	94.42	99.84	0.16	7.21	19.00	3626.04	1916.47

Substrato - composição		sólidos totais [%]	sólidos voláteis [%]	sólidos fixos [%]	pH	TRH [dias]	volume de biogás [ml]	volume de metano [ml]
Bagaço de Frutas	Inóculo	3.60	58.04	41.96	7.97	32.00	2.559.40	1.452.62
	Celulose Microcristalina	94.32	99.60	0.40	7.21	32.00	5.756.32	3.152.56
	Mix 30-70: Efluente de ovos e dejetos de aves	5.63	74.38	25.62	8.60	32.00	4.952.50	2.924.47
	Mix 30-70: Efluente de ovos, dejetos de aves e bagaço de fruta	8.03	72.71	27.29	6.90	32.00	5.608.01	3.210.10
Dejeto Suíno	Inoculo	4.42	47.74	52.26	7.70	17.00	289.19	19.63
	Dejeto Suíno UPL	7.02	63.76	36.24	7.81	28.00	1937	725.74
	Dejeto Suíno Creche	1.77	74.84	25.16	6.53	28.00	4424.98	2552.31
	Dejeto Suíno Terminação	12.70	67.65	32.35	7.62	23.00	1772.37	742.88
	Sangue suíno	18.49	96.00	4.00	6.87	21.00	3452.53	2084.24
	Pelo Suíno	21.81	92.17	7.83	7.00	28.00	1936.6	978.96
Dejeto Bovino	Lodo flotado dejetos Suínos	6.30	87.18	12.82	6.01	23.00	3740.24	2211.47
	Dejeto Bovino	14.40	60.06	39.94	8.15	23.00	1618.68	407.55
Dejeto Aves	Cama aviário	75.40	72.70	27.30	8.36	21.00	2805.75	1291.57
	Lodo flotado ativado dejetos aves	6.14	94.65	5.35	5.39	23.00	5771.03	3674.05
	Sangue aves	11.17	92.15	7.85	6.29	28.00	4353.38	2552.6
Resíduos Laticínios	Lodo ativado Laticínios	2.23	86.35	13.65	7.25	21.00	882.49	279.74
	Lodo flotado Laticínios	3.51	77.46	22.54	6.60	21.00	1863.82	1073.05
	Leite descartado	10.15	88.70	11.30	4.28	21.00	5520.61	3100.92
MIX diversos	Mix Lodos	5.50	90.50	9.50	5.30	21.00	4432.25	2894.65
	Mix Lodos e Sangue	6.90	91.70	8.30	5.80	21.00	4687.67	3265.27

Fonte: Elaborado pelo autor (2019)

## APÊNDICE A

Tabela 15 – Resultados obtidos para cada topologia da RNA A nas etapas de treinamento, validação e testes

	RNA_A_4	RNA_A_6	RNA_A_8	RNA_A_10	RNA_A_12	RNA_A_15	RNA_A_18	RNA_A_20	RNA_A_22	RNA_A_25
Total de épocas	1049	1051	1096	1108	1027	1047	541	656	449	420
Tempo de treinamento	2 s	2 s	3 s	3 s	3 s	3 s	1 s	2 s	1 s	1s
Performance (MSE)	1,13E-02	4,66E-03	1,59E-03	1,62E-04	1,11E-04	2,42E-07	1,42E-05	5,16E-05	5,16E-05	5,16E-05
Gradiente	7,96E-05	2,27E-05	1,69E-05	2,44E-04	1,20E-02	9,90E-04	3,12E-11	2,36E-11	4,07E-10	1,59E-09
Momento (MU)	1,00E-05	1,00E-07	1,00E-08	1,00E-06	1,00E-07	1,00E-07	1,00E-11	1,00E-11	1,00E-10	1,00E-11
Tentativas de validação	1000 (máx)	368	621	414	417					
Critério de parada	Tentativas de validação	Gradiente	Gradiente	Gradiente	Gradiente					
Melhor Performance de validação (MSE)	1,60E-02	1,61E-02	4,29E-03	2,24E-02	4,39E-03	1,41E-02	6,41E-03	4,82E-03	1,59E-02	1,38E-02
Nº de épocas no melhor MSE	49	51	96	108	27	47	173	35	35	3
R = Treinamento	0,97465	0,97818	0,99152	0,99258	0,97982	0,99627	0,99878	0,99014	0,99639	0,97205
R = Validação	0,97879	0,97293	0,99304	0,95196	0,99333	0,97589	0,99328	0,98903	0,97636	0,98218
R = Teste	0,98863	0,98215	0,98198	0,97705	0,97728	0,98067	0,91541	0,97155	0,98374	0,95211
R = Total	0,97814	0,97840	0,98918	0,98512	0,98193	0,98955	0,97614	0,98821	0,99098	0,97069

Fonte: Elaborado pelo autor (2019)

## APÊNDICE B

Tabela 16 – Resultados obtidos para cada topologia testada para RNA B, nas etapas de treinamento, validação e testes

	RNA_B_4	RNA_B_6	RNA_B_8	RNA_B_10	RNA_B_12	RNA_B_15	RNA_B_18	RNA_B_20	RNA_B_22	RNA_B_25
Total de épocas	1301	1275	1022	1013	1010	1047	1018	1005	1025	1003
Tempo de treinamento	3 s	3 s	2 s	2 s	5 s	3 s	3 s	4 s	4 s	4 s
Performance (MSE)	1,32E-02	5,50E-03	2,24E-03	1,90E-03	9,85E-04	4,21E-04	1,42E-04	1,83E-04	1,04E-05	5,11E-05
Gradiente	5,09E-04	1,70E-05	1,02E-07	4,89E-07	9,23E-04	4,01E-04	2,46E-04	9,99E-05	1,71E-04	3,99E-05
Momento (MU)	1,00E-07	1,00E-07	1,00E-06	1,00E-06	1,00E-08	1,00E-06	1,00E-07	1,00E-06	1,00E-07	1,00E-06
Tentativas de validação	1000 (max)	1000 (máx)								
Critério de parada	Tentativas de Validação									
Melhor Performance de validação(MSE)	1,95E-02	1,16E-02	3,23E-02	2,37E-02	2,58E-02	9,09E-03	1,78E-02	2,35E-02	1,03E-02	1,69E-02
Nº de épocas no melhor MSE	301	275	22	13	10	47	18	5	25	3
R = Treinamento	0,97329	0,98873	0,98494	0,97831	0,97302	0,99481	0,98729	0,98247	0,99056	0,97727
R = Validação	0,97053	0,96795	0,95019	0,96411	0,96386	0,97893	0,97027	0,96196	0,98557	0,97035
R = Teste	0,92669	0,95750	0,96214	0,96243	0,90167	0,98402	0,97758	0,96166	0,94672	0,88718
R = Total	0,96675	0,98223	0,97442	0,97303	0,95623	0,98979	0,98269	0,97558	0,98029	0,96985

Fonte: Elaborado pelo autor (2019)