

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

ANA PAULA MANDELLI

**MODELAGEM DO PERCENTUAL DE METANO EM BIOGÁS PRODUZIDO A
PARTIR DE RESÍDUOS DA PECUÁRIA**

MEDIANEIRA - PR

2022

ANA PAULA MANDELLI

**MODELAGEM DO PERCENTUAL DE METANO EM BIOGÁS PRODUZIDO A
PARTIR DE RESÍDUOS DA PECUÁRIA**

**Modeling of the Percentage of Methane in Biogas Produced from Livestock
Waste**

Dissertação apresentada como requisito para obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador: Eduardo Eyng.

Coorientador: Thiago Edwiges.

MEDIANEIRA - PR

2022



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite que outros remixem, adaptem e criem a partir do trabalho licenciado para fins não comerciais, desde que atribuam ao autor o devido crédito e que licenciam as novas criações sob termos idênticos.



ANA PAULA MANDELLI

MODELAGEM DO PERCENTUAL DE METANO EM BIOGÁS PRODUZIDO A PARTIR DE RESÍDUOS DA PECUÁRIA

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Tecnologias Computacionais Para O Agronegócio da Universidade Tecnológica Federal do Paraná (UTFPR).
Área de concentração: Tecnologias Computacionais Aplicadas À Produção Agrícola E Agroindústria.

Data de aprovação: 26 de Agosto de 2022

Dr. Eduardo Eyng, Doutorado - Universidade Tecnológica Federal do Paraná

Dra. Fabiana Costa De Araujo Schutz, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Leandro Fleck, Doutorado - Universidade Estadual do Mato Grosso do Sul - Uems

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 26/08/2022.

Dedico este trabalho à minha família e aos professores, pelos inúmeros esforços em contribuir com o andamento do projeto.

AGRADECIMENTOS

Aos meus pais, Sérgio e Ivanilde, que me auxiliaram nas horas difíceis.

Aos meus colegas de trabalho, que não me deixaram ser vencida pelo cansaço e de alguma forma me auxiliaram com os compromissos diários.

Aos colegas de curso, que permitiram a troca de experiências, em especial, à Maria Madalena, que, mesmo nos falando pouco, em todas as vezes, me incentivou a não desistir.

Aos meus professores, que contribuíram na construção do meu conhecimento, especialmente ao Prof. Eduardo, orientador, e ao Prof. Thiago, coorientador, pelas orientações prestimosas e trabalho realizado, permitindo que desenvolvesse a pesquisa, mesmo diante das muitas dificuldades as tarefas. O apoio de vocês foi inestimável para meu crescimento e conhecimento.

Ao grupo de pesquisas da Universidade Tecnológica Federal do Paraná (UTFPR), cujos membros foram pacientes e me acompanhar no laboratório, explicando-me todos os processos.

RESUMO

A atividade agrícola é base da economia na região Oeste paranaense, e nas últimas décadas, tem-se observado um crescimento expressivo desse ramo. Todavia, esse cenário tem provocado o aumento da quantidade de resíduos sólidos orgânicos gerados pelos processos agrícolas, requerendo a elaboração de tecnologias de tratamento para esses resíduos. Nesse contexto, a digestão anaeróbia é uma opção viável, pois, além de proporcionar o tratamento adequado do resíduo, gera o biogás como coproduto. O biogás, por conter metano na mistura, pode ser utilizado em sistemas de combustão para conversão da energia térmica ou elétrica. Entretanto, para se avaliar a viabilidade da geração de biogás, sobretudo, o percentual de metano de um determinado resíduo, são necessários ensaios laboratoriais de biodigestão. A estimativa do percentual de metano tem como desvantagem o tempo requerido para que a análise seja concluída, entre 30 e 60 dias. Sendo assim, a utilização da modelagem matemática para avaliar o percentual de metano de um determinado resíduo, sem que houvesse a necessidade da realização do teste, seria de grande valia nas análises de projeto do gênero. Ademais, considerando-se a não linearidade inerente à biodigestão, por envolver bactérias, a utilização das Redes Neurais Artificiais (RNAs) como ferramenta computacional de modelagem pode conferir robustez ao modelo ajustado. Diante disso, este trabalho teve como realizar a modelagem matemática do percentual de metano de resíduos oriundos da pecuária (criação de suínos, bovinos e aves), por meio de RNAs. Como resultados, foi possível verificar que os percentuais de metano se assemelham aos dos ensaios laboratoriais, levando à conclusão de que a RNA foi capaz de prever o percentual de metano no biogás produzido para a maioria das amostras testadas. Entretanto, em algumas amostras, a RNA forneceu respostas sem significado físico, sendo necessária a aplicação de um filtro de modo a permitir que a RNA fornecesse respostas apenas nos casos em que o valor da concentração de metano fosse factível.

Palavras-chave: digestão anaeróbia; redes neurais artificiais; resíduos agroindustriais.

ABSTRACT

The agricultural activity is the basis of the economy in the western region of Paraná, and in recent decades, an expressive growth of this branch has been observed. However, this scenario has caused an increase in the amount of solid organic waste generated by agricultural processes, requiring the development of treatment technologies for this waste. In this context, anaerobic digestion is a viable option because, besides providing the appropriate treatment of the waste, it generates biogas as a co-product. The biogas, because it contains methane in the mixture, can be used in combustion systems for conversion of thermal or electrical energy. However, to evaluate the feasibility of biogas generation, especially the percentage of methane of a particular waste, laboratory tests of biodigestion are necessary. The disadvantage of estimating the percentage of methane is the time required for the analysis to be completed, between 30 and 60 days. Thus, the use of mathematical modeling to evaluate the methane percentage of a given waste, without the need for testing, would be of great value in project analysis of this kind. Furthermore, considering the inherent nonlinearity of biodigestion, since it involves bacteria, the use of Artificial Neural Networks (ANN) as a computational modeling tool can provide robustness to the adjusted model. In view of this, this study aimed at mathematical modeling of the methane percentage of livestock waste (pig, cattle, and poultry farming) using ANNs. As results, it was possible to verify that the methane percentages are similar to those of laboratory tests, leading to the conclusion that the ANN was able to predict the methane percentage in the biogas produced for most of the samples tested. However, for some samples, the ANN provided answers without physical meaning, and it was necessary to apply a filter to allow the ANN to provide answers only in those cases in which the methane concentration value was feasible

Keywords: anaerobic digestion; artificial neural networks; agroindustrial waste.

LISTA DE ILUSTRAÇÕES

Figura 1 - Estrutura de Algoritmo Rede Neural Artificial (RNA)	20
Figura 2 - Analisador elementar de CHNS-O	28
Figura 3 – Estrutura da RNA	30

LISTA DE TABELAS

Tabela 1 - Tabela de Amostras de Resíduos Sólidos	26
Tabela 2 – Banco de dados para treinamento e validação da RNA Modelo 1	32
Tabela 3 - Banco de dados para treinamento e validação da RNA Modelo 2	33
Tabela 4 - Banco de dados para treinamento e validação da RNA Modelo 3	34
Tabela 5 – Resultado da RNA Modelo 1	36
Tabela 6 – Análise dos resultados da RNA Modelo 1 após aplicação do filtro	36
Tabela 7 - Resultado da RNA Modelo 2	37
Tabela 8 - Análise dos resultados da RNA Modelo 2 após aplicação do filtro	38
Tabela 9 - Resultado da RNA Modelo 3	39
Tabela 10 - Análise dos resultados da RNA Modelo 2 após aplicação do filtro	40

LISTA DE GRÁFICOS

Gráfico 1 – Simulação de percentual de metano (CH ₄) da RNA Modelo 1.....	37
Gráfico 2 - Simulação de percentual de metano (CH ₄) da RNA Modelo 2	39
Gráfico 3 - Simulação de percentual de metano (CH ₄) da RNA Modelo 3	40

LISTA DE ABREVIATURAS E SIGLAS

COR	Cortes
CP	Corte a Pasto
CRE	Crechário
LSC	Leite Semi Confinado
LCF	Leite Compost-Barn
PBM	Potencial Bioquímico de Metano
RNA	Redes Neurais Artificiais
TCD	Thermal Conductivity Detector
UPL	Unidade Produtora de Leitões
VDI	Verein Deutscher Ingenieure
T	Temperatura
TER	Terminação
V	Volume
P	Pressão
POS	Postura

LISTA DE SÍMBOLOS

C	Carbono
Ca	Cálcio
CH ₄	Metano
CO ₂	Dióxido Carbono
H	Hidrogênio
H ₂ S	Sulfeto de Hidrogênio
H ₂ O	Água
N	Nitrogênio
NH ₃	Amônia
O	Oxigênio
S	Enxofre
Mg	Magnésio

SUMÁRIO

1	INTRODUÇÃO	13
2	OBJETIVOS	15
2.1	Objetivo geral.....	15
2.2	Objetivos específicos.....	15
3	REVISÃO BIBLIOGRÁFICA	16
3.1	Resíduos na produção pecuária da região Oeste paranaense.....	16
3.2	A importância do processo de digestão anaeróbia e do biogás.....	17
3.3	Modelagem RNA.....	19
3.4	Redes Neurais Artificiais (RNA) como ferramenta para a modelagem de sistemas ambientais	21
4	MATERIAL E MÉTODOS	25
4.1	Coleta e preparo das amostras	25
4.2	Estimativa do percentual de metano	27
4.2.1	Ensaio de biodigestão anaeróbia.....	27
4.3	Caracterização química dos resíduos e do biogás produzido	28
4.3.1	Caracterização química dos resíduos	28
4.3.2	Caracterização química do biogás	29
4.4	Rede neural artificial para modelagem do percentual de metano em biogás produzido a partir de resíduos da pecuária	29
5	RESULTADOS E DISCUSSÃO	32
6	CONSIDERAÇÕES FINAIS	41
	REFERÊNCIAS.....	42

1 INTRODUÇÃO

As atividades agrícola, agropecuária e agroindustrial são a base da economia na região Oeste do estado do Paraná. O crescimento dessa atividade gera um aumento na quantidade de resíduos orgânicos, o que requer a existência de um planejamento para que esses resíduos tenham uma destinação adequada e correta.

Considerando a atenção aos impactos ambientais gerados pelos resíduos da pecuária, o interesse pelo processo de compostagem e de reutilização de resíduos tem sido estimulado. Os dejetos, como esterco das camas de gado leiteiro, de aviário ou mesmo os excrementos suínos depositados em esterqueiras podem ser utilizados como fonte de combustíveis e de fertilizantes, como afirmam Mota *et al.* (2019). Essas culturas produzem uma grande quantidade de resíduos, constituindo-se, efetivamente, um desafio dar um destino correto dos dejetos de forma a causar mínimos impactos ambientais. Nesse contexto, as fontes de energias alternativas aos combustíveis fósseis são recorrentes, além da redução da emissão de poluentes atmosféricos. Os biocombustíveis se destacam como uma alternativa de energia renovável, substituindo as fontes de energia fósseis.

A demanda por meios eficientes de tratar os resíduos orgânicos produzidos pelas atividades da agropecuária, conseqüentemente, também aumentou, sendo necessário desenvolver sistemas de prevenção e de controle para situações visando ao seu reaproveitamento, à reciclagem e ao tratamento. A digestão anaeróbia é uma das alternativas possíveis para o tratamento dos resíduos oriundos da pecuária. Como resultado, tem-se a produção de biogás, que pode ser utilizado como fonte de energia renovável, e o digestato, material que passou por processo de digestão anaeróbia e contém características fertilizantes que podem ser utilizadas como adubo orgânico. No tratamento de resíduos sólidos agropecuários, aumentaram-se os esforços para reduzir os custos de processo. Por meio da modelagem matemática, os processos de digestão anaeróbia possibilitaram diversos benefícios ao se avaliar o potencial de biodegradabilidade dos resíduos na produção de biogás (TRIOLO *et al.*, 2011).

Penteado *et al.* (2018) relatam que o metano é o principal componente do biogás, “[...] podendo atingir concentrações de 55 a 70%; ao passo que o dióxido de carbono compõe uma parcela de 30 a 45% do biogás.” (PENTEADO *et al.*, 2018, p. 27).

Com base na perspectiva da utilização do biogás como fonte de energia, este trabalho científico busca avaliar o percentual de metano produzido com a criação de suíno, bovino e aves. Os resultados dos ensaios podem ser utilizados como recursos para otimização de processos (CARDENAS-CLEVES *et al.*, 2016).

A verificação do percentual de metano é utilizada por pesquisadores para avaliar o potencial energético na produção de biogás de um resíduo (SOHOO *et al.*, 2021). Além disso, a possibilidade de se determinar o potencial de metano, o baixo custo, a reprodutibilidade e a facilidade na instalação são algumas das vantagens da realização do ensaio do Potencial Bioquímico de Metano (PBM). A desvantagem encontrada na realização da verificação do potencial de metano é o tempo elevado para se obter os resultados.

Partindo dessa perspectiva, a utilização de modelagem matemática pode contribuir com a agilidade em identificar sistemas mais eficientes para a produção do biogás, revelando a melhor matéria-prima e embasando os estudos de viabilidade técnica e econômica (LIMA; PASSAMANI, 2012).

Diversas tecnologias vêm sendo desenvolvidas para atender a tal finalidade, entre elas as Redes Neurais Artificiais (RNA), que é uma tecnologia atual e amplamente utilizada em diversas áreas de pesquisas. As RNAs podem ser definidas “[...] como uma estrutura interligada por elementos de processamento simples que são capazes de realizar operações para processamento de dados [...]” (ROCHA; MATOS; FREI, 2011 p. 738).

Assemelhando ao “[...] funcionamento do neurônio biológico típico [...]” (ROCHA; MATOS; FREI, 2011, p. 737), as RNAs utilizam modelos matemáticos para apresentar a classificação de padrões, o agrupamento de dados, as previsões temporais e outras funções. Para que apresentem esses resultados, contudo, é necessário realizar pesquisas e levantamento de informações reais de dados experimentais sobre o que se deseja aplicar, desenvolver uma modelagem e aplicá-la às RNAs.

Nesse contexto, o presente estudo busca a modelagem matemática do percentual de metano de resíduos da pecuária por meio da RNA, fazendo uso da capacidade de processamento dessa ferramenta computacional para alcançar um modelo preditivo do percentual de metano validado estatisticamente.

2 OBJETIVOS

2.1 Objetivo geral

Realizar a modelagem matemática do percentual de metano de resíduos oriundos da pecuária, por meio de Redes Neurais Artificiais (RNAs).

2.2 Objetivos específicos

- Avaliar a relação entre a composição elementar da amostra de resíduos e o percentual de metano;
- Construir um banco de dados para o percentual de metano em biogás produzido a partir de resíduos de pecuária;
- Realizar o treinamento de Redes Neurais Artificiais para estimar o percentual de metano no biogás.

3 REVISÃO BIBLIOGRÁFICA

3.1 Resíduos na produção pecuária da região Oeste paranaense

A região Oeste paranaense tem uma diversificada área de produção agrícola e agroindustrial, considerando as mudanças que ocorrem frequentemente no âmbito científico e tecnológico e que contribuem significativamente para a atividade no campo. A pecuária passou por importantes transformações nas últimas décadas. De acordo com Breitenbach e Souza (2015), foi necessária uma mudança de conduta, visando a uma maior participação de produtores no processo de industrialização. Sendo assim, foi preciso adotar medidas para melhorar a qualidade dos produtos, bem como um destino adequado e economicamente viável aos resíduos da produção.

Furlan *et al.* (2018) relatam que o “[...] aumento do volume de resíduos agrícolas e pecuários gerados, acompanhado do descarte inadequado dos mesmos é um problema mundial crescente [...]” (FURLAN *et al.*, 2018, p. 1), sendo importante realizar o descarte consciente de forma a não agredir o meio ambiente e verificar a possibilidade de reaproveitamento desse resíduo que “[...] resulta na redução de impactos ambientais [...]” (FURLAN *et al.*, 2018, p. 1). Há algumas formas de aproveitamento de alguns resíduos que as tornaram lucrativas, um exemplo é a produção de biogás.

O biogás não é apenas “[...] um subproduto obtido a partir da decomposição anaeróbia [...]”, como explicam Calza *et al.* (2015, p. 991). O biogás tornou-se alvo de muitas pesquisas incentivadas, sobretudo, aspectos econômicos, como a elevação do preço dos combustíveis fósseis, “[...] no intuito de criar novas formas de produção energética que possibilitem a redução do uso dos recursos naturais não renováveis [...]” (CALZA *et al.*, 2015, p. 991).

Barizon (2020) descreve que os “[...] resíduos animais compreendem principalmente dejetos, que são constituídos por fezes, urina e águas de lavagem”. (BARIZON, 2020, p. 22). É uma prática comum à aplicação direta desses resíduos em solo com fins agrônômicos, porém, a utilização inadequada pode acarretar danos ambientais.

O autor afirma que os resíduos da produção de suínos podem ser compostos por “[...] dejetos, sobras de ração, materiais dos pisos e água [...]” e que o volume e as características desses dejetos “[...] dependem da alimentação, tipos de bebedouros

e sistemas de limpeza, além do sistema de criação em que se encontram.” (BARIZON, 2020, p. 23).

Na bovinocultura, os dejetos apresentam potencial inferior para a produção do biogás, se comparado aos resíduos de aves e de suínos, haja vista que grande parte da matéria orgânica é degradada ainda no estômago dos ruminantes.

Os resíduos oriundos da avicultura são compostos por dejetos, serragem de cama de aviário e restos de ração. A produção de biogás a partir de substrato de avicultura apresenta algumas dificuldades, pois o resíduo pode ser composto por materiais de difícil degradação e conter baixo teor de água, “[...] o que faz com que seja necessária a adição de água para diluição do material e diminuição dos sólidos totais, pois, se o teor de sólidos totais for alto, demandará um longo tempo para conclusão do processo.” (BARIZON, 2020, p. 23).

3.2 A importância do processo de digestão anaeróbia e do biogás

O biogás é formado a partir de material orgânico, sendo que o processo de digestão anaeróbia envolve diferentes tipos de microrganismos complexos que realizam diferentes ações metabólicas em interação. Com isso, obtêm-se condições adequadas que devem ser respeitadas e seguidas para o correto funcionamento dos biodigestores (MOESTEDT *et al.*, 2016).

A tecnologia aplicada à digestão anaeróbia de resíduos da pecuária tem aumentado, por isso, é necessário conhecer o potencial de produção do biogás e de diversos tipos de substratos. O percentual de metano corresponde à produção final desse gás por meio do processo de digestão anaeróbia (MOREIRA, 2021).

O processo de digestão anaeróbia, conforme explicam Moestedt *et al.* (2016), “[...] pode ser dividida em quatro etapas principais; hidrólise, acidogênese, acetogênese e metanogênese.” (MOESTED *et al.*, 2016, p. 180). Os autores explicam que, durante a hidrólise, “[...] as enzimas extracelulares desintegram macromoléculas complexas em monômeros, como aminoácidos, ácidos graxos e açúcares.” (MOESTED *et al.*, 2016, p. 180). Os compostos oriundos desse processo são utilizados durante a acidogênese por bactérias fermentativas, sendo que os principais produtos são ácidos graxos voláteis, álcoois, ácido lático, gás carbônico, hidrogênio, amônia e sulfeto de hidrogênio.

Outra etapa do processo é a acetogênese, que é responsável pela oxidação dos produtos. As bactérias acetogênicas fazem parte de um grupo metabólico intermediário que produz substrato para as metanogênicas. Moestedt *et al.* (2016) esclarecem que, durante a acetogênese, “[...] os ácidos graxos mais longos são convertidos em acetato e hidrogênio/dióxido de carbono por diferentes reações de oxidação sintrófica.” (MOESTED *et al.*, 2016, p. 180).

A última etapa é o processo de degradação anaeróbia de compostos orgânicos, realizada por bactérias metanogênicas, utilizando componentes tais como: ácido acético, hidrogênio /dióxido de carbono, ácido fórmico, metanol, metilaminas e monóxido de carbono. A matéria orgânica biodegradável é transformada em metano e dióxido de carbono por meio da metanogênese (MOESTEDT *et al.*, 2016).

Sendo um processo de tratamento biológico de degradação de matéria orgânica, a digestão anaeróbia ocorre na ausência de oxigênio. Para Bastos *et al.* (2019), “[...] durante o processo de digestão grande parte da matéria orgânica (substrato) é convertido em biogás por meio de reações bioquímicas.” (BATOS *et al.*, 2019, p. 555). Dentre as composições da matéria orgânica para a produção do biogás, podem-se citar as substâncias ricas em proteínas e com alto potencial de biometano. Amaral, Steinmetz e Kunz (2019) descrevem que as altas cargas de tais materiais são frequentemente correlacionadas à “[...] instabilidade do processo e devido à liberação de nitrogênio de amônia (NH₃-N) [...]” (AMARAL; STEINMETZ; KUNZ, 2019, p. 31), o que, conseqüentemente, prejudica o processo de degradação microbiana.

Algumas metodologias para estimar a produção de gás metano de resíduos sólidos na pecuária são encontradas na literatura. Tais métodos variam em suas considerações, em sua complexidade e na quantidade de dados que necessitam. A forma de avaliar o potencial de metano da produção ocorre por meio da realização de pesquisas e de medições de campo da quantidade de biogás e da concentração de metano, direcionadas para implantação de um projeto específico. Para este trabalho, foram considerados os resultados dos ensaios de biodigestão anaeróbia (PBM) dos resíduos sólidos da criação de suíno, bovino e aves, relacionando, portanto, o percentual de metano obtido com a análise elementar desses resíduos.

Para avaliar a estrutura da digestão anaeróbia, são realizadas análises laboratoriais, podendo ser avaliada a caracterização da composição química e física dos resíduos, importante para se verificar a interação entre os microrganismos e os substratos. Amaral, Steinmetz e Kunz (2019) descrevem que essas avaliações

consistem em testes respirométricos anaeróbios e envolvem a “[...] avaliação da produção de biogás ou de metano a partir da massa conhecida de biomassa do inóculo ou do substrato.” (AMARAL; STEINMETZ; KUNZ, 2019, p. 31). Entre essas avaliações, é importante destacar a verificação do potencial bioquímico de metano (ou potencial energético) do substrato.

3.3 Modelagem RNA


As RNAs correspondem a uma tecnologia que vem sendo amplamente utilizada em diversas áreas de pesquisas. Elas podem ser definidas “[...] como uma estrutura interligada por elementos de processamento simples que são capazes de realizar operações para processamento de dados.” (ROCHA; MATOS; FREI, 2011 p. 738).

Assemelhando-se ao “[...] funcionamento do neurônio biológico típico [...]” (ROCHA; MATOS; FREI, 2011, p. 737), as RNAs utilizam modelos matemáticos para demonstrar a classificação de padrões, o agrupamento de dados, as previsões temporais, entre outras funções. Entretanto, para que as RNAs apresentem esses resultados, são necessários pesquisas e levantamentos de informações reais sobre o que se deseja aplicar ao modelo.

Para se construir um modelo de RNA, um fluxo de trabalho incorporado é estabelecido. Deve-se levar em consideração a coleta dos dados de entrada e de treinamento com uma previsão dos dados de saída. O modelo de algoritmo *backpropagation* trabalha com multicamadas e resolve problemas não linearmente separáveis, ou seja, aquele em que não se pode separar duas classes distintas no eixo cartesiano bidimensional traçando-se somente uma reta. “O treinamento de redes neurais com várias camadas pode ser entendido como um caso especial de aproximação de funções, onde não é levado em consideração nenhum modelo explícito dos dados.” (SHEPHERD, 1997).

Na Figura 1, tem-se um exemplo da estrutura do algoritmo.

Figura 1 - Estrutura de Algoritmo Rede Neural Artificial (RNA)



Fonte: Almeida (2014).

No algoritmo *backpropagation*, calcula-se o erro entre o que a rede encontrou no processo de treinamento; na sequência, recalcula-se o valor de todos os pesos, começando da última camada e indo até a primeira, sempre reduzindo a porcentagem de erro. O algoritmo consiste em algumas etapas, tais como inicializar todos os pesos da rede com pequenos valores aleatórios; fornecer dados de entrada à rede e calcular o valor da função de erro ao comparar ao valor de saída esperado.

Para computar o valor da função de erro, calculam-se os valores dos gradientes (vetores). Com a aferição desse vetor, atualiza-se cada peso de modo iterativo, sempre recalculando os vetores em cada passo da interação entre as camadas. A equação geral utilizada para os cálculos consta no estudo de Leite (2018).

(1)

$$w \leftarrow w - n \frac{\partial E}{\partial w}$$

A fórmula apresenta o valor do peso na iteração atual, que será o valor do peso na iteração anterior, corrigido de valor proporcional ao gradiente. O sinal negativo indica que a direção é contrária à de vetores. O parâmetro n representa a taxa de aprendizado na RNA, controlando o tamanho do passo que tomamos na correção do peso (LEITE, 2018).

O Método de Levenberg-Marquardt (LM), assim como o método de Newton, é bastante eficiente quando se trata de redes que não têm mais do que algumas centenas de conexões a serem ajustadas (HAGAN, 1994). Isso se deve,

principalmente, ao fato de que esses algoritmos necessitam armazenar uma matriz quadrada cuja dimensão é da ordem do número de conexões da rede.

3.4 Redes Neurais Artificiais (RNA) como ferramenta para a modelagem de sistemas ambientais

Selau e Ribeiro (2009) relatam que as RNAs “[...] podem ser aplicadas em problemas de regressão, classificação e compactação de dados [...]” (SELAU; RIBEIRO, 2009 p. 402), assim como em situações nas quais existem interações não lineares, ou seja, não apresentam um único sentido entre as variáveis dependentes e as independentes. Os autores descrevem uma ideia básica da construção de um “[...] modelo composto por um grande número de unidades de processamento, que são chamadas de neurônios, com um grande número de conexões entre eles.” (SELAU; RIBEIRO, 2009 p. 402). O processamento de informação da rede ocorre nos neurônios por meio de conexões denominadas sinapses ou pesos sinápticos (SELAU; RIBEIRO, 2009).

Há várias arquiteturas de RNA utilizadas como base para o treinamento da rede. Selau e Ribeiro (2009) pontuam as mais utilizadas, tais como “[...] as redes de funções de base radial, redes recorrentes, redes de Kohonen, etc.” (SELAU; RIBEIRO, 2009 p. 402). As técnicas de RNAs apresentam bons resultados como ferramentas de modelagem para tratamento de resíduos, sendo possível, por meio de técnicas, “ensinar” a rede, fornecendo valores de entrada e de saída para que o processo seja compreendido.

Uma das arquiteturas de redes apresentada por Selau e Ribeiro (2009) consiste em uma RNA organizada em camadas, na qual somente há conexão entre neurônios de camadas vizinhas. A rede neural pode ser composta por várias dessas camadas, em que “[...] uma rede neural de múltiplas camadas é dita totalmente conectada quando todos os nós de todas as camadas estão conectados com todos os nós das camadas vizinhas.” (SELAU; RIBEIRO, 2009 p. 402). É por meio dessas conexões, ou pesos sinápticos, que se apresenta a capacidade de armazenamento de informações de uma RNA.

Segundo Mohammadi *et al.* (2021), os modelos de RNA são compostos de células neurais e pesos, cujo princípio básico consiste em um sistema contínuo de elementos simples, que podem aprender relações complexas entre variáveis, tanto

independentes quando interdependentes. Para desenvolver um modelo de RNA, são envolvidas diversas etapas, incluído estratégias para a seleção de dados, para o processamento de dados, para definir a estrutura de rede neural e escolha do algoritmo de treinamento de rede e, por fim, para validar a rede treinada.

As RNAs têm uma estrutura contínua, como pontuam Mohammadi *et al.* (2021), consistindo em uma camada de entrada, outras intermediárias que são chamadas de camadas ocultas e a camada de saída. Cada uma delas denomina um processador simples (os neurônios), que está conectado às camadas por meio dos pesos sinápticos. A camada de entrada recebe as informações de fontes externas, ao passo que as camadas intermediárias (ocultas) realizam o pré-processamento e transferem-nas para outras camadas ocultas e, posteriormente, para a camada de saída.

Uma das principais capacidades das RNAs é o reconhecimento de padrões, que podem incorporar a essência de sua dependência entre os parâmetros de entrada e saída e de um processo de destino. Há diversas formas de aprendizagem de RNA; o *backpropagation* é uma delas, sendo constituído em uma camada de entrada com vários nós, uma camada oculta com vários nós e uma camada de saída contendo uma ou mais saídas. O principal conceito do algoritmo *backpropagation* é baseado no cálculo do erro ocorrido na camada de saída da rede neural, em que se recalcula o valor dos pesos da última camada de neurônios e, assim, percorre as camadas anteriores de trás para frente, atualizando os pesos das camadas a partir da última até chegar à camada de entrada da rede.

No algoritmo de aprendizagem, não há conexões entre os nós das camadas de entrada, oculta ou de saída. O processo de treinamento, por outro lado, começa onde o conjunto de dados de entrada é alocado, momento no qual os pesos são inicializados. Os algoritmos de retropropagação têm a função de minimizar erros de estimativa e alcançar um bom modelo generalizado, usado principalmente em termos de velocidade, de capacidade preditiva e de eficiência na obtenção de bons modelos (MOHAMMADI *et al.*, 2021).

Tendo em vista o propósito de facilitar processos e solucionar problemas de forma lógica, as RNAs estão sendo aplicadas em diversos setores da sociedade: saúde, educação, indústria etc. Eyng e Fileti (2010), por exemplo, no campo ambiental, aplicaram um controlador *feedforward-feedback* (que busca eliminar os efeitos de distúrbios mensuráveis, a fim de obter um controlador mais capaz de rejeitar

perturbações) com base em RNA a um processo de produção de etanol por fermentação, com características não lineares do sistema. Os resultados foram muito satisfatórios, superando a estratégia de controle tradicional (linear) baseada em um controlador Proporcional Integral Derivativo (PID).

Spörl, Castro e Luchiari (2011) abordaram o desafio da modelagem da fragilidade ambiental diante dos processos erosivos, dos deslizamentos de encostas, do assoreamento de cursos de água, das inundações e dos sistemas ambientais, a fim de traduzir esse conhecimento em modelos matemáticos. O seu trabalho foi aplicado em duas áreas-teste, com resultados bastante divergentes. Testou-se a viabilidade e a confiabilidade aplicada à elaboração de modelos de fragilidade ambiental, as RNAs. Os resultados comprovaram que é possível modelar, com razoável confiabilidade, o padrão de avaliação de especialistas na definição da fragilidade dos sistemas ambientais, eliminando a arbitrariedade e a subjetividade do processo de elaboração de modelos de fragilidade ambiental.

Salviano (2002) propôs a realização da modelagem do processo de tratamento de efluentes orgânicos da Rhodia Paulínia por meio de RNA com o objetivo de prever a concentração de nitrogênio “[...] no seio do reator biológico e assim fornecendo dados ao operador para controlar a dosagem de hidróxido de amônio, evitando-se o excesso de nitrogênio enviado para a bacia fluvial.” (SALVIANO, 2002, p. 6). Pela análise qualitativa, “[...] onze variáveis foram definidas como de entrada e uma variável como saída, formando uma arquitetura da rede neural [...]” (SALVIANO, 2002, p. 6), sendo de 11 neurônios na camada de entrada, 27 na camada oculta e um na camada de saída. Como resultado, o pesquisador relatou que, por meio da utilização das redes neurais para modelar a Estação de Tratamento de Efluentes (ETE), se detectou a realização de um procedimento operacional com sérios problemas de estabilização para a estação.

O trabalho apresentado por Bilgili, Demir e Varank (2009), desenvolvido no aterro sanitário de Odayeri, Istambul, Turquia, realizou a comparação do desempenho do lixo do aterro em relação aos resíduos sólidos em decomposição. Recorreu-se ao teste PBM para determinar o potencial oriundo de CH₄ dos resíduos sólidos durante 27 meses de operação do aterro. Nesse estudo, o desempenho do sistema foi utilizado para modelar o PBM das amostras retiradas do local do aterro em vários tempos

operacionais, por meio do programa MATLAB 6.5¹ para os reatores empregados. Por meio da modelagem do PBM, “[...] observou-se que o modo de consumo de substrato de primeira ordem dá um bom ajuste aos dados experimentais.” (BILGILI; DEMIR; VARANK, 2009, p. 4978), conforme apresentados nos resultados do guia de estudo para projetar e operar o aterro sanitário em condições ideais.

Outro estudo que pode ser citado foi conduzido Nair *et al.* (2016), a fim de avaliar o rendimento de metano do biogás em um biorreator anaeróbio utilizando RNA. Os “[...] biorreatores de aterro são considerados uma das novas tecnologias para produção simultânea de energia e estabilização de resíduos a partir da fração orgânica biodegradável de resíduos sólidos urbanos.” (NAIR *et al.*, 2016, p. 92).

Esse trabalho determinou o teor de metano (CH₄) no rendimento do biogás a partir da digestão da fração orgânica do sólido municipal de resíduos (resíduos alimentares, resíduos vegetais e aparas de quintal) coletados de uma colônia residencial típica de Nagpur, Índia. A pesquisa teve como foco os efeitos de vários fatores, como pH, teor de umidade, sólidos voláteis totais, ácidos graxos voláteis e fração de CH₄ na produção de biogás. Para a aplicação da RNA, foi utilizado MATLAB R2010a, e os conjuntos de dados do reator foram treinados usando-se o algoritmo *Levenberg Marquardt Back Propagation* (LMBP) (função *trainlm*) para avaliar o desempenho do erro quadrático médio (MSE). Como resultado, o biorreator anaeróbio forneceu uma recuperação otimizada de CH₄, o “[...] desempenho de conjuntos de dados de treinamento e validação mostraram coeficientes de correlação (R²) de 0,915 e 0,884, indicando, respectivamente, boa capacidade de generalização do modelo.” (NAIR *et al.*, 2016, p. 98).

¹ Disponível em: <https://ch.mathworks.com/products/matlab.html>. Acesso em: 1 jun. 2022.

4 MATERIAL E MÉTODOS

Neste estudo, inicialmente, foram coletados os insumos e o preparo das amostras para realizar um estudo do percentual de metano produzido durante a degradação dos resíduos sólidos da produção pecuária. Com base nos dados oriundos de ensaios de potencial bioquímico de metano, foram extraídos os percentuais de metano para compor um banco de dados, sendo realizado o treinamento da RNA a partir de um algoritmo de treinamento o *backpropagation*. Esse, por sua vez, teve a função de otimizar os pesos para que a rede neural pudesse aprender a mapear corretamente as entradas e as saídas para a identificação de padrões de produção de metano em função da composição dos resíduos agropecuários.

Os ensaios para a determinação do percentual de metano foram realizados com apoio de pesquisadores ligados ao Laboratório de Processos e Biocombustíveis, da Universidade Tecnológica Federal do Paraná (UTFPR), *campus* de Medianeira (PR).

4.1 Coleta e preparo das amostras

Para a realização deste trabalho, foram utilizadas amostras de resíduos orgânicos oriundos da produção pecuária. Foram coletadas as seguintes matérias primas: dejetos de suínos, bovinos e aves. Os dejetos animais foram coletados entre fevereiro e abril de 2021, em propriedades rurais do localizadas na região Oeste do estado do Paraná.

As amostras foram recolhidas em recipientes constituídos de polietileno e posteriormente congeladas para conservação. A Tabela 1 contém os dados das amostras de resíduos sólidos detalhados conforme a origem e a destinação. Cada amostra foi subdividida em três partes, empregadas como substrato no ensaio de potencial bioquímico de metano, proporcionando, portanto, que esse fosse realizado em triplicata.

Tabela 1 - Tabela de Amostras de Resíduos Sólidos

	Aves		Suíno			Bovino		
	Aves de Corte	Aves de Postura	Suíno UPL	Creche	Terminação	Confinados a Pasto	Semiconfinados	Compost Barn
Amostras	6	6	4	4	4	4	4	4
Ensaio de PBM em triplicata	18	18	12	12	12	12	12	12
Dados para treinamento RNA	15	15	9	9	9	9	9	9
Dados para validação RNA	3	3	3	3	3	3	3	3

Fonte: Autoria própria (2021).

Os dados coletados para o desenvolvimento da RNA foram coletados de amostra de dejetos de resíduos sólidos da criação de aves, de suínos e de bovinos. Para cada cultura, há algumas especificações quanto ao modelo produtivo:

Aves: dejetos de aves de corte e aves de postura;

Suíno: dejetos de criação de suínos de uma Unidade Produtora de Leitão (UPL), cujo manejo é feito visando-se a obter um melhor controle sanitário dos lotes, diminuir o estresse pós-desmame, adaptar o leitão e quebrar o ciclo patológico da maternidade e de fase terminação, que é quando ocorre a engorda do animal;

Bovino: dejetos de criação de bovino de corte confinados no pasto e de bovinos semiconfinados, os quais recebem complemento alimentar com concentrado; o modelo utilizado é o *Compost-Barn*, um sistema de instalação que consiste em espaço físico coberto para descanso dos animais, revestido com serragem.

Para o preparo das amostras, foi preciso secar o substrato a 50° C em um período de 24 horas para facilitar a moagem e igualar o percentual de umidade entre as elas, mantendo a homogeneidade ao serem incubadas. Após a secagem, as amostras foram armazenadas congeladas para evitar a proliferação de microrganismos e a degradação.

4.2 Estimativa do percentual de metano

A literatura apresenta diversas metodologias para a determinação do potencial bioquímico de metano. Para esta pesquisa, recorreu-se ao modelo descrito por Penteado *et al.* (2018), que utilizou frascos de vidro, com volume de 125 ml, compostos de tampas rosqueadas e de anéis de vedação. Esses reatores permitem a coleta do gás produzido durante o período de incubação das amostras.

O inóculo usado nos testes foi fornecido pelo Centro Internacional de Energias Renováveis – Biogás (Cibiogás), localizado no município de Foz do Iguaçu (PR), sendo composto por digestatos de reatores anaeróbios de tratamento de dejetos suínos/bovinos/aves e dejetos animais brutos. Após a coleta de um volume pré-determinado do inóculo em frasco plástico atóxico, esse foi aclimatado por um período de 5 a 7 dias em incubadora, sem agitação e com temperatura controlada em 37 °C.

Para observar a produção de gás metano e verificar a variabilidade dos ensaios, os testes foram realizados em triplicata, mantendo-se as amostras incubadas sob condições controladas de temperatura e pressão, durante um período entre 30 e 60 dias, quantificando e caracterizando o biogás produzido.

4.2.1 Ensaios de biodigestão anaeróbia

Os testes foram realizados em batelada, em frascos de vidro de 125 ml, em triplicata para cada amostra coletada e em incubadora com temperatura controlada em 37 °C sem agitação, conforme a base técnica proposta pela *Verein Deutscher Ingenieure* - VDI 4630 - (VDI, 2006). Duas triplicatas serviram de controle, sendo uma composta somente por inóculo e outra por celulose microcristalina e inóculo; essa última foi usada para validação da eficácia do inóculo, conforme descrito por Edwiges e Bollmann (2008). A relação inóculo/substrato (i/s) foi de 2/1 com base nos sólidos voláteis das amostras.

O monitoramento da produção de biogás foi realizado com seringas de vidro com 5 ml, 20 ml e 100 ml e com auxílio de um manômetro para equiparar a pressão interna do frasco com a pressão atmosférica (pressão manométrica). As seringas eram utilizadas para coletar o biogás produzido, sendo que a coleta cessava quando a pressão interna do frasco fosse igualada à atmosférica. Nos primeiros 10 dias, as coletas ocorreram diariamente, com intervalos posteriores de dois a três dias até que

a produção de biogás fosse equivalente a menos de 1% do volume total acumulado durante duas coletas consecutivas. A determinação da composição do biogás produzido nos testes de percentual de metano foi feita por meio de cromatografia gasosa no 5º, 15º e 25º dias da avaliação do percentual de metano. As análises avaliaram somente os percentuais de metano (CH₄) no biogás coletado.

4.3 Caracterização química dos resíduos e do biogás produzido

4.3.1 Caracterização química dos resíduos

A caracterização do substrato foi realizada por análise elementar, técnica analítica utilizada em diversas aplicações e diferentes setores. O equipamento empregado nas análises elementares foi o Analisador Elementar de CHNS-O (modelo Euro EA, Euro Vector) (Figura 3), disponibilizado na UTFPR, *campus* de Pato Branco (PR). Trata-se de um sistema com um ou dois reatores que realiza a combustão dinâmica e espontânea da amostra com uma subsequente separação cromatográfica. Após a separação, os gases de interesse são identificados em um detector de condutividade térmica (TCD). O instrumento é capaz de operar nas seguintes configurações: N, proteína, CN, CNS, CHNS, CHNO, CHNSO, S e O (EQUIPAMENTOS, 2021).

Figura 2 - Analisador elementar de CHNS-O



Fonte: UTFPR (2021).

Segundo Sousa *et al.* (2017), a análise elementar de CHNSO, “[...] também conhecida como análise orgânica elementar ou microanálise elementar, determina as

quantidades de Carbono (C), Hidrogênio (H), Nitrogênio (N), Enxofre (S) e Oxigênio (O) presentes em uma amostra.” (SOUSA *et al.*, 2017, p. 11). É um método confiável e econômico utilizado para avaliar a pureza e a composição química dos compostos. Na combustão, a amostra gera gases compostos uniformes dos elementos C, H, N e S. Esses produtos de combustão (por exemplo, CO₂, H₂O, NO₂ etc.) são medidos por cromatografia gasosa, determinando-se a relação dos elementos da amostra original.

A análise elementar dos resíduos da pecuária, utilizados como substratos, se pautou na determinação dos percentuais de C, H, N e S, no entanto, poucas amostras apresentaram valores significativos para o composto S, de modo que tal parâmetro não foi utilizado na modelagem via RNA.

4.3.2 Caracterização química do biogás

Um dos produtos da biodigestão anaeróbia é o biogás, cujo principal componente de interesse é o metano. Sendo assim, a caracterização do biogás se limitou a determinar o percentual de metano nas amostras de biogás. Isso foi feito por cromatografia gasosa, utilizando-se um cromatógrafo gasoso Perkin Elmer, modelo Clarus 680, coluna empacotada Plot Q, gás de arraste Hélio a uma velocidade de fluxo constante de 60 cm/s, temperatura do forno de 60 °C com rampa de aquecimento de 30 °C/min. até 240 °C, detector de condutividade térmica e volume de amostra de 0,5 ml.

4.4 Rede neural artificial para modelagem do percentual de metano em biogás produzido a partir de resíduos da pecuária

Como o treinamento de uma RNA constitui uma estratégia de modelagem empírica, a primeira etapa realizada foi a obtenção de dados referentes aos ensaios de biodigestão anaeróbia de resíduos da pecuária. Essa fase contou com o apoio de pesquisadores vinculados ao Laboratório de Processos e Biocombustíveis da UTFPR, *campus* de Medianeira (PR).

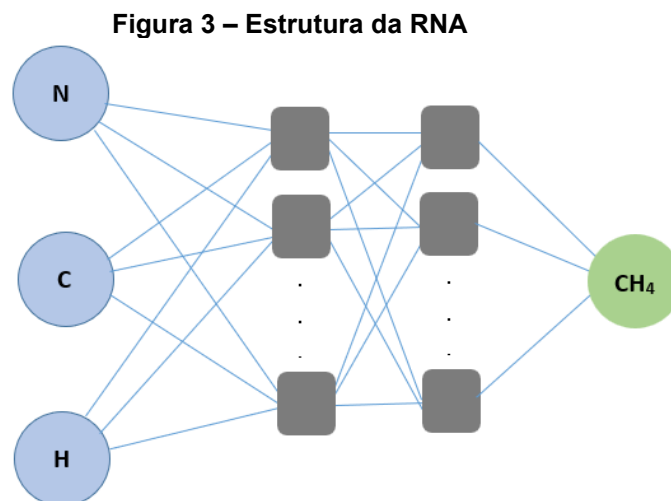
Nesse contexto, os bancos de dados de treinamento e de validação da RNA foram construídos tendo como entradas os dados da caracterização dos resíduos quanto à sua análise elementar (percentuais de N, C e H), e saída o percentual de

metano (CH_4) obtido após caracterização do biogás produzido durante os ensaios de biodigestão anaeróbia.

Para a modelagem da RNA, foi levado em conta a escolha dos dados que serviriam para treinar a rede e garantir a melhor forma de apresentá-los (normalização, codificação, filtragem entre outros), em função da escolha do número de neurônios em cada camada. Para que a RNA não reconheça apenas os padrões do conjunto de treinamento, separou-se um agrupamento de dados para a validação.

A RNA é treinada com os dados destinados para o treinamento, procedimento que é repetido algumas vezes (épocas). O teste final é executado com a rede que obteve o melhor desempenho com os dados do conjunto de validação (os quais nunca foram apresentados à RNA em questão).

A Figura 4 representa a estrutura da RNA com os neurônios de entrada e de saída.



Fonte: Autoria própria (2022).

O banco de dados de validação é utilizado após o treinamento para verificar se o algoritmo “aprendeu” o padrão, retornando um resultado semelhante aos dados realizados na pesquisa em laboratório. Para a construção do banco, foram realizados sorteios aleatórios de dados de cada tipo de cultura (suína, bovina e avícola). Os dados do banco de validação não estão presentes no banco de dados de treinamento, para que não haja valores idênticos, permitindo que se avalie, efetivamente, se a RNA foi devidamente treinada.

Para certificar o treinamento e auxiliar na tomada de decisão, foram elaborados três modelos para o treinamento da RNA com os dados das culturas selecionadas. Os dados foram organizados de forma que, para os três modelos, os dados de validação não estivessem presentes no banco de dados de treinamento.

A implementação foi realizada utilizando a ferramenta MATLAB, versão 2021b. Essa ferramenta tem um módulo especial para redes RNAs, chamado *Tool box Neural Network*. Recorreu-se ainda à planilha eletrônica MS-Excel para um pré-processamento.

Inicialmente, selecionou-se o modelo da rede. O algoritmo utilizado para o treinamento foi o Levenberg-Marquardt, o qual, segundo Benatti e Ribeiro (2017), garante boa definição das direções de minimização de função. Essa escolha foi motivada pelo fato de que esse algoritmo é o mais utilizado em aplicações de séries temporais e permite obter uma solução numérica para o problema de minimização de uma função.

Para implementar a RNA, utilizou-se a estrutura pautada pelo atendimento da função objetivo soma dos quadrados dos erros, ao nível de 1×10^{-5} .

O treinamento da RNA teve como dados de entrada os valores correspondentes ao N, C e H, e como saída esperava-se o valor de (CH₄). Para definir a melhor estrutura da RNA, variou-se o número de camadas ocultas, limitando-se a duas camadas. Além disso, variou-se o número de neurônios em cada camada oculta. Foram realizados testes variando o número de neurônios nas camadas ocultas, de 1 a 101, variando de 2 em 2.

5 RESULTADOS E DISCUSSÃO

Os resultados obtidos a partir dos ensaios de biodigestão anaeróbia das amostras dos resíduos da pecuária são apresentados nesta seção.

Por meio desses resultados, foi realizada a separação dos dados para o banco de dados de treinamento e de validação. Foram elaborados três modelos de banco de dados para o treinamento da RNA, com a intenção de avaliar se o desempenho da RNA seria influenciado, de alguma maneira, pelo sorteio de um ou outro dado. Os modelos estão compostos com as informações de N, C, H e Percentual de Metano (CH₄).

Na Tabela 2, são apresentados os dados dos bancos de treinamento e validação (destaque em azul) para o treinamento da RNA no Modelo 1.

Tabela 2 – Banco de dados para treinamento e validação da RNA Modelo 1

Origem	Nitrogênio (N) %	Carbono (C) %	Hidrogênio (H) %	Metano (CH₄)%
Suíno UPL1	1,755	34,512	5,369	72,1
Suíno UPL2	2,403	30,430	4,987	73,8
Suíno UPL3	5,883	36,413	6,137	71,8
Suíno UPL4	5,647	42,395	6,485	66,0
Suíno TER1	3,561	35,396	5,505	73,7
Suíno TER2	3,162	36,980	5,973	71,2
Suíno TER3	4.154	39.401	6.252	66,8
Suíno TER4	4,367	37,088	5,924	71,6
Suíno CRE1	2,631	39,594	5,671	66,7
Suíno CRE2	4,410	41,789	6,331	67,2
Suíno CRE3	2,484	41,722	6,257	73,0
Suíno CRE4	5.250	47.215	7.163	68,3
Aves POS1	5,622	29,826	4,177	54,1
Aves POS2	4,386	29,167	4,013	56,9
Aves POS3	3.877	24.354	3.164	54,2
Aves POS4	10,870	27,028	3,475	56,1
Aves COR1	3,329	37,867	5,634	54,4
Aves COR2	3,907	36,666	5,516	54,7
Aves COR3	3.913	28.228	4.350	54,1
Aves COR4	3,955	26,423	3,704	55,2
Bovino LSC1	1,915	41,119	5,440	59,7
Bovino LSC2	2.257	41.254	5.714	61,6
Bovino LSC3	2,224	38,357	5,584	59,8
Bovino LSC4	2,363	39,647	5,437	58,3
Bovino CP1	2,228	39,800	5,490	61,7
Bovino CP2	2,280	40,938	5,359	60,0

Bovino CP3	2,471	42,171	5,630	62,0
Bovino CP4	1.877	38.926	5.398	60,2
Bovino LCF1	2.411	38.445	5.443	58,6
Bovino LCF2	2,612	39,630	5,671	59,6
Bovino LCF3	2,756	40,104	5,823	62,5
Bovino LCF4	2,639	40,127	5,749	59,0

CRE = Crechário; COR = Cortes; CP = Corte a pasto; LSC = Leite Semi Confinado; LCF = Leite Compost-Barr

Fonte: **Autoria própria (2022).**

A Tabela 3 apresenta o banco de dados de treinamento e de validação (destaque em laranja) para a RNA do Modelo 2.

Tabela 3 - Banco de dados para treinamento e validação da RNA Modelo 2

Origem	Nitrogênio (N) %	Carbono (C) %	Hidrogênio (H) %	Metano (CH ₄)%
Suíno UPL1	1,755	34,512	5,369	72,1
Suíno UPL2	2,403	30,430	4,987	73,8
Suíno UPL3	5,883	36,413	6,137	71,8
Suíno UPL4	5,647	42,395	6,485	66,0
Suíno TER1	3,561	35,396	5,505	73,7
Suíno TER2	3,162	36,980	5,973	71,2
Suíno TER3	4.154	39.401	6.252	66,8
Suíno TER4	4,367	37,088	5,924	71,6
Suíno CRE1	2,631	39,594	5,671	66,7
Suíno CRE2	4,410	41,789	6,331	67,2
Suíno CRE3	2,484	41,722	6,257	73,0
Suíno CRE4	5.250	47.215	7.163	68,3
Aves POS1	5,622	29,826	4,177	54,1
Aves POS2	4,386	29,167	4,013	56,9
Aves POS3	3.877	24.354	3.164	54,2
Aves POS4	10,870	27,028	3,475	56,1
Aves COR1	3,329	37,867	5,634	54,4
Aves COR2	3,907	36,666	5,516	54,7
Aves COR3	3.913	28.228	4.350	54,1
Aves COR4	3,955	26,423	3,704	55,2
Bovino LSC1	1,915	41,119	5,440	59,7
Bovino LSC2	2.257	41.254	5.714	61,6
Bovino LSC3	2,224	38,357	5,584	59,8
Bovino LSC4	2,363	39,647	5,437	58,3
Bovino CP1	2,228	39,800	5,490	61,7
Bovino CP2	2,280	40,938	5,359	60,0
Bovino CP3	2,471	42,171	5,630	62,0
Bovino CP4	1.877	38.926	5.398	60,2
Bovino LCF1	2.411	38.445	5.443	58,6
Bovino LCF2	2,612	39,630	5,671	59,6

Bovino LCF3	2,756	40,104	5,823	62,5
Bovino LCF4	2,639	40,127	5,749	59,0

CRE = Crechário; COR = Cortes; CP = Corte a pasto; LSC = Leite Semi Confinado; LCF = Leite Compost-Barr

Fonte: **Autoria própria (2022).**

A Tabela 4 apresenta o banco de dados de treinamento e de validação (destaque em verde) para a RNA do Modelo 3.

Tabela 4 - Banco de dados para treinamento e validação da RNA Modelo 3

Origem	Nitrogênio (N) %	Carbono (C) %	Hidrogênio (H) %	Metano (CH ₄)%
Suíno UPL1	1,755	34,512	5,369	72,1
Suíno UPL2	2,403	30,430	4,987	73,8
Suíno UPL3	5,883	36,413	6,137	71,8
Suíno UPL4	5,647	42,395	6,485	66,0
Suíno TER1	3,561	35,396	5,505	73,7
Suíno TER2	3,162	36,980	5,973	71,2
Suíno TER3	4,154	39,401	6,252	66,8
Suíno TER4	4,367	37,088	5,924	71,6
Suíno CRE1	2,631	39,594	5,671	66,7
Suíno CRE2	4,410	41,789	6,331	67,2
Suíno CRE3	2,484	41,722	6,257	73,0
Suíno CRE4	5,250	47,215	7,163	68,3
Aves POS1	5,622	29,826	4,177	54,1
Aves POS2	4,386	29,167	4,013	56,9
Aves POS3	3,877	24,354	3,164	54,2
Aves POS4	10,870	27,028	3,475	56,1
Aves COR1	3,329	37,867	5,634	54,4
Aves COR2	3,907	36,666	5,516	54,7
Aves COR3	3,913	28,228	4,350	54,1
Aves COR4	3,955	26,423	3,704	55,2
Bovino LSC1	1,915	41,119	5,440	59,7
Bovino LSC2	2,257	41,254	5,714	61,6
Bovino LSC3	2,224	38,357	5,584	59,8
Bovino LSC4	2,363	39,647	5,437	58,3
Bovino CP1	2,228	39,800	5,490	61,7
Bovino CP2	2,280	40,938	5,359	60,0
Bovino CP3	2,471	42,171	5,630	62,0
Bovino CP4	1,877	38,926	5,398	60,2
Bovino LCF1	2,411	38,445	5,443	58,6
Bovino LCF2	2,612	39,630	5,671	59,6
Bovino LCF3	2,756	40,104	5,823	62,5
Bovino LCF4	2,639	40,127	5,749	59,0

CRE = Crechário; COR = Cortes; CP = Corte a pasto; LSC = Leite Semi Confinado; LCF = Leite Compost-Barr

Fonte: **Autoria própria (2022).**

A melhor estrutura de rede foi determinada com base nos resultados do Modelo 1 para a RNA, sendo, portanto, 3-7-7-1, correspondente a três neurônios na camada de entrada (percentuais de H, N e C nos resíduos), duas camadas ocultas com sete neurônios em cada uma e um neurônio na camada de saída (resposta da rede, percentual estimado de metano). Essa mesma estrutura foi utilizada para os Modelos 2 e 3, haja vista que é a mais simples dentre as testadas e, portanto, a que apresenta menor esforço computacional, proporcionado baixo erro percentual médio dentre os valores estimados pela RNA e os valores reais do conjunto de dados de validação.

A pesquisa apresentada por Lima e Passamani (2012) sobre a composição gasosa do biogás produzido na Estação de Tratamento de Esgoto (UFES) obteve valores semelhantes para CH₄, os quais estão entre 59,70 e 85,61 analisados no presente trabalho. De acordo com as pesquisadoras, “[...] tem-se que o metano é o gás que apresenta maior percentual na composição do biogás bruto, como já era esperado, apresentando concentrações médias de 77, 33% [...]” (LIMA; PASSAMANI, 2012, p. 60).

Lima (2016) também apresentou em sua pesquisa valores de CH₄ semelhantes, com números para CH₄ que variam de 21,1 até 70,1 em relação a este trabalho. O autor analisou a aplicação de modelos cinéticos a partir de substratos orgânicos diversos, concluindo que “[...] as análises da composição do biogás foram realizadas com o analisador de biogás modelo GEM5000, configurado para um tempo de sucção do biogás de 20 segundos, tempo adequado para sucção do biogás contido nos tubos eudiômetros.” (LIMA, 2016, p. 84).

Os resultados das simulações da RNA, nesta investigação, foram avaliados considerando o erro percentual médio, que é calculado com base no valor de CH₄ estimado pela RNA menos o valor de CH₄ Experimental dividido pelo valor de CH₄ Experimental, conforme a Equação 2.

(2)

$$\text{Erro percentual médio}(\%) = \left(\frac{[CH_4 \text{ estimado pela RNA}] - [CH_4 \text{ experimental}]}{[CH_4 \text{ experimental}]} \right) 100$$

Como resultado da simulação da RNA, a partir dos modelos dos resíduos sólidos da pecuária, foi possível verificar o percentual gás metano produzido pelas amostras. Para o Modelo 1, foram obtidos dados apresentados na Tabela 5 para o Percentual de Metano.

Tabela 5 – Resultado da RNA Modelo 1

AMOSTRA	CH ₄ EXPERIMENTAL (%)	CH ₄ ESTIMADO PELA RNA (%)
1	72,1	74,71
2	54,2	54,96
3	54,1	55,30
4	61,6	60,30
5	60,2	-18,10
6	58,6	50,40
7	66,8	-2009,58
8	68,3	101,32

Fonte: Autoria própria (2022).

Os resultados das amostras simuladas pela RNA foram satisfatórios assimilando-se aos valores de CH₄ experimental realizado em laboratório. As amostras 5, 7 e 8, estimadas pelo treinamento da RNA, apresentaram valores muito discrepantes dos de CH₄ experimental, como concentração de metano superior a 100% ou concentrações negativas. Entretanto, na maioria das vezes, as amostras demonstraram um padrão de resposta no qual o valor estimado se aproxima do experimental. Dessa forma, sem prejuízo aos resultados, definiu-se um filtro para as respostas da RNA. Para os Modelos 1, 2 e 3, foram consideradas como válidas as amostras com valores dos percentuais de CH₄ maiores que 0% e menores que 100%.

A Tabela 6 expõe os valores das amostras de CH₄ estimadas pela RNA que atendem ao requisito ideal com maior proximidade dos valores de CH₄ experimental, sendo essa a melhor estrutura para a RNA das amostras para o percentual de metano, conforme a média de valores definidas.

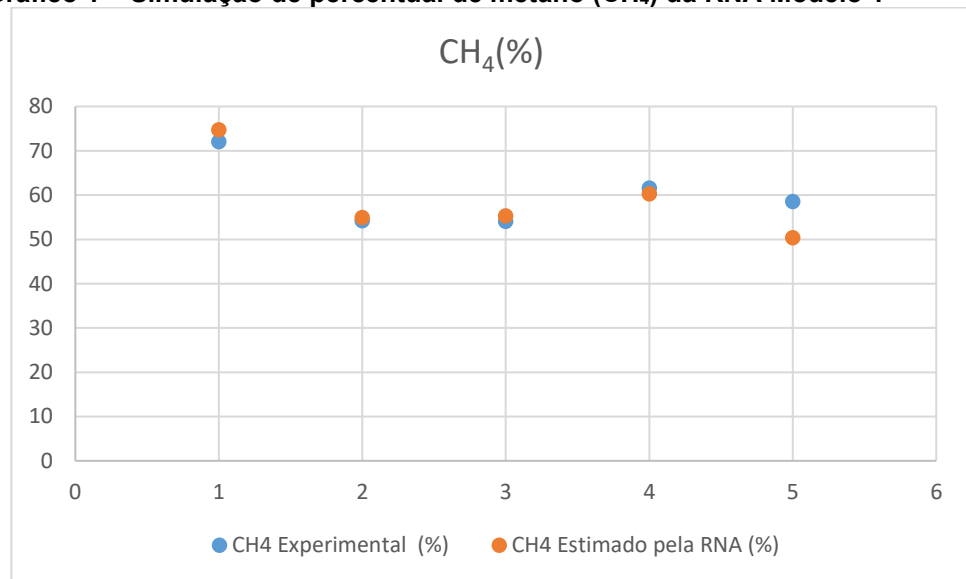
Tabela 6 – Análise dos resultados da RNA Modelo 1 após aplicação do filtro

AMOSTRA	CH ₄ EXPERIMENTAL (%)	CH ₄ ESTIMADO PELA RNA (%)	ERRO PERCENTUAL MÉDIO (%)
1	72,1	74,7	3,63
2	54,2	55,0	1,41
3	54,1	55,3	2,23
4	61,6	60,3	-2,10
5	58,6	50,4	-13,99

Fonte: Autoria própria (2022).

O Gráfico 1 demonstra a representação do percentual de metano (CH_4) para os valores simulados na RNA do Modelo 1 que atendem aos valores aplicados no filtro. É possível observar uma discrepância maior apenas na amostra 5, com um erro percentual médio de -13,99 %.

Gráfico 1 – Simulação de percentual de metano (CH_4) da RNA Modelo 1



Fonte: Autoria própria (2022).

Para o Modelo 2, os resultados do percentual de metano (CH_4) apresentados na Tabela 7 foram obtidos realizando-se um novo treinamento da RNA com o banco de dados de validação para o Modelo 2, com a mesma estrutura de rede configurada para o Modelo 1. Os valores de CH_4 estimados pela RNA foram satisfatórios, sendo que na maioria das amostras têm-se os valores aproximados aos de CH_4 experimental.

AMOSTRA	CH_4 EXPERIMENTAL REAL (%)	CH_4 ESTIMADO PELA RNA (%)
1	73,8	-8,38
2	54,1	56,04
3	56,9	56,03
4	59,7	-746,01
5	59,8	69,02
6	58,3	-8,21
7	73,7	80,75
8	71,2	74,82

Fonte: Autoria própria (2022).

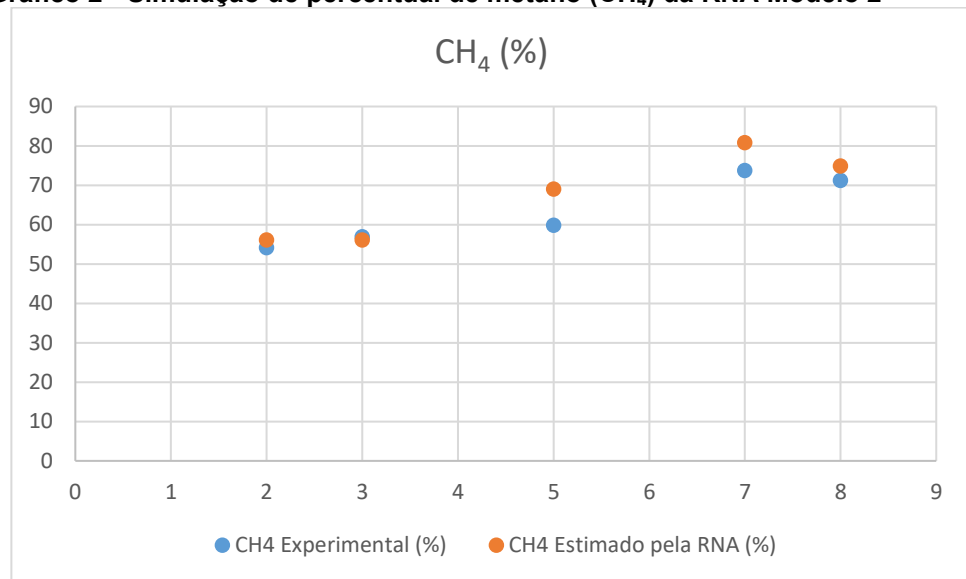
Os resultados de CH₄ estimado pela RNA nas amostras 1, 4 e 6 apresentam-se discrepantes em relação aos de CH₄ experimental com valores negativos, devendo ser aplicado para os resultados do Modelo 2 o filtro que considera como ideais os resultados de percentual de metano (CH₄) entre 0% e 100%. A Tabela 8 demonstra os valores das amostras para o percentual de metano ideais para o Modelo 2.

Tabela 8 - Análise dos resultados da RNA Modelo 2 após aplicação do filtro

AMOSTRA	CH₄ EXPERIMENTAL (%)	CH₄ ESTIMADO PELA RNA (%)	ERRO PERCENTUAL MÉDIO (%)
2	54,1	56,04	3,59
3	56,9	56,03	-1,53
5	59,8	69,02	15,42
7	73,7	80,75	9,57
8	71,2	74,82	5,08

Fonte: Autoria própria (2022).

A representação do percentual de metano (CH₄) para os valores simulados na RNA no Modelo 2 atendem aos aplicados no filtro. É possível observar uma discrepância maior nas amostras 5, com erro percentual médio de 15,42%, e 7, com erro percentual médio de 9,57%. Ao observar o Modelo 1 discutido anteriormente, os valores das simulações da RNA para o percentual de metano (CH₄) mantêm o padrão, sendo os estimados semelhantes aos valores experimentais de CH₄. O Gráfico 2 evidencia essa aproximação.

Gráfico 2 - Simulação de percentual de metano (CH₄) da RNA Modelo 2

Fonte: Autoria própria (2022).

Para o Modelo 3, os resultados do percentual de metano (CH₄) apresentados na Tabela 9 foram obtidos realizando-se um novo treinamento da RNA com o banco de dados de validação para o Modelo 3, com a mesma estrutura de rede configurada para o Modelo 1 e 2. Os valores de CH₄ estimados pela RNA são satisfatórios, e na maioria das amostras os valores estão próximos aos de CH₄ experimental.

Tabela 9 - Resultado da RNA Modelo 3

AMOSTRA	CH ₄ EXPERIMENTAL (%)	CH ₄ ESTIMADO PELA RNA (%)
1	66,7	68,48
2	54,7	-614,86
3	55,2	55,22
4	59,6	68,53
5	62,5	68,41
6	59	68,47
7	67,2	-614,59
8	73	72,45

Fonte: Autoria própria (2022).


Os resultados de CH₄ estimado pela RNA nas amostras 2 e 7 apresentam-se discrepantes em relação aos de CH₄ experimental com valores negativos, o que requer, para os resultados do Modelo 3, a aplicação do filtro que considera como ideais os resultados de percentual de metano (CH₄) entre 0% e 100%. A Tabela 10 demonstra os valores das amostras para o percentual de metano ideais para o Modelo 3.

Tabela 10 - Análise dos resultados da RNA Modelo 2 após aplicação do filtro

AMOSTRA	CH ₄ EXPERIMENTAL (%)	CH ₄ ESTIMADO PELA RNA (%)	ERRO PERCENTUAL MÉDIO (%)
1	66,7	68,48	2,67
3	55,2	55,22	0,03
4	59,6	68,53	14,98
5	62,5	68,41	9,46
6	59	68,47	16,05
8	73	72,45	-0,75

Fonte: Autoria própria (2022).

No Gráfico 3, tem-se a representação do percentual de metano (CH₄) para os valores simulados na RNA para o Modelo 3, os quais atendem aos valores aplicados no filtro. É possível observar uma discrepância nas amostras 4, com erro percentual médio de 14,98%, e 6, com erro percentual médio de 16,05%.

Gráfico 3 - Simulação de percentual de metano (CH₄) da RNA Modelo 3

Fonte: Autoria própria (2022).

Ao analisar os dados das simulações dos Modelos 1, 2 e 3 para os percentuais de C, N e H, que fornecem como resposta os valores percentuais de metano (CH₄), verifica-se discrepância em alguns valores, possivelmente, devido a diferentes origens de dejetos na composição das amostras. Outro fator que pode influenciar nos resultados é a quantidade de dados em banco para o treinamento e validação da RNA. Os valores simulados pela rede são validados pelo filtro, sendo o ajuste satisfatório, uma vez que o erro de predição não supera 17% e, na maioria dos pontos, é menor que 10%.

6 CONSIDERAÇÕES FINAIS

Este trabalho atentou-se para a estimativa do percentual de metano na produção de biogás na pecuária, observando-se os resultados do treinamento da RNA para as amostras de criação de suínos, bovinos e aves. Foi possível verificar que os resultados do percentual de metano se assemelham aos resultados dos ensaios laboratoriais, levando à conclusão de que a RNA foi capaz de prever o percentual de metano no biogás produzido para a maioria das amostras testadas.

A RNA mostrou-se instável fornecendo resultados discrepantes para algumas amostras realizadas em laboratório. Acredita-se que essa instabilidade pudesse ser minimizada caso o banco de dados de treinamento fosse ampliado.

A melhor estrutura de rede foi determinada com base nos resultados do Modelo 1 para a RNA, sendo, portanto, 3-7-7-1, correspondente a três neurônios na camada de entrada (percentuais de H, N e C nos resíduos), duas camadas ocultas com sete neurônios em cada uma e um neurônio na camada de saída (resposta da rede, percentual estimado de metano).

Como forma de segurança aos dados simulados pela RNA, foi estabelecido um filtro, que excluiu dados sem significado físico, como as concentrações de metano negativas ou maiores que 100%.

Nesse sentido, a RNA, quando alimentada com os dados da análise elementar do resíduo da pecuária, faz a estimativa do percentual de metano, apresentando resultados com precisão adequada (na maioria dos testes, o erro se mostrou menor que 10%), ou pode ser inconclusiva, nos casos em que o resultado da simulação não atender ao filtro proposto.

REFERÊNCIAS

- ALMEIDA, T. **Uma metodologia de reconhecimento de caracteres manuscritos utilizando redes neurais embarcadas**. 2014. Monografia (Especialização em Desenvolvimento de sistemas para dispositivos móveis) – Faculdade 7 de Setembro, Fortaleza, 2014.
- AMARAL, A. C. do; STEINMETZ, R. L. R.; KUNZ, A. Parâmetros de importância ao processo de digestão Anaeróbica. *In*: KUNZ, A.; STEINMETZ, R. L. R.; AMARAL, A. C. do (orgs.). **Fundamentos da digestão anaeróbia, purificação do biogás, uso e tratamento do digestato**. 1. ed. rev. Concoórdia: Sbera; Empraba Suínos e Aves, 2019, p. 27-39.
- BARIZON, F. **Mapeamento do potencial de produção de biogás no Estado do Paraná à partir de dejetos de suínos e bovinos leiteiros**. 2020. Dissertação (Mestrado em Engenharia) - Universidade Tecnológica Federal do Paraná, Francisco Beltrão, 2020.
- BASTOS, J. A. *et al.* Sustainable research methodology on the effect of the reuse of black liquor in the alkaline pre-treatment of garden residues for the production of biogas. **Journal of Environmental Management & Sustainability**, [s.l.], v. 8, n. 3, p. 554-567, 2019.
- BENATTI, K. A.; RIBEIRO, A. A. O Método de Levenberg-Marquardt para o Problema de Quadrados Mínimos não Linear. *In*: SIMPÓSIO DE MÉTODOS NUMÉRICOS EM ENGENHARIA, 2, Curitiba, 2017. **Anais...** Curitiba: UFPR, 2017, p. 230-237.
- BILGILI, M. S.; DEMIR, A; VARANK, G. Evaluation and modeling of biochemical methane potential (BMP) of landfilled solid waste: A pilot scale study. **Bioresource Technology**, [s. l.], v. 100, n. 21, p. 4976-4980, 2009.
- BREITENBACH, R.; SOUZA, R. S. Estrutura, conduta e governança na cadeia produtiva do leite: um estudo multicaso no rio grande do sul. **REAd. Rev. eletrôn. adm.**, Porto Alegre, v. 21, n. 3, p. 750-781, 2015.
- CALZA, L. F. *et al.* Avaliação dos custos de implantação de biodigestores e da energia produzida pelo biogás. **Eng. Agríc**, Jaboticabal, v. 35, n. 6, p. 990-997, 2015.
- CARDENAS-CLEVES, L. M. *et al.* Perspectivas del ensayo de potencial bioquímico de metano - pbm para el control del proceso de digestión anaerobia de residuos. **Rev. Ion**, Bucaramanga, v. 29, n. 1, p. 95-108, 2016.
- EDWIGES, T; BOLLMANN, H. A. Avaliação da qualidade das águas do Rio Belém, Curitiba-PR, com o emprego de indicadores quantitativos e perceptivos. **Eng. sanit. ambient.**, [s. l.], v. 13, n. 4, p. 443-452, 2008.
- EYNG, E; FILETI, A. M. F. Control of absorption columns in the bioethanol process: Influence of measurement uncertainties. **Engineering Applications of Artificial Intelligence**, [s. l.], v. 23, n. 2, p. 271-282, 2010.

FURLAN, F. L. *et al.* Uso de resíduos agrícolas e agroindustriais como adsorventes alternativos de manganês e ferro em solução aquosa. **Rev. Ambient. Água**, Taubaté, v. 13, n. 2, e2181, 2018.

HAGAN, M. Training Feedforward Networks with the Marquardt Algorithm. **IEEE Trans. on Neural Networks**, [s. l.], v. 5, n. 6, pp. 989-993, 1994.

LEITE, T. M. Redes Neurais, Perceptron Multicamadas e o Algoritmo Backpropagation. **Mediu.com**, 10 maio 2018. Disponível em: <https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8> Acesso em: 15 ago. 2022.

LIMA, A. C. G.; PASSAMANI, F. C. **Avaliação do potencial energético do biogás produzido no reator UASB da ETE-UFES**. 2012. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Ambiental) - Universidade Federal do Espírito Santo, Vitória, 2012.

LIMA, H. Q. **Determinação de parâmetros cinéticos do processo de digestão anaeróbia dos resíduos orgânicos de Santo André – SP por meio de testes do potencial bioquímico de metano**. 2016. Tese (Doutorado em Energia) – Universidade Federal do ABC, Santo André, 2016.

MOESTEDT, J. *et al.* Ammonia threshold for inhibition of anaerobic digestion of thin stillage and the importance of organic loading rate. **Microb Biotechnol**, [s. l.], n. 9, v. 2, p. 180-194, 2016.

MOHAMMADI, L. *et al.* Removal of Acid Dye from Aqueous Solutions with Adsorption onto Modified Wheat Bran – Modeling with Artificial Neural Networks. **Biointerface Research in Applied Chemistry**, [s. l.], v. 11, n. 6, p. 14044 – 14056, 2021.

MOREIRA, A. J. G. **Aplicação de modelos cinéticos a testes do potencial de biometanização de substratos orgânicos diversos**. 2021. Dissertação (Mestrado em Engenharia Ambiental) - Universidade Federal de Santa Catarina, Florianópolis, 2021.

MOTA, V. C. *et al.* Aproveitamento da cama de confinamento de bovino para adubação orgânica do milho. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, ano 2019, v. 23, n. 8, p. 620-624, 2019.

NAIR, V. V. *et al.* Artificial neural network based modeling to evaluate methane yield from biogas in a laboratory-scale anaerobic bioreactor. **Bioresource Technology**, [s. l.], v. 217, p. 90-99, 2016.

PENTEADO, M. C. *et al.* Análise do potencial de geração de biogás a partir da biodigestão anaeróbia da vinhaça e bagaço de cana. **Biblioteca Digital de Periódicos**, [s. l.], v. 3, n. 1, p. 26-33, 2018.

ROCHA, J. C.; MATOS, F. D; FREI, Fernando. Utilização De Redes Neurais Artificiais Para A Determinação Do Número De Refeições Diárias De Um Restaurante Universitário. **Rev. Nutr.**, Campinas, v. 24, n. 5, p. 735-742, 2011.

SALVIANO, F. O. C. **Modelagem e simulação de um tratamento de efluentes orgânicos através de redes neurais**. 2002. Dissertação (Mestrado em Engenharia Química) –Universidade Estadual de Campinas, Campinas, 2002.

SELAU, L. P. R; RIBEIRO, J. L. D. Uma sistemática para construção e escolha de modelos de previsão de risco de crédito. **Gestão e Produção**, [s. l.], v. 16, n. 3, p. 398-413, 2009.

SHEPHERD, A. J. **Second-Order Methods for Neural Networks: Fast and Reliable Methods for Multi-Layer Perceptrons**. Londres: Springer, 1997.

SOHOO, I. *et al.* Biochemical methane potential assessment of municipal solid waste generated in Asian cities: A case study of Karachi, Pakistan. **Renewable and Sustainable Energy Reviews**, [s. l.], v. 135, p. 1-12, 2021.

SOUSA, R. A. *et al.* **Preparação de amostras para análise elementar: Contexto Geral, Métodos Usuais e Aspectos Práticos**. 2017. Apostila de Apoio. Universidade Federal de Juiz de Fora, Juiz de Fora, 2017.

SPÖRL, C., CASTRO E. G.; LUCHIARI. A. Aplicação de Redes Neurais Artificiais na Construção de Modelos de Fragilidade Ambiental. 2011. **Revista do Departamento de Geografia**, São Paulo, v. 21, p. 113-135, 2011.

TRIOLO, J. M. *et al.* A new algorithm to characterize biodegradability of biomass during anaerobic digestion: Influence of lignin concentration on methane production potential. **Bioresource Technology**, [s. l.], v. 102, n. 20, p. 9395–9402, 2011.

UTFPR. **Universidade Tecnológica Federal do Paraná**, 3 de agosto de 2021. Disponível em: <http://portal.utfpr.edu.br/pesquisa-e-pos-graduacao/laboratorios-multiusuarios/laboratorios/central-de-analises-ca/equipamentos>. Acesso em: 11 maio 2022.

VDI. Former Editions. **VDI**, 15 de novembro de 2016. Disponível em: https://www.vdi.de/fileadmin/pages/vdi_de/redakteure/richtlinien/inhaltsverzeichnisse/2385990.pdf. Acesso em: 10 maio 2021.