



**UNIVERSIDADE ESTADUAL DA PARAÍBA – UEPB  
CENTRO DE CIÊNCIAS E TECNOLOGIA  
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA AMBIENTAL  
DOUTORADO EM ENGENHARIA AMBIENTAL**

**CARLOS ALBERTO ALVES BARRETO**

**PREDIÇÃO DAS EMISSÕES FUGITIVAS DE GÁS METANO NA CAMADA DE  
COBERTURA FINAL EM ATERRO SANITÁRIO A PARTIR DAS REDES NEURAIAS  
ARTIFICIAIS**

**CAMPINA GRANDE - PB  
2023**

**CARLOS ALBERTO ALVES BARRETO**

**PREDIÇÃO DAS EMISSÕES FUGITIVAS DE GÁS METANO NA CAMADA DE  
COBERTURA FINAL EM ATERRO SANITÁRIO A PARTIR DAS REDES NEURAIAS  
ARTIFICIAIS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Ciência e Tecnologia Ambiental da Universidade Estadual da Paraíba-UEPB, como exigência para obtenção do título de doutor em Engenharia Ambiental

**Área de concentração: Tecnologias de  
Tratamento de água e de resíduos**

**ORIENTADOR:** Prof. Dr. William de Paiva

**COORIENTADOR:** Prof. Dr. Márcio Camargo de Melo

**CAMPINA GRANDE - PB  
2023**

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

B273p Barreto, Carlos Alberto Alves.  
Predição das emissões fugitivas de gás metano na camada de cobertura final em aterro sanitário a partir das redes neurais artificiais [manuscrito] / Carlos Alberto Alves Barreto. - 2023.  
123 p. : il. colorido.

Digitado.

Tese (Doutorado em Engenharia Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2023.

"Orientação : Prof. Dr. William de Paiva, Coordenação do Curso de Engenharia Sanitária e Ambiental - CCT. "

"Coorientação: Prof. Dr. Márcio Camargo de Melo , UFCG - Universidade Federal de Campina Grande"

1. Aterro sanitário. 2. Gás metano. 3. Redes neurais artificiais. 4. Variações meteorológicas. I. Título

21. ed. CDD 628

**CARLOS ALBERTO ALVES BARRETO**

**PREDIÇÃO DAS EMISSÕES FUGITIVAS DE GÁS METANO NA CAMADA DE  
COBERTURA FINAL EM ATERRO SANITÁRIO A PARTIR DAS REDES NEURAIAS  
ARTIFICIAIS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Ciência e Tecnologia Ambiental da Universidade Estadual da Paraíba-UEPB, como exigência para obtenção do título de doutor em Engenharia Ambiental.

Área de concentração: Tecnologias de Tratamento de água e de resíduos

Aprovada em: 30 / 08 /2023

**BANCA EXAMINADORA:**

---

Orientador: Prof. Dr. William de Paiva  
Universidade Estadual da Paraíba

---

Coorientador: Prof. Dr. Márcio Camargo de Melo  
Universidade Federal de Campina Grande

---

Profa. Dra. Marcia Ramos Luiz  
Universidade Estadual da Paraíba

---

Prof. Dr. Fernando Fernandes Vieira  
Universidade Estadual da Paraíba

---

Prof. Dr. Gerson Marques dos Santos  
Universidade Federal do Vale do São Francisco

---

Prof. Dr. Cláudio Luis de Araújo Neto  
Universidade Federal do Maranhão

Dedico este trabalho aos meus filhos Hugo Leonardo Correia Barreto; Carlos Alberto Correia Barreto; Artur Henrique Correia Barreto; aos meus netos David Emanuel; Ana Luiza a minha mãe Leir Alves Gomes Barreto (*in memoriam*) e ao meu pai Enio Gomes Barreto (*in memoriam*).

## **AGRADECIMENTOS**

Agradeço a Deus e a Nossa Senhora Aparecida por estar me dando forças para realização deste trabalho e me orientando nos momentos mais difíceis.

Aos professores doutores William de Paiva, Márcio Camargo de Melo e a professora doutora Veruschka Escarião Dessoles Monteiro pelo apoio, na elaboração deste trabalho me orientando e fazendo observações precisas e estando sempre à disposição.

A todos os professores do departamento de Física da Universidade Federal de Pernambuco pelo apoio dado para execução deste trabalho.

Aos professores doutores Fernando Fernandes Vieira, Laércio Leal dos Santos, Gerson Marques dos Santos, Marcia Ramos Luiz, Cláudio Luis de Araújo Neto pelas sugestões e participação na banca de defesa da tese.

A todos os colegas do departamento de Física pelo apoio e incentivo na elaboração deste trabalho.

Aos professores da Universidade Estadual da Paraíba, pela dedicação e disposição em cooperar na execução deste trabalho.

Um agradecimento especial aos colegas Thiago Sena, Jeovana Santos, Jordan Souza, Fabiano Araujo e Daniel Bezerra pela colaboração no desenvolvimento deste trabalho.

Aos colegas dos grupos de pesquisa GPTECA da UEPB e GGA da UFCG pela grande colaboração que vem sendo dada para o desenvolvimento deste trabalho.

E a todos que contribuíram direta ou indiretamente no desenvolvimento deste trabalho. A secretária Nadilma pela atenção dada, durante este período de estudo no doutorado.

“Por vezes sentimos que aquilo que fazemos não é senão uma gota de água no mar. Mas o mar seria menor se lhe faltasse uma gota.”

(Madre Teresa de Calcutá).

## RESUMO

A quantificação das taxas de fluxo de gás metano através da camada de cobertura final em aterro sanitário podem variar no tempo e no espaço, portanto as ferramentas utilizadas para prever o comportamento do gás metano é essencial. O presente trabalho objetivou determinar a eficiência da camada de cobertura final em um aterro sanitário por meio de dados experimentais *in situ*, variáveis ambientais e geotécnicas para predição de emissões fugitivas de metano através de um modelo preditivo a partir de redes neurais artificiais. O campo experimental da pesquisa foi o Aterro Sanitário localizado na região semiárida do nordeste brasileiro. As determinações dos fluxos dos gases através da camada de cobertura foram realizadas utilizando-se a metodologia do ensaio com placa de fluxo estática em combinação com a medida de pressão, concentração dos gases, temperatura interna, temperatura externa e velocidade do vento. Foram realizados tratamentos estatísticos e Análise Descritiva dos dados, Análise de Componentes Principais, Regressão Linear Múltipla e por fim aplicação das Redes Neurais Artificiais. O banco de dados sintético foi concebido do modelo da regressão linear múltipla, no qual foram gerados 1000 valores aleatorizados e validados estatisticamente. Este estudo revelou que o melhor modelo obtido para prever a emissão de gás metano ocorreu na camada de entrada com dez neurônios, na camada oculta com vinte neurônios e um neurônio na camada de saída, com função de ativação da camada oculta *Tansing* e com função de ativação da camada de saída *Purelin* seguindo a arquitetura (10- 20- 1) com um *Mean Absolute Error* (MAE) de 0,001, *Determination Coefficient* ( $R^2$ ) de 1,00, *Efficiency Coefficient* (E) de 1,00, *Root Mean Square Error* (RMSE) com valor de 0,001 e *Normalize Root Mean Square Error* (NRMS) 9,3E-0,8, obtendo o melhor algoritmo de treinamento o (*Bayesian Regularization Backpropagation*). Ao se observar a escala preditiva foram apresentados valores de fluxo de metano fora dos recomendados pelas normas, com valor máximo de 492.73 g.m<sup>-2</sup>.dia<sup>-1</sup>. A predição, dos resultados obtidos apresentaram que a modelagem da rede neural artificial pode efetivamente prever o fluxo de metano através da camada de cobertura final de aterro sanitário, sendo importante para determinar a sua eficiência. A escala de eficiência demonstra a necessidade de estabelecer parâmetros para que os aspectos observados para a camada de cobertura tornem-se eficientes para que as emissões do gás metano fiquem dentro dos critérios determinados através das normas internacionais, trazendo melhoria no aspecto ambiental e financeiro para estes locais.

**Palavras-chaves:** aterro sanitário; gás metano; rede neurais artificiais; variações meteorológicas.



## ABSTRACT

The quantification of methane gas flow rates through the final cover layer in a landfill can vary over time and space, so the tools used to predict methane gas behavior are essential. The present study aimed to determine the efficiency of the final cover layer in a landfill through *in-situ* experimental data, environmental variables, and geotechnical factors for predicting fugitive methane emissions using an artificial neural network predictive model. The experimental field of research was the Sanitary Landfill located in the semi-arid region of northeastern Brazil. The determinations of gas flows through the cover layer were carried out using the static flux chamber test methodology in combination with measurements of pressure, gas concentrations, internal temperature, external temperature, and wind speed. Statistical treatments, Descriptive Data Analysis, Principal Component Analysis, Multiple Linear Regression, and finally the application of Artificial Neural Networks were performed. The synthetic database was designed using the multiple linear regression model, in which 1000 randomized and statistically validated values were generated. This study revealed that the best model obtained to predict methane gas emission occurred in the input layer with ten neurons, in the hidden layer with twenty neurons and in the output layer with one neuron, with the activation function of the hidden layer as *Tansig* and the activation function of the output layer as *Purelin*, following the architecture (10-20-1), with a *Mean Absolute Error* (MAE) of 0.001, *Determination Coefficient* ( $R^2$ ) of 1.00, *Efficiency Coefficient* (E) of 1.00, *Root Mean Square Error* (RMSE) with a value of 0.001, and *Normalized Root Mean Square Error* (NRMS) of 9.3E-0.8, obtaining the best training algorithm as Bayesian Regularization Backpropagation. When observing the predictive scale, methane flow values outside those recommended by standards were presented, with a maximum value of 492.73 g.m<sup>-2</sup>.dia<sup>-1</sup>. The prediction of the results showed that the modeling of the artificial neural network can effectively predict the methane flow through the final landfill cover layer, which is important for determining its efficiency. The efficiency demonstrates the need to establish parameters so that the aspects observed for the cover layer are efficient in keeping methane gas emissions within the criteria determined by international standards, bringing improvement to both environmental and financial scale aspects for these sites.

keywords: landfill ; methane gas; artificial neural network; meteorological variations.

## LISTA DE ILUSTRAÇÕES

<b>Figura 1</b> - Figura esquemática da estrutura de um aterro sanitário .....	19
<b>Figura 2</b> - Camadas de cobertura de solos utilizadas em aterro sanitário .....	19
<b>Figura 3</b> – Representação esquemática de uma camada de cobertura convencional em aterro sanitário .....	21
<b>Figura 4</b> - Representação esquemática de uma camada de cobertura evapotranspirativa em aterro sanitário .....	23
<b>Figura 5</b> - Representação esquemática de uma camada de cobertura tipo biocobertura em aterro sanitário .....	24
<b>Figura 6</b> – Representação esquemática da geração, conversão, transporte e emissão de gás em um aterro sanitário .....	25
<b>Figura 7</b> – Componentes de um neurônio biológico .....	35
<b>Figura 8</b> - Esquema de uma RNA.....	35
<b>Figura 9</b> - Rede Feedforward de uma camada de saída.....	36
<b>Figura 10</b> - Rede Feedforward de múltiplas camadas.....	37
<b>Figura 11</b> - Rede realimentada .....	37
<b>Figura 12</b> - Municípios que depositam RSU no aterro sanitário em estudo.....	45
<b>Figura 13</b> - Fluxograma da metodologia da pesquisa.....	44
<b>Figura 14</b> - Célula do Aterro Sanitário .....	45
<b>Figura 15</b> – Fotografia do dreno de gases vertical no aterro sanitário .....	45
<b>Figura 16</b> - Fotografias dos flares no aterro sanitário.....	46
<b>Figura 17</b> - Representação dos pontos de ensaios sobre a camada de cobertura final .....	46
<b>Figura 18</b> – Fotos dos procedimentos iniciais para as análises de solo (secagem prévia ao ar livre e destorroamento).....	47
<b>Figura 19</b> - Permeâmetro de parede flexível Triflex-2.....	48
<b>Figura 20</b> – Fotografias do ensaio com placa de fluxo tipo estática .....	49
<b>Figura 21</b> - Equipamentos utilizados para realização dos ensaios de fluxo de gás na camada de cobertura.....	50
<b>Figura 22</b> - Arquitetura do modelo considerando dez entradas, neurônios variando de 1 a 20 na camada oculta e uma camada de saída. ....	54
<b>Figura 23</b> - Variabilidade da temperatura externa (período seco e chuvoso) .....	57
<b>Figura 24</b> - Variabilidade da temperatura interna (período seco e chuvoso).....	58
<b>Figura 25</b> - Variabilidade da Pressão Atmosférica (período seco e chuvoso) .....	60
<b>Figura 26</b> - Variabilidade da umidade do ar (período seco e chuvoso) .....	61
<b>Figura 27</b> - Variabilidade da velocidade do vento (período seco e chuvoso).....	62
<b>Figura 28</b> - Variabilidade da Radiação solar (período seco e chuvoso).....	64
<b>Figura 29</b> - Variabilidade do Grau de compactação (período seco e chuvoso) .....	65
<b>Figura 30</b> - Variabilidade do Grau de saturação (período seco e chuvoso) .....	67
<b>Figura 31</b> - Variabilidade da massa específica aparente do solo (período seco e chuvoso) .....	68
<b>Figura 32</b> - Variabilidade da Umidade do solo (período seco e chuvoso).....	70
<b>Figura 33</b> - Variabilidade do Fluxo de metano (período seco e chuvoso) .....	71
<b>Figura 34</b> - Análise de componentes principais dos fatores intervenientes, meteorológicos e solos na emissão de gases pela camada de cobertura do Aterro Sanitário. ....	73
<b>Figura 35</b> - Comparação entre dados observados e preditos para o algoritmo <i>Trainbr</i> .....	84

<b>Figura 36</b> - Comparação entre a posição dos dados gerados e preditos para o fluxo de metano em relação ao algoritmo ( <i>Trainbr</i> ). .....	84
<b>Figura 37</b> – Valores observados x preditos ( <i>Trainbr</i> ) .....	85
<b>Figura 38</b> - Performance da RNA com melhor desempenho para predição do fluxo de metano ( <i>Trainbr</i> ).....	89
<b>Figura 39</b> - Comparação entre dados observados e preditos para o algoritmo <i>Trainscg</i> .....	88
<b>Figura 40</b> - Comparação entre a posição dos dados observado e preditos para o fluxo de metano em relação ao algoritmo ( <i>Trainscg</i> ).....	89
<b>Figura 41</b> - Valores observados x preditos ( <i>Trainscg</i> ) .....	89
<b>Figura 42</b> - Performance da RNA para predição do fluxo de metano ( <i>Trainscg</i> ) .....	90
<b>Figura 43</b> - Comparação entre dados observados e preditos para o algoritmo ( <i>Traincfg</i> ) .....	92
<b>Figura 44</b> - Comparação entre a posição dos dados observado e preditos para o fluxo de metano em relação ao algoritmo ( <i>traincfg</i> ) .....	93
<b>Figura 45</b> - Valores observados x preditos ( <i>Traincfg</i> ).....	93
<b>Figura 46</b> - Performance da RNA para predição do fluxo de metano ( <i>Traincfg</i> ).....	94
<b>Figura 47</b> - Comparação entre dados observados e preditos para o algoritmo <i>Trainlm</i> .....	96
<b>Figura 48</b> - Comparação entre a posição dos dados observados e preditos para o fluxo de metano em relação ao algoritmo <i>Trainlm (LM)</i> . .....	96
<b>Figura 49</b> - Gráfico com Valores observados x preditos ( <i>Trainlm</i> ) .....	97
<b>Figura 50</b> - Performance da RNA para predição do fluxo de metano ( <i>Trainlm</i> ) .....	98
<b>Figura 51</b> - Média do valor máximo e média do valor mínimo do fluxo de metano com nível de significância de 5% .....	101

## LISTA DE TABELAS

<b>Tabela 1</b> - Constituintes típicos do biogás.....	25
<b>Tabela 2</b> - Algoritmos de retropropagação e suas respectivas funções no MatLab.....	53
<b>Tabela 3</b> - Parâmetros utilizados para construção da RNA referente a emissões de GEE no aterro sanitário.....	54
<b>Tabela 4</b> - Análise descritiva dos dados .....	56
<b>Tabela 5</b> - Contribuições das variáveis nos dois primeiros componentes da ACP.....	76
<b>Tabela 6</b> - Matriz de correlação das variáveis de entrada da rede neural artificial .....	78
<b>Tabela 7</b> - Medidas de ajustamento do modelo da regressão .....	79
<b>Tabela 8</b> - Análise de variância da modelagem constitutiva do fluxo de metano. ....	80
<b>Tabela 9</b> - Coeficiente de regressão para determinação do fluxo de metano .....	81
<b>Tabela 10</b> - Métricas de desempenho do algoritmo Trainbr.....	82
<b>Tabela 11</b> - Métricas de desempenho do algoritmo Trainscg.....	86
<b>Tabela 12</b> - Métricas de desempenho do algoritmo Traincfg.....	90
<b>Tabela 13</b> - Métricas de desempenho do algoritmo Trainlm.....	94
<b>Tabela 14</b> - Média do valor máximo e média do valor mínimo do fluxo de metano .....	102

## LISTA DE ABREVIATURAS E SIGLAS

ABNT- Associação Brasileira de Normas Técnicas  
ACP- Análise de Componentes Principais  
ASMOC - Aterro Sanitário Metropolitano Oeste de Caucaia  
CP- Componente Principal  
CFI- *Carbon Farming Initiative*  
CO- Monóxido de Carbono  
CO<sub>2</sub>- Dióxido de Carbono  
CH<sub>4</sub>- Gás Metano  
FA- Função de Ativação  
GEE- Gases de Efeito Estufa  
GGA- Grupo de Geotecnia Ambiental  
H<sub>2</sub>S- Gás Sulfídrico  
NBR- Norma Brasileira  
RSU- Resíduos Sólidos Urbanos  
RNA- Redes Neurais Artificiais  
USEPA- *United States Environmental Protection Agency*  
ISWA- *International Solid Waste Association*  
IPCC- *Intergovernmental Panel on Climate Change*  
SQR- soma dos Quadrados dos Resíduos  
MAE- *Mean absolute error*  
MAPE- *Mean absolute percentage error*  
RMSE- *Root mean square error*  
UFMG- Universidade Federal de Campina Grande  
O<sub>2</sub> - Oxigênio

## LISTA DE QUADROS

<b>Quadro 1</b> - Funções e composições das camadas de aterros sanitários.....	20
<b>Quadro 2</b> - Composições e espessuras das camadas de coberturas finais de Aterros Sanitários brasileiros e internacionais .....	22
<b>Quadro 3</b> - Emissões fugitivas de metano verificada com placa de fluxo estática em diferentes regiões do Brasil, Ásia, Estados Unidos e Europa .....	26
<b>Quadro 4</b> - Forma, dimensões e volume de placas de fluxo (estática e dinâmica) encontradas na literatura.....	30
<b>Quadro 5</b> – Funções de ativação .....	38
<b>Quadro 6</b> - Trabalhos desenvolvidos com aplicação das RNA na geotecnia.....	41
<b>Quadro 7</b> - Trabalhos desenvolvidos com aplicação das RNA para previsão das concentrações das emissões de GEE.....	42
<b>Quadro 8</b> – Descrição dos ensaios geotécnicos e metodologias utilizadas .....	48
<b>Quadro 9</b> - Características dos equipamentos utilizados para medição de biogás na placa de fluxo.....	50
<b>Quadro 10</b> - Resumo com os melhores resultados dos treinamentos das redes neurais artificiais .....	98
<b>Quadro 11</b> - Indicadores da estatística descritiva com maiores e menores fluxos de metano, Brasil, Ásia, Estados Unidos e Europa .....	101

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>15</b>
<b>1.1</b>	<b>Objetivos.....</b>	<b>16</b>
<i>1.1.1</i>	<i>Objetivo geral.....</i>	<i>16</i>
<i>1.1.2</i>	<i>Objetivos específicos .....</i>	<i>16</i>
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA .....</b>	<b>18</b>
<b>2.1</b>	<b>Aterros Sanitários.....</b>	<b>18</b>
<b>2.2</b>	<b>Camada de Cobertura.....</b>	<b>19</b>
<i>2.2.1</i>	<i>Tipos de camada de cobertura.....</i>	<i>21</i>
<b>2.3</b>	<b>Gases gerados em aterros sanitários .....</b>	<b>24</b>
<i>2.3.1</i>	<i>Emissões fugitivas de biogás pela camada de cobertura de solo compactado .</i>	<i>26</i>
<b>2.4</b>	<b>Fatores que interferem no fluxo de gás metano pela camada de cobertura em aterro .....</b>	<b>27</b>
<b>2.5</b>	<b>Mecanismos de transporte de gases em aterros sanitários .....</b>	<b>28</b>
<b>2.6</b>	<b>Mensuração do fluxo de gases em camadas de coberturas de aterros sanitários.....</b>	<b>30</b>
<b>2.7</b>	<b>Modelagem estatística como ferramenta ao monitoramento da emissão de gases em aterros sanitários .....</b>	<b>31</b>
<i>2.7.1</i>	<i>Estatística descritiva .....</i>	<i>31</i>
<i>2.7.2</i>	<i>Regressão linear.....</i>	<i>32</i>
<i>2.7.3</i>	<i>Teste de seleção de modelos estatísticos.....</i>	<i>32</i>
<i>2.7.4</i>	<i>Modelagem não constitutiva.....</i>	<i>33</i>
<b>2.8.</b>	<b>Redes Neurais Artificiais (RNA) .....</b>	<b>33</b>
<i>2.8.1</i>	<i>Arquitetura das redes neurais .....</i>	<i>36</i>
<i>2.8.2</i>	<i>Funções de Ativação.....</i>	<i>38</i>
<i>2.8.3</i>	<i>Métricas de avaliação das RNA .....</i>	<i>39</i>
<i>2.8.4</i>	<i>Algoritmos de treinamento das redes neurais artificiais.....</i>	<i>41</i>
<i>2.8.5</i>	<i>Trabalhos realizados em aterros sanitários a partir de redes neurais artificiais .....</i>	<i>41</i>
<b>3</b>	<b>MATERIAIS E MÉTODOS .....</b>	<b>43</b>
<b>3.1</b>	<b>Área de estudo.....</b>	<b>43</b>
<b>3.2</b>	<b>Amostragem .....</b>	<b>46</b>
<b>3.3</b>	<b>Caracterização geotécnica do solo da camada de cobertura .....</b>	<b>47</b>
<b>3.4</b>	<b>Medições de gases do efeito estufa.....</b>	<b>49</b>
<b>3.5</b>	<b>Análise de dados.....</b>	<b>51</b>

3.5.1	<i>Modelagem não constitutiva com Redes Neurais Artificiais Para Fluxo de CH<sub>4</sub></i>	52
3.5.2	<i>Escala de eficiência</i>	55
4	<b>RESULTADOS E DISCUSSÕES</b>	56
4.1	<b>Análise descritiva dos dados</b>	56
4.2	<b>Variáveis Meteorológicas</b>	57
4.2.1	<i>Temperatura externa</i>	57
4.2.2	<i>Temperatura Interna</i>	58
4.2.3	<i>Pressão atmosférica</i>	59
4.2.4	<i>Umidade relativa do ar</i>	60
4.2.5	<i>Velocidade do vento</i>	62
4.2.6	<i>Radiação solar</i>	63
4.3	<b>Caracterização da Camada de Cobertura em termos geotécnicos</b>	65
4.3.1	<i>Grau de compactação (GC)</i>	65
4.3.2	<i>Grau de Saturação</i>	66
4.3.3	<i>Massa específica aparente do solo</i>	68
4.3.4	<i>Umidade do solo</i>	69
4.4	<b>Emissão fugitiva de CH<sub>4</sub></b>	71
4.4.1	<i>Metano</i>	71
4.5	<b>Análises Multivariadas</b>	72
4.5.1	<i>Análise de Componentes Principais (ACP)</i>	72
4.5.2	<i>Correlação entre parâmetros meteorológicos e geotécnicos do solo da camada de cobertura do Aterro Sanitário com as emissões de metano</i>	76
4.6	<b>Medidas de Ajustamento do modelo</b>	79
4.7	<b>Redes Neurais Artificiais</b>	82
4.7.1	<i>Resultados e desempenho dos treinamentos de redes neurais artificiais</i>	82
4.7.1.1	<i>Algoritmo Trainbr (Bayesian Regularization Backpropagation)</i>	82
4.7.1.2	<i>Algoritmo Trainscg (Scale Conjugate Gradient)</i>	86
4.7.1.3	<i>Algoritmo Traincfg (Fletcher-Powell Conjugate Gradient)</i>	90
4.7.1.4	<i>Algoritmo Trainlm (Levenberg–Marquardt)</i>	94
4.7.2	<i>Discussão geral das métricas avaliadas</i>	98
4.8	<b>Escala de eficiência</b>	100
5	<b>CONCLUSÕES</b>	103
	<b>REFERÊNCIAS</b>	104
	<b>APÊNDICE A - CÓDIGO DA REDE NEURAL ARTIFICIAL (RNA)</b>	119



## 1 INTRODUÇÃO

A camada de cobertura final é um dos principais componentes da estrutura do aterro sanitário, tendo como funções diminuição da proliferação de vetores e odores, controlar as emissões de gases para o meio ambiente, preservação contra intervenções antrópicas e diminuição da infiltração de água (Moreira *et al.*, 2020).

Existem dois tipos básicos de camadas de cobertura de aterros sanitários: a camada convencional, formada predominantemente por solos argilosos compactados e a camada alternativa, elaborada a partir de solos e outros materiais como produtos de compostagem e resíduos de construção civil. As camadas alternativas são construídas para otimizar o desempenho do aterro, reduzindo as emissões de gases e aumentando a retenção de líquidos em seu interior (Costa *et al.*, 2018).

As camadas de cobertura de aterros podem ainda ter a presença de geogrelhas que são fabricadas com alto peso molecular e fios de poliéster de alta tenacidade, desenvolvidas para serem um material de reforço de fácil instalação. Sua malha de abertura possui dimensões estáveis, assegurando que a resistência à tração será mobilizada sem deformação excessiva. Seu uso é predominantemente estrutural como reforço de estruturas de solo e aterros, podendo também, ser usadas para sobrepassar vazios que podem se desenvolver sob carregamentos em camadas granulares (estradas e autoestradas) ou sob sistemas de cobertura de aterros sanitários.

Destaca-se que o projeto e execução de camada de cobertura de aterros sanitários deve ter elevada eficiência com relação as emissões fugitivas de gases, sobretudo o metano, visto que o aumento da permeabilidade do solo aos gases, em camadas de cobertura de aterros sanitários, contribui para o aumento das concentrações do gás metano (CH<sub>4</sub>) na atmosfera.

Os gases que fluem pela camada de cobertura de solo compactado em aterros sanitários apresentam composições diversas e bastante tóxicas dependendo da concentração de cada gás na composição do biogás. Assim, quantificar emissões de gases de aterro que fluem pelos solos de camadas de cobertura deve ser de interesse não só devido a ganhos econômicos, mas também ambientais. O mais importante nesse sentido é padronizar métodos de medir qualitativamente e quantitativamente a eficiência dessas camadas (Maciel & Jucá, 2011).

A NBR 13.896/1997 (ABNT, 1997) determina o coeficiente de permeabilidade à água para camadas de base e de cobertura de aterro sanitário, mas não define a permeabilidade à gases. A determinação da permeabilidade do solo é de grande significância para a execução de projetos que necessitam da avaliação dos parâmetros de infiltração, escoamento superficial, água subterrânea, drenagem e estruturas (Singh *et al.*, 2020), contudo para se determinar a

eficiência de cada camada de cobertura é preciso também ser determinada a permeabilidade aos gases.

Dados geotécnicos e de permeabilidade gasosa possibilita determinar a eficiência de camada de cobertura final de aterros, contudo a construção de uma escala para mensurar a eficiência das camadas de cobertura final de aterros sanitários, em relação à retenção do biogás, deve levar em consideração os processos de variabilidade temporal e espacial das taxas de fluxo desses gases, sendo utilizada nos mais diversos cenários: tais como, condições meteorológicas locais, execução e operação dos aterros, tipo de camada de cobertura, aspectos geotécnicos, além das legislações vigentes

Neste sentido, o uso de modelos computacionais como as Redes Neurais Artificiais (RNA), podem determinar previsões para os fluxos dos gases em camadas de cobertura final de aterros por meio de dados de entrada relativos às condições meteorológicas locais, execução e operação dos aterros, tipo de camada de cobertura, aspectos geotécnicos e legislações vigentes, contribuindo para minimizar os problemas ambientais decorrentes da fuga dos gases para atmosfera.

Diversos modelos de RNA vem sendo aplicados para predição das concentrações das emissões de gases do efeito estufa (GEE) em aterros sanitários contudo há poucos estudos para previsão de emissões fugitivas de biogás pela camada de cobertura final, especialmente com relação ao CH<sub>4</sub> (Mateus, 2019).

## **1.1 Objetivos**

### ***1.1.1 Objetivo geral***

- Determinar a eficiência da camada de cobertura final em um aterro sanitário por meio de dados experimentais *in situ*, variáveis ambientais e geotécnicas para predição de emissões fugitivas de metano através de um modelo preditivo a partir de RNA.

### ***1.1.2 Objetivos específicos***

- Determinar o comportamento da camada de cobertura final de solo compactado em um Aterro Sanitário no semiárido brasileiro, em dois períodos sazonais (seca e chuva) com relação aos aspectos geotécnicos e meteorológicos.
- Quantificar as emissões fugitivas de CH<sub>4</sub> pela camada de cobertura final em um Aterro Sanitário, em dois períodos sazonais (seca e chuva).

- Correlacionar dados geotécnicos e meteorológicos com emissões fugitivas de CH<sub>4</sub> na camada de cobertura final em um Aterro Sanitário.
- Predizer a emissão de CH<sub>4</sub> por meio de um modelo preditivo através de RNA da camada de cobertura final em aterros.
- Propor uma escala para análise de eficiência da camada de cobertura final para aterros sanitários em relação as emissões fugitivas de CH<sub>4</sub> levando em consideração aspectos geotécnicos e variáveis meteorológicas locais.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 Aterros Sanitários

A geração anual de resíduos sólidos urbanos (RSU) no ano de 2016, atingiu aproximadamente 2,01 bilhões de toneladas dos quais aproximadamente 44% são compostos por orgânicos, enquanto os recicláveis representam 38%. Este número vem crescendo, de modo que até 2050 espera-se alcançar a marca de 3,4 bilhões de toneladas/ano de resíduos produzidos (Kaza *et al.*, 2018).

A disposição dos RSU dá-se, em sua maioria em aterros sanitários, que podem ser definidos pela norma NBR 8419 (ABNT, 1992):

“Uma técnica de disposição de RSU sem causar danos à saúde pública e à segurança, minimizando os impactos ambientais. Este método utiliza princípios de engenharia para confinar os resíduos sólidos à menor área possível e reduzi-los ao menor volume permissível, cobrindo-os com uma camada de terra na conclusão de cada jornada de trabalho, ou a intervalos menores, se for necessário.”

No entanto, a decomposição da matéria orgânica nos RSU começa quando são coletados, transferidos e transportados, continuando depois que o resíduo é despejado para o aterro, até que sejam compactados e cobertos (Duan *et al.*, 2021). Nos aterros, os resíduos orgânicos sofrem degradação microbiana, além de transformações físico-químicas, mudando o processo de aeróbico para anaeróbico ao longo de um determinado período, o que resulta na produção de líquidos (lixiviado) e gases (biogás), que precisam ser coletados e tratados (Zhao *et al.*, 2014).

A falta de segregação na fonte e o alto conteúdo orgânico de resíduos depositados em aterros sanitários, além de operações realizadas de maneira incorreta, tem intensificado emissões de gases efeito estufa, sendo considerados a terceira maior fonte de emissão antropogênica de CH<sub>4</sub> depois da agricultura e minas de carvão (ISWA, 2019).

Estudos realizados em 2019 pelo *Intergovernmental Panel on Climate Change* (IPCC), a concentração atmosférica de CH<sub>4</sub> aumentou cerca de 150% desde 1750. Aproximadamente 5,0 a 6,0 bilhões de toneladas de CH<sub>4</sub> são liberadas na atmosfera anualmente, sendo os aterros sanitários produtores de uma porcentagem significativa deste gás (ISWA, 2019). Em relação ao dióxido de carbono, os RSU contribuíram com um valor estimado de 760,6 milhões de toneladas de emissões globais em 2010 (Johari *et al.*, 2012).

O aterro sanitário possui propriedades estruturais (Figura1), de modo que a qualidade da camada de cobertura final, tem um grande potencial para interferir nas emissões de gases e

no controle da poluição das águas subterrâneas. O desempenho da camada de cobertura de aterros sanitários pode variar ao longo do tempo, em função das características do solo, índices de vazios, grau e umidade de compactação, além das variações climáticas como temperatura, pressão atmosférica e precipitação pluviométrica (Almeida, 2017).

**Figura 1** - Figura esquemática da estrutura de um aterro sanitário



**Fonte:** Portal Resíduos Sólidos, 2021.

## 2.2 Camada de Cobertura

A camada de cobertura final de aterros sanitários, também conhecida como *liner*, consiste em um sistema de proteção superficial que pode ser composto em geral, com solo argiloso compactado ou misturas de solos com materiais geossintéticos ou alternativos, que tem como função assegurar a proteção à saúde humana e meio ambiente, reduzindo os impactos através da eliminação de vetores e redução da exalação de odores, infiltração de água da chuva, fluxo de gases, erosão, além de recomposição da paisagem (Santos, 2019).

As camadas de cobertura em aterros sanitários apresentam composições de materiais distintos (Figura 2), e funções (Quadro 1) as quais dependem das características dos aterros (Boscov, 2012).

**Figura 2**- Camadas de cobertura de solos utilizadas em aterro sanitário



**Fonte:** adaptado de USEPA (2004).

**Quadro 1-** Funções e composições das camadas de aterros sanitários

Camada	Função	Composição do material utilizado
Superficial	Função de minimizar os efeitos da erosão causada pela água e pelo vento, proporcionando condições para o crescimento da vegetação.	Solo com vegetação, pedregulho.
Camada de proteção ou biótica.	Está localizada abaixo da camada superficial e tem como funções proteger as camadas subjacentes dos processos erosivos e da exposição a ciclos de umedecimento e secagem ou ciclos de gelo e degelo.	Solo, materiais reciclados.
Camada drenante.	Responsável por remover a água que penetra para o interior da camada de cobertura, minimizando a percolação e conduzindo-a para fora do aterro.	Areia e pedregulhos.
Camada impermeabilizante.	Responsável pela impermeabilização superior do aterro e tem como função principal minimizar a percolação da água no sistema de cobertura, impedindo a infiltração e promovendo o armazenamento ou drenagem lateral da água proveniente das camadas superiores.	Argila compacta
Camada de controle de gases.	Direciona os gases gerados pela massa de resíduos para os drenos de gás.	Areia, pedregulho, geotêxteis.
Camada de fundação ou de regularização da base.	Componente mais inferior do sistema de cobertura e serve para proporcionar um subleito firme para compactação de camadas sobrepostas aos resíduos, devendo ainda reduzir os efeitos de possíveis recalques diferenciais.	Resíduos ou materiais reciclados

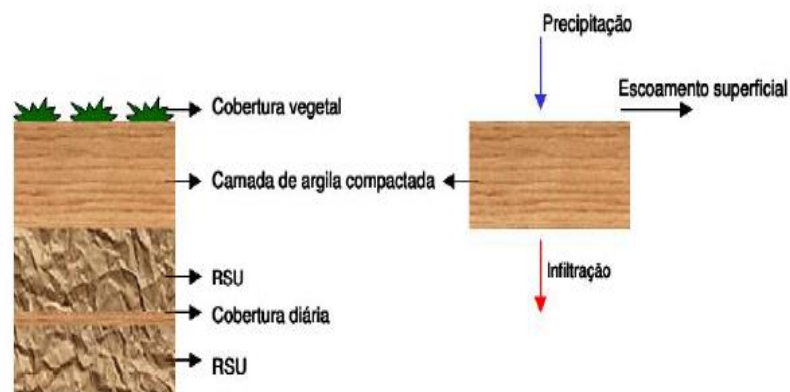
**Fonte:** Adaptado de Barreto (2022).

O solo utilizado na camada de cobertura final de um aterro sanitário deve considerar, seus aspectos geotécnicos. Alguns dos fatores importantes para o uso dos solos são: a granulometria, compactação, condutividade hidráulica. As camadas de cobertura final em aterros sanitários, mais utilizadas são: as camadas convencionais, coberturas evapotranspirativas e oxidativas (Garbo & Cossu, 2017).

### 2.2.1 Tipos de camada de cobertura

No Brasil, grande parte dos aterros sanitários utilizam a cobertura convencional, visto que há possibilidade de extração do solo na própria área do aterro sanitário ou nas proximidades, além do baixo custo quando comparado com as geomembranas (Santos, 2019). Apesar de não existir legislação específica sobre o tipo de material que a camada de cobertura deve ser constituída, de modo geral estas são de solos argiloso compactado e intercalados, com espessura entre 0,6 a 1,5m (Figura 3), visando a impermeabilização do topo das células dos aterros sanitários (Mariano, 2008).

**Figura 3** – Representação esquemática de uma camada de cobertura convencional em aterro sanitário



**Fonte:** Costa (2015).

Segundo a USEPA (2020), os aterros de resíduos sólidos não perigosos, que utilizam solos compactados, devem possuir na sua composição argila ou outros materiais que possuam percentual mínimo de partículas com diâmetro inferior a 0,075mm e limite de liquidez maior que 30%. Além disso, essas camadas devem apresentar espessura mínima de 45cm.

Dentre as normas internacionais em relação as camadas convencionais, destaca-se a normativa adotada pela Agência de Proteção Ambiental Americana (*United States Environmental Protection Agency* – USEPA), em que o sistema de cobertura final deve possuir uma camada de argila compactada com coeficiente de permeabilidade menor ou igual a  $1 \times 10^{-5}$  cm/s e as normativas europeias que são utilizadas para contribuir em alguns procedimentos práticos em relação à cobertura final de solo utilizada em aterros sanitários (Araújo, 2017).

A NBR 13896 (ABNT, 1997) determina que próximo ao local de instalação do aterro deve existir uma reserva natural extensa e homogênea de solo com coeficiente de permeabilidade igual ou menor a  $10^{-8}$  m/s e uma zona não saturada com mais de 3m de espessura.

Naturalmente parte dos gases gerados em aterros sanitários (25 a 55%) atravessa o sistema de cobertura (camada de solo) na forma de emissões fugitivas (Racho *et al.*, 2013), no entanto a cobertura convencional pode intensificar essas emissões, uma vez que podem apresentar fissuras em virtude dos processos de contração e expansão do solo, motivado pelas variações climáticas, levando o biogás a escapar livremente para a atmosfera (Oliveira *et al.*, 2013).

No Quadro 2 são expostos exemplos das composições e espessuras de camadas de coberturas finais, adotadas em alguns aterros sanitários no Brasil e em alguns aterros internacionais.

**Quadro 2** - Composições e espessuras das camadas de coberturas finais de Aterros Sanitários brasileiros e internacionais

Referência	Aterro	Composição da cobertura
Magalhães (2005)	Aterro Sanitário de Belo Horizonte (Belo Horizonte - MG)	Uma camada de solo misturada com resíduos da construção civil (espessura: 0,50m – 2,00 m)
Mariano (2008)	Aterro de Aguazinha (Olinda - PE)	Uma camada de solo areno argiloso (espessura 0, 25m a 0,90 m)
Machado <i>et al.</i> (2009)	Aterro Sanitário Metropolitano Centro (Salvador - Ba)	Drenos horizontais abaixo de uma membrana de PVC, uma camada de solo argiloso (espessura: 0,60 m) e uma camada de solo orgânico (espessura: 0,20 m).
Rosa <i>et al.</i> (2011) Aterro de RSU de Santa Maria (Santa Maria - RS)	Aterro de RSU de Santa Maria - RS	Uma camada de solo argiloso (espessura: 0,20m – 1,00 m)
Silva (2011)	Aterro de Nova Iguaçu (Nova Iguaçu - RJ)	Uma camada de areia silto argilosa (espessura: 0,80m)
Capaccioni <i>et al.</i> (2011)	Aterro Fano (Itália)	Uma camada de argila não compactada abaixo de uma camada de argila compactada.
Scheutz <i>et al.</i> (2014)	Aterro Klintholm (Dinamarca)	Uma camada de solo argiloso (espessura: 3,0 – 4,0 m)
Gallego <i>et al.</i> (2014)	Aterro Can Planas (Espanha, 1995)	Uma camada de argila compactada (espessura: 1,0 m), abaixo de uma camada de pedregulho (espessura: 20 cm) e solo orgânico (espessura: 20 cm)
Moreira <i>et al.</i> (2020)	Aterro Sanitário de Campina Grande - PB	Uma camada de areia argilosa (espessura: 0,60-1,30m)

**Fonte:** Adaptado de Barreto *et al.* (2020).

As camadas evapotranspirativas, são formadas por um material fino (camada capilar) construída acima de uma camada formada por bloco capilar com uma inclinação, sendo a vedação baseada em forças capilares e de fluxo não saturado (Lopes *et al.*, 2012).



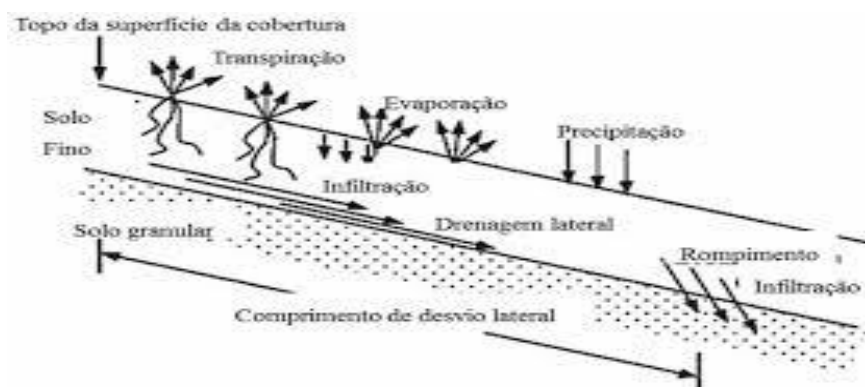
Esse tipo de camada utiliza características geotécnicas do solo como uma barreira para minimizar a infiltração da água na superfície dos aterros e, ao mesmo tempo, dificultar a saída de gases (Seheum *et al.*, 2008). Estes sistemas de coberturas podem ser aplicados em regiões com clima árido ou semiárido (USEPA, 2004), podendo ser uma opção viável sua aplicação para as condições brasileiras a depender de análises técnicas do material utilizado e de análises econômica, climáticas e ambientais do local.

Nos sistemas de cobertura convencional a infiltração é controlada pela maximização do escoamento superficial, enquanto, nas camadas evapotranspirativas, a infiltração é controlada pela capacidade do solo em armazenar água (Costa, 2015).

Apesar das vantagens das camadas evapotranspirativas, estas não são apropriadas em locais onde a evapotranspiração é insuficiente para remover a precipitação, visto que com o aumento da espessura (quase 3,0 m em alguns casos) os custos só permanecem baixos se o solo necessário estiver disponível nas proximidades do aterro (Goldenberg & Reddy, 2017).

Assim, os requisitos, para o dimensionamento desses sistemas de cobertura recomenda a escolha dos materiais de acordo com suas características e propriedades físicas. A NBR 13896 (ABNT, 1997) apenas expõe que o projeto da cobertura final deve minimizar a infiltração de água na célula, exigir pouca manutenção, não estar sujeita a erosão, acomodar assentamentos sem fratura e possuir um coeficiente de condutividade hidráulica inferior ao solo natural da área do aterro (menor que  $5 \times 10^{-7}$  m/s). A Figura 4 mostra um esquema do balanço hídrico de uma cobertura evapotranspirativa.

**Figura 4** - Representação esquemática de uma camada de cobertura evapotranspirativa em aterro sanitário



**Fonte:** Costa (2015).

A camada de cobertura metanotrófica (oxidativas) é um sistema projetado para otimizar as condições ambientais de consumo biológico de  $\text{CH}_4$ , que deve funcionar como um vasto biofiltro no aterro (Figura 5), geralmente utilizam materiais com produtos compostados que criam condições ótimas no desenvolvimento de microrganismos que consomem  $\text{CH}_4$  (Humer

*et al.*, 2009). A oxidação ocorre próximo à superfície da camada de cobertura e quanto maior for a profundidade da camada menor a eficiência da oxidação do metano (Pratt *et al.*, 2012).

**Figura 5** - Representação esquemática de uma camada de cobertura tipo biocobertura em aterro sanitário



**Fonte:** adaptado de USEPA (2004).

Os materiais utilizados nas camadas metanótroficas devem garantir porosidade aerada suficiente para que ocorra as trocas gasosas, permitindo a penetração de oxigênio da atmosfera e o fornecimento de metano dos resíduos, os quais são importantes para os processos de oxidação microbiana do metano (Huber-Humer *et al.*, 2011).

Algumas propriedades do solo como: teor de umidade, compactação, porosidade, teor da matéria orgânica, concentração  $\text{CH}_4$ , fluxo de  $\text{CH}_4$ , concentração de oxigênio, espessura da camada, condições climáticas e concentração de substâncias inibidoras podem influenciar o processo oxidativo do  $\text{CH}_4$  (Berger *et al.*, 2005), contudo as principais vantagens da camada metanótrofica é que são relativamente mais econômicas, em termos de operação e instalação, em comparação com um sistema de coleta de gás convencional, e exigem baixos custos de manutenção e mão de obra (Garbo & Cossu, 2017). Esse tipo de camada pode ser utilizada em aterro sanitário de pequeno porte ou aterros antigos onde a quantidade de biogás produzido é baixa e a utilização de um sistema de captação de biogás não é técnica e economicamente viável (Scheutz *et al.*, 2011).

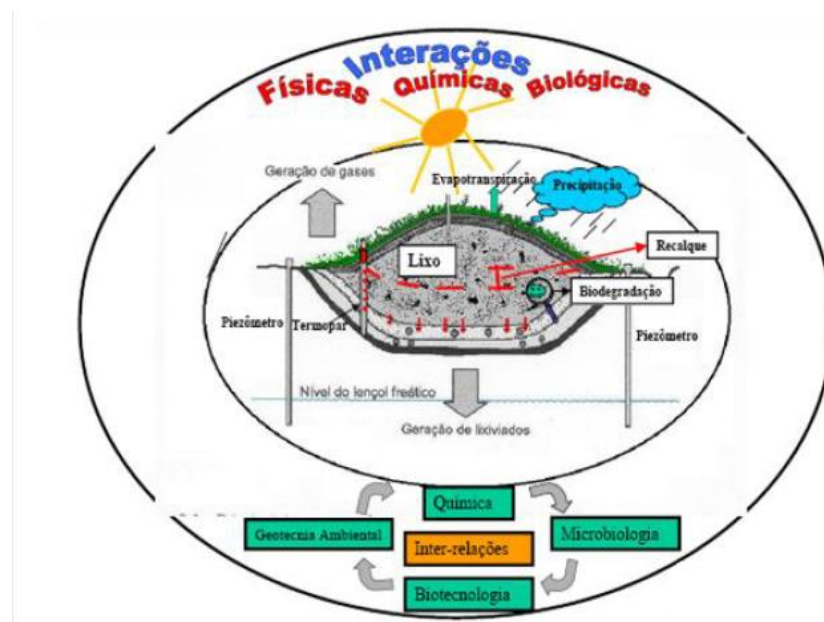
### 2.3 Gases gerados em aterros sanitários

O  $\text{CH}_4$  é um dos principais gases causadores do efeito estufa, representando um grave risco ambiental por dispor de potencial de aquecimento global 28 vezes superior ao dióxido de carbono. Apesar de estar presente em menor concentração que o  $\text{CO}_2$  na atmosfera, o  $\text{CH}_4$  varia de 45-60% na fração volumétrica do biogás (IPCC, 2019). Deste modo, nas últimas décadas, a

mitigação das emissões de GEE, em aterros sanitários está sendo um desafio enfrentado por muitos países em desenvolvimento (Kaza *et al.*, 2018).

O biogás produzido em aterros sanitários é obtido a partir da decomposição anaeróbia (ausência de oxigênio) dos resíduos orgânicos. Sua composição é a porcentagem obtida dos gases que varia de acordo com o substrato biodigerido, (natureza e tamanho), condições de funcionamento da biodigestão além de variáveis como pH, temperatura, nutrientes, capacidade tampão e taxa de oxigenação (Faria, 2012). A Figura 6 mostra os processos de transporte e emissão de gases em um aterro de RSU.

**Figura 6** – Representação esquemática da geração, conversão, transporte e emissão de gás em um aterro sanitário



**Fonte:** Adaptado de Barreto *et al.* (2020).

A composição média dos gases gerados da biodigestão anaeróbia está descrita na Tabela 1.

**Tabela 1**– Constituintes típicos do biogás

Constituinte	Percentual (% v/v)
Metano	45 – 60
Dióxido de carbono	40 – 60
Nitrogênio	2 – 5
Oxigênio	0,1 – 1,0
Amônia	0,1 – 1,0
Sulfetos, dissulfetos, mercaptanos etc	0 – 1,0
Hidrogênio	0 – 0,2
Monóxido de carbono	0 – 0,2
Constituintes traços	0,01 – 0,6

**Fonte:** Adaptado de O’Leary e Tchobanoglous (2002).

### 2.3.1 Emissões fugitivas de biogás pela camada de cobertura de solo compactado

Aproximadamente 5% das emissões antropogênicas de gases GEE são derivados do descarte de RSU em todo o mundo (Salomon *et al.*, 2012). Assim, os principais fatores que contribuem para o aparecimento e desaparecimento de GEE em aterro sanitário são: a geração pelo processo de biodegradação, remoção de CH<sub>4</sub> por meio de oxidação via microrganismos metanotróficos, além da fuga por meio de drenos e da interface da camada de cobertura (Candiani & Moreira, 2018). No Quadro 3 são reportadas medidas de fluxo de metano fugitivo pela camada de cobertura final em diversos aterros no Brasil, Europa, Ásia e Estados Unidos.

**Quadro 3** - Emissões fugitivas de metano verificada com placa de fluxo estática em diferentes regiões do Brasil, Ásia, Estados Unidos e Europa

Local de Estudo	Referência Bibliográfica	Composição da camada de cobertura	Emissão fugitiva de metano g.m <sup>-2</sup> .dia <sup>-1</sup>
Aterro Tamangapa (Indonésia)	Lando; Nakayama Shinamoka (2017)	Não informado	4,9 a 165,2
Aterro Nuevo Leon (México)	Gonzales Valencia <i>et al.</i> (2016)	Camada convencional	10 a 575
Aterro Fakse (Dinamarca)	Scheutz <i>et al.</i> (2009)	Camada biocobertura	77 a 155
Aterro da Aguazinha-PE (Brasil)	Mariano (2008)	Camada de cobertura areno-argiloso	0,004 a 400
Aterro na Califórnia (EUA)	Abichou <i>et al.</i> (2009)	Camada argila arenosa	0,1 a 175,7
Aterro da Muribeca-PE (Brasil)	Maciel (2003)	Camada de solo argiloso compactado	0,1 a 363,63
Aterro de BH-MG (Brasil)	Catapreta (2008)	Camada evapotranspirativa e barreira capilar	23,2 a 337,6
Aterro Caieiras-SP (Brasil)	Candiani & Viana (2018)	Camada convencional	18,6 a 149,8
Aterro em Campina Grande- PB (Brasil)	Moreira (2018)	Camada convencional	0 a 0,09
Aterro de Nashua (Estados Unidos)	Czepiel <i>et al.</i> (1996)	Camada de solo areno-argiloso	1.495,0
Aterro de Sudokwon (Inchon City, Coreia do Sul)	Park & Shin (2001)	Camada de solo composto por areia, silte e argila	176,85 a 3805,55
(Leste do Japão)	Ishigaki <i>et al.</i> (2005)	Camada de argila	0,038 a 384,0
Aterro Nova Iguaçu - RJ	Oliveira (2013)	Camada metanotrófica	0 a 35,23
Aterro Bandeirantes - SP	Silva <i>et al.</i> (2013)	Camada convencional	0,1 a 148,4
Aterro Sanitário Salvador - BA	Damasceno (2018)	Camada convencional	0 a 355,55
Aterro Sanitário Seropédica	Araújo (2016)	Camada convencional	7,2 a 369,2
	He <i>et al.</i> (2012)	Camada de solo argiloso	137

Aterro Sanitário A-Su-Wei na China	Li et al (2020)	Camada de solo de argila e cobertura vegetal	2,69 a 212
------------------------------------	-----------------	--	------------

**Fonte:** Adaptado de Barreto *et al* (2021).

Segundo Moreira (2018), no aterro sanitário em estudo o fluxo de CH<sub>4</sub> através da camada de cobertura final, foi 23 vezes inferior ao limite recomendado pela *Carbon Farming Initiative* (CFI, 2013). Essa norma estabelece um fluxo máximo de metano de 64,96 g.m<sup>-2</sup>.dia<sup>-1</sup> para camada de cobertura final de aterros sanitários.

#### 2.4 Fatores que interferem no fluxo de gás metano pela camada de cobertura em aterro

Os fatores que interferem nos processos de emissão do CH<sub>4</sub> pela camada de cobertura do aterro sanitário podem ser divididos em três grupos: a) condições meteorológicas (pressão atmosférica, precipitação pluviométrica, temperatura, velocidade do vento); b) condições da camada de cobertura (tipologia do solo, permeabilidade, porosidade, umidade, grau de compactação, grau de saturação); c) condições do ambiente interno em relação à massa dos resíduos ( drenagem interna dos gases, recalques diferenciais) (Rachor *et al.*, 2013). Para as emissões de metano, além das condições citadas destaca-se a variação temporal e espacial decorrentes das mudanças nas condições meteorológicas (Bian *et al.*, 2018).

A pressão atmosférica é considerada um fator chave no controle e transporte de emissões de CH<sub>4</sub> na camada de cobertura (Gebert & Groengroeft, 2011). Há uma correlação importante entre a emissão e a pressão atmosférica que podem ser negativas, ou seja maior pressão atmosférica menor as emissões de CH<sub>4</sub> (Shen *et al.*, 2018). A baixa pressão atmosférica converte o mecanismo de transporte de gás dominante de difusão para advecção e resultam em uma menor eficiência de oxidação de CH<sub>4</sub> (Bian *et al.*, 2018).

A temperatura relacionada com as condições meteorológicas é um fator que influencia no fluxo do biogás nos aterros, estimulando a movimentação das partículas de gás, tendendo a aumentar também a difusão. Desta forma, o gás pode se dispersar mais rápido em condições de temperatura mais elevada (Brito-Filho, 2005). A camada de cobertura pode apresentar variação diária e sazonal típica com a temperatura atmosférica (Abichou *et al.*, 2015), contudo o calor gerado pela oxidação de CH<sub>4</sub> também pode elevar a temperatura da camada de cobertura, de forma a influenciar o transporte, a oxidação e a emissão de CH<sub>4</sub> (Ng *et al.*, 2015).

A velocidade do vento e a precipitação pluviométrica destacam-se como fatores atenuantes as emissões de CH<sub>4</sub>. Segundo Delkash *et al.* (2016), para um intervalo de 2 a 10 horas, as emissões de metano em um aterro sanitário podem aumentar em 2 vezes, devido a um

aumento de 30% na velocidade do vento. Já a precipitação pluviométrica interfere na oxidação e na emissão através da camada de cobertura, uma vez que regulam o conteúdo de água do solo da cobertura, inibindo a promoção da atividade microbiana relacionada (Izumoto *et al.*, 2018).

Em relação as características geotécnicas do solo empregado na cobertura final de um aterro sanitário podem surgir múltiplos cenários de emissão de gases ou retenção, ou seja, se o solo estiver mais compactado numa determinada área em relação à outra, deverá existir um menor índice de vazios com menor fuga dos gases. Se os materiais de cobertura forem selecionados com maior rigor, solos argilosos são melhores que solos arenosos devido à coesão entre as partículas e a espessura da camada de cobertura atender às recomendações das normas (maior que 60 cm), espera-se que às emissões de gases no aterro seja em menor volume (Santos *et al.*, 2020).

## 2.5 Mecanismos de transporte de gases em aterros sanitários

Os gases produzidos dentro do aterro sanitário, têm a tendência de ocupar os espaços livres entre os resíduos ali depositados e a camada de solo que os cobre (Cheremisinoff, 2003). Assim o transporte tanto para o interior, quanto para o subsolo e exterior do aterro podem ocorrer devido a dois principais tipos de mecanismos, a difusão e a advecção (US ARMY CORPS OF ENGINEERS, 2008).

A difusão é vista como o mecanismo dominante para o transporte de CH<sub>4</sub> na camada de cobertura do aterro, pois possibilita a movimentação extensiva de gases de uma área para outra, sem que haja gradiente de pressão total (Mendonça, 2007). O fluxo difusivo é menor quando a concentração do gás se tornar uniforme no meio (Aubertin *et al.*, 2000), no entanto esta uniformidade é difícil de ser obtida, pois a atmosfera funciona como um excelente agente dispersivo de gases (Maciel, 2003).

O fluxo difusivo unidimensional é descrito pela 1ª Lei de Fick (Equação 1), sendo o contaminante transportado de uma região de alta concentração (potencial químico) para regiões de baixas concentrações químicas (Maciel, 2009).

$$J_g = -D_e \cdot \frac{ac}{az} \quad \text{Equação (1)}$$

Onde:

$J_g$  : *fluxo difusivo de massa de gás* [ $g \cdot m^{-2} \cdot s^{-1}$ ]

$D_e$  : *coeficiente de difusão do gás no solo* [ $m^2 \cdot s^{-1}$ ]

$\frac{ac}{az}$  : *gradiente de concentração do gás no meio* [ $g \cdot m^{-3} \cdot m^{-1}$ ]

Entre os processos que ocorrem na atmosfera os ventos tendem a contribuir para a dispersão dos gases, renovando o ar ao redor da massa de resíduos do aterro sanitário contribuindo para que o mecanismo de difusão continue ocorrendo entre o interior e o exterior do aterro (Borba *et al.*, 2018).

A advecção também pode desempenhar um papel importante no transporte e emissão, visto à pressurização na camada de cobertura do solo causados pelas variações temporais e espaciais da pressão atmosférica na superfície do solo de cobertura e geração contínua de gás da camada de resíduos (Xin *et al.*, 2065). Deste modo, sob baixa pressão atmosférica, a advecção em vez da difusão, pode ser o mecanismo dominante para o transporte dos gases no solo de cobertura (Bian *et al.*, 2018).

Portanto, nos aterros sanitários, a variação da pressão atmosférica pode alterar o mecanismo dominante de transporte de metano na camada de cobertura, o que pode influenciar a oxidação do gás. O fluxo advectivo pode ser calculado a partir a Lei de Darcy (Silva *et al.*, 2009). Segundo Maciel (2003), a Equação 2 realiza o cálculo desse tipo de fluxo em termos mássicos, considerando a compressibilidade de dos gases.

$$J a = \frac{K a . \rho_o . (P_e - P_s)}{2 . L . \mu . P_s} \quad \text{Equação (2)}$$

Onde:

*J a*: Fluxo advectivo do gás em massa [g.m<sup>-2</sup>. s<sup>-1</sup>)

*Ka*: Permeabilidade intrínseca do solo considerando o fluido compressível (m.s<sup>-1</sup>)

*ρ<sub>o</sub>*: Densidade do gás à uma dada pressão e temperatura (g.m<sup>-3</sup>)

*P<sub>e</sub>*: Pressão de entrada da amostra (Pa) *P<sub>s</sub>*: pressão de saída da amostra (Pa)

*L*: comprimento da amostra de solo (m)

*μ*: viscosidade dinâmica do fluido (Pa.s)

Outra via importante à emissão de gases em aterros sanitários, é a difusão molecular, que ocorre quando, no sistema, há diferença de concentração entre dois diferentes pontos, assim, o fluxo difusivo acontece de um ponto com maiores concentrações para outro com concentrações menores de gás (US ARMY CORPS OF ENGINEERS, 2008).

## 2.6 Mensuração do fluxo de gases em camadas de coberturas de aterros sanitários

A compreensão do funcionamento de fluxo de gases, através das camadas de cobertura em aterros sanitários é fundamental, sendo necessário a quantificação das emissões. Várias técnicas são utilizadas para a medição do fluxo de gases através da camada de cobertura em aterro sanitário, sendo as principais: dinâmica e mapeamento de pluma, traçador de gases, sensores a laser e placa de fluxo (Lucernoni *et al.*, 2017).

No método do mapeamento de pluma são utilizados sensores ópticos remotos, que medem a concentração dos gases no aterro sanitário (Babilotte *et al.*, 2010). O traçador de gases mede simultaneamente concentrações de metano e direção do vento, sendo utilizado como parâmetro um traçador de gás inerte, o N<sub>2</sub>O (óxido nitroso).

Na aplicação de laser é permitido as medições de concentrações de metano com grandes alcances, neste método é necessário o uso de veículos com equipamento de apoio (Park *et al.*, 2016). Neste método os fluxos de gases são obtidos por meio de modelagem numérica matemática de dispersão (Goldsmith-Junior *et al.*, 2012).

A metodologia para medição de biogás, a partir da placa de fluxo é apresentada na literatura como eficiente simples e barata (Lucernoni *et al.*, 2017), sendo utilizada por vários autores (Spokas *et al.*, 2006; Mariano & Jucá, 2010; Scheutz *et al.*, 2011; Maciel & Jucá, 2011; Goldsmith-Júnior *et al.*, 2012 Abichou *et al.*, 2015). Medições realizadas com placa de fluxo indicam taxas de emissões de metano na ordem de 0,0001g/m<sup>2</sup>/dia a 1000g/m<sup>2</sup> /dia (Lando *et al.*, 2017). As variações mensuradas são atribuídas a inúmeros fatores, como: camada de cobertura, idade e características dos resíduos e aspectos climáticos (Mariano & Jucá, 2010).

Não existe tamanho e forma padronizados para placas de fluxos, porém sabe-se que existe relação direta com as suas dimensões que estão diretamente relacionados à representatividade espacial: placas com área útil maior são mais representativas do que placas com menores dimensões (Maciel, 2003). O Quadro 4 apresenta forma e dimensões de algumas placas de fluxo encontradas na literatura.

**Quadro 4** - Forma, dimensões e volume de placas de fluxo (estática e dinâmica) encontradas na literatura.

Referência	Método	Forma	Base (m)	Altura (m)	Volume (m <sup>3</sup> )
Czepiel <i>et al.</i> (1996)	Estático	Cilíndrica	$\phi = 0,13$	0,18	0,00237
Maciel (2003)	Estático	Retangular	0,40 x 0,40	0,05	0,008
Ishigaki <i>et al.</i> , (2005)	Estático	Retangular	0,40 x 0,40	0,30	0,048
Mariano (2008)	Estático	Retangular	0,40 x 0,40	0,05	0,008



Scheutz <i>et al.</i> , (2010)	Estático	Cilíndrica	$\phi = 0,57$	0,20	0,050
Borba (2018)	Estático	Retangular	0,81 x 0, 81	0,05	0,032
Araújo (2017)	Estático	Retangular	1 x 1	0,05	0,05

**Fonte:** Damasceno (2019).

Estudos sobre emissões fugitivas de metano em aterros sanitários mostram a existência de variações temporais e espaciais, influenciadas por diversos fatores que vão desde as características geotécnicas dos solos, espessuras das camadas, idade dos resíduos, condições climáticas da região.

Diante disso, mitigar e mensurar o efeito estufa causado pelas emissões fugitivas de gases nos aterros sanitários se faz necessário. O estudo de modelos estatísticos, devem contribuir para uma previsão mais precisa dos fluxos emitidos pelos gases para atmosfera através da camada de cobertura final nos aterros sanitários.

## **2.7 Modelagem estatística como ferramenta ao monitoramento da emissão de gases em aterros sanitários**

Uma das preocupações estatísticas ao analisar dados, é a de ajustar modelos que explicitem estruturas dos fenômenos em observação, as quais frequentemente são formados por variações acidentais ou aleatórias. A identificação dessas estruturas permite conhecer melhor o fenômeno, bem como fazer afirmações sobre possíveis comportamentos do mesmo. Há uma diferença entre os modelos matemáticos, que são exatos, e os modelos estatísticos que são utilizados para projetar cenários, tanto futuros quanto passados (Martini-Neto *et al.*, 2011).

Para que os modelos estatísticos sejam desenvolvidos é necessário a realização de uma análise descritiva dos dados, identificar os parâmetros que apresentam correlação significativa com a variável resposta, executar os cálculos de regressão linear e/ou não linear, realizar os testes para selecionar os modelos e analisar os resíduos de regressão (Araújo-Neto, 2016).

A análise dos resíduos constitui uma das principais partes do trabalho estatístico, são os resíduos que determina se o modelo é adequado ou não para representar os dados da pesquisa.

### **2.7.1 Estatística descritiva**

A estatística descritiva, tem o objetivo de descrever e agrupar um conjunto de dados, a fim compreender as medidas de tendência central e de dispersão (Sharma, 2020).

Segundo Oliveira *et al.* (2022) a análise estatística descritiva possibilita as caracterizações das etapas parciais para cada indicador, através da determinação da média, desvio padrão, mínimo, mediana e máximo .

A distribuição do conjunto de dados possui pequena variabilidade (dispersão) quando o coeficiente de variação encontra-se em torno de 15 %; média dispersão quando estiver acima de 15 % até 30 %, e grande dispersão quando superar os 30 % (Correa, 2003).

Em relação a correlação entre duas variáveis pode se ter diversos graus, segundo Borges (2014) correlação muito forte, quando estiver entre 0,80 e 0,99, correlação forte de 0,60 a 0,70, correlação fraca de 0,40 a 0,59, correlação muito fraca de 0,20 a 0,39, correlação sem valor de 0,19 a 0,001 e correlação nula, quando o coeficiente for igual a 0.

### **2.7.2 Regressão linear**

A análise de dados através da regressão linear está entre as técnicas mais utilizadas para a construção de modelos para descrever o comportamento de uma variável dependente (resposta) a partir de um conjunto de outras variáveis independentes (explicativas) (Reyes, 2017). Os modelos de regressão linear podem ser simples ou múltiplos.

A técnica estatística da Regressão Linear Múltipla é usada para estudar a relação entre uma variável dependente e várias variáveis independentes explicativas. O Modelo Genérico Linear Geral é dado pela Equação 3, quando aplicado a uma amostra de tamanho  $n$ :

$$Y = \beta_0 + \beta^1 X_i + \dots + \beta^P X_P + e \quad \text{Equação (3)}$$

Onde:

- $Y$  é o valor da variável dependente;
- $X_i$  são os valores das variáveis independentes (constantes conhecidas);
- $\beta_i$  são parâmetros ou coeficientes de regressão;
- $\varepsilon$  é o erro aleatório do modelo.

Devido a heterogeneidade do ambiente em que o metano é produzido e da interação entre as variáveis que influenciam tanto a geração quanto a emissão de metano em aterros sanitários, os modelos de regressão linear múltipla são amplamente utilizados, visto que podem estimar as emissões fugitivas, na área de estudo de maneira satisfatória (Damasceno, 2019).

### **2.7.3 Teste de seleção de modelos estatísticos**

Independente, do tipo de modelo a ser utilizado deve-se proceder a seleção do modelo ideal, partindo de um conjunto de modelos relacionados. Para Jerônimo (2015), a utilização de diversos avaliadores de qualidade de ajuste transforma a escolha dos modelos em um processo minucioso, já que cada avaliador leva em conta determinadas características do modelo, tais

como o número de parâmetros e os resíduos estatístico. Uma solução para identificar o melhor modelo é analisar o coeficiente de determinação, os resíduos ou erro médio gerado.

A soma dos Quadrados dos Resíduos (SQR) determina o melhor modelo que se ajusta aos dados observados em uma determinada pesquisa, o menor valor do SQR indica o melhor modelo. Contudo, uma limitação a este método é pode afetar o seu desempenho, o tamanho da amostra, visto que interfere na variação do resíduo, assim, para amostras pequenas o resíduo diminuirá significativamente, afetando os graus de liberdade e conseqüentemente a relação do acaso e efeito de tratamento (Farias, 2014). Uma maneira de minimizar problemas em relação a dimensão da amostra, é o uso do quadrado médio dos resíduos (erro médio) como critérios de escolha.

Além dos métodos já mencionados, um determinado modelo pode ser testado utilizando-se critérios de informação construídos para avaliar a variância da função. Quando muito simples, o modelo não é capaz de prever a irregularidade dos dados portanto, quanto mais complexo um modelo tende a distribuir dados em muitos parâmetros, resultando em uma má estimativa de cada parâmetro e numa maior variância.

O êxito de um modelo de previsão, utilizando RNA depende da amplitude dos dados de entrada-saída, abrangência e confiabilidade (Araújo, 2015). Mota (2019) ressalta a importância de se utilizar um vasto banco de dados para que se possa ter um bom desempenho de uma RNA, pois, assim, há uma melhor generalização e se pode evitar o *overtraining*.

#### **2.7.4 Modelagem não constitutiva**

Os modelos constitutivos estão se predispondo para as abordagens não constitutiva devido as inovações tecnológicas. Esta metodologia permitiu a resolução de problemas na área da engenharia ambiental onde existem variáveis aleatórias nas quais a correlação entre entrada e saída não são conhecidas. (Alidoust *et al.*, 2021). Assim, as redes neurais artificiais podem ser utilizadas para criar modelos não constitutivos, com fundamentação em dados experimentais, para que predições de situações na área ambiental possam ser realizadas (Kandiri *et al.*, 2020).

### **2.8. Redes Neurais Artificiais (RNA)**

Uma rede neural artificial pode ser definida como um processador composto por unidades de processamento simples, os quais possuem capacidade de armazenar dados (Freeman & Skapura, 1991). As RNA surgiram a partir das ideias de McCulloch & Pitts (1943), que juntos publicaram o artigo *logical calculus of the ideas immanent in nervous activity* que difundiu os primeiros conceitos sobre esses sistemas, os quais são inspirados nos modelos de

atividade do sistema nervoso (Hebb, 1949) aprimorou a ideia desenvolvendo modelos de sistemas, hoje ainda utilizados em vários algoritmos matemáticos.

Em 1962, Rosenblatt introduziu uma nova abordagem de treinamento denominado *Perceptron*, de modo que as RNA passaram a ser treinadas para classificar alguns tipos de padrões e executar determinados tipos de funções (Figura 8). Segundo Laboissiere *et al.* (2015) as redes artificiais possuem a capacidade de aprender não somente por meio de exemplos, mas também por meio da generalização da informação aprendida.


A capacidade de aprendizado de uma RNA, consiste no processo de treinamento por meio do qual o neurônio aprenderá pela minimização do erro total de saída, reforçando ou enfraquecendo as conexões entre seus terminais, ajustando gradativamente seus pesos a cada iteração sobre os valores de entrada fornecidos. Este processo pode estar ou não, baseado no conhecimento prévio dos valores de saída esperados para cada entrada (Berger *et al.*, 2005).

Para que se possa compreender melhor o funcionamento básico de uma RNA se faz necessário entender o funcionamento do neurônio biológico. Conforme Cintra (2018), os neurônios são constituídos por:

- Dendritos: Tem a função de adquirir forma contínua, os estímulos vindos de outros neurônios (conectores);
- 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;
- Axônio: constituído por um único prolongamento, cuja missão é conduzir os impulsos elétricos para outros neurônios (Figura 7).

No sistema nervoso humano o cérebro é representado por uma rede de neurônios, os quais estão conectados entre si por meio de sinapses, que recebem informações e tomam decisões, através dos receptores que transformam estímulos em impulsos elétricos transmitindo informação para a rede neural, convertendo-os em repostas na saída do sistema (Cintra, 2018).

**Figura 7** – Componentes de um neurônio biológico

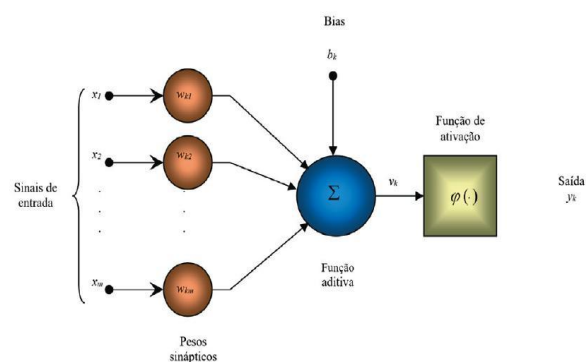


**Fonte:** Silva et al. (2010).

Em uma RNA, para cada nó de entrada é aplicado um valor, representado pelos dendritos. As conexões recebem os valores de cada nó, que são multiplicados pelo peso associado. Na camada seguinte os nós admitem o valor que corresponde a soma dos valores que foram produzidos pelas conexões anteriores sendo realizado um cálculo por meio de uma função de ativação, podendo ser esta função linear ou sigmoide (Figura 8). Portanto em uma RNA, para saídas desejadas o objetivo é encontrar o conjunto de pesos ótimos (Elsheikh *et al.*, 2019).

Abordagens a partir de redes neurais artificiais (RNA), fornecem alternativas mais precisas do que a estatística convencional, principalmente quando a relação com os dados não é linear (Fallah *et al.*, 2020). Uma rede neural é formada por um grande número de elementos processadores, os neurônios, amplamente interligados através de conexões com um determinado valor que determina o grau de conectividade entre estes, denominado peso da conexão ou sinapse (Furtado, 2019).

**Figura 8** - Esquema de uma RNA




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

### 2.8.1 Arquitetura das redes neurais

A arquitetura de uma rede neural tem relação direta com o algoritmo de aprendizagem que é utilizado para treinamento, portanto é necessário que a estrutura da rede leve em consideração o objetivo da modelagem (Silva *et al.*, 2010). Nesse sentido as estruturas das RNA são classificadas em três tipos rede: *feedforward* de uma camada, *feedforward* de múltiplas camadas e realimentada (Haykin, 2001).

A rede *feedforward* de uma camada apresenta os neurônios organizados em forma de camadas, de modo que os nós da camada de entrada se comunicam diretamente com as de saída (nós computacionais). A arquitetura do tipo *feedforward* em uma camada apresenta estrutura similar à do córtex humano, onde os neurônios se dispõem em camadas paralelas e consecutivas, e os axônios se estendem sempre no mesmo sentido, isto é, a informação propaga-se da entrada para a saída, não havendo, portanto, ligações entre os neurônios de uma mesma camada ou com camadas anteriores. É chamada de rede de uma camada em referência à camada de saída, pois os nós da entrada não processam nada, só apresentam os padrões à rede (Figura 9).

**Figura 9** - Rede Feedforward de uma camada de saída




**Fonte:** (Haykin, 2001).

As redes *feedforward* de múltiplas camadas são formadas por uma ou mais camadas escondidas (Figura 10). A função dos neurônios escondidos é intervir entre a camada de entrada e a de saída da rede de alguma maneira útil. Pela adição de uma ou mais camadas, a rede passa a melhor mapear problemas mais complexos. Por ser uma rede do tipo *feedforward*, as conexões se dão sempre no sentido da camada de entrada para a de saída (Furtado, 2019). Quando a rede

possuir todos os nós de uma camada comunicando-se com todos os nós da camada posterior, ela é dita totalmente conectada. Contudo, se alguma das conexões sinápticas não estiverem ligadas com a camada subsequente, a rede é dita parcialmente conectada (Kopiler *et al.*, 2019)


**Figura 10** - Rede Feedforward de múltiplas camadas



**Fonte:** Furtado (2019).

A rede realimentada distingue-se das redes neurais do tipo *feedforward* por permitir a realimentação de uma camada com as informações geradas pela camada posterior, ou ainda por fazer uma realimentação do neurônio com a sua própria saída (*selffeedback*). Para permitir essa realimentação, um dispositivo de atraso é introduzido, guardando as informações de saída de um instante anterior, até que ela possa ser fornecida como entrada do instante atual (Figura 11) (Furtado, 2019).

**Figura 11** -Rede realimentada

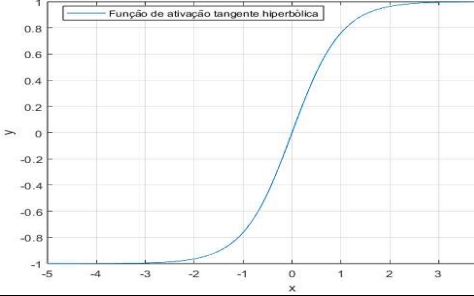
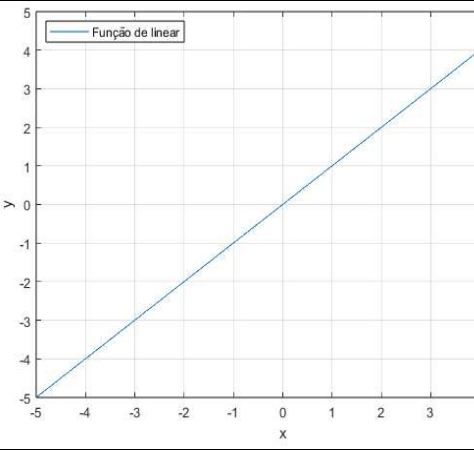
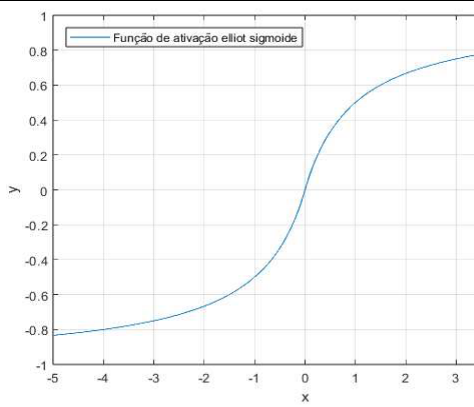


**Fonte:** Furtado (2019).

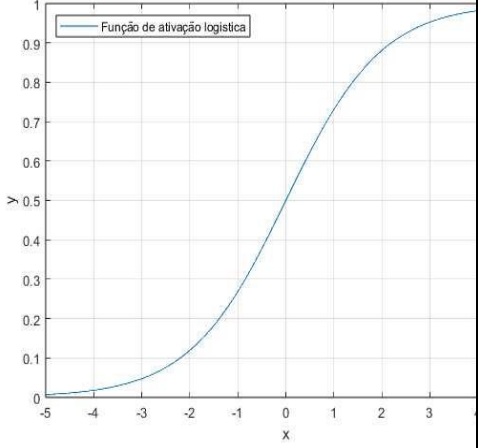
### 2.8.2 Funções de Ativação

A função de ativação é um componente da RNA que transforma uma entrada em uma determinada saída (Chiroma *et al.*, 2015). Existem diversos tipos de funções de ativação, (Quadro 5), contudo as mais utilizadas são: Sigmóide, Tangente hiperbólica e Linear (Hardin, 2001).

**Quadro 5**– Funções de ativação

NOME	EQUAÇÃO	SIMBOLO
Tangente Hiperbólica (Tansig)	$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$	
Linear (Purelin)	<p>Função linear(x) = kx  Sendo:  Função linear (x) variável dependente;  k = constante;  x = variável independente.</p>	
Elliot Simétrica	$f(x) = \frac{x}{\sqrt{1+x^2}} + 0,5$ <p>Sendo: função (x) = variável dependente;  x = variável independente.</p>	



<p>Função Logística ou Sigmoidal(<i>logsig</i>)</p>	<p>Função <i>logística</i> <math>(x) = \frac{1}{1+e^x}</math></p>	 <p>O gráfico mostra a função de ativação logística, uma curva sigmoide que varia de 0 a 1 em função de x. O eixo x varia de -5 a 4, e o eixo y varia de 0 a 1. A curva é quase 0 para x &lt; -3, passa por 0.5 em x = 0, e se aproxima de 1 para x &gt; 3.</p>
---	---	--

**Fonte:** Elaborado pelo autor, 2023.

### 2.8.3 Métricas de avaliação das RNA

As métricas de avaliação permitem averiguar se o modelo se adaptou bem aos dados e a possibilidade de ser utilizado nas tomadas de decisões. Algumas das métricas mais utilizadas são o *Mean absolute error* (MAE), o *Mean absolute percentage error* (MAPE) e o *Root mean square error* (RMSE) (Sampaio *et al.*, 2019).

O MAE mede a distância entre os valores preditos e observados, constituindo na média dos erros. Dessa forma, quanto menor o valor, melhor é a predição realizada pelo modelo (Mentzer & Bienstock 1998). O MAE é determinado pela Equação 4, onde  $\hat{y}_i$  é o valor predito,  $y_i$  o valor real e  $n$  o tamanho da amostra.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{Equação (4)}$$

O MAPE refere-se ao erro absoluto dividido pelo valor real, resultando no afastamento do valor predito ao observado em percentual, constituído pela média desses percentuais (Sampaio *et al.*, 2019). O MAPE é determinado na Equação 5, onde  $\hat{y}_i$  é o valor previsto,  $y_i$  o valor real e  $n$  o tamanho da amostra.

$$MAPE = \frac{100}{n} \sum_{i=0}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad \text{Equação (5)}$$

O RMSE é uma métrica amplamente utilizada para avaliar modelos, pode ser utilizado como métrica ideal para erros normais, refutando a ideia de que o MAE deve ser usado, exclusivamente. Entretanto o RMSE é inerentemente superior. Chai & Draxler (2014) afirmam que o RMSE é ideal para erros normalmente distribuídos, e sugerem que o MAE se aplique

apenas para erros uniformemente distribuídos. Esses mesmos autores defendem que uma combinação de métricas, incluindo RMSE e MAE, deve ser usado para avaliar o desempenho do modelo.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \text{Equação (6)}$$

O MSE é uma métrica que tem características semelhante ao MAE, entretanto de outro modo ao invés de aplicar o módulo em relação a diferença do valor real e o predito, essa métrica é elevada ao quadrado, portanto, fazendo com que o MAE sofra influência de valores que estão a uma certa distância. O RMSE configura-se como raiz quadrada do MSE e conseqüentemente sofre penalizações quando há grande diferenças entre o valor previsto e o real (WANG e LU, 2018). O MSE é determinado pela Equação 7.

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n} \quad \text{Equação (7)}$$

O coeficiente de determinação é uma medida da proporção da variância da variável dependente em torno de sua média que é explicada pelas variáveis independentes ou predictoras.

O R<sup>2</sup> mede o quanto a variável dependente é explicada pelo modelo, o seu valor varia entre 0 e 1 ou seja (0 a100%), e quanto maior o valor, melhor a concordância entre modelo e observação (Legates & McCabe-Jr, 1999)

Em relação ao R<sup>2</sup> baixos, próximos de zero, denotam que o modelo (representado pela Equação 8) não consegue explicar a relação existente entre as variáveis.

A Equação 8 indica o coeficiente de determinação

$$R^2 = \frac{\sum_{i=1}^n (X_E - \bar{X})^2}{\sum_{i=1}^n (X_O - \bar{X})^2} \quad \text{Equação (8)}$$

Onde: R<sup>2</sup> = Coeficiente de determinação

n = Número de variáveis

X<sub>E</sub> = Variáveis estimadas

X<sub>O</sub> = Variáveis observadas

$\bar{X}$  = Média das variáveis

### 2.8.4 Algoritmos de treinamento das redes neurais artificiais

O algoritmo *Bayesian Regularization Backpropagation* tem uma função objetiva que inclui uma soma residual de quadrados e a soma de pesos quadrados para minimizar os erros de estimativa e para alcançar um modelo eficiente e amplo (Kayri, 2016). Esse algoritmo normalmente requer mais tempo, mas pode resultar em boa generalização para conjuntos de dados difíceis, pequenos ou ruidosos (Heng, 2023).

Em relação ao algoritmo *Levenberg-Marquardt*, *Bayesian Regularization* e *Scaled Conjugate Gradient* são aplicadas no desenvolvimento de redes neurais artificiais. A elas são disponibilizados um conjunto de dados composto para que seja realizado o treino, a validação e o teste. Os dados de treino são utilizados para a moldagem da rede de acordo com o erro obtido. Os dados de validação são usados para determinar a parada do treinamento, analisando a capacidade de generalização da rede. Os dados de teste não têm qualquer efeito no treinamento, porém são necessários para dimensionar o desempenho a partir de uma medição independente.

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).

### 2.8.5 Trabalhos realizados em aterros sanitários a partir de redes neurais artificiais

As RNA constituem uma ferramenta relevante que tem sido usada com êxito para auxiliar nas mais diversas situações, em diferentes ramos da engenharia. Trabalhos que utilizam essa técnica no âmbito da geotecnia foram desenvolvidos nas últimas décadas e são elencados a seguir de acordo com os seus respectivos assuntos (Quadro 6).

**Quadro 6** - trabalhos desenvolvidos com aplicação das RNA na geotecnia

<b>Propriedades Geotécnicas do Solo</b>	<b>Estabilidade de Taludes</b>	<b>Liquefação do Solo</b>
<b>Referências Bibliográficas</b>	<b>Referências Bibliográficas</b>	<b>Referências Bibliográficas</b>
Park (2011)	Mayoraz & Vulliet (2002)	Baziar & Ghorbani (2005)
Park & Lee (2011)	Goh e Kulhawy (2003)	Kim e Kim (2006)
Ismeik e Al-Rawi (2014)	Ferentinou e Sakellariou (2007)	Hanna, Ural & Saygili (2007)
Tizpa <i>et al.</i> (2014)	Cho (2009)	Farrokhzad; Choobbasti e Barari (2010)
Javdanian, Jafarian & Haddad (2015)	Choobbasti, Farrokhzad & Barari (2009)	Venkatesh e Kumar (2012)
Dantas Neto <i>et al.</i> , (2017)	Kaunda <i>et al.</i> (2010)	Baziar & Saeedi Azizkandi (2013)

Sharma <i>et al.</i> (2017)	Li <i>et al.</i> (2018)	Venkatesh, Kumar, Tiwari (2013)
Benbouras <i>et al.</i> (2018)	Qian <i>et al.</i> (2019)	Rezaei e Choobbasti (2014)
Cui e Jing (2019)	Hataf e Azar (2020)	Abbaszadeh Shahri (2016)
Mota (2019)	Gao <i>et al.</i> , (2020)	Xue & Liu (2017)
Alam, Mondal e Shiuly (2020)	Lim e Fatty (2020)	Não informado
Alsharari, Olenko e Abuel-Naga (2020)	Marrapu e Jakka (2020)	Não informado
Wang, Moayedie & Kok Foong (2020)	Wang, Moayed; Kok Foong (2020)	Não informado

**Fonte:** Adaptado de Barreto (2022).

Vários modelos de redes neurais artificiais tem sido utilizados nos estudos para previsibilidade das concentrações das emissões de GEE em aterros sanitários (Quadro 7).

**Quadro 7-** trabalhos desenvolvidos com aplicação das RNA para previsão das concentrações das emissões de GEE

Modelos de Redes Neurais	Referências Bibliográficas	Aplicações
Perceptrons Multicamadas (MLP) modelo de retropropagação com uma camada oculta	Ozkaya <i>et al.</i> (2007)	Prever a fração de CH <sub>4</sub> de biogás em um aterro de biorreator na Turquia com e sem percolação de lixiviado
Modelo Retropropagação	Li <i>et al.</i> (2011)	Previsão de temperatura, metano, dióxido de carbono, e concentrações de oxigênio em um aterro sanitário no sul da Califórnia, EUA
<i>feed forward</i> Rede neural MLP de retropropagação	Abushammala <i>et al.</i> (2014)	Previsão de metano fração de oxidação do fundo do solo de cobertura do aterro sanitário na Malásia usando parâmetros como temperatura média do ar.

**Fonte:** Adaptado de Barreto (2022).

Xiao *et al.* (2021) propuseram a utilização de um algoritmo de AM de dois estágios, a rede neural híbrida NARX-BP, para estimar a produção de metano (principal composto do biogás) via transferência direta de elétrons. A avaliação do modelo foi feita por meio das métricas R-quadrado e MSE, onde o modelo NARX-BP apresentou melhores resultados se comparado com outros modelos tradicionais de RNA.

Olatunji *et al.* (2022) utilizaram a técnica ANFIS para estimar a produção de biogás e metano. Para avaliação do desempenho do modelo desenvolvido foram aplicadas as métricas RMSE, MAPE, *Median Absolute Deviation* (MAD) e R-quadrado.

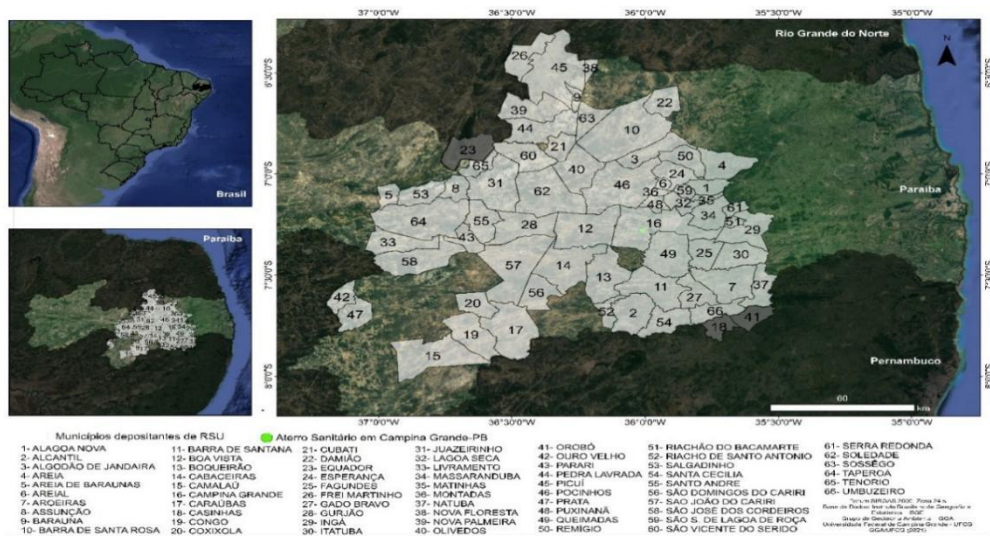
### 3 MATERIAIS E MÉTODOS

Na metodologia são apresentadas as etapas da pesquisa que compreende: área de estudo; coleta de dados da camada de cobertura final; caracterização geotécnica do solo; análise estatística dos parâmetros geotécnicos e meteorológicos; análise numérica com utilização das redes neurais artificiais.

#### 3.1 Área de estudo

O estudo foi realizado em um aterro sanitário localizado no semiárido brasileiro. São depositados no Aterro Sanitário em estudo mais de 600 toneladas de resíduos/dia, provenientes de 66 municípios, dos quais 64 são do estado da Paraíba e 2 do estado de Pernambuco (Figura 12).

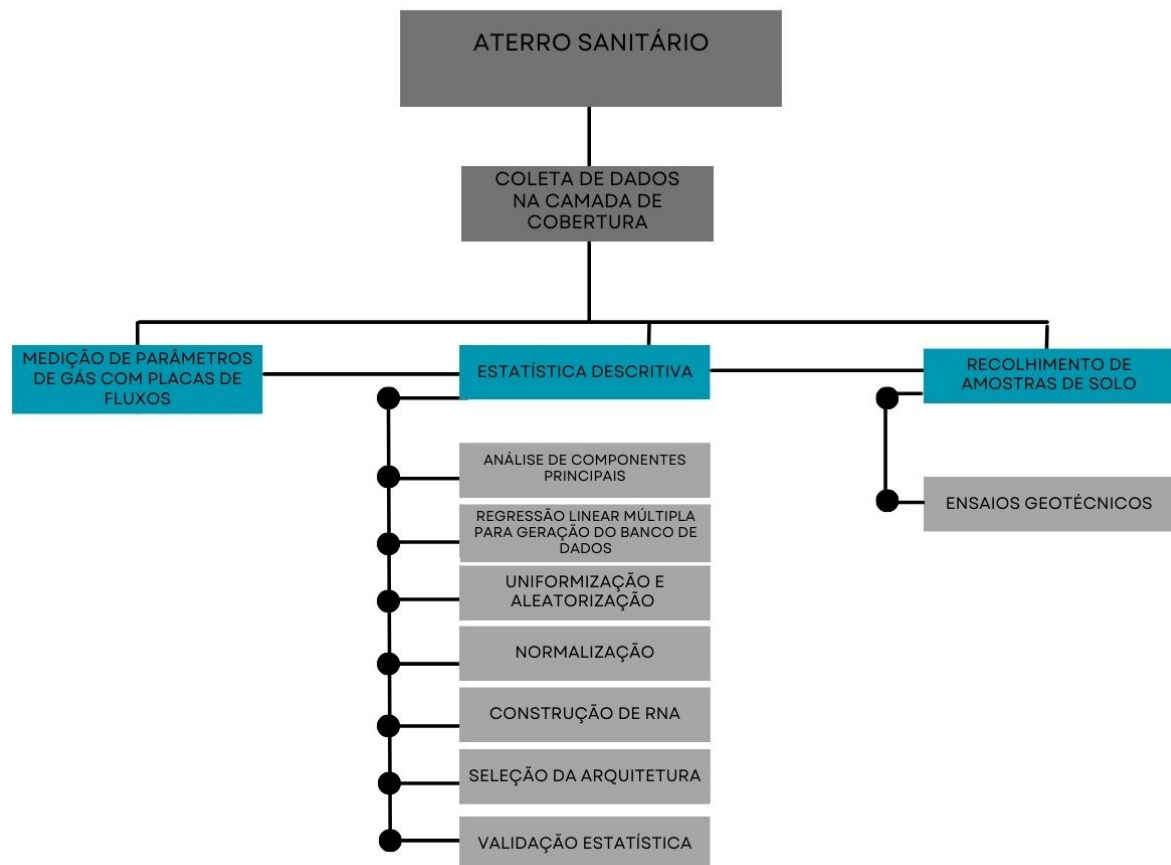
Figura 12- Municípios que depositam RSU no aterro sanitário em estudo



Fonte: GGA (2022).

A Figura 13 representa o fluxograma relativo aos procedimentos da metodologia executados na pesquisa.

**Figura 13** - Fluxograma da metodologia da pesquisa



**Fonte:** Elaborado pelo autor, 2023.

O aterro sanitário iniciou suas atividades em julho de 2015, ocupando uma área total de 80 ha, sendo destinados 39,38 ha para a construção das Células de resíduos. O aterro conta com uma macrocélula de RSU de área de 220m x 220m e uma altura média de 40 m, 40 drenos verticais para saída de gases, dos quais 29 são monitorados em termos de vazão e concentração de gases (Figura 14).

A camada de cobertura final é o do tipo convencional com solo compactado, estudos realizados identificaram solos com tipologia de argila de baixa plasticidade (CL), argila de alta plasticidade (CH), areia argilosa (SC) e areia siltosa (SM). Os coeficientes de permeabilidade à água variam de  $10^{-7}$  a  $10^{-8}$  m/s (Araújo, 2017; Souza et al, 2019), sendo a espessura com variações de 0,5 a 1,7 m (Moreira et al, 2020).

**Figura 14** - Células do Aterro Sanitário utilizado na Pesquisa



**Fonte:** GGA (2021)

De acordo com o Ministério do Meio Ambiente (MMA), nos aterros sanitários, os gases são captados por meio de um sistema de drenagem, formados por drenos verticais e *flares* que são equipamentos destinados à queima controlada do metano, transformando-o em dióxido de carbono dispostos em diferentes locais do aterro sanitário.

Os drenos verticais (Figura 15) alguns são constituídos por tubos de concreto dotados de orifícios que possa permitir a entrada de biogás ao longo de sua extensão. Os diâmetros internos têm 0,28m e os externos 0,37m. Em relação a proteção da tubulação da drenagem, as manilhas são revestidas por britas de número 3 (0,038 m), fixadas por uma malha de ferro com dimensões de 0,15x 0,15 m e diâmetro com variação entre 0,90 e 0,92m (GGA,2021).

Já os flares (Figura 16) têm um diâmetro de 400mm para que seja adaptado na parte superior do poço, um robô de 50mm (2”) com altura de 2,8m e o cilindro superior, onde se processa a queima, com altura de 40 cm e diâmetro de 60 cm. (GGA,2022).

**Figura 15** – Dreno de gases vertical no aterro sanitário utilizado na pesquisa



**Fonte:** GGA (2022).



**Figura 16** - Fotografias dos flares no aterro sanitário



Fonte: GGA (2022).

### 3.2 Amostragem

A área de coleta das amostras foi dividida em quadrantes, considerando a Equação 9 descrita pela *United States Environmental Protection Agency* (USEPA, 2004), relativas a áreas superiores a 5.000 m<sup>2</sup>, o que resultou em 36 quadrantes distribuídos ao longo da superfície da camada. A área delimitada para o estudo foi de aproximadamente 40.000 m<sup>2</sup>, na superfície da célula. (Figura 17).


$$N = 6 + 0,15\sqrt{A} \quad \text{Equação (9)}$$

Onde:

N= número de ensaios por meio de placa de fluxo;

A = área investigada do aterro (m<sup>2</sup>)

**Figura 17**- Representação dos pontos de ensaios sobre a camada de cobertura final



Fonte: GGA (2022).



Em decorrência da Pandemia do COVID-19, e dificuldades de acesso aos locais de coleta, não foi possível a realização de 36 amostragens por campanha. Os dados experimentais da pesquisa precisaram ser adaptados devido as mudanças de acesso e operação no aterro, sendo realizados 33 ensaios de placa de fluxo, divididos em duas campanhas de campo, sendo a primeira com 12 pontos, realizada entre 13/10/2020 e 06/11/2020, representativas do período seco; e a segunda campanha, com 21 pontos, realizadas entre 20/07/2021 e 30/07/2021, no período chuvoso. Os pontos de amostragem foram distribuídos aleatoriamente.

Os dados de temperatura média diária, precipitação, radiação solar, pressão atmosférica, umidade relativa do ar, velocidade média do vento, foram cedidos pelo Instituto Nacional de Meteorologia (INMET, 2021) na estação meteorológica A313 (latitude  $7^{\circ}13'32.07''S$  e longitude  $35^{\circ}54'17.39''$ ).

### 3.3 Caracterização geotécnica do solo da camada de cobertura

Para a caracterização geotécnica do solo da camada de cobertura foram coletadas amostras de solo nas mesmas estações amostrais, relativos as leituras de concentrações dos gases. Em cada estação 6kg de solo foram coletados da superfície os quais foram embalados, etiquetados e destinados para o Laboratório de Geotecnia Ambiental (LGA) da Universidade Federal de Campina Grande (UFCG), onde foram secos ao ar livre para posterior processamento (Figura 18). Em campo foram realizados o ensaio de cilindro de cravação e verificação da umidade do solo. Assim foi possível determinar a densidade seca, grau de compactação, porosidade, índices de vazios, umidade e grau de saturação do solo na camada de cobertura.

**Figura 18** – Fotos dos procedimentos iniciais para as análises de solo (secagem prévia ao ar livre e destorroamento)



Fonte: GGA (2021).

A caracterização geotécnica das amostras de solo foi realizada a partir da determinação da umidade relativa, massa específica dos grãos, limite de liquidez e plasticidade, compactação, granulometria, permeabilidade a água e ao ar de acordo com as normas estabelecidas pela

Associação Brasileira de Normas Técnicas (Quadro 8). Ensaios de permeabilidade à água e ao ar, estes foram realizados com permeâmetro de parede flexível Triflex-2 (Figura 19).

**Figura 19** - Permeâmetro de parede flexível Triflex-2



**Fonte:** GGA (2022).

**Quadro 8** – Descrição dos ensaios geotécnicos e metodologias utilizadas

<b>Ensaios</b>	<b>Método</b>
Preparação de amostras e teor de umidade	NBR 6457 (ABNT, 2016) – Amostras de solo – Preparação para ensaios de compactação e ensaios de caracterização
Massa específica dos grãos	NBR 6458 (ABNT, 2016) – Solo – Determinação da massa específica dos grãos de pedregulho que passam na peneira 4,8 mm.
Limite de Liquidez	NBR 6459 (ABNT, 2016) – Solo – Determinação do Limite de Liquidez.
Limite de Plasticidade	NBR 7180 (ABNT, 2016) – Solo – Determinação do Limite de Plasticidade.
Compactação	NBR 7182 (ABNT, 2016) – Solo – Ensaio de Compactação.
Granulometria por peneiramento e sedimentação	NBR 7181 (ABNT, 2016) – Solo – Análise Granulométrica.
Permeabilidade à água	NBR 14545 (ABNT, 2000) – Determinação do coeficiente de permeabilidade de solos argilosos à carga variável.
Permeabilidade ao ar	ASTM D 6539 (ASTM, 2013)

**Fonte:** Elaborado pelo autor, 2023.

### 3.4 Medições de gases do efeito estufa

Foram realizadas aferições/medições das concentrações de CH<sub>4</sub>, CO<sub>2</sub>, H<sub>2</sub>S, O<sub>2</sub> e CO, utilizando placa de fluxo estática em combinação com a medida de pressão e concentração dos gases (Maciel, 2003).

A placa de fluxo utilizada nessa pesquisa corresponde a uma caixa em aço galvanizado quadrada com dimensões de 0,40m x 0,40m; altura útil de 5cm; área útil de 0,16m<sup>2</sup>; volume útil de 0,008m<sup>3</sup>, tem formato de degrau para que, ao ser cravada na camada de cobertura, evite a entrada de ar atmosférico para o interior da caixa, além de facilitar a sua cravação. O degrau fica em contato direto com o solo, de maneira que a área útil da placa seja a única área de passagem de fluxo de biogás pela camada de cobertura durante o ensaio (Figura 20).

A metodologia de ensaio de placa de fluxo consistiu em delimitar o perímetro necessário, em seguida a placa foi cravada na superfície do solo do aterro sanitário (Figura 20a). Posteriormente, a placa de fluxo foi colocada no local e pressionada ao solo (Figura 20b). Para a coleta ser iniciada, os instrumentos de medição da concentração dos gases e pressão foram encaixados sobre a placa (Figura 20c) e, ao final do ensaio, a placa foi recolhida de forma adequada, selando o local que foi escavado (Figura 20d).


**Figura 20** – Fotografias do ensaio com placa de fluxo tipo estática



**Fonte:** Souza (2020).

No topo da caixa há duas conexões de saída (do tipo encaixe rápido), foram conectados os equipamentos de medição de concentração dos gases e temperatura interna. Sendo estes utilizados para medição de biogás identificados na Figura 21 e descritas no Quadro 9.

**Figura 21** - Equipamentos utilizados para realização dos ensaios de fluxo de gás na camada de cobertura



**Fonte:** GGA/ UFCG (2022).

**Quadro 9** - Características dos equipamentos utilizados para medição de biogás na placa de fluxo

Equipamentos	Parâmetro (concentração)	Faixa de medição	Faixa de erro do equipamento
Drager X- am 7000	CO <sub>2</sub>	0 - 100 %	± 2,0%
Drager X- am 7000	CH <sub>4</sub>	0 - 100 %	± 5,0%
Drager X- am 7000	H <sub>2</sub> S	0 - 500 ppm	± 5,0%
Drager X- am 7000	O <sub>2</sub>	0 - 25 %	± 1,0%
Drager X- am 7000	CO	0 - 500 ppm	± 1,0%
Akso - Ak205	Pressão	20psi (máxima)	± 1,0%
Termometer Appa Mt-600	Temperatura	- 50 a 1.300°C	± 0,5%

**Fonte:** Elaborado pelo autor, 2023.

Em cada ponto amostral foram realizadas em média 10 medições sequenciais, com intervalos de 5 minutos sendo realizadas leituras das concentrações dos gases, temperatura interna, temperatura externa.

O fluxo dos gases foi estimado de acordo com as equações 10 e 11 (Czepiel *et al.*, 1996).

$$QES = \frac{V_{placa}}{A_{placa}} * \frac{\Delta C_i}{\Delta T} * \frac{273,15}{(273,15+T_{int.})} * \frac{P_{atm}}{1000} \quad \text{Equação (10)}$$

$$J = QES \times \rho \quad \text{Equação (11)}$$

Onde:

$QES$  = taxa de emissão volumétrica superficial do gás ( $NL s^{-1}.m^{-2}$ );

$J$  = taxa de emissão mássica superficial do gás ( $g.s^{-1}.m^{-2}$ );

$V_{placa}$  = volume útil da placa de fluxo (L);

$A_{placa}$  = área de solo coberta pela placa ( $m^2$ );  
 $\Delta C/\Delta t$  = variação da concentração do gás (% V/V) com o tempo (s);  
 $T_{int.}$  = temperatura interna do gás na placa ( $^{\circ}C$ );  
 $P_{atm}$  = pressão atmosférica (mbar);  
 $\rho$  = massa específica do gás ( $kg.m^{-3}$ );

O fluxo de biogás, neste estudo, é apresentado em termos mássicos. Foi realizada a correção da densidade dos gases ( $CH_4$  e  $CO_2$ ) em função das leituras das temperaturas internas durante o ensaio de placa de fluxo, conforme Equações 12 e 13.

$$\rho_{CH_4}(T_{int.}) = \frac{\rho_{CH_4}(0^{\circ}C) * 273}{[273 + t(^{\circ}C)]} \quad \text{Equação (12)}$$

$$\rho_{CO_2}(T_{int.}) = \frac{\rho_{CH_4}(0^{\circ}C) * PM_{CO_2}}{PM_{CH_4}} \quad \text{Equação (13)}$$

Em que:

$\rho_{CH_4}(t)$  = densidade do  $CH_4$  em função da temperatura ( $^{\circ}C$ );  
 $\rho_{CH_4} = 0,716 \text{ kg.m}^{-3}$   
 $\rho_{CO_2}(t)$  = densidade do  $CO_2$  em função da temperatura ( $^{\circ}C$ );  
 $T_{i \text{ int.}}$  = temperatura interna do gás na placa ( $^{\circ}C$ );  
 $PM_{CO_2}$  = peso molecular do  $CO_2 = 44$ ;  
 $PM_{CH_4}$  = peso molecular do  $CH_4 = 16$ .

### 3.5 Análise de dados

Para o tratamento estatístico foi realizada a análise descritiva dos dados, aplicado para os indicadores: média (X), desvio padrão (DP), valor máximo, valor mínimo e coeficiente de variação (CV).

No tratamento estatístico dos resultados experimentais foi utilizado o *software Statistica* versão 12.0, visando determinar a análise de variância (ANOVA). Foram analisados 06 parâmetros meteorológicos (temperatura externa, temperatura interna, pressão atmosférica, radiação solar, umidade relativa do ar e velocidade do vento) e 04 parâmetros para solo (grau de compactação, grau de saturação, massa específica aparente do solo e umidade do solo).

Com o objetivo de identificar o nível da relação entre os fatores intervenientes e as emissões fugitivas de  $CH_4$  através da camada de cobertura de solo compactado de aterro sanitário foi realizada Análise de Componentes Principais (ACP). O *software utilizado foi o Statistica* (versão 12.0), sendo realizada uma análise de correlação para identificar a intercessão das variáveis no processo.



Na busca de estabelecer um modelo descritivo das relações entre as variáveis investigadas com o fluxo de metano, procedeu-se análise de regressão linear múltipla, Equação 14. Dessa forma, foi possível determinar o fluxo de metano e conseqüentemente os respectivos parâmetros que influenciam sua geração no aterro sanitário.

$$J_{CH_4} = a + b_1x_1 + b_2x_2 \dots b_nx_n \quad \text{Equação (14)}$$

Sendo:

$J_{CH_4}$  = Fluxo de metano ( $g \cdot m^{-2} \cdot dia^{-1}$ );

$a$  = coeficiente linear da  $i$  – ésima variável;

$n$  = número de variáveis independentes.

Na Equação 14,  $b_1$  é o coeficiente de regressão associado à primeira variável preditora  $x_1$  e  $b_2$  é o coeficiente de regressão associado à segunda variável preditora  $x_2$  e assim consecutivamente.

### **3.5.1 Modelagem não constitutiva com Redes Neurais Artificiais Para Fluxo de CH<sub>4</sub>**

O conjunto de entrada contou com dez variáveis: temperatura externa, temperatura interna, pressão atmosférica, radiação solar, umidade relativa do ar, velocidade do vento, grau de compactação, grau de saturação, massa específica aparente do solo e umidade do solo. Já o banco de saída foi o fluxo de metano observado.

O banco de dados inicial contou com 33 pontos de coleta de gás e fluxo real de CH<sub>4</sub>. Por isso, objetivando otimizar o processo de previsão por RNA das emissões fugitivas de metano, na cobertura do aterro sanitário, o banco de dados sintético foi gerado do modelo da regressão linear múltipla, depois aleatorizado em seguida normalizado (até atingir 1000 elementos), e validados estatisticamente.

Para a escolha da RNA ótima, o conjunto de dados foi dividido em informações de treinamento, validação e teste (70/15/15). Porém, devido as particularidades de alguns algoritmos de treinamento, a etapa de validação é suprimida, mudando a quantidade de dados no treinamento e no teste (70/30).

A modelagem não constitutiva foi realizada por meio de RNA, com linguagem de programação do *software Matlab R2021a*.

Os dados de entrada foram normalizados para que a amplitude entre as entradas e saídas ficassem com a mesma proporção. O processo de normalização utilizada nesse trabalho foi realizado por meio da Equação 15 utilizando valores máximos e mínimos.

$$y_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad \text{Equação 15}$$

Onde:

$Y_{norm}$  =  $y$  normalizado;  
 $x$  = valor atual da série;  
 $x_{min}$  = valor mínimo da série;  
 $x_{max}$  = valor máximo da série.

A Tabela 2 resume os algoritmos de retropropagação usados durante a etapa de treinamento. O processo de treinamento é encerrado automaticamente quando os erros estão com tolerância requerida ou quando os números de interações são atingidos (Ghaedi & Vafael, 2017).

O algoritmo neural aplicado nos modelos foi fixado como *feedforward com backpropagation*, o qual é amplamente utilizado.

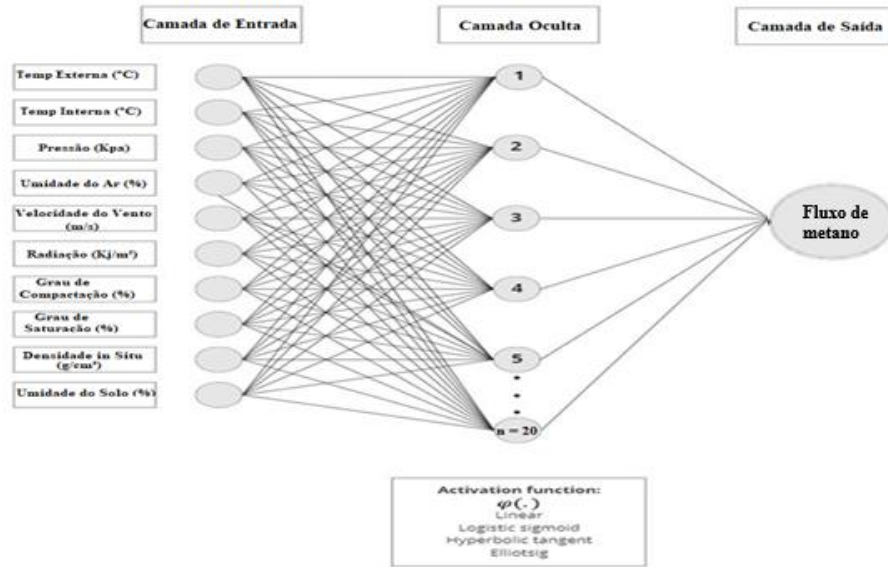
**Tabela 2-** Algoritmos de retropropagação e suas respectivas funções no *MatLab*

Algoritmo	Função
Levenberg- Marquardt	Trainlm
Bayesian Regularization	Trainbr
BFGS quasi- Newton	trainbfg
Conjugate gradient with Powell-Beale restarts	traincgb
Conjugate gradient with Fletcher- Reeves updates	traincfg
Conjugate gradient with Polak-Ribière updates	traincgp
Gradient descent	Traingd
Gradient descent with momentum and adaptive learning rete	traingdx
Scale conjugate gradient	trainscg
One-step secant	trainoss
Resilient backpropagation	Trainrp

**Fonte:** Elaborado pelo autor, 2023.

A Figura 22 apresenta as principais características do banco de dados e da RNA treinada.

**Figura 22** - Arquitetura do modelo considerando dez entradas, neurônios variando de 1 a 20 na camada oculta e uma camada de saída



**Fonte:** Elaborado pelo autor, 2023.

As funções de treinamentos com melhores desempenho nesse estudo foram: traingd (Gradient Descent Backpropagation), trainlm (Levenberg–Marquardt), trainbr (Bayesian Regularization Backpropagation), trainscg (Scale Conjugate Gradient) e traincfg (Fletcher-Powell Conjugate Gradient). O banco de dados foi dividido aleatoriamente como 70% de dados de treinamento e 30% de teste. A Tabela 3 demonstra os principais parâmetros testados no desenvolvimento da RNA.

**Tabela 3** – Parâmetros utilizados para construção da RNA referente a emissões de GEE no aterro sanitário

Parâmetros	Valores	Informações
Função de treinamento	Trainbr, Trainlm, Trainscg, Traincfg Traingd	Testes em função das arquiteturas
Neurônios na camada oculta	1-20	Neurônios variando de 1-20 na camada oculta
Função de transferência na camada oculta e de saída	Tangente Hiperbólica, Log-sigmoid, Linear e Elliotsig.	Combinações entre camada oculta e de saída
Validação	MAE, RMSE, NRMSE, R <sup>2</sup> e E	Métricas de desempenho

**Fonte:** Elaborado pelo autor, 2023.



Para obtenção da RNA ótima, foram simulados diversos modelos com diferentes topologias variando de 1 a 20 neurônios em uma única camada oculta. Para determinação da melhor função de ativação da camada oculta e de saída foram examinadas as funções: Tangente Hiperbólica (tansig), Log-sigmoid (logsig), Linear (purelin) e Elliot Symmetric Sigmoid (elliotsig). A determinação da melhor arquitetura foi realizada por tentativa e erro, totalizando 1600 treinamentos, de modo a encontrar a arquitetura que apresenta o menor critério de erro.

A acurácia dos modelos desenvolvidos neste trabalho foi avaliada a partir de diversos parâmetros estatísticos. Portanto, para cada arquitetura neural foi determinada a sua performance através dos parâmetros: Mean Absolute Error (MAE); Root Mean Square Error (RMSE); Normalize Root Mean Square Error (NRMSE), Determination Coefficient ( $R^2$ ) and Efficiency Coefficient (E).

### 3.5.2 Escala de eficiência

Além da permeabilidade saturada à água, o fluxo de  $CH_4$  que flui na camada de cobertura final nos aterros sanitários deve ser mensurado juntamente com a eficiência da camada no decorrer do tempo, inclusive nos períodos secos e chuvosos.

A quantificação da emissão do  $CH_4$  pela superfície da camada de cobertura final é complicada e complexa, visto que existem algumas dificuldades como variabilidade temporal e espacial das taxas de fluxo.

Nesse contexto por meio do Quadro 3, em que são expostos fluxo de metano e tipologia da camada de cobertura final, em aterros sanitários no Brasil, na Ásia, Europa e Estados Unidos foi construída uma escala preditiva, onde os dados analisados por meio da estatística descritiva apresentaram os indicadores maiores e menores do fluxo de metano da camada de cobertura final no aterro sanitário, média, desvio padrão, variância, assimetria e a mediana.

O tratamento estatístico foi realizado através do *software Microsoft Excel*, com o objetivo de caracterizar as etapas parciais para os indicadores. Os resultados foram expostos utilizando um gráfico da função logarítmica, visto que apresentaram uma grande variabilidade.

## 4 RESULTADOS E DISCUSSÕES

### 4.1 Análise descritiva dos dados

Na Tabela 4 é apresentada análise descritiva dos fatores meteorológicos, propriedades e características solo da camada de cobertura do aterro sanitário.

**Tabela 4** - Análise descritiva dos dados

Variáveis	Média	Mediana	Mínimo	Máximo	Desvio Padrão	Coefficiente de Variação
Temperatura externa (°C)	32,05	31,11	24,75	41,31	3,82	11,92
Temperatura interna (°C)	34,22	35,10	0,00	45,36	7,54	22,03
Pressão Atmosférica (hPa)	953,15	954,00	949,00	958,00	2,09	0,22
Umidade relativa do ar (%)	60,66	57,00	41,00	92,00	13,56	22,36
Velocidade do vento (m/s)	16,15	15,12	10,00	23,04	3,58	22,21
Radiação (kJ/m <sup>2</sup> )	1853,35	2051,09	202,64	2867,99	684,83	36,95
Grau de compactação (%)	84,26	84,57	69,68	98,94	6,89	8,18
Grau de saturação (%)	18,69	16,98	5,23	51,43	10,12	54,17
Massa específica aparente do solo (g.cm <sup>-3</sup> )	1,58	1,59	1,31	1,86	0,12	8,18
Umidade do solo (%)	4,77	4,34	1,36	13,33	2,39	50,23
Fluxo de CH <sub>4</sub> (g.m <sup>-2</sup> d <sup>-1</sup> )	24,88	4,28	0,00	386,66	68,09	273,66

**Fonte:** Elaborado pelo autor, 2023.

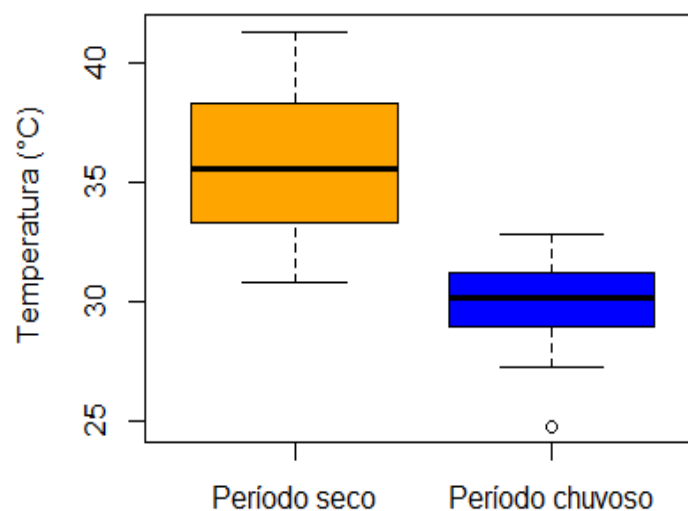
Na seção 4.2 será discutido os resultados da estatística descritiva dos dados e analisadas as variáveis independentes e suas correlações com a emissão do CH<sub>4</sub> na camada de cobertura final em aterro sanitário nos períodos seco e chuvoso.

## 4.2 Variáveis Meteorológicas

### 4.2.1 Temperatura externa

A temperatura externa não só influencia o fluxo de biogás no aterro sanitário através da camada de cobertura final, mas também influencia diretamente na geração de biogás, uma vez que a temperatura ideal para atividades de bactérias anaeróbicas está entre 30°C e 41°C. (Barreto *et al.*, 2022). A Figura 23 possibilita uma melhor análise da variabilidade da temperatura externa em relação ao período seco e chuvoso.

**Figura 23-** Variabilidade da temperatura externa (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

Para o período seco, as temperaturas médias no ambiente do aterro sanitário foram em torno de 35,8°C, com amplitude de 11°C, durante o período monitorado. No período chuvoso as temperaturas médias foram de 29°C, com amplitude de 8°C, sendo as diferenças observadas significativas entre os períodos ( $p= 0,01$ ).

No aterro sanitário metropolitano Oeste de Caucaia, no Ceará (ASMOC), obteve temperaturas variando entre 31,9 °C a 36 °C para os períodos sem chuva, com uma amplitude de 5 °C, em relação ao período chuvoso foi de 23,1 °C a 29,3 °C com uma amplitude de 6 °C.


Damasceno (2019) observou que o período em que ocorreram as maiores emissões de metano foi nos meses de maiores temperaturas coincidindo com período seco do local estudado. Isso já era esperado, pois em solos que não estejam saturados com líquidos em seus poros permitem o maior fluxo de gases. Além do mais, em períodos secos não ocorrem variações

bruscas de temperatura, o que não desestabiliza o interior da camada de cobertura de solo compactado em termos microbianos, que o permite a conversão de  $\text{CH}_4$  a  $\text{CO}_2$ . Nesse caso pode ocorrer um aparente aumento no fluxo de  $\text{CO}_2$ .

#### 4.2.2 Temperatura Interna

A temperatura interna nos aterros sanitários é elevada em comparação com a externa. Temperaturas de até  $64^\circ\text{C}$  no interior de aterros sanitários foram relatadas em estudos anteriores (Willumsen, 2013). A digestão anaeróbica de resíduos orgânicos em aterros produz calor, assim é a temperatura interna afeta mais a geração de  $\text{CH}_4$  em relação a temperatura externa (Aghdam *et al.*, 2017). Essa diferença favorece o fluxo de  $\text{CH}_4$  do interior para o exterior do aterro sanitário, o que também promoveu um maior fluxo de gases através da camada de cobertura final. Na Figura 24, o gráfico apresentado possibilita observar a variabilidade da temperatura interna em relação ao período seco e chuvoso.

**Figura 24** - Variabilidade da temperatura interna (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

A Figura 24 apresenta o boxplot da variação da temperatura interna, para o período seco e chuvoso, observando-se uma assimetria à esquerda para o período chuvoso. Os valores das temperaturas para o período chuvoso estão distribuídos, em sua maioria abaixo da mediana, 75% dos dados. A temperatura média para o período seco foi de  $37,89^\circ\text{C}$ , para o período chuvoso foi  $32,20^\circ\text{C}$ .

O comportamento hidráulico e mecânico dos RSU, bem como as propriedades de revestimento das camadas de coberturas tem uma estreita relação com a temperatura interna do

maciço (Reddy *et al.*, 2017). O aumento da temperatura interna afeta diretamente na viscosidade dos líquidos, o que por sua vez influencia na sua permeabilidade. O efeito capilaridade, que se traduz na migração de líquidos através da camada de cobertura será maior se houver uma menor viscosidade, por exemplo.


A temperatura também afeta na viscosidade de gás, ou seja, se a temperatura aumentar a viscosidade dos gases aumentam em função dos choques moleculares. Entretanto, esse fator deve ser melhor estudado em fluxo de gases em camadas de cobertura de aterros sanitários. No caso específico do aterro sanitário em estudo, a temperatura aliada a baixa saturação da camada de cobertura, influenciou no maior fluxo de gases por essa camada.

#### **4.2.3 Pressão atmosférica**

Observa-se na análise descritiva que houve uma variação de 0,22% para os dados observados durante a realização da campanha, ou seja, não ocorreram variações significativas de pressões atmosféricas no aterro sanitário, durante o período que foi realizada a pesquisa ( $p=0,69$ ).

No período seco a pressão atmosférica variou em torno de (954 hPa), no período chuvoso (958 hPa). Em média as pressões atmosféricas foram ligeiramente maiores no aterro sanitário no período chuvoso, sendo observado um menor fluxo de metano para este período, o que corrobora que a pressão atmosférica pode mudar inclusive a direção do fluxo de gases. Rees-White *et al.* (2019) encontraram uma estreita relação entre a emissão de CH<sub>4</sub> e a pressão atmosférica. Entretanto, deve-se levar em consideração a diferença de gradiente interno e externo de pressão à camada de cobertura para se determinar com maior precisão a direção do fluxo de gases através da camada de cobertura.

**Figura 25** - Variabilidade da Pressão Atmosférica (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

A diminuição na pressão atmosférica pode provocar um aumento potencial no fluxo de metano do maciço sanitário para o ambiente externo, uma vez que seja mantido o gradiente de pressão (maior pressão interna de gases). Por outro lado, o aumento da pressão externa em relação à interna faz com que o ar flua para o solo ou interior da camada de solo compactado, inclusive diluindo a concentração dos gases solo (Nwachukwu, 2013).

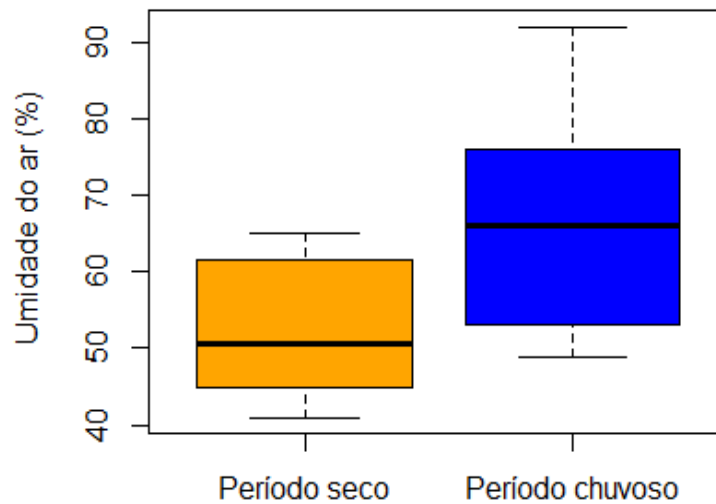
#### 4.2.4 Umidade relativa do ar

A umidade relativa do ar influencia na umidade do solo da camada de cobertura de solos compactados em aterros sanitários e, conseqüentemente, as taxas de emissão de gases (Borba *et al.*, 2018).

Marques-Junior (2020) observou no período de janeiro de 2018 à novembro de 2019 que a umidade relativa do ar sofreu poucas variações, apresentando uma média de 80% durante o período monitorado, e, considera-se que, esse teor pode favorecer o processo biodegradativo e a atividade microbiana para geração de biogás no aterro sanitário, inclusive na conversão de metano a dióxido de carbono no interior da camada de cobertura, o que favorece a diminuição do fluxo de metano e aumenta a de dióxido de carbono. Esse quadro só não será eficiente, se houver fissuras, ou seja, os gases percolarão por essas fissuras livremente e sem tratamento. A camada de cobertura final de aterros sanitários, quando projetada e executada de maneira eficiente trata os gases que por elas passam.

No período seco a umidade relativa do ar variou de 41% a 65%, para o chuvoso a variação foi de 49% a 92%, com média de 66,22%, sendo as diferenças observadas consideradas não significativa ( $p= 0,87$ ) (Figura 26).

**Figura 26** - Variabilidade da umidade relativa do ar (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

Maciel (2009) observou, em seus estudos em região semiárida, umidades relativas do ar entre 68,9 e 86,1%, durante o período chuvoso, valores próximos aos encontrados no aterro sanitário. Não são reportados valores de umidade do ar superiores a 90% durante a estação chuvosa (Guedes, 2018). Dentre as variáveis ambientais, a umidade relativa do ar se destaca no clima semiárido devido sua variabilidade ao longo do período chuvoso com umidade alta e período seco com umidade relativa mais baixa (Sousa, 2018).

Segundo Borba *et al.* (2018), o maior valor de umidade relativa do ar foi observado no período chuvoso (novembro/2014), com 84%, e o menor valor, em dia de muito vento (outubro/2014), com 21%.

Destaca-se que a amplitude de variação da umidade relativa do ar, durante o estudo, foi duas vezes maior no período chuvoso. Valores maiores de umidade relativa do ar podem aumentar a concentração de CH<sub>4</sub> na superfície da camada de cobertura final (Shen *et al.*, 2018).

Os altos índices de umidade relativa do ar influenciam na umidade do solo da camada de cobertura final do aterro sanitário, afetando a quantificação da taxa de emissão dos GEE (Borba *et al.*, 2018). Além disso, como já comentado, a umidade do solo da camada de cobertura pode juntamente com os líquidos acumulados de precipitações anteriores, obstruir poros ou

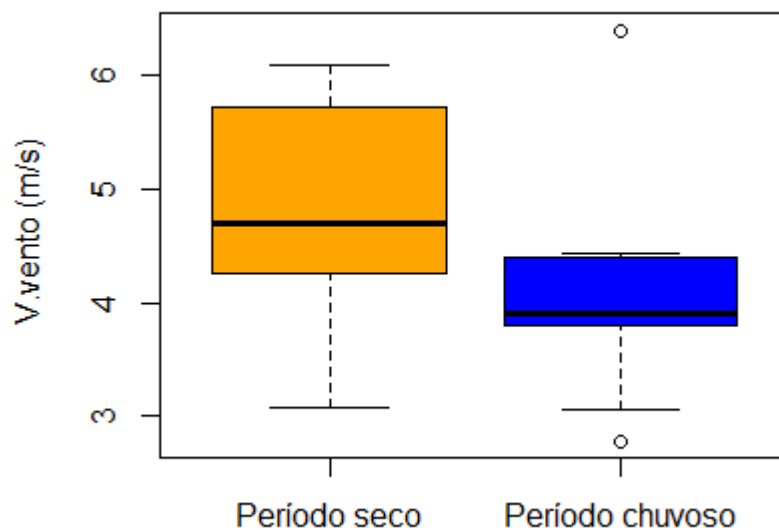
vazios do solo, ou seja, o solo está em saturação ou próximo da saturação, o que impede a passagem de gases. Durante o período chuvoso, o fluxo de gases foi menor se comparado ao período seco, corroborando com estudos de Santos (2019).

#### 4.2.5 Velocidade do vento

Em aterros sanitários os ventos são importantes, tanto em relação ao transporte de odores para fora do ambiente do aterro, como tem papel preponderante no processo de advecção. Segundo Manhein *et al.* (2021) os gradientes de pressão entre a massa de resíduos e a superfície do aterro podem ocorrer através do vento, variação na pressão barométrica ou pelo acúmulo de pressão nos resíduos.

No aterro sanitário foi medida velocidade do vento que variou de 3,06 m/s a 6,1 m/s nas amostragens, durante o período seco. Já no período chuvoso houve uma oscilação entre 2,77 e 6,4 m/s (Figura 27). Nota-se que houve uma diminuição gradativa da velocidade durante o período chuvoso. As variações observadas entre os períodos foram não significativas ( $p=0,24$ ).

**Figura 27** - Variabilidade da velocidade do vento (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

Na região em estudo, nos meses de julho a março (período seco), a velocidade do vento ficou entre 3,00 m/s e 3,9 m/s e nos meses de abril, maio e junho (período chuvoso) a velocidade do vento oscilou de 2,77 m/s a 2,81 m/s, tendo como velocidade anual é de 3,25 m/s (Medeiros, 2021).



Na região semiárida, durante o período seco, a fraca nebulosidade provoca um aumento da incidência da radiação solar ocasionando maiores temperaturas do ar, promovendo um alto déficit entre os centros de alta e baixa pressão, causando maiores velocidade do vento. Os menores valores de velocidades do vento, observados no período chuvoso, podem ser justificados pela atuação da Zona de Convergência Intertropical (ZCIT) e pelo enfraquecimento dos ventos alísios de sudeste nessa região (Júnior *et al.*, 2019).

Maciel (2009) relata que este fator meteorológico tem relação com a diluição do biogás imediatamente acima da camada de cobertura, e variações de pressões atmosférica devido à turbulência ocorrendo aumento das emissões dos gases por drenos verticais e através da camada de cobertura final de aterros sanitários.

Um aumento na pressão atmosférica geralmente resulta em transporte advectivo e/ou difusivo reduzido através de coberturas de aterros e pode resultar em uma reversão de fluxo (absorção líquida em vez de emissões líquidas). A forte incidência de rajadas de vento na região do aterro sanitário contribui para a dispersão dos gases emitidos (Borba, 2016) e para um maior fluxo de gases na camada de cobertura, especialmente, no período seco.


É interessante ressaltar que há uma estreita relação entre velocidade dos ventos, pressão atmosférica, o que influencia diretamente nas emissões fugitivas de gases pela camada de cobertura.

#### **4.2.6 Radiação solar**

Em aterros sanitários a radiação solar, é uma importante variável a ser monitorada, visto que afeta a temperatura, que é um fator interveniente no processo de difusão e o transporte do biogás. Além disso, a radiação solar pode afetar a temperatura do solo de cobertura de aterros sanitários, que influencia a oxidação e as emissões de CH<sub>4</sub> (Xin *et al.*, 2016).

A radiação solar na região do aterro sanitário, apresentou média de 2238.20 kJ/m<sup>2</sup>, durante o período seco, variando de 719,29 a 2867,99 KJ/m<sup>2</sup>. No período chuvoso a média de radiação solar foi de 1602.40 KJ/m<sup>2</sup>, variando de 202,64 a 2631,44 KJ/m<sup>2</sup>, sendo as diferenças entre os períodos de estudo não significativas (Figura 28) (p= 0,47).

**Figura 28** - Variabilidade da Radiação solar (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

As diferenças não significativas entre os períodos observadas são características da região, mesmo não ocorrendo elevadas precipitações nos períodos chuvosos, a radiação tende a reduzir (Silva, 2022).

Santiago (2022) observou na cidade de Natal/RN variações anuais de radiação nos valores de  $684\text{kJ/m}^2$  a  $943,84\text{kJ/m}^2$ . Durante o período seco a radiação é superior  $900\text{kJ/m}^2$  enquanto nos meses chuvosos a radiação é levemente inferior a  $720\text{kJ/m}^2$ .

Pode-se notar nos dados apresentados na Figura 28, que existe uma certa influência na radiação solar que ocorre no período seco e chuvoso com as emissões fugitivas de  $\text{CH}_4$  pela camada de cobertura. A radiação solar está diretamente ligada a evaporação de líquidos na camada de cobertura, o que por sua vez aumenta os caminhos da percolação dos gases. É claro, que deve ocorrer mais estudo com relação a evaporação de líquidos da camada de cobertura, inclusive para se determinar como o fenômeno da sucção age nessas camadas.

De uma maneira geral a sucção age a favor da permeabilidade aos gases no interior da camada de cobertura de solo compactado. Destaca-se que, o conhecimento prévio da sucção e de sua variação com o teor de umidade devido à evaporação é de fundamental importância para realizar uma análise dos solos, quando submetidos ao ressecamento. A sucção de um solo é um parâmetro mais relevante para conhecimento de seu comportamento não saturado.

Basicamente, sucção dos solos é uma quantidade energética para avaliar a sua capacidade de reter água. Quando água livre migra para dentro de um solo, ela será retida ou


adsorvida por ele. Para desprender esta água adsorvida, energia externa tem de ser aplicada, indo de encontro às forças de retenção do solo (Pinheiro *et al.*, 2017). A energia aplicada por unidade de volume de água para desprendê-la é a sucção (Lee & Wray, 1995) e quanto mais secos os solos, maior a sucção.

### 4.3 Caracterização da Camada de Cobertura em termos geotécnicos

#### 4.3.1 Grau de compactação (GC)

O GC não possui nenhuma regulamentação ou índices mínimos a serem atendidos para camadas de cobertura final de aterros sanitários, entretanto um bom índice de GC representa a principal finalidade da camada de cobertura de solo compactado, a impermeabilização, seja a água ou gás.

**Figura 29** - Variabilidade do Grau de compactação (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

No período seco houve uma variação de 73,4% a 92% do CG para a camada de cobertura final do aterro sanitário em estudo. Mariano (2008) observou que solos com GC superior a 90% apresentaram maior retenção de metano para as maiores profundidades em aterro sanitários.

Pode-se considerar o papel do GC no processo de retenção de gases e consequente mitigação de sua emissão para a atmosfera. Para o período chuvoso o GC sofreu uma variação de 69,98 a 98,94%. No período seco a amplitude foi de 18,6%, para o período chuvoso foi de 28,96%, destacando que quanto maior o grau de compactação, menor são os vazios do solo.

Interessante frisar que o GC de uma camada de cobertura de um aterro sanitário pode variar após a sua execução. A passagem de máquinas, equipamentos e caminhões podem alterar o CG do solo. Em dias secos, inclusive, pode ocorrer a dispersão de líquidos para diminuir partículas poeira na atmosfera e, por consequência, o grau de compactação pode ser alterado.

Se por um lado o grau de compactação no período seco diminuiu no Aterro Sanitário em estudo o fluxo de gases aumentou, pois ocorre um aumento nos vazios dos solos, propiciando o fluxo desses gases do maciço sanitário para a atmosfera. Isso já era esperado. Com relação ao período chuvoso, os valores de CG comparado ao período seco foram próximos, mas a variação foi maior.

#### **4.3.2 Grau de Saturação**

Conforme Araújo (2014), O aumento do grau de saturação, provoca uma diminuição na permeabilidade do solo ao ar tendo em vista que a quantidade e a continuidade dos poros aerados ficam reduzidos pela inserção de líquidos em seu interior.

É importante frisar que o grau de saturação é, geralmente, expresso em porcentagem e representa o volume de água contida nos vazios do solo. No solo seco ( $S=0$ ) não há a presença de água nos seus vazios, o que corrobora com a passagem de gases. Do contrário, solo saturado ( $S=100\%$ ), tem todos os seus vazios preenchidos com água.

Jucá & Maciel (2006) investigaram a influência do grau de saturação de água na permeabilidade ao gás da argila compactada. Observou-se uma ligeira diminuição na permeabilidade ao gás devido ao aumento no grau de saturação entre 10% e 85%.

No entanto se o grau de saturação foi maior que 85%, a permeabilidade ao gás diminuiu significativamente com um pequeno incremento de água. Este fenômeno indica que o grau de saturação com um valor de 85% representa o ponto em que a fase de ar passa de uma fase contínua para uma fase descontínua na argila compactada.


O solo empregado na execução da camada de cobertura final do Aterro Sanitário em estudo, de acordo com Sistema Unificado de Classificação dos Solos (SUCS ASTM D2487-11), é do tipo areia argilosa (SC)/areia siltosa (SM), tendo um percentual de finos de 38% (Santos *et al.*, 2020).

Solo arenoso, também chamado de solo de textura leve, é caracterizado pelo alto teor de areia (superior a 70%) e menor teor de argila (inferior a 70%) em sua composição. É um tipo de solo normalmente granuloso, pobre em nutrientes e com baixo teor de matéria orgânica. Já solos argilosos, de uma maneira geral, a grande impermeabilidade é uma das principais

características. É por causa dessa propriedade que a argila encharca, bem como seca com facilidade.

Entretanto, com a junção de ambos os solos, há um ganho em desempenho do solo gerado. No caso do Aterro em estudo o solo, como já comentado é do tipo SC/SM, o que gerou dados como o grau de saturação, variando de 5,23% a 27,43% para o período seco, com média de 12,57%, e para o período chuvoso, uma variação de 8,85% a 51,43% com uma média de 22,09% (Figura 30).

**Figura 30** - Variabilidade do Grau de saturação (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

Moreira *et al.* (2020) observou em solos do aterro sanitário, um grau de saturação na ordem de 40,2%. Logo, o valor de 95% de saturação do solo é dificilmente atingido *in situ*, o que implica na ocorrência de valores consideráveis de permeabilidade ao ar, indicando que a camada de cobertura final não será eficiente para impedir a passagem de gases para atmosfera.

De acordo com os resultados observados, o solo da camada de cobertura final encontra-se no estado não saturado. Ng *et al.* (2015) afirmam que os solos não saturados são mais favoráveis aos fluxos de gases do que os solos saturados, uma vez que, quando há um aumento do grau de saturação, o ar presente nos vazios do solo deixa de ser contínuo e passa a ser ocluso, reduzindo assim a permeabilidade ao ar e, portanto, aumentando a taxa de emissão de biogás. Observa-se uma significância entre grau de saturação e os períodos secos e chuvosos. ( $p=0,001$ ).

Destaca-se aqui que o incremento e/ou decréscimo na taxa de emissão de gases no período chuvoso e seco são intrinsecamente ligados ao grau de saturação e de compactação, índice de vazios e outras características geotécnicas da camada de solo empregada na cobertura.

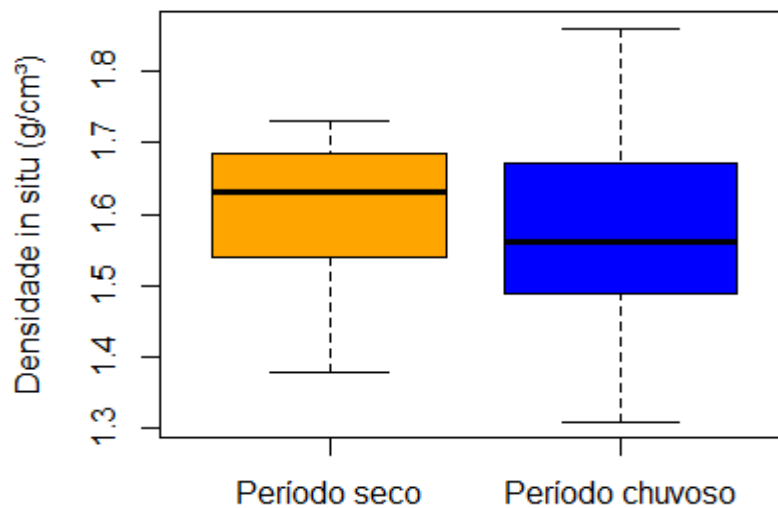
#### 4.3.3 Massa específica aparente do solo

A massa específica aparente ( $\rho$ ) de um solo é dado pela relação entre a massa de um solo (M) e seu respectivo volume (V). A massa específica aparente seca de um solo é obtida pela razão entre a massa de um solo seco ( $M_s$ ) e o respectivo volume total (V). Neste caso o teor de umidade do solo é zero ( $w=0$ ).

De uma maneira geral não houve diferença significativa na massa específica aparente do solo da camada de cobertura do Aterro Sanitário em estudo entre os períodos seco e chuvoso ( $p=0,80$ ). Altos valores de massa específica aparente do solo são comuns em locais onde há o fluxo de maquinário pesado, como é o caso dos aterros sanitários ( $1,5$  a  $1,7$   $\text{g/cm}^3$ ), onde diariamente há a entrada e saída de veículos portando resíduos sólidos urbanos, além de não haver qualquer tipo de manejo (revolvimento ou incorporação de matéria orgânica) (Bogunovic *et al.*, 2017).

A Figura 31 apresenta massa específica aparente do solo do aterro sanitário, onde foram observados para o período chuvoso um valor máximo de  $1,86\text{g/cm}^3$  e um valor mínimo  $1,31$   $\text{g/cm}^3$ . Para o período seco foram observados um valor máximo de  $1,73\text{g/cm}^3$  e um valor mínimo de  $1,38$   $\text{g/cm}^3$ .

**Figura 31** - Variabilidade da massa específica aparente do solo (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

Estes valores são considerados entre médios a altos, podendo serem atribuídos ao sistema de manejo utilizado para a construção e a manutenção da camada de cobertura final do aterro sanitário (Magalhães *et al.*, 2020).

Interessante, que os solos para camada de cobertura final de aterros, especialmente, quando ocorre passagem de maquinários e transporte de pessoal/funcionários, de fato apresentam uma variação na massa específica aparente do solo. Em alguns casos, pode ocorrer, inclusive, o bloqueio total de gases que passam pela camada de cobertura, mesmo em período seco. Se por um lado os gases ficam contidos e são liberados para o sistema de drenagem, por outro lado, se houver falhas de execução na drenagem de gases e líquidos, pode ocorrer até explosões e, em alguns casos a biodegradação dos resíduos fica comprometida.

Conforme Jucá & Maciel (2006), a permeabilidade ao ar não é apenas função da umidade, mas também a interação entre o teor de água, a estrutura e a massa específica aparentem do solo.


#### **4.3.4 Umidade do solo**

Em relação a umidade do solo para as camadas de cobertura final dos aterros sanitários, esta deve ficar entre 10-20%, sendo este valor necessário para a oxidação do metano (Chanton *et al.*, 2011).

A oxidação do metano é consequência da passagem desse gás pela camada de cobertura e do oxigênio proveniente do ar atmosférico. É preferível o fluxo de CO<sub>2</sub>, pois além de ser menos tóxico que o metano, é um produto da oxidação do próprio CH<sub>4</sub>. Assim, é possível encontrar uma menor concentração de CH<sub>4</sub> na superfície da camada de cobertura em relação a sua base, ou seja, a sua concentração diminui com a espessura da camada em direção à superfície. Por outro lado, ocorre um acréscimo de CO<sub>2</sub>.

De acordo com Figura 32, no período seco, a umidade do solo variou entre 1,36% e 5,92% enquanto no período chuvoso, variou entre 3,24% e 13,33%. Observa-se que houve uma amplitude de 4,96% para o período seco e 10,09% para o período chuvoso.

**Figura 32** - Variabilidade da Umidade do solo (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

Em relação as emissões de gases em aterro sanitário, Rachor *et al.* (2013) observou em seus estudos que emissões mais altas estão associadas a umidades mais baixas. Este processo está associado ao aumento da taxa de oxidação do metano através das bactérias presente no solo. Mas é bom frisar que o processo de passagem de gás pela camada de cobertura diminui com o acréscimo de umidade em seu interior. Nesse sentido, Maciel (2009), observou que os fluxos de gases são desfavorecidos quando há um preenchimento da matriz do solo por água.

Segundo Abichou *et al.* (2015) quando a umidade do solo é inferior a 10%, a taxa de oxidação bacteriana é muito baixa, no entanto a atividade microbiana se eleva quando a umidade do solo é superior a 20%.

A umidade média do solo, obtida foi de 4,77%, valor inferior obtido por Lopes *et al.* (2012) no Aterro Sanitário de Muribeca -PE, de 15%. Variações sazonais foram observadas nos dados de cobertura final do aterro sanitário onde o teor de umidade foi geralmente significativamente maior na estação chuvosa do que na estação seca (Hanson *et al.*, 2023).

Observa-se diferenças significativas nos ensaios de umidade no solo da camada de cobertura entre os períodos, ou seja, maior umidade período chuvoso, menor umidade período seco ( $p=0,001$ ).

Os parâmetros associados às variáveis meteorológicas e caracterização da camada de cobertura em termos geotécnicos de um aterro sanitário, bem como a execução de uma camada de cobertura podem ser usados para se confeccionar uma escala de eficiência de para essas



camadas com relação ao fluxo de gases, entretanto, estudos com dados reais e o uso de modelagem constitutiva ou não constitutivas devem ser exploradas.


#### 4.4 Emissão fugitiva de CH<sub>4</sub>

##### 4.4.1 Metano

Neste trabalho foi abordado com mais ênfase a emissão de metano pela camada de cobertura do Aterro Sanitário na região do semiárido paraibano, além de ser um gás do efeito estufa. Em particular, o CH<sub>4</sub> é quase 25 vezes mais poderoso do que o CO<sub>2</sub> (Kaza *et al.*, 2016).

O maior valor para o fluxo de CH<sub>4</sub> observado nesta pesquisa foi de 386,66 g.m<sup>-2</sup>.dia<sup>-1</sup> e o valor mínimo de 0,00 g.m<sup>-2</sup>.dia<sup>-1</sup> (Figura 33). Embora o fluxo de metano tenha sido maior no período seco os valores são próximos ao do período chuvoso. Deve-se destacar que na camada de cobertura do Aterro Sanitário em estudo foi possível verificar a presença de fissuras, o que permite o fluxo sem obstrução à atmosfera. Isso pode ser uma das causas desses valores próximos.

**Figura 33** - Variabilidade do Fluxo de metano (período seco e chuvoso)



**Fonte:** Elaborado pelo autor, 2023.

Ao quantificar as emissões de metano, fica claro que não apenas diferentes condições climáticas devem ser consideradas, mas também diferenças nas vias de emissão através da cobertura final do aterro sanitário devem ser caracterizados, pois a influência das condições climáticas não é uniforme em toda a superfície (Rachor *et al.*, 2013). E isso foi observado no Aterro em estudo, inclusive, com regiões da camada de cobertura de solo compactado com

passagem de caminhão dispersor de água, enquanto outras estavam com água acumulada em sua superfície.

São reportados para o aterro sanitário de Palermo na Itália por Trapani *et al.*, (2013), valores de 0,09 a 1.118,00 g.m<sup>-2</sup>.dia<sup>-1</sup>. Borba (2018) no Aterro Sanitário de Seropédica, Rio de Janeiro-RJ, verificou um valor máximo de emissão de CH<sub>4</sub> de 389.00 g.m<sup>-2</sup>.dia<sup>-2</sup>.

Houve uma variação de 273,66% para o fluxo de metano na camada de cobertura final, sendo considerado um valor muito alto se comparado a outros aterros no Brasil e no mundo. Segundo Vanni (1998) um valor acima de 35% indica uma heterogeneidade, como observado nesta pesquisa.

Abichou *et al.* (2006) observaram em sua pesquisa, duas camadas de cobertura em um Aterro Sanitário localizado na Flórida, Estados Unidos, e apresentaram uma classificação para as emissões de CH<sub>4</sub>, dividida em três grupos: Baixo (< 10 g.m<sup>-2</sup>. dia<sup>-1</sup>), médio (entre 10 g.m<sup>-2</sup>. dia<sup>-1</sup> e 25 g.m<sup>-2</sup>. dia<sup>-1</sup>) e alto (> 25 g.m<sup>-2</sup>. dia<sup>-1</sup>).

As alterações observadas em relação às taxas de emissão do CH<sub>4</sub>, podem ser relacionadas ao objetivo proposto para cada aterro ao decorrer do tempo, diretamente ligados às propriedades do solo, tais como, grau de compactação, grau de saturação, umidade do solo, além das variações climáticas, pressão atmosférica, velocidade do vento (Vilela & Araújo, 2021).

As elevadas temperaturas medidas no aterro sanitário, localizado na região semiárida do estado da Paraíba-Brasil são favoráveis ao fluxo de metano. Maciel (2009) relata que variações na temperatura ambiente é um dos fatores que interfere nas emissões fugitivas de gases através da camada de cobertura final em aterros sanitários, devido às alterações na temperatura do solo.

De uma maneira geral, é possível classificar o aterro sanitário com relação a emissão de gases pela camada de cobertura final como eficiente, porém estudos mais avançados devem continuar. Outro fator a ser considerado é que a camada de cobertura final não é homogênea espacialmente, o que faz com que alguns pontos tenham eficiência reduzida na retenção de gases.

## **4.5 Análises Multivariadas**

### **4.5.1 Análise de Componentes Principais (ACP)**

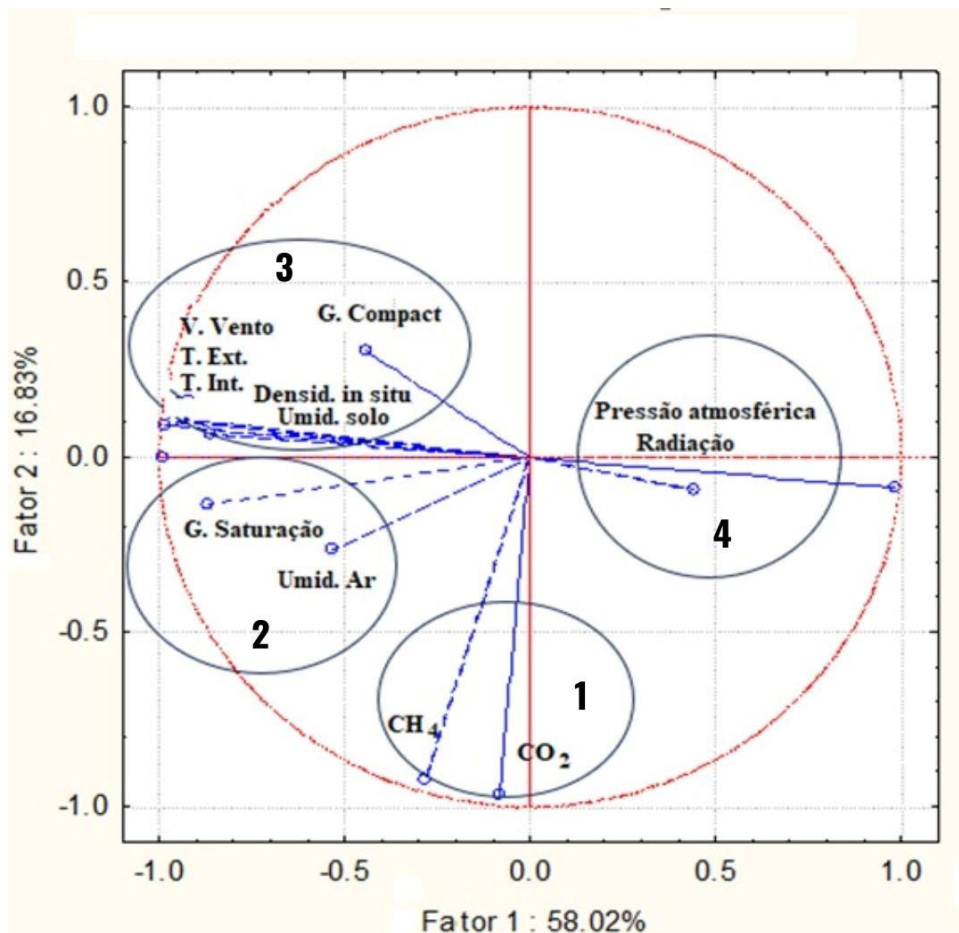
Os resultados da ACP mostram que os dados são estatisticamente representativos porque a soma da primeira componente principal (CP1) e a segunda componente principal (CP2) totalizou 74,85% (Figura 34). De acordo com Rencher (2002), a soma das duas componentes

principais, devem explicar, pelo menos 70% da variância total dos resultados. Diante disso o primeiro principal componente explica a porcentagem com uma variância maior com relação à segunda componente principal.

Através da análise das componentes principais observadas na Figura 34, verifica-se que a primeira componente principal (CP1) responde por 58,02% da variância total das variáveis originais e a (CP2) explica 16,83%.

A ACP utilizando os fatores intervenientes, meteorológicos e solos é apresentada na Figura 34, onde observa-se a formação de 4 grupos distintos. Grupo 1 (fluxo de CH<sub>4</sub>, fluxo de CO<sub>2</sub>); grupo 2 (grau de saturação, umidade do ar); grupo 3 (velocidade do vento, temperatura externa, temperatura interna, grau de compactação, umidade do solo, massa específica aparente do solo) grupo4 (pressão atmosférica, radiação).

**Figura 34** - Análise de componentes principais dos fatores intervenientes, meteorológicos e solos na emissão de gases pela camada de cobertura do Aterro Sanitário.



**Fonte:** Elaborado pelo autor, 2023.

No grupo 1 observa-se uma correlação positiva entre o fluxo de  $\text{CH}_4$  e  $\text{CO}_2$ . Em aterros sanitários a fluxo de metano está associado ao de dióxido de carbono e sempre que ocorre o aumento de gás em particular, ocorrerá o de outro. Isso não quer dizer que ocorreram na mesma proporção, pois o metano que passa pela camada de cobertura terá uma parcela sendo convertido em dióxido de carbono devido à atividade metabólica de bactérias metanotróficas, este processo é chamado de oxidação de  $\text{CH}_4$  (Mariano, 2008).

Embora o fluxo de metano diminua na camada, quanto mais  $\text{CH}_4$  passar por essa camada maior será a concentração de  $\text{CO}_2$  e, por isso, já era esperado correlações positivas entre os mesmos, ainda estando em um mesmo grupo de comportamento.

Verifica-se no grupo 2 que a umidade relativa do ar apresentou uma correlação média com a umidade do solo. Borba *et al.* (2018) observou que o maior valor de umidade relativa do ar foi verificado em dias de chuvas (novembro/2014), com 84%, e o menor valor, em dias de muito vento (outubro/2014), com 21%. Os maiores índices de umidade relativa do ar influenciam na umidade do solo da camada de cobertura final afetando a quantificação da taxa de emissão do  $\text{CH}_4$  no aterro sanitário. O grupo 3 é possível observar uma fraca correlação entre as emissões de  $\text{CH}_4$  e  $\text{CO}_2$  com a velocidade do vento, isso pode ser justificado porque quando há maiores velocidades dos ventos o fluxo do gás migram especialmente, pelas fissuras e não através da camada de cobertura final (Shen *et al.*, 2018).

Com relação aos fatores geotécnicos observados no grupo 3, a umidade do solo apresentou uma fraca correlação com a emissão do gás  $\text{CH}_4$ , sugerindo a necessidade de estudos da condição apresentada de não saturada do solo da camada de cobertura final, assim como sugerido Souza *et al.* (2018).

No grupo 4 a correlação entre pressão atmosférica e fluxo de  $\text{CH}_4$  e  $\text{CO}_2$  é fraca. Lopes (2011) identificou que os períodos de maiores temperaturas (máximas e mínimas) coincidiam com as maiores emissões de  $\text{CH}_4$  e  $\text{CO}_2$ , corroborando com os dados apresentados no aterro sanitário em estudo. O mesmo padrão ocorreu com pressões atmosféricas e o fluxo de gases.

De uma maneira geral, pode-se dizer que os fatores que mais contribuirão no fluxo de gases pela camada de cobertura foram grau de saturação do solo e umidade do ar e com padrão de correlação positiva, ou seja, aumentando a umidade do solo (grau de saturação) e umidade do ar, o fluxo de metano aumentou pela camada de cobertura. A princípio parece haver uma contradição, mas deve-se levar em conta que o solo não estava saturado, e portanto, não bloqueou de maneira estanque a passagem de gases, além do mais, o solo com um grau de saturação próxima à os encontrado no solo compactado para cobertura final no Aterro Sanitário em estudo favorecem a decomposição de metano em dióxido de carbono e por isso a

correlação positiva. Entretanto, se o grau de saturação do solo fosse próximo a 100% e com umidades do ar elevada, as correlações seriam negativas (inversas). Por isso, o grau de saturação do solo e a umidade relativa do ar devem ser incorporadas ao se projetar e executar camadas de cobertura para aterros sanitários. Se por um lado, não se deseja que o fluxo de gás ocorra de maneira livre na camada, por outro lado deseja-se que ele seja retido, mas não a ser um possível indutor de explosões e de mumificação dos resíduos sólidos contido em um aterro sanitário.

Outro quesito a se levar em conta é relação dos grupos 3 e 1, especialmente, grau de compactação e fluxo de gases. De uma maneira geral quanto maior o grau de compactação, mais estanque será a camada em relação ao fluxo de gases. Embora os grupos estejam em quadrantes próximos (3 e 4 - direita para esquerda), é, portanto, uma correlação fraca e positiva, contudo esperava-se ocorrer o inverso.

Em relação a Tabela 5 são observados os valores dos pesos para os parâmetros nas respectivas Componentes Principais (CP) para os períodos estudados destacando-se, os maiores valores absolutos dos parâmetros e as CP que mais influenciaram o processo.

Na CP1 os parâmetros: temperatura externa (0,124), temperatura interna (0,107), pressão atmosférica (0,138), velocidade do vento (0,132), grau de saturação (0,108), densidade *in situ* (0,139), e umidade média do solo (0,140) são os mais correlacionados com esta CP (Tabela 5). Com relação a CP2 destacaram-se: fluxo de metano (0,421) e fluxo de dióxido de carbono (0,464).

Pela análise de componentes principais foi estatisticamente observado, quais os principais parâmetros influenciaram o fluxo de CH<sub>4</sub> na camada de cobertura final do aterro sanitário e sua contribuição para os fatores intervenientes (solos e meteorológicos). Vale salientar o impacto dos parâmetros meteorológicos do fluxo de CH<sub>4</sub> na camada de cobertura final em aterros sanitários é reportado na literatura (Aghdam *et al.*, 2019).

Diante disso vale destacar os estudos de Xin *et al.* (2016) com radiação solar, temperatura ambiente e velocidade do vento; e Xu *et al.* (2014) com pressão atmosférica e velocidade do vento.

**Tabela 5** - Contribuições das variáveis nos dois primeiros componentes da ACP

Variáveis	CP1	CP2
Fluxo de metano	0.011	<b>0.421</b>
Fluxo de CO <sub>2</sub>	0.001	<b>0.464</b>
Temp. Externa	<b>0.124</b>	0.005
Temp. Interna	<b>0.107</b>	0.002
Pressão Atmosférica	<b>0.138</b>	0.003
Umidade do ar	0.040	0.034
Velocidade do vento	<b>0.132</b>	0.005
Radiação solar	0.027	0.004
Grau de compactação	0.027	0.044
Grau de saturação	<b>0.108</b>	0.009
Massa específica aparente do solo	<b>0.139</b>	0.003
Umidade do solo	<b>0.140</b>	0.005

**Fonte:** Elaborado pelo autor, 2023.

#### ***4.5.2 Correlação entre parâmetros meteorológicos e geotécnicos do solo da camada de cobertura do Aterro Sanitário com as emissões de metano***

Os resultados da análise de correlação para identificar os parâmetros de entrada para predição do fluxo de metano no aterro sanitário são apresentados na Tabela 6.

Na Tabela 6 é possível observar correlações estatísticas fracas entre o fluxo de gás (CO<sub>2</sub> e CH<sub>4</sub>) e os demais parâmetros analisados. Os parâmetros meteorológicos também foram aplicados nos estudos para previsão de gases em aterros sanitários por Uyanik *et al.* (2012), Abushammala *et al.* (2014), Kumar *et al.* (2016) e Xin *et al.* (2016). Nos estudos de Aghdam *et al.* (2019), foi observado uma correlação fraca (0.193) entre a temperatura externa e as emissões de gases.

Vale destacar que em camadas de cobertura de aterros sanitários pode ocorrer a oxidação do metano e segundo Scheutz *et al.* (2009), as temperaturas elevadas aumentam a atividade microbiana em *liners*. Se por um lado é reduzido o fluxo de metano, por outro lado será aumentado o fluxo de CO<sub>2</sub> nessas camadas. Assim, deve-se analisar até que ponto pressão atmosférica, temperatura, umidade relativa do ar, precipitações de fato interferem no processo

oxidativo e, por consequência, o fluxo desses gases na camada de cobertura. Sob baixa pressão atmosférica, a advecção, em vez da difusão, pode ser o mecanismo dominante para o transporte de metano através da camada de cobertura final de solo compactado do aterro sanitário. (Bian *et al.*, 2018).

Na Tabela 6, é possível observar que o parâmetro que mais se relacionou com o fluxo de gases, especialmente, metano, foi o Grau de Saturação, contudo a correlação foi fraca e positiva.

Tabela 6 - Matriz de correlação das variáveis de entrada da rede neural artificial

	CH <sub>4</sub>	CO <sub>2</sub>	Temp.Ext.	Temp.Int	Pressão	Umid.do.Ar	V. vento	Radiação	G.compact.	G.Saturação	Massa especifica aparente do solo	Umidade do solo
<b>CH<sub>4</sub></b>	1.000											
<b>CO<sub>2</sub></b>	0.911	1.000										
<b>Temp.Ext.</b>	0.193	-0.014	1.000									
<b>Temp.Int</b>	0.190	0.051	0.893	1.000								
<b>Pressão</b>	-0.196	0.005	-0.954	-0.840	1.000							
<b>Umid.Ar</b>	0.267	0.209	0.313	0.312	-0.454	1.000						
<b>V. vento</b>	0.190	-0.032	0.924	0.822	-0.972	0.451	1.000					
<b>Radiação</b>	0.051	0.115	-0.275	-0.262	0.404	-0.645	-0.371	1.000				
<b>G.compact.</b>	-0.064	-0.160	0.362	0.374	-0.391	0.017	0.379	0.020	1.000			
<b>G.Saturação</b>	0.372	0.212	0.701	0.649	-0.815	0.467	0.770	-0.316	0.535	1.000		
<b>Massa especifica aparente do solo</b>	0.196	-0.004	0.953	0.839	-1.000	0.458	0.972	-0.406	0.396	0.818	1.000	
<b>Umidade do solo</b>	0.277	0.082	0.923	0.821	-0.989	0.494	0.956	-0.404	0.391	0.883	0.990	1.000

Fonte: Elaborado pelo autor, 2023.



#### 4.6 Medidas de Ajustamento do modelo

Na Tabela 7 é apresentado a análise de variância para as medidas de ajustamento para o modelo gerado. O coeficiente de determinação  $R^2$  foi de 0,722 para um nível de significância de 5%, indicando que 72% da variabilidade do processo pode ser explicada pelo modelo gerado.

O valor de F encontrado através da análise de variância para o modelo foi de 5,7 com uma significância menor que 1%. Os resultados indicam que o modelo é adequado para o estudo recomendado.

Para o ajustamento do modelo o valor do RMSE foi de 35,2, sendo considerado um valor alto. Segundo Chai & Draxler (2014) a sensibilidade do RMSE a outliers é bem preocupante e mais comum com o uso dessa métrica. A existência dos outliers e sua probabilidade de ocorrência é bem descrito pela distribuição normal subjacente ao uso do RMSE. A métrica é descritiva, quando a capacidade para previsão entre os modelos é comparada (Wu & Lo, 2008).

**Tabela 7** - Medidas de ajustamento do modelo da regressão

Teste ao Modelo Global				
$R^2$	RMSE	F calculado	Graus de liberdade	p
0.722	35.2	5.7	10	0.001

**Fonte:** Elaborado pelo autor, 2023.

Na Tabela 8 é apresentada a análise de variância (Anova) da modelagem constitutiva do fluxo de metano.

**Tabela 8** - Análise de variância da modelagem constitutiva do fluxo de metano.

Variáveis	Soma de Quadrados	Graus de liberdade	Quadrado médio	p
Temperatura externa (°C)	13751.9	1	13751.9	0.01
Temperatura interna (°C)	3695.8	1	3695.8	0.17
Pressão (Kpa)	294.5	1	294.5	0.69
Umidade relativa do ar (%)	48.4	1	48.4	0.87
Velocidade do vento (km/h)	2669	1	2669	0.24
Radiação (Kj/m <sup>2</sup> )	969	1	969	0.47
Grau de Compactação (%)	115.4	1	115.4	0.80
Grau de Saturação (%)	28077.3	1	28077.3	0.001
Massa específica aparente do solo (g/cm <sup>3</sup> )	118.3	1	118.3	0.80
Umidade do solo (%)	46690.3	1	46690.3	0.001
Resíduos	40937.9	22	1860.8	

**Fonte:** Elaborado pelo autor, 2023.

O fluxo de metano foi determinado a partir da Equação 16 que descreve o modelo avaliado no cenário investigado.

*Equação (16)*

$$JCH_4 = -2766,39 + 9,47X_1 - 1,87X_2 + 1,83X_3 - 0,14X_4 + 2,90X_5 - 0,01X_6 - 648,61X_7 - 17,10X_8 + 34930,76X_9 + 88,16X_{10}$$

Na Tabela 9 é possível analisar a significância dos coeficientes de regressão da Equação 17.

**Tabela 9** - Coeficiente de regressão para determinação do fluxo de metano

Variável	Constantes	Coeficientes	p
<b>Intercepto</b>	a	-2766.39	0.54
<b>Temperatura externa (°C)</b>	X <sub>1</sub>	9.47	0.01
<b>Temperatura interna (°C)</b>	X <sub>2</sub>	-1.87	0.17
<b>Pressão (Kpa)</b>	X <sub>3</sub>	1.83	0.69
<b>Umidade relativa do ar (%)</b>	X <sub>4</sub>	-0.14	0.87
<b>Velocidade do vento (km/h)</b>	X <sub>5</sub>	2.90	0.24
<b>Radiação (Kj/m<sup>2</sup>)</b>	X <sub>6</sub>	-0.01	0.47
<b>Grau de Compactação (%)</b>	X <sub>7</sub>	-648.61	0.80
<b>Grau de Saturação (%)</b>	X <sub>8</sub>	-17.10	< .001
<b>Massa especifica aparente do solo (g/cm<sup>3</sup>)</b>	X <sub>9</sub>	34930.76	0.80
<b>Umidade do solo (%)</b>	X <sub>10</sub>	88.16	< .001

**Fonte:** Elaborado pelo autor, 2023.

Apesar de algumas variáveis não apresentarem significância estatística, conforme apresentado na Tabela 7, elas foram incluídas no modelo para determinação, do fluxo de CH<sub>4</sub>.

Conforme Rodrigues & Iemma (2014) há, na literatura especializada, uma certa divergência de opiniões sobre o fato de retirar ou não do modelo os parâmetros (variáveis) inerentes a uma interação não significativa. No caso em estudos todas as variáveis e suas interações foram mantidas, exceto quando o coeficiente de regressão foi igual a 0.

Esta decisão foi tomada, pois ao retirar as variáveis não significativas estatisticamente ocorreu uma redução do R<sup>2</sup> e aumento dos resíduos dos modelos, indicando modelos menos representativos.

## 4.7 Redes Neurais Artificiais

### 4.7.1 Resultados e desempenho dos treinamentos de redes neurais artificiais

As Tabelas 10, 11, 12 e 13 apresentam as métricas de desempenho dos algoritmos Trainbr, Trainscg, Traincfg, Trainlm, quantidade de neurônios na camada oculta, a função de ativação na camada oculta e função de ativação na camada de saída, para serem analisados através das medidas de performance e identificar qual a melhor arquitetura da rede neural. Além dos algoritmos citados, também foi testado o algoritmo Traingd, porém o erro observado nestes modelos o fez ser desconsiderado nas análises.

#### 4.7.1.1 Algoritmo Trainbr (Bayesian Regularization Backpropagation)

Baseado nos resultados demonstrados é possível observar que no algoritmo *Trainbr* as medidas de performance **MAE= 0,001, RMSE= 0,001, R<sup>2</sup>= 1, E=1** apresentou a melhor performance para camada oculta com 20 neurônios, função camada oculta *tansig*, função camada de saída *purelin*, a melhor arquitetura para o treinamento.

**Tabela 10** - Métricas de desempenho do algoritmo *Trainbr*. Onde: FA (Função de ativação); MAE (Erro médio absoluto); RMSE (Raiz quadrada do erro médio); NRMSE (Raiz quadrada do erro médio normalizado); R<sup>2</sup> (Coeficiente de determinação); E (Coeficiente de eficiência); Logsig (Função logística); Tansig (Função tangencial); Purelin (Função linear); Elliotsig (Função logística adaptada por Elliot).

Características da RNA			Medidas de performance				
Neurônios na camada oculta	FA camada oculta	FA camada de saída	MAE	RMSE	NRMS	R <sup>2</sup>	E
1	Logsig	Purelin	0.022	0.026	4.7E-05	0.999	1.0000
2	Elliotsig	Purelin	0.008	0.009	1.7E-05	1.000	1.0000
3	Elliotsig	Purelin	0.001	0.001	2.6E-06	1.000	1.0000
4	Logsig	Tansig	0.369	0.500	9.1E-04	1.000	0.9995
5	Elliotsig	Elliotsig	0.008	0.039	7.1E-05	1.000	0.9999

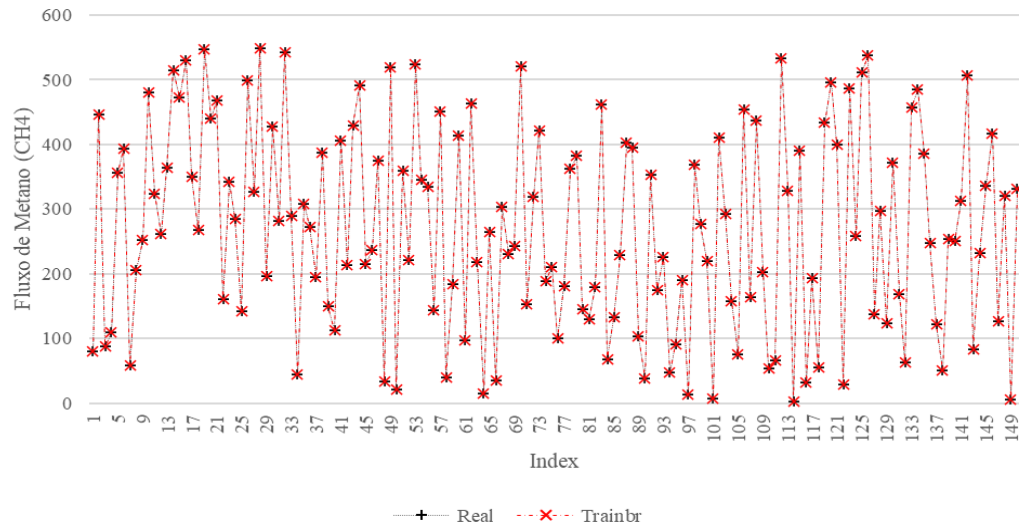
6	Logsig	Tansig	0.062	0.095	1.7E-04	1.000	0.9999
7	Tansig	Purelin	0.000	0.000	3.4E-07	1.000	1.0000
8	ElliotSig	Tansig	0.043	0.079	1.4E-04	0.999	0.9999
9	ElliotSig	ElliotSig	0.016	0.050	9.1E-05	1.000	1.0000
10	Logsig	Purelin	0.000	0.000	3.1E-07	1.000	1.0000
11	ElliotSig	Tansig	0.038	0.075	1.4E-04	1.000	0.9999
12	ElliotSig	Tansig	0.041	0.078	1.4E-04	1.000	0.9999
13	Logsig	Purelin	0.000	0.000	2.7E-07	1.000	1.0000
14	Logsig	Purelin	0.019	0.022	4.1E-05	1.000	1.0000
15	ElliotSig	Tansig	0.055	0.087	1.6E-04	0.999	0.9999
16	ElliotSig	Tansig	0.028	0.062	1.1E-04	1.000	1.0000
17	ElliotSig	Tansig	0.029	0.064	1.2E-04	1.000	0.9999
18	Logsig	Purelin	0.001	0.001	1.6E-07	1.000	1.0000
19	Logsig	Purelin	0.010	0.012	2.2E-05	1.000	1.0000
<b>20</b>	<b>Tansig</b>	<b>Purelin</b>	<b>0.001</b>	<b>0.001</b>	<b>9.3E-08</b>	<b>1.000</b>	<b>1.0000</b>

---

**Fonte:** Elaborado pelo autor, 2023.

A Figura 35, representa a forte concordância entre os valores observados e preditos do fluxo de metano mensurado na camada de cobertura final do aterro sanitário, para o algoritmo de treinamento *Trainbr*, os valores seguem uma tendência semelhante sem variação significativa.

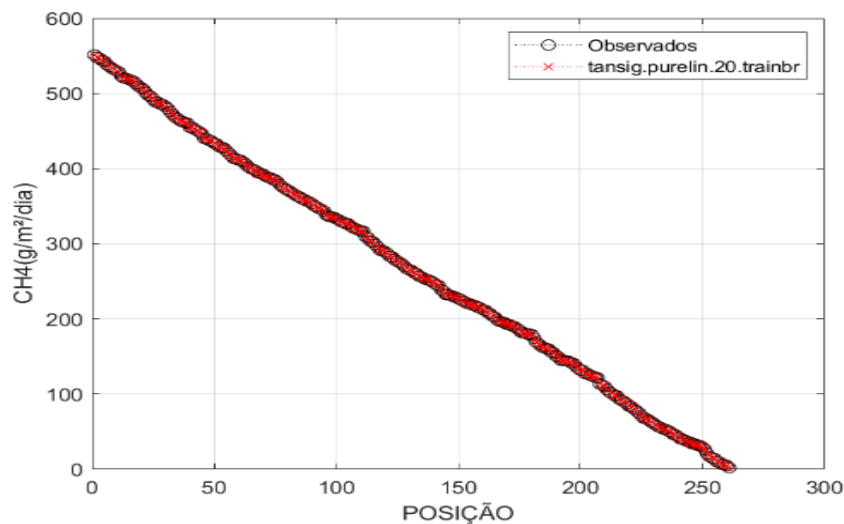
**Figura 35** - Comparação entre dados observados e preditos para o algoritmo Trainbr



**Fonte:** Elaborado pelo autor, 2023.

Observa-se na Figura 36 a comparação entre os dados preditos e as posições ocupadas na escala gerada para o fluxo de metano, em relação ao treinamento do algoritmo *Trainbr*.


**Figura 36** - Comparação entre a posição dos dados gerados e preditos para o fluxo de metano em relação ao algoritmo (*Trainbr*).



**Fonte:** Elaborado pelo autor, 2023.

Para analisar o comportamento da RNA, também foi plotado o gráfico do treinamento para o algoritmo *Trainbr*, demonstrando o comportamento dos valores, preditos e observados, indicando uma linearidade satisfatória, ou seja, as predições do fluxo de metano se aproximam dos valores reais (Figura 37).

**Figura 37** – Valores observados x preditos (*Trainbr*)




**Fonte:** Elaborado pelo autor, 2023

Observa-se que os pontos se distribuem formando-se uma reta do tipo  $Y = X$ , indicando proximidade entre as predições do modelo e os valores observados para a variável fluxo de metano. Esse padrão de distribuição é característico de um modelo com bom poder preditivo.

A Figura 38 representa o treinamento para o *Bayesian Regularization Backpropagation* foi interrompido após 1000 interações e com uma performance (erro quadrático médio) próximo de zero com um valor de  $6,7872e-09$ , sendo, possível observar a redução do erro e o melhor desempenho obtido nas RNA para predição do fluxo de metano.

O ajuste da rede durante a etapa de treinamento e teste mostrou-se com boa proximidade, uma vez que, quanto maior o número de épocas menor o erro quadrático médio (coeficiente relacionado com a performance do treinamento). Na Figura 38 é possível observar a redução do erro e o melhor desempenho obtido nas RNA para predição do fluxo de metano.

**Figura 38** - Performance da RNA com melhor desempenho para predição do fluxo de metano (Trainbr).



**Fonte:** Elaborado pelo autor, 2023.

O treinamento que apresentou melhor desempenho utilizando o algoritmo *trainbr*, mostrou que, quanto maior o número de iterações entre os neurônios em processamento menor o erro quadrático médio. Sendo para valores menores que 50 iterações  $MSE > 0$ , entre 50 e 900 iterações um valor quase constante na ordem de  $10^{-3}$  e entre 900 e 1000 iterações na ordem de  $10^{-9}$ .

#### 4.7.1.2 Algoritmo *Trainscg* (Scale Conjugate Gradient)

Para o algoritmo *Trainscg* os melhores valores obtidos para métricas de desempenho foram **MAE= 0,291, RMSE= 0,377, NRMS=0,001, R<sup>2</sup>=1, E=1** (Tabela 11). Isso significa que a melhor arquitetura para rede neural foi: 18 neurônios na camada oculta, função de ativação da camada oculta Tansig, função de ativação camada de saída Purelin.

Tabela 11 - Métricas de desempenho do algoritmo *Trainscg*. Onde: FA (Função de ativação); MAE (Erro médio absoluto); RMSE (Raiz quadrada do erro médio); NRMSE (Raiz quadrada do erro médio normalizado); R<sup>2</sup> (Coeficiente de determinação); E (Coeficiente de eficiência); Logsig (Função logística); Tansig (Função tangencial); Purelin (Função linear); Elliotsig (Função logística adaptada por Elliot).




Características da RNA			Medidas de desempenho				
Neurônios na camada oculta	FA camada oculta	FA camada de saída	MAE	RMSE	NRMS	R <sup>2</sup>	E
1	Logsig	Purelin	2.402	2.816	0.005	1.000	0.997
2	Logsig	Purelin	2.291	2.764	0.005	1.000	0.999
3	Logsig	Purelin	2.820	3.391	0.006	1.000	1.001
4	Tansig	Purelin	2.068	2.356	0.004	1.000	1.000
5	Tansig	Purelin	1.852	2.334	0.004	1.000	1.000
6	Logsig	Purelin	4.619	5.861	0.011	0.999	1.009
7	Logsig	Purelin	2.770	3.430	0.006	1.000	1.000
8	Logsig	Purelin	3.106	3.769	0.007	0.999	0.995
9	Tansig	Purelin	3.341	3.945	0.007	0.999	1.000
10	Tansig	Purelin	2.294	2.743	0.005	1.000	0.998
11	Logsig	Purelin	2.244	2.848	0.005	1.000	0.997
12	Tansig	Purelin	0.688	0.912	0.002	1.000	0.998
13	Tansig	Purelin	1.553	1.895	0.003	1.000	1.000
14	Tansig	Purelin	1.997	2.530	0.005	1.000	0.998
15	Tansig	Purelin	2.492	2.960	0.005	1.000	1.001
16	Tansig	Purelin	2.731	3.572	0.007	0.999	0.991
17	Logsig	Purelin	2.641	3.213	0.006	1.000	1.002

18	Tansig	Purelin	0.291	0.377	0.001	1.000	1.000
19	Tansig	Purelin	1.373	1.793	0.003	1.000	0.997
20	Tansig	Purelin	2.920	3.507	0.006	0.999	0.997

**Fonte:** Elaborado pelo autor, 2023.

Na Figura 39, observa-se que os valores gerados no treinamento do algoritmo *trainscg*, guardam certa similaridade com os resultados obtidos com o *trainbr*, indicando uma forte concordância entre os valores observados e previstos do fluxo de metano na camada de cobertura final do aterro sanitário localizado na região semiárida do nordeste brasileiro. Os resultados obtidos através das medidas de desempenho identificaram uma pequena variação no algoritmo *Trainscg*. Os valores preditos seguem uma tendência, sem alteração significativa.

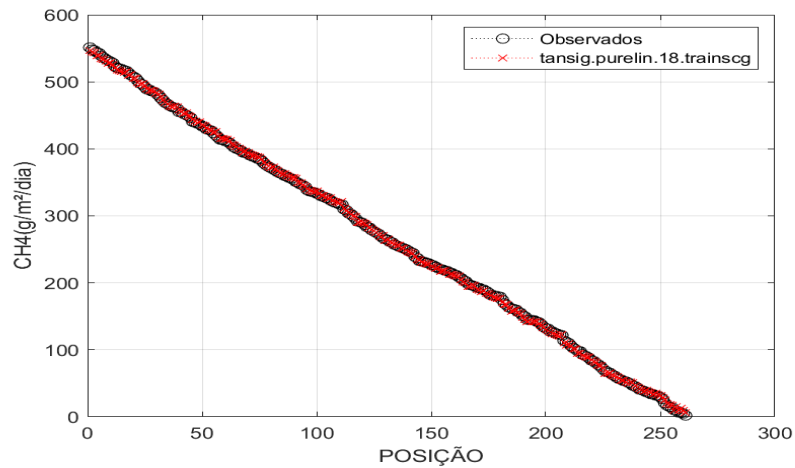
**Figura 39** - Comparação entre dados observados e preditos para o algoritmo *Trainscg*.



**Fonte:** Elaborado pelo autor, 2023.

A Figura 40 demonstra a comparação entre os dados observados e as posições ocupadas na escala gerada para o fluxo de metano, em relação ao treinamento do algoritmo *Trainscg*, com a função de ativação da camada oculta *Tansing* e a função de ativação da camada de saída *Purelin* e 18 neurônios na camada oculta.


**Figura 40** - Comparação entre a posição dos dados observado e preditos para o fluxo de metano em relação ao algoritmo (*Trainscg*)



**Fonte:** Elaborado pelo autor, 2023.

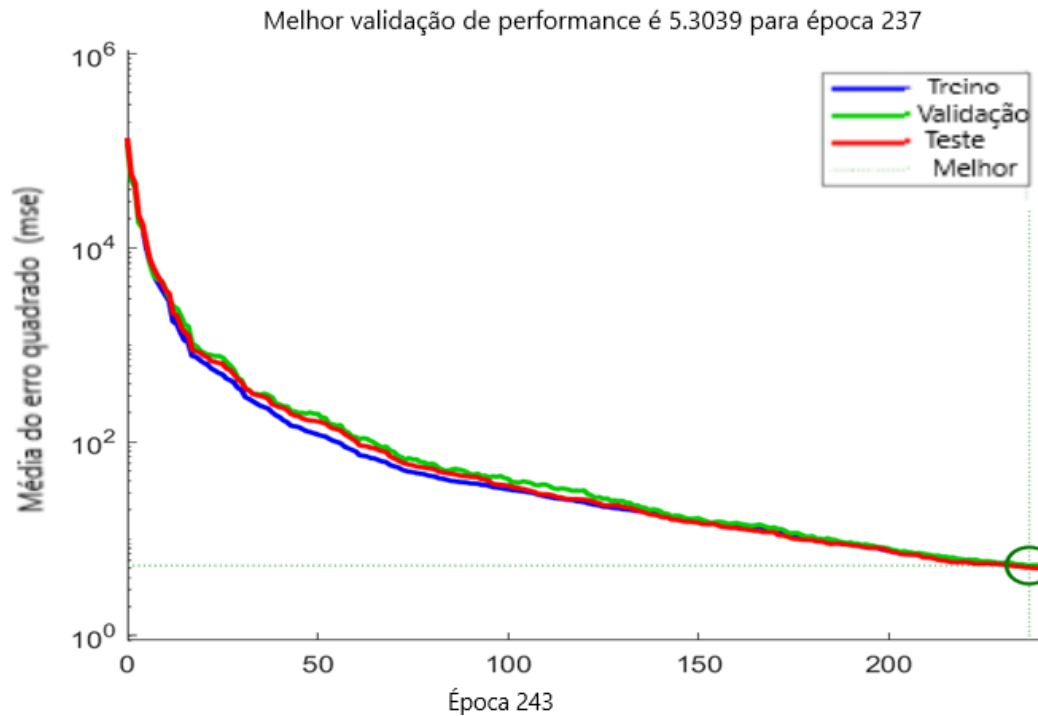
Figura 41, revela a eficiência da RNA treinada para o algoritmo *Trainscg*, onde os valores observados ficaram próximos dos valores preditos, demonstrando a eficiência da RNA.

**Figura 41** - Valores observados x preditos (*Trainscg*)



**Fonte:** Elaborado pelo autor, 2023.

A Figura 42 ilustra o desempenho da rede neural para o algoritmo *Trainscg*, identificando que a rede obteve o melhor ajuste ao executar 243 ciclos, porém na época 237 seu desempenho em validação do modelo, foi ultimada.

**Figura 42** - Performance da RNA para predição do fluxo de metano (*Trainscg*)

**Fonte:** Elaborado pelo autor, 2023.

#### 4.7.1.3 Algoritmo *Traincfg* (Fletcher-Powell Conjugate Gradient)

Verifica-se que o Algoritmo *Traincfg* obteve as melhores métricas de desempenho para o **MAE= 0,047**, **RMSE=0,058**, **NRMS=1.07E-04**, **R2=1**, **E=1**. Através da avaliação das medidas de desempenho, a melhor arquitetura foi a obtida com 18 neurônios na camada oculta, função de ativação camada oculta *Purelin*, função de ativação camada de saída *Purelin*.

**Tabela 12** - Métricas de desempenho do algoritmo *Traincfg*. Onde: FA (Função de ativação); MAE (Erro médio absoluto); RMSE (Raiz quadrada do erro médio); NRMSE (Raiz quadrada do erro médio normalizado); R<sup>2</sup> (Coeficiente de determinação); E (Coeficiente de eficiência); Logsig (Função logística); Tansig (Função tangencial); Purelin (Função linear); Elliotsig (Função logística adaptada por Elliot).

Características da RNA			Medidas de desempenho				
Neurônios na camada oculta	FA camada oculta	FA camada de saída	MAE	RMSE	NRMS	R <sup>2</sup>	E
1	Purelin	Purelin	0.142	0.171	3.13E-04	1.000	1.000
2	Logsig	Purelin	0.377	0.545	9.96E-04	1.000	0.999


3	Logsig	Purelin	0.652	0.793	1.45E-03	1.000	1.000
4	Purelin	Purelin	1.733	2.082	3.81E-03	1.000	0.997
5	Purelin	Purelin	0.142	0.170	3.10E-04	1.000	1.000
6	Purelin	Purelin	0.103	0.120	2.19E-04	1.000	1.000
7	Purelin	Purelin	0.047	0.058	1.05E-04	1.000	1.000
8	Tansig	Purelin	2.079	2.565	4.69E-03	1.000	0.998
9	Logsig	Purelin	1.962	2.426	4.43E-03	1.000	0.998
10	Tansig	Purelin	0.824	1.182	2.16E-03	1.000	1.000
11	Logsig	Purelin	1.439	1.679	3.07E-03	1.000	1.000
12	Tansig	Purelin	1.062	1.539	2.81E-03	1.000	1.000
13	Purelin	Purelin	0.048	0.059	1.08E-04	1.000	1.000
14	Tansig	Purelin	1.564	2.260	4.13E-03	1.000	0.998
15	Purelin	Purelin	0.535	0.648	1.18E-03	1.000	0.999
16	Purelin	Purelin	0.074	0.085	1.55E-04	1.000	1.000
17	Tansig	Purelin	1.866	2.407	4.40E-03	1.000	0.998

18	Purelin	Purelin	0.047	0.058	1.07E-04	1.000	1.000
19	Purelin	Purelin	0.221	0.267	4.87E-04	1.000	1.000
20	Tansig	Purelin	1.759	2.291	4.19E-03	1.000	1.000

**Fonte:** Elaborado pelo autor, 2023.

A Figura 43 apresenta os valores observados e os valores do treinamento predito pela rede neural para o fluxo de metano no Aterro Sanitário em estudo. Como não houve grandes variações entre as métricas de desempenho da primeira e da segunda arquitetura dos algoritmos, o gráfico se mantém semelhante aos apresentados nas figuras 41 e 42 com os dois primeiros, seguindo fielmente o valor real.


**Figura 43** - Comparação entre dados observados e preditos para o algoritmo (*Traincfg*)



**Fonte:** Elaborado pelo autor, 2023.

Figura 44, demonstra a comparação entre os dados observados e as posições ocupadas na escala gerada para o fluxo de metano, em relação ao treinamento do algoritmo, (*Traincfg*) com a função de ativação da camada oculta *Purelin* e a função de ativação da camada de saída *Purelin* e com 18 neurônios na camada oculta.


**Figura 44** - Comparação entre a posição dos dados observado e preditos para o fluxo de metano em relação ao algoritmo (*traincfg*)



**Fonte:** Elaborado pelo autor, 2023.


Figura 45, revela a eficiência da RNA treinada para o algoritmo *traincfg*, onde os valores observados ficaram próximos dos valores preditos, demonstrando a eficiência da RNA. Em relação ao valor da regressão não houve variação significativa em comparação com a arquitetura anterior. O Gráfico apresenta a arquitetura do treinamento do algoritmo *Traincfg* com 18 neurônios na camada oculta.

**Figura 45** - Valores observados x preditos (*Traincfg*)



**Fonte:** Elaborado pelo autor, 2023.

A Figura 46 ilustra o desempenho da rede neural para o algoritmo (*Traincfg*), identificando que a rede obteve o melhor ajuste ao executar 35 ciclos, porém o seu ajuste estava programado para 36 épocas. O desempenho em validação do modelo, foi ultimada com um MSE no valor de 0,001132.

**Figura 46** - Performance da RNA para predição do fluxo de metano (*Traincfg*)

**Fonte:** Elaborado pelo autor, 2023.

#### 4.7.1.4 Algoritmo *Trainlm* (*Levenberg–Marquardt*)

Quanto ao algoritmo *Trainlm* as melhores métricas de desempenho obtidas foram: **MAE= 0,001, RMSE= 0,001, NRMS= 4,95E-07, R<sup>2</sup>=1.00, E=1.00**. Diante das métricas observadas foi identificado que a melhor arquitetura da rede neural foi a de com 15 neurônios na camada oculta, função de ativação da camada oculta *Elliot*sig, função de ativação da camada de saída *Elliot*sig.

Tabela 13 - Métricas de desempenho do algoritmo *Trainlm*. Onde: FA (Função de ativação); MAE (Erro médio absoluto); RMSE (Raiz quadrada do erro médio); NRMSE (Raiz quadrada do erro médio normalizado); R<sup>2</sup> (Coeficiente de determinação); E (Coeficiente de eficiência); Logsig (Função logística); Tansig (Função tangencial); Purelin (Função linear); Elliotsig (Função logística adaptada por Elliot).

Características da RNA			Medidas de desempenho				
Neurônios na camada oculta	FA camada oculta	FA camada de saída	MAE	RMSE	NRMS	R <sup>2</sup>	E
1	Elliotsig	Purelin	0.046	0.052	9.42E-05	1.000	1.000
2	Tansig	Purelin	0.030	0.035	6.39E-05	1.000	1.000
3	Logsig	Purelin	0.001	0.001	2.47E-06	1.000	1.000
4	Elliotsig	Purelin	0.019	0.022	4.00E-05	1.000	1.000
5	Elliotsig	Tansig	0.043	0.075	1.38E-04	1.000	1.000




6	Tansig	Purelin	0.019	0.022	4.05E-05	1.000	1.000
7	Logsig	Purelin	0.001	0.001	8.26E-07	1.000	1.000
8	ElliotSig	Purelin	0.009	0.010	1.80E-05	1.000	1.000
9	Logsig	Tansig	0.405	0.533	9.74E-04	1.000	0.999
10	Logsig	Purelin	0.001	0.001	1.61E-06	1.000	1.000
11	ElliotSig	Purelin	0.017	0.020	3.65E-05	1.000	1.000
12	ElliotSig	Tansig	0.035	0.062	1.13E-04	1.000	1.000
13	ElliotSig	Tansig	0.044	0.086	1.57E-04	1.000	1.000
14	ElliotSig	ElliotSig	0.025	0.063	1.15E-04	1.000	1.000
<b>15</b>	<b>ElliotSig</b>	<b>ElliotSig</b>	<b>0.001</b>	<b>0.001</b>	<b>4.95E-07</b>	<b>1.000</b>	<b>1.000</b>
16	Logsig	Purelin	0.026	0.031	5.67E-05	1.000	1.000
17	ElliotSig	ElliotSig	0.000	0.000	3.73E-07	1.000	1.000
18	Tansig	Purelin	0.002	0.002	4.12E-06	1.000	1.000
19	ElliotSig	Purelin	0.024	0.027	4.87E-05	1.000	1.000
20	ElliotSig	ElliotSig	0.015	0.049	8.89E-05	1.000	1.000

---

**Fonte:** Elaborado pelo autor, 2023.

Figura 47 demonstra o treinamento realizado com o algoritmo *Trainlm (LM)* aplicado uma arquitetura com 15 neurônios na camada oculta, Função da camada oculta *ElliotSig* e Função da camada de saída *ElliotSig*, produziu resultados próximos, porém consideravelmente diferentes quando comparado com a aplicação na arquitetura do *Trainbr*.


**Figura 47** - Comparação entre dados observados e preditos para o algoritmo *Trainlm*



**Fonte:** Elaborado pelo autor, 2023.

Figura 48, demonstra a comparação entre os dados observados e as posições ocupadas na escala gerada para o fluxo de metano, em relação ao treinamento do algoritmo, *Trainlm* (*LM*).


**Figura 48** - Comparação entre a posição dos dados observados e preditos para o fluxo de metano em relação ao algoritmo *Trainlm* (*LM*).



**Fonte:** Elaborado pelo autor, 2023.

Os resultados dos modelos treinados usando o algoritmo de retropropagação *Levenberg-Marquardt LM* com valores observados e preditos são mostrados na Figura 49.


**Figura 49** - Gráfico com Valores observados x preditos (Trainlm)



**Fonte:** Elaborado pelo autor, 2023.

A Figura 50 mostra o comportamento da melhor performance do algoritmo *Trainlm* da RNA com 15 neurônios na camada oculta com valor do MSE de 0,00083317. A rede obteve o melhor ajuste ao executar 152 ciclos, dos 158 que estavam ajustados.

**Figura 50** - Performance da RNA para predição do fluxo de metano (Trainlm)



**Fonte:** Elaborado pelo autor, 2023.

#### 4.7.2 Discussão geral das métricas avaliadas

De forma geral, os treinamentos apresentaram desempenhos com homogeneidade, contudo são indicados no (Quadro 10) os melhores resultados obtidos nos desempenhos neurais.

**Quadro 10** - Resumo com os melhores resultados dos treinamentos das redes neurais artificiais

Algoritmo	Neurônios da camada oculta	Função de ativação da camada oculta	Função de ativação da camada de saída	MAE	RMSE	NRMS	R <sup>2</sup>	E
<i>Trainbr</i>	20	<i>Tansig</i>	<i>Purelin</i>	0.001	0.001	9.3E-08	1.000	1.000
<i>Trainscg</i>	18	<i>Tansig</i>	<i>Purelin</i>	0.291	0.377	0.001	1.000	1.000
<i>Traincfg</i>	18	<i>Purelin</i>	<i>Purelin</i>	0.047	0.058	1.07E-04	1.000	1.000
<i>Trainlm</i>	15	<i>ElliotSig</i>	<i>ElliotSig</i>	0.001	0.001	4.95E-07	1.000	1.000

**Fonte:** Elaborado pelo autor, 2023.

Foram observadas modificações para os parâmetros MAE, RMSE e NRMSE de acordo com o quantitativo de dados utilizados na saída da RNA. Os parâmetros observados mostraram-se satisfatórios, uma vez que, suas variações foram pequenas.

O algoritmo *Trainbr* apresentou melhor performance para predição do fluxo de metano através da camada de cobertura final do aterro sanitário em relação aos demais algoritmos.

Esse atualiza os valores de peso e viés de acordo com a otimização de *Levenberg-Marquardt*, processo identificado como regularização bayesiana. Nesse caso as paradas de validação são desativadas por padrão, para que o treinamento continue até que um ajuste ideal de erros e pesos sejam encontrados (Liang *et al.*, 2018).

Para RNA proposta, o melhor desempenho deu-se com 20 neurônios na camada oculta, similar ao observado por Oliveira *et al.* (2019) que utilizaram na sua pesquisa na camada oculta de 10 a 20 neurônios. Kannangara *et al.* (2018) desenvolveram no seu estudo o número de neurônios para camada oculta variando de 1 a 150.

A quantidade de neurônios na camada oculta da RNA varia de acordo com a qualidade/quantidade de dados disponíveis para treinamento. Até certo ponto, um aumento no número de neurônios, na camada oculta, é frequentemente correlacionado com um melhor desempenho de aprendizagem (Faris *et al.*, 2019). No entanto, o aumento da quantidade de neurônios pode levar ao *overfitting*, uma condição na qual o erro é mínimo nos dados de treinamento, mas pode ser significativo nos dados de teste; e isto acontece, porque as funções ajustadas tornam-se mais complexas à medida que o número de neurônios aumenta (Alreashed *et al.*, 2018).

Em relação ao estudo na camada de cobertura do aterro sanitário em estudo, os resultados obtidos demonstram que a função de ativação para as camadas de saída, *Purelin*, e na camada oculta a *Transing* foram as que apresentaram um melhor desempenho para predição do fluxo de CH<sub>4</sub>.

Para as variáveis apresentadas na entrada da RNA, foram observados bons resultados para os treinamentos, demonstrados por meio das métricas de desempenho. Diante disso são apresentados alguns estudos, onde foram utilizados modelos com RNA.

Scozzari (2008) aplicou um modelo de rede neural com parâmetros de entrada e dados meteorológicos para identificar o fluxo de biogás gerado a partir do aterro sanitário de resíduos sólidos urbanos.

No sul da Califórnia, EUA, Li *et al.* (2011) apresentaram um algoritmo *backpropagation MLP* para prever metano, dióxido de carbono, concentração de oxigênio e temperatura em um aterro sanitário.

Arabameri *et al.* (2017) realizou um trabalho comparando 10 algoritmos de treinamento em redes neurais para realizar a previsão para eficiência de remoção de DQO do lixiviado em aterro sanitário e identificou que o algoritmo *trainlm* foi melhor, devido à sua capacidade de melhor ajuste. Porém, no presente estudo o algoritmo *trainbr* apresentou a melhor performance para predição do fluxo de metano.

Abushammala *et al.* (2014) desenvolveram uma pesquisa utilizando a modelagem da oxidação do metano em solo de cobertura de aterro sanitário usando rede neural artificial. No estudo foi utilizado o algoritmo de retropropagação *feedforward* para predição da oxidação de CH<sub>4</sub> na camada de cobertura final do aterro sanitário em relação à temperatura do ar, teor de umidade do solo, concentração de oxigênio.

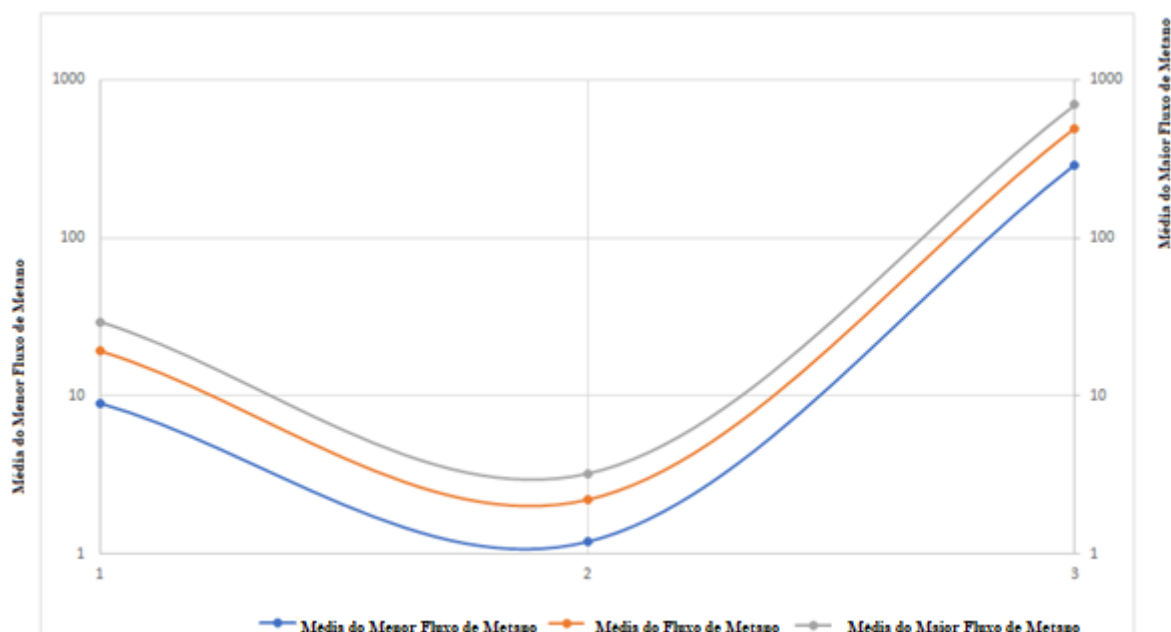
Por ser um ambiente heterogêneo envolvendo variáveis meteorológicas e geotécnicas os aterros sanitários precisam de um monitoramento complexo, em relação as emissões dos gases efeito estufa por meio da camada de cobertura final.

Através da rede neural artificial foi possível realizar a predição das emissões do fluxo de metano na camada de cobertura final no aterro sanitário em estudo e observou-se a importância das variáveis geotécnicas da camada de cobertura e meteorológicas apresentadas.

#### **4.8 Escala de eficiência**

Em relação a escala apresentada através do gráfico na figura 51 a média do maior valor do fluxo de metano foi de 695.90 g.m<sup>-2</sup>.dia<sup>-1</sup>. Os resultados obtidos demonstram que grande parte dos aterros sanitários no Brasil, Europa, Ásia e Estados Unidos não obedecem a norma estabelecida pela *Carbon Farming Initiative* (CFI, 2013), com um valor máximo de 64,96 g.m<sup>-2</sup>.dia<sup>-1</sup> para o fluxo de metano emitido através da camada de cobertura final.

**Figura 51** - Média do valor máximo e média do valor mínimo do fluxo de metano com nível de significância de 5%



**Fonte:** Elaborado pelo autor, 2023.

Na literatura brasileira e internacional são citados alguns aterros sanitários com valores máximos e mínimos do fluxo de metano em camada de cobertura de aterros sanitários. Valores de 4,9 a 165,2 g.m<sup>-2</sup>.dia<sup>-1</sup> foram observados para Aterro Sanitário de Tamangapa (Indonésia) (Lando *et al.*, 2017); e 0 a 355,55 g.m<sup>-2</sup>.dia<sup>-1</sup> para o Aterro Sanitário de Salvador - BA, no Brasil (Damasceno, 2019).

O Quadro 11 apresenta os indicadores da estatística descritiva, sendo os resultados obtidos através do estudo realizado sobre os maiores e menores fluxos de metano em diversos aterros sanitários no Brasil, Estados Unidos, Ásia e Europa. A média para o menor fluxo de metano foi de 19,25 g.m<sup>-2</sup>.dia<sup>-1</sup> e para o maior fluxo foi de 492,73 g.m<sup>-2</sup>.dia<sup>-1</sup>.

**Quadro 11** - Indicadores da estatística descritiva com maiores e menores fluxos de metano, Brasil, Ásia, Estados Unidos e Europa

<b>Média do menor fluxo de metano</b>	19.25(g.m <sup>-2</sup> .dia <sup>-1</sup> )	<b>Média do maior fluxo de metano</b>	492.73(g.m <sup>-2</sup> .dia <sup>-1</sup> )
<b>Erro padrão</b>	10.23	<b>Erro padrão</b>	203.16
<b>Mediana</b>	2.79	<b>Mediana</b>	274.8
<b>Moda</b>	0.1	<b>Moda</b>	#N/D
<b>Desvio padrão</b>	43.41	<b>Desvio padrão</b>	861.97
<b>Variância da amostra</b>	1885.15	<b>Variância da amostra</b>	743001.9
<b>Curtose</b>	10.88	<b>Curtose</b>	14.72
<b>Assimetria</b>	3.20	<b>Assimetria</b>	3.73
<b>Intervalo</b>	175.89	<b>Intervalo</b>	3787.2

<b>Mínimo</b>	0.001	<b>Mínimo</b>	18.3
<b>Máximo</b>	175.9	<b>Máximo</b>	3805.5
<b>Soma</b>	346.58	<b>Soma</b>	8869.2
<b>Contagem</b>	18	<b>Contagem</b>	18
<b>Maior (1)</b>	175.9	<b>Maior (1)</b>	3805.5
<b>Menor (1)</b>	0.001	<b>Menor (1)</b>	18.3
<b>Nível de confiança (95,0%)</b>	21.59	<b>Nível de confiança (95,0%)</b>	428.65

**Fonte:** Elaborado pelo autor, 2023.

Os resultados obtidos neste estudo demonstram que apenas a norma estabelecendo a permeabilidade do solo à água não é suficiente para estabelecer parâmetros em relação ao fluxo máximo de metano através da camada de cobertura final em aterros sanitários.

A média do fluxo de metano variou de 19, 25  $\text{g.m}^{-2}.\text{dia}^{-1}$  para 492,73.  $\text{g.m}^{-2}.\text{dia}^{-1}$  nos aterros sanitários localizados no Brasil, Estados Unidos, Ásia e Europa (Tabela 14).

**Tabela 14** - Média do valor máximo e média do valor mínimo do fluxo de metano

Média do menor fluxo de metano ( $\text{g.m}^{-2}.\text{dia}^{-1}$ )	Valores das médias do fluxo de metano	Média do maior fluxo de metano ( $\text{g.m}^{-2}.\text{dia}^{-1}$ )
9.02	Média do menor fluxo de metano	289.56
19.25	Média do fluxo de metano	492.73
29.48	Média do maior fluxo de metano	695.90

**Fonte:** Elaborada pelo autor, 2023.

Vale ressaltar que a RNA apresentada realizou uma predição do fluxo de  $\text{CH}_4$  para o aterro sanitário em estudo com uma média para o valor máximo de 270.2  $\text{g.m}^{-2}.\text{dia}^{-1}$  valor observado na escala de eficiência apresentada na Figura 51, demonstrando a média do valor máximo e a média do valor mínimo com nível de significância de 5%.



## 5 CONCLUSÕES

- A camada de cobertura final do aterro sanitários na região semiárida do nordeste brasileiro que foi objeto deste estudo apresentou eficiência para retenção do CH<sub>4</sub>;
- Nos períodos, seco e chuvoso, houve um comportamento distinto da camada de cobertura final para retenção do CH<sub>4</sub>, porém mesmo com as variações do fluxo a camada foi eficiente na retenção do gás independente do período analisado.
- Por meio da coleta de campo e aplicação das RNA foi quantificado e predito os valores dos fluxos de CH<sub>4</sub> da camada de cobertura final em um aterro sanitário da região semiárida do nordeste brasileiro;
- Durante o estudo o parâmetro que mais se correlacionou com fluxo de CH<sub>4</sub> na camada de cobertura final foi o grau de saturação do solo da camada de cobertura;
- Este estudo identificou que o *Trainbr* apresentou o melhor desempenho para predição da emissão de CH<sub>4</sub> através da camada de cobertura final de um aterro sanitário localizado na região semiárida do nordeste brasileiro;
- A escala de eficiência demonstrou que os valores obtidos para o fluxo de CH<sub>4</sub> na camada de cobertura final, para grande parte dos aterros sanitários localizados no Brasil e em alguns países situados em regiões da Europa, Ásia e Estados Unidos ficaram fora, das normas estabelecidas pela *Carbon Farming Initiative* (CFI, 2013).
- Os resultados obtidos nesta pesquisa sugerem para futuras pesquisas que novos parâmetros geotécnicos e meteorológicos sejam utilizados na entrada da rede neural realizando um comparativo para observar o comportamento da camada de cobertura final em relação as emissões de gás metano, para que possam ser normatização das camadas de cobertura.

## REFERÊNCIAS

- ABICHOU, T.; CHANTON, J.; POWELSON, D.; FLEIGER, J.; ESCORIAZA, S.; LEI, Y.; STERN, J. Methane flux and oxidation at two types of intermediate landfill covers. **Waste Management**, v. 26, n. 11, p. 1305-1312, 2006.
- ABICHOU, T.; KORMI, T.; YUAN, L.; JOHNSON, T.; FRANCISCO, E. Modeling the effects of vegetation on methane oxidation and emissions through soil landfill final covers across different climates. **Waste Management**, v. 36, p.230–240, 2015.
- ABBASZADEH SHAHRI, A. Assessment and Prediction of Liquefaction Potential Using Different Artificial Neural Network Models: A Case Study. **Geotech Geol Eng**, v. 34, p. 807–815, 2016.
- ABNT. Associação Brasileira de Normas Técnicas. **Norma NBR 6457: Amostras de solo - Preparação para ensaios de compactação e ensaios de caracterização**. Rio de Janeiro, 1986, 9 p.
- \_\_\_\_\_. **Norma NBR 6458: Grãos de pedregulho retidos na peneira de 4,8 mm. Determinação da massa específica, da massa específica aparente e da absorção de água**. Rio de Janeiro, 2016.
- \_\_\_\_\_. **Norma NBR 6459: Determinação do limite de liquidez**. Rio de Janeiro, 2016.
- \_\_\_\_\_. **Norma NBR 7180: Solo – Determinação do Limite de Plasticidade**. Rio de Janeiro, 2016.
- \_\_\_\_\_. **Norma NBR 7181: Solo – Análise Granulométrica**. Rio de Janeiro, 2016.
- \_\_\_\_\_. **Norma NBR 7182: Solo – Ensaio de Compactação**. Rio de Janeiro, 2016.
- \_\_\_\_\_. **Norma NBR 8419: Apresentação de projetos de aterros sanitários de resíduos sólidos urbanos**. Rio de Janeiro, 1992, 7p.
- \_\_\_\_\_. **Norma NBR 14545: Solo - Determinação do coeficiente de permeabilidade de solos argilosos a carga variável**. Rio de Janeiro. Pini, 2000.
- \_\_\_\_\_. **Norma NBR 13896: Aterros de resíduos não perigosos - Critérios para projeto, implantação e operação**. Rio de Janeiro. 1997
- ABUSHAMMALA, M. F.; BASRI, N.; ELFITHRI, R.; YOUNES, M. K.; IRWAN, D. Modeling of methane oxidation in landfill cover soil using an artificial neural network. **Journal Air Waste Manage Assoc**, v.64, n, p.150 159, 2014.
- AGHDAM, E. F.; SCHEUTZ, C.; KJELDSEN, P. Impact of meteorological parameters on extracted landfill gas composition and flow. **Waste Management**, v. 87, p. 905- 914, 2019.
- ALAM, S. K.; MONDAL, A.; SHIULY, A. Prediction of CBR Value of Fine Grained Soils of Bengal Basin by Genetic Expression Programming, Artificial Neural Network and Krigging Method. **Journal Geological Society India**, v, 95, p. 190–196, 2020.
- ALMEIDA, A. J. G. A. **Avaliação do desempenho das camadas de cobertura de aterro sanitário para a redução de emissões de gases do efeito estufa**. 2017. 93p. Dissertação (Mestrado em Engenharia Civil e Ambiental). Universidade Federal de Pernambuco,Caruaru – PE, 2017.

- ALSHARARI, B.; OLENKO, A.; ABUEL-NAGA, H. Modeling of electrical resistivity of soil based on geotechnical properties. **Expert Systems with Applications**, v. 141, p. 112966, 2020.
- ARABAMERI, A.; POURGHASEMI, H. R.; YAMANI, M. Applying different scenarios for landslide spatial modeling using computational intelligence methods. *Environmental earth sciences*, v. 76, p. 1-20, 2017.
- ARAGAW, T.T., CHAKMA, S. Artificial Neural Network Model for Prediction of Methane Fraction in Landfill Gas from Pretreated Waste in Bioreactor Landfills. *In: KALAMDHAD, A.S. (eds) Integrated Approaches Towards Solid Waste Management*. Springer, Cham.
- ARAÚJO NETO, C. L. de. **Análise do comportamento dos resíduos sólidos urbanos e desenvolvimento de modelos estatísticos para previsão das deformações de aterros sanitários**. 2016. 162 p. Dissertação (Mestrado em Engenharia Civil e Ambiental) Universidade Federal de Campina Grande, Campina Grande - PB, 2016.
- ARAÚJO, C. B. C **Aplicação das redes neurais artificiais do tipo perceptron na estimativa de recalques em estacas**. 2015. 228 p. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Fortaleza - CE, 2015.
- ARAUJO, P. S. **Análise do desempenho de um solo compactado utilizado na camada de cobertura de um aterro sanitário**. 2017. 138p. Dissertação (Mestrado em Engenharia Civil e Ambiental). Universidade Federal de Campina Grande, Campina Grande-PB, 2017.
- AUBERTIN, M.; AACHIB, M; AUTHIER, K. Evaluation of diffusive gas flux through covers with a GCL. **Geotextiles and Geomembranes**, v. 18, p. 215-233, 2000.
- BABILOTTE, A.; LAGIER, T.; FIANI, E.; TARAMINI, V. Fugitive methane emissions from landfills: field comparison of five methods on a french landfill. **Journal of Environmental Engineering**, v. 136, n. 8, p. 777-784, 2010.
- BAZIAR, M. H.; SAEEDI AZIZKANDI, A. Evaluation of lateral spreading utilizing artificial neural network and genetic programming. **International Journal of Civil Engineering**, v. 11, n. 2, p. 100-111, 2013.
- BENBOURAS, M. A.; MITICHE KETTAB, R.; ZEDIRA, H.; DEBICHE, F.; ZAIDI, N. Comparing nonlinear regression analysis and artificial neural networks to predict geotechnical parameters from standard penetration test. **Urbanism, Architecture and Construction Journal**, v. 9, n. 3, p. 257-288, 2018.
- BERGER, J.; FORNÉS, L. V.; OTT, C.; JAGER, J.; WAWRA, B.; ZANKE, U. Methane oxidation in a landfill cover with capillary barrier. **Waste Management**, v.25, n.4., p.369-373, 2005.
- BIAN, R.; XIN, D.; CHAI, X. A Simulation model for estimating methane oxidation and emission from landfill cover soils. **Waste Management.**, v.77, p. 426-434, 2018.
- BOCKREIS, A.; STEINBERG, I. Emissionen mechanisch-biologisch behandelter Abfälle bei der Deponierung – eine Bilanz aus Langzeitversuchen. *In: KÜHLE-WEIDEMEIER, M.; ABFALLFORSCHUNGSTAGE. Auf dem Weg in eine nachhaltige Abfallwirtschaft, Tagungsband*. Göttingen: Cuvillier Verlag, 2004
- BOGUNOVIC, I.; BILANDZIJA, D.; ANDABAKA, Z.; STUPIC, D.; COMINO, J. R.; CACIC, M.; PEREIRA, P. Soil compaction under different management practices. Croatian Vineyard. **Arabian Journal of Geosciences**, v. 10, n. 15, p. 1-9, 2017.

BORBA, P. F. S.; MARTINS, E. M.; CORREAS, M.; RITTER, E. Emissão de gases do efeito estufa de um aterro sanitário no Rio de Janeiro. **Eng. Sanit. Ambient.**, v.23, n.1, p.101-111, 2018.

BORGES, A. R. **Modelagem em experimentos fatoriais replicados para melhoria de processos industriais têxteis**. 2014. 85f. Tese (Doutorado em Engenharia de Produção) Universidade Católica do Rio de Janeiro, Rio de Janeiro – RJ, 2014.

BOSCOV, M. E. G. **Geotecnia ambiental**. São Paulo: Oficina de texto, 2012.

BRITO FILHO, L. F. **Estudo de gases em aterros - casos: Nova Iguaçu e Terra Brava**. 2005. 218p. Dissertação (Mestrado em Ciências em Engenharia Civil). Universidade Federal do Rio de Janeiro, Rio de Janeiro - RJ, 2005.

CAPACCIONI, B.; CARAMIELLO, C.; TATÀNO, F.; VISCIONE, A. Effects of a temporary HDPE cover on landfill gas emissions: Multiyear evaluation with the static chamber approach at an Italian landfill. **Waste Management**, v. 31, n. 5, p. 956-965, 2011.

CANDIANI, G.; MOREIRA, J. M. L. Avaliação dos parâmetros cinéticos da geração de metano em uma célula experimental de resíduos sólidos. **Engenharia Sanitária e Ambiental**, v. 23, p. 459-470, 2018.

CANDIANI, G.; VIANA, E. Emissões fugitivas de metano em aterros sanitários. **Geosp: Espaço e Tempo**, v.21, n.3, p.845-857, 2017.

CFI - DEPARTMENT OF INDUSTRY, INNOVATION, CLIMATE CHANGE, SCIENCE, RESEARCH AND TERTIARY EDUCATION. 2013. **Carbon Farming Initiative: Guidelines for Calculating Regulatory Baselines for Legacy Waste Landfill Methane Projects**, DIICCSRTE: Canberra, 2013.

CATAPRETA, C. A. A. **Comportamento de um aterro sanitario experimental: avaliação da influência do projeto, construção e operação**. 2007. 316 f. Tese (Doutorado em Saneamento, Meio Ambiente e Recursos Hídricos) – Universidade Federal de Minas Gerais. Belo Horizonte, 2007.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, v. 7, n.3, p. 1247-1250, 2014.

CHANTON, J.; ABICHOU, T.; LANDFORD, C.; HATER, G.; GREEN, R.; GOLDSMITH, D.; SWAN, N. Landfill methane oxidation across climate types in the US. **Environmental Science & Technology**, v. 45, p. 313–319, 2011.

CHEREMISINOFF, N. P. **Handbook of solid waste management and waste minimization technologies**. Burlington: Elsevier, 2003.

CHIROMA, H.; ABDULKAREEM, S.; HERAWAN, T. Evolutionary Neural Network model for West Texas Intermediate crude oil price prediction. **Applied Energy**, v. 142, p. 266–273, 2015

CHOOBBASTI, A. J.; FARROKHZAD, F.; BARARI, A. Prediction of slope stability using artificial neural network (case study: Noabad, Mazandaran, Iran). **Arab J Geosci**, v. 2, p. 311–319, 2009.

CHO, S. E. Probabilistic stability analyses of slopes using the ANN-based response surface. **Computers and Geotechnics**, v. 36, p. 787-797, 2009.

CINTRA, R. **Introdução a neurocomputação**. São Paulo: INPE, 2018.

CORREA, S. M. B. B. **Probabilidade e estatística**. 2ª ed. Belo Horizonte :PUC- Minas Virtual, 2003.

COSTA, M. D. **Estudos de camadas de cobertura de aterros sanitários em colunas de solos**. 144f. 2015. Tese de Doutorado. Tese (Doutorado)-Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Pernambuco, Recife.

COSTA, M.;D.; MARIANO, M.O. H.; ARAUJO,L.B.; JUCÁ,J. F. T. Estudos laboratoriais para avaliação do desempenho de camadas de cobertura de aterros sanitários em relação à redução de emissões de gases e infiltrações. **Engenharia Sanitária e Ambiental**, v. 23, p. 77-90, 2018.

CUI, K.; JING, X. Research on prediction model of geotechnical parameters based on BP neural network. **Neural Comput & Applic**, v. 31, p. 8205–8215, 2019.

CZEPIEL, P. M.; MOSHER, B.; CRILL, P. M.; HARRISS, R. C. Quantifying the effect of oxidation on landfill methane emissions. **Journal of geophysical research: Atmospheres**, v. 101, p. 16721-16729, 1996.

DAMASCENO, L. A. G. **Emissão fugitiva de metano através do sistema de cobertura de um aterro sanitário considerando a ocorrência de zonas com fissuramento**. 2018. 188p. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal da Bahia. Salvador - BA. 2019.

DANTAS NETO, S. A.; INDRARATNA, B.; OLIVEIRA, D. A. F.; ASSIS, A. P. Modelling the Shear Behaviour of Clean Rock Discontinuities Using Artificial Neural Networks. **Rock Mech Rock Eng**, v. 50, p. 1817-1831, 2017.

DELKASH, M.; ZHOU, B.; HAN, B.; CHOW, F. K.; RELLA, C. W.; IMHOFF, P. T. Shortterm landfill methane emissions dependency on wind. **Waste Management**, v. 55, n. 9, p. 288-298, 2016.

DUAN Z, SHEUTZ C, KJELDSSEN P. Trace gas emissions from municipal solid waste landfills: **A review**. **Waste Manag.**, v. 1; n:119, p.39-62, 2021.

ELSHEIKH, A. H.; SHARSHIR, S. W.; ELAZIZ, M. A.; KABEEL, A. E.; GUILAN, W.; HAIYOU, Z. Modeling of solar energy systems using artificial neural network: A comprehensive review. **Solar Energy**, v. 180, p. 622-639, 2019

FARROKHZAD, F.; CHOBBASTI, A. J.; BARARI, A. Artificial neural network model for prediction of liquefaction potential in soil deposits. *In: International Conferences on Recent Advances in Geotechnical Earthquake Engineering and Soil Dynamic*, v.4, 2010.

FALLAH, B.; NG, K. T. W.; VU, H. L.; TORAB, F. Application of a multistage neural network approach for time-series landfill gas modeling with missing data imputation. **Waste Manag**, v. 116, p 66–78, 2020.

FARIA, R. A. P. **Avaliação do potencial de geração de biogás e de produção de energia a partir da remoção da carga orgânica de uma estação de tratamento de esgoto-estudo de caso**. 2012. 76p. Dissertação (Mestrado em energia na agricultura) - Universidade Estadual do Oeste do Paraná Cascavel - PR. 2012.

- FARIAS, R. M. S. **Estudo dos recalques em aterros de resíduos sólidos urbanos: uma abordagem estatística e experimental**. 2014. 129 f. Dissertação (Mestrado em Engenharia Civil e Ambiental) - Universidade Federal de Campina Grande - Campina Grande - PB, 2014
- FARIS, H.; AL-ZOUBI, A. M.; HEIDARI, A. A.; ALJARAH, I. An intelligent system for spam detection and identification of the most relevant features based on evolutionary random weight networks. **Information Fusion**, v. 48, p. 67-83, 2019.
- FÁVERO, L. P.; BELFIORE, P.; DA SILVA, F. L.; CHAN, B. L. **A Análise de Dados: modelagem multivariada para tomada de decisões**. Rio de Janeiro: Elsevier, 2009.
- FERENTINOU, M. D.; SAKELLARIOU, M. G. Computational intelligence tools for the prediction of slope performance. **Computers and Geotechnics**, v. 34, n. 5, p. 362-384, 2007.
- FLECK, Leandro *et al.* Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016.
- FREEMAN, J.; SKAPURA, D. **Neural networks – Algorithms, Applications, and Programming Techniques**, Addison-Wesley, Boston, EUA, 1991.
- FURTADO, M. I. V. **Redes neurais artificiais: uma abordagem para sala de aula**. Ponta Grossa, PR: Atena Editora, 2019
- GALLEGO, E.; PERALES, J. F.; ROCA, F. J.; GUARDINO, X. Surface emission determination of volatile organic compounds (VOC) from a closed industrial waste landfill using a self-designed static flux chamber. **Science of the Total Environment**, v. 470-471, p. 587-599, 2014.
- GARBO, F.; COSSU, R. **Landfill cover systems: an overview**. In: INTERNATIONAL WASTE MANAGEMENT AND LANDFILL SYMPOSIUM, 16., 2017. Proceedings [...]. S. Margherita di Pula, Cagliari, Itália, 2017.
- GAO, W.; RAFTARI, M.; RASHID, A. S. A.; MU'AZU, M. A.; JUSOH, W. A. W. A predictive model based on an optimized ANN combined with ICA for predicting the stability of slopes. **Engineering with Computers**, v. 36, p. 325-344, 2020.
- GARBO, F.; COSSU, R. Landfill cover systems - An overview. Proceedings Sardinia *In: SIXTEENTH INTERNATIONAL WASTE MANAGEMENT AND LANDFILL SYMPOSIUM*, 2017, Cagloari: Italy. **Anais eletrônicos do Sixteenth international waste management and landfill symposium**, Italy: Cagliari, 2017.
- GEBERT, J.; GROENGROEFT, A; PFEIFFER E. M. Relevance of soil physical properties for the microbial oxidation of methane in landfill covers. **Soil Biology & Biochemistry**. v. 43, n. 9, p. 1759-1767, 2011.
- GGA/UFCG – GRUPO DE GEOTECNIA AMBIENTAL/UNIVERSIDADE FEDERAL DE CAMPINA GRANDE. **Acervo fotográfico**. Campina Grande: GGA/UFCG, 2021.
- GHAEDI, A. M.; VAFAEI, A. Applications of artificial neural networks for adsorption removal of dyes from aqueous solution: a review. **Advances in colloid and interface science**, v. 245, p. 20-39, 2017
- GOH, A. T. C.; KULHAWY, F. H. Neural network approach to model the limit state surface for reliability analysis. **Canadian Geotechnical Journal**, v. 40, n. 6, p. 1235-1244, 2003

- GOLDENBERG, M.; REDDY, K. R. Sustainability assessment of conventional and alternate landfill cover systems. *In*: BRANDON, T. L.; VALENTINE, R. J. (eds) **Geotechnical Frontiers 2017**. ASCE Library: Orlando - Florida, 2017, p. 323-332.
- GOLDSMITH JUNIOR, C. D.; CHANTON, J.; ABICHOU, T.; SWAN, N.; GREEN, R.; HATER, G. Methane emissions from 20 landfills across the United States using vertical radial plume mapping. **Journal of the Air & Waste Management Association**, v. 62, n. 2, p. 183-197, 2012
- GONZALEZ-VALENCIA, R.; RODRIGUEZ-MAGANA, F.; CRISTÓBAL, J.; THALASSO, F. Hotspot detection and spatial distribution of methane emissions from landfills by a surface probe method. **Waste management**, v. 55, p. 299-305, 2016.
- GUEDES, M. J. F. G.; MOREIRA, F. G. S.; SANTOS, J. J. N.; ARAUJO, P. S.; LYRA, M. V. M.; MELO, M. C.; MONTEIRO, V. E. D. Gas retention efficiency of a compacted soil landfill final cover in a semi-arid climate. **Environmental Engineering and Management Journal**, v. 20, n. 11, p. 1843-1851, 2021.
- GUEDES, M. J. F.; SANTOS MOREIRA, F. G.; DE PAIVA, W.; CURI, R. C. Avaliação de emissões de biogás e geração de energia em aterro sanitário no semiárido brasileiro. **Revista Ibero-Americana de Ciências Ambientais**, v. 9, n. 3, p. 188-203, 2018.
- HAIR, J. F.; BALCK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise multivariada de dados**. 5 ed. Porto Alegre: Bookman, 2005
- HANNA, A. M.; URAL, D.; SAYGILI, G. Neural network model for liquefaction potential in soil deposits using Turkey and Taiwan earthquake data. **Soil Dynamics and Earthquake Engineering**, v. 27, p. 521-540, 2007.
- HANSON, P. H.; SILVA, D. M.; LANZANOVA, L. S.; GUERRA, D.; LANZANOVA, M. E.; SOUZA, E. L.; BOHRER, R. E. G. Nabo forrageiro: potencialidades da espécie como descompactador do solo, reciclador de nutrientes e produtor de biomassa. **Research, Society and Development**, v. 12, n. 2, 2023.
- HAYKIN, S. **Redes Neurais: Princípios e prática**. Porto Alegre (RS): Editora Brookman, 2001. 900p.
- HE, Y.; CUI, Y. J.; YE, W. M.; CONIL, N. Effects of wetting-drying cycles on the airpermeability of compacted Teguline clay. **Engineering Geology**, v. 228, p. 173-179, 2017.
- HEBB, D. O. **The Organization of Behavior**. New York: Wiley, 1949.
- HILGER, H.; HUMER, M. Biotic landfill cover treatments for mitigating methane emissions. **Environmental Monitoring and Assessment**, v. 84, n 1–2, p.71–84, 2003.
- HUBER-HUMER, M.; KJELDEN, P.; SPOKAS, K. A. Special issue on landfill gas emission and mitigation. **Waste Management**, v. 31, p. 821–822, 2011
- HUBER-HUMER, M.; RÖDER, S.; LECHNER, P. Approaches to assess biocover performance on landfills. **Waste Management**. v. 29, n. 7, p. 2092-2104, 2009.
- INMET - Instituto Nacional de Meteorologia. **Dados Meteorológicos**. Governo Federal. 2021. Disponível em: < <https://bdmep.inmet.gov.br/>>.
- IPCC. Intergovernmental Panel On Climate Change. **Special report on global warming of 1.5 C (SR15)**." 2019.

- ISHIGAKI, T.; YAMADA, M.; NAGAMORI, M.; ONO, Y.; INOUE, Y. Estimation of methane emission from whole waste landfill site using correlation between flux and ground temperature. **Environmental Geology**, v. 48, n. 7, p. 845-853, 2005.
- ISMEIK, M.; AL-RAWI, O. Modeling Soil Specific Surface Area with Artificial Neural Networks. **Geotechnical Testing Journal**, v. 37, n. 4, p. 678-688, 2014.
- ISWA. INTERNATIONAL SOLID WASTE ASSOCIATION. **Climate Benefits due to Dumpsite Closure: Three case studies**. Rotterdam, Netherlands: ISWA. 2019.
- ISWA. INTERNATIONAL SOLID WASTE ASSOCIATION. ISWA. **Landfill operational guidelines**. 2. Ed<sup>a</sup> : Rotterdam, Netherlands:ISWA, 2010. 106 p.
- IZUMOTO, S.; HAMAMOTO, S.; KAWAMOTO, K.; NAGAMORI, M.; NISHIMURA, T. Monitoring of methane emission from a landfill site in daily and hourly time scales using an automated gas sampling system. **Environ. Sci. Pollut. Res.**, v. 25, p. 24500–24506, 2018
- JAVDANIAN, H.; JAFARIAN, Y.; HADDAD, A. Predicting damping ratio of fine-grained soils using soft computing methodology. **Arab J Geosci**, v. 8, p. 3959–3969, 2015.
- JERÔNIMO, G. C. **Modelos não lineares aplicados ao crescimento da macrófita *Lemna minor***. 2015. 70p. Dissertação (Mestrado em Ciência e Engenharia Ambiental) -Universidade Federal de Alfenas, Poços de Caldas -MG, 2015.
- JOHARI, A. AHMED, S. I. HASHIM, H. ALKALI, H. RAMLI, M. Economic and environmental benefits of landfill gas from municipal solid waste in Malaysia. **Renewable and Sustainable Energy Reviews**, v.16, p. 2907-2912, 2012.
- JUCÁ, J. F. T.; MACIEL, F. J. Gas Permeability of a Compacted Soil Used in a Landfill Cover Layer. **Advances in Unsaturated Geotechnics**, n. 147, p. 1535–1546, 2006
- JÚNIOR, G. N. A.; QUEIROZ, M. G.; JARDIM, A. M. R. F.; SILVA, M. J.; PEREIRA, P. C.; SILVA, T. G. F. Caracterização da direção predominante, velocidade máxima e média do vento do município de Petrolina-PE. **Pensar Acadêmico**, v. 17, n. 1, p. 43-49, 2019.
- KANNANGARA, M.; DUA, R.; AHMADI, L.; BENSEBAA, F. Modeling and prediction of regional municipal solid waste generation and diversion in Canada using machine learning approaches. **Waste Manag**, v. 74, p. 3–15, 2018.
- KAUNDA, R. B.; CHASE, R.B.; KEHEW, A. E.; KAUGARS, K.; SELEGEAN, J. P. Neural network modeling applications in active slope stability problems. **Environ Earth Sci.**, v. 60, p. 1545–1558, 2010.
- KAYRI, M. Predictive abilities of Bayesian regularization and levenberg-marquardt algorithms in artificial neural networks: A comparative empirical study on social data. **Mathematical and Computational Applications**, v. 21, n. 20, p. 1-11, 2017.
- KAZA, S.; YAO, L.; BHADA-TATA, P.; WOERDEN, F. **Van what a waste 2.0 everything you should know about solid waste management**; The World Bank: Washington (DC), 2018.
- KIM, Y.; KIM, B. Use of artificial neural networks in the prediction of liquefaction resistance of sands. **Journal of Geotechnical and Geoenvironmental Engineering**, v. 132, n. 11, 1502-1504, 2006.



- KHATAEE, A. R.; KASIRI, M. B. Artificial neural networks modeling of contaminated water treatment processes by homogeneous and heterogeneous nanocatalysis. **Journal of Molecular Catalysis A: Chemical**, v. 331, p. 86-100, 2010.
- KOPIER, A. A.; SILVA, V. N. A. L.; OLIVEIRA, L. A. A.; LINDEN, R.; SILVA, L. R. A. A.; FONSECA, B.L. C. Redes Neurais Artificiais e suas aplicações no setor elétrico. **Revista de Engenharia da Faculdade Salestana**, v. 9, p. 27–33, 2019.
- KUMAR, S.; NIMCHUK, N.; KUMAR, R.; ZIETSMAN, J.; RAMANI, T.; SPIEGELMAN, C.; KENNEY, M. Specific model for the estimation of methane emission from municipal solid waste landfills in India. **BioresourTechnol**, v. 216, p. 981–987, 2016.
- LABOISSIERE, L. A.; FERNANDES, R. A.; LAGE, G. G. Maximum and minimum stock price forecasting of Brazilian power distribution companies based on artificial neural networks. **Applied Soft Computing Journal**, v. 35, p. 66-74, 2015.
- LANDO, A. T.; NAKAYAMA, H.; SHIMAOKA, T. Application of portable gas detector in point and scanning method to estimate spatial distribution of methane emission in landfill. **Waste Management**, v. 59, p. 255-266, 2017
- LEGATES, D. R.; MCCABE JR, G. J. Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. **Water Resources Research**, v. 35, n. 1, p. 233-241, 1999.
- LI, A. J.; LIM, K.; CHIU, C. K.; HSIUNG, B. Application of artificial neural network in assessing fill slope stability. **World Academy of Science, Engineering and Technology, International Journal Of Geotechnical And Geological Engineering**, v. 12, n. 2, p.73-77, 2018.
- LI, A. J.; LIM, K.; FATTY, A. Stability evaluations of three-layered soil slopes based on extreme learning neural network. **Journal of the Chinese Institute of Engineers**, v. 43, n. 7, p. 628-637, 2020.
- LI, H.; SANCHEZ, R.; JOE, Q. I. N. S.; KAVAK, H. I.; WEBSTER, I. A.; TSOTSIS, T. T.; SAHIMI, M. Computer simulation of gas generation and transport in landfills. V: Use of artificial neural network and the genetic algorithm for short- and long-term forecasting and planning. **Chem Eng Sci**, v. 66, n. 12, p. 2646–2659, 2011.
- LI, L.; XIE, X.; GAO, T.; WANG, J. A modified conjugate gradient-based Elman neural network. **Cognitive Systems Research**, v. 68, n.2, p. 62–72, 2021.
- LIANG, Q.; HAN, H.; CUI, X.; QUING, H. Comparative study of probabilistic neural network and back propagation network for fault diagnosis of refrigeration systems. **Science and Technology for the Built Environment**, v. 24, n. 4, p. 448-457, 2018.
- LIANG, L.; LIU, M.; MARTIN, C.; SUN, W. A deep learning approach to estimate stress distribution: a fast and accurate surrogate of finite-element analysis. **Journal of The Royal Society Interface**, v. 15, n. 138, 2018.
- LOPES, R. L. **Infiltração de água e emissão de metano em camadas de cobertura de aterros de resíduos sólidos**. 250 f. 2011. Tese (Doutorado em Engenharia Civil) – Universidade Federal de Pernambuco, Recife. 2011.
- LOPES, R.L.; MACIEL, F.J.; JUCÁ, J.F.T. Avaliação da emissão de metano em aterro experimental de resíduos sólidos na Muribeca/PE - Brasil. **Revista AIDIS De Ingeniería Y Ciencias Ambientales**, v. 5, n. 1, p. 107-116, 2012.

- LUCERNONI, F.; RIZZOTTO, M.; CAPELLI, L.; BUSINI, V.; ROSSO, R.; SIRONI, S. Sampling method for the determination of methane emissions from landfill surfaces. **Waste Management & Research**, v. 35, n. 10, p. 1034-1044, 2017.
- MACHADO, S. L.; CARVALHO, M. F.; GOURC, J. P.; VILAR, O. M.; NASCIMENTO, J. C. F. Methane generation in tropical landfills: Simplified methods and field results. **Waste Management**, v. 29, p 153–161, 2009
- MACIEL, F. J. **Geração de biogás e energia em aterro experimental de resíduos sólidos urbanos**. 2009. 355 p. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, 2009.
- MACIEL, F. J. **Estudo da geração, percolação e emissão de gases no aterro de resíduos sólidos da Muribeca/PE**. 2003. 173 p. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife. 2003.
- MACIEL, F. J.; JUCÁ, J. F.T. Evaluation of landfill gas production and emissions in a MSW large-scale Experimental Cell in Brazil. **Waste Management**, v. 31, p. 966-977, 2011.
- MAGALHÃES, A. F. **Avaliação do desempenho de técnicas de bioengenharia na proteção e conservação da cobertura final de taludes em aterros de disposição de resíduos sólidos urbanos; estudo de caso para o aterro sanitário de Belo Horizonte, MG**. 2005. 186 p. Dissertação (Mestrado em Saneamento, Meio Ambiente e Recursos Hídricos) - Universidade Federal de Minas Gerais, Belo Horizonte, 2005.
- MAGALHÃES, A. F.; LOPES, S. R.; SOARES, B. L.; CARVALHO, J. A.; SIMÕES, G. F. Cobertura final de aterros sanitários: uma abordagem conservacionista ambiental. **Revista AIDIS De Ingeniería Y Ciencias Ambientales. Investigación, Desarrollo y práctica**, v. 13, n. 3, p. 669–681, 2020.
- MANHEIM, D. C.; YESILLER, N.; HANSON, J. L. Gas Emissions from Municipal Solid Waste Landfills: A Comprehensive Review and Analysis of Global Data. 2021. **Journal of the Indian Institute of Science**, v. 101, p. 625-657, 2021.
- MARIANO, M. O. H. **Avaliação da Retenção de Gases em Camadas de Cobertura de Aterros de Resíduos Sólidos**. 2008. 243 p. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, 2008.
- MARIANO, M. O. H.; JUCÁ, J. F. T. Ensaios de campo para determinação de emissões de biogás em camadas de cobertura de aterros de resíduos sólidos. **Engenharia Sanitária Ambiental**, v. 15, n. 3, p. 223-228, 2010
- MARQUES JUNIOR, F. A. F. **Condições intervenientes na geração de biogás de resíduos recém dispostos em aterro sanitário e com um ano de aterramento**. 2020. 79 p. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Campina Grande-PB, 2020
- MARRAPU, B. M.; JAKKA R. S. A Comparative Study on the Performance of ANN, MLR and MNR in the Assessment of Slope Stability for Kalla - Coonoor Hill Road Stretch of Nilgiris. In: SATAPATHY, S. *et al.* (eds) **International Conference on Emerging Trends in Engineering (ICETE)**. Learning and Analytics in Intelligent Systems, v. 2. Springer, Cham, 2020.
- MARTINI NETO, E; OLIVEIRA, E. F. D. P.; PASSOS, E. R. W. P. **Estatística básica**. Brasília: ECT/UniCorreios, 2011.

- MATEUS, S.C.S.; AGUIAR, P. H.D.V.; BARROS, R.T.D.V.; OLIVEIRA, E.C.D.O.; GADÉA, A. D. M. Estimativa da Geração de Biogás a Partir de RSU Utilizando Redes Neurais Artificiais (RNA). *In: 30º CONGRESSO BRASILEIRO DE ENGENHARIA SANITÁRIA E AMBIENTAL*, 2019, Natal. **Anais eletrônicos do 30º Congresso Brasileiro de Engenharia Sanitária e Ambiental**, Rio Grande do Norte: Natal, 2019.
- MAYORAZ, F.; VULLIET, L. Neural networks for slope movement prediction. *International Journal of Geomechanics*, v. 2, p. 153-173, 2002.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.
- MEDEIROS, R. M.; SABOYA, L. M. F.; FRANÇA, M. V.; ARAUJO, W. R.; FILHO, M. C.; HOLANDA, R. M.; COUTINHO JUNIOR, J. C. M. Comparativos das variabilidades do clima e do conforto ambiental nos municípios de Campina Grande e Monteiro, PB. **Revista Científica Multidisciplinar**, v. 2, n. 11, 2021.
- MEHRDAD, S. M.; ABBASI, M.; YEGANEH, B.; KAMALAN, H. Prediction of methane emission from landfills using machine learning models. **Environmental Progress & Sustainable Energy**, v. 40, n. 4, 2021
- MENDONÇA, R. M. G. **Estudo da Difusão de Oxigênio em Materiais de Cobertura**. 2007. 354p. Tese (Doutorado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Rio de Janeiro. 2007.
- MENTZER, J. T.; BIENSTOCK, C. C. **Sales Forecasting Management: understanding the techniques, systems and management of the sales forecasting process**. California: Sage, 1998.
- MERGH, L. S. **Análise de Indicadores da Gestão de Produção em Obras Corporativas**. 2019. 127 p. Dissertação (Mestrado em Construção Civil) – Universidade Federal de Minas Gerais, Belo Horizonte - MG, 2019.
- MOHAMMADI, L.; BANLASADI, M.; RAHDAR, A.; KYZAS, G. Z. Removal of Acid Dye from Aqueous Solutions with Adsorption onto Modified Wheat Bran – Modeling with Artificial Neural Networks. **Biointerface Research in Applied Chemistry**, v. 11, n. 6, p. 14044 – 14056, 2021.
- MØNSTER, J.; KJELDSSEN, P.; SCHEUTZ, C. Methodologies for measuring fugitive methane emissions from landfills—A review. **Waste Management**, v. 87, p. 835-859, 2019.
- MOREIRA, F. G. S.; GUEDES, M. J. F.; MONTEIRO, V. E. D.; MELO, M. C. Emissões fugitivas de biogás em camada de cobertura de solo compactado em aterro sanitário. **Engenharia Sanitária e Ambiental**, v. 25, n. 2, p. 247-258, 2020.
- MOREIRA, F.G.S. **Emissões fugitivas de biogás em célula de aterro sanitário**. 2018. 90 p. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Campina Grande, 2018.
- MOTA, D. G. A. **Prediction of soil shear strength parameters using artificial neural networks**. 2019. 159 p. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Fortaleza, 2019.
- NG, C. W. W.; CHEN, Z. K.; COO, J. L.; CHEN, R.; ZHOU, C. Gas breakthrough and emission through unsaturated compacted clay in landfill final cover. **Waste Management**, v. 44, p. 155– 163, 2015

- NWACHUKWU, A. N.; ANONYE, D. The effect of atmospheric pressure on CH<sub>4</sub> and CO<sub>2</sub> emission from a closed landfill site in Manchester, UK. **Environmental monitoring and assessment**, v. 185, p. 5729-5735, 2013.
- OLATUNJI, K. O.; AHMED, N. A.; MADYIRA, D. M.; ADEMAYO, A. O.; OGUNKUNLE, O.; ADELEKE, O. Performance evaluation of ANFIS and RSM modeling in predicting biogas and methane yields from *Arachis hypogea* shells pretreated with size reduction. **Renewable Energy**, v. 189, p. 288–303, 2022
- OLIVEIRA, A. C. E. De; RITTER, E.; MANNARINO, C. F. **Diagnóstico e avaliação de emissões fugitivas de biogás na camada de cobertura final da central de tratamento de resíduos de Nova Iguaçu e do lixão de Seropédica, Rio de Janeiro**. In: 27º CONGRESSO BRASILEIRO DE ENGENHARIA SANITÁRIA E AMBIENTAL, 2013, Goiânia-GO. **Anais eletrônicos do 27º Congresso Brasileiro de Engenharia Sanitária e Ambiental**, Goiânia: Goiás, p. 1-8, 2013.
- OLIVEIRA, T. S.; ANJOS, J. S.; RIBEIRO, S. E.; OLIVEIRA, D. M. Análise descritiva e de correlação dos indicadores de desempenho: Custo, prazo e ritmo. **Revista de Engenharia e Tecnologia**, v. 14, n. 1, 2022.
- PARK, H. I. Development of neural network model to estimate the permeability coefficient of soils. **Marine Georesources & Geotechnology Journal**, v. 29, p. 267-278, 2011.
- PARK, H. I.; LEE, S. R. Evaluation of the compression index of soils using an artificial neural network. **Computers and Geotechnics**, v. 38, p. 472-481, 2011.
- PARK, J. K.; KANG, J. Y.; Lee, N. H. Estimation of methane emission flux at landfill surface using laser methane detector: influence of gauge pressure. **Waste Management & Research**, v. 34, n. 8, p.784–792, 2016
- PARK, J. W.; SHIN, H. C. Surface emission of landfill gas from solid waste landfill. **Atmospheric Environment**, v. 35, n. 20, p. 3445-3451, 2001.
- PINHEIRO, R. J. B.; NUMMER, A. V.; RAUBER, A. C. Determinação da condutividade hidráulica das principais unidades geológico-geotécnicas de Santa Maria–RS. **Geosciences**, v. 36, n. 2, p. 347-363, 2017.
- PRATT, C. WALCROFT, A. TATE, K. ROSS, D. ROY, R. REID, M.H. VEIGA, P. W. In vitro methane removal by volcanic pumice soil biofilter columns over one year. **Journal of Environmental Quality**, v. 41, p.80–87, 2012.
- QIAN, Z. G.; LI, A. J.; CHEN, W. C.; LYAMIN, A. V.; JIANG, J. C. An artificial neural network approach to inhomogeneous soil slope stability predictions based on limit analysis methods. **Soils and Foundations**, v. 59, p. 556-569, 2019.
- RACHOR, I.M., GEBERT, J., GRÖNGRÖFT, A.; PFEIFFER, E.M. Variability of methane emissions from an old landfill over different time-scales. **European Journal of Soil Science**, v.64, n. 1, p.16-26, 2013.
- RAUBER, D.; FUGII, G. M.; NASCIMENTO, D. E.; SILVA, C. L. **Indicadores da gestão dos resíduos sólidos e saneamento básico presentes no plano municipal de saúde de Curitiba 2014-2017**. In: 8º FÓRUM INTERNACIONAL DE RESÍDUOS SÓLIDOS, 2017, Curitiba – PR. **Anais eletrônicos do 8º Fórum Internacional de Resíduos Sólidos**, Curitiba – PR, 2017

- REDDY, K. R.; KUMAR, G.; GIRI, R. K. Modeling coupled processes in municipal solid waste landfills: an overview with key engineering challenges. **International Journal of Geosynthetics and Ground Engineering**, v. 3, p. 1-21, 2017.
- REES-WHITE, T. C.; MONSTER, J.; BEAUEN, R. P.; SCHEUTZ, C. Measuring methane emissions from a UK landfill using the tracer dispersion method and the influence of operational and environmental factors. **Waste Management**, v. 87, p. 870-882, 2019.
- RENCHER, A.C. **Methods of Multivariate Analysis**, 2ªed. John Wiley & Sons, Inc. Publication: New York, 2002..
- REYES, D. M. A. **Ensaio de modelos de regressão linear e não-linear para dados simbólicos de tipo intervalo**. 2017. 83p. Dissertação (Mestrado em Ciências da Computação) - Universidade Federal de Pernambuco, Recife, 2017.
- REZAEI, S.; CHOBBASTI, A. J. Liquefaction assessment using microtremor measurement, conventional method and artificial neural network (Case study: Babol, Iran). **Front. Struct. Civ. Eng.**, v. 8, p. 292–307, 2014.
- RODRIGUES, M.I.; IEMMA, A.F. **Planejamento de Experimentos e Otimização de Processos**. 3ª. ed. Campinas: Cárita, 2014, 358 p.
- ROSA, A. S.; DALMONLIN, R. S. D.; PEDRON, F. A. Caracterização do solo de cobertura de aterros encerrados com ferramentas (geo)estatísticas. **Revista Engenharia Sanitária e Ambiental**, v. 16, n. 2, p. 121-126, 2011.
- RIBEIRO, V.; GOLDSCHMIDT, R.; CHOREN, R. Métodos para previsão de séries temporais e suas tendências de desenvolvimento. **Monografias em Sistemas e Computação**, v. 3, p. 1-26, 2009
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.
- SALOMON, K. R.; LORA, E. E. S.; ROCHA, M. H.; LEME, M. M. V. Biocombustíveis de primeira geração: biogás. *In*: LORA, E. E. S.; VENTURINI, O. J. **Biocombustíveis**. Ed. Interciência, Rio de Janeiro, 2012. p. 312-358
- SAMPAIO, I. G.; BERNARDINI, F.; PAES, A.; ANDRADE, E. O.; VITERBO, J. **Avaliação de modelos de predição e previsão construídos por algoritmos de aprendizado de máquina em problemas de cidades inteligentes**. *In*: Minicursos do XVI Simpósio Brasileiro de Sistemas de Informação, Porto Alegre: Sociedade Brasileira da Computação, 2019, pp. 81-113.
- SANTOS, G. O.; DE OLIVEIRA, F. C. H. P.; RIBEIRO, E. D.; FREIRE, S. C.; SILVA, R. A. C. Monitoramento das emissões fugitivas de CH<sub>4</sub> e CO<sub>2</sub> em camadas de cobertura de um aterro sanitário do Estado do Ceará, Brasil. **Revista Tecnologia e Sociedade**, v. 16, n. 41, p. 190-201, 2020.
- SANTOS, J. J. N. **Avaliação geotécnica de misturas de solo e composto orgânico para uso como biocoberturas em aterros sanitários**. 2019. 89f. Dissertação (Mestrado em Engenharia Civil e Ambiental) - Universidade Federal de Campina Grande, Campina Grande, 2019.
- SARTIN, M. A.; DA SILVA, A. C. R. Aproximação da função tangente hiperbólica em hardware. *In*: **Proceedings of International Conference on Engineering and Computer Education**. 2013. p. 361-365.

- SCHEUTZ, C.; PEDERSEN, G.B.; COSTA, G.; KJELDSEN, P. Biodegradation of methane and halocarbons in simulated landfill biocover systems containing compost materials. **Journal of Environmental Quality**, v. 38, n. 4, p. 1363-1371, 2009.
- SCHEUTZ, C.; SAMUELSSON, J.; FREDENSLUND, A. M.; KJELDSEN, P. Quantification of multiple methane emission sources at landfills using a double tracer technique. **Waste Management**, v. 31, n. 5, p. 1009-1017, 2011.
- SCOZZARI A. Non-invasive methods applied to the case of Municipal Solid Waste landfills (MSW): analysis of long-term data. **Adv Geosci**, v. 19, p. 33–38, 2008.
- SEHEUM, M.; NAM, K.; KIM, J. Y.; HWAN, S. K.; CHUNG, M. Effectiveness of compacted soil liner as a gas barrier layer in the landfill final cover system. **Waste Management**, v. 28, n. 10, p. 1909-1914, 2008
- SHARMA, L. K.; SINGH, R.; UMRAO, R. K.; SHARMA, K. M.; SINGH, T. N. Evaluating the modulus of elasticity of soil using soft computing system. **Engineering with Computers**, v. 33, p. 497–507, 2017.
- SHARMA, S. K. 2.1 Descriptive Statistics. *In*: RAM, M.; NAUTIYAL, O. P.; PANT, D. **Scientific Methods Used in Research and Writing**, Boca Raton: CRC Press, 2020. p. 9 – 17.
- SHEN, S.; CHEN, Y.; ZHAN, L.; XIE, H.; BOUAZZA, A.; HE, F.; ZOU, X. Methane hotspot localization and visualization at a large-scale Xi'na landfill in China: effective tool for landfill gas management. **Journal of environmental management**, v. 225, p. 232-241, 2018.
- SILVA, A. P.; LEAO, T. P.; TORMENA, C. A.; GONÇALVES, A. C. A. Determinação da permeabilidade ao ar em amostras indeformadas de solo pelo método da pressão decrescente. **Revista Brasileira de Ciência do Solo**, v. 33, p. 1535-1545, 2009.
- SILVA, D. J. F. **Estudo do balanço de radiação à superfície no bioma caatinga com diferentes densidades**. 2022. 108 p. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Campina Grande, Campina Grande, 2022.
- SILVA, I. N., SPATTI, D. H., e FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber Editora Ltda, 2010.
- SILVA, E.G. M. **Estudo experimental de gases em camadas de cobertura no Aterro de Nova Iguaçu -RJ**. 211. 109p, Dissertação (Mestrado em Engenharia Ambiental) – Universidade do Estado do Rio de Janeiro. Rio de Janeiro, 2011.
- SINGH, V. K.; KUMAR, D.; KASHYAP, P. S.; SINGH, P. K.; KUMAR, A.; SINGH, S. K. Modelling of soil permeability using different data driven algorithms based on physical properties of soil. **Journal of Hydrology**, v. 580, p. 124223-124242, 2020.
- SOUSA, M. C. B. Desejo por conforto: Estratégias adaptativas e índices preditivos no semiárido paraibano. 2018. 134 p. Dissertação (Mestrado em Arquitetura e Urbanismo) - Universidade Federal da Paraíba, João Pessoa, 2018
- SOUZA, J. C. M.; HONORATO, A. S.; BARRETO, C. A. A.; SANTOS, J. J. N.; PAIVA, W. **Comparação de parâmetros geotécnicos de solos utilizados em camada de cobertura de aterro sanitário**. *In*: I CONGRESSO INTERNACIONAL DE MEIO AMBIENTE E SOCIEDADE. 2019, Campina Grande – PB. **Anais eletrônicos do I Congresso Internacional de meio ambiente e sociedade**, Campina Grande – PB.

SPOKAS, K.; GRAFF, C.; MORCET, M.; ARAN, C. Implications of the spatial variability of landfill emission rates on geospatial analyses. **Waste Management**, v. 23, p. 599–607, 2006.

TIZPA, P.; CHENARI, R. J.; FARD, M. K.; MACHADO, S. L. An prediction of some geotechnical properties of soil from their index parameters. **Arab J Geosci**, v. 8, n. 5, p. 2911–2920, 2014.

TRAPANI, D.; BELLA, G.; VIVIANI, G. Uncontrolled methane emissions from a MSW landfill surface: Influence of landfill features and side slopes. **Waste Management**, v. 33, n. 10, p. 2108-2115, 2013.

USACE. UNITED STATES ARMY CORPS OF ENGINEERS. **Landfill off-gas collection and treatment systems**. Washington: USACE, 2008. 15 p

USEPA. UNITED STATES ENVIRONMENTAL PROTECTION AGENCY. **Code of Federal Regulations: Criteria for Municipal Solid Waste Landfills**. Chapter 40. Pt 257, App. III. (7-1-20 Edition). Washington DC, 53 p. 2020.

USEPA. UNITED STATES ENVIRONMENTAL PROTECTION AGENCY. **Monitoring Approaches for Landfill Bioreactors**. EPA/600/R-04/301. Cincinnati: National Risk Management Research Laboratory, Office of Research and Development., 2004.

UYANIK, I.; OZKAYA, B.; DEMIR, S.; CAKMAKCI, M. Meteorological parameters as an important factor on the energy recovery of landfill gas in landfills. **J Renew Sustain Energy**, v. 4, p. 1–9, 2012.

VENKATESH, K.; KUMAR, V.; TIWARI, R. P. Appraisal of liquefaction potential using neural network and neuro fuzzy approach. **Applied Artificial Intelligence**, v. 27, p. 700-720, 2013.

VILELA, P. S. J.; ARAÚJO, C. R. A. Estudo das emissões fugitivas de biogás a partir da camada de cobertura dos aterros sanitários. **Revista Ibero Americana de Ciências Ambientais**, v.12, n. 6, p. 308 – 318, 2021.

WANG, H.; MOAYEDI, H.; KOK FOONG, L. Genetic algorithm hybridized with multilayer perceptron to have an economical slope stability design. **Engineering with Computers**, v. 37, n. 4, p. 3067-3078, 2020

WANG, W.; LU, Y. Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding model. *In: IOP conference series: materials Science and engineering*. IOP Publishing, 2018.

XIAO, J.; LIU, C.; JU, B.; XU, H.; SUM, D.; DANG, Y. Estimation of in-situ biogas upgrading in microbial electrolysis cells via direct electron transfer: Two-stage machine learning modeling based on a NARX-BP hybrid neural network. **Bioresource Technology**, v. 330, 2021.

XIN, D.; HAO, Y.; SHIMAOKA, T.; NAKAYAMA, H.; CHAI, X. Site specific diel methane emission mechanisms in landfills: a field validated process based on vegetation and climate factors. **Environ Pollut**, v. 218, p. 673–680, 2016.

XU, L.; LIN, X.; AMEN, J.; WELDING, K.; MCDERMITT, D. Impact of changes in barometric pressure on landfill methane emission. **Global Biogeochem. Cycles**, v. 28, p. 679–695, 2014.

XUE, X.; LIU, E. Seismic liquefaction potential assessed by neural networks. **Environ Earth Sci.**, v. 76, n. 192, 2017.

ZHAO, X.; ZHOU, Y.; HUANG, S.; QIU, D.; SCHIDEMAN, L.; CHAI, X.; ZHAO, Y. Characterization of microalgae-bacteria consortium cultured in landfill leachate for carbon fixation and lipid production. **Bioresource Technology.** v. 156, p.322–328. 2014.



## APÊNDICE A - CÓDIGO DA REDE NEURAL ARTIFICIAL (RNA)

```

% Última modificação: Novembro 2022
% Título: Previsão do fluxo de metano
% Banco de dados 1

% limpando prompt
clear
clc

% definindo funções de ativação e treinamento
funcaoativacao = ["logsig" "tansig" "purelin" "elliotsig"];
funcaotreinamento = ["trainlm" "trainbr" "traingd" "trainbfg" "trainrp" "trainscg" "traincgb" "traincgf"
"traincgp" "trainoss" "traingdx"];

% Variáveis de controle
p = 1; % Navegador de funções de treinamento
i = 1; % Navegador de funções de ativação na camada oculta
j = 0; % Navegador de funções de ativação na camada de saída

% Primeira camada para escolha de cada função de ativação
while (p < 12)

    funtrain = funcaotreinamento{p}; % Função de treinamento na posição p
    exeline = 4; % Variável de controle para saída no excel
    neurons = 0; % Iniciar variável número de neurônios

    % Segunda camada para número de RNA treinadas n = 324
    while (exeline < 324)

        if (i == 1)% Função logsig na camada oculta

            while (exeline < 84)% Terceira camada para finalização do algoritmo logsig

                % Condições de contorno para o código
                if (exeline == 4)% Posição inicial para gravação dos dados .xlsx
                    neurons = 0;% Zerar o número de neurônios na camada oculta
                elseif (exeline == 24)% Posição para gravação dos dados .xlsx
                    neurons = 0;% Zerar o número de neurônios na camada oculta
                elseif (exeline == 44)% Posição para gravação dos dados .xlsx
                    neurons = 0;% Zerar o número de neurônios na camada oculta
                elseif (exeline == 64)% Posição para gravação dos dados .xlsx
                    neurons = 0;% Zerar o número de neurônios na camada oculta
                end

                if (exeline < 24)% Limite da primeira série de treinamentos Logsig_Logsig
                    j = 1;% Função logsig na camada de saída
                elseif (exeline >= 24) && (exeline < 44)% Limite da primeira série de treinamentos
                    Logsig_Tansig
                    j = 2;% Função tansig na camada de saída
                elseif (exeline >= 44)&&(exeline < 64)% Limite da primeira série de treinamentos
                    Logsig_Purelin
                    j = 3;% Função purelin na camada de saída
            end
        end
    end
end

```

```

elseif (exeline >= 64)&&(exeline < 84)%Limite da primeira série de treinamentos
Logsig_Elliotsig
    j = 4;%Função elliotssig na camada de saída
end

%Configurações dependentes para a RNA
atvfnco = funcaoativacao{i}; %Escolha da função de ativação na camada oculta
atvfncs = funcaoativacao{j}; %Escolha da função de ativação na camada de saída
neurons = neurons + 1; %Atualização do número de neurônios

%importacao do banco de dados
dadosgerais = xlsread("gases.xls", 4, "A2:L1001");%Banco de dados original
novaentrada = dadosgerais;%Variável de controle para o BD
entrada = novaentrada (:, 2:end);%Separação da entrada
saida = novaentrada (:, 1);%Separação da saída

%iniciando a rede neural
net = feedforwardnet(neurons);%Cria RNA do tipo feedforward
net = configure(net, entrada, saida);%Configura a RNA com o banco de dados

%treinamento

net.trainFcn = funtrain; %definindo algoritmo de treinamento
net.divideFcn = 'divideint';%tipo de divisão do BD

%divisao do banco de dados
net.divideParam.trainRatio = 0.7;%Porcentagem de treinamento
% net.divideParam.valRatio = 0.15;%Porcentagem de
% validação
net.divideParam.testRatio = 0.3;%Porcentagem de teste

%parametros da rna
net.trainParam.epochs = 1000; %numero maximo de iteracoes
net.trainParam.lr = 0.01; %taxa de aprendizagem
net.trainParam.time = inf; %tempo máximo de iteracoes

net.layers{1}.transferFcn = atvfnco; %definicao da funcao de ativacao da camada oculta
net.layers{2}.transferFcn = atvfncs; %definicao da funcao de ativacao da camada de saida

%treinamento
[net,tr] = train(net, entrada, saida);%treinamento da RNA

novaentrada = entrada;
saidamodificada = zeros(10, size(saida,2)); %cria matriz zeradas do tamanho da entrada de
dados
novasaida = [saida(1, :); saidamodificada];%Junta as linhas zeradas aos dados de entrada

%Separação das máscaras de treinamento e teste do banco de
%dados de entrada dependendo da distribuição do bd
treinoinput = gmultiply(novaentrada,tr.trainMask);%Máscara de treinamento
testeinput = gmultiply(novaentrada,tr.testMask);%Máscara de teste

```

```

    treino1input = cell2mat(treinoinput);%Conversão da máscara entrada (Célula) para formato
de matriz
    teste1input = cell2mat(testeinput);%Conversão da máscara saída (Célula) para formato de
matriz

    treino1input = treino1input(:,all(~isnan(treino1input)));% Remove os valores NaN
    teste1input = teste1input(:,all(~isnan(teste1input)));% Remove os valores NaN

    %Separação das máscaras de treinamento e teste do banco de
    %dados de saída dependendo da distribuição do bd
    treinooutput = gmultiply(novasaida,tr.trainMask);% Máscara de treinamento
    testeoutput = gmultiply(novasaida,tr.testMask);% Máscara de teste

    treino1output = cell2mat(treinooutput);%Conversão da máscara entrada (Célula) para
formato de matriz
    teste1output = cell2mat(testeoutput);%Conversão da máscara saída (Célula) para formato de
matriz

    treino1output = treino1output(:,all(~isnan(treino1output)));% Remove os valores NaN
    teste1output = teste1output(:,all(~isnan(teste1output)));% Remove os valores NaN

    %Remoção de linhas excedentes criadas para controle das
    %máscaras

    teste1output(11,:) = [];teste1output(10,:) = [];teste1output(9,:) = [];teste1output(8,:) = [];
    teste1output(7,:) = [];teste1output(6,:) = [];teste1output(5,:) = [];teste1output(4,:) = [];
    teste1output(3,:) = [];teste1output(2,:) = [];

    %Validacao
    resultado = net(teste1input); %Previsão dos dados de teste
    resultado = resultado'; %Transpor matriz resultado
    teste1output = teste1output'; %Transpor matriz de dados originais
    tt = teste1output(:,1); %Variável de controle para gráficos
    vetorindex = 1:length(tt);% Cria um vetor para posicionamento dos resultados em gráficos

    %Calcula o Erro Absoluto Médio (MAE)
    MAE = (mae(teste1output,resultado))';

    %Calcula o RMSE, MSE e Mape
    estatisticas = (CalcPerf(teste1output,resultado))';

    %Calcula o coeficiente de determinação R²
    Rdois = (est(teste1output,resultado))';

    %Calcula o coeficiente de eficiência (E)
    Eficiencia = (NSE(teste1output,resultado))';

    %Compilação e transcrição dos resultados
    estfinal = [MAE estatisticas.RMSE estatisticas.Mape estatisticas.NRMSE Rdois Eficiencia];
% Cria matriz de resultados
    nomenclatura = [num2str(neurons) convertCharsToStrings(atvfnc)
convertCharsToStrings(atvfncs) convertCharsToStrings(funtrain)]; % Cria matriz com a configuração
da RNA

```

```

        xlswrite ("Resultados.xlsx", nomenclatura, p, strcat ("A",
num2str(exeline),":", "D", num2str(exeline))); % Transcreve em xlsx a matriz de configurações
        xlswrite ("Resultados.xlsx", estfinal, p, strcat ("E",
num2str(exeline),":", "J", num2str(exeline))); % Transcreve em xlsx a matriz de resultados

%Exporta o workspace da RNA
nomerede = strcat(funtrain, "_", atvfnco, "_", atvfncs, "_"); % Nomenclatura dos arquivos
nomerede1 = strcat(atvfnco, ".", atvfncs); % Nomenclatura da legenda das imagens
save (strcat (nomerede, "_", num2str(neurons))); % Exporta o workspace

%Atualização da posição do arquivo xlsx
exeline = exeline + 1;

%Gráficos
figure(1)% Gráfico categoria Papel
plot (vetorindex,(teste1output), "ko:", vetorindex, (resultado),"rx:"); % Plotagem do gráfico
valores preditos e observados
grid on; % Ativar o grid
legend ("Observados", nomerede1+"."+neurons+"."+funtrain); % legenda
xlabel('POSICÃO'); % eixo x
ylabel('CH4(g/m²/dia)') % eixo y
saveas (gcf, strcat(nomerede, "CH4_", num2str(neurons)), "png");% Salvar o Gráfico .png

figure (2)
plotperform(tr)
saveas (gcf, strcat(nomerede, "perf_CH4_", num2str(neurons)), "png");% Salvar o Gráfico
.png

figure (3)
plot (teste1output, resultado,"ro:");
grid on; % Ativar o grid
xlabel('CH4(g/m²/dia) Observado'); % eixo x
ylabel('CH4(g/m²/dia) Preditos') % eixo y
saveas (gcf, strcat(nomerede, "OxP_CH4_", num2str(neurons)), "png");% Salvar o Gráfico
.png

%limpando o workspace
clear entrada saida perf vetorindex teste1output teste1input testeoutput testeinput
treino1input tr MAE treino1output treinooutput treinoinput validacaooutput validacao1output
validacaoinput validacao1input resultado perf mae estatisticas Rdois Eficiencia estfinal
clc

end

elseif (i == 2)% Função tansig na camada oculta
end

elseif (i == 3)% Função purelin na camada oculta
end

elseif (i == 4)% Função elliotstsig na camada oculta
end
else

```

```
    i = 0; %zera função de ativação
    j = 0; %zera função de ativação
end
    i = i + 1; %controle da posição na função de ativação
end
    p = p + 1; %Somatório para posição da função de treinamento
end
```