



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL

DANIEL EPIFÂNIO BEZERRA

**EVOLUÇÃO DO COMPORTAMENTO DOS RESÍDUOS SÓLIDOS URBANOS EM  
ATERRO SANITÁRIO SOB ASPECTOS MECÂNICOS**

Campina Grande - PB  
Fevereiro de 2023

DANIEL EPIFÂNIO BEZERRA

**EVOLUÇÃO DO COMPORTAMENTO DOS RESÍDUOS SÓLIDOS URBANOS EM  
ATERRO SANITÁRIO SOB ASPECTOS MECÂNICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal de Campina Grande – UFCG, em cumprimento às exigências para obtenção do título de mestre em Engenharia Civil e Ambiental.

**Área de concentração:** Recursos Hídricos e Saneamento Ambiental

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

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

Campina Grande - PB  
Fevereiro de 2023

B574e Bezerra, Daniel Epifânio.  
Evolução do comportamento dos resíduos sólidos urbanos em aterro sanitário sob aspectos mecânicos / Daniel Epifânio Bezerra. – Campina Grande, 2023.  
148 f. : il. color.

Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, 2023.

"Orientação: Prof. Dr. Márcio Camargo de Melo; Coorientação: Prof. Dr. William de Paiva".

Referências.

1. Resíduos Sólidos. 2. Características Físico-Químicas. 3. Atributos Mecânicos. 4. Degradação de Resíduos Sólidos Urbanos. 5. Redes Neurais Artificiais. I. Melo, Márcio Camargo de. II. Paiva, William de. III. Título.

CDU 628.4(043)

DANIEL EPIFÂNIO BEZERRA

EVOLUÇÃO DO COMPORTAMENTO DOS RESÍDUOS SÓLIDOS URBANOS EM  
ATERRO SANITÁRIO SOB ASPECTOS MECÂNICOS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal de Campina Grande – UFCG, em cumprimento às exigências para obtenção do título de mestre em Engenharia Civil e Ambiental.

Aprovado em: 24/02/2023

**BANCA EXAMINADORA:**

Prof. Dr. Márcio Camargo de Melo  
Universidade Federal de Campina Grande  
**Orientador**

Prof. Dr. Wiliam de Paiva  
Universidade Estadual da Paraíba  
**Coorientador**

Profa. Dra. Libânia da Silva Ribeiro  
Universidade Federal de Campina Grande  
**Examinadora Interna**

Prof. Dr. Cláudio Luís de Araújo Neto  
Universidade Federal do Maranhão  
**Examinador Externo**

Campina Grande - PB  
Fevereiro de 2023



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
POS-GRADUACAO ENGENHARIA CIVIL AMBIENTAL  
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

### REGISTRO DE PRESENÇA E ASSINATURAS

1. **ATA DA DEFESA PARA CONCESSÃO DO GRAU DE MESTRE EM ENGENHARIA CIVIL E AMBIENTAL**
2. **ALUNO(A): DANIEL EPIFÂNIO BEZERRA / COMISSÃO EXAMINADORA: DR. MÁRCIO CAMARGO DE MELO - PPGECA/UFCG (PRESIDENTE) - ORIENTADOR, DR. WILLIAM DE PAIVA - PPGECA/UFCG - COORIENTADOR, DR.ª LIBÂNIA DA SILVA RIBEIRO PPGECA/UFCG – EXAMINADORA INTERNA, DR. CLÁUDIO LUÍS DE ARAÚJO NETO – UFMA – EXAMINADOR EXTERNO (PORTARIA 03/2023). / TITULO DA DISSERTAÇÃO: “EVOLUÇÃO DO COMPORTAMENTO DOS RESÍDUOS SÓLIDOS URBANOS EM ATERRO SANITÁRIO SOB ASPECTOS MECÂNICOS” / ÁREA DE CONCENTRAÇÃO: RECURSOS HÍDRICOS E SANEAMENTO AMBIENTAL / HORA DE INICIO: 09:00 HORAS / FORMA DA SESSÃO: PRESENCIAL NO BLOCO CT, LABORATÓRIO DE PAVIMENTOS, CAMPUS SEDE DA UFCG, CAMPINA GRANDE.**
3. **EM SESSÃO REALIZADA DE FORMA PRESENCIAL, APÓS EXPOSIÇÃO DE CERCA DE 40 MINUTOS, O(A) CANDIDATO(A) FOI ARGUIDO(A) ORALMENTE PELOS MEMBROS DA COMISSÃO EXAMINADORA, TENDO DEMONSTRADO SUFICIÊNCIA DE CONHECIMENTO E CAPACIDADE DE SISTEMATIZAÇÃO NO TEMA DE SUA DISSERTAÇÃO, SENDO-LHE ATRIBUÍDA O CONCEITO “EM EXIGÊNCIA”, SENDO QUE A POSSIBILIDADE DE APROVAÇÃO ESTÁ CONDICIONADA À AVALIAÇÃO DA NOVA VERSÃO DO TRABALHO FINAL, SEGUINDO PROCEDIMENTOS PREVISTOS NA RESOLUÇÃO DO PROGRAMA. O PRESIDENTE DA COMISSÃO EXAMINADORA, OUVIDOS OS DEMAIS MEMBROS, DEVERÁ FICAR RESPONSÁVEL POR ATESTAR QUE AS CORREÇÕES SOLICITADAS NA LISTA DE EXIGÊNCIAS FORAM ATENDIDAS NA VERSÃO FINAL DO TRABALHO. A COMISSÃO EXAMINADORA CUMPRINDO OS PRAZOS REGIMENTAIS, ESTABELECE UM PRAZO MÁXIMO DE 30 DIAS PARA QUE SEJAM FEITAS AS ALTERAÇÕES EXIGIDAS. APÓS O DEPÓSITO FINAL DO DOCUMENTO DE DISSERTAÇÃO, DEVIDAMENTE REVISADO E MEDIANTE ATESTADO DO ORIENTADOR, O CONCEITO “EM EXIGÊNCIA” PASSARÁ IMEDIATAMENTE PARA O DE “APROVADO”. NA FORMA REGULAMENTAR, FOI LAVRADA A PRESENTE ATA, QUE É ASSINADA POR MIM, WELLINGTON LAURENTINO DOS SANTOS, SECRETÁRIO, ALUNO E OS MEMBROS DA COMISSÃO EXAMINADORA PRESENTES.**
4. **CAMPINA GRANDE, 24 DE FEVEREIRO DE 2023**



Documento assinado eletronicamente por **Daniel Epifânio Bezerra, Usuário Externo**, em 01/03/2023, às 09:01, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Libânia da Silva Ribeiro, Usuário Externo**, em 01/03/2023, às 09:01, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **William de Paiva, Usuário Externo**, em 01/03/2023, às 09:18, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).

---



Documento assinado eletronicamente por **Cláudio Luis de Araújo Neto, Usuário Externo**, em 01/03/2023, às 10:28, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).

---



Documento assinado eletronicamente por **MARCIO CAMARGO DE MELO, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 01/03/2023, às 11:30, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).

---



Documento assinado eletronicamente por **WELLINGTON LAURENTINO DOS SANTOS, SECRETÁRIO (A)**, em 01/03/2023, às 11:31, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).

---



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **3140570** e o código CRC **000C78F3**.

---

## AGRADECIMENTOS

A Deus.

A minha base, o meu pai Orlando Bezerra e minha mãe Maria Zélia Bezerra, pelo incentivo, amor, apoio e paciência em todos os momentos da minha vida. As minhas irmãs Ana Carolina e Ana Beatriz por toda ajuda e por estarem sempre presentes.

A minha segunda mãe Cícera da Silva e seu filho Robson de Assis, que me deram muito amor e apoio, estando presentes em todos os momentos de minha vida.

Aos meus avós Otaviano e Creuza (*in memoriam*), que embora fisicamente ausentes, sentia suas presenças ao meu lado, dando-me força. A minha Vó Maria Henriques Bezerra e às minhas tias, por todo acolhimento e ajuda em dez anos. E a todos os meus familiares por todo apoio e compreensão.

A minha família do coração, Socorro Nunes, Francisco de Assis, Isabelle Nunes, Ivila Nunes e Rael Nunes, por todo tempo, apoio, carinho e dedicação em todos esses anos.

Ao meu *crew*, em especial meus amigos, Ayrton Natthan Silva Ramos, Cleo Kaluaná Ferreira de Sousa, Diego Paulo Gomes, Hebert Jonathan Figueiredo Campos, Ivila Larricia Nunes Amorim Nascimento e Lucas Alves Batista Pequeno, que durante todos os nossos anos de amizade me mostraram cumplicidade, companheirismo, amor e paciência, sempre confiando e podendo contar com eles em todos os momentos.

Aos meus amigos, Raphael Jardelino, Elvis Sângelis, Thiago Ribeiro e Olívia Jardelino, que são meu maior refúgio, obrigado por todos os conselhos, conversas, risadas, pela paciência e todos os nossos momentos.

Em momentos difíceis do cenário mundial, a pandemia foi um momento pesado e eu não conseguiria superar sem o apoio de amigos que surgiram quando menos esperei. Só tenho a agradecer ao Tiago, Lucas, Kleuber, Fabiano, André, Maria e Renan por todas as risadas, conversas e todo tempo juntos, estou certo de que nesse momento vocês me motivaram a ser uma melhor pessoa.

Ao Grupo de Geotecnia Ambiental – GGA, por fornecer apoio em minhas pesquisas e estar presente na construção deste trabalho.

A professora Veruschka Escarião Dessoles Monteiro, coordenadora do GGA, que apesar de não ser uma das orientadoras desta pesquisa, sempre contribuiu com todo o incentivo, amizade, conselhos e orientações, sendo fundamental para meu crescimento como Engenheiro e aluno.

Ao professor Márcio Camargo de Melo, pela orientação, conselhos e palavras, por acreditar no projeto e auxiliar sendo base para que tudo desse certo durante o trajeto.

Ao professor William de Paiva, pela orientação, incentivo, confiança e amizade, por ter me ensinado a importância da pesquisa e por auxiliar em todo o processo acadêmico.

Ao Grupo de Geotecnia Ambiental (GGA), por todo o aprendizado e experiência adquirida durante esses dois anos de pesquisa, em especial ao subgrupo de ensaios geotécnicos que fui membro durante este tempo. A todos os membros, que demonstram amizade, companheirismo e união, por todos os conselhos e apoio, tenho certeza de que, cada um foi de fundamental importância para que essa pesquisa tivesse sucesso.

Aos professores do Programa de Pós-graduação em Engenharia Civil e Ambiental (PPGECA) da UFCG, pela dedicação e conhecimento compartilhado, tornando-me um profissional preparado e ajudando a despertar todo o amor pela área.

A todos os amigos e colegas que me apoiaram e contribuíram para minha formação acadêmica e pessoal.

A ECOSOLO Campina Grande – PB, pela disponibilidade e auxílio em cada etapa de campo desenvolvida durante esta pesquisa.

Ao CNPq, pelo apoio financeiro. A todos, muito obrigado.

*“Se estiver se sentindo desmotivado  
Ou sentindo que não é bom o suficiente.  
Incendeie seu coração.”*

*(Kyōjurō Rengoku na obra Kimetsu no Yaiba - Koyoharu Gotōge)*

## RESUMO

A operação de aterros sanitários é beneficiada quando se conhece o estado da degradação dos resíduos, em seu interior e nas diferentes etapas de seu ciclo de vida, uma vez que, com o tempo as características mecânicas e físico-químicas sofrem modificações. O objetivo desta pesquisa foi relacionar a evolução do comportamento dos RSU em diferentes fases de aterramento sob aspectos mecânicos no Aterro Sanitário em Campina Grande (ASCG). A metodologia compreendeu a coleta e caracterização físico-química e mecânica dos resíduos que chegam ao ASCG, provenientes de diferentes municípios do estado da Paraíba, Pernambuco e Rio Grande do Norte. O comportamento temporal dos resíduos também foi realizado por meio da análise das características geotécnicas e físico-químicas dos RSU que chegam ao ASCG, e, ainda, dos resíduos recém aterrados e com 1 e 2 anos de aterramento. Os dados físico-químicos e geotécnicos obtidos dos resíduos aterrados com idade igual ou superior a 0 anos foram coletados anteriormente à confecção dessa pesquisa pelo Grupo de Geotecnia Ambiental (GGA). Foi desenvolvido um modelo utilizando Redes Neurais Artificiais (RNA) para estimar a composição gravimétrica teórica dos RSU e o confronto dessa estimativa com a composição real aferida pela caracterização física. Os resultados da caracterização dos resíduos demonstram que em termos gravimétricos a fração de matéria orgânica é maior quando se avaliam os resíduos que chegam ao ASCG, porém, esse percentual sofre uma diminuição brusca de 880% após o aterramento. A caracterização físico-química revelou que os RSU, que chegam e recém aterrados no ASCG, são semelhantes, porém, ocorre uma rápida biodegradação. Os resíduos com 1 e 2 anos de aterramento são equivalentes em aspectos físico-químicos e mecânicos àqueles de aterros antigos. As análises estatísticas multivariadas permitiram, por correlação linear de *Pearson* e Análise de Componentes Principais verificar que os resíduos apresentam parâmetros que formam grupos isolados que refletem correlações positivas e negativas entre si. Essas correlações evidenciam o comportamento temporal dos resíduos sob diversos aspectos e demonstram que o ASCG proporciona um processo rápido de mudança nas características físicas dos resíduos. Os modelos de RNA, mostraram-se uma ferramenta eficiente e viável na previsão da composição gravimétrica dos resíduos, podendo ser utilizada por outros municípios.

**Palavras-chave:** características físico-químicas; atributos mecânicos; degradação de resíduos sólidos urbanos; redes neurais artificiais.

## ABSTRACT

The operation of sanitary landfills is benefited when the degradation state of the residues is known, inside and in the different stages of its life cycle, since, with time, the mechanical and physical-chemical characteristics undergo modifications. The objective of this research was to relate the evolution of MSW behavior in different stages of grounding under mechanical aspects in Sanitary Landfill in Campina Grande (ASCG). The methodology included the collection and physical-chemical and mechanical characterization of the waste that arrive at the ASCG, from different municipalities in the states of Paraíba, Pernambuco and Rio Grande do Norte. The temporal behavior of the waste was also carried out through the analysis of the geotechnical and physical-chemical characteristics of the MSW that arrived at the ASCG, and also of the waste recently landfilled and with 1 and 2 years of landfill. The physical-chemical and geotechnical data obtained from grounded waste aged 0 years or more were collected prior to the making of this research by the Environmental Geotechnical Group (GGA). A model was developed using Artificial Neural Networks (ANN) to estimate the theoretical gravimetric composition of the MSW and the confrontation of this estimate with the real composition measured by the physical characterization. The results of the waste characterization show that in gravimetric terms the fraction of organic matter is higher when evaluating the waste that arrives at the ASCG, however, this percentage suffers a sudden decrease of 880% after grounding. The physical-chemical characterization revealed that the MSW, which arrive and recently landed in the ASCG, are similar, however, a rapid biodegradation occurs. Waste that has been landfilled for 1 and 2 years is equivalent in physical-chemical and mechanical aspects to that of old landfills. Multivariate statistical analyzes allowed, through Pearson's linear correlation and Principal Component Analysis, to verify that the residuals present parameters that form isolated groups that reflect positive and negative correlations between themselves. These correlations show the temporal behavior of the residues under different aspects and demonstrate that the ASCG provides a fast process of change in the physical characteristics of the residues. The ANN models proved to be an efficient and viable tool in predicting the gravimetric composition of the waste, which can be used by other municipalities.

**Keywords:** physical-chemical characteristics; mechanical attributes; degradation of urban solid waste; artificial neural networks.

## LISTA DE FIGURAS

Figura 1 - Distribuição do tamanho das partículas do RSU. ....	29
Figura 2 - (a) Curvas de compactação para diferentes ensaios.....	34
Figura 3 - Curvas de tensão típicas de ensaios de cisalhamento direto com RSU. a) tensão cisalhante x deformação; b) tensão cisalhante x tensão normal. ....	36
Figura 4 - Comparação entre neurônio biológico e artificial. (a) Neurônio biológico humano; (b) Neurônio artificial; (c) Rede de neurônios sinápticos; (d) Rede Neural Artificial. ....	39
Figura 5 - Arquitetura do neurônio McCulloch-Pitts. ....	41
Figura 6 - Perceptron de Rosenblatt. ....	42
Figura 7 - Funcionamento da retropropagação. ....	45
Figura 8 - Função de ativação linear. ....	47
Figura 9 - Função de ativação sigmoide. ....	48
Figura 10 - Função de ativação tangente hiperbólica. ....	49
Figura 11 - Função de ativação sigmoide simétrica de Elliot.....	50
Figura 12 - Fluxograma experimental. ....	53
Figura 13 - Mapa de georreferenciamento do aterro sanitário em Campina Grande - PB. ....	54
Figura 14 - Configuração atual do aterro sanitário em Campina Grande - PB. ....	55
Figura 15 - (a) Caminhões basculantes; (b) caminhões compactadores; (c) e (d) diferentes disposições de RSU. ....	57
Figura 16 - (a) acomodação dos resíduos após chegada no ASCG; (b) coleta dos resíduos; (c) pesagem dos RSU. ....	58
Figura 17 - (a) acomodação dos RSU no galpão; (b) abertura de sacolas plásticas; (c) homogeneização; (d) resíduos quarteados. ....	59
Figura 18 - (a) resíduos picotados; (b) diluição em água destilada; (c) extrato. ....	61
Figura 19 - (a) preparação da amostra no balde; (b) balança analógica; (c) pesagem dos resíduos. ....	62
Figura 20 - Resíduos Sólidos Urbanos segregados. ....	63
Figura 21 - (a) soquete de concreto; (b) baldes de volumes diferentes; (c) elevação do soquete; (d) compactação do resíduo; (e) aferição da altura e do raio maior. ....	64
Figura 22 - (a) amostra para granulometria; (b) série de peneiras 76,2 - 19,1 mm; (c) pesagem do material; (d) peneiramento com agitador mecânico; (e) material retido nas peneiras. ....	66
Figura 23 - (a) Fração retida na peneira 19,1 mm; (b) Série de peneiras para peneiramento fino. ....	67

Figura 24 - Separação da amostra para massa específica real dos resíduos sólidos urbanos. . .	68
Figura 25 - Roteiro para ensaio de massa específica real dos resíduos sólidos urbanos. (a) calibração do conjunto Erlenmeyer + água destilada; (b) amostra homogeneizada; (c) preparação das amostras em submersão; (d) resíduos transferidos para os Erlenmeyers; (e) aplicação do vácuo 88 kPa; (f) aferição da temperatura. ....	69
Figura 26 - (a) adição de água na amostra; (b) aplicação de energia Proctor Normal; (c) pesagem do corpo de prova após a compactação. ....	72
Figura 27 - Moldagem dos corpos de prova e ensaio de resistência ao cisalhamento direto. (a) amostra; (b) caixa de cisalhamento; (c) moldagem com prensa hidráulica; (d) caixa de cisalhamento moldada; (e) rompimento na prensa; (f) resíduo cisalhado. ....	73
Figura 28 - Municípios que compõe o banco de dados para a RNA. ....	76
Figura 29 - Arquitetura do modelo considerando seis entradas, neurônios variando de 1 a 15 na camada oculta e seis categorias na camada de saída. ....	78
Figura 30 - Composição gravimétrica dos resíduos que chegam ao aterro sanitário em Campina Grande - PB. ....	81
Figura 31 - Evolução da composição gravimétrica dos RSU. ....	85
Figura 32 - Composição volumétrica aparente solta dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande - PB. ....	87
Figura 33 - Composição volumétrica aparente compactada dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande - PB. ....	88
Figura 34 - Massa específica aparente dos Resíduos Sólidos Urbanos dispostos no aterro sanitário em Campina Grande - PB. ....	89
Figura 35 - Curva granulométrica para os Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande - PB. ....	92
Figura 36 - Comparação de diferentes curvas granulométricas. ....	93
Figura 37 - Umidade dos Resíduos Sólidos Urbanos do ASCG. ....	95
Figura 38 - pH dos Resíduos Sólidos Urbanos do ASCG. ....	96
Figura 39 - Teor de sólidos voláteis dos Resíduos Sólidos Urbanos. ....	98
Figura 40 - DBO <sub>5</sub> e DQO dos Resíduos Sólidos Urbanos. ....	99
Figura 41 - Curva de compactação dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário de Campina Grande - PB. ....	101
Figura 42 - Resistência ao cisalhamento não inundada dos Resíduos Sólidos Urbanos: (a) tensão de cisalhamento-deformação horizontal; (b) deformações vertical-horizontal. ....	102

Figura 43 - Resistência ao cisalhamento inundada dos Resíduos Sólidos Urbanos. (a) tensão de cisalhamento-deformação horizontal; (b) deformações vertical-horizontal.....	104
Figura 44 - Envoltórias de ruptura dos resíduos que chegam ao ASCG. (a) condição não inundada; (b) condição inundada.....	105
Figura 45 - Correlação dos dados.....	108
Figura 46 - Análise de componentes principais das características dos resíduos sólidos urbanos. ....	109
Figura 47 - Comparação de desempenho neural dos dados preditos X observados da categoria Papel.....	114
Figura 48 - Comparação de desempenho neural dos dados preditos X observados da categoria Plásticos.....	115
Figura 49 – Comparação de desempenho neural dos dados preditos X observados da categoria Metal.....	116
Figura 50 - Comparação de desempenho neural dos dados preditos X observados da categoria Vidro.....	117
Figura 51 - Comparação de desempenho neural dos dados preditos X observados da categoria Matéria Orgânica.....	118
Figura 52 - Comparação entre a composição gravimétrica real e teórica.....	122

## LISTA DE TABELAS

Tabela 1 - Composição gravimétrica de RSU no mundo e no Brasil.....	26
Tabela 2 - Planejamento amostral para coleta de RSU. ....	56
Tabela 3 - Preparação da amostra para o ensaio de massa específica real. ....	68
Tabela 4 - Informações iniciais para o ensaio de cisalhamento direto do RSU. ....	74
Tabela 5 - Estatística descritiva do BD. ....	77
Tabela 6 - Massa específica real dos RSU que chegam ao aterro sanitário em Campina Grande. .....	91
Tabela 7 - Parâmetros de resistência dos RSU que chegam ao ASCG. ....	105
Tabela 8 - Estatística descritiva das características temporais dos RSU no ASCG. ....	107
Tabela 9 - Performance geral das arquiteturas neurais categorias de RSU. ....	112
Tabela 10 - Melhores modelos neurais para cada categoria de RSU ....	119
Tabela 11 - Informações gerais e previsões dos municípios que depositam RSU no ASCG (agosto/2022). ....	120

## LISTA DE QUADROS

Quadro 1 - Aspectos mecânicos para o RSU.....	27
Quadro 2 - Peso específico de Resíduos Sólidos Urbanos. ....	30
Quadro 3 - Teores de umidade de RSU.....	31
Quadro 4 - Parâmetros e métodos físico-químicos.....	60
Quadro 5 – Parâmetros e métodos geotécnicos.....	71
Quadro 6 - Parâmetros de construção de RNA.....	79
Quadro 7 - Métricas de desempenho .....	80

## SUMÁRIO

1 INTRODUÇÃO.....	19
1.1 Objetivos.....	20
1.1.1 Objetivo geral.....	20
1.1.2 Objetivos específicos.....	20
2 REVISÃO BIBLIOGRÁFICA.....	22
2.1 Resíduos Sólidos Urbanos.....	22
2.2 Biodegradação dos Resíduos Sólidos Urbanos.....	23
2.3 Características dos Resíduos Sólidos Urbanos.....	24
2.3.1 Características físico-químicas dos Resíduos Sólidos Urbanos.....	25
2.3.1.1 Composição gravimétrica dos Resíduos Sólidos Urbanos.....	25
2.3.1.2 Composição Volumétrica dos Resíduos Sólidos Urbanos.....	27
2.3.1.3 Tamanho das partículas dos Resíduos Sólidos Urbanos.....	28
2.3.1.4 Peso específico dos Resíduos Sólidos Urbanos.....	29
2.3.1.5 Umidade dos Resíduos Sólidos Urbanos.....	31
2.3.1.6 pH dos Resíduos Sólidos Urbanos.....	31
2.3.1.7 Teor de sólidos voláteis dos Resíduos Sólidos Urbanos.....	32
2.3.1.8 Demanda Química de Oxigênio (DQO) e Demanda Bioquímica de Oxigênio (DBO) dos Resíduos Sólidos Urbanos.....	33
2.3.2 Características geotécnicas dos Resíduos Sólidos Urbanos.....	33
2.3.2.1 Compactação dos Resíduos Sólidos Urbanos.....	33
2.3.2.2 Resistência ao cisalhamento dos Resíduos Sólidos Urbanos.....	35
2.4 Análise descritiva de dados.....	37
2.4.1 Correlação Linear de <i>Pearson</i> .....	37
2.4.2 Análise de componentes principais.....	37
2.5 Modelagem não constitutiva com Redes Neurais Artificiais.....	38
2.5.1 Fundamentos das Redes Neurais Artificiais.....	39

2.5.2 Breve histórico acerca das redes neurais artificiais.....	40
2.5.3 Topologias de redes neurais artificiais .....	43
2.5.3.1 Métodos de aprendizagem de redes neurais artificiais .....	44
2.5.3.2 Arquiteturas de redes neurais artificiais .....	44
2.5.3.2.1 Camadas ocultas e número de neurônios .....	46
2.5.3.2.2 Funções de ativação .....	46
2.5.3.2.3 Algoritmos de treinamento .....	50
2.5.4 Verificação estatística dos resultados.....	50
3 METODOLOGIA.....	52
3.1 Descrição do campo experimental .....	54
3.2 Planejamento estatístico e amostragem dos Resíduos Sólidos Urbanos.....	55
3.3 Coleta e amostragem dos Resíduos Sólidos Urbanos .....	57
3.4 Caracterização físico-química dos Resíduos Sólidos Urbanos.....	59
3.4.1 Composição gravimétrica dos Resíduos Sólidos Urbanos.....	61
3.4.2 Composição volumétrica dos Resíduos Sólidos Urbanos.....	63
3.4.3 Massa específica aparente solta e compactada dos Resíduos Sólidos Urbanos.....	64
3.4.4 Tamanho das partículas dos Resíduos Sólidos Urbanos .....	65
3.4.5 Massa específica real dos Resíduos Sólidos Urbanos.....	68
3.4.6 Teor de umidade dos Resíduos Sólidos Urbanos .....	70
3.5 Caracterização geotécnica dos Resíduos Sólidos Urbanos.....	71
3.5.1 Compactação dos Resíduos Sólidos Urbanos .....	71
3.5.2 Resistência ao cisalhamento direto dos Resíduos Sólidos Urbanos.....	72
3.6 Avaliação estatística do comportamento dos resíduos no aterro sanitário em Campina Grande.....	74
3.7 Modelagem não constitutiva da composição gravimétrica dos Resíduos Sólidos Urbanos por meio de redes neurais artificiais .....	75
3.7.1 Seleção de dados para as redes neurais artificiais .....	75
3.7.2 Criação dos bancos de dados das redes neurais artificiais .....	77

3.7.3 Construção e escolha das redes neurais artificiais .....	77
3.7.3.1 Avaliação do desempenho do modelo .....	79
3.7.3.2 Previsão da composição gravimétrica teórica do aterro sanitário em Campina Grande - PB .....	80
4 RESULTADOS .....	81
4.1 Caracterização físico-química dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande.....	81
4.1.1 Composição gravimétrica dos Resíduos Sólidos Urbanos no Aterro Sanitário em Campina Grande.....	81
4.1.1.1 Evolução da composição gravimétrica com o tempo de aterramento no aterro sanitário em campina grande .....	84
4.1.2 Composição volumétrica dos Resíduos Sólidos Urbanos.....	87
4.1.3 Massa específica aparente solta e compactada dos Resíduos Sólidos Urbanos .....	89
4.1.4 Massa específica real dos Resíduos Sólidos Urbanos.....	91
4.1.5 Tamanho das partículas dos Resíduos Sólidos Urbanos .....	92
4.1.6 Teor de umidade dos Resíduos Sólidos Urbanos .....	94
4.1.7 pH dos Resíduos Sólidos Urbanos .....	96
4.1.8 Teor de sólidos suspensos voláteis dos Resíduos Sólidos Urbanos.....	97
4.1.9 DBO <sub>5</sub> e DQO dos Resíduos Sólidos Urbanos.....	99
4.2 Caracterização geotécnica dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande .....	100
4.2.1 Compactação dos Resíduos Sólidos Urbanos .....	100
4.2.2 Resistência ao cisalhamento direto dos Resíduos Sólidos Urbanos.....	102
4.3 Análise descritiva dos dados.....	106
4.3.1 Estatística descritiva dos dados temporais dos Resíduos Sólidos Urbanos .....	106
4.3.2 Correlação linear de <i>Pearson</i> dos dados temporais dos Resíduos Sólidos Urbanos .....	107
4.3.3 Análise de componentes principais dos Resíduos Sólidos Urbanos .....	109

4.4 Modelagem não constitutiva da composição gravimétrica com redes neurais artificiais .....	111
4.4.1 Resultados e desempenhos dos treinamentos de redes neurais artificiais.....	111
4.4.1.1 Métricas de desempenho categoria Papel.....	113
4.4.1.2 Métricas de desempenho categoria Plásticos.....	114
4.4.1.3 Métricas de desempenho para a categoria Metal.....	115
4.4.1.4 Métricas de desempenho para a categoria Vidro.....	116
4.4.1.5 Métricas de desempenho para a categoria Matéria Orgânica .....	117
4.4.1.6 Discussão geral das métricas de desempenho avaliadas .....	118
4.4.2 Previsão da composição gravimétrica do aterro sanitário em Campina Grande....	119
5 CONCLUSÕES.....	123
REFERÊNCIAS .....	124
APÊNDICE A .....	139

## 1 INTRODUÇÃO

Aterros sanitários são uma forma de tratamento de Resíduos Sólidos Urbanos (RSU) baseado em técnicas sanitárias de impermeabilização do solo, compactação e cobertura diária de resíduos, coleta e tratamento de gases e lixiviado, entre outros procedimentos técnico-operacionais responsáveis por minimizar os aspectos negativos da deposição final do resíduo (BOSCOV, 2008; PORTELLA e RIBEIRO, 2014; MELO, 2017).

A análise adequada do desempenho de aterro, deve ser realizada de modo a garantir o uso ideal de suas instalações, objetivando aumentar a vida operacional. Essa análise do desempenho requer conhecimento e compreensão das características físicas, químicas e mecânicas dos resíduos sólidos no aterro, bem como das atividades operacionais no local (OWUSU-NIMO, F. *et al.*, 2019).

Outro parâmetro na avaliação do desempenho do aterro é a verificação do estado de degradabilidade dos RSU, a partir do conhecimento do comportamento das interações físicas e físico-químicas que ocorrem no maciço ao longo do tempo. Os parâmetros avaliados devem englobar as características dos RSU durante todo seu ciclo de vida, ou seja, desde a chegada no aterro sanitário até o período de finalização e estabilização. É conveniente, portanto, obter um perfil ao longo do tempo de degradação dos RSU e utilizá-lo para melhorar a eficiência da operação do empreendimento.

As propriedades mecânicas dos RSU desempenham um papel crucial durante as fases de operação, fechamento e pós-fechamento das instalações de contenção de resíduos. Portanto, devem-se ser investigados fatores como: composição dos resíduos, densidade, idade de aterramento, teor de umidade, esforço de compactação, espessura da camada de resíduos, profundidade de aterramento, grau de decomposição e fatores climáticos. Os parâmetros mecânicos do RSU são associados as características físico-químicas, pois a partir deles completa-se o perfil biodegradativo em aterros sanitários (RAMAIAH; RAMANA; MANOJ DATTA, 2017).

A análise gravimétrica de RSU auxilia na classificação individual e no conhecimento dos constituintes de determinado volume de resíduos, distribuindo em classes bem definidas como, por exemplo, matéria orgânica, recicláveis e rejeitos. Portanto, é possível estimar as propriedades de cada parcela de material e definir a forma de tratamento e destinação adequada. As características dos RSU variam por diversos fatores como os econômicos, sociais, culturais, climáticos, religiosos, relevo, escolaridade, nível de urbanização dentre outros, que configuram

distintas composições gravimétricas para uma mesma região, estado ou país (IBAM, 2001; BOSCOV, 2008; CHEN, 2018; KIM, 2019; VILLALBA, 2020).

Existem diversas técnicas tradicionais para caracterização física de resíduos, Bezerra (2020) afirma que na maioria dos países em desenvolvimento as caracterizações são demoradas e onerosas, nesse ponto de vista surge a necessidade de desenvolvimento metodologias que auxiliem nesse processo, uma das possibilidades é a modelagem matemática.

A utilização de Redes Neurais Artificiais (RNA) na previsão da composição gravimétrica de resíduos é uma técnica que se demonstra viável, pois a partir de sua aplicação ocorrerá a diminuição dos custos operacionais e de equipamentos, diminuição do tempo necessário para fazer as análises e redução dos riscos associados a saúde dos trabalhadores. Para realizar a estimativa da composição dos RSU, diversos estudos (BATINIC *et al.*, 2011; MIEZAH *et al.*, 2015; MA *et al.*, 2020; AYELERU *et al.*, 2021) utilizaram bancos de dados contendo informações de entrada como: variáveis socioeconômicas; demográficas; climáticas; e outros índices.

Nesse aspecto, o que motiva essa pesquisa é a necessidade de avaliar a degradação dos resíduos no Aterro Sanitário em Campina Grande (ASCG) por meio da caracterização dos resíduos que chegam ao ASCG e confrontação com uma série de dados físico-químicos e geotécnicos do Grupo de Geotecnia Ambiental (GGA) para as idades de 0, 1 e 2 anos de aterramento, além de gerar modelos de RNA para previsão da composição gravimétrica teórica dos RSU que chegam ao ASCG.

## **1.1 Objetivos**

### **1.1.1 Objetivo geral**

Avaliar o comportamento dos Resíduos Sólidos Urbanos em aterro sanitário sob aspectos mecânicos e físico-químicos.

### **1.1.2 Objetivos específicos**

- Verificar as características gravimétricas e volumétricas dos Resíduos Sólidos Urbanos que chegam ao Aterro Sanitário em Campina Grande-PB;

- Identificar características geotécnicas e físico-químicas dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande-PB;
- Observar as correlações dos parâmetros físico-químicos e geotécnicos dos Resíduos Sólidos Urbanos que chegam ao Aterro Sanitário em Campina Grande-PB, recém aterrados, com 1 e 2 anos de aterramento.
- Confrontar a composição real dos resíduos que chegam ao aterro sanitário em Campina Grande-PB com a composição teórica prevista a partir de Redes Neurais Artificiais.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo são abordados aspectos relativos à conceitos, propriedades, modelos, métodos e estudos relacionados aos Resíduos Sólidos Urbanos (RSU) e seu comportamento em aterros sanitários. A revisão bibliográfica está dividida em três seções: i) estado atual dos RSU; ii) aspectos biomecânicos dos RSU; iii) análise estatística e iv) redes neurais artificiais.

### 2.1 Resíduos Sólidos Urbanos

Resíduos Sólidos Urbanos (RSU) são um problema global que afeta todos, desde governos até indivíduos. Resíduos mal gerenciados provocam problemas de infraestrutura urbana, contaminação atmosférica, hídrica e do solo, além de ser um transtorno a saúde pública. À medida que os níveis de renda de um país aumentam, sua situação de gestão de resíduos também se modifica. O aumento da prosperidade e o movimento para áreas urbanas, acompanham um crescimento da geração *per capita* de RSU, tornando mais difícil sua coleta e destinação adequada.

A Lei nº 12.305, de 02 de agosto de 2010, que institui a Política Nacional dos Resíduos Sólidos define resíduos sólidos como: “material, substância, objeto ou bem descartado resultante de atividades humanas em sociedade, a cuja destinação final se procede, se propõe proceder ou se está obrigado a proceder, nos estados sólido ou semissólido, bem como gases contidos em recipientes e líquidos cujas particularidades tornem inviável o seu lançamento na rede pública de esgotos ou em corpos d’água, ou exijam para isso soluções técnica ou economicamente inviáveis em face da melhor tecnologia disponível” (BRASIL, 2010).

Para entender o panorama mundial sobre os RSU, foi desenvolvido o relatório *What a Waste 2.0*, produzido pelo *Waste Atlas* (2018). Esse relatório informa que, no mundo, são gerados anualmente, cerca de 2,01 bilhões de toneladas de RSU e diariamente a geração *per capita* está em torno de 0,74 kg, podendo sofrer variações, de 0,11 até 4,54 kg. O Brasil é um grande contribuinte da parcela mundial de geração de RSU. Segundo a Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais – ABRELPE (2022), o Brasil alcançou a marca de 81,6 milhões de toneladas de RSU geradas no ano de 2022 e cada brasileiro produziu em média 1,043 kg de RSU por dia, média acima do valor registrado mundialmente.

Geralmente em países em desenvolvimento, onde há grande densidade populacional e conseqüentemente, alta geração de RSU, utiliza-se a técnica de aterros sanitários para disposição final de RSU (NANDA e BERRUTI, 2021). O Brasil, é um dos países emergentes

que utilizam os aterros sanitários como principal forma de disposição de RSU. A ABRELPE (2022), estima que cerca de 61% dos resíduos gerados no país recebem disposição final ambientalmente adequada sendo conduzidos a aterros sanitários.

Define-se um aterro sanitário como uma técnica de disposição e tratamento de resíduos sólidos em uma área licenciada por órgãos ambientais, que não cause danos à saúde pública e à sua segurança, minimizando os impactos ambientais. Esse método utiliza os 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 solo na conclusão de cada jornada de trabalho, ou a intervalos menores, se necessário (NBR 8419 – ABNT, 1992).

Os aterros sanitários são as formas de disposição mais utilizadas no mundo, isso deve-se ao custo relativamente baixo, quando comparados a outras formas de tratamento, de operação e ao fato de serem ecologicamente corretos quando projetados e operados como biorreatores para aproveitamento de biogás e lixiviado (DAS *et al.*, 2019). Portanto, considera-se aterros sanitários como obras da geotecnia ambiental que visam controlar a percolação de contaminantes, a partir do confinamento de resíduos utilizando de técnicas de impermeabilização da base e cobertura dos resíduos, coleta e drenagem de líquidos, coleta e tratamento de emissão de gases, drenagem superficial, tratamento do lixiviado e monitoramento adequado, fornecendo informações para controle, respectivamente, da estabilidade estrutural e do impacto ambiental do aterro de resíduos (BOSCOV, 2008; NANDA e BERRUTI, 2021).

## **2.2 Biodegradação dos Resíduos Sólidos Urbanos**

Os aterros sanitários podem ser considerados reatores biológicos, cujo principais componentes de entrada são RSU e água e os principais elementos de saída é o lixiviado e biogás. A degradação dos resíduos nos aterros ocorre por mecanismos aeróbios e anaeróbios, devido à ação conjunta de diferentes tipos de microrganismos (MARQUES, 2001).

A fase aeróbia inicia antes da disposição dos RSU em aterros sanitários e se deve a presença de microrganismos nos resíduos e no meio ao qual ele está inserido. Já a fase anaeróbia, inicia quando não existe mais oxigênio nos vazios dos resíduos, fator causado pelo intenso consumo de oxigênio por microrganismos ou pela compressão. O processo de biodegradação não encerra até total consumo do substrato ou até que as condições de sobrevivência impeçam as atividades microbianas (HIRSCH, VERA e BRIONES, 2001).

Embora seja um processo natural, a decomposição dos RSU em um aterro sanitário é um processo complexo e para que ocorra um crescimento bacteriano satisfatório, todos os

microrganismos necessitam de condições mínimas para sobrevivência e posterior reprodução. Portanto, as fontes de nutrientes, oxigênio, pH, umidade e temperatura ideais são fatores essenciais para o seu desenvolvimento (MELO, 2011).

Segundo Salomani (2019), a biodegradação da matéria orgânica influencia nos parâmetros geotécnicos dos resíduos, pois envolve processos físicos, químicos e biológicos, nos quais a ação dos microrganismos governa a geração de gás, lixiviado e composição química, ocorrendo em cinco fases distintas: Aeróbia, caracterizada pela presença de oxigênio e curta duração; Anaeróbia ácida, ocorre até 2 meses após o aterramento, caracteriza-se pela hidrólise e formação de ácidos, com formação de bactérias facultativas; Anaeróbia metanogênica instável ou acelerada, até 2 anos de aterramento, fase de lenta formação de metano; Anaeróbia metanogênica estável, até 10 anos de aterramento, verifica-se alta e estável taxa de produção de metano; Metanogênica em declínio ou desacelerada: Bioestabilização de matéria orgânica e decréscimo da produção de metano.

A decomposição de resíduos, é um dos principais responsáveis pelos recalques em aterros sanitários observados a longos prazos, tendo em vista que há uma contínua transformação dos sólidos orgânicos em líquidos e gases. Por isso, a necessidade de realizar ensaios de caracterização dos resíduos aterrados para que se possa definir quão avançado está o processo de degradação. Desse modo, as características físico-químicas, biológicas e geotécnicas estão intimamente relacionadas em um maciço de RSU, e são determinantes para a evolução da biodegradação dos RSU ao longo do tempo (SHU *et al.*, 2022).

### **2.3 Características dos Resíduos Sólidos Urbanos**

Os RSU aterrados possuem três fases principais, a sólida, a líquida e a gasosa. A fase sólida compreende os resíduos em processo de degradação, a partir de processos físicos, químicos e biológicos, formando um meio poroso e gerando como subprodutos principais lixiviado (fase líquida) e gás (fase gasosa). Esses subprodutos podem estar preenchendo os vazios dos resíduos decompostos ou podem ser drenados de acordo com suas formas de tratamento.

A fase sólida, pode ser apresentada como a massa heterogênea de materiais aterrados. Uma forma de classificar esses materiais é a partir da norma alemã E 1-7 GDA (DGGT, 1994), que separa os RSU em: estáveis inertes altamente deformáveis e degradáveis.

O lixiviado, que representa a fase líquida dos resíduos de aterro, é o resultado de processos de biodegradação dos resíduos e da água que atinge a superfície, que pode ser

proveniente de sistemas de drenagem superficial, decantação e recirculação do próprio lixiviado (SALOMANI, 2019). A NBR 8419 (ABNT, 1996), define lixiviado (chorume) como “líquido, produzido pela decomposição de substâncias contidas nos resíduos sólidos, que tem como características a cor escura, o mau cheiro e a elevada Demanda Bioquímica de Oxigênio (DBO)”.

O subproduto gasoso tem em sua composição o metano, que é um elemento com possibilidade de reutilização na matriz energética. Porém, na maioria dos casos seu reaproveitamento não é econômico, devido ao baixo poder calorífico do metano e a surgência de problemas de corrosão dos equipamentos devido à presença de H<sub>2</sub>S (DUAN, SCHEUTZ e KJELDSEN, 2021). Portanto, quando não há a possibilidade de reaproveitamento do gás, os procedimentos de tratamento mais comuns consistem em queimá-los, convertendo-os em dióxido de carbono, óxidos de nitrogênio, dióxido de enxofre e outros gases.

### **2.3.1 Características físico-químicas dos Resíduos Sólidos Urbanos**

#### *2.3.1.1 Composição gravimétrica dos Resíduos Sólidos Urbanos*

A análise gravimétrica de RSU auxilia na classificação individual e na determinação dos percentuais em massa dos constituintes de determinado volume de resíduos, distribuindo em classes bem definidas como, por exemplo, matéria orgânica, recicláveis e rejeitos (BOSCOV, 2008).

Utilizando as recomendações da norma alemã *GDA Empfehlungen EI-7* (DGGT, 1994), podemos utilizar os grupos: plástico, matéria orgânica, vidro, metal, papel, papelão, têxteis sanitários, têxteis e couro, madeira, compósito (materiais constituídos pela junção de mais um tipo de material) e material misto.

Os dados sobre a composição gravimétrica dos RSU estão entre os mais fundamentais no campo da pesquisa de RSU. As informações de gravimetria podem ser associadas a dados bioquímicos e físicos sobre o RSU, auxiliando em sua interpretação, com finalidade de analisar o impacto ambiental do setor de gerenciamento de resíduos, planejar instalações de coleta e disposição de RSU e realizar políticas de redução e reciclagem de resíduos (JAUNICH *et al.*, 2019; ZHOU *et al.*, 2022).

A composição gravimétrica dos resíduos, é uma das características acerca dos RSU que sofre variação a partir de diversos parâmetros tais como: perfil socioeconômico, condições climáticas locais, demografia, grau de reciclagem e frequência de coleta de Resíduos Sólidos

Urbanos. O grupo de baixa renda apresenta uma alta proporção de composição de resíduos orgânicos, enquanto o grupo de alta renda apresenta uma geração relativamente maior de resíduos de papel, metais, vidros e resíduos diversos (YU *et al.*, 2013; WASTE ATLAS, 2018; CHENG *et al.*, 2020; SHAH *et al.*, 2021).

A composição gravimétrica média mundial, apresentada pelo *Waste Atlas* (2018), mostrou que cerca de 44% dos resíduos gerados consiste em matéria orgânica putrescível. Enquanto no Brasil, de acordo com a Abrelpe (2020), a composição gravimétrica apresentou aproximadamente 45,3% de matéria orgânica putrescível, um valor bem próximo do que a média mundial e menor que a média de 51,4% apresentada pelo Plano Nacional de Resíduos Sólidos (BRASIL, 2012). A aproximação dos percentuais, indicam o desenvolvimento do Brasil ao longo dos anos analisados, a Tabela 1 apresenta a comparação gravimétrica entre as principais características de RSU encontradas no Brasil e no Mundo.

Tabela 1 - Composição gravimétrica de RSU no mundo e no Brasil.

<b>Classe</b>	<b>Composição gravimétrica no mundo 2018 (%)<sup>1</sup></b>	<b>Composição gravimétrica no Brasil 2012 (%)<sup>2</sup></b>	<b>Composição gravimétrica no Brasil 2020 (%)<sup>3</sup></b>
Matéria Orgânica	44	51,4	45,3
Metal	4	2,9	2,3
Papel/Papelão e tetrapak	17	13,1	11,8
Plásticos	12	13,5	16,8
Vidro	5	2,4	2,7
Outros	18	16,7	21,1

Fontes: Adaptado de Waste Atlas (2018)<sup>1</sup>, adaptado de Brasil (2012) e Adaptado de Abrelpe (2020)<sup>3</sup>.

A composição gravimétrica dos RSU aterrados muda ao longo do tempo. Geralmente, o tamanho das partículas diminui, há a biodegradação do material e da forma dos materiais. Pode-se dizer, que a dinâmica de um aterro sanitário está entrelaçada com as frações de RSU que o compõe (PECORINI e IANNELLI, 2020). Dixon e Langer (2006) ressaltam a importância da composição dos resíduos, a curto e longo prazo, para o entendimento das alterações mecânicas durante a disposição e confinamento dos RSU. O Quadro 1 retrata cinco aspectos mecânicos das categorias de RSU.

Quadro 1 - Aspectos mecânicos para o RSU.

<b>Característica</b>	<b>Material</b>
Resistência a tração	Orgânicos, papel e metais.
Resistência a compressão	Cerâmicas, materiais inertes, vidro e metais.
Alongamento na ruptura	Polímeros e plásticos.
Módulo de elasticidade	Matais, cerâmicas, vidros e materiais inertes.
Resistência ao cisalhamento	Metais e materiais semelhantes a solos em maior proporção; papel, cerâmicas, vidros, polímeros e plásticos em menor proporção.

Fonte: Adaptado de Dixon e Langer (2006).

Os Resíduos Sólidos Urbanos têm composição bastante heterogênea, que em sua maioria possuem um conteúdo energético que pode ser recuperado por meio de processos termoquímicos, como na incineração, por exemplo. De acordo com Fallahizadeh *et al.* (2019), a incineração de RSU traz consigo diversos benefícios, como redução na massa (~70%) e volume (~90%), recuperação eficiente de energia e desinfecção completa de resíduos patogênicos. A Europa é um exemplo de utilização dessa tecnologia, onde grande parte do vapor gerado pela incineração de RSU está sendo utilizada para aquecimento urbano central, além da produção de energia elétrica.

### 2.3.1.2 Composição Volumétrica dos Resíduos Sólidos Urbanos

A composição volumétrica consiste na obtenção percentual dos volumes dos componentes dos RSU. Assim como a composição gravimétrica, o detalhamento das características é separado em classes, enfatizando cada tipo de resíduo identificado na análise.

A análise da composição volumétrica é pouco explorada na literatura, devido à falta de metodologias bem definidas. A determinação do volume ocupado pelos resíduos é essencial para o gerenciamento dos RSU, principalmente na etapa de destinação final, porque através desse método é possível determinar o volume aproximado que os RSU irão ocupar no aterro sanitário, portanto, é um importante parâmetro para estipular a vida útil do aterro sanitário e para avaliar a estabilidade geotécnica do maciço (CORRÊA, 2020).

Conhecer o volume dos materiais é fundamental para saber como se comporta esses resíduos no interior do maciço sanitário. Xie *et al.* (2022), relatam que, os resíduos plásticos

agem nos aterros sanitários como uma matriz de reforço, de modo similar a solos reforçados. Apesar do reforço aumentando a estabilidade de aterros de RSU, os plásticos ainda são um problema, por dificultar degradação da matéria orgânica e criar bolsões impermeáveis.

É importante ressaltar que entender como ocorre a degradação da fração orgânica depositada em aterros sanitários com o tempo. Melo *et al.* (2016), indicam que conforme a idade de aterramento do material putrescível, o volume de resíduos diminui e, consecutivamente, causa recalque devido a variação do volume no maciço.

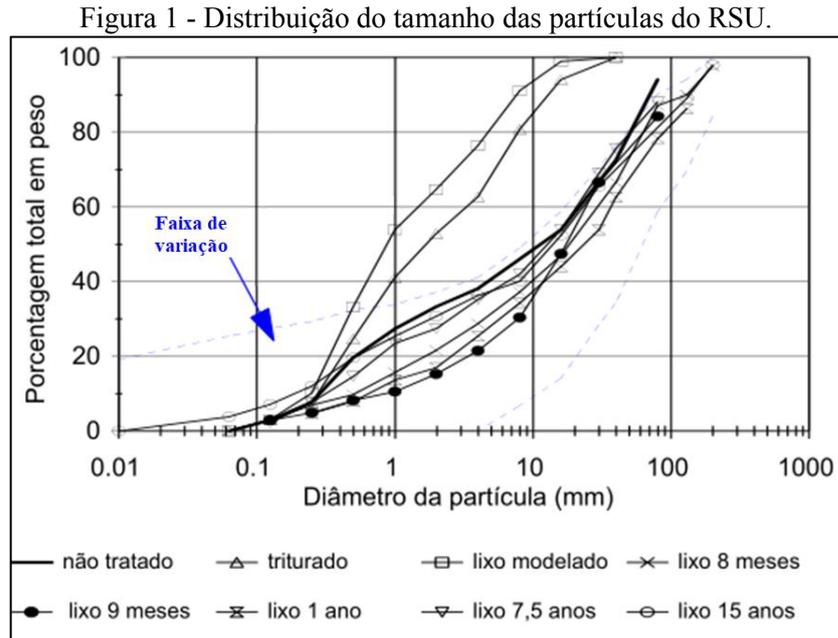
### 2.3.1.3 Tamanho das partículas dos Resíduos Sólidos Urbanos

Devido à grande heterogeneidade e variedade do RSU, não existe um método padronizado para a determinação da dimensão de suas partículas. Portanto, comumente para a análise dos tamanhos das partículas dos RSU utilizando-se a análise granulométrica clássica da mecânica dos solos (CORREA, 2013; SALAMONI, 2019).

Singh e Chandel (2020), reforçam que, a determinação da granulometria dos RSU é de grande importância para avaliar o comportamento do maciço, tendo em vista que, o tamanho das partículas influencia no movimento do material e na velocidade de degradação, parâmetros diretamente relacionados com a resistência ao cisalhamento dos RSU e consecutivamente para a avaliação da estabilidade dos taludes de aterros sanitários.

De acordo com o tamanho das partículas de RSU, pode-se caracterizá-los como material com elevado percentual de material grosseiro (partículas > 20mm) e com fração fina (partículas < 0,075 mm). A biodegradação da matéria orgânica presente nos RSU aumenta o percentual da fração mais fina dos resíduos com o tempo. Assim, os resíduos estabilizados têm uma tendência a ter uma granulometria mais fina do que os resíduos frescos (KNOCHENMUS *et al.* (1998); DIXON e JONES, 2005; CORRÊA, 2020).

A Figura 1 mostra, na cor preta, as curvas do tamanho das partículas para Resíduos Sólidos Urbanos com diferentes idades (MANASSERO *et al.* 1996) e, na cor azul, a faixa de variação típica para distribuição granulométrica do RSU sugerida por JESSBERGER (1994).



#### 2.3.1.4 Peso específico dos Resíduos Sólidos Urbanos

O peso específico dos resíduos sólidos relaciona o peso do material com o seu volume e tem grande efeito no assentamento do aterro e na estabilidade do talude. Em geral, à medida que os ingredientes residuais aumentam, o peso unitário varia, podendo aumentar ou diminuir, de acordo com a categoria de resíduos avaliada (YANG *et al.*, 2018).

O peso específico do RSU é necessário para muitas análises de engenharia de aterros sanitários, incluindo estabilidade e dinâmica de taludes, perfuração de geomembrana, esmagamento de tubos e avaliação da capacidade de aterros sanitários. No entanto, o valor do peso específico dos RSU continua a ser uma grande fonte de incerteza nas análises de desempenho de aterros sanitários, devido a heterogeneidade da composição, a saturação e o grau de degradação (ZEKKOS *et al.*, 2006).

A determinação do peso específico, depende essencialmente da composição gravimétrica, exemplo da presença de materiais leves ou putrescíveis, da distribuição granulométrica, pois quanto menores as partículas, mais fácil a formação de arranjos densos, do grau de compactação dos resíduos, devido ao aumento da densidade pela compactação e da idade dos resíduos, em que o peso específico e outras características aumentam a partir da degradação dos RSU (BOSCOV, 2008; BABU *et al.*, 2014).

Kavazanjian (2001) observa que o valor do peso específico na estabilidade de taludes “pode ser benéfico ou prejudicial, dependendo da idade do aterro e do período predominante

na análise”. Vale salientar que, além do peso específico médio, deve-se estudar a distribuição do peso específico, de acordo com as camadas de resíduos e o tempo de aterramento no maciço sanitário.

O peso específico de RSU é um parâmetro fundamental para determinação da vida útil do aterro sanitário, além de ser uma ferramenta para quantificar a quantidade de RSU gerada por uma determinada população. Os parâmetros peso específico aparente, umidade e peso específico dos sólidos podem ser utilizados na obtenção de outras características físicas do RSU, tais como índice de vazios, porosidade e grau de saturação, além de serem variáveis importantes em estudos de estimativa da compressibilidade de RSU (BREITMEYER, BENSON e EDIL, 2020).

Diversos autores, buscam compreender o comportamento do peso específico dos resíduos e relacioná-los com aspectos acerca da operação do aterro. Miranda (2004) afirma que o principal fator de influência no peso específico é a composição dos resíduos, porém ele também irá depender da compactação durante a execução do aterro, da decomposição dos resíduos com o tempo, da dissipação das poro-pressões dos líquidos e dos gases, e da consolidação dos resíduos devido à sobreposição de novas camadas. Alguns valores de peso específico de RSU publicados na literatura especializada são apresentados no Quadro 2.

Quadro 2 - Peso específico de Resíduos Sólidos Urbanos.

<b>Forma do RSU</b>	<b>Peso específico aparente (kN.m<sup>-3</sup>)</b>	<b>Fonte</b>
Resíduos em caminhões compactadores	2,0 - 3,9	Tchobanoglous (1993)
Compactação moderada	4,7 - 6,3	Oweis (1993)
Compactação excelente	8,6 - 9,4	
RSU recém-lançados	7,0	Santos e Presa (1995)
RSU após recalque	10,0	
Resíduos compactados e com alto teor de orgânicos	5,0 - 7,0	Kaimoto e Cepollina (1996)
Resíduos escavados em uma camada superficial de aterro	10,0 - 12,0	Zomberg <i>et al.</i> (1999)
Resíduos soltos	1,5 - 3,5	Abreu (2000)
Compactação moderada	3,5 - 6,5	
Compactação excelente	6,5 - 14,0	
Compactação variada	9,1 - 19,7	Miranda (2004)
RSU fresco	8,5	Reddy <i>et al.</i> (2009)
RSU fresco	2,0 - 4,0	Araújo Neto (2016)
RSU compactado	4,4 - 19,1	Araújo Neto (2021)

Fonte: Acervo de pesquisa (2022).

### 2.3.1.5 Umidade dos Resíduos Sólidos Urbanos

O teor de umidade dos RSU se trata de um parâmetro que apresenta a variação de líquido presente nos RSU. Esse parâmetro depende da composição inicial do material, das condições climáticas locais, do processo de operação dos aterros, da taxa de decomposição biológica, da capacidade e funcionamento dos sistemas de coleta de líquidos percolados e das camadas de base e de cobertura do maciço (CORRÊA, 2020).

Esse parâmetro, segundo autores como Tapahuasco (2009) e Remédio (2014), influencia a atividade microbiana de biodegradação, sendo um dos fatores críticos que afetam a biodegradação dos RSU, conseqüentemente, para geração de lixiviado e biogás. Como resultado, podem influenciar o comportamento mecânico da massa de resíduos. Altos valores de umidade acarretam aumento de poropressão nos maciços sanitários, que reduzem a tensão efetiva, resultando em menores valores de resistência ao cisalhamento (DACIOLO, 2020).

Diversos trabalhos foram desenvolvidos para determinação do teor de umidade dos RSU, o Quadro 3 mostra valores encontrados para diferentes condições e características dos RSU.

Quadro 3 - Teores de umidade de RSU.

Forma do RSU	Teor de umidade (%)	Temperatura (°C)	Fonte
Aterros e em caminhão compactador - EUA	15 - 40	105	Tchobanoglous (1993)
Aterro sanitário Bandeirantes/ SP - Brasil	50 - 100	70	Carvalho (1999)
Aterro metropolitano centro Salvador/BA - Brasil	60 - 140	70	Nascimento (2007)
Resíduos soltos de Campina Grande/PB - Brasil	40 - 60	65	Ribeiro (2012)
Região Metropolitana de Recife/PE - Brasil	9,48 – 10,47	65	Corrêa (2020)

Fonte: Acervo de pesquisa (2022).

### 2.3.1.6 pH dos Resíduos Sólidos Urbanos

No processo de biodegradação dos RSU, a análise do potencial hidrogeniônico (pH) pode indicar a evolução da degradação dos resíduos, por fornecer informações da condição ácida (H<sup>+</sup>) ou básica de um meio (OH<sup>-</sup>), interferindo nas atividades enzimáticas ou na toxicidade de algum composto. Na digestão anaeróbia, o pH tem comportamento diferenciado

devido a formação de várias substâncias, ácidas ou básicas, em todas as fases de degradação: hidrólise, acidogênica, acetogênica, metanogênica (RIBEIRO, 2012).

De acordo com Araújo Neta (2019), valores baixos de pH favorecem o crescimento de fungos, a decomposição da celulose e lignina (constituente da madeira) e os próprios microrganismos regulam automaticamente os valores do pH, porém, valores extremos podem inativar os seres vivos e os valores muito baixos de pH são indicativos de falta de maturação, por isso o pH é um indicador que diretamente está ligado a evolução temporal do comportamento dos resíduos.

De modo geral, o pH ótimo para o crescimento bacteriano está na faixa de valores entre 6,5 e 7,5, especialmente para microrganismos metanogênicos (TCHOBANOGLIOUS, THEISEN e VIGIL, 1993).

Desta forma, existe uma intrínseca relação entre o pH, o teor de ácidos graxos voláteis e a alcalinidade total que determina o sistema ácido/base, devendo esta relação ser mantida dentro de limites para que exista um equilíbrio químico satisfatório entre os microrganismos, pois podem inibir ou não o processo biodegradativo dos resíduos sólidos (RIBEIRO, 2021).

### *2.3.1.7 Teor de sólidos voláteis dos Resíduos Sólidos Urbanos*

Pode-se dizer que uma amostra de RSU, os Sólidos Totais (ST), podem ter em sua composição uma porcentagem de Sólidos Totais Voláteis (STV) e outra de sólidos não voláteis, que estarão inertes ou fixos. O procedimento para determinação do Teor de Sólidos Voláteis (STV) é realizado a partir da calcinação da amostra a 550°C, em que a fração orgânica será oxidada, reduzindo a massa inicial, qualificando, portanto, o SV como um parâmetro para avaliar a biodegradação dos RSU (LANGE *et al.* 2002; SALAMONI, 2019).

A heterogeneidade dos RSU é um dos fatores que complicam a utilização do teor de sólidos voláteis como análise de biodegradação dos resíduos. Isso deve-se principalmente por alguns materiais inorgânicos que possuem degradação de média a lenta apresentarem altos valores de STV. Valores estes, que podem ser equiparados com os STV de materiais que tem rápida degradação. Pode-se utilizar como exemplos os plásticos com degradação lenta (87% de STV) e os têxteis com rápida degradação (98% de STV) (SILVA e MOTA, 2019).

### 2.3.1.8 Demanda Química de Oxigênio (DQO) e Demanda Bioquímica de Oxigênio (DBO) dos Resíduos Sólidos Urbanos

A Demanda Química de Oxigênio (DQO) pode ser definida como a medida volumétrica da quantidade de oxigênio consumido para oxidação da fração orgânica e inorgânica com potencial oxidável existente na amostra aquosa produzida com o resíduo ou no lixiviado (NATH e DEBNATH, 2022). A análise de DQO, parte do princípio de que toda matéria orgânica pode ser oxidada sob condições ácidas e de elevadas temperaturas.

Geralmente encontram-se valores de DQO maiores que os valores de  $DBO_5$ , este fato dá-se pela existência de partes orgânicas resistentes à degradação biológica, e o valor de DQO tende a se distanciar dos valores de  $DBO_5$ , quanto mais significativas forem as frações de matéria orgânica resistente à oxidação biológica. Altos valores de DQO caracterizam resíduos frescos e baixos valores de DQO caracterizam resíduos que já se encontram em fase de degradação (CONTRERA, 2008; BERNAT *et al.*, 2021).

A Demanda Bioquímica de Oxigênio (DBO), pode ser definida como um parâmetro que indica a quantidade de matéria orgânica na amostra, porém ela determina como resultado a quantidade total de oxigênio requerida durante o processo de estabilização da matéria orgânica por microrganismos (ABREU, 2015; LOU *et al.*, 2020).

Segundo Cossu *et al.* (2012), a relação  $DBO_5/DQO$  retrata a biodegradabilidade da matéria orgânica presente na massa de RSU, que varia com a idade do aterro. O resíduo em sua fase inicial (estado fresco), apresenta razões maiores ou iguais a 0,5. Em aterros sanitários tidos como velhos, a razão  $DBO_5/DQO$  pode-se encontrar na faixa de 0,05 a 0,2, indicando pequena presença da matéria orgânica degradável no resíduo, por outro lado eles apresentam compostos orgânicos recalcitrantes, que são consumidos nos ensaios de DQO (EHRIG, 1988; TCHOBANOGLIOUS *et al.*, 1993).

## 2.3.2 Características geotécnicas dos Resíduos Sólidos Urbanos

### 2.3.2.1 Compactação dos Resíduos Sólidos Urbanos

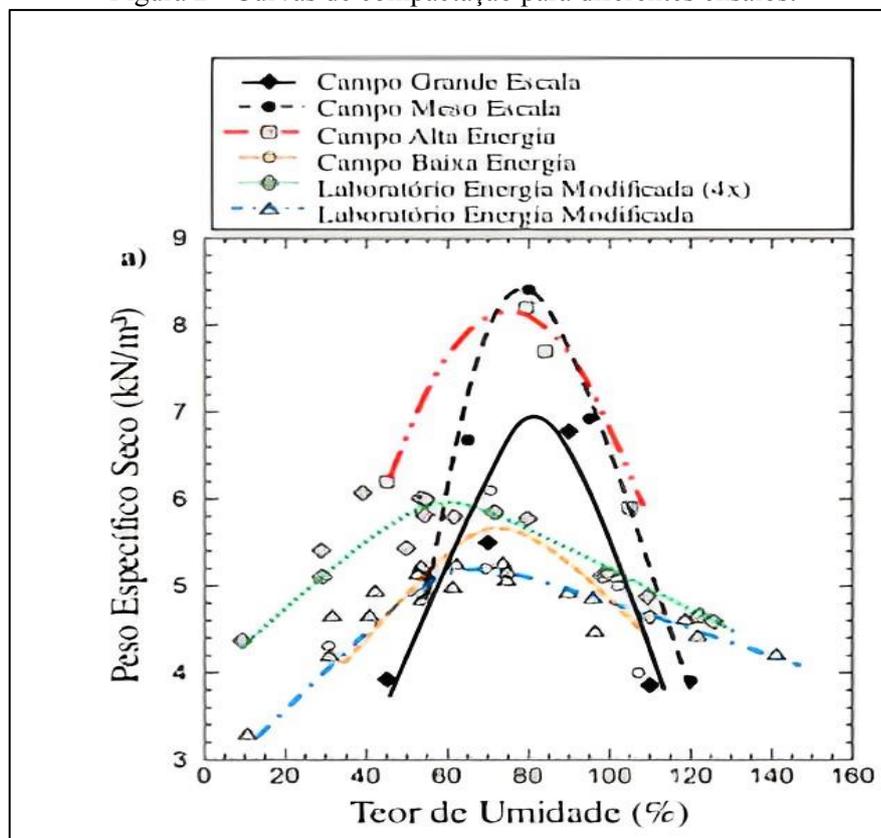
Fatores de operação do aterro sanitário como a vida útil do aterro, capacidade de alteamento, estabilidade de taludes, capacidade de carga da fundação, interfaces de cobertura e base e níveis de deformação do maciço, sofrem influências do nível de compactação dos RSU. Por outro lado, a compactação dinâmica do RSU, apresenta vantagens no aspecto de operação

dos aterros, pois pode reduzir o volume ocupado pelos RSU e melhorar as características mecânicas dessas estruturas, aumentando a densidade e reduzindo os recalques. Entre outras vantagens de uma boa compactação estão a redução da migração descontrolada de gases e lixiviados, diminuição da vazão de líquidos lixiviados, a possibilidade de tráfego imediato de veículos sobre o maciço e melhorias no aspecto estético da massa de resíduos aterrada (COX *et al.*, 2015; DACIOLO, 2020).

Durante a operacionalização de um aterro sanitário, as camadas sobrepostas de resíduos e o processo de decomposição da matéria orgânica acabam por promover uma redução volumétrica do aterro e alteram o seu comportamento geotécnico, principalmente, em relação à sua estabilidade e aos possíveis recalques. Portanto, uma boa compactação garante, também, aos maciços de um aterro sanitário, condições estruturais e de estabilidade (CATAPRETA *et al.*, 2006).

Observa-se na Figura 2, a variabilidade dos parâmetros de compactação das amostras de RSU e a variação do peso específico e da umidade.

Figura 2 - Curvas de compactação para diferentes ensaios.



Fonte: Adaptado de Cox *et al.* (2015).

Solos com composição que inclui o componente de reforço dos materiais fibrosos, apresentam um peso específico seco menor quando comparados com solos sem inclusão de fibras. Esta redução se deve à resistência de compactação de materiais fibrosos e ao fato de que estes possuem peso específico mais baixo do que os materiais granulares dos resíduos.

### 2.3.2.2 Resistência ao cisalhamento dos Resíduos Sólidos Urbanos

A determinação dos parâmetros de resistência ao cisalhamento (ângulo de atrito e coesão) e peso unitário dos RSU para o dimensionamento de aterros sanitários geralmente inclui testes de laboratório ou de campo, ou estimativas baseadas na literatura. Observações do comportamento tensão-deformação depende de fatores, como a composição, a densidade, o teor de umidade, a distribuição espacial dos componentes constituintes e a idade. A determinação da tensão cisalhante é um parâmetro fundamental, que influencia no desenvolvimento de projetos de revestimentos de aterros sanitários, de análise de estabilidade de taludes e fundações, de circulação de lixiviados e de sistema de camada de cobertura (DIXON e JONES, 2005).

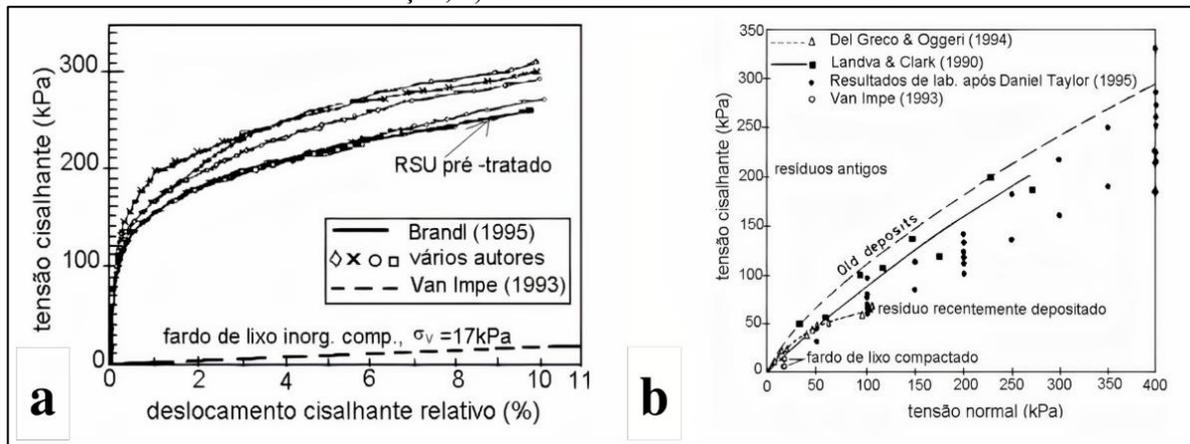
Segundo Karimpour-Fard *et al.* (2011), a resistência ao cisalhamento dos aterros sanitários, se assemelha ao comportamento de aterros de solos com reforços. Os RSU possuem duas matrizes, uma mista, constituída por compostos finos e granulares, e uma de reforço, na qual estão presentes componentes fibrosos e resistentes a tração.

Os ensaios de laboratório (triaxial e cisalhamento direto) tem sido os mais usados na avaliação da resistência do RSU, os quais vêm sendo executados em amostras construídas em laboratório e amostras deformadas coletadas de aterros sanitários. Uma das grandes dificuldades na realização desse ensaio é a dificuldade de obtenção de amostras de boa qualidade, pois deve-se tomar cuidado com a distribuição do tamanho dos grãos e a composição que represente as características aproximadas do RSU em determinados locais (KÖNIG e JESSBERGER, 1997; KNOCHENMUS *et al.*, 1998). Como informa Manassero *et al.* (1996), esse tipo de ensaio não reproduz o real comportamento do resíduo no aterro, mas serve como uma aproximação inicial para procedimentos mais exatos.

A Figura 3, apresenta resultados típicos ao se realizar ensaios de cisalhamento direto, além de comparar resultados obtidos por diversos autores. De acordo com Massanero *et al.* (1996), as curvas de resistência ao cisalhamento para RSU, apresentam um aumento contínuo de resistência de acordo com a deformação medida e nenhuma delas apresentou pico de resistência. Observa-se que, quando não há um pico, nas curvas de Tensão x Deformação

(Figura 3a), os parâmetros de resistência serão determinados a partir de uma deformação considerada admissível (10 a 15 %). Na Figura 3b, são apresentadas variações da tensão cisalhante ( $\tau$ ) com tensão normal ( $\sigma$ ) resultante de ensaios de cisalhamento direto.

Figura 3 - Curvas de tensão típicas de ensaios de cisalhamento direto com RSU. a) tensão cisalhante x deformação; b) tensão cisalhante x tensão normal.



Fonte: Adaptado de Massanero *et al.* (1996).

Para Keramati *et al.* (2019), a partir da análise dos parâmetros de resistência ao cisalhamento do RSU, pode-se gerar um modelo para prever o comportamento tensão-deformação do RSU em diferentes etapas de biodegradação e envelhecimento. Muitos pesquisadores se esforçaram para definir um modelo para prever o comportamento dos RSU nos últimos anos. Devido às várias composições, porcentagens e mudanças ao longo do tempo dos RSU, parece quase impossível desenvolver um modelo. No entanto, um critério pode ser estabelecido com base nas características e condições dos resíduos para desenvolver modelos preditivos úteis para projetar novos aterros em áreas semelhantes às áreas designadas (KERAMATI, 2019).

Kölsch (1995) apresentou um modelo de resistência dos RSU onde a envoltória de resistência é bi-linear, no qual a inclinação íngreme da envoltória de resistência se deve ao reforço das fibras, enquanto a variação da inclinação acontece quando a resistência à tração alcança seu valor máximo e deixa de contribuir para a resistência ao cisalhamento, passando a representar apenas a parcela referente ao atrito. Araújo Neto (2021), desenvolveu uma pesquisa utilizando recursos de inteligência artificial, para determinação dos parâmetros de intercepto coesivo e ângulo de atrito em RSU com diferentes idades de aterramento.

## 2.4 Análise descritiva de dados

A estatística clássica baseia-se na análise descritiva geral de uma série pré-determinada de dados e permite uma visão inicial dos aspectos gerais de um banco de dados. A estatística descritiva utiliza apenas os valores obtidos nas amostras e sem considerar sua posição. As principais discretizações realizadas são: distribuição de frequências, média, desvio padrão e coeficiente de variação (PAIVA, 2009).

Como as amostras experimentais apresentam erros, a estatística descritiva auxilia nas observações preliminares quanto a medidas de tendência central, de dispersão e medidas de forma. Estas análises fornecem uma maior confiabilidade aos dados coletados e indicam uma tendência inicial do comportamento dos parâmetros observados (BUSSAB e MORETTIN, 2017).

### 2.4.1 Correlação Linear de *Pearson*

A matriz de correlação é utilizada para iniciar a análise estatística dos dados históricos dos diversos universos estudados, identificando visualmente as variáveis envolvidas no estudo que se relacionam entre si. A determinação do grau de relação entre duas variáveis é dada pelo coeficiente de *Pearson*, também chamado de coeficiente de correlação, ou simplesmente correlação para os pares de variáveis. Esse coeficiente é um número entre -1 e 1 que expressa o grau de dependência linear entre duas variáveis quantitativas, que quando negativa indica que uma variável diminui com o aumento da outra, e positiva quando uma variável aumenta com o aumento da outra (JOHNSON; WICHERN, 2007).

Segundo Cressie (2015), em estatística espacial, o correlograma (ou função de correlação) reflete graficamente a estrutura de dependência de um processo espacial subjacente e como essa estrutura de dependência muda com a distância geográfica. O correlograma é o gráfico utilizado em séries temporais para traçar as autocorrelações em diversas defasagens. A análise desse gráfico permite entender se a série é aleatória ou possui alguma tendência ou sazonalidade (YANG, 2022).

### 2.4.2 Análise de componentes principais

A Análise de Componentes Principais (ACP) é uma técnica estatística de análise multivariada que transforma linearmente um conjunto original de variáveis, inicialmente

correlacionadas entre si, num conjunto substancialmente menor de variáveis não correlacionadas que contém a maior parte da informação do conjunto original. A ACP é a técnica mais conhecida e está associada à ideia de redução de massa de dados, com menor perda possível da informação (HONGYU e SANDANIELO, 2016).

Autores como Kumari *et al.* (2019), avaliaram, a partir de ACP, as características do lixiviado, de um grande número de aterros sanitários em todo o mundo, para descobrir possíveis semelhanças ou diferenças entre os parâmetros físico-químicos avaliados. No município de Rolândia - PR, Golçalves *et al.* (2019), utilizaram dados físico-químicos de lixiviado e solos para correlacionar e identificar, a partir de ACP, os principais parâmetros que podem ser utilizados como indicadores de contaminação. Já Ergene, Aksoy e Sanin (2022), aplicaram a metodologia de ACP para avaliação da contaminação das águas subterrâneas dentro e ao redor do aterro municipal de resíduos sólidos de Ghazipur, localizado na Índia.

## **2.5 Modelagem não constitutiva com Redes Neurais Artificiais**

Inspiradas essencialmente no funcionamento de um neurônio biológico, as Redes Neurais Artificiais (RNA) são modeladas matematicamente operando a partir de um conjunto de neurônios artificiais. As RNA são frequentemente usadas para análise estatística e modelagem de dados, sendo uma alternativa às técnicas padrões de regressão não linear ou análise de cluster e em problemas de classificação e previsão. Entre suas características pode-se destacar a capacidade de aprendizado e processamento de um conjunto de dados, além da capacidade de resolução de problemas não lineares (CHENG e TITTERINGTON, 1994; GURNEY, 1997; HAYKIN, 2001; GOES *et al.*, 2019).

Globalmente, vem ganhando-se força uma mudança no paradigma dos modelos clássicos por modelos inteligentes utilizando RNA. Diversos autores utilizam RNA em campos práticos, como: realização a estimativa da composição dos RSU (MA *et al.*, 2020; AYELERU *et al.*, 2021); análise de imagem cardíaca a partir de tomografia para estimar se acúmulo de placas estreitou as artérias coronárias (TESCHE e GRAY, 2020); compressão de vídeos e imagens (MA *et al.*, 2020); previsões diárias de pico de carga de eletricidade e do horário em que ocorre o pico (MILOJKOVIŪ *et al.*, 2012) e previsão da demanda de biodiesel em um país (CAIRES e SIMONELLI, 2021).

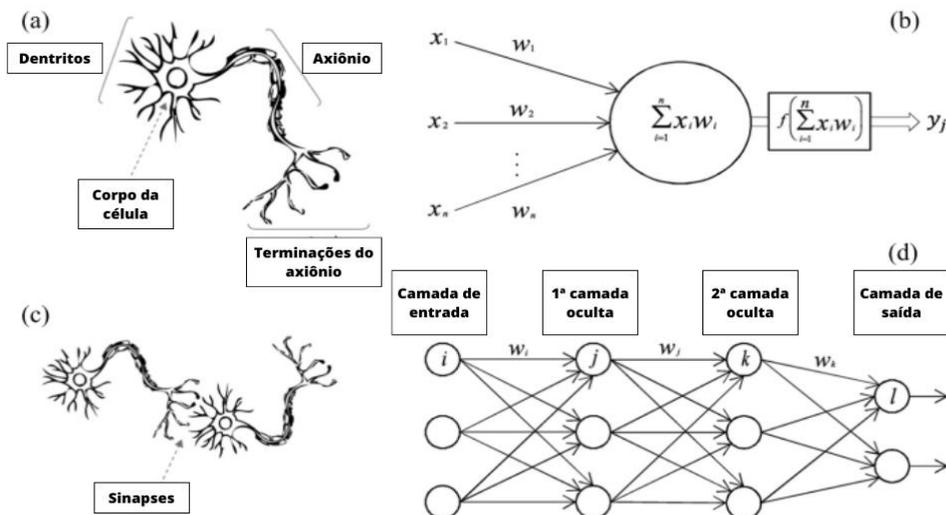
### 2.5.1 Fundamentos das Redes Neurais Artificiais

O objetivo da neurociência computacional é encontrar explicações mecanicistas sobre como o sistema nervoso processa informações para apoiar a função cognitiva, bem como o comportamento adaptativo. O grande desafio é, portanto, definir modelos que expliquem as medidas neurais, bem como o comportamento adaptativo complexo. O cérebro é uma rede neural recorrente profunda que explora transformações não lineares em vários estágios e dinâmicas complexas. Portanto, parece inevitável que a neurociência computacional venha a confiar cada vez mais em modelos complexos, provavelmente da família de redes neurais recorrentes profundas (KIETZMANN, 2018).

O cérebro humano é um sistema de computação complexo capaz de pensar, lembrar e resolver problemas. Houve várias tentativas de emular as funções cerebrais com um modelo de computador e, geralmente, envolveu a simulação de uma rede de neurônios, comumente chamada de redes neurais. O cérebro contém aproximadamente 100 bilhões de neurônios que estão densamente interconectados com mil a dez mil conexões por neurônio (HAYKIN, 2001; SUZUKI, 2013).

De acordo com MENG, HU e ANCEY (2020), um neurônio é a unidade celular fundamental do sistema nervoso do cérebro. Nele ocorre o processamento simples (soma) que recebe e combina sinais de outros neurônios por meio de caminhos de entrada chamados dendritos que contêm junções sinápticas. Os componentes básicos de um neurônio são mostrados na Figura 4a e seus equivalentes esquemáticos na Figura 4b.

Figura 4 - Comparação entre neurônio biológico e artificial. (a) Neurônio biológico humano; (b) Neurônio artificial; (c) Rede de neurônios sinápticos; (d) Rede Neural Artificial.



Fonte: Adaptado de Suzuki (2013).

Se o sinal combinado de todos os dendritos for forte o suficiente, o neurônio "dispara", produzindo um sinal de saída ao longo de um caminho, chamado axônio. O axônio se divide e se conecta a milhares de dendritos (caminhos de entrada) de outros neurônios, por meio de sinapses, (junções contendo um fluido neurotransmissor que controla o fluxo de sinais elétricos) localizadas nos dendritos. A Figura 4c mostra como ocorre a conexão sináptica no neurônio biológico e a Figura 4d demonstra a equivalência em RNA. A transmissão dos "sinais através das sinapses é de natureza eletroquímica, e as magnitudes dos sinais dependem das forças sinápticas das junções sinápticas (UHRIG, 1995).

Outra categoria de pesquisa, são as Redes Neurais Biológicas (RNB), que se concentra na construção de que podem emular as características biológicas, estruturais e funcionais das RNB. Esta categoria usa modelos simplificados e controláveis para testar novas teorias de funções cerebrais derivadas dos dados de RNB e testar novas drogas nas doenças relacionadas ao cérebro. As RNA também podem fornecer plataformas de computação semelhantes ao cérebro (ZHANG et. al, 2019).

A maioria dos neurônios em RNA, como suas contrapartes biológicas, realizam cálculos não lineares com base em suas entradas. Esses neurônios são geralmente neurônios pontuais com uma única função de ativação não linear que liga a soma das entradas à atividade de saída. A não linearidade é essencial para o poder das RNA (YANG e WANG, 2020).

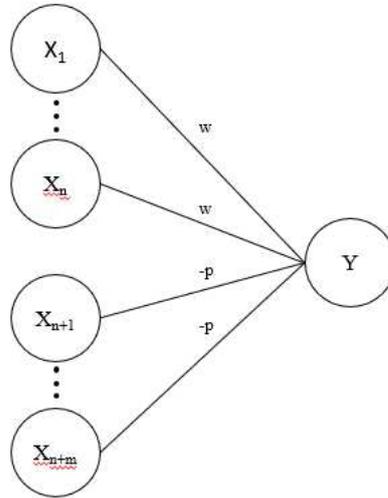
### **2.5.2 Breve histórico acerca das redes neurais artificiais**

A história das redes neurais é mais longa do que a maioria das pessoas pensam. Carvalho (2019) relata que, embora a ideia de “uma máquina que pensa” possa ser relatada desde os gregos antigos, o entendimento das RNA deve-se iniciar a partir dos primeiros estudos concretos realizados por McCulloch e Pitts (1943). Eles propuseram um modelo matemático que representa o comportamento do neurônio e da rede de neurônios que formam o cérebro no artigo “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”.

A pesquisas de McCulloch e Pitts (1943), comparam o funcionamento das RNA com o funcionamento dos neurônios biológicos. Assim, eles podem descrever o sistema nervoso humano como uma rede de neurônios, cada um com um corpo celular e um axônio. Suas adjunções, ou sinapses, estão sempre entre o axônio de um neurônio e o corpo celular de outro. Os neurônios sofrem um tipo de excitação iniciando um impulso que conduz informação, essa atividade é denominada lei do “tudo ou nada” (*all-or-one*) da atividade nervosa, e é suficiente

para assegurar que a atividade de qualquer neurônio seja representada como uma lógica proposicional. O neurônio de McCulloch e Pitts está representado na Figura 5.

Figura 5 - Arquitetura do neurônio McCulloch-Pitts.



Fonte: Adaptado de Chakraverty, Sahoo e Mahato (2019).

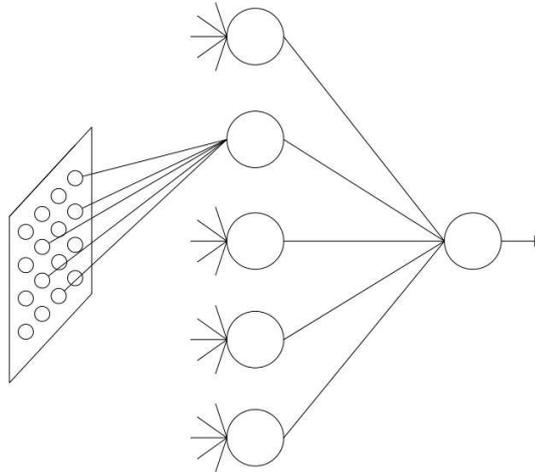
Portanto, se traduzida para uma perspectiva biológica, a suposição de McCulloch e Pitts (1943), implicava que, todas as entradas para o neurônio poderiam ser somadas diretamente, ou seja, o internamente eram executadas ao mesmo tempo. Entretanto, um dos pontos que diferia do neurônio biológico, é que nesse caso, o neurônio artificial permitia que a magnitude da entrada contribuísse para o estado interno.

Uma das principais ideias que surgiram a partir da pesquisa de McCulloch e Pitts (1943), foi a comparação de neurônios com um limiar binário e lógica *booleana* (0 e 1 ou declarações verdadeiro e falso), ou seja, o neurônio dispara com a entrada 1 e fica neutro com entrada 0. Os caminhos de informações nos neurônios ainda tinham a característica de serem excitatórios (Figura 5), caso as conexões sinápticas representadas por  $w$  fossem maiores que 0, senão são considerados inibitórios e suas conexões sinápticas são representadas por  $-p$  (GHOSH-DASTIDAR, 2009; CHAKRAVERTY, SAHOO e MAHATO, 2019).

Considera-se como o segundo momento marcante, no desenvolvimento das RNA, a teoria desenvolvida por Frank Rosenblatt (1958), que considerou um sistema nervoso hipotético, chamado de *perceptron*. Em seu trabalho intitulado “*The perceptron: a probabilistic model for information storage and organization in the brain*” Frank Rosenblatt (1958), percebeu que diferentemente dos organismos biológicos, os *perceptrons* ilustravam algumas propriedades de sistemas inteligentes, porém sem se aprofundar em condições especiais. Um

*perceptron*, mesmo com um único nível lógico e uma camada de resposta, pode mostrar uma série de propriedades interessantes em problemas de classificação de padrões linearmente separáveis, a Figura 6 demonstra a arquitetura do *perceptron* de Rosenblatt.

Figura 6 - *Perceptron* de Rosenblatt.



Fonte: Adaptado de Rosenblatt (1958).

O *perceptron* de Rosenblatt usou uma camada de elementos de processamento fixo para transformar os dados brutos de entrada. Esses elementos de processamento podem ser vistos como as funções de base de um discriminante linear generalizado com a forma de pesos adaptativos conectados a uma transformação não linear fixa do vetor de entrada e uma função de ativação de limiar (ZAMORA-CÁRDENAS *et al.*, 2020). Comparando os estudos de Rosenblatt (1958) com McCulloch e Pitts (1943), observa-se, sua principal contribuição diz respeito a introduções de pesos na equação. Para comprovar a efetividade do *perceptron*, Rosenblatt utilizou um computador IBM 704, que conseguiu aprender a distinguir cartões, que estavam marcados à esquerda de outros cartões marcados à direita.

Os modelos ADALINE e MADALINE do neurônio, que partem do princípio da adaptação linear (*ADaptive LINEar*), foram propostos por Widrow e Hoff (1960). O modelo ADALINE, reconhecia padrões binários de modo que, se recebesse uma frequência binária na entrada poderia realizar previsões dos próximos bits a serem lidos. O modelo MADALINE foi o primeiro modelo de rede neural aplicado a um problema do mundo real, pois utilizando um filtro com adaptação em tempo real pode eliminar ecos em linhas telefônicas (CASTELO BRANCO, 2016).

Apesar de ser topologicamente semelhante ao *perceptron*, os modelos de Widrow e Hoff (1960), ajustam os pesos sinápticos utilizando o chamado algoritmo do mínimo quadrado médio

(LMS, *Least Mean-Square*), também conhecido como algoritmo do gradiente estocástico. A função calculada é simplesmente a combinação linear dos pesos e das entradas, ou equivalentemente o produto interno do vetor de pesos e o vetor das entradas.

O ritmo dos estudos sobre RNA desacelerou nos anos 70, porém em 1982, vários eventos renovaram os interesses. Hopfield (1982) apresentou um documento que objetivava criar dispositivos úteis a partir de RNA, não simplesmente modelar cérebros. Para isso, ele utilizou uma função de energia para formular um novo modo de se entender a computação por redes recorrentes com conexões sinápticas simétricas. Esse novo modelo, denominado como redes de Hopfield, embora não se apresentasse como modelos realísticos dos sistemas neurobiológicos, elas partem do princípio de armazenamento de informação em redes dinamicamente estáveis, esse é o ponto de início do que se conhece como retropropagação e aprendizado profundo (HAYKIN, 2001).

Esse campo de pesquisa explodiu mesmo em 1986, com o livro confeccionado por Rumelhart, Hinton e William (1986), no qual, apresentam um modelo matemático e computacional que propicia o treinamento supervisionado dos *perceptrons* de múltiplas camadas. Surgia, então, o algoritmo *backpropagation*, um algoritmo de otimização global sem restrições, que distribuem erros de reconhecimento de padrões em toda a rede. O resultado é que as redes de *backpropagation* “aprendem” de forma mais lenta, pois necessitam, possivelmente, de milhares de iterações para aprender, mas geram um resultado muito preciso.

A promessa do aprendizado profundo (*Deep Learning*) não é que os computadores comecem a pensar como seres humanos. Entretanto, o *Deep Learning*, busca melhorar o processamento de dados em um computador, para que este seja capaz de realizar atividades, que antes eram realizadas apenas por seres humanos, como reconhecer imagens e voz, criar obras de arte ou tomar decisões por si mesmo.

### **2.5.3 Topologias de redes neurais artificiais**

De modo geral, as RNA estão recebendo cada vez mais atenção por causa de sua capacidade de expressar funções complexas de forma flexível. Um modelo típico de RNA consiste em três partes principais: regras de aprendizado, arquitetura de rede e uma função de ativação. A estrutura da rede é formada por várias camadas: uma camada de entrada, uma camada de saída e uma ou várias camadas ocultas, com cada camada contendo vários neurônios. Cada um dos neurônios em uma camada está conectado aos neurônios das camadas adjacentes por meio de coeficientes chamados ponderações (MENG, HU e ANCEY, 2020).

### *2.5.3.1 Métodos de aprendizagem de redes neurais artificiais*

A principal propriedade de uma rede neural é sua capacidade de aprender com o ambiente ao qual está inserida e melhorar seu desempenho por meio do aprendizado. A melhoria do desempenho ocorre ao longo do tempo de acordo com uma medida predefinida. Uma rede neural aprende sobre seu ambiente por meio de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de viés. Idealmente, após cada iteração do processo de aprendizagem, a rede torna-se mais bem informada sobre o ambiente (HAYKIN, 2001).

Os dois tipos de aprendizados mais utilizados de treinamentos com RNA são o aprendizado supervisionado e o não-supervisionado. De acordo com Verma, Singh e Dixit (2022), o aprendizado supervisionado é uma abordagem de aprendizado que é usada para treinar a base do modelo em dados de treinamento rotulados, esses dados contam com valores de entrada e saída, capacitando a RNA a fornecer respostas para cada vetor de treinamento. A segunda etapa consiste na verificação do erro, entre a resposta fornecida pelo modelo e a resposta real a qual a rede está calibrada, desta forma o sistema de aprendizagem vai sendo modificado, objetivando minimizar os erros.

Métodos baseados aprendizagem não supervisionada têm um impacto significativo no problema de detecção de anomalias. Esses métodos de aprendizado não possuem nenhum conhecimento prévio e são baseados no princípio de que eventos normais ocorrem várias vezes e eventos anormais ocorrem com pouca frequência ou raramente. Nessa situação, os algoritmos devem “aprender” os relacionamentos ou recursos subjacentes dos dados disponíveis e agrupar casos com recursos ou características semelhantes (BERRY, MOHAMED e YAP, 2019).

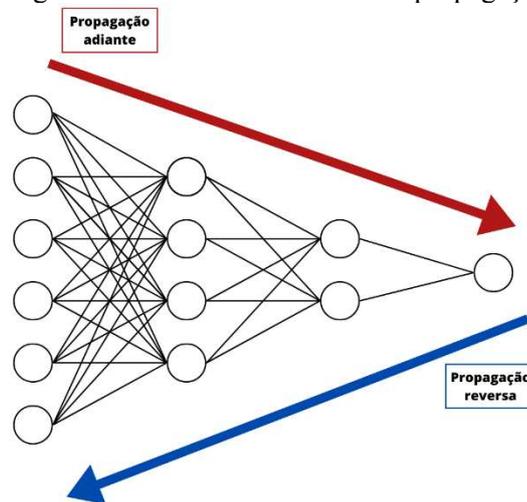
### *2.5.3.2 Arquiteturas de redes neurais artificiais*

Em um projeto de RNA, inicialmente deve-se escolher o objeto de estudo e definir o banco de dados a ser utilizado, em seguida, faz-se a escolha da arquitetura neural a ser trabalhada. Após a definição do banco de dados do projeto deve-se escolher a arquitetura da RNA. Segundo Chokshi, Dashwood e Hughes (2017), determinar a arquitetura do modelo é uma das tarefas mais importantes e difíceis no desenvolvimento de modelos de RNA. Como não existe uma teoria geral para relacionar arquiteturas de rede a funções neurais específicas, aplica-se algoritmos genéticos para buscar soluções modulares ótimas. A escolha da arquitetura de rede para aprender uma tarefa é um trabalho visual, já que é possível avaliar qual modelo apresentou melhor desempenho em relação ao sistema natural (HAPPEL e MURRE, 1994).

Atualmente, as RNA do tipo *feedforward* (passo à frente) estão sendo usadas em uma variedade de aplicações com grande sucesso. De acordo com Benardos e Vosniakos (2007), a principal vantagem em utilizar redes *feedforward* é que eles “aprendem” com exemplos, não requerendo um algoritmo de resolução de problemas especificado pelo usuário. Sua segunda vantagem principal é que eles possuem uma capacidade inerente de generalização. Isso significa que eles podem identificar e responder a padrões semelhantes, mas não idênticos àqueles com os quais foram treinados.

Associado ao método *feedforward* é utilizado o método de retropropagação de erro também chamado de *backpropagation*, que consiste, de forma resumida, em duas fases. Na primeira fase, denominada *forward* (propagação adiante), a alimentação de dados é realizada na etapa de entrada da rede e as respostas são obtidas a partir dos cálculos envolvendo os bias e pesos sinápticos adotados inicialmente. Em seguida, realiza-se a etapa *backward* (propagação reversa) com alimentação da saída para a entrada, realizando-se os ajustes no *bias* e pesos sinápticos da rede, de forma a reduzir o erro. As duas fases são realizadas simultaneamente durante o processo de aprendizagem, conforme a Figura 7 (SILVA, SPATTI e FLAUZINO, 2010).

Figura 7 - Funcionamento da retropropagação.



Fonte: Acervo de pesquisa (2022).

Para selecionar a melhor arquitetura para as redes do tipo *feedforward* deve-se considerar basicamente quatro aspectos, são eles: número de camadas, número de neurônios em cada camada, função de ativação de cada camada e algoritmo de treinamento (porque ele determina o valor final dos pesos e *bias*) (DONGARE *et al.*, 2012; SHARKAWY, 2020).

### 2.5.3.2.1 Camadas ocultas e número de neurônios

Uma RNA pode ter várias camadas com neurônios distribuídos entre elas. A primeira camada é onde os dados de entrada da rede vão ser inseridos. A camada intermediária ou camada oculta, é responsável pelos processamentos da rede, podendo existir mais de uma camada oculta, dependendo do tipo de processo exigido. A última camada é definida como de saída, que recebe os valores já processados pela rede.

Os neurônios localizados nas camadas ocultas agem como detectores de características, ou seja, conforme o processo de aprendizagem avança, os neurônios ocultos começam a identificar características associadas a perfis do banco de dados de treinamento. Para isso, intrinsecamente, eles realizam uma transformação não linear dos dados de entrada para um espaço oculto, ou espaço de características (HAYKIN, 2001).

O número de neurônios da(s) camada(s) oculta(s) é definido levando-se em consideração o funcionamento da rede. Não existe uma regra geral que defina o número de camadas escondidas, esse número pode variar de 0 até n camadas. Alguns autores citam a regra de Hilton para definir o número de nós que as camadas intermediárias da rede devem ter. Essa regra afirma que o número de nós da segunda camada oculta não deve exceder a um terço ( $1/3$ ) do valor da primeira camada oculta (MIRANDA, DE FREITAS e FAGGION, 2009).

Vale ressaltar que é muito mais fácil garantir a convergência de treinamento de redes neurais maiores, mas esse sucesso costuma ser enganoso, porque redes neurais com um número excessivo de neurônios não têm boa interpolação habilidades e não consegue lidar adequadamente com novos padrões que não foram utilizados no processo de treinamento (WILAMOWSKI, 2009).

### 2.5.3.2.2 Funções de ativação

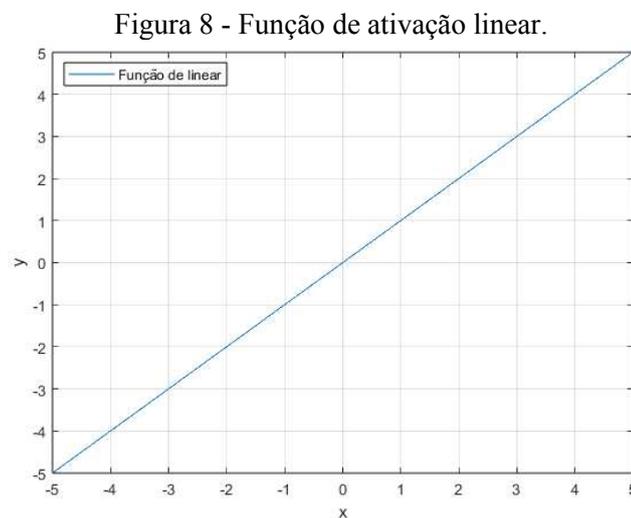
A Função de Ativação (FA) refere-se à característica de neurônios ativados poderem ser retidos e mapeados por uma função não linear, que pode ser usada para resolver problemas não lineares. A função de ativação é usada para aumentar a capacidade de expressão do modelo de rede neural, o que pode fazer com que a rede neural tenha o significado de inteligência artificial (WANG *et al.*, 2020)

As funções de ativação são basicamente divididas em dois tipos, funções de ativação lineares e funções de ativação não-lineares. Onde as funções de ativação linear mantêm uma

constante, as funções de ativação não lineares criam mais variação que utiliza a construção da rede neural.

Pode-se dizer que FA linear não adiciona não linearidade à rede, mas para melhores resultados a não linearidade precisa ser introduzida nas RNA. Caso contrário, uma rede neural produz a saída como uma função linear das entradas, apesar de ter várias camadas. Além disso, na prática, os dados geralmente não são separáveis linearmente; portanto, as camadas não lineares ajudam a projetar os dados de maneira não linear no espaço de recursos que pode ser usado com diferentes funções objetivas (DUBEY, SINGH e CHAUDHURI, 2022).

Uma função linear (*purelin*) pode ser considerada como um FA simples que produz  $kx$  para a entrada  $x$  com  $k$  como uma constante (Figura 8).



Fonte: Acervo de pesquisa (2022).

A função linear está expressa na Equação 1.

$$\text{função linear}(x) = kx \quad (1)$$

Sendo:

função linear ( $x$ ) = variável dependente;

$k$  = constante;

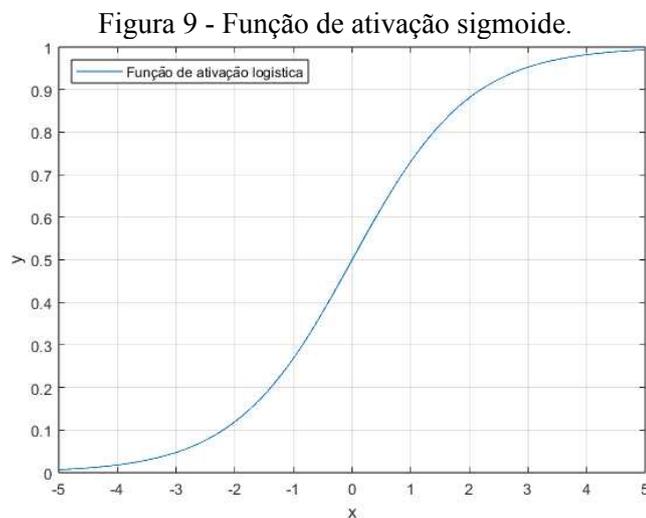
$x$  = variável independente.

A função logística ou sigmoideal é uma das mais utilizadas em treinamentos com RNA e é definida como uma função crescente com balanceamento adequado entre o comportamento linear e não linear e assume um intervalo de variação entre 0 e 1 (FLECK et al, 2016). A Equação 2, mostra a definição desta função.

$$\text{função logística } (x) = \frac{1}{1 + e^x} \quad (2)$$

Sendo:  
 função logística (x) = variável dependente;  
 x = variável independente.

A curva da função sigmoide (*logsig*) é mostrada na Figura 9, que é uma função de ativação não linear comum.



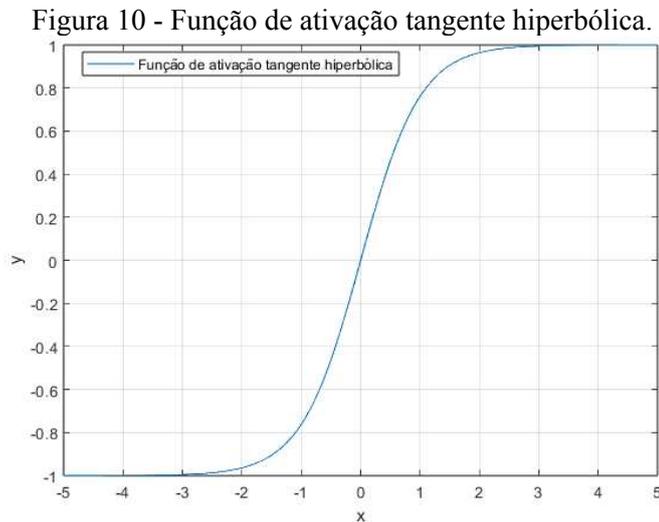
Fonte: Acervo de pesquisa (2022).

Observando, a inclinação do gráfico tende a ser zero quando a entrada é muito grande ou muito pequena. Quando a inclinação da função é próxima de zero, o gradiente que passou para a rede subjacente torna-se muito pequeno, o que dificultará o treinamento efetivo dos parâmetros da rede. Enquanto isso, a direção da atualização do peso apenas em uma direção devido à saída dessa função é sempre positiva, o que afetará a taxa de convergência (DUBEY SINGH e CHAUDHURI, 2022).

A função tangente hiperbólica (*tansig*) também tem sido usada como FA em redes neurais. É semelhante à função Logistic Sigmoid enquanto exhibe a propriedade centrada em zero. A Equação 3 representa o comportamento da FA tangente hiperbólica.

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (3)$$

Comparada com a Função Sigmoide, a função Tansig também é não linear, mas ao contrário da Sigmoide, sua saída é centrada em zero e comprime um número de valor real no intervalo  $[-1, 1]$ , portanto, pode existir explosão das ativações (FENG e LU, 2019). Observa-se este comportamento para a FA Tansig na Figura 10.



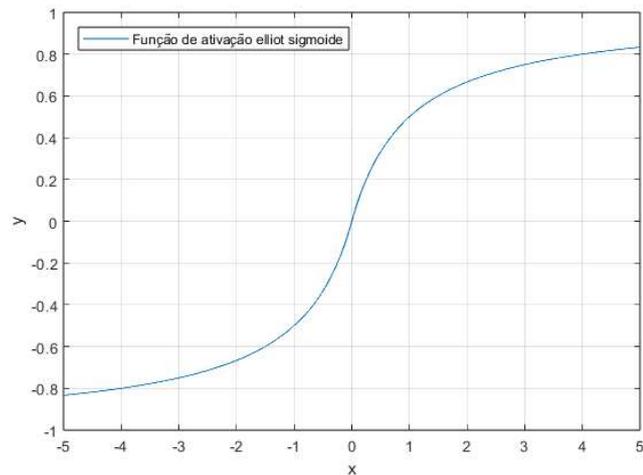
Uma função que vem tomando espaço é a FA de transferência sigmoide simétrica de Elliot (Equação 4). A vantagem desta função de transferência sobre outros sigmóides é que ela é rápida para calcular em hardware de computação simples, pois não requer nenhuma função exponencial ou trigonométrica (NGUYEN, FERNANDES e TEIXEIRA, 2022).

$$f(x) = \frac{x}{\sqrt{1+x^2}} + 0,5 \quad (4)$$

Sendo:  
 função logística (x) = variável dependente;  
 x = variável independente.

A função de ativação Elliot Simétrica (Figura 11) mapeia a saída em um intervalo de  $[-1, +1]$  e é uma aproximação mais rápida da tangente hiperbólica (SALMERON e RUIZ-CELMA, 2018).

Figura 11 - Função de ativação sigmoide simétrica de Elliot.



Fonte: Acervo de pesquisa (2022).

#### 2.5.3.2.3 Algoritmos de treinamento

Existem muitos tipos diferentes de RNA, no caso de utilização para análise de dados, é importante distinguir entre modelos RNA (o arranjo da rede) e algoritmos de treinamento de RNA (cálculos que eventualmente produzem as saídas da rede (AGATONOVIC-KUSTRIN e BERESFORD, 2000). Segundo Guimarães *et al.* (2008), a escolha da rede neural é o estágio decisivo durante o treinamento, pois, a RNA é submetida a fatores que influenciam no aprendizado, o algoritmo de treinamento e o número de épocas (ciclos ou iterações).

Os algoritmos de RNA usam métodos de otimização não lineares locais ou globais para otimizar os pesos das redes neurais *feedforward*. O desempenho do treinamento varia com base na função objetivo do processo de otimização e na superfície de erro subjacente para um determinado problema. Os algoritmos amplamente utilizados são *Levenberg-Marquadt (LM)*, *BFGS Quasi Newton*, *Resilient Back-Propagation*, *Scaled conjugate gradient*, *Conjugate gradient with Powell-Beale restarts*, *Fletcher-Powell conjugate gradient*, *Polak-Ribiere conjugate gradient*, *One step secan* (BAPTISTA, RODRIGUES e MORGADO-DIAS, 2020; ANUSHKA e UPAKA, 2020; ADELEKE *et al.*, 2021).

#### 2.5.4 Verificação estatística dos resultados

A avaliação do desempenho dos modelos não constitutivos é uma tarefa importante, que auxilia na identificação dos melhores modelos que representem com precisão o comportamento do banco de dados. Vários estudos desenvolvidos para resolução de problemas relacionados a

composição ou geração de resíduos sólidos aplicam várias métricas de desempenho para avaliação da performance da RNA. Por exemplo, Adeleke *et al.* (2021) aplicou a raiz quadrada do erro médio (RMSE), o desvio absoluto médio (MAD), a porcentagem de erro absoluto médio (MAPE) e o coeficiente de correlação (R); Ma *et al.* (2020), aplicaram o coeficiente de determinação ( $R^2$ ) e o erro quadrático médio (MSE); Adamović *et al.* (2017), utilizou o RMSE, MAPE, o erro absoluto médio (MAE), o índice de concordância (d) e coeficiente de Nash-Sutcliffe (E) como índices de avaliação.

Diversos índices de avaliação têm diferentes aplicabilidades e limitações. O  $R^2$  mede o quanto a variável dependente pode ser explicada pelo modelo. Seu valor varia entre 0 e 1 (0 a 100%), e quanto maior o valor, melhor a concordância entre modelo e observação (LEGATES e MCCABE JR, 1999).

O MAPE é uma medida de erro percentual, ou seja, seu valor indica o percentual que o valor predito estará distante do valor real e não é adequado para dados contendo valores zero (XU *et al.*, 2021). As medidas relativas ao erro absoluto, como o RMSE, MSE e MAE, representam a diferença entre os valores observados e preditos. O MAE mede o módulo da média da diferença entre o valor real com o predito e não sofre influência de valores discrepantes (*Outliers*). O MSE é uma métrica similar ao MAE, porém, ao invés de aplicar o módulo a diferença do valor real e predito, essa métrica é elevada ao quadrado, portanto, o MAE sofre influência de valores muito distantes. O RMSE configura-se como a raiz quadrada do MSE e sofre penalizações quando há grandes diferenças entre o valor previsto e o real (WANG e LU, 2018).

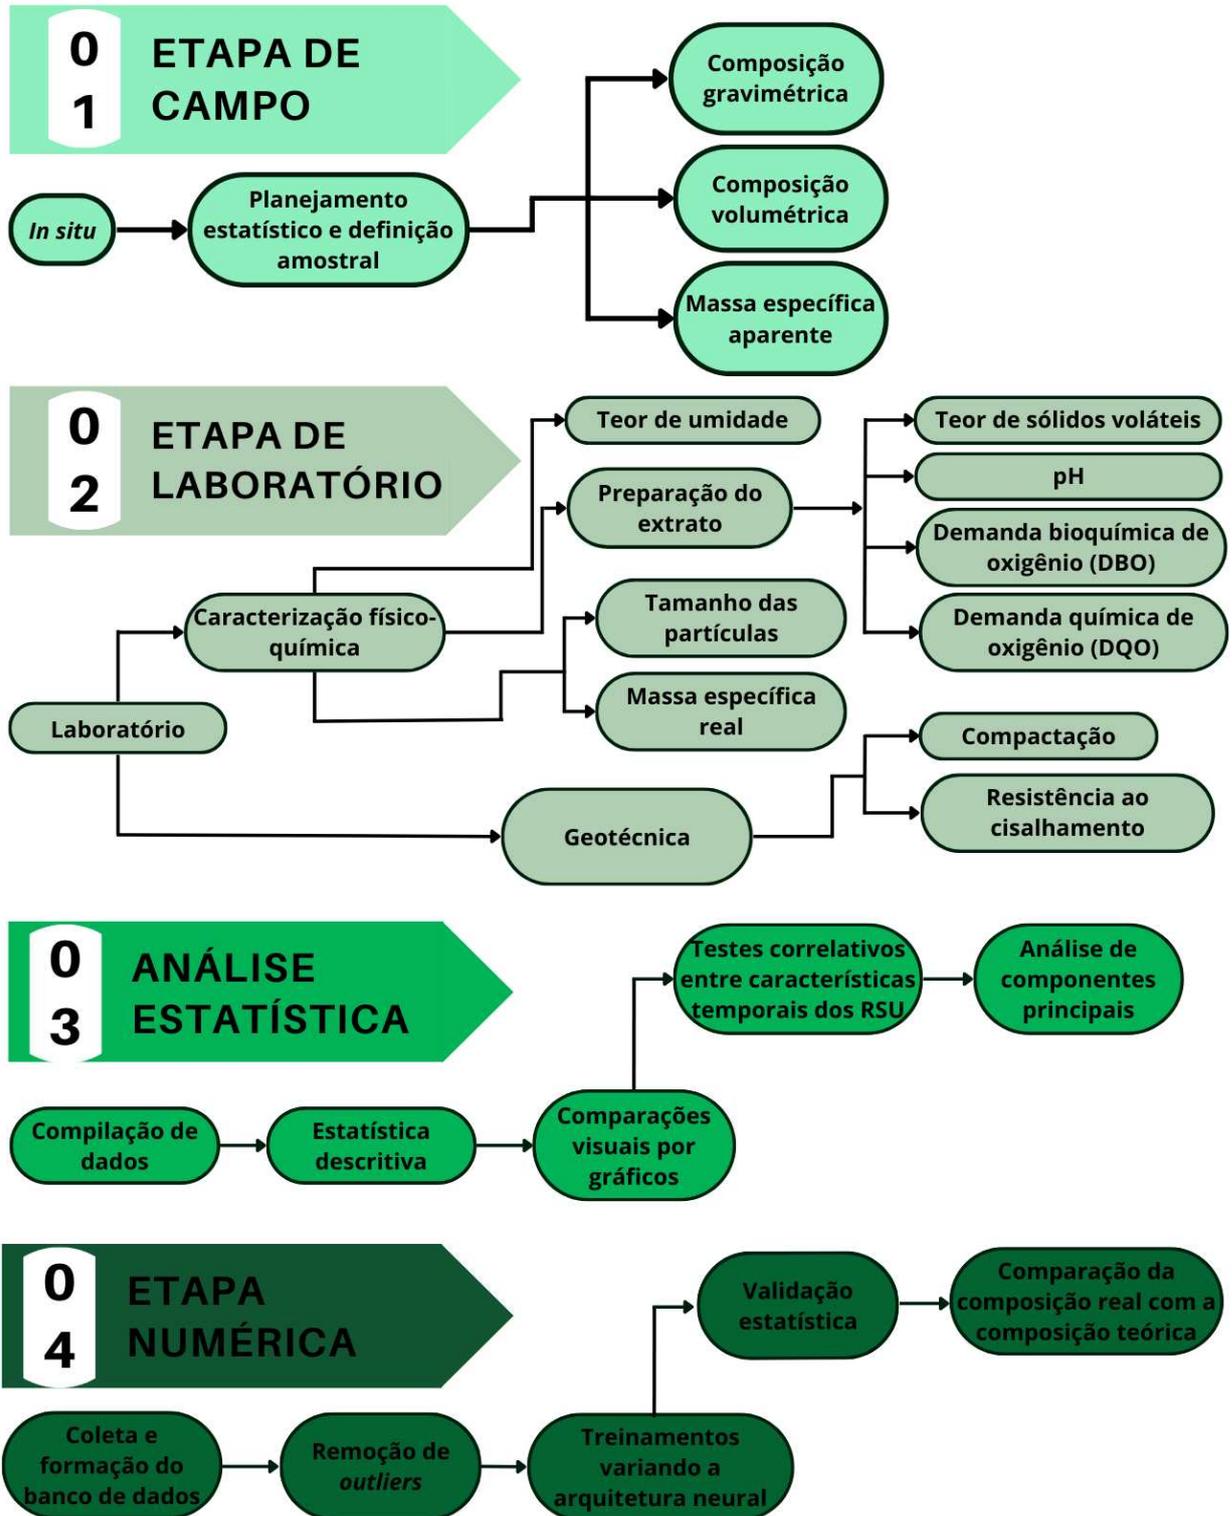
Uma métrica de desempenho pouco utilizada trata-se do coeficiente de eficiência desenvolvido por Nash e Sutcliffe (1970). Seu valor fica entre  $-\infty$  e 1, e quanto maior o valor, melhor a concordância entre modelo e observação.

### 3 METODOLOGIA

Nesse capítulo é realizada uma breve descrição do campo experimental: o Aterro Sanitário localizado em Campina Grande – PB (ASCG). São apresentadas também as quatro etapas da pesquisa que compreende: i) caracterização *in situ* dos RSU que chegam ao ASCG; ii) caracterização física, química e geotécnica, laboratorial, dos RSU que chegam ao ASCG; iii) análise estatística dos parâmetros envolvendo os RSU no ASCG e; iv) análise numérica utilizando redes neurais artificiais.

As etapas i e ii, que envolvem a caracterização dos RSU, que chegam ao ASCG, contou com a colaboração dos integrantes do Grupo de Geotecnia Ambiental (GGA/UFCG). Essa dissertação é uma das linhas de pesquisa do GGA, um grupo interdisciplinar, que conta com alunos de iniciação científica, mestrados, doutorandos e pesquisadores.

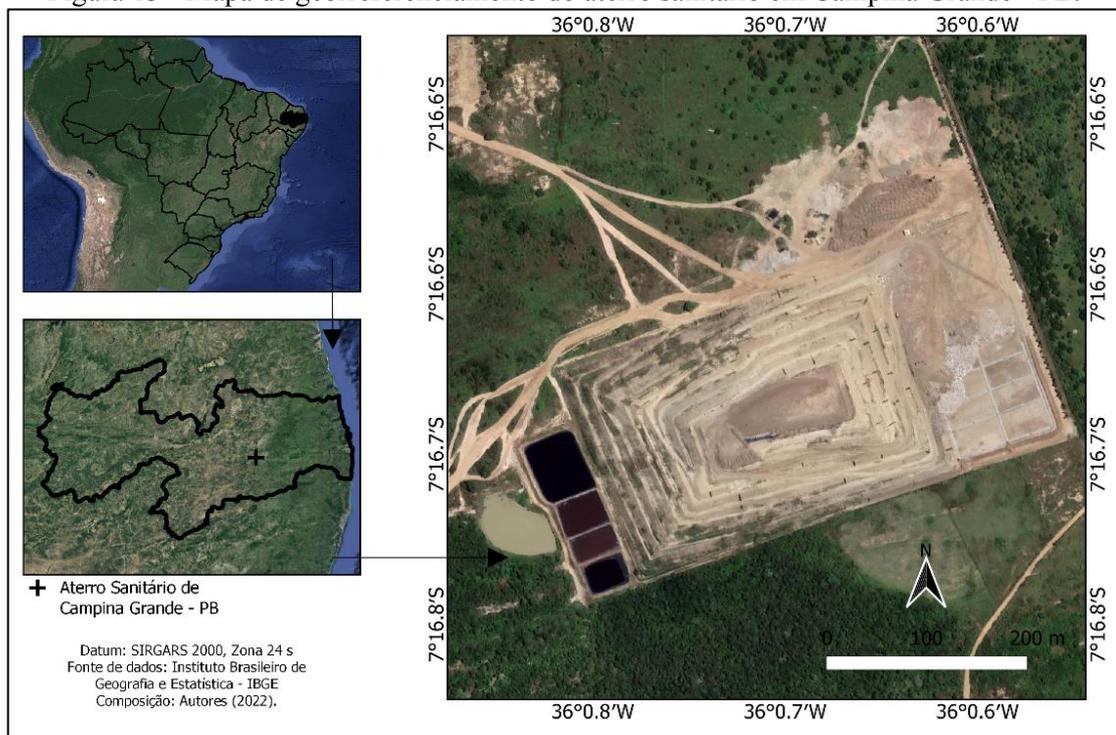
Figura 12 - Fluxograma experimental.



### 3.1 Descrição do campo experimental

O presente estudo, utilizou como base os Resíduos Sólidos Urbanos provenientes do Aterro Sanitário em Campina Grande-PB (ASCG). O ASCG pertence, e é gerido pela empresa Ecosolo Gestão Ambiental de Resíduos Ltda, localizado na Fazenda Logradouro II, distrito de Catolé de Boa Vista, no município de Campina Grande-PB, ( $7^{\circ} 16' 44,4''$  S,  $36^{\circ} 00' 44,0''$  W) como apresenta a Figura 13.

Figura 13 - Mapa de georreferenciamento do aterro sanitário em Campina Grande - PB.



Fonte: Acervo de pesquisa (2022).

O ASCG é objeto de monitoramento e pesquisas do Grupo de Geotecnia Ambiental da Universidade Federal de Campina Grande (GGA - UFCG), desde 2016 por intermédio de um Acordo de Parceria celebrado entre a Universidade Federal de Campina Grande (UFCG) e a referida empresa, a qual é responsável pela operação do Aterro, tendo como interveniente a Fundação Parque Tecnológico da Paraíba (PaqTcPB).

Inicialmente, o ASCG foi projetado para receber  $350 \text{ tRSU.dia}^{-1}$ , resultando em uma vida útil de 25 anos. Porém, com o passar do tempo, diversos municípios da Paraíba, Pernambuco e Rio Grande do Norte passaram a depositar seus resíduos no ASCG. Atualmente, o aterro recebe, em média,  $650 \text{ tRSU.dia}^{-1}$ , provenientes de 71 municípios, podendo sofrer variações sazonais entre  $525$  e  $721 \text{ tRSU.dia}^{-1}$ .

A atual configuração de deposição de resíduos do ASCG, é apresentada na Figura 14, tem duas Células já encerradas, a Célula 1 de dimensões de 100 metros de comprimento por 220 metros de largura e a Célula 2 de dimensões 100 metros de comprimento por 100 metros de largura, ambas com altura de aproximadamente 40 metros, executadas a cada 5 m, taludes com inclinação de 1:2 e bermas intermediárias de 6 m de largura. No momento, o ASCG opera a Célula 3 de mesmas dimensões da Célula 2, e que quando finalizada haverá uma junção entre as Células 1, 2 e 3.

Figura 14 - Configuração atua do aterro sanitário em Campina Grande - PB.



Fonte: Acervo de pesquisa (2022).

O ASCG ainda conta com um sistema de lagoas de acumulação de lixiviado (Figura 14), que são utilizadas para recirculação e tratamento por evaporação. As águas pluviais são drenadas e conduzidas a lagoa de drenagem pluvial, localizada próxima as lagoas de lixiviado e, quando necessário, essa água é utilizada para umidificar vias de acesso diminuindo a poeira no local.

### 3.2 Planejamento estatístico e amostragem dos Resíduos Sólidos Urbanos

Os RSU foram coletados no Aterro Sanitário de Campina Grande, no dia 30 de agosto de 2022. Nesse mês, o ASCG recebeu RSU de 71 municípios distintos, por isso, foi realizado

um planejamento estatístico com finalidade de obter uma amostra que expressasse, com maior proximidade, as características dos resíduos depositados no aterro. O plano de amostragem foi realizado segundo o procedimento recomendado pela norma NBR 10007 (ABNT, 2004) - Amostragem de Resíduos.

Para determinar a amostragem dos RSU que chegam ao aterro, utilizou-se a Equação 5 que realiza a estimativa da média de uma população finita com erro amostral e confiança estimada como mostrado na Tabela 2 (MORETTIN e BUSSAB, 2017).

$$n = \frac{Z^2 * \sigma^2 * N}{d^2 * (N - 1) + Z^2 * \sigma^2} \quad (5)$$

Sendo:

n = tamanho da amostra;

Z = grau de confiança desejado;

$\sigma^2$  = desvio padrão populacional da variável estudada;

N = tamanho da população;

d = erro amostral.

O planejamento estatístico utilizou o valor médio mensal de resíduos que foram dispostos no ASCG durante os últimos doze meses. A Tabela 2 demonstra os valores utilizados para o planejamento e o total estipulado para realização da amostragem dos RSU.

Tabela 2 - Planejamento amostral para coleta de RSU.

<b>Planejamento estatístico</b>	
Média (N)	657,80 toneladas
Desvio ( $\sigma^2$ )	24,91 toneladas
Grau de confiança (Z)	1,28
Erro amostral (d)	10
Tamanho da amostra (n)	10 toneladas

Fonte: Acervo de pesquisa (2022).

O ASCG recebe resíduos de 71 municípios distintos e 17 empresas privadas, a chegada dos resíduos é contínua e em todos os dias da semana. Devido questões operacionais, foi escolhido a terça feira (30 de agosto de 2022), dia geralmente com maior contribuição semanal,

para recolhimento do material a ser caracterizado, garantindo maior representatividade das contribuições de cada município depositante. Durante o dia estabelecido para coleta do material, obteve-se um total de 204 toneladas de resíduos, representando cerca de 25% de contribuição total no ASCG.

### 3.3 Coleta e amostragem dos Resíduos Sólidos Urbanos

O procedimento operacional da coleta dos RSU iniciou pelo período da manhã no Aterro Sanitário em Campina Grande. Os resíduos chegavam em caminhões de tipos variados, basculantes (Figura 15a) e compactadores (Figura 15b). Em seguida, o resíduo foi acomodado em pilhas em uma área próxima a operação do aterro (Figura 15c e 15d).

Figura 15 - (a) Caminhões basculantes; (b) caminhões compactadores; (c) e (d) diferentes disposições de RSU.



Fonte: Acervo de pesquisa (2022).

Conforme a chegada dos caminhões no aterro, as amostras foram acomodadas em duas pilhas, onde observou-se a contribuição do município de Campina Grande no total de resíduos recebidos (Figura 16a) e iniciou-se o processo de amostragem dos RSU. Para alcançar as 10 toneladas de RSU estipuladas no planejamento experimental, foram tomadas porções proporcionais de cada pilha de resíduos, com o auxílio de uma pá carregadeira Caterpillar modelo 924H (Figura 16b). Para realizar a aferição da massa de resíduos, foi utilizado um caminhão caçamba e uma balança rodoviária (Figura 16c).

Figura 16 - (a) acomodação dos resíduos após chegada no ASCG; (b) coleta dos resíduos; (c) pesagem dos RSU.



Fonte: Acervo de pesquisa (2022).

Os resíduos pesados foram encaminhados para um galpão de apoio próximo a entrada do ASCG, onde foram dispostos (Figura 17a). Para garantir melhor homogeneização dos RSU, foi realizada a abertura manual de alguns sacos plásticos (Figura 17b). Após esse procedimento, deu-se sequência a homogeneização (Figura 17c) e ao quarteamento (Figura 17d) com auxílio de uma retroescavadeira Caterpillar modelo 416e. O processo do quarteamento seguiu

conforme instruído na NBR 10007 (ABNT, 2004) - Amostragem de Resíduos, na qual foram tomadas duas partes opostas entre si, pré-homogeneizadas, para constituir uma nova amostra e descartadas as partes restantes. Os procedimentos de homogeneização e quartejamento foram repetidos até atingir uma massa de aproximadamente, 969 kg de RSU.

Figura 17 - (a) acomodação dos RSU no galpão; (b) abertura de sacolas plásticas; (c) homogeneização; (d) resíduos quarteados



Fonte: Acervo de pesquisa (2022).

Devido a coleta de resíduos, realizada no dia 30 de agosto de 2022, ocorrer durante todo o dia de operação do ASCG, as etapas de caracterização foram conduzidas no dia seguinte 31 de agosto de 2022.

### 3.4 Caracterização físico-química dos Resíduos Sólidos Urbanos

As análises físico-químicas de RSU tiveram como objetivo subsidiar a avaliação da degradação dos resíduos, bem como sua interferência nos aspectos mecânicos e geotécnicos do

ASCG. Para isso, foram realizados ensaios de caracterização gravimétrica e volumétrica, determinação do teor de umidade, peso específico, tamanho das partículas, pH, teor de sólidos voláteis e DQO.

No Quadro 4 estão descritos os ensaios e as metodologias adotadas para a caracterização físico-química dos RSU.

Quadro 4 - Parâmetros e métodos físico-químicos.

<b>Parâmetros</b>	<b>Método</b>
Composição gravimétrica	Adaptado da GDA Empfehlungen E1-7 (DGGT, 1994).
Composição volumétrica	Mariano <i>et al.</i> (2007), Catapreta (2008), Ribeiro (2012) e Araújo Neto (2016).
Massa específica aparente solta e compactada	Adaptado de CETESB (1990).
Tamanho das partículas	Adaptação da NBR 7181 (ABNT, 2016) e contribuições de Alcântara (2007), Farias (2014) e Araújo Neto (2021).
Massa específica real dos resíduos	Yesiller <i>et al.</i> (2014), NBR 6508 (ABNT, 1984) e Araújo Neto (2016).
Teor de umidade	Manassero <i>et al.</i> (1996) e Araújo Neto (2021).
pH	Standard Methods (AWWA, APHA e WEF, 2017).
Teor de sólidos voláteis	Who (1979).
Demanda Química de Oxigênio (DQO)	Standard Methods (AWWA, APHA e WEF, 2017).
Demanda Bioquímica de Oxigênio (DBO)	Standard Methods (AWWA, APHA e WEF, 2017).

Fonte: Acervo de pesquisa (2022).

Para obtenção dos parâmetros físico-químicos, pH, teor de sólidos voláteis, DQO e DBO, foi produzido um extrato líquido, equivalente ao lixiviado. Para cada 0,5 kg de resíduo picotado, nas dimensões 1x3 (Figura 18a), foi adicionado 1 L de água destilada (Figura 18b). Após 30 minutos de submersão em água, a amostra passou por peneiramento na malha de 1,2

mm. O extrato finalizado (Figura 18c), foi encaminhado para o Laboratório de Geotecnia Ambiental (LGA), na Universidade Federal de Campina Grande – UFCG, para realização das análises físico-químicas.

Figura 18 - (a) resíduos picotados; (b) diluição em água destilada; (c) extrato.



Fonte: Acervo de pesquisa (2022).

### 3.4.1 Composição gravimétrica dos Resíduos Sólidos Urbanos

Os resíduos quarteados foram dispostos em uma lona plástica, e classificados seguindo as instruções da norma alemã *Empfehlungen E1-7* (DGGT, 1994), que divide os resíduos nos seguintes grupos: papel, papelão, plástico, vidro, metal, matéria orgânica putrescível, têxteis sanitários, têxteis e couro, madeira, compósito (materiais constituídos pela junção de mais um tipo de material) e material misto.

Porém, por se tratar de uma composição de resíduos frescos, a categoria “material misto” foi trocada pela categoria “outros”, tendo em vista que, não havia frações pastosas de difícil identificação. Outra adaptação operacional foi a incorporação da categoria compósitos na categoria outros, devido à pequena fração de compósitos identificados na amostra.

A segregação manual, foi então agrupada em 11 categorias de resíduos: papel, papelão, plástico, vidro, metal, matéria orgânica putrescível, têxteis sanitários, têxteis e couro, madeira e outros, definindo-se assim, a composição gravimétrica. Após a triagem inicial, os resíduos foram acomodados em baldes (Figura 19b), pesados em uma Balança Mecânica Plataforma *Welmy* com capacidade de carga de 150 kg (Figura 19a), e precisão de 10 g (Figura 19c). Para determinar o percentual de cada componente presente nos resíduos utilizou-se a Equação 6, que relaciona a massa de cada componente a massa total dos resíduos.

$$CF = \frac{M_{FS}}{M_T} \times 100 \quad (6)$$

Sendo:

CF = composição física ou gravimétrica (%);

$M_{FS}$  = massa da fração segregada (kg);

$M_T$  = massa total dos resíduos (kg).

Figura 19 - (a) preparação da amostra no balde; (b) balança analógica; (c) pesagem dos resíduos.



Fonte: acervo de pesquisa (2022).

Ao final da segregação, os resíduos foram espalhados sobre uma lona preta, a fim de verificar visualmente cada uma das categorias analisadas (Figura 20).

Figura 20 - Resíduos Sólidos Urbanos segregados.



Fonte: Acervo de pesquisa (2022).

### 3.4.2 Composição volumétrica dos Resíduos Sólidos Urbanos

Logo após a gravimetria foi determinada a composição volumétrica, a partir das medições de volumes o qual o RSU ocupa em relação aos volumes de recipientes calibrados. Para isso, utilizou-se adaptações das metodologias de Mariano *et al.* (2007), Catapreta (2008), Ribeiro (2012) e Araújo Neto (2016), que para a fração caracterizada pela gravimetria tinham seus volumes aferidos enquanto soltos e compactados estaticamente.

Para facilitar as medidas de volume, considerou-se os recipientes (baldes) com formatos cônicos (Figura 21b), previamente calibrados a partir de aferições com trena métricas de seu diâmetro menor (base do recipiente) e altura. Portanto, colocava-se em cada recipiente a quantidade de resíduos para preenchê-lo, e imediatamente registrava-se a composição volumétrica solta das frações de resíduos. Em seguida, com o auxílio de um soquete circular de concreto com massa de 56 kg (Figura 21a), compactava-se estaticamente os resíduos, simulando o procedimento ocorrido dentro da célula do aterro (Figura 21c). O procedimento de compactação ocorreu através da aplicação do soquete por 3 vezes sobre o resíduo, respeitando o tempo de 30 segundos de aplicação sobre a amostra e 10 segundos de suspensão do soquete (Figura 22d). Ao final desse processo media-se novamente a altura do resíduo compactado ao topo do recipiente e o diâmetro maior onde estava o topo da fração de resíduos (Figura 21d).

Figura 21 - (a) soquete de concreto; (b) baldes de volumes diferentes; (c) elevação do soquete; (d) compactação do resíduo; (e) aferição da altura e do raio maior.



Fonte: Acervo de pesquisa (2022).

Finalmente, obtém-se a composição volumétrica utilizando a Equação 7.

$$V = \frac{\pi h (R^2 + Rr + r^2)}{3} \quad (7)$$

Sendo:

V = volume dos resíduos soltos (m<sup>3</sup>);

h = altura encontrada (m);

R = raio menor (m);

r = raio maior (m).

### 3.4.3 Massa específica aparente solta e compactada dos Resíduos Sólidos Urbanos

A massa específica aparente solta e compactada dos RSU que chegam ao ASCG foi determinada a partir da pesagem dos resíduos segregados durante a composição gravimétrica e volumétrica. Para a massa específica aparente solta, os baldes de volume definido foram preenchidos manualmente com a fração de RSU, sem compactação, até o limite superior do balde. Registraram-se então a massa e o volume para cada componente do RSU. Já a determinação da massa aparente compactada utilizou-se o mesmo procedimento, porém os

resíduos sofreram compactação estática por meio de um soquete manual confeccionados em concreto, após o enchimento dos recipientes. Este procedimento foi realizado seguindo as recomendações de CETESB (1990).

Portanto, a massa específica solta e compactada dos RSU foi calculada através da Equação (8).

$$\rho = \frac{M}{V} \quad (8)$$

Sendo:

$\rho$  = massa específica aparente ( $\text{kg}\cdot\text{m}^{-3}$ );

$M$  = massa da amostra (kg);

$V$  = volume da amostra ( $\text{m}^3$ ).

#### 3.4.4 Tamanho das partículas dos Resíduos Sólidos Urbanos

A determinação da granulometria dos RSU fundamenta-se na adaptação da NBR 7181 (ABNT, 2016) e contribuições de Alcântara (2007), Farias (2014) e Araújo Neto (2021). Para classificar a fração fina seguiram-se os procedimentos descritos em REMECOM (*Réseau Européen de Mesures Pour la Caractérisation des Ordures Ménagères*), Defra (2004), que reconhece como finos a quantidade de material que passa na peneira de espessura igual à 20 mm.

A preparação da amostra de RSU para o ensaio de granulometria foi obtida a partir da pilha de resíduos destinada à caracterização inicial, de onde retiram-se dois baldes (com capacidade de 100 L) para secagem ao ar livre. Após 30 dias de secagem, os resíduos foram homogeneizados e quarteados. Posteriormente, duas pilhas foram descartadas e duas pilhas foram novamente homogeneizadas. Da pilha final homogeneizada, foram retirados 10 kg para o ensaio de granulometria (Figura 22a).

No laboratório foi realizado o peneiramento da fração grossa utilizando cinco peneiras, uma circular e quatro retangulares (Figura 22b). A amostra que chegou no LGA foi pesada para conferência da massa inicial de 10 kg (Figura 22c). A peneira circular utilizada nesse procedimento possuía a maior abertura com 76,2 mm (diâmetro da malha). Em seguida, utilizando um agitador mecânico de peneiras foi finalizado o peneiramento grosso com a série

entre 50,8 mm até 19,1 mm de diâmetro (Figura 22d). Os resíduos retidos nas peneiras (Figura 22e) foram pesados e levados a estufa a 100° C por 24h.

Figura 22 - (a) amostra para granulometria; (b) série de peneiras 76,2 - 19,1 mm; (c) pesagem do material; (d) peneiramento com agitador mecânico; (e) material retido nas peneiras.



Fonte: Acervo de pesquisa (2022).

Os resultados obtidos a partir das massas retidas em cada peneira são calculados a partir das Equações 9 e 10.

$$PR = \frac{MR}{MTS} * 100 \quad (9)$$

$$PP = 100 - PR \quad (10)$$

Sendo:

PR = Porcentagem retida no peneiramento grosso;

MR = Massa retida;

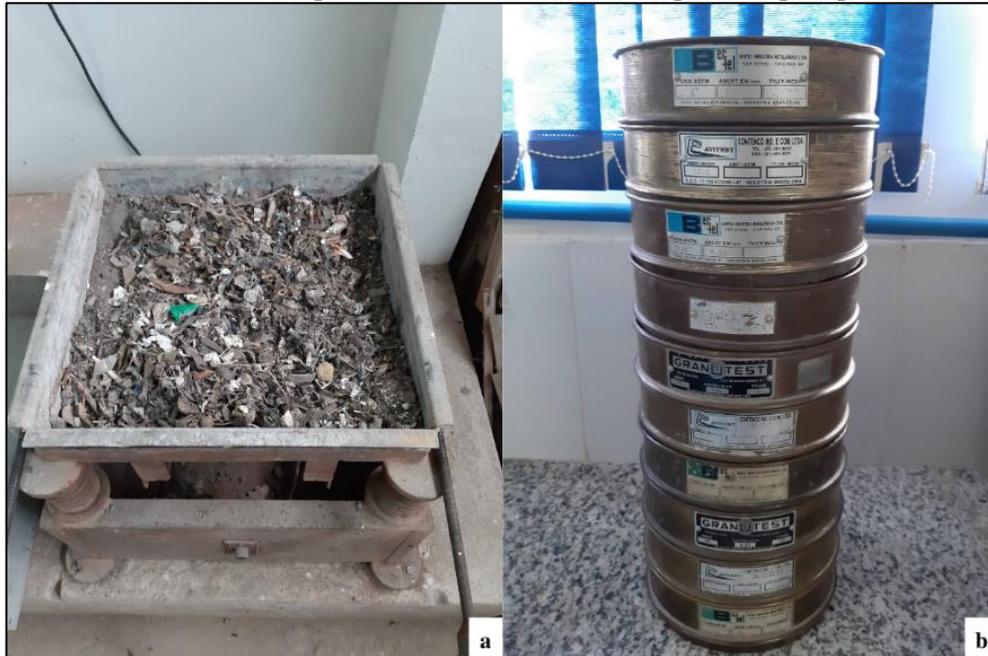
MTS = Massa total seca;

PP = Porcentagem que passa no peneiramento grosso;

Para o peneiramento fino pesou-se 1 kg dos resíduos passantes na peneira de malha 19,1 mm (Figura 23a). Em seguida, o peneiramento foi realizado manualmente, com as malhas variando de 9,5 mm a 0,072 mm (Figura 23b). Como estabelece a NBR 7181 (ABNT, 2016) a

amostra retida na peneira 0,072 mm foi lavada. Por fim, o material retido em cada peneira foi pesado.

Figura 23 - (a) Fração retida na peneira 19,1 mm; (b) Série de peneiras para peneiramento fino.



Fonte: Acervo de pesquisa (2022).

A porcentagem retida e a porcentagem passante são calculadas por meio das Equações 11 e 12.

$$PR = \frac{MR}{MTSF} * 100 \quad (11)$$

$$PP = (100 - PR) - N \quad (12)$$

Sendo:

PR = Porcentagem retida no peneiramento fino;

MR = Massa retida;

MTS = Massa total dos finos;

PP = Porcentagem que passa no peneiramento fino;

N = Fração representativa da amostra fina.

### 3.4.5 Massa específica real dos Resíduos Sólidos Urbanos

A massa das amostras de RSU utilizadas para esse ensaio, condizem com as porcentagens determinadas na etapa de composição gravimétrica dos RSU que chegam ao ASCG obtida nesse trabalho (Figura 24).

Figura 24 - Separação da amostra para massa específica real dos resíduos sólidos urbanos.



Fonte: Acervo de pesquisa (2022).

Na Tabela 3 pode-se observar a massa de cada fração de resíduo utilizado para determinação da massa específica real.

Tabela 3 - Preparação da amostra para o ensaio de massa específica real.

<b>Componente de RSU</b>	<b>Massa (g)</b>	<b>Componente de RSU</b>	<b>Massa (g)</b>
Papel	0,41	Têxteis sanitários	3,13
Metal	0,48	Plástico mole	3,88
Madeira	0,48	Matéria orgânica putrescível	11,09
Vidro	0,55	Total	25,00
Material misto	0,63		
Papelão	1,30		
Têxteis e couro	1,51		
Plástico duro	1,54		

Fonte: Acervo de pesquisa (2022).

Os ensaios de massa específica real de RSU foram realizados utilizando como base a metodologia descrita por Araújo Neto (2016) com adaptações de Yesiller *et al.* (2014) e das normas D854 (ASTM, 2010) e NBR 6508 (ABNT, 1984). Portanto, neste trabalho utilizou-se um Erlenmeyer de 250 ml em substituição ao picnômetro, tendo em vista que, o picnômetro apresenta um gargalo de tamanho menor, fato que dificultaria o processo de colocar e retirar os RSU.

De modo geral, o ensaio segue em consonância com a NBR 6508 (ABNT, 1984), porém os principais passos podem ser observados na Figura 25a até a Figura 25f. Os ensaios foram realizados de duas maneiras, com imersão prévia da amostra e sem imersão prévia.

Figura 25 - Roteiro para ensaio de massa específica real dos resíduos sólidos urbanos. (a) calibração do conjunto Erlenmeyer + água destilada; (b) amostra homogeneizada; (c) preparação das amostras em submersão; (d) resíduos transferidos para os Erlenmeyers; (e) aplicação do vácuo 88 kPa; (f) aferição da temperatura.



Fonte: Acervo de pesquisa (2022).

O valor de massa específica da amostra de RSU foi determinado utilizando a Equação 13 relatada pela NBR 6508 (ABNT, 1984) e utilizada, a princípio, em solos.

$$\delta = \frac{M_1 \times 100 / (100 + h)}{\left[ \frac{M_1 \times 100}{100 + h} \right] + M_3 - M_2} \delta_t \quad (13)$$

Sendo:

$\delta$  = massa específica, em  $\text{g.cm}^{-3}$ ;

$M_1$  = massa do RSU úmido;

$M_2$  = massa do conjunto Erlenmeyer + água destilada + RSU;

$M_2$  = massa do conjunto Erlenmeyer + água destilada;

$h$  = teor de umidade da amostra;

$\delta_t$  = correção da massa específica para a temperatura de 20°C.

### 3.4.6 Teor de umidade dos Resíduos Sólidos Urbanos

A umidade dos RSU foi determinada conforme metodologia adaptada da NBR 6457 (ABNT, 2016) pelo método da estufa, base úmida e procedimentos descritos por Manassero *et al.* (1996) e Araújo Neto (2021). Existem várias metodologias acerca da temperatura a se utilizar nos ensaios de determinação de teor de umidade com RSU. Nesse trabalho resolveu-se utilizar a temperatura de 100°C para determinação do teor de umidade dos RSU, pois, as variações de temperatura não demonstram diferenças significativas quanto ao resultado, a única diferença seria o tempo necessário para estabilização do peso seco das amostras de resíduos.

Para determinação do teor de umidade, utilizou-se uma amostra representativa dos resíduos, contendo cerca de 50g. As aferições de massas foram realizadas em balança de precisão Marte modelo AS5500C, e encaminhadas para secagem na estufa a 100°C até estabilização da massa (aproximadamente 24h). Em seguida, as amostras foram mantidas no dessecador até entrarem em equilíbrio térmico com o ambiente. Os cálculos para determinação de umidade partem da Equação 14.

$$h = \frac{P_i - P_f}{P_i} \times 100 \quad (14)$$

Sendo:

$h$  = teor de umidade dos resíduos sólidos (%);

$P_i$  = peso inicial dos resíduos sólidos (g);

$P_f$  = peso final após secagem dos resíduos sólidos (g);

### 3.5 Caracterização geotécnica dos Resíduos Sólidos Urbanos

As propriedades geotécnicas e os métodos para os ensaios com resíduos, que chegam ao ASCG, estão descritos no Quadro 5.

Quadro 5 – Parâmetros e métodos geotécnicos.

<b>Parâmetros</b>	<b>Método</b>
Compactação	Adaptação da NBR 7182 (ABNT, 2016).
Resistência ao cisalhamento direto	Adaptação da D3080 (ASTM, 2011) e Abreu e Vilar (2017).

Fonte: Acervo de pesquisa (2022).

#### 3.5.1 Compactação dos Resíduos Sólidos Urbanos

A preparação da amostra de RSU, para o ensaio de compactação, foi obtida a partir da pilha de resíduos destinada à caracterização inicial, de onde retiraram-se dois baldes (com capacidade de 100 L) para secagem ao ar livre. Após 30 dias de secagem foram coletados 7 kg para o ensaio de compactação.

No ensaio de compactação dos resíduos foi utilizada como base a NBR 7182 (ABNT, 2016). Porém, precisou-se fazer adaptações, como a utilização um molde cilíndrico padrão CBR, devido à heterogeneidade da composição e do tamanho das partículas de RSU, com volume de 4098,9 cm<sup>3</sup>, soquete grande com peso de 4640,0 g, caindo de uma altura de 0,465 mm em relação a superfície dos resíduos e energia Proctor Normal. A Figura 26, mostra alguns passos do ensaio de compactação com Resíduos Sólidos Urbanos.

Figura 26 - (a) adição de água na amostra; (b) aplicação de energia Proctor Normal; (c) pesagem do corpo de prova após a compactação.



Fonte: Acervo de pesquisa (2022).

A partir da curva de compactação, pode-se determinar a massa específica seca máxima e umidade ótima dos RSU que chegam ao ASCG.

### 3.5.2 Resistência ao cisalhamento direto dos Resíduos Sólidos Urbanos

Como não existem metodologias para realização de experimentos com resistência ao cisalhamento direto de RSU, necessita-se fazer adaptações da norma específica para solos D3080 (ASTM, 2011) e utilizar trabalhos disponíveis na literatura como Abreu e Vilar (2017). Os ensaios de resistência ao cisalhamento direto dos RSU, que chegam ao aterro sanitário, foram realizados nas condições inundada e não inundada. Por fim, encontrou-se o intercepto coesivo e ângulo de atrito nos resíduos.

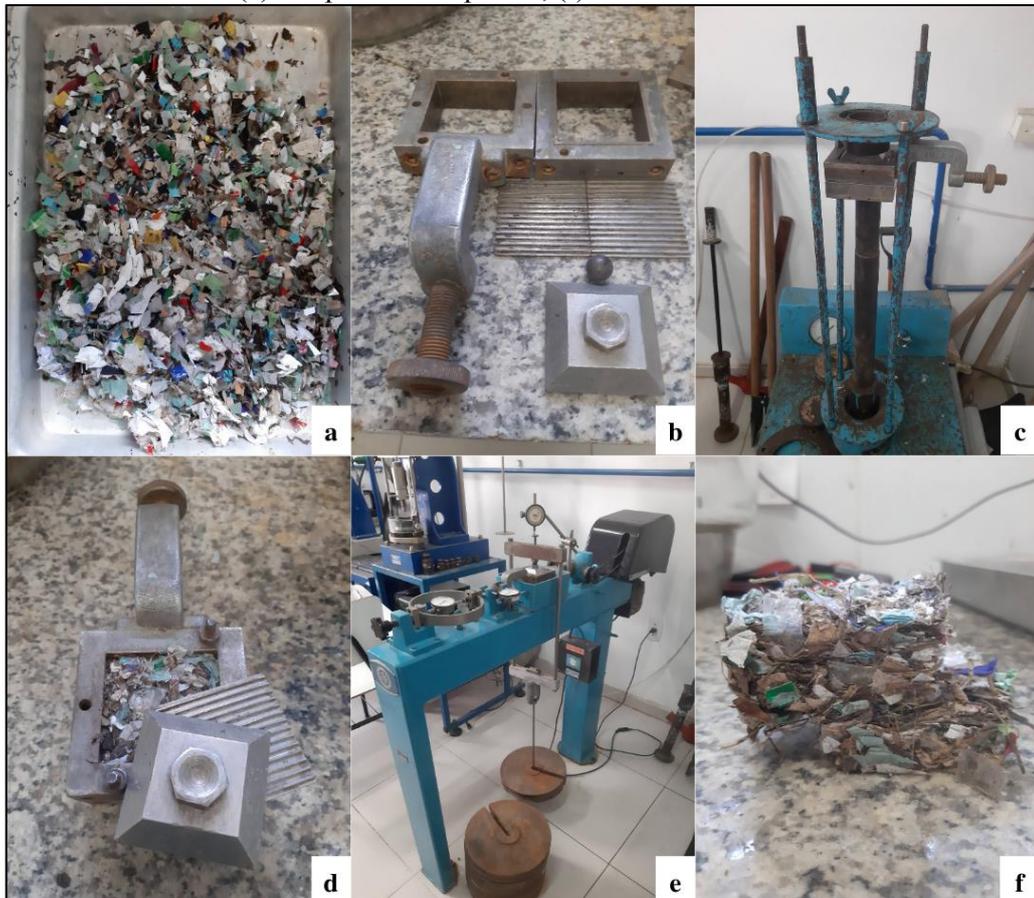
O peso específico para o ensaio foi fixado em um valor médio de  $10 \text{ kN.m}^{-3}$  (valor próximo ao peso específico máximo dos RSU) e o teor de umidade foi definido como 53%, correspondente a umidade média registrada para os resíduos que chegam ao ASCG. Adotou-se uma margem de projeto de tensões normais de 50, 175 e 300 kPa, para os ensaios inundados e não inundados.

A amostra de RSU foi preparada de acordo com a composição gravimétrica (Figura 27a) e com os parâmetros de peso específico e umidade adotados para o ensaio. Em seguida, os

resíduos foram colocados na caixa de cisalhamento (Figura 27b). Por terem em seu constituinte elementos expansivos como os plásticos, necessitou realizar a compactação com auxílio de uma prensa hidráulica (Figura 27c), deixando o nível de RSU rente a borda da caixa de cisalhamento (Figura 27d).

Utilizou-se para o rompimento das amostras uma prensa de cisalhamento direto da marca ELE (Figura 27e), que possui um sistema de carga confinantes em pesos pendurais. Associado a prensa, utilizou-se dois extensômetros e um anel dinamométrico. Os deslocamentos verticais foram medidos por um extensômetro com precisão de 0,0005 polegadas e para os deslocamentos horizontais utilizou-se um extensômetro com precisão de 0,001 polegadas. O anel dinamométrico foi utilizado para medir a força resistente, ele tem constante de  $0,154 \text{ kgf.div}^{-1}$  e capacidade 184,8 kgf. A Figura 27f, mostra os RSU após rompimento em prensa.

Figura 27 - Moldagem dos corpos de prova e ensaio de resistência ao cisalhamento direto. (a) amostra; (b) caixa de cisalhamento; (c) moldagem com prensa hidráulica; (d) caixa de cisalhamento moldada; (e) rompimento na prensa; (f) resíduo cisalhado.



Fonte: Acervo de pesquisa (2022).

Para o ensaio de cisalhamento direto nos RSU, deve-se adotar alguns critérios, que são responsáveis para as leituras e configurações desses ensaios. A Tabela 4 mostra as características do ensaio.

Tabela 4 - Informações iniciais para o ensaio de cisalhamento direto do RSU.

<b>Deformação horizontal (%)</b>	<b>Velocidade do cisalhamento (mm.min<sup>-1</sup>)</b>	<b>Tempo inicial para estabilização de amostra (min)</b>
<b>0,5 - 28</b>	0,3	5

Fonte: Acervo de pesquisa (2022).

Na condição inundada, utilizou-se o ácido acético como líquido imersor por 24 horas anteriores ao ensaio. Outro aspecto observado, é a característica expansiva dos resíduos quando em imersão, por isso, pode-se adotar uma carga de assentamento de 1/12 à carga estabelecida para o ensaio. Após a imersão, a metodologia segue os mesmos passos do ensaio não inundado.

### **3.6 Avaliação estatística do comportamento dos resíduos no aterro sanitário em Campina Grande**

A avaliação da biodegradação do resíduo e eventual verificação da performance do aterro foram realizadas por meio da análise evolutiva das características mecânicas e físico-químicas dos RSU. Para isso, utilizou-se os parâmetros físico-químicos dos RSU que chegam ao ASCG avaliados nesse trabalho em comparação com os parâmetros observados por Araújo Neto (2021). Foram comparados os resíduos que chegam ao ASCG e em diferentes idades de aterramento, consecutivamente 0, 1 e 2 anos de aterramento. Assim, montou-se um banco de dados contendo os parâmetros de composição gravimétrica, peso específico máximo, umidade ótima, umidade de aterramento, pH, teor de sólidos voláteis, DQO e DBO.

Utilizando o *software R Studio 3.3.0*, foi construído um correlograma, com os parâmetros citados, para verificar a existência de correlações linear de *Pearson* significativas entre conjuntos de dados, ou seja, se os dados desses conjuntos variaram da mesma maneira de acordo com o tempo de degradação. Após a construção da matriz de correlação, utilizou-se as variáveis que possuíam correlação linear de *Pearson* maior que 0,7, com dois ou mais parâmetros distintos, para realizar um estudo multivariado dos dados através da Análise de

Componentes Principais (ACP), com intuito de avaliar a formação de grupos que apresentam variáveis equivalentes.

### **3.7 Modelagem não constitutiva da composição gravimétrica dos Resíduos Sólidos Urbanos por meio de redes neurais artificiais**

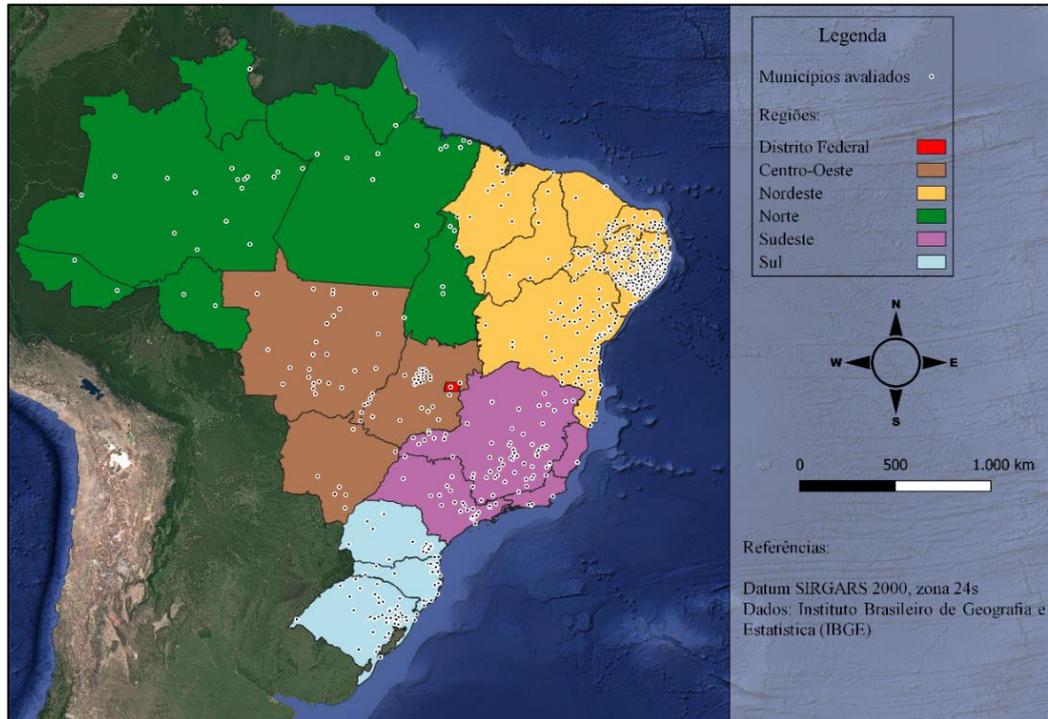
A modelagem não constitutiva foi desenvolvida por meio de RNA, com a linguagem de programação do *software Matlab R2021a*. Conforme Bezerra (2020), o *Matlab* combina um ambiente ajustado para análise iterativa e processos de design com uma linguagem de programação que expressa diretamente a matriz de valores. Ele inclui um editor de *scripts* que combinam código, saída e texto formatado em um bloco de anotações executável (*Mathworks*, 2020).

A criação do modelo neural seguiu basicamente três etapas: coleta de dados e criação dos bancos de dados, codificação da RNA no *Matlab R2021a* (Apêndice A) e confecção e escolha da melhor RNA.

#### **3.7.1 Seleção de dados para as redes neurais artificiais**

Para esse estudo, foi construído um banco de dados contendo composições gravimétricas de RSU em 715 municípios brasileiros (Figura 28), criados, contemplando as cinco regiões do país, como mostrado no Apêndice A. A coleta desses dados foi realizada em literatura tecnocientífica e em banco de dados obtidos a partir dos Planos Estaduais de Gerenciamento de Resíduos Sólidos (PEGRS).

Figura 28 - Municípios que compõe o banco de dados para a RNA.



Fonte: Acervo de pesquisa (2022).

Todos os municípios estudados obtiveram as caracterizações gravimétricas dos RSU por meio de amostragem de campo e procedimentos convencionais e manuais. Durante a pesquisa existiram diversas metodologias para compor a composição dos resíduos, porém a divisão em classes mais encontrada nos trabalhos e adotada para a construção do banco de dados dessa pesquisa foi: papel/papelão, plástico, metal, vidro, matéria orgânica putrescível, têxteis, madeira e outros tipos de resíduos.

Associados aos municípios onde foram identificadas as composições gravimétricas dos RSU, foram coletados indicadores socioeconômicos, que podem ter algum tipo de relação com a composição gravimétrica. Para isso utilizando o ATLAS BRASIL (2022), obteve-se dados acerca de 106 indicadores socioeconômicos diferentes, entre eles destacam-se: Índice de Desenvolvimento Urbano municipal (IDHm), renda per capita, taxa de atividade de pessoas com 18 anos ou mais, valores adicionados aos diversos setores da economia (indústria, comércio, serviços públicos e agropecuária), percentual de atendimento da coleta urbana de resíduos, entre outros indicadores.

Ainda como complementos foram coletados duas séries de dados climáticos, precipitação e temperatura, e um dado geográfico que é a altitude.

### 3.7.2 Criação dos bancos de dados das redes neurais artificiais

Para criação do Banco de Dados (BD), foi realizado uma remoção de *outliers* condizentes com os valores de composição gravimétrica da RNA. Após a remoção dos *outliers*, os dados foram submetidos a treinamentos por redes neurais, de modo a encontrar a combinação de indicadores que melhor se correlacionam com os dados de composição gravimétrica. Ou seja, por tentativa e erro, foram selecionados 4 indicadores socioeconômicos que podem refletir na geração e na composição dos resíduos.

Por meio de testes aplicados na RNA, foram escolhidas as variáveis socioeconômicas que melhor se comportaram como previsores de composição gravimétrica de RSU. Esses dados foram: (1) índice de desenvolvimento humano municipal (IDHm), esse fator é um dos principais indicadores, visto que, ele representa as três dimensões desse parâmetro (longevidade, educação e renda), por isso é o mais adequado para avaliar o estágio de crescimento de um município; (2) índice de Theil; (3) índice de Gini e (4) renda per capita, os tópicos 4, 3 e 2, refletem o poder de consumo da população e quanto mais elevado esse índice maior a qualidade de vida, influenciando diretamente a produção de resíduos, bem como suas características.

Já para os dados de saída da RNA, utilizou-se os seguintes dados de composição gravimétrica de RSU: papel, plástico, vidro, metal e matéria orgânica putrescível.

Na Tabela 5 são apresentadas as variáveis de entrada e saída por meio de diversos parâmetros abordados nessa pesquisa.

Tabela 5 - Estatística descritiva do BD.

Estatística descritiva	Variáveis de saída					Variáveis de entrada			
	Papel	Plástico	Metal	Vidro	Orgânicos	Idhm	Theil	Gini	Renda per capita (R\$/pessoa)
<b>Média</b>	9.80	12.04	3.04	2.81	54.35	0.65	0.49	0.51	426.05
<b>Desvio padrão</b>	0.27	0.28	0.13	0.14	0.71	0.01	0.01	0.00	16.79
<b>Mínimo</b>	0.08	0.01	0.01	0.01	13.00	0.49	0.16	0.27	134.92
<b>Máximo</b>	27.24	31.81	23.90	16.67	81.94	0.91	0.92	0.73	2179.21

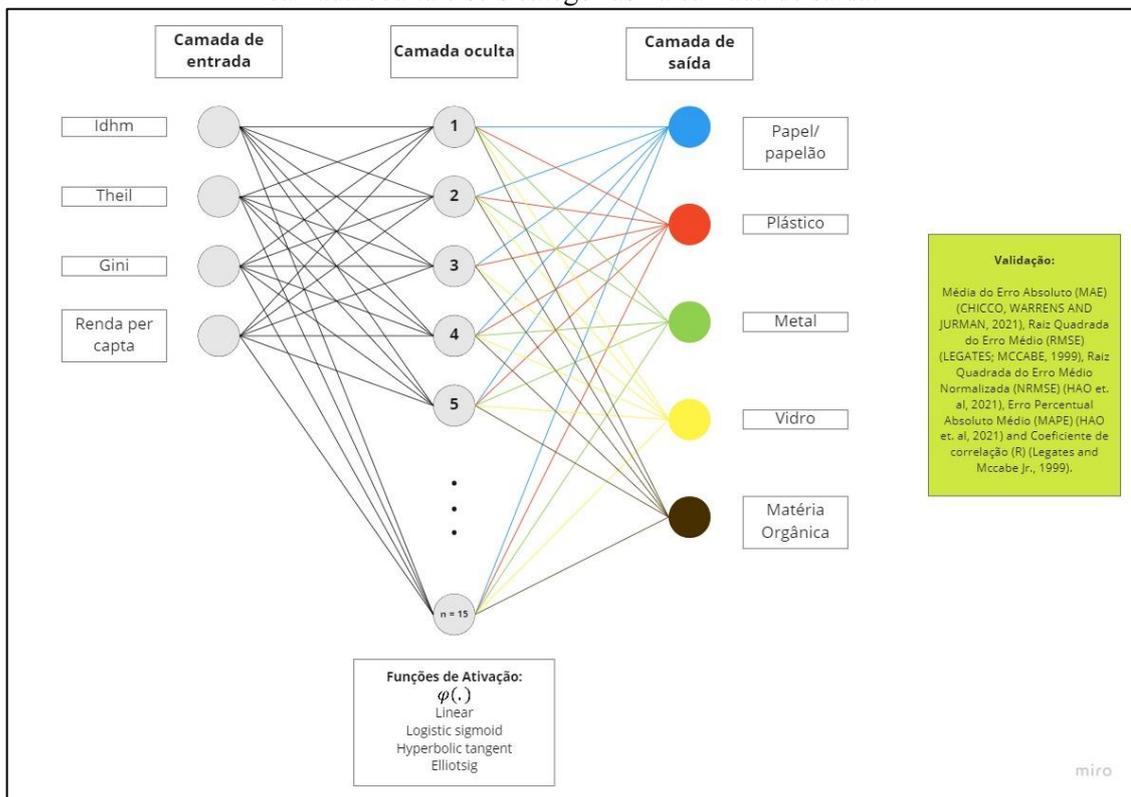
Fonte: Acervo de pesquisa (2022).

### 3.7.3 Construção e escolha das redes neurais artificiais

A construção das RNA foi feita variando diversos parâmetros de treinamento, como quantidade de neurônios na camada oculta, funções de ativação e funções de treinamento. Para isso foram testadas várias redes neurais, possibilitando realizar vários treinamentos

supervisionados. Com a finalidade de realizar esses treinamentos, foi informado ao modelo neural, os dados de entrada (indicadores socioeconômicos) e as respostas (valores de composição gravimétrica nas cinco categorias estudadas). A escolha da RNA foi baseada nas validações estatísticas de cada arquitetura de RNA testada. A Figura 29 mostra os parâmetros para construção e escolha da rede modelada.

Figura 29 - Arquitetura do modelo considerando seis entradas, neurônios variando de 1 a 15 na camada oculta e seis categorias na camada de saída.



Fonte: Acervo de pesquisa (2022).

As relações entre as variáveis foram analisadas através de RNA com *backpropagation*, que é o algoritmo neural amplamente aplicado aos modelos *feedforward*. Os algoritmos de treinamento nesse estudo foram: *traingd* (Gradient Descent Backpropagation), *trainlm* (Levenberg–Marquardt), *trainbr* (Bayesian Regularization Backpropagation) e *trainrp* (Resilient Backpropagation). O banco de dados foi dividido aleatoriamente como 70% de dados de treinamento 30% de teste. O Quadro 6 demonstra os principais parâmetros testados no desenvolvimento da RNA.

Quadro 6 - Parâmetros de construção de RNA.

Parâmetros	Valores	Informações
Função de treinamento	<i>Trainbr, Trainlm, Traingd e Trainrp</i>	Funções testadas para cada arquitetura definida
Neurônios na camada oculta	1-15	A quantidade de neurônios na camada oculta variou entre 1-15
Função de transferência na camada oculta e de saída	Tangente hiperbólica, logística sigmoide, linear e sigmoide simétrica de Elliot.	FA entre camadas oculta e de saída
Validação	MAE, RMSE, NRMSE, MAPE e R	Métricas de desempenho por saída

Fonte: Acervo de pesquisa (2022).

Para obtenção da RNA ótima, foram simulados diversos modelos com diferentes topologias, variando de 1 a 15 neurônios em uma única camada oculta. Para determinação da melhor FA a camada oculta e de saída foram examinadas as funções: tangente hiperbólica (*tanh*), logística sigmoide (*logsig*), linear (*purelin*) e sigmoide simétrica de Elliot (*elliotsig*). A determinação da melhor arquitetura foi realizada por tentativa e erro, totalizando 960 treinamentos, de modo a encontrar a arquitetura que apresenta o menor critério de erro.

Os dados de entrada da RNA passaram por normalização para que a amplitude entre as entradas e saídas ficassem com a mesma proporção. A normalização utilizada nesse trabalho foi por meio da Equação 15, utilizando máximos e mínimos.

$$y_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (15)$$

Sendo:

$y_{norm}$  = y normalizado;

x = valor atual da série;

$x_{min}$  = valor mínimo da série;

$x_{max}$  = valor máximo da série.

### 3.7.3.1 Avaliação do desempenho do modelo

A acurácia do modelo desenvolvido nesse trabalho foi avaliada a partir de diversos parâmetros estatísticos. Portanto, para cada arquitetura neural foi determinada a sua performance por intermédio dos parâmetros listados no Quadro 7.

Quadro 7 - Métricas de desempenho

Métrica	Fórmula	Fonte
MAE	$\frac{\sum_{i=1}^n  \hat{y}_i - y_i }{n}$	Chicco, Warrens e Jurman (2021)
RMSE	$\sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$	Legates e Mccabe Jr. (1999)
NRMSE	$\frac{RMSE}{y_{max} - y_{min}}$	Hao <i>et al.</i> (2021)
MAPE	$\frac{1}{n} \sum_{i=1}^n \left( \frac{y_i - \hat{y}_i}{\hat{y}_i} \right)$	Hao <i>et al.</i> (2021)
R	$\left\{ \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{[\sum_{i=1}^n (y_i - \bar{y})^2]^{0,5} [\sum_{i=1}^n (x_i - \bar{x})^2]^{0,5}} \right\}^2$	Legates e Mccabe Jr. (1999)

Fonte: Acervo de pesquisa (2022).

O coeficiente de correlação (R) demonstra a dependência do valor predito e o observado, assim como o valor de  $R^2$  varia entre 0 e 1, e quanto mais próximo de 1 melhor a associação entre as variáveis (LEGATES e MCCABE JR., 1999).

As medidas de erro absoluto, como RMSE, NRMSE e MAE, representam o desvio médio entre o valor observado e predito. Se as respostas previstas forem muito próximas das respostas verdadeiras, as medições de erro serão pequenas. Se as respostas previstas e verdadeiras diferirem substancialmente, pelo menos para algumas observações, elas serão grandes. Um valor de zero indicaria um ajuste perfeito aos dados (CHICCO, WARRENS AND JURMAN, 2021; HAO *et al.*, 2021).

### 3.7.3.2 Previsão da composição gravimétrica teórica do aterro sanitário em Campina Grande - PB

Utilizando as melhores arquiteturas de RNA, validadas estatisticamente, pode-se realizar a previsão da composição gravimétrica dos RSU, que chegam ao aterro sanitário. Para isso, utilizou-se indicadores socioeconômicos de 68 municípios que depositam seus resíduos no ASCG, obtendo-se, portanto, a previsão para cada município. Por meio, de uma média ponderada utilizando como pesos o percentual de contribuição de cada município, determinou-se a composição gravimétrica teórica do ASCG.

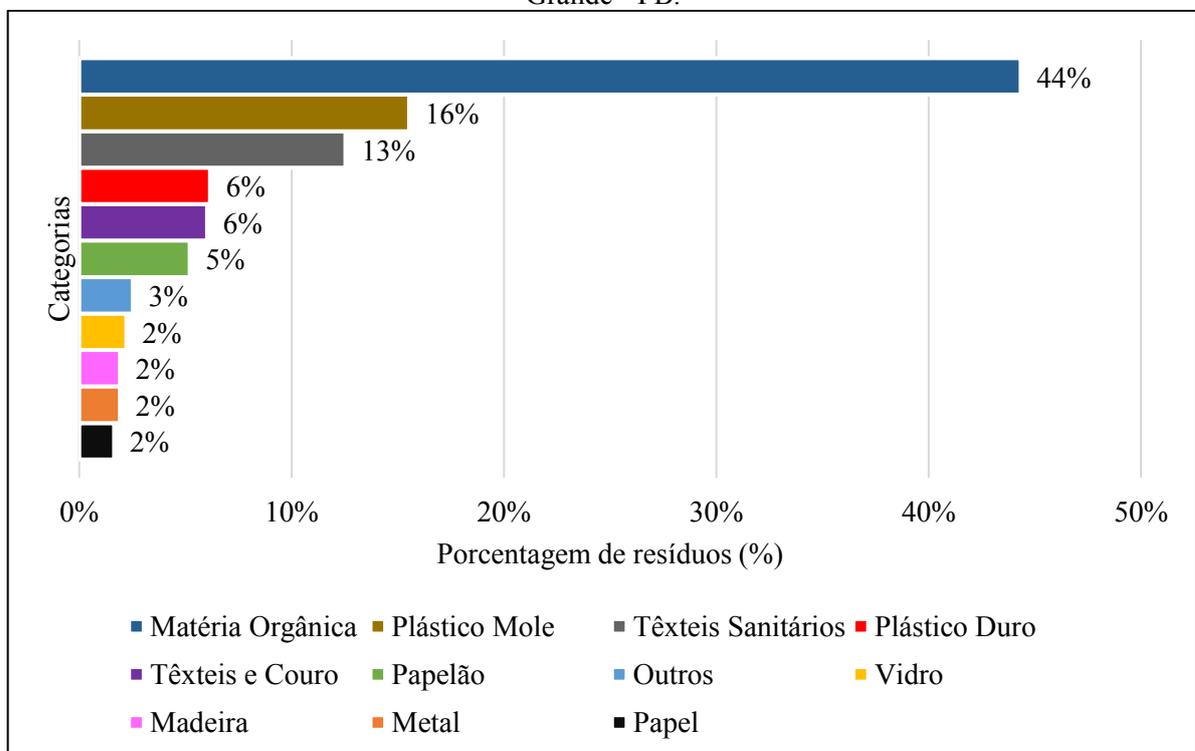
## 4 RESULTADOS

### 4.1 Caracterização físico-química dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande

#### 4.1.1 Composição gravimétrica dos Resíduos Sólidos Urbanos no Aterro Sanitário em Campina Grande

A identificação dos diferentes componentes entre os RSU, que chegam em um aterro sanitário, auxilia em seu gerenciamento operacional. A partir dessas características, pode-se estimar alguns fatores de aterros sanitários como: volume de aterro, vazão de lixiviado e emissão de gases. A composição gravimétrica dos resíduos de uma localidade varia de acordo com os parâmetros econômicos, sazonalidade, clima, geografia, fatores políticos, culturais, normativos e legais. A Figura 30 expressa a composição gravimétrica dos RSU que chegam ao ASCG.

Figura 30 - Composição gravimétrica dos resíduos que chegam ao aterro sanitário em Campina Grande - PB.



Fonte: Acervo de Pesquisa (2022).

Na Figura 30, verifica-se a composição gravimétrica dos RSU que chegam ao ASCG. Percebe-se que as categorias “matéria orgânica putrescível”, “plástico mole” e “têxteis sanitários” são as mais representativas, compondo cerca de 73% do material analisado.

Outro detalhe a ser destacado na Figura 30, é o elevado percentual de matéria orgânica putrescível, que se aproxima de 44%, valor igual a média nacional e mundial, estimadas respectivamente, pela Abrelpe (2020) e pelo *Waste Atlas* (2018). A estimativa da produção de resíduos orgânicos no mundo se modifica de acordo com os parâmetros socioeconômicos avaliados. A biodegradação desse material quando aterrados, provoca deformações na massa de resíduos, que na fase inicial de aterramento propicia grandes recalques, alta produção de gases e geração de lixiviado.

De acordo com Nanda e Berruti (2021), o percentual de resíduos orgânicos produzidos varia consideravelmente de acordo com o nível de renda. Portanto, quanto maior a renda menor o percentual de resíduos orgânicos gerado. O teor de matéria orgânica putrescível nos RSU, de grupos populacionais considerados de baixa renda (países pobres), pode representar até 65% da composição gravimétrica dos resíduos. Em países desenvolvidos e de alta renda registram-se valores inferiores a 30% em peso, enquanto nos países em desenvolvimento, com renda entre média e alta, chega a superar a marca de 50% (ALELUIA e FERRÃO, 2016).

No cenário nacional, o ASCG apresenta pequena diferença na fração de resíduos orgânicos, quando comparado ao Aterro Sanitário de Santo André – SP, onde cerca de 50% dos resíduos destinados, de acordo com Vieira e Candiani (2021), são de material putrescível, porém foi superior ao percentual orgânico de 40,27%, segundo Tagliaferro e Viana (2019), destinados ao Aterro Sanitário em Campinas – SP. Quanto a região nordeste, o ASCG possui um teor de material orgânico superior ao Aterro Sanitário Metropolitano de Natal - RN, que apresentou de acordo com Silva (2019), aproximadamente 42% de matéria orgânica putrescível.

O teor de matéria orgânica putrescível é particularmente importante, pois quanto maior a quantidade de um determinado componente, mais próximo será as características gerais do maciço a este componente. Este teor preponderante de matéria orgânica putrescível, quando comparada com os demais componentes influenciará na geração de lixiviado, biogás, poropressões no interior do maciço, teor de água, na resistência, compressibilidade, adensamento e recalques.

Foi observado por Buratti *et al.* (2015), que para diminuir a fração orgânica disposta em aterros sanitários existem diversas tecnologias ou métodos de tratamento, como a compostagem e a digestão anaeróbica. Entretanto, a carga ambiental real e o benefício do desvio de resíduos orgânicos dos aterros sanitários ainda precisa ser avaliada minuciosamente, já que estudos

demonstram que não há consenso sobre qual tratamento é a melhor opção para a fração orgânica, principalmente, porque os resíduos dependem das especificidades locais (LAURENT *et al.*, 2014).

A fração de resíduos recicláveis é composta por “plásticos” (22%), papel/papelão (7%), vidro (2%) e metal (2%) (Figura 30). As etapas envolvendo a logística reversa de resíduos recicláveis são estimuladoras do processo econômico envolvendo essas frações de RSU. Portanto, totalizando 33% da fração de resíduos, os recicláveis representam cerca de 215 toneladas mensais dos RSU dispostos no ASCG. Esse tipo de material, pode passar pelo processo de recuperação gerando renda e empregos, e diminuindo consideravelmente a quantidade de resíduos aterrada.

Observa-se de acordo com Aurpa e Islam (2022), durante o período da pandemia de COVID 19 e até o momento atual, houve um aumento em torno de 60% no descarte de resíduos plásticos em aterros sanitários. A quantidade de plásticos depositada no ASCG gira em torno de 22%, representando um teor elevado e influenciado pelas mudanças nos hábitos de consumo da população em geral nos últimos anos.

A presença de resíduos plásticos em aterros sanitários é desejável, já que eles apresentam funções de reforços, proporcionando uma maior resistência à tração, possibilitando a maximização da altura do aterro (KÖNIG e JESSBERGER, 1997). Entretanto, em grandes quantidades e de forma indiscriminada, podem causar outros problemas, tendo em vista que, devido suas características mecânicas, eles apresentam um efeito de “colchão” na compactação, ou seja, após realizado o processo de compactação o plástico pode voltar a expandir, passando a falsa impressão de boa compactação (FARIAS, 2014; ARAÚJO NETO, 2021). Ainda, o excesso de plástico no maciço sanitário pode causar o estruturamento de bolsões, que comprometem a drenagem de lixiviado, o processo biodegradativo, a percolação de líquidos no maciço e a estabilidade dos taludes do aterro sanitário (YU *et al.*, 2022).

Outro ponto negativo registrado por Yu *et al.* (2022), é que o resultado da biodegradação dos resíduos plásticos pode gerar microplásticos, um polímero com partículas menores que 5mm que podem causar poluição ambiental. Diversos autores, como Praagh, Hartman e Brandmyr (2018), He (2019) e XU *et al.* (2022), pesquisaram a presença de microplásticos no lixiviado de aterro sanitário e confirmam a presença desse subproduto da degradação variando entre 20 e 90 itens.g<sup>-1</sup>.

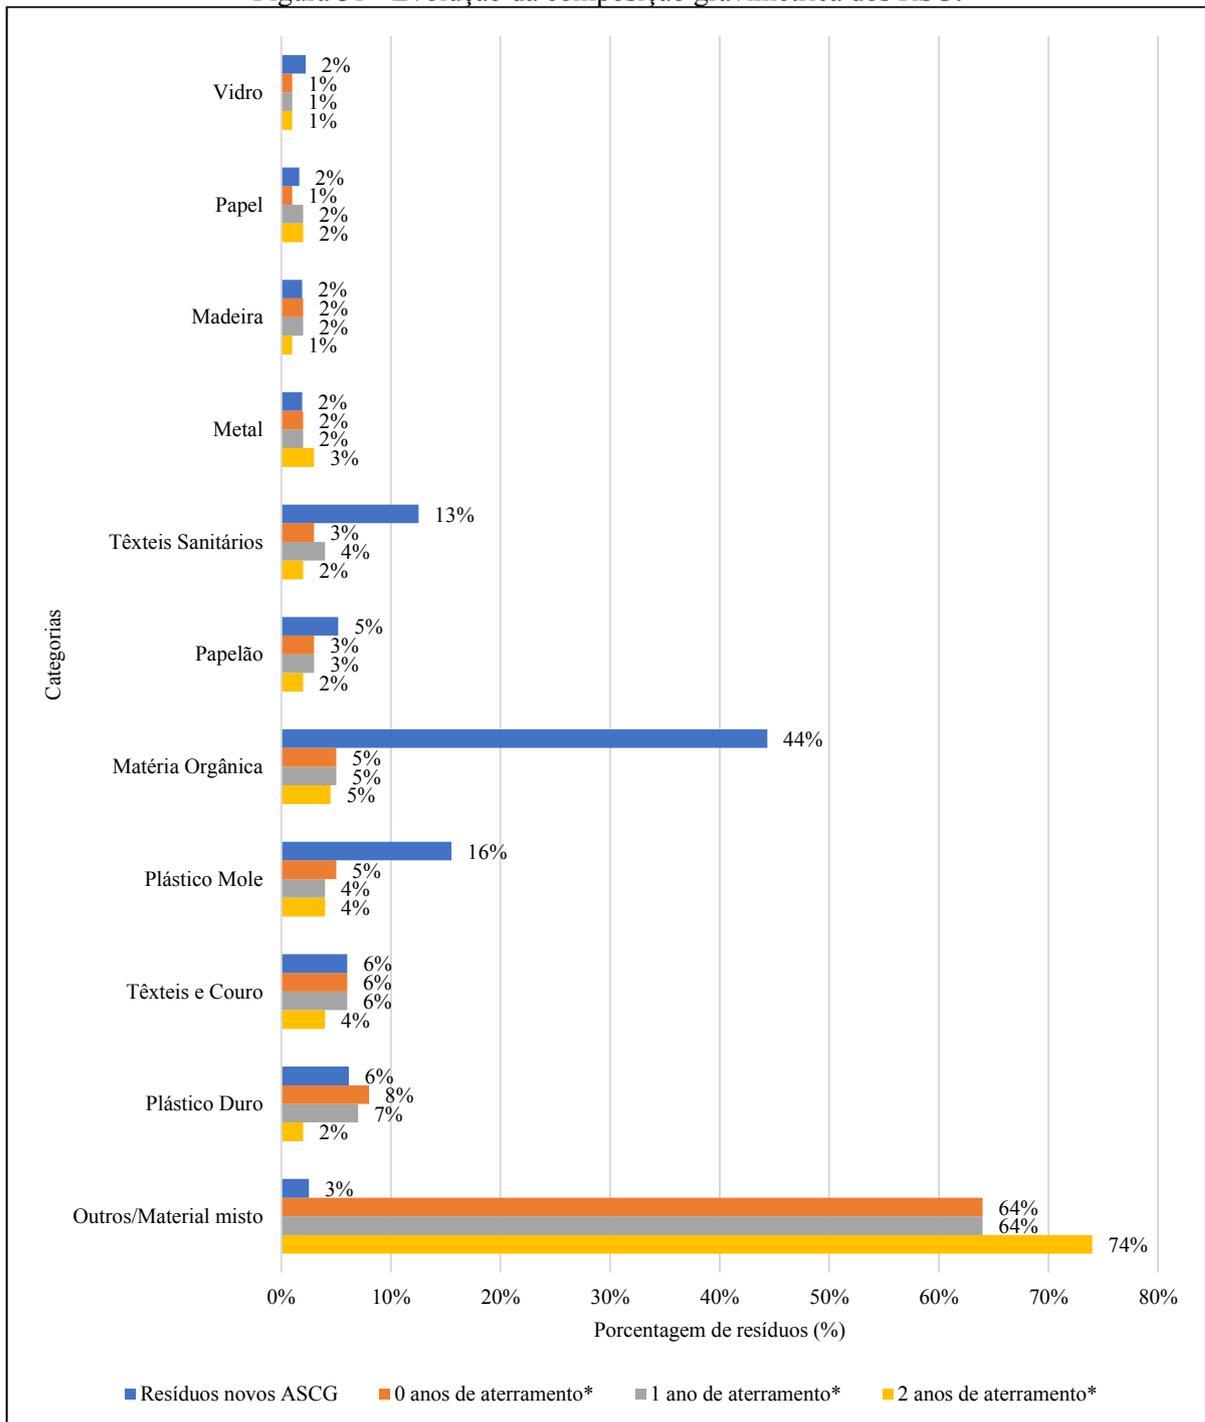
As categorias têxteis e couro (6%) e têxteis sanitários (13%), destacam-se como grandes contribuidoras na porcentagem total dos resíduos. Segundo Farrant *et al.* (2010) e Kim (2019), o consumo desses materiais está diretamente relacionada ao aumento populacional e renda *per*

*capta* dos habitantes. Dessa forma, é necessário que se realizem estudo voltados para investigações de como esse material deve ser manuseado da melhor forma possível em relação ao meio ambiente, o que deve incluir as etapas de coleta, reuso, reciclagem e disposição final de forma adequada.

#### *4.1.1.1 Evolução da composição gravimétrica com o tempo de aterramento no aterro sanitário em campina grande*

Os RSU presentes no ASCG são bastante heterogêneos e possuem comportamentos variáveis ao longo do tempo, devido principalmente, a presença de componentes com potencial de biodegradação. Portanto, o tipo e a quantidade de constituintes dos RSU estão entre os principais fatores considerados como parâmetros comportamentais dos RSU. A avaliação dos percentuais de RSU no aterro sanitário, sob o ponto de vista de diferentes idades de aterramento estão mostrados na Figura 31.

Figura 31 - Evolução da composição gravimétrica dos RSU.



Fonte: Araújo Neto (2021) \* e Acervo de pesquisa (2022).

A maior discrepância encontrada comparando os resíduos que chegam ao ASCG aqueles de 0, 1 e 2 anos de aterramento, está na fração de matéria orgânica ou material putrescível. Observa-se que, nos resíduos que atualmente chegam ao aterro, a fração de orgânicos é de aproximadamente 44% e para os RSU com 0, 1 e 2 anos de aterramento, se mantém em 5%, o que permite concluir que houve uma redução do teor de matéria orgânica de aproximadamente 880%, em apenas 3 anos de aterramento. Esse fato pode ser justificado devido ao processo de

aterramento, de compactação e da biodegração dos RSU que ocorre no interior do maciço sanitário, uma vez que, os compostos orgânicos são transformados e/ou incorporados a outros materiais, dificultando seu processo de identificação. Deve-se notar que, a categoria material misto aumentou com o passar do tempo de aterramento, quando comparada a fração desse material nos resíduos que chegam ao ASCG. O material misto entre 0 e 2 anos de aterramento apresentou um aumento entre 64% e 73%, respectivamente.

Estudos revelam tendências similares a redução da quantidade de matéria orgânica ao longo do tempo, bem como o aumento do material misto com o tempo de aterramento dos RSU. Esse fato está associado a decomposição química e biológica dos componentes orgânicos e percíveis dos resíduos por meio de processos biológicos. A decomposição dos resíduos orgânicos varia de acordo com as condições de aterramento das amostras, em diferentes quantidades iniciais de material orgânico, bem como o grau de sua degradabilidade com o tempo (SHARIATMADARI, SADEGHPOUR e MOKHTARI, 2015; RAMAIAH, RAMANA e DATTA, 2017; OKHTARI, HESHMATI RAFSANJANI e SHARIATMADARI, 2019).

Os plásticos possuem comportamento decrescente de acordo com sua idade de aterramento. Verifica-se que, entre os resíduos que chegam ao ASCG, a porcentagem de plásticos (mole e duro) gira em torno de 22%, os recém aterrados em torno de 13,2%, com 1 ano de aterramento em 10,3% e 6,4% com 2 anos de confinamento. Embora os plásticos, de maneira geral, apresentem maior estabilidade química e física em comparação a outros grupos, ocorre uma diminuição percentual dessa fração ao longo do tempo, justificada pelo crescimento de outras categorias como material misto. Outro fator que influencia na presença de plásticos no maciço é a decomposição química, causada pela elevada temperatura no interior do maciço e/ou por ação de substâncias ácidas ou básicas, que conseqüentemente, reduz o teor de plásticos de acordo com tempo de aterramento.

Atualmente, existe em diversos pontos nos municípios que depositam resíduos no ASCG, a inserção de plásticos biodegradáveis, acelerando a decomposição dessa categoria com o tempo.

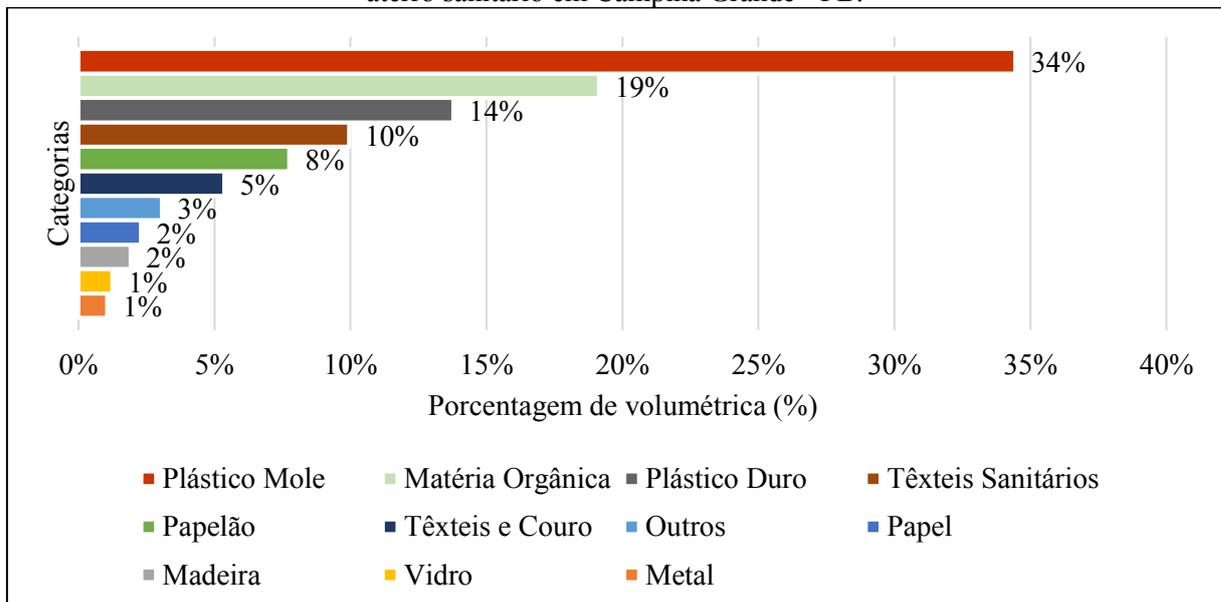
A importância dos plásticos na massa de resíduos é definida por diversos autores como König e Jessberger (1997), Farias (2014) e Araújo Neto (2021), eles relatam ainda, que o desempenho dos plásticos e tecidos como elementos de reforço da massa de resíduos, bem como sua maior compressibilidade e deformabilidade, sofrem grandes variações em seus teores ao longo do tempo, causando mudanças significativas no comportamento mecânico da massa de resíduos.

Os demais materiais (vidro, metal, papel, madeira, papelão, têxteis sanitários, têxteis e couro e outros), independentemente da idade de aterramento, apresentaram percentuais inferiores a 10% na composição gravimétrica, mesmo assim, podem afetar a estabilidade do aterro sanitário. Embora, as categorias vidros e metais, tenham baixa degradação com o tempo, eles se comportam como materiais de apoio, por causa da sua capacidade de absorção de cargas e diminuição do recalque diferencial, em pontos de maior concentração vidros e metais.

#### 4.1.2 Composição volumétrica dos Resíduos Sólidos Urbanos

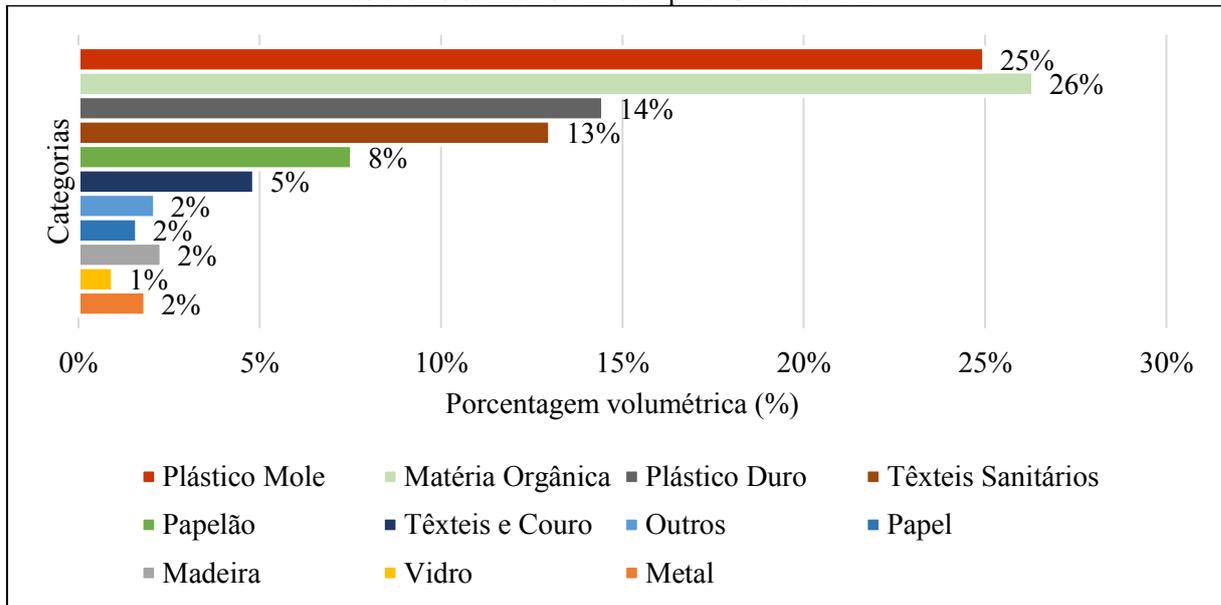
A composição volumétrica é um método que auxilia no gerenciamento e operação de aterros sanitários, uma vez que, é possível ter uma estimativa do espaço físico ocupado por cada fração de resíduos. As Figuras 32 e 33, apresentam respectivamente, a composição volumétrica aparente solta e compactada dos RSU que chegam ao ASCG.

Figura 32 - Composição volumétrica aparente solta dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande - PB.



Fonte: Acervo de pesquisa (2022).

Figura 33 - Composição volumétrica aparente compactada dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande - PB.



Fonte: Acervo de pesquisa (2022).

Nas Figuras 32 e 33, pode-se perceber a grande porcentagem volumétrica dos plásticos (mole e duro) e sua variação quando soltos e compactados. Os plásticos quando soltos (Figura 32), apresentam 48% do volume total de resíduos, quando esse tipo de resíduo foi compactado (Figura 33), seu volume diminuiu apresentando 40% do volume total dos RSU, que chegam ao ASCG. Ressalta-se, que os plásticos não apresentam a maior massa que chega ao ASCG, porém possuem grande volume e quando apresentados, podem diminuir a vida útil do aterro, ocupando boa parte do espaço do maciço, mesmo quando compactados, onde poderiam ser depositadas outras categorias de RSU. Outro fator agravante do excesso de plásticos no maciço é o efeito de “colchão”, expresso por Farias (2014), que passa uma falsa indicação de boa compactação desse material, o que pode prejudicar a operação do aterro.

A matéria orgânica registrou o maior aumento de volume após a compactação das frações de RSU, passando de 19% (Figura 32) para 26% (Figura 33). De acordo com Owusunimo *et al.* (2019), a deformação imediata causada pelo aterramento da fração orgânica de RSU, em aterros sanitários é pequena, independente da energia de compactação utilizada. Entretanto, o recalque ocorrido durante o tempo, sofre grande influência da biodegradação da parcela orgânica, uma vez que, esse material é transformado em subproduto líquido e gasoso.

Devido à grande parcela de disposição de resíduos do ASCG ser proveniente do município de Campina Grande – PB, pode-se ser realizada a comparação desse estudo com o de Araújo Neto (2016), que apresentou um volume de plásticos solto 53,5% e compactado 39,2% e de material putrescível 14,6% solto e 24,5% compactado. Portanto, verificou-se uma

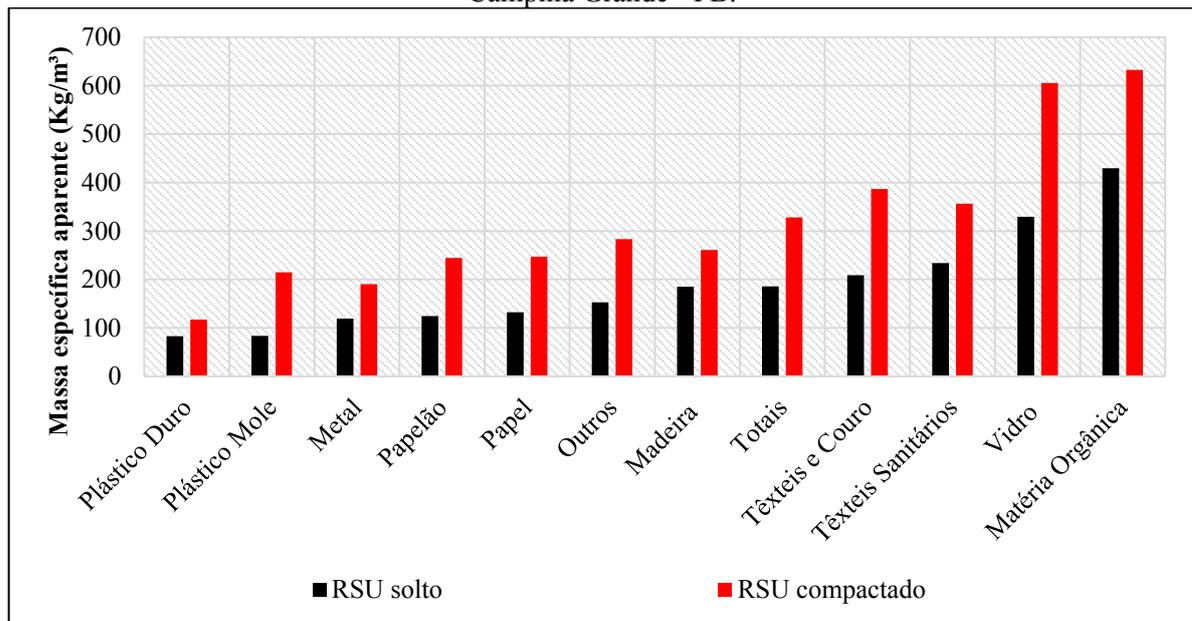
diminuição em 5,5% da fração volumétrica de plásticos solto e um aumento na porcentagem de matéria orgânica solta de 4,4% e compactada de 1,5%. Essas divergências partem do princípio da heterogeneidade dos RSU, bem como a mudança de comportamento da população pode contribuir para esta variação, uma vez que, os mesmos tipos de resíduos apresentam características diferentes, como por exemplo, tamanho de partículas, umidade e resistência, fatores que modificam o peso e espaço ocupado pelo material.

Os demais materiais avaliados nesse estudo, como: papel, papelão, vidro, metal, têxteis sanitários, têxteis e couro, madeira e outros, praticamente, não sofreram modificações quanto a variação volumétrica antes (33% do volume) e após a compactação (34% do volume). Deve-se destacar, que esses materiais ocupam grande volume no ASCG, devido à ausência de projetos de reaproveitamento ou reciclagem, o que poderia gerar empregos e renda, além de aumentar a vida útil do aterro sanitário em Campina Grande.

#### 4.1.3 Massa específica aparente solta e compactada dos Resíduos Sólidos Urbanos

Utilizando valores da composição gravimétrica e volumétrica dos RSU que chegam ao ASCG, obteve-se a massa específica aparente solta e compactada, conforme mostrado na Figura 34.

Figura 34 - Massa específica aparente dos Resíduos Sólidos Urbanos dispostos no aterro sanitário em Campina Grande - PB.



Fonte: Acervo de pesquisa (2022).

Na Figura 34, percebe-se que todas as categorias de resíduos apresentaram aumento na massa específica aparente após sua compactação. Por isso, entende-se que a compactação dos RSU, em aterros sanitários, deve ser realizada de maneira eficiente, mantendo a boa operação e aumentando a vida útil no empreendimento.

A massa específica aparente média dos RSU, que chegam ao ASCG, foi de  $185,4 \text{ kg.m}^{-3}$  para os resíduos soltos e de  $328,3 \text{ kg.m}^{-3}$  para os resíduos compactados (Figura 35). Existem diversos autores que estabelecem faixas aceitáveis de massa específica dos RSU, como: Tchobanoglous *et al.* (1993), que estabelece variações de 101 a  $355 \text{ kg.m}^{-3}$  para resíduos não compactados e 362 a  $492 \text{ kg.m}^{-3}$  para resíduos mediamente compactados, Mota (2000), que utiliza valores usuais de massa específica aparente solta da ordem de 200 a  $300 \text{ kg.m}^{-3}$  e Abreu (2000) indica faixas de 150 a  $350 \text{ kg.m}^{-3}$  para resíduos soltos e 350 a  $650 \text{ kg.m}^{-3}$  para resíduos mediamente compactados. Avaliando as massas específicas obtidas nessa pesquisa, é possível perceber que tanto a massa específica não compactada, quanto a massa específica compactada está enquadrada nos valores indicados por Tchobanoglous *et al.* (1993) e Abreu (2000).

Outros autores como Leite (2008), Garcez (2009) e Melo (2011), consideraram que a massa específica aparente compactada de  $700 \text{ kg.m}^{-3}$  são excelentes, até mesmo, para um bom funcionamento mecânico e biodegradativo de um maciço sanitário. As compactações excessivas, entretanto, podem diminuir a permeabilidade de líquidos no interior do maciço sanitário, que podem inibir ou dificultar os processos biodegradativos, por outro lado, a mal compactação dos RSU, pode causar problemas de estabilidade. Portanto, a compactação é um importante requisito a ser avaliado no empreendimento.

Os plásticos, metais e papel/papelão foram as frações que apresentaram menores massas específicas aparentes soltas e compactadas (Figura 34), indicando que precisam de mais espaço e volumes para serem dispostos em aterros. Para esses materiais, os plásticos são os resíduos com maior necessidade de volume em aterros sanitários. Porém, para materiais como plásticos, metais e papel/papelão, que são resíduos que possuem técnicas de reaproveitamento, pode-se diminuir o volume requerido em aterros, quando utilizados em sistemas de logística reversa, reciclagem e reaproveitamento desses compostos, aumentando assim a vida útil de aterro sanitário.

A matéria orgânica é um importante indicador de redução de volume em aterros, pois de acordo com Catapreta *et al.* (2006), com o tempo de operação, os aterros sanitários sobrepõem camadas de resíduos e tem intenso processo de biodegradação da fração orgânica, fatores que promovem a redução do volume do empreendimento e alteram sua estabilidade. Portanto, uma boa compactação dos resíduos associados aos processos de decomposição da

matéria orgânica, permite identificar melhor as mudanças geotécnicas, que podem ocorrer em um aterro sanitário, principalmente, em relação a sua estabilidade e aos processos de recalques (MELO, 2011).

#### 4.1.4 Massa específica real dos Resíduos Sólidos Urbanos

As massas específicas reais dos RSU, que chegam ao ASCG, são mostradas na Tabela 6.

Tabela 6 - Massa específica real dos RSU que chegam ao aterro sanitário em Campina Grande.

		<b>Sem imersão</b>	<b>Com imersão</b>
	Ensaio 1	783,24	1248,65
	Ensaio 2	806,49	1110,10
<b>Massa específica real (kg.m<sup>-3</sup>)</b>	Ensaio 3	807,69	1554,57
	<b>Média</b>	<b>799,14</b>	<b>1271,10</b>
	<b>Desvio padrão</b>	<b>13,78</b>	<b>173,33</b>

Fonte: Acervo de pesquisa (2022).

Nos ensaios realizados, verificou-se que a massa específica real média para os resíduos sem imersão foi de 799,14 kg.m<sup>-3</sup>, com 13,78 kg.m<sup>-3</sup> de desvio padrão. Já para os resíduos que passaram 12 horas de imersão, em água destilada, a média da massa específica real foi de 1304,44 kg.m<sup>-3</sup>, com 173,33 kg.m<sup>-3</sup> de desvio padrão. A diferença apresentada entre os dois tipos de amostras analisadas foi de 471,96 kg.m<sup>-3</sup>, provavelmente ligada ao tempo de imersão dos RSU em água.

Existem poucos estudos que tratam a respeito de metodologias para determinação da massa específica real dos RSU. Comparando os valores observados nesse trabalho (Tabela 8), em onde a massa específica real dos RSU foi de 1271,10 kg.m<sup>-3</sup> para RSU com imersão e 799,14 kg.m<sup>-3</sup> para RSU sem imersão, aos trabalhos de Yesiller *et al.* (2014) e Araújo Neto (2016), observa-se a proximidade dos resultados. Para resíduos novos Yesiller *et al.* (2014), encontrou uma faixa de massa específica real variando entre 1377 a 1530 kg.m<sup>-3</sup>. Já Araújo Neto (2016), realizou ensaios com e sem imersão, para amostras de RSU do município de Campina Grande - PB, onde com imersão apresentou 1343,3 kg.m<sup>-3</sup> e sem imersão 898,3 kg.m<sup>-3</sup>.

A massa específica real apresentou valores com maior proximidade a literatura quando foram testadas amostras com imersão. Essa diferença está associada a presença de ar nos vazios

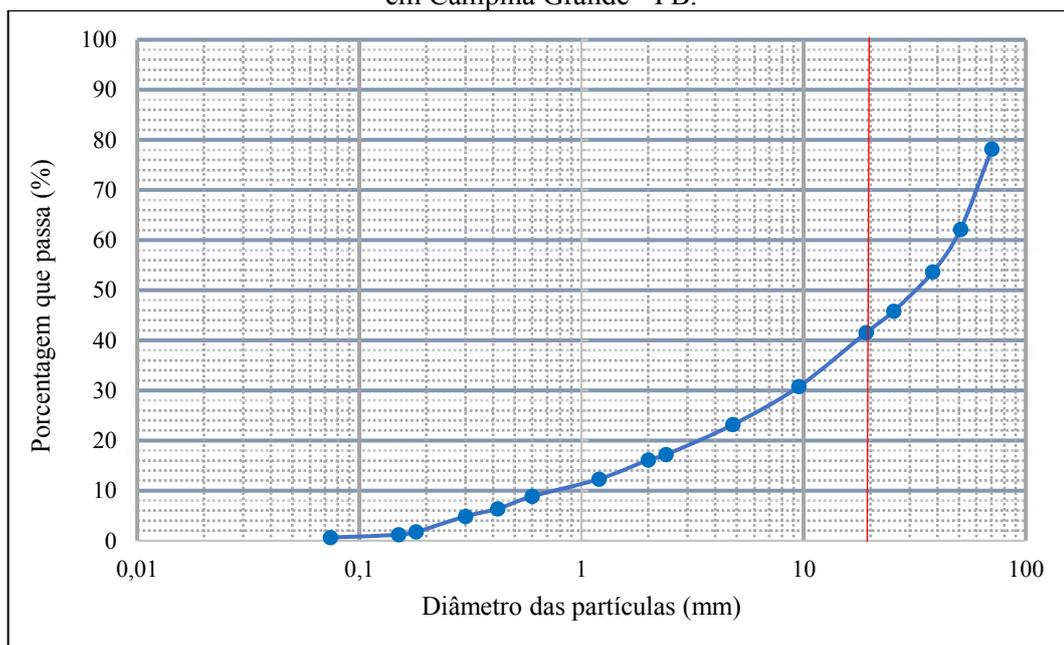
dos materiais que compõem os RSU, quando são utilizadas amostras sem imersão prévia de 12 horas. Por não existir metodologias para retirada completa do ar entre as estruturas do RSU, detecta-se variabilidade nas análises de massa específica real.

Portanto Yesiller *et al.* (2014) recomendam que para conhecer a massa específica real, devem-se analisar parâmetros físicos, químicos e biológicos. É viável ainda realizar a análise da densidade dos resíduos, a verificação do índice de vazios e aferição dos teores de umidade que representam o resíduo a ser analisado.

#### 4.1.5 Tamanho das partículas dos Resíduos Sólidos Urbanos

Na Figura 35, é apresentada a porcentagem em massa de partículas, em diferentes tamanhos, para os RSU que chegam ao ASCG.

Figura 35 - Curva granulométrica para os Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande - PB.



Fonte: Acervo de pesquisa (2022).

A norma *Remecom* (Defra, 2004), considera a porcentagem de finos as partículas com diâmetros inferiores a 20 mm. Portanto, analisando os resultados, pode-se identificar na Figura 35, os resíduos que chegam ao ASCG apresentaram cerca de 41% de partículas passantes na peneira 19,1 mm, ou seja, partículas finas.

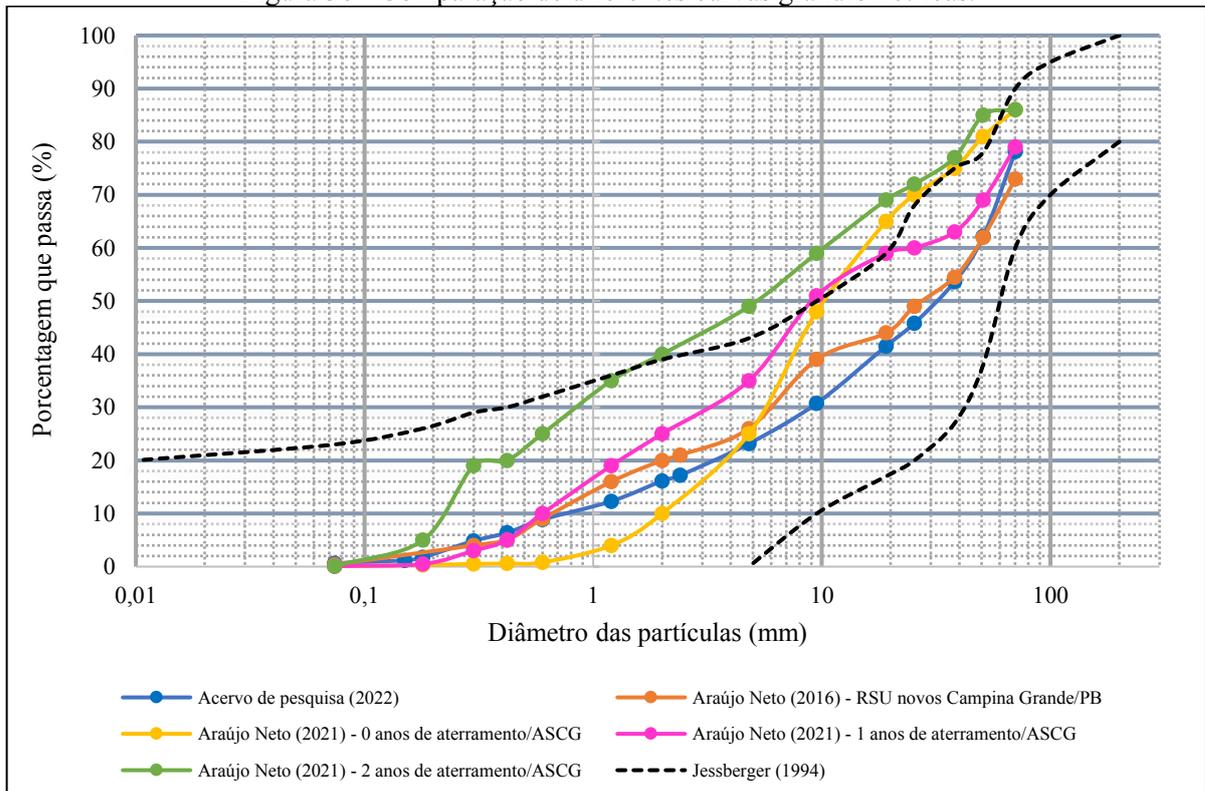
De acordo com Alcântara (2007), um fator que acelera a biodegradação dos resíduos é a influência do tamanho das partículas identificadas, pois quanto menor o material particulado,

maior a superfície de contato entre os resíduos e os microrganismos presentes no aterro sanitário, conseqüentemente, maior a atividade biológica e transformação de matéria em líquidos e gases. Mesmo assim, deve-se destacar que a elevada biodegradação de resíduos não apenas ao tamanho das partículas, mas ao tipo do material a ser degradado. Outro fator que deve estar associado à presença de finos é a ocorrência de recalques mais acentuados no maciço sanitário, devido a facilidade de biodegradação de finos.

A heterogeneidade intrínseca dos RSU é a justificativa principal quando se trata da divisão entre a fração grossa e fina dos resíduos, já que os materiais encontrados na granulometria eram de diversos tipos, formas e volumes. Portanto, a medida de que o diâmetro da malha das peneiras diminui, houve um aumento na densidade dos materiais, por isso, obteve-se uma curva granulométrica bem graduada. A fração grossa do resíduo, representado pelos 37% da amostra total favorecem a geração de vazios, podendo causar recalques devido à acomodação das partículas ao longo do tempo.

Os ensaios para verificar a granulometria dos RSU, apresentada na Figura 36, confronta a curva granulométrica dos RSU que chegam ao ASCG, com os RSU com idades de aterramento 0, 1 e 2 anos, determinada por Araújo Neto (2021), e com as curvas sugeridas por Jessberg (1994) que indicam a faixa granulométrica média dos RSU.

Figura 36 - Comparação de diferentes curvas granulométricas.



Fonte: Acervo de pesquisa (2022).

Em primeiro plano, verifica-se se que apenas as curvas granulométricas dos RSU, que chegam ao ASCG e o estudo de Araújo Neto (2016), estão totalmente entre o intervalo sugerido por Jessberg (1994). Os RSU com 0 anos de aterramento, apresentaram-se, quase totalmente dentro da faixa de Jessberg (1994), uma vez que, apenas diâmetros acima de 10 mm ficaram fora da faixa. Já os RSU com 1 ano de aterramento, apresentou valores fora da faixa apenas no intervalo de diâmetro das partículas entre 10 e 20 mm. Por último, os resíduos com 2 anos de aterramento, apresentaram a maior dispersão em relação à faixa estabelecida por Jessberg (1994), sendo que, a curva granulométrica apresentou discrepância, a partir do diâmetro de partículas superior a 2 mm. Os RSU aterrados apresentaram comportamentos fora dos padrões estabelecidos por Jessberg (1994), uma vez que, se mostram fora das curvas estipuladas, essas diferenças são justificadas principalmente, pela heterogeneidade e processos biodegradativos dos resíduos.

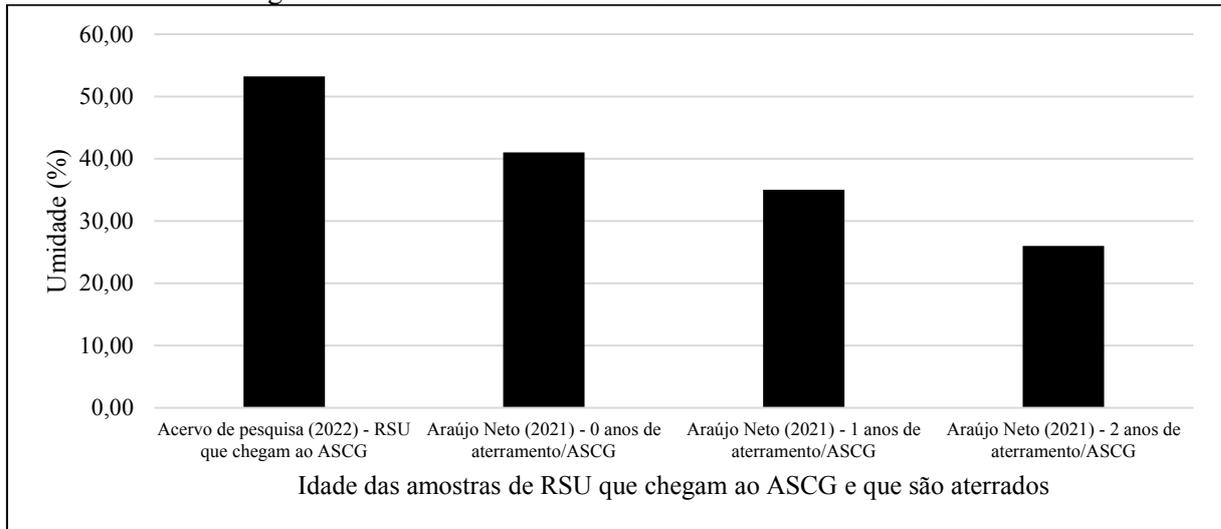
A partir da Figura 37, é possível observar o comportamento da curva gravimétrica dos RSU, levando em consideração todo o período de disposição e aterramento, ou seja, do período que o RSU chega ao ASCG até alcançar 2 anos de aterramento. Observa-se, que o teor de finos (<20mm) variou entre 41% e 68%. Sendo que, o maior percentual de finos encontra-se nos resíduos com 2 anos de aterramento e o menor foi constatado nos resíduos que chegam ao ASCG. Os processos biodegradativos causam a decomposição dos materiais presentes no RSU, diminuindo e transformando certos materiais, quanto menores dimensões das partículas, maior a interação com os microrganismos e conseqüentemente a degradação.

Não houve diferenças significativas nas análises das frações grossas (>20mm) para os resíduos aterrados, variações entre 10% e 20%, porém, ressalta-se uma diminuição quando comparado os resíduos aterrados e o RSU que chega ao ASCG (fração grossa: 37%).

#### **4.1.6 Teor de umidade dos Resíduos Sólidos Urbanos**

A umidade média das amostras dos RSU, que chegam ao aterro sanitário, está apresentada na Figura 37. Esse valor é confrontado com os teores de umidade determinados por Araújo Neto (2021), para diferentes idades de aterramento. Observa-se que o teor de umidade possui uma tendência decrescente de acordo com a idade de aterramento dos resíduos no ASCG.

Figura 37 - Umidade dos Resíduos Sólidos Urbanos do ASCG.



Fonte: Acervo de pesquisa (2022).

O teor de umidade observado para os RSU que chegam ao ASCG foi registrado em 53,24% (Figura 37). Esse valor está em conformidade com Bidone e Povinelli (1999), que obtiveram uma faixa ótima de umidade, compreendida entre 40% e 60%. Já o CEMPRE (2000) estima um teor de umidade, em uma faixa típica de 60 a 80%, devido à quantidade elevada de matéria orgânica existente nos resíduos das cidades na maioria das regiões do Brasil. No município de Campina Grande - PB, Ribeiro (2012), estabeleceu a faixa ótima para resíduos soltos entre 40% e 60%. Tchobanoglous (1993), apresentou valores diferentes para resíduos de aterros sanitários nos EUA, por exemplo, apresentando uma faixa de teor de umidade entre 15% e 40%.

Portanto, o elevado teor de umidade dos resíduos que chegam ao ASCG pode estar associado ao percentual gravimétrico de matéria orgânica (44%) obtidos nesse trabalho. O clima também influencia a umidade dos RSU, devido à infiltração das águas pluviométricas nas camadas de cobertura. Para resíduos novos, Melo (2011), estabelece que altos teores de umidade e aumento da lixiviação, também são favorecidos em determinados períodos do ano pelos valores de precipitação, que em Campina Grande - PB alcançam a média anual de 700 mm. O ASCG, apresentou um teor de umidade para os resíduos que chegam, enquadrados ou bem próximos as faixas de umidade ótima citadas anteriormente.

A umidade dos resíduos que chegam deve estar próxima as faixas ótimas estabelecidas na literatura, pois, o teor de umidade, nos maciços sanitários é um fator importante na velocidade de degradação dos materiais putrescíveis, acarretando desenvolvimento de pressões neutras e recalques na célula de resíduos.

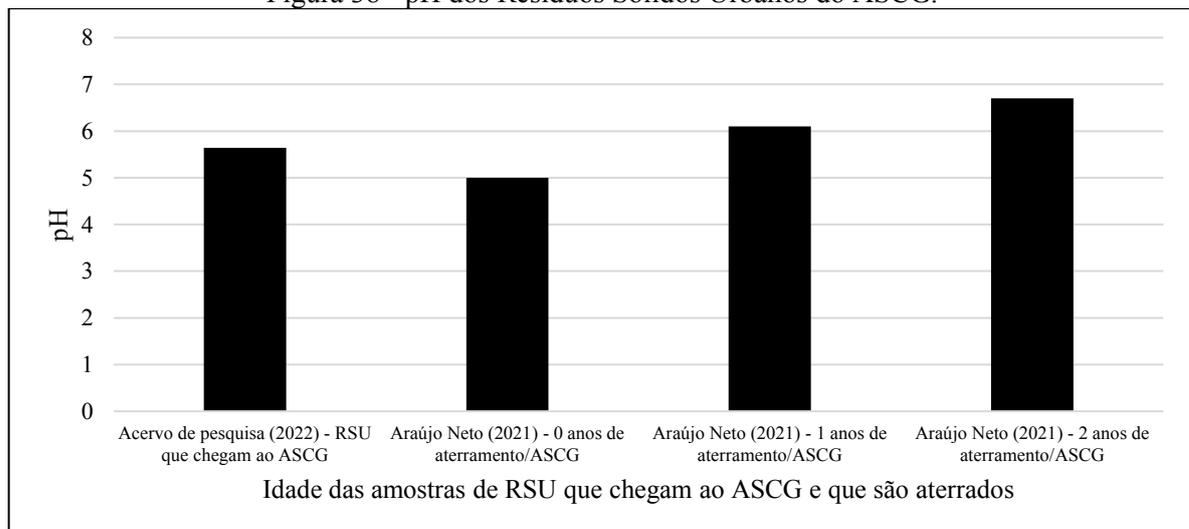
O comportamento do teor de umidade dos resíduos que chegam é variável, de modo que, cada componente de RSU tem diferentes teores de umidade. Por isso, o teor de umidade dos resíduos sólidos novos é um parâmetro que varia de acordo com a composição gravimétrica, clima, frequência de coleta e disposição final e desenvolvimento da região. Já os resíduos aterrados sofrem influência de parâmetros mais específicos como a composição gravimétrica, pluviometria, drenagem superficial e de base, profundidade e a ocorrência ou não da recirculação do lixiviado (BOSCOV, 2008).

Analisando a Figura 37, pode-se perceber que o teor de umidade no ASCG tem uma tendência decrescente e seu comportamento difere do comportamento apresentado em outros aterros sanitários, em que a umidade tende a aumentar de acordo com o tempo de aterramento (REDDY *et al.*, 2015). Araújo Neto (2021), justifica a diminuição de umidade de acordo com as características do aterro em Campina Grande - PB: grande espessura da camada de cobertura (chegando a 1 m), que dificulta a infiltração de água superficial e a recirculação do lixiviado e o clima do município onde o empreendimento está inserido, caracterizando-se como semiárido, com baixa pluviometria e elevada evaporação.

#### 4.1.7 pH dos Resíduos Sólidos Urbanos

Pode-se considerar que o pH das amostras de RSU (Figura 38), é equiparado a um sistema típico de digestão anaeróbia.

Figura 38 - pH dos Resíduos Sólidos Urbanos do ASCG.



Fonte: Acervo de pesquisa (2022).

Observa-se na Figura 38, que o pH do extrato de resíduos sólidos apresentou uma evolução típica do processo de digestão anaeróbia em aterros, em que inicialmente, os resíduos novos apresentaram um valor médio de pH abaixo da neutralidade, em torno de 5,6, este valor indica um meio com características ácidas ou ligeiramente ácidas. Os resíduos que chegam ao ASCG, praticamente não apresentaram diferença de pH em relação aos resíduos recém aterrados (0 anos) estudados por Araújo Neto (2021).

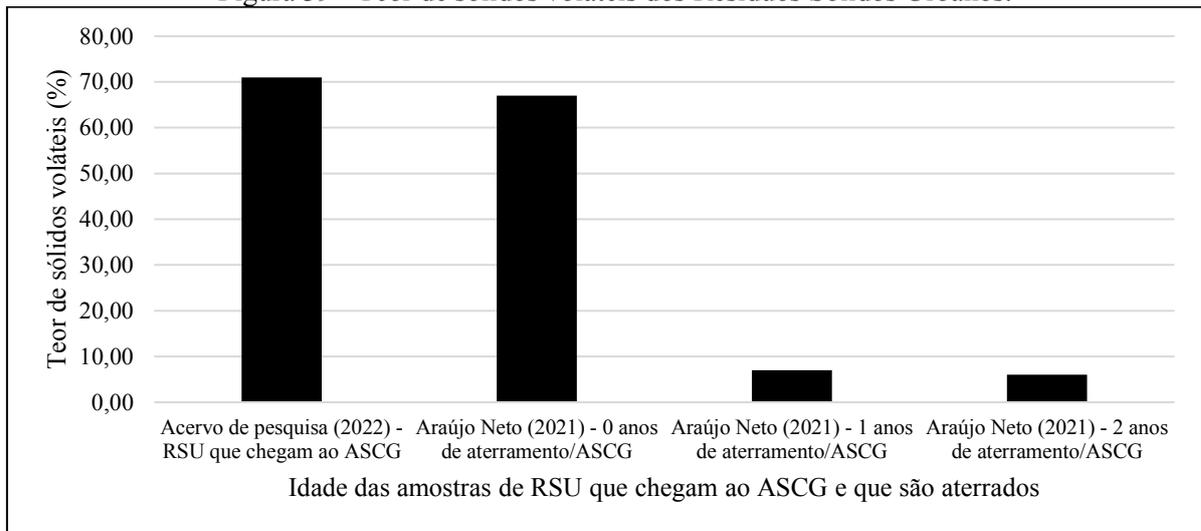
De acordo com Nascimento *et al.* (2022), os resíduos sofrem uma redução inicial do pH pela ação das bactérias acidogênicas, as quais liberam rapidamente concentrações de ácido láctico, amônia e ácidos graxos voláteis, que conferem aos resíduos novos pH abaixo da neutralidade. Esse comportamento é esperado e deve-se manter abaixo de 6,5 para resíduos frescos ou com pequenas idades de aterramento (<5 anos) (TENG *et al.*, 2021).

Os dados na Figura 38, revelam uma elevação do pH de 5,6 para 6,7 após 2 anos de aterramento. A faixa que o pH dos resíduos amostrados do ASCG, encontra-se de acordo com Teng *et al.* (2021), indica que o nível de biodegradação do ASCG equivale a um aterro de média idade (5 a 10 anos), possuindo seu pH entre 6,5 e 7,5. Portanto, o ASCG possui um processo biodegradativo acelerado, devido as condições operacionais do aterro sanitário e as condições climáticas da região, esse fato é corroborado com estudos de Araújo Neto (2021) e Silva (2022).

#### **4.1.8 Teor de sólidos suspensos voláteis dos Resíduos Sólidos Urbanos**

A Figura 39, apresenta a evolução temporal dos sólidos voláteis. Pode-se observar que, os valores de sólidos voláteis apresentaram valores elevados para resíduos novos ou com pouco tempo de aterramento, reduzindo significativamente ao longo do período analisado.

Figura 39 - Teor de sólidos voláteis dos Resíduos Sólidos Urbanos.



Fonte: Acervo de pesquisa (2022).

Os resíduos que chegam ao ASCG apresentaram alto teor de sólidos voláteis, em torno de 70%, característica apresentada em análises de resíduos frescos. Outros aterros apresentaram comportamentos semelhantes, como no caso de Firmo (2013) que detectou 82,97% de teor de sólidos voláteis nos resíduos frescos em Recife – PE. Os sólidos voláteis de RSU que chegam ao ASCG se aproximaram com os resíduos recém aterrados (0 anos de aterramento), corroborando a existência de grande quantidade de material orgânico nos dois estudos.

O teor de sólidos voláteis muitas vezes é utilizado para quantificar a biodegradabilidade dos resíduos sólidos, pois quando uma amostra é submetida a uma temperatura de calcinação de 550°C, a fração orgânica é oxidada, reduzindo a massa inicial. Embora os SV indiquem de forma indireta a quantidade de matéria orgânica a ser degradada nos resíduos, não há necessariamente relação direta entre sólidos voláteis, DQO e DBO. A DBO, por exemplo, será elevada se os sólidos voláteis forem facilmente biodegradáveis, mas será baixa se eles forem recalcitrantes (NASCIMENTO *et al.*, 2022).

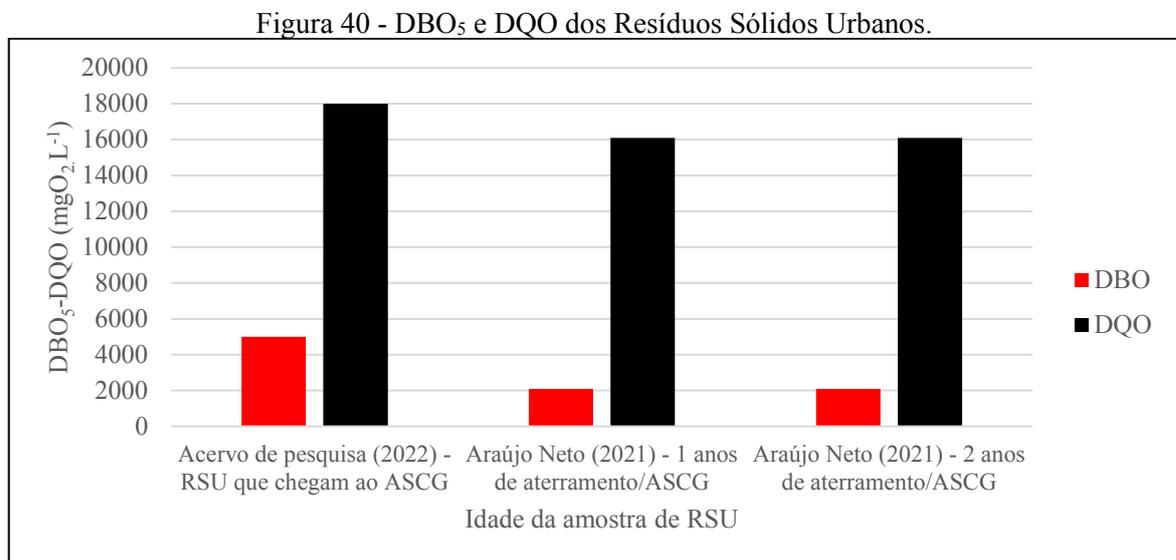
Verificam-se abruptas diminuições nos teores de sólidos voláteis a partir de 1 ano de aterramento, saindo da faixa de 60% a 70%, para valores abaixo dos 10%, indicando uma elevada atividade biológica. Araújo Neto (2021), afirma que o teor de sólidos voláteis também pode sofrer reduções pela inserção do solo, utilizado para a cobertura de resíduos em aterros, antes e após a operação de células.

Kelly (2002) e Decottignies *et al.* (2005), afirmam que os resíduos sólidos com teores de sólidos voláteis inferiores a 10% correspondem a um material já bioestabilizado. Outros trabalhos corroboram para afirmar essa faixa percentual, como por exemplo, Fucale (2005), que observou um teor de sólidos voláteis de 10,5% para resíduos estabilizados na Alemanha; Russo

(2005), que também verificou uma faixa de 1,7% a 2,6% em resíduos com 10 anos de aterramento em Portugal; bem como Alves (2008), estudou os resíduos com 7 anos de aterramento do aterro da Muribeca – PE.

#### 4.1.9 DBO<sub>5</sub> e DQO dos Resíduos Sólidos Urbanos

A Figura 40, apresenta a evolução da DQO e DBO<sub>5</sub> ao longo do tempo de aterramento. Esses parâmetros são importantes para estimativas de situação de biodegradação da matéria orgânica nos RSU.



Fonte: Acervo de pesquisa (2022).

Observa-se na Figura 40, que a DQO sofre pequenas variações de acordo com o tempo de aterramento, variando entre os resíduos que chegam ao ASCG e os resíduos com 2 anos de aterramento. Essa variação, se dá, respectivamente, de 18000 mgO<sub>2</sub>.L<sup>-1</sup> para 16000 mgO<sub>2</sub>.L<sup>-1</sup>. Já a DBO<sub>5</sub>, sofre uma variação mais brusca, saindo de 4500 mgO<sub>2</sub>.L<sup>-1</sup> para 2000 mgO<sub>2</sub>.L<sup>-1</sup>. As concentrações de DBO<sub>5</sub> e DQO tendem a sofrer reduções ao longo da degradação dos resíduos aterrados, contudo a concentração de DQO decresce mais lentamente em relação à DBO<sub>5</sub>, uma vez que, a DQO é um parâmetro que pode ser relacionado com os mais diversos tipos de matéria orgânica (facilmente degradável e a dificilmente degradável) (NASCIMENTO *et al.*, 2022).

Segundo Tchobanoglous, Theisen e Vigil (1993) e Hamada (1997), deve ser feita a relação DBO<sub>5</sub>/DQO, pois é a partir desta relação que é possível inferir qual o estágio de degradação em que se encontram os resíduos. Teng *et al.* (2021), informam faixas as quais os aterros são inseridos de acordo com a relação DBO<sub>5</sub>/DQO. Para aterros velhos (>10 anos) a

relação  $DBO_5/DQO$  de ser menor que 0,1, em aterros com média idade (5 a 10 anos) varia de 0,1 a 0,5 e para aterros novos (<5 anos) deve ser maior que 0,5. Portanto, a relação  $DBO_5/DQO$  para o aterro sanitário em Campina Grande – PB, considerando os resíduos que chegam ao ASCG, com 1 ano e 2 anos de aterramento, têm valores respectivos de, 0,27, 0,13 e 0,13, que são característicos de aterros com idade entre 5 e 10 anos, indicando rápida a estabilização dos RSU depositados nesse empreendimento.

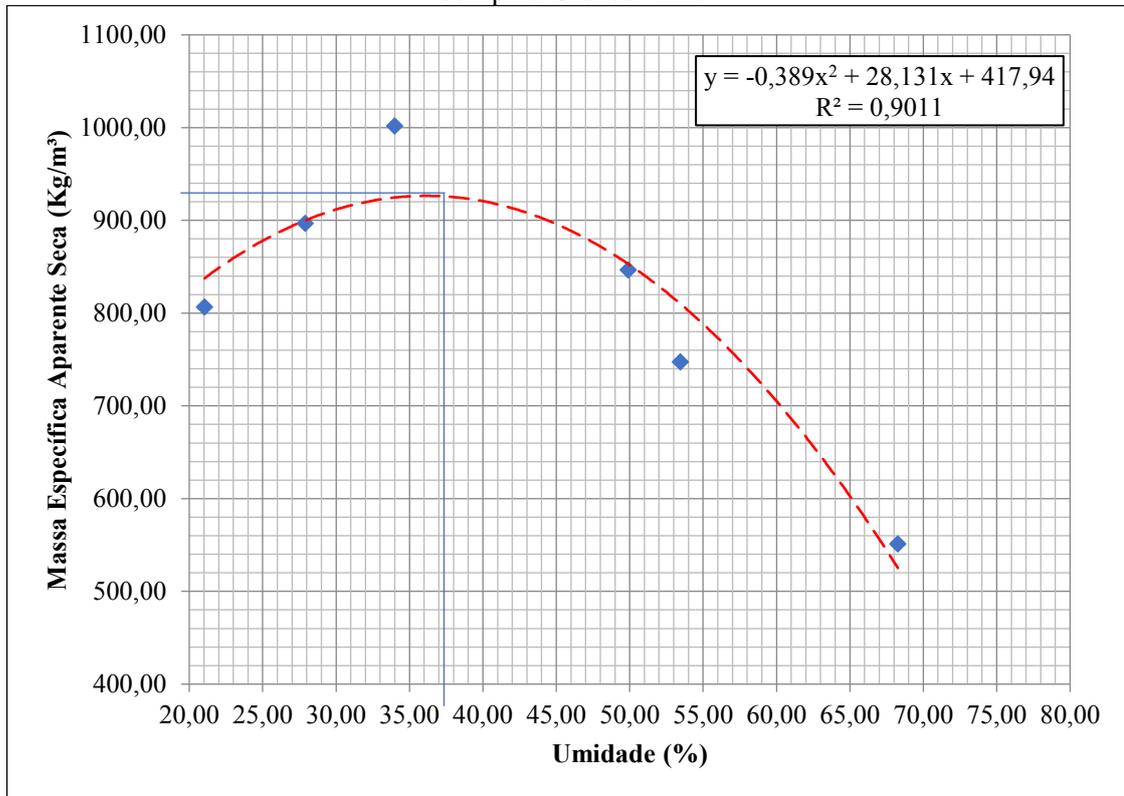
De acordo com os resultados obtidos da caracterização físico-química no ASCG, pode-se notar uma mudança temporal da composição desses resíduos, influenciando no comportamento geral desse empreendimento. É interessante ressaltar, que as mudanças, físicas ou químicas atreladas ao tempo, modificam também, as características comportamentais do aterro, em relação às propriedades geotécnicas do maciço, evidenciando os recalques e a estabilidade do aterro.

## **4.2 Caracterização geotécnica dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário em Campina Grande**

### **4.2.1 Compactação dos Resíduos Sólidos Urbanos**

O ensaio de laboratório de compactação permitiu a obtenção da massa específica seca máxima e do teor de umidade ótimo, utilizando energia de Proctor normal, como mostra a Figura 41.

Figura 41 - Curva de compactação dos Resíduos Sólidos Urbanos que chegam ao aterro sanitário de Campina Grande - PB.



Fonte: Acervo de pesquisa (2022).

Observa-se que a massa específica seca máxima observada para os resíduos que chegam ao ASCG foi aproximadamente,  $920 \text{ kg.m}^{-3}$  e a umidade ótima foi de 37,2%.

Na literatura encontram-se diferentes valores que corroboram com os resultados verificados na compactação dos RSU, que chegam ao ASCG. Reddy *et al.* (2009) determinaram uma massa específica seca máxima de  $420 \text{ kg.m}^{-3}$  e teor de água ótimo de 70% para os resíduos frescos, que chegam ao aterro sanitário de *Orchard* nos Estados Unidos. Cox *et al.* (2015), relatam que o peso específico máximo pode variar entre  $500 \text{ kg.m}^{-3}$  e  $850 \text{ kg.m}^{-3}$  e o teor de umidade ótima entre 45% e 80%, dependendo das condições operacionais do aterro e da energia de compactação utilizada.

Constatou-se que os resíduos que chegam ao ASCG, são compactados com uma umidade de 53,5%, apresentando-se acima da ótima que é de 37,2% (Figura 41). Portanto, verifica-se que durante a compactação dos resíduos no maciço sanitário, há um volume sobressalente de água, que por sua vez, aumentará o volume ocupado pelos resíduos. Para evitar esse fenômeno, a realização de uma pré-secagem dos resíduos, objetivando diminuição do volume de água nos vazios para redução do volume total requerido na célula e aumento da vida útil do empreendimento.

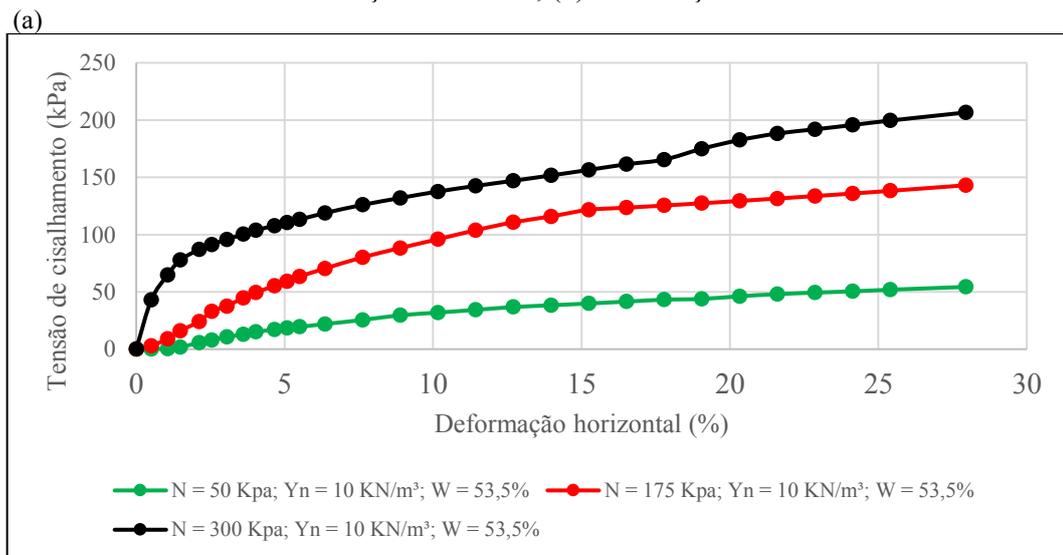
O comportamento da compactação dos RSU muda de acordo com a idade de aterramento desses resíduos. As curvas de compactação indicam um peso específico seco máximo  $920 \text{ kg.m}^{-3}$ ,  $810 \text{ kg.m}^{-3}$ ,  $670 \text{ kg.m}^{-3}$  e  $690 \text{ kg.m}^{-3}$  e umidade ótima de 37,2%, 34%, 35% e 48%, para os resíduos que chegam ao ASCG (Figura 41) e com 0, 1 e 2 anos de aterramento, como especificado por Araújo Neto (2021), respectivamente.

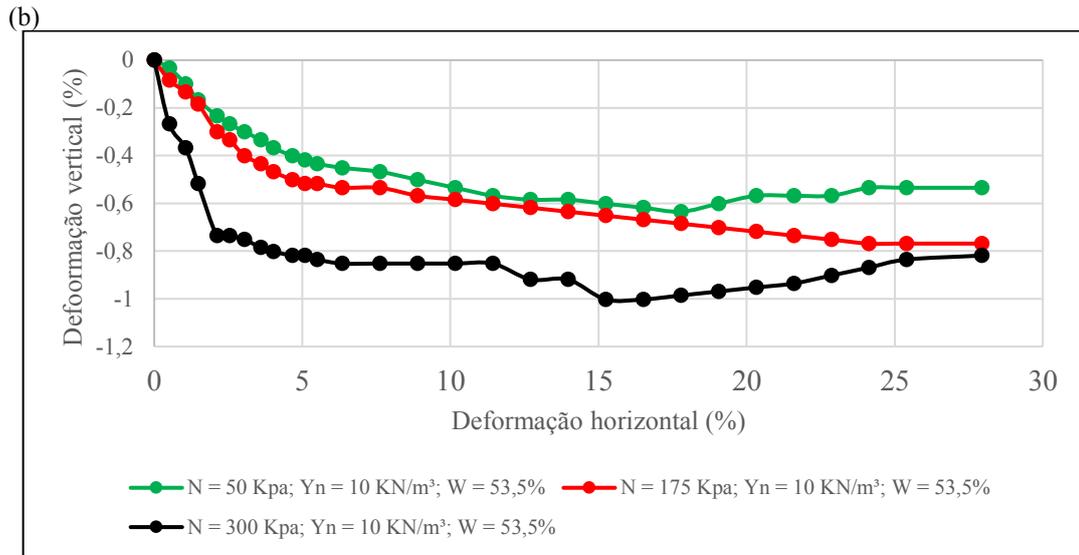
Uma boa compactação em campo, quando se trata de maciços sanitários, deve ser aquela que favoreça, além da estabilidade, uma boa degradabilidade dos resíduos, diminuição da vazão de líquidos lixiviados e trânsito imediato sobre o maciço. Quando o grau de compactação é excessivo, pode-se inibir os processos biodegradativos e, conseqüentemente, os aterros terão suas deformações retardadas, refletindo em um menor tempo de vida útil do empreendimento (CATAPRETA, 2008).

#### 4.2.2 Resistência ao cisalhamento direto dos Resíduos Sólidos Urbanos

Os ensaios de cisalhamento foram realizados, em laboratório, com amostras RSU que chegam ao ASCG, objetivando determinar o ângulo de atrito e o coeficiente de coesão para as condições semelhantes de campo. Os resultados do ensaio de cisalhamento direto para as condições não inundadas estão expressos na Figura 42.

Figura 42 - Resistência ao cisalhamento não inundada dos Resíduos Sólidos Urbanos: (a) tensão de cisalhamento-deformação horizontal; (b) deformações vertical-horizontal.





Fonte: Acervo de pesquisa (2022).

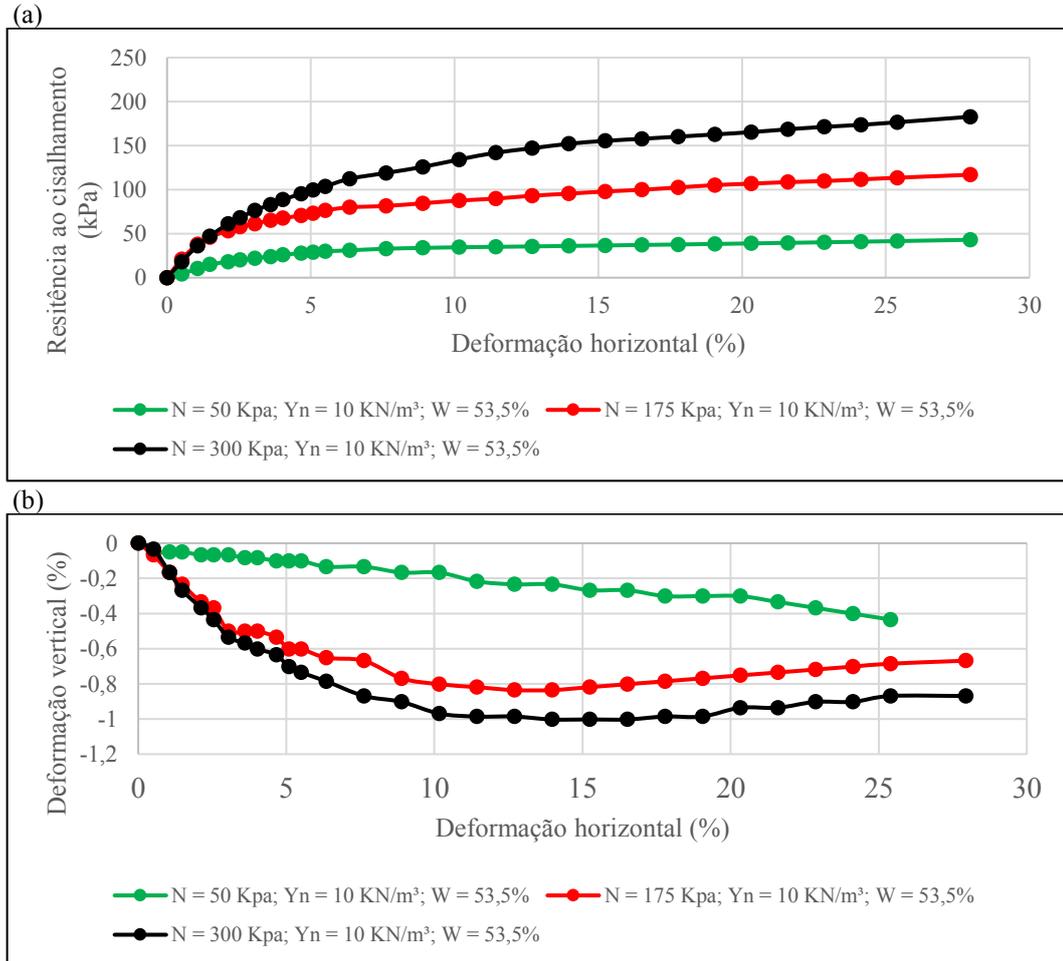
A partir da análise da Figura 42a, pode-se perceber que a tensão desviadora de cada curva tensão-deformação aumentou continuamente, pela influência da deformação axial, sem atingir um valor assintótico (valor de pico). De acordo com Zhan, Chen e Ling (2008), esse comportamento pode indicar que o efeito de reforço, contribuído pelos materiais fibrosos, torna-se maior em altos níveis de deformação e sob alta pressão de confinamento. Essa característica, faz com que o resíduo atinja padrões de um solo reforçado por fibras, concedendo maior estabilidade ao maciço sanitário.

Diferentes autores mostram em seus trabalhos tendências similares de resistência ao cisalhamento por deformação horizontal, quando observam amostras de RSU para diferentes condições. Por exemplo, Chen e Ling (2008) testaram amostras de resíduos com 6 a 9 anos de idade de aterramento e 44% a 100% de umidade, Redy *et al.* (2009), fez testes de cisalhamento para resíduos frescos com  $0,5 \text{ kN.m}^{-3}$  e 45,4% de umidade, Chouksey e Babu (2015), variaram o tamanho das partículas de resíduo e fixaram o peso específico em  $10,5 \text{ kN.m}^{-3}$  e umidade em 44% e Araújo Neto (2021), alternou a idade de aterramento (0 a 2 anos), o peso específico ( $10$  a  $15 \text{ kN.m}^{-3}$ ) e o teor de umidade (34 a 65%). Todos os trabalhos citados obtiveram curvas de cisalhamento com comportamentos similares aos encontrados nesta pesquisa.

As curvas de deformação vertical versus deformação horizontal mostradas na Figura 42b, para o peso específico de  $10 \text{ kN.m}^{-3}$  e 53,5% de umidade, demonstram que a amostra com tensão normal de 175 kPa exibiu um comportamento apenas compressivo durante o cisalhamento. Já as amostras com tensão normal de 50 kPa e 300 kPa, apresentaram um comportamento compressivo no início do ensaio e expansivo ao final.

Os resultados dos ensaios de resistência ao cisalhamento inundado estão mostrados na Figura 43.

Figura 43 - Resistência ao cisalhamento inundada dos Resíduos Sólidos Urbanos. (a) tensão de cisalhamento-deformação horizontal; (b) deformações vertical-horizontal.



Fonte: Acervo de pesquisa (2022).

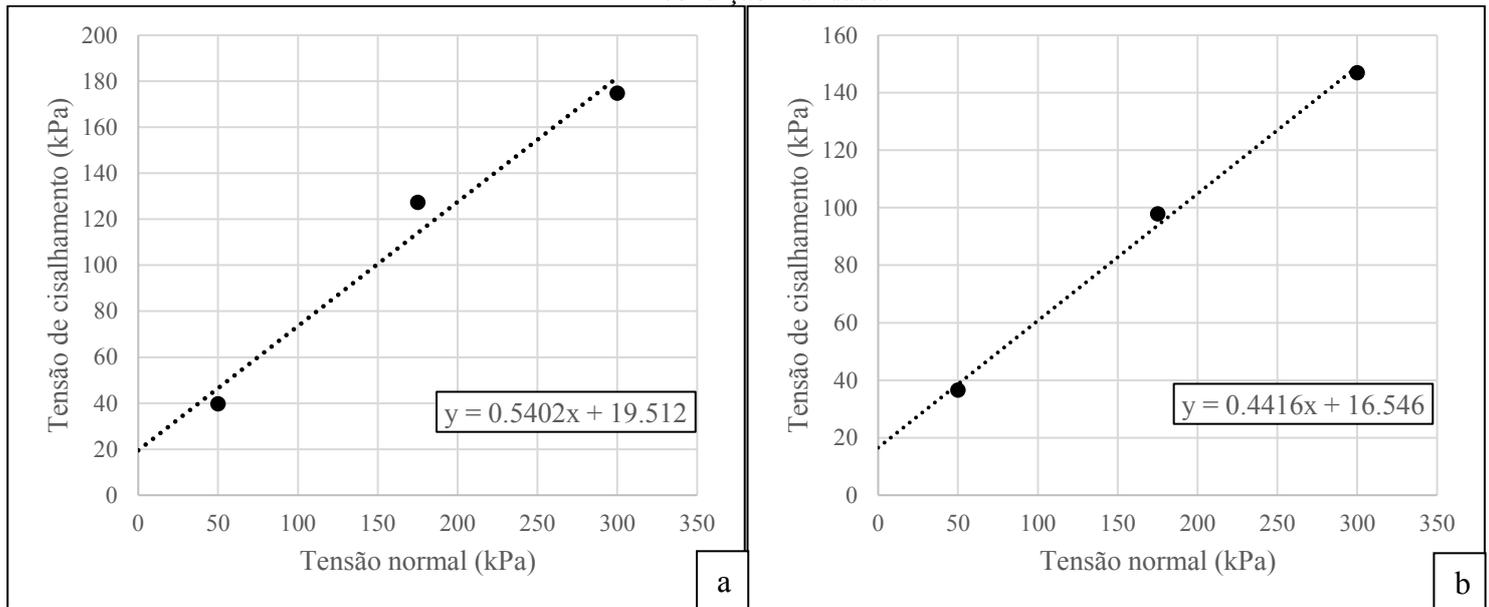
Observa-se na Figura 43a que o comportamento das curvas de cisalhamento para a condição de ensaio inundada, se aproximam com as curvas observadas nos ensaios não inundados. Portanto, verifica-se o crescimento sem tendência de pico. Quando se compara a curva tensão cisalhante versus deformação horizontal, da condição inundada e não inundada, verifica-se nas Figuras 42a e 43a, que os resíduos na condição inundada possuem tensões cisalhantes inferiores e faz-se necessário maiores deslocamentos horizontais para atingirem maiores tensões cisalhantes, principalmente para a tensão normal de 300 kPa.

Já quando analisadas as curvas de deformação vertical versus deformação horizontal (Figura 43b), observa-se que para o ensaio inundado, os resíduos submetidos a tensão de 50 kPa apresentaram um comportamento compressivo, já que houve decaimento da curva.

Observa-se que, as curvas dos resíduos submetidos as cargas de 175 kPa e 300 kPa, têm comportamentos semelhantes, onde passam por um processo compressivo ao início do ensaio e expansivo ao final.

A Figura 44 apresenta as envoltórias de ruptura dos RSU, que chegam ao ASCG, para o ensaio não inundado (Figura 44a) e para o ensaio inundado (Figura 44b).

Figura 44 - Envoltórias de ruptura dos resíduos que chegam ao ASCG. (a) condição não inundada; (b) condição inundada.



Fonte: Autores (2022).

A partir da análise das envoltórias é possível obter os parâmetros de ângulo de atrito e intercepto coesivo, relacionados com os ajustes das curvas. Esses valores são mostrados na Tabela 7.

Tabela 7 - Parâmetros de resistência dos RSU que chegam ao ASCG.

Condição	$\phi$ (°)	c (kPa)
<b>Não inundado</b>	28,38	19,51
<b>Inundado</b>	23,75	13,45

Fonte: Acervo de pesquisa (2022).

Verifica-se de acordo com a Tabela 7, que o ângulo de atrito e o intercepto coesivo foi menor na condição inundada. O ângulo de atrito dos RSU pode estar ligado ao grau de compactação, composição gravimétrica, tamanho e forma dos resíduos. As partículas com menores dimensões (como matéria orgânica) podem envolver as maiores, diminuindo o atrito

interno e favorecendo a estabilidade dos maciços. Desta forma, quanto maior o ângulo de atrito, maior a quantidade de partículas que diminuem os atritos entre as partículas de resíduos.

O estudo do comportamento tensão-deformação-resistência de RSU ainda é um tema complexo, principalmente, devido aos efeitos da heterogeneidade de seus constituintes, visto que materiais inertes coexistem com matrizes altamente deformáveis e/ou biodegradáveis. Landva & Clark (1986) realizaram ensaios de cisalhamento direto a determinação da resistência de RSU de amostras de resíduos novos e velhos. Para resíduos velhos obtiveram  $\phi = 38^\circ$  a  $42^\circ$  e  $c = 14\text{kPa}$  a  $19\text{kPa}$  e para resíduos novos encontraram  $\phi = 24^\circ$  e  $c = 23\text{kPa}$ . Observa-se que, os valores de ângulo de atrito e intercepto coesivo encontrados nesta pesquisa (Tabela 7), ficaram próximos aos observados por Landva & Clark (1986).

Araújo Neto (2021), realizou ensaios de resistência ao cisalhamento, para resíduos aterrados, verificando a influência do peso específico sobre a resistência. Analisando os parâmetros para o peso específico de  $10\text{kPa}$ , o ângulo de atrito apresentou pouca ou nenhuma variação para os resíduos com menor peso específico ( $10\text{kPa}$ ), entre  $25,9^\circ$  e  $28,4^\circ$ , e maior umidade (65%) nas três idades de aterramento (0, 1 e 2) na condição não inundada. Para esta configuração, a coesão aumentou de  $0\text{kPa}$  para  $19,1\text{kPa}$ , quando comparado os resíduos com 0 e 1 ano de aterrados e de  $0\text{kPa}$  para  $7\text{kPa}$ , quando comparados os resíduos com 0 e 2 anos de aterrados.

### **4.3 Análise descritiva dos dados**

#### **4.3.1 Estatística descritiva dos dados temporais dos Resíduos Sólidos Urbanos**

A Tabela 8, demonstra a avaliação inicial (média, desvio padrão, coeficiente de variação, máximo e mínimo) dos parâmetros estudados e identificados a respeito dos resíduos que chegam ao ASCG e recém aterrados, 1 e 2 anos de aterramento.

Tabela 8 - Estatística descritiva das características temporais dos RSU no ASCG.

<b>Parâmetros avaliados</b>	<b>Média</b>	<b>Desvio Padrão</b>	<b>Coefficiente de Variação</b>	<b>Valor máximo</b>	<b>Valor mínimo</b>
<b>pH</b>	5.86	0.72	12.27	6.70	5.00
<b>Teor de sólidos voláteis (%)</b>	37.75	36.12	95.69	71.00	6.00
<b>DBO<sub>5</sub> (mgO<sub>2</sub>.L<sup>-1</sup>)</b>	2825.00	1450.00	51.33	5000.00	2100.00
<b>DQO (mgO<sub>2</sub>.L<sup>-1</sup>)</b>	16575.00	950.00	5.73	18000.00	16100.00
<b>Y<sub>n</sub> máxima (kg.m<sup>-3</sup>)</b>	772.50	116.15	15.04	920.00	670.00
<b>W ótima (%)</b>	38.55	6.44	16.71	48.00	34.00
<b>W campo (%)</b>	38.88	11.54	29.67	53.50	26.00
<b>Papel/papelão (%)</b>	5.00	1.41	28.28	7.00	4.00
<b>Plásticos (%)</b>	14.25	6.55	45.97	22.00	6.00
<b>Vidro (%)</b>	1.25	0.50	40.00	2.00	1.00
<b>Metal (%)</b>	2.25	0.50	22.22	3.00	2.00
<b>Matéria Orgânica (%)</b>	14.75	19.50	132.20	44.00	5.00
<b>Outros (%)</b>	63.00	28.79	45.69	81.00	20.00
<b>Qt. finos (%)</b>	58.25	12.09	20.76	68.00	41.00
<b>Qt. grossos (%)</b>	24.00	8.76	36.48	37.00	18.00

Fonte: Acervo de pesquisa (2022).

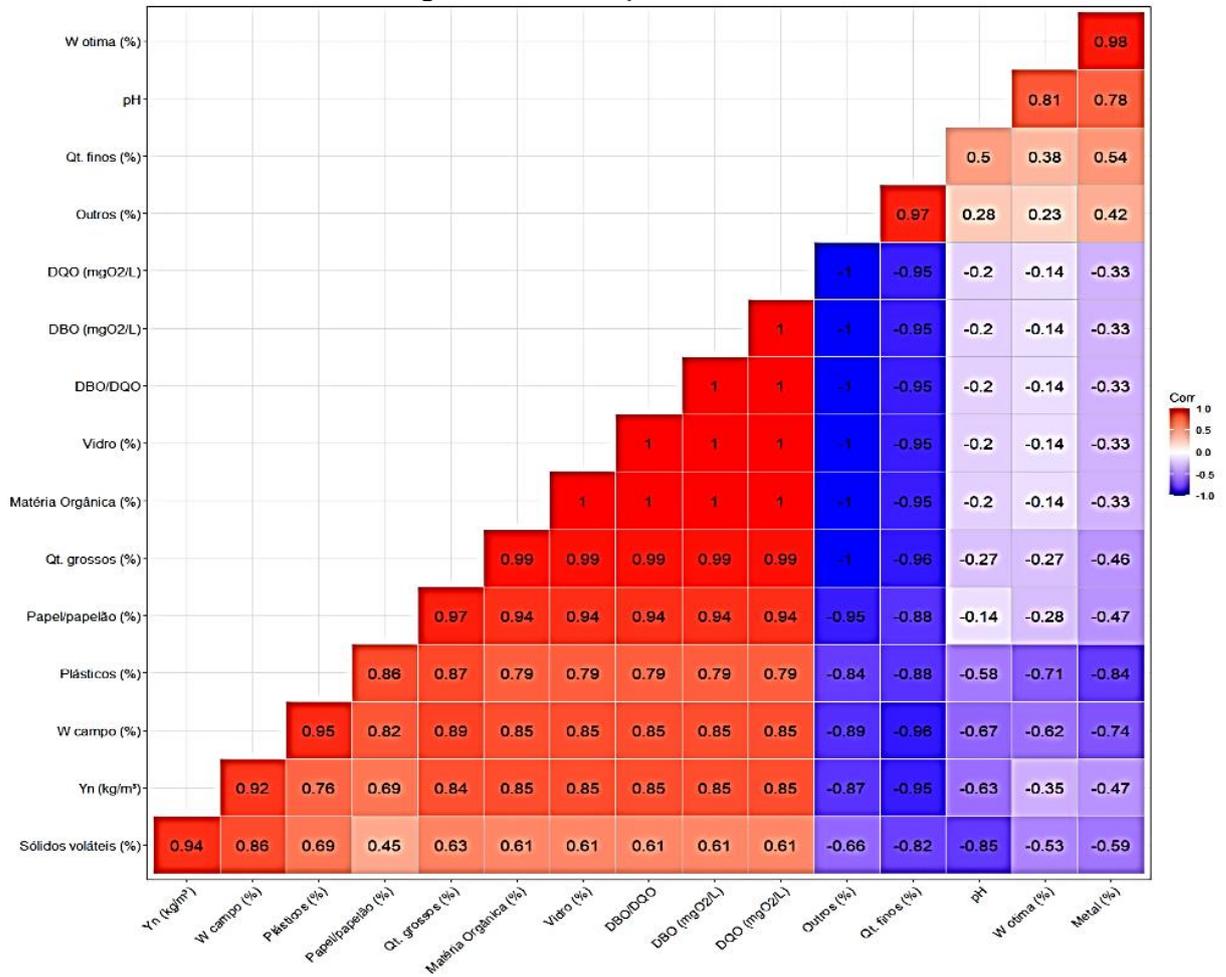
A estatística descritiva é uma ferramenta de análise, com grande importância para discussão da qualidade de dados. Dessa forma, Paiva (2009), a partir da observação da dispersão do conjunto, salienta que quando o coeficiente de variação for maior que 30%, a dispersão é considerada alta, entretanto, com valores 15 e 30% são consideradas de média dispersão e abaixo de 15% a dispersão é considerada baixa.

Assim, das variáveis apresentadas na Tabela 8, sólidos voláteis, DBO<sub>5</sub>, fração de plásticos, vidro, matéria orgânica e quantidade de grossos apresentaram elevada dispersão, de acordo com Paiva (2009). A elevada dispersão nas categorias, sólidos voláteis, DBO<sub>5</sub> e matéria orgânica está associada com a grande degradação do material putrescível no estágio inicial da biodegradação. O peso específico seco máximo (Y<sub>n</sub>), umidade ótima, umidade de campo, papel/papelão, fração de metal e fração de finos não demonstraram grande variação entre os resíduos avaliados. Porém, os indicadores pH e DQO apresentaram baixas dispersões.

#### 4.3.2 Correlação linear de *Pearson* dos dados temporais dos Resíduos Sólidos Urbanos

Para avaliar as correlações dos parâmetros ao longo do monitoramento, gerou-se um correlograma (Figura 45). Assim, utilizou-se o critério adotado por Melo (2011) e Ribeiro (2012), que excluam variáveis que não apresentassem uma correlação, de +/- 0,70, com pelo menos duas outras variáveis.

Figura 45 - Correlação dos dados.



Fonte: Acervo de pesquisa (2022).

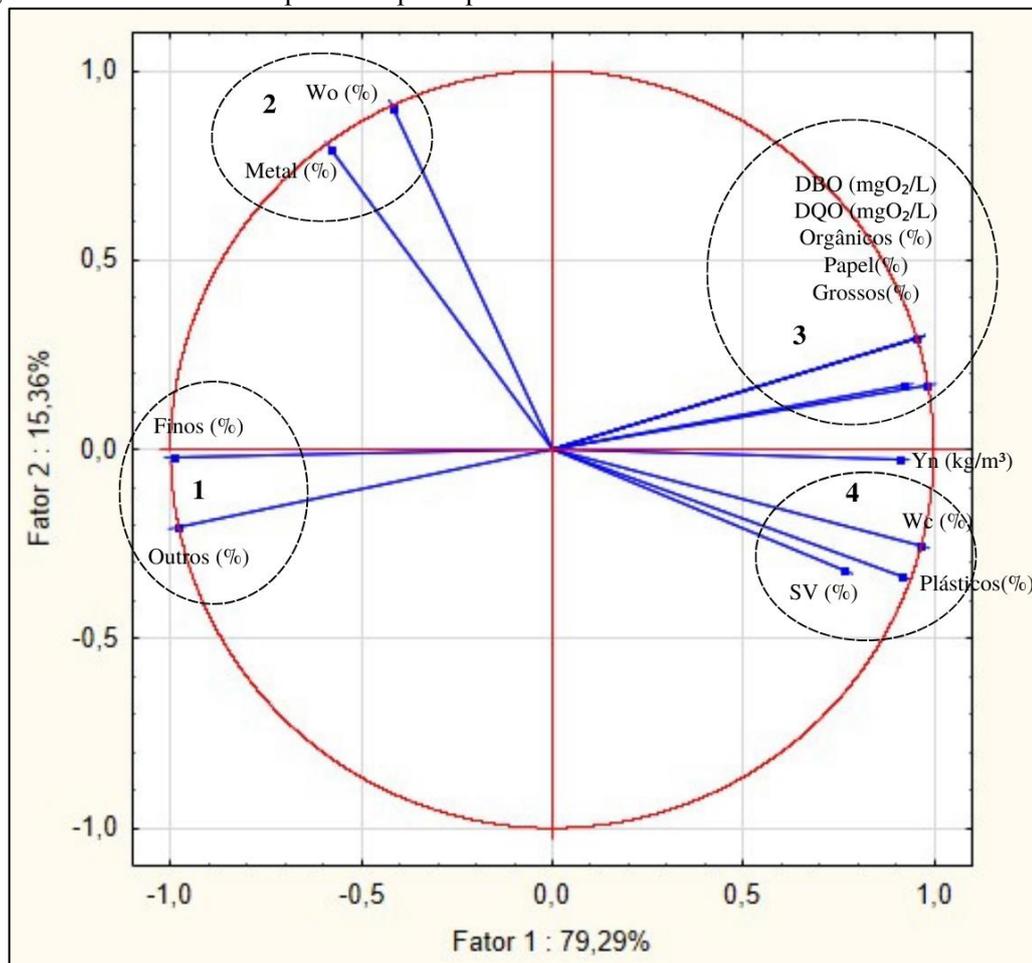
Na Figura 45, observa-se que apenas a variável do pH não possui uma correlação positiva ou negativa maior ou igual a 0,7 com duas ou mais variáveis. Pode-se destacar também, que variáveis como DBO<sub>5</sub> e DQO, sofrem grande influência quando correlacionadas com o diâmetro das partículas (percentual de grossos e finos), sólidos suspensos voláteis e quantidade de matéria orgânica.

Outro fator que tem muita influência da matéria orgânica e do teor de sólidos voláteis é o peso específico máximo seco. É interessante frisar que, esse valor é influenciável quando tem grandes quantidades de orgânicos, tendo em vista que, esse material possui grande retenção de água e durante a compactação atinge maiores pesos específicos.

### 4.3.3 Análise de componentes principais dos Resíduos Sólidos Urbanos

A Análise de Componentes Principais (ACP) foi confeccionada utilizando os dados de DBO, DQO, Sólidos Voláteis (SV), peso específico seco máximo ( $Y_n$ ), umidade ótima ( $W_o$ ), umidade de campo ( $W_c$ ), percentual de grossos e finos e percentuais de papel, plásticos, metal, vidro, matéria orgânica e outros tipos de resíduos. O único parâmetro removido para ACP, foi o pH, pois de acordo com a Figura 46 não atendeu ao critério de duas ou mais correlações lineares maiores que 0,7.

Figura 46 - Análise de componentes principais das características dos resíduos sólidos urbanos.



Fonte: Acervo de pesquisa (2022).

A ACP utilizando os dados de resíduos que chegam ao aterro, recém aterrados, com 1 e 2 anos de aterramento é apresentada na Figura 46, onde observa-se a formação de 4 grupos correlacionados mais intimamente. Eles são formados com elementos de dispersão semelhantes e tem uma boa representatividade já que o fator associado é de 94,65%. Na Figura 47, foi possível distinguir 4 grupos distintos, o grupo 1,2, 3 e 4. Esses grupos foram formados a partir

da proximidade das variáveis, por exemplo, o grupo 2 formado pelo percentual de finos e outros tipos de RSU.

Verifica-se no grupo 1 (Figura 46), que há uma estreita correlação entre o percentual de outros materiais e de finos. A categoria outros materiais, está associada ao aumento de material misto, observado com o tempo de aterramento. Indicando que, possuem em sua grande maioria, granulometrias inferiores a 19,1 mm. Portanto, esse comportamento era esperado, tendo em vista que quanto maior o tempo de degradação dos RSU, maior a quantidade de material misto e maior o percentual de finos.

O grupo 2 apresenta uma certa discrepância, já que associa positivamente a umidade ótima na compactação e o percentual de metais na composição. Pois não existem relações diretas entre as variáveis analisadas durante a compactação dos resíduos.

O grupo 3 é o maior entre os grupos relacionados (Figura 46), ele expressa a correlação positiva e direta entre as variáveis DBO, DQO, fração de orgânicos e papel e porcentagem de grossos. De fato, as variáveis analisadas possuem boa correlação, tendo em vista que, a diminuição do percentual de orgânicos ao longo do tempo reflete em diminuição da DBO e DQO, assim como na diminuição da fração de grossos, já que a biodegradação favorece a formação de resíduos finos. Em concordância, com as variáveis analisadas, observa-se o percentual de papel, que passa por processo efetivo de biodegradação e há grande redução de sua granulometria com o passar do tempo.

O grupo 4 é o último avaliado na Figura 46. Nesse grupo, observa-se que a umidade de campo tem correlação direta e positiva com o percentual de plásticos e com o teor de sólidos voláteis. Esse comportamento é esperado, uma vez que os resíduos plásticos conseguem reter líquidos e quando secos perdem grande massa de água, aumentando assim o teor de umidade dos resíduos ao longo do tempo de aterramento. Os RSU quando chegam ao aterro, encontram-se nas condições aos quais foram dispostos para coleta e o teor de umidade varia muito de acordo com o local, clima, temperatura e acondicionamento, podendo chegar até a 60% de retenção de água (MELO, 2011). Durante as fases de aterramento esse teor de umidade tende a diminuir, levando em consideração que, a formação de subprodutos como a geração de biogás e a lixiviação dos resíduos, diminuindo por efeito de biodegradação o percentual de plásticos e a umidade dos RSU.

Verifica-se ainda na Figura 46, que existiram também a correlação positiva entre os grupos. Por exemplo, o grupo 3 e 4 apresentam correlação linear positiva, fato já esperado, pois, o aumento de orgânicos, DBO, DQO, papel e grossos, na prática também ocorre o aumento de sólidos voláteis e umidade de campo, já que em termos gerais, o teor de sólidos voláteis está

intimamente ligado a fração de material orgânico na amostra de RSU e no tempo observado ocorre o crescimento conjunto desses fatores. A umidade de campo também apresenta forte correlação positiva com as variáveis listadas no grupo 3 e 4. Melo (2011) identificou um comportamento semelhante em célula experimental de resíduos, onde na sua ACP identificou correlação linear positiva entre as variáveis de DBO, sólidos voláteis e umidade de campo.

As correlações lineares negativas estão expressas na Figura 46, quando avaliados os grupos em quadrantes opostos, por exemplo o grupo 1 e 3, que revelam que a quantidade de finos aumenta quando a quantidade de materiais facilmente biodegradáveis e o diâmetro de partículas diminui e, como consequência também diminuem DBO e DQO. Esse comportamento era esperado, já que a quantidade de finos aumenta com o tempo, a partir da degradação de partículas maiores.

Outra análise que apresenta forte correlação linear negativa são os grupos 1 e 4, mesmo sendo grupos próximos entre si, formam grandes ângulos, justificando a forte correlação. Esse é um comportamento esperado, já que a presença de material misto e percentual de finos, cresce ou decresce de forma inversamente proporcional a umidade de campo, quantidade de plásticos e umidade de campo. É importante ressaltar que apresentaram correlações lineares negativas os grupos 2 e 3 e os grupos 2 e 4, porém o ângulo entre essas relações foi próximo a 90°, indicando baixa correlação entre os dados.

#### **4.4 Modelagem não constitutiva da composição gravimétrica com redes neurais artificiais**

##### **4.4.1 Resultados e desempenhos dos treinamentos de redes neurais artificiais**

Utilizando métricas estatísticas (MAE, RMSE, NRMSE, R e MAPE) foram avaliados os melhores modelos neurais. As redes apresentaram diversas combinações de arquitetura, a partir de agrupamentos de funções de ativação (ou transferência) nas camadas de entrada e saída, número de neurônios na camada oculta e algoritmo de treinamento, que para simplificar as análises foram mantidos quatro deles (traingd, trainlm, trainbr e trainrp). Os melhores desempenhos neurais e métricas estatísticas estão expostos na Tabela 9.

Tabela 9 - Performance geral das arquiteturas neurais categorias de RSU.

Categoria	FA camada Oculta	FA camada Saída	Nº de neurônios camada oculta	Algoritmo de treinamento	Métricas de desempenho				
					MAE	RMSE	NRMSE	R	MAPE (%)
<b>Papel a</b>	ElliotSig	ElliotSig	14	Traingd	1.4	2.1	0.27	0.5	19
<b>Papel b</b>	ElliotSig	Tansig	9	Traingd	1.4	2.1	0.23	0.5	22
<b>Plástico a</b>	ElliotSig	Tansig	6	Traingd	2.3	3.5	0.20	0.7	30
<b>Plástico b</b>	ElliotSig	Purelin	12	Traingd	2.2	3.0	0.12	0.9	22
<b>Plástico c</b>	Tansig	Tansig	8	Traingd	3.0	4.1	0.16	0.7	39
<b>Plástico d</b>	Tansig	Purelin	14	Trainlm	2.8	3.9	0.16	0.6	38
<b>Plástico e</b>	Purelin	Tansig	11	Trainrp	2.7	4.0	0.27	0.6	32
<b>Metal</b>	ElliotSig	Purelin	3	Traingd	0.7	1.0	0.33	0.8	29
<b>Vidro a</b>	ElliotSig	ElliotSig	10	Traingd	0.8	1.2	0.27	0.5	48
<b>Vidro b</b>	ElliotSig	ElliotSig	11	Traingd	0.7	1.0	0.26	0.7	32
<b>Vidro c</b>	Purelin	ElliotSig	5	Trainrp	0.7	1.1	0.38	0.7	32
<b>Matéria Orgânica a</b>	ElliotSig	Purelin	5	Traingd	5.2	7.3	0.21	0.5	11
<b>Matéria Orgânica b</b>	ElliotSig	Purelin	12	Traingd	4.9	7.3	0.32	0.5	10
<b>Matéria Orgânica c</b>	Logsig	Purelin	3	Traingd	3.8	5.3	0.17	0.7	8

\*Onde: FA (Função de ativação); Tansig (Tangente Hiperbólica); Purelin (Linear); Logsig (Logística); ElliotSig (Elliot Symmetric Sigmoid); trainbr (Bayesian Regularization); traingd (Gradient Descent Backpropagation); trainlm (Levenberg–Marquardt); trainrp (Resilient Backpropagation); MAE (Erro absoluto médio); RMSE (Raiz do erro quadrático médio); NRMSE (Raiz do erro quadrático médio normalizado) e R (Coeficiente de correlação).

Fonte: Acervo de pesquisa (2022).

De forma geral, os treinamentos apresentaram desempenhos similares, contudo são indicados na Tabela 9, exclusivamente os melhores desempenhos neurais. Durante as análises foram utilizadas quatro funções de treinamento, porém a função *Trainbr* não demonstrou bons resultados em nenhuma das categorias de resíduos. O desempenho insatisfatório dessa rede, pode ser associado ao fato de que a função *Trainbr* atualiza os valores de peso e viés de acordo com a otimização de Levenberg-Marquardt, processo chamado de regularização bayesiana e as paradas de validação são desativadas por padrão, para que o treinamento continue até que uma combinação ideal de erros e pesos seja encontrado (LIANG *et al.*, 2018).

A função de treinamento que prevaleceu quanto aos melhores desempenhos foi a *Traingd*, enquanto que as funções de treinamento *Trainlm* e *Trainrp* apareceram poucas vezes. Pode-se destacar o algoritmo *Traingd* como uma função de treinamento de rede que atualiza os valores de peso e bias de acordo com a descida do gradiente. O algoritmo de gradiente descendente geralmente é muito lento, pois requer pequenas taxas de aprendizado para um aprendizado estável. Alguns autores encontraram bons desempenhos em redes neurais utilizando a função *Traingd*, como por exemplo, Pandey *et al.* (2012), que a utilizaram na

previsão de temperatura interna em edifícios (MAE:0.67 e MSE: 0.75) e Pamungkas *et al.* (2020) para previsão de colheitas na Indonésia (MAE: 0.0366, RMSE: 0.1913 e MAPE: 29.89%), demonstrando diversas e efetivas aplicações para a função de treinamento.

Como forma de detalhar os treinamentos realizados neste trabalho, os resultados foram divididos por categorias em relação a composição gravimétrica dos RSU. A seguir são mostrados comparativos dos modelos com os dados reais para as seguintes categorias: Papel/papelão, plástico, metal, vidro e matéria orgânica.

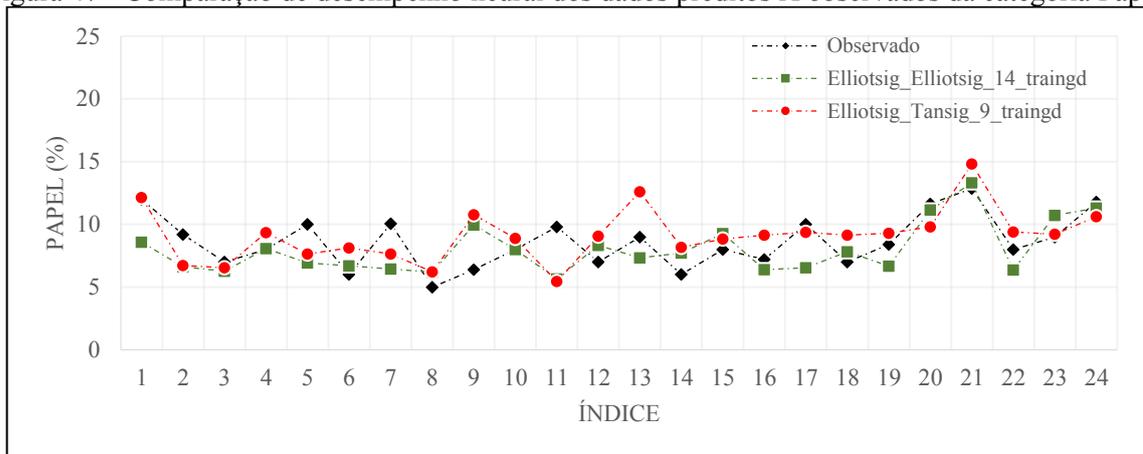
#### 4.4.1.1 Métricas de desempenho categoria Papel

É possível destacar duas RNA que representam as melhores performances estatísticas da categoria Papel, nomeadas de *Papel a* e *Papel b*. Essas RNA foram construídas utilizando o algoritmo de treinamento *Traingd*, configuradas com respectivamente, com 14 e 9 neurônios na camada oculta. A rede *Papel a* utilizou função de ativação *Elliot* sig nas camadas ocultas e de saída. Já a rede *Papel b*, teve na camada oculta a função *Elliot* sig e na camada de saída a função *Tansig*.

Observa-se que na categoria Papel, ambas as redes apresentadas na Tabela 9, apresentaram bons desempenhos relacionados a medição de erros, porém a acurácia da predição *Papel a* apresenta uma pequena vantagem de desempenho. O MAE e o RMSE, foram respectivamente 1.4 e 2.1, já o NRMSE ficaram próximos entre si, sendo 0.27 para o treinamento *Papel a* e 0.23 para o treinamento *Papel b*. Nos dois casos o indicador de correlação dos dados apresentou valores idênticos, R de 0.5.

O grande diferencial nos treinamentos, deu-se a partir da análise do MAPE, registrando uma diferença de 3% entre os dois modelos e classificando o melhor desempenho para o modelo *Papel a*. Portanto, mesmo com baixas correlações, ambos os modelos apresentaram baixos valores de erro e altas acurácias, em que o modelo *Papel a* e *Papel b*, representam cerca de respectivamente, 81% e 78% de representatividade dos dados (MAPE: 19 e 22), sendo um ajuste aceitável entre os valores observados e preditos, como é possível verificar na Figura 47.

Figura 47 - Comparação de desempenho neural dos dados preditos X observados da categoria Papel.



Fonte: Acervo de pesquisa (2022).

Na Figura 47, observa-se forte concordância entre os dados observados e previstos pelo modelo. Porém, pode-se perceber que existem previsões no modelo que estão acima ou abaixo dos valores relacionados as amostras observadas. As dispersões observadas em relação aos valores preditos, podem ser relacionadas ao fato da grande variação de características da categoria de resíduos Papel, em comparação aos indicadores socioeconômicos utilizados na pesquisa.

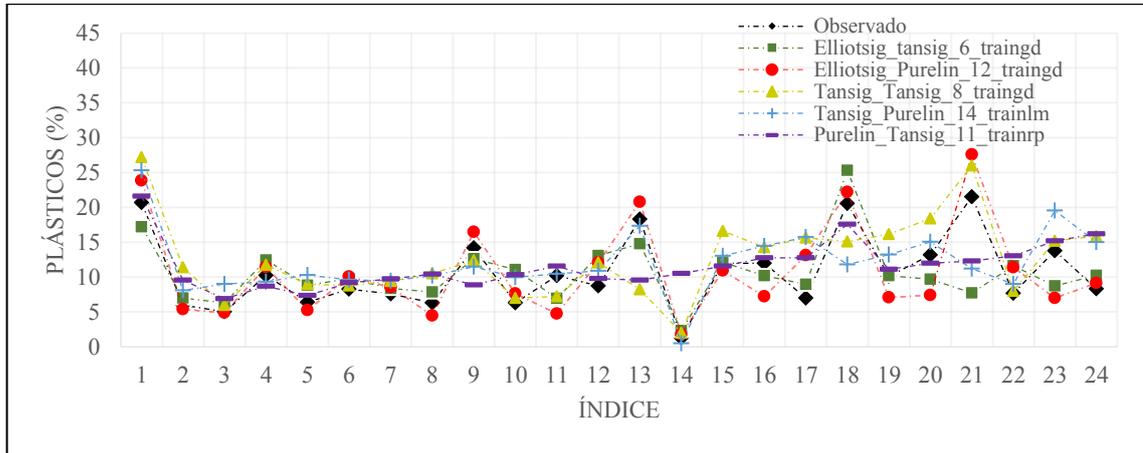
#### 4.4.1.2 Métricas de desempenho categoria Plásticos

A categoria de resíduos Plástico teve o maior número de treinamentos com boas métricas de desempenho, totalizando 5 treinamentos, nomeados de *Plástico a* até *Plástico e*. Como simplificação serão discutidos os dois primeiros treinamentos (*Plástico a* e *Plástico b*), que demonstraram melhores estatísticas de erro e correlação. Também para esses modelos, a função de treinamento predominante foi a *Traingd*. A RNA *Plástico a* teve 6 neurônios na camada oculta, função de treinamento na camada oculta *Elliotsig* e *Tansig* na camada de saída. Enquanto a *Plástico b* apresentou 12 neurônios na camada oculta, *Elliotsig* como ativação na camada oculta e *Tansig* na de saída.

Na Tabela 9, encontram-se as métricas de desempenho para os treinamentos nesta categoria. Similar a categoria Papel, os treinamentos de Plástico, também apresentaram bons resultados e ficaram próximos entre si, com MSE, RMSE, NRMSE e R de 2.2, 3.0, 0.12, 0.9, respectivamente. A rede nomeada como *Plástico b* apresentou um desempenho neural um pouco superior a *Plástico a*, que teve MSE, RMSE, NRMSE e R de 2.3, 3.5, 0.2, 0.7, respectivamente.

Observou-se uma diferença de 8% do MAPE entre as redes *Plástico a* e *Plástico b*, apresentando respectivas representatividades de 70% e 78% (MAPE: 22 e 30), demonstrando bons ajustes entre os valores observados e preditos, como pode ser observado na Figura 48.

Figura 48 - Comparação de desempenho neural dos dados preditos X observados da categoria Plásticos.



Fonte: Acervo de pesquisa (2022).

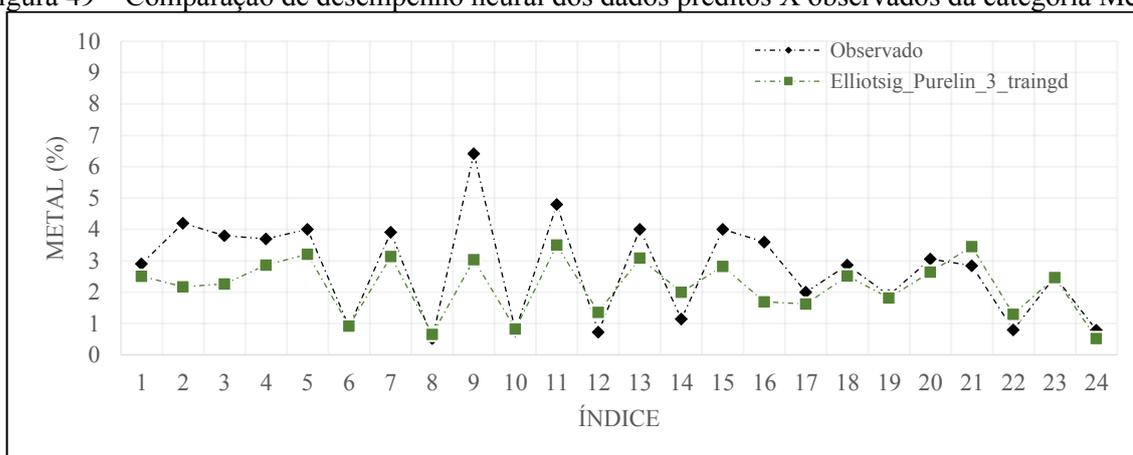
As discordâncias entre os valores preditos e observados na Figura 48, podem estar associadas ao fato da grande amplitude de dados de porcentagem de Plástico, que variam aproximadamente, entre 0,5 e 30 %. Outro fator que pode ter causado erros, é a quantidade de dados de entrada da RNA, de modo que poderiam ser realizados ajustes objetivando a melhor performance.

#### 4.4.1.3 Métricas de desempenho para a categoria Metal

A Tabela 9 apresenta um único treinamento e sua arquitetura para a categoria de resíduos *Metal*. A rede apresenta uma arquitetura neural com 3 neurônios na camada oculta, função de treinamento *Traingd*, funções de transferência *Elliotstsig* para a camada oculta e *Purelin* para a camada de saída. As métricas de desempenho MAE, RMSE, NRMSE, R e MAPE, tem valores respectivos de, 0.7, 1.0, 0.33, 0.8 e 29%.

A RNA para o *Metal* demonstrou proximidade entre os valores observados e preditos, como observa-se na Figura 49, e a partir do MAPE que indica representatividade dos dados preditos de 71 % em relação dos dados observados.

Figura 49 – Comparação de desempenho neural dos dados preditos X observados da categoria Metal.



Fonte: Acervo de pesquisa (2022).

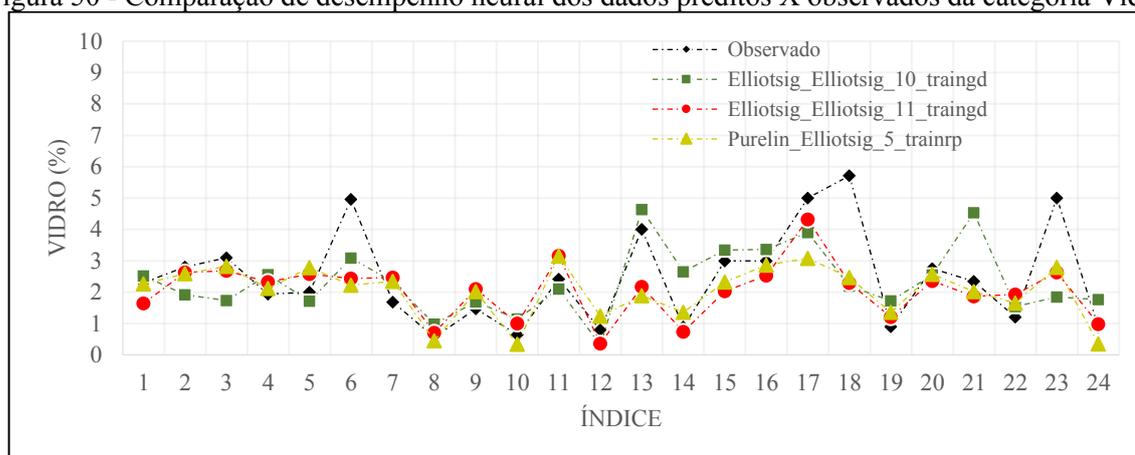
Um comportamento similar pode ser notado na categoria *Metal* com as demais categorias, em relação a algumas variações entre os dados observados e preditos. Essa relação se dá pela sensibilidade do modelo a valores extremos nas entradas da RNA.

#### 4.4.1.4 Métricas de desempenho para a categoria Vidro

Semelhante as outras categorias, o Vidro apresentou 3 arquiteturas neurais com boas métricas de desempenho. Nomeadas de *Vidro a*, *Vidro b* e *Vidro c*, as redes tiveram como funções de treinamento, *Traingd*, *Traingd* e *Trainrp*, respectivamente. As categorias *Vidro a* e *Vidro b*, apresentaram a mesma configuração, modificando apenas o número de neurônios na camada oculta (10 e 11 neurônios, respectivamente). Para esses modelos foi utilizada a função de ativação *Elliotsig* tanto para a camada oculta, quanto para a camada de saída. Já a arquitetura *Vidro c*, utilizou a função de transferência na camada oculta *Purelin* e na camada de saída *Elliotsig*, com 5 neurônios na camada oculta.

Para fins de simplificação das análises, foi identificado na Tabela 9 que as redes *Vidro b* e *Vidro c* apresentam melhores desempenhos com as métricas MAE, RMSE, NRMSE, R e MAPE, apresentando valores respectivos para *Vidro b* de, 0.7, 1.0, 0.26, 0.7 e 32%. Já para *Vidro c* as métricas MAE, RMSE, NRMSE, R e MAPE, compreenderam valores respectivos de 0.7, 1.1, 0.38, 0.7 e 32%. De modo geral, ambas as redes apresentam boas comparações entre os valores preditos e observados como mostrado na Figura 50.

Figura 50 - Comparação de desempenho neural dos dados preditos X observados da categoria Vidro.



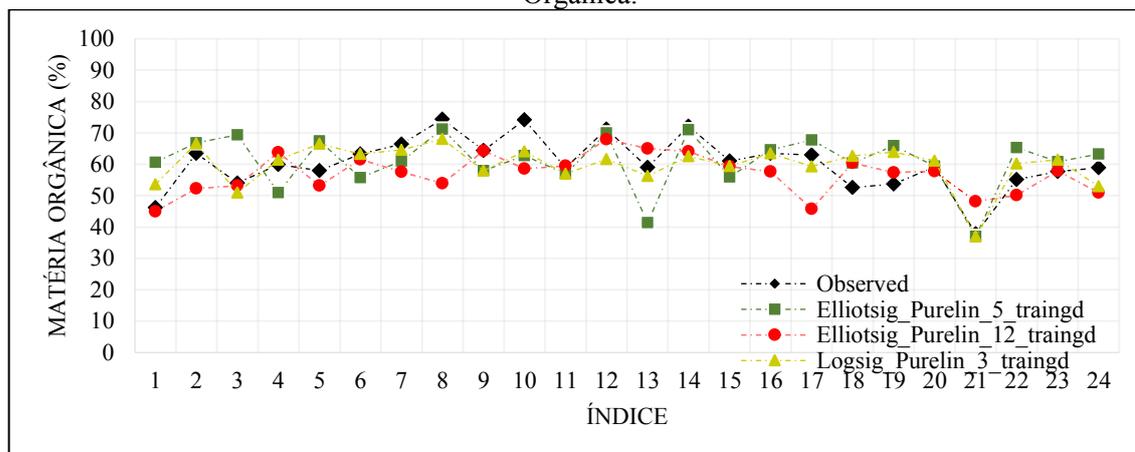
Fonte: Acervo de pesquisa (2022).

O desempenho neural pode sofrer um *Overfitting*, pois a rede apresentou ótimos valores de treinamento, mas alguns valores observados estão um pouco distantes dos preditos, casos similares aos resultados vistos nas outras categorias, esses casos estão representados ainda quando analisadas as métricas MAPE, em que os modelos *Vidro b* e *Vidro c* tem cerca de 68% de acurácia.

#### 4.4.1.5 Métricas de desempenho para a categoria Matéria Orgânica

De maneira análoga a categoria Vidro, os resíduos orgânicos apresentaram 3 arquiteturas ótimas de desempenho. Porém, de modo geral, vale destacar a arquitetura *Resíduos Orgânicos c*, que como pode-se observar na Tabela 9, apresenta as melhores métricas estatísticas de desempenho, exibindo valores de MAE, RMSE, NRMSE, R e MAPE, de respectivamente, 3,8, 5,3, 0,17, 0,7 e 8%. A configuração utilizada nesse modelo utilizou como função de treinamento *Traingd*, função de ativação na camada oculta e de saída, respectivamente, *Logsig* e *Tansig* e 3 neurônios na camada oculta. A Figura 51 apresenta os melhores treinamentos da categoria Matéria Orgânica.

Figura 51 - Comparação de desempenho neural dos dados preditos X observados da categoria Matéria Orgânica.



Fonte: Acervo de pesquisa (2022).

Dentre todas as categorias, é possível observar na Figura 51, que o treinamento *Orgânicos c*, apresentou a maior similaridade com os dados observados, porém, pode-se perceber pequenas variações no modelo, ocasionadas provavelmente pela sensibilidade e as respostas à grandes variações de percentual Orgânicos (40-75%).

#### 4.4.1.6 Discussão geral das métricas de desempenho avaliadas

Analisando para cada categoria de resíduos, funções de ativação, o intervalo de neurônios de 1 a 15 e algoritmos de treinamento, pode-se identificar estatisticamente, que os valores de MAE, RMSE e NRMSE oscilaram entre 2 e 7,3%, enquanto o R se manteve maior que 0,5. O MAPE variou entre 8 e 48%, de acordo com as composições físicas de RSU apresentadas.

De modo geral os parâmetros de erro estatístico MAE, RMSE e NRMSE variam de acordo com a dimensão utilizada para os dados de saída. Por isso, a eficiência desses parâmetros é relativa à precisão da análise realizada e seus valores representam o desvio médio entre observado e predito. O RMSE consegue identificar desvios de grandes magnitudes, enquanto o MAE faz uma análise mais local, igualando todos os desvios. Destaca-se que para esse trabalho, todos os parâmetros de erro avaliados se mostraram satisfatórios, uma vez que, sua variação foi pequena, quando comparados aos valores das séries estudadas.

O MAPE é um índice que indica uma média dos erros percentuais absolutos e quanto menor o MAPE, maior é a precisão. Segundo Vivas, Allende-Cid e Salas (2020), quando o MAPE tem valores <10%, pode-se considerar que a análise possui uma previsão de alta

acurácia, entre 10% e 20%, o modelo faz boa previsão, entre 20% e 50%, uma previsão razoável e >50%, uma previsão de pequena acurácia.

O comportamento do R é bastante independente da linearidade do modelo de ajuste da RNA, e quanto mais próximo de 1, maior é a proximidade entre os dados preditos e observados. É importante portanto, ao escolher os melhores modelos de cada categoria de resíduo avaliar o R em conjunto com as outras métricas de desempenho MAE, RMSE, NRMSE e MAPE. A Tabela 10 mostra o principal modelo encontrado para cada categoria de resíduo.

Tabela 10 - Melhores modelos neurais para cada categoria de RSU

Categoria	Métricas de desempenho					Avaliação MAPE
	MAE	RMSE	NRMSE	R	MAPE (%)	
<b>Papel a</b>	1.4	2.1	0.27	0.5	19	BP
<b>Plástico b</b>	2.2	3.0	0.12	0.9	22	MP
<b>Metal</b>	0.7	1.0	0.33	0.8	29	MP
<b>Vidro b</b>	0.7	1.0	0.26	0.7	32	MP
<b>Matéria Orgânica c</b>	3.8	5.3	0.17	0.7	8	EP

Obs.: BP = boa previsibilidade; MP = média previsibilidade; EP = excelente previsibilidade.

Fonte: Acervo de pesquisa (2022).

A Tabela 10 mostra que os modelos avaliados nessa pesquisa demonstram bons resultados, quando comparados as literaturas acerca de previsões de composições gravimétricas utilizando RNA. Em trabalho similar envolvendo os dados gravimétricos Joanesburgo na África do Sul, Adeleke *et al.* (2021), encontraram valores similares de RMSE, entre 2 e 5%, um R entre 0,8 e 0,9 e MAPE de 12 a 20%. Eles avaliaram quatro categorias de resíduos, orgânicos, papel, plástico e têxteis, e como entrada apenas dados climáticos da região como velocidade do vento, umidade, temperatura máxima e mínima.

Outro estudo, utilizando como saída a composição gravimétrica, foi realizado por Ma *et al.* (2020), porém o único parâmetro de validação aplicado a seus modelos foi o R, que identificou os melhores treinamentos com valores acima de 0,6. Batinic *et al.* (2011), realizaram uma previsão da composição gravimétrica da Sérvia e obtiveram valores de MAE próximos a 7% para todas as categorias avaliadas e um valor de R de 0,96.

#### 4.4.2 Previsão da composição gravimétrica do aterro sanitário em Campina Grande

A Tabela 11 mostra o quantitativo em massa e percentual depositado por cada município no ASCG para o mês de agosto de 2022, os indicadores socioeconômicos mais atualizados de

cada município avaliado e as previsões da composição gravimétrica realizadas para cada município.

Tabela 11 - Informações gerais e previsões dos municípios que depositam RSU no ASCG (agosto/2022).

Clientes	Total Recebido (Ton)	Porcentagem de contribuição (%)	IDHM	Theil	Índice de Gini	Renda per capita	Papel	Plásticos	Metal	Vidro	Matéria Orgânica	Outros
Umbuzeiro	43,47	0,22	0,58	0,57	0,54	237,25	7,45	16,06	2,90	1,99	56,48	15,12
São Domingos do Cariri	25,28	0,13	0,59	0,42	0,47	341,56	6,27	16,31	3,08	1,61	52,91	19,83
São Jose dos Cordeiros	31,23	0,16	0,56	0,47	0,49	233,71	6,15	15,65	3,04	1,85	55,38	17,93
Alagoa Nova	243,82	1,24	0,58	0,55	0,54	272,81	7,36	16,11	2,88	1,94	56,49	15,23
Alcantil	55,47	0,28	0,58	0,46	0,48	245,01	5,81	15,88	3,07	1,75	54,20	19,29
Algodão de Jandaira	23,14	0,12	0,55	0,41	0,47	218,70	5,13	15,38	3,08	1,79	54,66	19,95
Areia	287,78	1,46	0,59	0,55	0,55	319,92	7,60	16,28	2,81	1,80	55,92	15,59
Areia de Baraunas	9,81	0,05	0,56	0,40	0,46	270,54	5,58	15,76	3,10	1,67	53,64	20,24
Areial	110,57	0,56	0,61	0,47	0,49	282,18	5,90	16,27	3,05	1,68	53,37	19,73
Aroeiras	127,23	0,65	0,55	0,64	0,58	226,05	8,07	15,74	2,72	2,36	59,16	11,95
Assunção	46,55	0,24	0,61	0,53	0,54	336,67	7,36	16,38	2,86	1,72	54,92	16,77
Barauna	47,07	0,24	0,56	0,50	0,51	211,36	6,52	15,60	3,00	1,95	56,19	16,73
Barra de Santa Rosa	125,17	0,64	0,56	0,52	0,52	233,51	6,83	15,84	2,96	1,96	56,40	16,01
Barra de Santana	39,92	0,20	0,57	0,43	0,50	211,08	5,56	15,55	3,05	1,87	55,12	18,86
Boa Vista	58,13	0,30	0,65	0,32	0,42	314,11	8,17	16,40	3,23	1,51	48,60	22,08
Boqueirão	212,37	1,08	0,61	0,38	0,46	319,11	6,38	16,30	3,13	1,59	51,74	20,86
Cabaceiras	34,67	0,18	0,61	0,41	0,46	283,93	5,42	16,21	3,13	1,61	51,93	21,71
Camalaú	57,93	0,29	0,57	0,42	0,46	242,92	5,24	15,66	3,10	1,70	53,69	20,61
Campina Grande	12818,69	65,18	0,72	0,61	0,58	630,03	10,40	15,63	2,18	1,53	42,24	28,03
Caraúbas	25,82	0,13	0,59	0,39	0,45	296,38	6,11	16,08	3,13	1,61	52,37	20,71
Casinhas	41,23	0,21	0,57	0,37	0,45	200,83	4,79	15,43	3,13	1,70	53,11	21,84
Caturité	20,18	0,10	0,62	0,58	0,56	371,05	8,46	16,43	2,69	1,71	55,07	15,64
Coxixola	14,23	0,07	0,64	0,46	0,48	306,15	5,63	16,49	3,09	1,60	51,71	21,48
Cubatí	59,74	0,30	0,57	0,45	0,48	237,71	5,69	15,70	3,06	1,78	54,58	19,18
Damiao	49,65	0,25	0,52	0,42	0,49	182,89	5,52	14,99	3,04	1,96	56,36	18,13
Equador	74,20	0,38	0,62	0,46	0,50	292,55	5,70	16,37	3,05	1,66	53,01	20,22
Esperança	508,34	2,58	0,62	0,55	0,54	330,66	7,71	16,45	2,86	1,71	54,55	16,72
Fagundes	88,31	0,45	0,56	0,52	0,52	235,02	6,84	15,83	2,96	1,96	56,46	15,95
Gado Bravo	28,57	0,15	0,51	0,55	0,56	170,29	6,75	14,98	2,87	2,26	59,55	13,59
Gurjão	40,77	0,21	0,63	0,38	0,45	288,53	5,76	16,25	3,16	1,57	50,88	22,38
Ingá	288,58	1,47	0,59	0,48	0,49	282,85	6,19	16,19	3,03	1,70	54,01	18,88
Itatuba	94,96	0,48	0,56	0,48	0,49	244,16	6,29	15,80	3,03	1,83	55,21	17,85
Juazeirinho	135,08	0,69	0,57	0,50	0,51	255,68	6,66	15,95	2,98	1,87	55,72	16,81
Junco do Seridó	82,09	0,42	0,62	0,42	0,47	280,15	5,27	16,24	3,11	1,62	52,10	21,66
Lagoa Seca	368,76	1,88	0,63	0,56	0,54	380,73	8,17	16,48	2,78	1,66	54,25	16,66
Livramento	62,92	0,32	0,57	0,50	0,50	207,73	6,49	15,63	3,02	1,89	55,63	17,33

Continua...

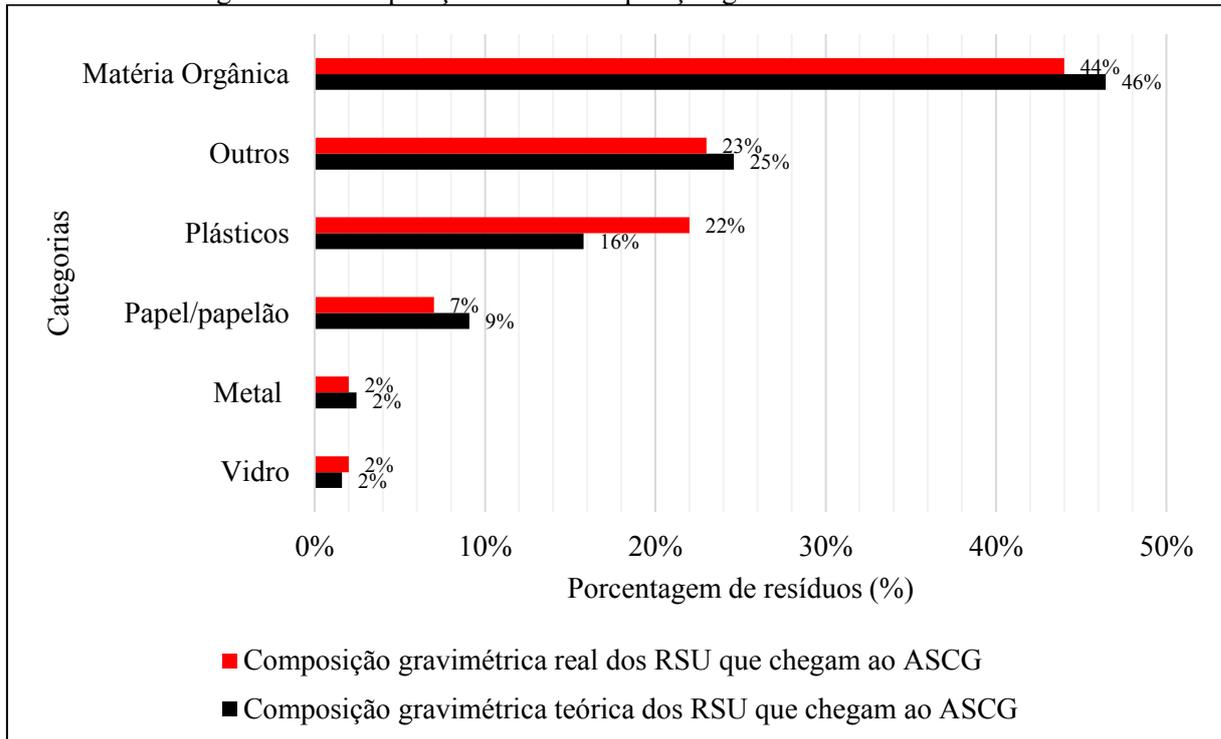
## ...Continuação da Tabela 13

<b>Massaranduba</b>	124,66	0,63	0,57	0,40	0,46	247,98	5,26	15,66	3,11	1,68	53,53	20,75
<b>Matinhas</b>	20,32	0,10	0,54	0,33	0,44	217,60	5,95	15,28	3,13	1,71	53,31	20,61
<b>Mogeiro</b>	126,82	0,64	0,57	0,48	0,50	227,05	6,29	15,79	3,03	1,85	55,15	17,89
<b>Montadas</b>	96,66	0,49	0,59	0,44	0,47	238,17	5,31	15,86	3,10	1,70	53,35	20,68
<b>Natuba</b>	46,07	0,23	0,54	0,54	0,54	198,68	6,86	15,47	2,92	2,14	57,94	14,67
<b>Nova Floresta</b>	140,41	0,71	0,60	0,50	0,51	287,45	6,67	16,27	2,99	1,73	54,39	17,95
<b>Nova Palmeira</b>	46,27	0,24	0,60	0,37	0,45	272,29	5,80	15,95	3,15	1,60	51,94	21,57
<b>Olivedos</b>	38,00	0,19	0,60	0,49	0,49	217,32	6,32	15,96	3,07	1,79	53,92	18,95
<b>Orobó</b>	287,92	1,46	0,61	0,49	0,52	237,64	6,47	16,13	3,01	1,82	54,48	18,09
<b>Ouro Velho</b>	22,14	0,11	0,61	0,39	0,47	305,23	5,71	16,29	3,12	1,60	51,91	21,38
<b>Parari</b>	13,29	0,07	0,58	0,52	0,49	300,27	6,96	16,19	3,00	1,71	54,48	17,66
<b>Pedra Lavrada</b>	50,47	0,26	0,57	0,45	0,49	267,79	5,71	15,97	3,04	1,75	54,51	19,02
<b>Picuí</b>	165,77	0,84	0,61	0,54	0,53	326,53	7,49	16,38	2,89	1,72	54,78	16,75
<b>Pocinhos</b>	174,87	0,89	0,59	0,40	0,46	253,75	5,18	15,87	3,12	1,64	52,67	21,51
<b>Prata</b>	21,14	0,11	0,61	0,44	0,44	271,47	5,46	16,16	3,14	1,60	51,67	21,97
<b>Puxinanã</b>	123,82	0,63	0,62	0,38	0,45	283,93	5,73	16,17	3,16	1,58	51,18	22,18
<b>Queimadas</b>	577,42	2,94	0,61	0,50	0,46	292,50	6,28	16,28	3,08	1,64	52,64	20,08
<b>Remigio</b>	279,75	1,42	0,61	0,58	0,55	319,14	8,10	16,34	2,79	1,79	55,62	15,35
<b>Riachão do Bacamarte</b>	47,46	0,24	0,55	0,48	0,49	262,31	6,34	15,83	3,02	1,82	55,45	17,54
<b>Riacho de Santo Antônio</b>	18,29	0,09	0,59	0,33	0,43	275,73	7,34	15,91	3,18	1,56	51,03	20,99
<b>Salgadinho</b>	15,62	0,08	0,56	0,42	0,46	217,39	5,11	15,48	3,11	1,73	53,90	20,67
<b>Salgado de São Felix</b>	84,74	0,43	0,57	0,48	0,50	217,45	6,28	15,67	3,03	1,87	55,40	17,75
<b>Santa Cecília</b>	69,21	0,35	0,53	0,43	0,48	197,49	5,60	15,06	3,05	1,91	55,94	18,43
<b>Santo André</b>	14,08	0,07	0,60	0,42	0,47	273,72	5,30	16,11	3,10	1,64	52,74	21,11
<b>São Joao do Cariri</b>	56,42	0,29	0,62	0,52	0,53	373,55	7,19	16,47	2,87	1,64	53,95	17,87
<b>Serra Redonda</b>	64,51	0,33	0,57	0,47	0,48	268,53	6,01	15,97	3,05	1,74	54,47	18,77
<b>Soledade</b>	155,75	0,79	0,62	0,49	0,51	330,05	6,41	16,43	2,98	1,65	53,61	18,93
<b>Sossego</b>	31,40	0,16	0,57	0,48	0,50	218,20	6,27	15,72	3,03	1,86	55,22	17,90
<b>Taperoá</b>	165,70	0,84	0,58	0,50	0,48	267,88	6,52	16,05	3,04	1,74	54,39	18,27
<b>Tenorio</b>	34,97	0,18	0,58	0,35	0,43	269,63	6,80	15,81	3,17	1,57	51,65	21,01
<b>Congo</b>	54,38	0,28	0,58	0,45	0,49	263,84	5,67	16,00	3,05	1,74	54,27	19,27
<b>São Sebastião de Lagoa de Roça</b>	115,35	0,59	0,59	0,44	0,48	262,87	5,40	16,06	3,08	1,69	53,44	20,34
<b>Total</b>	<b>19665,41</b>											

Fonte: Acervo de pesquisa (2022).

Utilizando a informação da Tabela 11, foi realizada uma média ponderada com pesos relacionados a massa de resíduos de cada município. Assim, obteve-se a composição teórica dos RSU dispostos no ASCG e comparou-se com a composição real realizada neste trabalho (Figura 52).

Figura 52 - Comparação entre a composição gravimétrica real e teórica.



Fonte: Acervo de pesquisa (2022).

De modo geral, observa-se na Figura 52, que não houve grande dispersão quando comparados os dados de composição gravimétrica teórica com a real. Apenas a categoria Plásticos demonstrou certa discrepância entre os valores preditos e reais. Essa diferença pode estar associada ao erro do modelo escolhido para fazer as previsões da categoria, uma vez que um modelo apenas consegue estimar os valores testados, não representando na íntegra o valor real. O teor de plástico está totalmente associado as características socioeconômicas de um local, portanto quando se verifica no banco de dados original são observadas grandes variações que dependem do local analisado.

Outro motivo da diferença entre os valores preditos e observados deve-se a criação do banco de dados, pois para isso utilizou-se de um acervo disponível na literatura tecno-científica em nível nacional, portanto os indicadores socioeconômicos utilizados variam em diferentes regiões, podendo não representar com tanta exatidão os municípios onde foram realizadas as previsões de composições gravimétricas. Ainda, constata-se que os dados socioeconômicos do Brasil são defasados, tendo em vista que, existiram problemas na coleta e tabulação de dados pelo órgão oficial brasileiro, causando certa imprecisão, já que, os valores preditos podem não estar totalmente condizentes com a realidade atual.

## 5 CONCLUSÕES

- O comportamento temporal dos RSU no ASCG, sob aspectos mecânicos, tem forte influência da biodegradação dos resíduos. Uma vez que, as mudanças físicas e químicas atreladas ao tempo, se comportam de modo a alterar as características comportamentais do aterro.
- A composição gravimétrica dos resíduos que chegam ao Aterro Sanitário em Campina Grande apresentou a maior fração gravimétrica de matéria orgânica putrescível, seguido por têxteis sanitários e plásticos.
- O grande volume e pequena massa específica de plásticos destacaram-se, por ocupar o maior volume de aterro. Essa categoria causa um efeito colchão a partir de expansão após a compactação, prejudicando a operação do aterro e diminuindo sua vida útil.
- A caracterização físico-química do extrato de lixiviado demonstra que os resíduos que chegam ao ASCG, estão em fase inicial de biodegradação, apresentando alta carga orgânica favorecendo a atividade microbiológica.
- Levando em consideração a umidade ótima obtida na curva de compactação, os RSU que chegam ao ASCG apresentam elevados teores de umidade e recomenda-se a pré-secagem, garantindo que esses resíduos sejam compactados de forma otimizada.
- As curvas de resistência ao cisalhamento apresentaram comportamentos semelhantes para os ensaios em condições inundadas e não inundadas, porém em condições inundadas possuem tensões de cisalhamento inferiores as observadas para as tensões normais de 50, 175 e 300 kPa.
- A análise de componentes principais mostrou a formação de grupos correlacionados entre si e demonstraram as interpelações entre os comportamentos físico-químicos e geotécnicos, das variáveis analisadas nesse processo, possibilitando o seu uso em processos envolvendo os parâmetros dos RSU.
- Foram construídas diversas arquiteturas de RNA com boas métricas de desempenho para previsão da composição gravimétrica dos resíduos, destacando 14 arquiteturas distribuídas entre as categorias de RSU.
- A previsão da composição dos resíduos que chegam ao ASCG, utilizando as arquiteturas ótimas demonstraram grande eficiência, uma vez que, os valores preditos ficaram próximos da composição gravimétrica determinada *in situ*.

## REFERÊNCIAS

- ABRELPE – ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE LIMPEZA PÚBLICA E RESÍDUOS ESPECIAIS. **Panorama dos Resíduos Sólidos no Brasil: 2022**. Rio de Janeiro, 2022.
- ABREU, A. E. S., **Avaliação geofísica e resistência ao cisalhamento de Resíduos Sólidos Urbanos de diferentes idades**. 2015. 233 f. Tese (Doutorado em Geotecnia) – Universidade de São Paulo, São Carlos, 2015.
- ABREU, R. C. de. **Compressibilidade de maciços sanitários**. 2000. Dissertação (Mestrado) – Universidade de São Paulo, São Paulo, 2000.
- ADAMOVIĆ, V. M. *et al.* Prediction of municipal solid waste generation using artificial neural network approach enhanced by structural break analysis. **Environmental Science and Pollution Research**, v. 24, n. 1, p. 299-311, 2017.
- ADELEKE, O. *et al.* Application of artificial neural networks for predicting the physical composition of municipal solid waste: An assessment of the impact of seasonal variation. **Waste Management & Research**, v. 39, n. 8, p. 1058-1068, 2021.
- AGATONOVIC-KUSTRIN, S.; BERESFORD, R. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. **Journal of pharmaceutical and biomedical analysis**, v. 22, n. 5, p. 717-727, 2000.
- ALCÂNTARA, P. B. **Avaliação da Influência da Composição de Resíduos Sólidos Urbanos no Comportamento de Aterros Simulados**. 2007. 366 f. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, PE, 2007.
- ALELUIA, J.; FERRÃO, P. Characterization of urban waste management practices in developing Asian countries: A new analytical framework based on waste characteristics and urban dimension. **Waste management**, v. 58, p. 415-429, 2016.
- ALVES, I. R. F. S. **Análise experimental do potencial de geração de biogás em resíduos sólidos urbanos**. 2008. 118p. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, PE, 2008.
- AMERICAN PUBLIC HEALTH ASSOCIATION. APHA: **Standard Methods for Examination of Water and Wastewater**. 22 ed. APHA, AWWA and WEF. 2017.
- ANUSHKA, P.; UPAKA, R. Comparison of different artificial neural network (ANN) training algorithms to predict the atmospheric temperature in Tabuk, Saudi Arabia. **Mausam**, v. 71, n. 2, p. 233-244, 2020.
- ARAÚJO NETA, D. G. de. **Biodegradação dos resíduos sólidos urbanos por meio das características do lixiviado gerado no aterro sanitário em Campina Grande-PB**. 2019. 78 f. Dissertação (Mestrado em Engenharia Civil e Ambiental), Universidade Federal de Campina Grande - Paraíba - Brasil, 2019.

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 f. Dissertação (Mestrado em Engenharia Civil e Ambiental) - Universidade Federal de Campina Grande, Paraíba, Brasil, 2016.

ARAÚJO NETO, C. L. de. **Modelagem da resistência ao cisalhamento de resíduos sólidos urbanos para análises da estabilidade de taludes de aterros sanitários**. 2021. 295 f. Tese (Doutorado em Engenharia Civil e Ambiental) - Universidade Federal de Campina Grande, Paraíba, Brasil, 2021.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **ABNT NBR 10007: Amostragem de Resíduos**. Rio de Janeiro: ABNT, 2004.

\_\_\_\_\_. **ABNT NBR 6508: Solo – Determinação da massa específica**. Rio de Janeiro: ABNT, 1984.

\_\_\_\_\_. **ABNT NBR 7181: Solo - análise granulométrica**. Rio de Janeiro: ABNT, 2016.

\_\_\_\_\_. **ABNT NBR 8419: Apresentação de projetos de aterros sanitários de resíduos sólidos**. Rio de Janeiro: ABNT, 1992.

AURPA, S. S.; HOSSAIN, S.; ISLAM, M. A. Effect of Plastic Waste on Volume Consumption of Landfill during the COVID-19 Pandemic. **Sustainability**, v. 14, n. 23, p. 15974, 2022.

AYELERU, O. O. *et al.* Forecasting municipal solid waste quantity using artificial neural network and supported vector machine techniques: A case study of Johannesburg, South Africa. **Journal of Cleaner Production**, v. 289, p. 125671, 2021.

BAPTISTA, F. D.; RODRIGUES, S.; MORGADO-DIAS, F.. Performance comparison of ANN training algorithms for classification. In: **2013 IEEE 8th International Symposium on Intelligent Signal Processing**. IEEE, 2013. p. 115-120.

BATINIC, B. *et al.* Using ANN model to determine future waste characteristics in order to achieve specific waste management targets -case study of Serbia. **Journal of Scientific and Industrial Research**, 2011. v. 70, n. 7, p. 513–518.

BENARDOS, P. G.; VOSNIAKOS, G.-C. Optimizing feedforward artificial neural network architecture. **Engineering applications of artificial intelligence**, v. 20, n. 3, p. 365-382, 2007.

BERNAT, K. *et al.* Biological treatment of leachate from stabilization of biodegradable municipal solid waste in a sequencing batch biofilm reactor. **International Journal of Environmental Science and Technology**, 2021. v. 18, n. 5, p. 1047–1060.

BERRY, Michael W.; MOHAMED, Azlinah; YAP, Bee Wah (Ed.). **Supervised and unsupervised learning for data science**. Springer Nature, 2019.

BEZERRA, Daniel Epifânio. **Redes Neurais Artificiais para determinação da composição de resíduos sólidos urbanos**. 2020. 62f. Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) - Universidade Estadual da Paraíba, Campina Grande, PB, 2020.

BIDONE, F. R. A.; POVINELLI, J. **Conceitos básicos de resíduos sólidos**. 1. ed. São Carlos: EESC/USP, 1999. 109p.

BOSCOV, M. E. G. **Geotecnia ambiental**. São Paulo: Oficina de Textos, 2008.

BREITMEYER, R. J.; BENSON, C. H.; EDIL, T. B. Effect of changing unit weight and decomposition on unsaturated hydraulics of municipal solid waste in bioreactor landfills. **Journal of Geotechnical and Geoenvironmental Engineering**, v. 146, n. 5, p. 04020021, 2020.

BURATTI, C. *et al.* Life Cycle Assessment of organic waste management strategies: An Italian case study. **Journal of Cleaner Production**, 2015. v. 89, p. 125–136.

BUSSAB, W. O.; MORETTIN, P. A. **Estatística Básica**. São Paulo: Editora Saraiva, 2017, 9ª Edição.

CAIRES, K. V. L.; SIMONELLI, G. Previsão da demanda brasileira de biodiesel utilizando redes neurais artificiais. **Research, Society and Development**, v. 10, n. 5, p. e17410513381-e17410513381, 2021.

CARVALHO, L. de A. **Redes neurais artificiais para modelagem de altos-fornos**. 2019. 157 f. Tese (Doutorado em Engenharia de Materiais) – Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, MG, 2019.

CARVALHO, M. de F. **Comportamento mecânico de resíduos sólidos urbanos**. 1999. 330 f. Tese (Doutorado em Geotecnia) - Universidade de São Paulo, São Carlos, SP, 1999.

CASTELO BRANCO, C. A. S. **Algoritmos adaptativos LMS normalizados proporcionais: proposta de novos algoritmos para identificação de plantas esparsas**. 2016. 176 f. Dissertação (Programa de Pós-Graduação em Engenharia de Eletricidade) - Universidade Federal do Maranhão, São Luís, MA, 2016.

CATAPRETA, C. A. A. **Comportamento de um aterro sanitário experimental: avaliação da influência do projeto, construção e operação**. 2008. Tese (Doutorado) – Universidade Federal de Minas Gerais, Belo Horizonte, MG, 2008.

CATAPRETA, C. A. A., SIMOES, G. F., BARROS, R. T. V. **Avaliação da densidade de resíduos sólidos urbanos dispostos em um aterro experimental**. In: Congresso de la Asociación Interamericana de Ingeniería Sanitaria y Ambiental, Punta del Este, Uruguay. Anais. Punta del Este: AIDIS. 2006.

CETESB. Companhia de Tecnologia de Saneamento Ambiental. **Resíduos sólidos urbanos e limpeza pública**. 1990. São Paulo – SP.

CHAKRAVERTY, S.; SAHOO, D. M.; MAHATO, N. R.. McCulloch–Pitts neural network model. In: **Concepts of Soft Computing**. Springer, Singapore, 2019. p. 167-173.

CHEN, Y. C. Effects of urbanization on municipal solid waste composition. **Waste management**, v. 79, p. 828-836, 2018.

CHENG, B.; TITTERINGTON, D. Michael. Neural networks: A review from a statistical perspective. **Statistical science**, p. 2-30, 1994.

CHENG, J. *et al.* Analysis of the factors that affect the production of municipal solid waste in China. **Journal of Cleaner Production**, v. 259, p. 120808, 2020.

CHICCO, Da.; WARRENS, M. J.; JURMAN, G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. **PeerJ Computer Science**, v. 7, p. e623, 2021.

CHOKSHI, P.; DASHWOOD, R.; HUGHES, D. J. Artificial Neural Network (ANN) based microstructural prediction model for 22MnB5 boron steel during tailored hot stamping. **Computers & Structures**, v. 190, p. 162-172, 2017.

CHOUKSEY, S. K.; BABU, GL S. Constitutive model for strength characteristics of municipal solid waste. **International Journal of Geomechanics**, v. 15, n. 2, 2015.

CONTRERA, R. C. **Estudo da tratabilidade de lixiviados de aterros sanitários em sistema de reatores anaeróbio e aeróbio operados em bateladas sequenciais e em um filtro biológico anaeróbio contínuo de fluxo ascendente**. 2008. 789 f. Tese (Doutorado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos – SP, 2008.

CORRÊA, C. L. **Análise da influência do plástico mole na resistência ao cisalhamento de resíduos sólidos urbanos**. 2013. 110 f. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, PE, 2013.

CORRÊA, C. L. **Estudo das propriedades mecânicas dos resíduos sólidos urbanos**. 2020. 231f. Tese (Doutorado em Engenharia de Civil) - Universidade Federal de Pernambuco, Recife, PE, 2020.

COSSU, R.; LAI, T., SANDON, A. Standardization of BOD<sub>5</sub>/COD ratio as a biological stability index for MSW. **Waste Management**, Vol. 32. p. 1503-1508, 2012.

COX, J. T. *et al.* Implications of variable waste placement conditions for MSW landfills. **Waste Management**, v. 46, p. 338–351, 2015.

CRESSIE, N. **Statistics for spatial data**. John Wiley & Sons, 2015.

DACIOLO, L. V. P. **Parâmetros de resistência de RSU: abordagem probabilística para análises de estabilidade de taludes de aterros de resíduos**. 126f. 2020. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal de São Carlos, São Carlos, 2020.

DAS, S. *et al.* Solid waste management: Scope and the challenge of sustainability. **Journal of Cleaner Production**, 2019. v. 228, p. 658–678.

DECOTTIGNIES, V. *et al.* Comparison of analytical methods to determine the stability of municipal solid waste and related wastes. Memórias. Sardinia 2005. In: **INTERNATIONAL WASTE MANAGEMENT AND LANDFILL SYMPOSIUM**, 10, 2005. Cagliari. Anais. Cagliari, 3-7, 2005.

DGGT, Deutsche Gesellschaft für Geotechnik. **Geotechnik der Deponien und Altlasten. GDA- Empfehlungen**, 3 Auflage, Ernst & Sohn, Berlin, 1994.

DIXON, N.; JONES, D. R. V. Engineering properties of municipal solid waste. **Geotextiles and Geomembranes**, [s. l.], v. 23, n. 3, p. 205-233, 24 fev. 2005.

DIXON, N.; LANGER, U. Development of a MSW classification system for the evaluation of mechanical properties. **Waste Management**, v. 26, n. 3, p. 220–232, 2006.

DONGARE, A. D. *et al.* Introduction to artificial neural network. **International Journal of Engineering and Innovative Technology (IJEIT)**, v. 2, n. 1, p. 189-194, 2012.

DUAN, Z.; SCHEUTZ, C.; KJELDSEN, P. Trace gas emissions from municipal solid waste landfills: A review. **Waste Management**, 2021. v. 119, p. 39–62.

DUBEY, Shiv Ram; SINGH, Satish Kumar; CHAUDHURI, Bidyut Baran. Activation functions in deep learning: A comprehensive survey and benchmark. **Neurocomputing**, 2022.

EHRIG, H.-J. Quality and quantity of sanitary landfill leachate. **Waste Management & Research**, v. 1, n. 1, p. 53-68, 1988.

FALLAHIZADEH, Saeid *et al.* Estimation of methane gas by LandGEM model from Yasuj municipal solid waste landfill, Iran. **MethodsX**, v. 6, p. 391-398, 2019.

ERGENE, Didar; AKSOY, Ayşegül; SANIN, F. Dilek. Comprehensive analysis and modeling of landfill leachate. **Waste Management**, v. 145, p. 48-59, 2022.

FARIAS, R. M. de 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.

FARRANT, L.; OLSEN, S. I.; WANGEL, A. Environmental benefits from reusing clothes. **Int. J. Life Cycle Assess.** v. 15, p 726-736, 2010.

FENG, J.; LU, S. Performance analysis of various activation functions in artificial neural networks. In: **Journal of physics: conference series**. IOP Publishing, 2019. p. 022030.

FIRMO, A. L. B. **Estudo numérico e experimental da geração de biogás a partir da biodegradação de resíduos sólidos urbanos**. 2013. 268p. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, PE, 2013.

FLECK, Leandro *et al.* Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016.

FUCALE, S. P. **Influência dos componentes de reforço na resistência de resíduos sólidos urbanos**. 2005. 216p. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, PE, 2005.

GARCEZ, L. R. SALES, K. C. S.; LEITE, H. E. A. S.; MONTEIRO, V. E. D.; LEITE, V. D. Relação carbono/nitrogênio existente em um bioreator de resíduos sólidos da cidade de Campina Grande. **XXXI Congresso Interamericano de Engenharia Sanitária e Ambiental - AIDIS**. 2008.

GHOSH-DASTIDAR, S.; ADELI, H. Spiking neural networks. **International journal of neural systems**, v. 19, n. 04, p. 295-308, 2009.

GUIMARÃES, A. M. *et al.* Módulo de validação cruzada para treinamento de redes neurais artificiais com algoritmos backpropagation e resilient propagation. **Publicatio UEPG: Ciências Exatas e da Terra, Agrárias e Engenharias**, v. 14, n. 01, 2008.

GURNEY, K. **An Introduction to Neural Networks**. Reino Unido (UK): UCL Press, 1997.

HAO, S., RYU, D., WESTERN, A., PERRY, E., BOGENA, H., & FRANSSEN, H. J. H. Performance of a wheat yield prediction model and factors influencing the performance: A review and meta-analysis. **Agricultural Systems**, v. 194, p. 103278, 2021.

HAPPEL, B. L. ; MURRE, J. MJ. Design and evolution of modular neural network architectures. **Neural networks**, v. 7, n. 6-7, p. 985-1004, 1994.

HAYKIN, S. **Redes Neurais: Princípios e prática**. Porto Alegre (RS): Editora Brookman, 2001. 900p.

HE, P. *et al.* Municipal solid waste (MSW) landfill: A source of microplastics?-Evidence of microplastics in landfill leachate. **Water research**, v. 159, p. 38-45, 2019.

HIRSCH, A. K.; VERA, R. A.; BRIONES, M. E. Estudio a escala de laboratorio para la determinación de los parámetros hidrológicos óptimos para la generación de metano em rellenos sanitários em Chile. **Project de Investigación**, n°202, v. 788, p. 1-61, 2001.

HONGYU, K.; SANDANIELO, V. L. M.; DE OLIVEIRA JUNIOR, G. J.. Análise de componentes principais: resumo teórico, aplicação e interpretação. **ES Engineering and Science**, v. 5, n. 1, p. 83-90, 2016.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the national academy of sciences**, v. 79, n. 8, p. 2554-2558, 1982.

IBAM. **Manual de Gerenciamento Integrado de resíduos sólidos**. Coordenação técnica Victor Zular Zveibil. Rio de Janeiro: IBAM, 2001.

IPT, CEMPRE. Lixo Municipal: Manual de Gerenciamento Integrado. **Publicação IPT– Instituto de Pesquisa Tecnológicas, S. Paulo**, 2000.

JAUNICH, M. K. *et al.* Solid waste management policy implications on waste process choices and systemwide cost and greenhouse gas performance. **Environmental science & technology**, v. 53, n. 4, p. 1766-1775, 2019.

JESSBERGER, H.L. Geotechnical aspects of landfill design and construction. Part 2: material parameters and test methods. **Proceedings of the Institution of Civil Engineers Geotechnical Engineering**. V. 107, n. 2, 105–113, 1994.

JOHNSON, R.A.; WICHERN, D.W. **Applied multivariate statistical analysis**, 6 ed., Madison: Prentice Hall International. 2007. 816p.

KAIMOTO, L. S. A.; CEPOLLINA, M. Considerações sobre alguns condicionantes e critérios geotécnicos de projeto e executivos de aterros sanitários. **Simpósio Internacional de Qualidade Ambiental, Projeto de Aterros de Resíduos, e Saneamento de Áreas Degradadas**, v. 16, p. 51-54, 1996.

KARIMPOUR-FARD, Mehran *et al.* A laboratory study on the MSW mechanical behavior in triaxial apparatus. **Waste management**, v. 31, n. 8, p. 1807-1819, 2011.

KAVAZANJIAN, E. Mechanical properties of municipal solid waste. In: **Proceedings sardinia**. 2001. p. 415-424.

KELLY, Ryan J. **Solid waste biodegradation enhancements and the evaluation os analytical methods used to predicted waste stability**. 2002. Thesis (Master of science in Environmental Science and Engineering) - Faculty of Virginia Polytechnic Institute and State University, Blacksburg, Virginia/USA, 2002.

KIETZMANN, Tim C.; MCCLURE, Patrick; KRIEGESKORTE, Nikolaus. Deep neural networks in computational neuroscience. **BioRxiv**, p. 133504, 2018.

KIM, Viviane Jin Hee. **Análise da composição gravimétrica dos resíduos domiciliares de São Carlos (SP)**. 2019. 196 f. Dissertação (Mestrado em Engenharia Hidráulica e Saneamento). Universidade de São Paulo – USP, São Carlos, SP. 2019.

KNOCHENMUS, G.; WOJNAROWICZ, M.; VAN IMPE (1998). Stability of Municipal Solid Wastes. In: **Proc. of the Third International Congress on Environmental Geotechnics**, Lisboa, Portugal, Sêco e Pinto (ed.), Balkema, Rotterdam, p. 977-1000.

KÖLSCH, F. Materials values for some mechanical Properties of omestic waste. In: **INTERNATIONAL LANDFILL SYMPOSIUM**, 5., 1995, S. Margherita di Pula, Cagliari, Italy. Anais. Cagliari: CISA, 1995. v. 2, p.711-729

KÖNIG, D.; JESSBERGER, H. L. Waste mechanics. **ISSMFE technical committee TC5 on environmental geotechnics**, p. 35-76, 1997.

KUMARI, Priyanka et al. Application of principal component analysis and correlation for assessing groundwater contamination in and around municipal solid waste landfill of Ghazipur, Delhi. **Journal of the Geological Society of India**, v. 94, p. 595-604, 2019.

LANDVA, A.; CLARK, J. Geotechnics of Waste Fill. In: **STP1070-EB Geotechnics of Waste Fills—Theory and Practice**. West Conshohocken, PA, Anais. West Conshohocken, PA: ASTM International, 1990. p. 86–103.

- LANDVA, A.; CLARK, J. Geotechnical Testing of Wastefill. In: **39<sup>th</sup> Canadian Geotechnical Conference**, Ottawa, Ontario, 1986. P. 371-385.
- LANGE, L. C.; COLHO, H. M.; ALVES, D. E. W. S.; FERREIRA, C. F. A.; SIMÕES, G. F.; SILVA, F. V. B. **Metodologias para análises laboratoriais de resíduos sólidos urbanos, líquidos lixiviados de aterros sanitários e solos. Rede cooperativa de pesquisas – alternativa de disposição de resíduos sólidos urbanos para pequenas comunidades.** PROSAB, P. 200-221. 2002.
- LAURENT, A. *et al.* Review of LCA studies of solid waste management systems–Part I: Lessons learned and perspectives. **Waste management**, v. 34, n. 3, p. 573-588, 2014.
- 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.
- LEITE, H. E. A. S. **Estudo do comportamento de aterros de RSU em um biorreator em escala experimental na cidade de Campina Grande –PB.** 2008. 2018 f. Dissertação (Mestrado em Engenharia Civil e Ambiental). Universidade Federal de Campina Grande, Campina Grande, PB, 2008.
- LIANG, Qingqing *et al.* 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.
- LIMA, L. M. Q. **Tratamento e Biorremediação.** 3 ed. São Paulo: Hemus Livraria, 265p. 2004.
- LINDAMULLA, L. *et al.* Municipal Solid Waste Landfill Leachate Characteristics and Their Treatment Options in Tropical Countries. **Current Pollution Reports**, 2022. v. 8, n. 3, p. 273–287.
- LUO, Hongwei *et al.* Recent advances in municipal landfill leachate: A review focusing on its characteristics, treatment, and toxicity assessment. **Science of the Total Environment**, v. 703, p. 135468, 2020.
- LU, P. *et al.* Review on fate of chlorine during thermal processing of solid wastes. **Journal of Environmental Sciences (China)**, 2019. v. 78, p. 13–28.
- MA, S. *et al.* Estimating Physical Composition of Municipal Solid Waste in China by Applying Artificial Neural Network Method. **Environmental Science and Technology**, 2020. v. 54, n. 15, p. 9609–9617.
- MA, Shijun *et al.* Estimating physical composition of municipal solid waste in China by applying artificial neural network method. **Environmental science & technology**, v. 54, n. 15, p. 9609-9617, 2020.
- MA, Siwei, *et al.* "Image and video compression with neural networks: A review." **IEEE Transactions on Circuits and Systems for Video Technology**. 2019, p. 1683-1698.

- MANASSERO, M.; VAN IMPE, W.F.; BOUAZZA, A. Waste disposal and containment. In: **INTERNATIONAL CONGRESS ON ENVIRONMENTAL GEOTECHNICS**, 2., 1996, Osaka, Japão. Anais. Osaka: 1996, v. 3, p. 1425–1474.
- MARIANO, M. O. H.; MACIEL, F. J.; FUCALE, S. P.; JUCÁ, J. F. T.; BRITO, A. R. de. Composição gravimétrica e volumétrica dos rsu da célula piloto do aterro de resíduos sólidos da Muribeca. In: **CONGRESSO BRASILEIRO DE ENGENHARIA SANITÁRIA E AMBIENTAL**, 24., 2007, Belo Horizonte, MG. Resumo.
- MARQUES, A. C. M. **Compactação e compressibilidade de resíduos sólidos urbanos**. 2001. 267 f. Tese (Doutorado em Geotecnia) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, 2001.
- 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.
- MELO, M. C. de *et al.* Deformação vertical dos resíduos sólidos urbanos em uma célula experimental em função da composição gravimétrica e volumétrica dos materiais. **Matéria (Rio de Janeiro)**, v. 21, p. 450-460, 2016.
- MELO, M. C. de. **Estudo da matéria orgânica nos recalques de resíduos sólidos urbanos aterrados**. 2011. 159 f. (Doutorado em Ciência e Engenharia de Materiais) - Universidade Federal de Campina Grande - Paraíba - Brasil, 2011.
- MENG, Z.; HU, Y.; ANCEY, C.. Using a data driven approach to predict waves generated by gravity driven mass flows. **Water**, v. 12, n. 2, p. 600, 2020.
- MIEZAH, K. *et al.* Municipal solid waste characterization and quantification as a measure towards effective waste management in Ghana. **Waste Management**, 2015. v. 46, p. 15–27.
- Milojkoviü, J.; Litovski,I.; Litovski, V.; "ANN Application for the Next Day Peak Electricity Load Prediction", **11th Symposium on Neural Network Applications in Electrical Engineering**, September 2012, Belgrade, Serbia.
- MIRANDA, A. M. de. **Estudos do peso específico de resíduos sólidos urbanos**. 2004. 112 f. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, 2004.
- MIRANDA, F. A.; DE FREITAS, S. R. C.; FAGGION, P. L.. Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de RNA e krigagem. **Boletim de Ciências Geodésicas**, v. 15, n. 3, p. 428-443, 2009.
- MOKHTARI, M.; HESHMATI RAFSANJANI, A. A.; SHARIATMADARI, N.. The effect of aging on the compressibility behavior and the physical properties of municipal solid wastes: a case study of Kahrizak landfill, Tehran. **Environmental Earth Sciences**, v. 78, n. 16, p. 1-14, 2019.
- MONTEIRO, V. E. D. Análises físicas, químicas e biológicas no estudo do comportamento do aterro da Muribeca. 2003. Tese (Doutorado em Engenharia Civil) – Centro de Tecnologia e Geociências, Universidade Federal de Pernambuco, Recife, PE, 2003.

MORETTIN, P. A.; BUSSAB, W. O. Estatística básica. Saraiva Educação SA, 2017.

MOTA, S. Introdução à engenharia ambiental. 2ª. Ed. **Rio de Janeiro: ABES. Associação Brasileira de Engenharia Ambiental e Sanitária**, 2000.

NANDA, S.; BERRUTI, F. Municipal solid waste management and landfilling technologies: a review. **Environmental Chemistry Letters**, 2021. v. 19, n. 2, p. 1433–1456.

NASCIMENTO, J. C. F. do. **Comportamento mecânico de resíduos sólidos urbanos**. 2007. 160 f. Dissertação (Mestrado em Geotecnia) – Universidade de São Paulo, São Carlos, SP, 2007.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models, part I – **A discussion of principles**. **Journal of Hydrology**, [s. l.]. v. 10, n.3, p. 282-290, 1970.

NATH, Aishi; DEBNATH, Animesh. A short review on landfill leachate treatment technologies. **Materials Today: Proceedings**, 2022. V. 67, n 8 , p. 1290-1297.

NGUYEN, Le Quyen; FERNANDES, Paula Odete; TEIXEIRA, João Paulo. Analyzing and Forecasting Tourism Demand in Vietnam with Artificial Neural Networks. **Forecasting**, v. 4, n. 1, p. 36-50, 2022.

OWEIS, I. S. (1993). **Stability of Landfill Geotechnical Practice for Waste Disposal**. Ed. David & Daniel, p.244-268.

OWUSU-NIMO, F. *et al.* Characteristics and management of landfill solid waste in Kumasi, Ghana. **Scientific African**, 2019. v. 3.

Paiva, William de. **Aplicação da estatística para descrever o comportamento de um solo expansivo**. 2009. 217 f. Tese (Doutorado em Engenharia Civil). Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Pernambuco, Recife, PE, 2009.

Pamungkas, A., R. Zulkarnain, K. Adiyana, Waryanto, H. Nugroho, and A S Saragih. "Application of Artificial Neural Networks to Forecast Litopenaeus Vannamei and Penaeus Monodon Harvests in Indramayu Regency, Indonesia." **IOP Conference Series. Earth and Environmental Science**, 2020.

PANDEY, S.; HINDOLIYA D.A.; RITU M. "Artificial Neural Networks for Predicting Indoor Temperature Using Roof Passive Cooling Techniques in Buildings in Different Climatic Conditions." **Applied Soft Computing**.

PANTIC, J. J. *et al.* Geotechnical Effects of Municipal Solid Waste Destruction with Different Compaction Methods. In: **Proceedings of the Bulgarian Academy of Sciences**. 2022. p. 110-120.

PECORINI, Isabella; IANNELLI, Renato. Characterization of excavated waste of different ages in view of multiple resource recovery in landfill mining. **Sustainability**, v. 12, n. 5, p. 1780, 2020.

- PORTELLA, M. O.; RIBEIRO, J. C. J. Aterros sanitários: aspectos gerais e destino final dos resíduos. **Revista Direito Ambiental e Sociedade**, v. 4, n. 1, 2014.
- PRAAGH, M. v.; HARTMAN, Co.; BRANDMYR, E. **Microplastics in landfill leachates in the nordic countries**. Nordic Council of Ministers. Dinamarca: Rosendahls, 2018. 53 p.
- RAJAGOPAL, R.; MASSÉ, D. I.; SINGH, G. A critical review on inhibition of anaerobic digestion process by excess ammonia. **Bioresource technology**, v. 143, p. 632-641, 2013.
- Ramaiah, B.J, G.V Ramana, and Manoj Datta. "Mechanical Characterization of Municipal Solid Waste from Two Waste Dumps at Delhi, India." **Waste Management (Elmsford)**. v 68 p 275-291. 2017.
- REDDY, K. R.; HETTIARACHCHI, H.; GIRI, R. K.; GANGATHULASI, J. Effects of Degradation on Geotechnical Properties of Municipal Solid Waste from Orchard Hills Landfill, USA. **International Journal of Geosynthetics and Ground Engineering**, [s. l.], v. 1, n.3, p.1-14, 15 jul. 2015.
- REDDY, K. R.; HETTIARACHCHI, H.; PARAKALLA, N. S.; GANGATHULASI, J.; BOGNER, J. E. Geotechnical properties of fresh municipal solid waste at Orchard Hills Landfill, USA. **Waste Management**, [s. l.], v. 29, n. 2, p. 952-959, fev. 2009.
- REDDY, K. R. *et al.* Geotechnical properties of fresh municipal solid waste at Orchard Hills Landfill, USA. **Waste Management**, v. 29, n. 2, p. 952-959, 2009.
- REMÉDIO, Flávio Henrique. **Análise de estabilidade de taludes de aterro de resíduos sólidos urbanos utilizando parâmetros geotécnicos de propostas bibliográficas e correlações com o NSPT**. 2014. 131f. Dissertação (Mestrado em Geociências) - Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, SP, 2014.
- RIBEIRO, L. S. *et al.* Análise da relação de indicadores físico-químicos do lixiviado gerado em um aterro sanitário no Semiárido Brasileiro. **AGROPECUÁRIA CIENTÍFICA NO SEMIÁRIDO**, v. 17, n. 1, p. 36-42, 2021.
- RIBEIRO, L. S. **Estudo da Degradação dos Resíduos Sólidos Urbanos através dos Parâmetros Físicos e Físico-Químicos em um Biorreator de Escala Experimental**. 2012. 137 f. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Campina Grande, PB, 2012.
- ROSENBERG, M. S. The bearing correlogram: a new method of analyzing directional spatial autocorrelation. **Geographical Analysis**, v. 32, n. 3, p. 267-278, 2000.
- ROSENBLATT, F. The *perceptron*: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Parallel Distributed Processing. Vol. 1, **MIT Press**, 1996.

RUSSO, M. A. T. **Avaliação dos processos de transformação de resíduos sólidos urbanos em aterro sanitário**. 298p. 2005. Tese (Doutorado em Engenharia Civil) - Universidade do Minho, Braga, Portugal, 2005.

SALAMONI, G. P. D. *et al.* **Compressibilidade de resíduos sólidos urbanos devido aos processos de biodegradação em um aterro sanitário**. 2019. 230 f. Tese (Doutorado em Engenharia Civil). Universidade Federal de Santa Maria, Santa Maria, RS, 2019.

SALMERON, J. L.; RUIZ-CELMA, A. Elliot and symmetric eliot extreme learning machines for Gaussian noisy industrial thermal modelling. **Energies**, v. 12, n. 1, p. 90, 2018.

SANTOS, L. A. O.; PRESA, E. P. Compressibilidade de aterros sanitários controlados. **III Simpósio sobre Barragens de Rejeito e Disposição de Resíduos-REGEO**, v. 95, p. 577-591, 1995.

SHAH, A. V. *et al.* Municipal solid waste as a sustainable resource for energy production: State-of-the-art review. **Journal of Environmental Chemical Engineering**, v. 9, n. 4, p. 105717, 2021.

SHARIATMADARI, N.; SADEGHPOUR, A. H.; MOKHTARI, MJIJCE. Aging effect on physical properties of municipal solid waste at the Kahrizak Landfill, Iran. **International Journal of Civil Engineering**, v. 13, n. 1, p. 126-136, 2015.

SHARKAWY, A. N. Principle of neural network and its main types. **Journal of Advances in Applied & Computational Mathematics**, v. 7, p. 8-19, 2020.

SHU, S. *et al.* Effect of gas pressure on municipal solid waste landfill slope stability. **Waste Management & Research**, v. 40, n. 3, p. 323-330, 2022.

SILVA, A. K. M.; MOTA, F. S. B. **Caracterização dos Resíduos Sólidos Urbanos: Aproveitamento do Biogás**. 1 ed. Curitiba: Editora Appris, 2019. 213p.

SILVA, A. S. **Avaliação da toxicidade dos resíduos sólidos urbanos da cidade de Campina Grande – PB**. 2012. 140f. Dissertação (Mestrado em Engenharia Civil e Ambiental) - Universidade Federal de Campina Grande, Campina Grande, PB, 2012.

SILVA, A. L. F. **Potencial de aproveitamento energético do biogás produzido no Aterro Sanitário Metropolitano de Natal**. 2019. 56 f. Monografia (Bacharel em Engenharia Ambiental). Universidade Federal do Rio Grande do Norte, Natal, RN, 2019.

SILVA, E. M.. **Ecotoxicidade de resíduos sólidos urbanos e de lixiviado gerado em aterro sanitário**. 2022. 185 f. Tese (Doutorado em Engenharia Civil e Ambiental) - Universidade Federal de Campina Grande, Paraíba, Brasil, 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.

SIMÕES, G.F. **Modelo para avaliação de recalques em aterros de disposição de resíduos sólidos urbanos**. 2000. 139p. Tese (Doutorado em Engenharia Civil) – Pontificia Universidade Católica do Rio de Janeiro, Rio de Janeiro, RJ, 2000.

SINGH, A.; CHANDEL, M. K. Effect of ageing on waste characteristics excavated from an Indian dumpsite and its potential valorisation. **Process Safety and Environmental Protection**, v. 134, p. 24-35, 2020.

Suzuki, K. Artificial Neural Networks-Architectures and Applications; **IntechOpen Limited**. London, UK, 2013.

TAGLIAFERRO, E. R.; VIANA, D. V. Caracterização Gravimétrica dos Resíduos Sólidos de um Aterro Sanitário Municipal no Interior do Estado de São Paulo. **Periódico Técnico e Científico Cidades Verdes**, v. 7, n. 16, 2019.

TAPAHUASCO, W. F. C. **Análise do comportamento de maciços sanitários e proposta de novas equações de previsão de recalques considerando a parcela de biodegradação**. 2009. 161 f. Tese (Doutorado em Engenharia Civil) - Universidade de Brasília, Brasília, 2009.

TENG, C. *et al.* Characterization and treatment of landfill leachate: A review. **Water Research**, 2021. v. 203, n. July, p. 117525.

TESCHE, C.; GRAY, H. N. Machine learning and deep neural networks applications in coronary flow assessment: the case of computed tomography fractional flow reserve. **Journal of Thoracic Imaging**, v. 35, p. S66-S71, 2020.

UHRIG, R. E. Introduction to artificial neural networks. In: **Proceedings of IECON'95-21st Annual Conference on IEEE Industrial Electronics**. IEEE, 1995. p. 33-37.

VERMA, K. K.; SINGH, B. M.n; DIXIT, A. A review of supervised and unsupervised machine learning techniques for suspicious behavior recognition in intelligent surveillance system. **International Journal of Information Technology**, v. 14, n. 1, p. 397-410, 2022.

VIEIRA, L. C.; CANDIANI, G. Potencial energético de resíduos sólidos urbanos na Região do Grande ABC Paulista. *Revista Ibero Americana de Ciências Ambientais*, v.12, n.2, p.328-342, 2021.

VILLALBA, L. *et al.* Household solid waste characterization in Tandil (Argentina): Socioeconomic, institutional, temporal and cultural aspects influencing waste quantity and composition. **Resources, Conservation and Recycling**, v. 152, p. 104530, 2020.

VIVAS, E.; ALLENDE-CID, H.; SALAS, R.o. A systematic review of statistical and machine learning methods for electrical power forecasting with reported mape score. **Entropy**, v. 22, n. 12, p. 1412, 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.

WANG, Y. *et al.* The influence of the activation function in a convolution neural network model of facial expression recognition. **Applied Sciences**, v. 10, n. 5, p. 1897, 2020.

WASTE ATLAS. **What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050**. Urban Development Series. Washington, DC: World Bank, 2018.

WIDROW, B.; HOFF, M. E. **Adaptive switching circuits**. Stanford Univ Ca Stanford Electronics Labs, 1960.

Wilamowski, B.M. "Neural Network Architectures and Learning Algorithms." *IEEE Industrial Electronics Magazine* 3.4 (2009): 56-63.

XIE, Yuekai et al. Geotechnical properties of fresh municipal solid wastes with different compositions under leachate exposure. **Waste Management**, v. 149, p. 207-217, 2022.

XU, A. *et al.* Status and prospects of atmospheric microplastics: A review of methods, occurrence, composition, source and health risks. **Environmental Pollution**, p. 119173, 2022.

YANG, D. Correlogram, predictability error growth, and bounds of mean square error of solar irradiance forecasts. **Renewable and Sustainable Energy Reviews**, v. 167, p. 112736, 2022.

YANG, G. R.; WANG, X. J. Artificial neural networks for neuroscientists: A primer. **Neuron**, v. 107, n. 6, p. 1048-1070, 2020.

YANG, R.; XU, Z.; CHAI, J. A Review of Characteristics of Landfilled Municipal Solid Waste in Several Countries: Physical Composition, Unit Weight, and Permeability Coefficient. **Polish journal of environmental studies**, v. 27, n. 6, 2018.

YESILLER, N.; HANSON, J. L.; COX, J. T.; NOCE, D. E. Determination of specific gravity of municipal solid waste. **Waste Management**, [s. l.], v. 34, n. 5, p. 848-858, mai. 2014.

YU, F. *et al.* Effect of landfill age on the physical and chemical characteristics of waste plastics/microplastics in a waste landfill sites. **Environmental Pollution**, v. 306, p. 119366, 2022.

YU, J. *et al.* Physical and chemical characterization of ashes from a municipal solid waste incinerator in China. **Waste management & research**, v. 31, n. 7, p. 663-673, 2013.

ZAMORA-CÁRDENAS, W.; ZUMBADO, M.; TREJOS-ZELAYA, Ignacio. McCulloch-Pitts Artificial Neuron and Rosenblatt's *Perceptron*: An abstract specification in: **Technology Inside by CPIC**, v. 5, p. 16-29, 2020.

ZEKKOS, D. *et al.* Unit weight of municipal solid waste. **Journal of Geotechnical and Geoenvironmental Engineering**, v. 132, n. 10, p. 1250-1261, 2006.

ZHAN, T. L. T.; CHEN, Y. M.; LING, W. A. Shear strength characterization of municipal solid waste at the Suzhou landfill, China. **Engineering Geology**, v. 97, n. 3-4, p. 97-111, 2008.

ZHANG, Q. *et al.* Artificial neural networks enabled by nanophotonics. **Light: Science & Applications**, v. 8, n. 1, p. 1-14, 2019.

ZHAO, R. *et al.* Impacts of different aged landfill leachate on PVC corrosion. **Environmental Science and Pollution Research**, v. 26, n. 18, p. 18256-18266, 2019.

ZHOU, C. *et al.* A comparison study of bottom-up and top-down methods for analyzing the physical composition of municipal solid waste. **Journal of Industrial Ecology**, v. 26, n. 1, p. 240-251, 2022.

ZHOU, J. *et al.* Graph neural networks: A review of methods and applications. **AI Open**, v. 1, p. 57-81, 2020.

## APÊNDICE A

O Apêndice A mostra de maneira resumida o código utilizado para o treinamento com Redes Neurais Artificiais.

```

%Criado por: Daniel Epifânio Bezerra
%Última modificação: Novembro 2022
%Título: Previsão de composição gravimétrica
%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"
"traingf" "traingcp" "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
            elseif (exeline >= 64)&&(exeline < 84)%Limite da primeira série de treinamentos
                Logsig_Elliotsig
                j = 4;%Função elliotstsig na camada de saída
            end
        end
    end
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("Dados.xls", 4, "C2:L421");%Banco de dados original
novaentrada = dadosgerais;%Variável de controle para o BD
entrada = novaentrada(:, 7:end);%Separação da entrada
saida = novaentrada(:, 1:6);%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; %número máximo de iterações
net.trainParam.lr = 0.01; %taxa de aprendizagem
net.trainParam.time = inf; %tempo máximo de iterações

```

```

net.layers{1}.transferFcn = atvfnco; %definição da função de ativação da camada
oculta
net.layers{2}.transferFcn = atvfncs; %definição da função de ativação da camada de
saída

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

entradamodificada = zeros(2, size(entrada,2)); %cria matriz zeradas do tamanho da
entrada de dados
novaentrada = [entrada(1:4, :); entradamodificada];%Junta as linhas zeradas aos
dados de entrada

%Separação das máscaras de treinamento e teste do bd
%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(saida,tr.trainMask);%Máscara de treinamento
testeoutput = gmultiply(saida,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
teste1input (6,:) = [];
teste1input (5,:) = [];

%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(:,1),resultado(:,1))); (mae
(teste1output(:,2),resultado(:,2)));
(mae (teste1output(:,3),resultado(:,3)));(mae (teste1output(:,4),resultado(:,4)));
(mae (teste1output(:,5),resultado(:,5)));(mae (teste1output(:,6),resultado(:,6)))]';

%Calcula o RMSE, MSE e Mape
estatisticas = [(CalcPerf (teste1output(:,1),resultado(:,1))); (CalcPerf
(teste1output(:,2),resultado(:,2)));

```

```

        (CalcPerf (teste1output(:,3),resultado(:,3)))(CalcPerf
(teste1output(:,4),resultado(:,4)));
        (CalcPerf (teste1output(:,5),resultado(:,5)))(CalcPerf
(teste1output(:,6),resultado(:,6)))]';

```

```

%Calcula o coeficiente de determinação R2

```

```

Rdois = [(est (teste1output(:,1),resultado(:,1))); (est
(teste1output(:,2),resultado(:,2)));
        (est (teste1output(:,3),resultado(:,3)))(est (teste1output(:,4),resultado(:,4)));
        (est (teste1output(:,5),resultado(:,5)))(est (teste1output(:,6),resultado(:,6)))]';

```

```

%Calcula o coeficiente de eficiência (E)

```

```

Eficiencia = [(NSE (teste1output(:,1),resultado(:,1))); (NSE
(teste1output(:,2),resultado(:,2)));
        (NSE (teste1output(:,3),resultado(:,3)))(NSE (teste1output(:,4),resultado(:,4)));
        (NSE (teste1output(:,5),resultado(:,5)))(NSE (teste1output(:,6),resultado(:,6)))]';

```

```

%Compilação e transcrição dos resultados

```

```

estfinal = [MAE estatisticas.RMSE estatisticas.Mape estatisticas.NRMSE Rdois
Eficiencia]; %Cria matriz de resultados

```

```

nomenclatura = [num2str(neurons) convertCharsToStrings(atvfnco)
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), ":", "AN", 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(:,1)*100, "ko:", vetorindex, resultado(:,1)*100, "rx:");
%Plotagem do gráfico valores preditos e observados
grid on; %Ativar o grid
legend ("Observados", nomerede1+"."+neurons+"."+funtrain); %legenda
xlabel('POSIÇÃO'); % eixo x
ylabel('PAPEL (%)') % eixo y
saveas (gcf, strcat(nomerede, "Papel", num2str(neurons)), "png");%Salvar o Gráfico
.png

figure(2)%Gráfico categoria Plástico
plot (vetorindex, teste1output(:,2)*100, "ko:", vetorindex,
resultado(:,2)*100, "rx:");%Plotagem do gráfico valores preditos e observados
grid on;%Ativar o grid
legend ("Observados", nomerede1+"."+neurons+"."+funtrain);%legenda
xlabel('POSIÇÃO'); % eixo x
ylabel('PLÁSTICO (%)') % eixo y
saveas (gcf, strcat(nomerede, "Plástico", num2str(neurons)), "png");%Salvar o
Gráfico .png

```

```

figure(3)%Gráfico categoria Vidro
plot (vetorindex,teste1output(:,3)*100, "ko:", vetorindex,
resultado(:,3)*100,"rx:");%Plotagem do gráfico valores preditos e observados
grid on;%Ativar o grid
legend ("Observados", nomerede1+"."+neurons+"."+funtrain);%legenda
xlabel("POSIÇÃO"); % eixo x
ylabel("VIDRO (%)') % eixo y
saveas (gcf, strcat(nomerede, "Vidro",num2str(neurons)), "png");%Salvar o Gráfico
.png

```

```

figure(4)%Gráfico categoria Metal
plot (vetorindex,teste1output(:,4)*100, "ko:", vetorindex,
resultado(:,4)*100,"rx:");%Plotagem do gráfico valores preditos e observados
grid on;%Ativar o grid
legend ("Observados", nomerede1+"."+neurons+"."+funtrain);%legenda
xlabel("POSIÇÃO"); % eixo x
ylabel("METAL (%)') % eixo y
saveas (gcf, strcat(nomerede, "Metal",num2str(neurons)), "png");%Salvar o Gráfico
.png

```

```

figure(5)%Gráfico categoria Matéria Orgânica
plot (vetorindex,teste1output(:,5)*100, "ko:", vetorindex,
resultado(:,5)*100,"rx:");%Plotagem do gráfico valores preditos e observados
grid on;%Ativar o grid
legend ("Observados", nomerede1+"."+neurons+"."+funtrain);%legenda
xlabel("POSIÇÃO"); % eixo x
ylabel("MATÉRIA ORGÂNICA (%)') % eixo y
saveas (gcf, strcat(nomerede, "Matéria Orgânica",num2str(neurons)),
"png");%Salvar o Gráfico .png

```

```

figure(6)%Gráfico categoria Outros
plot (vetorindex,teste1output(:,6)*100, "ko:", vetorindex,
resultado(:,6)*100,"rx:");%Plotagem do gráfico valores preditos e observados
grid on;%Ativar o grid
legend ("Observados", nomererede1+"."+neurons+"."+funtrain);%legenda
xlabel("POSIÇÃO"); % eixo x
ylabel('OUTROS (%)') % eixo y
saveas (gcf, strcat(nomererede, "Outros",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 %Parte simplificada por repetir trechos
+ elseif (i == 3)%Função purelin na camada oculta %Parte simplificada por repetir trechos
+ elseif (i == 4)%Função elliotstsig na camada oculta %Parte simplificada por repetir
trechos

```

```
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
```