



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

**DANIEL EPIFÂNIO BEZERRA**

**REDES NEURAS ARTIFICIAIS PARA DETERMINAÇÃO DA COMPOSIÇÃO DE  
RESÍDUOS SÓLIDOS URBANOS**

**CAMPINA GRANDE  
2020**

**DANIEL EPIFÂNIO BEZERRA**

**REDES NEURAIS ARTIFICIAIS PARA DETERMINAÇÃO DA COMPOSIÇÃO DE  
RESÍDUOS SÓLIDOS URBANOS**

Trabalho de Conclusão de Curso (TCC) apresentado ao Departamento de Engenharia Sanitária e Ambiental da Universidade Estadual da Paraíba (UEPB), como requisito obrigatório à obtenção do título de Bacharel em Engenharia Sanitária e Ambiental.

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

**CAMPINA GRANDE  
2020**

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

B574r Bezerra, Daniel Epifânio.  
Redes Neurais Artificiais para determinação da composição de resíduos sólidos urbanos [manuscrito] / Daniel Epifanio Bezerra. - 2020.  
62 p. : il. colorido.  
Digitado.  
Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia , 2020.  
"Orientação : Prof. Dr. William de Paiva , Departamento de Engenharia Sanitária e Ambiental - CCT."  
1. Resíduos sólidos urbanos. 2. Composição Gravimétrica.  
3. Redes Neurais Artificiais. I. Título  
21. ed. CDD 628.44

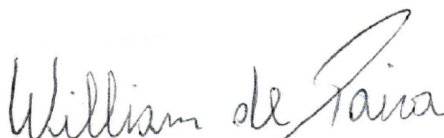
**DANIEL EPIFÂNIO BEZERRA**

**REDES NEURAS ARTIFICIAIS PARA DETERMINAÇÃO DA COMPOSIÇÃO DE  
RESÍDUOS SÓLIDOS URBANOS**

Trabalho de Conclusão de Curso (TCC) apresentada ao Departamento de Engenharia Sanitária e Ambiental da Universidade Estadual da Paraíba (UEPB), como requisito obrigatório à obtenção do título de Bacharel em Engenharia Sanitária e Ambiental.

Aprovada em: 09/12/2020.

**BANCA EXAMINADORA**



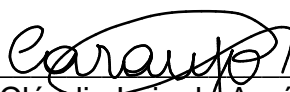
---

Prof. Dr. William de Paiva (Orientador)  
Universidade Estadual da Paraíba (UEPB)



---

Prof. Dr. Laércio Leal dos Santos  
Universidade Estadual da Paraíba (UEPB)



---

Prof. Me. Cláudio Luís de Araújo Neto  
Centro Universitário Maurício de Nassau (UNINASSAU)

## AGRADECIMENTOS

À Deus, por toda paciência e força concedidos durante todo período da graduação.

A minha base, o meu pai Orlando Bezerra e minha mãe Maria Zélia, 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 me acolherem em sua casa nesses últimos sete anos. E a todos os meus familiares por todo apoio e compreensão.

A minha namorada Sabrina Holanda Oliveira, por todo o carinho, cumplicidade, apoio e compreensão, por sempre estar do meu lado nos momentos de dedicação aos estudos.

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

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

Ao professor William de Paiva, pela orientação, incentivo, confiança, amizade; por ter me ensinado a importância da pesquisa e por acreditar que seria capaz de desenvolver esse trabalho.

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

A ONG Engenheiros Sem Fronteira e a todos os membros do núcleo de Campina Grande - PB, que me acolheram e ensinaram a desempenhar uma engenharia sustentável e humanizada. Especialmente a diretora geral Ana Aparecida Moreira Tavares, que me deu apoio em diversos aspectos da minha pesquisa.

Aos professores do Curso de Bacharelado em Engenharia Sanitária e Ambiental da UEPB, pela dedicação e conhecimento compartilhado, tornando-me um profissional preparado e ajudando a despertar todo o amor pela área, eles me orgulham em fazer parte desta Universidade.

Aos funcionários da UEPB, Adna de Alcantara e Souza Bandeira, Alisson De Albuquerque Egito e Déborah Denise dos Santos Silva, pela presteza e atendimento quando foi necessário.

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

Ao CNPq, pelo apoio financeiro.

A todos, muito obrigado.

## RESUMO

O manejo inadequado dos Resíduos Sólidos Urbanos (RSU) pode acarretar inúmeros problemas e transtornos socioeconômicos e ambientais, como por exemplo, doenças, enchentes e danos ao meio ambiente. Sendo, portanto, um grande problema ao poder público, que necessita investir cada vez mais para realizar o gerenciamento. Uma forma de auxiliar na gestão de qualquer tipo de resíduo é determinar a sua composição gravimétrica, porém esse processo possui alto custo e varia de acordo com as condições da população. Portanto, esse trabalho objetiva utilizar o Índice de Desenvolvimento Humano municipal (IDHm), para modelar, por meio de Redes Neurais Artificiais (RNA), dados quantitativos a respeito da composição de RSU em municípios. Para isso, foi necessário coletar dados nas bibliografias disponíveis sobre a composição gravimétrica e IDHm, tratá-los e construir um banco de dados, para em seguida treinar as redes neurais estudadas. O treinamento consistiu em fixar o tipo de rede (*Bayesian Regularization*) e alternar a quantidade de neurônios na camada oculta, o número de iterações do processo e o tipo de função de ativação, determinando assim qual rede se adaptou melhor aos dados. A RNA escolhida foi executada e comparada com dados de composição gravimétrica de 3 municípios: Campina Grande - PB, São Carlos - SP e Curitiba - PR. Com os resultados obtidos, verificou-se que a RNA teve boa performance quando executada, por isso, foi realizada a previsão da composição de RSU em relação a esses municípios para o ano de 2030. As principais características apresentadas foram a redução de geração de matéria orgânica e o aumento da quantidade de resíduos na categoria “outros”.

**Palavras-Chave:** Resíduo Sólido Urbano. Composição Gravimétrica. Redes Neurais Artificiais.

## **ABSTRACT**

The inadequate management of Solid Waste (SW) can lead to numerous socioeconomic and environmental problems and disorders, such as diseases, floods and damage to the environment. Therefore, it is a major problem for the government, which needs to invest more and more to carry out management. One way to assist in the management of any type of waste is to determine its gravimetric composition, but this process has a high cost and varies according to the conditions of the population. Therefore, this work aims to use the municipal Human Development Index (HDI), to model, using Artificial Neural Networks (ANN), quantitative data regarding the composition of MSW in municipalities. For this, it was necessary to collect data in the available bibliographies on gravimetric composition and HDI, treat them and build a database, and then train the studied neural networks. The training consisted of fixing the type of network (Bayesian Regularization) and alternating the number of neurons in the hidden layer, the number of iterations of the process and the type of activation function, thus determining which network best adapted to the data. The chosen ANN was performed and compared with gravimetric composition data from 3 cities: Campina Grande - PB, São Carlos - SP and Curitiba - PR. With the results obtained, it was found that the ANN had a good performance when performed, so it was made a prediction of the composition of MSW in relation to these municipalities for the year 2030. The main characteristics presented were the reduction of generation of matter and the increase in the amount of waste in the "other" category.

**Keywords:** Solid Waste. Gravimetric Composition. Neural Networks.



## LISTA DE ILUSTRAÇÕES

Figura 1 - Ensaio de gravimetria. a: retiradas da amostra; b: resíduos; c: pesagem do material .....	17
Figura 2 - Geração de RSU per capita.....	18
Figura 3 - Geração em toneladas de RSU anual em alguns países.....	19
Figura 4 - Composição gravimétrica média mundial .....	19
Figura 5 - Geração total de resíduos por região.....	20
Figura 6 - Destinação dos resíduos no Brasil.....	21
Figura 7 - Arquitetura de uma RNA.....	24
Figura 8 - Representação da Função Limiar.....	25
Figura 9 - Representação da função sigmoide.....	26
Figura 10 - Representação da função tangente hiperbólica.....	26
Figura 11 - Boxplot de composições gravimétricas .....	32
Figura 12 - Tempo de aprendizagem da função de ativação Tangente Hiperbólica.	35
Figura 13 - Tempo de aprendizagem da função de ativação Logística.....	35
Figura 14 - Gradiente de treinamento para a função de ativação Tangente Hiperbólica e para função Logística.....	36
Figura 15 - Gradiente de treinamento para a função de ativação Tangente Hiperbólica e para função Logística.....	37
Figura 16 - Interface do treinamento da rede selecionada.....	38
Figura 17 - Gráfico da performance na RNA escolhida.....	38
Figura 18 - Gráficos das regressões na RNA escolhida.....	39
Figura 19 - Localização do município de Campina Grande – PB.....	40
Figura 20 - Estimativas de RSU no município de Campina Grande - PB.....	40
Figura 21 - Localização do município de São Carlos - SP .....	41
Figura 22 - Estimativas de RSU no município de São Carlos – SP.....	42
Figura 23 - Localização do município de Curitiba - PR.....	43
Figura 24 - Estimativas de RSU no município de Curitiba - PR.....	43

## LISTA DE QUADROS

Quadro 1 - Classificação dos RSU.....	15
Quadro 2 - Recorte do banco de dados da pesquisa. ....	31
Quadro 2 - Classificação dos dados por região.....	33
Quadro 3 - Estatística descritiva das variáveis.....	34

## LISTA DE TABELAS

Tabela 1 - Análises descritivas realizadas. ....	28
Tabela 2 - Abreviações para o eixo horizontal. ....	30

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>11</b>
<b>2 OBJETIVOS</b> .....	<b>13</b>
<b>2.1 OBJETIVO GERAL</b> .....	<b>13</b>
<b>2.2 OBJETIVOS ESPECÍFICOS</b> .....	<b>13</b>
<b>3 FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>14</b>
<b>3.1 RESÍDUOS SÓLIDOS</b> .....	<b>14</b>
<b>3.1.1 Composição Gravimétrica</b> .....	<b>16</b>
<b>3.1.2 Panorama dos resíduos sólidos no mundo</b> .....	<b>17</b>
<b>3.1.3 Panorama dos resíduos sólidos no Brasil</b> .....	<b>20</b>
<b>3.2 ÍNDICES DE DESENVOLVIMENTO</b> .....	<b>22</b>
<b>3.3 REDES NEURAIS</b> .....	<b>23</b>
<b>3.3.1 Arquitetura da rede</b> .....	<b>24</b>
<b>3.3.2 Funções de ativação</b> .....	<b>25</b>
<b>4 METODOLOGIA</b> .....	<b>27</b>
<b>4.1 CONSTRUÇÃO DO BANCO DE DADOS</b> .....	<b>27</b>
<b>4.2 TRATAMENTO E MODELAGEM ESTATÍSTICA</b> .....	<b>27</b>
<b>4.3 CONSTRUÇÃO DA REDE NEURAL ARTIFICIAL E PREDIÇÃO DE COMPOSIÇÃO GRAVIMÉTRICA DE RESÍDUOS</b> .....	<b>28</b>
<b>5 RESULTADOS E DISCUSSÕES</b> .....	<b>30</b>
<b>5.1 COLETA E TRATAMENTO DE DADOS</b> .....	<b>30</b>
<b>5.2 ANÁLISE DA RNA</b> .....	<b>34</b>
<b>5.2.1 Tempo de execução</b> .....	<b>34</b>
<b>5.2.2 Performance e Gradiente</b> .....	<b>36</b>
<b>5.3 ESCOLHA DA RNA</b> .....	<b>37</b>
<b>5.4 VALIDAÇÃO DA RNA E PREVISÃO DE DADOS</b> .....	<b>39</b>
<b>5.4.1 Campina Grande</b> .....	<b>39</b>
<b>5.4.2 São Carlos</b> .....	<b>41</b>
<b>5.4.3 Curitiba</b> .....	<b>42</b>
<b>6. CONSIDERAÇÕES FINAIS</b> .....	<b>45</b>
<b>REFERÊNCIAS</b> .....	<b>47</b>
<b>ANEXO A – Banco de dados do projeto</b> .....	<b>51</b>

## 1 INTRODUÇÃO

O crescimento populacional e o avanço da industrialização proporcionaram aumento na geração de Resíduos Sólidos Urbanos (RSU). A gestão desses resíduos tem ao longo dos anos merecido atenção do Poder Público devido aos impactos ambientais negativos. A geração de resíduos, sua carga poluidora e formas inadequadas de disposição final, resultam em poluição dos solos, do ar atmosférico, e das águas superficiais e subterrâneas. Além disso, são relatadas graves consequências a saúde pública, como: proliferação de doenças transmitidas por vetores ou parasitas e, casos de óbitos (DE ALMEIDA et al., 2020).

O gerenciamento de RSU é uma atividade interdisciplinar que consiste em produção, coleta, transferência, processamento e destinação correta, para minimizar os impactos negativos ao meio ambiente e a saúde pública. Diante disso, a produção de resíduos em países em desenvolvimento é agravada devido a rápida urbanização, falta de investimento no setor de saneamento ambiental, tecnologias inadequadas e problemas de má gestão pública (DAS et al., 2019).

A gestão de resíduos é um assunto complexo que envolve componentes relativos à prevenção da produção dos resíduos, às políticas ambientais, à regulação e legislação aplicadas às atividades da gestão de resíduos. Além disso, uma boa parte dos investimentos são provenientes do poder público, fato que dificulta o gerenciamento dos resíduos (SILVA et. al, 2017).

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. Portanto, é possível estimar as propriedades de cada parcela de material e definir forma de tratamento e destinação adequada. Essa composição pode variar em função do nível educacional, hábitos, atividade econômica, clima e nível de desenvolvimento da região (BOSCOV, 2008).

O estudo gravimétrico dos RSU é uma importante ferramenta para gestão de resíduos e do aterro. Porém, essa técnica envolve custos de operação, mão de obra qualificada, utilização de Equipamentos de Proteção Individual (EPI) e ainda oferece riscos de contaminação a equipe responsável pela triagem dos resíduos. Portanto, pode-se considerar que o ambiente ao qual o ensaio está envolvido é insalubre, podendo prejudicar a saúde do grupo responsável.

Outro agravante para o ensaio de gravimetria é a dificuldade de quantificação devido a sua heterogeneidade e variação em função das diferenças geográficas, não existe amostradores e procedimentos de ensaios adequados para obtenção de amostras representativas (MATTEI e ESCOSTEGUY, 2007).

Uma alternativa de diminuir os custos e riscos associados ao ensaio da composição gravimétrica é a utilização de modelagem matemática, substituindo as análises físicas por numéricas. Uma alternativa é aplicar as Redes Neurais Artificiais (RNA) para correlacionar os índices de desenvolvimento com a composição gravimétrica dos RSU.

AS RNA são procedimentos inspirados no sistema de processamento de informação e aprendizagem para modelar matematicamente o funcionamento do cérebro humano. Assim, pode-se interpretar o funcionamento cerebral como um sistema de informação, não linear e complexo, tornando possível a o processamento de informações complexas (ALMEIDA et al., 2009).

O processo de aprendizagem de uma rede neural é fundamentado em aprender de acordo com um ambiente e assim melhorar seu desempenho. Elas se diferenciam pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado (HAYKIN, 2001).

Devido a esta problemática, viu-se necessário desenvolver uma metodologia eficiente e de baixo custo para determinação da composição gravimétrica dos resíduos sólidos em diferentes municípios, utilizando a modelagem a partir das RNA, mediante os cenários complexos de aprendizagem e caracterização de padrões, permitindo a simulação dos dados quantitativos de composição de RSU.

## 2 OBJETIVOS

### 2.1 OBJETIVO GERAL

Modelar, por meio de Redes Neurais Artificiais para testar e simular quantitativamente a composição gravimétrica e volumétrica, destacando uma solução baseada em métodos indiretos, de acordo com as características socioeconômicas de uma população.

### 2.2 OBJETIVOS ESPECÍFICOS

- Construir um banco de dados da composição gravimétrica de vários municípios brasileiros;
- Ajustar a arquitetura da Redes Neurais Artificiais em função da quantidade de neurônios na camada oculta e da quantidade de dados utilizados em seu treinamento;
- Validar a Redes Neurais Artificiais comparando os dados de saída com os dados reais disponíveis na literatura;
- Utilizar a Redes Neurais Artificiais para prever a composição gravimétrica e volumétrica dos RSU em municípios brasileiros.

### 3 FUNDAMENTAÇÃO TEÓRICA

#### 3.1 RESÍDUOS SÓLIDOS

A Política Nacional de Resíduos Sólidos (PNRS), estabelecida pela Lei nº 12.305 em 02 de agosto de 2010, propõe a prática de hábitos sustentáveis, a prevenção e redução na geração de resíduos, incentiva à reciclagem e a reutilização dos resíduos, além de estabelecer regras para a destinação final deles. Desse modo, os aterros sanitários surgem como uma alternativa de tratamento dos resíduos sólidos, visto que apresentam baixo custo e maior praticidade quando comparado às outras tecnologias. A PNRS também define resíduos sólidos em seu art. 3º, inciso XVI, como:

Resíduos sólidos: 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).

Portanto, os Resíduos Sólidos têm relação com aquilo que tem valor econômico e pode ser reciclado ou reaproveitado após o seu descarte. Ao contrário dos rejeitos, que são também um tipo de resíduo sólido, todavia não podem ser reciclados ou reutilizados posteriormente, ficando no descarte a única opção disponível (DE ALMEIDA et. al, 2020). Os rejeitos também são definidos na PNRS em seu art. 3º, inciso XV, como:

Rejeitos: resíduos sólidos que, depois de esgotadas todas as possibilidades de tratamento e recuperação por processos tecnológicos disponíveis e economicamente viáveis, não apresentem outra possibilidade que não a disposição final ambientalmente adequada (PNRS, 2017).

Os resíduos por sua vez, são classificados em diversos tipos, a depender de determinadas características ou propriedades identificadas. De acordo com a ABNT (2004) – NBR 10.004, os resíduos são classificados quanto a sua periculosidade, composição química e características físicas como mostrado na Quadro 1.



Quadro 1 - Classificação dos RSU.

Classificação		Definição
Periculosidade	Resíduos Classe I - Perigosos	Resíduos sólidos ou mistura de resíduos sólidos, que em função de suas características de inflamabilidade, toxicidade, corrosividade, reatividade e patogenicidade, podem provocar danos à saúde pública, através do aumento da mortalidade ou morbidade ou ainda provocar efeitos adversos ao meio ambiente, quando manuseados ou armazenados inadequadamente.
	Resíduos classe IIA - Não inertes	Resíduos sólidos ou mistura de resíduos sólidos que não se enquadram na classe I ou na classe IIB. Estes resíduos podem ter propriedades como: combustibilidade, biodegradabilidade ou solubilidade em água.
	Resíduos classe IIB - Inertes	Resíduos sólidos ou mistura de resíduos sólidos que, submetidos a um contato mecânico ou estático com água destilada não tenham nenhum de seus constituintes solubilizados em concentrações superiores aos padrões de potabilidade de águas, excetuando os padrões: cor, turbidez e sabor.
Química	Orgânicos	Originados principalmente da decomposição de plantas e animais, matéria orgânica, resíduos e esgotos domésticos, resíduos de podas e jardinagem, lodos de ETE, excrementos humanos e animais.
	Inorgânicos	Substâncias químicas minerais ou bioquímicas, relativamente estáveis ou capazes de alterar as condições físico-químicas
Física	Secos	Materiais recicláveis como, metais, papéis, plásticos e vidros.
	Úmidos	Resíduos de origem orgânica, como por exemplo, restos de alimentos e os resíduos provenientes de banheiros.

Fonte: ABNT - NBR 10004 (2004).

A PNRS (BRASIL, 2010) trouxe regulamentação para a gestão integrada de resíduos sólidos, apresentando alguns conceitos em seu artigo 3º que são bastante relevantes para a compreensão do tema. Definindo o gerenciamento de resíduos sólidos como o conjunto de ações exercidas direta ou indiretamente, nas etapas de coleta, transporte, transbordo, tratamento e destinação final ambientalmente correta dos resíduos sólidos, bem como a disposição final ambientalmente adequada de rejeitos de acordo com plano municipal de gestão integrada de resíduos sólidos ou com o plano de gerenciamento de resíduos sólidos.

A gestão de resíduos sólidos é um serviço que todo governo municipal fornece a seus residentes. E que, apesar dos níveis desse serviço, seus impactos e custos ambientais variarem dramaticamente entre municípios, o gerenciamento de resíduos sólidos é, sem dúvida, o serviço municipal mais importante e serve como pré-requisito para outras ações municipais (HOORNWEG e BHADA-TATA, 2012).

Portanto, a gestão de resíduos sólidos é a destinação final ambientalmente adequada dada a esses resíduos, de forma que diminua os impactos ao meio ambiente e promova o desenvolvimento sustentável. Além disso, é responsabilidade do município gerador do resíduo deve fornecer a destinação adequada ao mesmo, garantindo a qualidade de vida e a redução dos riscos à saúde da população e a contaminação do meio ambiente (LISBINSKI et. al, 2020).

### **3.1.1 Composição Gravimétrica**

O conhecimento da composição gravimétrica dos resíduos é indispensável nas fases de planejamento e operação nos serviços de limpeza pública, facilitando a identificação dos métodos e técnicas adequadas de tratamento e disposição final de acordo com cada realidade (STEINER, 2010). A dinâmica dos aterros sanitários é influenciada pelos constituintes dos RSU depositados, sua semelhança com as características reais dos componentes é aumentada de acordo com a quantidade de dados analisada (ARAUJO NETO, 2016).

A classificação gravimétrica (Figura 1) determina a porcentagem de cada constituinte da massa de resíduos sólidos, proporcionalmente ao seu peso. Uma das principais metodologias para caracterizar os resíduos é a exposta na NBR 10007: “Amostragem de resíduos sólidos” (ABNT, 2004). O processo de caracterização é realizado seguindo as seguintes etapas: coleta de material, homogeneização, quarteamento, separação dos componentes e pesagem de cada componente.

Figura 1 - Ensaio de gravimetria. a: retiradas da amostra; b: resíduos; c: pesagem do material



Fonte: Araújo Neto (2016).

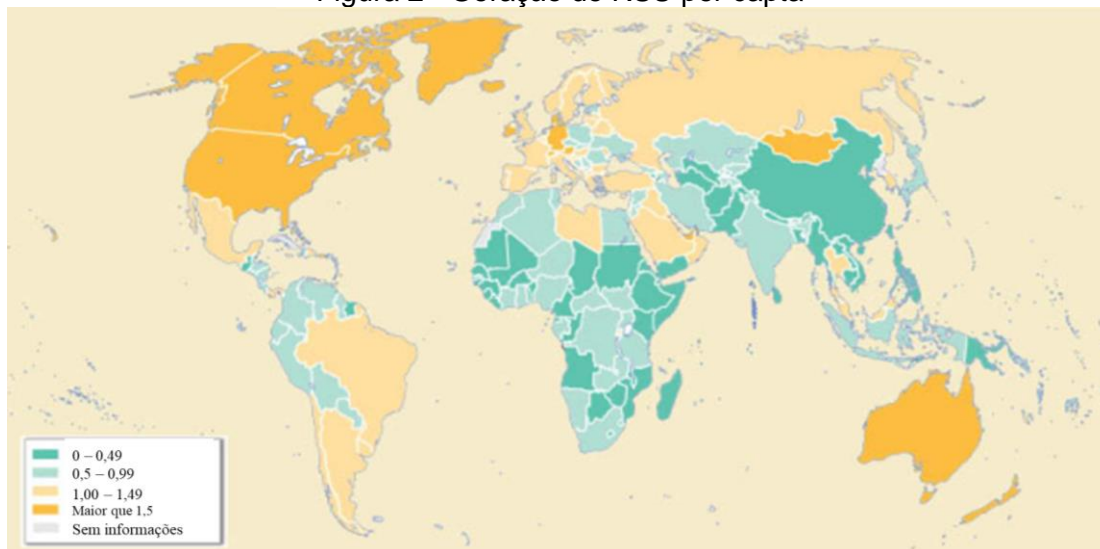
### 3.1.2 Panorama dos resíduos sólidos no mundo

A partir de estudos da geração de RSU nos países pertencentes a Organização para a Cooperação e Desenvolvimento Econômico (OECD), percebeu-se uma variação em questões como quantidade e composição dos RSU. Dentre os motivos desta variação estão: os níveis e padrões de consumo, as taxas de urbanização, os níveis de renda, tipos de estilo de vida e práticas nacionais de gerenciamento de resíduos. Apenas alguns países pertencentes ao grupo, como França, Hungria, Japão, Eslováquia e Espanha, conseguiram separar sua geração total de resíduo dos índices de desenvolvimento socioeconômico (OECD, 2020).

O grupo World Bank (2018), afirma que cerca de 2,01 bilhões de toneladas de RSU são produzidas anualmente, com pelo menos 33% sem gerenciamento ambientalmente adequado. Os países de alta renda, embora representem apenas 16% da população mundial, são responsáveis por 34% (aproximadamente 683 milhões de toneladas) da geração anual de resíduos sólidos. No mundo, a quantidade

média de resíduos produzido por pessoa é de 0,74 kg por dia, mas variam amplamente, de 0,11 a 4,54 kg (Figura 2).

Figura 2 - Geração de RSU per capita




Fonte: Adaptado World Bank (2018).

À medida que nações e cidades se tornam mais populosas e prósperas, oferecem mais produtos e serviços aos cidadãos de forma que elas enfrentam quantidades correspondentes de resíduos para gerenciar por meio de tratamento e descarte. Em todo o mundo, quase 40% dos resíduos são descartados em aterros sanitários, cerca de 19% são submetidos à recuperação de materiais por meio de reciclagem e compostagem e 11% são tratados por meio de incineração moderna. Embora globalmente 33% dos resíduos ainda sejam despejados de forma irregular, governos estão cada vez mais reconhecendo os riscos e custos de lixões e adotando métodos sustentáveis de disposição final (WORLD BANK, 2018).

Pode-se afirmar então que o PIB *per capita* nos países desenvolvidos está correlacionada com a alta geração de RSU. Por exemplo, nos EUA, o nível atual de geração de RSU é de cerca de 258 milhões de toneladas anuais, seguido pela Alemanha com 51 milhões de toneladas e Japão com 44 milhões de toneladas (Figura 3). A situação não é melhor nas economias em rápido desenvolvimento. A China sempre está disputando o topo da lista com os Estados Unidos e, de fato, a geração de RSU atingiu 220,4 milhões de toneladas de resíduos em 2015 (JI et al., 2016).


Figura 3 - Geração em toneladas de RSU anual em alguns países



Fonte: Adaptado World Bank (2018).

A hierarquia da gestão de RSU é a mesma internacionalmente, redução na fonte, reutilização, reciclagem e compostagem, recuperação e incineração de resíduos e descarte em aterro nessa ordem. No entanto, o status atual dos métodos de gerenciamento de RSU varia de país para país. Outra característica que varia é a composição física dos resíduos, em nível mundial percebe-se que a maior quantidade de resíduo gerado é a matéria orgânica, atingindo quase metade da geração (Figura 4).

Figura 4 - Composição gravimétrica média mundial



Fonte: Adaptado World Bank (2018).


Nas últimas décadas acentuaram-se as preocupações dos líderes mundiais a respeito da preservação ambiental e foram feitos encontros que estabeleceram metas

e objetivos para o desenvolvimento sustentável. No encontro mais recente ocorreu a elaboração da Agenda 2030 que elenca, em seus 17 Objetivos de Desenvolvimento Sustentáveis (ODS), problemas concretos e complexos que precisam ser solucionados por toda a sociedade global a fim de garantir a sobrevivência da humanidade (GT AGENDA 2030, 2018).

### 3.1.3 Panorama dos resíduos sólidos no Brasil

O cenário de gestão de RSU no Brasil está passando por mudanças nos últimos anos, sobretudo após a aprovação da Política Nacional de Resíduos Sólidos, instituída pela Lei Federal nº 12.305, de 02 de agosto de 2010 (BRASIL, 2010). Nela, estão estabelecidas as diretrizes relativas à gestão integrada e ao gerenciamento de resíduos sólidos, as responsabilidades dos geradores e do poder público e os instrumentos econômicos aplicáveis, tendo assimilado conceitos vigentes em países desenvolvidos, particularmente na Europa (MANNARINO, 2016).


Mesmo com as evoluções na legislação, o Brasil ainda é um grande gerador de resíduos. A ABRELPE (2019) estimou que, em 2018, foram geradas no Brasil 79 milhões de toneladas, sendo coletados um montante de 72,7 milhões (Figura 5). A quantidade média de resíduo produzido *per capita* gira em torno de 1,035 kg por dia (dependendo da classe social de cada indivíduo).



Fonte: Adaptado ABRELPE (2019).

Desse valor coletado, cerca de 59,5% teve destinação adequada em aterros sanitários, esses dados expõem um avanço em relação a 2017. Contudo, o país ainda vivenciou uma situação desconfortante onde 3001 municípios destinaram incorretamente seus resíduos, ou seja, cerca de 29,5 milhões de toneladas de resíduo foram descartados em lixões e aterros controlados (Figura 6) (ABRELPE, 2019).

Figura 6 - Destinação dos resíduos no Brasil.



Fonte: Adaptado ABRELPE (2019).

A alta geração de resíduos deve ser controlada adotando medidas de gerenciamento e gestão. A PNRS define e diferencia esses dois termos em seu artigo 3º, como:

X - gerenciamento de resíduos sólidos: conjunto de ações exercidas, direta ou indiretamente, nas etapas de coleta, transporte, transbordo, tratamento e destinação final ambientalmente adequada dos resíduos sólidos e disposição final ambientalmente adequada dos rejeitos, de acordo com plano municipal de gestão integrada de resíduos sólidos ou com plano de gerenciamento de resíduos sólidos, exigidos na forma desta Lei;

XI - gestão de resíduos sólidos: conjunto de ações voltadas para a busca de soluções para os resíduos sólidos, de forma a considerar as dimensões política, econômica, ambiental, cultural e social, com controle social e sob a premissa do desenvolvimento sustentável.

Uma ferramenta que auxilia na gestão dos resíduos brasileiros é o Sistema Nacional de Informações sobre Saneamento (SNIS). A partir desses dados são

gerados diagnósticos sobre serviços de água e esgotos, manejo de resíduos sólidos urbanos e drenagem e manejo de águas pluviais. O diagnóstico gerado sobre resíduos sólidos destaca os dados permitindo identificar o comportamento dos serviços de limpeza urbana e manejo de resíduos sólidos nos municípios brasileiros, a partir das informações prestadas, indicadores e estimativas calculadas (BRASIL, 2019).

Os serviços de limpeza urbana geram custo ao poder público. Estima-se que em 2018, os municípios aplicaram mensalmente, em média, R\$ 10,15 por habitante, movimentando cerca de R\$ 28,1 bilhões de reais (ABRELPE, 2019).

Apesar do investimento, muitos municípios ainda precisam resolver problemas básicos na gestão de resíduos sólidos, como melhora na eficiência de coleta, implantação de coleta seletiva e instalação de aterros sanitários (MANNARINO et al., 2016).

### 3.2 ÍNDICES DE DESENVOLVIMENTO

Para a caracterização geral de aspectos econômicos e/ou sociais nacionais por município (“socioeconômicos”) existem os dados levantados pelo Instituto Brasileiro de Geografia e Estatística (IBGE) a partir do Censo Demográfico sobre rendimento nominal médio mensal por domicílio, percentual de domicílios com rendas médias extremas, Produto Interno Bruto *per capita* (PIBpc), a contribuição dos setores da agropecuária, indústria, de serviços e impostos; o Índice de Desenvolvimento Humano Municipal (IDHM) e seus componentes de longevidade, educacional e de renda, além de condições de saneamento básico (LANDAU & MOURA, 2020).

Na sua formulação clássica, o IDH é composto por três indicadores, que representam a oportunidade de uma sociedade de ter vidas longas e saudáveis, de ter acesso a conhecimento, e de ter comando sobre os recursos de forma a garantir um padrão de vida digno. O IDHm é uma medida composta de indicadores de três dimensões do desenvolvimento humano: longevidade, educação e renda. O índice varia de 0 a 1. Quanto mais próximo de 1, maior o desenvolvimento humano. O IDHm brasileiro segue as mesmas três dimensões do IDH Global - longevidade, educação e renda, mas vai além: adequa a metodologia global ao contexto brasileiro e à disponibilidade de indicadores nacionais (PNUD, 2013).

Diversos estudos sobre saneamento básico, correlacionam a renda e o PIB de uma determinada região com a composição dos resíduos sólidos urbanos, a



diversidade de aspectos socioculturais e ambientais do país traz diferenciações na composição dos resíduos. Portanto, pode-se afirmar que o grau de desenvolvimento social e econômico, representado pelo IDH, propicia a diferenciação na composição gravimétrica observada em diferentes países e cidades (SÃO MATEUS et. al, 2019).

### 3.3 REDES NEURAS

A Modelagem Matemática consiste na arte de transformar problemas da realidade em problemas matemáticos e resolvê-los interpretando suas soluções na linguagem do mundo real. O que tem se mostrado eficaz tanto para dar significado aos conteúdos matemáticos trabalhados como para a construção do conhecimento matemático em si, podendo ser utilizada tanto como um método científico de pesquisa quanto como uma estratégia de ensino-aprendizagem (BASSANEZI, 2006).

RNAs são procedimentos inspirados no sistema de processamento de informação e aprendizagem, para modelar matematicamente o funcionamento do cérebro humano. Assim, pode-se interpretar o funcionamento cerebral como um sistema de informação, não linear e complexo, tornando possível a o processamento de informações complexas (FREITAS et. al, 2013).

O processo de aprendizagem de uma rede neural é fundamentado em aprender de acordo com um ambiente e assim melhorar seu desempenho. Elas se diferenciam pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado. A arquitetura de uma rede neural restringe o tipo de problema no qual a rede poderá ser utilizada, e é definida pelo número de camadas, pelo número de nós em cada camada, pelo tipo de conexão entre os nós e por sua topologia (HAYKIN, 2001).

Existem duas formas básicas de aprendizado de redes neurais: aprendizado supervisionado e aprendizado não supervisionado. No aprendizado supervisionado, um agente externo apresenta à rede neural alguns conjuntos de padrões de entrada e seus correspondentes padrões de saída. A resposta fornecida pela rede neural é comparada à resposta esperada. O erro verificado é informado à rede para que sejam feitos ajustes a fim de melhorar suas futuras respostas (HAYKIN, 2001).

Já na aprendizagem não supervisionada, não existe um agente externo para acompanhar o processo de aprendizado. Neste tipo de aprendizagem, somente os padrões de entrada estão disponíveis para a rede neural. A rede processa as entradas


e, detectando suas regularidades, tenta progressivamente estabelecer representações internas para codificar características e classificá-las automaticamente (SANTOS e FARIAS, 2019).

### 3.3.1 Arquitetura da rede

Em termos de topologia, para implementar uma RNA deve-se definir diferentes variáveis, dentre as quais: a) o número de nós na camada de entrada (tal variável corresponde ao número de variáveis que serão usadas para alimentar a rede neural, sendo normalmente as variáveis de maior importância para o problema em estudo); b) o número de camadas escondidas e o número de neurônios a serem colocados nessas camadas e; c) o número de neurônios na camada de saída (SANTOS et al., 2005).

Uma forma simplificada de funcionamento de uma RNA é a esquematização expostas na Figura 7. Geralmente, um sinal é recebido pela camada de entrada. Passando, em seguida, por uma camada oculta onde o sinal é multiplicado por um peso e após a soma ponderada dos sinais tratados nesta camada, o sistema produz uma saída, baseada da extrapolação de um limite (HAYKIN, 2001).

Figura 7 - Arquitetura de uma RNA.



Fonte: Adaptado Haykin (2001).

As RNAs do tipo *feedforward* são ferramentas eficazes para controle de sistemas e modelamento. Ela possui características não-lineares quanto ao

mapeamento entre as camadas. Apesar da eficiência, esta abordagem não retrata a realidade dos sistemas físicos. Devido à capacidade de modelar com fidelidade ações não lineares, as RNAs se constituem uma importante ferramenta para o controle de sistemas (BRAGA et. al, 2000).

O treinamento utilizando o algoritmo de *backpropagation* é dividido em duas fases. Nesse treinamento um padrão é apresentado à camada de entrada da rede, processado e levado até a camada de saída. Em seguida, a saída obtida é comparada à saída desejada para esse padrão apresentado. Assim, se a saída for diferente do esperado, o erro é calculado e enviado até a camada de entrada, atualizando os pesos das conexões sinápticas, causando a retropropagação (ARAÚJO e BANDEIRA, 2019).


### 3.3.2 Funções de ativação

A função de ativação é representada por  $\varphi(v)$ , ela define a saída do neurônio em termos do campo local induzido (HAYKIN, 2001). A seguir, serão mostrados três tipos de função de ativação:

- Função de Limiar: também conhecida como função degrau é representada na Equação 1 e na Figura 8.

$$Y = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (1)$$

Figura 8 - Representação da Função Limiar.




Fonte: Haykin (2001).

- Função Sigmóide: Apresenta um gráfico no formato de S, é a forma mais comum de função de ativação. Ela exibe um balanceamento entre a função linear e a não-linear. Um exemplo desse tipo é a função logística, representada na Equação 2 e Figura 9.

$$\varphi(v) = \frac{1}{1 + e^{(-\alpha v)}} \quad (2)$$

Figura 9 - Representação da função sigmoide.




Fonte: Haykin (2001).

- Função tangente hiperbólica: O resultado de saída sempre assumirá valores reais entre -1 e 1, representada pela Equação 3 e Figura 10.

$$\varphi(v) = \frac{1 - e^{(-\alpha v)}}{1 + e^{(-\alpha v)}} \quad (3)$$

Figura 10 - Representação da função tangente hiperbólica.



Fonte: Araújo & Bandeira (2019).

## 4 METODOLOGIA

Essa pesquisa está associada ao Grupo de Pesquisa em Tecnologia Ambiental (GPTecA) da Universidade Estadual da Paraíba.

### 4.1 CONSTRUÇÃO DO BANCO DE DADOS

Inicialmente foi realizado um levantamento bibliográfico contendo o máximo de dados sobre a composição gravimétrica dos RSU em diversos municípios do Brasil, focando-se em 6 categorias de resíduos (Papel/Papelão, Plástico, Metal, Vidro, Matéria Orgânica e Outros). Os maiores fornecedores de dados para a pesquisa foram os Planos Estaduais de Resíduos Sólidos (PERS), seguidos de produções científicas englobando composição de RSU em municípios brasileiros. Em seguida, para cada município foi pesquisado o IDHm para os anos de 1991, 2000 e 2010.

Os dados foram tabulados no software *Microsoft Excel 365* e sofreram pré-tratamento eliminando dados que apresentaram inconsistências. Após essa verificação inicial, as informações passaram por tratamento estatístico.

### 4.2 TRATAMENTO E MODELAGEM ESTATÍSTICA

Todas as análises desta etapa foram realizadas utilizando o software *Microsoft Excel 365*. Com o intuito de obter melhor performance, foi realizada a análise descritiva dos dados de composição de RSU e de IDHm de acordo com a Tabela 1. Posteriormente, foi gerado o *boxplot* do conjunto de dados com o objetivo de identificar os *outliers*, que estes foram removidos da série de dados.

Tabela 1 - Análises descritivas realizadas.

Conjunto de dados	Análises realizadas
Papel	
Plástico	Amplitude, valor mínimo, valor
Metal	máximo, média, moda, mediana,
Vidro	verificação de 1º e 3º quartis,
Matéria Orgânica	variância, desvio padrão e
Outros	coeficiente de variação.
IDHm	

Fonte: Autor (2020).

Por causa da grande variação dos anos em que foram coletados dados a respeito da composição gravimétrica de resíduos nos municípios e da limitação da quantidade de anos do IDHm, viu-se necessário determinar o IDHm para anos diferentes dos disponibilizados pelos Censos. Para isso, utilizou-se modelagem estatística a partir de regressão logarítmica (Equação 4).

$$Y = \alpha + \beta \cdot \ln(x) \quad (4)$$

Onde:

Y: variável dependente (IDHm);

$\alpha$ : constante de regressão sendo correspondente ao ponto onde a reta de regressão intercepta o eixo y;

$\beta$ : coeficiente de regressão, isto é, representa a variação de Y em função da variação de uma unidade da variável X;

X: variável independente (ano estudado).

#### 4.3 CONSTRUÇÃO DA REDE NEURAL ARTIFICIAL E PREDIÇÃO DE COMPOSIÇÃO GRAVIMÉTRICA DE RESÍDUOS

O software utilizado para desenvolvimento da rede neural foi o *Matlab R2018a*. O MATLAB® combina um ambiente ajustado para análise iterativa e processos de design com uma linguagem de programação que expressa diretamente a matriz. Ele

inclui um editor de scripts que combinam código, saída e texto formatado em um bloco de anotações executável (Mathworks, 2020).

Os dados de entrada (*input*) da RNA correspondem aos índices de desenvolvimento humano municipal (IDHm). Os dados relacionados as camadas de saída (*target*) foram os dados de composição gravimétrica de RSU.

Após construir o banco de dados, contendo as fontes de entrada e saída da RNA, foi necessário definir o modelo mais adequado para o processamento desses dados. Para isto, utilizou-se a ferramenta *nntool*, uma interface que permite treinar redes neurais a partir do próprio *software*.

Através dessa ferramenta foram realizados diversos treinamentos, fixando o algoritmo como *Byesian Regularization*, que geralmente requer mais tempo de processamento, mas pode resultar em boa generalização para conjuntos de dados difíceis, pequenos ou ruidosos. E alternando a quantidade de iterações (50, 500 e 1000), o número de neurônios na camada oculta (3, 4, 10, 20, 30, 50 e 100) e o tipo de função de ativação (Função Logística e Função Tangente Hiperbólica).

Depois dessa análise, foi verificada qual arquitetura de rede neural disponibilizou os melhores resultados. Com o modelo pronto, realizou-se a confrontação dos dados experimentais de composição gravimétrica obtidos no *Matlab* com os dados reais disponíveis nas bibliografias, comprovando assim a diferença mínima entre o método experimental e as análises reais. Com a RNA também foi possível analisar a composição de RSU para municípios brasileiros, focando o município de Campina Grande no tempo atual e realizar previsões para anos futuros.

## 5 RESULTADOS E DISCUSSÕES

Para compreensão de alguns termos de nomenclatura da RNA confeccionada no *software* e das Figuras 14 e 15 neste tópico, é necessário analisar a Tabela 2.

Tabela 2 - Abreviações para o eixo horizontal.

<b>Eixo Horizontal</b>	<b>Iterações</b>	<b>Quant. Neurônios</b>	<b>Nomenclatura</b>
1	50		
2	500	3	n1
3	1000		
4	50		
5	500	4	n2
6	1000		
7	50		
8	500	10	n3
9	1000		
10	50		
11	500	20	n4
12	1000		
13	50		
14	500	30	n5
15	1000		
16	50		
17	500	50	n6
18	1000		
19	50		
20	500	100	n7
21	1000		

Fonte: Autor (2020).

### 5.1 COLETA E TRATAMENTO DE DADOS

A pesquisa bibliográfica resultou na tabulação de dados sobre RSU de 213 municípios brasileiros (ANEXO A). Porém, no Quadro 2 é possível ver um pequeno recorte do banco de dados.

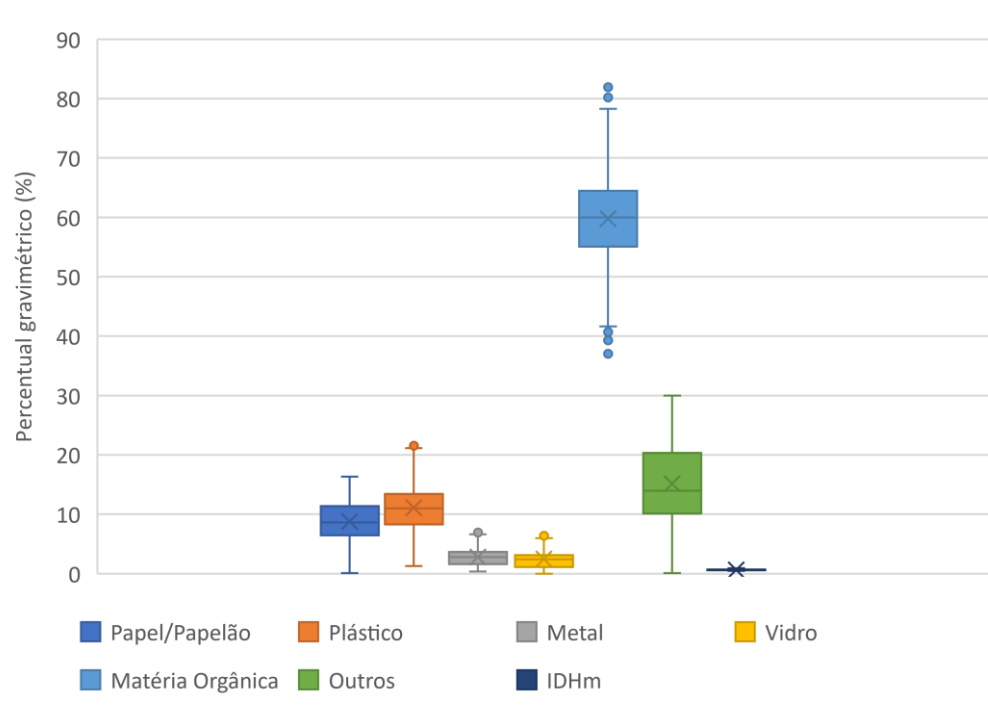


Quadro 2 - Recorte do banco de dados da pesquisa.

Município	UF	Composição do resíduo (%)						IDHm	Fonte
		Papel	Plástico	Metal	Vidro	Matéria Orgânica	Outros		
Apuí	AM	8.60	13.30	4.10	2.50	58.50	13.00	0.659	SEMA (2015)
Aracaju	SE	16.06	4.32	1.97	1.82	50.60	25.23	0.757	EMSURB (2009)
Belo Horizonte	MG	11.41	11.71	2.64	2.50	67.51	4.23	0.666	Mercedes (1998)
Botucatu	SP	8.43	8.37	3.85	1.99	74.11	3.25	0.665	Oliveira et. al (1998)
Bragança	PA	6.55	21.12	3.54	6.36	37.05	25.39	0.716	Silva et. al (2018)
Cabedelo	PB	6.60	6.80	1.30	1.40	66.40	17.50	0.544	Filho et. al (1998)
Caruaru	PE	10.30	5.40	0.70	5.50	78.00	0.10	0.672	SEMAS (2012)
Caxias do Sul	RS	8.00	6.60	2.90	1.30	58.80	22.40	0.641	Pessin & Silva (1991)
Fortaleza	CE	14.20	15.70	3.30	2.10	47.50	17.20	0.756	Barreto et. al (2015)
Hidrolândia	GO	7.94	12.49	0.97	2.92	63.54	12.14	0.709	Oliveira et. al (2019)
Itacoatiara	AM	15.05	17.85	2.31	1.14	51.32	12.33	0.746	Guimarães (2019)
Ji-Paraná	RO	12.00	7.50	2.20	2.00	66.70	9.60	0.728	Dos Santos (2011)
Juiz de fora	MG	8.75	7.18	2.48	2.63	69.36	9.60	0.611	Azevedo et. al (1998)
Melgaço	MT	7.15	6.24	3.55	3.04	66.06	13.96	0.484	De Campos et. al (2016)
Petrolina	PE	7.00	19.00	3.00	3.00	48.00	20.00	0.698	SEMAS (2012)
Porto Alegre	RS	16.10	11.10	2.60	2.50	52.50	15.20	0.711	Costa (1998)
Rubiácea	SP	6.90	17.10	2.80	1.30	44.90	27.00	0.808	Lima et. al (2018)
São José da Laje	AL	6.96	4.90	4.29	2.32	64.11	17.42	0.549	SEMARH apud Silva (2011)
São Leopoldo	RS	13.30	12.30	1.52	1.72	58.65	12.51	0.766	PROSINOS (2012)
Vitória	ES	11.67	6.86	2.79	1.77	63.43	13.48	0.672	Baptista (1993)

Fonte: Autor (2020).

Esses dados passaram por pré-tratamento estatístico, utilizando um gráfico do tipo *boxplot* (Figura 11), a fim de identificar e remover dados apresentados como *outliers*.

Figura 11 - *Boxplot* de composições gravimétricas

Fonte: Autor (2020).

A partir do *boxplot* na Figura 11 foi possível fazer a remoção de *Outliers* e valores extremos. Esses, são valores individuais atípicos ou aberrantes os quais podem ser causados por erros de coleta de dados, incluindo erros de introdução de dados. É importante ressaltar que os *outliers*, pontos marcados acima do limite superior e abaixo do limite inferior, foram identificados e removidos nas categorias Plástico, Metal, Vidro e Matéria Orgânica. Enquanto, algumas categorias não apresentaram *outliers*.

Um outro fator analisado foi a quantidade de dados por região geográfica no Brasil como apresenta-se no Quadro 2.

Quadro 3 - Classificação dos dados por região.

<b>Região</b>	<b>Quantidade de municípios (Dados brutos)</b>	<b>Quantidade de municípios (Após remoção de <i>outliers</i>)</b>
Norte	6	6
Nordeste	156	98
Centro-Oeste	26	18
Sudeste	11	10
Sul	14	14
Total	213	146

Fonte: Autor (2020).

A partir desta análise foi possível perceber que a região Nordeste tem um grande acervo bibliográfico sobre gestão, controle e análise de RSU quando comparado a outras regiões, apresentando cerca de 83% a mais de dados do que a região Centro-Oeste que ficou na segunda colocação quanto a acervo disponível.

Já a região Norte apresentou a menor quantidade de bibliografia na área, isso pode ser causado pelo déficit que a gestão de resíduos sólidos sofre na região. Oliveira e Medeiros (2019) afirmam que o Norte do país teve grandes avanços após o surgimento da PNRS, mesmo assim o setor de gerenciamento de RSU ainda está em emergência.

Após o pré-tratamento e a formação do banco de dados foi realizada a estatística descritiva para cada grupo de amostra, os resultados estão expressos no Quadro 3.

Quadro 4 - Estatística descritiva das variáveis.

Estatística	Grupo Amostrado						
	Papel	Plástico	Metal	Vidro	Matéria Orgânica	Outros	IDHm
Amostras	146	146	146	146	146	146	146
Maior Valor	16.320	21.520	6.900	7.000	81.940	30.000	0.894
Menor Valor	1.650	1.270	0.360	0.000	37.000	0.100	0.484
Amplitude	14.670	20.250	6.540	7.000	44.940	29.900	0.410
Média	8.734	11.133	2.695	2.439	60.216	14.784	0.641
Moda	12.000	7.500	1.000	2.500	61.000	9.090	-
Mediana	8.410	10.790	2.727	2.370	60.350	13.645	0.614
1º Quartil	6.250	8.230	1.505	1.248	56.165	9.600	0.566
3º Quartil	11.428	13.460	3.548	3.038	65.285	19.375	0.714
Variância	11.946	15.657	2.054	2.419	77.153	53.656	0.009
Desvio Padrão	3.456	3.957	1.433	1.555	8.784	7.325	0.096
Coefficiente de Variação	39.572	35.543	53.184	63.779	14.587	49.548	14.967

Fonte: Autor (2020)

Os dados sofrem dispersão dependendo do valor do coeficiente de variação (CV). Até 15% tem pequena variabilidade, entre 15 e 30% média e quando supera 30% tem alta dispersão. Os dados do Quadro 5 mostram que as variáveis de Matéria Orgânica e IDHm apresentam baixa dispersão, enquanto os outros grupos de dados apresentam alta dispersão (PAIVA, 2009).

## 5.2 ANÁLISE DA RNA

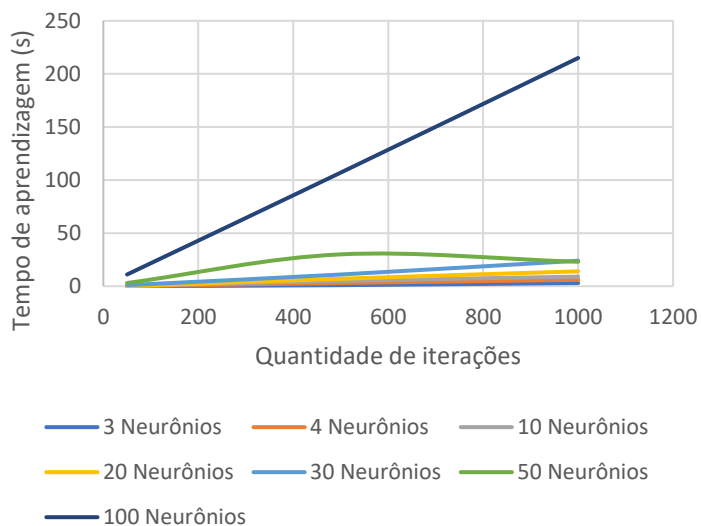
O treinamento da rede neural revelou o tempo de execução, a performance, o gradiente e o parâmetro de ajuste de *Levenberg-Marquardt* ( $\mu$ ). Onde este último é utilizado na execução do algoritmo *bayesian regularization*. Os resultados expressos para cada rede estão expressos nos tópicos a seguir.

### 5.2.1 Tempo de execução

Embora a variável tempo não seja um fator limitante para obtenção da melhor rede, é importante avaliá-las quanto ao tempo pela viabilidade de reprodução do algoritmo. Portanto, a partir das Figuras 12 e 13, pode-se observar que o aumento no

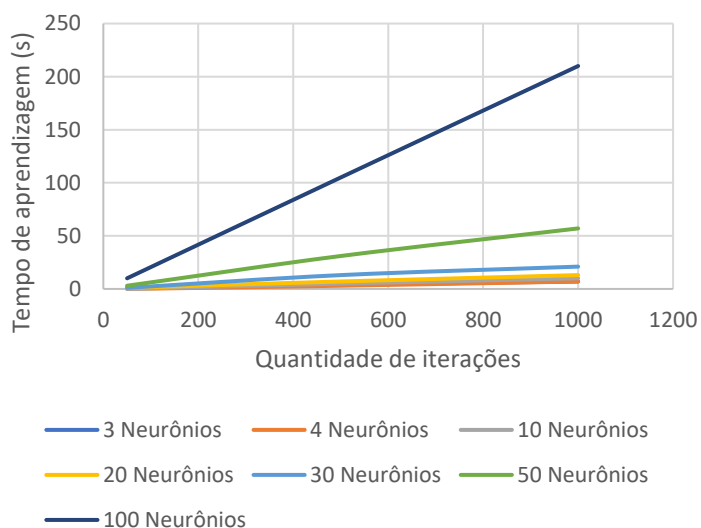
número de neurônios da camada oculta e a quantidade de iterações interferem diretamente no tempo de execução da RNA.

Figura 12 - Tempo de aprendizagem da função de ativação Tangente Hiperbólica.



Fonte: Autor (2020).

Figura 13 - Tempo de aprendizagem da função de ativação Logística.



Fonte: Autor (2020).

Nota-se que, ainda na Figura 13, a função de ativação Tangente hiperbólica apresentou em média um menor tempo de execução. Porém, o tempo de 215 segundos, considerado o maior exigido no processamento, foi atingido na rede n7\_1000 (TANSIN), criada com 100 neurônios na camada oculta, utilizando a função Tangente hiperbólica e com 1000 processos de iterações. Uma rede quase idêntica

em questões de tempo de processamento foi a n7\_1000 (LOGSIN), que marcou 210 segundos e foi construída com as mesmas configurações da rede n7\_1000 (TANSIN).

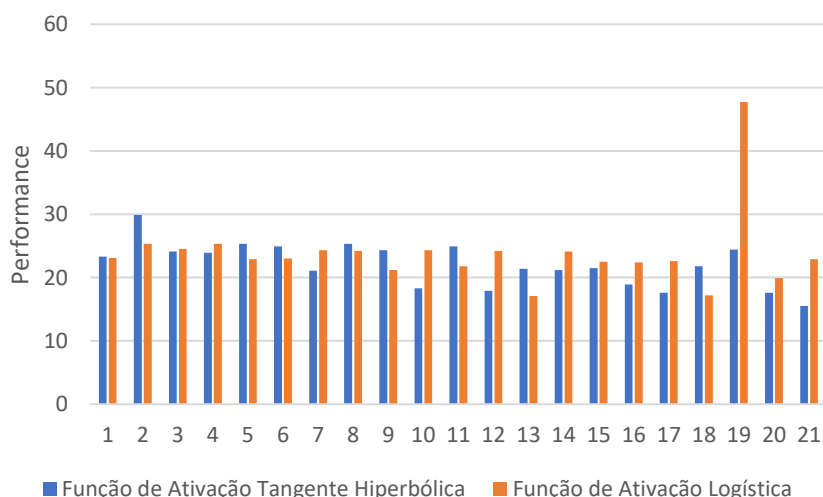
Martins et al. (2007), através de um estudo classificando texturas com RNA, observaram que, com o aumento do número de neurônios, o tempo para treinamento da rede aumenta, devido ao maior número de atualizações sinápticas. Esses resultados estão em concordância com os valores obtidos nas Figuras 12 e 13.

### 5.2.2 Performance e Gradiente

A regularização modifica a função de performance adicionando um termo que consiste na média da soma dos quadrados dos pesos e desvios da rede. No entanto, o problema com a regularização é que é difícil determinar o valor ideal para o parâmetro da taxa de performance, por isso é desejável determinar automaticamente os parâmetros ideais de regularização. O conjunto de treinamento é usado para calcular o gradiente e atualizar os pesos e desvios da rede. O erro no conjunto de validação é monitorado durante o processo de treinamento. (NEGOITA et. al, 2018).

Apresenta-se na Figura 14 demonstrando a performance de cada rede treinada em relação ao número de iterações e a quantidade de neurônios na camada oculta.

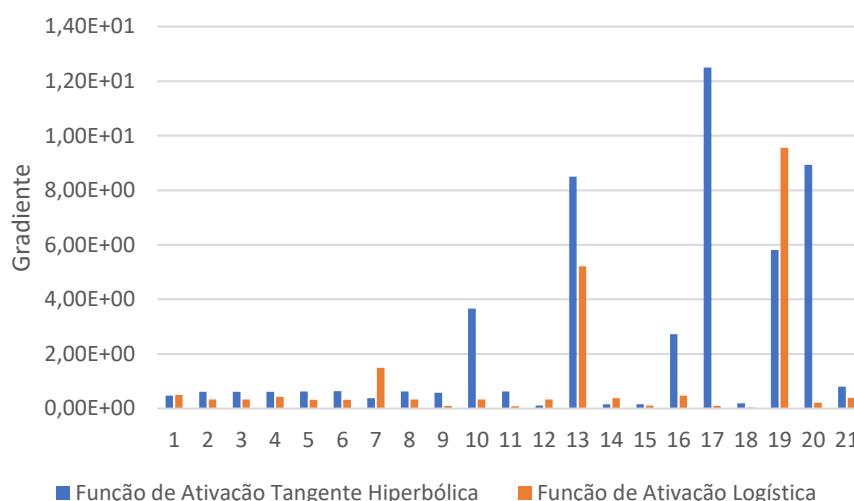
Figura 14 - Gradiente de treinamento para a função de ativação Tangente Hiperbólica e para função Logística.



Fonte: Autor (2020).

O gradiente é um critério de parada no treinamento de uma RNA e mostrado na Figura 15 para cada rede treinada em relação ao número de iterações e a quantidade de neurônios na camada oculta.

Figura 15 - Gradiente de treinamento para a função de ativação Tangente Hiperbólica e para função Logística.



Fonte: Autor (2020).

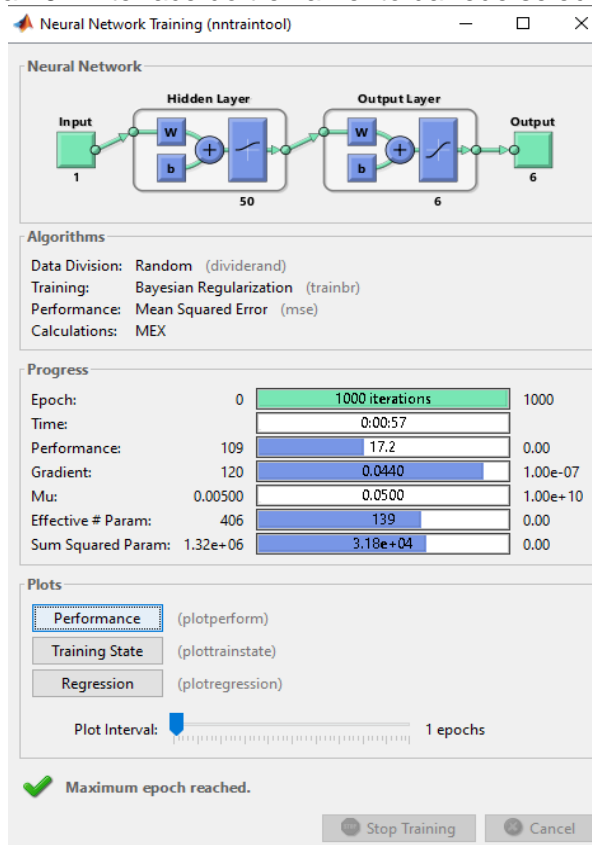
Quando o erro de validação aumenta para um determinado número de iterações, o treinamento é interrompido e os pesos e desvios no mínimo do erro de validação são retornados (NEGOITA et. al, 2018). Portanto, o erro do conjunto de testes não é usado durante o treinamento, mas é utilizado como uma verificação adicional de que a rede generaliza bem e compara diferentes modelos de RNA.

A RNA treinada pode então ter seu desempenho avaliado em função do gradiente e da performance (Figuras 14 e 15). As melhores redes que generalizaram o conjunto de dados sobre RSU foram as redes denominadas no treinamento n7\_1000 (TANSIN) e n6\_1000 (LOGSIN), sendo a última a mais bem avaliada.

### 5.3 ESCOLHA DA RNA

A partir da análise dos dados sobre as RNAs treinadas, foi possível determinar a RNA com melhor desempenho entre todas as outras, sendo escolhida a RNA denominada n6\_1000 (LOGSIN). Essa rede teve em seu treinamento 50 neurônios na camada oculta, utilizando-se a função de ativação logística, 1000 iterações para conversão, gradiente de 0,044 e tempo de treinamento de 57 segundos (Figura 16).


Figura 16 - Interface do treinamento da rede selecionada.



Fonte: Autor (2020).

A ferramenta *nntool* ainda permite realizar a plotagem dos dados de performance, status de treinamento e regressão para cada rede treinada. Os gráficos da RNA escolhida estão representados consecutivamente nas Figuras 17 e 18.

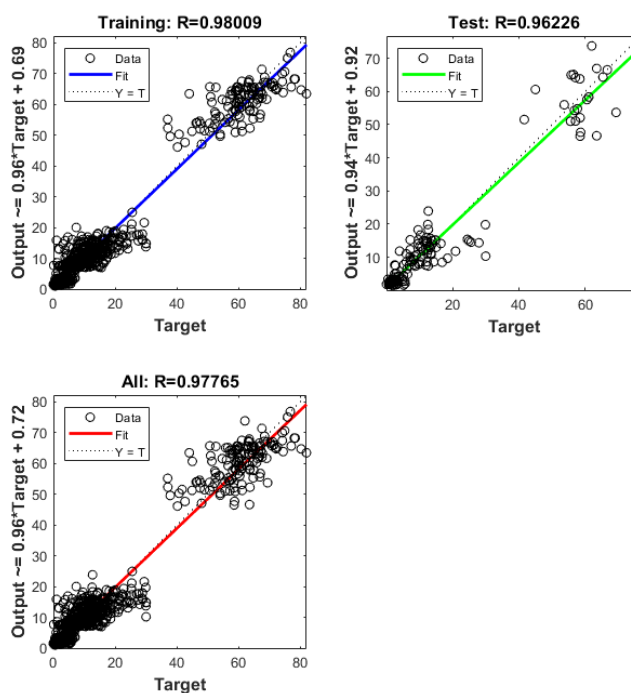
Figura 17 - Gráfico da performance na RNA escolhida



Fonte: Autor (2020).



Figura 18 - Gráficos das regressões na RNA escolhida



Fonte: Autor (2020).

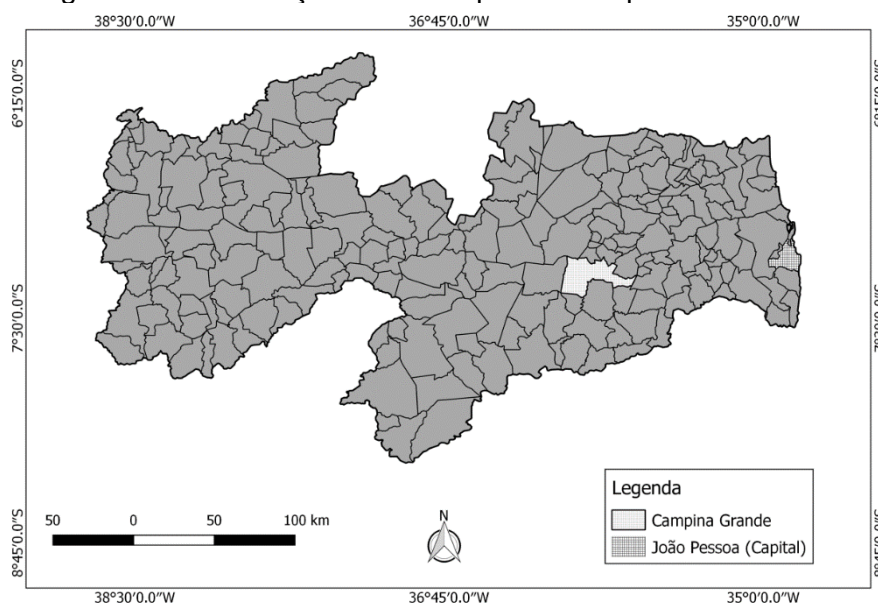
## 5.4 VALIDAÇÃO DA RNA E PREVISÃO DE DADOS

A RNA foi então validada a partir de dados sobre três municípios, Campina Grande - PB, São Carlos - SP e Curitiba - PR sendo realizada uma projeção sobre a situação dos resíduos para o ano de 2030.

### 5.4.1 Campina Grande

Campina Grande é uma cidade localizada no interior do estado da Paraíba. Com 49 bairros e 5 distritos, a cidade tem uma população de 385.213 habitantes, área total por volta de 621 km<sup>2</sup> e área urbana de, aproximadamente, 96 km<sup>2</sup>. Segundo projeções a população estimada para o município de Campina Grande no ano de 2018 é de 407.472 habitantes (IBGE, 2020). A cidade é considerada como um dos principais polos tecnológicos do interior do Nordeste e responsável pelo desenvolvimento dos municípios em localizados ao seu redor (Figura 19).

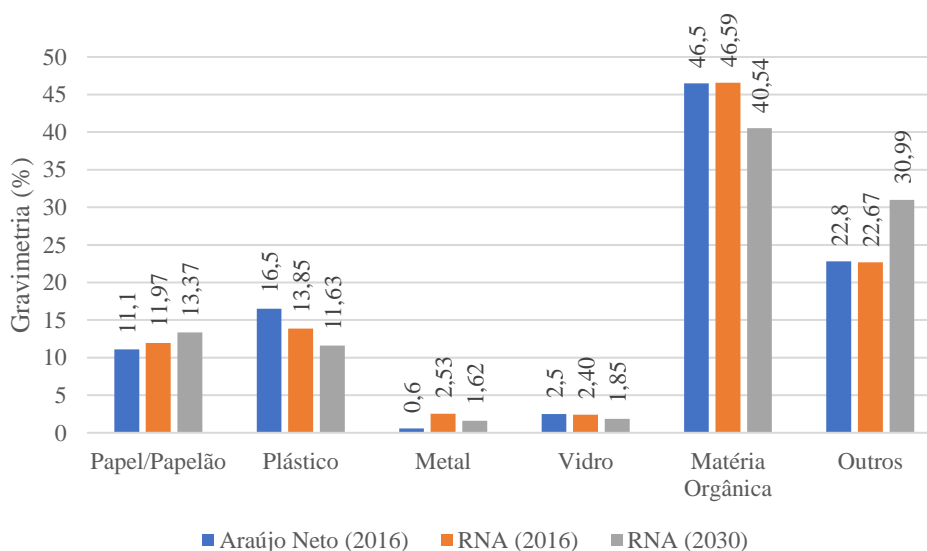
Figura 19 - Localização do município de Campina Grande – PB



Fonte: Autor (2020).

Para validação da rede foi utilizada a pesquisa de Araújo Neto (2016), onde foi realizada a composição gravimétrica dos resíduos da cidade, representando o percentual da quantidade em peso de cada constituinte de RSU. Assim, foi possível comparar com a previsão da rede para o mesmo ano e realizar a projeção para o ano de 2030. O IDHm estimado para 2016 foi 0,7993 e para o ano de 2030 foi 0,8951. A comparação citada está referida na Figura 20.

Figura 20 - Estimativas de RSU no município de Campina Grande - PB



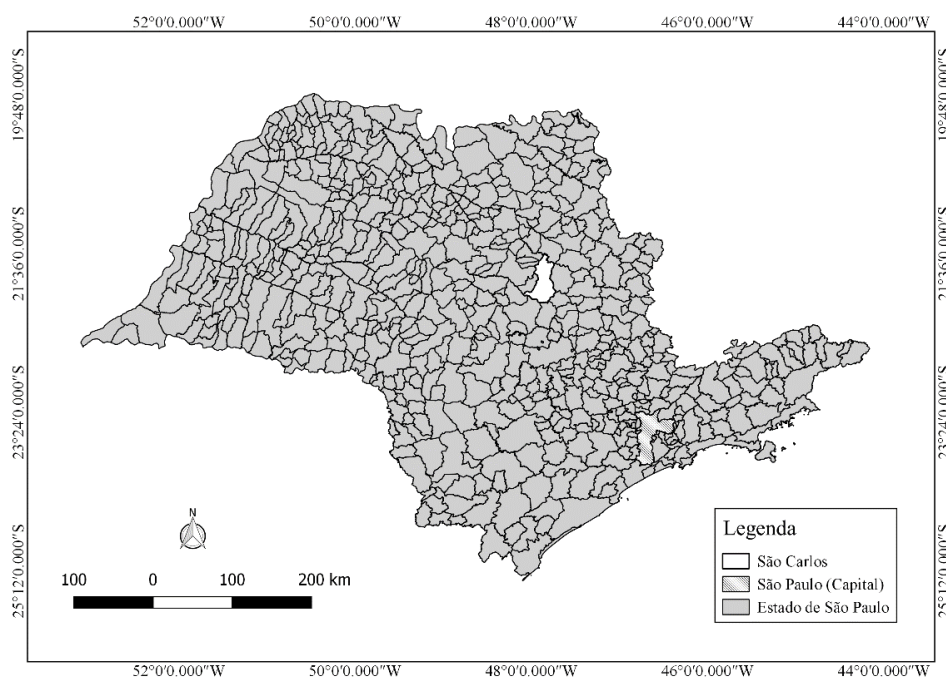
Fonte: Autor (2020).

A Figura 20, revela a eficiência da RNA treinada, os valores determinados ficaram próximos dos valores estimados por Araújo Neto (2016), demonstrando a eficiência da RNA. O estudo constatou a previsão do resíduo para o ano de 2030, onde ficou perceptível a diminuição da produção de matéria orgânica, relacionada com o aumento do IDHm. Feil et. al (2015), relatam que um local com maior desenvolvimento gera menor quantidade de matéria orgânica, porém pode aumentar a quantidade de papel e diminuir a quantidade de plástico e de metal.

#### 5.4.2 São Carlos

O município de São Carlos está localizado no interior do estado de São Paulo, na região centro-leste, com área total de 1.136.907 km<sup>2</sup> e altitude de 830 m (Figura 21). A população estimada para o ano de 2018 é de 247.088, possui um PIB per capita de R\$ 40.435,49 (IBGE, 2020).


Figura 21 - Localização do município de São Carlos - SP



Fonte: Autor (2020).

A validação da RNA foi realizada a partir dos dados de composição gravimétrica da pesquisa de Kim (2019) e por modelagem de IDHm de 0,9011 para o ano de 2019. Também foi possível fazer a previsão da Composição para o ano de 2030 a partir do

IDHm estimado (0,9653) para o mesmo ano. Esses dados estão mostrados na Figura 22.



Fonte: Autor (2020).

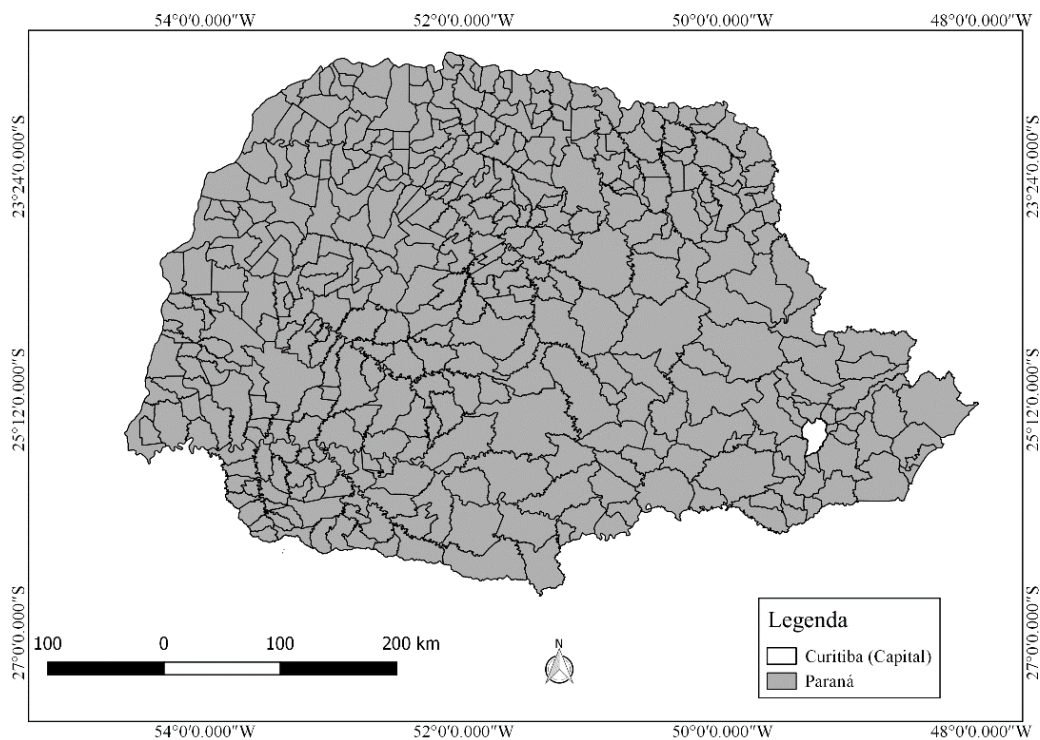
Comparando o modelo da RNA (2018) com os valores medidos em 2018 por Kim (2019) foi verificada uma boa adaptação da RNA. Ficou perceptível a diminuição na quantidade produzida de Matéria Orgânica e vidro, aumento no consumo de papel e papelão, plástico e metal, o que pode ser associado a mudanças nos padrões de consumo e geração de resíduos na cidade.

Kim (2019), afirma que a quantidade de produtos inseridos na categoria “outros” deve-se ao aumento na criação de produtos que não se enquadram em nenhuma das categorias anteriormente citadas. Esse fato vale para as projeções de resíduos para anos futuros.

### 5.4.3 Curitiba

Curitiba é a capital do estado do Paraná, localizado a 934 metros de altitude, área de 434.892 km<sup>2</sup> e localizada a cerca de 110 quilômetros do Oceano Atlântico (Figura 23). Segundo os cálculos do IBGE, em julho de 2016 Curitiba chegou aos 1.893.997 habitantes, atingindo em 2017 um PIB per capita de R\$ 44.384 e um IDHm no último censo de 0.823 (IBGE, 2020).


Figura 23 - Localização do município de Curitiba - PR.



Fonte: Autor (2020).

Para realização da validação da RNA foi analisada a pesquisa de Tavares (2007) e por modelagem o IDHm de 0,7921 para o ano de 2016. Também foi possível fazer a previsão da Composição para o ano de 2030 a partir do IDHm estimado (0,9852), esses dados estão expostos na Figura 24.

Figura 24 - Estimativas de RSU no município de Curitiba - PR.



Fonte: Autor (2020).

Analisando a Figura 24, é possível comprovar a eficiência da RNA, que apresentou resultados similares aos disponibilizados para o ano de 2016 por Tavares (2007). Assim como os outros municípios, verificou-se a redução de percentual de Matéria Orgânica devido ao aumento do desenvolvimento socioeconômico nessa região. Foi perceptível também o aumento da categoria “Outros” tendo em vista, que os municípios mais desenvolvidos passam a gerar mais rejeitos, pela produção de resíduos que não se encaixam nas outras categorias (FEIL et.al, 2015; KIM, 2019).

## 6. CONSIDERAÇÕES FINAIS

A gestão dos resíduos sólidos urbanos é, em boa parte dos casos dos municípios brasileiros, considerada falha. Existe uma grande produção de RSU porém não é corretamente acondicionado, tratado ou destinado. Uma prova da falha desses sistemas é a diferença por região na quantidade de dados encontrados na literatura a respeito da composição gravimétrica dos resíduos. Este fato está comumente ligado a inexistência de um plano municipal de gerenciamento integrado de resíduos sólidos (PGIRS).

A RNA treinada demonstrou bons padrões de convergência nos testes realizados pelo software *matlab 2018a* através da interface *nntool*. Quando a rede foi executada com os dados de IDHm para os 3 municípios testados demonstrou uma boa precisão, já que os valores de saída (composição gravimétrica de RSU) se aproximaram dos valores disponíveis na literatura.

Portanto, pode-se afirmar que a modelagem para o ano de 2030, apresenta um cenário bem realista quanto a composição dos RSUs. As principais análises feitas a partir dessa projeção são discutidas nos tópicos:

- A matéria orgânica em todas as projeções mostrou-se diminuir em função do aumento do desenvolvimento social, representado pelo IDHm, nas localidades estudadas. A redução desse tipo de resíduo tem-se tornado uma tendência em países desenvolvidos e com alto IDH;
- Um aumento na produção de papel, papelão e plástico, mesmo que em pequenas porcentagens, pode ser visto alternando entre os 3 municípios estudados. Este fato pode estar associado com o aumento da produção industrial, principalmente de produtos que utilizam embalagens;
- As quantidades analisadas de metal e vidro sofreram pequenas variações em seus percentuais pode-se dizer que não sofreram influência dos índices analisados;
- A categoria outros teve um aumento substancial com o aumento do IDHm. Com o desenvolvimento as indústrias vão criando novos produtos, estes não se enquadram em quaisquer outras categorias e são enquadrados como rejeitos no tópico “Outros”.

Mesmo com os bons resultados da RNA, vale-se salientar que ela foi construída a partir de análises empíricas, portanto está sujeita a erros. A aproximação realizada com o modelo proposto é bastante útil para alguns municípios, principalmente devido a escassez de recursos para realização caracterização física, porém a RNA não substitui com 100% de precisão a caracterização *in loco*.

Com o passar do tempo, vão ser realizadas em vários municípios a gravimetria dos resíduos, este fato aumentará a quantidade de dados disponíveis na literatura, consecutivamente alimentará o banco de dados de futuras redes a serem construídas. Outro fator limitante é a modelagem do IDHm, por possuir apenas 3 anos analisados pode causar inconsistências na estimativa. Após o próximo Censo, o IBGE atualizará seu banco de dados, fornecendo mais um valor de IDHm e melhorando a precisão dos valores modelados.



## REFERÊNCIAS

ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 10004:** Resíduos Sólidos – classificação. Rio de Janeiro, 2004.

\_\_\_\_\_. – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 10007:** Amostragem de resíduos sólidos. Rio de Janeiro, 2004.

ABRELPE – ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE LIMPEZA PÚBLICA E RESÍDUOS ESPECIAIS. **Panorama dos Resíduos Sólidos no Brasil:** 2018. Rio de Janeiro, 2019.

ALMEIDA, A. C. et al. **Estimation of aboveground forest biomass in Amazonia with neural networks and remote sensing.** IEEE Latin America Transactions, v. 7, n. 1, p. 27-32, 2009.

ALVARENGA, B. S.; SANTOS, F. A. **Estudo comparativo sobre o PIB e a inflação no Brasil Período:** 1995 a 2010. REFAS: Revista FATEC Zona Sul, v. 4, n. 1, p. 3, 2017.

ARAÚJO NETO, Cláudio Luís. **Análise do comportamento dos resíduos sólidos urbanos e desenvolvimento de modelos estatísticos para previsão das deformações de aterros sanitários.** Dissertação (Mestrado em Engenharia Civil e Ambiental), Universidade Federal de Campina Grande - UFCG, Campina Grande - PB, 2016.

ARAÚJO, Elias de Moura; BANDEIRA, Josué de Paula. **Previsão de ICMS por Rede Neural Backpropagation.** 2019, 141 p. Trabalho de Conclusão de Curso (Graduação). Instituto Federal de Educação, Ciência e Tecnologia de Goiás. Inhumas, 2019.

BASSANEZI, R. C. **Ensino-aprendizagem com modelagem matemática: uma nova estratégia.** São Paulo: Contexto, 2006. 3.ed. 389 p.

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

BRAGA, A. P. et. al. **Redes Neurais Artificiais teoria e aplicações.** Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A., 2000.

BRASIL, Lei Federal nº 11.445, de 5 de janeiro de 2007a. estabelece as diretrizes nacionais para o saneamento básico; cria o Comitê Interministerial de Saneamento Básico; altera as Leis nos 6.766, de 19 de dezembro de 1979, 8.666, de 21 de junho de 1993, e 8.987, de 13 de fevereiro de 1995; e revoga a Lei nº 6.528, de 11 de maio de 1978. **Diário Oficial da República Federativa do Brasil**, Brasília, 5 jan. 2007, Seção 1, p. 14.

\_\_\_\_\_. Lei nº 12.305, de 2 de agosto de 2010a. Institui a Política Nacional de Resíduos Sólidos; altera a Lei no 9.605, de 12 de fevereiro de 1998; e dá outras

providências. **Diário Oficial da República Federativa do Brasil**, Brasília, 3 ago. 2010, Seção 1, p. 3.

\_\_\_\_\_. Decreto nº. 7.404, de 23 de dezembro de 2010b. Regulamenta a Lei nº. 12.305, de 2 de agosto de 2010, que institui a Política Nacional de Resíduos Sólidos, cria o Comitê Interministerial da Política Nacional de Resíduos Sólidos e o Comitê Orientador para a Implantação dos Sistemas de Logística Reversa, e dá outras providências. **Diário Oficial da República Federativa do Brasil**, Brasília, 23 dez. 2010, Seção 1, p. 1.

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

DE ALMEIDA, G. G. F.; DA SILVEIRA, R. C. E.; ENGEL, V.. **Coleta e reciclagem de resíduos sólidos urbanos: contribuição ao debate da sustentabilidade ambiental**. *Future Studies Research Journal: Trends and Strategies*, v. 12, n. 2, 2020.

FEIL, A.; SPILKI, F. R.; SCHREIBER, D. **Análise global das características de frações de resíduos urbanos residenciais**. *Revista Brasileira de Ciências Ambientais (Online)*, n. 38, p. 63-77, 2015.

FREITAS, C. C. et. al. **Aplicação de Redes Neurais Artificiais na Modelagem de Reatores Fotoquímicos**. 27º Congresso Brasileiro de Engenharia Sanitária e Ambiental. Rio de Janeiro: ABES, 2013.

GT AGENDA 2030 - **GRUPO DE TRABALHO DA SOCIEDADE CIVIL PARA AGENDA 2030**. Relatório Luz. 2018. Disponível em: <<https://gtagenda2030.org.br>>. Acesso em: 22 ago.2020.

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

IBGE - Instituto Brasileiro de Geografia e Estatística. *Cidades*. 2020. Disponível em: <<http://cidades.ibge.gov.br/xtras/uf.php?lang=&coduf=25&search=paraiba>>. Acesso: maio de 2020.

HOORNWEG, D.; BHADA-TATA, P. **What a Waste: A Global Review of Solid Waste Management. Urban development series**; knowledge papers n. 15. World Bank, Washington, DC.

JI, L. et al. **Municipal solid waste incineration in China and the issue of acidification: A review**. *Waste Management & Research*, v. 34, n. 4, p. 280-297, 2016.

KIM, Viviane Jin Hee. **Análise da composição gravimétrica dos resíduos domiciliares de São Carlos (SP)**. Tese de Doutorado (Escola de Engenharia de São Carlos). Universidade de São Paulo - USP. 2019.

LANDAU, E. C.; MOURA, L. **Configuração Territorial do Brasil: Divisão Política, Biomas, Características Demográficas e Socioeconômicas**. In: LANDAU, Elena Charlotte et al. Dinâmica da produção agropecuária e da paisagem natural no Brasil nas últimas décadas: sistemas agrícolas, paisagem natural e análise integrada do espaço rural. Brasília: Embrapa, 2020. Cap. 3. p. 61-92.

LISBINSKI, F. C. et al. **A importância dos consórcios públicos na gestão dos resíduos sólidos urbanos: uma análise do consórcio intermunicipal cigres**. Revista Gestão & Sustentabilidade Ambiental, v. 9, n. 2, p. 3-36, 2020.

MANNARINO, C. F.; FERREIRA, J. A.; GANDOLLA, M. **Contribuições para a evolução do gerenciamento de resíduos sólidos urbanos no Brasil com base na experiência Européia**. Engenharia Sanitária e Ambiental, v. 21, n. 2, p. 379-385, 2016.

MARTINS, A. C. G.; SIMÕES, A. S.; PRADO, G. I. **Classificação de texturas usando redes neurais artificiais e o modelo de Spot Noise**. Anais do VI Encontro Nacional de Inteligência Artificial, 2007.

MathWorks. Matlab R2020a. Products. Disponível em: <https://www.mathworks.com/products/matlab.html>. Acessado em: 13/05/2020

MATTEI, G.; ESCOSTEGUY, P. A. V. **Composição gravimétrica de resíduos sólidos aterrados**. Engenharia Sanitária e Ambiental, v. 12, n. 3, p. 247-251, 2007.

MAVROPOULOS, A.; TSAKONA, M.; ANTHOULI, Aida. **Urban waste management and the mobile challenge**. Waste Management & Research, v. 33, n. 4, p. 381-387, 2015.

MENDES, J. R. L. et al. **Diagnóstico da disposição final dos resíduos sólidos urbanos no estado da Paraíba**. Revista Brasileira de Direito e Gestão Pública, v. 8, n. 2, p. 449-457, 2020.

NEGOITA, G. A. et al. **Deep Learning: a Tool for Computational Nuclear Physics**. arXiv preprint arXiv:1803.03215, 2018.

OECD - Organisation for Economic Co-operation and Development. **Circular economy, waste and materials**. Paris, France: OECD; 2020. Disponível em: <<https://www.oecd.org/environment/environment-at-a-glance/Circular-Economy-Waste-Materials-Archive-February-2020.pdf>>. Acessado em: 09/07/2020.

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

PNUD - **Programa das Nações Unidas para Desenvolvimento. Índice de Desenvolvimento Humano Municipal Brasileiro**. – Brasília: PNUD, Ipea, FJP, 2013. 96 p.

SANTOS, A. M. et. al. **Usando Redes Neurais Artificiais e Regressão Logística na predição da Hepatite A**. Revista Brasileira de Epidemiologia, v.8, n.2, p. 117-126, 2005.

SANTOS, Ana Cíntia Brandão dos; FARIAS, Gilmar Alves de. **Reudes neurais: um conceito para matemática industrial**. In: FARIAS, Gilmar Alves de; SILVA, Janne Cristina de Araújo; SANTOS, Maria José Costa dos; MATOS, Fernanda Cíntia Costa (orgs.). ...Uma gota de conhecimento. Campinas, SP: Pontes Editores, 2019. p. 69-83.

SÃO MATEUS, Maria do Socorro Costa et al. - **Características dos resíduos sólidos urbanos (rsu) do estado da BAHIA e sua correlação com o índice de desenvolvimento humano**. In: Congresso brasileiro de engenharia sanitária e ambiental, 30., 2019, Natal - RN. Anais Eletrônicos.

SILVA, C. L. da; FUGII, G. M.; SANTOYO, A. . **Proposta de um modelo de avaliação das ações do poder público municipal perante as políticas de gestão de resíduos sólidos urbanos no Brasil: um estudo aplicado ao município de Curitiba**. urbe. Revista Brasileira de Gestão Urbana, v. 9, n. 2, p. 276-292, 2017.

STEINER, P. A. **Gestão de resíduos sólidos em centros comerciais do município de Curitiba – PR. 2010**. 179 f. Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambiental). Universidade Federal do Paraná. Curitiba, 2010.

TAVARES, Romero Coelho. **Composição gravimétrica: uma ferramenta de planejamento e gerenciamento do resíduo urbano de Curitiba e região metropolitana**. Dissertação (Programa Profissionalizante em Desenvolvimento de Tecnologia - PRODETEC). Instituto de Tecnologia para o Desenvolvimento (LACTEC) e do Instituto de Engenharia do Paraná (IEP). 2007.

WORLD BANK, What a Waste 2.0 - **A Global Snapshot of Solid Waste Management to 2050**. Washington, DC: World Bank Group, 2018.

## **ANEXO A – Banco de dados do projeto**

Dados				Composição do resíduo (%)						Dados sobre o município	Referências
N	Município	Estado	Ano	Papel,Papelão	Plástico	Metal	Vidro	Matéria Orgânica	Outros	IDH	Fonte
1	Palmas	TO	2010	9,76	14,79	2,96	0,59	70,71	1,19	0,803585019	COELHO et. al (2011)
2	Santa Rita do Novo Destino	GO	2014	12,67	14,33	3,33	3,00	60,00	6,67	0,707735256	AMARO & ZANETI apud GOIAS (2016)
3	Carmo do Rio Verde	GO	2014	12,67	14,33	3,33	3,00	58,33	8,01	0,769385125	AMARO & ZANETI apud GOIAS (2016)
4	Pilar de Goiás	GO	2014	12,67	14,33	3,33	3,00	58,33	8,33	0,744756114	AMARO & ZANETI apud GOIAS (2016)
5	São Luíz do Norte	GO	2014	11,57	13,09	3,04	2,74	60,87	8,70	0,743496206	AMARO & ZANETI apud GOIAS (2016)
6	Morro Agudo de Goiás	GO	2014	10,36	11,73	2,73	2,45	63,64	9,09	0,742537277	AMARO & ZANETI apud GOIAS (2016)
7	Nova América	GO	2014	10,36	11,73	2,73	2,45	63,64	9,09	0,715378132	AMARO & ZANETI apud GOIAS (2016)
8	Itapaci	GO	2014	11,62	13,15	3,06	2,75	60,33	9,09	0,78753495	AMARO & ZANETI apud GOIAS (2016)
9	Rianópolis	GO	2014	12,09	13,68	3,18	2,86	59,09	9,09	0,742128785	AMARO & ZANETI apud GOIAS (2016)
10	Rubiataba	GO	2014	11,43	12,94	3,01	2,71	60,18	9,73	0,784179257	AMARO & ZANETI apud GOIAS (2016)
11	Goianésia	GO	2014	11,44	12,95	3,01	2,71	60,00	9,89	0,782465939	AMARO & ZANETI apud GOIAS (2016)
12	Guaraíta	GO	2014	11,40	12,90	3,00	2,70	60,00	10,00	0,746682951	AMARO & ZANETI apud GOIAS (2016)
13	Guarinos	GO	2014	11,40	12,90	3,00	2,70	60,00	10,00	0,731439256	AMARO & ZANETI apud GOIAS (2016)
14	Nova Glória	GO	2014	11,40	12,90	3,00	2,70	60,00	10,00	0,732237291	AMARO & ZANETI apud GOIAS (2016)

15	Ceres	GO	2014	11,49	13,00	3,02	2,72	59,69	10,08	0,823819481	AMARO & ZANETI apud GOIAS (2016)
16	Itapuranga	GO	2014	11,30	12,79	2,97	2,68	60,13	10,13	0,785977709	AMARO & ZANETI apud GOIAS (2016)
17	Barro Alto	GO	2014	11,63	13,16	3,06	2,76	59,18	10,20	0,675732673	AMARO & ZANETI apud GOIAS (2016)
18	Rialma	GO	2014	11,33	12,82	2,98	2,68	59,65	10,53	0,78387012	AMARO & ZANETI apud GOIAS (2016)
19	Hidrolina	GO	2014	10,56	11,94	2,78	2,50	61,11	11,11	0,720930146	AMARO & ZANETI apud GOIAS (2016)
20	Santa Isabel	GO	2014	10,56	11,94	2,78	2,50	61,11	11,11	0,808809177	AMARO & ZANETI apud GOIAS (2016)
21	Hidrolândia	GO	2016	7,94	12,49	0,97	2,92	63,54	12,14	0,708717501	OLIVEIRA et. al (2019)
22	Melgaço	MT	2016	7,15	6,24	3,55	3,04	66,06	13,96	0,484016644	DE CAMPOS et. Al (2016)
23	Ipiranga de Goiás	GO	2014	10,86	12,29	2,86	2,57	57,14	14,29	0,754368745	AMARO & ZANETI apud GOIAS (2016)
24	Uruana	GO	2014	8,44	9,56	2,22	2,00	55,56	22,22	0,738697998	AMARO & ZANETI apud GOIAS (2016)
25	São Patrício	GO	2014	3,80	4,30	1,00	0,90	60,00	30,00	0,743763933	AMARO & ZANETI apud GOIAS (2016)
26	Várzea Grande	MT	2015	11,00	20,00	1,00	1,00	37,00	30,00	0,63190949	JUNIOR et. al (2015)
27	Coari	AM	2012	11,90	13,50	1,50	2,40	66,70	4,00	0,598076911	SEMA (2015)
28	Ji-Paraná	RO	2011	12,00	7,50	2,20	2,00	66,70	9,60	0,727948907	DOS SANTOS (2011)
29	Itacoatiara	AM	2019	15,05	17,85	2,31	1,14	51,32	12,33	0,746274871	GUIMARÃES (2019)
30	Apuí	AM	2012	8,60	13,30	4,10	2,50	58,50	13,00	0,659166567	SEMA (2015)
31	Manacapuru	AM	2012	8,40	10,10	1,90	0,90	53,70	25,00	0,632602022	SEMA (2015)
32	Bragança	PA	2018	6,55	21,12	3,54	6,36	37,05	25,39	0,715741547	SILVA et. al (2018)
33	Caruaru	PE	2010	10,30	5,40	0,70	5,50	78,00	0,10	0,671915532	SEMAS (2012)

34	Serra Talhada	PE	2010	8,19	11,60	3,39	4,55	71,38	0,89	0,65294486	SEMAS (2012)
35	Piranhas	AL	2011	5,69	6,35	1,00	4,01	81,94	1,01	0,5811671	SEMARH (2011)
36	Santana do Ipanema	AL	2011	8,52	17,05	0,57	1,14	71,02	1,70	0,59143134	SEMARH (2011)
37	Gravatá	PE	2010	12,00	8,00	6,20	5,80	64,90	3,10	0,633868572	SEMAS (2012)
38	Flores	PE	2010	5,12	8,29	5,28	0,54	77,01	3,76	0,557830042	SEMAS (2012)
39	Aracaju	SE	1994	15,13	8,86	3,00	1,45	67,70	3,86	0,579344019	Daltro et al. (1994)
40	Vicência	PE	2010	8,42	10,37	5,64	4,04	66,84	4,69	0,607218733	SEMAS (2012)
41	Moreno	PE	2010	12,00	14,00	1,00	7,00	61,00	5,00	0,646102568	SEMAS (2012)
42	Carpina	PE	2010	3,71	12,84	1,18	1,71	74,87	5,69	0,68121165	SEMAS (2012)
43	Santa Cruz da Baixa Verde	PE	2010	9,01	8,79	3,18	5,95	66,99	6,08	0,616851743	SEMAS (2012)
44	Araçoiaba	PE	2010	14,00	12,00	4,00	2,00	61,00	7,00	0,593760996	SEMAS (2012)
45	Timbaúba	PE	2010	9,80	12,25	5,00	5,20	60,55	7,20	0,618888221	SEMAS (2012)
46	Iati	PE	2010	5,97	6,53	1,15	0,59	78,29	7,47	0,517795934	SEMAS (2012)
47	Tacaimbó	PE	2010	3,90	12,60	6,90	5,60	63,20	7,80	0,553340123	SEMAS (2012)
48	Ibimirim	PE	2010	1,65	9,04	1,16	0,00	80,21	7,94	0,546538956	SEMAS (2012)
49	Solidão	PE	2010	12,60	7,89	5,26	3,15	63,15	7,95	0,578093367	SEMAS (2012)
50	Itaíba	PE	2010	4,75	7,19	1,37	2,88	75,83	7,98	0,503954028	SEMAS (2012)
51	Macaparana	PE	2010	9,88	11,03	4,33	3,88	62,58	8,30	0,60382347	SEMAS (2012)
52	Araripina	PE	2010	6,40	10,33	2,46	0,59	71,85	8,37	0,600074873	SEMAS (2012)
53	Trindade	PE	2010	11,01	14,21	3,55	1,95	60,39	8,89	0,599772248	SEMAS (2012)
54	Brejo da Madre de Deus	PE	2010	5,05	4,04	6,06	5,05	70,71	9,09	0,555874533	SEMAS (2012)
55	Itaquitinga	PE	2010	12,00	16,00	5,00	5,50	52,00	9,50	0,577533154	SEMAS (2012)
56	Brejão	PE	2010	10,18	7,72	1,33	2,18	69,04	9,55	0,532302297	SEMAS (2012)



57	Sairé	PE	2010	12,64	16,85	1,69	0,84	58,43	9,55	0,570675089	SEMAS (2012)
58	Buíque	PE	2010	9,10	10,80	4,80	3,20	62,50	9,60	0,521411764	SEMAS (2012)
59	Jurema	PE	2010	8,50	14,30	1,40	0,70	65,40	9,70	0,545168726	SEMAS (2012)
60	Capoeiras	PE	2010	11,80	10,70	2,50	0,90	64,20	9,90	0,550110806	SEMAS (2012)
61	Afogados da Ingazeira	PE	2010	7,20	12,00	3,60	3,00	63,50	10,70	0,658545528	SEMAS (2012)
62	Vertentes	PE	2010	10,39	13,15	3,53	2,93	59,24	10,76	0,581076957	SEMAS (2012)
63	Igarassu	PE	2010	12,00	7,00	2,00	5,00	63,00	11,00	0,667715384	SEMAS (2012)
64	Ilha de Itamaracá	PE	2010	12,00	7,00	2,00	5,00	63,00	11,00	0,659983104	SEMAS (2012)
65	Jaboatão dos Guararapes	PE	2010	12,00	7,00	2,00	5,00	63,00	11,00	0,720622075	SEMAS (2012)
66	Parnamirim	PE	2010	8,00	12,00	3,00	4,00	62,00	11,00	0,771500267	SEMAS (2012)
67	Lagoa de Itaenga	PE	2010	14,00	13,00	6,00	4,00	52,00	11,00	0,589557065	SEMAS (2012)
68	Cachoeirinha	PE	2010	16,20	14,00	1,70	0,90	55,85	11,35	0,620789588	SEMAS (2012)
69	Santa Filomena	PE	2010	9,20	8,90	4,20	2,80	63,50	11,40	0,539922615	SEMAS (2012)
70	Bezerros	PE	2010	9,70	12,10	6,90	5,50	54,30	11,50	0,603702081	SEMAS (2012)
71	Calumbi	PE	2010	4,75	6,04	4,92	0,13	72,52	11,64	0,561600115	SEMAS (2012)
72	Palmeirina	PE	2010	10,06	6,15	3,91	1,68	66,48	11,72	0,551469784	SEMAS (2012)
73	Goiana	PE	2010	8,50	9,05	3,50	4,35	62,80	11,80	0,647578255	SEMAS (2012)
74	Jaqueira	PE	2010	3,68	9,00	0,52	0,56	74,40	11,84	0,570901265	SEMAS (2012)
75	Condado	PE	2010	5,00	11,00	3,00	3,00	66,00	12,00	0,584015187	SEMAS (2012)
76	Nazaré da Mata	PE	2010	8,00	12,00	4,00	3,00	61,00	12,00	0,653761189	SEMAS (2012)
77	Serrita	PE	2010	10,00	14,00	4,00	2,00	58,00	12,00	0,592293707	SEMAS (2012)
78	Barra de Guabiraba	PE	2010	15,52	15,96	2,69	3,12	50,65	12,06	0,556854273	SEMAS (2012)

79	Tamandaré	PE	2010	8,37	8,78	0,87	2,61	67,18	12,19	0,583744872	SEMAS (2012)
80	Canhotinho	PE	2010	9,30	8,72	2,91	2,33	64,53	12,21	0,540829657	SEMAS (2012)
81	Pedra	PE	2010	10,20	13,15	3,15	2,90	58,30	12,30	0,564053557	SEMAS (2012)
82	Petrolândia	PE	2010	9,00	9,60	4,50	3,40	61,00	12,50	0,629509468	SEMAS (2012)
83	Angelim	PE	2010	9,80	13,20	3,20	3,00	58,30	12,50	0,56921088	SEMAS (2012)
84	Delmiro Gouveia	AL	2016	6,40	15,03	2,14	5,27	58,49	12,67	0,690065484	ARAUJO et. Al (2018)
85	Santa Cruz	PE	2010	6,80	7,90	3,90	2,90	65,80	12,70	0,636441352	SEMAS (2012)
86	Inajá	PE	2010	16,32	8,74	1,12	1,82	59,26	12,74	0,522732598	SEMAS (2012)
87	Penedo	AL	2011	7,17	19,92	2,39	1,20	56,57	12,75	0,635178923	SEMARH (2011)
88	Panelas	PE	2010	5,90	9,60	3,80	3,40	64,50	12,80	0,568000795	SEMAS (2012)
89	Itacuruba	PE	2010	9,90	8,40	3,80	3,00	62,00	12,90	0,601832897	SEMAS (2012)
90	Mirandiba	PE	2010	8,00	11,00	3,00	2,00	63,00	13,00	0,582856583	SEMAS (2012)
91	Paudalho	PE	2010	10,00	13,00	4,00	2,00	58,00	13,00	0,632701311	SEMAS (2012)
92	Belém do São Francisco	PE	2010	7,60	10,40	4,00	2,90	62,00	13,10	0,633746956	SEMAS (2012)
93	Delmiro Gouveia	AL	2011	5,14	20,57	2,86	5,71	52,57	13,15	0,617117706	SEMARH (2011)
94	Cortês	PE	2010	5,18	8,71	0,73	0,80	71,17	13,41	0,563164464	SEMAS (2012)
95	Pombos	PE	2010	5,18	8,71	0,73	0,80	71,17	13,41	0,596762311	SEMAS (2012)
96	Itapetim	PE	2010	7,58	7,84	1,87	0,00	69,26	13,45	0,591615855	SEMAS (2012)
97	Piranhas	AL	2016	7,25	13,75	2,50	5,00	57,69	13,81	0,631601725	ARAUJO et. Al (2018)
98	Tabira	PE	2010	8,64	9,18	3,18	1,59	63,55	13,86	0,604409169	SEMAS (2012)
99	Ouricuri	PE	2010	9,80	10,20	4,80	2,42	58,90	13,88	0,568919249	SEMAS (2012)
100	Palmares	PE	2010	5,80	12,20	2,10	1,30	64,70	13,90	0,614734808	SEMAS (2012)
101	Sirinhaém	PE	2010	2,95	17,41	1,40	1,08	63,19	13,97	0,596569824	SEMAS (2012)

102	Cabo de Santo Agostinho	PE	2010	7,00	11,00	5,00	1,00	62,00	14,00	0,685053942	SEMAS (2012)
103	Itambé	PE	2010	9,00	10,00	4,00	4,00	59,00	14,00	0,568187095	SEMAS (2012)
104	Sertânia	PE	2010	14,79	17,55	3,30	2,31	47,63	14,42	0,610217997	SEMAS (2012)
105	Ipubi	PE	2010	7,79	10,39	1,73	0,43	64,94	14,72	0,551948451	SEMAS (2012)
106	Escada	PE	2010	8,23	16,46	2,47	1,23	56,79	14,82	0,631110421	SEMAS (2012)
107	Betânia	PE	2010	11,00	13,59	1,62	1,37	57,52	14,90	0,558561042	SEMAS (2012)
108	Afrânio	PE	2010	10,00	7,00	3,00	0,00	65,00	15,00	0,578089231	SEMAS (2012)
109	Lajedo	PE	2010	1,90	15,00	2,60	1,10	64,40	15,00	0,61018825	SEMAS (2012)
110	Rio Formoso	PE	2010	6,39	6,37	6,42	1,47	64,35	15,00	0,602447824	SEMAS (2012)
111	Lagoa do Carro	PE	2010	6,00	11,00	3,00	7,00	58,00	15,00	0,62230557	SEMAS (2012)
112	Correntes	PE	2010	10,37	7,93	3,05	3,05	60,37	15,23	0,531051506	SEMAS (2012)
113	Riacho das Almas	PE	2010	10,65	18,01	6,61	0,96	48,46	15,31	0,571791128	SEMAS (2012)
114	Camocim de São Félix	PE	2010	10,13	8,97	1,21	0,23	63,89	15,57	0,587117538	SEMAS (2012)
115	Ingazeira	PE	2010	9,70	7,30	2,40	0,00	64,90	15,70	0,61306388	SEMAS (2012)
116	Catende	PE	2010	3,60	10,56	1,48	0,23	68,32	15,81	0,603948996	SEMAS (2012)
117	Barreiros	PE	2010	5,70	10,95	1,07	0,00	66,42	15,86	0,579855302	SEMAS (2012)
118	Maraial	PE	2010	8,21	10,45	1,64	0,99	62,81	15,90	0,522521902	SEMAS (2012)
119	Glória do Goitá	PE	2010	2,17	6,32	0,77	0,64	74,13	15,97	0,596024355	SEMAS (2012)
120	São José de Espinharas	PB	2018	8,34	15,56	2,94	0,58	56,59	15,99	0,719170352	PGIRS-SJE (2018)
121	Olinda	PE	2010	12,00	8,00	2,00	2,00	60,00	16,00	0,736383206	SEMAS (2012)
122	São Joaquim do Monte	PE	2010	11,76	10,90	1,54	0,88	58,89	16,03	0,523124044	SEMAS (2012)

123	Manari	PE	2010	7,26	15,23	1,16	2,06	58,03	16,26	0,485069422	SEMAS (2012)
124	Propriá	SE	2000	7,42	10,04	1,14	0,78	64,29	16,33	0,541020845	BARRETO (2000)
125	Vitória de Santo Antão	PE	2010	5,35	9,92	1,57	2,12	64,57	16,47	0,638601656	SEMAS (2012)
126	Santa Terezinha	PE	2010	4,70	7,50	0,90	0,00	70,40	16,50	0,590244344	SEMAS (2012)
127	Floresta	PE	2010	11,60	13,90	2,60	3,00	52,30	16,60	0,626238031	SEMAS (2012)
128	Primavera	PE	2010	8,33	11,25	2,92	3,33	57,50	16,67	0,585150842	SEMAS (2012)
129	Arapiraca	AL	2011	10,82	18,36	5,57	5,90	42,62	16,73	0,657672036	SEMARH (2011)
130	Águas Belas	PE	2010	4,03	8,21	1,89	0,57	68,38	16,92	0,517043619	SEMAS (2012)
131	Amaraji	PE	2010	7,14	9,52	2,86	1,43	61,90	17,15	0,575353585	SEMAS (2012)
132	União dos Palmares	AL	2009	10,50	5,10	4,60	2,70	59,90	17,20	0,565732959	SEMARH apud SILVA (2011)
133	Fortaleza	CE	2010	14,20	15,70	3,30	2,10	47,50	17,20	0,756286113	BARRETO et. al (2015)
134	São José da Laje	AL	2009	6,96	4,90	4,29	2,32	64,11	17,42	0,549446449	SEMARH apud SILVA (2011)
135	Cabedelo	PB	1997	6,60	6,80	1,30	1,40	66,40	17,50	0,543921236	Filho et ai. (1998)
136	Paranatama	PE	2010	4,36	7,21	1,68	1,34	67,54	17,87	0,528518921	SEMAS (2012)
137	São Caetano do Sul	PE	2010	8,10	12,80	2,60	6,80	51,60	18,10	0,876122318	SEMAS (2012)
138	Saloá	PE	2010	5,44	7,17	1,38	0,60	67,08	18,33	0,554779524	SEMAS (2012)
139	Porto Real do Colégio	AL	2011	5,19	13,51	2,60	0,78	59,48	18,44	0,556843829	SEMARH (2011)
140	Quipapá	PE	2010	0,08	3,99	0,41	0,08	76,94	18,50	0,53543622	SEMAS (2012)
141	Santana do Mundaú	AL	2009	6,20	6,03	5,68	1,58	62,01	18,50	0,49615688	SEMARH apud SILVA (2011)
142	Santana dos Garrotes	PB	2015	4,61	16,73	1,64	2,34	56,06	18,62	0,674755821	DA COSTA et. al (2016)
143	Ibateguara	AL	2009	7,23	5,88	5,70	2,32	60,17	18,70	0,489317047	SEMARH apud SILVA (2011)

144	Arcoverde	PE	2010	9,00	18,00	1,00	0,00	53,00	19,00	0,663615503	SEMAS (2012)
145	Jataúba	PE	2010	9,70	7,80	1,80	5,70	55,80	19,20	0,526095837	SEMAS (2012)
146	Pirambu	SE	2012	9,20	18,20	0,61	1,11	51,37	19,51	0,618519598	SANTOS (2012)
147	Jatobá	PE	2010	10,30	9,00	3,80	3,10	54,00	19,80	0,566289797	SEMAS (2012)
148	Petrolina	PE	2010	7,00	19,00	3,00	3,00	48,00	20,00	0,697531329	SEMAS (2012)
149	Ferreiros	PE	2010	8,14	13,64	3,22	4,13	50,57	20,30	0,611944475	SEMAS (2012)
150	Agrestina	PE	2010	7,20	11,50	2,30	1,00	57,60	20,40	0,590327589	SEMAS (2012)
151	Terra Nova	PE	2010	9,38	10,22	3,27	4,17	52,48	20,48	0,59900833	SEMAS (2012)
152	Chã Grande	PE	2010	2,55	9,10	0,92	3,03	63,50	20,90	0,597249761	SEMAS (2012)
153	Paulista	PE	2012	10,00	8,90	2,40	3,50	54,20	21,00	0,612007649	AQUINO et. al (2016)
154	Abreu e Lima	PE	2010	10,00	8,90	2,40	3,50	54,20	21,00	0,678882805	SEMAS (2012)
155	Fernando de Noronha	PE	2010	10,00	8,90	2,40	3,50	54,20	21,00	0,798131996	SEMAS (2012)
156	Ipojuca	PE	2010	10,00	8,90	2,40	3,50	54,20	21,00	0,615429714	SEMAS (2012)
157	Triunfo	PE	2010	8,00	15,00	5,00	1,00	50,00	21,00	0,603224309	SEMAS (2012)
158	Cupira	PE	2010	3,33	1,27	1,14	0,89	72,16	21,21	0,585747342	SEMAS (2012)
159	Calçado	PE	2010	7,50	5,20	5,20	1,00	59,80	21,30	0,558679995	SEMAS (2012)
160	Brejinho	PE	2010	7,60	6,10	2,30	3,00	59,60	21,40	0,584379581	SEMAS (2012)
161	Traipu	AL	2011	13,60	17,63	5,79	2,27	39,29	21,42	0,527098903	SEMARH (2011)
162	São José da Coroa Grande	PE	2010	2,64	15,06	2,00	4,35	53,82	22,13	0,61577805	SEMAS (2012)
163	Maceió	AL	2019	4,37	4,43	0,68	0,86	67,45	22,21	0,814262938	DE OLIVEIRA SILVA et al. (2020)
164	Xexéu	PE	2010	1,72	6,93	0,89	4,96	63,24	22,26	0,539857479	SEMAS (2012)
165	Jucati	PE	2010	6,70	11,80	3,40	0,70	54,80	22,60	0,544508824	SEMAS (2012)
166	São João	PE	2010	3,92	13,47	2,48	1,81	55,40	22,92	0,564097118	SEMAS (2012)
167	Verdejante	PE	2010	8,25	6,43	4,25	3,77	54,25	23,05	0,60049501	SEMAS (2012)

168	Alagoinha	PE	2010	4,30	11,50	2,30	1,00	57,60	23,30	0,592942231	SEMAS (2012)
169	Belém de Maria	PE	2010	3,71	7,32	3,70	1,94	59,91	23,42	0,571132281	SEMAS (2012)
170	Palmeira dos Índios	AL	2011	6,54	12,75	3,27	1,63	52,29	23,52	0,64397003	SEMARH (2011)
171	Água Preta	PE	2010	4,80	9,60	3,70	0,40	57,70	23,80	0,544992557	SEMAS (2012)
172	Dormentes	PE	2010	8,80	8,50	3,80	2,50	52,60	23,80	0,587638451	SEMAS (2012)
173	Gameleira	PE	2010	1,93	8,89	0,36	1,61	63,09	24,12	0,591541551	SEMAS (2012)
174	Bonito	PE	2010	5,30	10,10	1,60	1,40	57,10	24,50	0,54447068	SEMAS (2012)
175	Porto da Folha	SE	2010	13,80	18,50	1,10	0,00	42,10	24,50	0,56257242	Casado et. al (2010)
176	Aracaju	SE	2009	16,06	4,32	1,97	1,82	50,60	25,23	0,756987935	EMSURB (2009)
177	Nossa Senhora do Socorro	SE	2012	4,64	9,41	0,66	0,72	59,20	25,37	0,687913733	M&C ENGENHARIA (2012)
178	Lagoa dos Gatos	PE	2010	6,90	7,50	3,20	1,00	55,80	25,60	0,548228445	SEMAS (2012)
179	Lagoa Grande	PE	2010	8,05	11,20	3,37	2,32	49,45	25,61	0,598815809	SEMAS (2012)
180	Bom Conselho	PE	2010	8,00	10,00	2,00	1,00	53,00	26,00	0,555791288	SEMAS (2012)
181	Quixaba	PE	2010	9,83	12,20	5,08	5,40	40,71	26,78	0,572434746	SEMAS (2012)
182	Ibirajuba	PE	2010	5,80	7,10	1,50	0,80	57,30	27,50	0,578430099	SEMAS (2012)
183	Cabrobó	PE	2010	4,30	10,10	4,90	5,70	47,30	27,70	0,61353652	SEMAS (2012)
184	Joaquim Nabuco	PE	2010	2,76	12,28	0,48	0,05	56,48	27,95	0,549012592	SEMAS (2012)
185	Craíbas	AL	2011	8,18	7,67	1,53	3,07	50,90	28,65	0,537899749	SEMARH (2011)
186	Pesqueira	PE	2010	8,40	9,50	2,80	4,30	46,20	28,80	0,609377371	SEMAS (2012)
187	Jupi	PE	2010	8,00	11,60	4,20	3,30	44,00	28,90	0,581132892	SEMAS (2012)

188	Chã de Alegria	PE	2010	3,92	6,73	0,43	4,32	54,67	29,93	0,602841805	SEMAS (2012)
189	Mamborê	PR	2016	15,60	16,80	5,20	2,00	54,00	6,40	0,818566099	GALDINO & MARTINS (2016)
190	Mamborê	PR	2015	15,60	16,80	4,20	2,00	54,00	7,40	0,803789792	GALDINO & MOTA (2015)
191	Xangri-lá	RS	2018	5,35	10,00	0,72	3,90	76,70	8,68	0,841321566	ENGELMANN (et. AI, 2020)
192	Campo Largo	PR	2006	15,90	18,90	3,60	2,60	48,90	10,10	0,700380718	TAVARES (2007)
193	Novo Hamburgo	RS	2015	12,69	14,82	1,49	3,61	57,13	10,26	0,809513842	WASKOW (2015)
194	São Leopoldo	RS	2012	13,30	12,30	1,52	1,72	58,65	12,51	0,765756628	PROSINOS (2012)
195	Porto Alegre	RS	1997	16,10	11,10	2,60	2,50	52,50	15,20	0,71107509	Costa (1998)
196	Caxias do Sul	RS	1995	8,00	6,60	2,90	1,30	58,80	22,40	0,641173072	Pessin e silva. (1991)
197	Nova Veneza	SC	2014	12,86	21,52	2,84	2,34	37,83	22,61	0,816813663	GUADAGNIN et. al (2014)
198	Ponta Grossa	PR	2013	12,00	15,90	4,00	4,60	40,70	22,80	0,804818833	EIDAM (2019)
199	Iomerê	SC	2014	8,00	6,00	0,50	2,00	58,00	25,50	0,894112753	CAMPOS et. al (2017)
200	Lajeado	RS	2019	13,27	13,93	0,79	2,44	40,17	29,40	0,795081953	MALLMANN et. AI (2019)
201	Santa Cruz do Sul	RS	2019	9,92	13,48	2,02	3,02	41,65	29,91	0,878832411	DA SILVA TRENTIN et. AI (2019)
202	Tuneiras do Oeste	PR	2018	6,00	12,00	2,00	5,00	45,00	30,00	0,825908871	SANTOS (2018)
203	Juiz de fora	MG	1990	14,60	10,78	3,23	1,36	68,12	1,91	0,591869514	DEMLURB, apud Azevedo et al, (1988)
204	Botucatu	SP	1997	8,43	8,37	3,85	1,99	74,11	3,25	0,665112765	Oliveira et al.(1998)
205	Belo Horizonte	MG	1996	11,41	11,71	2,64	2,50	67,51	4,23	0,66552998	Mercedes (1998)
206	Juiz de fora	MG	1992	8,75	7,18	2,48	2,63	69,36	9,60	0,611253634	Azevedo et al. (1998)

207	Maria da Fé	MG	2016	11,10	12,20	5,60	2,80	55,60	12,70	0,806467308	ALKMIN & JUNIOR (2017)
208	Vitória	ES	1993	11,67	6,86	2,79	1,77	63,43	13,48	0,672017791	Baptista (1993)
209	Araçuaí	MG	2018	11,80	8,32	0,79	0,89	58,90	19,30	0,806079008	SANTOS et. Al (2018)
210	Igarapé	MG	2013	7,50	10,00	0,60	4,10	58,40	19,40	0,75491024	TASSINARI (2019)
211	Salinas	MG	2013	12,80	13,40	4,30	3,30	46,50	19,70	0,733844694	COSTA et. Al (2013)
212	Lagoa da Prata	MG	2015	8,80	1,94	4,32	2,74	60,56	21,64	0,80551922	COSTA (2015)
213	Rubiácea	SP	2018	6,90	17,10	2,80	1,30	44,90	27,00	0,807540127	LIMA et. al (2018)