



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO ACADÊMICO DO AGRESTE  
NÚCLEO DE TECNOLOGIA  
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

VICTOR AMORIM PORTO FARIAS

**MODELO DE APOIO À GESTÃO PÚBLICA MUNICIPAL: Um estudo baseado em  
clusterização de escolas municipais para ações eficientes de distribuição de insumos**

Caruaru

2025

VICTOR AMORIM PORTO FARIAS

**MODELO DE APOIO À GESTÃO PÚBLICA MUNICIPAL: Um estudo baseado em clusterização de escolas municipais para ações eficientes de distribuição de insumos**

Dissertação apresentada ao programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, Centro Acadêmico do Agreste, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção. Área de concentração: Pesquisa Operacional.

Orientador: Prof. Dra. Thárcylla Rebecca Negreiros Clemente

Coorientador: Prof. Dr. José Leão e Silva Filho

Caruaru

2025

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Farias, Victor Amorim Porto.

Modelo de apoio à gestão pública municipal: um estudo baseado em clusterização de escolas municipais para ações eficientes de distribuição de insumos / Victor Amorim Porto Farias. - 2025.  
102f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro Acadêmico do Agreste, Programa de Pós-Graduação em Engenharia de Produção, 2025.

Orientação: Thárcylla Rebecca Negreiros Clemente.

Coorientação: José Leão e Silva Filho.

Inclui referências e anexos.

1. Gestão de insumos escolares; 2. Escolas municipais; 3. Alimentação escolar; 4. Clusterização; 5. K-Modes; 6. Caruaru-PE. I. Clemente, Thárcylla Rebecca Negreiros. II. Filho, José Leão e Silva. III. Título.

UFPE-Biblioteca Central

VICTOR AMORIM PORTO FARIAS

**MODELO DE APOIO À GESTÃO PÚBLICA MUNICIPAL: Um estudo baseado em clusterização de escolas municipais para ações eficientes de distribuição de insumos**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, Centro Acadêmico do Agreste, como requisito para a obtenção do título de Mestre em Engenharia de Produção. Área de concentração: Pesquisa Operacional.

Aprovado em: 24/02/2025.

**BANCA EXAMINADORA**

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Thárcylla Rebecca Negreiros Clemente (Orientadora)  
Universidade Federal de Pernambuco – UFPE

---

Prof. Dr. José Leão e Silva Filho (Coorientador)  
Universidade Federal de Pernambuco - UFPE

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Ana Paula Henriques Gusmão de Araújo Lima (Examinadora Interna)  
Universidade Federal de Pernambuco - UFPE

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Veruschka Vieira Franca (Examinadora Externa)  
Universidade Federal de Sergipe - UFS

## AGRADECIMENTOS

Agradeço a Deus, pois sem Ele eu não conseguiria chegar até aqui. Ele é quem nos dá forças e nos permite caminhar em busca dos nossos objetivos.

Aos meus pais, Sandro Porto e Andrea Porto, por estarem sempre me apoiando durante toda a jornada até aqui e por continuarem me incentivando cada vez mais. Sou muito grato por todo o suporte e conselhos de vocês, que me moldaram. Tudo isso me motiva a querer ir mais longe. Eterna gratidão por serem quem vocês são na minha vida.

À minha irmã Maria Cecília que sempre deixou meus dias mais leves e descontraídos. Nossos momentos de conversas, mesmo que curtos, são muito bons e ajudam a esquecer os problemas.

À minha noiva Maria Luiza, por estar ao meu lado diariamente desde o início da graduação e segurar minha mão em todos os momentos. Todo seu apoio, compreensão, conselhos e companheirismo foram fundamentais para que eu nunca pensasse em desistir nas horas difíceis e para que as dificuldades fossem lidadas da melhor forma. Obrigado por sempre acreditar em mim, meu amor.

Ao meu avô José Ivan, que teve uma participação muito importante na minha vida com seus conselhos sábios, que me moldaram e hoje posso dizer que sou quem sou também pelos seus ensinamentos. Embora hoje, por problemas de saúde, o senhor não possa mais me dar seus conselhos, suas conversas me ajudam muito e saiba que nunca esquecerei seus ensinamentos.

Ao meu tio Lenildo Amorim, por me ajudar em vários momentos durante a graduação em que eu precisei de ajuda e sempre esteve à disposição. Nunca esquecerei.

A Zackinho, meu filhinho de 4 patas (*in memoriam*), por estar sempre presente com suas alegrias e animar todos os meus dias desde o início da graduação. Mesmo não estando mais aqui, as lembranças boas ficam e sempre lembrarei dos dias de estudos em que estava exausto, mas mesmo assim ele estava do meu lado, me fazendo feliz.

Aos meus professores e orientadores José Leão e Thárcylla Clemente, por compartilharem comigo seus conhecimentos, suas experiências e por seus conselhos sábios que me conduziram da melhor forma durante a trajetória acadêmica. Só tenho a agradecer todas as oportunidades que foram dadas, tentei aproveitar todas da melhor forma.

Aos meus amigos da graduação que fizeram o mestrado comigo, Josenildo e Ednael, pelos momentos descontraídos durante o curso.

Ao PPGEP/CAA e ao FACEPE, por fornecerem toda estrutura e apoio necessário.

## RESUMO

A distribuição eficiente de insumos alimentares para as escolas municipais de Caruaru-PE representa um desafio significativo para a gestão pública, considerando a diversidade de perfis das escolas e a necessidade de reduzir desperdícios alimentares. A identificação das unidades escolares, atualmente, é baseada pelo Território de Gestão Sustentável (TGS) a que a escola pertence, e não destaca as características e demandas de cada escola, o que pode gerar excesso ou escassez de recursos na alocação. Este estudo propõe o uso da clusterização como ferramenta para aprimorar essa gestão, agrupando as escolas conforme suas características. Utilizando o algoritmo K-Modes, adequado para dados categóricos, as escolas foram agrupadas conforme características como número de alunos, tipo da escola e demanda de refeições, permitindo uma gestão mais eficiente. Os resultados mostram que essa abordagem pode contribuir para uma gestão mais eficiente dos insumos alimentares, fornecendo suporte à Secretaria de Educação e Esportes (SEDUC) do Município de Caruaru-PE na tomada de decisões e promovendo uma distribuição mais adequada dos recursos.

**Palavras-chave:** gestão de insumos escolares; escolas municipais; alimentação escolar; clusterização; K-Modes; Caruaru-PE.

## ABSTRACT

The efficient distribution of food supplies to municipal schools in Caruaru-PE represents a significant challenge for public management, considering the diversity of school profiles and the need to reduce food waste. The identification of school units is currently based on the Sustainable Management Territory (SMT) to which the school belongs, and does not highlight the characteristics and demands of each school, which can generate excess or shortage of resources in the allocation. This study proposes the use of clustering as a tool to improve this management, grouping schools according to their characteristics. Using the K-Modes algorithm, suitable for categorical data, schools were grouped according to characteristics such as number of students, type of school, and demand for meals, allowing for more efficient management. The results show that this approach can contribute to more efficient management of food supplies, providing support to the Department of Education and Sports (DESMC) of the Municipality of Caruaru-PE in decision-making and promoting a more appropriate distribution of resources.

**Keywords:** management of school supplies; municipal schools; school meals; clustering; K-Modes; Caruaru-PE.

## LISTA DE ILUSTRAÇÕES

Figura 1 -	Planejamento de refeições escolares	20
Figura 2 -	Etapas básicas de análise de <i>cluster</i>	23
Figura 3 -	Agrupamento de classes em um dendograma de forma hierárquica	25
Figura 4 -	Exemplo de clusterização baseada em densidade	27
Figura 5 -	Mapa de calor da quantidade de escolas por cidade	31
Figura 6 -	Fronteiras das GREs do Estado de Pernambuco	32
Figura 7 -	Cidades com mais escolas no Estado de Pernambuco	33
Figura 8 -	Divisão dos TGSs de Caruaru-PE	34
Figura 9 -	Distribuição da população por região	34
Gráfico 1 -	Percentual de escolas nas zonas rural e urbana de Caruaru-PE	35
Figura 10 -	Localização das escolas municipais de Caruaru-PE	39
Figura 11 -	Combinações de palavras-chave	42
Figura 12 -	Processo de busca	43
Figura 13 -	Distribuição dos artigos ao longo dos anos	44
Figura 14 -	Quantidade de artigos por periódico	45
Figura 15 -	Quantidade de artigos por país	46
Gráfico 2 -	Distribuição das publicações por tipo de estudo	47
Figura 16 -	Etapas metodológicas	66
Figura 17 -	Localização das escolas do <i>cluster 1</i>	77
Figura 18 -	Localização das escolas do <i>cluster 2</i>	79
Figura 19 -	Localização das escolas do <i>cluster 3</i>	81
Figura 20 -	Localização das escolas do <i>cluster 4</i>	83
Figura 21 -	Localização das escolas do <i>cluster 5</i>	85

## LISTA DE TABELAS

Tabela 1 -	Quantidade de escolas por TGS	35
Tabela 2 -	Quantidade de alunos nas zonas rural e urbana de Caruaru-PE	35
Tabela 3 -	Quantidade de alunos por classificação nas escolas de Caruaru-PE	36
Tabela 4 -	Refeições disponibilizadas nas escolas municipais de Caruaru-PE	36
Tabela 5 -	Quantidade de alunos por tipo de escola de Caruaru-PE	37
Tabela 6 -	Quantidade de escolas por tipo de escola de Caruaru-PE	37
Tabela 7 -	Quantidade de alunos por porte das escolas de Caruaru-PE	37
Tabela 8 -	Quantidade de escolas por porte das escolas de Caruaru-PE	37
Tabela 9 -	Objetivos principais dos artigos analisados	49
Tabela 10 -	Metodologias/Ferramentas utilizadas pelos autores dos artigos	51
Tabela 11 -	Trabalhos mais relevantes identificados	55
Tabela 12 -	Principais referências de clusterização encontradas na literatura	61
Tabela 13 -	Características dos <i>clusters</i>	73
Tabela 14 -	Escolas pertencentes ao <i>cluster 1</i>	73
Tabela 15 -	Escolas pertencentes ao <i>cluster 2</i>	73
Tabela 16 -	Escolas pertencentes ao <i>cluster 3</i>	74
Tabela 17 -	Escolas pertencentes ao <i>cluster 4</i>	74
Tabela 18 -	Escolas pertencentes ao <i>cluster 5</i>	74
Tabela 1B -	Dados sobre as escolas municipais de Caruaru-PE	100

## LISTA DE ABREVIATURAS E SIGLAS

ACO	<i>Ant Colony Optimization</i>
AHP	<i>Analytic Hierarchy Process</i>
BiA	<i>Bat-inspired Algorithm</i>
CLIQUE	<i>Clustering in Quest</i>
CMEI	Centro Educacional de Educação Infantil
CNPNA	Conselho Nacional de Pesquisa Norte Americano
CS	<i>Cuckoo Search</i>
DBSCAN	<i>Density-Based Spatial Clustering of Applications with Noise</i>
DEA	<i>Data Envelopment Analysis</i>
DTM	<i>Decision Tree Model</i>
EJA	Educação de Jovens e Adultos
EM	Escola Municipal
ETI	Escola de Tempo Integral
FNDE	Fundo Nacional de Desenvolvimento da Educação
GA	<i>Genetic Algorithm</i>
GRE	Gerência Regional de Educação
GWO	<i>Gray Wolf Optimizer</i>
HS	<i>Harmony Search</i>
IA	Inteligência Artificial
IBGE	Instituto Brasileiro de Geografia e Estatística
ID	Identificação
Idr	Imagem de dissimilaridade reordenada
IDS	<i>Intrusion Detection System</i>
INEP	Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira
IoT	<i>Internet of Things</i>
Kh	<i>Krill Herd</i>
Kg	Quilograma
KPI	<i>Key Performance Indicator</i>
MCDM	<i>Multi-Criteria Decision Making</i>
MFA	<i>Material Flow Analysis</i>
NSLP	<i>National School Lunch Program</i>
PNAE	Programa Nacional de Alimentação Escolar

PSO	<i>Particle Swarm Optimization</i>
SEDUC	Secretaria de Educação e Esportes
SI	Swarm Intelligence
SWOT	<i>Strenghts, Weaknesses, Oportunities, Threats</i>
TGS	Território de Gestão Sustentável
VRPCDD	<i>Vehicle Routing Problem with a common due date</i>
WFP	<i>World Feeding Program</i>
WoS	<i>Web of Science</i>

## LISTA DE SÍMBOLOS

$\cup$	Conjunto união
$\mathbb{R}$	Conjunto dos números reais
$\neq$	Desigualdade
$=$	Igualdade
$\leq$	Menor que ou igual
$\{ \}$	Conjunto de números
$\in$	Pertence
$\forall$	Para todo ou para qualquer que seja
$( )$	Agrupar números
$\sqrt{\quad}$	Raíz quadrada
$\Sigma$	Somatório
$ x $	Valor absoluto em $x$

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
1.1	OBJETIVOS	16
<b>1.1.1</b>	<b>Objetivo geral</b>	<b>16</b>
<b>1.1.2</b>	<b>Objetivos específicos</b>	<b>16</b>
1.2	JUSTIFICATIVA E RELEVÂNCIA DO TRABALHO	16
1.3	ESTRUTURA DO TRABALHO	18
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>19</b>
2.1	GESTÃO DE ALIMENTAÇÃO ESCOLAR	19
2.2	MÉTODOS DE CLUSTERIZAÇÃO	22
<b>2.2.1</b>	<b>Classificação dos algoritmos de clusterização</b>	<b>24</b>
2.2.1.1	Clusterização hierárquica	24
2.2.1.2	Clusterização baseada em densidade	26
2.2.1.3	Clusterização baseada em grade	27
2.2.1.4	Clusterização particional	28
<b>2.2.2</b>	<b>Algoritmo K-Modes</b>	<b>29</b>
2.3	O CONTEXTO ESCOLAR DE CARUARU E PERNAMBUCO	31
<b>3</b>	<b>REVISÃO DA LITERATURA</b>	<b>40</b>
3.1	REVISÃO DA LITERATURA SOBRE ALIMENTAÇÃO ESCOLAR	40
<b>3.1.1</b>	<b>Metodologia de pesquisa da revisão</b>	<b>40</b>
3.1.1.1	Coleta de dados na revisão de literatura	41
3.1.1.2	Análise descritiva	44
<b>3.1.2</b>	<b>Avaliação dos artigos selecionados</b>	<b>47</b>
3.1.2.1	Discussões sobre as metodologias encontradas	51
<b>3.1.3</b>	<b>Trabalhos mais relevantes identificados</b>	<b>55</b>
3.2	REVISÃO SOBRE ALGORITMOS DE CLUSTERIZAÇÃO	57
<b>3.2.1</b>	<b>Métodos e algoritmos de clusterização</b>	<b>60</b>
<b>4</b>	<b>METODOLOGIA</b>	<b>64</b>
4.1	NATUREZA DA PESQUISA	64
4.2	CLASSIFICAÇÃO DA PESQUISA	64
4.3	PROCEDIMENTOS DE COLETA DE DADOS	64
4.4	DESCRIÇÃO METODOLÓGICA DAS ETAPAS DO ESTUDO	65

<b>5</b>	<b>APLICAÇÃO DO K-MODES PARA CLUSTERIZAÇÃO DAS ESCOLAS</b>	<b>67</b>
5.1	ANÁLISE CONTEXTUAL DO PROBLEMA ESTUDADO	67
5.2	ESCOLHA DO ALGORITMO DE ACORDO COM AS CARACTERÍSTICAS DO PROBLEMA	69
5.3	DESCRIÇÃO DAS ESCOLAS	70
5.4	APLICAÇÃO DO K-MODES	70
5.5	PROPOSTAS GERENCIAIS PARA A GESTÃO DOS INSUMOS ALIMENTARES	75
5.6	DISCUSSÃO SOBRE OS CLUSTERS FORMADOS	86
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>87</b>
6.1	CONCLUSÃO	87
6.2	LIMITAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS	87
	<b>REFERÊNCIAS</b>	<b>89</b>
	<b>ANEXO A – DECLARAÇÃO DE APOIO E INTERESSE PELO PROJETO DE PESQUISA</b>	<b>99</b>
	<b>ANEXO B – ESCOLAS MUNICIPAIS DA CIDADE DE CARUARU-PE E SUAS CARACTERÍSTICAS</b>	<b>100</b>

## 1 INTRODUÇÃO

As instituições de ensino estão presentes em grande parte do dia dos estudantes, oferecendo os serviços de educação básica, ensino fundamental e ensino médio. Além das atividades educacionais, muitas escolas são encarregadas do processo de alimentação e desenvolvimento desses jovens. A merenda escolar faz parte da rotina de estudantes em todo o Brasil (SANTOS, 2024). Este tipo de insumo pode ser representado por uma ou mais refeições oferecidas aos estudantes no turno matutino, vespertino ou noturno, e deve ser consumido em ambiente adequado nas dependências das escolas como forma de apoiá-los a realizar as atividades escolares, diariamente. A merenda é um alimento que serve como combustível para que o estudante possa render o dia todo nas suas atividades educacionais (DAMATTA, 1997).

Conseqüentemente, é necessário que os insumos alimentícios não faltem durante a jornada escolar. No Brasil, o Programa Nacional de Alimentação Escolar (PNAE) está diretamente relacionado com essa gestão, que foi estabelecido na década de 50 para contribuir com o desenvolvimento dos estudantes, aprendizagem, rendimento escolar e a instrução da alimentação saudável (CIVIL, 2009). Contudo, para que as exigências do PNAE sejam cumpridas, no quesito de não faltar insumos, é necessário que haja a gestão desde o pedido dos insumos até a distribuição das refeições completas.

Alguns dos pontos que costumam ser discutidos sobre esses recursos são: a frequência de consumo, a quantidade demandada, a distribuição dos insumos e das refeições, a qualidade dos alimentos e suas datas de validade. A partir desses pontos, alguns processos podem ser assumidos como fundamentais para uma boa gestão dos insumos, como: o gerenciamento do consumo, a distribuição logística dos insumos, o armazenamento dos insumos, o relacionamento ao longo da cadeia de suprimentos, o planejamento envolvendo a oferta dos insumos, a demanda e a taxa de consumo dos alimentos (SANTOS, 2023).

À Secretaria de Educação e Esportes (SEDUC) da cidade de Caruaru-PE, localizada no Estado de Pernambuco, compete garantir o acesso da população à educação básica e manter a rede pública municipal de ensino, além de elaborar, implantar e acompanhar políticas educacionais voltadas para a melhoria da qualidade do ensino, e desenvolver políticas de ampliação do acesso à educação integral (SIEC, 2024). Dentre suas atribuições, a SEDUC do município de Caruaru-PE tem o compromisso e a responsabilidade de fazer a gestão de alimentação escolar em toda a rede municipal.

Caruaru-PE é o município que possui o terceiro maior número de escolas municipais

registradas no Estado de Pernambuco, e por tal abrangência, a gestão de alimentação escolar é conduzida por uma coordenação específica vinculada à SEDUC. Segundo os registros da referida secretaria, os insumos para as merendas escolares são distribuídos seguindo um cardápio nutricional semanal e é feita independente da classificação do porte da escola (pequeno, médio ou grande), ou o tipo de regime de atividades (integral ou não integral).

As escolas do referido município são agrupadas e gerenciadas pelo sistema baseado em Território de Gestão Sustentável (TGS), que totalizam 9 (nove) regiões geográficas classificadas entre região urbana e região rural. A informação do TGS a qual a escola pertence é utilizada para direcionar os insumos que serão destinadas a ela. No entanto, é oportuno considerar outros critérios de descrição e avaliação para definir a real necessidade da escola, a fim de melhorar indicadores de desempenho como o custo dessa operação, a entrega ideal dos insumos e a redução de desperdícios pelo possível desequilíbrio da oferta, número de estudantes e taxa de consumo das refeições.

Por tal oportunidade, a presente pesquisa propõe uma metodologia capaz de agregar informações sobre o perfil das escolas em estudo. A resolução do problema de clusterização de dados consiste na classificação não supervisionada de objetos *clusters*, não sendo necessário um conhecimento prévio sobre as suas classes ou categorias (JAIN; DUBES, 1988), onde seu objetivo é obter grupos que apresentem padrões semelhantes e que possam refletir a forma como os dados são estruturados. Para isso, deve-se maximizar a similaridade entre os objetos de um mesmo grupo e minimizar a similaridade entre objetos de grupos distintos (HAN; KAMBER, 2006).

Por essa perspectiva, é proposto o uso do algoritmo de clusterização K-Modes para obter-se grupos de escolas que apresentem características semelhantes entre si. O uso de algoritmos de clusterização para problemas que envolvem esse contexto da alimentação escolar ainda é escasso na literatura, assim como não há muitos estudos sobre o tema onde o foco seja em melhoria na gestão e distribuição dos alimentos, e o uso de ferramentas e métodos de engenharia para a gestão no ambiente escolar, o que eleva a contribuição deste estudo para a literatura e para a aplicação na gestão pública.

Dessa forma, o algoritmo é capaz de auxiliar no estabelecimento de *clusters* que fornecerão a SEDUC informações que permitem melhorar a visão sistêmica do processo de distribuição de alimentos nas escolas do município de Caruaru-PE. Com isso, pretende-se fornecer informações úteis para que a gestão pública possa desenvolver ações eficientes sobre o gerenciamento de insumos para os ambientes escolares, apoiando-se nos resultados de agrupamento para lidar com as principais dificuldades enfrentadas no processo, assim como

apoiar-se na solução encontrada para diferenciar as escolas por perfis.

## 1.1 OBJETIVOS

### 1.1.1 Objetivo geral

O objetivo geral deste trabalho é fornecer informações para o gerenciamento e distribuição de insumos de alimentos escolares, focando em ações eficientes de gestão, baseado em agrupamento por perfis de escolas do município de Caruaru-PE.

### 1.1.2 Objetivos específicos

Para o alcance do objetivo geral, foram definidos os seguintes objetivos específicos:

- Coletar dados referentes ao contexto das escolas do município de Caruaru-PE;
- Elaborar uma análise descritiva sobre o contexto das escolas do município de Caruaru-PE;
- Listar os principais critérios ou métodos que são utilizados no gerenciamento da distribuição dos alimentos nas escolas e os principais problemas que existem envolvendo alimentos no ambiente escolar;
- Definir padrões de identificação dos perfis das escolas em estudo; e,
- Aplicar o algoritmo de clusterização e definir regras de agrupamento baseadas em semelhanças entre as escolas em estudo.

## 1.2 JUSTIFICATIVA E RELEVÂNCIA DO TRABALHO

Nos últimos anos, segundo dados coletados do Instituto Brasileiro de Geografia e Estatística (IBGE), tem-se observado um aumento na população brasileira, onde chegou a 203,1 milhões em 2022, com aumento de 6,5% frente ao censo demográfico anterior, realizado em 2010 (IBGE, 2023). Isso impacta também no número de estudantes, onde de acordo com o Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), existem 47,3 milhões, considerando todas as etapas educacionais, distribuídos em 178,5 mil escolas (INEP, 2024). A rede municipal é a principal responsável pela oferta dos anos iniciais do fundamental: são 10,1 milhões de estudantes (69,3%), o que corresponde a 85,5% da rede pública (INEP, 2024).

O número de estudantes é muito alto, e com esse aumento, deve haver uma maior preocupação no quesito da distribuição de insumos (refeições) para os alunos de escolas públicas, pois os impactos negativos caso não haja a gestão desses insumos, pode ser em larga escala, devido a quantidade de estudantes que utilizam esse benefício.

Em contrapartida, o desperdício alimentar, que é quando um alimento próprio para uso é descartado (ARAÚJO; ROCHA, 2017), é um fator que também deve ser levado em consideração, pois é algo que sempre ocorre nas escolas com alguns alimentos e o descarte dependendo da escola e do alimento, é em excesso (RIBEIRO; ROCHA, 2019). O desperdício ocorre se a quantidade entregue nas escolas ultrapassar o necessário, não sendo interessante que esses mesmos alimentos que são desperdiçados, continuem com a oferta maior que a demanda. Isso é um motivo para que a gestão pública tenha ciência e saiba a quantidade que deve ser entregue em cada escola, visando evitar o desperdício.

Uma forma de auxiliar a gestão pública no gerenciamento e distribuição de alimentos escolares é utilizando métodos e algoritmos eficazes que levem em conta as características das escolas e que as classifique em grupos de afinidade, onde os grupos mostram semelhanças entre as instituições e isso pode servir como ferramenta de apoio a decisão, possibilitando melhorias no sistema de distribuição de alimentos (FERNANDES; FONSECA, 2014). Os métodos de clusterização são úteis para problemas em que há vários objetos com diferentes perfis e que pretende-se agrupá-los por afinidades. Entre os vários algoritmos encontrados na literatura, o K-Modes estende o algoritmo K-Means, usando uma medida de dissimilaridade de correspondência simples para variáveis categóricas, utilizando modas em vez de médias para montagem dos *clusters*, além de um método baseado em frequência para minimizar a função de custo na clusterização (NG *et al.*, 2007).

Existem poucos trabalhos que envolvem gestão de alimentação escolar considerando a área da engenharia (FARIAS *et al.*, 2024a) com o foco na distribuição satisfatória dos insumos. No entanto, a exemplo do trabalho de FARIAS *et al.* (2024b), a maior parte dos trabalhos encontrados abordam a problemática de distribuição de alimentos utilizando métodos de roteirização, em que são consideradas variáveis como a capacidade dos caminhões de volume de carga e o tempo disponível para entregar o que é demandado. Não há discussões sobre os diferentes perfis das escolas.

Neste contexto, este trabalho propõe uma abordagem para a gestão da distribuição de alimentos, agrupando as escolas com perfis semelhantes com base em variáveis operacionais, como o porte, o número de alunos e a quantidade de refeições servidas. Dessa forma, a clusterização oferece uma alternativa mais alinhada com as necessidades específicas de cada

escola, contribuindo para a redução do desperdício e uma gestão de insumos alimentares mais estratégica.

### 1.3 ESTRUTURA DO TRABALHO

O presente estudo está estruturado em 6 capítulos:

- No Capítulo 1, é apresentada a Introdução, que contém em sua estrutura toda a contextualização do que é abordado no estudo e os conceitos que serão desenvolvidos;
- No Capítulo 2, são apresentadas as fundamentações teóricas, que trarão embasamento para os conceitos que serão utilizados ao longo do estudo;
- No Capítulo 3, são apresentadas as revisões da literatura referentes a problemáticas e metodologias utilizadas na literatura e aos métodos de clusterização;
- No Capítulo 4, são apresentados os procedimentos metodológicos necessários para a realização do presente estudo;
- No Capítulo 5, são apresentados a descrição do problema, aplicação do algoritmo para montagem dos *clusters* e o direcionamento da gestão baseado nos resultados;
- No Capítulo 6, é apresentada a conclusão e considerações finais do trabalho.

Por fim, são listadas as referências bibliográficas e os anexos utilizados para esse trabalho.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, são apresentados os principais conceitos que fundamentam o entendimento sobre a gestão de alimentação escolar relacionada com a administração pública, a clusterização como ferramenta utilizada para auxiliar a gestão e o contexto escolar da cidade de Caruaru no Estado de Pernambuco.

### 2.1 GESTÃO DE ALIMENTAÇÃO ESCOLAR

Um dos primeiros estudos envolvendo gestão de alimentos foi o de Stigler (1945), onde o autor desenvolveu um dos principais estudos sobre o problema da dieta e que direcionou muitos estudos servindo como base. Nesse estudo, o autor realizou um estudo que tinha como objetivo definir a dieta de custo mínimo, tal que fosse possível alimentar um homem de 70kg, considerando os requisitos mínimos nutricionais exigidos na época pelo Conselho Nacional de Pesquisa Norte Americano (CNPNA). Com os alimentos fazendo parte da rotina de milhares de estudantes e com os diversos desafios que ocorrem tanto em questões logísticas, financeiras, operacionais e até mesmo em questões nutricionais como visto por Stigler (1945), estudos foram feitos relacionados a gestão desses alimentos.

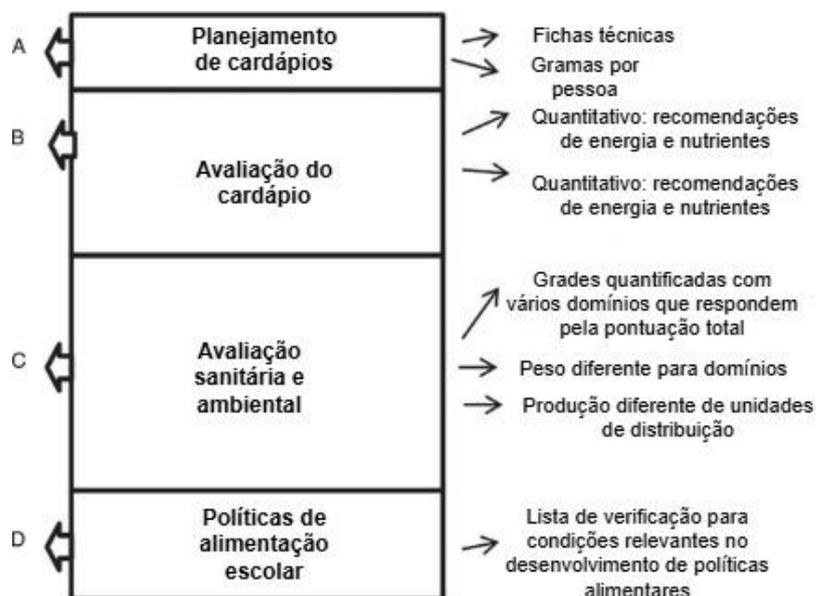
A alimentação escolar, com base em Issa *et al.* (2014), tem papel fundamental no processo de aprendizado dos alunos, e com isso, a administração pública do quesito da alimentação nas escolas torna-se uma ferramenta importante para que os objetivos sejam atingidos. A gestão de alimentos nas escolas públicas depende não somente de uma boa administração pública financeiramente, mas também de uma boa gestão operacional por parte dos envolvidos. A Resolução nº 06 de 2020 do Fundo Nacional de Desenvolvimento da Educação (FNDE) dispõe sobre o fornecimento da alimentação escolar aos estudantes da educação básica no âmbito do PNAE.

O repasse da verba para a aquisição de alimentos é feito pelo governo federal por meio do PNAE, onde toda a verba passada só pode ser exclusivamente utilizada para este fim. Contudo, para a distribuição de alimentos ocorrer, não requer apenas o lado financeiro, mas também a contratação de mão de obra, compra de equipamentos e supervisão dos alimentos de acordo com as normas de vigilância sanitária, para garantir a qualidade e validade dos alimentos estocados e garantir que cheguem como planejado a escola e aos estudantes (RODRIGUES; COSTA, 2021).

A Figura 1 apresenta um exemplo de como seria uma gestão de alimentos escolares

como resultado de fases subsequentes, desde a aquisição de ingredientes até a preparação das refeições, transporte e entrega para as escolas e, finalmente, descarte de sobras.

Figura 1 - Planejamento de refeições escolares



Fonte: Adaptado de Rocha *et al.* (2014)

A preocupação com questões de gestão da merenda escolar tem estimulado pesquisadores a desenvolver trabalhos em diferentes aspectos, abordando diferentes problemáticas. Uma das problemáticas é o fator custo, que estão contidos nas refeições, variando de acordo com as mesmas. O que diferencia o tipo de refeição são os tipos de alimentos e também a quantidade de vezes que cada refeição é servida.

Para o PNAE, Saraiva *et al.* (2013) realizaram um estudo sobre o cenário da compra de alimentos da agricultura familiar e Amorim *et al.* (2020) divulgaram estratégias como suporte ao PNAE para lidar com a insegurança alimentar durante e após a COVID-19. Cruz *et al.* (2013) desenvolveram um estudo que envolveu otimização na elaboração de cardápios para uma creche, onde o foco do estudo foi minimizar os custos, respeitando restrições que maximizam o número de vitaminas A e C dos alimentos. Os autores utilizaram o método de ponderação da função objetivo do problema e como resultado tiveram 18 cardápios propostos que atendem à dieta.

A montagem dos cardápios é muito importante pois deve seguir rigorosamente os padrões estabelecidos, onde lidar com essas restrições torna-se um grande desafio, fazendo pesquisadores realizarem estudos de gestão de alimentação escolar envolvendo otimização de cardápios, como: Moreira *et al.* (2015); Silva *et al.* (2017) e Silva (2019). Moreira *et al.*

(2015) propõem algoritmos genéricos para realizar a elaboração de cardápios em escolas de forma automatizada atendendo os requisitos do PNAE. Silva *et al.* (2017) estudaram uma variação do problema iniciado por Stigler (1945), onde os autores propõem uma dieta restringindo alguns nutrientes de forma que a saúde do indivíduo não fosse comprometida e concluíram que o algoritmo genético é o mais eficiente para esse tipo de problema. Já Silva (2019) em seu trabalho apresentou um problema de montagem de cardápios que se limitava ao que tinha em estoque apenas, onde o algoritmo genético também foi utilizado.

Planejar o que vai ser ofertado aos alunos está presente em muitas problemáticas. O planejamento é de grande importância para o gerenciamento dos alimentos escolares, pois permite que haja um controle do que precisa ser ofertado (AMARO COSTA *et al.*, 2020). Ainda de acordo com Amaro Costa *et al.* (2020), esse planejamento promove segurança e qualidade na tomada de decisão, o que é essencial para garantir que não falem alimentos aos estudantes. A falta de insumos escolares para as refeições diárias pode acarretar complicações no desenvolvimento dos estudantes, o que reforça a necessidade de coordenar as cadeias desses produtos (FERREIRA; PADULA, 1998).

Por fim, falando de gestão de alimentos escolares de maneira geral, Setyaningtyas *et al.* (2022) geriram serviços de alimentação e aceitação para crianças com ingestão alimentar desequilibrada em uma escola primária de período integral. Anderson *et al.* (2018) testaram se oferecer refeições mais saudáveis afeta o desempenho dos alunos, medido pelas notas dos testes. Ouellette *et al.* (2024) propõem métodos de distribuição escolar, tipos de refeições e procedimentos de segurança alimentar após o fechamento das escolas na COVID-19, que continuou fornecendo merenda para os estudantes, mesmo estando fechadas.

Como exposto, a gestão de alimentos em ambientes escolares é um requisito fundamental para a sustentabilidade da prestação dos serviços educacionais. Em grande parte dos casos, a oferta de refeições assegura a continuidade da formação dos estudantes e oferece segurança nutricional para a comunidade. No entanto, para auxiliar a gestão na elaboração de ações eficientes sobre a distribuição dos insumos necessários ao processo de preparo das refeições, é oportuno o conhecimento sobre o perfil de oferta das escolas, que pode ser identificado por características estruturais como a quantidade de estudantes matriculados, a quantidade de refeições oferecidas, o regime de atividades, dentre outros.

Para identificar os diferentes perfis das escolas, algumas metodologias podem ser utilizadas, dentre elas os métodos de clusterização que propõem o agrupamento de elementos semelhantes em uma mesma categoria, sem definição prévia.

## 2.2 MÉTODOS DE CLUSTERIZAÇÃO

Clusterização, ou agrupamento, é o processo de agrupar um conjunto de objetos em *clusters* de modo que os objetos dentro de um *cluster* sejam semelhantes entre si, mas sejam diferentes dos objetos em outros *clusters* (HAN, 2001). Para Wang (2010), clusterização é uma ferramenta matemática que tenta descobrir estruturas ou certos padrões em um conjunto de dados, onde os objetos dentro de cada *cluster* mostram um certo grau de similaridade. Na estrutura da clusterização *fuzzy*, de acordo com Wang (2010), permite que cada vetor de características pertença a mais de um *cluster* com diferentes graus de associação (entre 0 e 1) e limites vagos ou *fuzzy* entre os *clusters*.

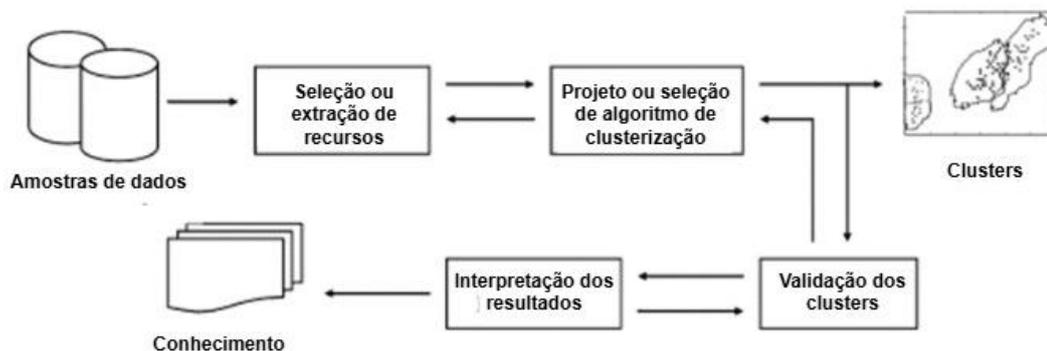
O primeiro registro de publicação sobre um método que aplicou a clusterização foi sobre o Método Hierárquico de Ligação (SORENSEN, 1948), e desde lá, centenas de outras aplicações e algoritmos foram criados.

O problema da clusterização é sobre particionar um dado conjunto de dados em *clusters* de forma que os pontos de dados em um *cluster* sejam mais semelhantes entre si do que pontos em *clusters* diferentes (GUHA *et al.*, 1998). Hruschka & Ebecken (2001) definiram como seria representado o problema de clusterização considerando um conjunto  $n$  de objetos  $X = \{X_1, X_2, \dots, X_n\}$ , onde cada  $X_i \in \mathbb{R}^p$  é um vetor de  $p$  medidas reais que dimensionam as características do objeto, no qual estes são clusterizados em  $k$  *clusters* disjuntos  $C = \{C_1, C_2, \dots, C_k\}$ , de forma que tenha-se as seguintes condições:

- $C_1 \cup C_2 \cup \dots \cup C_k = X$ ;
- $C_i \neq 0, \forall i, 1 \leq i \leq k$ ;
- $C_i \cap C_j = \emptyset, \forall i \neq j, 1 \leq i \leq k, 1 \leq j \leq k$ .

Dessa forma, de acordo com as condições descritas acima, um objeto não pode pertencer a mais de um *cluster* e que cada *cluster* deve conter pelo menos um objeto. Assume-se ainda que o valor de  $k$  é desconhecido, pois se for conhecido, o problema é referido como o problema de  $k$ -Clusterização (COLE, 1998).

A Figura 2 apresenta as etapas que consistem na análise de *cluster* com um caminho de *feedback*, onde essas etapas estão intimamente relacionadas entre si e afetam os *clusters* derivados.

Figura 2 - Etapas básicas de análise de *cluster*

Fonte: Adaptado de Xu e Wunsch (2005).

Xu e Wunsch (2005) fazem uma breve descrição de como são as etapas:

- Seleção de recursos ou extração: A seleção de recursos escolhe recursos que se diferenciam entre um conjunto de candidatos, enquanto a extração de recursos utiliza algumas transformações para gerar recursos úteis e novos a partir dos originais;
- Projeto ou seleção de algoritmo de clusterização: É geralmente combinado com a seleção de uma medida de proximidade correspondente e a construção de uma função de critério. Os padrões são agrupados de acordo com a semelhança em si, onde a medida de proximidade afeta diretamente a formação dos *clusters* resultantes;
- Validação do *cluster*: Padrões e critérios de avaliação eficazes são importantes para fornecer aos usuários um grau de confiança para os resultados de clusterização derivados dos algoritmos usados. Essas avaliações devem ser objetivas e não ter preferências por nenhum algoritmo. Além disso, devem ser úteis para responder a perguntas: Quantos *clusters* estão ocultos nos dados?; Os *clusters* obtidos são significativos?; Por que escolher algum algoritmo em específico em vez dos demais?;
- Interpretação dos resultados: O objetivo final da clusterização é fornecer aos usuários *insights* significativos dos dados originais, para que eles possam efetivamente resolver os problemas encontrados.

Uma das limitações do processo de clusterização é que encontrar o melhor agrupamento para um conjunto de dados não é algo fácil (HRUSCHKA; EBECKEN 2001). De acordo com os autores, esse problema é NP-completo e não é computacionalmente possível encontrá-lo, a não ser que  $n$  (quantidade de objetos) e  $k$  (quantidade de *clusters*)

sejam extremamente pequenos, no qual o número de partições distintas em que pode-se dividir  $n$  objetos em  $k$  *clusters* aumenta aproximadamente como  $\frac{k^n}{n!}$ .

### 2.2.1 Classificação dos algoritmos de clusterização

De acordo com o método adotado para definir *clusters*, os algoritmos podem ser amplamente classificados nos seguintes tipos, como sendo os principais (JAIN *et al.*, 1999):

- Clusterização hierárquica (*hierarchical clustering*): Mescla *clusters* menores em maiores ou divide os *clusters* maiores. O resultado do algoritmo é uma árvore de *clusters*, chamada dendrograma, que mostra como os *clusters* estão relacionados. Ao cortar o dendrograma em um nível desejado, um agrupamento dos itens de dados em grupos disjuntos é obtido.
- Clusterização baseada em densidade (*density-based clustering*): Tem como ideia principal o agrupamento de objetos vizinhos de um conjunto de dados em *clusters* com base nas condições de densidade.
- Clusterização baseada em grade (*grid-based clustering*): É proposta principalmente para mineração de dados espaciais. Sua principal característica é que eles quantizam o espaço em um número finito de células e então eles fazem todas as operações no espaço quantizado.
- Clusterização particional (*partitional clustering*): Tenta decompor diretamente o conjunto de dados em um conjunto de *clusters* disjuntos. Mais especificamente, eles tentam determinar um número inteiro de partições que otimizam uma determinada função de critério. A função de critério pode enfatizar a estrutura local ou global dos dados e sua otimização é um procedimento iterativo.

Porém, de acordo com Han & Kamber (2001), alguns algoritmos de clusterização integram as ideias de outros, tornando difícil muitas vezes classificar um algoritmo como pertencente a uma única categoria de clusterização.

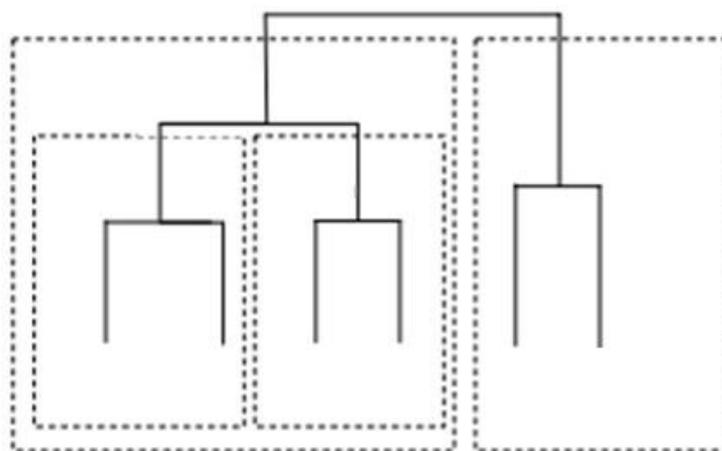
#### 2.2.1.1 Clusterização hierárquica

Já na década de 1970, acreditava-se que cerca de 75% de todo o trabalho publicado sobre clusterização empregava algoritmos hierárquicos (MURTAGH; CONTRERAS, 2012). Os métodos tradicionais de clusterização hierárquica consistem em identificar *clusters*

homogêneos progressivamente, por meio da junção ou separação de *clusters* anteriores na amostra (CARVALHO *et al.*, 2009). O critério para a formação de *clusters* é a distância entre eles, no qual a distância pode ser adotada de diversas formas. Ainda de acordo com os autores, ela pode ser feita de forma aglomerativa - iniciando com alguns *clusters* e objetos e então unindo-os em novos *clusters* - ou divisiva - iniciando com um *cluster* apenas e dividindo-o em novos *clusters*.

Os resultados são normalmente mostrados como uma árvore binária ou dendograma (tipo específico de diagrama que organiza fatores e variáveis e divide a base de dados em subconjuntos menores). A Figura 3 representa como é um dendograma, onde a raiz representa o conjunto de dados e os nós representam os indivíduos, e percebe-se também que o dendograma pode ser “cortado” em diferentes níveis dependendo do número  $k$  de *clusters* requeridos.

Figura 3 - Agrupamento de classes em um dendograma de forma hierárquica



Fonte: Adaptado de Benanni e Benabdeslem (2006)

Com base no estudo de Cassiano (2014), o dendograma pode ser criado de duas formas:

- Abordagem aglomerativa (*bottom-up*). O início ocorre considerando cada objeto como sendo um *cluster*. Em cada etapa, calcula-se a distância entre cada par de *clusters*, e essas distâncias são geralmente armazenadas em uma matriz de dissimilaridade simétrica. Por fim, escolhe-se 2 *clusters* com a distância mínima, une-os e atualiza a matriz de distâncias. Este processo continua até que todos os objetos estejam em um único *cluster* (o nível mais alto da hierarquia), ou até que uma condição de término ocorra.

- Abordagem divisiva (*top-down*). Nesta abordagem, o processo é o inverso da abordagem *bottom-up*, por começar com todos os objetos em um único *cluster*. Em cada etapa, um *cluster* é escolhido e dividido em dois *clusters* menores. Este processo continua até que se tenham  $n$  *clusters* ou até que uma condição de término ocorra.

Os autores Zhang *et al.* (1996) afirmam em seu estudo que a melhor estimativa para a complexidade de um algoritmo prático por método hierárquico é  $O(n^2)$ , ou seja, se  $n$  for muito grande, o algoritmo vai ser ineficiente para o problema. Os algoritmos hierárquicos mais conhecidos são o de link único (*single-link*) e o de link completo (*complete-link*) (JAIN, 2010).

#### 2.2.1.2 Clusterização baseada em densidade

A maioria dos métodos particionais de clusterização trabalha com base na distância entre os objetos, e esses métodos podem encontrar dificuldades para descobrir *clusters* de formas arbitrárias, por outro lado, nos métodos de clusterização baseados em densidade, os *clusters* são definidos como regiões densas, separadas por regiões menos densas que representam ruídos (CASSIANO; PESSANHA, 2014). As regiões densas podem ter uma forma arbitrária e os pontos dentro de uma região podem também estar distribuídos arbitrariamente e, por isso, os métodos baseados em densidade são considerados mais apropriados para filtrar ruídos e descobrir *clusters* com forma arbitrária, tais como elíptica, cilíndrica e espiralada, até os completamente cercados por outro “*cluster*” (HAN; KAMBER, 2001).

Os autores Ester *et al.* (1996) observam ao visualizar um conjunto de objetos como pode ser visto na Figura 4, é possível detectar *clusters* circulares no conjunto 1, *clusters* de formatos arbitrários no conjunto 2 e *clusters* de ruídos não pertencentes a qualquer dos *clusters* no conjunto 3. De acordo com a percepção que pode ser percebida ao observar a Figura 4, é notável que há uma densidade de objetos dentro de cada *cluster* que é claramente maior do que fora deles.

O algoritmo DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) é um exemplo de algoritmo de densidade que até hoje é um dos mais utilizados, no qual cria grupos de objetos em regiões de alta densidade e é capaz de descobrir grupos de formatos arbitrários em bases de dados espaciais e com ruídos. Para o DBSCAN, um grupo é definido como um conjunto máximo de pontos conectados por densidade (OLIVEIRA, 2007).

Figura 4 - Exemplo de clusterização baseada em densidade



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

O DBSCAN é um algoritmo de clusterização que se baseia na densidade de pontos proposto por Ester *et al.* (1996), onde agrupa pontos próximos em *clusters* e ignora regiões onde a densidade de pontos é baixa (pontos muito espaçados entre si). Uma das vantagens desse algoritmo é que é capaz de identificar *clusters* de forma arbitrária, sem necessidade de definir anteriormente a quantidade de *clusters* a serem formados, além de não ser prejudicado pela presença de *outliers*. Ou seja, são utilizados quando os dados contém *outliers* e/ou ruídos, quando os *clusters* possuem formas diferentes do convencional (esféricas) e quando não é possível definir a quantidade de *clusters* a ser formado pelo algoritmo.

### 2.2.1.3 Clusterização baseada em grade

Os métodos baseados em grade dividem os objetos em um número finito de células que formam uma estrutura de grade multidimensional na qual todas as operações de agrupamento são realizadas (FERREIRA *et al.*, 2010). De acordo com Han & Kamber (2006), a principal vantagem do método é que as operações independem do número de objetos da base de dados, e sim do número de células da estrutura da grade, o que melhora o desempenho dos algoritmos baseados nesta heurística.

Um exemplo de algoritmo baseado em grade é o algoritmo CLIQUE (*Clustering in Quest*) (AGRAWAL *et al.*, 1998), que é baseado em grade e em densidade. O algoritmo particiona o conjunto de dados em subespaços (grade de células) para encontrar agrupamentos suficientemente densos. Cada grade organiza um conjunto de dados, separando os valores contínuos de cada atributo em um número de intervalos discretos. Por fim, cada objeto é atribuído a uma célula a qual seu intervalo contém o valor original do objeto (FERREIRA *et al.*, 2010).

#### 2.2.1.4 Clusterização particional

Os algoritmos que fazem parte deste grupo dividem a base de dados em  $k$ -grupos, onde o número  $k$  é dado pelo usuário (ESTER *et al.*, 1996).

O algoritmo inicialmente escolhe  $k$  objetos para servir como centros de  $k$  *clusters*. A medida de similaridade utilizada divide os objetos em  $k$  *clusters*, com cada um representando o menor valor de distância entre ele e seu centro. O algoritmo então determina que objetos devem mudar de *cluster* usando uma estratégia de controle iterativa. Isso faz com que a função objetivo seja otimizada. Após a divisão inicial, há duas possibilidades na escolha do “elemento” que vai representar o centro do *cluster*: ou utiliza-se a média dos objetos que pertencem ao *cluster* em questão, também chamada de centro de gravidade do *cluster* (esta é a abordagem conhecida como K-Means); ou escolhe como representante o objeto que se encontra mais próximo ao centro de gravidade do *cluster* (abordagem é conhecida como *k-medoids*), sendo o elemento mais próximo ao centro chamado de *medoid* (CASSIANO, 2014).

O algoritmo K-Means (MACQUEEN, 1967) é uma técnica bastante conhecida para realizar agrupamentos não hierárquicos e é o mais popular algoritmo particional. Foi descoberto independentemente em diferentes campos científicos por Steinhaus (1956) e ainda é um dos algoritmos mais utilizados por sua facilidade de implementação, simplicidade e eficiência (JAIN, 2010).

A ideia do K-Means é dividir a base de dados em  $k$  *clusters* que tenham instâncias semelhantes, considerando uma medida de similaridade, similaridade essa que entre duas amostras, é medida utilizando uma função de distância euclidiana duas amostras  $x_i$  e  $x_j$  (DE ARAÚJO AGUIAR *et al.*, 2018), onde  $d$  representa a distância entre elas, conforme Equação 1.

$$d(x_i, x_j) = \sqrt{\sum_{p=1}^d (x_{i,p} - x_{j,p})^2} \quad (1)$$

De acordo com Cassiano (2014), a Equação 2 apresenta a função objetivo mais utilizada para espaços métricos nos métodos particionais, sendo representada como o erro quadrático:

$$E = \sum_{j=1}^k \sum_{x \in c_j} \|x - m_j\|^2, \text{ para } k \in (1, n) \quad (2)$$

Onde  $E$  é a soma do erro quadrado para todos os objetos na base de dados,  $p$  é o ponto no espaço representando um dado objeto e  $m_i$  é o representante do *cluster*  $C_i$ . Se dividir a Equação 2 por  $n$ , resultará na distância média de cada objeto ao seu respectivo representante (ESTER; WITTMANN, 1998).

O K-Means possui algumas variações, como o K-Modes, que lida com dados categóricos em vez de apenas dados numéricos (CHATURVEDI *et al.*, 2001) e o K-Prototypes que combina características numéricas e categóricas em um único algoritmo (JI *et al.*, 2013).

### 2.2.2 Algoritmo K-Modes

O K-Modes é um algoritmo de clusterização utilizado para lidar especificamente com dados categóricos (KOUSHIK *et al.*, 2021) e é aplicado em situações onde os dados categóricos são predominantes e onde a segmentação pode gerar *insights* significativos (SAINI, 2023). De acordo com Saini (2023), o K-Modes é utilizado em estudos que envolvem classificação de grupos com características semelhantes. A capacidade do K-Modes de lidar com dados puramente categóricos, sem necessidade de transformações complexas, o torna um método eficiente e acessível para diferentes contextos (KOUSHIK *et al.*, 2021; SAINI, 2023; FARAZI *et al.*, 2022).

Para iniciar o K-Modes, é necessário ter um número definido de  $k$  *clusters*. Dessa forma, testes manuais devem ser feitos para que o número de *clusters* formados gere resultados favoráveis. Ao fazer testes, não é esperado que se tenha nem uma quantidade muito pequena de *clusters* (1 ou 2 *clusters*), sendo uma divisão ineficiente, onde cada *cluster* teria várias escolas, nem uma quantidade alta (7 ou mais *clusters*), onde a diferença entre os *clusters* se tornarão muito pequenas. Com isso, o equilíbrio deve ser encontrado, onde as características que formam cada *cluster* sejam o mais homogêneas possível e que os *clusters* realmente tenham uma diferença considerável um do outro.

É uma adaptação do K-Means para conjuntos de dados categóricos, removendo a limitação somente numérica do K-Means e mantendo sua eficiência no agrupamento de grandes conjuntos de dados categóricos (AGGARWAL; REDDY, 2014). Ainda de acordo com os autores, o K-Modes fez as seguintes modificações:

- 1) Usa uma medida de dissimilaridade para objetos categóricos;
- 2) Substitui as médias dos *clusters* pelas modas;
- 3) Usa um método baseado em frequência para encontrar as médias.

A distância de Hamming pode ser usada para encontrar a moda do *cluster* mais próxima de um objeto. A moda de um *cluster* é usada para atribuir um objeto não atribuído ao *cluster* mais próximo. Com base na obra de Aggarwal e Reddy (2014), seja  $X = \{X_1, X_2, \dots, X_n\}$  um conjunto de  $n$  objetos categóricos descritos por atributos categóricos  $A_1, A_2, \dots, A_m$ . Uma moda de  $X$  é um vetor  $Q = [q_1, q_2, \dots, q_m]$  que minimiza a função  $D(X, Q)$ , como é apresentado na Equação 3.

$$D(X, Q) = \sum_{i=1}^n d_1(X_i, Q) \quad (3)$$

Onde  $d_1$  é uma função de distância, como a distância de Hamming. Foi provado que a função  $D(X, Q)$  é minimizada se e somente se cada posição  $j$  da moda  $Q$  contém o valor mais frequente no atributo  $A_j$ , tal que  $fr(A_j = q_j | X) \geq fr(A_j = c_{i,j} | X)$  para  $q_j \neq c_{i,j}$  para todo  $j = 1, \dots, m$ .

A moda do vetor  $Q$  não é necessariamente um elemento de  $X$ . A moda do *cluster*  $c$  é um vetor  $\mu_c = \{\mu_{c1} \dots \mu_{cm}\}$ , onde  $\mu_{cj}$  é o valor mais frequente de  $c$  para o  $j$ -ésimo atributo. A moda de  $c$  é determinada definindo  $\mu_{cj}$  para o valor mais frequente para a  $j$ -ésima categoria em  $c$ . Para encontrar uma moda para um conjunto, seja  $n_{ci,j}$  o número de objetos com o  $i$ -ésimo valor  $c_{i,j}$  no atributo  $A_j$  e  $fr(A_j = c_{i,j} | X) = n_{ci,j}/n$  a frequência relativa do valor  $c_{i,j}$  em  $X$ . A Equação 4 é referente a função de custo, onde o algoritmo do K-Modes avalia o custo total em relação ao conjunto de dados inteiro de acordo com essa função, em cada vez que uma nova moda é obtida sobre os  $k$  *clusters*,  $n$  objetos e  $m$  atributos categóricos.

$$P(X, Q) = \sum_{i=1}^n \cdot \sum_{i=1}^n \cdot \sum_{i=1}^n \cdot \sigma(c_{i,j}, q_{l,j}) \quad (4)$$

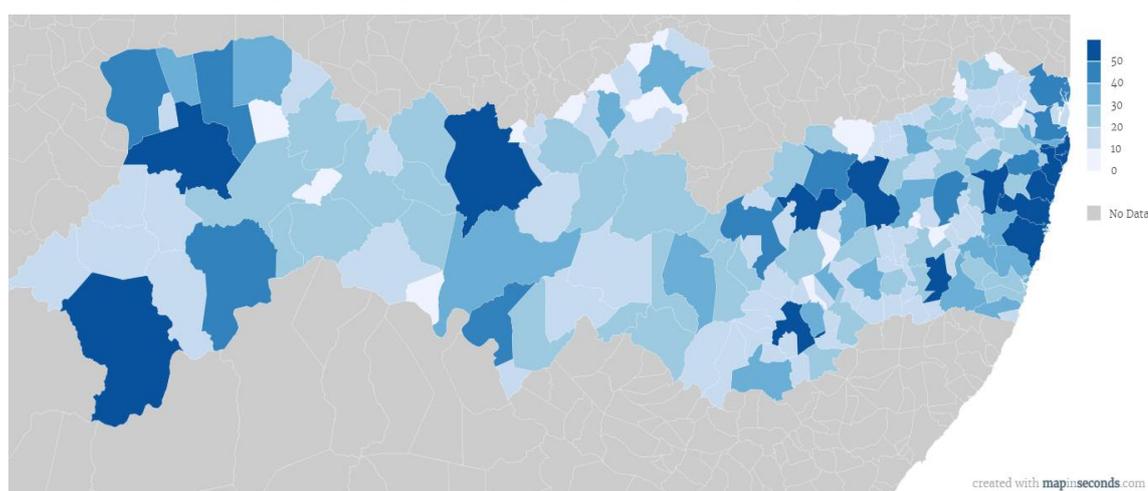
A gestão da alimentação escolar representa um grande desafio para a administração pública, especialmente em municípios com uma grande quantidade de escolas distribuídas em diferentes regiões. Garantir que os insumos alimentares sejam entregues de maneira eficiente, considerando a demanda real de cada unidade, é essencial para evitar tanto a escassez quanto o desperdício de alimentos. No município de Caruaru-PE, a distribuição dos insumos é realizada com base na localização das escolas, utilizando o sistema TGS. No entanto, essa abordagem desconsidera características importantes das escolas, como o porte, número de alunos e quantidade de refeições servidas diariamente, o que pode levar a uma alocação ineficiente dos recursos.

Nesse contexto, a clusterização surge como uma estratégia benéfica, pois permite agrupar escolas com características semelhantes, criando perfis que podem facilitar o planejamento logístico e a alocação de recursos. A escolha do algoritmo K-Modes para este estudo se justifica pelo fato de que os dados analisados são lidados de forma categórica, como o tipo das escolas, o porte, o intervalo de alunos que a escola está inserida, e o intervalo de refeições servidas. Diferente de outros métodos de clusterização que trabalham com dados numéricos, o K-Modes utiliza a moda para definir os centróides dos *clusters*, tornando-se mais adequado para o problema em questão.

### 2.3 O CONTEXTO ESCOLAR DE CARUARU E PERNAMBUCO

O Estado de Pernambuco contém em todo seu território, até o momento do presente estudo, 4.770 escolas municipais, localizadas em 184 cidades (ESCOLAS, 2024). Cada município de Pernambuco, sem exceção, possui no mínimo 05 escolas municipais (ESCOLAS, 2024), e todas essas escolas fornecem alimentos escolares aos estudantes durante o período de refeições. A Figura 5 mostra o mapa de calor de todas as cidades distribuídas por todo o Estado, onde a cor com tonalidade mais escura representa uma maior quantidade de escolas do que a tonalidade mais clara.

Figura 5 - Mapa de calor da quantidade de escolas por cidade



Fonte: O Autor (2024).

Nesse contexto, a cidade de Caruaru, que é a cidade alvo desse estudo, é uma cidade localizada na Gerência Regional de Educação (GRE) Agreste Centro Norte (região 09), como é apresentado na Figura 6, e é uma das cidades que mais possui escolas municipais no Estado

todo, como pode ser visto na Figura 7, ocupando a 3º colocação, com 144 escolas municipais ao todo, perdendo apenas para Recife (329) e Jaboatão dos Guararapes (149).

A Figura 7 ainda apresenta a quantidade de escolas ativas nas 20 cidades que mais possuem escolas em sua região, onde nessas 20 cidades, o total de escolas equivale a 1.648, ou seja, aproximadamente a 34,55% do total de escolas em todo o Estado, o que é relativamente uma grande parcela, considerando que os demais 65,45% (3.122 escolas) estão distribuídas em 164 cidades.

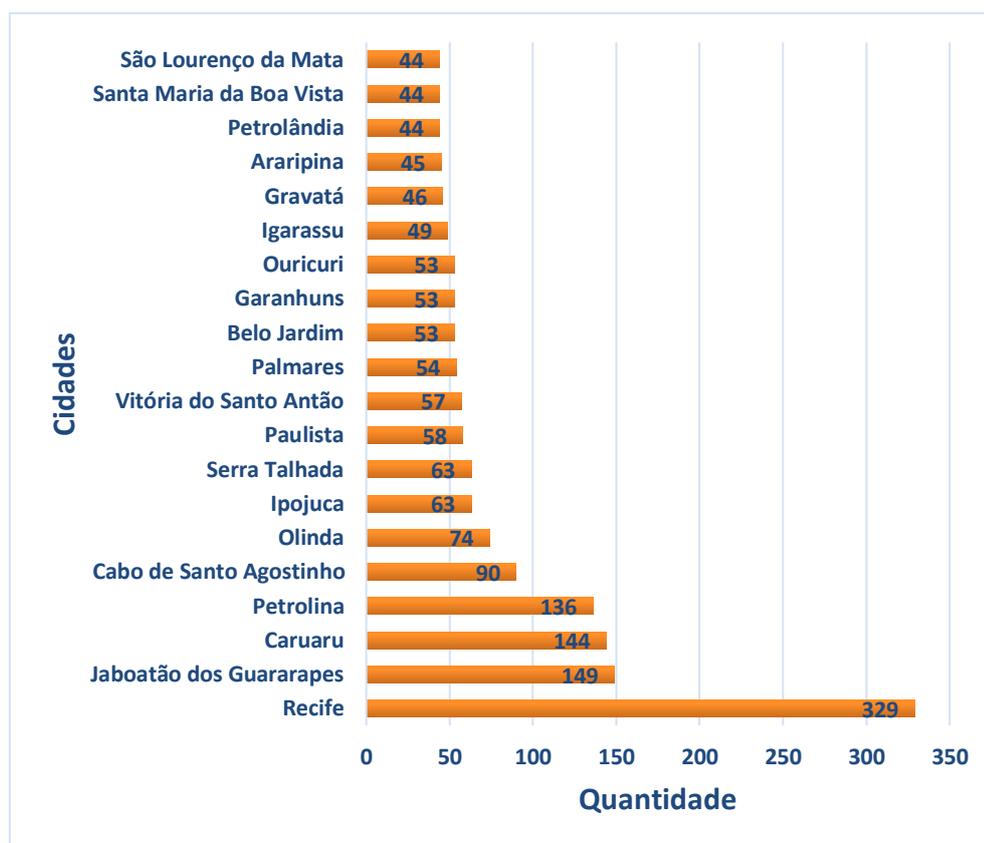
Todas as escolas municipais do Estado fornecem alimentação aos estudantes, sem custos. Nisso, a rede municipal de ensino da cidade de Caruaru-PE disponibiliza o fornecimento de merenda escolar de modo que todos os cardápios e refeições são elaborados por nutricionistas, levando em consideração as necessidades nutricionais dos estudantes. Ou seja, os cardápios são montados com base em uma série pré-definida de cardápios diários, sendo cada cardápio formado por um conjunto de refeições. A distribuição dos alimentos é feita independente da classificação do porte da escola (pequeno, médio ou grande), ou o tipo de regime de atividades (integral ou não integral). No entanto, essa distribuição segue um cardápio nutricional semanal elaborado por nutricionistas, considerando diretrizes do PNAE e padrões estabelecidos pelo Ministério da Saúde (FNDE, 2020).

Figura 6 - Fronteiras das GREs do Estado de Pernambuco



Fonte: (SEDUC, 2024).

Figura 7 - Cidades com mais escolas no Estado de Pernambuco

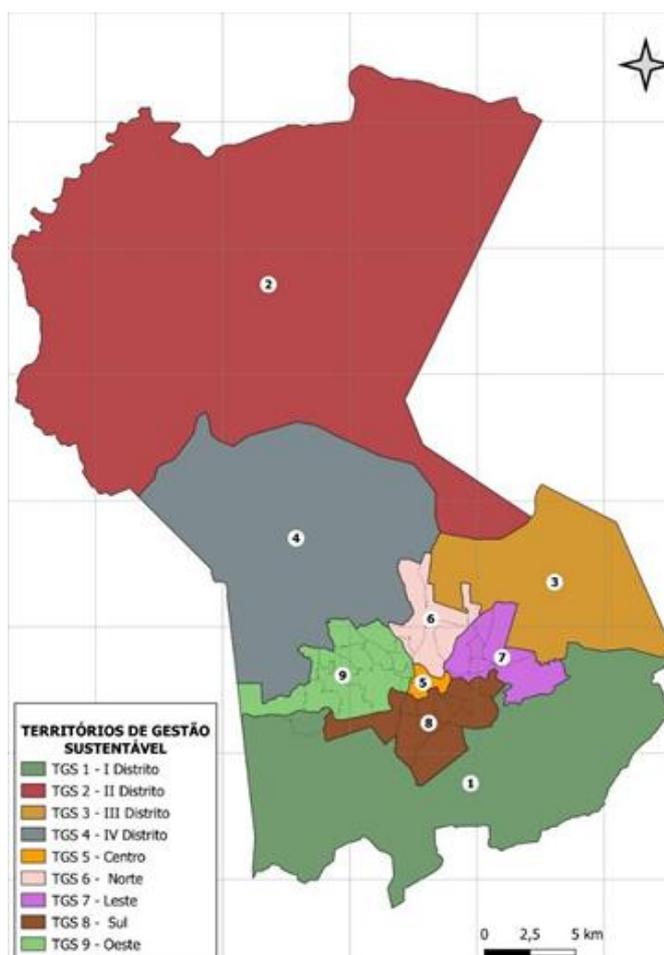


Fonte: Adaptado de Escolas (2024).

No ano de 2024, foram constatadas na cidade um total de 144 escolas municipais em atividade (ESCOLAS, 2024). Essas escolas se dividem entre 9 TGS (Território de Gestão Sustentável), onde o intervalo do TGS 1 ao TGS 4 corresponde às regiões de zona rural e o intervalo do TGS 5 ao TGS 9 corresponde às regiões de zona urbana.

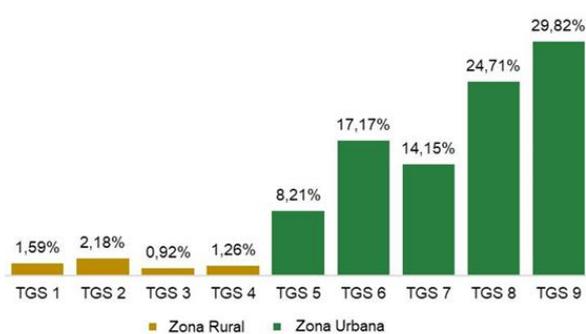
A Figura 8 apresenta como é feita a divisão dos territórios, onde há a diferenciação dos diferentes grupos por cores. É notável que alguns TGS são bem maiores que outros, porém, a população dos TGS 1 à 4 é bem inferior à dos TGS 5 à 9, mesmo contando com maior área de extensão. De acordo com Sapl (2021), 94,05% dos munícipes residem na zona urbana e 5,95% na zona rural. Porém, o número de escolas na zona rural ultrapassa o número de escolas na zona urbana, e isso pode ocorrer principalmente devido a necessidade de alimentação da população local. A Figura 9 evidencia como é a realidade da distribuição da população por TGS e a Tabela 1 mostra a quantidade de escolas por TGS.

Figura 8 - Divisão dos TGSs de Caruaru-PE



Fonte: (SAPL, 2021).

Figura 9 – Distribuição da população por região



Fonte: (SAPL, 2021).

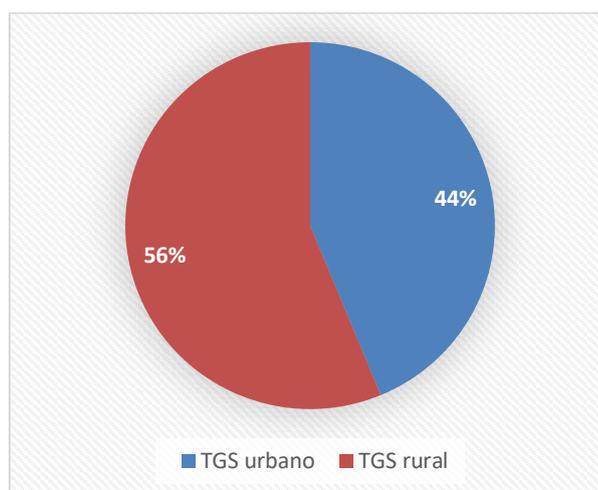
Tabela 1 – Quantidade de escolas por TGS

TGS	Quantidade de escolas
1	21
2	23
3	16
4	21
5	10
6	08
7	16
8	12
9	17

Fonte: (SEDUC, 2024).

O percentual da quantidade das escolas por TGS das zonas urbana e rural são expressos no Gráfico 1, no qual há uma diferença considerável de 18 escolas entre elas, onde a zona rural possui 81 escolas (56,25%) e a zona urbana possui 63 escolas (43,75%). A Tabela 2 apresenta a quantidade e o percentual de alunos que estão alocados em cada zona.

Gráfico 1 – Percentual de escolas nas zonas rural e urbana de Caruaru-PE



Fonte: (SEDUC, 2024).

Tabela 2 – Quantidade de alunos nas zonas rural e urbana de Caruaru-PE

Zona	Quantidade de alunos	Percentual
Zona Rural	11257	23,73%
Zona Urbana	36185	76,27%

Fonte: (SEDUC, 2024).

As escolas municipais de Caruaru-PE contam no ano de 2024 com um total de 47.442 estudantes, que se dividem entre os tipos da escola e o porte. O público é definido entre:

- Público infantil: 3 à 5 anos (berçário; berçário I; berçário II; pré I; pré II);

- Fundamental 1: 6 à 11 anos (1º ano; 2º ano; 3º ano; 4º ano; 5º ano);
- Fundamental 2: 12 à 15 anos (6º ano; 7º ano; 8º ano; 9º ano);
- EJA (Educação de Jovens e Adultos): 19 à 60 anos (Fase I; Fase II; Fase III; Fase IV).

A Tabela 3 apresenta a quantidade de alunos de acordo com a classificação dos mesmos que dependerá da idade e do nível de escolaridade que se encontram.

Tabela 3 – Quantidade de alunos por classificação nas escolas de Caruaru-PE

<b>Classificação dos alunos</b>	<b>Quantidade de alunos</b>	<b>Percentual</b>
Infantil	9713	20,47%
Fundamental 1	19045	40,14%
Fundamental 2	15739	33,18%
EJA	2945	6,21%

Fonte: (SEDUC, 2024).

As escolas do município se dividem em 3 tipos: EM – Escola Municipal; CMEI – Centro Educacional de Educação Infantil e ETI – Escola de Tempo Integral. Essas escolas possuem refeições que funcionam em um horário padrão, expressos na Tabela 4.

Tabela 4 - Refeições disponibilizadas nas escolas municipais de Caruaru-PE

<b>Tipo de refeição</b>	<b>Tipo de escolas</b>	<b>Horários</b>
Café da manhã	EM	07:00-07:30
Café da manhã	CMEI	07:00-08:00
Lanche da manhã	ETI	09:00-09:30
Lanche da manhã	EM e CMEI	09:30-10:00
Almoço	ETI e EM	12:30-13:30
Lanche da tarde	CMEI	14:00-14:30
Lanche da tarde	ETI e EM	15:00-15:30
Jantar	CMEI	16:00-16:30
Jantar	ETI e EM (quando há EJA)	18:30-19:00

Fonte: (SEDUC, 2024).

Esses tipos de escolas irão influenciar na rotina e na distribuição dos alimentos. Todas as escolas funcionam em tempo integral, porém as diferenças entre os tipos de escola são:

- EM: Escolas que funcionam em regime integral para alunos do fundamental 1 e 2. Algumas funcionam no período noturno para atender ao público do EJA. Por estarem localizadas em zona rural, além da zona urbana, possuem mais refeições do que as ETIs, oferecendo café da manhã como um diferencial. Possuem 4 refeições: café da manhã; lanche da manhã; almoço; lanche da tarde. Para o público EJA, há apenas uma refeição, que é na chegada dos estudantes;

- ETI: Escolas que funcionam em regime integral para alunos do fundamental 1 e 2. Algumas funcionam no período noturno para atender ao público do EJA. Possuem 3 refeições: lanche da manhã; almoço; lanche da tarde. Possui a mesma rotina para o público EJA que as escolas EM possuem;
- CMEI: Escolas que funcionam em regime integral e atendem exclusivamente ao público infantil, não funcionando no período noturno. Possuem 5 refeições: café da manhã; lanche da manhã; almoço; lanche da tarde; jantar.

Há algumas exceções em algumas escolas EM e ETI, que possuem alunos pré I e pré II. As Tabelas 5 e 6 apresentam a quantidade de alunos e de escolas por tipo de escola e as Tabelas 7 e 8 apresentam a quantidade de alunos e de escolas de acordo com o porte das escolas.

Tabela 5 – Quantidade de alunos por tipo de escola de Caruaru-PE

<b>Tipo da escola</b>	<b>Quantidade de alunos</b>	<b>Percentual</b>
EM	36528	77,00%
ETI	4254	08,97%
CMEI	6660	14,04%

Fonte: (SEDUC, 2024).

Tabela 6 – Quantidade de escolas por tipo de escola de Caruaru-PE

<b>Tipo da escola</b>	<b>Quantidade de escolas</b>	<b>Percentual</b>
EM	106	73,61%
ETI	7	4,86%
CMEI	31	21,53%

Fonte: (SEDUC, 2024).

Tabela 7 – Quantidade de alunos por porte das escolas de Caruaru-PE

<b>Porte das escolas</b>	<b>Quantidade de alunos</b>	<b>Percentual</b>
Pequeno	8054	16,98%
Médio	15273	32,19%
Grande	24115	50,83%

Fonte: (SEDUC, 2024).

Tabela 8 – Quantidade de escolas por porte das escolas de Caruaru-PE

<b>Porte das escolas</b>	<b>Quantidade de escolas</b>	<b>Percentual</b>
Pequeno	92	63,89%
Médio	32	22,22%
Grande	20	13,89%

Fonte: (SEDUC, 2024).

O porte das escolas varia de acordo com a capacidade de estudantes que a escola comporta. As escolas consideradas de pequeno porte comportam no máximo 300 alunos. As escolas consideradas de médio porte comportam de 301 a 700 alunos. As escolas consideradas de grande porte comportam acima de 701 alunos.

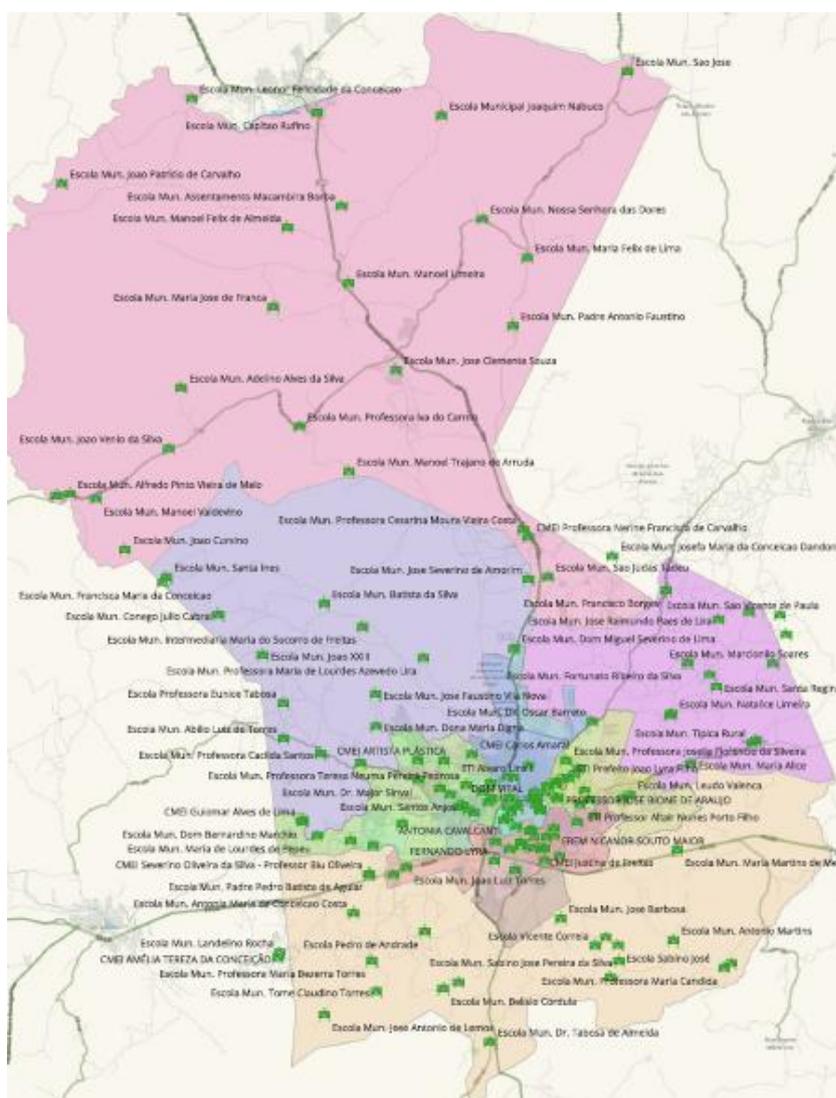
O fato da maioria das escolas estarem em uma zona afastada do centro de distribuição mostra a importância que a gestão da distribuição possui, devido a dificuldade de acesso ser maior e a necessidade da merenda na rotina de todos os estudantes. A Figura 10 apresenta o mapa de Caruaru-PE com marcações em verde indicando cada escola que é considerada municipal.

Um outro fator que deve ser considerado na gestão de alimentação escolar de Caruaru-PE é a demanda que cada escola tem, que varia de acordo com a faixa etária dos estudantes, a quantidade de alunos e a rotina das escolas. Essas diferenças impactam diretamente a quantidade de refeições necessárias e a frequência de reposição dos insumos.

As diretrizes do PNAE, juntamente com recomendações do Ministério da Saúde (FNDE, 2020), estabelecem padrões nutricionais e quantidades médias de consumo alimentar por faixa etária. Segundo esses parâmetros, alunos do CMEI devem receber cinco refeições diárias, cada uma contendo entre 200 e 300 gramas de alimentos sólidos. Já os alunos do EM e ETI consomem entre três e quatro refeições diárias, com porções entre 300 e 400 gramas. Para os alunos do EJA, o fornecimento é de uma refeição diária, com porções de 400 a 500 gramas.

Atualmente, a distribuição dos insumos alimentares nas escolas municipais de Caruaru-PE é feita por meio do sistema de TGS com o objetivo facilitar a administração pública e a logística de distribuição, organizando o envio de insumos com base na localização das escolas. A SEDUC é responsável pela gestão da alimentação escolar e realiza a distribuição dos insumos seguindo um cardápio nutricional semanal preestabelecido. O envio dos alimentos ocorre de forma centralizada, partindo do centro de distribuição municipal para as escolas de cada TGS.

Figura 10 – Localização das escolas municipais de Caruaru-PE



Fonte: (SEDUC, 2024).

A distribuição espacial das escolas municipais de Caruaru-PE evidencia a necessidade de um planejamento estratégico que considere não apenas a localização geográfica, mas também as características de cada unidade. Diferentes perfis de escolas demandam abordagens distintas na alocação de insumos, reforçando a importância de metodologias que permitam agrupar essas unidades de forma mais representativa. Nesse sentido, a literatura já explorou ferramentas que contribuem para a gestão de alimentação escolar, sendo necessário compreender os métodos aplicados e as lacunas existentes. O próximo capítulo apresenta uma revisão da literatura, analisando estudos relevantes sobre a distribuição de alimentos escolares e o uso de técnicas de clusterização.

### 3 REVISÃO DA LITERATURA

Este capítulo apresenta o resultado do esforço de busca na literatura por trabalhos publicados com referência ao tema da gestão de alimentação escolar.

#### 3.1 REVISÃO DA LITERATURA SOBRE ALIMENTAÇÃO ESCOLAR

Mesmo com uma maior proporção de alunos matriculados em escolas públicas no Brasil e um aumento de trabalhos na literatura voltados a distribuição de alimentos nas escolas ao redor do mundo (FARIAS *et al.*, 2024a), ainda assim existem algumas questões sobre esse tema, que envolvem a problemática, metodologias utilizadas e origem do artigo. Com isso, esta etapa da revisão tem como objetivo investigar as problemáticas dos estudos, as metodologias utilizadas e as origens dos artigos, considerando as perguntas:

- Quais critérios ou métodos são utilizados para gerenciar a distribuição dos alimentos nas escolas?
- Quais são os problemas que existem envolvendo alimentos no ambiente escolar?
- Quais são as principais revistas que os artigos foram publicados?

Para isso, a revisão da literatura deste capítulo apresenta os artigos referentes a distribuição de alimentos nas escolas, abrangendo os estudos publicados nos últimos 20 anos (de 2004 a 2024). A divisão deste capítulo está dividida da seguinte forma:

- 1) Metodologia de pesquisa da revisão:
  - a) Coleta de dados na revisão de literatura;
  - b) Análise descritiva.
- 2) Avaliação dos artigos selecionados;
- 3) Trabalhos mais relevantes identificados.

##### 3.1.1 Metodologia de pesquisa da revisão

A metodologia desta revisão é uma adaptação da metodologia realizada por Igarashi *et al.* (2013), onde os autores realizam a coleta de dados, selecionam as bases de dados e por meio de análises, selecionam os estudos que são relevantes. No presente estudo, além de serem selecionados os artigos relevantes, são feitas análises descritivas com os mesmos.

### 3.1.1.1 Coleta de dados na revisão de literatura

Para ter uma busca ampla referentes ao tema, foram feitas buscas estruturadas por palavras-chave em 02 bases de dados: *Web of Science* (WoS) e *Scopus*. WoS é especialmente importante na seleção de fontes de pesquisa para referencial teórico (BIRKLE *et al.*, 2020) e *Scopus* é um banco de dados de resumos e citações de literatura revisada por pares (TOBER, 2011).

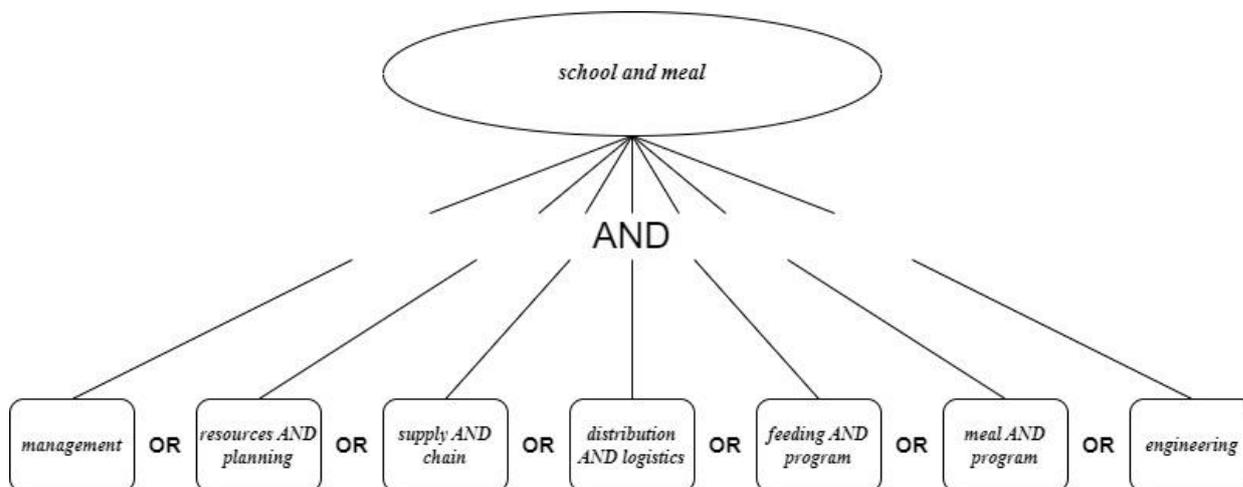
Segundo Strozzi *et al.* (2017), esses são os bancos de dados mais utilizados para delineamento de campos do conhecimento. O quantitativo de artigos encontrados de ambas as bases de dados já é exposto com as duplicações removidas com o apoio do *software Mendeley*, que identifica os artigos que são duplicados e facilita a análise individual dessas duplicações antes da remoção. Esse *software* foi adquirido pela *Elsevier* em 2013 e se tornou a principal plataforma da editora para colaboração acadêmica, compilando e organizando referências, extraindo dados, identificando duplicações etc (ELSTON, 2019).

Os critérios de inclusão a serem inseridos no filtro de busca foram:

- Considerar apenas artigos disponíveis na língua inglesa;
- Considerar apenas artigos encontrados por meio da combinação das seguintes palavras-chave, conforme apresentado na Figura 11;
- Considerar apenas artigos publicados no período de 2004 até 15 de julho de 2024;
- Considerar, no WoS, apenas os artigos em que sua área de pesquisa esteja em uma das categorias: *food science technology; science technology other topics; development studies; engineering; public administration; operations research management science; mathematic; transportation;*
- Considerar, no Scopus, apenas os artigos em que sua área de pesquisa esteja em uma das categorias: *business; management and accounting; engineering; mathematics.*

Para um melhor entendimento da Figura 11, é apresentada a lógica de leitura: *(school AND meal) AND (management) OR (school AND meal) AND (resources AND planning) OR (school AND meal) AND (supply AND chain) OR (school AND meal) AND (distribution AND logistics) OR (school AND meal) AND (feeding AND program) OR (school AND meal) AND (meal AND program) OR (school AND meal) AND (engineering).*

Figura 11 – Combinações de palavras-chave



Fonte: O Autor (2024).

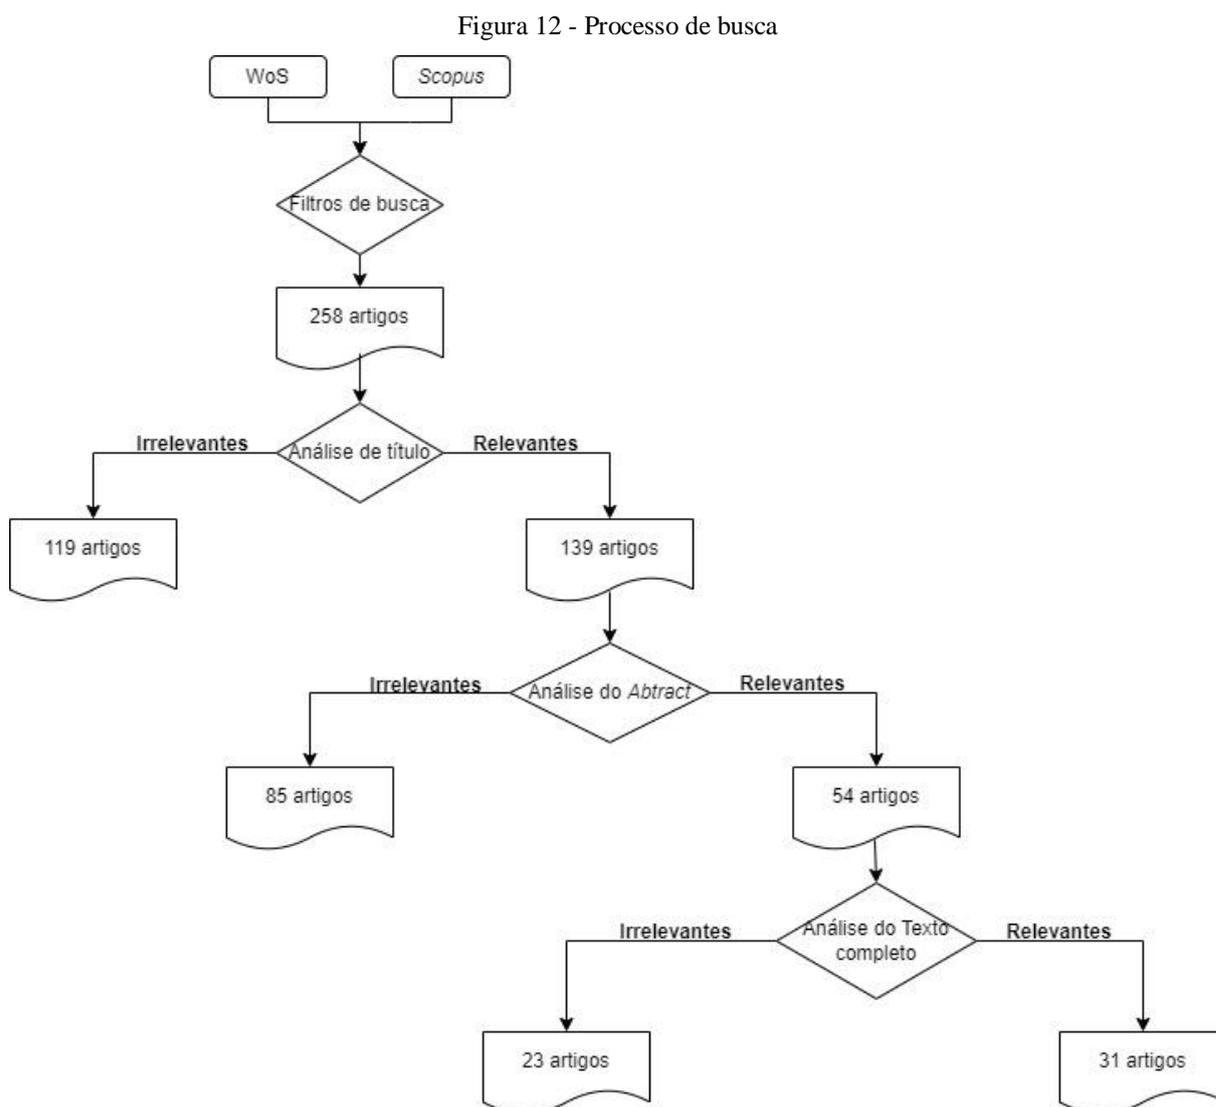
Estas palavras que foram combinadas com “*school*” e “*meal*”, são as que permitem buscas mais diretas e referentes a alimentação escolar envolvendo gerenciamento, administração, engenharia, logística, distribuição, planejamento, recursos e cadeia de suprimentos. Importante salientar também que foi feita uma única busca com todas as combinações, justificando o uso do “*OR*”, que buscava a combinação com uma palavra-chave, ou com outra palavra-chave. Essa lógica abrangeu todas as palavras-chave descritas, gerando um único resultado.

Os critérios de exclusão dos artigos nas análises de título, *abstract* e texto completo, foram:

- Desconsiderar artigos que tratavam de política;
- Desconsiderar artigos em que o foco era investigar a saúde dos estudantes;
- Desconsiderar artigos em que o foco era investigar as características químicas/físicas dos alimentos;
- Desconsiderar artigos em que o foco era comparar programas de alimentação;
- Desconsiderar artigos em que não abordavam gestão na alimentação escolar;
- Desconsiderar artigos em que o foco era em energias renováveis;
- Desconsiderar artigos em que a gestão ocorria fora do ambiente escolar ou não envolvia os estudantes;
- Desconsiderar artigos em que as palavras-chave eram apenas citadas, mas não abordadas no artigo.

A busca na WoS obteve um total de 216 artigos após os filtros aplicados, enquanto na

*Scopus* rendeu um total de 74 artigos ao todo, totalizando 290 artigos. Ao serem removidos os artigos duplicados, a amostra total de artigos a serem analisados foi de 258. Após isso e considerando os critérios de remoção dos artigos que seriam considerados irrelevantes para a revisão, foram feitas as análises de título, *abstract* e texto completo. O resultado é apresentado na Figura 12, obtendo-se a amostra final de 31 artigos, que se referem a modelos de gestão de alimentação escolar.



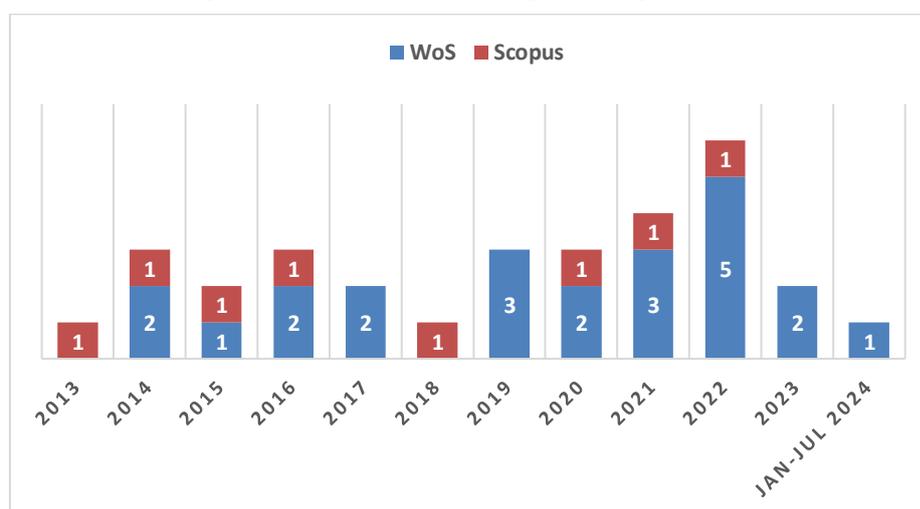
Fonte: Adaptado de Igarashi *et al.* (2013).

A partir dessa amostra final, os resultados da revisão irão explorar as perguntas que nortearam a busca, por meio de uma análise descritiva e avaliação dos artigos selecionados.

### 3.1.1.2 Análise descritiva

Com base nos resultados filtrados e seleção dos artigos, é possível ver na Figura 13 a distribuição dos mesmos ao longo dos anos, onde percebe-se que não houveram artigos selecionados de 2004 até 2012. O que pode explicar esse resultado é que embora alguns programas existam há mais de 50 anos, como o PNAE no Brasil e o NSLP (*National School Lunch Program*) nos Estados Unidos, foi somente a partir dos anos 2000 que a alimentação escolar atraiu o interesse de agências governamentais em níveis internacional, nacional e regional (CUPERTINO *et al.*, 2022). É também percebido que há mais publicações selecionadas no WoS do que no Scopus.

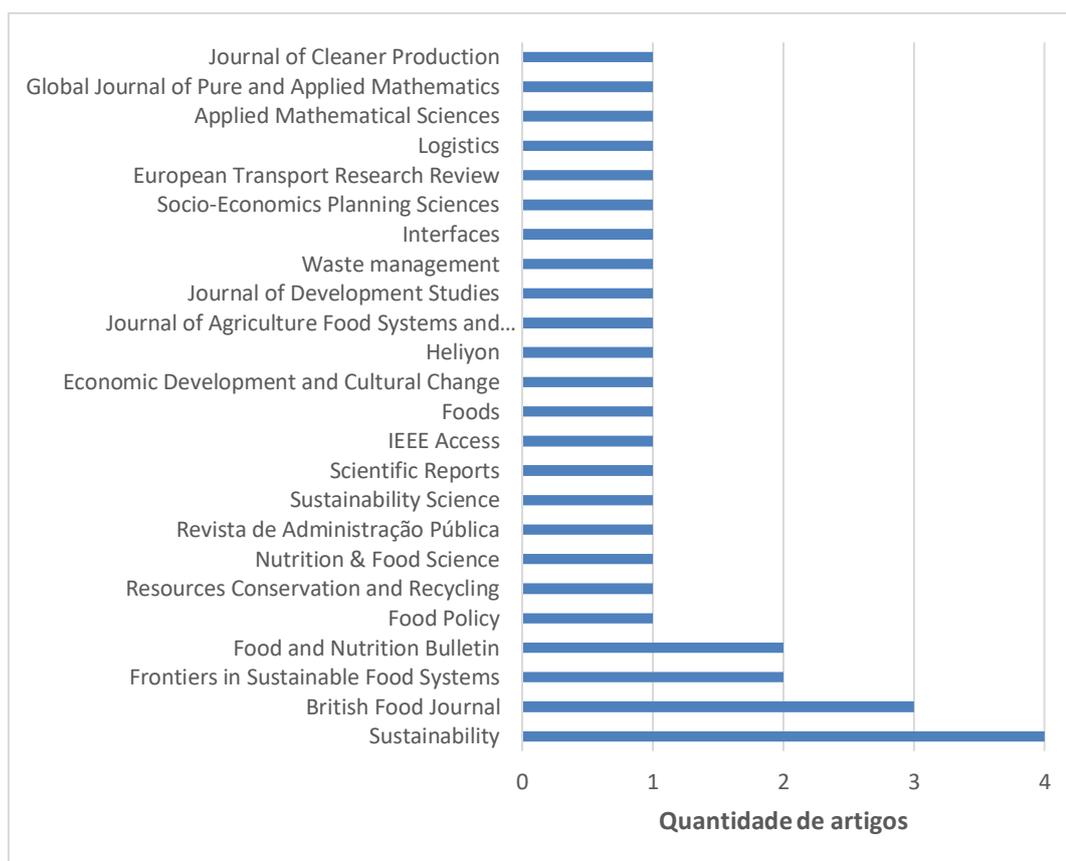
Figura 13 - Distribuição dos artigos ao longo dos anos



Fonte: O Autor (2024).

Mesmo não havendo um aumento expressivo nos últimos anos, é evidente a importância do tema e o forte interesse dos autores na temática, mesmo não sendo algo muito explorado. Dos 24 periódicos analisados, de acordo com as publicações, o que mais houve artigos publicados conforme apresentado na Figura 14, foi o *Sustainability* com 4 publicações, seguido do *British Food Journal*, com 3 publicações.

Figura 14 - Quantidade de artigos por periódico



Fonte: O Autor (2024).

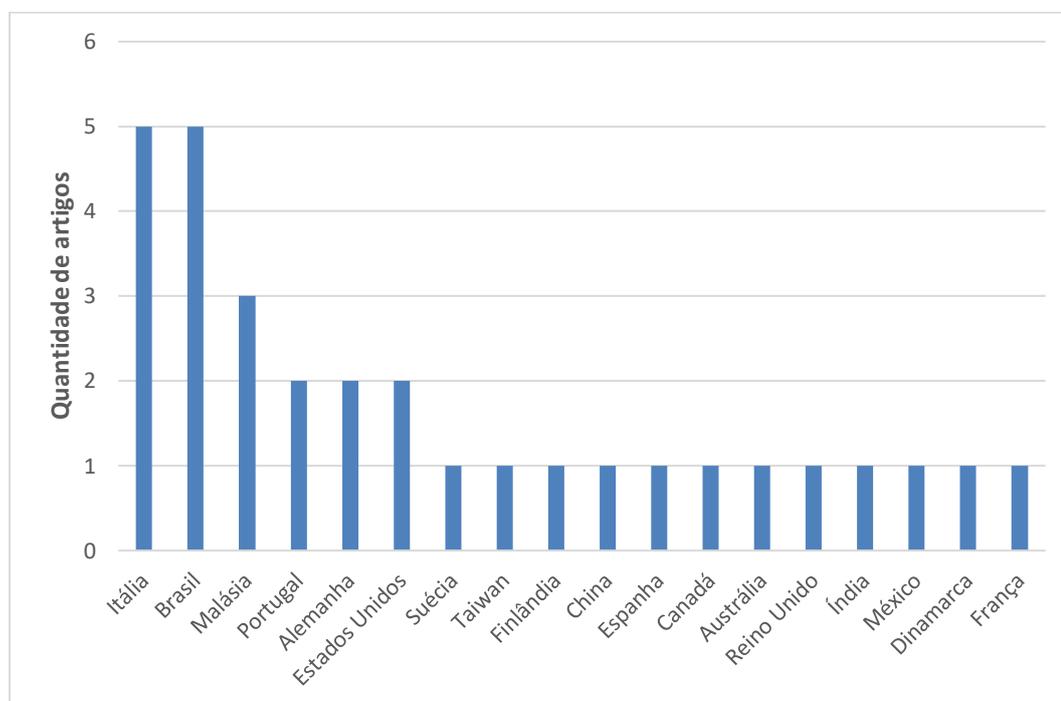
Falando da origem dos artigos, foi considerado que o país do principal autor de cada publicação seria o país de origem do artigo. Com isso, de acordo com a Figura 15, é visto que Itália, Brasil e Malásia são os países que mais apresentaram artigos que publicaram estudos sobre gestão de alimentação escolar.

Ainda de acordo com a Figura 15, há uma maior tendência de que os estudos sejam publicados em países desenvolvidos (12 países), do que em países em desenvolvimento (6 países). De acordo com Cupertino *et al.* (2022), os países que possuem renda média e alta são os que mais se concentram nos programas de alimentação escolar.

Por outro lado, ainda segundo os autores, é mais difícil abordar os programas de alimentação escolar em países em desenvolvimento, pois há mais limitações em diversos aspectos, como o financeiro, segurança alimentar entre outros. Justifica o Brasil e Malásia estarem com mais publicações em relação aos demais o fato de serem países em desenvolvimento e ainda os programas terem muitas metas a alcançarem. Já a Itália que é um país considerado desenvolvido, um fator que pode justificar um número maior de publicações é o fato de que o Programa Mundial de Alimentos (WFP - *World Feeding Program*) estar

instalado em Roma, capital da Itália, se tornando interesse de estudo entre muitos pesquisadores do país.

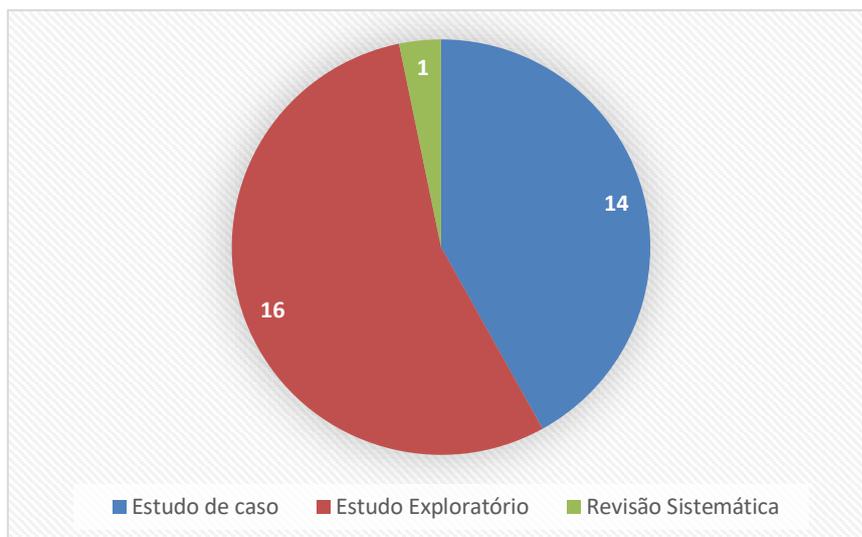
Figura 15 - Quantidade de artigos por país



Fonte: O Autor (2024).

Por fim, em relação ao tipo de estudo, as publicações foram classificadas em três tipos, e a quantidade de artigos por categoria pode ser vista no Gráfico 2. Consta-se que aproximadamente 52% dos artigos realizaram estudo exploratório, e essa observação pode ser justificada pois estudos exploratórios envolvem levantamentos bibliográficos, entrevistas com pessoas que possuem experiências práticas com o problema pesquisado e quando se busca explorar um tema pouco conhecido ou pouco estudado, com o intuito de compreendê-lo melhor e formular hipóteses para futuras pesquisas.

Gráfico 2 - Distribuição das publicações por tipo de estudo



Fonte: O Autor (2024).

### 3.1.2 Avaliação dos artigos selecionados

Com base nos artigos selecionados, foram vistos vários tipos de objetivos relacionados com alimentação escolar, que direcionaram os estudos. Cada objetivo possui uma característica que norteia os resultados das publicações de forma diferente, onde mesmo que seja um assunto em comum, cada objetivo tem pesos diferentes e impactam no resultado final de formas específicas. Para que haja um melhor entendimento acerca dos objetivos, a seguir são apresentados os mesmos e o que eles abordam, de forma que justifique a classificação de cada artigo a um objetivo específico:

- Desperdício/Consumo de alimentos: Na parte do desperdício, refere-se a artigos que tiveram como foco quantificar o desperdício de alimentos, examinar o status da geração de desperdício e avaliar as causas: avaliando os principais indicadores de desempenho (KPI's – *Key Performance Indicator*); analisando a perda de valor monetária de alimentos não consumidos e análise de fluxo de massa (MFA – *Material Flow Analysis*). Também é importante a comparação de percepções de desperdício entre os consumidores. Na parte do consumo, refere-se a artigos que contabilizaram os alimentos consumidos nas escolas.
- Método de avaliação de licitação pública: Refere-se a artigos que analisaram se existem uniformidades de abordagem nos métodos de avaliação de licitação pública de alimentos para escolas e que fosse utilizada uma ferramenta de gestão para isso.

- Ofertas/Planejamento do cardápio escolar: Na parte de ofertas do cardápio escolar, refere-se a artigos que analisaram as razões sobre a falta de implementação de ofertas de cardápios e aceitação dos mesmos nas cantinas escolares. Na parte do planejamento, refere-se a artigos que buscaram implementar softwares com técnicas de IA (Inteligência Artificial) para habilitar agilidade no momento de fornecer opções de alimentos, ou que apenas tentaram aplicar ferramentas de gestão para esse planejamento para gerar benefícios, tais como: redução de custos; maior variedade; agilidade; ingestão recomendada de nutrientes.
- Gerenciamento durante a COVID-19: Refere-se a artigos que praticaram gerenciamento de recursos durante a pandemia da COVID-19, revelando os problemas operacionais, logísticos entre outros que surgiram com a pandemia. Além disso, artigos que propuseram estratégias que trouxessem soluções constantes até o fim da pandemia.
- Utilização de alimentos regionais nos cardápios: Refere-se a artigos que analisaram a inclusão de novos alimentos regionais que agregassem positivamente o cardápio e utilizaram ferramentas de gestão para identificar quais alimentos regionais seriam adequados e classificá-los corretamente.
- Gerenciamento de custos dos alimentos: Refere-se a artigos que analisaram as implicações dos custos nos alimentos escolares com retiradas/acréscimos de alimentos ao cardápio. Também artigos que avaliaram a relação custo-eficácia aos alunos no quesito de alimentação.
- Satisfação dos alunos na qualidade da alimentação escolar: Refere-se a artigos que analisaram até que ponto os alunos valorizam as características do serviço de alimentação escolar e identificaram variáveis que afetam o grau de satisfação dos alunos com a qualidade das refeições escolares.
- Distribuição/Entrega de alimentos: Refere-se a artigos que sugerem métodos de solução de distribuição e entrega de alimentos, além de discutir os desafios enfrentados.
- Influência dos alimentos na educação: Refere-se a artigos que investigaram a relação entre o fornecimento de alimentação escolar e o resultado educacional dos alunos.

Na Tabela 9, é possível verificar que o objetivo principal mais abordado foi

“Desperdício/Consumo de alimentos”, mostrando a preferência que os autores possuem nessa abordagem quando fazem estudos na área de alimentação escolar. É percebido que dos 31 artigos, apenas um não está listado nos objetivos e nas metodologias, pois foram citados/contabilizados apenas os artigos que relataram os objetivos e metodologias conforme apresentados nas classificações. O artigo que não foi citado é uma revisão de literatura (BATISTELA DOS SANTOS *et al.*, 2022) e fornece informações sobre gestão de alimentação escolar, mas não trabalha diretamente com os objetivos e metodologias listados.

Tabela 9 - Objetivos principais dos artigos analisados

Problemática/Objetivo	Quantidade
Desperdício/Consumo de alimentos	10
Ofertas/Planejamento do cardápio escolar	6
Gerenciamento durante COVID-19	4
Distribuição/Entrega de alimentos	4
Gerenciamento de custos dos alimentos	2
Utilização de alimentos regionais	1
Satisfação dos alunos na qualidade da alimentação escolar	1
Método de avaliação de licitação pública	1
Influência dos alimentos na educação	1
Total	30

Fonte: O Autor (2024).

Falando das metodologias utilizadas para alcançar os objetivos, a mais utilizada na gestão de alimentos escolares foi a que se refere ao grupo de “Inferência Estatística”, mais precisamente, questionários e testes de hipóteses foram os métodos mais utilizados para lidar com as problemáticas, como pode ser visto na Tabela 10.

A justificativa para maior uso da estatística é pelo fato de que a coleta de dados muitas vezes requer entrevistas, para que os autores fiquem cientes das características dos problemas, além de que devem ser elaborados muitas vezes questionários, e as análises pós coleta de dados muitas vezes requerem mensuração de dados, testes de hipóteses para possíveis resultados, análise de médias, desvio padrão, entre outros. Avaliando as metodologias utilizadas, elas foram classificadas em três categorias, onde é visto abaixo todas as classificações e os artigos associados:

- **Programação multiobjetivo ou Multicritério (MCDM):** O Conceito de programação linear multiobjetivo trata-se de trabalhar com mais de uma função objetivo em um único problema (DA SILVA CRUZ, 2015) ou multicritérios (MCDM - *Multi-Criteria Decision Making*). Os modelos multiobjetivo têm as

vantagens de fácil formulação para um problema com tamanhos diferentes e de fornecer uma solução preferencial para um problema com vários objetivos (WANG; YANG, 2009; KANNAN *et al.*, 2014). Os artigos considerados aqui foram: (SALVATORE *et al.*, 2021); (FABRI *et al.*, 2015); (PETRUZZELLI *et al.*, 2023); (SEGREDO *et al.*, 2020); (GAJPAL *et al.*, 2019); (MAHADEVAN *et al.*, 2013); (GRANILLO-MACÍAS, 2021); (JENSEN *et al.*, 2015); (SUFAHANI; ISMAIL, 2014) e (ALI *et al.*, 2016).

- **Inferência Estatística:** A inferência estatística se preocupa em usar dados para responder a perguntas substantivas. No tipo de problemas aos quais a inferência estatística pode ser aplicada de forma útil, os dados são variáveis no sentido de que, se os dados pudessem ser coletados mais de uma vez, não seriam obtidos resultados numéricos idênticos todas as vezes (WELSH, 2011). Os artigos considerados aqui foram: (ERIKSSON *et al.*, 2017); (PIRES *et al.*, 2022); (CAMARÉNA, 2022); (MARQUES *et al.*, 2022); (BAUER; MORLOCK, 2024); (CHU *et al.*, 2023); (ALA-KARVIA *et al.*, 2022); (LIU *et al.*, 2016); (NOLL *et al.*, 2019); (MAIETTA; GORGITANO, 2016); (CONNOLLY *et al.*, 2021); (POPPE *et al.*, 2019); (PALACIOS-ARGÜELLO *et al.*, 2018) e (BOSCHINI *et al.*, 2020).
- **Análise estratégica:** As análises estratégicas permitem avaliar a situação inicial, avaliar a situação dentro e fora da empresa e revelar os fatores que causarão mudanças no ambiente (DAVID, 2011). As análises são utilizadas para descobrir problemas, identificar os fatores subjacentes e estudar seu impacto, e o desempenho estratégico também depende dos recursos e capacidades da empresa e da compreensão de seus impactos (VOLNA; PAPULA, 2013). A análise estratégica, portanto, deve ter um papel importante na tomada de decisão estratégica (PAPULOVA; GAZOVA, 2016) e utilizam técnicas conhecidas como a análise SWOT (*Strengths, Weaknesses, Opportunities and Threats*) e DEA (*Data Envelopment Analysis*). Os artigos considerados aqui foram: (KASAVAN *et al.*, 2021); (BORLIZZI *et al.*, 2017); (AMORIM *et al.*, 2020); (GELLI; SUWA, 2014); (FERNANDES *et al.*, 2016) e (COELHO *et al.*, 2022).

Tabela 10 - Metodologias/Ferramentas utilizadas pelos autores dos artigos

Área de concentração	Método ou Ferramenta	Quantidade
Programação Multiobjetivo ou Multicritério (MCDM)	Otimização exata ou heurísticas	5
	DTM ( <i>Decision Tree Model</i> )	1
	VRPCDD ( <i>Vehicle Routing Problem with a Common Due Date</i> )	1
	Programação não-linear	1
	Problema multi-objetivo AHP ( <i>Analytic Hierarchy Process</i> )	1
Inferência Estatística	Testes de hipóteses	8
	Questionários	6
Análise Estratégica	Modelos com mapeamentos	3
	Análise SWOT	1
	Análise/Coleta de dados	1
	DEA ( <i>Data Envelopment Analysis</i> )	1

Fonte: O Autor (2024).

### 3.1.2.1 Discussões sobre as metodologias encontradas

Com o intuito de gerar uma visão mais abrangente acerca das metodologias aplicadas nos estudos, serão listados como cada metodologia foi abordada com mais detalhes, de acordo com os estudos citados.

- **Otimização exata ou heurísticas:** Mahadevan *et al.* (2013) proporam, para abordar o problema logístico do estudo, uma solução heurística de decomposição em três estágios, que consiste em agrupar escolar formando *clusters*, atribuir veículos de distribuição apropriados aos *clusters* e aplicar a roteirização dos veículos dentro desses *clusters*. O objetivo inicial foi criar *k clusters* que minimizassem a distância de viagem para veículos, em seguida os veículos são atribuídos de acordo com o menor custo e por fim, é feito o planejamento de rota para determinar a sequência de visitação em cada nó de cada *cluster*.
- **DTM (*Decision Tree Model*):** Fabri *et al.* (2015) proporam uma árvore de decisão (*Decision Tree Model* – DTM) para identificação de alimentos para auxiliar a inclusão deles nos cardápios, onde essa DTM foi baseada nas principais questões elencadas em entrevistas pelos pesquisadores e entrevistados, para que todos os alimentos citados como regionais pelos entrevistados tivessem a mesma classificação quando aplicados na DTM, assim como os não regionais.

- **VRPCDD (*Vehicle Routing Problem with a Common Due Date*):** Gajpal *et al.* (2019) realizaram um problema de roteamento de veículos com uma data de vencimento comum (VRPCDD), no qual todos os clientes são atendidos antes de um prazo especificado em comum. O problema é moldado pelo sistema de distribuição de refeições, no qual a comida é entregue antes do horário de almoço nas escolas. Os autores desenvolveram dois algoritmos heurísticos para resolver o problema, onde o primeiro é baseado no vizinho mais próximo, e o segundo é baseado em um algoritmo de economia (CLARKE; WRIGHT, 1964). No modelo proposto, a função objetivo minimiza o custo total da viagem, já as restrições garantem que: haja apenas um arco de entrada para cada nó; o arco de entrada e saída de cada nó pertença a um mesmo veículo; cada veículo deve partir do depósito de saída 0 e retornar ao depósito de entrada  $n + 1$ ; a capacidade de cada veículo denominada  $Q$  não deve ser ultrapassada; conectividade das rotas preservadas; todos os nós sejam visitados antes da data de vencimento comum.
- **Programação não-linear:** Jensen *et al.* (2015) combinam no estudo receitas, registros alimentares e dados de desperdício de alimentos escolares com dados de preços de fornecedores de serviços de alimentação dentro de uma estrutura de otimização econômica, a fim de permitir a comparação entre os custos dessas refeições com o custo dos almoços embalados em casa e estimar os efeitos de suposições alternativas sobre o custo do fornecimento eficiente de refeições escolares. Para determinação dos custos mínimos, foi estabelecido um modelo de programação não-linear considerando: padrões dos cardápios; mão-de-obra; custos; equipamentos.
- **Problema multi-objetivo:** Segredo *et al.* (2020) consideraram no problema duas funções objetivo, tornando o problema multi-objetivo. O primeiro objetivo foi a minimização do custo do cardápio e o segundo objetivo foi para minimizar o número de repetições com que os pratos e grupos alimentares são repetidos no cardápio. Esse número de repetições depende do número de dias para os quais o cardápio é projetado, uma vez que o intervalo de tempo entre as refeições também é considerado. Essa modelagem teve como intuito elaborar um planejador de cardápio automatizado.
- **AHP (*Analytic Hierarchy Process*):** Salvatore *et al.* (2021) realizaram análise de conteúdo das licitações italianas de alimentos para extrair os principais critérios

da problemática e utilizaram o método AHP (*Analytic Hierarchy Process*) para avaliar e comparar a importância de vários critérios de avaliação de licitações de alimentos, priorizando alternativas de tomada de decisão por meio de comparações pareadas. Uma das principais contribuições do estudo foi a atribuição de pontuações a grupos de critérios.

- **Testes de hipóteses:** Eriksson *et al.* (2017) realizaram a coleta de dados de trinta cozinhas de escolas localizadas na Suécia, onde foi feita a medição de desperdício alimentar em pelo menos duas categorias: resíduos de pratos e sobras no serviço. Após isso, com os dados coletados, analisaram esses dados com o intuito de comparar a média de desperdício por porção entre diferentes tipos de cozinhas e grupos de consumidores. Um teste *t* de duas amostras foi utilizado para verificar diferenças entre cozinhas que produzem alimentos no local, além de comparar níveis de desperdício entre escolas. Pires *et al.* (2022) realizaram a coleta de dados também de 160 participantes focando também no desperdício de alimentos. Para estimar o desperdício, foi feita a pesagem individual dos restos alimentares. Já os participantes, realizaram uma estimativa visual de seus resíduos alimentares. A comparação entre os valores percebidos pelos participantes e os medidos pelos autores foi feita utilizando o teste de Mann-Whitney, para verificar se a percepção dos consumidores estava de acordo com o desperdício real. A metodologia incluiu a avaliação de fatores como: porções servidas; causas do desperdício; percepção sensorial dos alimentos.
- **Questionários:** Camaréna (2022) em seu estudo explorou aspectos durante a implementação de um projeto de *software* em escolas dos Estados Unidos que usaram técnicas de IA para fornecer mais agilidade e opções de alimentos saudáveis por meio de entrevistas semiestruturadas por meio de questionários, onde ocorreram correlações entre a análise de documentos, observações dos entrevistados e as entrevistas. Bauer & Morlock (2024) também realizaram no estudo uma entrevista semiestruturada com questionários padronizados em um grupo de 16 alunos, onde foram criados textos introdutórios, com foco no questionário ser o mais simples possível, evitando vieses e incentivando com que os alunos não utilizassem de respostas pré-definidas, além de que o questionário possuiu 42 perguntas. Esses questionários foram construídos com direcionamento a identificação de fatores que justifiquem o motivo de não aceitação de alimentos saudáveis nas escolas por parte dos alunos, de modo que fosse implementado uma

sugestão que introduzisse esse tipo de alimento, sendo isso possível apenas tendo ciência das barreiras existentes, sendo todas essas informações possivelmente coletadas com a elaboração e planejamento do questionário.

- **Modelos com mapeamentos:** Kasavan *et al.* (2021) estimaram o quantitativo de alimentos desperdiçados por meio de pesagem direta, onde os autores afirmam esse ser o método mais confiável para se ter dados precisos dessas amostras, para com esses dados, fornecer uma ferramenta *benchmarking* para o processo de produção dos alimentos escolares, sendo esse *benchmarking* construído por meio de um modelo de mapeamento, abrangendo desde a matéria prima até o consumo dos alimentos, incluindo o desperdício que existe.
- **Análise SWOT:** Gelli & Suwa (2014) aplicaram a análise SWOT no estudo para apresentar as descobertas de quais são os pontos fortes, fracos, oportunidades e ameaças encontradas em uma cozinha de uma escola localizada no país Bangladesh, onde comparado com outros modelos, encontrou pontos a mais que são considerados importantes para análise do que pode ser melhorado e implementado.
- **Análise/Coleta de dados:** Amorim *et al.* (2020) com o intuito de propor um conjunto de estratégias para que o PNAE pudesse garantir o fornecimento de merenda escolar aos alunos durante e após o período de isolamento social da COVID-19, realizaram análise e coleta de dados, iniciando com a análise e apresentação da fome no Brasil, para em seguida analisarem o processo de enfraquecimento das políticas de segurança alimentar e nutricional e por fim, analisaram a evolução do PNAE e sua situação no momento do estudo.
- **DEA (Data Envelopment Analysis):** Borlizzi *et al.* (2017) realizaram a conversão de dados referentes ao consumo alimentar em calorias por pessoa e estimaram a variabilidade do consumo entre diferentes grupos de renda, identificando desigualdades no acesso a alimentos recebidos gratuitamente em escolas. O DEA é aplicado nesse contexto para medir a eficiência com que diferentes grupos populacionais transformam os recursos disponíveis em consumo adequado de energia alimentar, revelando as faixas de renda com maior ineficiência.

A análise da literatura não encontrou estudos que aplicassem técnicas de clusterização no contexto da gestão de alimentação escolar como foco do estudo. Embora existam diversas pesquisas que abordam a temática da distribuição de alimentos em escolas, nenhuma das

publicações analisadas utilizou a clusterização como método para categorizar escolas com o objetivo de otimizar a distribuição dos insumos. Além disso, também não foram encontrados estudos que tratassem especificamente da categorização de escolas para a melhoria da logística de distribuição.

### 3.1.3 Trabalhos mais relevantes identificados

Foi feita uma avaliação das 15 publicações mais relevantes entre as 31 selecionadas, por meio da quantidade de citações, onde a data de coleta foi no dia 15 de julho de 2024. Além disso, são apresentados o ano de cada publicação, título e seus respectivos autores, como pode ser visto na Tabela 11.

Tabela 11 - Trabalhos mais relevantes identificados

Índice	Título	Autores	Citações	% citações	Ano de publicação
1	Quantification of food waste in public catering services - A case study from a Swedish municipality	Eriksson, M; Osowski, C P; Malefors, C; Björkman, J; Eriksson, E	115	22,95%	2017
2	School meals and pupil satisfaction. Evidence from Italian primary schools	Singh, A; Park, A; Dercon, S	58	11,58%	2014
3	Plate Waste in School Lunch Programs in Beijing, China	Liu, Y; Cheng, S K; Liu, X J; Cao, X C; Xue, L; Liu, G	49	9,78%	2016
4	Ultra-processed food consumption by Brazilian adolescents in cafeterias and school meals	Noll, P R S; Noll, M; de Abreu, L C; Baracat, E C; Silveira, E A; Sorpreso, I C E	48	9,58%	2019
5	Why the waste? A large-scale study on the causes of food waste at school canteens	Boschini, M; Falasconi, L; Cicatiello, C; Franco, S	44	8,78%	2020
6	A new diet scheduling model for Malaysian school children using zero-one optimization approach	Ali, M; Sufahani, S; Ismail, Z	27	5,39%	2016
7	National school feeding program: strategies to overcome food insecurities	de Amorim, A L B; Ribeiro, J R S;	24	4,79%	2020

	during and after the COVID-19 pandemic	Bandoni, D H			
8	A new menu planning model for Malaysian secondary schools using optimization approach	Sufahani, S; Ismail, Z	23	4,59%	2014
9	Quantification of food waste in school canteens: A mass flow analysis	Kasavan, S; Ali, N I B M; Ali, S S B; Masarudin, N A B; Yusoff, S B	21	4,19%	2021
10	Assessing the economic and environmental impacts of urban food systems for public school canteens: case study of Great Lyon region	Palacios-Argüello, L; Gonzalez-Feliu, J; Gondran, N; Badeig, F	19	3,79%	2018
11	Logistics optimization through a social approach for food distribution	Granillo-Macías, R	17	3,39%	2021
12	Enhancing Linkages Between Healthy Diets, Local Agriculture, and Sustainable Food Systems: The School Meals Planner Package in Ghana	Fernandes, M; Galloway, R; Gelli, A; Mumuni, D; Hamdani, S; Kiamba, J; Quarshie, K; Bhatia, R; Aurino, E; Peel, F; Drake, L	16	3,19%	2016
13	Regional foods in Brazilian school meals	Fabri, R K; Proença, R P D; Martinelli, S S; Cavalli, S B	15	2,99%	2015
14	Dedication, innovation, and collaboration: A mixed-methods analysis of school meals in Connecticut during COVID-19	Connolly, K; Babbin, M I; McKee, S L; McGinn, K; Cohen, J F W; Chafouleas, S M; Schwartz, M B	14	2,79%	2021
15	Sustainability Recommendations and Practices in School Feeding: A Systematic Review	dos Santos, E B; Maynard, D D; Zandonadi, R P; Raposo, A; Botelho, R B A	11	2,20%	2022

---

Fonte: O Autor (2024).

Dentre as publicações analisadas, aproximadamente 47% utilizaram inferências estatísticas como ferramenta principal para conduzir o estudo, enquanto cerca de 34% focaram no desperdício/consumo de alimentos como problema central. Vale ressaltar que, embora a inferência estatística seja amplamente utilizada, seu objetivo nos estudos analisados

é distinto do proposto neste trabalho. Nessas pesquisas, a inferência é aplicada principalmente para análises de dados e identificação de padrões.

Importante salientar que além de haverem mais publicações tanto na inferência estatística como no desperdício/consumo de alimentos, esses grupos também apresentam maior número de citações: aproximadamente 70% de citações o grupo de inferência estatística e aproximadamente 56% de citações o grupo de desperdício/consumo de alimentos.

Com base nas publicações e análise das mesmas, é evidente que há muitas problemáticas em relação ao desperdício de alimentos, sendo maioria nessa revisão, que é algo que acontece no contexto apresentado nessa dissertação. Outro fator percebido na revisão é de que os alimentos não podem faltar nas refeições escolares, principalmente os saudáveis, como fator importante no desempenho dos alunos. Entretanto, essa dissertação tem o intuito de analisar a metodologia de clusterização que mais se adequa ao apoio da gestão de alimentos escolares, envolvendo a distribuição desses insumos de forma que evite desperdício, onde deve ser feita uma verificação e busca da metodologia a ser aplicada.

Em contrapartida, a proposta desse estudo é a metodologia de clusterização como ferramenta de apoio à gestão de alimentos nas escolas. Dessa forma, a reorganização proposta com os *clusters* formados pode representar uma alternativa interessante para aprimorar a gestão dos insumos alimentares, trazendo elementos que podem contribuir para um modelo mais eficiente e estruturado. Ao agrupar as escolas de acordo com perfis semelhantes, a metodologia permite uma melhor adaptação dos tempos de reposição de estoque, maior controle sobre a diversidade nutricional e redução de desperdícios. Além disso, essa abordagem possibilita um planejamento logístico mais estratégico, ajustando a distribuição conforme a demanda real de cada escola.

Para verificação de metodologias e algoritmos de clusterização para o contexto desse estudo, é realizada uma segunda revisão da literatura.

### 3.2 REVISÃO SOBRE ALGORITMOS DE CLUSTERIZAÇÃO

Com o passar dos anos, tem-se observado um aumento no número de trabalhos na literatura que envolvem a clusterização nos mais diversos tipos de problemas. Conseqüentemente, novos algoritmos, adaptações ou expansões de algoritmos já existentes ocorrem. Um novo algoritmo de clusterização foi desenvolvido (LEI *et al.*, 2008) para ser aplicado a um diagnóstico de falhas de uma empresa de rolamentos de locomotivas, onde o algoritmo foi capaz de reconhecer de forma confiável não apenas diferentes categorias e

gravidades de falhas, mas também as falhas compostas. Uma revisão da literatura que usa a clusterização como base para otimização de enxame de partículas (*Particle Swarm Optimization* - PSO), conduzida por Alam *et al.* (2014), investiga o crescimento da literatura em SI (*Swarm Intelligence* – Inteligência de Enxame) e seus algoritmos, onde diferentes técnicas de otimização baseadas na clusterização foram aplicadas para investigar a solução ideal para os problemas de agrupamento.

Várias abordagens foram desenvolvidas com aplicações envolvendo técnicas/algoritmos de clusterização. Algumas dessas abordagens:

- Segmentação de clientes (BENÍTEZ *et al.*, 2014; LÓPEZ *et al.*, 2011; CHEN *et al.*, 2017);
- Análise de imagens (CHARYTANOWICZ *et al.*, 2010; ROCHA *et al.*, 2009; XU *et al.*, 2014);
- Análise de texto (ABUALIGAH *et al.*, 2018; ABUALIGAH *et al.*, 2020; JANSSENS *et al.*, 2007);
- Detecção de anomalias (PANDEESWARI; KUMAR, 2016; LYU *et al.*, 2017; MOSHTAGHI *et al.*, 2011).

Benítez *et al.* (2014) utilizam algoritmos de clusterização dinâmica para a classificação das séries temporais de consumo de energia, classificando os clientes de acordo com seus padrões de consumo de energia e avaliar suas tendências gerais de consumo. López *et al.* (2011) propuseram um algoritmo de clusterização hierárquica (Hopfield-K-Means) para classificar os clientes, de modo que essa segmentação visa estabelecer diferentes tarifas para cada diferente grupo de clientes. Estes últimos autores utilizaram este algoritmo para suprir limitações da aleatoriedade da solução inicial (fornecida pelo K-Means) e a pré-alocação do número de *clusters* (fornecida pelo *Follow the Leader*). Chen *et al.* (2017) trabalham com dados de transações de clientes, analisando o comportamento em empresas de varejo e comércio eletrônico. Os autores propuseram um algoritmo de clusterização particional (*PurTreeClust*) para um agrupamento rápido de árvores de compras, onde uma nova métrica de distância é proposta para calcular efetivamente a distância entre duas árvores de compras. Para agrupar os dados da árvore de compras, primeiro classificaram-as como árvores representativas candidatas com uma nova densidade separada e, em seguida, selecionaram os principais *k* clientes como representantes de *k* grupos de clientes.

Charytanowicz *et al.* (2010) utilizam um algoritmo de clusterização de gradiente completo em um conjunto de dados reais de grãos, onde os autores estimaram que o algoritmo

realizasse a diferenciação de diferentes grãos em *clusters* por meio da imagem deles. Rocha *et al.* (2009) também usaram uma abordagem para agrupamento de dados, porém baseada na floresta de caminho ótimo (*Optimum-path Forest*) e apresentaram extensões para grandes conjuntos de dados com resultados para segmentação interativa de imagens e para classificação rápida, precisa e automática de tecido cerebral em imagens de ressonância magnética. Xu *et al.* (2014) também trabalharam com análise de imagens, porém com o intuito de reduzir ruídos dos *clusters* para reconstrução das imagens sem ruídos com apoio do algoritmo K-Means.

No âmbito de trabalhar com análises de texto, Abualigah *et al.* (2018) realizam a clusterização de documentos de texto por meio do algoritmo *Krill herd* (Kh), que é um algoritmo baseado em enxame (*swarm-based*), que imita o comportamento de rebanhos de *krill* durante a busca por alimentos – que é um crustáceo oceânico em enxame (CAVAN *et al.*, 2019) – e de acordo com os autores, esse algoritmo tem sido utilizado em muitos problemas complexos de otimização. Abualigah *et al.* (2018) dizem que a clusterização de documentos de texto se refere ao método de agrupamento de uma enorme quantidade de documentos de texto em grupos coerentes e densos, onde os documentos no mesmo grupo são semelhantes, onde as versões iniciais do algoritmo são herdadas do K-Means e a decisão de clusterização é baseada em duas funções objetivo combinadas, já Abualigah *et al.* (2020), por sua vez, realizaram experimentos para analisar o desempenho de diversos algoritmos nessa abordagem de clusterização de documentos de texto, incluindo o algoritmo KH (*Harmony Search* (HS), *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO), *Ant Colony Optimization* (ACO), *Krill Herd* (KH), *Cuckoo Search* (CS), *Gray Wolf Optimizer* (GWO) e *Bat-inspired Algorithm* (BiA)). Os autores chegaram a conclusão de que o desempenho dos algoritmos é quase o mesmo, com pequenas diferenças. Já os autores Janssens *et al.* (2007) aplicam um método de clusterização híbrido baseado no qui-quadrado inverso de Fisher (*Fisher's inverse chi-square*) visando agrupar publicações científicas de acordo com os conteúdos textuais e com a estrutura do gráfico de citações.

Os sistemas em nuvem, além dos benefícios que trazem aos usuários, podem apresentar graves problemas de segurança, portanto, Pandeewari & Kumar (2016) criaram um Sistema de Detecção de Intrusão (*Intrusion Detection System* - IDS) para detectar ataques internos e externos (anomalias) utilizando um algoritmo híbrido que é uma mistura do algoritmo de agrupamento Fuzzy C-Means. Já Lyu *et al.* (2017) utilizam um algoritmo de clusterização hiperelipsoidal (*hyperellipsoidal clustering*) para detecção de anomalias em uma abordagem que envolve a internet das coisas (*Internet of Things* – IoT). Com base no estudo

de Moshtaghi *et al.* (2011), uma das alternativas para detecção de anomalias é clusterizar elipsoides, e uma das possíveis situações é na rede de sensores sem fio. Os autores desenvolveram uma teoria subjacente a três medidas de similaridade que podem ser usadas para encontrar *clusters* de elipsoides semelhantes no espaço  $p$ . Os *clusters* de elipsoides são sugeridos por blocos escuros ao longo da diagonal de uma Imagem de dissimilaridade reordenada (Idr). Os autores concluíram que a distância focal é a melhor medida de similaridade elíptica.

Pensando nas diversas abordagens e facilitação que a clusterização propõe, ela foi pensada para trabalhar com os dados das escolas para propor *clusters* que facilitarão a visualização dos diferentes perfis e, por consequência, a gestão dos insumos escolares alimentares. Além da escolha da ferramenta, existem diversos algoritmos e deve ser escolhido o que mais se adapta ao contexto/situação. Para este estudo, optou-se pelo uso do algoritmo K-Modes, pois ele é adequado para lidar com variáveis categóricas, como porte da escola, número de alunos dentro de faixas específicas e quantidade de refeições servidas.

### 3.2.1 Métodos e algoritmos de clusterização

Dividir os algoritmos em métodos não é uma tarefa fácil, pois a noção de *cluster* não é definida com muita precisão (ESTIVILL-CASTRO; YANG, 2000), e por isso existem diversos métodos de clusterização e cada autor tem sua opinião própria. Fraley & Raftery (1998) dividem os métodos de clusterização em duas categorias principais: hierárquicos e particionamento. Já Han & Kamber (2001) categorizam os métodos da clusterização em três categorias principais adicionais: baseada em densidade, baseada em modelo e baseada em grade. Para essa revisão, pelo número de categorias ser mais abrangente, foram escolhidas as classificações baseadas de acordo com Estivill-Castro & Yang (2000), seguidas de seus subgrupos (quando houver):

- Métodos Hierárquicos;
- Métodos de Particionamento;
  - a) Algoritmos de Minimização de Erros;
  - b) Clusterização Teórica de Grafos.
- Métodos Baseados em Densidade;
- Métodos Baseados em Modelos;
  - a) Árvores de Decisão;

- b) Redes Neurais.
- Métodos Baseados em Grades;
- Métodos de Computação Suave.
  - a) Clusterização *Fuzzy*;
  - b) Abordagens Evolucionárias;
  - c) Recozimento Simulado.

A Tabela 12 apresenta um resumo dos métodos, algoritmos utilizados e as problemáticas apresentadas nas principais publicações relacionadas a clusterização, onde o critério foi o número de citações.

Tabela 12 - Principais referências de clusterização encontradas na literatura

<b>AUTOR(ES)</b>	<b>PROBLEMÁTICA</b>	<b>MÉTODO &amp; (ALGORITMO)</b>
Lin <i>et al.</i> (2020)	Identificar grupos de risco sobre inundações repentinas.	Método hierárquico ( <i>ISO-Maximum</i> )
Wild & Brankley (2000)	Selecionar <i>clusters</i> que representam séries químicas.	Método hierárquico ( <i>Ward's Algorithm</i> )
Zhang & Zhao (2014)	Construir um portfólio de índice ótimo com erro de rastreamento minimizado.	Método de particionamento - Algoritmo de minimização de erro ( <i>Genetic Algorithm</i> )
Wu & Leahy (1993)	Segmentação de imagem.	Método de particionamento – Clusterização teórica de grafos ( <i>Gomory-Hu algorithm</i> )
Campello <i>et al.</i> (2013)	Maximizar a estabilidade geral de agrupamentos selecionados,	Método baseado em densidade (DBSCAN)
Sander <i>et al.</i> (1998)	Descobrir <i>clusters</i> de formato arbitrário e distinguir ruídos.	(Método baseado em densidade (GDBSCAN)
Gaddam <i>et al.</i> (2007)	Classificar atividades normais e anômalas em uma rede de computadores, um circuito eletrônico ativo e um sistema mecânico de feixe de massa.	Método baseado em modelos – Árvores de decisão (K-Means+103)
Orhan <i>et al.</i> (2011)	Suporte à decisão diagnóstica no tratamento da epilepsia.	Método baseado em modelos – Redes neurais (K-Means)
Wu & Wilamowski (2016)	Categorizar dados com formas e ruído arbitrários.	Método baseado em densidade e grade (FSFDP e DBSCAN)
Agrawal <i>et al.</i> (2014)	Segmentação intracraniana de imagem cerebral de ressonância magnética usando valores de intensidade de píxel pelo método de detecção de ponto de contorno ótimo.	Método de computação suave – Clusterização <i>fuzzy</i> ( <i>Fuzzy C-Means</i> )
Selim & Alsultan (1991)	A abordagem de recozimento simulado para resolver problemas de otimização é descrita e é proposta para resolver o problema de agrupamento.	Método de computação suave – Recozimento simulado ( <i>Annealing Algorithm</i> )

Fonte: O Autor (2024).

Pensando em analisar na literatura artigos que trabalharam com algoritmos de clusterização envolvendo refeições escolares, são feitas as combinações de palavras-chave no banco de dados da *Scopus*:

- *Clustering AND school AND meal.*

Essa combinação seguiu alguns critérios para eliminar publicações que não fossem do interesse dessa revisão:

- Apenas artigos;
- Em inglês;
- Faz parte de áreas relacionadas a engenharia, matemática, administração e similares.

Após a busca, foram encontrados três artigos: (GRANILLO-MACÍAS, 2021); (BANIUKIEWICZ *et al.*, 2018); (MAHADEVAN *et al.*, 2013), que fazem uso da clusterização envolvendo a gestão de alimentação escolar. Apenas o estudo de Baniukiewicz *et al.* (2018) não havia sido citado na revisão anterior. Uma justificativa para isso pode ser pelo tipo de palavras-chave que o artigo utilizou, que foram as palavras “*network science*”, “*obesity*”, “*spatial networks*” e “*zoning*”.

Granillo-Macías (2021) utilizou o algoritmo de clusterização K-Means como ferramenta de apoio para otimizar a logística de distribuição e entrega de alimentos escolar usando modelos matemáticos que incluem: distância de transporte; localizações ótimas; roteamento de veículos por diferentes *clusters*. Baniukiewicz *et al.* (2018) utilizaram a ideia de clusterização espacial (computacionalmente com um alto desempenho no estudo) para analisar dados de *fast-foods* e escolas em uma região e verificar a influência que os *fast-foods* possuem na alimentação dos alunos. Já Mahadevan *et al.* (2013) utilizam o algoritmo de clusterização K-Means como ferramenta de apoio para roteamento de veículos de entrega de alimentos, onde a distribuição dos veículos foi realizada com base nos *clusters* formados.

De acordo com De Oliveira (2022), os algoritmos mais utilizados e conhecidos na literatura são, respectivamente, os algoritmos K-Means e o DBSCAN, onde o K-Means exige que o número de *clusters* seja estabelecido pelo usuário antes do processo e o DBSCAN não exige isso, além de ser um algoritmo não paramétrico baseado em densidade. Ainda de acordo com a autora, o DBSCAN pode ser usado para identificar *clusters* de qualquer forma em um conjunto de dados contendo ruídos e *outliers*.

O algoritmo K-Modes, derivado do K-Means, possui uma aplicação abordando a alimentação (BHANUPRAKASH; SETTY, 2024). Nessa abordagem, o algoritmo foi

utilizado para agrupar crianças de acordo com em seus padrões alimentares e perfis das doenças causadas pela desnutrição. Outros estudos utilizaram o K-Modes para o ambiente escolar, porém em outras abordagens que não são alimentação, como a clusterização com base nos diferentes tipos de conhecimento que os alunos possuem (KHAYI; RUS, 2019) e uso do algoritmo como ferramenta de apoio na avaliação do treinamento de professores (HUANG, 2023).

Como visto na revisão, não existem trabalhos com o uso do K-Modes considerando a problemática de alimentação escolar. Desta forma, observa-se a necessidade de discussão e aplicação do K-Modes, que será abordado nessa dissertação. E com base no que foi exposto na fundamentação teórica e nas aplicações dos artigos que trabalharam com clusterização, o método proposto que mais se adequa ao problema do presente estudo é o método baseado em centróides (particional). Essa escolha se deve ao fato de que os métodos particionais, como o K-Modes, são eficazes para segmentar um grande número de objetos em grupos distintos, onde o número de *clusters* é pré-definido. Diferente de métodos hierárquicos, que não são escaláveis para grandes conjuntos de dados, ou baseados em densidade, que exigem parâmetros específicos para identificar *clusters*, os métodos particionais oferecem maior controle sobre o agrupamento. No caso deste estudo, a necessidade de segmentar escolas de acordo com perfis categóricos faz com que a abordagem particional seja mais apropriada, pois permite definir grupos de escolas com características similares, facilitando a gestão dos insumos escolares.

## 4 METODOLOGIA

Neste capítulo, será abordado os procedimentos metodológicos que servirão como base para a elaboração desse estudo, referente a proposta de aspectos gerenciais que irão direcionar a gestão dos insumos alimentares nas escolas municipais da cidade de Caruaru-PE. São apresentadas além das classificações metodológicas que conduzirão esse estudo, as etapas de construção com base no modelo apresentado por Ramos (2020).

### 4.1 NATUREZA DA PESQUISA

Ramos (2020) divide a natureza da pesquisa em 2 categorias: básica e aplicada. A natureza da pesquisa básica, de acordo com a autora, está associada a algo novo, um avanço na ciência, não necessitando ser aplicada. Já a aplicada, é direcionada a aplicação de conhecimentos prévios para encontrar a solução de um problema específico. Portanto, a natureza da pesquisa desse estudo tem categoria aplicada, pois partirá de conhecimentos já existentes, ferramentas e algoritmos, como ferramentas de apoio para a gestão municipal de insumos nas escolas.

### 4.2 CLASSIFICAÇÃO DA PESQUISA

O projeto possui tanto característica qualitativa, como quantitativa, e o nome dado quando isso ocorre é “quali-quantitativa”. A abordagem qualitativa é feita para desenvolver a pesquisa que fará toda a gestão dos dados para torná-los úteis para a problemática e a abordagem quantitativa é referente as etapas da pesquisa que lidam com dados numéricos como os dados como as variáveis numéricas que são transformadas em categóricas e o próprio algoritmo que possui etapas dessa natureza quantitativa.

Já o direcionamento desta pesquisa possui uma natureza exploratória, pois foca na investigação dos diferentes perfis que as escolas possuem e de como elas serão agrupadas para serem pensadas em novas estratégias e ações que sirvam de apoio a gestão de insumos

### 4.3 PROCEDIMENTOS DE COLETA DE DADOS

A coleta de dados foi feita com base em entrevistas com responsáveis pela

distribuição dos insumos alimentares para as escolas, sendo esses responsáveis:

- Nutricionistas;
- Gerente administrativo;
- Motoristas responsáveis pela entrega;
- Secretária;
- Gestores das escolas.

Os dados foram passados por meio de anotações, documentos impressos e planilhas, onde algumas informações já estavam prontas e outras foram organizadas conforme o autor desse estudo solicitava. A coleta de dados foi referente a:

- Listagem das escolas;
- Características das escolas;
- Alimentos disponíveis para entrega;
- Cardápio das escolas;
- Como são feitas as entregas dos alimentos;
- Dias que os alimentos são entregues em cada escola;
- Consumo per capita dos estudantes.

#### 4.4 DESCRIÇÃO METODOLÓGICA DAS ETAPAS DO ESTUDO

O presente estudo apresenta 8 etapas metodológicas que direcionam toda a pesquisa, desde a fase de embasamento teórico até as interpretações dos resultados.

As etapas 1 e 2 consistem na realização da fundamentação teórica e da revisão da literatura, de forma a obter embasamento suficiente sobre as lacunas e características existentes no que diz respeito ao tema em questão e ao uso de ferramentas de clusterização, bem como o entendimento dos diferentes tipos de algoritmos de clusterização. Esta revisão tem como base livros e artigos publicados em periódicos e congressos que tenham relação com a área de estudo.

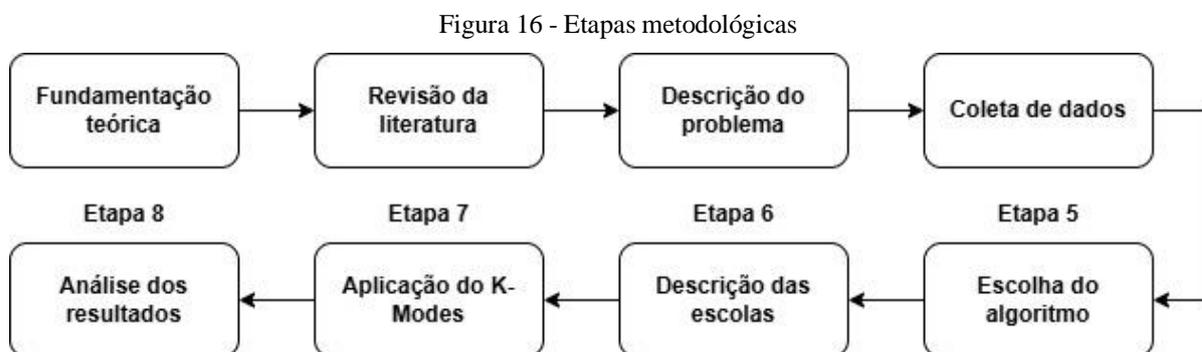
A etapa 3 é referente ao estudo de caso, onde é feita a descrição do problema, contendo todos os detalhes do que o estudo aborda. A etapa 4 consiste na coleta de dados, onde todos os dados desse estudo foram fornecidos pela SEDUC, no qual a autorização para coleta desses dados ocorreu com a apresentação da carta de declaração de apoio e interesse pela pesquisa, conforme Anexo A.

A etapa 5 vem logo após a coleta de dados, que servirá como fator importante na

escolha do algoritmo de clusterização, onde o algoritmo é escolhido de acordo com as características do método e as características do problema abordado. A metodologia de clusterização com o algoritmo K-Modes foi escolhida para permitir uma segmentação das escolas baseada em suas características, como o porte e a quantidade de refeições. Esta abordagem difere do sistema TGS utilizado atualmente. Em sequência, a etapa 6 é referente a descrição e análise dos dados das escolas, onde é visto que cada escola possui perfis diferentes, variando desde sua localização até mesmo sua capacidade de alunos, demanda de refeições e quantidade de alunos ativos.

Na etapa 7 é aplicado o algoritmo K-Modes para definir quais serão os *clusters* e definir quais escolas farão parte de cada um. Por fim, na etapa 8, é realizada as análises dos resultados, onde são sugeridos aspectos gerenciais baseados nos resultados e nos desperdícios alimentares que podem ocorrer dependendo da quantidade de insumos que é entregue nas escolas, além das considerações finais.

Essas etapas metodológicas da dissertação não baseiam-se em um modelo de algum autor já estabelecido ou adaptação de alguma metodologia de algum estudo, e sim em como a pesquisa foi conduzida. Um resumo dessas 8 etapas é apresentada na Figura 16.



Fonte: O Autor (2024).

## 5 APLICAÇÃO DO K-MODES PARA CLUSTERIZAÇÃO DAS ESCOLAS

Neste capítulo, será apresentada a aplicação do algoritmo K-Modes para a clusterização das escolas municipais localizadas na cidade de Caruaru-PE, quanto a seus perfis, sendo definidos de acordo com o número de alunos, porte da escola, categoria da escola e número de refeições que é demandada pela escola na semana. Após isso, serão propostos aspectos gerenciais que irão direcionar a gestão dos insumos para as escolas com base em algumas estimativas: quantidade de alimentos demandada e desperdício de alimentos.

### 5.1 ANÁLISE CONTEXTUAL DO PROBLEMA ESTUDADO

As escolas municipais de Caruaru-PE são distribuídas em 9 regiões (TGSs), onde essas regiões são divididas entre zona rural e zona urbana. Além de possuírem diferentes números de alunos, capacidade de alunos e níveis de alunos, são também diferenciadas pela demanda de refeições, sendo essa demanda estimada com base na quantidade de alunos e na etapa escolar que esse aluno está inserido.

No total são 144 escolas que possuem diferentes perfis e diferentes necessidades de reposição de alimentos. De acordo com o FNDE (2020) e com o Ministério da Saúde (2014), são utilizadas como referências algumas diretrizes do PNAE contendo estimativas sobre a nutrição escolar relacionadas ao consumo médio diário por refeição e a quantidade média, em gramas, que cada aluno consome, de acordo com seu nível escolar e faixa etária.

Alunos da categoria CMEI (de 3 à 5 anos):

- Servir 5 refeições ao dia, de acordo com a SEDUC;
- É recomendado que cada refeição forneça de 15% a 20% das necessidades nutricionais diárias;
- Conter de 200 a 300 gramas de alimentos sólidos, por refeição.

Alunos da categoria Fundamental I e II (6 à 15 anos):

- Servir 3 ou 4 refeições, de acordo com a SEDUC, sendo 3 refeições para escolas da categoria ETI e 4 refeições para escolas da categoria EM;
- É recomendado que cada refeição forneça de 20% a 30% das necessidades nutricionais diárias;
- Conter de 300 a 400 gramas de alimentos sólidos, por refeição.

Alunos da categoria EJA (19 à 60 anos):

- Servir 1 refeição, de acordo com a SEDUC;
- É recomendado que cada refeição forneça 30% das necessidades nutricionais diárias;
- Conter de 400 a 500 gramas de alimentos sólidos, por refeição.

Ainda de acordo com o Ministério da Saúde (2014), é reconhecida a variabilidade nas necessidades energéticas e nutricionais dependendo do indivíduo, sugerindo a adaptação de porções de acordo com as necessidades individuais, podendo variar para esse estudo em torno de 10% para mais ou para menos.

Para que haja uma maior eficiência na entrega dos alimentos nas escolas, é importante que seja analisado qual a demanda de cada escola. Essa demanda é baseada no número de refeições e na quantidade de alimentos a serem entregues. A Equação 5 é referente ao cálculo do número de refeições de cada escola e a Equação 6 é referente ao cálculo da quantidade necessária, em gramas, de alimentos por escola.

$$R = T_i * n \quad (5)$$

Onde:

- R = Número total de refeições na semana, na escola;
- $T_i$  ( $i = 1, 2, 3, 4$ ) = Número de refeições servidas semanalmente de acordo com o tipo da escola: 1 = EJA; 2 = ETI; 3 = EM; 4 = CMEI;
- $n$  = Número total de alunos.

$$Q = R * P_j \quad (6)$$

Onde:

- Q = Peso total de alimentos que serão demandados para a escola, naquela semana;
- $P_j$  ( $j = 1, 2, 3$ ) = Peso recomendado que cada aluno deve consumir, por refeição: 1 = CMEI; 2 = EJA; 3 = Fundamental I e II).

Tendo como base essas estimativas, é possível evitar tanto a falta de alimentos como o desperdício em excesso.

Com base em Busato & Ferigollo (2018), no Brasil, o desperdício de alimentos chega a 40mil toneladas de alimentos por dia, onde as escolas possuem uma parcela dessa estimativa. Ricarte *et al.* (2021) afirmam que é importante definir os diferentes tipos de

desperdícios, onde existe o desperdício por parte de alimentos que não chegaram a ser utilizados e sobras em pratos de alimentos prontos que vão para o lixo.

O desperdício que ocorre com base na sobra de alimentos não utilizados (sobras limpas) aborda a questão com base no que é ofertado e o que é demandado, onde muitas vezes é recebido mais do que é necessário, muitas vezes com receio de que falte alimentos. Porém dependendo da quantidade em excesso, os alimentos podem acabar estragando ou indo para o lixo por falta de espaço nas escolas. Já o desperdício que ocorre com base nas sobras que ficam nos pratos dos estudantes possuem relação com a quantidade de porções que são oferecidas aos estudantes.

## 5.2 ESCOLHA DO ALGORITMO DE ACORDO COM AS CARACTERÍSTICAS DO PROBLEMA

Para seleção do algoritmo, como o foco é realizar a clusterização baseada em centróides (clusterização particional), e não com base em regiões de alta densidade, distribuições probabilísticas e nem mesmo hierarquia de *clusters*, foi delimitado que há 3 alternativas de escolha de algoritmos para ser utilizado na problemática:

- K-Means;
- K-Modes;
- K-Prototypes.

O que definiu a escolha do algoritmo foi o modo como as variáveis que representam as características das escolas seriam tratadas. O K-Means (MACQUEEN, 1967) trabalha apenas com variáveis numéricas, o K-Modes (HUANG, 1997a) trabalha apenas com variáveis categóricas e o K-Prototypes possibilita um misto entre variáveis numéricas e categóricas (HUANG, 1997b).

O problema possui variáveis que são definidas como categóricas, onde cada escola possui características que são divididas em classes, tratadas com base em intervalos categorizados. Dessa forma, o K-Modes foi o algoritmo escolhido. O porte das escolas é definido com base em uma categoria que é um intervalo de alunos. O próprio intervalo de alunos é tratado com base em intervalos que tem o objetivo de identificar quais escolas fazem parte daquele intervalo. O mesmo funciona para o número de refeições. Por fim, como são 3 tipos de escolas, esses grupos são 3 classes diferentes.

O K-Modes é uma variação do K-Means (CHATURVEDI *et al.*, 2001) que foi projetada especificamente para dados categóricos, ou seja, em vez de calcular a média dos

pontos dos dados para encontrar o centro do *cluster*, o K-Modes usa a moda dos atributos categóricos para definir o centro do *cluster*.

### 5.3 DESCRIÇÃO DAS ESCOLAS

No total são 144 escolas na cidade de Caruaru-PE que são consideradas municipais, onde a diferenciação de seus perfis ocorre de acordo com as seguintes características:

- Tipo de escola;
- TGS;
- Porte da escola;
- Quantidade de alunos;
- Quantidade de refeições.

Na Tabela 1B são apresentadas as escolas, em ordem alfabética, e suas características, que servirão de base para criação dos clusters e separação das escolas por grupos de afinidade.

Para formação dos *clusters* no próximo tópico, são consideradas categorias, onde as variáveis que não eram numéricas continuaram dessa forma e as variáveis numéricas foram transformadas em variáveis categóricas. O TGS das escolas não foi considerado para definição dos *clusters*, somente para resultados posteriores a formação dos mesmos.

### 5.4 APLICAÇÃO DO K-MODES

Para o presente estudo, pretende-se agrupar as escolas em *clusters* de acordo com seus diferentes perfis. Para se obter o resultado final com o algoritmo K-Modes, primeiramente foi preciso ter conhecimento da quantidade de *clusters* que seria utilizada para direcionar a gestão. Para chegar na resposta, foram feitos testes com o K-Modes para 4, 5 e 6 *clusters*.

Os tipos de escolas que foram utilizados no algoritmo foram:

- EM;
- ETI;
- CMEI.

Os portes das escolas que foram utilizados no algoritmo foram:

- Pequeno;
- Médio;
- Grande.

Os intervalos de alunos que caracterizaram as escolas foram:

- De 2 a 49;
- De 50 a 99;
- De 100 a 149;
- De 150 a 349;
- De 350 a 799;
- De 800 a 1900;
- Acima de 1900.

Os intervalos de refeições que caracterizaram as escolas foram:

- De 2 a 99;
- De 100 a 199;
- De 200 a 299;
- De 300 a 699;
- De 700 a 1299;
- De 1300 a 2199;
- De 2200 a 8200.

O passo-a-passo do K-Modes, tendo as informações categóricas de cada escola e o número pré-definido de *clusters*, é feito com base no Algoritmo 1.

---

#### ALGORITMO 1: K-MODES

---

##### INICIALIZAÇÃO

- 01: Seja  $k = 5$
- 02: Utilizar as modas dos *clusters* formados como centroides
- 03: **Enquanto** houver diferença entre as escolas e o *cluster faça*
- 04:     **Para** cada escola no conjunto de dados **faça**
- 05:             **Para** cada centroide de *cluster faça*
- 06:                     Comparar cada variável categórica da escola com o centróide
- 07:                     **Se** a variável for diferente
- 08:                             Adicionar 1
- 09:                     **Senão:** Adicionar 0
- 10:                     **Fim Se**
- 11:             **Fim Para**
- 12:     Atribuir a escola ao *cluster* com a menor distância

- 13:           **Se** houver empate  
 14:           Escolher aleatoriamente  
 15:           **Fim Se**  
 16:   **Fim Para**  
 17: **Fim Enquanto**  
 18: Retornar as escolas agrupadas nos 5 *clusters* com seus respectivos centróides  
 19: **Fim**
- 

Com base no Algoritmo 1, as escolas que não foram agrupadas com base na total semelhança com os *clusters* formados, foram alocadas com base na menor distância ao centróide do *cluster* que a escola apresentou essa mínima diferença e o processo é repetido até todas as escolas estarem agrupadas.

Um total de 5 *clusters* de referência, obtidos pelo K-Modes, são apresentados na Tabela 13. A análise com 4 *clusters* não foi satisfatória, pois com um *cluster* a menos, foi visto que quase todas as escolas saíram do cluster removido (*cluster 2*) para um outro *cluster* (*cluster 1*), o sobrecarregando. Essa fusão resultou em um *cluster 1* heterogêneo, que passaria a incluir escolas com características muito diferentes, comprometendo a coerência da segmentação. A análise com 6 *clusters* também não foi satisfatória, pois foi criado gerado um 6° *cluster* com escolas alocadas do *cluster 2* e do *cluster 5*, se tornando um *cluster* com poucas escolas (12 unidades), resultando em uma segmentação excessiva. Além disso, as características desse *cluster* são próximas às do *cluster 5*, o que sugere que essa divisão não acrescenta uma diferenciação significativa. A análise com 5 *clusters* apresenta uma distribuição mais equilibrada das escolas e mantém a coerência em suas características, agrupando escolas com perfis semelhantes.

Tendo a definição da quantidade de *clusters* que será utilizada, é então aplicado o K-Modes para tratar com as variáveis categóricas do problema para um número de 5 *clusters*. O K-Modes além de identificar quais serão as características dos 5 *clusters* do problema com base na moda das características das escolas, também aloca as escolas que não possuem todas as características semelhantes aos *clusters* mais próximos do perfil.

Após aplicação do K-Modes, foram formados os 5 *clusters* com suas respectivas escolas que são consideradas de mesmo perfil. A Tabela 13 apresenta as características dos *clusters* formados e as Tabelas 14, 15, 16, 17, 18 apresentam quais escolas são pertencentes.

Tabela 13 - Características dos *clusters*

Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5
Tipo da escola: EM	Tipo da escola: EM	Tipo da escola: EM	Tipo de escola: EM	Tipo de escola: CMEI
De 2 a 49 alunos	De 50 a 99 alunos	De 350 a 799 alunos	De 800 a 1900 alunos	De 150 a 349 alunos
Pequeno porte	Pequeno porte	Médio porte	Grande porte	Pequeno porte
De 2 a 99 refeições servidas na semana	De 200 a 299 refeições servidas na semana	De 1300 a 2199 refeições servidas na semana	De 2200 a 8200 refeições servidas na semana	De 700 a 1299 refeições servidas na semana

Fonte: O Autor (2024).

Tabela 14 - Escolas pertencentes ao *Cluster 1*

ID	Escola	ID	Escola
1	Adelino Alves da Silva	18	José Severino de Amorim
2	Antônia Maria da Conceição Costa	19	Manoel Bandeira
3	Antônio Martins	20	Manoel Henrique da Silva
4	Assentamento Macambira Borba	21	Manoel Trajano de Arruda
5	Batista da Silva	22	Manoel Valdevino
6	Belísio Córdula	23	Marcionilo Soares
7	Cônego Julio Cabral	24	Maria Martins de Melo
8	João Cursino	25	Nossa Senhora de Aparecida
9	João Demócrito Florêncio	26	Padre Antônio Faustino
10	João Patrício de Carvalho	27	Professora Cacilda Santos
11	João Vênio da Silva	28	Professora Maria Cândida
12	João XXIII	29	Professora Maria de Lourdes Azevedo Lira
13	Joaquim Nabuco	30	Sabino José Pereira da Silva
14	José Barbosa	31	Santa Inês
15	José Faustino Vila Nova	32	São Severino
16	José Raimundo Paes de Lira	33	São Vicente de Paula
17	José Raimundo Sobrinho	34	Vicente Correia

Fonte: O Autor (2024).

Tabela 15 - Escolas pertencentes ao *Cluster 2*

ID	Escola	ID	Escola
1	Abílio Luis de Torres	16	Manoel Félix de Almeida
2	Alfredo Pinto Vieira de Melo	17	Maria Alice
3	Dom Miguel Severino de Lima	18	Maria José de França
4	Dona Maria Digna	19	Natalice Limeira
5	Dr. Oscar Barreto	20	Nossa Senhora das Dores
6	Duda Umbuzeiro	21	Pedro de Andrade
7	Fortunato Ribeiro da Silva	22	Professora Eunice Tabosa
8	Francelino Guilherme de Azevedo	23	Professora Maria de Lourdes Pepeu
9	Francisca Maria da Conceição	24	Professora Maria Emília
10	Francisco Borges	25	Santa Regina

11	Heleno Cumarú	26	São José
12	João Luiz Torres	27	São Judas Tadeu
13	José Manoel da Silveira	28	São Luiz de Gonzaga
14	Josefa Maria da Conceição Dandon	29	Típica Rural
15	Leonor Felicidade da Conceição	30	Tomé Claudino Torres

Fonte: O Autor (2024).

Tabela 16 - Escolas pertencentes ao *Cluster 3*

ID	Escola	ID	Escola
1	Álvaro Lins	17	Manoel Limeira
2	Artista Plástica Luisa Cavalcanti Maciel	18	Maria Félix
3	Babu	19	Padre Pedro Batista de Aguiar
4	Capitão João Velho	20	Paulina Monteiro
5	Capitão Rufino	21	Pedro de Souza
6	Dr. Amaro de Lyra e César	22	Prefeito Anastácio Rodrigues da Silva
7	Dr. Tabosa de Almeida	23	Prefeito João Lyra Filho
8	Escola Municipal Fernando Soares Lira	24	Professor Amaro Matias Silva
9	Escola Reunida Casa do Trabalhador	25	Professor Carlos Antonio Amaral de Almeida
10	Escolas Reunidas Duque de Caxias	26	Professor José Florêncio Leão
11	Guiomar Alves de Lima - Guiomar Lima	27	Professor Rubem de Lima Barros
12	Irmã Ceciliana Gross	28	Professora Cesarina Moura Vieira Costa
13	Joel Pontes	29	Professora Gianete Silva
14	José Clemente de Souza	30	Professora Maria Bezerra Torres
15	Landelino Rocha	31	Professora Maria de Lourdes Nascimento Pontes - Tia Lourdinha
16	Lions Club	32	Severino José de Oliveira

Fonte: O Autor (2024).

Tabela 17 - Escolas pertencentes ao *Cluster 4*

ID	Escola	ID	Escola
1	Colégio Municipal Professor Luiz Pessoa da Silva	11	Professor José Florêncio Neto (Professor Machadinho)
2	Colégio Municipal Professora Laura Florêncio	12	Professor José Laurentino Santos
3	Deputada Cristina Tavares	13	Professor Kermógenes Dias de Araújo
4	Dom Bernardino Marchiό	14	Professor Leudo Valença
5	Duque de Caxias	15	Professora Josélia Florêncio da Silveira
6	Mestre Vitalino	16	Professora Margarida Maria de Farias Barros Miranda
7	Nossa Senhora de Fátima	17	Professora Mariana de Lourdes Lima
8	Presidente Kennedy	18	Professora Sinhazinha
9	Professor Altair Nunes Porto Filho	19	Professora Teresa Neuma Pereira Pedrosa
10	Professor Augusto Tabosa	20	Santos Anjos

Fonte: O Autor (2024).

Tabela 18 - Escolas pertencentes ao *Cluster 5*

ID	Escola	ID	Escola
1	Amélia Tereza da Conceição	15	Maria Aleir Ribeiro Galvão
2	Artesão Severino Vitalino	16	Maria Anunciada Rodrigues
3	Dom Antonio Soares Costa	17	Professora Guiomar Lyra
4	Érika Patrícia	18	Professora Iva do Carmo Silva
5	Escola Intermediária Maria do Socorro de Freitas	19	Professora Lindomar Pinheiro
6	Evangélica Reverendo Genésio Campos	20	Professora Maria do Carmo Queiroz Cabral
7	Flora Bezerra	21	Professora Nerine Francisca de Carvalho

8	Helena Martins Gomes	22	Severina Maria do Carmo - Dona Biu
9	Irmã Rosália	23	Severino Oliveira da Silva - Professor Biu Oliveira
10	Ivanise Flora Araújo de Menezes	24	Tia Carminha
11	José Pinheiro dos Santos Filho	25	Tia Clarice
12	Justina de Freitas	26	Tia Malude
13	Leopoldina Queiroz de Lima	27	Vereador José Ailton do Nascimento
14	Major Sinval	28	Wirton Lira

Fonte: O Autor (2024).

O *cluster* que possui menos escolas é o 4 com um total de 20 escolas, e o *cluster* que possui mais escolas é o 1 com um total de 34 escolas. Os *clusters* 2, 3 e 5 possuem respectivamente 30, 32 e 28 escolas.

A análise dos *clusters* sugere que as escolas agrupadas compartilham características semelhantes, mas com algumas variações dentro de cada *cluster*. No *cluster* 2, por exemplo, todas as escolas são de pequeno porte, mas há variações na quantidade de alunos e no número de refeições servidas. Isso indica que, embora o algoritmo tenha identificado um padrão, há nuances que podem influenciar a gestão dos insumos. No *cluster* 3, formado majoritariamente por escolas de médio porte, foi observada uma diversidade maior nos tipos de escolas. Essa diversidade pode demandar estratégias diferenciadas de distribuição, considerando as necessidades específicas de cada tipo de escola.

Além disso, alguns *clusters* apresentam escolas distribuídas em diferentes TGSs, reforçando a ideia de que a localização geográfica, isoladamente, pode não ser o fator mais determinante para a alocação dos insumos alimentares. No *cluster* 5, por exemplo, há escolas espalhadas por quase todos os TGSs do município, o que pode indicar que perfis semelhantes de demanda alimentares não estão necessariamente agrupados em uma mesma região. Esse aspecto pode ser relevante para um planejamento logístico mais eficiente, possibilitando ajustes na periodicidade e no volume das entregas conforme as características das escolas.

Dessa forma, os agrupamentos gerados pelo K-Modes não devem ser vistos como uma classificação rígida, mas sim como um ponto de partida para compreender padrões e tendências na demanda alimentar.

## 5.5 PROPOSTAS GERENCIAIS PARA A GESTÃO DOS INSUMOS ALIMENTARES

No *cluster* 1, entre as 34 escolas, todas são de pequeno porte e todas elas, no critério de número de alunos, se enquadram nas características do *cluster*, onde a escola que possui menos alunos é a Professora Maria de Lourdes Azevedo Lira, com 6 alunos, e as escolas com

mais alunos são as que possuem 43 alunos. Todas as escolas são do tipo EM e estão localizadas do TGS 1 ao TGS 4, onde os IDs das escolas em cada TGS são apresentadas a seguir. Os IDs de cada escola podem ser vistos nas Tabelas 14, 15, 16, 17 e 18.

- TGS 1: ID 2, 3, 6, 17, 19, 24, 25 e 28;
- TGS 2: ID 1, 4, 10, 11, 13, 14, 20, 21, 22, 30 e 34;
- TGS 3: ID 16, 23, 32 e 33;
- TGS 4: ID 5, 7, 8, 9, 12, 15, 18, 26, 27, 29 e 31.

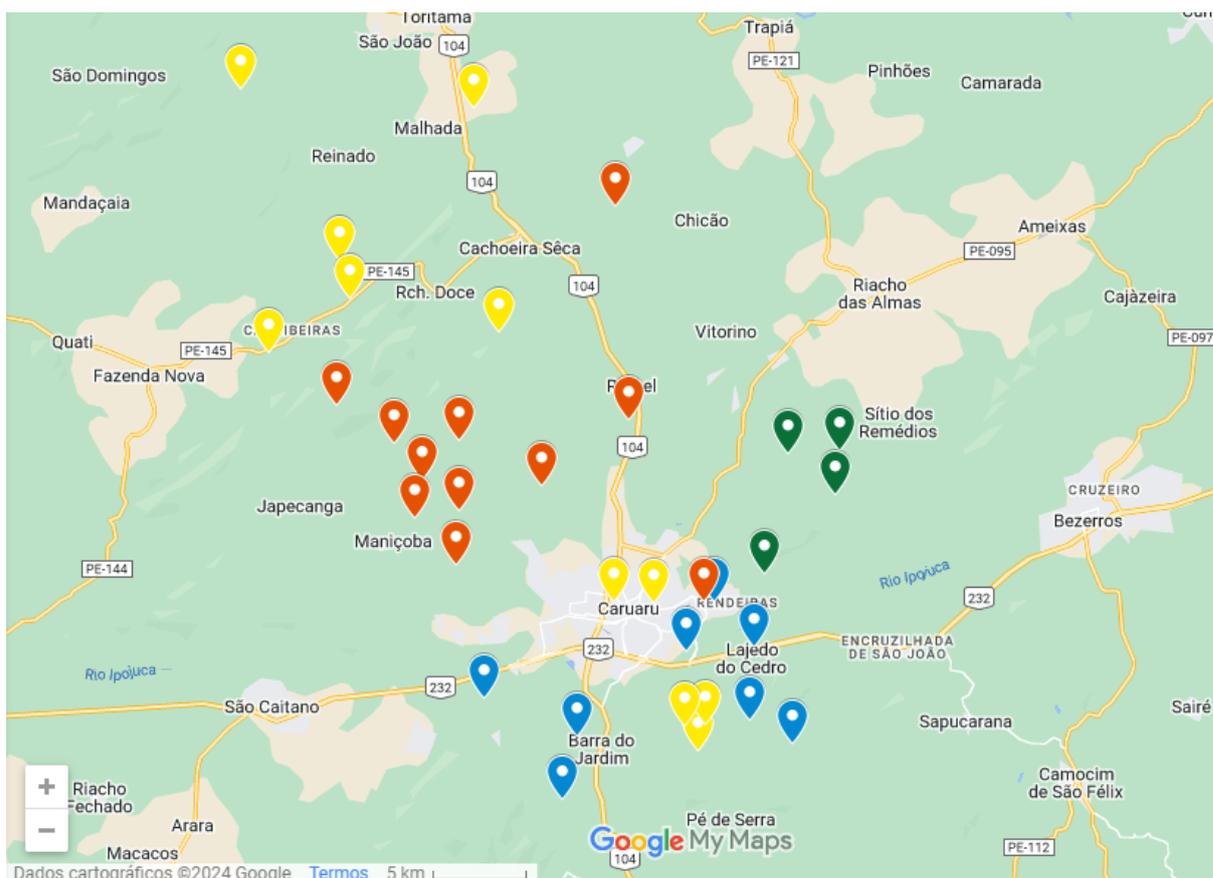
Em relação ao número de refeições, algumas escolas possuem um intervalo diferente do que representa o *cluster* 1, como pode ser visto na lista abaixo.

- Diferente: ID 1, 2, 6, 10, 12, 13, 16, 17, 19, 25, 26, 27, 31, 32 e 33;
- Mesmo intervalo: ID 3, 4, 5, 7, 8, 9, 11, 14, 15, 18, 20, 21, 22, 23, 24, 28, 29, 30 e 34.

A escola Professora Maria de Lourdes Azevedo Lira, que apresenta o menor número de refeições semanal, conta com apenas 24 refeições na semana, já a escola com maior número de refeições que é a líder do *cluster*, é a escola Joaquim Nabuco, com 187 refeições semanais.

No total, 19 escolas possuem características idênticas ao *cluster* e 15 escolas foram agregadas ao *cluster* por meio da aproximação com as escolas já inclusas, onde a diferença dessas 15 escolas foram de apenas um critério (referente à quantidade de refeições servidas). A Figura 17 apresenta as escolas que fazem parte do *cluster* 1 divididas por TGS, onde cada TGS apresenta uma cor diferente.

- TGS 1 – Azul;
- TGS 2 – Amarelo;
- TGS 3 – Verde;
- TGS 4 – Vermelho.

Figura 17 – Localização das escolas do *cluster 1*

Fonte: O Autor (2024).

No *cluster 2*, entre as 30 escolas, todas elas são de pequeno porte. Algumas dessas escolas possuem um total de alunos diferente do intervalo do *cluster*, onde essas escolas são listadas abaixo.

- Diferente: ID 5, 6, 12 e 23;
- Mesmo intervalo: ID 1, 2, 3, 4, 7, 8, 9, 10, 11, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 24, 25, 26, 27, 28, 29 e 30.

A escola Leonor Felicidade da Conceição é a que possui a menor quantidade de alunos do *cluster*, que equivale a 47, e a escola Professora Maria de Lourdes Pepeu lidera nesse critério, com um total de 129 alunos.

Há uma escola (ID 11) que não é da categoria EM, estando na categoria CMEI. A listagem abaixo mostra as escolas pertencentes ao *cluster 2* e seus respectivos TGSs.

- TGS 1: ID 11, 12, 21, 23 e 30;
- TGS 2: ID 2, 6, 15, 16 e 18;
- TGS 3: ID 5, 7, 10, 13, 14, 17, 19, 24, 25, 28 e 29;
- TGS 4: ID 1, 3, 4, 8, 9, 20, 22, 26 e 27.

Além de algumas escolas terem diferenças da característica do *cluster* no intervalo de alunos, há um grupo de escolas que se diferenciam do intervalo de refeições: 3, 4, 5, 6, 7, 10, 12, 16, 18, 19, 23, 26 e 30. A escola São José apresenta o menor número de refeições semanais do *cluster*, totalizando 161, e a escola Professora Maria de Lourdes Pepeu é a líder do grupo nesse quesito, com 545 refeições semanais.

Há um total de 16 escolas que possuem características idênticas ao *cluster*, e 14 escolas foram agregadas ao *cluster* por meio da aproximação às escolas que já estavam inclusas. As diferenças nessas 14 escolas foram:

- Tipo da escola: ID 11;
- Intervalo de refeições: ID 3, 4, 7, 10, 16, 18, 19, 26 e 30;
- Intervalo de alunos: ID 5, 6, 12 e 23.

Ou seja, das 14 escolas, 10 delas possuem 1 característica diferente (ID 11) e 4 delas, 2 características diferentes (IDs 5, 6, 12 e 23). A Figura 18 apresenta as escolas que fazem parte do *cluster 2*, divididas por TGS, onde cada TGS apresenta uma cor diferente.

- TGS 1 – Azul;
- TGS 2 – Amarelo;
- TGS 3 – Verde;
- TGS 4 – Vermelho.



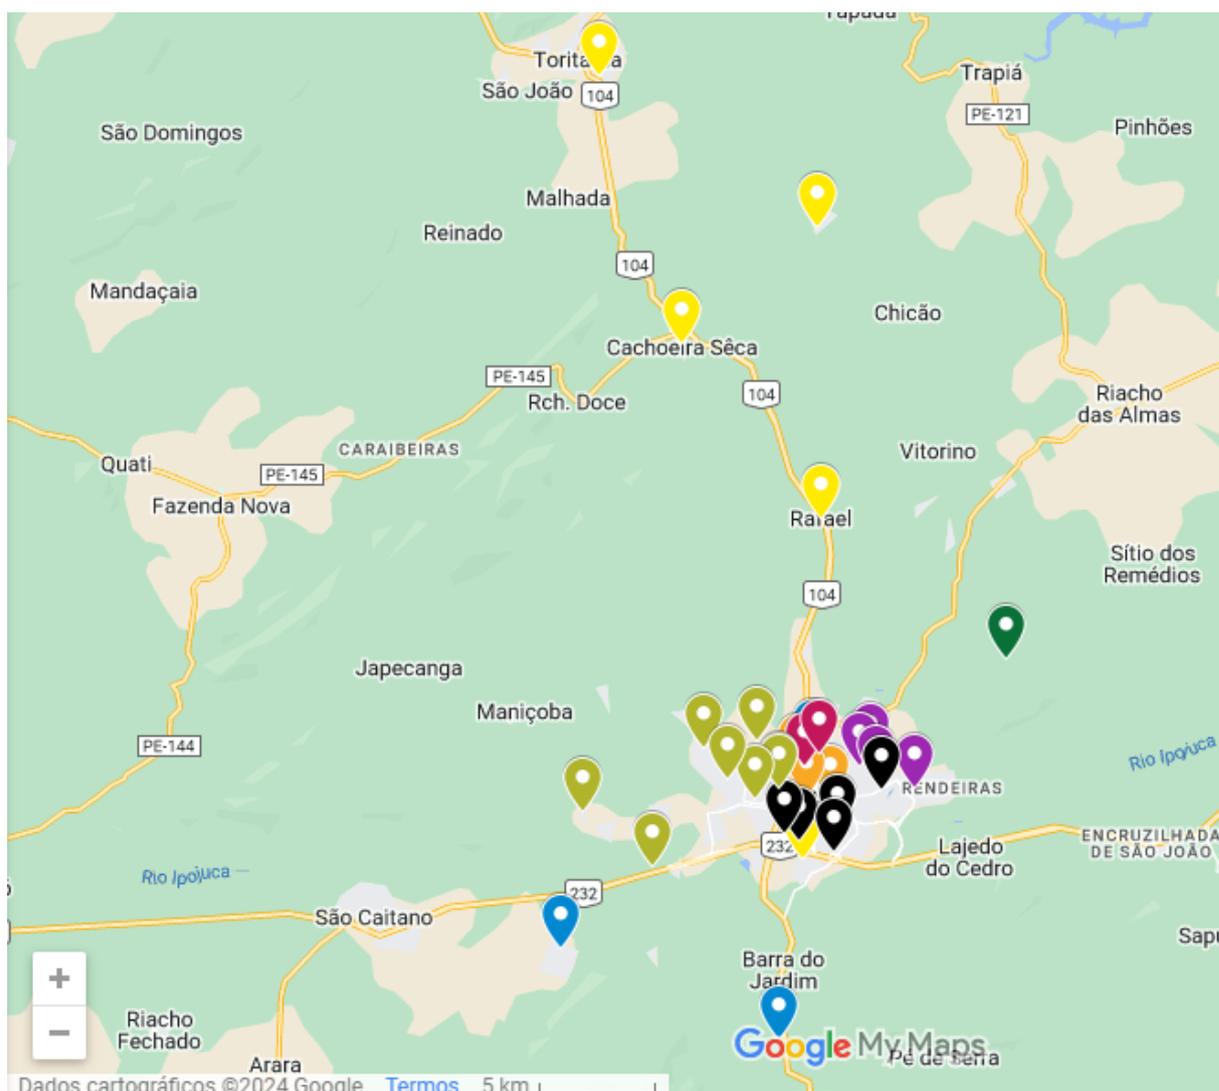
Há um total de 6 escolas com intervalos de refeições diferentes do que define o *cluster*: ID 2, 4, 9, 14, 16 e 28, onde a ID 16 é a líder do *cluster* nesse quesito e a ID 4 é a com pior desempenho nesse critério.

Esse *cluster*, diferente dos *clusters* anteriores comentados nesse tópico, possuem escolas espalhadas por quase todos os TGSs. O único TGS que não apresenta escolas nesse grupo é o TGS 4. Abaixo estão listadas as escolas pertencentes a cada TGS.

- TGS 1: ID 7, 15 e 30;
- TGS 2: ID 5, 14, 17, 18 e 28;
- TGS 3: ID 4;
- TGS 5: ID 8, 9, 10 e 26;
- TGS 6: ID 1 e 12;
- TGS 7: ID 22, 23, 24 e 27;
- TGS 8: ID 13, 20, 21, 29 e 32;
- TGS 9: ID 2, 3, 6, 11, 16, 19, 25 e 31.

A Figura 19 complementa as informações passadas com a localização das escolas pertencentes a esse *cluster*, onde cada cor corresponde a um TGS diferente.

- TGS 1 – Azul;
- TGS 2 – Amarelo;
- TGS 3 – Verde;
- TGS 5 – Laranja;
- TGS 6 – Rosa;
- TGS 7 – Roxo;
- TGS 8 – Preto;
- TGS 9 – Bege.

Figura 19 – Localização das escolas do *cluster* 3

Fonte: O Autor (2024).

Em comparação com os 2 *clusters* vistos anteriormente a este, neste tópico, o *cluster* 3 foi o que mais houveram escolas com no mínimo uma diferença do que caracteriza o *cluster*. No total foram 13 escolas com características idênticas ao *cluster* e 19 escolas com pelo menos uma diferença. As diferenças e quais escolas fizeram parte desses grupos é listado a seguir.

- Tipo da escola – ID: 1, 3, 6, 10, 12, 22, 23, 27 e 32;
- Intervalo de refeições – ID: 9, 14, 16 e 28;
- Intervalo de refeições e intervalo de alunos – ID: 4;
- Intervalo de refeições e tipo de escola – ID: 2;
- Intervalo de alunos e tipo de escola – ID: 8, 11, 25 e 31.

Em resumo, das 19 escolas, 13 delas possuem 1 característica diferente (IDs 1, 3, 6, 9,

10, 12, 14, 16, 22, 23, 27, 28 e 32) e 6 escolas possuem 2 características diferentes (IDs 2, 4, 8, 11, 25 e 31). Nenhuma escola, durante o processo do algoritmo K-Modes, foi agrupada com 3 ou mais diferenças.

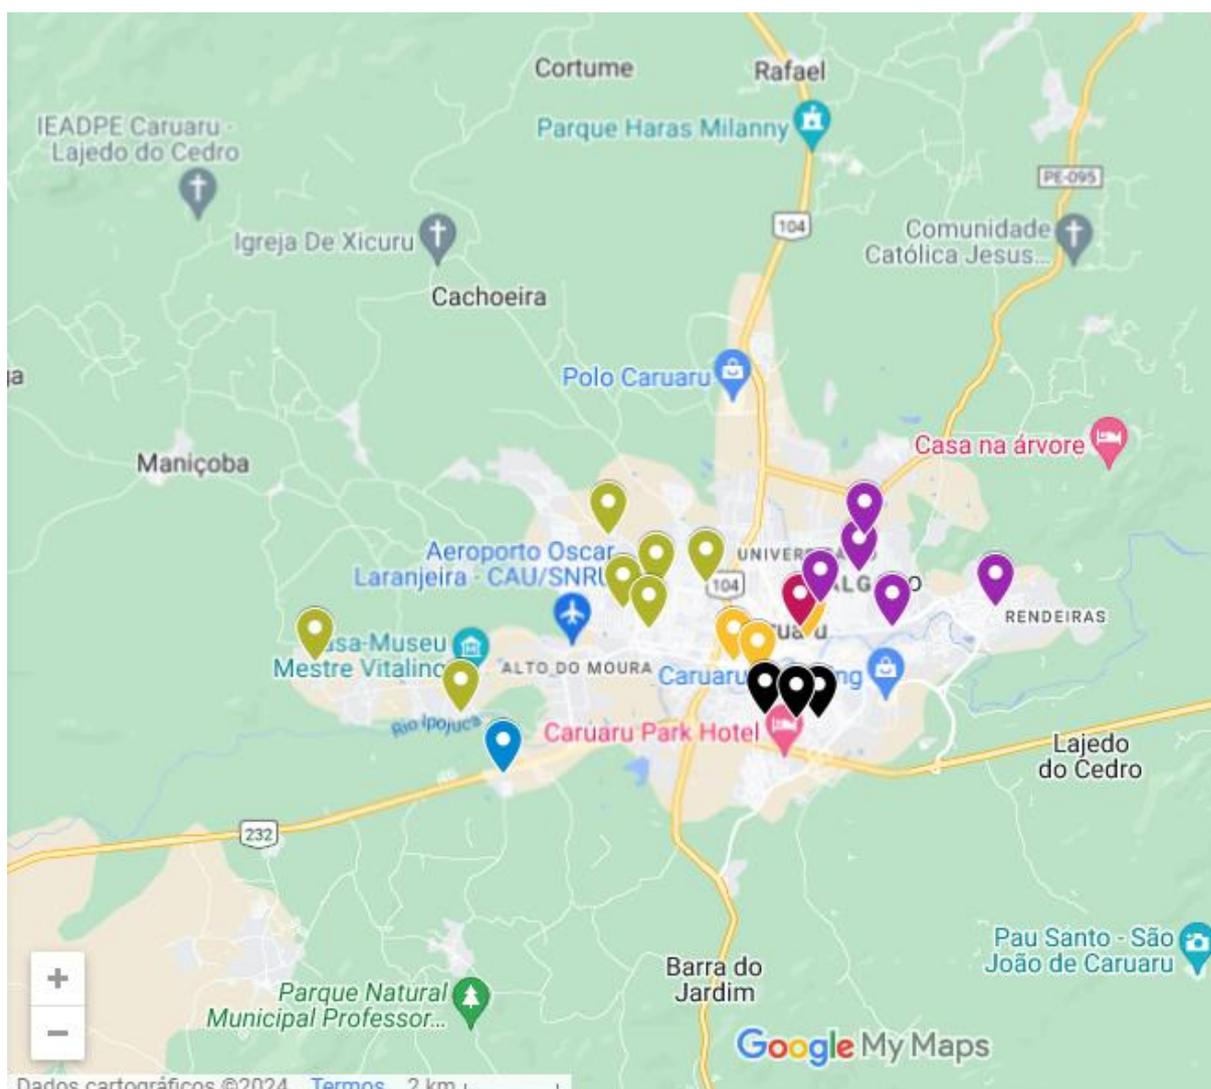
No *cluster* 4, entre as 20 escolas, todas elas são de grande porte e apenas 2 escolas possuem o intervalo de alunos diferente do que caracteriza o *cluster*: ID 11 e 14, onde são justamente essas escolas que apresentam o pior e melhor desempenho nesse quesito, respectivamente. Há apenas uma escola que não é do tipo EM, estando na categoria ETI (ID 9) e no quesito refeições, todas as escolas estão dentro do intervalo que caracteriza o *cluster*, sendo 2491 e 8163 o número mínimo e máximo de refeições das escolas pertencentes ao grupo.

Embora esse *cluster* seja o que possui menos escolas, elas estão espalhadas em 6 tipos de TGSs diferentes, como pode ser visto abaixo.

- TGS 1: ID 8;
- TGS 5: ID 10, 11 e 17;
- TGS 6: ID 5;
- TGS 7: ID 2, 9, 14, 15 e 18;
- TGS 8: ID 1, 7 e 13;
- TGS 9: ID 3, 4, 6, 12, 16, 19 e 20.

A Figura 20 complementa as informações relacionadas ao TGS ao apresentar as localizações das escolas, onde cada cor representa um TGS diferente.

- TGS 1 – Azul;
- TGS 5 – Laranja;
- TGS 6 – Rosa;
- TGS 7 – Roxo;
- TGS 8 – Preto;
- TGS 9 – Bege.

Figura 20 – Localização das escolas do *cluster* 4

Fonte: O Autor (2024).

Apenas 3 escolas, das 20, apresentam características diferentes do *cluster*, sendo o *cluster* com uma maior proporção de escolas com 100% de afinidade.

Por fim, no *cluster* 5, entre as 28 escolas, todas são de pequeno porte. O número de escolas que possuem um total de alunos diferente do intervalo do *cluster* é relativamente alto, totalizando 11 escolas: ID 3, 4, 7, 9, 13, 19, 23, 24, 26, 27 e 28. O tipo de escolas que caracteriza o *cluster* é o CMEI, sendo 22 das escolas desse tipo e as outras 6 são do tipo EM (ID 5, 6, 14, 16, 17 e 18).

O intervalo de refeições também só apresenta 17 escolas com valores dentro do que é caracterizado ao *cluster*, totalizando 11 escolas com intervalos de refeições diferentes (IDs 2, 3, 4, 9, 13, 16, 19, 22, 24, 26 e 28).

Assim como o *cluster* 3, as escolas desse *cluster* abordam quase todos os TGSs da

cidade de Caruaru-PE, sendo apresentado abaixo a lista de escolas que fazem parte de cada TGS.

- TGS 1: ID 1, 14, 16 e 27;
- TGS 2: ID 18 e 21;
- TGS 4: ID 5;
- TGS 5: ID 3, 17 e 24;
- TGS 6: ID 9, 19, 20, 25 e 26;
- TGS 7: ID 6, 7, 8, 10, 11 e 13;
- TGS 8: ID 4, 12, 15, 22 e 28;
- TGS 9: ID 2 e 23.

Complementando essas informações e com a associação das cores com os TGSs, a Figura 21 ilustra onde estão localizadas as escolas do *cluster 5*.

- TGS 1 – Azul;
- TGS 2 – Amarelo;
- TGS 4 – Laranja;
- TGS 5 – Laranja;
- TGS 6 – Rosa;
- TGS 7 – Roxo;
- TGS 8 – Preto;
- TGS 9 – Bege.



## 5.6 DISCUSSÃO SOBRE OS CLUSTERS FORMADOS

A partir da aplicação do algoritmo K-Modes para a formação dos cinco *clusters*, observou-se que nenhuma escola foi agrupada apresentando três ou mais diferenças em relação às características predominantes do seu respectivo *cluster*. No caso do *cluster* 5, por exemplo, das 28 escolas agrupadas, 9 correspondem integralmente às características do *cluster*, 10 apresentam uma única diferença e 9 possuem duas diferenças.

A análise desses agrupamentos sugere que a clusterização pode oferecer uma nova forma de enxergar a distribuição dos insumos alimentares, permitindo considerar não apenas a localização das escolas, mas também seus perfis. Uma possível vantagem dessa abordagem seria uma melhor previsibilidade no envio dos alimentos, uma vez que a gestão pode se basear em dados de demanda de escolas com características semelhantes. Além disso, a padronização dos envios e a organização da logística de distribuição podem ser facilitadas, já que escolas dentro do mesmo *cluster* compartilham perfis similares, o que poderia impactar na eficiência dos tempos de carga e descarga.

Embora a localização continue sendo um fator relevante, os resultados apontam que escolas geograficamente próximas entre si podem apresentar diferenças significativas em termos de porte, número de alunos e quantidades de refeições servidas. Isso pode indicar que a adoção de uma estratégia de gestão baseada nesses perfis poderia trazer benefícios, como uma melhor adaptação dos tempos de reposição de estoque e maior atenção à diversidade nutricional, especialmente para escolas que oferecem um maior número de refeições. Por outro lado, escolas menores poderiam demandar reposições mais frequentes para evitar desperdícios e melhor aproveitamento da validade dos alimentos.

Dessa forma, a reorganização proposta com os *clusters* formados pode representar uma alternativa interessante para aprimorar a gestão dos insumos alimentares, trazendo elementos que poderiam contribuir para um modelo mais eficiente e estruturado. No entanto, para validar esses benefícios, seria necessário um aprofundamento maior na análise prática da implementação desse modelo.

## 6 CONSIDERAÇÕES FINAIS

### 6.1 CONCLUSÃO

Este estudo teve como objetivo fornecer informações adicionais para a gestão da alimentação escolar nas escolas municipais de Caruaru-PE por meio da clusterização, utilizando o algoritmo K-Modes. A proposta foi baseada na necessidade de otimizar a distribuição de insumos alimentares, reduzindo desperdícios e tornando o processo mais eficiente. A metodologia aplicada permitiu agrupar as escolas com base em suas características, como número de alunos, tipo da escola e demanda de refeições, possibilitando uma gestão mais estratégica e alinhada com as reais necessidades de cada unidade.

Os resultados obtidos demonstram que a abordagem adotada pode contribuir para a melhoria da alocação dos recursos alimentares, tornando o processo de distribuição mais eficiente e reduzindo excessos ou insuficiências no fornecimento. Além disso, evidencia-se que a categorização das escolas com base em seus perfis oferece uma alternativa eficiente de conhecimento sobre as demandas das escolas. Dessa forma, este trabalho apresenta uma contribuição direta para a gestão pública, ao fornecer uma metodologia que pode auxiliar na tomada de decisões de maneira mais embasada e eficaz para a gestão de alimentos no ambiente escolar.

### 6.2 LIMITAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Apesar das contribuições apresentadas, este estudo possui algumas limitações. A clusterização foi realizada com base em um conjunto específico de variáveis, sem considerar outros fatores que podem influenciar na distribuição de alimentos, como sazonalidade na demanda, restrições estruturais das escolas ou particularidades do transporte dos insumos. Estudos futuros podem incorporar novos critérios para tornar a análise ainda mais precisa e adaptável à realidade das escolas.

Outra limitação está relacionada à aplicação prática do modelo. Embora os resultados teóricos demonstrem sua viabilidade, seria interessante realizar um estudo de caso com a implementação real em algumas escolas, avaliando os impactos diretos na gestão e comparando os resultados com o modelo tradicional. Isso permitiria ajustes mais refinados na metodologia e possibilitaria sua aplicação em larga escala.

Além disso, recomenda-se que pesquisas futuras explorem a integração dessa

abordagem com outras ferramentas de gestão e análise de dados, permitindo um monitoramento contínuo e dinâmico da distribuição dos insumos alimentares. Esse tipo de aprimoramento pode ser útil não apenas para Caruaru-PE, mas para outros municípios que enfrentam desafios semelhantes na administração da merenda escolar.

Outro aspecto relevante a ser explorado em pesquisas futuras é a questão do desperdício de alimentos nas escolas municipais. A literatura aponta que essa é uma das principais problemáticas relacionadas à alimentação escolar, sendo frequentemente abordada em estudos que analisam a eficiência da distribuição e consumo dos insumos. O desperdício pode ocorrer tanto no momento do preparo das refeições quanto no descarte de alimentos não utilizados, seja por vencimento do prazo de validade ou por uma alocação inadequada dos recursos.

## REFERÊNCIAS

- ABUALIGAH, Laith Mohammad; KHADER, Tajudin; HANANDEH, Essam Said. A combination of objective functions and hybrid algorithm for text document clustering analysis. **Engineering Applications of Artificial Intelligence**, v. 73, p. 111-125, 2018.
- ABUALIGAH, Laith et al. Nature-inspired optimization algorithms for text document clustering—a comprehensive analysis. **Algorithms**, v. 13, n. 12, p. 345, 2020.
- AGGARWAL, Charu C.; REDDY, Chandan K. Data clustering. **Algorithms and applications. Chapman&Hall/CRC Data mining and Knowledge Discovery series, Londra**, 2014.
- AGRAWAL, Rakesh et al. Automatic subspace clustering of high dimensional data for data mining applications. In: **Proceedings of the 1998 ACM SIGMOD international conference on Management of data**. 1998. p. 94-105.
- AGRAWAL, Sanjay; PANDA, Rutuparna; DORA, Lingraj. A study on fuzzy clustering for magnetic resonance brain image segmentation using soft computing approaches. **Applied Soft Computing**, v. 24, p. 522-533, 2014.
- ALA-KARVIA, Urszula et al. COVID-19 driven adaptations in the provision of school meals in the Baltic Sea Region. **Frontiers in Sustainable Food Systems**, v. 5, p. 750598, 2022.
- ALAM, Shafiq et al. Research on particle swarm optimization based clustering: a systematic review of literature and techniques. **Swarm and Evolutionary Computation**, v. 17, p. 1-13, 2014.
- ALI, Maselan; SUFAHANI, Suliadi; ISMAIL, Zuhaimy. A new diet scheduling model for Malaysian school children using zero-one optimization approach. **Global Journal of Pure and Applied Mathematics**, v. 12, n. 1, p. 413-419, 2016.
- AMARO COSTA, Isaque Santiago; DOS SANTOS GURGEL, Jorge; DA COSTA SOUZA, Andréa Moura. Funções e aplicações das atividades do planejamento e controle da produção em uma indústria de insumos para empresas do setor têxtil do ceará. **Journal of Management Analysis/Revista Gestão em Análise**, v. 9, n. 2, 2020.
- AMORIM, Ana Laura Benevenuto de; RIBEIRO JUNIOR, José Raimundo Sousa; BANDONI, Daniel Henrique. National school feeding program: strategies to overcome food insecurities during and after the COVID-19 pandemic. **Revista de Administração Pública**, v. 54, p. 1134-1145, 2020.
- ANDERSON, Michael L.; GALLAGHER, Justin; RITCHIE, Elizabeth Ramirez. School meal quality and academic performance. **Journal of Public Economics**, v. 168, p. 81-93, 2018.
- ARAÚJO, Lillian; ROCHA, Ada. Avaliação e controlo o desperdício alimentar em refeitórios escolares do município de Barcelos. **Artigo em Revista Científica Nacional, Universidade do Porto**, 2017.
- BANIUKIEWICZ, Magda; DICK, Zachariah L.; GIABBANELLI, Philippe J. Capturing the fast-food landscape in England using large-scale network analysis. **EPJ Data Science**, v. 7,

n. 1, p. 39, 2018.

BATISTELA DOS SANTOS, Emanuele et al. Sustainability recommendations and practices in school feeding: a systematic review. **Kompass Nutrition & Dietetics**, v. 2, n. 2, p. 83-102, 2022.

BAUER, Monika; MORLOCK, Gertrud E. Incremental implementation concept for healthy eating habits in German school with kiosk. **Nutrition & Food Science**, 2024.

BENÍTEZ, Ignacio et al. Dynamic clustering segmentation applied to load profiles of energy consumption from Spanish customers. **International Journal of Electrical Power & Energy Systems**, v. 55, p. 437-448, 2014.

BHANUPRAKASH, C.; SETTY, Aishwarya. Prediction of diseases caused in Child Dieting System by using K-Modes Algorithm. In: **2024 International Conference on Smart Systems for applications in Electrical Sciences (ICSSSES)**. IEEE, 2024. p. 1-6.

BIRKLE, Caroline et al. Web of Science as a data source for research on scientific and scholarly activity. **Quantitative Science Studies**, v. 1, n. 1, p. 363-376, 2020.

BORLIZZI, Andrea; DELGROSSI, Mauro Eduardo; CAFIERO, Carlo. National food security assessment through the analysis of food consumption data from Household Consumption and Expenditure Surveys: The case of Brazil's Pesquisa de Orçamento Familiares 2008/09. **Food policy**, v. 72, p. 20-26, 2017.

BOSCHINI, Matteo et al. Why the waste? A large-scale study on the causes of food waste at school canteens. **Journal of Cleaner Production**, v. 246, p. 118994, 2020.

BUSATO, Maria Assunta; FERIGOLLO, Maira Cristina. Desperdício de alimentos em unidades de alimentação e nutrição: uma revisão integrativa da literatura. **Holos**, v. 1, p. 91-102, 2018.

CAMARÉNA, Stéphanie. Artificial Intelligence (AI) for sustainable institutional food systems: implementation of AI tools for school nutrition program management in the United States of America. **Frontiers in Sustainable Food Systems**, v. 6, p. 743810, 2022.

CAMPELLO, Ricardo JGB; MOULAVI, Davoud; SANDER, Jörg. Density-based clustering based on hierarchical density estimates. In: **Pacific-Asia conference on knowledge discovery and data mining**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 160-172.

CARVALHO, Alexandre Xavier Ywata et al. **Clusterização hierárquica espacial com atributos binários**. Texto para Discussão, 2009.

CASSIANO, Keila Mara. **Análise de séries temporais usando análise espectral singular (SSA) e clusterização de suas componentes baseada em densidade**. Dissertação de Doutorado do Programa de Pós Graduação em engenharia Elétrica, PUC-Rio, Rio de Janeiro, 2014.

CASSIANO, Keila Mara; PESSANHA, José Francisco Moreira. Análise espectral singular com clusterização baseada em densidade na modelagem de séries temporais. **Anais do XLVI Simpósio Brasileiro de Pesquisa Operacional. Salvador-BA**, 2014.

CHARYTANOWICZ, Małgorzata et al. Complete gradient clustering algorithm for features analysis of x-ray images. In: **Information Technologies in Biomedicine: Volume 2**.

Springer Berlin Heidelberg, 2010. p. 15-24.

CHATURVEDI, Anil; GREEN, Paul E.; CAROLL, J. Douglas. K-modes clustering. **Journal of classification**, v. 18, p. 35-55, 2001.

CHEN, Xiaojun et al. Purtreeclust: A clustering algorithm for customer segmentation from massive customer transaction data. **IEEE transactions on knowledge and data engineering**, v. 30, n. 3, p. 559-572, 2017.

CHU, Chung-Min; CHIH, Chueh; TENG, Chih-Ching. Food waste management: A case of Taiwanese high school food catering service. **Sustainability**, v. 15, n. 7, p. 5947, 2023.

CIVIL, Casa. LEI Nº 11.947, DE 16 DE JUNHO DE 2009. **Caderno de Legislação**, p. 5, 2009.

CLARKE, Geoff; WRIGHT, John W. Scheduling of vehicles from a central depot to a number of delivery points. **Operations research**, v. 12, n. 4, p. 568-581, 1964.

COELHO, Taniellen Miranda et al. Public School Food Supply Chain during the COVID-19 Pandemic: A Case Study of the City of Vitória (Brazil). **Logistics**, v. 6, n. 1, p. 20, 2022.

COLE, Rowena Marie. **Clustering with genetic algorithms**. Crawley, Australia: University of Western Australia, 1998.

CONNOLLY, Katherine et al. Dedication, innovation, and collaboration: A mixed-methods analysis of school meals in Connecticut during COVID-19. **Journal of Agriculture, Food Systems, and Community Development**, v. 10, n. 2, p. 11–27-11–27, 2021.

CRUZ, A. R. et al. Uma abordagem multiobjetivo inteira para a dieta em creches. **Anais do XLV Simpósio Brasileiro de Pesquisa Operacional**, 2013.

CUPERTINO, Alessandra et al. School feeding programs: what happens globally?. **International journal of environmental research and public health**, v. 19, n. 4, p. 2265, 2022.

DA SILVA CRUZ, Hewerton Umbelito. **Introdução à Programação Linear Inteira Multiobjetivo**. 2015.

DAMATTA, Roberto. A casa & a rua. **Rio de janeiro: Rocco**, p. 1971-1973, 1997.

DAVID, Fred R. **Strategic management concepts and cases**. Prentice hall, 2011.

DE ARAÚJO AGUIAR, Pedro Alexandre; DE SANTANA JÚNIOR, Clodomir Joaquim; BASTOS FILHO, Carmelo José Albanez. Aplicação de Algoritmos de Clusterização em uma Base de Dados de Reservas de Hotéis. **Revista de Engenharia e Pesquisa Aplicada**, v. 3, n. 3, 2018.

DE OLIVEIRA, Pamella Letícia Silva et al. Identificação de Pesquisas e Análise de Algoritmos de Clusterização para a Descoberta de Perfis de Engajamento. **Revista Brasileira de Informática na Educação**, v. 30, p. 01-19, 2022.

ELSTON, Dirk M. Mendeley. **Journal of the American Academy of Dermatology**, v. 81, n. 5, p. 1071, 2019.

ERIKSSON, Mattias et al. Quantification of food waste in public catering services—A case study from a Swedish municipality. **Waste Management**, v. 61, p. 415-422, 2017.

ESCOLAS. **Escolas, municipais** – Pernambuco, 2024. Disponível em: <https://escolas.com.br/municipais/pe?pagina=28>. Acesso em: 11 set.2024.

ESTER, Martin et al. A density-based algorithm for discovering clusters in large spatial databases with noise. In: **kdd**. 1996. p. 226-231.

ESTER, Martin; WITTMANN, Rüdiger. Incremental generalization for mining in a data warehousing environment. In: **Advances in Database Technology—EDBT'98: 6th International Conference on Extending Database Technology Valencia, Spain, March 23–27, 1998 Proceedings 6**. Springer Berlin Heidelberg, 1998. p. 135-149.

ESTIVILL-CASTRO, Vladimir; YANG, Jianhua. Fast and robust general purpose clustering algorithms. In: **Pacific Rim International Conference on Artificial Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000. p. 208-218.

FABRI, Rafaela Karen et al. Regional foods in Brazilian school meals. **British Food Journal**, v. 117, n. 6, p. 1706-1719, 2015.

FARAZI, Nahid Parvez; MURSHED, Mohammad Neaz; HADIUZZAMAN, Md. Application of machine learning to investigate heterogeneity in users' perception of intercity train service quality in developing countries. **Case Studies on Transport Policy**, v. 10, n. 1, p. 227-238, 2022.

FARIAS, Victor Amorim Porto; E SILVA FILHO, José Leão; CLEMENTE, Thárcylla Rebecca Negreiros. Análise bibliométrica sobre gestão de alimentos em ambiente escolar: Uma revisão dentre os anos de 2000 e 2024. **Anais do Encontro Nacional de Engenharia de Produção-ENEGEP, Fortaleza**, 2024a.

FARIAS, Victor Amorim Porto; E SILVA FILHO, José Leão; CLEMENTE, Thárcylla Rebecca Negreiros. Gestão de insumos para merenda escolar utilizando uma heurística de roteirização de entregas. **Anais do LVI Simpósio Brasileiro de Pesquisa Operacional**, 2024b.

FERNANDES, Ana Gabriela de Souza; FONSECA, Alexandre Brasil Carvalho da; SILVA, Adilson Aderito da. Alimentação escolar como espaço para educação em saúde. **Ciência & Saúde Coletiva**, v. 19, p. 39-48, 2014.

FERNANDES, Meenakshi et al. Enhancing linkages between healthy diets, local agriculture, and sustainable food systems: the school meals planner package in Ghana. **Food and nutrition bulletin**, v. 37, n. 4, p. 571-584, 2016.

FERREIRA, Fábio dos S.; CAMPOS, G.; SILVA, J. Clusterização com algoritmo genético baseado em densidade e grade. **Anais do XLIISBPO, Bento Gonçalves**, 2010.

FERREIRA, Gabriela Cardozo; PADULA, Antônio Domingos. Estrutura produtiva e competitividade da cadeia da carne bovina no Rio Grande do Sul. **Encontro anual da anpad**, v. 22, 1998.

FRALEY, Chris; RAFTERY, Adrian E. How many clusters? Which clustering method? Answers via model-based cluster analysis. **The computer journal**, v. 41, n. 8, p. 578-588, 1998.

Fundo Nacional de Desenvolvimento da Educação (FNDE). Resolução CD/FNDE nº 6, de 8 de maio de 2020. **Dispõe sobre o atendimento da alimentação escolar aos alunos da**

**educação básica no âmbito do Programa Nacional de Alimentação Escolar – PNAE.** Disponível em: <http://www.fn.de.gov.br/programas/alimentacao-escolar>. Acesso em: 15 out.2024.

GADDAM, Shekhar R.; PHOHA, Vir V.; BALAGANI, Kiran S. K-Means+ ID3: A novel method for supervised anomaly detection by cascading K-Means clustering and ID3 decision tree learning methods. **IEEE transactions on knowledge and data engineering**, v. 19, n. 3, p. 345-354, 2007.

GAJPAL, Yuvraj; ROY, Vivek; SAHAY, B. S. Vehicle routing for a mid-day meal delivery distribution system. **Heliyon**, v. 5, n. 1, 2019.

GELLI, Aulo; SUWA, Yuko. Investing in innovation: Trade-offs in the costs and cost-efficiency of school feeding using community-based kitchens in Bangladesh. **Food and nutrition bulletin**, v. 35, n. 3, p. 327-337, 2014.

GRANILLO-MACÍAS, Rafael. Logistics optimization through a social approach for food distribution. **Socio-Economic Planning Sciences**, v. 76, p. 100972, 2021.

GUHA, Sudipto; RASTOGI, Rajeev; SHIM, Kyuseok. CURE: An efficient clustering algorithm for large databases. **ACM Sigmod record**, v. 27, n. 2, p. 73-84, 1998.

HAN, Jiawei. KAMBER, Micheline. **Data Mining concepts and techniques**, p. 279-328, 2001.

HAN, Jiawei; KAMBER, Micheline. **Data Mining Concepts and Techniques Second Edition/J. Han, M. Kamber–Elsevier**, 2006.

HAN, Jiawei. Spatial clustering methods in data mining: A survey. **Geographic data mining and knowledge discovery**, p. 188-217, 2001.

HRUSCHKA, E. R.; EBECKEN, N. F. F. A Generic algorithm for cluster analysis: **IEEE Transactions on Evolutionary Computation**. 2001.

HUANG, Zhexue. A fast clustering algorithm to cluster very large categorical data sets in data mining. **Dmkd**, v. 3, n. 8, p. 34-39, 1997a.

HUANG, Z. Clustering Large Data Sets With Mixed Numeric And Categorical Values," **Proceedings Of 1st Pacific-Asia Conference on Knowledge Discovery And Data Mining**. 1997b.

HUANG, Zongyan. Exploration of digital media art professional design talent class training based on K-mode algorithm. **Applied Mathematics and Nonlinear Sciences**, 2023.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Notícias, Censo 2022 - Brasil**, 2023. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/37237-de-2010-a-2022-populacao-brasileira-cresce-6-5-e-chega-a-203-1-milhoes#:~:text=A%20popula%C3%A7%C3%A3o%20do%20pa%C3%ADs%20chegou,foi%20de%200%2C52%25>. Acesso em: 03 jul.2024.

IGARASHI, Mieko; DE BOER, Luitzen; FET, Annik Magerholm. What is required for greener supplier selection? A literature review and conceptual model development. **Journal of Purchasing and Supply Management**, v. 19, n. 4, p. 247-263, 2013.

INEP – Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira. **Censo**,

**Escolar** – Brasil, 2024. Disponível em: <http://www.gov.br/inep/pt-br/assuntos/noticias/censo-escolas/mec-e-inep-divulgam-resultados-do-censo-escolar-2023>. Acesso em: 07 jun.2024.

ISSA, Raquel Carvalho et al. Alimentação escolar: planejamento, produção, distribuição e adequação. **Revista Panamericana de Salud Publica**, v. 35, p. 96-103, 2014.

JAIN, A. K.; DUBES, R. C. Algorithms for clustering data. **Prentice Hall**, 1988.

JAIN, Anil K. Data clustering: 50 years beyond K-means. **Pattern recognition letters**, v. 31, n. 8, p. 651-666, 2010.

JAIN, Anil K.; MURTY, M. Narasimha; FLYNN, Patrick J. Data clustering: a review. **ACM computing surveys (CSUR)**, v. 31, n. 3, p. 264-323, 1999.

JANSSENS, Frizo; GLÄNZEL, Wolfgang; DE MOOR, Bart. Dynamic hybrid clustering of bioinformatics by incorporating text mining and citation analysis. In: **Proceedings of the 13th ACM SIGKDD international conference on knowledge discovery and data mining**. 2007. p. 360-369.

JENSEN, Jørgen Dejgård et al. Cost of New Nordic Diet school meals. **British Food Journal**, v. 117, n. 9, p. 2372-2386, 2015.

Ji, Jinchao et al. An improved k-prototypes clustering algorithm for mixed numeric and categorical data. **Neurocomputing**, v. 120, p. 590-596, 2013.

KANNAN, Devika; DE SOUSA JABBOUR, Ana Beatriz Lopes; JABBOUR, Charbel José Chiappetta. Selecting green suppliers based on GSCM practices: Using fuzzy TOPSIS applied to a Brazilian electronics company. **European Journal of operational research**, v. 233, n. 2, p. 432-447, 2014.

KASAVAN, Saraswathy et al. Quantification of food waste in school canteens: A mass flow analysis. **Resources, Conservation and Recycling**, v. 164, p. 105176, 2021.

KHAYI, Nisrine Ait; RUS, Vasile. Clustering Students Based on Their Prior Knowledge. **International Educational Data Mining Society**, 2019.

KOUSHIK, C.; BHATTACHARJEE, Ritwika; HEMALATHA, C. Sweetlin. Symptoms based early clinical diagnosis of COVID-19 cases using hybrid and ensemble machine learning techniques. In: **2021 5th international conference on computer, communication and signal processing (ICCCSP)**. IEEE, 2021. p. 1-6.

LEI, Yaguo et al. New clustering algorithm-based fault diagnosis using compensation distance evaluation technique. **Mechanical Systems and Signal Processing**, v. 22, n. 2, p. 419-435, 2008.

LIN, Kairong et al. Assessment of flash flood risk based on improved analytic hierarchy process method and integrated maximum likelihood clustering algorithm. **Journal of Hydrology**, v. 584, p. 124696, 2020.

LIU, Yao et al. Plate waste in school lunch programs in Beijing, China. **Sustainability**, v. 8, n. 12, p. 1288, 2016.

LÓPEZ, José J. et al. Hopfield–K-Means clustering algorithm: A proposal for the segmentation of electricity customers. **Electric Power Systems Research**, v. 81, n. 2, p. 716-724, 2011.

LYU, Lingjuan et al. Fog-empowered anomaly detection in IoT using hyperellipsoidal clustering. **IEEE Internet of Things Journal**, v. 4, n. 5, p. 1174-1184, 2017.

MACQUEEN, James et al. Some methods for classification and analysis of multivariate observations. In: **Proceedings of the fifth Berkeley symposium on mathematical statistics and probability**. 1967. p. 281-297.

MAHADEVAN, B. et al. Redesigning midday meal logistics for the Akshaya Patra Foundation: OR at work in feeding hungry school children. **Interfaces**, v. 43, n. 6, p. 530-546, 2013.

MAIETTA, Ornella Wanda; GORGITANO, Maria Teresa. School meals and pupil satisfaction. Evidence from Italian primary schools. **Food Policy**, v. 62, p. 41-55, 2016.

MARQUES, Cátia et al. Impact of a food education session on vegetables plate waste in a portuguese school canteen. **Sustainability**, v. 14, n. 24, p. 16674, 2022.

Ministério da Saúde (BR). **Guia Alimentar para a População Brasileira**. 2. ed. Brasília: Ministério da Saúde, 2014. Disponível em: [https://bvsms.saude.gov.br/bvs/publicacoes/guia\\_alimentar\\_populacao\\_brasileira\\_2ed.pdf](https://bvsms.saude.gov.br/bvs/publicacoes/guia_alimentar_populacao_brasileira_2ed.pdf). Acesso em: 15 out.2024.

MOREIRA, Rafaela Priscila Cruz; WANNER, Elizabeth Fialho; MARTINS, Flávio Vinícius Cruzeiro. Algoritmo genético para elaboração de cardápios nutricionais para alimentação escolar. In: **Anais do 12º Congresso Brasileiro de Inteligência Computacional**. 2015.

MOSHTAGHI, Masud et al. Clustering ellipses for anomaly detection. **Pattern Recognition**, v. 44, n. 1, p. 55-69, 2011.

MURTAGH, Fionn; CONTRERAS, Pedro. Algorithms for hierarchical clustering: an overview. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 2, n. 1, p. 86-97, 2012.

NG, Michael K. et al. On the impact of dissimilarity measure in k-modes clustering algorithm. **IEEE transactions on pattern analysis and machine intelligence**, v. 29, n. 3, p. 503-507, 2007.

NOLL, Priscilla Rayanne e Silva et al. Ultra-processed food consumption by Brazilian adolescents in cafeterias and school meals. **Scientific Reports**, v. 9, n. 1, p. 7162, 2019.

OLIVEIRA, C. **EDACLUSTER: Um Algoritmo Evolucionário para Análise de Agrupamentos Baseados em Densidade e Grade**. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal do Pará, 2007.

ORHAN, Umut; HEKIM, Mahmut; OZER, Mahmut. EEG signals classification using the K-means clustering and a multilayer perceptron neural network model. **Expert Systems with Applications**, v. 38, n. 10, p. 13475-13481, 2011.

PALACIOS-ARGÜELLO, Laura et al. Assessing the economic and environmental impacts of urban food systems for public school canteens: case study of Great Lyon Region. **European Transport Research Review**, v. 10, p. 1-20, 2018.

PANDEESWARI, N.; KUMAR, Ganesh. Anomaly detection system in cloud environment using fuzzy clustering based ANN. **Mobile Networks and Applications**, v. 21, p. 494-505, 2016.

PAPULOVA, Zuzana; GAZOVA, Andrea. Role of strategic analysis in strategic decision-making. **Procedia Economics and Finance**, v. 39, p. 571-579, 2016.

PETRUZZELLI, Mara et al. Towards sustainable school meals: integrating environmental and cost implications for nutritious diets through optimisation modelling. **Sustainability Science**, p. 1-20, 2023.

PIRES, Iva et al. Food waste perception of workplace canteen users—a case study. **Sustainability**, v. 14, n. 3, p. 1324, 2022.

POPPE, Robert; FRÖLICH, Markus; HAILE, Getinet. School meals and educational outcomes in rural Ethiopia. **The Journal of Development Studies**, v. 55, n. 8, p. 1741-1756, 2019.

RAMOS, Ana Flávia Pontes. **Estudo de tempos e aplicação de ferramentas de qualidade para aumento da produtividade em empresa de acumuladores elétricos**. Trabalho de Conclusão de Curso, UFPE, 2020.

RICARTE, Michelle Pinheiro Rabelo et al. Avaliação do desperdício de alimentos em uma unidade de alimentação e nutrição institucional em Fortaleza-CE. **Saber Científico (1982-792X)**, v. 1, n. 1, p. 158-175, 2021.

RIBEIRO, Joana; ROCHA, Ada. Impacto económico do desperdício alimentar num centro escolar. **Artigo em Revista Científica Nacional, Universidade do Porto**, 2019.

ROCHA, Ada et al. System of planning and evaluation of school meals. **Public health nutrition**, v. 17, n. 6, p. 1264-1270, 2014.

ROCHA, Leonardo Marques; CAPPABIANCO, Fábio AM; FALCÃO, Alexandre Xavier. Data clustering as an optimum-path forest problem with applications in image analysis. **International Journal of Imaging Systems and Technology**, v. 19, n. 2, p. 50-68, 2009.

RODRIGUES, Paulo Henrique; COSTA, José Maurício. Um estudo sobre a otimização da gestão da alimentação em escolas públicas. **Anais do LIII Simpósio Brasileiro de Pesquisa Operacional**, 2021.

SAINI, Mukesh Kumar. Machine learning techniques for precise heart disease prediction. **International Journal of Science and Research (IJSR)**, v. 12, n. 12, p. 2120-2129, 2023.

SALVATORE, Fiorella Pia et al. Public food procurement for Italian schools: results from analytical and content analyses. **British Food Journal**, v. 123, n. 8, p. 2936-2951, 2021.

SANDER, Jörg et al. Density-based clustering in spatial databases: The algorithm gdbscan and its applications. **Data mining and knowledge discovery**, v. 2, p. 169-194, 1998.

SANTOS, João Pedro Grechi. **Desenvolvimento de um método para gestão de estoque em uma empresa de persianas e cortinas de médio porte**. Trabalho de Conclusão de Curso. Universidade Federal do Rio Grande do Sul, 2023.

SANTOS, Talita Chayene Oliveira dos. **A percepção dos professores sobre o programa nacional de alimentação escolar (PNAE): Um estudo de caso em uma escola no município de Nísia Floresta**. Trabalho de Conclusão de Curso. Universidade Federal do Rio Grande do Norte, 2024.

SAPL – Sistema de Apoio ao Processo Legislativo. **Norma, Jurídica** – Lei nº 6.785, 2021. Disponível em: [https://sapl.caruaru.pe.leg.br/media/sapl/public/normajuridica/2021/8789/lei\\_6785\\_-\\_projeto\\_9141\\_-\\_ppa\\_2022-2025.pdf](https://sapl.caruaru.pe.leg.br/media/sapl/public/normajuridica/2021/8789/lei_6785_-_projeto_9141_-_ppa_2022-2025.pdf). Acesso em 11 set.2024.

SARAIVA, Elisa Braga et al. Panorama da compra de alimentos da agricultura familiar para o Programa Nacional de Alimentação Escolar. **Ciência & Saúde Coletiva**, v. 18, n. 4, p. 927-935, 2013.

SEDUC – Secretaria de Educação e Esportes. **GRs, Escolas** – Pernambuco, 2024. Disponível em: <https://portal.educacao.pe.gov.br/gres-e-escolas/>. Acesso em: 11 set.2024.

SEGREDO, Eduardo et al. Schoolthy: automatic menu planner for healthy and balanced school meals. **IEEE access**, v. 8, p. 113200-113218, 2020.

SELIM, Shokri Z.; ALSULTAN, K. 1. A simulated annealing algorithm for the clustering problem. **Pattern recognition**, v. 24, n. 10, p. 1003-1008, 1991.

SETYANINGTYAS, Stefania Widya; ARIMBI, Agnessia Nanda; DIANA, Rian. Exploration of school meal food service management: a case study of a full-day school. **International Journal of Public Health**, v. 11, n. 3, p. 903-910, 2022.

SIEC – Sistema de Informações da Educação de Caruaru. **Secretaria de Educação e Esportes, Caruaru** – Pernambuco, 2024. Disponível em: <https://educacao.caruaru.pe.gov.br/pagina/secretaria-de-educacao-e-esportes>. Acesso em: 16 set.2024.

SILVA, Jefferson Emanuel Caldeira da. Recomendação de cardápios saudáveis e otimizados conforme disponibilidade de alimentos. **Master's thesis, Universidade Federal de Campina Grande, Campina Grande – Paraíba**, 2019.

SILVA, Joao Gabriel Rocha et al. Um estudo comparativo entre um algoritmo genético e um algoritmo de evolução diferencial para o problema da dieta restrita em calorias. **Anais do XLIX Simpósio Brasileiro de Pesquisa Operacional**, 2017.

SORENSEN, Thorvald. A method of establishing groups of equal amplitude in plant sociology based on similarity of species content and its application to analyses of the vegetation on Danish commons. **Biologiske skrifter**, v. 5, p. 1-34, 1948.

STEINHAUS, H. Sur la division des corps matériels en parties. **Bull. Acad. Polon. Sci.**, C1. III vol IV: 801-804. 1956.

STIGLER, George J. The cost of subsistence. **Journal of farm economics**, v. 27, n. 2, p. 303-314, 1945.

STROZZI, Fernanda et al. Literature review on the ‘Smart Factory’ concept using bibliometric tools. **International journal of production research**, v. 55, n. 22, p. 6572-6591, 2017.

SUFAHANI, Suliadi; ISMAIL, Zuhaimy. A new menu planning model for Malaysian secondary schools using optimization approach. **Applied Mathematical Sciences**, v. 8, n. 151, p. 7511-7518, 2014.

TOBER, Markus. PubMed, ScienceDirect, Scopus or Google Scholar–Which is the best search engine for an effective literature research in laser medicine?. **Medical Laser**

**Application**, v. 26, n. 3, p. 139-144, 2011.

VOLNA, Jana; PAPULA, Ján. Analysis of the behavior of Slovak enterprises in the context of low innovation performance. **Procedia-Social and Behavioral Sciences**, v. 99, p. 600-608, 2013.

WANG, Tai-Yue; YANG, Yih-Hwang. A fuzzy model for supplier selection in quantity discount environments. **Expert Systems with applications**, v. 36, n. 10, p. 12179-12187, 2009.

WANG, Zengfeng. Comparison of four kinds of fuzzy C-means clustering methods. In: **2010 Third International Symposium on Information Processing**. IEEE, 2010. p. 563-566.

WELSH, Alan H. **Aspects of statistical inference**. John Wiley & Sons, 2011.

WILD, David J.; BLANKLEY, C. John. Comparison of 2D fingerprint types and hierarchy level selection methods for structural grouping using Ward's clustering. **Journal of Chemical Information and Computer Sciences**, v. 40, n. 1, p. 155-162, 2000.

WU, Bo; WILAMOWSKI, Bogdan M. A fast density and grid based clustering method for data with arbitrary shapes and noise. **IEEE Transactions on Industrial Informatics**, v. 13, n. 4, p. 1620-1628, 2016.

WU, Zhenyu; LEAHY, Richard. An optimal graph theoretic approach to data clustering: Theory and its application to image segmentation. **IEEE transactions on pattern analysis and machine intelligence**, v. 15, n. 11, p. 1101-1113, 1993.

XU, Linlin et al. SAR image denoising via clustering-based principal component analysis. **IEEE transactions on geoscience and remote sensing**, v. 52, n. 11, p. 6858-6869, 2014.

XU, Rui; WUNSCH, Donald. Survey of clustering algorithms. **IEEE Transactions on neural networks**, v. 16, n. 3, p. 645-678, 2005.

ZHANG, Yan; ZHAO, Zhong-qiu. Research on Tracking Error Minimization Based on Dynamic Clustering and Genetic Algorithm. **Transactions of Beijing institute of Technology**, v. 34, n. 2, p. 117-120, 2014

## ANEXO A – DECLARAÇÃO DE APOIO E INTERESSE PELO PROJETO DE PESQUISA



CARUARU

PREFEITURA MUNICIPAL DE CARUARU

### DECLARAÇÃO DE APOIO E INTERESSE PELO PROJETO DE PESQUISA

A Prefeitura do Município de Caruaru localizada na RD 08 declara para fins de comprovação junto ao Edital FACEPE 35/2022 PBPG em relação à Ação Estratégica CIÊNCIA NAS PREFEITURAS DO INTERIOR que o projeto intitulado "**Modelo de apoio à gestão de distribuição de insumos para instituições educacionais da rede pública municipal no interior de Pernambuco**" apresenta temática de interesse para esta administração municipal e seus resultados poderão auxiliar na resolução das seguintes questões:

- a) Aquisição de modelos de otimização no processo de gerenciamento dos insumos distribuídos para as escolas do município;
- b) Desenvolvimento de novos modelos de gestão que apoiem a melhoria da qualidade dos serviços educacionais do município;
- c) Desenvolvimento de produtos tecnológicos ampliados para outros setores da administração do município; e
- d) Melhoria do mapeamento estratégico do desempenho da gestão de insumos.

Declaramos, ainda, que iremos disponibilizar infra-estrutura adequada ao desenvolvimento do projeto na própria sede de Prefeitura ou em local melhor apropriado para o aluno e orientador.

Caruaru, 19 de dezembro de 2022.

Aline Tibúrcio Gomes de Araújo Silva

Secretária de Educação  
do Município de Caruaru-PE

## ANEXO B – ESCOLAS MUNICIPAIS DA CIDADE DE CARUARU-PE E SUAS CARACTERÍSTICAS

Os dados apresentados na Tabela 1B, foram disponibilizados pela Secretaria de Educação e Esportes (SEDUC) do Município de Caruaru-PE no ano de 2024.

Tabela 1B – Dados sobre as escolas municipais de Caruaru-PE

Escola	TGS	Tipo da escola	Quantidade de alunos	Porte da escola	Número de refeições na semana
Abílio Luis de Torres	4	EM	50	Pequeno	217
Adelino Alves da Silva	2	EM	22	Pequeno	100
Alfredo Pinto Vieira de Melo	2	EM	64	Pequeno	256
Álvaro Lins	6	ETI	592	Médio	1776
Amélia Tereza da Conceição	1	CMEI	185	Pequeno	925
Antonia Maria da Conceição Costa	1	EM	38	Pequeno	166
Antônio Martins	1	EM	18	Pequeno	77
Artesão Severino Vitalino	9	CMEI	295	Pequeno	1475
Artista Plástica Luisa Cavalcanti Maciel	9	CMEI	461	Médio	2305
Assentamento Macambira Borba	2	EM	10	Pequeno	40
Babu	9	CMEI	367	Médio	1835
Batista da Silva	4	EM	28	Pequeno	64
Belísio Córdula	1	EM	34	Pequeno	146
Capitão João Velho	3	EM	306	Médio	1080
Capitão Rufino	2	EM	472	Médio	2033
Colégio Municipal Professor Luiz Pessoa da Silva	8	EM	1487	Grande	5414
Colégio Municipal Professora Laura Florêncio	7	EM	1494	Grande	5307
Cônego Julio Cabral	4	EM	10	Pequeno	40
Deputada Cristina Tavares	9	EM	1506	Grande	5361
Dom Antonio Soares Costa	5	CMEI	123	Pequeno	615
Dom Bernardino Marchiό	9	EM	1888	Grande	3276
Dom Miguel Severino de Lima	4	EM	77	Pequeno	322
Dona Maria Digna	4	EM	80	Pequeno	344
Dr. Amaro de Lyra e César	9	ETI	649	Médio	1947
Dr. Oscar Barreto	3	EM	113	Pequeno	487
Dr. Tabosa de Almeida	1	EM	362	Médio	1447
Duda Umbuzeiro	2	EM	107	Pequeno	323
Duque de Caxias	6	EM	936	Grande	3921
Érika Patrícia	8	CMEI	88	Pequeno	440
Escola Intermediária Maria do Socorro de Freitas	4	EM	273	Pequeno	1121
Escola Municipal Fernando Soares Lira	5	CMEI	342	Médio	1710
Escola Reunida Casa do Trabalhador	5	EM	569	Médio	2276
Escolas Reunidas Duque de Caxias	5	ETI	482	Médio	1446
Evangélica Reverendo Genésio Campos	7	EM	221	Pequeno	884
Flora Bezerra	7	CMEI	147	Pequeno	735
Fortunato Ribeiro da Silva	3	EM	78	Pequeno	334
Francelino Guilherme de Azevedo	4	EM	67	Pequeno	291
Francisca Maria da Conceição	4	EM	62	Pequeno	248
Francisco Borges	3	EM	92	Pequeno	383
Guiomar Alves de Lima - Guiomar Lima	9	CMEI	306	Médio	1530
Helena Martins Gomes	7	CMEI	192	Pequeno	960

Heleno Cumarú	1	CMEI	55	Pequeno	275
Irmã Ceciliana Gross	6	ETI	560	Médio	1680
Irmã Rosália	6	CMEI	132	Pequeno	660
Ivanise Flora Araújo de Menezes	7	CMEI	242	Pequeno	1210
João Cursino	4	EM	8	Pequeno	32
João Demócrito Florêncio	4	EM	14	Pequeno	56
João Luiz Torres	1	EM	121	Pequeno	543
João Patrício de Carvalho	2	EM	43	Pequeno	182
João Vênio da Silva	2	EM	15	Pequeno	60
João XXIII	4	EM	22	Pequeno	104
Joaquim Nabuco	2	EM	43	Pequeno	187
Joel Pontes	8	EM	459	Médio	1984
José Barbosa	2	EM	22	Pequeno	88
José Clemente de Souza	2	EM	662	Médio	2553
José Faustino Vila Nova	4	EM	15	Pequeno	70
José Manoel da Silveira	3	EM	54	Pequeno	230
José Pinheiro dos Santos Filho	7	CMEI	213	Pequeno	1065
José Raimundo Paes de Lira	3	EM	32	Pequeno	137
José Raimundo Sobrinho	1	EM	32	Pequeno	139
José Severino de Amorim	4	EM	10	Pequeno	45
Josefa Maria da Conceição Dandon	3	EM	50	Pequeno	215
Justina de Freitas	8	CMEI	159	Pequeno	795
Landelino Rocha	1	EM	573	Médio	2198
Leonor Felicidade da Conceição	2	EM	47	Pequeno	203
Leopoldina Queiroz de Lima	7	CMEI	118	Pequeno	590
Lions Club	9	EM	639	Médio	2935
Major Sinval	1	EM	209	Pequeno	897
Manoel Bandeira	1	EM	23	Pequeno	100
Manoel Félix de Almeida	2	EM	71	Pequeno	305
Manoel Henrique da Silva	2	EM	23	Pequeno	92
Manoel Limeira	2	EM	524	Médio	2033
Manoel Trajano de Arruda	2	EM	14	Pequeno	60
Manoel Valdevino	2	EM	17	Pequeno	76
Marcionilo Soares	3	EM	9	Pequeno	36
Maria Aleir Ribeiro Galvão	8	CMEI	168	Pequeno	840
Maria Alice	3	EM	64	Pequeno	256
Maria Anunciada Rodrigues	1	EM	153	Pequeno	662
Maria Félix	2	EM	525	Médio	1962
Maria José de França	2	EM	72	Pequeno	311
Maria Martins de Melo	1	EM	20	Pequeno	86
Mestre Vitalino	9	EM	977	Grande	3737
Natalice Limeira	3	EM	72	Pequeno	320
Nossa Senhora das Dores	4	EM	69	Pequeno	232
Nossa Senhora de Aparecida	1	EM	41	Pequeno	184
Nossa Senhora de Fátima	8	EM	1558	Grande	6232
Padre Antonio Faustino	4	EM	43	Pequeno	131
Padre Pedro Batista de Aguiar	9	EM	583	Médio	2153
Paulina Monteiro	8	EM	358	Médio	1500
Pedro de Andrade	1	EM	52	Pequeno	222
Pedro de Souza	8	EM	500	Médio	1877
Prefeito Anastácio Rodrigues da Silva	7	CMEI	352	Médio	1760
Prefeito João Lyra Filho	7	ETI	452	Médio	1356
Presidente Kennedy	1	EM	865	Grande	3225
Professor Altair Nunes Porto Filho	7	ETI	917	Grande	2491
Professor Amaro Matias Silva	7	EM	428	Médio	1860
Professor Augusto Tabosa	5	EM	897	Grande	3428
Professor Carlos Antonio Amaral de Almeida	9	CMEI	302	Médio	1510
Professor José Florêncio Leão	5	EM	538	Médio	1798

Professor José Florêncio Neto (Professor Machadinho)	5	EM	722	Grande	2939
Professor José Laurentino Santos	9	EM	1879	Grande	6949
Professor Kermógenes Dias de Araújo	8	EM	1082	Grande	4328
Professor Leudo Valença	7	EM	2166	Grande	8163
Professor Rubem de Lima Barros	7	ETI	602	Médio	1806
Professora Cacilda Santos	4	EM	43	Pequeno	172
Professora Cesarina Moura Vieira Costa	2	EM	692	Médio	2486
Professora Eunice Tabosa	4	EM	51	Pequeno	222
Professora Gianete Silva	8	EM	480	Médio	1761
Professora Guiomar Lyra	5	EM	274	Pequeno	1130
Professora Iva do Carmo Silva	2	EM	281	Pequeno	978
Professora Josélia Florêncio da Silveira	7	EM	1445	Grande	5012
Professora Lindomar Pinheiro	6	CMEI	128	Pequeno	640
Professora Margarida Maria de Farias Barros Miranda	9	EM	1252	Grande	4877
Professora Maria Bezerra Torres	1	EM	358	Médio	1393
Professora Maria Cândida	1	EM	23	Pequeno	92
Professora Maria de Lourdes Azevedo Lira	4	EM	6	Pequeno	24
Professora Maria de Lourdes Nascimento Pontes - Tia Lourdinha	9	CMEI	339	Médio	1695
Professora Maria de Lourdes Pepeu	1	EM	129	Pequeno	545
Professora Maria do Carmo Queiroz Cabral	6	CMEI	233	Pequeno	1165
Professora Maria Emília	3	EM	55	Pequeno	265
Professora Mariana de Lourdes Lima	5	EM	938	Grande	3422
Professora Nerine Francisca de Carvalho	2	CMEI	210	Pequeno	1050
Professora Sinhazinha	7	EM	1015	Grande	4204
Professora Teresa Neuma Pereira Pedrosa	9	EM	1188	Grande	4320
Sabino José Pereira da Silva	2	EM	21	Pequeno	97
Santa Inês	4	EM	42	Pequeno	178
Santa Regina	3	EM	64	Pequeno	281
Santos Anjos	9	EM	903	Grande	3612
São José	4	EM	53	Pequeno	161
São Judas Tadeu	4	EM	66	Pequeno	281
São Luiz de Gonzaga	3	EM	59	Pequeno	236
São Severino	3	EM	26	Pequeno	115
São Vicente de Paula	3	EM	28	Pequeno	120
Severina Maria do Carmo - Dona Biu	8	CMEI	260	Pequeno	1300
Severino José de Oliveira	8	CMEI	439	Médio	2195
Severino Oliveira da Silva - Professor Biu Oliveira	9	CMEI	147	Pequeno	735
Tia Carminha	5	CMEI	114	Pequeno	570
Tia Clarice	6	CMEI	192	Pequeno	960
Tia Malude	6	CMEI	78	Pequeno	390
Típica Rural	3	EM	52	Pequeno	208
Tomé Claudino Torres	1	EM	95	Pequeno	415
Vereador José Ailton do Nascimento	1	CMEI	145	Pequeno	725
Vicente Correia	2	EM	10	Pequeno	40
Wirton Lira	8	CMEI	128	Pequeno	640