UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Seleção da localização de armazéns frigorificados para operações de distribuição através do agrupamento das distâncias dirigidas

Fábio Fernando da Silva

Dissertação de Mestrado do Programa de Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria (MECAI)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Fábio Fernando da Silva

Seleção da localização de armazéns frigorificados para operações de distribuição através do agrupamento das distâncias dirigidas

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestre – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria.
VERSÃO REVISADA

Área de Concentração: Matemática, Estatística e Computação

Orientador: Prof. Dr. Francisco Louzada Neto

USP – São Carlos
Julho de 2020

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

S586s Silva, Fábio Fernando da
Seleção da localização de armazéns frigorificados
para operações de distribuição através do agrupamento
das distâncias dirigidas / Fábio Fernando da Silva;
orientador Francisco Louzada Neto . -- São Carlos,
2020.
58 p.

Dissertação (Mestrado - Programa de Pós-Graduação
em Mestrado Profissional em Matemática, Estatística
e Computação Aplicadas à Indústria) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2020.

1. Localização de Instalações. 2. Desenho da rede
da cadeia de suprimentos. 3. Segmentação de mercado.
4. Distância dirigida. 5. k-médias. I. , Francisco
Louzada Neto, orient. II. Título.

Fábio Fernando da Silva

**Frozen facilities location for distribution operations based on
driving distance clustering**

Master dissertation submitted to the Institute of
Mathematics and Computer Sciences – ICMC-USP, in
partial fulfillment of the requirements for the degree of
the Master – Professional Masters in Mathematics,
Statistics and Computing Applied to Industry. *FINAL
VERSION*

Concentration Area: Mathematics, Statistics and
Computing

Advisor: Prof. Dr. Francisco Louzada Neto

USP – São Carlos
July 2020

FÁBIO FERNANDO DA SILVA

**SELEÇÃO DA LOCALIZAÇÃO DE ARMAZÉNS FRIGORIFICADOS PARA OPERAÇÕES DE
DISTRIBUIÇÃO ATRAVÉS DO AGRUPAMENTO DAS DISTÂNCIAS DIRIGIDAS**

Dissertação apresentada ao Instituto de
Ciências Matemáticas e de Computação -
ICMC-USP, como parte dos requisitos para
obtenção do título de Mestre.

Aprovado em 23 de junho de 2020.

COMISSÃO JULGADORA:

Prof. Dr. Francisco Louzada Neto
ICMC-USP
Presidente

Prof. Dr. Adciano Kamimura Suzuki
ICMC-USP
Membro

Prof. Dr. Pedro Luiz Ramos
Membro externo

Prof. Dr. Anderson Luiz Ara Souza
UFBA
Membro

Este trabalho é dedicado a Deus, que me permitiu a dádiva de ser pai.

Em especial ao meu filho,

Pedro Antônio,

que trouxe sentido a esta caminhada.

AGRADECIMENTOS

Os agradecimentos principais são direcionados aos meus pais, Nair e Antônio, pela dedicação à família e pelo exemplo de que o conhecimento e o trabalho são bens importantes e necessários.

Agradeço ainda minha esposa, Elisangela, pelo apoio sem o qual não seria possível a conclusão deste trabalho.

Agradecimentos especiais são direcionados ao Prof. Dr. Francisco Louzada Neto, pela orientação e direcionamento.

*“As invenções são, sobretudo,
o resultado de um trabalho de teimoso.”
(Santos Dumont)*

RESUMO

SILVA, F. F. **Seleção da localização de armazéns frigorificados para operações de distribuição através do agrupamento das distâncias dirigidas**. 2020. 58 p. Dissertação (Mestrado – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2020.

A localização de instalações é considerada por muitos pesquisadores e profissionais uma decisão estratégica importante dentro do desenho da rede da cadeia de suprimentos. Os problemas de localização de instalações são caracterizados a partir de um espaço onde a distância é definida, localizando um conjunto de novos pontos em número fixo ou variável com o intuito de minimizar o custo de satisfazer as demandas dadas com relação a algum conjunto de restrições. Esse trabalho apresenta o uso da distância dirigida para a seleção de localizações e o cálculo da demanda de produtos com temperatura controlada para todo o território brasileiro. Essa análise é baseada no uso do algoritmo k-médias para o agrupamento e posterior sugestão da melhor localização, respeitando os requisitos de distância e consumo. Como prova do conceito, são apresentados o ambiente computacional, o código fonte em R, o cálculo da demanda em escala municipal, a relação existente entre a segmentação do mercado e o número de agrupamentos. Acreditamos que o método apresentado nessa dissertação possa ser aplicado para melhorar o gerenciamento das decisões da cadeia de suprimentos e ajudar as empresas a avaliar mais rapidamente as localizações das instalações.

Palavras-chave: Localização de instalações. Desenho da rede da cadeia de suprimentos. Segmentação de mercado. Distância dirigida. k-médias..

ABSTRACT

SILVA, F. F. **Frozen facilities location for distribution operations based on driving distance clustering**. 2020. 58 p. Dissertação (Mestrado – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2020.

Facilities location is considered by many researchers and professionals to be an important strategic decision within the design of the supply chain network. Location problems are characterized from a space which the distance is defined, locating a set of new points in a fixed or variable number in order to minimize the cost of satisfying the demands given with respect to some set of constraints. This dissertation presents the use of the driving distance for selection of locations based on calculated demand for products with controlled temperature into Brazilian territory. This analysis is based on k-means algorithm for grouping and suggestion of the best location, respecting the distance and consumption requirements. As proof of the concept, the computational environment, the source code in R, the calculation of demand on a municipal scale, the relationship between market segmentation and the number of clusters are presented. We believe that the method presented in this dissertation can be applied to improve the management of supply chain decisions and help companies to access facility locations more quickly.

Keywords: Facility Location. Supply Chain Network Design. Market Segmentation. Driving Distance. k-means..

LISTA DE ILUSTRAÇÕES

Figura 1 – Distâncias Euclidiana, grande círculo e dirigida entre SP e RJ.	36
Figura 2 – Demanda municipal mensal em posições paletes.	42
Figura 3 – Mapa da demanda municipal mensal em m ³	43
Figura 4 – Mapa dos agrupamentos e seus respectivos centros de gravidade.	44

LISTA DE QUADROS

Quadro 1 – Grupos de produtos com temperatura controlada.	30
Quadro 2 – Explicação das variáveis do conjunto de dados.	33

LISTA DE TABELAS

Tabela 1 – Bases consultadas para as referências bibliográficas	26
Tabela 2 – Aquisição alimentar domiciliar <i>per capita</i> anual por estado	31
Tabela 3 – Demanda estática mensal para São Paulo/SP em posições palete e m^3	32
Tabela 4 – Demanda estática mensal para Rio de Janeiro/RJ em posições palete e m^3	33
Tabela 5 – Demanda total brasileira.	41
Tabela 6 – Localização dos centros de gravidade de cada agrupamento	45
Tabela 7 – Agrupamento 2, centro de gravidade Firmino Alves/BA	46
Tabela 8 – Demanda potencial dos agrupamentos em m^3	47
Tabela 9 – Municípios brasileiros com as 100 maiores demandas	55
Tabela 9 – Municípios brasileiros com as 100 maiores demandas	56
Tabela 9 – Municípios brasileiros com as 100 maiores demandas	57
Tabela 9 – Municípios brasileiros com as 100 maiores demandas	58

LISTA DE ABREVIATURAS E SIGLAS

ABIAF	Associação Brasileira da Indústria Frigorificada
Big Data	Grande Volume de Dados ou Megadados
FLPs	Facility Location Problems
GIS	Sistemas de Informações Geográficas
IARW	2019 IARW Global Top 25 List
IBGE	Instituto Brasileiro de Geografia e Estatística
IoT	Internet of Things
KDD	<i>Knowledge Discovery in Databases</i>
POF	Pesquisa de Orçamentos Familiares
RFID	Radio Frequency Identification
robô	Algoritmo desenvolvido para cumprir uma série de rotinas de forma autônoma
SIDRA	Sistema IBGE de Recuperação Automática
Visual Analytics	Análise Visual
WFLO	<i>World Food Logistics Organization</i>

SUMÁRIO

1	INTRODUÇÃO	25
2	MATERIAIS E MÉTODOS	27
2.1	Considerações gerais	27
2.2	Análise visual	28
2.3	Mineração de dados e descoberta de conhecimento em bases de dados	28
2.4	Estimando a demanda	30
2.5	Funções de distância na teoria da localização	33
2.6	Segmentação de mercado	36
2.7	Ambiente computacional	38
3	RESULTADOS	41
4	CONCLUSÕES E TRABALHOS FUTUROS	49
4.1	Trabalhos futuros	49
	REFERÊNCIAS	51
APÊNDICE A	DEMANDA DOS 100 MAIORES MERCADOS	55

INTRODUÇÃO

A localização de instalações é considerada por muitos pesquisadores e profissionais uma decisão estratégica importante dentro do desenho da rede da cadeia de suprimentos. A teoria da localização foi introduzida formalmente pela primeira vez por Alfred Weber (1909), que considerou o problema de localizar um armazém único para minimizar a distância de viagem total entre o armazém e um conjunto de clientes espacialmente distribuídos (BRANDEAU; CHIU, 1989). Com o intuito de dar suporte científico e prático à teoria da localização, diversos modelos foram desenvolvidos e aplicados em áreas diferentes nas últimas décadas. Uma revisão ampla pode ser encontrada em (BRANDEAU; CHIU, 1989), (MELO; NICKEL; GAMA, 2009), (REVELLE; EISELT, 2005) e (TURKOGLU; GENEVOIS, 2019a). Do ponto de vista geral, problemas de localização de instalações ou *Facility Location Problems* (FLPs), são definidos em termos de espaço e tempo, permitindo que ambas as dimensões sejam analisadas por aspectos discretos e contínuos (ARABANI; FARAHANI, 2012). Estes trabalhos utilizam em sua grande maioria a distância Euclidiana, que apesar de válida para diversos estudos, segundo Turkoglu e Genevois (2019b), pode ser melhorada com o uso da distância dirigida Shih (2015). Conforme abordado por Mishra e Singh (2020), as empresas estão vivenciando uma revolução na tomada de decisões orientadas por dados, apresentando imenso potencial para transformar instalações tradicionais em uma rede de instalações inteligentes otimizadas e eficientes. Estas instalações inteligentes guiam sua inteligência a partir da coleta de dados em tempo real por meio da Internet das Coisas, do inglês *Internet of Things* (IoT) e de sensores de identificação por rádio frequência, do inglês *Radio Frequency Identification* (RFID), para suportar a tomada de decisão rápida e precisa para o gerenciamento de toda a cadeia de suprimentos. Contudo, os dados gerados aqui são volumosos, do inglês *Big Data*, e possuem potencial promissor somente quando a instalação é capaz de aproveitar as informações úteis deste grande conjunto de dados. Apesar da grande massa de dados acumulada atualmente pelas empresas de logística (NGUYEN *et al.*, 2018), a capacidade de análise ainda está limitada ao uso de técnicas simples e ferramentas manuais, em sua maioria planilhas eletrônicas. Desta forma, o objetivo deste trabalho compreende em:

- Desenvolver uma metodologia de análise, que sirva de referência para a seleção de localizações;
- Fazer uso das técnicas de visualização e informações geoespaciais buscando melhores interpretações dos dados;
- Estabelecer um ambiente computacional de código aberto para a roteirização massiva;
- Utilizar a distância dirigida como função-objetivo;
- Auxiliar na tomada de decisões gerenciais em nível estratégico.

As referências utilizadas para a revisão bibliográfica foram selecionadas a partir das bases de dados do Google Acadêmico, Mendeley e SCOPUS. As consultas foram realizadas a partir das seguintes palavras chave: **“facility location” OR “market segmentation” OR “supply chain network design” AND “driving distance”**. Os resultados são apresentados na Tabela 1:

Tabela 1 – Bases consultadas para as referências bibliográficas

Base	Resultados	Data
Google Acadêmico	532	15/08/2020
Mendeley	4	15/08/2020
SCOPUS	4	15/08/2020

Fonte: Elaborada pelo autor.

Foram utilizados ainda dois livros textos tradicionais, a saber (BALLOU, 2010) e (CHOPRA; MEINDL, 2015) para tópicos específicos. É importante observar que, apesar de muito ter sido escrito sobre localização de armazéns, somente os trabalhos de Shih (2015) e Boscoe, Henry e Zdeb (2012) mencionam o uso da distância dirigida até a presente data. O restante do trabalho está organizado da seguinte forma. O Capítulo 2 é subdividido em diversas seções, nas quais são apresentados os principais tópicos para a realização deste trabalho. Na Seção 2.1 são realizadas as considerações gerais, na Seção 2.2 é apresentado como este trabalho utiliza algumas técnicas de Análise Visual com o intuito de facilitar a tomada de decisão a partir da interpretação dos dados, na Seção 2.3 são discutidas as técnicas fundamentais para a formação da base de dados do trabalho, na Seção 2.4 é apresentada a metodologia utilizada para estimar a demanda de produtos com requisitos de temperatura controlada, na Seção 2.5 é discutido a importância das funções de distância, na Seção 2.6 a segmentação de mercado é utilizada para suportar o modelo de agrupamento e na Seção 2.7 o ambiente computacional está descrito com maiores detalhes. O Capítulo 3 apresenta os resultados, sendo de grande importância a validação de cada agrupamento dentro das premissas apresentadas na Seção 2.1. Finalmente, as considerações finais são realizadas no Capítulo 4 sendo que na Seção 4.1 são apresentadas algumas sugestões para trabalhos futuros.

MATERIAIS E MÉTODOS

Para realizar esse trabalho, diversas técnicas são utilizadas, uma vez que não há disponível na literatura uma única técnica ou ferramenta que resolva a questão de análise de grandes volumes de informações de maneira visual e analítica de forma automática.

Da aquisição dos dados e descoberta de conhecimento até a apresentação dos dados de maneira que os tomadores de decisão possam interagir e atuar, diversos trabalhos apresentaram a evolução dos Sistemas de Informações Geográficas (GIS) e o desafio chave de combinar de maneira inteligente as técnicas de visualização e os algoritmos analíticos, permitindo que a experiência humana guie o processo de tomada de decisão.

Por isso, ferramentas de código aberto e fabricantes de sistemas oferecem uma ampla variedade de tecnologias para a tratativa de dados espaciais, permitindo que técnicas avançadas estejam disponíveis ao alcance de um acesso à Internet.

Considerando que a manipulação e entendimento de dados geográficos são uma necessidade, apresentamos as principais técnicas utilizadas e as informações produzidas.

2.1 Considerações gerais

Inicialmente, para a realização do trabalho as seguinte considerações gerais são assumidas:

- Cada localização terá como área de atendimento a distância dirigida máxima de 150 quilômetros;
- Todos os centros de distribuição terão 100.000 m³ de capacidade;
- Para o cálculo do Centro de Gravidade será utilizada a demanda potencial de cada cidade, calculada de acordo com a Equação 2.1, apresentada na página 32.

2.2 Análise visual

Vive-se em um mundo onde a capacidade de produzir e armazenar dados supera em muito a habilidade humana de usar essa massa de dados brutos para tomada de decisão [Kerren et al. \(2008a\)](#). Ainda de acordo com os mesmos autores, esse fenômeno é conhecido como o "problema de sobrecarga de informações", referindo-se ao perigo de perder-se em dados irrelevantes para a tarefa atual, processados ou apresentados de maneira inapropriada.

A interpretação das informações apresentadas depende da escala, da cognição humana, da percepção visual, das cores, de treinamento e das técnicas de apresentação escolhidas. Para apresentar dados espaciais de uma forma compreensível aos seres humanos, mapas têm sido utilizados por diversas áreas do conhecimento. Conforme mencionado em [Keim et al. \(2010\)](#), "o uso de mapas pode ser considerado como uma análise (geo)visual".

Segundo [Thomas e Cook \(2005\)](#), a Análise Visual (Visual Analytics) é “a ciência do raciocínio analítico, facilitado por interfaces visuais interativas”. Uma definição mais atual e específica é dada em [Keim et al. \(2010\)](#), "A análise visual combina técnicas de análise automatizadas com visualizações interativas para um efetivo entendimento, raciocínio e decisão com base em conjuntos de dados grandes e complexos".

Algumas dificuldades conhecidas na visualização de dados geoespaciais são a super plotagem, a dificuldade de encontrar agrupamentos pequenos e a tratativa espaço-tempo simultaneamente [Keim et al. \(2004\)](#).

Em relação ao mapeamento de cores, serão seguidas as orientações relacionadas em [Zhou e Hansen \(2016\)](#), utilizando o mapa de cores sequencial **ColorBrewer**, conforme [Brewer \(2013\)](#).

Para permitir que a interpretação dos dados tabulares seja realizada de maneira fácil, as informações devem ser expostas de forma compreensível. Assim, para evitar alguns problemas conhecidos ([KERREN et al., 2008b](#)) e permitir a descoberta de significado e intuições em dados espaciais de maneira visual, esse trabalho utilizará a abordagem de apresentação do seu conjunto de dados em mapas.

2.3 Mineração de dados e descoberta de conhecimento em bases de dados

O termo *Knowledge Discovery in Databases* (KDD) ou em português “Descoberta de Conhecimento em Bases de Dados” foi cunhado em 1989 por Piatetsky-Shapiro para o primeiro workshop na técnica de análise de dados, conforme [Piatetsky-Shapiro \(1991\)](#).

Desde as primeiras publicações sob esta nomenclatura [Piatetsky-Shapiro \(1991\)](#), o processo KDD tem sido apresentado como uma "oportunidade para resolver o problema de

extração de conhecimento em grandes bases de dados", até o uso em trabalhos atuais, como por exemplo, (KERREN *et al.*, 2008a), (SACHA *et al.*, 2014), "a técnica de descoberta de conhecimento e mineração tornou-se um ciência com longa tradição e bases teóricas sólidas", conforme citado em Keim *et al.* (2010).

Segundo Silva, Peres e Boscarioli (2016), "o termo mineração de dados é definido em termos do esforço para descoberta de padrões em bases de dados. A partir dos padrões descobertos, têm-se condições de gerar conhecimento útil para um processo de tomada de decisão".

Conforme descrito em Fayyad, Piatetsky-Shapiro e Smyth (1996), as fases do processo são:

1. Compreender o domínio do aplicativo e o objetivo do processo;
2. Criar um conjunto de dados de destino como um subconjunto de todos os dados disponíveis;
3. Atuar na limpeza e pré-processamento de dados para remover o ruído, manipulação dos dados faltantes e valores atípicos;
4. Realizar a redução e projeção dos dados para focar os recursos relevantes para o problema;
5. Corresponder metas de processo para um método de mineração de dados. Decidir o objetivo do modelo, como o agrupamento ou a classificação;
6. Escolher os algoritmos de mineração de dados para corresponder à finalidade do modelo da **Etapa 5**;
7. Executar os algoritmos nos dados;
8. Proceder com a interpretação dos padrões minerados para torná-los compreensíveis pelo usuário, como o resumo e a visualização;
9. Atuar sobre o conhecimento descoberto, como informar ou tomar decisões.

O processo KDD será utilizada neste trabalho para a construção da base de dados, que suportará a estimativa da demanda de consumo de produtos com necessidade de temperatura controlada, apresentada na Seção 2.4.

2.4 Estimando a demanda

A previsão de consumo de produtos com necessidade de temperatura controlada é uma tarefa bastante árdua, uma vez que as informações não são encontradas de maneira consolidada em nenhuma fonte oficial brasileira.

Como ponto de partida, utilizamos a Pesquisa de Orçamentos Familiares (POF) a qual, segundo o Instituto Brasileiro de Geografia e Estatística (IBGE), "avalia as estruturas de consumo, de gastos, de rendimentos e parte da variação patrimonial das famílias, oferecendo um perfil das condições de vida da população a partir da análise dos orçamentos domésticos."

Apesar do início da divulgação dos primeiros resultados da POF 2017-2018 terem sido iniciados no final de 2019, os dados para estimar a demanda de consumo foram extraídos da POF 2008-2009, já completamente divulgados.

Os dados foram obtidos através do Sistema IBGE de Recuperação Automática (SIDRA) e os grupos foram selecionados conforme o Quadro 1.

Quadro 1 – Grupos de produtos com temperatura controlada.

Grupo	Descrição
5.3	Massas
7.	Carnes
8.	Vísceras
9.	Pescados
10.	Aves e Ovos
11.	Laticínios

Fonte: Elaborada pelo autor.

A escolha dos grupos apresentados no quadro 1, seguiu o critério de controle de temperatura conforme o Manual de Armazenamento de Produtos da *World Food Logistics Organization* (WFLO). Uma característica comum aos produtos que compõem cada um dos grupos selecionados é a temperatura de armazenamento mínimo de -18°C , a saber, produtos “congelados”.

A Tabela 2, apresenta a aquisição alimentar domiciliar *per capita* anual em quilogramas por estado.

Tabela 2 – Aquisição alimentar domiciliar *per capita* anual por estado

Estado	Consumo per capita anual/Kg
Rio Grande do Sul	145,765
Santa Catarina	129,615
Paraná	113,127
Rondônia	107,030
Pará	103,618
Amazonas	103,026
Acre	102,198
Tocantins	99,437
Mato Grosso do Sul	98,548
São Paulo	98,376
Minas Gerais	96,121
Rio Grande do Norte	95,172
Ceará	89,140
Rio de Janeiro	89,017
Distrito Federal	87,265
Sergipe	86,773
Amapá	85,608
Goiás	82,711
Bahia	81,372
Paraíba	79,649
Mato Grosso	79,261
Piauí	76,254
Espírito Santo	75,434
Pernambuco	71,399
Maranhão	63,986
Roraima	56,470
Alagoas	55,204

Ordenação ascendente realizada pelo autor

Fonte: [IBGE-SIDRA \(2008\)](#).

As informações fornecidas pela POF não contemplam granularidade além dos estados brasileiros, porém devido a distância escolhida como limite para atendimento de cada armazém na Seção 2.1, a saber 150 quilômetros, será utilizado o nível geográfico municipal (IBGE-DTB, 2018) para formação da base de dados.

A partir das variáveis primárias, população urbana e aquisição alimentar (IBGE-SIDRA, 2008), elaboramos a equação da demanda estática 2.1:

$$D_e = P_u * AFC, \quad (2.1)$$

onde, D_e é a demanda estática estimada em quilogramas (Kg), P_u é a população urbana do município e AFC é o consumo alimentar per capita, conforme Tabela 2.

A conversão da demanda estática de quilogramas (Kg) para posições paletes (p.p) e metros cúbicos (m^3), demonstradas na Tabela 3 e na Tabela 4, relacionam a demanda com o espaço físico utilizado nos centros de distribuição para seu armazenamento, sendo posteriormente utilizadas nesse trabalho.

Para exemplificar o uso da Equação 2.1, segue o cálculo completo para a cidade de São Paulo/SP na Tabela 3.

Tabela 3 – Demanda estática mensal para São Paulo/SP em posições paleta e m^3 .

Descrição	Valores	Unidades
População Urbana	11.152.344	[pessoas]
POF	98,376	[per capita / Kg / ano]
+30% Fora de Casa	127,89	[per capita / Kg / ano]
Alimento Frio Consumido	1.426.259.891	[Kg / ano]
Capacidade por Paleta	800	[Kg]
Quantidade de Paletes	148.569	[mês]
Expectativa de Giro	20	[dias]
Demanda Estática Necessária	99.046	[posições paletes] ¹
Conversão 1 posição paleta	8	[m^3]
Demanda Estática Necessária	792.367	[m^3]

Fonte: Elaborada pelo Autor

¹ considerar 30 dias

Para a cidade do Rio de Janeiro/RJ, a Equação 2.1 apresenta os resultados da Tabela 4.

Tabela 4 – Demanda estática mensal para Rio de Janeiro/RJ em posições palete e m^3 .

Descrição	Valores	Unidades
População Urbana	6.320.446	[pessoas]
POF	89,017	[per capita / Kg / ano]
+30% Fora de Casa	115,72	[per capita / Kg / ano]
Alimento Frio Consumido	731.415.284	[Kg / ano]
Capacidade por Palete	800	[Kg]
Quantidade de Paletes	76.189	[mês]
Expectativa de Giro	20	[dias]
Demanda Estática Necessária	50.793	[posições paletes] ²
Conversão 1 posição palete	8	[m^3]
Demanda Estática Necessária	406.343	[m^3]

Fonte: Elaborada pelo autor.

Seguindo a mesma lógica apresentada nas Tabelas 3 e 4, uma base de dados foi preparada manualmente para todos os municípios brasileiros. Essa base de dados foi enriquecida com as informações de latitude e longitude, conforme metodologia KDD apresentada na Seção 2.3, isto é, geolocalizados. O conjunto de dados compreende 5570 amostras e 8 variáveis, considerando as informações apresentadas no Quadro 2:

Quadro 2 – Explicação das variáveis do conjunto de dados.

Variável	Explicação
nome_mun	Nome do município
CD_GEOCODI	Código do setor censitário do IBGE
uf	Estado
AFCMes	Alimento Frio consumido no mês
CapEstNepp	Capacidade estática nominal em posições paletes
CapEstNem3	Capacidade estática nominal em m^3
lat	Latitude decimal
lon	Longitude decimal

Fonte: Elaborada pelo autor.

A demanda pode ser visualizada na Figura 3, no Capítulo 3 dos **Resultados**.

2.5 Funções de distância na teoria da localização

Para Zarinbal (2009), as funções de distância desempenham um papel importante nos problemas de localização de instalações. A autora apresenta diferentes funções de distância

² considerar 30 dias

utilizadas em problemas de localização, tendo cada uma delas seu domínio, vantagens e desvantagens. Ela define distância como uma descrição numérica de quão distantes os objetos estão em um dado momento no tempo.

De acordo com [Ballou \(2010\)](#), o trabalho de planejamento da rede de suprimentos tem natureza geográfica e obriga os profissionais envolvidos a utilizar distâncias para estimar o custo de transporte entre pontos de origem e destino. Ainda segundo o mesmo autor, as distâncias calculadas sempre irão reduzir a distância real entre dois pontos, uma vez que os veículos não trafegam em linhas retas. O próprio autor apresenta uma tabela com fatores de correção chamados de fator de circuito.

Baseado nos trabalhos de [Zarinbal \(2009\)](#), [Ballou \(2010\)](#), [Chopra e Meindl \(2015\)](#), nota-se que as funções de distância mais utilizadas nos modelos de superfície plana são as distâncias Euclidiana e a Retilínea.

De acordo com o trabalho de [Boscoe, Henry e Zdeb \(2012\)](#), há a necessidade de se realizar um ajuste na distância Euclidiana, quando essa é utilizada em modelos de localização para calcular a distância entre pontos de origem e destino. Os autores propõem um modelo de regressão linear simples, para aproximar a distância Euclidiana da realidade através do cálculo do fator de circuito. Eles concluem que este modelo gera resultados desproporcionais para distâncias curtas, sendo necessário identificar uma faixa de valores válidos para sua equação.

Outra função de distância importante mencionada em [Ballou \(2010\)](#), [Csoke \(2015\)](#), [Onnela \(2015\)](#) é a distância de grande círculo. O autor [Mwemezi e Huang \(2011\)](#) apresenta a distância de grande círculo como o caminho mais curto sobre uma superfície esférica, e afirma que aplicando esta medida de distância aos problemas de localização de instalações, esses podem ser modelados mais realisticamente devido a natureza esférica da terra. De acordo com [Shih \(2015\)](#) os modelos de localização de instalações esféricos são mais realísticos do que os modelos de localização de instalações planos, especialmente para grandes distâncias.

De acordo com [Gonçalves et al. \(2014\)](#), muitos estudos utilizam a distância Euclidiana pela sua facilidade de cálculo e investigam a percepção atual de que o uso da distância dirigida sobre a malha rodoviária é uma alternativa superior, mesmo que historicamente cara e trabalhosa. Afirmam que dada a densidade da malha rodoviária americana, os autores consideram que não há grandes melhorias nos cálculos de distância e que os resultados sugerem que muitos estudos considerando distâncias em linha reta continuam válidos. Reconhecem também que rios, montanhas, regiões costeiras e grandes obstáculos intransponíveis, podem proporcionar grandes variações na distância de um ponto de origem para um ponto de destino. Afirmam que o custo para obter a distância dirigida e o tempo de viagem se tornou desprezível, recomendando assim a incorporação dessa pequena precisão adicional em futuros estudos, principalmente nos casos que o fator urgência seja preponderante.

No trabalho de [Shih \(2015\)](#), o autor afirma que não há muitos artigos que apresentam

decisões ótimas ou quase ótimas de localização de instalações, envolvendo funções objetivas utilizando a distância dirigida. São apresentados exemplos os quais a distância Euclidiana e a distância de grande círculo são muito próximas, e ao mesmo tempo a distância dirigida é muito mais longa, considerando a região do meio oeste americano. O autor conclui que na presença de barreiras geográficas, considerando o custo de transportes, a distância dirigida deve ser levada em consideração nas decisões de localização da instalação.

Os autores [Boscoe, Henry e Zdeb \(2012\)](#) afirmam que devido à precariedade das estradas nas regiões estudadas, os sistemas GIS geram uma distância superior à esperada pela literatura, reduzindo assim a precisão no cálculo de coeficientes.

Para ilustrar as diferenças e semelhanças entre a distância Euclidiana, de grande círculo, e a distância dirigida, tomamos como exemplo dois pontos de referência entre as duas cidades mais populosas do Brasil, respectivamente São Paulo (**latitude= -23.530350, longitude= -46.737540**) e Rio de Janeiro (**latitude= -22.834480, longitude= -43.337440**).

A distância Euclidiana será calculada utilizando o teorema de Pitágoras sobre uma projeção cilíndrica equidistante, como apresentado em ([VENESS, 2019](#)), através das equações:

$$x = \Delta\lambda \cdot \cos \varphi_m, \quad (2.2)$$

$$y = \delta\varphi, \quad (2.3)$$

e

$$d = R \cdot \sqrt{x^2 + y^2}. \quad (2.4)$$

A distância de grande círculo será calculada utilizando a fórmula de haversine, como apresentado em [Veness \(2019\)](#), através das equações:

$$a = \sin^2(\Delta\varphi/2) + \cos \varphi_1 \cdot \cos \varphi_2 \cdot \sin^2(\Delta\lambda/2), \quad (2.5)$$

$$c = 2 \cdot \operatorname{atan2}(\sqrt{a}, \sqrt{1-a}), \quad (2.6)$$

e

$$d = R \cdot c. \quad (2.7)$$

No cálculo de ambas as distâncias, a Euclidiana é a de grande círculo, φ é a latitude, λ é a longitude, $R = 6.372.797.560856$ metros é o raio da terra conforme [PROJECT OSRM \(2019a\)](#). Os ângulos devem estar em radianos.

Logo se têm uma distância Euclidiana de 356,16 quilômetros e uma distância de grande círculo de 356,15 quilômetros.

Utilizando a Figura 1 como referência visual dos pontos escolhidos entre São Paulo e Rio de Janeiro, pode-se constatar que a distância Euclidiana e a distância de grande círculo são semelhantes, e que a distância dirigida, nesse caso de 425,2 quilômetros, é muito mais longa.

Figura 1 – Distâncias Euclidiana, grande círculo e dirigida entre SP e RJ.

Fonte: [PROJECT OSRM \(2019c\)](#).

A fim de poder realizar a localização de armazéns em todo o território brasileiro, verificou-se a necessidade de calcular uma matriz de distâncias dirigidas entre todos os municípios do Brasil, a saber, 5570 municípios. Devido ao grande número de consultas, $5570 \times 5570 = 31.024.900$, e conforme sugestão de trabalho futuro em ([SHIH, 2015](#)), foi preparado um ambiente computacional conforme descrito na Seção 2.7.

2.6 Segmentação de mercado

Conforme definido por [SMITH \(1956\)](#), a segmentação de mercado consiste em visualizar um mercado heterogêneo (caracterizado por demanda divergente), como um número menor de mercados homogêneos em resposta a diferentes preferências de produtos entre segmentos importantes. É atribuível aos desejos dos consumidores ou usuários, para obter uma satisfação mais precisa de suas diversas necessidades.

Segundo [LOUZADA-NETO et al. \(2010\)](#), "segmentar os clientes é então uma maneira de identificá-los e dividi-los em subgrupos distintos, caracterizados por necessidades, desejos e gostos particulares relativamente homogêneos, de modo a permitir uma abordagem mais direcionada e maior adequação de produtos, serviços e comunicação a esses grupos de consumidores".

De acordo com [Dolnicar, Grün e Leisch \(2018\)](#), a segmentação traz diversos benefícios, dentre eles, onde a empresa está e onde quer estar no futuro, o que a empresa é boa em relação ao concorrentes, entendimento do que os consumidores desejam, possibilidade de levar ao domínio de um nicho de mercado, oferta de produtos ou serviços customizados para um pequeno grupo de clientes, melhora do esforço de venda permitindo que a equipe foque em um grupo de clientes ao invés de cada cliente individualmente, possibilidade de contribuir para a formação da equipe, considerando que profissionais de diferentes áreas devem trabalhar em conjunto.

Conforme mencionado em [Nguyen et al. \(2018\)](#) o algoritmo de agrupamento k-médias

está entre as técnicas mais adaptáveis, uma vez que ele pode ser aplicado em modelos de agrupamento, classificação, previsão e simulação. Adicionalmente, [Wedel e Kamakura \(2000\)](#) afirma que o método de segmentação não hierárquico k-médias é o mais conhecido e amplamente utilizado, porém necessita antecipadamente do número de agrupamentos e demanda um grande esforço computacional. Esse último trabalho chama a atenção para a ênfase dada por [SMITH \(1956\)](#), sobre a segmentação de mercado surgir da conceitualização gerencial de um mercado estruturado e particionado e não do particionamento empírico do mercado com base nos dados coletados sobre as características do consumidor.

Diante dessas considerações, apesar da existência de diversos métodos teóricos para identificar a melhor quantidade de grupos, tais como o método do cotovelo (do inglês Elbow Method) e o método da silhueta (do inglês Silhouette Method), para o algoritmo k-médias, neste trabalho optou-se pela construção de um cenário onde serão utilizados 50 agrupamentos. Esse número de agrupamentos foi escolhido considerando os seguintes fatores:

- Tamanho da demanda total brasileira, calculada nesse trabalho e apresentada na Tabela 5 como sendo de 11.118.797 [m³/mês];
- Capacidade de 100.000 m³ para cada CD, apresentada como premissa na Seção 2.1;
- Tamanho do mercado a ser capturado de 50%.

Em resumo, temos a equação 2.8:

$$k = DTB/CCD * TM, \quad (2.8)$$

Na equação 2.8, DTB é a demanda total brasileira em m³, CCD é a capacidade máxima do CD m³ e TM é o tamanho do mercado a ser capturado em %.

Cada um destes agrupamentos deverá possuir uma demanda em m³ capaz de utilizar 100% da capacidade de armazenamento de cada centro de distribuição, dentro da distância máxima dirigida estipulada de 150 quilômetros. Para relacionar essas informações com a realidade, consideramos que o Brasil possui 10 milhões de m³ de capacidade de armazenagem frigorificada conforme as informações da Associação Brasileira da Indústria Frigorificada (ABIAF). Neste cenário, teríamos uma empresa de um pouco mais de 3 milhões de m³ de capacidade de armazenagem frigorificada, o que no momento da escrita deste trabalho posicionaria a referida empresa, considerando-se o quesito m³, como a primeira do mercado brasileiro e a décima no ranking mundial segundo a 2019 IARW Global Top 25 List (IARW).

A criação dos agrupamentos seguiu os seguintes passos:

- **Passo 1** Carregar o conjunto de dados;
- **Passo 2** Calcular a matriz de distâncias dirigidas;

- **Passo 3** Executar o algoritmo k-médias;
- **Passo 4** Calcular o centro de gravidade de cada agrupamento;
- **Passo 5** Geolocalizar os municípios contidos em cada agrupamento;
- **Passo 6** Desenhar o gráfico dos agrupamentos e seus centros de gravidade;
- **Passo 7** Validar as distâncias e os volumes de acordo com as premissas;
- **Passo 8** Retornar ao passo 3 e ajustar o número de grupos, caso alguma premissa não seja cumprida.

Os agrupamentos gerados a partir deste passo a passo podem ser visualizados na Figura 4, no Capítulo 3 dos **Resultados**.

2.7 Ambiente computacional

A necessidade de se obter referência espacial está amplamente disponível por meio da Internet como as bases do Google Mapas, Bing Mapas e ESRI segundo [SZTUTMAN \(2014\)](#). De forma geral, essas ferramentas são proprietárias, de uso gratuito e limitado a consultas manuais, considerando um número previamente definido de localizações. Para consultas automáticas, simultâneas e com grandes quantidades de localizações são oferecidos serviços pagos.

Algumas outras ferramentas utilizam o modelo de código aberto, sendo possível preparar um ambiente cliente/servidor para executar as consultas de uma maneira independente ([LUXEN; VETTER, 2011](#)), tal como a utilizada no presente trabalho, seguindo as orientações do guia rápido ([PROJECT OSRM, 2019b](#)).

O ambiente computacional foi construído em um Macbook Pro, configurado para o idioma Inglês com as características e ferramentas a seguir:

- Processador de 6 núcleos Intel Core i7 de 2,6 GHz;
- Memória RAM de 16 GB 2400 MHz DDR4;
- MacOS Catalina versão 10.15.2;
- R 3.6.0 GUI 1.70 El Capitan build (7657); ³
- Virtual Box versão 6.0.14 r133895 (Qt5.6.3);
- Microsoft® Excel versão 16.33 para auxiliar na exploração dos dados;

³ O código fonte desse trabalho em R está disponível em <https://zenodo.org/badge/latestdoi/229626451>

- Corretor ortográfico Português Brasil do Microsoft® Word versão 16.33;
- Overleaf L^AT_EX com o Modelo de Teses e Dissertações ICMC/USP.

Um ponto fundamental para a execução bem sucedida do cálculo da matriz de distâncias dirigidas, entre todos os municípios brasileiros, foi a quantidade de memória RAM e a quantidade de memória de troca alocadas na máquina virtual.

Sendo assim, seguem as características mais importantes da máquina virtual:

- Sistema Operacional Ubuntu 18.04.2 LTS 64 bits;
- Memória RAM de 8 GB;
- Disco Rígido de 100 GB;
- Memória de troca (swap) de 4 GB;
- Docker.

RESULTADOS

A demanda total de produtos com requisitos de temperatura controlada no Brasil, encontrada pelo método proposto na Seção 2.4, é apresentada na Tabela 5.

Tabela 5 – Demanda total brasileira.

Descrição	Valores	Unidades
Quilogramas/mês	1.667.822.198	[Kg/mês]
Toneladas/mês	1.667.822	[tons/mês]
Posições paletes	1.389.814	[pp/mês]
Metros cúbicos/mês	11.118.797	[m ³ /mês]

Fonte: Elaborada pelo autor.

Após uma análise rápida do conjunto de dados utilizando-se estatística descritiva, verificamos uma variação de valores em relação as características da demanda, explicitada pela distância entre a média e a mediana. Nesse caso, observou-se que aproximadamente 86% dos valores são menores do que a média.

Outra ação realizada no conjunto de dados, foi a exclusão dos valores considerados fora de série, a saber, os 100 maiores valores, conforme Apêndice A.

Sendo assim, o diagrama de caixa apresentado na Figura 2, mostra os valores da demanda, sem considerar os valores fora de série.

Figura 2 – Demanda municipal mensal em posições paletes.

Fonte: Elaborada pelo autor.

A assimetria à direita ou positiva visualizada no diagrama de caixa da Figura 2, corrobora com o que foi constatado numericamente, isto é, que há mais mercados com pequenos valores de demanda, mesmo após a exclusão dos valores fora de série.

Todas as considerações a partir deste ponto foram realizadas com o conjunto de dados completo, incluindo os valores fora de série.

A Figura 3 apresenta a proporção da demanda e seu respectivo município, relacionando o tamanho dos pontos e as cores mais intensas, com os municípios de maiores demandas.

Figura 3 – Mapa da demanda municipal mensal em m³.

Fonte: Elaborada pelo autor.

Na Figura 4 é apresentado o resultado do agrupamento, podendo ser interpretado como a localização sugerida para cada centro de distribuição e sua respectiva área de influência/distribuição.

Figura 4 – Mapa dos agrupamentos e seus respectivos centros de gravidade.

Fonte: Elaborada pelo autor.

A Tabela 6 mostra as informações necessárias para relacionar no mapa a localização do centro de gravidade de cada agrupamento encontrado:

Tabela 6 – Localização dos centros de gravidade de cada agrupamento

Agrupamento	Localização	Longitude	Latitude
1	Santo Antônio/MA	-44.8000948483084	-4.70048787566208
2	Firmino Alves/BA	-39.8848003838099	-14.9955163843395
3	Chapecó/SC	-52.6065955780303	-27.2108481876387
4	Nova Maringá/MT	-56.847048639611	-12.9814108120216
5	Olho d' Água das Flores/AL	-37.1983604997378	-9.57721515455302
6	Palmeirópolis/TO	-48.343410147053	-13.1546042727869
7	São Francisco do Glória/MG	-42.2801051882712	-20.7533014279967
8	Barrolândia/TO	-48.8059157272048	-9.82740386397258
9	Nanuque/MG	-40.6002631633198	-17.7037850850206
10	Mato Grosso/PA	-37.747687091473	-6.49851172781938
11	Araçoiaba/PE	-35.0902160213776	-7.76740031224677
12	Ipangaçu/RN	-36.859180447887	-5.51863919611726
13	Jardim Santa Fé/SP	-46.7877121424711	-23.4183703685817
14	Rosana/SP	-53.0310838639638	-22.5690319786322
15	Pracinha/SP	-51.0542816136081	-21.8377812400664
16	Terra Roxa/PR	-54.1214625628699	-24.2812475699236
17	Pajeú do Piauí/PI	-42.7590910639436	-7.7157084908634
18	Bom Jesus/PI	-44.0312043247265	-9.32724175562883
19	Mandirituba/PR	-49.3251857076781	-25.8921824058894
20	São Luís/MA	-44.4006924918565	-2.69509201895271
21	Magé/RJ	-43.1902512123853	-22.7279479388652
22	Pentecoste/CE	-39.1196589432855	-3.79962317112379
23	Barcarena/PA	-48.5681147203233	-1.7014854263901
24	Carmo da Mata/MG	-44.8483653754474	-20.6274860968031
25	Codajás/AM	-62.0966630064737	-4.00877524647092
26	Prainha/PA	-53.6577855303478	-1.50053153775374
27	São Geraldo do Araguaia/PA	-48.6168185647829	-6.02268156937967
28	Fátima/BA	-38.1856088769564	-10.6096009755644
29	Juazeiro do Norte/CE	-39.3271104672427	-7.12404214317223
30	Espinosa/MG	-42.6892266946136	-14.9112134961185
31	Ariquemes/RO	-62.7954900888806	-10.172527644062
32	Iaçu/BA	-40.1977173805758	-12.9399259717063
33	Esmeraldas/MG	-44.2027474616102	-19.772376947081
34	Bagé/RS	-53.7451892778337	-30.9664550769273
35	Brochier/RS	-51.6450705956041	-29.5922371153112
36	Pindorama/SP	-48.9474496070138	-21.2161125878555
37	Jundiaí do Sul/PR	-50.2514997022554	-23.3768942456374
38	Parnamirim/RN	-35.2088865810983	-5.88950086318607
39	Uberaba/MG	-48.1120332993058	-19.372755390931
40	Pau d' Arco do Piauí/PI	-42.5527148766123	-5.19794308663815
41	Pouso Alegre/MG	-45.8296473532874	-22.3574679667722
42	Abadiânia/GO	-48.6686820309218	-16.2218358061594
43	Vila Nova de Bananal/ES	-41.142307334951	-19.7048582775757
44	Bom Retiro/SC	-49.3872696096507	-27.8656326172911
45	São João da Lagoa/MG	-44.2713572046535	-16.7927780136128
46	Ibateguara/AL	-35.9229526760909	-8.94456982248396
47	Juscimeira/MT	-54.9650309826426	-16.1311263943402
48	Novo Airão/AM	-60.9757885300968	-2.69373640203786
49	Catolândia/BA	-44.5413320850201	-12.2548596305991
50	Santo Amaro/BA	-38.7836767543592	-12.5995900540514

Fonte: Elaborada pelo autor.

A partir desse ponto, pode-se iniciar a análise individual dos agrupamentos, para compreender o potencial de cada localização dentro das restrições estabelecidas.

Respeitando a distância dirigida de 150 quilômetros, para o raio em torno do Agrupamento 2, tem-se uma demanda potencial de 55.757 m³, conforme a soma das 48 primeiras linhas do atributo **CapEstNem³** na Tabela 7.

Tabela 7 – Agrupamento 2, centro de gravidade Firmino Alves/BA

Seq	Localização	Distância	CapEstNem3	Latitude	Longitude
1	Firmino AlvesBA	12427	255	-14.92474	-39.91960
2	Santa Cruz da VitoriaBA	16720	298	-14.91218	-39.79616
3	ItororoBA	26439	1064	-15.11847	-40.06607
4	Floresta AzulBA	33390	432	-14.87611	-39.69309
5	IbicuiBA	38586	703	-14.74884	-39.94015
6	IguaiBA	40698	857	-14.75321	-40.08979
7	Itaju do ColoniaBA	43091	344	-15.16522	-39.77556
8	IbicaraiBA	43631	1051	-14.85834	-39.59180
9	Nova CanaaBA	56963	403	-14.85003	-40.18621
10	ItapetingaBA	59422	3895	-15.24751	-40.25099
11	AlmadinaBA	59780	299	-14.70831	-39.67246
12	ItapeBA	62205	422	-14.98677	-39.52783
13	JussariBA	65212	287	-15.12540	-39.50714
14	CoaraciBA	66166	1124	-14.64865	-39.58985
15	Barro PretoBA	74360	311	-14.77039	-39.41395
16	AratacaBA	81578	328	-15.21951	-39.42431
17	ItabunaBA	83498	11733	-14.78803	-39.27842
18	PotiraguaBA	89205	388	-15.59456	-39.87340
19	ItapitangaBA	91264	446	-14.51081	-39.61051
20	PocoesBA	93301	2037	-14.52385	-40.36372
21	Dario MeiraBA	94655	299	-14.41293	-40.00176
22	MacaraniBA	96518	802	-15.53027	-40.39049
23	Sao Jose da VitoriaBA	96946	303	-15.06678	-39.37249
24	ItambeBA	100096	1158	-15.25160	-40.62390
25	ItajuípeBA	100185	990	-14.67569	-39.37249
26	CaatibaBA	104431	317	-14.96770	-40.34969
27	BueraremaBA	105251	898	-15.01441	-39.29987
28	CamacanBA	108648	1451	-15.42010	-39.49640
29	MaiquiniqueBA	110092	406	-15.62206	-40.26483
30	ItagibaBA	111577	563	-14.23298	-39.85791
31	ItarantimBA	112515	899	-15.64910	-40.02229
32	IlheusBA	113263	9126	-14.79319	-39.04640
33	PlanaltoBA	114395	874	-14.66907	-40.47719
34	Aurelino LealBA	117766	671	-14.36791	-39.46574
35	UnaBA	125002	883	-15.20907	-39.19597
36	IpiauíBA	126059	2373	-14.13494	-39.73858
37	UrucuBA	126810	927	-14.51550	-39.29987
38	Bom Jesus da SerraBA	127176	163	-14.38655	-40.59406
39	Santa LuziaBA	128251	474	-15.42326	-39.27910
40	AiquaraBA	128696	158	-14.09613	-39.87848
41	Boa NovaBA	131991	341	-14.36562	-40.20750
42	Pau BrasilBA	132147	434	-15.48974	-39.69309
43	ItagiBA	133434	600	-14.16195	-40.01348
44	Manoel VitorinoBA	141185	432	-14.14814	-40.24023
45	UbaitabaBA	143136	1034	-14.30889	-39.32261
46	MascoteBA	144704	686	-15.69693	-39.44503
47	JordaniaMG	146637	501	-15.90139	-40.18442
48	Barra do ChocaBA	149754	1317	-14.86595	-40.57785
49	BandeiraMG	152677	165	-15.89045	-40.57373
50	JitaunaBA	153351	544	-13.94462	-39.87848

Fonte: Elaborada pelo autor.

Seguindo o mesmo princípio da Tabela 7, a demanda potencial para cada um dos 50

agrupamentos é apresentada na Tabela 8.

Tabela 8 – Demanda potencial dos agrupamentos em m³.

Seq	Capm3	Seq	Capm3
1	24.186	26	2.508
2	55.757	27	21.665
3	83.114	28	42.590
4	1.324	29	66.342
5	47.793	30	14.201
6	1.867	31	22.273
7	77.057	32	22.857
8	25.081	33	380.797
9	10.326	34	21.585
10	45.562	35	555.051
11	303.296	36	237.374
12	39.287	37	125.940
13	1.949.434	38	109.810
14	53.474	39	90.562
15	81.470	40	68.559
16	67.021	41	206.431
17	2.993	42	329.618
18	2.943	43	23.026
19	359.438	44	82.877
20	60.232	45	45.405
21	871.903	46	105.628
22	247.605	47	19.022
23	15.732	48	-
24	85.146	49	10.712
25	2.613	50	276.837

Fonte: Elaborada pelo autor.

Os Agrupamentos 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 12, 14, 15, 16, 17, 18, 20, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 34, 39, 40, 43, 44, 45, 47, 48 e 49 **NÃO** atenderam a premissa da capacidade em m³ para cada centro de distribuição, conforme estipulado na Seção 2.1, a saber, 100.000 m³.

Após investigação mais detalhada do agrupamento 48, constatamos que nenhuma cidade incluída tem acesso rodoviário, estando localizadas nos estados do Amazonas e do Pará, o que resultou num efeito colateral do agrupamento por meio das distâncias inexistentes.

Por outro lado, os Agrupamentos 11, 13, 19, 21, 22, 33, 35, 36, 37, 38, 41, 42, 46, e 50, atendem ambas as premissas estipuladas, ou seja, raio de 150 quilômetros e capacidade superior a 100.000 m³, sendo candidatos a serem submetidos a um estudo de viabilidade financeira, onde outros fatores como os sugeridos na Seção 4.1, poderiam ser considerados.

CONCLUSÕES E TRABALHOS FUTUROS

Nesse trabalho três objetivos foram alcançados, sendo o primeiro deles a apresentação de uma metodologia para estimar o consumo de produtos com temperatura controlada (demanda). O segundo, dada a localização e a demanda em cada destino, em termos de suas coordenadas geográficas, a metodologia proposta nesse trabalho é capaz de determinar a localização ideal de cada instalação. O terceiro foi estabelecer uma plataforma computacional com ferramentas de uso livre para localizar a instalação ideal. Além disso foi verificado que, na presença de barreiras geográficas, a distância dirigida deve ser levada em consideração nas decisões de localização da instalação.

Esse trabalho abordou a localização de instalações em todo o território brasileiro, utilizando distâncias dirigidas em uma superfície esférica.

Não foram considerados alguns fatores que podem afetar os locais das instalações, tais como: custos e disponibilidade de mão-de-obra (incluindo salários, produtividade, idade e sindicalização), políticas fiscais dos governos estaduais e locais (incluindo incentivos e impostos), questões de infraestrutura (rodovias estaduais e federais, ferrovias, hidrovias, portos e aeroportos), questões relacionadas a qualidade de vida (educação, custo de vida, assistência médica, esportes, atividades culturais, moradia, entretenimento, instalações religiosas, etc.).

O método proposto apresentou resultados, os quais podem ser aplicados para melhorar o gerenciamento das decisões da cadeia de suprimentos, e ajudar as empresas a avaliar rapidamente as localizações das instalações.

4.1 Trabalhos futuros

A primeira sugestão para um trabalho futuro é atualizar os resultados utilizando-se as informações da POF 2017-2018. Pensando em um planejamento empresarial de longo prazo, a coleta, preparação e a manutenção dos dados devem ser automatizadas por meio de algum

Algoritmo desenvolvido para cumprir uma série de rotinas de forma autônoma (robô). Para que essa metodologia possa ser utilizada no dia a dia para tomada de decisões estratégicas, o desenvolvimento de uma interface de usuário capaz de facilitar a interação com os dados e a apresentação gráfica dos resultados, é necessária. Por último, considerando o avanço acadêmico desse trabalho, outros algoritmos de agrupamento podem ser empregados e seus resultados avaliados.

REFERÊNCIAS

ARABANI, A. B.; FARAHANI, R. Z. Facility location dynamics: An overview of classifications and applications. **Computers & Industrial Engineering**, Pergamon, v. 62, n. 1, p. 408–420, feb 2012. ISSN 0360-8352. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360835211002877>>. Citado na página 25.

BALLOU, R. H. **Gerenciamento da Cadeia de Suprimentos/Logística Empresarial**. Porto Alegre: Bookman, 2010. 494–497 p. Citado nas páginas 26 e 34.

BOSCOE, F. P.; HENRY, K. A.; ZDEB, M. S. A Nationwide Comparison of Driving Distance Versus Straight-Line Distance to Hospitals. **Professional Geographer**, 2012. Citado nas páginas 26, 34 e 35.

BRANDEAU, M. L.; CHIU, S. S. An Overview of Representative Problems in Location Research. **Management Science**, v. 35, n. 6, p. 645–674, jun 1989. Disponível em: <<http://pubsonline.informs.org/doi/abs/10.1287/mnsc.35.6.645>>. Citado na página 25.

BREWER, C. A. **A web tool for selecting color maps**. 2013. Acessado em: 29/12/2017. Disponível em: <<https://http://colorbrewer2.org/#>>. Citado na página 28.

CHOPRA, S.; MEINDL, P. **Supply chain management : strategy, planning, and operation**. Sixth edition. Boston: Pearson, 2015. Citado nas páginas 26 e 34.

CSOKE, M. E. **The Facility Location Problem**. Dissertação (Mestrado) — Governors State University, 2015. All Student Theses. 63. Disponível em: <<https://opus.govst.edu/theses/63>>. Citado na página 34.

DOLNICAR, S.; GRÜN, B.; LEISCH, F. **Market Segmentation Analysis - Understanding It, Doing It, and Making It Useful**. 1. ed. Springer, Singapore, 2018. Open Access. ISBN 978-981-10-8818-6. Disponível em: <<https://link.springer.com/content/pdf/10.1007/978-981-10-8818-6.pdf>>. Citado na página 36.

FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. The kdd process for extracting useful knowledge from volumes of data. **Commun. ACM**, ACM, New York, NY, USA, v. 39, n. 11, p. 27–34, nov. 1996. ISSN 0001-0782. Disponível em: <<http://doi.acm.org/10.1145/240455.240464>>. Citado na página 29.

GONÇALVES, D. N. S.; GONÇALVES, C. D. M.; ASSIS, T. F. D.; SILVA, M. A. D. Analysis of the difference between the euclidean distance and the actual road distance in Brazil. In: **Transportation Research Procedia**. [S.l.: s.n.], 2014. Citado na página 34.

IBGE-DTB. **Divisão Territorial Brasileira, Lista de municípios**. 2018. [Online; accessed 22/12/2019]. Disponível em: <ftp://geofp.ibge.gov.br/organizacao_do_territorio/estrutura_territorial/divisao_territorial/2018/DTB_2018.zip>. Citado na página 32.

IBGE-SIDRA. **Tabela 2393 - Aquisição alimentar domiciliar per capita anual por grupos, subgrupos e produto**. 2008. [Online; accessed 23/12/2019]. Disponível em: <<https://sidra.ibge.gov.br/Tabela/2393#/t/2393/n3/all/v/all/p/last%201/c217/4104%204158%204237%204259%204466%204504/d/v1207%203/l/v,p%2Bc217,t/resultado>>. Citado nas páginas 31 e 32.

KEIM, D.; KOHLHAMMER, J.; ELLIS, G.; MANSMANN, F. E. **Mastering the Information Age – Solving Problems with Visual Analytics**. Eurographics Association, 2010. Disponível em: <<http://www.vismaster.eu/wp-content/uploads/2010/11/VisMaster-book-lowres.pdf>>. Acesso em: 27/12/2017. Citado nas páginas 28 e 29.

KEIM, D.; PANSE, C.; SIPS, M.; NORTH, S. Visual data mining in large geospatial point sets. **Computer Graphics and Applications, IEEE**, p. 36 – 44, 10 2004. Citado na página 28.

KERREN, A.; STASKO, J. T.; FEKETE, J.-D.; (EDS.), C. N. Information visualization: Human-centered issues and perspectives. In: _____. Springer-Verlag Berlin Heidelberg, 2008. v. 4950, p. 154–175. Acessado em: 29/12/2017. Disponível em: <[disponível em: https://link.springer.com/book/10.1007%2F978-3-540-70956-5](https://link.springer.com/book/10.1007%2F978-3-540-70956-5)>. Citado nas páginas 28 e 29.

_____. Information visualization: Human-centered issues and perspectives. In: _____. Springer LNCS, 2008. v. 4950, p. 134–153. Disponível em: <<http://www.cs.ubc.ca/labs/imager/tr/2008/pitfalls/pitfalls.pdf>>. Citado na página 28.

LOUZADA-NETO, F.; DINIZ, C. A. R.; COSTA, C. C. D.; SILVA, P. H. F. D.; DESTEFANI, C. R.; O. TEMPONI, A. P. Procedimentos estatísticos para segmentação de base de dados. **Revista Brasileira de Pesquisas de Marketing, Opinião e Mídia**, v. 5, n. 5, p. 32–39, 9 2010. Acessada em: 10/01/2020. Disponível em: <http://www.revistapmkt.com.br/LinkClick.aspx?fileticket=qh7U_Na4hyc%3d&tabid=407&portalid=9&mid=863>. Citado na página 36.

LUXEN, D.; VETTER, C. Real-time routing with openstreetmap data. In: **Proceedings of the 19th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems**. New York, NY, USA: ACM, 2011. (GIS '11), p. 513–516. ISBN 978-1-4503-1031-4. Disponível em: <<http://doi.acm.org/10.1145/2093973.2094062>>. Citado na página 38.

MELO, M. T.; NICKEL, S.; GAMA, F. Saldanha-da. Facility location and supply chain management - A review. **European Journal of Operational Research**, 2009. ISSN 03772217. Citado na página 25.

MISHRA, S.; SINGH, S. P. Distribution network model using big data in an international environment. **Science of The Total Environment**, v. 707, p. 135549, 2020. ISSN 0048-9697. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0048969719355433>>. Citado na página 25.

MWEMEZI, J. J.; HUANG, Y. Optimal facility location on spherical surfaces: algorithm and application. **New York Science Journal**, v. 4, n. 7, p. 21–28, 2011. Citado na página 34.

NGUYEN, T.; ZHOU, L.; SPIEGLER, V.; IEROMONACHOU, P.; LIN, Y. Big data analytics in supply chain management: A state-of-the-art literature review. **Computers and Operations Research**, v. 98, p. 254–264, oct 2018. Citado nas páginas 25 e 36.

ONNELA, N. **Determining the Optimal Distribution Center Location**. Dissertação (Mestrado) — Tampere University of Technology, 2015. Master of Science Thesis, 89 pages, 23 Appendix pages. Disponível em: <<http://urn.fi/URN:NBN:fi:ty-201504221207>>. Citado na página 34.

PIATETSKY-SHAPIO, G. Knowledge discovery in real databases: A report on the ijcai-89 workshop. **AI Magazine - Reports from three of the 1990 Spring symposia and eight workshops held over the past two years**, American Association for Artificial Intelligence Menlo Park, CA, USA, Volume 11 Issue 5, Jan. 1991, p. 68–70, 1991. Disponível em: <<https://pdfs.semanticscholar.org/a8cd/b6dd622e1f0d61abae345a3ddb9795c02f.pdf>>. Citado na página 28.

PROJECT OSRM. **OSRM-BACKEND. Definição do raio da terra utilizado pelo OSRM**. 2019. [Online; accessed 17/12/2019]. Disponível em: <https://github.com/Project-OSRM/osrm-backend/blob/088d4edc6b761d2642a9b1ab7d85b701d3165fb2/include/util/coordinate_calculation.hpp#L26-L28>. Citado na página 35.

_____. **OSRM Docker Quick Start. The easiest and quickest way to setup your own routing engine**. 2019. [Online; accessed 18/12/2019]. Disponível em: <<https://hub.docker.com/r/osrm/osrm-backend/>>. Citado na página 38.

_____. **OSRM Server engine. Distância dirigida entre São Paulo e Rio de Janeiro**. 2019. [Online; accessed 17/12/2019]. Disponível em: <<http://map.project-osrm.org/?z=8¢er=-23.014020%2C-45.126343&loc=-23.536211%2C-46.737751&loc=-22.826918%2C-43.336856&hl=en&alt=0>>. Citado na página 36.

REVELLE, C.; EISELT, H. Location analysis: A synthesis and survey. **European Journal of Operational Research**, North-Holland, v. 165, n. 1, p. 1–19, aug 2005. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0377221704002139>>. Citado na página 25.

SACHA, D.; STOFFEL, A.; STOFFEL, F.; KWON, B. C.; ELLIS, G.; KEIM, D. A. Knowledge generation model for visual analytics. **IEEE Transactions on Visualization and Computer Graphics**, v. 20, n. 12, p. 1604–1613, 12 2014. Acessado em: 30/12/2019. Citado na página 29.

SHIH, H. Facility Location Decisions Based on Driving Distances on Spherical Surface. **American Journal of Operations Research**, 2015. ISSN 2160-8830. Citado nas páginas 25, 26, 34 e 36.

SILVA, L. A.; PERES, S. M.; BOSCARIOLI, C. **Introdução a Mineração de Dados com aplicações em R**. 1 ed.. ed. [S.l.]: Elsevier Editora Ltda, 2016. 10-12 p. ISBN 978-85-352-8446-1. Citado na página 29.

SMITH, W. Product differentiation and marketing representation as alternative marketing strategies. **Journal of Marketing**, Springer-Verlag Berlin Heidelberg, v. 21, p. 3–8, 7 1956. Acessada em: 12/01/2020. Disponível em: <https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=2ahUKEwjB2tHik_7mAWhnKLkGHRtvBnYQFjAAegQIARAC&url=https%3A%2F%2Fedisciplinas.usp.br%2Fpluginfile.php%2F2134710%2Fmod_folder%2Fcontent%2F0%2FProduct%2520Differentiation%2520and%2520Market%2520Segmentation%2520as%2520Alternative%2520Marketing%2520Strategies%2520-%2520American%2520Marketing%2520Association.pdf%3Fforcedownload%3D1&usg=AOvVaw38OnQOKWtJohcUcWVvR9aD>. Citado nas páginas 36 e 37.

SZTUTMAN, P. **Análise da qualidade posicional das bases do Google Maps, Bing Maps e da Esri para referência espacial em projetos em SIG : aplicação para o município de São Paulo**. Dissertação (Mestrado) — Escola Politécnica, University of São Paulo, São Paulo, 2014. Master's Dissertation in Engenharia de Transportes. Citado na página 38.

THOMAS, J. J.; COOK, K. A. E. **Illuminating the Path: The Research and Development Agenda for Visual Analytics**. IEEE Computer Society Press, 2005. ISBN 0-7695-2323-4. Disponível em: <<https://www.hSDL.org/?view&did=485291>>. Citado na página 28.

TURKOGLU, D. C.; GENEVOIS, M. E. A comparative survey of service facility location problems. **Annals of Operations Research**, 2019. Disponível em: <<https://doi.org/10.1007/s10479-019-03385-x>>. Citado na página 25.

_____. A comparative survey of service facility location problems. **Annals of Operations Research**, 2019. Disponível em: <<https://doi.org/10.1007/s10479-019-03385-x>>. Citado na página 25.

VENESS, C. **Calculate distance, bearing and more between Latitude/Longitude points**. 2019. [Online; accessed 12/11/2019]. Disponível em: <<http://www.movable-type.co.uk/scripts/latlong.html>>. Citado na página 35.

WEDEL, M.; KAMAKURA, W. A. Clustering methods. In: _____. **Market Segmentation: Conceptual and Methodological Foundations**. Boston, MA: Springer US, 2000. p. 39–73. ISBN 978-1-4615-4651-1. Disponível em: <https://doi.org/10.1007/978-1-4615-4651-1_5>. Citado na página 37.

ZARINBAL, M. Distance functions in location problems. In: _____. **Facility Location: Concepts, Models, Algorithms and Case Studies**. Heidelberg: Physica-Verlag HD, 2009. p. 5–17. ISBN 978-3-7908-2151-2. Disponível em: <https://doi.org/10.1007/978-3-7908-2151-2_1>. Citado nas páginas 33 e 34.

ZHOU, L.; HANSEN, C. A survey of colormaps in visualization. **IEEE Transactions on Visualization and Computer Graphics**, v. 22, p. 2051–2069, 2016. Citado na página 28.

DEMANDA DOS 100 MAIORES MERCADOS

A Tabela 9 apresenta informações relacionadas as 100 maiores demandas mapeadas:

Tabela 9 – Municípios brasileiros com as 100 maiores demandas

Seq	Localização	AFCMes	CapEstNem3	Latitude	Longitude
1	Sao PauloSP	118.854.991	792.367	-23,5505199	-46,63331
2	Rio de JaneiroRJ	60.951.274	406.342	-22,9068467	-43,1729
3	Belo HorizonteMG	24.732.705	164.885	-19,9245018	-43,93524
4	FortalezaCE	23.680.342	157.869	-3,7318616	-38,52667
5	SalvadorBA	23.580.249	157.202	-12,9730401	-38,5023
6	BrasiliaDF	23.466.089	156.441	-15,7941569	-47,88253
7	Porto AlegreRS	22.255.355	148.369	-30,0346471	-51,21766
8	CuritibaPR	21.470.365	143.136	-25,4289541	-49,26714
9	ManausAM	20.010.614	133.404	-3,1190275	-60,02173
10	BelemPA	15.507.448	103.383	-1,4557794	-48,4902
11	GuarulhosSP	13.023.119	86.821	-23,4543148	-46,53365
12	RecifePE	11.893.974	79.293	-8,0475622	-34,87696
13	GoianiaGO	11.622.266	77.482	-16,6868824	-49,26479
14	CampinasSP	11.313.256	75.422	-22,9098833	-47,06258
15	Sao GoncaloRJ	9.633.855	64.226	-22,8272883	-43,06376
16	Campo GrandeMS	8.287.185	55.248	-20,4697105	-54,62012
17	NatalRN	8.286.790	55.245	-5,7792569	-35,20092
18	Duque de CaxiasRJ	8.217.600	54.784	-22,7862985	-43,30531
19	Sao Bernardo do CampoSP	8.021.377	53.476	-23,6898429	-46,56485
20	Nova IguaçuRJ	7.594.870	50.632	-22,7561319	-43,46074
21	Santo AndreSP	7.208.740	48.058	-23,6742228	-46,5436
22	OsascoSP	7.105.715	47.371	-23,5328871	-46,792

Tabela 9 – Municípios brasileiros com as 100 maiores demandas

Seq	Localização	AFCMes	CapEstNem3	Latitude	Longitude
23	JoinvilleSC	6.990.623	46.604	-26,3044084	-48,84638
24	Sao LuisMA	6.644.299	44.295	-2,5391099	-44,2829
25	Caxias do SulRS	6.622.928	44.153	-29,1634031	-51,17967
26	Sao Jose dos CamposSP	6.576.745	43.845	-23,223701	-45,90091
27	Ribeirao PretoSP	6.426.050	42.840	-21,170511	-47,81025
28	TeresinaPI	6.340.673	42.271	-5,0920108	-42,80376
29	ContagemMG	6.262.443	41.750	-19,9161508	-44,08088
30	Joao PessoaPB	6.219.395	41.463	-7,1194958	-34,84501
31	SorocabaSP	6.188.273	41.255	-23,5015338	-47,45259
32	UberlandiaMG	6.115.264	40.768	-18,9146078	-48,27538
33	LondrinaPR	6.048.297	40.322	-23,3044524	-51,16958
34	FlorianopolisSC	5.690.874	37.939	-27,5953778	-48,54805
35	MaceioAL	5.574.535	37.164	-9,6498487	-35,70895
36	AracajuSE	5.369.034	35.794	-10,9472468	-37,07308
37	Juiz de ForaMG	5.314.621	35.431	-21,7624237	-43,3434
38	AnanindeuaPA	5.285.077	35.234	-1,3642722	-48,37472
39	CanoasRS	5.113.620	34.091	-29,9132584	-51,18619
40	Jaboatao dos GuararapesPE	4.877.584	32.517	-8,1693806	-34,93706
41	PelotasRS	4.835.157	32.234	-31,7653989	-52,33759
42	Diamante do NortePR	4.731.685	31.545	-22,657229	-52,86114
43	NiteroiRJ	4.701.808	31.345	-22,8858975	-43,11522
44	CuiabaMT	4.643.758	30.958	-15,6014109	-56,09789
45	Porto VelhoRO	4.530.517	30.203	-8,7611605	-63,90043
46	Belford RoxoRJ	4.526.007	30.173	-22,7645391	-43,39963
47	Feira de SantanaBA	4.501.401	30.009	-12,2597272	-38,96466
48	SantosSP	4.466.367	29.776	-23,9561304	-46,32641
49	MauaSP	4.444.818	29.632	-23,668163	-46,46171
50	Sao Joao de MeritiRJ	4.423.217	29.488	-22,790968	-43,3698
51	MaringaPR	4.297.402	28.649	-23,4209995	-51,93306
52	BlumenauSC	4.139.092	27.594	-26,9165792	-49,07173
53	DiademaSP	4.114.705	27.431	-23,6818396	-46,62097
54	Sao Jose do Rio PretoSP	4.087.006	27.247	-20,811761	-49,37623
55	Campos dos GoytacazesRJ	4.037.978	26.920	-21,7626902	-41,31849
56	CarapicuiubaSP	3.938.805	26.259	-23,5239623	-46,84112
57	Santa MariaRS	3.921.699	26.145	-29,68725	-53,81545
58	BetimMG	3.908.362	26.056	-19,9673078	-44,20119

Tabela 9 – Municípios brasileiros com as 100 maiores demandas

Seq	Localização	AFCMes	CapEstNem3	Latitude	Longitude
59	GravataiRS	3.845.112	25.634	-29,942289	-50,99079
60	Mogi das CruzesSP	3.808.028	25.387	-23,5213379	-46,18587
61	PiracicabaSP	3.801.953	25.346	-22,7342864	-47,64806
62	JundiaíSP	3.774.894	25.166	-23,1857076	-46,89781
63	Ponta GrossaPR	3.734.632	24.898	-25,0993621	-50,15845
64	Novo HamburgoRS	3.707.744	24.718	-29,6918991	-51,12557
65	BauruSP	3.604.162	24.028	-22,314459	-49,0587
66	Montes ClarosMG	3.586.556	23.910	-16,7286406	-43,85821
67	ViamãoRS	3.552.122	23.681	-30,0722165	-51,09696
68	São VicenteSP	3.536.306	23.575	-23,960745	-46,39614
69	MacapáAP	3.535.455	23.570	0,0355735	-51,07053
70	ItaquaquecetubaSP	3.429.232	22.862	-23,4849456	-46,34948
71	Rio BrancoAC	3.416.041	22.774	-9,9753837	-67,82492
72	Vila VelhaES	3.371.570	22.477	-20,3477821	-40,29495
73	São LeopoldoRS	3.367.286	22.449	-29,7549941	-51,15028
74	FrancaSP	3.336.256	22.242	-20,5393794	-47,40135
75	SerraES	3.321.516	22.143	-20,1215224	-40,30779
76	CascavelPR	3.309.565	22.064	-24,9578832	-53,45954
77	Campina GrandePB	3.168.515	21.123	-7,2290752	-35,88083
78	Foz do IguaçuPR	3.112.412	20.749	-25,5163356	-54,58538
79	GuarujáSP	3.098.064	20.654	-23,9949104	-46,25688
80	AlvoradaRS	3.089.913	20.599	-29,991901	-51,08137
81	Ribeirão das NevesMG	3.063.047	20.420	-19,7618937	-44,08531
82	UberabaMG	3.013.304	20.089	-19,7473748	-47,93916
83	Rio GrandeRS	2.991.313	19.942	-32,2998858	-52,44655
84	AnápolisGO	2.945.763	19.638	-16,328546	-48,9534
85	São JoséSC	2.910.997	19.407	-27,6140791	-48,63709
86	TaubatéSP	2.905.985	19.373	-23,0204559	-45,55636
87	São José dos PinhaisPR	2.903.249	19.355	-25,5318354	-49,20357
88	OlindaPE	2.864.478	19.097	-7,9908056	-34,84163
89	LimeiraSP	2.853.892	19.026	-22,5836504	-47,40983
90	Passo FundoRS	2.844.312	18.962	-28,2587812	-52,416
91	CaucaiaCE	2.802.606	18.684	-3,6824047	-38,91323
92	Praia GrandeSP	2.792.782	18.619	-24,0088421	-46,41246
93	CariacicaES	2.759.224	18.395	-20,2642764	-40,42036
94	PetropolisRJ	2.712.584	18.084	-22,5112638	-43,17791

Tabela 9 – Municípios brasileiros com as 100 maiores demandas

Seq	Localização	AFCMes	CapEstNem3	Latitude	Longitude
95	SuzanoSP	2.698.880	17.993	-23,5453209	-46,31162
96	VitoriaES	2.678.795	17.859	-20,2976178	-40,29578
97	CriciumaSC	2.662.713	17.751	-28,6727702	-49,37338
98	Governador ValadaresMG	2.637.640	17.584	-18,8549317	-41,95592
99	Taboao da SerraSP	2.606.033	17.374	-23,6228759	-46,78166
100	BarueriSP	2.565.758	17.105	-23,5113691	-46,87294

Fonte: Elaborada pelo autor.