



**UFOP**

Universidade Federal  
de Ouro Preto

**Universidade Federal de Ouro Preto  
Instituto de Ciências Exatas e Aplicadas  
Departamento de Computação e Sistemas**

# **Internet das Coisas Sociais: uma abordagem quantitativa**

**Thiago Silva de Figueiredo**

## **TRABALHO DE CONCLUSÃO DE CURSO**

**ORIENTAÇÃO:**

**Helen de Cássia Sousa da Costa Lima**

**Outubro, 2024  
João Monlevade–MG**

**Thiago Silva de Figueiredo**

**Internet das Coisas Sociais: uma abordagem  
quantitativa**

Orientadora: Helen de Cássia Sousa da Costa Lima

Monografia apresentada ao curso de Engenharia de Computação do Instituto de Ciências Exatas e Aplicadas, da Universidade Federal de Ouro Preto, como requisito parcial para aprovação na Disciplina “Trabalho de Conclusão de Curso II”.

**Universidade Federal de Ouro Preto**

**João Monlevade**

**Outubro de 2024**

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

F475i Figueiredo, Thiago Silva De.  
Internet das Coisas Sociais [manuscrito]: uma abordagem  
quantitativa. / Thiago Silva De Figueiredo. - 2024.  
51 f.: il.: color., gráf., tab., mapa.

Orientadora: Profa. Dra. Helen de Cássia Lima.  
Monografia (Bacharelado). Universidade Federal de Ouro Preto.  
Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de  
Computação .

1. Computação. 2. Teoria dos grafos. 3. Redes sociais. 4. Internet das  
Coisas. I. Lima, Helen de Cássia. II. Universidade Federal de Ouro Preto.  
III. Título.

CDU 004

Bibliotecário(a) Responsável: Sônia Marcelino - CRB6/2247



## FOLHA DE APROVAÇÃO

**Thiago Silva de Figueiredo**

### **Internet das Coisas Sociais: uma abordagem quantitativa**

Monografia apresentada ao Curso de Engenharia de Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Engenharia de Computação.

Aprovada em 10 de outubro de 2024.

#### Membros da banca

Dra. Helen de Cássia Sousa da Costa Lima - Orientadora - Universidade Federal de Ouro Preto

Dr. Carlos Henrique Gomes Ferreira - Universidade Federal de Ouro Preto

Dr. Filipe Nunes Ribeiro - Universidade Federal de Ouro Preto

Helen de Cássia Sousa da Costa Lima, orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 22/10/2024.



Documento assinado eletronicamente por **Helen de Cassia Sousa da Costa Lima, PROFESSOR DE MAGISTERIO SUPERIOR**, em 22/10/2024, às 16:27, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0799368** e o código CRC **ABEDB19B**.

*Este trabalho é dedicado aos meus avós.*

# Agradecimentos

Agradeço aos meus avós, Maria José e Antônio (*in memoriam*), por terem me acolhido e permitido que eu me dedicasse aos estudos. Aos meus pais, Alberto e Maria, pelo suporte e amizade incondicionais. Agradeço também à minha orientadora, Helen, por sua orientação e apoio fundamentais durante todo o desenvolvimento deste trabalho. Por fim, agradeço a todos os meus colegas de curso pela colaboração e companheirismo ao longo desta jornada.

*Faz parte da natureza humana o desejo de conhecer, e é através da razão e da observação que ampliamos nosso entendimento do universo. Que a busca pelo conhecimento científico e tecnológico seja guiada pela virtude e pela sabedoria.*

# Resumo

Com o aumento dos dispositivos da *Internet of Things* (IoT), tornam-se necessárias soluções computacionais flexíveis e adequadas à mobilidade e ao contexto ‘social’ dos objetos, surgindo assim os paradigmas *Internet of Mobile Things* (IoMT) e *Social Internet of Things* (SIoT). Por isso, o objetivo deste projeto é melhorar o conhecimento que se tem sobre como objetos da IoT se movem e interagem entre si. O projeto seguirá um método exploratório a fim de mensurar a movimentação e interação dos objetos da IoT, utilizando métricas de grafos, redes sociais, mobilidade e clusterização em bases de dados reais e sintéticas. Essas análises são blocos de construção para criar aplicativos, fazer previsões, oferecer sugestões, apoiar decisões de usuário/dispositivo e melhorar algoritmos de roteamento. Os resultados destacam a importância de dispositivos públicos, que exercem uma influência central na rede, indicando seu papel crucial para o fluxo de informações. Em contraste, dispositivos estáticos têm um papel menos centralizado, sugerindo uma distribuição de conectividade mais equilibrada. Os dados aqui expostos são essenciais para identificar pontos de vulnerabilidade e otimizar o desempenho da rede. Dessa forma, o projeto visa contribuir para a adoção e implementação efetiva da IoT e para o desenvolvimento de aplicações e soluções otimizadas para o contexto IoT do futuro, móvel e conectado.

**Palavras-chaves:** IoT. IoMT. SIoT. Teoria dos Grafos. Redes Sociais.

# Abstract

With the increase in *Internet of Things* (IoT) devices, flexible computational solutions suitable for mobility have become necessary, leading to the emergence of *Internet of Mobile Things* (IoMT) and *Social Internet of Things* (SIoT) paradigms. Therefore, the goal of this project is to enhance understanding of how IoT objects move and interact with each other. The project will follow an exploratory approach to measure the movement and interaction of IoT objects, utilizing graph metrics, social networks, mobility, and clustering. The results highlight the importance of public devices, which exert a central influence on the network, indicating their crucial role in information flow. In contrast, static devices play a less centralized role, suggesting a more balanced distribution of connectivity. The data presented here are essential for identifying points of vulnerability and optimizing network performance. Thus, the project aims to contribute to the effective adoption and implementation of IoT and to the development of optimized applications and solutions for the future, mobile, and connected IoT context.

**Key-words:** IoT. IoMT. SIoT. Graph theory. Social Network.

# Lista de ilustrações

Figura 1 – Distribuição por mobilidade e propriedade . . . . .	22
Figura 2 – Contagem por dispositivo . . . . .	23
Figura 3 – Visualização de dispositivos na cidade de Santander. . . . .	25
Figura 4 – Visualização de encontro entre dispositivos. . . . .	26
Figura 5 – Média do número de contatos . . . . .	28
Figura 6 – Média do tempo de contato . . . . .	28
Figura 7 – Amostra do grafo de encontros. . . . .	29
Figura 8 – Comunidades extraídas pelo método de <i>Louvain</i> . . . . .	31
Figura 9 – Excentricidade média . . . . .	32
Figura 10 – Closeness Centrality médio . . . . .	33
Figura 11 – Grau médio . . . . .	34
Figura 12 – Betweenness centrality médio . . . . .	35
Figura 13 – Pagerank médio . . . . .	36
Figura 14 – Eigencentrality médio . . . . .	37
Figura 15 – Coeficiente de clusterização . . . . .	38
Figura 16 – Comparação entre comunidades . . . . .	39
Figura 17 – Contagem de elementos por comunidade . . . . .	41
Figura 18 – Posição geográfica das comunidades . . . . .	42
Figura 19 – Comparação por mobilidade . . . . .	44
Figura 20 – Impacto da mobilidade . . . . .	45

# Lista de tabelas

Tabela 1 – Dispositivos privados (Dados sintéticos) . . . . .	21
Tabela 2 – Dispositivos públicos (Dados reais) . . . . .	22
Tabela 3 – Percentual de posse de dispositivos privados conforme <i>Global Web Index</i> (GWI) em 2020 . . . . .	24
Tabela 4 – Exemplo de rastro de dispositivos móveis privados . . . . .	24
Tabela 5 – Exemplo do rastro com os dados tratados . . . . .	25
Tabela 6 – Exemplo de encontro entre dispositivos . . . . .	26
Tabela 7 – Comparação entre grafo original e backbone . . . . .	30
Tabela 8 – Correlação entre grafo original e o backbone extraído . . . . .	30
Tabela 9 – Matriz de correlação entre as métricas . . . . .	38
Tabela 10 – Distribuição percentual dos dispositivos por comunidade . . . . .	40

# Lista de abreviaturas e siglas

**IoT** *Internet of Things*

**IoMT** *Internet of Mobile Things*

**SIoT** *Social Internet of Things*

**SWIM** *Small World In Motion*

**GW** *Global Web Index*

**GiST** *Generalized Search Tree*

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	Problema	14
1.2	Objetivos	14
1.3	Metodologia	15
1.4	Organização do trabalho	15
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>16</b>
2.1	Métricas de grafo	16
2.2	Backbone	17
2.3	Extração de comunidades	18
2.4	Trabalhos relacionados	18
<b>3</b>	<b>DESENVOLVIMENTO</b>	<b>21</b>
3.1	Base de dados	21
3.2	Perfil dos dados de entrada	22
3.3	Preparação dos dados	23
3.4	Cruzamento dos dados	25
3.5	Grafo de interações	26
3.6	Encontros dos dispositivos	27
3.7	Estrutura principal do grafo	28
3.8	Extração de comunidades	30
<b>4</b>	<b>RESULTADOS</b>	<b>32</b>
4.1	Análise do grafo	32
4.2	Análise de comunidades	39
4.3	Análise da mobilidade	44
<b>5</b>	<b>CONCLUSÃO</b>	<b>47</b>
	<b>REFERÊNCIAS</b>	<b>49</b>

# 1 Introdução

Atualmente, a Internet das Coisas, do inglês *Internet of Things* (IoT), já se consolidou como uma tendência tecnológica com a presença crescente de objetos inteligentes em diversos ambientes. Segundo [Shahab et al. \(2022\)](#), estima-se que o número de dispositivos da IoT alcance aproximadamente 25,1 bilhões até 2025. Conforme [Sundmaeker et al. \(2010\)](#), a ideia básica da IoT é que praticamente qualquer objeto físico no mundo pode se tornar um computador conectado à internet. Para ser mais preciso, os objetos não se transformam em computadores, mas podem conter pequenos computadores. Quando isso acontece, esses objetos são frequentemente chamados de objetos inteligentes (ou “*smart things*”), pois podem agir de forma mais inteligente do que aqueles que não foram equipados com essa tecnologia.

O aumento de dispositivos *smart*, que processam informações e interagem com o ambiente, inclui também dispositivos móveis, o que torna a mobilidade um fator fundamental na IoT ([JÚNIOR et al., 2021](#)). Nesse contexto emergem dois paradigmas principais: a *Internet of Mobile Things* (IoMT), que lida com objetos móveis ([MESLIN; RODRIGUEZ; ENDLER, 2020](#); [SANTOS et al., 2021](#)), e a *Social Internet of Things* (SIoT), que enfoca as interações sociais entre objetos, fornecendo serviços uns aos outros ([ATZORI et al., 2012](#); [MARCHE et al., 2020](#)).

Com a evolução da IoT, a maioria das interações futuras será estabelecida entre dispositivos inteligentes, muitas vezes baseadas na proximidade física. Compreender o movimento e as interações entre esses objetos é essencial para promover avanços tanto na IoMT quanto na SIoT ([JÚNIOR et al., 2021](#)). Esse entendimento pode otimizar redes e sistemas, aprimorando algoritmos de roteamento e comunicação e contribuindo para uma melhor gestão de recursos e segurança. Além disso, analisar as dinâmicas sociais e de mobilidade dos objetos pode impulsionar inovações em áreas como cidades inteligentes e logística.

Nesse cenário, torna-se fundamental realizar uma análise mais ampla dos padrões de comportamento e interação entre dispositivos em grande escala. O padrão de mobilidade de uma comunidade, juntamente com outras informações que orientam a tomada de decisões, revela-se mais eficaz quando vinculado à análise do comportamento social ([CHANG, 2021](#)). Essas análises podem oferecer soluções mais precisas e eficientes para os desafios relacionados à mobilidade e interação social dos objetos IoT, contribuindo para a otimização das decisões estratégicas.

Portanto, este projeto visa expandir o escopo da pesquisa iniciada em trabalho de Iniciação Científica. Enquanto o estudo anterior se concentrou em dados sintéticos de

dispositivos privados da **IoT**, o presente projeto busca incrementar a pesquisa incluindo dados reais provenientes de objetos públicos em um ambiente de cidade inteligente. A relevância desta iniciativa reside na possibilidade de explorar a dinâmica da interação entre objetos públicos e privados, móveis e estáticos em um contexto urbano, fornecendo dados importantes para otimizar a adoção de soluções envolvendo **IoT**. Espera-se que os resultados desta pesquisa contribuam para o desenho de soluções mais eficientes para a arquitetura de redes e protocolos no âmbito da Internet das Coisas.

## 1.1 Problema

Ambientes modernos frequentemente possuem diversos dispositivos inteligentes trocando e produzindo dados, o que oferece uma oportunidade única para estudar padrões de interação e movimentação desses objetos. Pesquisas recentes têm investigado comportamentos, propriedades e características resultantes da análise de dados coletados desses ambientes (JÚNIOR et al., 2021; JÚNIOR et al., 2022; SANTOS et al., 2021). Essas análises são fundamentais para a otimização do tráfego de dados e desenvolvimento de protocolos mais eficientes e robustos para ambientes dinâmicos e heterogêneos. No entanto, uma das grandes limitações dessas análises é a escassez de dados de acesso público que abrangem tanto a mobilidade quanto as interações sociais de objetos inteligentes.

Sendo assim, este trabalho busca unir rastros reais e sintéticos para proporcionar uma análise mais completa da **SIoT**. Para isso, serão utilizados dados que incluem coordenadas e momentos de chegada e partida dos dispositivos. A base de dados reais será obtida a partir do projeto SmartSantander<sup>1</sup>, que engloba milhares de dispositivos distribuídos tanto em locais fixos quanto em veículos públicos. De forma complementar aos dados reais, algumas aproximações serão propostas utilizando dados sintéticos. Dessa forma, uma adaptação ao modelo de mobilidade *Small World In Motion* (**SWIM**) (MEI; STEFA, 2009) foi utilizado, pois esse modelo produz um padrão de mobilidade que se aproxima de rastros reais. Todos os dados estão disponíveis de forma *online*<sup>2</sup>, e possuem informações de mais de 15.000 dispositivos.

## 1.2 Objetivos

O objetivo deste projeto é utilizar uma base de dados mais ampla e diversa para dar continuidade a estudos preliminares e melhorar o conhecimento sobre como os objetos da **IoT** se movem e interagem entre si. Neste sentido, objetiva-se responder a seguinte pergunta: “Quais são os padrões de comportamento e mobilidade dos objetos da Internet das Coisas?”. De forma mais específica, almeja-se:

<sup>1</sup> <https://www.smartsantander.eu/> - Acesso em: 03 de julho de 2024

<sup>2</sup> <http://www.social-iot.org/> - Acesso em: 25 de fev. de 2024

- i Analisar registros de objetos inteligentes em bases mais completas, incluindo dados reais e sintéticos;
- ii Realizar medições utilizando métricas de grafos, redes sociais e mobilidade, para caracterizar o comportamento dos objetos.

### 1.3 Metodologia

Após o levantamento bibliográfico, que visa compreender o estado da arte da pesquisa, serão manipuladas duas fontes de dados distintas: a base de dados real obtida do projeto SmartSantander e uma base sintética gerada pelo modelo SWIM. O processo metodológico envolverá a coleta e integração desses dados, permitindo identificar padrões de mobilidade e gerar possíveis interações entre os dispositivos. A manipulação dos dados será crucial para a criação de cenários realistas que simulem as dinâmicas de interação entre os objetos da [IoT](#).

Na etapa seguinte, diversas métricas quantitativas serão aplicadas para analisar o comportamento dos dispositivos e as interações observadas. Utilizaremos conceitos de redes sociais, teoria dos grafos e análise de mobilidade, o que permitirá uma compreensão mais abrangente das relações formadas no ecossistema criado. Essa abordagem tem o potencial de contribuir para aprimorar a gestão de dispositivos e redes em ambientes conectados, além de possibilitar avanços no desenvolvimento de novas aplicações, algoritmos de roteamento e soluções otimizadas para a Internet das Coisas.

### 1.4 Organização do trabalho

O restante do trabalho está organizado da seguinte maneira: na Seção 1, definimos o problema central do estudo e descrevemos as abordagens metodológicas adotadas. Na Seção 2, são apresentados os trabalhos relacionados, fornecendo uma visão geral das pesquisas e desenvolvimentos anteriores que servem de base ou de inspiração para este projeto. As etapas de desenvolvimento do estudo, incluindo as ferramentas e processos utilizados, são abordadas de na Seção 3. Já na Seção 4, são discutidos os resultados obtidos, analisando as implicações e a relevância dos achados. Por fim, na Seção 5, são apresentadas as conclusões do trabalho, destacando as contribuições mais significativas.

## 2 Revisão bibliográfica

Este capítulo tem como objetivo fundamentar os conceitos abordados ao longo deste estudo, por meio de uma revisão da literatura existente sobre os temas em questão. Além disso, serão utilizadas pesquisas já realizadas que reforçam e complementam o assunto proposto neste trabalho.

### 2.1 Métricas de grafo

Os grafos são estruturas matemáticas que representam relações entre entidades, sendo amplamente utilizados em diversas áreas do conhecimento, como ciência da computação, redes sociais, biologia e transporte. A análise de grafos permite entender e modelar interações complexas, facilitando a visualização de padrões e a identificação de conexões relevantes. Para avaliar essas estruturas, diversas métricas tradicionais são aplicadas, ressaltando propriedades como conectividade, centralidade e distribuição de caminhos. Essas métricas ajudam a quantificar e classificar a importância de vértices e arestas, contribuindo para uma melhor compreensão do comportamento e da dinâmica dos sistemas representados.

Neste trabalho, pretendemos utilizar a combinação de grafos e suas métricas como ferramentas para analisar e compreender a dinâmica dos dados da rede **SIoT**. Para isso, adotaremos algumas métricas que serão fundamentais para a análise proposta, cujas definições podem ser encontradas na obra de [Wasserman \(1994\)](#). As métricas a serem consideradas são:

- ***Closeness Centrality***: Mede a proximidade de um vértice em relação a todos os outros vértices do grafo. Um vértice com alta centralidade de proximidade (*closeness centrality*) é capaz de alcançar outros vértices rapidamente, indicando sua influência na rede.
- ***Eccentricity***: Refere-se à distância máxima entre um vértice e os demais vértices do grafo. Um vértice com baixa excentricidade (*eccentricity*) é considerado central, pois está próximo de todos os outros.
- ***Betweenness Centrality***: Avalia a importância de um vértice com base na quantidade de caminhos mais curtos que passam por ele. Vértices com alta centralidade de intermediação (*betweenness centrality*) atuam como “ponte” entre diferentes partes da rede.

- **PageRank**: Originalmente desenvolvido para classificar páginas da web (PAGE, 1999), essa métrica avalia a importância de um vértice com base na quantidade e na qualidade dos links que apontam para ele, considerando a influência dos vértices conectados.
- **Degree**: Refere-se ao número de conexões (arestas) que um vértice possui. Um vértice com alto grau (*degree*) é considerado altamente conectado e pode ser importante para a dinâmica da rede.
- **Eigenvector Centrality**: Uma extensão da centralidade de grau (*degree*), leva em consideração não apenas o número de conexões, mas também a importância dos vértices aos quais um nó está conectado. Objetos conectados a outros vértices influentes têm uma centralidade maior.
- **Clustering**: Mede a tendência de os vértices de um grafo estarem agrupados em comunidades. Um alto coeficiente de agrupamento (*clustering*) indica que os vizinhos de um vértice estão fortemente conectados, refletindo a presença de estruturas locais na rede.

## 2.2 Backbone

As redes sociais podem ser modeladas como grafos, onde os nós representam indivíduos ou entidades e as arestas indicam as conexões ou interações entre eles. Contudo, quando há um grande número de conexões, estas tendem a mascarar as estruturas subjacentes e as comunidades que refletem os padrões de comportamento coletivo da rede. Essa sobrecarga de conexões irrelevantes prejudica a compreensão e a clareza do fenômeno estudado, exigindo o uso de algoritmos para eliminá-las, em um processo frequentemente denominado extração do *backbone* da rede. O objetivo desses algoritmos é identificar as conexões significativas para um fenômeno específico, resultando em uma versão simplificada, mas ainda representativa da rede.

De acordo com Ferreira et al. (2022), muitas conexões em uma rede podem não ser significativas, comprometendo a visualização de suas estruturas e comunidades essenciais. Em seu estudo, foram testados e validados diversos métodos de extração em dois casos com requisitos distintos. Para este trabalho, optamos pelo *Disparity Filter* (SERRANO; BOGUNÁ; VESPIGNANI, 2009), que determina que uma aresta entre um par de nós é relevante se seu peso se desvia de forma desproporcional em relação às outras arestas conectando os mesmos nós aos seus vizinhos. Assim, arestas relevantes são aquelas cujos pesos se afastam significativamente da suposição de que os pesos de todas as arestas incidentes em um nó são uniformemente distribuídos.

De modo geral, esse método se baseia em uma análise de disparidade, onde a importância de cada aresta é avaliada em função das suas características e das propriedades dos nós que conecta. Em essência, o *Disparity Filter* determina um limiar que diferencia arestas “fortes” (que conectam nós com alta conectividade ou relevância) de arestas “fracas” (que conectam nós menos relevantes). Ao aplicar esse filtro, são mantidas apenas as arestas que superam esse limiar, resultando em um grafo reduzido que preserva a estrutura essencial da rede original, facilitando a análise e interpretação dos padrões subjacentes.

## 2.3 Extração de comunidades

Em cenários do mundo real, os nós de uma rede tendem a se organizar em módulos fortemente conectados, conhecidos como comunidades ou *clusters*, onde os nós dentro de uma comunidade têm maior probabilidade de estarem relacionados entre si do que com o resto da rede. Sendo assim, a extração e análise de comunidades em grafos são técnicas essenciais para identificar esses conjuntos de estruturas subjacentes em redes complexas, como redes sociais (BEDI; SHARMA, 2016). Essas comunidades são grupos de nós altamente interconectados, cujos membros compartilham características ou comportamentos semelhantes. A identificação dessas subestruturas facilita a compreensão da dinâmica da rede, permitindo a compreensão sobre a propagação de informações (GU; WANG; YIN, 2019), a formação de grupos sociais (NOBRE; FERREIRA; ALMEIDA, 2020) ou a detecção de padrões anômalos (CHEN; HENDRIX; SAMATOVA, 2012). Além disso, técnicas de análise de comunidades podem auxiliar na otimização de sistemas, previsão de tendências e melhoria da eficiência em diversas outras áreas, tornando-se ferramentas indispensáveis para lidar com o crescente volume de dados interconectados.

Blondel et al. (2008) introduziram um método iterativo e heurístico para otimização da modularidade, chamado método de *Louvain*, que é amplamente utilizado devido à sua rapidez e capacidade de gerar comunidades de alta qualidade. Em seu algoritmo, na primeira iteração, cada nó é tratado como uma comunidade individual e, iterativamente, o algoritmo tenta mover os nós para comunidades vizinhas de forma a aumentar o ganho local de modularidade. Na segunda fase, as comunidades formadas são condensadas em supernós, criando um grafo reduzido. Esse processo é repetido até que não haja mais melhorias significativas na modularidade global. A simplicidade e rapidez do método, aliadas à sua capacidade de gerar comunidades de alta qualidade, o tornaram uma das técnicas mais populares para a detecção de comunidades em redes grandes e complexas.

## 2.4 Trabalhos relacionados

A Internet das Coisas tem sido assunto recorrente de pesquisas, principalmente em uma era em que os dados são tão valiosos. Não por acaso, a Internet das Coisas Sociais

(SIoT) também tem sido um tema amplamente pesquisado nas mais diversas áreas do conhecimento, incluindo a ciência de dados, redes sociais complexas e, claro, redes de computadores. Nesta seção, será apresentada uma breve discussão sobre trabalhos que abordam este tema, especialmente aqueles relacionados com o objetivo deste trabalho.

Asl et al. (2013), por exemplo, analisaram as interações entre os objetos da IoT para configurar um grafo de objetos que possa ser usado para algoritmos, protocolos e aplicações de SIoT. Para isso, a co-presença dos dispositivos foi utilizada para estabelecer interações sociais entre eles. Porém, poucas métricas de mobilidade foram exploradas. Além disso, a modelagem atribuiu um conjunto de objetos a cada pessoa com base no tipo de lugar em que ela está, em vez de um conjunto de dispositivos pessoais previamente estabelecidos.

Marche et al. (2020), por sua vez, analisaram um conjunto de dados baseado em objetos reais da IoT na cidade de Santander. Os dados foram disponibilizados para a comunidade para teste de diversas propostas em torno das comunicações objeto-a-objeto. Simulações mostraram como diferentes regras para a criação de relacionamentos afetam a navegabilidade geral da rede. No entanto, as métricas tradicionais de análise de mobilidade e relações sociais não foram aplicadas para entender o comportamento dos objetos inteligentes em um contexto social.

Outros autores exploram o uso de aprendizado de máquina para a predição e classificação de laços sociais em redes de dispositivos IoT (JÚNIOR et al., 2022). Eles se concentram na análise das interações entre dispositivos para identificar padrões e prever laços sociais. Apesar do uso conjunto de dados reais e sintéticos, assim como o proposto neste trabalho, o foco da pesquisa foi na utilização de aprendizado de máquina para classificar o tipo de conexão, porém, a interação dos objetos não foi analisada.

Em pesquisas recentes, um novo modelo de mobilidade para IoT foi proposto, já que, segundo os autores, há pouco foco na mobilidade dos objetos em si (ALVES; RETTORE; SANTOS, 2023). Os autores adaptaram modelos tradicionais, que imitam padrões de mobilidade humana, para reproduzir a mobilidade dos dispositivos IoT, diferenciando entre dispositivos com padrões de movimento semelhantes aos humanos e dispositivos predominantemente estacionários. Apesar de bons resultados obtidos para gerar rastros de mobilidade para os objetos da IoT, a interação entre eles foi pouco explorada.

Silva et al. (2022) propõem o *MobVis*, um framework desenvolvido para caracterizar e comparar rastros de mobilidade, usando diversas métricas de maneira simplificada. Além disso, o *MobVis* se mostrou capaz de extrair e visualizar aspectos espaciais, temporais e sociais dos dados de mobilidade tudo isso por meio de uma interface web. Para demonstrar o funcionamento do framework, foi realizado um estudo de caso que analisou as características de dois rastros distintos, táxis e objetos IoT. Porém, devido à capacidade de processamento do framework proposto, a quantidade de dados analisada não foi tão abrangente e a

interação dos objetos não foi ponto focal de análise.

Este trabalho tem como objetivo aplicar diferentes métricas para entender a rede **SIoT**, integrando com bases mais completas trabalho previamente publicado por [Júnior et al. \(2021\)](#). Para isso, serão utilizados dados sintéticos baseados em um modelo de mobilidade e dados reais de uma cidade inteligente, incluindo objetos fixos e móveis capazes de interagirem entre si. Diferentes indicadores quantitativos de mobilidade e de redes complexas serão aplicados para traduzir o comportamento dos dispositivos e a qualidade da rede de comunicação entre eles estabelecida.

## 3 Desenvolvimento

Após a realização do levantamento bibliográfico para identificar oportunidades de melhorias nas pesquisas existentes, um dos principais objetivos deste trabalho foi aprofundar a análise da **SIoT** com dados mais completos. Para isso, foi necessário buscar fontes de dados que se adequassem ao perfil desejado, ou seja, rastros de mobilidade de dispositivos da Internet das Coisas contendo tanto suas coordenadas geográficas quanto o tempo de permanência em cada uma delas. Com esses dados em mãos, a etapa final consistirá na sua manipulação e posterior análise.

### 3.1 Base de dados

Seguindo a abordagem adotada em pesquisas recentes (JÚNIOR et al., 2022), utilizaremos dados provenientes de bases de dados públicas, disponíveis de forma online, em nossas análises. Estas bases possuem tanto dados reais, do projeto *SmartSantander* (GUTIÉRREZ et al., 2013), quanto dados sintéticos gerados por meio do modelo de mobilidade *Small World In Motion* (SWIM) (MEI; STEFA, 2009). O número total de objetos compreendidos nesta base é de 16.216 dispositivos, dos quais 14.600 são de usuários privados e 1.616 são de serviços públicos.

Estes objetos podem ser de duas categorias possíveis: móveis ou estáticos. Os objetos móveis, como smartphone e o relógio inteligente, por exemplo, serão levados com o seu proprietário para todos os lugares. Os objetos estáticos, por sua vez, possuem uma coordenada inicial e lá permanecem durante todo o rastro. Além disto, é importante ressaltar que o rastro aqui analisado possui um tempo total de 10 dias, mais de três vezes superior em comparação com analisado na abordagem anterior (JÚNIOR et al., 2021). A Tabela 1 apresenta os dispositivos de usuários privados e sua característica de mobilidade, já na Tabela 2, os dados públicos são apresentados.

Dispositivo	Mobilidade	Descrição Simplificada
Carro	Móvel	Veículo particular
Sensores Domésticos	Estático	Sensores domésticos
Computador	Estático	Computador pessoal
Impressora	Estático	Impressora particular
Dispositivo <i>Fitness</i>	Móvel	Dispositivo de monitoramento de <i>fitness</i>
Smartphone	Móvel	Telefone celular pessoal
Relógio Inteligente	Móvel	Relógio inteligente pessoal
Tablet	Móvel	Tablet pessoal

Tabela 1 – Dispositivos privados (Dados sintéticos)

Dispositivo	Mobilidade	Descrição Simplificada
Dispositivos de Alerta	Estático	Dispositivos de alerta para emergências
Sensores Meteorológicos	Estático	Sensores de condições meteorológicas
Caminhão de Lixo	Móvel	Caminhões de coleta de lixo
Sensores Urbanos	Estático	Sensores urbanos para diversas condições
Parquímetro	Estático	Sistemas de estacionamento
Ponto de Interesse	Estático	Locais de interesse na cidade
Iluminação Pública	Estático	Iluminação pública
Táxis ou Ônibus	Móvel	Veículos de transporte público

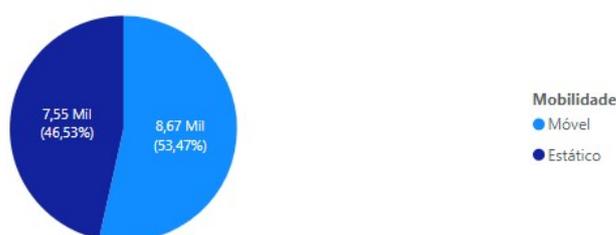
Tabela 2 – Dispositivos públicos (Dados reais)

## 3.2 Perfil dos dados de entrada

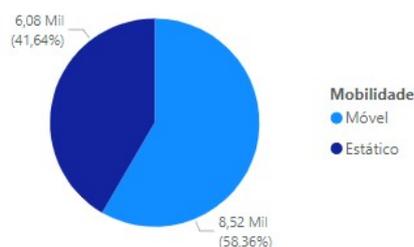
Para realizar as análises é importante conhecer o perfil dos dados de entrada na modelagem proposta. Conforme apresentado, o registro possui tanto objetos públicos quanto privados, sendo que 1.616 são dispositivos públicos e 14.600 são dispositivos privados. Apesar da quantidade de dados privados ser muito maior do que a de dados públicos, isso parece coerente com a realidade, uma vez que estes objetos podem ser adquiridos por diversos indivíduos, enquanto os objetos públicos dependem de investimentos governamentais e infraestruturais, que são mais limitados e burocráticos.

Figura 1 – Distribuição por mobilidade e propriedade

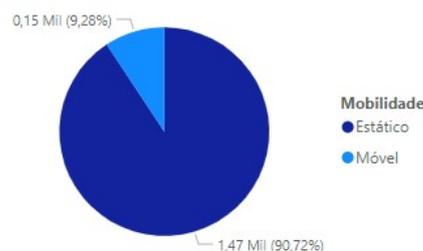
(a) Distribuição de acordo com mobilidade dos dispositivos



(b) Mobilidade dos dispositivos privados



(c) Mobilidade dos dispositivos públicos

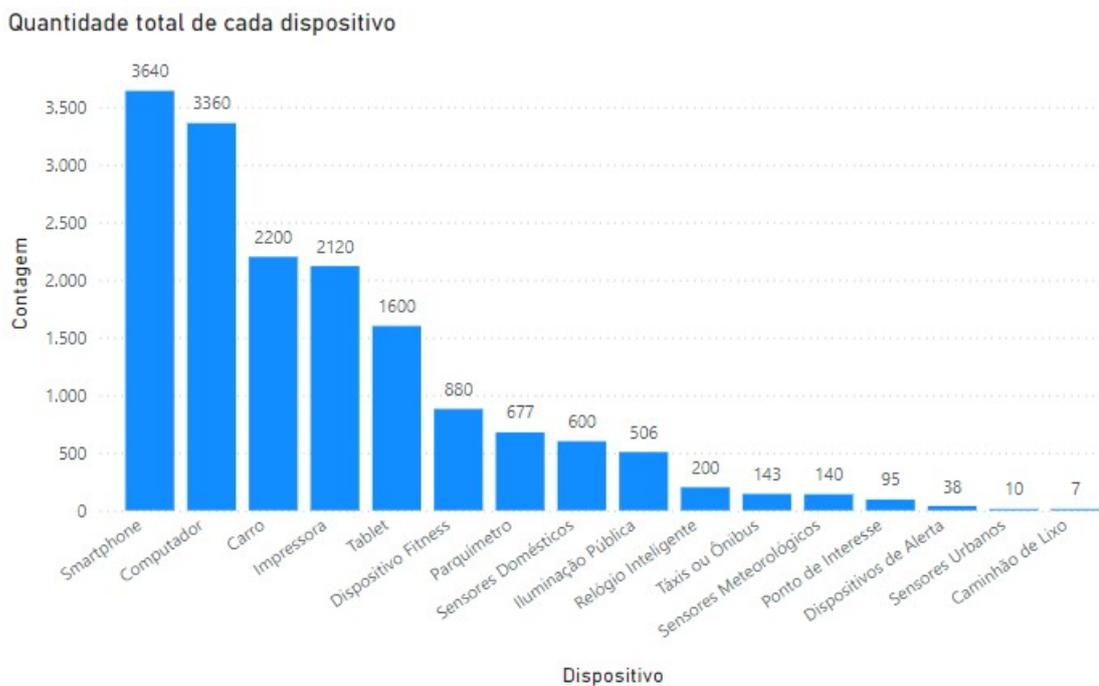


Um dado que chama a atenção na distribuição dos dispositivos é quanto à sua mobilidade. No geral, os dados estão bem divididos entre móveis e estáticos (vide Figura 1-a). Porém, ao analisarmos separadamente os objetos privados (Figura 1-b), observamos que a maior parte dos dispositivos possui mobilidade (58,6%). Os dados públicos, por

sua vez, são em maioria estáticos (Figura 1-c), o que novamente faz sentido uma vez que objetos públicos estáticos, como semáforos, postes e sensores, são mais comuns em cidades inteligentes porque suas funções estão ligadas a infraestruturas fixas, enquanto objetos públicos móveis, como ônibus ou e demais veículos, são mais limitados em número e focados em mobilidade e serviços específicos.

Outro ponto observado foi a quantidade existente para cada objeto dentro da base de dados analisada. Smartphone, computador e carro são os objetos em maior quantidade. Já caminhão de lixo, e sensores urbanos possuem uma quantidade bem reduzida. A distribuição completa pode ser vista na Figura 2. O número de objetos privados está em concordância com pesquisa realizada em 2020 pela *Global Web Index (GWI)*<sup>1</sup>, empresa de pesquisa de público, e que pode ser observado na Tabela 3.

Figura 2 – Contagem por dispositivo



### 3.3 Preparação dos dados

Diversas manipulações foram necessárias para adaptar o rastro disponível na base de dados ao problema levantado. Para isso, como o dado original dos dispositivos móveis e privados continha a posição cartesiana do proprietário do objeto, foi necessário, em um primeiro momento, transformar esta informação em dados dos objetos. Ou seja, se um usuário  $U$ , que possui um *smartphone* e um *tablet*, está na coordenada  $x = 10, y = 5$  no tempo  $Início = 60$  e sai no tempo  $Fim = 100$ , o rastro seria transformado conforme

<sup>1</sup> <https://www.gwi.com/> - Acesso em 05 de mar. de 2024

Dispositivo	Mobilidade	Percentual (%)
Smartphone	Móvel	91
Carro	Móvel	55
Tablet	Móvel	40
Dispositivo <i>Fitness</i>	Móvel	22
Relógio Inteligente	Móvel	5
Computador	Estático	84
Impressora	Estático	53
Sensores Domésticos	Estático	15

Tabela 3 – Percentual de posse de dispositivos privados conforme [GWI](#) em 2020

Tabela 4. Já no caso dos dados dos dispositivos estáticos, apenas o identificador do objeto e sua coordenada foram fornecidos. O tempo em que estes objetos permaneceram na coordenada compreende todo o período analisado, e nesse caso, o início para todo objeto estático é 0 segundos, e o fim cerca de 864.000 segundos (10 dias).

Usuário	Dispositivo	x	y	Início	Fim
U	Smartphone	10	5	60	100
U	Tablet	10	5	60	100

Tabela 4 – Exemplo de rastro de dispositivos móveis privados

Além disso, um dos objetivos deste trabalho é analisar a possibilidade de interação entre os objetos, para isso, é necessário definir um raio de comunicação para cada dispositivo. Dessa forma, adotamos o *Bluetooth* como protocolo de comunicação entre os objetos, pois o *Bluetooth* e o *ZigBee* estão entre os protocolos mais utilizados ([ELHADI et al., 2018](#)). Sendo assim, o raio de cada dispositivo foi definido de forma aleatória entre 15 e 30 metros ([AL-SARAWI et al., 2017](#)), pois barreiras podem interferir na qualidade do alcance. Esta também é uma alteração importante ao compararmos com o trabalho anterior ([JÚNIOR et al., 2021](#)), visto que o raio adotado nas primeiras análises foi de 100 metros para todos dispositivos da rede.

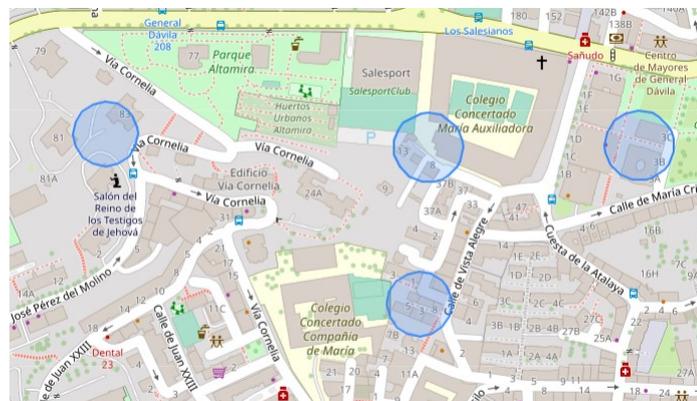
Uma outra etapa foi a transformação dos pontos em coordenadas geográficas para facilitar no cruzamento espacial dos dados. A transformação do ponto cartesiano  $(x, y)$  em coordenadas de latitude e longitude aproximadas na cidade de Santander, Espanha, foi crucial para a visualização dos dados geoespaciais, permitindo uma análise mais intuitiva e eficaz da distribuição e dinâmica dos dispositivos de interesse na área urbana. A utilização da extensão PostGIS do PostgreSQL desempenhou um papel fundamental nesse processo, pois ela proporciona funcionalidades avançadas para o armazenamento, consulta e manipulação de dados espaciais. Dessa forma, ao converter as coordenadas cartesianas para um sistema de coordenadas geográficas, foi possível integrar os dados em mapas interativos, facilitando a interpretação visual e o processamento de encontros. Um exemplo da base de dados tratada pode ser visto na Tabela 5. A visualização em um mapa

interativo pode ser observado na Figura 3, onde os círculos azuis são os dispositivos e o tamanho do círculo representa o raio de comunicação.

Usuário	Dispositivo	Lat	Lon	Início	Fim	Alcance (m)
2312	4744	43.458664	-3.805868	498430	499690	17
901	3051	43.475570	-3.816558	28980	29640	23
1100	6055	43.465052	-3.806129	481870	487110	20
2167	4067	43.482594	-3.820313	809270	809580	17
0	16188	43.465229	-3.828790	204092	204256	30

Tabela 5 – Exemplo do rastro com os dados tratados

Figura 3 – Visualização de dispositivos na cidade de Santander.



### 3.4 Cruzamento dos dados

De posse dos dados tratados, a etapa seguinte consistiu no cruzamento espacial e temporal dos dispositivos, isto é, encontrar objetos que estiveram no raio de comunicação um do outro no mesmo intervalo de tempo. O cruzamento de dados foi efetuado utilizando o PostGIS, uma extensão espacial do PostgreSQL. Especificamente, foi criada uma área em torno de cada coordenada pontual, representando um raio de comunicação entre 15 e 30 metros, simulando o alcance de um sinal *Bluetooth* (AL-SARAWI et al., 2017). Cada dispositivo possui raio previamente definido conforme pode ser visto na coluna *Alcance (m)* da Tabela 5.

A utilização do PostGIS ofereceu diversas vantagens nesse contexto, principalmente relacionado à capacidade de realizar interseções geométricas de maneira eficiente. A indexação espacial, por meio do índice *Generalized Search Tree (GiST)*, foi outro benefício significativo e crucial, pois permitiu a rápida consulta e recuperação dos dados, o que melhorou drasticamente o desempenho das operações de interseção.

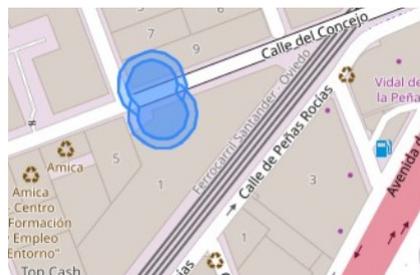
Dessa forma, após a criação dos indexes para otimizar a consulta, buscou-se encontrar todos os objetos que estiveram no raio de comunicação um do outro, no mesmo

intervalo de tempo. Além disso, uma das informações de interesse de cada encontro foi o tempo total em que ele ocorreu. Para isso, uma coluna de *Tempo de Sobreposição* foi criada. Exemplos de encontro podem ser observados na Tabela 6, e uma representação no mapa é exibida na Figura 4.

Dispositivo 1	Dispositivo 2	Início	Fim	Sobreposição
4318	16214	122044.22	122255.79	211.57
1152	15372	125580.00	125680.00	100.00
4318	16209	122384.26	122626.15	241.89
619	14989	120400.00	120720.00	320.00
619	14990	120400.00	120720.00	320.00

Tabela 6 – Exemplo de encontro entre dispositivos

Figura 4 – Visualização de encontro entre dispositivos.



Por fim, com todos os registros criado, a próxima etapa consistiu na construção de um grafo para representar as possíveis interações entre os objetos da rede *SIoT*. Nesse grafo, os nós correspondem aos dispositivos da rede, e as arestas são estabelecidas sempre que dois dispositivos se encontram pelo menos uma vez. Além disso, por se tratar de interações mútuas, o grafo é não direcionado, e o peso das arestas reflete a quantidade de contatos. A partir desse grafo, serão analisadas diversas métricas para extrair informações sobre o comportamento dos dispositivos.

### 3.5 Grafo de interações

O grafo de interações criados após o cruzamento dos dados resultou em 9.150.213 de encontros, dos quais:

- 5.048.569 encontros ocorreram somente entre dispositivos privados;
- 2.368.778 encontros ocorreram somente entre dispositivos públicos;
- 1.732.866 encontros ocorreram entre dispositivos públicos e privados.

A fim de otimizar as análises, dispositivos estáticos de um mesmo dono não tiveram o seu encontro incorporado nos registros. O mesmo foi feito para dispositivos móveis de um mesmo dono, pois, estes objetos passaram todo tempo em contato um com o outro, portanto não trariam informações tão relevantes. Porém, um outro diferencial deste projeto em relação à sua versão inicial, é que objetos estáticos e móveis de um mesmo usuário passaram a ser incorporados no registro de encontros, uma vez que esses encontros rotineiros podem trazer informações importantes para o contexto analisado.

De modo geral, o número de encontros destaca a alta conectividade dos dispositivos, com uma prevalência significativa de interações entre dispositivos privados. Isso pode ser explicado pelo maior número e diversidade de objetos privados em circulação, que têm mobilidade e presença constante no cotidiano das pessoas. Em contrapartida, os dispositivos públicos, embora menos numerosos e geralmente limitados a áreas específicas e funções relacionadas à infraestrutura urbana, realizaram um número razoável de encontros. Além disso, os dispositivos privados tendem a interagir mais entre si, enquanto os públicos permanecem em funções e locais mais delimitados, restringindo o número de interações cruzadas.

## 3.6 Encontros dos dispositivos

Outra característica importante de se analisar é a duração e a quantidade de encontros dos objetos da rede. Nas Figuras 5 e 6, é possível observar a média do tempo de contato e do número de encontros por dispositivo, nota-se que dispositivos com funções públicas e móveis, como o caminhão de lixo e demais veículos públicos (táxis ou ônibus), tendem a ter uma quantidade média de encontros muito maior, mas com tempos médio de contato bem menores. Isso indica que esses dispositivos interagem frequentemente com outros nós devido à sua mobilidade e presença em áreas públicas, mas essas interações são de curta duração.

Por outro lado, sensores meteorológicos e parquímetros, apresentam um número médio de encontros considerável e tempo médio de contato bem relevante. Isso sugere que esses dispositivos, por estarem localizados em áreas fixas, permanecem em contato por períodos mais prolongados, provavelmente devido à sua natureza estática.

Por sua vez, os dispositivos privados e móveis, como smartphone, dispositivos de *fitness*, tablet e carro estão mais equilibrados com relação ao tempo médio de contato e o número de encontros, o que sugere que eles desempenham um papel importante nas interações da rede, tanto em frequência quanto em duração. Isso pode indicar que, apesar de serem móveis e, portanto, menos previsíveis em termos de localização, eles estão frequentemente em áreas de alta conectividade e interagem consistentemente com outros dispositivos.

Figura 5 – Média do número de contatos

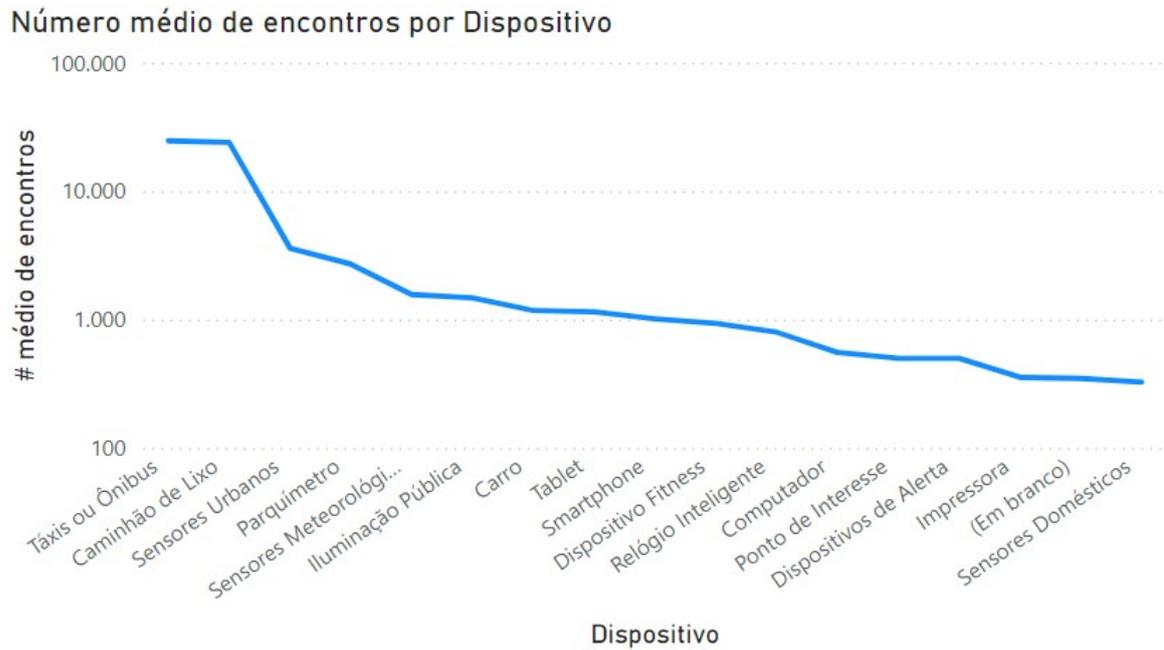
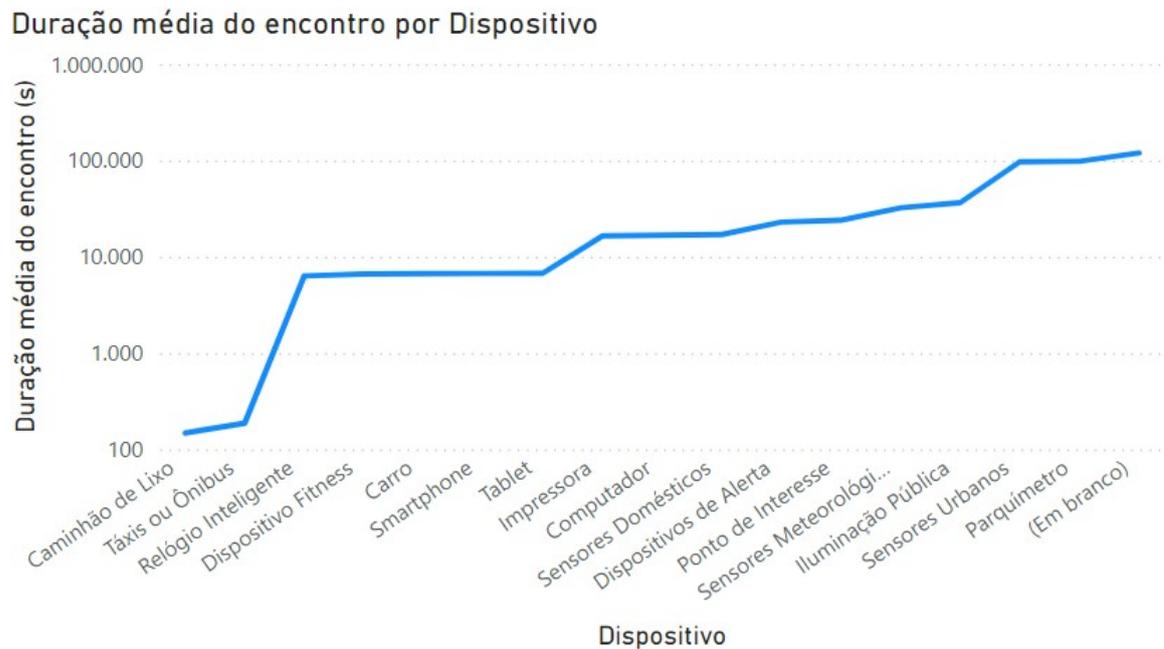


Figura 6 – Média do tempo de contato

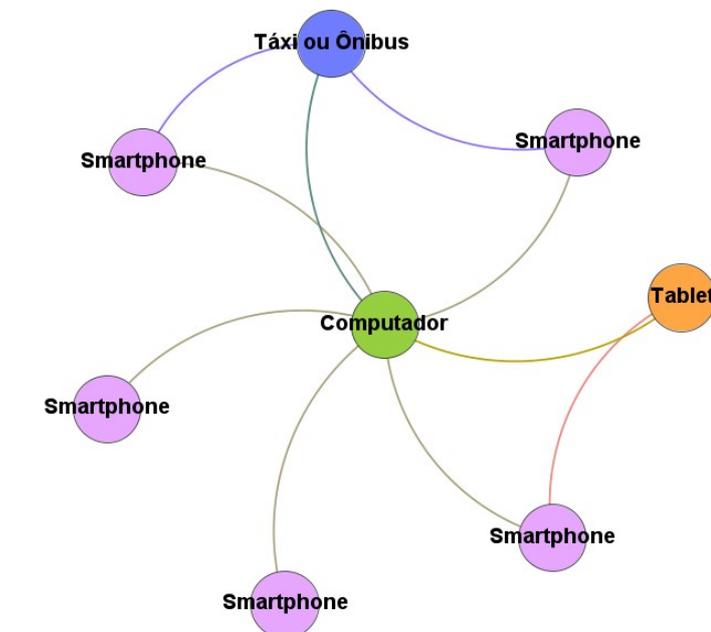


### 3.7 Estrutura principal do grafo

Dos mais de 9 milhões de encontros criados, 4.729.583 ocorreram de maneira exclusiva. Isto é, considerando cada objeto como um nó da rede, houveram cerca de 4.7 milhões de arestas indicando que esses nós se encontraram ao menos uma vez durante o

rastro analisado. Na Figura 7 uma amostra do grafo pode ser visualizada. Nesta imagem, um recorte da rede-ego formada por um computador é exibida, isto é, uma sub-rede com o computador como nó central (o “ego”) e todos os nós conectados diretamente a ele.

Figura 7 – Amostra do grafo de encontros.



Devido à grande quantidade de arestas e vértices, decidiu-se realizar a extração do *backbone* do grafo, ou seja, a remoção do subgrafo que contém apenas as conexões e vértices mais significativos. Para [Ferreira et al. \(2022\)](#), muitas ligações em uma rede podem não ser relevantes, o que compromete a visualização das estruturas e comunidades essenciais. Sendo assim, conforme destacado na Seção 2.2, escolhemos o *Disparity Filter* ([SERRANO; BOGUNÁ; VESPIGNANI, 2009](#)), que estabelece que uma aresta entre um par de vértices é considerada relevante se seu peso se desvia de maneira desproporcional em comparação com as demais arestas que conectam os mesmos vértices aos seus vizinhos.

O grafo original, que inclui todos os dispositivos e arestas, é composto por cinco componentes conectados, ou seja, cinco subconjuntos de vértices em que todos estão interligados, sem qualquer conexão com vértices fora desses subconjuntos. Dentre eles, o maior componente conectado contém 16.194 arestas, o que representa aproximadamente 99,86% dos dispositivos da rede. Em contraste, os outros quatro componentes são formados por um número insignificante de arestas (apenas 2 ou 3), sendo constituídos principalmente por sensores de clima e temperatura, que, devido à sua localização geograficamente isolada, não se conectaram à rede principal. Após a aplicação do algoritmo de *Disparity Filter*, utilizando um *score* de 0,9 como limiar para a extração do *backbone* da rede, o grafo resultante foi reduzido a um único componente conectado. Essa transformação ocorreu porque o subgrafo resultante abrange as conexões mais fortes e significativas da rede.

Métrica	Original	Backbone
# Vértices	16.216	15.899
# Arestas	4.729.583	149.865
# Comp. conectado	5	1

Tabela 7 – Comparação entre grafo original e backbone

Ao concentrar-se nessas conexões relevantes, o *backbone* preservou a maior parte da conectividade original, resultando em um único componente conexo que representa a estrutura principal da rede. Conforme pode ser visto na Tabela 7, o total de dispositivos mantidos após essa manipulação foi de 15.899 objetos distintos, o que equivale a 98,04% em relação à rede original e 98,17% em relação ao maior componente conectado. Apesar de manter a estrutura de vértices quase inalterada, o número de arestas caiu cerca de 97%. Ainda assim, a Tabela 8 demonstra que, para as métricas *degree*, *eigencentrality*, *pagerank* e *betweenness*, há uma correlação<sup>2</sup> positiva moderada a forte entre os dois grafos. Isso sugere que a estrutura de conectividade, a influência dos nós e os papéis intermediários são consistentes entre o grafo original e o extraído pelo algoritmo de remoção do *backbone*. Sendo assim, a análise será realizada em cima desse sub-grafo, já que ele possibilitará uma melhor análise das comunidades existentes.

Métrica	Coefficiente de Correlação
Degree	0.6028
Eigencentrality	0.6325
Pagerank	0.6086
Betweenness	0.6389

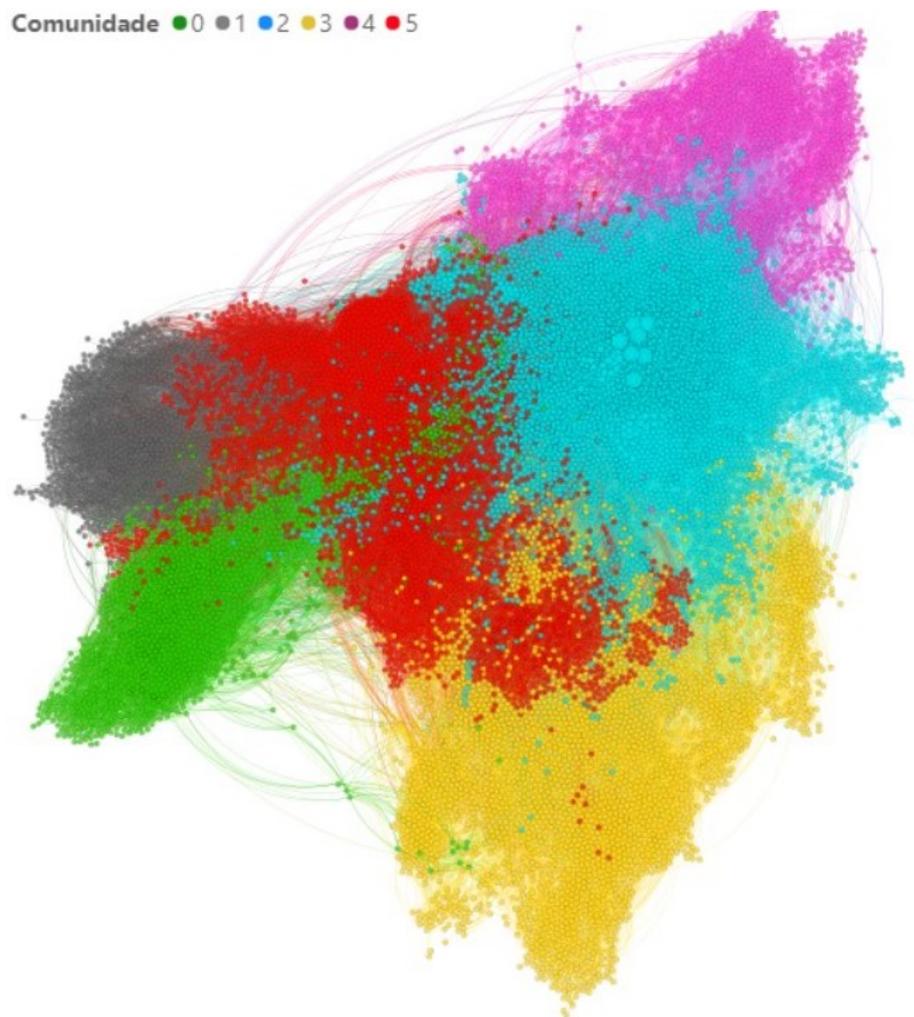
Tabela 8 – Correlação entre grafo original e o backbone extraído

### 3.8 Extração de comunidades

Para aprofundar a compreensão do comportamento social dos dispositivos da rede *SIoT* criada, realizou-se a extração de comunidades. Utilizando o software Gephi, aplicou-se o método de *Modularity Class*, implementado pelo algoritmo de *Louvain* (BLONDEL et al., 2008). Conforme introduzido na seção 2.3, esse método agrupa os dispositivos em comunidades, maximizando a modularidade da rede, ou seja, identificando subgrupos de dispositivos que apresentam conexões mais fortes entre si do que com o restante da rede. Essa abordagem será essencial para entender a estrutura organizacional da rede *IoT* e identificar padrões de comportamento dentro dos grupos criados. Ao todo, seis grupos distintos puderam ser identificados, conforme pode ser observado na Figura 8, que representa o grafo de conexões onde a cor dos vértices representa a sua comunidade. As características de cada uma delas será analisada na seção de resultados.

<sup>2</sup> Via PostgreSQL, a função *corr()* foi utilizada para calcular a correlação de *Pearson* entre colunas

Figura 8 – Comunidades extraídas pelo método de *Louvain*.



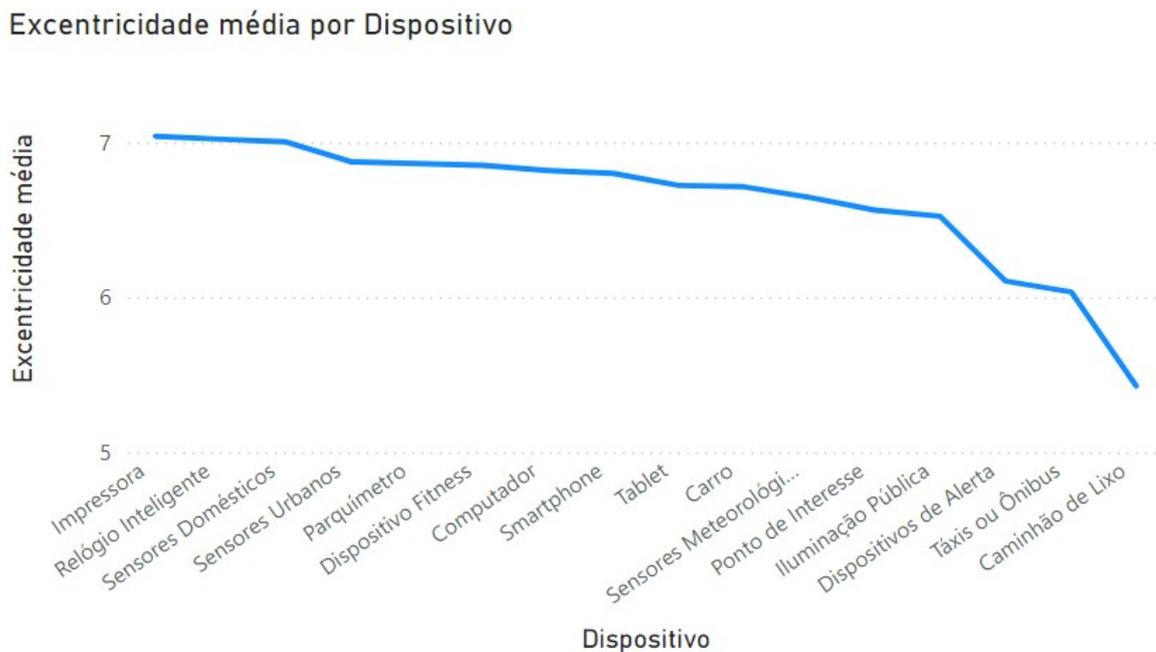
## 4 Resultados

Nesta seção, serão apresentados os resultados obtidos a partir das análises realizadas sobre o grafo construído. As métricas avaliadas buscam evidenciar o comportamento dos dispositivos da rede **SIoT**, considerando suas interações e o padrão de conectividade entre eles. A seguir, discutimos os principais achados e suas implicações para o estudo.

### 4.1 Análise do grafo

Conforme explicado anteriormente, as métricas e análises serão realizadas sobre o grafo resultante da extração do *backbone* da rede. O *backbone*, por concentrar as conexões mais significativas e remover as menos relevantes, preservou a estrutura essencial e a conectividade da rede original. Sendo assim, essa abordagem permitirá uma análise mais focada e clara dos padrões e características da rede, facilitando a compreensão de sua estrutura fundamental. Com base nesse grafo refinado, diversas métricas foram avaliadas para melhor compreender a dinâmica da rede, e os resultados são apresentados na sequência:

Figura 9 – Excentricidade média

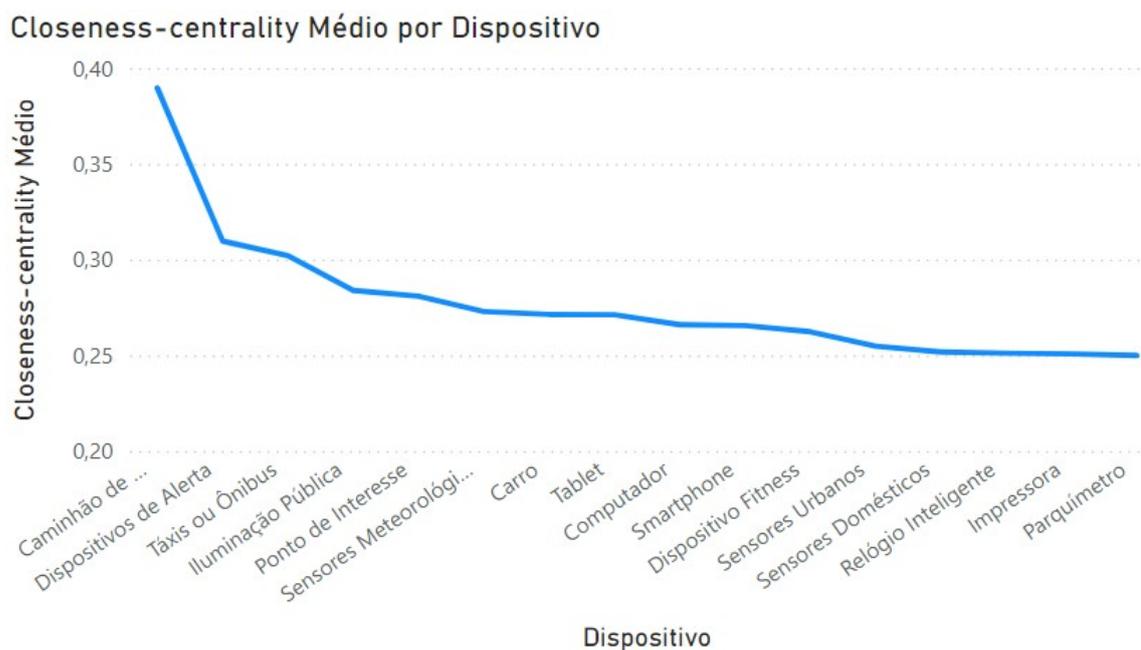


- **Eccentricity:** A análise da excentricidade média, que indica a distância máxima de um nó a todos os outros nós na rede, sugere que a maioria dos dispositivos está relativamente próxima do centro da rede, com excentricidade média variando entre

aproximadamente 5, 4 e 7, 0. Pela Figura 9, nota-se que dispositivos como o caminhão de lixo e demais veículos públicos (táxis ou ônibus) apresentam excentricidade média mais baixa, indicando que estão mais centralizados e têm melhor conectividade com outros dispositivos da rede. Esse dado está em concordância com o observado na Figura 5, já que estes dispositivos se destacam pelo número médio de encontros realizados.

Em contrapartida, dispositivos como impressoras e relógios inteligentes possuem excentricidade média mais alta, sugerindo que eles estão mais distantes, ou seja, precisam realizar mais saltos na rede para alcançar os outros nós. Mas, no geral, a baixa variação nas excentricidades sugere que a rede é relativamente bem conectada, com a maioria dos dispositivos estando a uma distância moderada uns dos outros, o que pode indicar uma estrutura de rede eficiente e coesa.

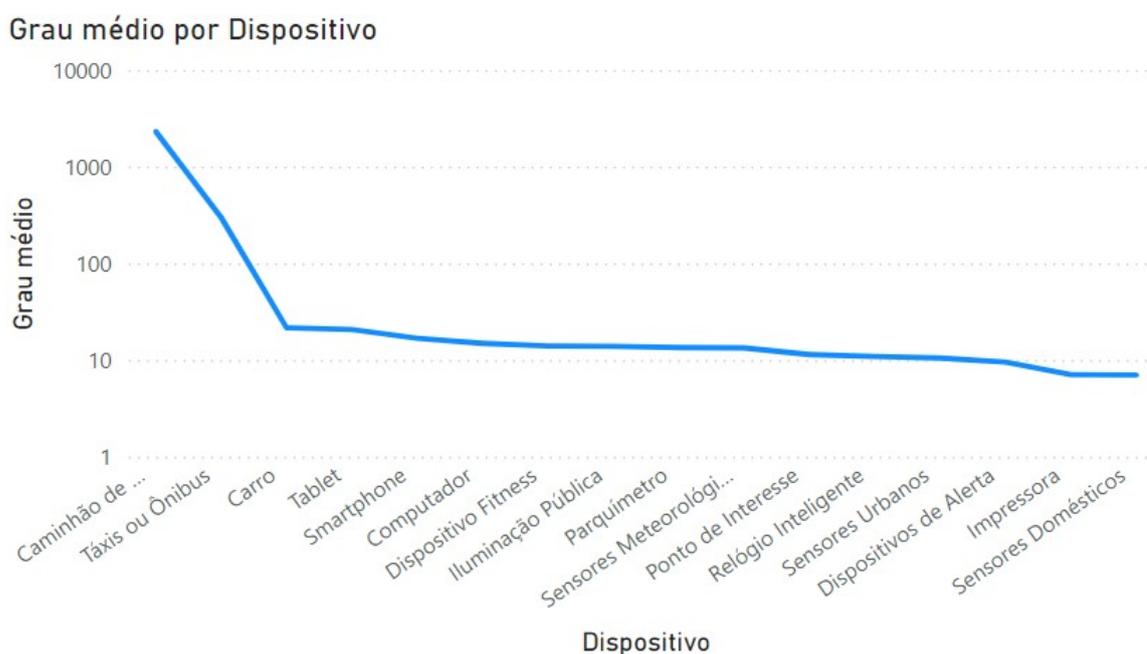
Figura 10 – Closeness Centrality médio



- **Closeness Centrality:** A análise da centralidade de proximidade (*closeness centrality*), medida que indica o quão perto um nó está dos demais nós da rede, revela que dispositivos com maior centralidade, como caminhão de lixo e dispositivos de alerta, estão em posições mais centrais (vide Figura 10). Por isso, pode-se dizer que esses objetos apresentam uma alta capacidade de alcançar rapidamente outros vértices, o que aponta para um papel crucial na conectividade geral e na eficiência das comunicações na rede. Dispositivos com alta centralidade de proximidade tendem a ter menos saltos necessários para atingir outros dispositivos.

Em análise conjunta com a excentricidade, podemos observar uma correlação inversa (vide Tabela 9). Dispositivos com excentricidade mais baixa, também têm uma centralidade de proximidade mais alta, indicando que estão mais próximos do centro da rede e têm uma maior eficiência na comunicação. Por outro lado, dispositivos com excentricidade mais alta, mostram uma centralidade de proximidade menor, refletindo que estão mais distantes e, portanto, podem ser associados a um alcance menos eficiente.

Figura 11 – Grau médio

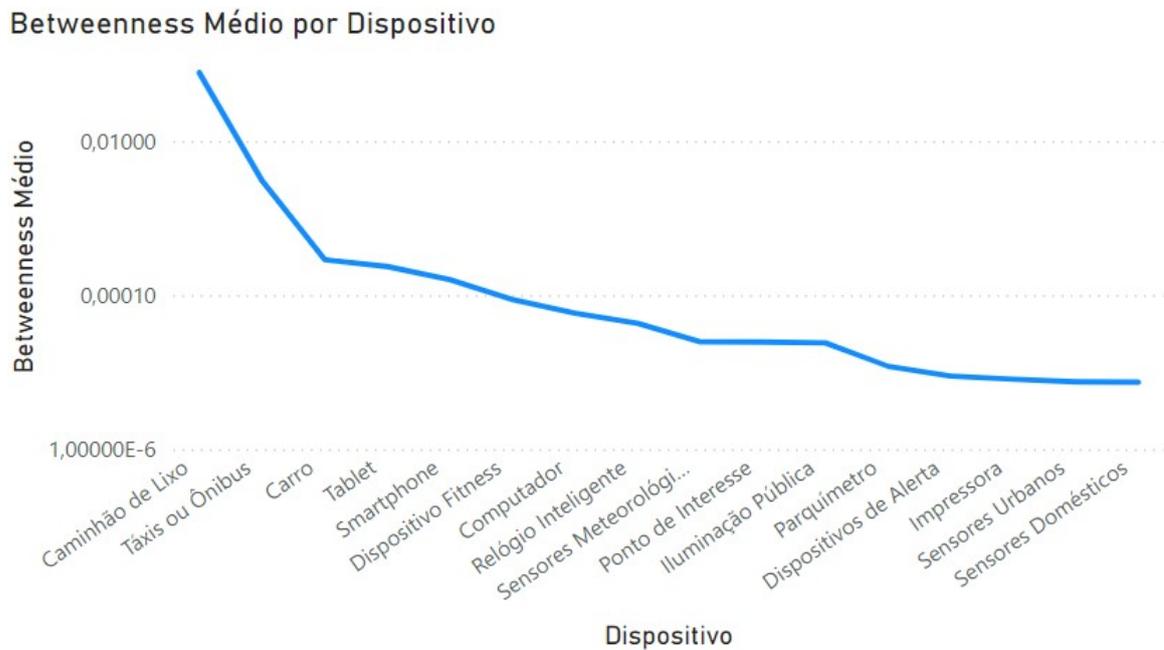


- **Degree:** A análise do grau médio dos dispositivos revela variações significativas na conectividade dentro da rede. O grau de um nó é o número de conexões diretas que ele possui com outros nós, refletindo sua conectividade imediata. Na Figura 11, observa-se que dispositivos públicos móveis apresentam um grau médio extremamente alto. Isso sugere que esses dispositivos estão altamente conectados com muitos outros nós, desempenhando papéis centrais com possibilidade de atuação como *hubs* importantes na estrutura da rede IoT. A alta conectividade desses dispositivos indica que eles são cruciais para a uma boa comunicação e para o fluxo de dados na rede, servindo como pontos principais de interseção entre diferentes grupos.

Por outro lado, dispositivos privados e estáticos (sensores domésticos e impressoras) têm graus médios significativamente mais baixos. Esses valores indicam que esses dispositivos estão menos conectados e interagem com um número menor de outros dispositivos na rede. Isso pode sugerir que, por desempenharem papéis mais especí-

ficos, locais e menos centrais, eles possuem menor influência na estrutura geral da rede.

Figura 12 – Betweenness centrality médio

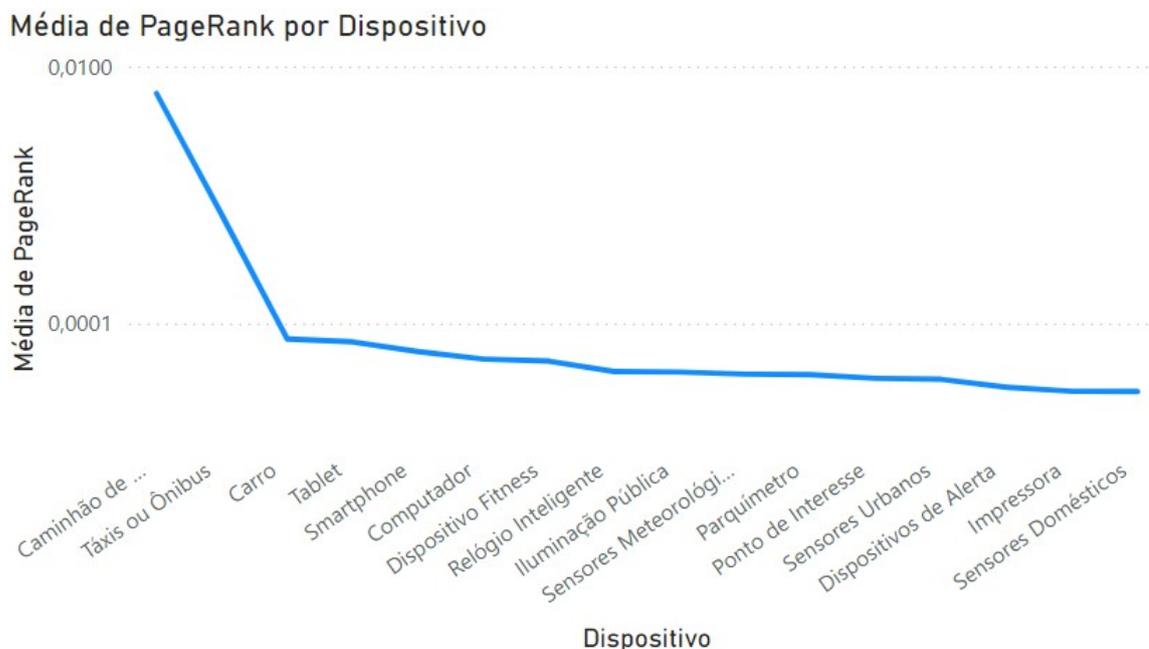


- **Betweenness Centrality:** Pela Figura 12, a análise da centralidade de intermediação (*betweenness*), que mede o quanto um nó atua como intermediário nos menores caminhos entre outros nós, revela novamente que o caminhão de lixo se destaca significativamente com a maior centralidade de intermediação média. Esse valor reforça como este dispositivo desempenha grande importância na mediação da comunicação, facilitando a passagem de informações entre muitos outros nós, sendo dessa forma, um ponto estratégico para a transmissão de dados dentro da rede IoT de uma cidade inteligente. Mas, assim como os demais veículos públicos, esse alto valor está fortemente atrelado ao grau e ao número médio de encontros realizados por esses dispositivos, conforme pode ser observado na matriz de correlações exibida na Tabela 9.

Ainda na Figura 12, observa-se que os valores de centralidade de intermediação variam menos se ignorarmos o caminhão de lixo e os demais veículos públicos. Dispositivos privados como os carros, tablets e smartphones apresentaram os maiores valores de centralidade de intermediação, demonstrando que eles também desempenham papéis importantes na mediação de comunicações na rede. Assim como os veículos públicos, esses dispositivos podem atuar como rotas intermediárias para a troca de dados entre outros nós. Por outro lado, dispositivos estáticos e privados apresentam valores mais baixos. Em concordância com a métrica de grau (*Degree*), isso indica que sua

função na rede é mais localizada, com pouca influência sobre o fluxo de comunicação entre dispositivos.

Figura 13 – Pagerank médio

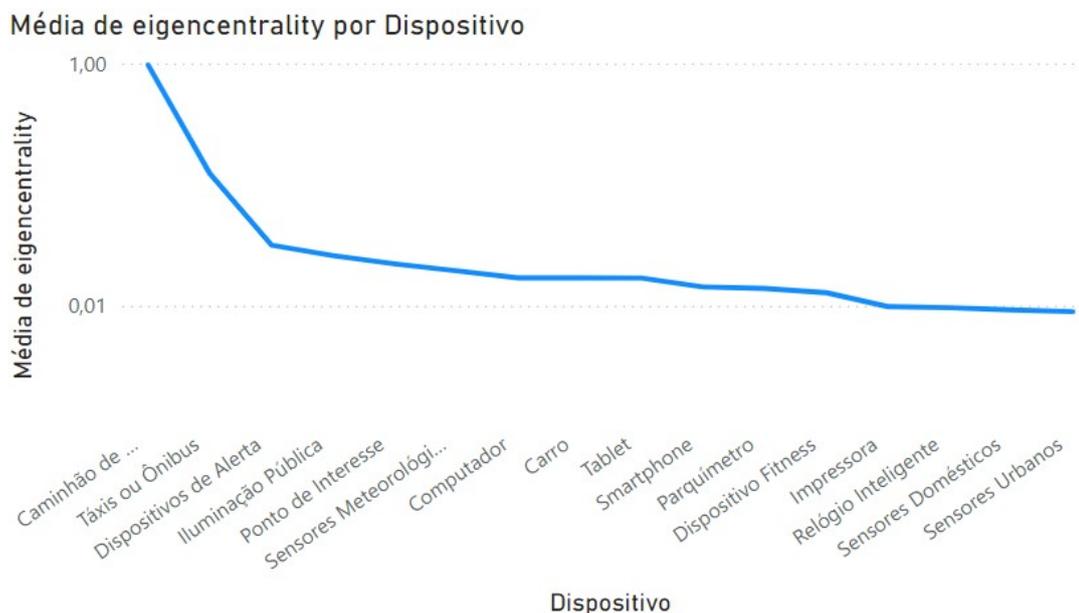


- **PageRank:** O *pagerank*, métrica que atribui uma pontuação a cada nó com base na quantidade e na qualidade das conexões que ele possui, destaca novamente os veículos públicos, denotando que ele é amplamente conectado a outros nós importantes na rede. Na Figura 13, notamos que o valor elevado destes objetos é muito superior aos demais, posicionando-os como nós fundamentais na infraestrutura geral. Por outro lado, dispositivos privados móveis apresentam valores menores, o que indica que, embora conectados, não possuem o mesmo nível de importância ou influência na rede se comparados diretamente aos objetos públicos móveis.

Os dispositivos com menores valores de *pagerank*, como sensores domésticos e impressoras, reforçam a ideia de que a rede é distribuída, com alguns poucos nós centrais e muitos outros com papéis de menor impacto em termos de propagação de informação. Porém, analisando os dispositivos isolando os públicos móveis, é notável a liderança de carros privados, smartphones e tablets. Ou seja, sua importância na rede pode indicar um papel semelhante na propagação de dados, com menor dependência de nós altamente influentes.

- **Eigenvector Centrality:** De maneira similar ao observado pelo *PageRank*, ao analisar o *eigenvector centrality* pela Figura 14, os veículos públicos se destacam indicando uma extrema importância na rede devido a suas conexões com nós altamente centrais. Esta métrica avalia a importância de um nó com base na influência

Figura 14 – Eigencentrality médio

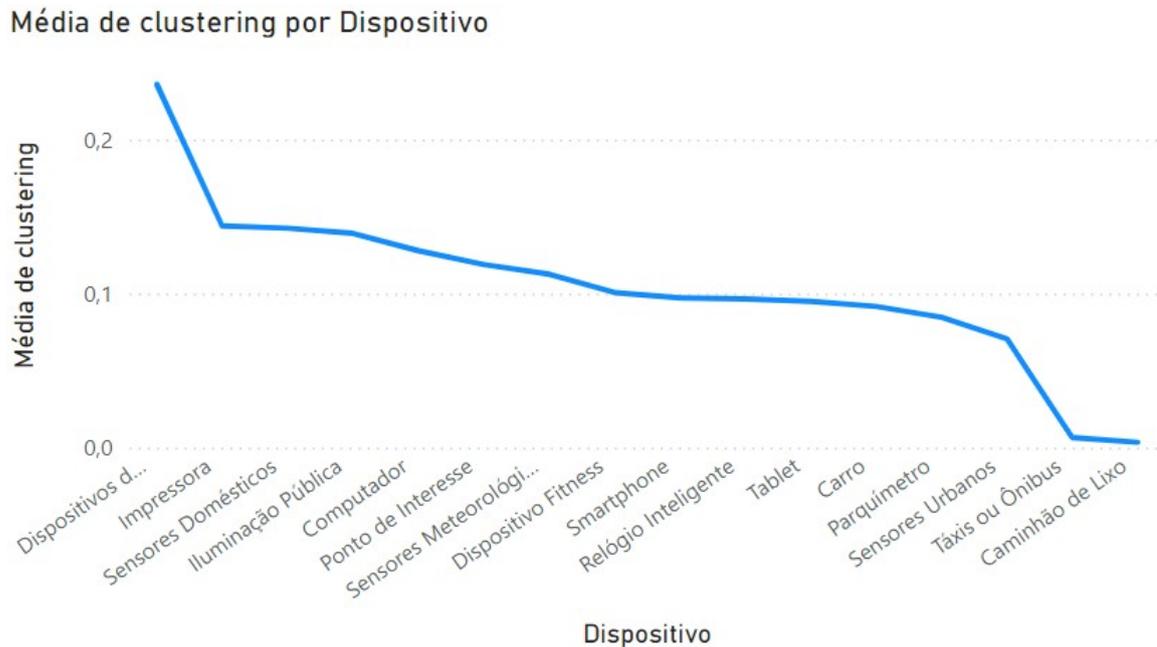


de seus vizinhos, considerando que conexões com nós altamente centrais conferem maior relevância ao nó em questão. Em contrapartida, dispositivos como dispositivos de alerta, iluminação pública e pontos de interesse apresentam valor moderado, apontando-os para papéis secundários, mas ainda importantes. Entre os dispositivos restantes, pode-se dizer que a métrica se mostrou mais equilibrada. Isso sugere que a maioria dos dispositivos tem um papel semelhante na rede.

- **Clustering:** A análise do coeficiente de clusterização revela que, apesar de alguns dispositivos serem críticos para a funcionalidade da rede, eles apresentam valores baixos de clusterização. Os dispositivos públicos e móveis, que têm papéis significativos na rede devido à sua alta centralidade e outros atributos, mostram um coeficiente de clusterização muito baixo. Isso indica que, embora esses dispositivos estejam estrategicamente posicionados e possuam conexões extensas, seus vizinhos imediatos não formam uma rede densa e interconectada. Esse fenômeno reforça que esses dispositivos atuam como pontos de conexão entre diferentes partes da rede, em vez de participar de grupos locais altamente coesos.

Por outro lado, dispositivos estáticos exibem coeficientes de clusterização relativamente mais altos, o que indica que esses dispositivos tendem a ter vizinhos que estão bem conectados entre si. Isso pode refletir uma estrutura mais compacta e localmente coesa, onde a interconexão entre vizinhos é mais pronunciada. A discrepância observada na Figura 15 entre dispositivos importantes com baixa clusterização e aqueles com alta clusterização pode ser explicada pela função e papel distintos desses dispositivos na rede. Se por um lado os dispositivos com alta centralidade e baixa

Figura 15 – Coeficiente de clusterização



clusterização podem estar mais envolvidos na mediação de conexões, os dispositivos com maior clusterização contribuem para a formação de comunidades locais.

Conforme pontuado na análise de algumas métricas, pode-se observar uma certa correlação entre elas. Na Tabela 9, observou-se uma forte correlação positiva entre o *Degree* e métricas como *Betweenness* (0,92) e *Pageranks* (0,99), sugerindo que os dispositivos mais conectados também tendem a ocupar posições centrais e de alta importância na propagação de informações. A métrica *Eigencentrality* também apresenta correlações positivas moderadas com *Degree* (0,81) e *Betweenness* (0,73), indicando a relevância dos nós mais conectados em clusters influentes. Já a centralidade *Closeness* possui uma correlação negativa forte com a *Eccentricity* (-0,88), refletindo que nós mais próximos de todos os outros tendem a ter uma excentricidade menor, ou seja, estão mais centralizados na rede.

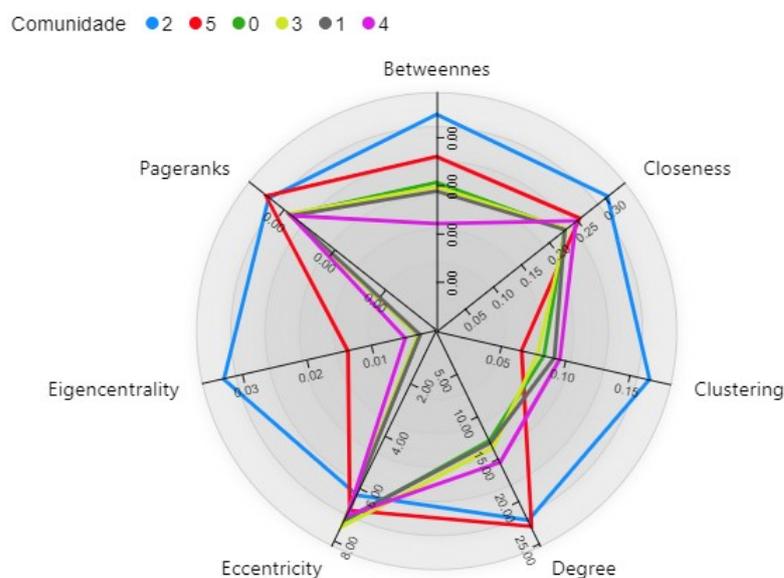
Métrica	Closeness	Betweenness	Eccentricity	Clustering	Eigencentrality	Pageranks	Degree
Closeness	1,00	0,10	-0,88	0,29	0,61	0,12	0,16
Betweenness	0,10	1,00	-0,08	-0,05	0,73	0,94	0,92
Eccentricity	-0,88	-0,08	1,00	-0,23	-0,51	-0,11	-0,15
Clustering	0,29	-0,05	-0,23	1,00	0,16	-0,07	-0,06
Eigencentrality	0,61	0,73	-0,51	0,16	1,00	0,77	0,81
Pageranks	0,12	0,94	-0,11	-0,07	0,77	1,00	0,99
Degree	0,16	0,92	-0,15	-0,06	0,81	0,99	1,00

Tabela 9 – Matriz de correlação entre as métricas

## 4.2 Análise de comunidades

Após aplicação do método *Modularity Class*, implementado pelo algoritmo de Louvain, seis comunidades distintas foram identificadas e numeradas de 0 a 5. Cada comunidade foi interpretada com base no valor médio das métricas já apresentadas neste trabalho. O estudo das comunidades da rede revela diferentes padrões de comportamento entre os grupos de dispositivos, conforme pode ser observado no gráfico radar da Figura 16.

Figura 16 – Comparação entre comunidades



A Comunidade 2, por exemplo, apresenta o maior valor para centralidade de proximidade (*closeness*) e um coeficiente de clusterização (*clustering*) elevado, sugerindo que os dispositivos desse grupo têm boas conexões locais e trocam informações de forma eficiente dentro de sua vizinhança. Além disso, o grau médio (*degree*) elevado indica um alto número de conexões por dispositivo, o que corrobora com sua baixa excentricidade, ou seja, os nós dessa comunidade têm uma distância média curta entre os demais nós da rede.

Já a Comunidade 5, apresenta coeficiente de clusterização (*clustering*) e *eigencentrality* mais baixos, o que pode indicar que esta comunidade é relativamente isolada e pouco integrada, tanto em termos de influência global na rede quanto na coesão interna. As comunidades 0, 1 e 3, por sua vez, seguem um padrão semelhante, com métricas moderadas de centralidade e clusterização, o que sugere que, embora estejam mais dispersas, ainda apresentam organização interna e forte conexão local. Em contrapartida, a comunidade 4 tem maior coeficiente de clusterização e grau relativamente alto quando comparado às comunidades 0, 1 e 3, o que indica uma coesão interna um pouco mais forte em relação à seus similares, porém a centralidade de intermediação (*betweenness*) é a menor dentre todas as outras, o que indica que os dispositivos dessa comunidade fazem pouco papel de

ponte entre os demais nós.

Classe	Dispositivo	Porcentagem por comunidade					
		0	1	2	3	4	5
Privados Móveis	Smartphone	24,8	24,8	22,5	23,5	24,0	19,1
	Carro	16,2	15,2	13,6	14,5	14,0	11,4
	Tablet	10,4	9,8	10,1	10,8	10,7	8,6
	Dispositivo <i>Fitness</i>	4,9	6,9	5,3	5,6	6,8	4,6
	Relógio Inteligente	1,1	1,3	1,2	1,5	1,2	1,0
Privados Estáticos	Computador	24,5	24,4	20,5	24,6	23,4	15,4
	Impressora	13,8	14,4	12,9	14,9	15,3	9,4
	Sensores Domésticos	4,2	3,0	3,5	4,2	4,2	2,9
Públicos Estáticos	Parquímetro	0,0	0,0	2,2	0,0	0,0	15,8
	Iluminação Pública	0,1	0,0	4,5	0,0	0,0	6,7
	Sensores Meteorológicos	0,1	0,0	1,1	0,1	0,0	1,2
	Ponto de Interesse	0,0	0,0	0,8	0,1	0,1	1,0
	Sensores Urbanos	0,0	0,0	0,1	0,0	0,0	0,2
	Dispositivos de Alerta	0,0	0,0	0,6	0,0	0,0	0,0
Públicos Móveis	Táxis ou Ônibus	0,0	0,0	0,9	0,0	0,0	2,6
	Caminhão de Lixo	0,0	0,0	0,1	0,0	0,0	0,0

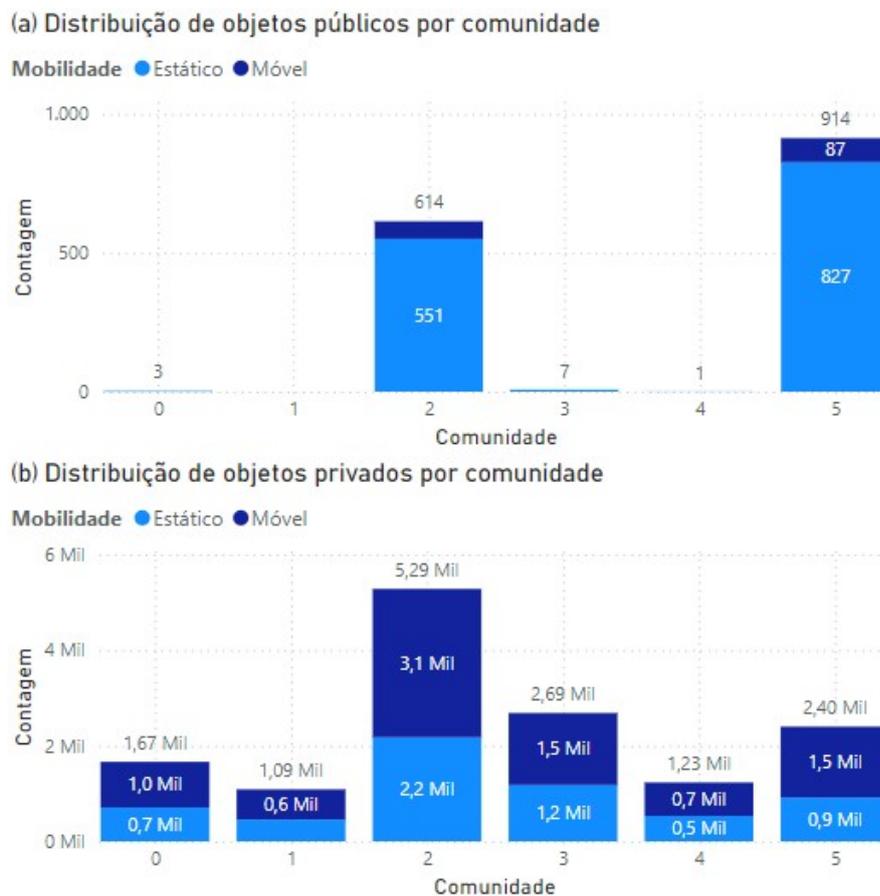
Tabela 10 – Distribuição percentual dos dispositivos por comunidade

Outro ponto analisado, foi em relação à distribuição dos dispositivos em cada comunidade encontrada. Na Tabela 10 é possível visualizar o percentual ocupado por cada objeto dentro da sua comunidade. Este levantamento se mostrou interessante uma vez que novamente as comunidades 0, 1, 3 e 4 demonstraram uma distribuição muito similar. Além disso, seus dispositivos são majoritariamente privados, com um percentual muito pequeno para um ou outro objeto público. Já as comunidades 2 e 5 são as que possuem maior população de dispositivos públicos, e a comunidade 2 é a única que possui em seu grupo os alarmes e caminhões de lixo. Este último ponto, justifica por exemplo, o porque o essa comunidade apresenta valores médios elevados para diversas métricas, já que os caminhões de lixos foram nós altamente importantes na rede analisada.

Fazendo uma comparação conjunta com a quantidade total de objetos presente em cada comunidade, percebe-se pela Figura 17 (a e b) que a comunidade 2 é consideravelmente maior do que as demais, além de ser a mais diversa já que contempla todos os objetos (vide Tabela 10). Além disso, fica visualmente notável que os dispositivos públicos se concentram nas comunidades 2 e 5 (Figura 17-a), e são majoritariamente estáticos. Já as comunidades 0, 1, 3 e 4 que demonstraram métricas muito parecidas assim como uma distribuição interna bem semelhante, além de serem as menores e compostas quase em sua totalidade por dispositivos privados, possuem poucas características pontuais.

Para entender melhor o comportamento de cada comunidade, realizaremos uma análise detalhada de cada grupo individualmente. Utilizaremos uma representação geográfica dos dispositivos estáticos de cada comunidade, observando sua posição relativa em relação

Figura 17 – Contagem de elementos por comunidade



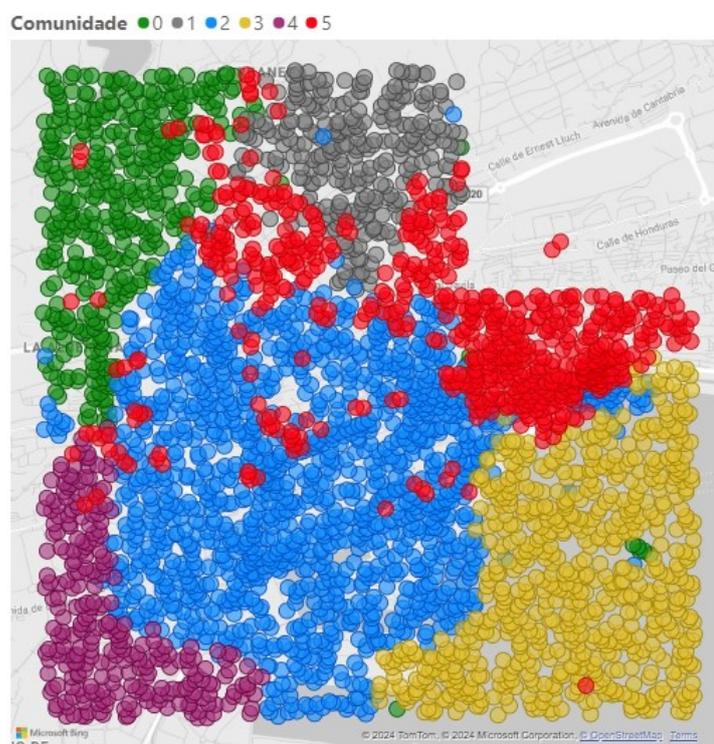
à vizinhança. A escolha por dispositivos estáticos se deve ao fato de que eles definem a vizinhança em que o proprietário reside. Em contraste, a localização dos dispositivos móveis é imprevisível, exigindo a definição de um momento específico para capturar sua posição. A Figura 18 ilustra a forte correlação entre as comunidades e suas respectivas localizações no mapa. Essa observação é particularmente interessante, considerando que a construção do grafo se baseou apenas na conectividade entre os nós, sem considerar suas coordenadas. Apesar disso, o algoritmo utilizado conseguiu identificar comunidades que refletem de forma significativa sua disposição espacial, evidenciando a eficácia da metodologia na formação de grupos coerentes com a distribuição geográfica dos dispositivos.

Para uma análise mais detalhada do comportamento e das características das comunidades identificadas, discutiremos individualmente cada comunidade, explorando suas particularidades e como elas se destacam em relação às métricas analisadas:

- **Comunidade 0 - Dispositivos menos interconectados:**

A Comunidade 0, caracterizada por um grau reduzido, e a segunda menor centralidade *eigenvector*, pode ser considerada uma comunidade periférica. Esta designação reflete

Figura 18 – Posição geográfica das comunidades



a sua posição relativamente isolada e menos integrada dentro da rede de dispositivos (noroeste). Suas métricas indicam que os dispositivos nesta comunidade têm poucas conexões mútuas entre seus vizinhos. Além disso, a baixa centralidade *eigenvector* indica que esses dispositivos têm uma influência limitada sobre outros nós da rede. Por não ser tão central ou conectada, ela se destaca por ter a segunda maior excentricidade, o que indica que seus dispositivos estão, em média, mais distantes de outros dispositivos na rede. Isso reforça a ideia de que essa comunidade opera de maneira mais isolada e com menos interconexões significativas.

- **Comunidade 1: Baixa influência e conectividade:**

A Comunidade 1, que apresenta as menores medidas de centralidade *eigenvector*, centralidade de proximidade, e *PageRank*, além de grau e *betweenness* relativamente baixos, pode ser identificada como comunidade marginal (norte). Esses dispositivos se destacam por sua baixa influência dentro da rede, já que estão relativamente distantes dos demais objetos, contribuindo pouco para a eficiência de comunicação geral. Além disso, o *PageRank* baixo corrobora a ideia de que esses dispositivos têm uma importância reduzida, pois essa comunidade é composta por dispositivos que têm um papel periférico na estrutura da rede, com poucas conexões e menor capacidade de servir como intermediários na troca de informações.

- **Comunidade 2 - Central e influente:**

A Comunidade 2, caracterizada por seu elevado número de membros, destaca-se por sua baixa excentricidade e alta centralidade de proximidade, o que indica que seus dispositivos estão relativamente próximos dos demais nós da rede (central). Esses dispositivos têm uma influência significativa devido à sua posição central e à densidade de suas conexões internas. Além disso, a comunidade apresenta o maior valor de *betweenness* e o segundo maior *PageRank*, evidenciando sua importância como intermediária na troca de informações da rede como um todo e sua relevância na hierarquia geral. Com o segundo maior número de dispositivos públicos, essa comunidade também tem um papel destacado na interação com o ambiente externo.

- **Comunidade 3 - Alta excentricidade:**

A Comunidade 3 é notável por sua alta excentricidade, o que sugere que seus dispositivos estão mais distantes em termos de caminho mínimo dentro da rede. O segundo menor coeficiente de clusterização, indica uma menor densidade de conexões entre os dispositivos. Apesar de apresentar uma excentricidade maior, a comunidade ocupa a terceira posição em termos de *PageRank*, sugerindo que nós dessa comunidade possuem conexões influentes na rede como um todo, pois é uma comunidade vizinha de outras comunidades influentes (2 e 5). Além disso, a comunidade 3 se destaca por ser a segunda com maior número de objetos privados. Esta característica pode contribuir para a variabilidade nas interações e na estrutura interna da comunidade, influenciando em sua classificação do *PageRank*.

- **Comunidade 4 - Alta coesão e baixa intermediação:**

A Comunidade 4 é caracterizada por um baixo valor de centralidade de intermediação (*betweenness centrality*), o que indica que os dispositivos dessa comunidade têm uma função menos central na mediação de conexões entre outras partes da rede (localizada a sudoeste). Além disso, a comunidade possui o segundo menor valor de *PageRank*, o que reforça a ideia de que, apesar de uma boa coesão interna, sua influência geral na rede pode ser relativamente limitada. Por outro lado, a Comunidade 4 se destaca pelo segundo maior coeficiente de clusterização, indicando uma alta densidade de conexões entre seus membros. Essa característica sugere que, dentro da comunidade, os dispositivos estão bem interconectados, formando um grupo com boas interações internas. A comunidade também é a segunda menor em termos de número de dispositivos, o que pode contribuir para essa alta coesão.

- **Comunidade 5 - Nós de alta influência:**

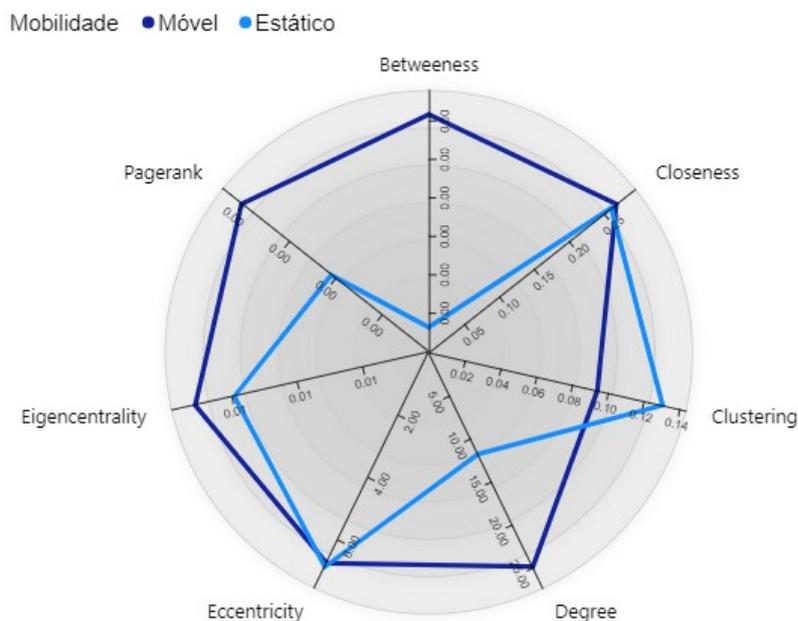
A Comunidade 5 é notável por seu alto número de conexões (grau) e seu alto valor de *PageRank*, o que indica que os dispositivos nesta comunidade desempenham um papel significativo na rede, sendo altamente influentes e possivelmente servindo como

pontos centrais de comunicação. Esta comunidade também se destaca com a segunda maior centralidade de *eigenvector*, sublinhando a importância de seus membros em termos de influência e alcance dentro da rede. A grande quantidade de dispositivos públicos nesta comunidade colabora para que ela desempenhe um papel crucial na disseminação de informações de forma mais ampla. No entanto, a Comunidade 5 possui o menor coeficiente de clusterização, o que pode ser notado também pela sua dispersão no mapa, sugerindo que, embora os dispositivos sejam bem conectados globalmente, suas interações internas são menos densas.

### 4.3 Análise da mobilidade

A Internet das Coisas (IoT) tem se expandido para incluir dispositivos móveis, o que torna crucial entender o impacto da mobilidade na formação do que é conhecido como a *Internet of Mobile Things (IoMT)*. Portanto, compreender o comportamento desses dispositivos móveis é fundamental para o desenvolvimento de soluções computacionais flexíveis e adaptadas a esse cenário. Até o momento, as discussões apresentadas reforçaram a importância da mobilidade para a comunicação dentro da rede. A Figura 19 apresenta uma comparação das métricas envolvendo objetos móveis e estáticos.

Figura 19 – Comparação por mobilidade



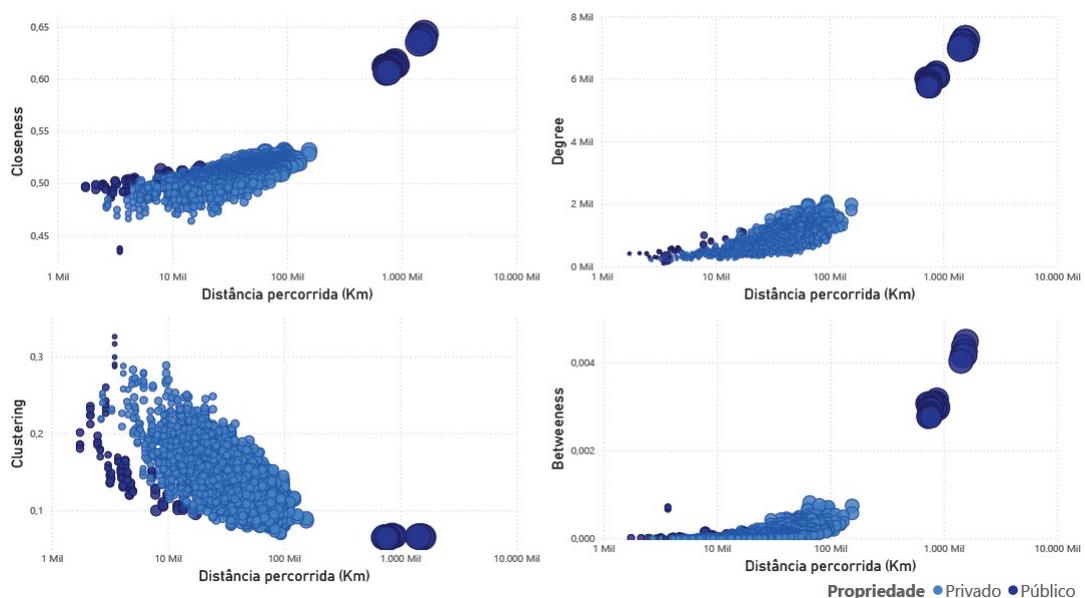
Os dispositivos móveis se destacam principalmente nas métricas de *Degree* e *Betweenness*, evidenciando que, além de se conectarem a um número maior de nós, esses dispositivos atuam como pontes fundamentais entre nós que, de outra forma, estariam desconectados. Em contrapartida, o coeficiente de clusterização (*clustering*) revela que os

dispositivos estáticos têm maior propensão a formar comunidades mais densas e interconectadas. Um ponto interessante surge ao comparar as métricas de centralidade *eccentricity* e *closeness*: observa-se que a mobilidade não exerce um impacto direto na distância entre os nós na rede, o que à primeira vista pode parecer contra-intuitivo. No entanto, devido à abundância de dispositivos móveis, eles acabam facilitando a intermediação entre dispositivos estáticos, conectando-os de forma mais eficiente à rede como um todo.

O *PageRank* de objetos móveis na rede analisada se mostrou mais elevado que o de objetos estáticos devido à sua maior interatividade e dinâmica. Os dispositivos móveis, conforme visto ao decorrer das análises, tendem a estabelecer mais conexões e interagir com uma variedade maior de outros nós, o que resulta em uma maior relevância e visibilidade dentro da rede. Além disso, a movimentação contínua pode levar a um aumento nas oportunidades de ligação com nós de alta relevância, melhorando assim seu *PageRank*.

Além de compreender o impacto da mobilidade em si, é fundamental analisar como a distância percorrida por um objeto influencia sua relevância dentro da rede. Na Figura 20, observamos que, à medida que a distância total percorrida por um objeto aumenta, sua performance em diversas métricas tende a melhorar. Foram analisadas as centralidades de proximidade (*closeness*), intermediação (*betweenness*), clusterização (*clustering*) e grau. O tamanho dos círculos reflete o grau dos objetos, exceto no gráfico de grau, onde o tamanho é determinado pela importância de acordo com o *Pagerank*.

Figura 20 – Impacto da mobilidade



Os resultados mostram que os valores das métricas acompanham, de forma geral, a distância percorrida. No entanto, a clusterização é maior para os objetos que percorrem distâncias menores, como também observado na Figura 19, em que objetos estáticos se

destacam nesse aspecto. Um exemplo claro dessa dinâmica está nos objetos públicos, representados em azul escuro, como caminhões de lixo, táxis e ônibus, que se destacam na maioria das métricas. Esses veículos cobrem grandes distâncias e atuam em toda a cidade, o que aumenta tanto seu grau quanto sua importância na rede, já que sua função é justamente conectar diversas partes do sistema urbano, fortalecendo suas conexões e relevância.

Sendo assim, podemos dizer que os objetos móveis desempenham um papel fundamental nas redes IoT de centros urbanos, especialmente em um contexto social e de alta mobilidade. Sua capacidade de conectar diferentes partes da rede, percorrendo grandes distâncias e atuando como intermediários cruciais, realça sua importância para a comunicação eficiente entre dispositivos.

## 5 Conclusão

A Internet das Coisas (IoT) já faz parte do nosso cotidiano, com dispositivos inteligentes integrando-se progressivamente às nossas casas, serviços, centros urbanos e até mesmo aos objetos que carregamos no bolso. Diante dessa realidade, entender o comportamento desses objetos em um contexto de mobilidade é fundamental para desenvolver soluções mais eficientes. Tais soluções podem, por exemplo, contribuir para melhorar a infraestrutura de comunicação e otimizar o uso dos dispositivos, promovendo maior fluidez na troca de informações. Além disso, compreender os padrões de comportamento desses dispositivos possibilita ganhos em termos de conectividade e redução de latências, bem como uma gestão mais eficiente dos recursos de rede. Ao compreender as interações sociais entre os objetos, torna-se viável prever eventos, aumentar a segurança e ampliar as funcionalidades da IoT, tanto no aspecto social (SIoT) quanto na mobilidade (IoMT). Isso é possível porque, ao entender como os dispositivos interagem e se movimentam, podemos ajustar as redes para melhorar o roteamento de dados, antecipar congestionamentos, alocar melhor os recursos e responder mais rapidamente a eventos crítico

Este estudo se concentrou em investigar o comportamento de dispositivos públicos e privados, utilizando um conjunto de dados que abrange objetos móveis e estáticos, com dados reais e simulados. Ferramentas como o PostGIS permitiram simulações que identificam momentos de “contato” entre dispositivos por meio da aplicação de áreas em torno dos objetos que representam seus alcances. Essa abordagem possibilitou a modelagem de interações reais e a exploração de interações hipotéticas. A análise dos dados do projeto SmartSantander, combinados com os dados sintéticos do modelo SWIM, revelou como as interações entre os dispositivos são influenciadas principalmente pela mobilidade.

Os dispositivos públicos, especialmente os móveis, como caminhões de lixo, desempenham um papel central na conectividade da rede. Suas rotas e padrões de movimentação ajudam a reforçar a conectividade da rede, funcionando como pontos de comunicação importantes em diferentes áreas. O uso do algoritmo de extração de *backbone* (*Disparity Filter*) foi fundamental para preservar a estrutura principal da rede, removendo grande parte das arestas menos relevantes, o que simplificou o processo de detecção de comunidades. Além disso, o algoritmo de *Louvain*, permitiu a criação de comunidades bem definidas. Embora focado apenas no grafo gerado, ele representou de maneira concisa a segmentação geográfica dos objetos. Por fim, as comunidades identificadas apresentaram características sociais claramente delineadas, conforme evidenciado pelas métricas aplicadas, destacando dispositivos que desempenham papéis centrais e outros que atuam como pontes entre diferentes setores, facilitando a comunicação entre objetos móveis e estáticos.

Para pesquisas futuras, pode-se expandir essa análise para outros tipos de dispositivos em diferentes contextos urbanos. Além disso, visto a importância de veículos públicos no contexto analisado, outra possibilidade seria estudar como otimizar a alocação destes objetos, com o objetivo de melhorar a eficiência das redes de **IoT** em centros urbanos inteligentes.

# Referências

- AL-SARAWI, S. et al. Internet of things (iot) communication protocols. In: IEEE. *8th ICIT*. [S.l.], 2017. p. 685–690. Citado 2 vezes nas páginas 24 e 25.
- ALVES, T. E.; RETTORE, P. H.; SANTOS, B. P. A mobility model of the internet of things. In: SBC. *Anais do XXIX Simpósio Brasileiro de Sistemas Multimídia e Web*. [S.l.], 2023. p. 221–229. Citado na página 19.
- ASL, H. Z. et al. How often social objects meet each other? analysis of the properties of a social network of iot devices based on real data. In: *IEEE GLOBECOM*. [S.l.: s.n.], 2013. p. 2804–2809. Citado na página 19.
- ATZORI, L. et al. The social internet of things (sIoT)—when social networks meet the internet of things: Concept, architecture and network characterization. *Computer networks*, Elsevier, v. 56, n. 16, p. 3594–3608, 2012. Citado na página 13.
- BEDI, P.; SHARMA, C. Community detection in social networks. *Wiley interdisciplinary reviews: Data mining and knowledge discovery*, Wiley Online Library, v. 6, n. 3, p. 115–135, 2016. Citado na página 18.
- BLONDEL, V. D. et al. Fast unfolding of communities in large networks. *Journal of statistical mechanics: theory and experiment*, IOP Publishing, v. 2008, n. 10, p. P10008, 2008. Citado 2 vezes nas páginas 18 e 30.
- CHANG, S. e. a. Mobility network models of covid-19 explain inequities and inform reopening. *Nature*, Nature Publishing Group, v. 589, n. 7840, p. 82–87, 2021. Citado na página 13.
- CHEN, Z.; HENDRIX, W.; SAMATOVA, N. F. Community-based anomaly detection in evolutionary networks. *Journal of Intelligent Information Systems*, Springer, v. 39, n. 1, p. 59–85, 2012. Citado na página 18.
- ELHADI, S. et al. Comparative study of iot protocols. *Smart Application and Data Analysis for Smart Cities (SADASC'18)*, 2018. Citado na página 24.
- FERREIRA, C. H. G. et al. On network backbone extraction for modeling online collective behavior. *Plos one*, Public Library of Science San Francisco, CA USA, v. 17, n. 9, p. e0274218, 2022. Citado 2 vezes nas páginas 17 e 29.
- GU, K.; WANG, L.; YIN, B. Social community detection and message propagation scheme based on personal willingness in social network. *Soft Computing*, Springer, v. 23, p. 6267–6285, 2019. Citado na página 18.
- GUTIÉRREZ, V. et al. *SmartSantander: Internet of things research and innovation through citizen participation*. [S.l.]: Springer, 2013. Citado na página 21.
- JÚNIOR, J. J. et al. Utilizando aprendizado por representação para a classificação de laços sociais da iot. In: SBC. *Anais do VI Workshop de Computação Urbana*. [S.l.], 2022. p. 112–125. Citado 3 vezes nas páginas 14, 19 e 21.

- JÚNIOR, J. J. et al. Como os objetos da internet das coisas se comportam? uma análise através de métricas quantitativas. In: SBC. *Anais do V Workshop de Computação Urbana*. [S.l.], 2021. p. 56–69. Citado 5 vezes nas páginas 13, 14, 20, 21 e 24.
- MARCHE, C. et al. How to exploit the social internet of things: Query generation model and device profiles' dataset. *Elsevier*, v. 174, 2020. Citado 2 vezes nas páginas 13 e 19.
- MEI, A.; STEFA, J. Swim: A simple model to generate small mobile worlds. In: IEEE. *IEEE INFOCOM 2009*. [S.l.], 2009. p. 2106–2113. Citado 2 vezes nas páginas 14 e 21.
- MESLIN, A. M.; RODRIGUEZ, N. d. L. R.; ENDLER, M. Supporting multiple smart-city applications based on musanet, a common iomt middleware. In: SBC. *Anais do XVIII Workshop em Clouds e Aplicações*. [S.l.], 2020. p. 13–26. Citado na página 13.
- NOBRE, G. P.; FERREIRA, C. H. G.; ALMEIDA, J. M. Beyond groups: Uncovering dynamic communities on the whatsapp network of information dissemination. In: SPRINGER. *Social Informatics: 12th International Conference, SocInfo 2020, Pisa, Italy, October 6–9, 2020, Proceedings 12*. [S.l.], 2020. p. 252–266. Citado na página 18.
- PAGE, L. *The PageRank citation ranking: Bringing order to the web*. [S.l.], 1999. Citado na página 17.
- SANTOS, B. P. et al. A internet das coisas está preparada para mobilidade? In: SBC. *V CoUrb*. [S.l.], 2021. p. 1–14. Citado 2 vezes nas páginas 13 e 14.
- SERRANO, M. Á.; BOGUNÁ, M.; VESPIGNANI, A. Extracting the multiscale backbone of complex weighted networks. *Proceedings of the national academy of sciences*, National Acad Sciences, v. 106, n. 16, p. 6483–6488, 2009. Citado 2 vezes nas páginas 17 e 29.
- SHAHAB, S. et al. Siot (social internet of things): a review. *ICT analysis and applications*, Springer, p. 289–297, 2022. Citado na página 13.
- SILVA, L. N. et al. Mobvis: A framework for analysis and visualization of mobility traces. In: IEEE. *2022 IEEE Symposium on Computers and Communications (ISCC)*. [S.l.], 2022. p. 1–6. Citado na página 19.
- SUNDMAEKER, H. et al. Vision and challenges for realising the internet of things. *IERC, European Commision*, v. 3, n. 3, p. 34–36, 2010. Citado na página 13.
- WASSERMAN, S. Social network analysis: Methods and applications. *The Press Syndicate of the University of Cambridge*, 1994. Citado na página 16.