

Identificação de Perfis de Consumo de Gadgets por Técnicas de Clusterização

Maria Amaralina de C. Rufino¹, Raissa Barcellos¹

¹Departamento de Ciência da Computação – Universidade do Estado do Rio de Janeiro
(UERJ), Rio de Janeiro – RJ – Brasil

maria.planeje2@gmail.com, raissa.barcellos@ime.uerj.br

Abstract. *This research analyzes the temporal evolution of global consumption of wearable devices and personal gadgets between 2015 and 2025, aiming to identify technological adoption patterns at an international level. Methodologically, a quantitative approach is adopted, grounded in Exploratory Data Analysis (AED) and unsupervised machine learning (clustering) algorithms, employing the K-Means algorithm for market segmentation and Principal Component Analysis (PCA) for dimensional reduction and data interpretation. The results demonstrate the formation of four distinct consumption profiles: Cluster 0 (Productivity and Entertainment), focused on personal computers for professional or educational activities; Cluster 1 (Mobility Leadership), centered on the practical use of smartwatches and smartphones; Cluster 2 (Mass Consumption of Mobile Devices), driven by peaks in trade volume for cell phones and consoles; and Cluster 3 (Advanced Entertainment and Integrated Ecosystem), characterized by high technological maturity and leadership in video game consoles and smartwatches. The findings indicate that the consumption of these devices transcends the strictly utilitarian dimension, shaping up as a dynamic socioeconomic phenomenon. It is concluded that the study contributes to the macrostructural understanding of the global technology market, offering theoretical and practical insights for the formulation of corporate strategies and market analyses in the sector.*

Resumo. *Esta pesquisa analisa a evolução temporal do consumo global de dispositivos vestíveis e gadgets pessoais entre 2015 e 2025, visando identificar padrões de adoção tecnológica em nível internacional. Metodologicamente, adotou-se uma abordagem quantitativa fundamentada na Análise Exploratória de Dados (AED) e em algoritmos de agrupamento não supervisionado (clustering), empregando o algoritmo K-Means para a segmentação dos mercados e a Análise de Componentes Principais (PCA) para a redução dimensional e interpretação dos dados. Os resultados evidenciam a formação de quatro perfis distintos de consumo: o Cluster 0 (Produtividade e*

Entretenimento), focado em computadores pessoais para atividades profissionais ou educacionais; o Cluster 1 (Liderança em Mobilidade), voltado para o uso prático de smartwatches e smartphones; o Cluster 2 (Consumo Massivo de Dispositivos Móveis), impulsionado por picos de volumetria comercial em celulares e consoles; e o Cluster 3 (Entretenimento Avançado e Ecossistema Integrado), caracterizado por alta maturidade tecnológica e liderança em consoles e relógios inteligentes. Os achados indicam que o consumo desses dispositivos transcende a dimensão estritamente utilitária, configurando-se como um fenômeno socioeconômico dinâmico. Conclui-se que o estudo contribui para a compreensão macroestrutural do mercado tecnológico global, oferecendo subsídios teóricos e práticos para a formulação de estratégias corporativas e análises de mercado no setor.

1. Introdução

Desde o surgimento dos computadores pessoais, a tecnologia tem avançado rapidamente, impactando diretamente a comunicação, o trabalho e a realização de tarefas cotidianas. De acordo com a *International Data Corporation* [IDC 2016 apud Hsiao e Chen 2018], as vendas de *smartwatches* apresentaram projeções otimistas, estimando-se um faturamento de US\$17,8 bilhões até 2020. Dados mais recentes confirmam essa tendência: em 2024, o mercado global de *wearables* alcançou 534,6 milhões de unidades comercializadas, com um crescimento de 5,4% em relação ao ano anterior, segundo o relatório *Worldwide Quarterly Wearable Device Tracker* da [IDC 2025]. Apesar de uma queda nas vendas de *smartwatches* em 2016, esses dispositivos tornaram-se cada vez mais integrados ao cotidiano das pessoas e apresentam um potencial significativo para contribuir em diversas áreas, como saúde, esportes, comunicação e serviços financeiros [Hsiao e Chen 2018]. [Zacour et al. 2022] ressaltam que os *gadgets* modernos atuam como inovações disruptivas que ampliam significativamente o acompanhamento pessoal, oferecendo funcionalidades e utilidades percebidas que facilitam atividades diárias, especialmente voltadas ao modelo de saúde preventivo e ao monitoramento remoto em tempo real. O crescimento do mercado de dispositivos vestíveis também está relacionado ao interesse do setor de Internet das Coisas (*IoT*), que considera esses produtos uma plataforma estratégica para integrar os mundos físico e digital. [Yang et al. 2024] destacam que esses dispositivos se diferenciam dos celulares e computadores por funcionarem de forma contínua e estarem mais intimamente conectados ao corpo humano. Além disso, atualizações constantes em *hardware*, *software*, *design* e interfaces, impulsionadas pelo uso de sensores miniaturizados, telas de alta resolução e algoritmos de Inteligência Artificial são fatores que estimulam a intenção de compra, uma vez que o *design* diferenciado, o posicionamento de mercado e o *marketing* foram fundamentais para a transformação desses produtos em itens de consumo cobiçados [Shang 2024].

A delimitação deste estudo concentra-se na evolução temporal desse consumo em nível internacional ao longo de uma década, situando-se entre os anos de 2015 e 2025. A

relevância desta temática fundamenta-se no fato de que o entendimento de mercados globais integrados auxilia a decodificar as verdadeiras preferências dos usuários em uma sociedade crescentemente conectada. Contudo, embora os dados da [IDC 2025](#) apontem para uma consolidação do mercado global de *wearables*, a adoção desses dispositivos não ocorre de forma homogênea entre as diferentes nações. O rápido avanço tecnológico e a integração com a Internet das Coisas (*IoT*) criam um cenário de consumo complexo, onde fatores como prestígio social, infraestrutura tecnológica e comportamento do consumidor variam drasticamente. O problema central desta pesquisa reside na dificuldade de mapear, de forma clara e segmentada, como o consumo de *gadgets* evoluiu em diferentes contextos internacionais ao longo da última década (2015-2025). Sem uma identificação precisa dos padrões de adoção, torna-se desafiador para gestores e desenvolvedores compreenderem se o mercado caminha para uma convergência global ou se perfis regionais distintos demandam estratégias de mercado personalizadas. Diante desse cenário de crescimento e transformação tecnológica, este trabalho investiga o consumo de *gadgets* em dez países entre 2015 e 2025 e, por meio de análises exploratórias e técnicas de clusterização, busca identificar tendências e perfis internacionais de consumo tecnológico.

Para responder a essa questão, o objetivo geral proposto consiste em analisar a evolução do consumo de *gadgets* em dez países no período de 2015 a 2025, identificando tendências e perfis internacionais por meio de técnicas de análise exploratória e clusterização. Como objetivos específicos, propõe-se: realizar levantamentos e organizar os dados de consumo de *gadgets* nos dez países selecionados durante o recorte temporal de dez anos; realizar a Análise Exploratória de Dados (*AED*) para identificar variações, picos de crescimento e possíveis correlações entre os mercados; e aplicar algoritmos de *clustering* para agrupar países com comportamentos de consumo similares, definindo perfis de adoção tecnológica.

A presente pesquisa oferece contribuições significativas em duas esferas principais: a contribuição metodológica e a contribuição prática. A primeira demonstra a eficácia da integração entre a Análise Exploratória de Dados (*AED*) e técnicas de *machine learning* para a compreensão de mercados globais, incorporando o suporte visual de gráficos como o Radar, o *PCA* com *Hexbin* e o Diagrama de Sankey para fornecer um modelo replicável para o estudo de outras categorias de produtos. Já a segunda, ao realizar uma análise multi-país abrangendo uma década, o trabalho provê *insights* valiosos para empresas do setor de tecnologia e *IoT*, permitindo a segmentação de mercados baseada em comportamento real de consumo e nos fluxos de transição dos perfis, indo além de simples divisões geográficas ou econômicas tradicionais.

Este trabalho está estruturado em seis partes principais, organizadas da seguinte forma: esta Seção 1 introduz o tema, delimitando o problema, a pergunta de pesquisa, os objetivos e a relevância do estudo. A Seção 2 apresenta a fundamentação teórica sobre análise exploratória de dados aplicada ao consumo, segmentação por perfil, tendências globais no mercado de *gadgets* e a relevância da análise de dados para estratégias de mercado. A Seção 3 descreve os procedimentos metodológicos adotados, detalhando o

ambiente de programação *Python*, as bibliotecas utilizadas, as fontes de dados e as técnicas de análise. A Seção 4 apresenta os resultados obtidos por meio das análises exploratórias e do agrupamento de países. A Seção 5 desenvolve a discussão crítica dos achados frente à literatura especializada e às interpretações das ferramentas visuais do modelo. Por fim, a Seção 6 consolida as conclusões da pesquisa, explicitando suas limitações metodológicas e direcionando sugestões para investigações futuras.

2. Fundamentação Teórica

2.1 Análise Exploratória de Dados no Contexto de Consumo

A análise exploratória de dados (AED), conforme [\[Rao et al. 2021\]](#), é uma etapa essencial para examinar informações, detectar padrões e resumir as características de um conjunto de dados através de recursos visuais e estatísticos.

Esta prática permite compreender comportamentos de consumo de forma lógica e fundamentada antes de análises mais complexas.

Conforme demonstrado por [\[Li et al. 2022\]](#), a aplicação da AED no mercado de *gadgets* é crucial para converter dados brutos em perfis de usuários, identificando como hábitos e diferenças geográficas moldam o uso de tecnologias globalmente. Com isso, a técnica fundamenta a previsão de tendências e o entendimento sobre a evolução do consumidor em diversas regiões do mundo.

2.2 Agrupamento e Segmentação por Perfil de Consumo

De acordo com [\[Queiroz et al. 2023\]](#), as técnicas de agrupamento (*clustering*) são ferramentas que organizam informações com base em semelhanças e ajudam a identificar dados que fogem do comportamento padrão. No ambiente de mercado, [\[Ling e Weiling 2025\]](#) explicam que a segmentação divide o público em grupos conforme suas preferências e hábitos, permitindo que as empresas criem estratégias personalizadas e melhorem a satisfação dos clientes.

O método *K-Means* é reconhecido como uma das escolhas mais comuns para realizar essa tarefa devido à sua simplicidade e agilidade. Este algoritmo, como detalhado por [\[Sinaga e Yang 2020\]](#) e [\[Queiroz et al. 2023\]](#), organiza os dados em um número específico de grupos determinado pelo pesquisador, procurando aproximar cada item do ponto central de seu grupo. Contudo, o modelo possui limitações conhecidas, como a dependência do ponto de partida escolhido para os grupos e a sensibilidade a valores muito discrepantes (*outliers*), o que pode gerar variações nos resultados finais.

Aplicada ao consumo de *gadgets*, essa prática permite agrupar países ou consumidores com comportamentos tecnológicos parecidos em escala global. Dessa maneira, a segmentação fundamenta decisões estratégicas, ajudando a prever tendências e a entender como o mercado se transforma em diferentes partes do mundo.

2.3 Redução de Dimensionalidade e Análise de Componentes Principais (PCA)

A redução de dimensionalidade é uma etapa essencial para analisar dados complexos, principalmente quando o excesso de informações dificulta a visão clara do que realmente importa. [\[Vitório et al. 2021\]](#) explicam que essa estratégia transforma dados brutos em representações simples, o que permite extrair conhecimento de arquivos que, de outra forma, poderiam parecer extensos ou confusos. Ao simplificar essa complexidade, o pesquisador ganha uma base mais segura para entender os problemas e tomar decisões fundamentadas. Entre as principais técnicas para essa finalidade, destaca-se a Análise de Componentes Principais (*PCA*). [\[Salih Hasan et al. 2021\]](#) definem o *PCA* como uma técnica de redução de dimensionalidade utilizada para transformar um grande conjunto de variáveis em um conjunto menor, que ainda contenha a maior parte dos detalhes e informações originais. O objetivo central é melhorar a interpretabilidade dos dados sem perder informações significativas, criando novas variáveis que não possuem relação entre si. Ao reduzir dados de altas dimensões para dimensões inferiores, a técnica facilita o processamento e a visualização das informações. O *PCA* busca encontrar uma posição otimizada para manter a máxima variância da informação, extraíndo o que é essencial e eliminando dados redundantes ou ruidosos. Por ser um método de aprendizado não supervisionado, ele permite que a análise se torne mais rápida e eficiente computacionalmente. No estudo sobre o mercado global de *gadgets*, o uso do *PCA* se justifica pela necessidade de organizar as informações do *dataset*. Ao concentrar a variação dos diversos dados de consumo nos eixos principais, a técnica permite visualizar onde as informações mudam mais. Essa estrutura torna os perfis de consumo global muito mais evidentes, permitindo separar os padrões entre os países e confirmar que as tendências encontradas são consistentes, mesmo com um número menor de amostras.

2.4 Tendências Globais no Mercado de *Gadgets*

Os *gadgets*, tecnicamente descritos por [\[Ometov et al. 2021\]](#) como tecnologias vestíveis integradas a acessórios ou vestimentas, evoluíram para compor redes de automação que facilitam as tarefas diárias por meio de serviços personalizados e monitoramento constante. De acordo com [\[Julianingsih et al. 2021\]](#), esses pequenos aparelhos eletrônicos possuem funções específicas voltadas a tornar o trabalho e as necessidades humanas mais práticos e eficientes, sendo considerados ferramentas de comunicação multifuncionais essenciais na sociedade moderna. Conforme explicam [\[Valencia-Arias et al. 2023\]](#), essa integração entre dispositivos inteligentes busca atender às demandas crescentes dos usuários em diversos setores, transformando ambientes em ecossistemas mais conectados e produtivos. Historicamente, essa busca por aprimorar a experiência humana remonta a invenções de séculos passados, atingindo hoje o patamar de sistemas de realidade aumentada e dispositivos altamente sofisticados.

Atualmente, o setor de *gadgets* apresenta uma expansão acelerada, com previsões de crescimento anual superior a 20% e um mercado global que deve ultrapassar 150 bilhões de euros até 2028. Para compreender esse cenário dinâmico, [\[Ling e Weiling 2025\]](#) destacam que a segmentação estratégica dos consumidores é uma ferramenta fundamental, pois permite dividir o público em grupos baseados em comportamentos e

preferências para personalizar as ações de mercado. Dessa forma, o mapeamento de perfis tecnológicos permite que pesquisadores e empresas acompanhem variações culturais e geográficas na aceitação de novas tecnologias, fundamentando decisões estratégicas em escala mundial.

2.5 A importância da Análise de Dados para Estratégias de Mercado

A análise de dados consiste no processo de inspeção, limpeza, transformação e modelagem de dados com o objetivo de descobrir informações úteis, apoiar a tomada de decisões e identificar padrões e tendências sob perspectivas inteligentes orientadas a dados [\[Sarker 2021\]](#). [\[Wang et al. 2018\]](#) destacam quatro tipos principais de análise de dados, cada um aplicado a objetivos e contextos específicos, utilizando métodos diferentes para tratar os dados coletados. Esses tipos são: descritiva, diagnóstica, preditiva e prescritiva, amplamente utilizados em diferentes estágios da tomada de decisão organizacional e frequentemente combinados em soluções integradas de análise de dados [\[Houtmeyers et al. 2021\]](#).

Todo o processo de coleta, limpeza, transformação, descrição, modelagem e interpretação sistemática de informações envolve a análise de dados e, atualmente, esse processo é amplamente automatizado, com algoritmos que geram *insights* para pesquisadores e gestores [\[MIT Sloan Review Brasil 2024\]](#). De modo geral, [\[Neves et al. 2024\]](#) sustentam que a capacidade de análise de dados constitui um recurso estratégico essencial para fortalecer o desempenho competitivo e assegurar o sucesso operacional e de mercado. Essa competência permite que as organizações tomem decisões baseadas em evidências, identifiquem oportunidades ou ameaças e compreendam as necessidades dos clientes de forma sistemática, reduzindo significativamente as chances de falhas estratégicas. Aplicada ao mercado de *gadgets*, a análise de dados permite compreender o presente e antecipar tendências futuras de consumo por meio da descoberta de padrões e previsões de demanda.

2.6 Trabalhos Relacionados

Para a seleção dos trabalhos relacionados, foi realizada uma busca bibliográfica sistemática em bases de dados como *ScienceDirect*, *SBC OpenLib (SOL)* e *ResearchGate*. A busca foi realizada utilizando palavras-chave que definem os temas centrais do trabalho, conectando o consumo de dispositivos tecnológicos com as técnicas de análise de dados aplicadas, incluindo: *Cluster analysis*, *exploratory study*, *K-Means*, *smartwatch*, *consumer adoption*, *Gadgets*, *Wearables* e Comportamento do Consumidor. Os critérios de inclusão priorizaram estudos que aplicaram técnicas de análise exploratória de dados (AED) e o algoritmo *K-Means* para segmentação de mercado ou análise de comportamento de uso de dispositivos tecnológicos. A escolha dos artigos justifica-se pela convergência metodológica com o presente trabalho, uma vez que todos adotam obrigatoriamente uma análise exploratória para fundamentar a compreensão das variáveis antes da aplicação do agrupamento. [\[Malhotra et al. 2022\]](#) investigaram o uso de Dispositivos de Assistente Baseados em Voz (*VBADs*), dispositivos inteligentes

habilitados por IA. O estudo analisou as palavras descritivas utilizadas pelos usuários, suas intenções de uso (funcionais versus relacionais) e realizou um mapeamento perceptual de marcas populares. Por meio de análise de *cluster*, utilizando aprendizado de máquina e *K-Means*, e análise de correspondência, os autores demonstraram que os *VBADs* não apenas cumprem funções utilitárias, mas também estabelecem vínculos relacionais com os usuários, sendo percebidos como parceiros, amigos ou membros da família. Verificou-se que *Google Assistant* e *Alexa* criam laços relacionais, enquanto *Siri* e *Bixby* são majoritariamente percebidos como dispositivos utilitários. Esses achados possuem implicações gerenciais relevantes para o desenvolvimento de produtos e estratégias de segmentação [Malhotra et al. 2022].

[Kutz e Senefonte 2025] investigaram a segmentação de clientes em comércio eletrônico, visando interpretar comportamentos e gerar estratégias acionáveis para o varejo digital. Os autores aplicaram análise exploratória dos dados *RFM* (Recência, Frequência e Valor Monetário), identificando forte assimetria e heterogeneidade, o que representou desafios para a segmentação. Foram testadas três abordagens: o modelo *RFM* padrão, que gerou excesso de fragmentação; *RFM* combinado com *K-Means*, que reduziu o número de *clusters*, mas manteve limitações; e *K-Means* associado à transformação *Box-Cox*, que possibilitou identificar quatro segmentos bem definidos e interpretáveis, como “*Champions*” e “*Hibernating*”, com significativa redução do escore de distorção [Kutz e Senefonte 2025]. [Visuri et al. 2021] analisaram a evolução dos estilos de uso de *smartwatches* ao longo do tempo, com o objetivo de compreender como a adoção inicial e o uso diário se transformam em padrões de comportamento mais estáveis. Com base em dados de 79 usuários coletados entre 2015 e 2017, aplicaram técnicas de agrupamento, destacando o algoritmo *K-Means*, para identificar 33 tipos distintos de comportamento. Esses comportamentos foram classificados como “exploratórios”, que tendem a desaparecer com o tempo, e “aceitos”, que se consolidam no uso de longo prazo. Os resultados indicaram que os usuários ajustam seu uso de forma seletiva e passiva, adaptando-se às capacidades reais do dispositivo e confirmando teorias sobre difusão de inovações e declínio de interesse após a fase inicial de novidade [Visuri et al. 2021].

Tabela 1: Comparação entre os trabalhos selecionados

Referência	Objetivo	Metodologia	Resultados
[Kutz e Senefonte 2025]	Segmentar consumidores de e-commerce para gerar <i>insights</i> estratégicos	Análise exploratória de dados, <i>RFM</i> padrão, <i>RFM</i> com <i>K-Means</i> e Transformação <i>Box-Cox</i>	<i>RFM</i> tradicional gerou fragmentação excessiva; <i>K-Means</i> reduziu segmentos para 5; com <i>Box-Cox</i> , alcançou 4 segmentos claros e interpretáveis

[Malhotra et al. 2022]	Analisar percepções e intenções de uso de assistentes de voz	Clusterização (<i>K-Means</i>), análise de correspondência	VBADs cumprem funções utilitárias e relacionais; Google <i>Assistant</i> e Alexa criam vínculos afetivos, enquanto Siri e Bixby mantêm perfil utilitário
[Visuri et al. 2021]	Investigar a evolução do uso de <i>smartwatches</i> a longo prazo	Coleta de dados de 79 usuários (14 meses); extração de 98 variáveis; agrupamento <i>K-Means</i> ($k=33$); análise de transições	Identificados 33 comportamentos, divididos em exploratórios e aceitos; uso tende a estabilizar; comportamentos aceitos mais passivos e seletivos

Na literatura recente, diversos estudos aplicaram técnicas de análise de dados e agrupamento para compreender o consumo de tecnologia. Entretanto, essas pesquisas ainda se concentram em níveis específicos, como consumidores individuais, dispositivos ou marcas isoladas. Em contraste, este trabalho se diferencia da literatura ao adotar uma abordagem integrada para a análise do consumo de *gadgets* em escala internacional. Diferentemente de estudos que se concentram em usuários individuais ou dispositivos específicos, esta pesquisa considera países como unidade de análise, permitindo uma perspectiva comparativa global. Além disso, ao integrar múltiplas categorias de dispositivos tecnológicos e combinar análise exploratória de dados com técnicas de clusterização e redução de dimensionalidade, o estudo possibilita a identificação de perfis de consumo mais abrangentes. Como resultado, são revelados padrões globais e regionais de comportamento tecnológico, contribuindo para uma compreensão mais ampla da dinâmica do mercado de *gadgets*.

3. Metodologia

O presente trabalho caracteriza-se como uma pesquisa quantitativa, de natureza exploratória e descritiva. A metodologia foi delineada a partir de uma sequência lógica e sistemática de etapas, com o objetivo de assegurar a transparência e a replicabilidade do estudo, abrangendo desde a aquisição e o tratamento dos dados até a análise e interpretação dos padrões de consumo. Essa organização metodológica está sintetizada na Figura 1, que apresenta de forma esquemática o fluxo completo das etapas desenvolvidas ao longo da pesquisa.



Figura 1. Etapas do processo de coleta, tratamento e análise de dados

3.1. Coleta e Preparação dos Dados

A base de dados utilizada nesta pesquisa é um conjunto de dados público intitulado "*Global Tech Gadget Consumption Data 2015-2025*", obtido da plataforma de ciência de dados *Kaggle* [SOUNDANKAR 2024]. O *dataset* é um painel de dados (ou série temporal *cross-seccional*) que abrange o período de 2015 a 2025. Ele agrega informações de 10 países, detalhando o consumo anual em quatro categorias principais de *gadgets*: vendas de *smartphones* (em milhões), envios de *laptops* (em milhões), adoção de consoles de videogame (%) e adoção de *smartwatches* (%). Os dez países analisados correspondem à totalidade dos registros disponibilizados pelo *dataset* utilizado, não tendo sido realizada uma seleção amostral adicional por parte dos autores. Adicionalmente, o *dataset* inclui variáveis contextuais como o gasto médio do consumidor (em USD - dólar americano \$) e a geração de lixo eletrônico (em toneladas métricas).

Conforme descrito pelo autor da base, o *dataset* possui natureza sintética, tendo sido construído a partir de tendências observadas em relatórios e análises de mercado de fontes como *IDC*, *Gartner*, *Statista* e outras publicações do setor tecnológico. Dessa

forma, os valores disponibilizados não representam necessariamente medições reais, mas sim distribuições e padrões considerados plausíveis para fins de pesquisa e análise. Assim, os resultados deste estudo devem ser interpretados como uma investigação exploratória sobre padrões de consumo tecnológico, não tendo como objetivo representar com exatidão o mercado global real.

O pré-processamento dos dados foi uma etapa fundamental para garantir a qualidade e a adequação da análise, sendo executado em quatro fases: Limpeza e Padronização, Tradução, Tratamento de dados inválidos e Agregação de dados. Para a Limpeza e Padronização os nomes dos atributos foram convertidos para um formato padronizado (minúsculas, sem caracteres especiais, ex: *smartphone_sales_millions*). Já na Tradução, para facilitar a interpretação e a apresentação dos resultados no contexto brasileiro, os rótulos de países (ex: "USA" para "EUA") e os nomes dos atributos (ex: "*Laptop Shipments (Millions)*" para "Envios de *Laptops* (Milhões)") foram traduzidos para o português. No Tratamento de Dados Inválidos, conforme identificado em uma inspeção preliminar, o atributo *5G Penetration Rate (%)* foi removido do escopo da análise. A presença de valores positivos para esta métrica em anos anteriores à implementação comercial da tecnologia (ex: 2015-2016) compromete a veracidade da variável, tornando-a inadequada para a análise. Além disso, a variável lixo eletrônico foi desconsiderada desta análise para manter o foco exclusivo no comportamento de adoção e perfis de *gadgets*.

Por fim, na Estruturação dos Dados, a análise adotou uma abordagem longitudinal, preservando a granularidade anual de todos os registros. Cada linha do *DataFrame* representa o perfil de consumo de um país em um ano específico (unidade país-ano), totalizando 110 instâncias de dados. Essa estrutura permite que o modelo de agrupamento identifique não apenas os perfis de consumo, mas também as trajetórias e transições tecnológicas ao longo da década analisada, servindo como a entrada principal para o algoritmo de clusterização.

3.2. Procedimentos de Análise

A análise dos dados foi dividida em duas grandes frentes, alinhadas aos objetivos específicos da pesquisa. A primeira fase da análise consistiu em uma Análise Exploratória de Dados (AED) para compreender as características fundamentais do *dataset*. Esta etapa teve como objetivo: (i) Identificar tendências temporais (2015-2025) por país; (ii) Comparar o consumo médio entre as regiões pré-definidas (América, Ásia e Europa). A segunda fase, central para responder à questão de pesquisa, foi a aplicação da técnica de agrupamento não supervisionado *K-Means*. A Seleção de Atributos foi realizada com base nos objetivos da pesquisa. Foram selecionados os quatro atributos primários que definem o consumo de *gadgets*: *vendas_smartphones_milhoes*, *envios_laptops_milhoes*, *adocao_consoles_pct* e *penetracao_smartwatch_pct*. Foi necessário realizar a normalização dos Dados, visto que os atributos selecionados possuem escalas distintas (i.e., milhões de unidades versus percentuais), os dados foram normalizados antes de

serem submetidos ao algoritmo. Foi utilizado o *StandardScaler* [Amorim et al. 2023] (*Z-score*), que transforma os dados para que tenham média 0 e desvio padrão 1. Este procedimento é mandatório para o *K-Means* [Sinaga e Yang 2020], pois garante que todos os atributos tenham peso equivalente no cálculo das distâncias euclidianas. Na Determinação do Número Ótimo de *Clusters* (k), a escolha de k não foi trivial, pois as métricas de validação apresentaram resultados conflitantes, uma ocorrência comum em dados do mundo real. Os Índices *Davies-Bouldin* [Davies e Bouldin 1979] (DBI) e *Calinski-Harabasz* [Caliński e Harabasz 1974] (CHI) apresentaram valores que favorecem estruturas com maior número de partições (como $k=7$ e $k=8$), enquanto o Coeficiente de Silhueta (*Silhouette Score*) [Rousseeuw 1987] apontou picos locais e comportamentos marginais estáveis nas soluções intermediárias. A solução com $k=4$ foi selecionada para a análise final. Embora a solução com 5 *clusters* tenha apresentado desempenho semelhante nas métricas internas de validação, optou-se pela configuração com 4 grupos devido à maior clareza dos padrões temporais e à menor fragmentação visual. Essa decisão baseou-se na capacidade de distinguir bem os perfis gerados, produzindo resultados coesos que se alinham diretamente ao objetivo de identificar a evolução e as trajetórias do consumo global ao longo do tempo. Além disso, a análise numérica para $k=4$ mostrou um Coeficiente de Silhueta de 0,23, um Índice *Davies-Bouldin* de 1,33 e um Índice *Calinski-Harabasz* de 32,47. Apesar de os modelos mais detalhados (como $k=7$ e $k=8$) apresentarem indicadores estatísticos diferentes, os valores obtidos para quatro grupos confirmam que essa divisão é adequada e válida para o estudo.

3.3. Interpretação e Visualização dos Resultados

Para garantir a clareza na exposição dos dados e facilitar a interpretação dos padrões identificados, a apresentação dos resultados foi estruturada através dos seguintes instrumentos visuais, cada um com uma finalidade analítica específica: Gráficos de Linha, barras, radar, dispersão e diagramas de fluxo. A utilização de Gráficos de Linha justifica-se pela sua eficiência em demonstrar tendências e padrões, utilizando linhas para indicar a magnitude dos atributos analisados ao longo do tempo [Josyula et al. 2023]. Neste estudo, eles foram empregados para demonstrar a evolução do consumo entre 2015 e 2025, evidenciando trajetórias individuais de crescimento ou declínio para cada nação analisada. Complementarmente, os Gráficos de Barras foram utilizados para realizar comparações regionais, uma vez que o comprimento das barras é proporcional aos atributos medidos, o que facilita a visualização de resumos de dados e o retrato de relações entre diferentes variáveis [Josyula et al. 2023]. Essa técnica permite sumarizar as médias de consumo nos blocos América, Europa e Ásia, tornando evidente a liderança geográfica em cada categoria de *gadget*.

Para a caracterização detalhada dos perfis identificados, utilizou-se o Gráfico de Radar. Este modelo funciona projetando múltiplas variáveis quantitativas em eixos que partem de um ponto central, criando uma forma geométrica que representa o "perfil" único de cada grupo. A escolha por este gráfico justifica-se pela sua capacidade de exibir simultaneamente os quatro atributos de consumo, facilitando o reconhecimento de

"assinaturas" ou perfis multidimensionais de cada *cluster* de maneira intuitiva. Para que a plotagem ocorresse em uma escala comum e comparável, os valores médios dos atributos de cada grupo foram normalizados por meio do *MinMaxScaler* [Amorim et al. 2023], que comprime os dados no intervalo entre 0 e 1 sem distorcer as relações originais entre os pontos. Para validar visualmente a separação e a coesão dos grupos no espaço amostral, aplicou-se a plotagem em Gráfico de Dispersão fundamentada na Análise de Componentes Principais (*PCA*). Segundo [Salih Hasan et al. 2021], essa técnica de redução de dimensionalidade é necessária para mapear atributos de alta dimensão em um plano bidimensional, permitindo observar a proximidade estatística entre os países e confirmar a consistência dos agrupamentos realizados pelo algoritmo *K-Means* [Sinaga e Yang 2020].

Finalmente, introduziu-se o Diagrama de Sankey para mapear as transições temporais dos países entre as partições geradas. Conforme apontam [Gutwin et al. 2023], os diagramas de Sankey destacam-se na representação visual de fluxos direcionados por utilizarem um arranjo linear ordenado da esquerda para a direita, estruturado em eixos verticais sequenciais. No contexto desta pesquisa, as entidades geográficas foram mapeadas ao longo do tempo, em que os nós representam os *clusters* em cada ano específico e as ligações (fitas) indicam os países que transitaram de um perfil para outro entre períodos consecutivos. Adicionalmente, o peso quantitativo do fluxo é codificado diretamente pela espessura das ligações, permitindo mensurar visualmente o volume de nações que efetuaram caminhos idênticos. A adoção da abordagem linear do Sankey justifica-se por sua maior facilidade de leitura e menor exaustão mental quando comparada a *layouts* radiais, proporcionando um referencial familiar que reduz significativamente os erros de interpretação e o tempo de *tracing* visual no rastreamento de trajetórias longitudinais.

3.4. Tecnologias utilizadas

A implementação desta pesquisa foi desenvolvida utilizando a linguagem de programação *Python* (versão 3.10 ou superior), escolhida por ser uma ferramenta versátil e amplamente adotada em estudos que envolvem ciência de dados e aprendizado de máquina. Todo o trabalho foi conduzido dentro do ambiente *Google Colab*, uma plataforma baseada em nuvem que oferece vantagens centrais para este projeto, como a execução interativa de códigos e a facilidade de compartilhamento e reprodução das etapas desenvolvidas. O fluxo de trabalho foi estruturado com o apoio de um ecossistema de bibliotecas fundamentais, iniciando pela *Pandas*, utilizada como base para a manipulação de dados estruturados, o que permitiu a leitura dos arquivos originais, a limpeza de informações inválidas, a tradução de termos e a criação de tabelas dinâmicas (*pivot tables*) de evolução temporal. Complementarmente, a biblioteca *NumPy* foi empregada para dar suporte às operações matemáticas vetoriais e à estruturação lógica e geométrica dos arranjos de dados.

A modelagem analítica e estatística foi conduzida por meio da biblioteca *Scikit-learn* (*sklearn*), ferramenta responsável por operacionalizar os procedimentos centrais do

estudo através de três de seus módulos principais: o *preprocessing*, para a aplicação das técnicas de padronização por escore Z (*StandardScaler*) e normalização em escala comum (*MinMaxScaler*); o *cluster*, para a segmentação das instâncias através do algoritmo *K-Means*; e o *decomposition*, para a redução de dimensionalidade espacial via *Principal Component Analysis (PCA)*. Adicionalmente, o submódulo *metrics* foi essencial para extrair os índices quantitativos de validação dos agrupamentos, computando o Coeficiente de Silhueta (*Silhouette Score*), o Índice *Davies-Bouldin* e o Índice *Calinski-Harabasz*.

Para a comunicação visual e a geração dos resultados gráficos, empregaram-se duas abordagens complementares. A biblioteca *Matplotlib* (módulo *pyplot*) foi utilizada de forma integrada ao estilo *Seaborn-v0_8* para garantir um controle rigoroso sobre a arquitetura estática das imagens, permitindo a construção de grades comparativas para os gráficos de validação, a plotagem do gráfico de radar multidimensional e a visualização da dispersão geométrica bidimensional gerada pelo *PCA*. Dentro desta estrutura, a *Matplotlib* também foi responsável pela implementação do mapeamento hexagonal de densidade (função *Hexbin*), método essencial para evidenciar a concentração das instâncias país-ano e mitigar a sobreposição visual dos pontos no plano. Acoplada a essa visualização espacial, incorporou-se a biblioteca especializada *adjustText*, algoritmo responsável por realizar o ajuste iterativo e automatizado da posição das etiquetas textuais de país-ano, eliminando colisões visuais e garantindo a legibilidade dos rótulos mesmo nos quadrantes de maior densidade de pontos. Por fim, visando a representação dos fluxos dinâmicos longitudinais, incorporou-se a biblioteca *Plotly* (módulo *graph_objects*), ferramenta indispensável para a renderização interativa do Diagrama de Sankey, mapeando as transições de *clusters* e os volumes de caminhos dos países ao longo do tempo. Complementarmente, a biblioteca nativa *Warnings* foi configurada para a filtragem e omissão de alertas futuros do interpretador, garantindo a limpeza do console. A convergência desse conjunto de ferramentas permitiu que todo o fluxo metodológico acontecesse de maneira unificada, assegurando a reprodutibilidade e a integridade analítica da pesquisa.

4. Resultados

A análise revela variações significativas no consumo de tecnologias ao longo do tempo e entre regiões, bem como a emergência de perfis distintos de consumo. Esses achados evidenciam tanto padrões globais quanto comportamentos específicos, posteriormente explorados por meio de técnicas de clusterização.

4.1. Evolução Temporal (2015-2025)

A análise das séries temporais revela mercados dinâmicos com volatilidade acentuada em todas as categorias de produtos. No que se refere às vendas de *smartphones* e aos envios de *laptops*, essas categorias, medidas em milhões de unidades, apresentam comportamentos típicos de mercados de massa. A China demonstrou uma liderança incontestável em volume, ultrapassando a marca de 400 milhões de *smartphones* comercializados em 2017 e 2020.




Figura 2: Evolução Temporal das Vendas de *Smartphones* por País (2015-2025)

No segmento de *laptops*, o país também atingiu patamares expressivos, com volumes superiores a 140 milhões em 2015 e 2024. Já os Estados Unidos apresentaram picos de *laptops* projetados para aproximadamente 80 milhões em 2024, embora tenham enfrentado quedas significativas em períodos intermediários da série histórica.




Figura 3: Evolução Temporal dos Envios de *Laptops* por País (2015-2025)

Quanto à adoção de *smartwatches*, observa-se uma trajetória de crescimento marcada por uma alta instabilidade anual. Coreia do Sul, Estados Unidos e Reino Unido sustentam as maiores taxas ao longo do período analisado, com o mercado da Coreia do Sul atingindo um pico de aproximadamente 24,5% em 2021 e o dos Estados Unidos alcançando quase 25% em 2023. Diferente de um modelo de ascensão linear que parte de níveis muito baixos, países como Brasil e Índia iniciaram o registro em 2015 com índices de adoção já relevantes, situados em 12% e 17%, respectivamente, e mantêm projeções de encerrar o ano de 2025 acima da marca de 10%.




Figura 4: Evolução Temporal da Adoção de *Smartwatches* por País (2015-2025)

Por outro lado, a categoria de consoles de videogame não exibe uma tendência de crescimento universal, sendo impactada por ciclos de consumo bastante voláteis. Em vez de uma média constante e elevada, o mercado é liderado por picos consistentes em países como Canadá e Alemanha, com o Canadá atingindo cerca de 39% de adoção em 2024. O Reino Unido e os Estados Unidos demonstram uma instabilidade notável, alcançando patamares entre 35% e 37% apenas no encerramento do período 2025, após enfrentarem vales críticos abaixo de 10% em anos anteriores, como observado no Reino Unido em 2016 e nos Estados Unidos entre 2022 e 2024. O Japão também registrou uma variabilidade extrema, com seu ápice de 36% em 2016 seguido de quedas acentuadas para 5% em 2021 e 9% em 2024, embora projete uma recuperação para cerca de 29% em 2025. No sentido oposto, a França encerra o período com uma projeção de queda para níveis inferiores a 10% em 2025.




Figura 5: Evolução Temporal da Adoção de Consoles de Videogame por País (2015-2025)

4.2. Comparação Regional do Consumo

Para a análise regional, os dez países foram agrupados em: América (Brasil, Canadá e EUA), Europa (Alemanha, França e Reino Unido) e Ásia (China, Índia, Japão e Coreia

do Sul). As médias de consumo para o período (2015-2025) revelam especializações geográficas distintas (Figuras 6 e 7). No que se refere à venda de *Smartphones* e Envios de *Laptops*, observa-se na Figura 6, que a Europa lidera a média global de vendas de *smartphones* com aproximadamente 280 milhões de unidades anuais, seguida de perto pela Ásia (~275 milhões) e pela América, que apresenta o menor volume médio entre os blocos (~250 milhões). No segmento de *laptops*, a hierarquia se inverte. A região da América detém a liderança com uma média de aproximadamente 88 milhões de envios, superando ligeiramente a Ásia (~87 milhões) e deixando a Europa na terceira posição com cerca de 84 milhões de unidades enviadas.

Já no que se refere à Adoção de Consoles e *Smartwatches*, a análise das taxas percentuais, demonstrada na Figura 7, revela padrões de comportamento de uso diferenciados. A Ásia destaca-se com a maior taxa média de adoção de consoles de videogame, atingindo aproximadamente 23%, enquanto a América registra 22% e a Europa apresenta a menor adoção média (~20%). No mercado de vestíveis (*wearables*), a América consolida sua liderança com uma penetração média de *smartwatches* de 15%. A Europa ocupa a posição intermediária com 14%, enquanto a Ásia apresenta o menor índice médio de penetração entre as três regiões, com aproximadamente 13,5%.

Análise Regional do Consumo Médio de Gadgets (2015-2025)




Figura 6: Comparação Regional das Médias de Vendas de *Smartphones* e *Laptops* (2015-2025)




Figura 7: Comparação Regional das Médias de Adoção de Consoles e Smartwatches (2015-2025)

4.3. Análise de Agrupamento

Para a identificação dos perfis de consumo, utilizou-se o algoritmo *K-Means* com $k=4$ clusters. Esta configuração foi selecionada após a avaliação do Coeficiente de Silhueta e dos índices DBI e CHI, que indicaram uma estrutura de agrupamento coesa e distinta para as 110 instâncias anuais de dados (país-ano). A Tabela 2 apresenta os perfis identificados, em que os valores representam a média das variáveis originais obtidas para cada grupo. Observa-se que o *Cluster 0* concentra os maiores valores médios de envios de *laptops*, com 121,87 milhões de unidades, mantendo índices moderados nas demais variáveis. O *Cluster 1* destaca-se por apresentar um padrão com envios reduzidos de *laptops* e menor adoção de consoles (12,59%), porém sustentando uma adoção intermediária de *smartphones* e *smartwatches*. Por sua vez, o *Cluster 2* exibe a liderança absoluta em vendas de *smartphones*, atingindo a marca expressiva de 426,82 milhões, acompanhada por uma robusta adoção de consoles, embora registre a menor adoção de *smartwatches* (8,47%). Finalmente, o *Cluster 3* destaca-se pelos maiores níveis de adoção de consoles (29,37%) e adoção de *smartwatch* (19,27%), evidenciando um padrão de consumo altamente tecnológico e voltado a dispositivos complementares.

Tabela 2: Perfil Médio dos Clusters Identificados (k=4)

Atributo	Cluster 0	Cluster 1	Cluster 2	Cluster 3
Vendas de <i>Smartphones</i> (milhões)	169,31	218,29	426,82	292,06
Envios de <i>Laptops</i> (milhões)	121,87	55,25	93,09	83,44

Adoção de Consoles (%)	19,72	12,59	27,93	29,37
Adoção de <i>Smartwatch</i> (%)	11,07	16,13	8,47	19,27

Cada nação pôde transitar entre diferentes agrupamentos ao longo do tempo. Para retratar essa distribuição histórica, a Tabela 3 apresenta a Matriz de Evolução Temporal, detalhando a classificação ano a ano de cada país de 2015 a 2025 e evidenciando a volatilidade dos mercados de *gadgets*.

Tabela 3: Matriz de Evolução Temporal dos *Clusters* (2015-2025)

País	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024	2025
Brasil	2	1	1	0	1	3	3	0	1	1	2
Canadá	0	1	3	3	2	0	2	0	3	3	0
China	0	0	2	2	0	2	0	1	3	0	1
França	1	1	1	3	3	2	0	1	0	0	1
Alemanha	2	2	1	0	2	3	3	1	3	1	0
Índia	3	2	1	0	0	3	3	1	3	3	0
Japão	3	3	2	2	1	2	1	2	0	1	3
Coreia do sul	3	1	3	3	0	2	1	2	2	3	1
Reino Unido	2	1	0	2	1	2	1	0	1	3	2
Estados Unidos	0	1	1	0	0	3	3	1	1	1	3

4.4. Caracterização e Validação dos Perfis Globais

A análise visual, por meio do gráfico de radar (Figura 8) e da projeção em *PCA* (Figura 8), permite uma comparação integrada das dimensões de consumo, ilustrando as diferenças entre os grupos identificados. O gráfico de radar (Figura 8) facilita a visualização do perfil de cada *cluster* ao representar, em um único plano, os diferentes atributos de consumo. Cada eixo corresponde a uma variável, e quanto mais distante do centro, maior o valor médio daquele atributo. Dessa forma, é possível perceber visualmente quais dimensões se destacam em cada grupo. Essa visualização complementa

os valores apresentados na Tabela 2, permitindo uma comparação mais intuitiva entre os *clusters*.

Para facilitar a interpretação dos resultados, foram atribuídas denominações aos *clusters* identificados pelo algoritmo *K-Means*. Essas denominações possuem caráter interpretativo e foram definidas com base nos padrões médios observados nas variáveis analisadas, não representando categorias absolutas ou classificações formais dos mercados estudados. O *Cluster 0*, denominado Perfil Orientado a Produtividade e Entretenimento, concentra países em anos específicos nos quais há uma forte demanda por computadores pessoais, superando as demais categorias de *gadgets* e indicando um mercado focado em atividades profissionais ou educacionais. O *Cluster 1*, designado como Perfil de Liderança em Mobilidade, reflete momentos de mercado altamente voltados para o uso prático de relógios inteligentes e *smartphones*, registrando uma presença contida e estratégica de consoles e *laptops*. O *Cluster 2*, definido como Padrão de Consumo Massivo de Dispositivos Móveis, espelha os picos de volumetria comercial e populacional, impulsionado por recordes absolutos de vendas de *smartphones* e forte inserção de consoles, embora apresente a menor adoção proporcional de *smartwatches*. Por fim, o *Cluster 3*, caracterizado como Perfil de Entretenimento Avançado e Ecossistema Integrado, consolida os cenários de maior maturidade tecnológica e valor agregado, liderando simultaneamente na adoção de consoles de videogame e relógios inteligentes, amparado por um consumo expressivo e robusto de *smartphones*.

A Figura 9 apresenta a projeção dos dados em duas dimensões por meio do *PCA*, que reduz a complexidade dos dados originais mantendo a maior parte da variação. Nesse gráfico, cada ponto representa o registro de um país em um ano específico (instância país-ano), e a proximidade entre os pontos indica similaridade nos padrões de consumo naquele período. Assim, observações posicionadas próximas tendem a apresentar comportamentos semelhantes, enquanto pontos mais distantes indicam perfis distintos. Essa visualização permite observar, de forma dinâmica e intuitiva, a separação entre os grupos identificados pelo algoritmo de clusterização, validando a partição matemática desses quatro grupos e confirmando a consistência do algoritmo *K-Means* na ausência de sobreposições críticas. Como um mesmo país possui múltiplos pontos ao longo da série temporal, a distribuição espacial no *PCA* comprova visualmente a capacidade do modelo de rastrear deslocamentos comportamentais temporais.

Comparação de Perfis de Consumo por Cluster (Dados Anuais)




Figura 8: Gráfico de Radar: Comparação Multidimensional dos Perfis de Consumo por Cluster

De forma complementar, o diagrama de Sankey apresentado na Figura 10 evidencia que os países não permanecem associados a um mesmo perfil de consumo ao longo do período analisado. A representação das transições entre 2015 e 2025 demonstra que parte das nações manteve sua classificação original, enquanto outras migraram para diferentes clusters, refletindo mudanças em seus padrões de consumo de dispositivos tecnológicos. Observa-se, por exemplo, que países inicialmente classificados no Cluster 0 (Produtividade) passaram a integrar os clusters Mobilidade e Ecossistema Integrado, enquanto países pertencentes aos clusters Consumo Massivo e Ecossistema Integrado também apresentaram redistribuições entre os diferentes perfis. Essas mudanças indicam que a evolução do mercado de gadgets é dinâmica e influenciada por transformações econômicas, tecnológicas e comportamentais, tornando inadequada uma classificação estática dos países. Ao sintetizar as trajetórias de alguns países entre os extremos da série temporal, a Figura 10 facilita a visualização dessas mudanças estruturais e reforça a interpretação de que os perfis identificados representam estados transitórios, e não características permanentes das economias analisadas.




Figura 9: Visualização dos *Clusters* através da Análise de Componentes Principais (PCA)




Figura 10. Transição de alguns países nos *clusters* 2015-2025

5. Discussão

A jornada pelos dados do mercado global de *gadgets* entre 2015 e 2025 revela uma estrutura de consumo que ignora distâncias físicas para se concentrar em afinidades comportamentais. Ao observar os padrões que emergem desse período a partir das análises iniciais de evolução temporal e de comparação regional, nota-se que as abordagens exploratórias tradicionais conseguem mapear os volumes macro das variáveis, mas não são suficientes para detalhar as nuances dinâmicas do setor. Foi preciso ir além e utilizar a combinação de métodos com a clusterização e as ferramentas visuais do Gráfico de Radar, do *PCA* e do Diagrama de Sankey para que a realidade dos dados se organizasse de forma clara. A partir do desenho desses perfis, o de Liderança em Mobilidade (*Cluster 1*) aproxima o comportamento anual de países como o Brasil e o Reino Unido em um ritmo acelerado de uso de novas tecnologias, focado em *smartphones* e relógios inteligentes. Essa convergência sugere a força de uma forte relação com a conectividade diária, em que o dispositivo atuaria de forma prática na rotina dos usuários, independentemente de barreiras geográficas. Em paralelo, o grupo voltado ao Perfil Orientado a Produtividade e Entretenimento (*Cluster 0*) reúne observações de países como Japão, China, Índia, Alemanha e França, onde os computadores pessoais mantêm um papel mais funcional e estável na demanda por *hardware*. Por outro lado, as análises espaciais revelam o Padrão de Consumo Massivo de Dispositivos Móveis (*Cluster 2*) que apresenta uma dinâmica distinta, indicando mercados que focam na volumetria de aparelhos primários, mas registram menor adesão a periféricos complementares, enquanto o Perfil de Entretenimento Avançado e Ecossistema Integrado (*Cluster 3*) consolida os cenários de maior uso conjunto de consoles e vestíveis.

Essa organização dos dados encontra um suporte na literatura acadêmica, especialmente quando confrontada com o que [\[Malhotra et al. 2022\]](#) descrevem sobre o atendimento de necessidades funcionais e relacionais com a tecnologia. No grupo focado em mobilidade, a alta taxa de adoção de *gadgets* reforça a ideia de que esses aparelhos deixaram de ser ferramentas isoladas para se tornarem componentes ativos da própria identidade e do cotidiano, atuando como extensões práticas de comunicação. Da mesma forma, as variações e transições temporais de interesse capturadas ao longo dos anos pelo fluxo do diagrama de Sankey e pela densidade do mapeamento hexagonal no *PCA* podem ser compreendidas e complementadas através da visão longitudinal de [\[Visuri et al. 2021\]](#). Os autores apontam que o comportamento e os estilos de uso dos consumidores em relação a dispositivos vestíveis evoluem e se transformam organicamente com o tempo para se adaptar às capacidades tecnológicas, o que ajuda a explicar por que os registros anuais dos países flutuam e se deslocam entre os grupos ao longo da década. O fato de termos utilizado métodos não supervisionados combinados para enxergar esses grupos, seguindo a lógica de mapeamento comportamental sugerida por [\[Kutz e Senefonte 2025\]](#),

foi o que permitiu separar essas nuances de transição, mostrando que olhar apenas de forma isolada para a localização geográfica ou para estatísticas agregadas convencionais não seria suficiente para entender a real diversidade e a volatilidade de cada mercado.

Um diferencial relevante deste estudo está na escolha de olhar para o cenário internacional de forma integrada, utilizando os registros anuais dos países como peças centrais da análise em vez de focar apenas em usuários ou marcas específicas, oferecendo uma perspectiva macroeconômica abrangente na literatura de *gadgets*. Essa perspectiva permite enxergar a distribuição dos aparelhos de uma forma mais ampla, embora o caminho tenha revelado desafios metodológicos importantes que foram superados pelo suporte visual dos gráficos. No gráfico de radar, foi possível enxergar claramente o formato de cada perfil, mostrando como o centroide de mobilidade puxa a linha para o eixo de celulares e vestíveis enquanto o de produtividade se estica para os *laptops*. Já o gráfico de *PCA* demonstrou a separação física do modelo, projetando os pontos país-ano em duas dimensões onde o mapeamento em formato hexagonal coloriu as áreas mais densas, provando em quais perfis o comportamento de consumo de cada nação caiu geograficamente a cada ano. Por fim, o diagrama de Sankey funcionou como o mapa de conexão dessas definições ao longo do tempo, ilustrando como um país deixa de preencher os requisitos de um grupo e passa a adotar a assinatura numérica de outro de um período para o seguinte. Esse comportamento dinâmico capturado demonstra que nenhuma nação permanece fixada em um único perfil permanente ao longo dos onze anos coletados, expondo a flexibilidade das trajetórias de consumo. Além disso, os resultados baseados em volumes puros de vendas devem considerar as limitações de representatividade do *dataset* original do *Kaggle*, que possui possíveis ruídos de coleta primária. Somado a isso, a decisão de não incluir os dados sobre a adoção do 5G e o volume de lixo eletrônico foi um passo necessário devido às inconsistências encontradas nas fontes originais, o que acabou limitando a discussão sobre a infraestrutura de rede e o impacto ambiental do consumo tecnológico no cenário atual.

Ainda assim, os perfis encontrados entregam um mapa estratégico valioso para compreender as tendências do setor. Como bem observam [\[Neves et al. 2024\]](#) ao discutirem a aplicação de inteligência de dados e análise preditiva para antecipar cenários competitivos, o tratamento analítico correto das informações é o que apoia o desenvolvimento de estratégias corporativas e de mercado eficientes. Ter a clareza de que o comportamento de consumo em determinados períodos compartilha mais semelhanças entre mercados distintos do que com nações vizinhas baseadas apenas em proximidade regional permite que marcas e pesquisadores ajustem sua mira analítica. Em vez de desperdiçar recursos com campanhas genéricas, os resultados sugerem que o caminho para o sucesso está em entender essas afinidades globais, tratando cada grupo de acordo com sua verdadeira relação com a tecnologia e a inovação.

6. Conclusão

Esta pesquisa ofereceu uma visão dos padrões de consumo de tecnologias vestíveis e dispositivos pessoais observados na base analisada para o período de 2015 a 2025. Ao combinar análise exploratória e técnicas de aprendizado de máquina não supervisionadas, identificou-se que o uso de gadgets na base analisada não se distribui de forma homogênea entre os países, mas se organiza em padrões de comportamento que transcendem agrupamentos geográficos tradicionais. O algoritmo *K-Means* revelou quatro grupos distintos através de registros anuais dinâmicos, destacando perfis focados em liderança em mobilidade, aproximando o comportamento temporal de nações como Brasil e Reino Unido, em produtividade, em consumo massivo por volume e em entretenimento avançado. Os resultados sugerem que, no conjunto de dados analisado, existe uma tendência de crescente integração desses dispositivos ao cotidiano dos consumidores, como ferramentas úteis e extensões da conexão pessoal.

A Análise de Componentes Principais (*PCA*) atuou como suporte visual e estatístico na redução da dimensionalidade dos dados, permitindo compreender a dispersão geométrica e a densidade dos registros sem a perda das informações essenciais fornecidas pelas variáveis de consumo originais. Em síntese, o estudo alcança seu objetivo ao identificar padrões de consumo de gadgets nos países presentes na base analisada, oferecendo subsídios para a compreensão desses comportamentos e para o desenvolvimento de estudos futuros com bases de dados mais abrangentes. Apesar dos resultados obtidos, o trabalho apresenta limitações que abrem espaço para pesquisas futuras. Como limitações explícitas, a base de dados utilizada possui escopo limitado, tanto em número de países quanto em variáveis, o que pode impactar a representatividade dos resultados frente à totalidade do mercado internacional. Adicionalmente, a base utilizada possui natureza sintética, tendo sido construída a partir de tendências observadas em relatórios de mercado. Dessa forma, os resultados devem ser interpretados como evidências exploratórias, e não como uma representação exata do mercado global. Outro ponto relevante refere-se à sensibilidade do algoritmo *K-Means* à escolha do número de *clusters* e à escala das variáveis, o que tendeu a gerar zonas de fronteira na classificação de instâncias anuais específicas.

Como continuidade para essas pesquisas futuras, sugere-se ampliar a amostra para incluir mais países em desenvolvimento, possibilitando uma análise mais abrangente das desigualdades digitais, especialmente no Hemisfério Sul. Além disso, a incorporação de variáveis contextuais, como aspectos culturais e educacionais, pode contribuir para uma melhor explicação dos perfis identificados. Também se destaca a possibilidade de aplicar modelos preditivos para estimar a adoção de novas tecnologias, como dispositivos de realidade aumentada e soluções de *IoT* doméstica. Por fim, recomenda-se investigar o impacto ambiental do consumo de *gadgets*, incorporando variáveis como a geração de lixo eletrônico, com vistas ao desenvolvimento de abordagens alinhadas à economia circular.

7. Referências Bibliográficas

IDC (2025). "Wearable vendor". Disponível em:

<https://www.idc.com/promo/wearablevendor/>. Acesso em: 15 de abril de 2026.

Hsiao, Kuo-Lun e Chen, Chia-Chen (2018). "What drives smartwatch purchase intention? Perspectives from hardware, software, design, and value". *Telematics and Informatics*, v. 35, n. 1, p. 103-113. DOI: <https://doi.org/10.1016/j.tele.2017.10.002>.

Zacour, Jose Eduardo de Moura Castro et al. (2022). "Prontidão e Aceitação de Dispositivos Vestíveis Para Cuidados Com a Saúde". In: *Anais do XLVI Encontro da ANPAD - EnANPAD*. On-line: ANPAD. Disponível em: <https://anpad.org.br/>.

Yang, Luyao, Amin, Osama and Shihada, Basem (2024). "Intelligent Wearable Systems: Opportunities and Challenges in Health and Sports". *ACM Computing Surveys*, vol. 56, no. 7, art. 190, pp. 1-42. DOI: <https://doi.org/10.1145/3648469>.

Shang, Xiaoyun (2024). "The Current Status and Future Trends of Wearable Devices". *Applied and Computational Engineering*, v. 120, p. 98-104. DOI: <https://doi.org/10.54254/2755-2721/2025.18829>.

Rao, A. S., Vardhan, B. V. e Shaik, H. (2021). "Role of Exploratory Data Analysis in Data Science". In: *Proceedings of the 2021 6th International Conference on Communication and Electronics Systems (ICCES)*, Coimbatre, India, p. 1457-1461. DOI: <https://doi.org/10.1109/ICCES51350.2021.9488986>.

Li, T. et al. (2022). "Smartphone App Usage Analysis: Datasets, Methods, and Applications". *IEEE Communications Surveys & Tutorials*, vol. 24, no. 2, pp. 937-966. DOI: <https://doi.org/10.1109/COMST.2022.3163176>.

Queiroz, Virginia, Furtado, Lara Sucupira e Pinheiro, Vlândia Celia (2023). "Aplicando algoritmos de clusterização para encontrar inconsistências em bases de dados fiscais". In: *Anais do II Brazilian Workshop on Artificial Intelligence in Finance (BWAIF)*. Porto Alegre: SBC, p. 120–131. DOI: <https://doi.org/10.5753/bwaif.2023.230762>.

Ling, L. S. e Weiling, C. T. (2025). "Enhancing Segmentation: A Comparative Study of Clustering Methods". *IEEE Access*, vol. 13, pp. 47418-47439. DOI: <https://doi.org/10.1109/ACCESS.2025.3550339>.

Sinaga, K. P. e Yang, M.-S. (2020). "Unsupervised K-Means Clustering Algorithm". *IEEE Access*, vol. 8, pp. 80716-80727. DOI: <https://doi.org/10.1109/ACCESS.2020.2988796>.

Vitório, Marcelo, Barcellos, Raissa, Bernardini, Flávia e Viterbo, José (2021). "Uma ferramenta móvel para recomendação de visualização de dados abertos municipais". In: Anais do IX Latin American Symposium on Digital Government (LASDIGOV) / Workshop de Computação Aplicada em Governo Eletrônico (WCGE). Porto Alegre: SBC, p. 95-106. DOI: <https://doi.org/10.5753/wcge.2021.15980>.

Salih Hasan, Basna Mohammed e Abdulazeez, Adnan Mohsin (2021). "A Review of Principal Component Analysis Algorithm for Dimensionality Reduction". Journal of Soft Computing and Data Mining, v. 2, n. 1, p. 20–30. Disponível em: <https://penerbit.uthm.edu.my/ojs/index.php/jscdm/article/view/8032>.

Ometov, A. et al. (2021). "A Survey on Wearable Technology: History, State-of-the-Art and Current Challenges". Computer Networks, v. 193, art. 108074. DOI: <https://doi.org/10.1016/j.comnet.2021.108074>.

Valencia-Arias, A. et al. (2023). "Smart home adoption factors: A systematic literature review and research agenda". PLoS ONE, vol. 18, no. 10, art. e0292558. DOI: <https://doi.org/10.1371/journal.pone.0292558>.

Julianingsih, D. et al. (2021). "Utilization of Gadget Technology as a Learning Media". IAIC Transactions on Sustainable Digital Innovation (ITSDI), v. 3, n. 1, p. 43-45. DOI: <https://doi.org/10.34306/itsdi.v3i1.522>

Neves, Ana Paula Zanetti, Zilber, Silvia Novaes e Lopes, Evandro Luiz (2024). "The Power of Big Data Analytics for the Competitive Performance of Digital Startups in an Emerging Economy". International Journal of Business and Management, v. 19, n. 5, p. 254. DOI: <https://doi.org/10.5539/ijbm.v19n5p254>.

Malhotra, Suzanee, Chaudhary, Kiran e Alam, Mansaf (2022). "Modeling the use of voice-based assistant devices (VBADs): A machine learning-based exploratory study using cluster analysis and correspondence analysis". International Journal of Information Management Data Insights, v. 2, n. 1, art. 100069. DOI: <https://doi.org/10.1016/j.jjime.2022.100069>.

Kutz, Ewerthon J. e Senefonte, Helen C. M. (2025). "Mapeando perfis de consumidores de e-commerce com RFM e K-means". In: Anais do IX Workshop de Computação Urbana (CoUrb). Porto Alegre: SBC, p. 99–112. DOI: <https://doi.org/10.5753/courb.2025.8768>.

Visuri, A. et al. (2021). "Understanding usage style transformation during long-term smartwatch use". Personal and Ubiquitous Computing, v. 25. DOI: <https://doi.org/10.1007/s00779-020-01511-2>.

- Amorim, L. B. V. de, Cavalcanti, G. D. C. e Cruz, R. M. O. (2023). "The choice of scaling technique matters for classification performance". *Applied Soft Computing*, v. 133, art. 109924. DOI: <https://doi.org/10.1016/j.asoc.2022.109924>.
- Davies, D. e Bouldin, D. (1979). "A Cluster Separation Measure". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. PAMI-1, n. 2, p. 224-227. DOI: <https://doi.org/10.1109/TPAMI.1979.4766909>.
- Calinski, T. e Harabasz, J. (1974). "A Dendrite Method for Cluster Analysis". *Communications in Statistics - Theory and Methods*, v. 3, n. 1, p. 1-27. DOI: <https://doi.org/10.1080/03610927408827101>.
- Rousseeuw, P. J. (1987). "Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis". *Journal of Computational and Applied Mathematics*, v. 20, p. 53-65. DOI: [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7).
- Josyula, H. et al. (2023). "A Review on Data Visualization for Exploratory Data Analysis". *Zenodo*, v. 38, p. 487-494. DOI: <https://doi.org/10.5281/zenodo.777730>.
- Gutwin, C., Mairena, A. e Bandi, V. (2023). "Showing Flow: Comparing Usability of Chord and Sankey Diagrams". In: *Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems (CHI '23)*. New York: ACM, art. 825, p. 1–10. DOI: <https://doi.org/10.1145/3544548.3581119>.
- SOUNDANKAR, Atharva. **Global tech gadget consumption data 2015–2025**. Versão 1. Kaggle, 2025. Disponível em: <https://www.kaggle.com/datasets/atharvasoundankar/global-tech-gadget-consumption-data-2015-2025>. Acesso em: 1 jan. 2025.
- Wang, Y., Kung, L. e Byrd, T. (2018). "Big data analytics: Understanding its capabilities and potential benefits for healthcare organizations". *Technological Forecasting and Social Change*, v. 126, p. 3-13. DOI: <https://doi.org/10.1016/j.techfore.2015.12.019>.
- MIT Sloan Review Brasil (2024). "Análise de dados". MIT Sloan Management Review Brasil. Disponível em: <https://mitsloanreview.com.br/analise-de-dados/>.
- Sarker, I. H. (2021). "Data Science and Analytics: An Overview from Data-Driven Smart Perspectives". *SN Computer Science*, v. 2, n. 5, art. 377. DOI: <https://doi.org/10.1007/s42979-021-00765-8>.
- Houtmeyers, K. C., Jaspers, A. e Figueiredo, P. (2021). "Managing the Training Process in Elite Sports: From Descriptive to Prescriptive Data Analytics". *International Journal*

of Sports Physiology and Performance, v. 16, n. 11, p. 1719-1723. DOI:
<https://doi.org/10.1123/ijsp.2020-0958>.