

**Análise da pandemia da
Covid-19 a partir de dados
públicos: estudo
comparativo entre Brasil e
mundo com base em
datasets oficiais**

**Anna Carolina Mendonça Mello das Neves
Juliana Baptista dos Santos França**

NCE - 04/25

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
INSTITUTO TERCIO PACCITI DE APLICAÇÕES E PESQUISAS COMPUTACIONAIS

ANÁLISE DA PANDEMIA DA COVID-19 A PARTIR DE DADOS PÚBLICOS:
Estudo comparativo entre Brasil e mundo com base em datasets oficiais

Anna Carolina Mendonça Mello das Neves
Juliana Baptista dos Santos França

Rio de Janeiro
2025

EQUIPE TÉCNICA:

Organizadora:

Anna Carolina Mendonça Mello das Neves - (Graduanda em Ciências Matemáticas e da Terra/UFRJ)

Coordenadora:

Juliana Baptista dos Santos França
- Instituto de Computação (IC/UFRJ)

RESUMO

Este relatório técnico tem como objetivo analisar dados públicos sobre a pandemia de COVID-19, com foco comparativo entre o Brasil e o cenário mundial. A pesquisa parte de uma curadoria inicial de fontes abertas, priorizando conjuntos de dados robustos e confiáveis, como o Brasil.IO e o WHO Data Portal. A partir desses dados, foram realizadas análises separadas do contexto nacional e internacional, e em seguida, uma comparação estruturada entre os principais indicadores epidemiológicos. A motivação do estudo reside na importância da transparência e acessibilidade dos dados públicos, bem como na necessidade de compreender os padrões de evolução da pandemia, suas desigualdades regionais e os efeitos da vacinação. A análise contempla aspectos como evolução temporal, taxa de mortalidade, impacto proporcional à população e cobertura vacinal, contribuindo para o entendimento da pandemia em múltiplas escalas e reforçando o papel da ciência de dados na saúde pública.

Palavras-chave: COVID-19; dados públicos; Brasil.IO; WHO; comparação Brasil x Mundo; saúde pública; análise epidemiológica

ABSTRACT

This technical report aims to analyze public data on the COVID-19 pandemic, focusing on a comparative perspective between Brazil and the global context. The research begins with a preliminary curation of open sources, prioritizing robust and reliable data sets such as Brazil.IO and the WHO Data Portal. Based on these datasets, separate analyses of national and international scenarios were conducted, followed by a structured comparison of key epidemiological indicators. The motivation for this study lies in the importance of data transparency and accessibility, as well as the need to understand the pandemic's progression patterns, regional inequalities, and the effects of vaccination strategies. The analysis covers aspects such as temporal evolution, mortality rate, population-adjusted impact, and vaccination coverage, contributing to a broader understanding of the pandemic and reinforcing the role of data science in public health.

Keywords: COVID-19; public data; Brazil.IO; WHO; Brazil vs World comparison; public health; epidemiological analysis

SUMÁRIO

1	INTRODUÇÃO.....	5
2	METODOLOGIA E DADOS UTILIZADOS.....	6
	2.1 CURADORIA DE DADOS PÚBLICOS.....	6
	2.2 ESCOLHA DOS DATASETS.....	6
	2.3 TABELAS UTILIZADAS.....	6
	2.4 PERGUNTAS QUE ORIENTAM AS ANÁLISES.....	9
	2.5 O QUE SE ESPERA DAS ANÁLISES.....	9
3	ANÁLISE DOS DADOS DO BRASIL.....	10
	3.1 CÓDIGO E GRÁFICOS.....	10
	3.2 INTERPRETAÇÃO DOS RESULTADOS.....	27
4	ANÁLISE DOS DADOS DO MUNDO.....	28
	4.1 CÓDIGO E GRÁFICOS.....	28
	4.2 INTERPRETAÇÃO DOS RESULTADOS.....	42
5	COMPARAÇÃO BRASIL X MUNDO.....	48
	5.1 CÓDIGO E GRÁFICOS.....	48
	5.2 INTERPRETAÇÃO DOS RESULTADOS.....	50
6	CONSIDERAÇÕES FINAIS.....	53
	REFERÊNCIAS.....	55

1 INTRODUÇÃO

O uso de dados públicos tem se tornado cada vez mais relevante em projetos de análise e pesquisa, especialmente pela transparência, acessibilidade e potencial de aplicação em diferentes áreas. Este trabalho surgiu a partir da proposta de encontrar e explorar essas bases abertas, entendendo como são estruturadas, quem as disponibiliza e quais possibilidades analíticas oferecem.

A etapa inicial consistiu em mapear diversas fontes de dados públicos, nacionais e internacionais, avaliando formatos, profundidade das informações e confiabilidade. Entre os conjuntos identificados, destacaram-se dois relacionados à pandemia de COVID-19: o Brasil.IO, com dados detalhados do cenário nacional, e o WHO Data Portal, que reúne indicadores globais padronizados. A robustez e a complementaridade dessas fontes motivaram a escolha do tema.

Com base nesses datasets, o projeto passou a focar na análise da pandemia em duas escalas: Brasil e mundo. Esta escolha permitiu observar padrões, diferenças regionais e características específicas de cada contexto. A partir dessas análises individuais, foi possível estruturar uma comparação entre os principais indicadores epidemiológicos, oferecendo uma visão integrada da evolução da COVID-19.

2 METODOLOGIA E DADOS UTILIZADOS

2.1 Curadoria dos Dados Públicos

A primeira etapa do projeto consistiu em uma busca por datasets públicos, com o objetivo de entender quais dados estão disponíveis, quem os fornece, em que formatos são distribuídos e qual o grau de profundidade de cada fonte. Foram consultadas plataformas nacionais e internacionais, priorizando aquelas que oferecem dados abertos, estruturados e com potencial analítico.

A curadoria envolveu a organização dos datasets em uma tabela geral, contendo nome da fonte, link de acesso, descrição, tema e tipo de arquivo. Essa etapa permitiu mapear o ecossistema de dados públicos disponíveis para análise, com destaque para áreas como saúde, educação, meio ambiente e economia.

2.2 Escolha dos Datasets

Após a curadoria inicial, foram selecionados dois conjuntos de dados sobre a pandemia de COVID-19, por apresentarem robustez, confiabilidade e estrutura adequada para análises comparativas:

- Brasil.IO – COVID-19: Dados por município e por dia, com registros de casos e óbitos coletados das secretarias estaduais. Permite análise temporal e regional detalhada.
- WHO Data Portal – COVID-19: Dados globais organizados por país, com indicadores padronizados sobre casos, óbitos e vacinação. Ideal para comparações internacionais e análise de políticas públicas.

A escolha desses conjuntos de dados ocorreu devido à complementaridade entre o nível de detalhamento nacional e a abrangência internacional, o que permitiu uma análise integrada da pandemia.

2.3 Tabelas Utilizadas

Duas tabelas principais foram utilizadas (Tabela 1 e Tabela 2).

Tabela 1: Tabela Geral – Datasets Públicos: Lista com diversas fontes abertas, incluindo Brasil.IO, Base dos Dados, IBGE, IPEA, WHO, World Bank, entre outras.

DATASET	LINK	DESCRIÇÃO	TIPO
Brasil.IO	https://brasil.io/datasets/	Dados públicos organizados por voluntários: COVID-19, eleições, educação, etc.	CSV
Base dos Dados – Pesquisa	https://basedosdados.org/search	Plataforma que organiza e trata dados públicos acessíveis.	CSV, SQL

BNDES	https://dadosabertos.bnDES.gov.br/datas-et/	Informações sobre financiamentos e apoio a empresas e projetos pelo BNDES.	CSV, PDF
IPEA	https://www.ipea.gov.br/portal/dados-abertos	Indicadores sociais e econômicos, séries históricas e estudos.	XLS, CSV
IBGE	https://dados.gov.br/dados/organizacoes/visualizar/instituto-brasileiro-de-geografia-e-estatistica-ibge	Dados sobre população, território, economia, educação, saúde.	XLS, CSV
Ministério da Educação	https://dados.gov.br/dados/organizacoes/visualizar/ministerio-da-educacao	Dados sobre programas educacionais, instituições e desempenho.	CSV
Microdados do Censo Escolar – INEP	https://www.gov.br/inep/pt-br/aceso-a-informacao/dados-abertos/microdados/cento-escolar	Dados detalhados sobre escolas, alunos, professores e estrutura.	CSV
Ministério da Agricultura e Pecuária	https://dados.gov.br/dados/organizacoes/visualizar/ministerio-da-agricultura-e-pecuaria	Dados sobre produção agrícola, inspeção, políticas e exportações.	CSV
MMA – Dados Ambientais	https://dados.mma.gov.br/dataset	Conjuntos de dados ambientais sobre fauna, flora, unidades de conservação e clima.	CSV, PDF, ZIP, SHP
ANVISA	https://dados.gov.br/dados/organizacoes/visualizar/agencia-nacional-de-vigilancia-sanitaria-anvisa	Dados sobre medicamentos, alimentos, cosméticos e autorizações sanitárias.	CSV
Cadastro Nacional da Pessoa Jurídica (CNPJ)	https://dados.gov.br/dados/conjuntos-dados/cadastro-nacional-da-pessoa-juridica---cnpj	Lista oficial de empresas registradas no Brasil, com dados de identificação e atividade econômica.	CSV
DATASUS	https://brasil.io/dataset/covid19/caso	Dados sobre casos de COVID-19, internações, óbitos e vacinação no Brasil.	CSV
Ministério do Meio Ambiente	https://dados.gov.br/dados/organizacoes/visualizar/ministerio-do-meio-ambiente-e-mudanca-do-clima	Dados sobre biodiversidade, licenciamento, áreas protegidas e mudanças climáticas.	CSV
Terrabrasilis – INPE	https://terrabrasis.dpi.inpe.br/geonetwor k/srv/eng/catalog.search#/metadata/a5220c18-f7fa-4e3e-b39b-feeb3ccc4830	Dados geoespaciais sobre desmatamento na Amazônia, com mapas e séries temporais.	PDF, SHP
CETESB – Dados Ambientais SP	https://cetesb.sp.gov.br/catalogo-de-dados-abertos/	Monitoramento ambiental do estado de São Paulo: ar, água, resíduos e licenciamento.	CSV
WHO Data Portal	https://data.who.int/	Portal com dados da OMS sobre saúde pública, doenças e políticas globais.	CSV, XLSX
UCDP – Uppsala	https://ucdp.uu.se/	Dados sobre conflitos armados, guerras e violência política no	XLSX, CSV

Conflict Data Program		mundo.	
Data360 – Banco Mundial	https://data360.worldbank.org	Visualizações e indicadores sobre desenvolvimento humano e econômico global.	CSV
World Bank Data Catalog	https://datacatalog.worldbank.org/search?q=&sort=last_updated_date%20desc	Catálogo de dados do Banco Mundial sobre países, setores e políticas.	CSV, XLS
Data Europa	https://data.europa.eu/en	Portal de dados abertos da União Europeia com temas variados.	CSV, JSON, XLSX
AWS	https://registry.opendata.aws/	Conjuntos de dados hospedados na nuvem da Amazon, incluindo clima, genômica e transporte.	CSV, JSON, GeoTIFF
Amazon Sales	https://www.kaggle.com/datasets/karkavelrajai/amazon-sales-dataset	Dados de vendas da Amazon com categorias, preços e avaliações.	CSV
Tesla	https://www.kaggle.com/datasets/abhimanu/neuki/tesla-inc-tsla-dataset	Dados financeiros da Tesla: ações, produção, desempenho.	CSV
Netflix	https://www.kaggle.com/datasets/shivamb/netflix-shows	Lista de filmes e séries da Netflix com gênero, país e data de lançamento.	CSV
Spotify	https://www.kaggle.com/datasets/abdulzz/spotify-most-streamed-songs	Faixas mais tocadas com atributos musicais e popularidade.	CSV

Tabela 2: Tabela COVID – Brasil x Mundo: Tabela reduzida com foco nos datasets selecionados, contendo links diretos, descrição dos dados e formatos disponíveis.

Dataset	Link	Descrição	Tipo
Brasil.IO	https://brasil.io/dataset/covid19/caso/	Casos e óbitos por município e por dia, coletados das secretarias estaduais. Permite análise temporal e regional detalhada.	CSV
Ministério da Saúde – Painel COVID	https://www.gov.br/saude/pt-br/composicao/seidigi/demas/covid19	Portal institucional com dados oficiais sobre vacinação, doses aplicadas e cobertura vacinal no Brasil, por UF e por tipo de vacina.	XLSX, HTML
Painel Interativo – Vacinação COVID	https://infoms.saude.gov.br/extensions/SEIDIGI_DEMAS_VACINACAO_MENU_COVID/SEIDIGI_DEMAS_VACINACAO_MENU_COVID.html	Painel interativo com visualizações e dados detalhados sobre vacinação contra COVID-19, incluindo bivalente, monovalente e doses por faixa etária e região.	XLSX, HTML
WHO Data	https://data.who.int/dashboards/covid19/data?n=o	Dados globais sobre casos, óbitos e indicadores de saúde por país. Ideal para	CSV, XLSX

Portal – COVID-19		comparações internacionais e análise de políticas públicas.	
-------------------	--	---	--

2.4 Perguntas que orientam as análises

As análises foram guiadas por cinco perguntas principais, aplicadas tanto ao cenário nacional quanto ao internacional:

1. Como evoluíram os casos ao longo do tempo?
2. Qual é o impacto proporcional à população?
3. Como se comporta a taxa de mortalidade?
4. Qual foi a cobertura vacinal ao longo do tempo?
5. Quais desigualdades regionais podem ser observadas?

2.5 O que se espera das análises

A análise dos dados da COVID-19 no Brasil e no mundo tem como objetivo compreender a evolução da pandemia em diferentes contextos, considerando aspectos regionais, temporais e estruturais. Espera-se identificar padrões de contágio e mortalidade, avaliar os dados públicos e entender como diferentes países responderam à crise.

Ao comparar os dados nacionais com os internacionais, será possível observar semelhanças e contrastes entre as estratégias adotadas, os impactos sociais e a evolução dos indicadores ao longo do tempo.

O resultado esperado é um conjunto de insights que contribua para o entendimento da pandemia e que possa ser útil em discussões sobre políticas públicas, prevenção e preparação para eventos semelhantes.

3 ANÁLISE DOS DADOS DO BRASIL

3.1 Códigos e Gráficos

3.1.1 Códigos Iniciais

```
import pandas as pd
import matplotlib.pyplot as plt

df_boletim = pd.read_csv('/content/boletim.csv')
df_caso = pd.read_csv('/content/caso.csv')
df_caso_full = pd.read_csv('/content/caso_full.csv')
df_obito = pd.read_csv('/content/obito_cartorio.csv')

df_caso_full.head()
df_caso_full.info()
df_caso_full.describe()
df_caso_full.columns
df_caso_full.shape
df_caso_full.isnull().sum()

df_caso_full['date'] = pd.to_datetime(df_caso_full['date'])
colunas_util = [
    'date',
    'state',
    'city',
    'epidemiological_week',
    'estimated_population',
    'last_available_confirmed',
    'last_available_confirmed_per_100k_inhabitants',
    'last_available_deaths',
    'last_available_death_rate'
]

df_covid = df_caso_full[colunas_util].copy()
df_covid = df_covid.dropna(subset=[

    'last_available_confirmed',

    'last_available_deaths'

])
df_covid.duplicated().sum()
```

Os códigos iniciais têm como objetivo preparar os dados nacionais de COVID-19 para análise. As etapas realizadas incluem:

- Importação das bibliotecas pandas e matplotlib.pyplot, essenciais para manipulação de dados e geração de gráficos.
- Leitura dos arquivos CSV contendo os dados brutos: boletins epidemiológicos, casos confirmados, óbitos e base completa (caso_full).
- Exploração inicial dos dados, com comandos como .head(), .info(), .describe(), .columnse .shape, que ajudam a entender a estrutura, tipos de variáveis e possíveis inconsistências.
- Verificação de valores ausentes com .isnull().sum() para identificar colunas com dados faltantes.
- Conversão da coluna de datas para o formato datetime, permitindo análises temporais. Seleção de colunas relevantes para a análise, como número de casos, óbitos, população estimada e taxa de mortalidade.
- Criação de um novo DataFrame (df_covid) com apenas as colunas úteis, e remoção de registros incompletos com .dropna().

Essas etapas garantem que os dados estejam limpos, estruturados e prontos para as análises que serão feitas nas próximas seções, organizadas por pergunta.

3.1.2 Como evoluíram os casos ao longo do tempo?



```
# Agrupamento nacional por semana
df_nacional = df_covid.groupby('epidemiological_week').agg({
    'last_available_confirmed': 'sum',
    'last_available_deaths': 'sum'
}).reset_index()

# Gráfico de casos confirmados
plt.figure(figsize=(12, 5))
plt.plot(df_nacional['epidemiological_week'],
df_nacional['last_available_confirmed'], label='Casos Confirmados',
color='blue')
plt.title('Casos Confirmados por Semana Epidemiológica - Brasil')
plt.xlabel('Semana Epidemiológica')
plt.ylabel('Casos Confirmados')
plt.grid(True)
```

```
plt.legend()
plt.show()
```

```
# Gráfico de óbitos
```

```
plt.figure(figsize=(12, 5))
plt.plot(df_nacional['epidemiological_week'],
df_nacional['last_available_deaths'], label='Óbitos', color='red')
plt.title('Óbitos por Semana Epidemiológica - Brasil')
plt.xlabel('Semana Epidemiológica')
plt.ylabel('Óbitos')
plt.grid(True)
plt.legend()
plt.show()
```




```

# Filtrar apenas dados agregados por estado
df_estado_caso = df_caso[df_caso['place_type'] == 'state'].copy()
# Selecionar colunas úteis
colunas_util_estado = [
    'date',
    'state',
    'confirmed',
    'deaths',
    'estimated_population',
    'confirmed_per_100k_inhabitants',
    'death_rate'
]
df_covid_estado = df_estado_caso[colunas_util_estado].copy()
# Converter data para datetime
df_covid_estado['date'] = pd.to_datetime(df_covid_estado['date'])
# Criar coluna de semana epidemiológica
df_covid_estado['epidemiological_week'] =
df_covid_estado['date'].dt.isocalendar().week +
df_covid_estado['date'].dt.year * 100


regioes = {
    'Norte': ['AC', 'AP', 'AM', 'PA', 'RO', 'RR', 'TO'],
    'Nordeste': ['AL', 'BA', 'CE', 'MA', 'PB', 'PE', 'PI', 'RN', 'SE'],
    'Centro-Oeste': ['DF', 'GO', 'MT', 'MS'],
    'Sudeste': ['ES', 'MG', 'RJ', 'SP'],
    'Sul': ['PR', 'RS', 'SC']
}
df_covid_estado['regiao'] = df_covid_estado['state'].map(
    {estado: regiao for regiao,
     estados in regioes.items() for estado in estados}
)
df_regioes = df_covid_estado.groupby(['regiao',
    'epidemiological_week'])[['confirmed', 'deaths']].sum().reset_index()
plt.figure(figsize=(12, 6))
for regiao in df_regioes['regiao'].unique():
    dados = df_regioes[df_regioes['regiao'] == regiao]
    plt.plot(dados['epidemiological_week'], dados['confirmed'],
    label=regiao)
plt.title('Casos Confirmados por Semana Epidemiológica - Regiões do
Brasil')
plt.xlabel('Semana Epidemiológica')
plt.ylabel('Casos Confirmados')

```

```
plt.legend()
plt.grid(True)
plt.show()
```



```
plt.figure(figsize=(12, 6))
for regio in df_regioes['regiao'].unique():
    dados = df_regioes[df_regioes['regiao'] == regio]
    plt.plot(dados['epidemiological_week'], dados['deaths'],
            label=regiao)
plt.title('Óbitos por Semana Epidemiológica - Regiões do Brasil')
plt.xlabel('Semana Epidemiológica')
plt.ylabel('Óbitos')
plt.legend()
plt.grid(True)
plt.show()
```



```
df_estados = df_covid_estado.groupby(['state',
    'epidemiological_week'])[['confirmed', 'deaths']].sum().reset_index()
df_total_estado = df_estados.groupby('state')[['confirmed',
    'deaths']].max().sort_values(by='confirmed', ascending=False)
print(df_total_estado)
```


	confirmed	deaths
state		
SP	36474398	1168475
MG	23164562	424715
PR	16823881	300034
RS	15782477	272621
RJ	14496400	508139
SC	11667283	151476
BA	10652474	206834
GO	8841432	183231
CE	8670009	186812
ES	7253031	100209
PE	6207998	149317
PA	5244116	126462
MT	5063255	103960
PB	4154361	71278
AM	4066529	99043
MS	3628635	73221
DF	3601087	75934
RN	3430679	56770
MA	2963665	76052
RO	2729798	50132
PI	2569082	53983
SE	2272997	44128
AL	2064531	47799
TO	1808945	26337
AP	1122092	14852
RR	1083165	14998
AC	864779	13929

Os códigos utilizados nesta etapa têm como objetivo analisar a evolução dos casos confirmados e dos óbitos por COVID-19 no Brasil ao longo do tempo, agrupados por semana epidemiológica. As principais etapas foram:


1. Agrupamento dos dados nacionais por semana epidemiológica, somando os casos e óbitos registrados em todo o país.
2. Geração de gráficos de linha para visualizar a progressão dos casos confirmados e dos óbitos ao longo das semanas.
3. Utilização da biblioteca matplotlib para construir visualizações claras e comparáveis. Esses gráficos permitem observar os momentos de pico da pandemia, as variações entre ondas e os efeitos das intervenções públicas, como campanhas de vacinação. Os gráficos 1 e 2 mostram, respectivamente, a evolução dos casos confirmados e de óbitos de COVID-19 no Brasil entre as semanas epidemiológicas de 2020 a 2022.

3.1.3 Qual é o impacto proporcional à população? e 3.1.4 Como se comporta a taxa de mortalidade?

```
import seaborn as sns
plt.figure(figsize=(12, 6))
sns.barplot(data=df_total_estado, x='state', y='casos_100k',
palette='viridis')
plt.title('Casos por 100 mil habitantes - Estados do Brasil')
plt.xlabel('Estado')
plt.ylabel('Casos por 100 mil habitantes')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()
```



```
plt.figure(figsize=(12, 6))
sns.barplot(data=df_total_estado, x='state', y='obitos_100k',
palette='rocket')
plt.title('Óbitos por 100 mil habitantes - Estados do Brasil')
plt.xlabel('Estado')
plt.ylabel('Óbitos por 100 mil habitantes')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()
```



```
media_letalidade = df_total_estado['letalidade'].mean()
print(f"Média nacional da taxa de letalidade: {media_letalidade:.2f}%")
Média nacional da taxa de letalidade: 1.99%
```

```
estados_acima_media = df_total_estado[df_total_estado['letalidade']
>media_letalidade]
print(estados_acima_media[['state', 'letalidade']])
```

	state	letalidade
18	RJ	3.496941
25	SP	3.193770
9	MA	2.562241
2	AM	2.435335
13	PA	2.406385
15	PE	2.394983
1	AL	2.320828
5	CE	2.154312
16	PI	2.100867
8	GO	2.064176
12	MT	2.049809
11	MS	2.002808

Os códigos utilizados nesta etapa têm como objetivo analisar a taxa de mortalidade por COVID-19 nos estados brasileiros, considerando o número de casos e óbitos por 100 mil habitantes. As principais ações realizadas foram:

1. Criação de indicadores proporcionais, como casos e óbitos por 100 mil habitantes, permitindo uma análise mais justa entre estados com diferentes populações.
2. Geração de gráficos de barras com a biblioteca seaborn, facilitando a comparação visual entre os estados.
3. Cálculo da taxa de letalidade, definida como a proporção de óbitos em relação ao número de casos confirmados.
4. Identificação dos estados com letalidade acima da média nacional, destacando os mais afetados proporcionalmente.

Os gráficos 3 e 4 mostram, respectivamente, a incidência de casos e óbitos por 100 mil habitantes em cada estado. E a tabela mostra os estados acima da média nacional de letalidade, que foi de 1.99%.

3.1.5 Qual foi a cobertura vacinal ao longo do tempo?


```
df_ocorrencia_bivalente = pd.read_excel('0eaf8701-da6e-4af7-a631-
955f42e827c4.xlsx')
df_ocorrencia_monovalente = pd.read_excel('df008f44-6146-4259-9af3-
3e1c4dcb5ced.xlsx')
df_residencia_bivalente = pd.read_excel('55067d41-2420-46fa-8181-
d445457cd5c7.xlsx')
```

```

df_residencia_monovalente = pd.read_excel('33856075-e8cc-402d-b718-
2bd48ba4ad46.xlsx')

# Gráfico de cobertura vacinal - 2 doses
df_residencia_monovalente_sorted =
df_residencia_monovalente.sort_values(by='Cobertura Vacinal - 2 doses
(%)', ascending=False)
plt.figure(figsize=(12, 6))
sns.barplot(data=df_residencia_monovalente_sorted, x='UF Residência',
y='Cobertura Vacinal - 2 doses (%)', palette='crest')
plt.title('Cobertura Vacinal - 2 doses (%) por Estado')
plt.xlabel('Estado')
plt.ylabel('Cobertura (%)')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()

```



```


# Gráfico de cobertura vacinal - 3 doses
df_residencia_monovalente_sorted =
df_residencia_monovalente.sort_values(by='Cobertura Vacinal - 3 doses
(%)', ascending=False)
plt.figure(figsize=(12, 6))
sns.barplot(data=df_residencia_monovalente_sorted, x='UF Residência',
y='Cobertura Vacinal - 3 doses (%)', palette='flare')
plt.title('Cobertura Vacinal - 3 doses (%) por Estado')
plt.xlabel('Estado')
plt.ylabel('Cobertura (%)')
plt.xticks(rotation=45)


```

```


plt.grid(True)
plt.show()
# Gráfico de cobertura vacinal - 4 doses
df_residencia_monovalente_sorted =
df_residencia_monovalente.sort_values(by='Cobertura Vacinal - 4 doses
(%)', ascending=False)
plt.figure(figsize=(12, 6))
sns.barplot(data=df_residencia_monovalente_sorted, x='UF Residência',
y='Cobertura Vacinal - 4 doses (%)', palette='mako')
plt.title('Cobertura Vacinal - 4 doses (%) por Estado')
plt.xlabel('Estado')
plt.ylabel('Cobertura (%)')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()

```






```
# Gráfico de cobertura vacinal bivalente
df_residencia_bivalente_sorted =
df_residencia_bivalente.sort_values(by='Cobertura Vacinal (%) -
Residência', ascending=False)
plt.figure(figsize=(12, 6))
sns.barplot(data=df_residencia_bivalente_sorted, x='UF Residência',
y='Cobertura Vacinal (%) - Residência', palette='viridis')
plt.title('Cobertura Vacinal Bivalente (%) por Estado')
plt.xlabel('Estado')
plt.ylabel('Cobertura (%)')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()
```



```
# Evolução semanal de casos confirmados
df_casos_semanal =
df_covid_estado.groupby('epidemiological_week')['confirmed'].sum().reset_index()
plt.figure(figsize=(14, 6))
plt.plot(df_casos_semanal['epidemiological_week'],
df_casos_semanal['confirmed'], color='blue')
plt.axvline(x=202101, color='red', linestyle='--', label='Início da
vacinação (202101)')
plt.title('Evolução semanal de casos confirmados no Brasil')
plt.xlabel('Semana Epidemiológica')
plt.ylabel('Casos Confirmados')
plt.legend()
plt.grid(True)
plt.show()
```



Os códigos desta etapa têm como objetivo analisar a cobertura vacinal contra a COVID-19 no Brasil, considerando diferentes tipos de vacina (monovalente e bivalente) e diferentes números de doses (2, 3 e 4). As ações realizadas foram:

1. Leitura dos arquivos Excel contendo os dados de vacinação por estado, separados por ocorrência e residência.
2. Ordenação dos dados por percentual de cobertura vacinal, permitindo destacar os estados com maior e menor adesão.
3. Geração de gráficos de barras com a biblioteca `seaborn`, para visualização clara da cobertura por UF.
4. Criação de gráfico temporal com linha vertical indicando o início da vacinação (semana epidemiológica 202101), relacionando a evolução dos casos com o avanço da imunização.

Esses códigos permitem observar padrões de adesão vacinal, diferenças entre estados e o impacto da vacinação na curva de casos. Os gráficos mostram respectivamente a Cobertura Vacinal (2 doses) por Estado, Cobertura Vacinal (3 doses) por Estado, Cobertura Vacinal (4 doses) por Estado, Cobertura Vacinal Bivalente por Estado e a Evolução semanal de casos com marco da vacinação.

3.1.6 Quais desigualdades regionais podem ser observadas?

```
# Ordenar estados por número de casos e óbitos
df_total_estado_sorted = df_total_estado.sort_values(by='confirmed',
ascending=False)
```


```

# Gráfico de casos confirmados por estado
plt.figure(figsize=(12, 6))
sns.barplot(data=df_total_estado_sorted, x='state', y='confirmed',
            palette='Blues')
plt.title('Total de Casos Confirmados por Estado')
plt.xlabel('Estado')
plt.ylabel('Casos Confirmados')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()


# Gráfico de óbitos por estado
df_total_estado_sorted = df_total_estado.sort_values(by='deaths',
            ascending=False)
plt.figure(figsize=(12, 6))
sns.barplot(data=df_total_estado_sorted, x='state', y='deaths',
            palette='Reds')
plt.title('Total de Óbitos por Estado')
plt.xlabel('Estado')
plt.ylabel('Óbitos')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()

```





```
# Calcular taxa de letalidade (%)
df_total_estado['letalidade_%'] = (df_total_estado['deaths'] /
df_total_estado['confirmed']) * 100
# Gráfico de taxa de letalidade
df_letalidade_sorted = df_total_estado.sort_values(by='letalidade_%',
ascending=False)
plt.figure(figsize=(12, 6))
sns.barplot(data=df_letalidade_sorted, x='state', y='letalidade_%',
palette='magma')
plt.title('Taxa de Letalidade (%) por Estado')
plt.xlabel('Estado')
plt.ylabel('Letalidade (%)')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()
```




```
# Adicionar coluna de região
def get_regiao(uf):
    for regioao, estados in regioes.items():
        if uf in estados:
            return regioao
    return 'Desconhecido'

df_total_estado['regiao'] = df_total_estado['state'].apply(get_regiao)

# Agrupar por região
df_regiao = df_total_estado.groupby('regiao')[['confirmed',
'deaths']].sum().reset_index()

df_regiao['letalidade_%'] = (df_regiao['deaths'] /
df_regiao['confirmed']) * 100

# Gráfico por região
plt.figure(figsize=(10, 6))
sns.barplot(data=df_regiao.sort_values(by='letalidade_%',
ascending=False), x='regiao', y='letalidade_%', palette='coolwarm')
plt.title('Taxa de Letalidade (%) por Região')
plt.xlabel('Região')
plt.ylabel('Letalidade (%)')
plt.grid(True)
plt.show()
```



Os códigos desta etapa têm como objetivo identificar desigualdades regionais na pandemia de COVID-19 no Brasil, com base em três indicadores principais:

- Total de casos confirmados por estado
 - Total de óbitos por estado
- Taxa de letalidade (%) por estado e por região

As ações realizadas incluem:

- Ordenação dos estados por número de casos e óbitos, permitindo destacar os mais afetados em termos absolutos.
- Cálculo da taxa de letalidade, definida como a proporção de óbitos sobre casos confirmados.
- Agrupamento por região geográfica, com base na sigla da UF, para análise comparativa entre Norte, Nordeste, Centro-Oeste, Sudeste e Sul.
- Geração de gráficos de barras com a biblioteca seaborn, facilitando a visualização das disparidades.

Os gráficos dessa seção mostram, respectivamente, Total de Casos Confirmados por Estado, Total de Óbitos por Estado, Taxa de Letalidade (%) por Estado e Taxa de Letalidade (%) por Região.

3.2 Interpretação dos resultados

3.2.1 Como evoluíram os casos ao longo do tempo?

A análise da evolução temporal dos casos e óbitos demonstra que o Brasil vivenciou sucessivas ondas da pandemia, cada qual inserida em contextos epidemiológicos distintos. Os primeiros picos, registrados em 2020, refletem a rápida disseminação inicial do vírus em um cenário caracterizado por baixa imunidade populacional e limitada capacidade de resposta institucional. No ano de 2021, observa-se um incremento expressivo no número de casos, associado à circulação de variantes com maior transmissibilidade, como a Gama e, posteriormente, a Delta. A partir da semana epidemiológica 2021-01, correspondente ao início da campanha de vacinação, verifica-se uma alteração no padrão da curva: embora novas ondas tenham ocorrido, sua intensidade tende a ser menor e os períodos de estabilização tornam-se mais prolongados. Esse comportamento sugere que a imunização, aliada ao acúmulo de experiência dos sistemas de saúde, desempenhou papel relevante na redução da gravidade e da velocidade de propagação da doença.

3.2.2 Qual é o impacto proporcional à população?

A análise proporcional, ajustada por 100 mil habitantes, revela aspectos que não são perceptíveis nos números absolutos. Estados como Mato Grosso (MT), Rondônia (RO), Distrito Federal (DF) e Rio de Janeiro (RJ) apresentam incidência elevada, indicando que, mesmo com populações relativamente menores, enfrentaram forte pressão epidemiológica. Tal comportamento pode estar relacionado a fatores como densidade urbana, padrões de mobilidade regional, capacidade de testagem e diferenças nos sistemas de registro de casos. A comparação proporcional evidencia que determinadas regiões, apesar de apresentarem números totais inferiores, sofreram impacto relativo significativo, reforçando a importância de indicadores ajustados para a adequada compreensão da magnitude da pandemia em cada território.

3.2.3 Como se comporta a taxa de mortalidade?

A taxa de letalidade apresenta variações expressivas entre os estados brasileiros. A média nacional, estimada em aproximadamente 1,99%, é superada por unidades federativas como RJ, SP, AM e PA, que registram valores mais elevados. Esses resultados podem refletir desigualdades estruturais, incluindo disponibilidade de leitos de UTI, tempo de resposta hospitalar, acesso ao diagnóstico precoce e condições socioeconômicas da população. A análise regional indica que o Sudeste concentra a maior letalidade média, enquanto o Sul apresenta os menores índices, sugerindo diferenças na capacidade de enfrentamento da

pandemia. Ademais, estados da região Norte, como Amazonas (AM) e Pará (PA), vivenciaram momentos críticos de colapso hospitalar, o que contribuiu para o aumento da mortalidade em determinados períodos.

3.2.4 Qual foi a cobertura vacinal ao longo do tempo?

A cobertura vacinal evidencia um padrão decrescente à medida que o número de doses aumenta. A segunda dose obteve ampla adesão, refletindo tanto o esforço inicial das campanhas quanto a elevada percepção de risco naquele momento. Contudo, observa-se queda significativa na adesão à terceira e quarta doses, possivelmente influenciada por fatores como redução da percepção de gravidade, menor mobilização institucional e restrições de elegibilidade em determinadas fases. A vacina bivalente, destinada ao enfrentamento de variantes mais recentes, apresentou cobertura ainda mais limitada, sobretudo em estados da região Norte. A análise temporal demonstra que, após o início da vacinação, houve redução consistente nos casos e óbitos, reforçando o papel central da imunização na mitigação dos impactos da pandemia.

3.2.5 Quais desigualdades regionais podem ser observadas?

As desigualdades regionais são um dos elementos mais marcantes da análise. O Sudeste concentra o maior número absoluto de casos e óbitos, mas também apresenta melhores indicadores de cobertura vacinal e maior capacidade hospitalar. Já o Norte e o Nordeste enfrentam desafios históricos relacionados à infraestrutura, logística e acesso à saúde, o que se reflete em taxas de letalidade mais elevadas e menor adesão às doses adicionais. Estados como AM e PA, por exemplo, enfrentaram momentos de colapso hospitalar que impactaram diretamente os desfechos clínicos. Essas diferenças evidenciam que a pandemia não afetou o país de forma homogênea e reforçam a necessidade de políticas públicas adaptadas às realidades regionais, considerando fatores sociais, econômicos e estruturais.

4 ANÁLISE DOS DADOS DO MUNDO

4.1 Códigos e Gráficos

4.1.1 Códigos Iniciais

```
import pandas as pd
import matplotlib.pyplot as plt
df_who = pd.read_csv('/content/WHO-COVID-19-global-table-data.csv')
df_vac = pd.read_csv('/content/COV_VAC_UPTAKE_2024.csv')
df_prod = pd.read_csv('/content/COV_VAC_PROD.csv')
df_deaths = pd.read_csv('/content/WHO-COVID-19-global-monthly-death-
by-age-data.csv')
df_vac2123 = pd.read_csv('/content/COV_VAC_UPTAKE_2021_2023.csv')
df_vac24 = pd.read_csv('/content/COV_VAC_UPTAKE_2024.csv')
df_who.head()
df_who.info()
df_who.describe()
df_who.columns
df_who.shape
df_who.isnull().sum()
print(df_deaths.columns.tolist())
# Criar coluna de data no formato YYYY-MM-01
df_deaths['DATE'] = pd.to_datetime(df_deaths['Year'].astype(str) + '-'
+ df_deaths['Month'].astype(str).str.zfill(2) + '-01')
# Definir nomes das colunas
col_pais = 'Country'
col_regiao = 'Who_region'
col_obitos = 'Deaths'
```


Os códigos iniciais têm como objetivo preparar os dados globais para análise. As etapas realizadas incluem:

- Importação das bibliotecas pandas e matplotlib.pyplot, essenciais para manipulação e visualização dos dados.
- Leitura dos arquivos CSV contendo dados de casos, óbitos, vacinação e produção de vacinas por país e por mês.
- Exploração preliminar dos dados com comandos como .head(), .describe(), .info() e .isnull().sum() para entender a estrutura e identificar possíveis inconsistências.
- Criação de coluna de data no formato padrão, permitindo análises temporais agregadas.
- Definição de colunas-chave para facilitar o agrupamento e filtragem por país, região e tipo de indicador.

Essas etapas garantem que os dados estejam limpos, estruturados e prontos para as análises específicas que serão feitas nas próximas subseções.


4.1.2 Como evoluíram os casos ao longo do tempo?

```
import seaborn as sns
df_mensal_global =
df_deaths.groupby('DATE')[col_obitos].sum().reset_index()
plt.figure(figsize=(14,6))
sns.lineplot(data=df_mensal_global, x='DATE', y=col_obitos,
color='black')
plt.title('Evolução mensal de óbitos por COVID - Mundo')
plt.xlabel('Data')
plt.ylabel('Óbitos mensais')
plt.grid(True)
plt.xticks(rotation=45)
plt.tight_layout()
plt.show()
```




```
df_mensal_regiao = df_deaths.groupby(['DATE',
col_regiao])[col_obitos].sum().reset_index()
plt.figure(figsize=(14,6))
sns.lineplot(data=df_mensal_regiao, x='DATE', y=col_obitos,
hue=col_regiao)
plt.title('Evolução mensal de óbitos por região da OMS')
plt.xlabel('Data')
plt.ylabel('Óbitos mensais')
```

```
plt.grid(True)
plt.xticks(rotation=45)
plt.tight_layout()
plt.show()
```



```
df_total_pais =
df_deaths.groupby(col_pais)[col_obitos].sum().reset_index()
df_top_paises = df_total_pais.sort_values(by=col_obitos,
ascending=False).head(10)
plt.figure(figsize=(12,6))
sns.barplot(data=df_top_paises, x=col_pais, y=col_obitos,
palette='Reds')
plt.title('Top 10 países com mais óbitos acumulados')
plt.xlabel('País')
plt.ylabel('Óbitos acumulados')
plt.xticks(rotation=45)
plt.grid(True)
plt.tight_layout()
plt.show()
```



Os códigos utilizados nesta etapa têm como objetivo analisar a evolução mensal dos óbitos por COVID-19 em escala global. As ações realizadas incluem:


- Agrupamento dos dados por mês, somando os óbitos registrados em todos os países.
- Geração de gráfico de linha para visualizar a tendência global ao longo do tempo.
- Segmentação por região da OMS, permitindo comparar o comportamento da pandemia entre diferentes partes do mundo.
- Identificação dos países com maior número acumulado de óbitos, com destaque para os dez mais afetados.

Essas visualizações ajudam a compreender a dinâmica temporal da pandemia e a distribuição geográfica dos impactos mais severos.

4.1.3 Qual é o impacto proporcional à população?


```
# Selecionar e limpar
df_impacto = df_who[['Name', 'Cases - cumulative total per 100000
population', 'Deaths - cumulative total per 100000 population']].copy()
# Excluir linha agregada "Global"
df_impacto = df_impacto[df_impacto['Name'] != 'Global']
# Remover países com dados ausentes
df_impacto = df_impacto.dropna(subset=['Deaths - cumulative total per
100000 population'])
# Ordenar por óbitos por 100k
df_top_impacto = df_impacto.sort_values(by='Deaths - cumulative total
per 100000 population', ascending=False).head(10)
```

```
# Plotar gráfico
plt.figure(figsize=(12,6))
sns.barplot(data=df_top_impacto, x='Name', y='Deaths - cumulative total
per 100000 population', palette='Reds')
plt.title('Top 10 países com mais óbitos por 100 mil habitantes')
plt.xlabel('País')
plt.ylabel('Óbitos por 100 mil hab.')
plt.xticks(rotation=45)
plt.grid(True, axis='y', alpha=0.3)
plt.tight_layout()
plt.show()
```



```
df_top_casos = df_impacto.dropna(subset=['Cases - cumulative total per
100000 population']) \
    .sort_values(by='Cases - cumulative total per
100000 population', ascending=False) \
    .head(10)

plt.figure(figsize=(12,6))
sns.barplot(data=df_top_casos, x='Name', y='Cases - cumulative total
per 100000 population', palette='Blues')
plt.title('Top 10 países com mais casos por 100 mil habitantes')
plt.xlabel('País')
plt.ylabel('Casos por 100 mil hab.')
plt.xticks(rotation=45)
plt.grid(True, axis='y', alpha=0.3)
plt.tight_layout()
plt.show()
```



Os códigos desta etapa têm como objetivo identificar os países mais impactados pela pandemia em termos proporcionais, ou seja, ajustados pela população. As ações realizadas incluem:


- Seleção dos indicadores de casos e óbitos por 100 mil habitantes, disponíveis na base da OMS.
- Exclusão da linha agregada “Global” e remoção de países com dados ausentes.
- Ordenação dos países por maior número proporcional de casos e óbitos.
- Geração de gráficos de barras com os 10 países mais afetados em cada indicador.

Esses gráficos permitem observar quais países, independentemente do tamanho populacional, sofreram os maiores impactos relativos.

4.1.4 Como se comporta a taxa de mortalidade?

```
# Calcular taxa de mortalidade (%)
df_who['taxa_mortalidade'] = (df_who['Deaths - cumulative total'] /
df_who['Cases - cumulative total']) * 100
# Excluir "Global" e dados ausentes
df_mortalidade = df_who[df_who['Name'] !=
'Global'].dropna(subset=['taxa_mortalidade'])
# Top 10 países com maior taxa
df_top_mortalidade = df_mortalidade.sort_values(by='taxa_mortalidade',
ascending=False).head(10)
```

```
plt.figure(figsize=(12,6))
sns.barplot(data=df_top_mortalidade, x='Name', y='taxa_mortalidade',
palette='Purples')
plt.title('Top 10 países com maior taxa de mortalidade por COVID (%)')
plt.xlabel('País')
plt.ylabel('Taxa de mortalidade (%)')
plt.xticks(rotation=45)
plt.grid(True, axis='y', alpha=0.3)
plt.tight_layout()
plt.show()
```



Os códigos desta etapa têm como objetivo calcular e visualizar a taxa de mortalidade por COVID-19 em diferentes países. As ações realizadas incluem:

- Cálculo da taxa de mortalidade (%), definida como a razão entre óbitos acumulados e casos acumulados multiplicada por 100.
- Exclusão da linha agregada “Global” e remoção de países com dados ausentes.
- Ordenação dos países por maior taxa de mortalidade.
- Geração de gráfico de barras com os 10 países com os maiores índices.

Essa abordagem permite identificar os países onde a proporção de mortes em relação aos casos foi mais crítica, independentemente do volume absoluto de registros.


4.1.5 Qual foi a cobertura vacinal ao longo do tempo?

```
df_vac['COVID_VACCINE_COV_1D'] =
pd.to_numeric(df_vac['COVID_VACCINE_COV_1D'], errors='coerce')
```

```

df_vac = df_vac.dropna(subset=['COVID_VACCINE_COV_1D'])
# Pegar último registro por país
df_last = df_vac.sort_values(['COUNTRY', 'DATE']).groupby('COUNTRY',
as_index=False).tail(1)
# Top 10 países por cobertura
df_cov_top =
df_last[['COUNTRY', 'COVID_VACCINE_COV_1D']].sort_values('COVID_VACCINE_
COV_1D', ascending=False).head(10)
plt.figure(figsize=(12,6))
sns.barplot(data=df_cov_top, x='COUNTRY', y='COVID_VACCINE_COV_1D',
palette='Greens')
plt.title('Top 10 países com maior cobertura de pelo menos 1 dose (%)')
plt.xlabel('País')
plt.ylabel('Cobertura, 1ª dose (%)')
plt.xticks(rotation=45)
plt.grid(True, axis='y', alpha=0.3)
plt.tight_layout()
plt.show()

```



```


# Preparar dados de vacinação
df_vac2123['COVID_VACCINE_COV_TOT_A1D'] =
pd.to_numeric(df_vac2123['COVID_VACCINE_COV_TOT_A1D'], errors='coerce')
df_vac2123['DATE'] = pd.to_datetime(df_vac2123['DATE'],
errors='coerce')
# Agrupar por mês e calcular média global de cobertura
df_vac2123['month'] = df_vac2123['DATE'].dt.to_period('M')
df_vac_mensal =

```

```

df_vac2123.groupby('month')['COVID_VACCINE_COV_TOT_A1D'].mean().reset_index()
df_vac_mensal['month'] = df_vac_mensal['month'].dt.to_timestamp()
# Preparar dados de óbitos globais
df_deaths['DATE'] = pd.to_datetime(df_deaths['DATE'], errors='coerce')
df_deaths_mensal =
df_deaths.groupby('DATE')['Deaths'].sum().reset_index()
# Gráfico combinado
fig, ax1 = plt.subplots(figsize=(14,6))
# Linha 1: óbitos mensais
sns.lineplot(data=df_deaths_mensal, x='DATE', y='Deaths', ax=ax1,
color='red', label='Óbitos mensais (Global)')
ax1.set_ylabel('Óbitos mensais', color='red')
ax1.tick_params(axis='y', labelcolor='red')
# Linha 2: cobertura vacinal média
ax2 = ax1.twinx()
sns.lineplot(data=df_vac_mensal, x='month',
y='COVID_VACCINE_COV_TOT_A1D', ax=ax2, color='green', marker='o',
label='Cobertura vacinal média (%)')
ax2.set_ylabel('Cobertura vacinal média (%)', color='green')
ax2.tick_params(axis='y', labelcolor='green')
plt.title('Evolução da vacinação vs óbitos globais')
plt.grid(True, axis='x', alpha=0.3)
plt.tight_layout()
plt.show()

```



```


# Preparar últimos valores de cobertura por país
df_vac2123['COVID_VACCINE_COV_TOT_A1D'] =
pd.to_numeric(df_vac2123['COVID_VACCINE_COV_TOT_A1D'], errors='coerce')
df_vac2123['DATE'] = pd.to_datetime(df_vac2123['DATE'],

```

```

errors='coerce')
df_vac2123 = df_vac2123.dropna(subset=['COVID_VACCINE_COV_TOT_A1D'])
df_last_vac =
df_vac2123.sort_values(['COUNTRY', 'DATE']).groupby('COUNTRY').tail(1)
# Usar código de país para garantir o match com df_deaths
df_regiao = df_deaths[['Country_code', 'Who_region']].drop_duplicates()
# Merge (IS03 ↔ IS03)
df_last_vac = df_last_vac.merge(df_regiao, left_on='COUNTRY',
right_on='Country_code')
# Média por região
df_regiao_cov =
df_last_vac.groupby('Who_region')['COVID_VACCINE_COV_TOT_A1D'].mean().r
eset_index()
# Gráfico
plt.figure(figsize=(10,6))
sns.barplot(data=df_regiao_cov, x='Who_region',
y='COVID_VACCINE_COV_TOT_A1D', palette='Blues')
plt.title('Cobertura vacinal média por região da OMS')
plt.xlabel('Região OMS')
plt.ylabel('Cobertura média (%)')
plt.grid(True, axis='y', alpha=0.3)
plt.tight_layout()
plt.show()

```



Os códigos desta etapa têm como objetivo analisar a cobertura vacinal global contra a COVID-19, tanto em termos temporais quanto geográficos. As ações realizadas incluem:

Conversão de dados de cobertura vacinal para formato numérico e temporal, permitindo análises por país e por mês.

-Identificação dos países com maior cobertura de pelo menos uma dose, com base no último registro disponível.

-Cálculo da média mensal global de cobertura vacinal, para observar a evolução ao longo dos anos.

-Geração de gráfico combinado, relacionando a curva de vacinação com a curva de óbitos globais.

-Cálculo da cobertura média por região da OMS, evidenciando disparidades geográficas. Essas visualizações permitem avaliar o avanço da imunização e sua correlação com a redução da mortalidade.



3.1.6 Quais desigualdades regionais podem ser observadas?

```
# Excluir linha agregada "Global"
df_who = df_who[df_who['Name'] != 'Global']
# Converter colunas para numérico e preencher ausentes
df_who['Cases - cumulative total'] = pd.to_numeric(df_who['Cases -
cumulative total'], errors='coerce').fillna(0)
df_who['Deaths - cumulative total'] = pd.to_numeric(df_who['Deaths -
cumulative total'], errors='coerce').fillna(0)
# Top 10 países em casos
df_top_cases = df_who[['Name', 'Cases - cumulative
total']].sort_values('Cases - cumulative total',
ascending=False).head(10)
plt.figure(figsize=(12,6))
sns.barplot(data=df_top_cases, x='Name', y='Cases - cumulative total',
palette='Blues')
plt.title('Top 10 países com mais casos acumulados de COVID-19')
plt.xlabel('País')
plt.ylabel('Casos acumulados')
plt.xticks(rotation=45)
plt.tight_layout()
plt.show()
# Top 10 países em óbitos
df_top_deaths = df_who[['Name', 'Deaths - cumulative
total']].sort_values('Deaths - cumulative total',
```

```

ascending=False).head(10)
plt.figure(figsize=(12,6))
sns.barplot(data=df_top_deaths, x='Name', y='Deaths - cumulative
total', palette='Reds')
plt.title('Top 10 países com mais óbitos acumulados de COVID-19')
plt.xlabel('País')
plt.ylabel('Óbitos acumulados')
plt.xticks(rotation=45)
plt.tight_layout()
plt.show()

```



```


# Agrupar por região da OMS
df_region = df_who.groupby('WHO Region')[['Cases -


```

```


cumulativetotal', 'Deaths - cumulative total']].sum().reset_index()
# Gráfico de casos por região
plt.figure(figsize=(10,6))
sns.barplot(data=df_region, x='WHO Region', y='Cases - cumulative
total', palette='Greens')
plt.title('Casos acumulados por região da OMS')
plt.xlabel('Região OMS')
plt.ylabel('Casos acumulados')
plt.tight_layout()
plt.show()
# Gráfico de óbitos por região
plt.figure(figsize=(10,6))
sns.barplot(data=df_region, x='WHO Region', y='Deaths - cumulative
total', palette='Purples')
plt.title('Óbitos acumulados por região da OMS')
plt.xlabel('Região OMS')
plt.ylabel('Óbitos acumulados')
plt.tight_layout()
plt.show()

```





```
# Calcular taxa de mortalidade por região
df_region['MortalityRate'] = (df_region['Deaths - cumulative total'] /
df_region['Cases - cumulative total']) * 100
plt.figure(figsize=(10,6))
sns.barplot(data=df_region, x='WHO Region', y='MortalityRate',
palette='Oranges')
plt.title('Taxa de mortalidade (%) por região da OMS')
plt.xlabel('Região OMS')
plt.ylabel('Taxa de mortalidade (%)')
plt.tight_layout()
plt.show()
# Mostrar valores
print(df_region[['WHO Region', 'MortalityRate']])
```



	WHO Region	MortalityRate
0	Africa	1.927240
1	Americas	1.584270
2	Eastern Mediterranean	1.503016
3	Europe	0.810742
4	Other	1.701571
5	South-East Asia	1.306397
6	Western Pacific	0.202140

Os códigos desta etapa têm como objetivo identificar desigualdades regionais na pandemia de COVID-19 em escala global. As ações realizadas incluem:

- Agrupamento dos dados por país e por região da OMS, somando casos e óbitos acumulados.
- Identificação dos 10 países com maior número absoluto de casos e óbitos, destacando os mais afetados.
- Geração de gráficos comparativos por região, evidenciando diferenças entre continentes.
- Cálculo da taxa de mortalidade (%) por região, permitindo avaliar a gravidade dos desfechos em cada contexto.

Essas visualizações ajudam a compreender como fatores estruturais, demográficos e políticos influenciaram os impactos da pandemia em diferentes partes do mundo.

4.2 Interpretação dos resultados

4.2.1 Como evoluíram os casos ao longo do tempo?

A análise da série temporal mensal de óbitos mostra que o mundo enfrentou ondas sucessivas da pandemia, com picos concentrados principalmente entre 2020 e 2021. O primeiro movimento expressivo de aumento ocorre ainda em 2020, quando há rápida disseminação global em um cenário de baixa imunidade e limitada preparação dos sistemas de saúde. Em 2021, observa-se um novo patamar elevado de mortes, indicando que, mesmo com algum avanço de resposta, o vírus continuou causando forte impacto. A partir de 2022, a curva global de óbitos passa a apresentar tendência de queda e estabilização em níveis bem inferiores aos picos iniciais. Esse comportamento sugere o efeito combinado da ampliação da cobertura vacinal, da maior experiência clínica no manejo dos casos graves e, possivelmente, de mudanças no perfil das infecções. Embora os óbitos não desapareçam, a redução da intensidade das ondas indica melhora na capacidade mundial de conviver e responder à doença.

4.2.2 Qual é o impacto proporcional à população?

Quando os dados são ajustados por 100 mil habitantes, o panorama global muda de forma relevante. Em vez de destacar apenas grandes países em números absolutos, passam a aparecer na liderança países como Peru, Bulgária, Hungria, Bósnia e Herzegovina, Macedônia do Norte, Montenegro, Geórgia, Croácia, Tchêquia e Eslováquia em óbitos por 100 mil habitantes, e Chipre, República Tcheca, San Marino, Eslovênia, Aruba, Geórgia, Gibraltar, Lituânia, Andorra e Jersey em casos por 100 mil habitantes. Isso mostra que o impacto proporcional foi especialmente alto em alguns países de menor população, microestados ou regiões com características específicas (densidade, estrutura etária, organização do sistema de saúde). Em muitos casos, a combinação de surtos intensos com população relativamente pequena resulta em taxas muito elevadas. Além disso, a análise proporcional evidencia que o peso da pandemia não se restringiu às grandes potências econômicas, mas afetou de forma severa países com menos visibilidade na mídia internacional.

4.2.3 Como se comporta a taxa de mortalidade?

A taxa de mortalidade calculada como $(\text{óbitos acumulados/casos acumulados}) \times 100$ revela um grupo de países com percentuais muito elevados, como Iêmen, Sudão, Síria, Somália, Peru, Egito, México, Bósnia e Herzegovina, Lesoto e Afeganistão. Muitos deles compartilham contextos de conflito, fragilidade institucional ou limitação severa de infraestrutura sanitária.

Nesses cenários, a taxa de mortalidade tende a ser influenciada por dois fatores principais: baixa testagem (subestimação de casos) e dificuldade de acesso a cuidados adequados. Com

poucos testes, o número de casos confirmados fica artificialmente reduzido, aumentando a proporção de óbitos entre os registros. Ao mesmo tempo, sistemas de saúde frágeis dificultam o tratamento de casos graves. Assim, a taxa de mortalidade deixa de refletir apenas a agressividade da doença e passa a indicar também a capacidade do país de diagnosticar, monitorar e tratar a população.

Quando a análise é feita por região da OMS, observa-se que África e algumas regiões intermediárias apresentam taxas de mortalidade mais altas, enquanto Europa e Pacífico Ocidental apresentam valores mais baixos. Isso reforça a relação entre estrutura de saúde, recursos disponíveis e desfechos clínicos.

4.2.4 Qual foi a cobertura vacinal ao longo do tempo?

A análise da cobertura vacinal global mostra um avanço significativo a partir de 2021, com crescimento rápido da proporção da população com pelo menos uma dose. A curva de cobertura média mundial aumenta de forma consistente até atingir um patamar de estabilização, enquanto a curva de óbitos mensais segue trajetória de redução, o que sugere forte associação entre imunização em massa e queda da mortalidade. Quando se observa os países com maior cobertura de ao menos uma dose, surgem na liderança nações como Portugal, Emirados Árabes, Chile, Cuba, Malta, Islândia, Espanha, Uruguai, Catar e Irlanda. Em geral, são países com sistemas de saúde organizados, comunicação centralizada e boa capacidade logística, o que facilita campanhas amplas e rápidas.

A análise por região da OMS mostra uma desigualdade clara: Sudeste Asiático (SEAR) e Pacífico Ocidental (WPR) apresentam coberturas médias em torno de 80%, enquanto Américas (AMR) e Europa (EUR) ficam em faixa intermediária, e África (AFR) apresenta a menor cobertura média, em torno de 44%. Essas diferenças refletem não apenas disponibilidade de vacinas, mas também capacidade operacional, financiamento, prioridade política e aceitação da população.

4.2.5 Quais desigualdades regionais podem ser observadas?


A análise de casos, óbitos e mortalidade por região da OMS evidencia desigualdades marcantes. Em números absolutos, Europa lidera em casos acumulados, seguida por Pacífico Ocidental e Américas, o que pode refletir tanto alta circulação viral quanto maior capacidade de testagem e registro. Em óbitos acumulados, as Américas estão na frente, seguidas por Europa e Sudeste Asiático, indicando que o impacto em desfechos fatais foi particularmente intenso no continente americano.

Quando se observa a taxa de mortalidade regional, o quadro se torna ainda mais revelador: África apresenta a maior taxa proporcional, enquanto o Pacífico Ocidental tem a menor. Essa combinação sugere que, em algumas regiões, o menor número de casos registrados não significa necessariamente baixa circulação, mas pode refletir subnotificação, baixa testagem e limitação na vigilância epidemiológica. Ao mesmo tempo, a gravidade dos desfechos – traduzida em maior mortalidade proporcional – aponta para sistemas de saúde com menor capacidade de absorver a demanda em situações de crise. De forma geral, os resultados indicam que a pandemia de COVID-19 amplificou desigualdades pré-existentes entre países e regiões. Onde havia mais estrutura, recursos e coordenação, os impactos, embora grandes, foram melhor controlados. Onde havia fragilidade, escassez ou conflito, a combinação de baixa testagem, cobertura vacinal desigual e serviços de saúde limitados resultou em índices mais críticos de mortalidade e impacto proporcional.


5 COMPARAÇÃO BRASIL X MUNDO

5.1 Códigos e Gráficos

```
# Calcular óbitos e casos para Brasil e Mundo
obitos_brasil = df_who[df_who['Name'] == 'Brazil']['Deaths - cumulative
total'].values[0]
casos_mundo = df_who['Cases - cumulative total'].sum()
obitos_mundo = df_who['Deaths - cumulative total'].sum()
# Calcular taxa de mortalidade
taxa_brasil = (obitos_brasil / casos_brasil) * 100
taxa_mundo = (obitos_mundo / casos_mundo) * 100
df_taxa = pd.DataFrame({
    'Categoria': ['Brasil', 'Mundo'],
    'Taxa de mortalidade (%)': [taxa_brasil, taxa_mundo]
})
plt.figure(figsize=(8,6))
sns.barplot(data=df_taxa, x='Categoria', y='Taxa de mortalidade (%)',
palette='Oranges')
plt.title('Taxa de mortalidade: Brasil vs Mundo')
plt.ylabel('Taxa (%)')
plt.tight_layout()
plt.show()
print(df_taxa)
```



```
# Cobertura do Brasil
cov_brasil = df_last_vac[df_last_vac['COUNTRY'] ==
'BRA']['COVID_VACCINE_COV_TOT_A1D'].values[0]
# Média global
cov_global = df_last_vac['COVID_VACCINE_COV_TOT_A1D'].mean()
df_cov = pd.DataFrame({
'Categoria': ['Brasil', 'Média global'],
'Cobertura (%)': [cov_brasil, cov_global]
})
plt.figure(figsize=(8,6))
sns.barplot(data=df_cov, x='Categoria', y='Cobertura (%)',
hue='Categoria', palette='Greens', legend=False)
plt.title('Cobertura vacinal: Brasil vs Média global')
plt.ylabel('Cobertura (%)')
plt.tight_layout()
plt.show()
print(df_cov)
```



Os códigos utilizados nesta etapa têm como objetivo comparar diretamente os indicadores do Brasil com os dados globais, utilizando os mesmos critérios de cálculo aplicados nas seções anteriores. As ações realizadas incluem:

- Cálculo da taxa de mortalidade (%) para Brasil e Mundo, com base nos óbitos e casos acumulados.
- Cálculo da cobertura vacinal (%) de pelo menos uma dose, comparando o último valor registrado para o Brasil com a média global.
- Geração de gráficos de barras para visualização clara das diferenças entre os dois contextos. Esses gráficos permitem destacar os pontos de maior discrepância entre o cenário nacional e o panorama internacional.

5.2 Interpretação dos Resultados e Análise Comparativa

A comparação entre os indicadores do Brasil e os dados globais revela uma posição ambivalente do país no contexto da pandemia de COVID-19. Em termos de cobertura vacinal, o desempenho brasileiro pode ser considerado relativamente favorável; entretanto, quando se analisam taxas de mortalidade e impacto proporcional, observa-se que o país apresenta valores superiores à média mundial. Essa dualidade sugere que a ampla disponibilidade de

vacinas e a adesão populacional, embora essenciais, não foram suficientes para mitigar desfechos mais graves diante de desigualdades estruturais e limitações do sistema de saúde. A **evolução temporal dos casos e óbitos** evidencia múltiplas ondas tanto no Brasil quanto no cenário global, com picos concentrados entre 2020 e 2021, seguidos de queda gradual e estabilização em níveis inferiores. No plano internacional, essa transição ocorreu de forma relativamente mais homogênea, refletindo a diversidade de ritmos de vacinação e de adoção de medidas de controle. No Brasil, contudo, a curva apresenta oscilações mais abruptas, caracterizadas por períodos de crescimento acelerado seguidos de quedas acentuadas. Esse padrão pode estar associado a variações na implementação de políticas públicas, à adesão irregular às medidas não farmacológicas e a momentos de maior ou menor coordenação entre diferentes esferas governamentais.

Quando se observa o **impacto proporcional à população**, O Brasil se destaca por apresentar simultaneamente elevada incidência proporcional e elevado volume absoluto de casos e óbitos. Em análises globais, países menores ou microestados frequentemente figuram nas primeiras posições em termos proporcionais, devido à sensibilidade das taxas por 100 mil habitantes a pequenas variações. O Brasil, entretanto, ocupa posição relevante tanto em números absolutos quanto em incidência proporcional, reforçando a magnitude do impacto da pandemia no contexto nacional.

A **taxa de mortalidade** é um dos indicadores em que a discrepância entre Brasil e mundo se torna mais evidente. Enquanto a média global gira em torno de 0,92%, o Brasil apresenta cerca de 1,82%, praticamente o dobro. Esse dado sugere que, proporcionalmente, os casos brasileiros resultaram em morte com frequência maior do que a média mundial. Do ponto de vista analítico, esse resultado pode estar associado a uma combinação de fatores: momentos de colapso assistencial, desigual acesso a leitos de UTI, diferenças regionais marcantes na estrutura hospitalar, atrasos na busca por atendimento, além de potenciais limitações na testagem em determinadas fases da pandemia. A taxa mais elevada também pode refletir subnotificação de casos leves e moderados em alguns períodos, o que reduz o denominador e eleva a letalidade aparente.

Em relação à **cobertura vacinal**, o cenário se inverte parcialmente. O Brasil apresenta desempenho superior à média global. A cobertura de pelo menos uma dose alcançou aproximadamente 87%, frente a 63,4% no cenário mundial. Esse resultado reflete a tradição do Programa Nacional de Imunizações (PNI), a capilaridade das unidades básicas de saúde e a experiência acumulada em campanhas de vacinação em massa. Contudo, observa-se redução na adesão às doses subsequentes e às vacinas bivalentes, fenômeno também presente em escala global. Dessa forma, ainda que a campanha de vacinação tenha alcançado elevado êxito operacional, a efetividade na redução da mortalidade mostrou-se limitada em razão de

condicionantes estruturais internos, tais como desigualdades regionais, capacidade hospitalar heterogênea e restrições no acesso oportuno aos serviços de saúde.

As **desigualdades regionais** aparecem de forma recorrente e influenciam diferentes dimensões da análise. Em escala global, regiões como África e algumas áreas do Mediterrâneo Oriental apresentam menor cobertura vacinal, maior taxa de mortalidade e, muitas vezes, menor capacidade de testagem e registro, evidenciando o peso de fatores econômicos, políticos e logísticos. No Brasil, padrão semelhante se repete internamente: estados do Norte e Nordeste enfrentam maiores dificuldades de acesso, infraestrutura limitada e indicadores mais desfavoráveis, enquanto regiões como Sudeste e Sul concentram melhor estrutura de serviços e maior cobertura vacinal. Assim, a comparação Brasil x Mundo revela um paralelismo: os mesmos mecanismos que geram desigualdade entre países e regiões da OMS reproduzem-se, em menor escala, entre estados e regiões brasileiras. De forma geral, a análise comparativa indica que o Brasil se insere no grupo de países fortemente impactados pela COVID-19, com desempenho misto: robustez relativa em vacinação, mas vulnerabilidade em mortalidade e impacto proporcional. A combinação de alta circulação viral, desigualdades socioeconômicas e capacidade limitada de resposta em determinadas regiões contribuiu para um cenário em que a cobertura vacinal, embora elevada, não foi suficiente para alinhar os indicadores de gravidade à média global.

6 CONSIDERAÇÕES FINAIS

A análise comparativa dos dados do Brasil e do mundo sobre a pandemia de COVID-19 permite extrair algumas conclusões centrais, relevantes tanto do ponto de vista epidemiológico quanto da perspectiva de análise de dados. Primeiro, os resultados reforçam a importância de considerar indicadores absolutos e proporcionais de forma conjunta. Números totais de casos e óbitos são essenciais para dimensionar a carga global da doença, mas podem ocultar realidades específicas quando não são ajustados pela população. A utilização sistemática de métricas como casos e óbitos por 100 mil habitantes, bem como taxas de mortalidade e cobertura vacinal, mostrou-se fundamental para identificar países e regiões desproporcionalmente afetados. Segundo, a comparação entre Brasil e mundo evidencia que a vacinação é um componente necessário, mas não suficiente para explicar os desfechos da pandemia. O Brasil apresentou cobertura vacinal superior à média global, o que, em tese, deveria contribuir para reduzir a mortalidade. No entanto, a taxa de mortalidade brasileira manteve-se acima da média mundial, indicando a influência de fatores adicionais, como desigualdades regionais, capacidade hospitalar, acesso a cuidados intensivos, tempo de resposta dos sistemas de saúde e determinantes sociais da saúde. Do ponto de vista de análise de dados, isso mostra que a interpretação de um indicador isolado pode levar a conclusões incompletas. Do ponto de vista quantitativo, o Brasil apresentou taxa de mortalidade de aproximadamente 1,82%, significativamente superior à média global de 0,92%, mesmo tendo alcançado cobertura vacinal inicial superior à média mundial. Essa discrepância sugere que a vacinação, embora essencial, não foi suficiente para compensar limitações estruturais do sistema de saúde, desigualdades regionais e momentos de sobrecarga hospitalar. A análise temporal reforça esse ponto: os picos de mortalidade no Brasil ocorreram antes da consolidação da cobertura vacinal, indicando que a imunização em massa chegou tardiamente em relação ao avanço da doença.

Esse atraso não é apenas perceptível nos dados epidemiológicos, mas também documentado em fontes oficiais. O Relatório Final da CPI da Pandemia do Senado Federal concluiu que houve atrasos significativos na aquisição de vacinas, classificados como “atraso deliberado” e associados a condutas negligentes na condução da resposta federal. A Agência Brasil registrou que o relator da CPI identificou que a demora ocorreu mesmo diante de ofertas formais de fabricantes internacionais. Reportagens baseadas na minuta oficial da CPI, como as publicadas pelo G1, reforçam que esses atrasos foram considerados um dos fatores centrais que contribuíram para mortes evitáveis.

Do ponto de vista de análise de dados, essa informação é crucial para interpretar a diferença entre o desempenho vacinal e os desfechos clínicos. Embora o Brasil tenha alcançado alta cobertura de primeira dose, a vacinação em larga escala ocorreu após os períodos mais críticos de transmissão e mortalidade, o que reduz seu impacto sobre os indicadores acumulados. Em outras palavras, a vacinação foi eficiente quando implementada, mas não foi implementada no momento ideal para evitar o maior número de óbitos. Terceiro, os achados destacam a relevância das desigualdades estruturais na compreensão da pandemia. Em escala global, regiões com menores recursos apresentaram maior mortalidade proporcional e menor cobertura vacinal; em escala nacional, regiões brasileiras com menor infraestrutura de saúde e maior vulnerabilidade social foram mais penalizadas. Essa recorrência sugere que crises sanitárias tendem a amplificar desigualdades preexistentes, e que políticas públicas precisam ser desenhadas com foco em equidade, não apenas em média nacional.

Do ponto de vista metodológico, o trabalho demonstrou o potencial do uso de ferramentas de análise de dados (como Python, pandas, seaborn e matplotlib) para explorar grandes bases públicas, realizar agregações temporais e regionais, calcular indicadores derivados e produzir visualizações que facilitam a interpretação. A organização dos dados por semana epidemiológica, mês, país, região e grupo populacional permitiu construir narrativas quantitativas coerentes com o comportamento observado da pandemia. Em síntese, os resultados mostram que o Brasil enfrentou a pandemia com capacidade técnica relevante, mas com limitações estruturais e institucionais que comprometeram a efetividade da resposta inicial. A combinação entre alta circulação viral, desigualdades regionais, atrasos documentados na aquisição de vacinas e sobrecarga hospitalar explica por que o país apresentou impacto mais severo do que a média global, mesmo com avanços importantes na fase posterior da campanha de imunização. Esse estudo reforça a importância de integrar múltiplas fontes, cruzar indicadores e interpretar resultados à luz do contexto, evitando leituras simplistas baseadas em um único número ou gráfico.

REFERÊNCIAS

BRASIL.IO. **COVID-19 – Casos e óbitos por município e estado**. 2024. Disponível em: <https://brasil.io/dataset/covid19/caso/>. Acesso em: 15 dez. 2025.

BRASIL. Ministério da Saúde. Secretaria de Informação e Saúde Digital (SEIDIGI). **COVID-19 – Dados epidemiológicos nacionais**. Brasília, 2024. Disponível em: <https://www.gov.br/saude/pt-br/composicao/seidigi/demas/covid19> Acesso em: 15 dez. 2025.

BRASIL. Ministério da Saúde. SEIDIGI – DEMAS. **Painel de Vacinação COVID-19 – Informações consolidadas**. Brasília, 2024. Disponível em: https://infoms.saude.gov.br/extensions/SEIDIGI_DEMAS_VACINACAO_MENU_COVID/SEIDIGI_DEMAS_VACINACAO_MENU_COVID.html Acesso em: 15 dez. 2025.

ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). **WHO COVID-19 Data Dashboard – Global cases, deaths and vaccination**. Genebra, 2024. Disponível em: <https://data.who.int/dashboards/covid19/data?n=o> Acesso em: 15 dez. 2025.

BRASIL. Senado Federal. **Relatório Final da CPI da Pandemia**. Brasília, 2021. Disponível em: <https://www12.senado.leg.br> Acesso em: 15 dez. 2025.

AGÊNCIA BRASIL. **Relator da CPI vê atraso deliberado na compra de vacinas**. Brasília, 2021. Disponível em: <https://agenciabrasil.ebc.com.br> Acesso em: 15 dez. 2025.

G1 – GRUPO GLOBO. **Atraso para aquisição de vacinas ganha destaque na minuta do relatório da CPI**. 2021. Disponível em: <https://g1.globo.com> Acesso em: 15 dez. 2025.

PYTHON SOFTWARE FOUNDATION. **Python LanguageReference, version 3.x**. Disponível em: <https://www.python.org/> Acesso em: 15 dez. 2025.

PANDAS DEVELOPMENT TEAM. **pandas: Python Data Analysis Library**. Disponível em: <https://pandas.pydata.org/> Acesso em: 15 dez. 2025.

SEABORN DEVELOPMENT TEAM. **Seaborn Statistical Data Visualization**. Disponível em: <https://seaborn.pydata.org/> Acesso em: 15 dez. 2025.

MATPLOTLIB DEVELOPMENT TEAM. **Matplotlib: Visualization with Python**. Disponível em: <https://matplotlib.org/> Acesso em: 15 dez. 2025.