

Amostragem e Tipos de Amostras

Compreendendo a Importância da Amostragem e os Diferentes Métodos de Seleção de Amostras

Márcio Nicolau

2025-09-17

Table of contents

Introdução e Objetivos	2
Objetivos de Aprendizagem	2
Conceitos Fundamentais em Amostragem	2
População (Universo)	2
Amostra	3
Censo	3
Parâmetro vs. Estatística	3
Por Que Amostrar?	3
Diagrama Conceitual de Amostragem	4
Métodos de Amostragem Probabilística	4
Amostragem Aleatória Simples (AAS) - Simple Random Sampling (SRS)	4
Exemplo: Amostragem Aleatória Simples	5
Python	5
R	5
Amostragem Estratificada	6
Exemplo: Amostragem Estratificada	6
Python	6
R	8
Amostragem Sistemática	9
Amostragem por Conglomerados (Cluster Sampling)	9
Métodos de Amostragem Não Probabilística	10
Amostragem por Conveniência	10
Amostragem por Quotas	10
Considerações Finais sobre Amostragem	11
Verificação de Aprendizagem	11

List of Figures

1	Conceitos Fundamentais em Amostragem	4
2	Diagrama de Amostragem Estratificada	7

Introdução e Objetivos

Nas aulas anteriores, exploramos a estatística descritiva e a análise exploratória de dados, aprendendo a resumir e visualizar informações de um conjunto de dados. No entanto, muitas vezes, é inviável ou impossível coletar dados de uma população inteira (por exemplo, todos os cidadãos de um país, todos os clientes de uma empresa global, ou todas as transações financeiras). É aqui que entra a **amostragem**.

A amostragem é o processo de selecionar um subconjunto de indivíduos ou itens de uma população maior para estimar características dessa população. Um bom plano de amostragem é essencial para garantir que as conclusões tiradas da amostra sejam válidas e representativas da população, evitando vieses e economizando tempo e recursos.

Nesta aula, desvendaremos a importância da amostragem, definiremos seus termos chave e exploraremos os diversos métodos de seleção de amostras, classificando-os em probabilísticos e não probabilísticos.

Objetivos de Aprendizagem

Ao final desta aula, você será capaz de:

- Distinguir entre população, amostra, censo, parâmetro e estatística.
- Compreender a necessidade e os benefícios da amostragem.
- Diferenciar entre métodos de amostragem probabilística e não probabilística.
- Identificar e aplicar os principais tipos de amostragem probabilística (aleatória simples, estratificada, sistemática, por conglomerados).
- Identificar os principais tipos de amostragem não probabilística (por conveniência, por cotas, intencional).
- Reconhecer as vantagens e desvantagens de cada método de amostragem.
- Utilizar Python e R para implementar alguns métodos de amostragem probabilística.

Conceitos Fundamentais em Amostragem

Para compreender a amostragem, é fundamental estabelecer uma terminologia clara.

População (Universo)

A **população** (ou universo) é o conjunto completo de todos os elementos (indivíduos, objetos, eventos, etc.) que possuem uma ou mais características em comum e sobre os quais se deseja obter informação. É o grupo total de interesse para o estudo.

Exemplos:

- Todos os eleitores aptos em um país.
- Todas as lâmpadas produzidas por uma fábrica em um mês.
- Todos os clientes de uma operadora de telefonia.

Amostra

A **amostra** é um subconjunto (parte) da população que é selecionado para ser estudado. O objetivo é que a amostra seja representativa da população para que as conclusões obtidas a partir dela possam ser generalizadas para toda a população.

Exemplos:

- 1.000 eleitores entrevistados de um país.
- 100 lâmpadas testadas de um lote de produção.
- Um grupo de 500 clientes contatados para uma pesquisa de satisfação.

Censo

Um **censo** ocorre quando dados são coletados de *todos* os elementos da população. É um levantamento completo.

Características:

- Oferece informações completas sobre a população.
- Geralmente é caro, demorado e, em muitos casos, impraticável ou impossível.
- Pode ser destrutivo (por exemplo, testar a resistência de todos os parafusos de um lote).

Parâmetro vs. Estatística

- **Parâmetro:** É uma medida numérica que descreve uma característica da **população**. Geralmente é desconhecido e é o que desejamos estimar. (Ex: Média populacional μ , Desvio padrão populacional σ , Proporção populacional P).
- **Estatística:** É uma medida numérica que descreve uma característica da **amostra**. É calculada a partir dos dados da amostra e usada para estimar o parâmetro populacional. (Ex: Média amostral $\bar{x}$, Desvio padrão amostral s , Proporção amostral $\hat{p}$).

Por Que Amostrar?

A amostragem é preferível a um censo na maioria das situações devido a:

- **Custo:** Coletar dados de uma amostra é geralmente muito mais barato.
- **Tempo:** A coleta e análise de dados de uma amostra são mais rápidas.
- **Praticidade:** Muitas populações são muito grandes ou inacessíveis.
- **Precisão:** Em alguns casos, uma amostra bem planejada pode, paradoxalmente, fornecer resultados mais precisos que um censo mal executado, devido à menor complexidade e maior controle sobre a coleta de dados.
- **Natureza Destrutiva:** Se o processo de coleta destrói o item (e.g., teste de vida útil de produtos), a amostragem é a única opção.

Diagrama Conceitual de Amostragem




Figure 1: Conceitos Fundamentais em Amostragem

Métodos de Amostragem Probabilística

A **amostragem probabilística** (ou aleatória) é aquela em que todos os elementos da população têm uma chance conhecida (e diferente de zero) de serem selecionados para a amostra. Isso permite calcular a probabilidade de erro amostral e, portanto, generalizar os resultados para a população com um determinado nível de confiança. É a base da inferência estatística (Bussab; Morettin, 2017).

Amostragem Aleatória Simples (AAS) - Simple Random Sampling (SRS)

É o método mais básico. Cada elemento da população tem a mesma probabilidade de ser selecionado.

Como funciona:

1. Obter uma lista completa de todos os elementos da população (frame amostral).
2. Atribuir um número único a cada elemento.
3. Utilizar um gerador de números aleatórios para selecionar os elementos.

Vantagens:

- Simples de entender e implementar.
- Livre de vieses do pesquisador.
- Base para outros métodos.

Desvantagens:

- Exige uma lista completa da população (nem sempre disponível).
- Pode ser impraticável para populações muito grandes.
- Pode não garantir a representatividade de subgrupos importantes (chance de selecionar apenas um tipo de elemento por acaso).

Exemplo: Amostragem Aleatória Simples

Python

```
import pandas as pd
import numpy as np

# População de exemplo: 1000 IDs
populacao_ids = list(range(1, 1001))
print(f"Tamanho da população: {len(populacao_ids)}")

# Definir o tamanho da amostra
tamanho_amostra = 50

# Amostragem Aleatória Simples
# np.random.choice é excelente para isso, com replace=False para não repetir
amostra_aas = np.random.choice(populacao_ids, size=tamanho_amostra, replace=False)

print(f"\nAmostra Aleatória Simples (primeiros 10 IDs): {amostra_aas[:10]}...")
print(f"Tamanho da amostra AAS: {len(amostra_aas)}")
```

R

```
# População de exemplo: 1000 IDs
populacao_ids <- 1:1000
cat(sprintf("Tamanho da população: %d\n", length(populacao_ids)))

# Definir o tamanho da amostra
tamanho_amostra <- 50
```

```
# Amostragem Aleatória Simples
# sample() é a função básica para amostragem em R, com replace=FALSE por padrão
amostra_aas <- sample(populacao_ids, size = tamanho_amostra, replace = FALSE)

cat(sprintf("\nAmostra Aleatória Simples (primeiros 10 IDs): %s...\n", paste(head(amostra_aas, 10), col=1)))
cat(sprintf("Tamanho da amostra AAS: %d\n", length(amostra_aas)))
```

Amostragem Estratificada

A população é dividida em subgrupos (estratos) homogêneos e não sobrepostos. Em seguida, uma amostra aleatória simples é retirada de *cada* estrato. Isso garante que subgrupos importantes sejam representados na amostra na proporção correta.

Quando usar: Quando a população é heterogênea, mas pode ser dividida em estratos homogêneos (ex: renda, sexo, região geográfica).

Vantagens:

- Garante representatividade de subgrupos.
- Reduz o erro amostral se os estratos forem bem definidos.
- Permite análises separadas para cada estrato.

Desvantagens:

- Exige conhecimento prévio da população para definir os estratos.
- O frame amostral precisa conter informações sobre o estrato de cada elemento.

Exemplo: Amostragem Estratificada

Python

```
import pandas as pd
import numpy as np

# População de exemplo com "gênero" como estrato
# Criando um DataFrame simulado
np.random.seed(42)
populacao_df = pd.DataFrame({
    'ID': range(1, 1001),
    'Genero': np.random.choice(['Masculino', 'Feminino', 'Outro'], size=1000, p=[0.48, 0.50, 0.02]),
    'Idade': np.random.randint(18, 65, size=1000)
})

print(f"Distribuição de gênero na população:\n{populacao_df['Genero'].value_counts(normalize=True)}")

# Definir o tamanho total da amostra
tamanho_amostra_total = 100
```




Figure 2: Diagrama de Amostragem Estratificada

```

# Calcular as proporções dos estratos na população
proporcoes_estratos = populacao_df['Genero'].value_counts(normalize=True)

# Calcular o tamanho da amostra para cada estrato
tamanhos_amostra_estratos = (proporcoes_estratos * tamanho_amostra_total).round().astype(int)
print(f"\nTamanhos de amostra por estrato:\n{tamanhos_amostra_estratos}")

amostra_estratificada = pd.DataFrame()
for genero, tamanho in tamanhos_amostra_estratos.items():
    # Selecionar aleatoriamente dentro de cada estrato
    sub_amostra = populacao_df[populacao_df['Genero'] == genero].sample(n=tamanho, random_state=42)
    amostra_estratificada = pd.concat([amostra_estratificada, sub_amostra])

print(f"\nAmostra Estratificada (primeiras 5 linhas):\n{amostra_estratificada.head()}")
print(f"\nTamanho da amostra estratificada: {len(amostra_estratificada)}")
print(f"Distribuição de gênero na amostra estratificada:\n{amostra_estratificada['Genero'].value_counts}")

```

R

```

library(dplyr)

# População de exemplo com "gênero" como estrato
set.seed(42)
populacao_df <- data.frame(
  ID = 1:1000,
  Genero = sample(c('Masculino', 'Feminino', 'Outro'), size = 1000, replace = TRUE, prob = c(0.48, 0.50, 0.02)),
  Idade = sample(18:65, size = 1000, replace = TRUE)
)
cat("Distribuição de gênero na população:\n")
print(prop.table(table(populacao_df$Genero)))

# Definir o tamanho total da amostra
tamanho_amostra_total <- 100

# Calcular as proporções dos estratos na população
proporcoes_estratos <- prop.table(table(populacao_df$Genero))

# Calcular o tamanho da amostra para cada estrato
tamanhos_amostra_estratos <- round(proporcoes_estratos * tamanho_amostra_total)
cat("\nTamanhos de amostra por estrato:\n")
print(tamanhos_amostra_estratos)

amostra_estratificada <- populacao_df %>%
  group_by(Genero) %>%

```



```

sample_n(size = as.numeric(tamanhos_amostra_estratos[cur_group_id()]), replace = FALSE) %>%
ungroup()

cat("\nAmostra Estratificada (primeiras 5 linhas):\n")
print(head(amostra_estratificada, 5))
cat(sprintf("\nTamanho da amostra estratificada: %d\n", nrow(amostra_estratificada)))
cat("Distribuição de gênero na amostra estratificada:\n")
print(prop.table(table(amostra_estratificada$Genero)))

```

Amostragem Sistemática

Seleciona elementos de uma lista ordenada em intervalos regulares.

Como funciona:

1. Obter uma lista ordenada da população.
2. Calcular o intervalo de amostragem $k = N/n$ (população/amostra).
3. Selecionar um ponto de partida aleatório entre 1 e k .
4. Selecionar cada k -ésimo elemento a partir desse ponto.

Vantagens:

- Mais fácil de implementar que a AAS para grandes populações.
- Pode ser mais representativa que a AAS se a lista tiver um padrão subjacente que não seja detectado pela aleatoriedade.

Desvantagens:

- Se houver um padrão oculto na lista que se alinha com o intervalo k , pode introduzir viés.
- Exige uma lista ordenada da população.

Amostragem por Conglomerados (Cluster Sampling)

A população é dividida em grupos (conglomerados) que são heterogêneos internamente, mas homogêneos entre si (miniaturas da população). Em vez de amostrar indivíduos de cada grupo, amostra-se *grupos inteiros*.

Como funciona:

1. Dividir a população em conglomerados (ex: bairros, escolas, cidades).
2. Selecionar aleatoriamente alguns conglomerados.
3. Coletar dados de *todos* os elementos dentro dos conglomerados selecionados.
 - (Pode haver estágios múltiplos, por exemplo, selecionar cidades e depois bairros dentro das cidades).

Quando usar: Quando a população está geograficamente dispersa ou quando é mais eficiente amostrar grupos do que indivíduos isolados.

Vantagens:

- Economia de custos e tempo, especialmente para populações dispersas.

- Não requer uma lista completa de todos os indivíduos, apenas dos conglomerados.

Desvantagens:

- Pode levar a um erro amostral maior do que AAS ou estratificada se os conglomerados não forem realmente representativos da população.
- Os resultados podem ser menos precisos.

Métodos de Amostragem Não Probabilística

A **amostragem não probabilística** é aquela em que a seleção dos elementos da amostra não envolve aleatoriedade, e a probabilidade de cada elemento ser selecionado é desconhecida. Isso significa que não se pode quantificar o erro amostral, e as conclusões não podem ser generalizadas estatisticamente para a população.

Quando usar: Para estudos exploratórios, pesquisas qualitativas, quando a amostragem probabilística é inviável, ou para obter insights rápidos e de baixo custo.

Amostragem por Conveniência

Seleciona os elementos mais acessíveis ou fáceis de alcançar.

Exemplo: Entrevistar pessoas que passam na rua ou alunos de uma sala de aula específica.

Vantagens:

- Muito rápida e barata.

Desvantagens:

- Alto risco de viés, pois a amostra pode não ser representativa.
- Resultados não generalizáveis.

Amostragem por Quotas

Semelhante à estratificada, mas a seleção dentro de cada “cota” não é aleatória. A população é dividida em subgrupos com base em características específicas (cotas), e o pesquisador preenche essas cotas com elementos acessíveis.

Exemplo: Entrevistar 50 homens e 50 mulheres, escolhendo as primeiras 50 pessoas de cada gênero que encontrar.

Vantagens:

- Garante representatividade de certos subgrupos (nas proporções definidas).
- Mais rápida e barata que a amostragem estratificada.

Desvantagens:

- Viés de seleção dentro das cotas.
- Não é probabilística, portanto, não generalizável estatisticamente.

Considerações Finais sobre Amostragem

A escolha do método de amostragem depende de diversos fatores, incluindo:

- **Objetivo da Pesquisa:** Se o objetivo é generalizar para a população, métodos probabilísticos são indispensáveis.
- **Recursos (Tempo, Custo):** Restrições de recursos podem levar à escolha de métodos não probabilísticos.
- **Conhecimento da População:** A disponibilidade de um frame amostral e informações sobre estratos.
- **Precisão Requerida:** O nível de precisão desejado para as estimativas.

É crucial sempre declarar o método de amostragem utilizado e suas implicações para a interpretabilidade e generalização dos resultados.

Verificação de Aprendizagem

Resolva os problemas abaixo, aplicando os conceitos de amostragem.

1. Problema 1 (Terminologia):

Considere um estudo sobre a altura média dos estudantes de uma universidade.

- a) Defina a **população** para este estudo.
- b) Defina uma possível **amostra**.
- c) O que seria um **parâmetro** neste contexto?
- d) O que seria uma **estatística** neste contexto?

2. Problema 2 (Escolha do Método de Amostragem):

Para cada cenário abaixo, indique qual método de amostragem probabilística seria mais apropriado (Amostragem Aleatória Simples, Estratificada, Sistemática, por Conglomerados) e justifique sua escolha:

- a) Um pesquisador deseja avaliar a satisfação dos funcionários de uma grande empresa (5.000 funcionários) com o novo plano de benefícios. Ele tem acesso a uma lista alfabética completa de todos os funcionários.
- b) Uma organização de saúde quer estimar a prevalência de uma doença em crianças em idade escolar em um grande estado, que possui muitas cidades e escolas.
- c) Uma empresa de pesquisa de mercado quer saber a opinião de jovens (18-24 anos), adultos (25-54 anos) e idosos (55+ anos) sobre um novo produto, garantindo que cada faixa etária esteja representada proporcionalmente na amostra.
- d) Um analista de qualidade precisa inspecionar 100 itens de um lote de 10.000 itens que saem de uma linha de produção. Os itens estão numerados sequencialmente.

3. Problema 3 (Amostragem em Python/R):

Você possui um dataset simulado de clientes de uma loja online:

ID_Cliente	Idade	Renda	Regiao
1	25	3000	Norte
2	30	5000	Sul

```
3          | 45      | 7000   | Leste  
... (total de 500 clientes)
```

Assuma que há 150 clientes na região Norte, 200 no Sul, 100 no Leste e 50 no Oeste.

- a) Crie um `DataFrame` (Python) ou `data.frame` (R) com 500 clientes simulados, seguindo a distribuição de regiões e com `Idade` entre 18 e 70, `Renda` entre 1500 e 10000.
- b) Utilizando **Amostragem Aleatória Simples**, selecione uma amostra de 50 clientes. Mostre as primeiras 5 linhas da amostra e sua distribuição de `Regiao`.
- c) Utilizando **Amostragem Estratificada** pela coluna `Regiao`, selecione uma amostra de 50 clientes, garantindo que a proporção de clientes de cada região na amostra seja a mesma da população. Mostre as primeiras 5 linhas da amostra e sua distribuição de `Regiao`. Compare esta distribuição com a da amostra aleatória simples.

Referências Bibliográficas

BUSSAB, Luiz O. de M.; MORETTIN, Pedro A. **Estatística Básica**. 9. ed. São Paulo: Saraiva, 2017.