



SME0803 Visualização e Exploração de Dados

Representação de dados quantitativos

Prof. Cibele Russo

cibele@icmc.usp.br

Baseado em

Murteira, B. J. F., Análise Exploratória de Dados. McGraw-Hill, Lisboa, 1993.

Mário de Castro. Notas de aula de Análise Exploratória de Dados. ICMC-USP, 2010.

Variáveis discretas

Dados: n observações de uma variável discreta x .

Existem m diferentes valores $x_1 < x_2 < \dots < x_m$, $1 \leq m \leq n$.

Tabela de frequências: tabela com os valores de x_j e uma das ou ambas as frequências f_j e f_j^* , $j = 1, \dots, m$.

x	frequência absoluta	frequência relativa
x_1	f_1	f_1^*
x_2	f_2	f_2^*
\vdots	\vdots	\vdots
x_m	f_m	f_m^*
<i>Total</i>	n	1(100%)

As frequências acumuladas F_j e F_j^* estão bem definidas, $j = 1, \dots, m$ e podem ser uma coluna de uma tabela de frequências.

Gráfico de linhas verticais

Representação em linhas verticais das frequências absolutas




Gráfico de barras

Representação das frequências absolutas em retângulos.

Gráfico de barras para notas




Gráfico de barras





Gráfico de pontos

Cada observação é representada por um ponto. Valores repetidos produzem pontos empilhados.



Variáveis contínuas

Dados: n observações de uma variável contínua x .

Existem m diferentes valores $x_1 < x_2 < \dots < x_m$, $1 \leq m \leq n$.

Tabela de frequências. Se m é “grande”, uma tabela com todos os diferentes valores não cumpre o papel de resumir os dados.

Variáveis contínuas

Representação em k **intervalos de classe** (ou **classes**) do tipo $[LI_j, LS_j)$, $j = 1, \dots, k$.

LI_j : limite inferior e LS_j : limite superior.

Construção:

- 1 Escolha do número de classes (k). Usualmente, $5 \leq k \leq 15$.
- 2 Cálculo da amplitude (A): $A = \max - \min$, sendo que \min e \max são o menor e o maior valor dos dados.
- 3 Cálculo da amplitude de classe (h): $h = A/k$.
- 4 Obtenção dos limites das classes: $LI_1 = \min$, $LS_1 = LI_1 + h$,
 $LI_2 = LS_1$, $LS_2 = LI_2 + h$, ..., $LI_k = LS_{k-1}$, $LS_k = \max$.

Variáveis contínuas

Observações:

- 1 h e L/I podem ser arredondados por conveniência.
- 2 Cada valor observado de x pertence a uma e apenas uma classe.
- 3 h pode variar com a classe.

Variáveis contínuas

Ponto médio da classe (ou marca de classe): $X_j = \frac{LI_j + LS_j}{2}$

Frequência absoluta da classe (f_j): número de observações $\in [LI_j, LS_j)$.

Frequência relativa de cada intervalo de classe: $f_j^* = f_j/n$.

Frequência acumulada da classe (F_j):

$$F_j = f_1 + f_2 + \dots + f_j = \sum_{i=1}^j f_i, F_k = n$$

Frequência acumulada relativa da classe:

$$F_j^* = \frac{F_j}{n}, F_k^* = 1$$

Obs. Na representação por classes há perda de informação.

Histograma

Densidade de frequência (ou densidade):

$$f_{d_j} = \frac{f_j}{h_j} \text{ ou } f_{d_j}^* = \frac{f_j^*}{h_j}, j = 1, \dots, k$$

Representação gráfica:

Histograma (histogram - Karl Pearson, 1895):

Gráfico de barras adjacentes com bases iguais às amplitudes das classes e alturas iguais às densidades.

Obs. Se as classes tiverem amplitude constante, as alturas das barras usualmente são iguais às frequências.

Histograma


Propriedades do histograma:

$$\bullet \sum_{j=1}^k h_j f_{d_j} = \sum_{j=1}^k h_j \frac{f_j}{h_j} = \sum_{j=1}^k f_j = n$$

$$\bullet \sum_{j=1}^k h_j f_{d_j}^* = \sum_{j=1}^k h_j \frac{f_j^*}{h_j} = \sum_{j=1}^k f_j^* = 1$$





Obs. Na construção de um histograma, quanto maior for n , melhor.

Histograma



O histograma fornece uma ideia da distribuição dos dados.

Variáveis contínuas



Diferentes números de classes

Variáveis contínuas





Figure 7. Living histogram of 143 student heights at University of Connecticut.

Histograma humano.


Fonte: The American Statistician 56(3), 223 - 229, 2002.

Polígono de frequências

Formado pelos segmentos unindo os pontos centrais dos topos das barras.




Polígono de frequências



Polígono de frequências acumuladas (ogiva)

Formado por segmentos de retas unindo o limite superior das classes no topo das barras.



Polígono de frequências acumuladas (ogiva)




Gráfico de pontos

Cada observação é representada por um ponto.

Não há perda de informação.

Se n for grande, o gráfico pode perder em clareza.

Gráfico de pontos




Gráfico de pontos

**Gráfico de pontos
(com arredondamento)**





Gráfico de pontos



New York Times em 21/02/2021:

<https://pbs.twimg.com/media/EuwfGryXAAE6zhc?format=jpg&name=large>

Gráfico de linhas

Representa variáveis coletadas com referência a uma unidade de tempo. Chamadas de séries históricas ou séries temporais (time series). Séries temporais podem ser de variáveis discretas ou qualitativas.




Gráfico de linhas



Gráfico de linhas do índice de Gini de 2012 a 2019.

Fonte: <https://portal.fgv.br/noticias/>

desigualdade-renda-brasil-bate-recorde-aponta-levantar

Gráfico de ramos-e-folhas

Para um conjunto de dados quantitativos contínuos, considerando algum arredondamento específico, representamos a parte fracionária com **folhas** e a parte inteira são os **ramos**.

Motivação: Considere as notas de 100 alunos em uma prova.

```
> stem(notas)

The decimal point is at the |

 1 | 8
 2 | 56
 3 | 14444556789
 4 | 001112244456666677889
 5 | 001112333334555566778999
 6 | 000122445568889
 7 | 00122236777899
 8 | 234579
 9 | 00336
10 | 0
```

Fonte: adaptado das notas de aula de M. Castro.

Gráfico de ramos-e-folhas (stem-and-leaf display ou stemplot)

Representação com **nenhuma ou pouca perda de informação**.

Cada valor observado da variável é dividido em duas partes: **ramo** (dígitos dominantes) e **folha** (dígitos dominados).

Os ramos se situam à esquerda de uma linha vertical e as folhas à direita. O número de ramos é escolhido.

Usualmente uma folha representa o último dígito de um número (números podem ser arredondados ou representados como múltiplos de potências de 10).

Os dígitos restantes de um número compõem o ramo.

Gráfico de caixa (boxplot)

Representação gráfica inteligente que permite a observação da **localização, dispersão, assimetria, pontos discrepantes** (outliers).

Além disso, permite comparar visualmente a distribuição de dados em dois grupos. Pode indicar evidências sobre a igualdade das médias entre os dados de dois grupos, pendente de análise confirmatória inferencial.

Gráfico de caixa (boxplot)

Boxplot ou gráfico de caixa





Gráfico de caixa (boxplot)



Boxplots de dados anuais de passageiros aéreos.