


Introdução à Probabilidade e à Estatística I

Resolução Lista 1

Professor: Pedro Morettin & Chang Chiann

1.

(a) Podemos inserir dados no software R e construir um histograma com 5 intervalos:



(b) Uma medida de posição é a média \bar{X} e uma medida de dispersão é a variância $Var(X) = s_X^2$. No software R, o comando é o seguinte (também pode ser feito no Excel ou outro pacote estatístico):

```
> mean(X)
```

```
[1] 40.42
```

> var(X)

[1] 680.0037

2.

- (a) Quando cada observação é multiplicada por 2, temos o seguinte para as medidas (assume-se que X é a matriz de dados original e Y a matriz multiplicada por 2, ou seja, $Y_i = 2X_i$):

Média:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$
$$\bar{Y} = \frac{\sum_{i=1}^n 2 \cdot X_i}{n} = 2 \cdot \bar{X}$$

Variância:

$$s_X^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} = \frac{\sum_{i=1}^n X_i^2 - n\bar{X}^2}{n-1}$$
$$s_Y^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n-1} = \frac{\sum_{i=1}^n (2 \cdot X_i)^2 - n\bar{Y}^2}{n-1}$$

Segue que:

$$s_Y^2 = \frac{\sum_{i=1}^n 4 \cdot X_i^2 - 4n\bar{X}^2}{n-1} = 4 \cdot s_X^2$$

Mediana:

$$\text{med}(Y) = 2 \cdot \text{med}(X)$$

Note que usando os dados do problema 1, a mediana é a média aritmética entre a observação de número 25 e a observação de número 26, após a ordenação dos dados em ordem crescente. Logo, qualquer transformação que não altere a ordenação e que seja realizada em todas as observações (neste caso, a multiplicação por 2) impactará da mesma forma a mediana.

- (b) Seguindo os passos do item anterior poderíamos provar que (assume-se que X é a matriz de dados original e Y a matriz somada do valor 10, ou seja, $Y_i = X_i + 10$):

Média: $\bar{Y} = \bar{X} + 10$

Variância: $s_Y^2 = s_X^2$ (variância de uma constante é zero)

Mediana: $\text{med}(Y) = \text{med}(X) + 10$

(c) Agora suponha que $Y_i = (X_i - \bar{X})$. Assim, temos:

$$\text{Média: } \bar{Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})}{n} = \frac{\sum_{i=1}^n X_i}{n} - \frac{n\bar{X}}{n} = 0$$

$$\text{Variância: } s_Y^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n-1} = \frac{\sum_{i=1}^n Y_i^2 - n\bar{Y}^2}{n-1} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} = s_X^2$$

(novamente, dado que \bar{X} é uma constante, não afeta a variância)

$$\text{Mediana: } \text{med}(Y) = \text{med}(X) + \bar{X}$$

(d) Agora suponha que $Y_i = \frac{(X_i - \bar{X})}{s_X}$

$$\text{Média: } \bar{Y} = \frac{\sum_{i=1}^n \frac{(X_i - \bar{X})}{s_X}}{n} = \frac{\sum_{i=1}^n X_i}{ns_X} - \frac{n\bar{X}}{ns_X} = 0$$

$$\text{Variância: } s_Y^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n-1} = \frac{\sum_{i=1}^n Y_i^2 - n\bar{Y}^2}{n-1} = \frac{\sum_{i=1}^n \frac{(X_i - \bar{X})^2}{s_X^2}}{(n-1)s_X^2} = \frac{s_X^2}{s_X^2} = 1$$

3.

(a) A mediana é uma medida resistente, pois é pouco afetada por valores extremos, ao passo que a média não. Por exemplo, se temos os seguintes dados observados: 5,7,8,10,12,15. A mediana $\text{med}(X)$ é 9 e a média \bar{X} é 9,5. Porém, se último valor ao invés de 15 torna-se 150, teríamos $\text{med}(X) = 9$ e $\bar{X} = 32$. Ou seja, a mediana é mais adequada quando a distribuição é assimétrica à direita ou à esquerda.

(b) Sempre que os dados forem simétricos, teremos $\text{med}(X) = \bar{X}$. Por exemplo, usando o software R:


```
> X <- c(1,2,2,3,3,3,4,4,4,4,5,5,5,5,5,6,6,6,6,7,7,7,8,8,9)
> median(X)
```

```
[1] 5
```

```
> mean(X)
```




```
[1] 5
```

```
> hist(X,breaks=c(0,1,2,3,4,5,6,7,8,9),main="")
```



(c) Podemos usar variáveis normais com médias iguais e variâncias crescentes. No software R:

```
> X<-rnorm(1000,mean=0,sd=1)
> Y<-rnorm(1000,mean=0,sd=2)
> Z<-rnorm(1000,mean=0,sd=3)
> par(mfrow=c(3,1))
> hist(X,xlim=c(-10,10))
> hist(Y,xlim=c(-10,10))
> hist(Z,xlim=c(-10,10))
```



Ou seja, o histograma tem aparência mais dispersa, quanto maior a variância.

4.


- (a) Denominando por X a variável aleatória do peso dos frangos, temos que a média aproximada $Me(X)$ neste caso é obtida usando os pontos médios (x_1, x_2, \dots, x_6) de cada classe e as respectivas frequências (n_1, n_2, \dots, n_6) com que cada classe de peso ocorre:

$$Me(X) = \frac{970 \cdot 60 + 990 \cdot 160 + 1010 \cdot 280 + 1030 \cdot 260 + 1050 \cdot 160 + 1070 \cdot 80}{1000} = 1020,8$$

- (b) A variância aproximada é obtida de forma semelhante, usando como se os pontos médios (x_1, x_2, \dots, x_6) fossem as observações e considerando a média obtida no item (a).

$$Var(X) = \frac{\sum_{i=1}^n n_i (x_i - Me(X))^2}{n} = 691,36$$

(c) O histograma fica o seguinte:



(d) Podemos calcular os quantis/ percentis e achar os limites das quatro categorias da seguinte forma (note que para isso tivemos que acumular os percentuais). No software R, usamos o código:

```
> quantile(X, probs=c(0.2, 0.5, 0.8, 1))
```

```
20% 50% 80% 100%
990 1020 1050 1070
```

Logo, o limites de peso (X) das categorias são os seguintes:

A: $X \leq 990$ gramas

B: $990 < X \leq 1020$ gramas

C: $1020 < X \leq 1050$ gramas

D: $X > 1050$ gramas

(e) Sabemos que a média é de 1020,8 gramas e a variância é de 691,36, logo o desvio padrão é de 26,29. Assim, o granjeiro decide separar os animais com peso inferior à $(1020,8 - 2 \cdot 26,29) = 968,21$ para receberem ração reforçada e os com peso superior à 1060,24 para serem reprodutores. Podemos então obter os percentuais de frangos

sujeitos a esses tratamentos específicos calculando a área do histograma abaixo de 968,21 e a área acima de 1060,24 e dividindo pela área total. Assim, temos que 2,46% dos frangos receberão ração reforçada e 7,9% serão separados para reprodução.

5.

- (a) Temos que calcular a média aproximada da distribuição, considerando os pontos médios de cada intervalo, conforme o exercício 4.

$$Me(X) = \frac{19 \cdot 18 + 21 \cdot 12 + 24 \cdot 10 + 28 \cdot 8 + 33 \cdot 2}{50} = 22,48$$


Sendo assim, como a média aproximada é superior a 22, temos que a campanha surtiu algum efeito.

- (b) Vamos calcular a variância aproximada considerando os pontos médios:


$$Var(X) = \frac{\sum_{i=1}^n n_i (x_i - Me(X))^2}{n} = 14,64$$

Logo, $dp(X) = 3,82$ e $\frac{2dp(X)}{\sqrt{n}} = 1,083$. Como $Med(X) - 22 = 0,48$, temos que a campanha não surtiu efeito, segundo esta regra.

- (c) O histograma, considerando os pontos médios é o seguinte. Nota: o software R somente produz gráficos com valores equidistantes no eixo x , porém os intervalos das classes não são equidistantes. Contudo, é possível notar que a primeira classe vai de 18 a 20, a segunda vai de 20 a 22, a terceira de 22 a 26 e assim por diante, terminando em $X=36$.



6.



7.

(a) Vamos calcular os quantis da distribuição do Ex.1 usando o software R:

```
> quantile(X,probs=c(0.1,0.4,0.8,0.9))
```

```
10% 40% 80% 90%  
13.9 25.6 65.2 78.2
```


(b) Usamos o mesmo comando, porém agora com as probabilidades dos quartis:

```
> quantile(X,probs=c(0.25,0.5,0.75))
```

```
25% 50% 75%  
20.25 31.00 61.00
```

(c) O desvio absoluto mediano é igual à mediana dos desvios absolutos dos dados em relação à mediana. Usando os dados, temos que $med(X) = 31$. Logo, a medida é igual à 17.

8.



Ou seja, os dados claramente não são simétricos.

9.

- (a) Chamando de Y a variável que representa os dados, temos que a média, a mediana, o desvio padrão e o desvio médio são, respectivamente:

$$Me(Y) = 18,4$$

$$Med(Y) = 14,8$$

$$dp(Y) = 13,066$$


$$dm(Y) = 8,76$$

- (b) A média aparada a 10% é obtida eliminando 10% das menores e das maiores observações e calculando a média aritmética dessa distribuição aparada. Como se tratam de 15 observações, vamos eliminar as duas menores e as duas maiores observações, obtendo uma média aparada de 15,66.

Já o desvio absoluto mediano é calculado da seguinte forma: calculam-se os desvios absolutos de cada observação com relação à mediana e daí a mediana desses desvios. Como $Med(Y)=14,8$, temos que o desvio absoluto mediano é 7,4.

- (c) Pelo gráfico podemos ver que há um valor atípico:

```
> boxplot(Y,main = "Box Plot Y",ylab = "Y")
```



10. Podemos calcular algumas medidas usando o software R:

```
> #medidas de posição
```

```
>
```

```
> media<-mean(ibv)
```

```
[1] 18619.97
```

```
> mediana<-median(ibv)
```

```
[1] 13245
```

```
> #medidas de dispersão
```

```
>
```

```
> desvio_padrao<-sd(ibv)
```

```
[1] 14823.54
```

```
> desvio_absoluto_mediano<-mad(ibv, center = median(ibv), constant=1)
```

```
[1] 6445
```

(observação: o desvio padrão no R é calculado dividindo por n-1, ou seja, corresponde ao desvio padrão amostral s_X^2)