

Data Mining

Tópicos em análise de Dados

Prof. Dr. Joaquim Assunção

DEPARTAMENTO DE COMPUTAÇÃO APLICADA
CENTRO DE TECNOLOGIA
UFSM
2024

Fair user agreement

Este material foi criado para a disciplina de Mineração de Dados - Centro de Tecnologia da UFSM.

Você pode usar este material livremente*; porém, caso seja usado em outra instituição, **me envie um e-mail** avisando o nome da instituição e a disciplina.

*A maior parte deste material foi retirado do livro: “**Joaquim V. C. Assunção. Uma Breve Introdução à Mineração de Dados: Bases Para a Ciência de Dados, com Exemplos em R.** 192 páginas. Novatec. 2021. ISBN-10 : 6586057507.”

Prof. Dr. Joaquim Assunção.

joaquim@inf.ufsm.br

Mineração & análise de dados

- Atividade que pode ser realizada antes e depois da mineração.
 - Antes, com o objetivo de entender os dados para melhor formular hipóteses ou definir um tipo de algoritmo alvo.
 - Depois, com o objetivo de validar padrões, apresentar e comparar resultados.

Análise de dados

- O básico para análise de dados é também o elementar da estatística.
 - Comumente, se obtêm em conjuntos valores estatísticos como média, mediana, quartis, e desvio padrão.

// Tais valores servem para descrever conjuntos de dados; da mesma forma como peso, altura, tamanho e cor do cabelo servem para descrever a aparência de uma pessoa.

Technical demo, hands on!

- Em R, use as funções `summary()` e `sd()` para obter média, mediana, quartis, e desvio padrão.
- *Complete o gráfico adicionando os demais valores*



```
X <- sample(40)
plot(X, ylim = c(0,60), ylab="Valores")
text(10,56,paste('Média: ',summary(X)[4]))
```

Análise de dados







- Gráficos são importantes para entender, mostrar e comparar conjuntos de dados.
- São amplamente usados nas mais diversas tarefas, para os mais diversos fins, e com diversos níveis de complexidade.

Análise de dados

- Há diversos tipos de gráficos e incontáveis combinações que podemos fazer para adicionar mais informação em um gráfico. Porém...
- Deve-se tomar cuidado ao criar um gráfico com muitas informações. O excesso de informações não contribui para a qualidade de uma imagem.



Alguns gráficos comuns para análise e visualização de dados



Technical demo, hands on!

- Boxplot em R

```
carros_HPWT <- mtcars[,c(2,4,6)]  
boxplot(hp~cyl,data=carros_HPWT, xlab="Número de cilindros",  
        ylab="Horse Power")
```

- Gráfico de linha em R

```
Y <- sample(30)  
X <- seq(as.Date("2020-07-01"), as.Date("2020-07-30"), by = "days")  
plot(X,Y,type='l', xlab = 'Data', ylab = 'Valores')
```

```
DF <- data.frame(X,Y)  
ggplot(DF, aes(x=X, y=Y)) + geom_line()
```

Requer pacote: *ggplot2*

Distribuições estatísticas

- Distribuições estatísticas revelam como os dados estão distribuídos de acordo com seus valores.
- Algumas das distribuições comuns são: Distribuição Normal, Uniforme, Bernoulli, Binomial, e Pareto.

Distribuições estatísticas

- Cada distribuição possui duas funções: PDF (Probability Density Function) e CDF (Cumulative Density Function).
- A densidade acumulada (CDF) é sempre um valor de 0 a 1 (100%). Já a probabilidade da densidade é um valor específico da variável em questão.
- A função PDF é comumente representada por $f(x)$ (minúsculo), e a função CDF é representada por $F(x)$ (maiúsculo).

Distribuição normal

- Também conhecida como bell curve (curva do sino).
- Fundamental importância para diversas áreas
- Algo em torno de 68% da população estará entre um desvio padrão da média.




Figura 2.10: Distribuição normal.

Distribuição Uniforme

- Clássico exemplo de distribuição uniforme é a jogada de dados (objeto).

$$P(X) = \frac{1}{x_1 - x_n + 1}$$

- Por exemplo, para a jogada de dados, temos: $(1/(6 - 1 + 1)) = 0.1667$ para cada valor.





Figura 2.12: Exemplo de conjunto com distribuição uniforme.



Distribuição de Pareto

- A regra geral é 80 – 20, onde mais de 80% dos recursos são atrelados a menos de 20% dos indivíduos.
- Comumente encontramos gráficos com a densidade acumulada CDF para enfatizar a perspectiva do total.



Distribuição de Pareto

- Além disso, indivíduos da elite são mostrados a esquerda do gráfico; o que é o oposto de outras distribuições



Distribuição de Bernoulli

- A distribuição de Bernoulli é binária no sentido de que só pode haver duas saídas: “sucesso” ou “falha”.
- A densidade de Bernoulli depende diretamente da chance de sucesso atribuída a variável de probabilidade p

$$PDF(K) = \begin{cases} 1 - p & SE \ p == 0 \\ p & SE \ p == 1 \end{cases}$$

Discretas e contínuas

- Dentre as categorias de distribuições, podemos separar em duas, discretas e contínuas.
- Bernoulli e Binomial são exemplos de distribuições discretas.
- Dentre as distribuições contínuas, algumas comumente usadas são Poisson e Exponencial.