

Agrupamento de Dados e Aplicações

Representação de Dados e
Medidas de Proximidade

Prof. Eduardo R. Hruschka



Créditos

- O material a seguir consiste de adaptações e extensões dos originais:
 - Elaborados por Eduardo Hruschka e Ricardo Campello
 - de (Tan et al., 2006)
 - de E. Keogh (SBBD 2003)
 - de G. Piatetsky-Shapiro (KDNuggets)





Agenda

- Motivação
- Tipos e Escalas de Dados
- Normalizações
- Medidas de Proximidade
 - Similaridade
 - Dissimilaridade
- Noções de Significância Estatística (casa)

Agrupamento de Dados (*Clustering*)


- Aprendizado não supervisionado
- Encontrar grupos “naturais” de objetos




Noção de grupo pode ser ambígua





Quantos grupos (clusters)?




Seis grupos



Dois grupos



Quatro grupos



Visualizando Clusters

- Sistema visual humano é muito poderoso para reconhecer padrões
- Entretanto...
 - *"Humans are good at discerning subtle patterns that are really there, but equally so at imagining them when they are altogether absent"* (Carl Sagan)
- Everitt et al., Cluster Analysis, Chapter 2 (Visualizing Clusters), Fourth Edition, Arnold, 2001

Definindo o que é um Cluster

- Conceitualmente, definições são subjetivas:
 - Homogeneidade (coesão interna)...
 - Heterogeneidade (separação)...
 - Densidade (concentração)...
- É preciso formalizar matematicamente
- Existem diversas medidas
 - Cada uma induz (impõe) uma estrutura aos dados
 - Em geral, baseadas em algum tipo de **(dis)similaridade**

Medidas de (Dis)Similaridade

- Existem diversas medidas de (dis)similaridade, para diferentes contextos de aplicação
- Cada uma presume que os objetos são descritos por atributos de uma determinada natureza
 - qualitativos, quantitativos, misturas, textos
- Para discuti-las precisamos antes falar um pouco sobre tipos e escalas de dados...

❑ Reconhecer o **tipo** e a **escala** dos dados nos ajuda a escolher o algoritmo de agrupamento:

❑ **Tipo de dados:** no presente contexto, refere-se ao grau de quantização dos dados

❑ Atributo **Binário**:

❑ 2 valores

❑ Atributo **Discreto**:

❑ valores enumeráveis

❑ **binário** é caso particular

❑ Atributo **Contínuo**:

❑ valores numéricos reais

❑ Podemos tratar qualquer atributo como assumindo valores na forma de números, em algum tipo de **escala**

❑ **Escala de dados:** indica a significância relativa dos números (nominal, ordinal, intervalar e taxa)

❑ **Escala Qualitativa:**

❑ **Nominal:** números usados como *nomes*; p. ex.

❑ $\{M, F\} = \{0, 1\}$

❑ $\{\text{Solteiro, Casado, Separado, Viúvo}\} = \{0, 1, 2, 3\}$

❑ **Ordinal:** números possuem apenas informação sobre a ordem relativa:

❑ $\{\text{ruim, médio, bom}\} = \{1, 2, 3\} = \{10, 20, 30\} = \{1, 20, 300\}$

❑ $\{\text{frio, morno, quente}\} = \{1, 2, 3\}$

Faz sentido realizar cálculos diretamente com escalas qualitativas?

❑ Escala Quantitativa:

❑ Intervalar:

❑ Interpretação dos números depende de uma unidade de medida, cujo zero é arbitrário

❑ Exemplos:

❑ $26^{\circ}\text{C} = 78^{\circ}\text{F}$ não é 2 vezes mais quente do que 13°C (55°F)

❑ 400D.C. não é 2x mais tempo histórico do que 200D.C.

❑ Razão:

❑ Interpretação não depende de qualquer unidade

❑ Exemplo:

❑ $2x \text{ Salário} = 2x \text{ poder de compra}$, “independentemente” da moeda

Medidas de (Dis)similaridade

"A escolha da medida de dis(similaridade) é importante para aplicações, e a melhor escolha é frequentemente obtida via uma combinação de experiência, habilidade, conhecimento e sorte..."

Gan, G., Ma, C., Wu, J., **Data Clustering: Theory, Algorithms, and Applications**, SIAM Series on Statistics and Applied Probability, 2007

Notação

- **Matriz de Dados $\mathbf{X}$:**

- N linhas (objetos) e n colunas (atributos):

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & & \ddots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{Nn} \end{bmatrix}$$

- Cada **objeto** (linha da matriz) é denotado por um vetor $\mathbf{x}_i$

- Exemplo:

$$\mathbf{x}_1 = [x_{11} \quad \cdots \quad x_{1n}]$$

Notação

- **Matriz de Dados $\mathbf{X}$:**

- N linhas (objetos) e n colunas (atributos):

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & & \ddots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{Nn} \end{bmatrix}$$

- Cada **atributo** (coluna) da matriz será denotada por um vetor $\mathbf{a}_i$

- Exemplo:

$$\mathbf{a}_1 = [x_{11} \quad \cdots \quad x_{N1}]^T$$


Notação

- **Matriz de Proximidade** (Dissimilaridade ou Similaridade):

- N linhas e N colunas:

$$\mathbf{D} = \begin{bmatrix} d(\mathbf{x}_1, \mathbf{x}_1) & d(\mathbf{x}_1, \mathbf{x}_2) & \cdots & d(\mathbf{x}_1, \mathbf{x}_N) \\ d(\mathbf{x}_2, \mathbf{x}_1) & d(\mathbf{x}_2, \mathbf{x}_2) & \cdots & d(\mathbf{x}_2, \mathbf{x}_N) \\ \vdots & & \ddots & \vdots \\ d(\mathbf{x}_N, \mathbf{x}_1) & d(\mathbf{x}_N, \mathbf{x}_2) & \cdots & d(\mathbf{x}_N, \mathbf{x}_N) \end{bmatrix}$$

- Simétrica se proximidade d apresentar propriedade de simetria



Proximidade

■ Similaridade

- Mede o quanto dois objetos são parecidos
 - quanto mais parecidos, maior o valor
- Geralmente valor $\in [0, 1]$

■ Dissimilaridade


- Mede o quanto dois objetos são diferentes
 - quanto mais diferentes, maior o valor
- Geralmente valor $\in [0, d_{\max}]$ ou $[0, \infty]$


Similaridade x Dissimilaridade

- Converter dissimilaridades (**d**) em similaridades (**s**) e vice-versa é útil:
 - Se ambas forem definidas em $[0,1]$, a conversão é direta:
 - $\mathbf{s} = 1 - \mathbf{d}$ ou $\mathbf{d} = 1 - \mathbf{s}$ (linear, não distorce os valores)
 - Caso contrário, algumas alternativas são:
 - se limitantes para **s** ($s_{\min}$ e $s_{\max}$) ou **d** ($d_{\min}$ e $d_{\max}$) forem conhecidos, podemos re-escalar em $[0,1]$ e usar $\mathbf{s} = 1 - \mathbf{d}$ (homework)
 - se $\mathbf{d} \in [0, \infty]$, não há como evitar uma transformação não linear
 - Ex: $\mathbf{s} = 1/(1 + \alpha \mathbf{d})$ ou $\mathbf{s} = e^{-\alpha \mathbf{d}}$

$\alpha \rightarrow$ constante positiva


- melhor forma depende do problema





Dissimilaridade e Distância

- Dissimilaridades são em geral calculadas utilizando medidas de **distância**
- Uma medida de distância é uma medida de dissimilaridade que apresenta um conjunto de propriedades



Propriedades de Distâncias

- Seja $d(\mathbf{p}, \mathbf{q})$ a distância entre dois objetos $\mathbf{p}$ e $\mathbf{q}$
- Então valem as seguintes propriedades:
 - **Positividade e Reflexividade:**
 - $d(p, q) \geq 0 \quad \forall p \text{ e } q$
 - $d(p, q) = 0$ se, e somente se, $p = q$
 - **Simetria:**
 - $d(p, q) = d(q, p) \quad \forall p \text{ e } q$
- Além disso, d é dita uma **métrica** se também vale:
 - $d(p, q) \leq d(p, r) + d(r, q) \quad \forall p, q \text{ e } r$ (**Desigualdade Triangular**)
 - Estudar slide oculto (homework)

Desigualdade Triangular:

- Encontrar o objeto mais próximo de **Q** em uma base de dados formada por três objetos (**a,b,c**)

- Assumamos que já se disponha de algumas distâncias entre pares de objetos: $d(a,b)$, $d(a,c)$, $d(b,c)$

- Calculamos $d(Q,a) = 2$ e $d(Q,b) = 7.81$

- Não é necessário calcular explicitamente $d(Q,c)$:

$$d(Q,b) \leq d(Q,c) + d(c,b)$$


$$d(Q,b) - d(c,b) \leq d(Q,c)$$

$$7.81 - 2.30 \leq d(Q,c)$$


$$5.51 \leq d(Q,c)$$

➤ Já se pode afirmar que **a** está mais próximo de **Q** do que qualquer outro objeto da base de dados

➤ Veremos mais adiante no curso um possível uso desta propriedade em agrupamento de dados



	a	b	c
a		6.70	7.07
b			2.30
c			



Propriedades de Similaridade

- As seguintes propriedades são desejáveis e em geral são válidas para similaridades:
 - Seja $s(\mathbf{p}, \mathbf{q})$ a similaridade entre $\mathbf{p}$ e $\mathbf{q}$
 - $s(p, q) = 1$ apenas se $p = q$ (similaridade máxima)
 - $s(p, q) = s(q, p) \quad \forall p \text{ e } q$ (simetria)

Medidas de (Dis)similaridade:

a) Atributos **contínuos**

b) Atributos **discretos**

c) Atributos **mistos**

- Estudaremos medidas amplamente utilizadas na prática
- Há uma vasta literatura sobre este assunto
 - ver bibliografia

a) Atributos Contínuos

a.1) Distância Euclidiana:

$$d_{(\mathbf{x}_i, \mathbf{x}_j)}^E = \|\mathbf{x}_i - \mathbf{x}_j\| = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2}$$



- Métrica
- Tende a induzir *clusters* hiper-esféricos
- *Clusters* invariantes com rel. a translação e rotação no espaço dos atributos (Duda et al., Pattern Classification, 2001)
- Implementações computacionais eficientes usam $(d^E)^2$
- Atributos com maiores valores e variâncias tendem a *dominar* os demais...

Exemplo 1:

	a₁	a₂	a₃	a₄
x₁	1	2	5	803
x₂	1	1	5	712
x₃	1	1	5	792
x₄	0	2	6	608
x₅	0	1	5	677
x₆	1	1	5	927
x₇	1	1	5	412
x₈	1	1	6	368
x₉	1	1	6	167
x₁₀	0	2	5	847
Média	0,70	1,30	5,30	631,30
Variância	0,23	0,23	0,23	59045,34

$$d^E(\mathbf{x}_1, \mathbf{x}_2) = ?$$


Exemplo 2:



- Pode-se lidar com tais problemas por meio do que usualmente se denomina **normalização**
- Estudaremos as formas de normalização mais comuns...




Normalização

- Re-escala Linear [0,1]:
$$l_{ij} = \frac{x_{ij} - \min(\mathbf{a}_j)}{\max(\mathbf{a}_j) - \min(\mathbf{a}_j)}$$
- Padronização Escore z :
$$z_{ij} = \frac{x_{ij} - \mu_{\mathbf{a}_j}}{\sigma_{\mathbf{a}_j}}$$



N(0,1) se atributo
possui dist. Normal

Normalização não é necessariamente sempre apropriada ...



escore z
(efeito semelhante
para linear [0,1])

❑ Em Resumo:

- Atributos com escala mais ampla / maior variabilidade tendem a ter maior peso nos cálculos de distâncias
 - Isso representa uma espécie de pré-**ponderação** implícita dos dados
 - Normalização busca eliminar esse efeito, assumindo ser artificial
 - p. ex., simples consequência do uso de unidades de medida específicas
 - porém, também impõe uma (contra) ponderação aos dados originais
 - pode introduzir distorções se (ao menos parte das) diferentes variabilidades originais refletiam corretamente a natureza do problema
- ❑ Por esses e outros motivos, agrupamento de dados é considerada uma área desafiadora

Recomendações ?

- Difícil fornecer sugestões independentes de domínio
- Everitt et al. (2001) sugerem que *escores z* e normalizações lineares $[0,1]$ não são eficazes em geral
- Lembremos que ADs envolve, em essência, **análise exploratória de dados**
 - Quais são os pesos mais apropriados ?
 - para pesos 0 e 1 $\Rightarrow$ quais são os melhores atributos ?
 - questão remete a agrupamento em sub-espacos...

a.2) Distância de **Minkowski**:

$$d_{(\mathbf{x}_i, \mathbf{x}_j)}^p = \|\mathbf{x}_i - \mathbf{x}_j\|_p = \left(\sum_{k=1}^n |x_{ik} - x_{jk}|^p \right)^{1/p}$$


- Para $p = 2$: Distância Euclidiana
- Para $p = 1$: Distância de **Manhattan** (*city block, taxicab*)
 - recai na Distância de **Hamming** para atributos binários
- Para $p \rightarrow \infty$: Dist. **Suprema** $d_{(\mathbf{x}_i, \mathbf{x}_j)}^\infty = \|\mathbf{x}_i - \mathbf{x}_j\|_\infty = \max_{1 \leq k \leq n} |x_{ik} - x_{jk}|$
- (Homework) Em 2-dimensões, quais são as superfícies formadas pelos pontos equidistantes de um ponto de origem?

□ a.2.1) Distância de **Minkowski Normalizada**:

$$d_{(\mathbf{x}_i, \mathbf{x}_j)}^p = \|\mathbf{x}_i - \mathbf{x}_j\|_p = \left(\frac{\sum_{k=1}^n \delta_{ijk} |x_{ik} - x_{jk}|^p}{\sum_{k=1}^n \delta_{ijk}} \right)^{1/p}$$

$$\begin{cases} \delta_{ijk} = 0 & \text{se } x_{ik} \textbf{ ou } x_{jk} \text{ forem ausentes} \\ \delta_{ijk} = 1 & \text{se } x_{ik} \textbf{ e } x_{jk} \text{ forem conhecidos} \end{cases}$$

- Permite cálculos na presença de valores faltantes
- Alternativa à imputação
- Qual a melhor abordagem?
 - **análise exploratória de dados...**



Distância com Valores Ausentes

Exemplo (Distância Euclidiana Normalizada entre $\mathbf{x}_1$ e $\mathbf{x}_3$):

Obj. / Atrib.	a_1	a_2	a_3	a_4
$\mathbf{x}_1$	2	-1	?	0
$\mathbf{x}_2$	7	0	-4	8
$\mathbf{x}_3$	?	3	5	2
$\mathbf{x}_4$	?	10	?	5

- **Exercício:** calcule todas as demais distâncias.

a.3) Distância de **Mahalanobis**:

$$\left(d_{(\mathbf{x}_i, \mathbf{v}_j)}^m\right)^2 = (\mathbf{x}_i - \mathbf{v}_j)^T \boldsymbol{\Sigma}_j^{-1} (\mathbf{x}_i - \mathbf{v}_j)$$

$\boldsymbol{\Sigma}_j$ = matriz de covariâncias do j-ésimo grupo de dados, com objetos $\mathbf{x}_l$ ($l = 1, \dots, N_j$) e centro $\mathbf{v}_j$:

$$\boldsymbol{\Sigma}_j = \begin{pmatrix} c_{11} & c_{12} & \dots & c_{1n} \\ c_{21} & c_{22} & \dots & c_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ c_{n1} & c_{n2} & \dots & c_{nn} \end{pmatrix} = \frac{1}{N_j} \sum_{l=1}^{N_j} (\mathbf{x}_l - \mathbf{v}_j)(\mathbf{x}_l - \mathbf{v}_j)^T$$

$$\mathbf{v}_j = \frac{1}{N_j} \sum_{l=1}^{N_j} \mathbf{x}_l$$



simétrica

a.3) Distância de **Mahalanobis**...

$$\left(d_{(\mathbf{x}_i, \mathbf{v}_j)}^m\right)^2 = (\mathbf{x}_i - \mathbf{v}_j)^T \cancel{\Sigma^{-1}} (\mathbf{x}_i - \mathbf{v}_j)$$

- Iniciemos desprezando a inversa da matriz de covariâncias, presumindo que seja **Identidade**
- Vetores capturam, em 2D, diferenças de valores das variáveis em dois eixos (x e y) representadas por Δx e Δy
- Lembrando que:

$$\mathbf{v}_j = \frac{1}{N_j} \sum_{l=1}^{N_j} \mathbf{x}_l$$

Temos que tais diferenças se referem àquelas entre um objeto e o vetor médio de um dado grupo de dados (cluster):

$$d^2 = [\Delta x \ \Delta y] [\Delta x \ \Delta y]^T = \Delta x^2 + \Delta y^2 \text{ (distância Euclidiana)}$$

O que a matriz de covariâncias agrega?

a.3) Distância de **Mahalanobis** ...


Σ_j = matriz de covariâncias do j-ésimo grupo de dados, com objetos $\mathbf{x}_l$ ($l = 1, \dots, N_j$) e centro $\mathbf{v}_j$:

$$\Sigma_j = \begin{pmatrix} c_{11} & c_{12} & \dots & c_{1n} \\ c_{21} & c_{22} & \dots & c_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ c_{n1} & c_{n2} & \dots & c_{nn} \end{pmatrix} = \frac{1}{N_j} \sum_{l=1}^{N_j} (\mathbf{x}_l - \mathbf{v}_j)(\mathbf{x}_l - \mathbf{v}_j)^T \quad \mathbf{v}_j = \frac{1}{N_j} \sum_{l=1}^{N_j} \mathbf{x}_l$$

Em 2D, para cada ponto, $l=1, \dots, N_j$, teremos um componente entrando na média com a forma de $[\Delta x \ \Delta y]^T \times [\Delta x \ \Delta y]$:

$$\begin{bmatrix} \Delta x^2 & \Delta x \Delta y \\ \Delta y \Delta x & \Delta y^2 \end{bmatrix}$$

Ao calcularmos a média dessas matrizes para todos os objetos do grupo, o que capturamos?




Lembrete: queremos calcular a média de termos de forma:

$$\begin{bmatrix} \Delta x^2 & \Delta x \Delta y \\ \Delta y \Delta x & \Delta y^2 \end{bmatrix}$$

- a) Pensando apenas no grupo circular (esquerda), o que esperamos encontrar na matriz?
- b) Analogamente, o que esperamos para o grupo elipsoidal?
- c) (Homework) Faça os cálculos para os dois grupos de dados acima.

Exemplo pedagógico:



Considere o pto. (2,1)
e suas distâncias aos
centros dos grupos:

$$d^m(2,1)_c = 10$$

$$d^m(2,1)_e = 29$$

Consideremos agora
que esse ponto se
mova para cima...


$$\Sigma_c = \begin{bmatrix} 0.1 & 0 \\ 0 & 0.1 \end{bmatrix}$$

$$\Sigma_c^{-1} = \begin{bmatrix} 10 & 0 \\ 0 & 10 \end{bmatrix}$$

$$\Sigma_e = \begin{bmatrix} 0.80 & 0.27 \\ 0.27 & 0.11 \end{bmatrix}$$

$$\Sigma_e^{-1} = \begin{bmatrix} 7 & -17 \\ -17 & 50 \end{bmatrix}$$

Exemplo pedagógico:



Qual é o *cluster* mais próximo?


$$\Sigma_c = \begin{bmatrix} 0.1 & 0 \\ 0 & 0.1 \end{bmatrix}$$

$$\Sigma_c^{-1} = \begin{bmatrix} 10 & 0 \\ 0 & 10 \end{bmatrix}$$

$$\Sigma_e = \begin{bmatrix} 0.80 & 0.27 \\ 0.27 & 0.11 \end{bmatrix}$$

$$\Sigma_e^{-1} = \begin{bmatrix} 7 & -17 \\ -17 & 50 \end{bmatrix}$$

Exemplo pedagógico...



$$d^m(2.0, 1.5)_c = 12.5$$

$$d^m(2.0, 1.5)_e = 8.80$$


- Voltaremos a esse assunto quando estudarmos GK e EM
- Problemas apresentados pela distância de Mahalanobis?
 - Cálculo da inversa da matriz de covariâncias...

Nota:

- A distância de Mahalanobis é uma distância de um objeto a um grupo de pontos (em particular, ao seu centro)
- Se calculada entre dois objetos, assume implicitamente que um deles é o centro de um grupo com covariância Σ_j
- Generalizações para distância entre 2 grupos são discutidas em (Everitt et al., 2001)

Visão Geométrica

- Onde se situam os pontos eqüidistantes de um vetor



a.4) Correlação Linear de **Pearson**

$$r(\mathbf{x}_i, \mathbf{x}_j) = \frac{\frac{1}{n} \sum_{k=1}^n (x_{ik} - \mu_{\mathbf{x}_i})(x_{jk} - \mu_{\mathbf{x}_j})}{\frac{1}{n} \sqrt{\sum_{k=1}^n (x_{ik} - \mu_{\mathbf{x}_i})^2 \sum_{i=1}^n (x_{jk} - \mu_{\mathbf{x}_j})^2}} = \frac{\text{COV}(\mathbf{x}_i, \mathbf{x}_j)}{\sigma_{\mathbf{x}_i} \cdot \sigma_{\mathbf{x}_j}}$$

➤ medida de similaridade



➤ interpretação intuitiva ?

Pearson, K., Mathematical contributions to the theory of evolution, III Regression, Heredity and Panmixia, *Philos. Trans. Royal Soc. London Ser. A*, v. 187, pp. 253-318, 1896.


Interpretação intuitiva – agrupamento de atributos:

a_1	a_2	a_2'
0.8009	0.6000	0.6558
0.8116	0.6128	0.6128
0.8222	0.6255	0.6255
0.8228	0.6262	0.6262
0.8243	0.6280	0.6280
0.8303	0.6352	0.6352
0.8381	0.6446	0.6446
0.8411	0.6482	0.6482
0.8446	0.6523	0.6523
0.8475	0.6558	0.6000

	(a_1, a_2)	(a_1, a_2')
Pearson	1.000	-0.080




Há várias outras medidas de correlação, e.g. ver: Campello & Hruschka, *On Comparing Two Sequences of Numbers and Its Applications to Clustering Analysis*, **Information Sciences**, 2009)



Correlação


- Mede interdependência entre vetores numéricos
 - Por exemplo, interdependência linear
- Pode ser portanto usada para medir similaridade
 - entre 2 objetos descritos por atributos numéricos
 - entre 2 atributos numéricos (seleção de atributos)
- Correlação de **Pearson** mede a compatibilidade linear entre as **tendências** dos vetores
 - despreza média e variabilidade
 - muito útil em bioinformática



Correlação de Pearson

- Cálculo do coeficiente de Pearson:
 - Padronizar vetores via score-z
 - Calcular produto interno


$$p'_k = (p_k - \mu_p) / \sigma_p$$
$$q'_k = (q_k - \mu_q) / \sigma_q$$
$$\text{correlação}(\mathbf{p}, \mathbf{q}) = \frac{\mathbf{p}' \bullet \mathbf{q}'}{n}$$




Correlação

- Valor no intervalo $[-1, +1]$
 - Correlação $(\mathbf{p}, \mathbf{q}) = +1$
 - Objetos p e q têm um relacionamento linear positivo perfeito
 - Correlação $(\mathbf{p}, \mathbf{q}) = -1$
 - Objetos p e q têm um relacionamento linear negativo perfeito
 - Correlação $(\mathbf{p}, \mathbf{q}) = 0$
 - Não existe relacionamento linear entre os objetos p e q
 - Relacionamento linear: $\mathbf{p}_k = a\mathbf{q}_k + b$

Avaliação Visual de Correlação



Scatter plots para dois objetos considerando diferentes pares de atributos.



Exercício

- Calcular correlação de Pearson entre os seguintes objetos **p** e **q**


$$\mathbf{p} = [1 \ -3 \ 0 \ 4 \ 1 \ 0 \ 3]$$

$$\mathbf{q} = [0 \ 1 \ 4 \ -2 \ 3 \ -1 \ 4]$$

a.5) **Cosseno**

- Correlação de Pearson tende a enxergar os vetores como sequências de valores e capturar as semelhanças de forma / tendência dessas sequências
 - Não trata os valores como assimétricos
 - Valores nulos interferem no resultado
- Similaridade baseada no **Cosseno**, embora seja matematicamente similar, possui características diferentes:


$$\cos(\mathbf{x}_i, \mathbf{x}_j) = \frac{\mathbf{x}_i^T \cdot \mathbf{x}_j}{\|\mathbf{x}_i\| \cdot \|\mathbf{x}_j\|}$$



Similaridade Cosseno


- Apropriada para **atributos assimétricos***
 - Muito utilizada em mineração de textos
 - grande número de atributos, poucos não nulos (dados esparsos)
- Sejam $\mathbf{d}_1$ e $\mathbf{d}_2$ vetores de valores assimétricos
 - $\cos(\mathbf{d}_1, \mathbf{d}_2) = (\mathbf{d}_1 \bullet \mathbf{d}_2) / ||\mathbf{d}_1|| ||\mathbf{d}_2||$
 - $\bullet$: produto interno entre vetores
 - $||\mathbf{d}||$: é o tamanho (norma) do vetor $\mathbf{d}$
 - Mede o cosseno do ângulo entre os respectivos versores

Exemplo gráfico:



$$\cos(\mathbf{x}_1, \mathbf{x}_3) = \cos(\mathbf{x}_2, \mathbf{x}_3) = 0.95 \text{ (ângulo } \approx 18^\circ)$$

➤ Para calcular distâncias: $d(\mathbf{x}_i, \mathbf{x}_j) = 1 - \cos(\mathbf{x}_i, \mathbf{x}_j)$



Exemplo numérico

■ Sejam os vetores $\mathbf{d}_1$ e $\mathbf{d}_2$:

■ $\mathbf{d}_1 = [3 \ 2 \ 0 \ 5 \ 0 \ 0 \ 0 \ 2 \ 0 \ 0]$

■ $\mathbf{d}_2 = [1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 1 \ 0 \ 2]$


$$\cos(\mathbf{d}_1, \mathbf{d}_2) = (\mathbf{d}_1 \bullet \mathbf{d}_2) / \|\mathbf{d}_1\| \|\mathbf{d}_2\|$$

$$\mathbf{d}_1 \bullet \mathbf{d}_2 = 3*1 + 2*0 + 0*0 + 5*0 + 0*0 + 0*0 + 0*0 + 2*1 + 0*0 + 0*2 = 5$$

$$\|\mathbf{d}_1\| = (3^2 + 2^2 + 0^2 + 5^2 + 0^2 + 0^2 + 0^2 + 2^2 + 0^2 + 0^2)^{0.5} = (42)^{0.5} = 6.481$$

$$\|\mathbf{d}_2\| = (1^2 + 0^2 + 0^2 + 0^2 + 0^2 + 0^2 + 0^2 + 1^2 + 0^2 + 2^2)^{0.5} = (6)^{0.5} = 2.245$$

$$\cos(\mathbf{d}_1, \mathbf{d}_2) = 0.3150$$



Exercícios

1) Calcular dissimilaridade entre **p** e **q** usando medida de similaridade cosseno:

$$\mathbf{p} = [1 \ 0 \ 0 \ 4 \ 1 \ 0 \ 0 \ 3]$$

$$\mathbf{q} = [0 \ 5 \ 0 \ 2 \ 3 \ 1 \ 0 \ 4]$$

2) Assumindo que **p** e **q** são versores, demonstre que $d_E(\mathbf{p}, \mathbf{q})^2 = 2d_{\cos\theta}$ para $d_{\cos\theta} = (1 - \cos\theta)$

b) Atributos Discretos

Motivação:

	Sexo	País	Estado Civil	Comprar
$\mathbf{x}_1$	M	França	solteiro	Sim
$\mathbf{x}_2$	M	China	separado	Sim
$\mathbf{x}_3$	F	França	solteiro	Sim
$\mathbf{x}_4$	F	Inglaterra	casado	Sim
$\mathbf{x}_5$	F	França	solteiro	Não
$\mathbf{x}_6$	M	Alemanha	viúvo	Não
$\mathbf{x}_7$	M	Brasil	casado	Não
$\mathbf{x}_8$	F	Alemanha	casado	Não
$\mathbf{x}_9$	M	Inglaterra	solteiro	Não
$\mathbf{x}_{10}$	M	Argentina	casado	Não

$$d(\mathbf{x}_1, \mathbf{x}_6) = ?$$

$$d(\mathbf{x}_1, \mathbf{x}_7) = ?$$

b.1) Atributos Binários:

- Calcular a distância entre $\mathbf{x}_1 = [1 \ 0 \ 0 \ 1 \ 1 \ 0 \ 0 \ 1 \ 0 \ 0]$ e $\mathbf{x}_2 = [0 \ 0 \ 0 \ 1 \ 0 \ 1 \ 1 \ 0 \ 0 \ 0]$
- Usando uma tabela de contingências temos:

		Objeto $\mathbf{x}_j$		
Objeto $\mathbf{x}_i$		1	0	Total
	1	n_{11}	n_{10}	$n_{11} + n_{10}$
	0	n_{01}	n_{00}	$n_{01} + n_{00}$
	Total	$n_{11} + n_{01}$	$n_{10} + n_{00}$	n

$$S_{(\mathbf{x}_i, \mathbf{x}_j)}^{SM} = \frac{n_{11} + n_{00}}{n_{11} + n_{00} + n_{10} + n_{01}} = \frac{n_{11} + n_{00}}{n}$$

Coeficiente de Casamento Simples
(Zubin, 1938)

$$1 - S_{(\mathbf{x}_i, \mathbf{x}_j)}^{SM} = \frac{n_{10} + n_{01}}{n} = \frac{d_{(\mathbf{x}_i, \mathbf{x}_j)}^{\text{Hamming}}}{n}$$

(Hamming, 1950)

Entretanto, podemos ter:

➤ **Atributos simétricos:** valores igualmente importantes

➤ Exemplo típico → Sexo (M ou F)

➤ **Atributos assimétricos:** valores com importâncias distintas – presença de um efeito é mais importante do que sua ausência

➤ Exemplo: sejam 3 objetos que apresentam (1) ou não (0) dez sintomas para uma determinada doença

$$\mathbf{x}_1 = [1 \ 0 \ 0 \ 1 \ 1 \ 0 \ 0 \ 1 \ 0 \ 1]$$

$$\mathbf{x}_2 = [1 \ 0 \ 1 \ 1 \ 0 \ 1 \ 1 \ 1 \ 0 \ 0]$$

$$\mathbf{x}_3 = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0]$$

$$SSM(\mathbf{x}_1, \mathbf{x}_2) = 0.5;$$


$$SSM(\mathbf{x}_1, \mathbf{x}_3) = 0.5;$$

➤ Conclusão?

➤ Para atributos assimétricos, pode-se usar, por exemplo, o *Coeficiente de Jaccard* (1908):

$$S_{(\mathbf{x}_i, \mathbf{x}_j)}^{Jaccard} = \frac{n_{11}}{n_{11} + n_{10} + n_{01}}$$

- Focada nos *casamentos* do tipo 1-1
- Despreza *casamentos* do tipo 0-0
- Existem outras medidas similares na literatura, mas CCS e Jaccard são as mais utilizadas
 - Ver Kaufman & Rousseeuw, Finding Groups in Data: An Introduction to Cluster Analysis, Wiley, 2005.



Outro Exemplo

$$\mathbf{p} = [1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0]$$

$$\mathbf{q} = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 1 \ 0 \ 0 \ 1]$$

$n_{01} = 2$ (número de atributos em que $\mathbf{p} = 0$ e $\mathbf{q} = 1$)


$n_{10} = 1$ (número de atributos em que $\mathbf{p} = 1$ e $\mathbf{q} = 0$)

$n_{00} = 7$ (número de atributos em que $\mathbf{p} = 0$ e $\mathbf{q} = 0$)

$n_{11} = 0$ (número de atributos em que $\mathbf{p} = 1$ e $\mathbf{q} = 1$)

$$\begin{aligned} \text{CCS} &= (n_{11} + n_{00}) / (n_{01} + n_{10} + n_{11} + n_{00}) \\ &= (0+7) / (2+1+0+7) = 0.7 \end{aligned}$$

$$J = n_{11} / (n_{01} + n_{10} + n_{11}) = 0 / (2 + 1 + 0) = 0$$



Exercício

- Calcular dissimilaridade entre **p** e **q** usando coeficientes:
 - Casamento Simples
 - Jaccard

$$\begin{aligned}\mathbf{p} &= [1 \ 0 \ 0 \ 1 \ 1 \ 0 \ 1 \ 0 \ 1 \ 1 \ 1 \ 0] \\ \mathbf{q} &= [0 \ 1 \ 0 \ 0 \ 1 \ 1 \ 0 \ 0 \ 1 \ 0 \ 1 \ 1]\end{aligned}$$

b.2) **Atributos Nominais** (não binários)

➤ Pode-se usar uma **Codificação 1-de-n**

○ Exemplo:

○ Estado civil $\in \{\text{solteiro, casado, divorciado, viúvo}\}$:

○ Criar 4 atributos binários: solteiro $\in \{0,1\}$, ... , viúvo $\in \{0,1\}$

➤ Tratar como atributos assimétricos

➤ Pode introduzir um número elevado de atributos

b.3) Atributos Ordinais

Ex.: Gravidade de um efeito: {nula, baixa, média, alta}

- Ordem dos valores é importante
 - Normalizar e então utilizar medidas de (dis)similaridade para valores contínuos (p. ex. Euclidiana, cosseno, etc):
 - $\{1, 2, 3, 4\} \rightarrow (\text{rank} - 1) / (\text{número de valores} - 1)$
 - $\{0, 1/3, 2/3, 1\}$
- Abordagem comum

c) Atributos Mistos (Contínuos e Discretos)

Método de Gower (1971):

$$S_{(\mathbf{x}_i, \mathbf{x}_j)} = \frac{1}{n} \sum_{k=1}^n s_{ijk} \longrightarrow d_{(\mathbf{x}_i, \mathbf{x}_j)} = 1 - S_{(\mathbf{x}_i, \mathbf{x}_j)}$$

Para atributos nominais / binários:

$$\begin{cases} (x_{ik} = x_{jk}) \Rightarrow s_{ijk} = 1; \\ (x_{ik} \neq x_{jk}) \Rightarrow s_{ijk} = 0; \end{cases}$$

Para atributos ordinais ou contínuos:

$$s_{ijk} = 1 - |x_{ik} - x_{jk}| / R_k \quad R_k = \max_m \mathbf{x}_{mk} - \min_m \mathbf{x}_{mk}$$

R_k = faixa de observações do k -ésimo atributo (*termo de normalização*)

General Approach for Combining Similarities

- | Sometimes attributes are of many different types, but an overall similarity is needed
 - and sometimes, there are missing values...

1. For the k^{th} attribute, compute a similarity, s_k , in the range $[0, 1]$.
2. Define an indicator variable, δ_k , for the k^{th} attribute as follows:

$$\delta_k = \begin{cases} 0 & \text{if the } k^{th} \text{ attribute is a binary asymmetric attribute and both objects have} \\ & \text{a value of 0, or if one of the objects has a missing values for the } k^{th} \text{ attribute} \\ 1 & \text{otherwise} \end{cases}$$

3. Compute the overall similarity between the two objects using the following formula:

$$similarity(p, q) = \frac{\sum_{k=1}^n \delta_k s_k}{\sum_{k=1}^n \delta_k}$$

Sumário:

- Medidas de dis(similaridade) mais populares foram descritas, mas há várias outras na bibliografia
- Diferentes medidas de dis(similaridade) afetam a formação (indução) dos *clusters*
 - Como selecionar a medida de (dis)similaridade?
 - Devemos padronizar? Caso afirmativo, como?
- Infelizmente, não há respostas definitivas e globais
- Análise de agrupamento de dados é, em essência, um processo subjetivo, dependente do problema
- Lembrem: **análise exploratória de dados!**

Algumas Questões Complementares...

Suponha que já se conheça um conjunto de pontos que pertençam a um grupo G_1 e que se considere esses pontos como mais ou menos próximos ao grupo como um todo segundo alguma medida de distância a partir do seu centro

Questão: Dado que a distância de um novo ponto (até então desconhecido) para o centro de G_1 é, digamos, $d=5$, o **quão próximo** de G_1 é de fato este ponto ?

- A quantificação ($d=5$) é absoluta, mas a interpretação é relativa
- **Teoria de Probabilidades** pode ajudar

A discussão anterior remete a uma questão fundamental quando se lida com diferentes medidas, índices, critérios para quantificar um determinado evento

Questão: Como interpretar um dado valor medido ?

Note que 0.9, por exemplo, não é necessariamente um valor significativamente alto de uma medida c/ escala 0 a 1

Depende de distribuições de probabilidade !

- Precisamos de uma distribuição de referência para avaliar a magnitude do valor da medida


- Por hora, para fins do nosso exemplo simples, a distribuição de ref. pode ser a da distância “d” de interesse
 - de pontos gerados pelo fenômeno descrito por G_1 ao seu centro
- Suponha hipoteticamente que se conheça essa distribuição:
 - p. ex. normal com média μ e desvio padrão σ , ou seja, $N(\mu, \sigma)$
- Fazendo a padronização escore-z tem-se $N(0,1)$
 - $z = (d - \mu) / \sigma$
- Suponha mais uma vez hipoteticamente que a média e desvio sejam tais que nossa medida $d = 5$ implica $z = 1,96$
- **O que poderíamos concluir...?**

➤ Poderíamos concluir que a probabilidade de se observar um valor de distância $d < 5$ para um ponto de G_1 é 97,5%

➤ Isso pode sugerir que:


➤ um novo ponto observado com $d = 5$ não foi gerado pelo mesmo fenômeno descrito por G_1 , ou

➤ esse ponto é um evento relativamente raro de G_1




➤ Mas... e se não conhecemos a distribuição ?

- Se não conhecemos, podemos tentar estimar...
- No caso do nosso exemplo simples, podemos montar um histograma das distâncias dos pontos conhecidos de G_1



Dados (100 pontos 2D)




Histograma (10 bins) – Dist. Euclidiana

- Aprofundaremos essas questões mais adiante no curso...

Principais referências usadas para preparar essa aula:

- Xu, R., Wunsch, D., **Clustering**, IEEE Press, 2009
 - Capítulos 1 e 2, pp. 1-30
- Jain, A. K., Dubes, R. C., **Algorithms for Clustering Data**, Prentice Hall, 1988
 - Capítulos 1 e 2, pp. 1-25
- Gan, G., Ma, C., Wu, J., **Data Clustering: Theory, Algorithms, and Applications**, SIAM Series on Statistics and Applied Probability, 2007
 - Capítulos 1 e 2, pp. 1-24
- Kaufman, L., Rousseeuw, P. J., **Finding Groups in Data: An Introduction to Cluster Analysis**, 2a Edição, Wiley, 2005
 - Capítulo 1, seção 2



Outras Referências

- Everitt, B. S., Landau, S., Leese, M., *Cluster Analysis*, Hodder Arnold Publication, 2001
- P.-N. Tan, Steinbach, M., and Kumar, V., *Introduction to Data Mining*, Addison-Wesley, 2006
- Duda, R. O., Hart, P. E., and Stork, D. G., *Pattern Classification*, 2nd Edition, Wiley, 2001
- Triola, M. F., *Elementary Statistics*, 8ª Ed., Prentice-Hall, 2000