

K-means parte 2

Jacques Wainer

IC – Unicamp

Novembro 2015

Como escolher o k

- medidas internas - usando apenas os dados originais
- medidas externas - usando informação extra sobre os dados, em particular a classe que eles pertencem.
- medidas externas fazem sentido quando se tem a classe de *alguns* dados e usa-se isso para ajustar os grupos. Se voce tem a classe de todos os dados, então use um classificador.

Medidas internas

- **coesão** dentro de um grupo (intra-grupo): os pontos dentro de um mesmo grupo devem estar próximos entre si.
- **separação** dos diferentes grupos (inter-grupo) os grupos devem estar distantes entre si.
- varias definições e intuições sobre o que são distancia intra cluster e distantcia inter-clusters, e como agrega-las

(Familia de) indice de Dunn

$$DI = \frac{\min inter_{ij}}{\max intra_k} \quad (1)$$

onde $inter_{ij}$ é alguma medida de distancia entre grupos i e j e $intra_k$ é alguma medida de distancia dentro de um grupo k

Coesão implica em um intra pequeno e separação um inter grande, portanto valores maiores de indice de Dunn são preferiveis

(Familia de) indice de Dunn

Medidas $inter_{ij}$

- distancia entre os centros dos grupos
- menor distancia entre os pontos de i e de j
- a media das distancias entre pontos de i e j

Medidas $intra_k$

- soma das distancias do centro aos pontos de k
- maior distancia ente dois pontos de k
- media das distancias entre pontos de k

Silhueta

Para cada dado i

- $a(i)$ é a distancia de i até o centro do seu cluster
- $b(i)$ é a distancia média de i até os dados do cluster mais próximo
- $s(i) = \frac{b(i)-a(i)}{\max[a(i),b(i)]}$ é a silhueta do dado
- a silhueta é a média dos $s(i)$ para todos os dados
- $-1 \leq s(i) \leq 1$ e $s(i) \approx 1$ significa $a(i) \ll b(i)$ - portanto silhuetas altas são preferíveis

Medidas internas

- Há muitas outras medidas internas de qualidade da clusterização,
- Os critérios que se baseiam em uma visão que a distancia intra deve ser pequena e a inter grande são critérios pensados para o k-means onde os grupos são convexos.
- algumas métricas: Gap, figure of merit, intracluster variability, connectivity
- O livro texto tem um capítulo (14) bem detalhado sobre medidas de qualidade de cluster que deve ser consultado. Nas transparencias eu não fiz distinção entre medidas internas e medida relativas (que o livro faz).

Medidas externas

- Se os (ou alguns dos) dados clusterizados pertencem a classes já conhecidas, mas não usadas na clusterização, então essa informação pode ser usada para avaliar a qualidade da clusterização
- um critério é a **concordancia**, ou seja os grupos devem corresponder as classes externas
- um critério é **pureza** ou seja cada grupo deve conter dados de apenas uma classe. Note que pode haver mais grupos/cluster do que classes, mas cada grupo deve ser puro em relação a uma classe

Medidas externas

- A maioria dos índices externos se baseiam em 4 conjuntos:
- SS os **pares** de dados que pertencem ao mesmo cluster (clusterização) e a mesma classe (informação externa)
- SD os pares que pertencem a um mesmo cluster mas a classes diferentes
- DS cluster diferentes mas mesma classe
- DD cluster e classes diferentes
- para concordancia, SS e DD são bons. Para pureza SS, DS e DD são bons.

Algumas medidas externas

- Índice Rand = $\frac{|SS|+|DD|}{|SS|+|SD|+|DS|+|DD|}$
- Índice de Jaccard = $\frac{|SS|}{|SS|+|SD|+|DS|}$
- Índice de Fowlkes e Mallows (entre 0 e 1)
- Hubert normalizado (entre -1 e 1)
- Rand corrigido (entre -1 e 1 e 0 significa que as concordâncias são devido ao acaso).
- variação da informação

Medidas de clusterização em R

pacote `fpc` função `cluster.stats` [▶ link](#)

- matriz de distancia em vez dos dados originais `dist(dados)`
- resultado do clustering `kmeans()$cluster`
- `alt.clustering` as classes externas (se existem)
- computa `dunn`, `silhouette` `avg.silwidth`, `corrected rand` e `variation of information` `vi` se classificação externa fornecida.

Como escolher o k do k-means

- a ideia é usar uma métrica (interna ou externa) e variar o k até achar um máximo (ou mínimo).
- infelizmente isso é mais teórico que prático
- algumas métricas decrescem (ou crescem) sistematicamente como o k e aí você deve procurar uma descontinuidade na curva geral
- [▶ link](#) (ruidoso várias métricas) e [▶ link](#) (várias medidas do Dunn e não apenas uma)

Como escolher o k do k-means em R

```
> library(fpc)
> dat=iris[,-5]
> ddat=dist(dat)
> clus=lapply(2:20,function(x) kmeans(dat,x,nstart=10)$cluster)
> clus[1:2]
..
> stats=lapply(clus,function(x) cluster.stats(ddat,x))
> stats[1]
..
> out=sapply(stats,function(x) c(n=x$cluster.number,dunn=x$dunn))
> out
..
> par(mfrow=c(1,2))
> plot(out[1,],out[2,],xlab="k",ylab="dunn",type="l")
> plot(out[1,],out[3,],xlab="k",ylab="sil",type="l")
```

Como escolher o k em R

Função `kmeansrun` [link](#) faz a busca acima, mas para apenas 2 metricas

- `asw` - silhouette
- `ch` - Calinski-Harabasz (?)

```
> bestkm=kmeansruns(dat,2:20,runs=10,criterion="asw")
```

```
> bestkm
```

```
..
```

```
> b2=kmeansruns(dat,2:20,runs=10,criterion="ch")
```

```
> b2
```

```
...
```

Variações do k-means

Gerar os centros iniciais, e

- 1 atribuir cada dado ao grupo cujo centro está mais próximo
- 2 recomputar o centro do grupo como sendo a média dos dados que pertencem ao grupo

Outras definições de centro: k -medianas

- Mudanças no passo 2 acima:
- k-medianas: computa-se o centro como sendo a mediana dos dados do grupo.
- k-medianas é menos sensível a outliers: pontos anômalos não puxam o centro para eles.
- implementado pela função `kcca` do pacote `flexclust` [▶ link](#)

Outras definições de centro: k-medoids

- o centro é o dado do grupo cuja soma das distancias aos elementos do grupo é a menor
- k-medoids é o unico algoritmo da familia do k-means que funciona para dados relacionais (grafos) - os centros não são “pontos novos” do espaço mas sim um dos dados.
- implementado pela função `pam` do pacote `cluster` [link](#)

Variações algorítmicas

2 truques para big data:

- rode o k-means numa amostra (pequena) dos dados. Isto gera os centros, classifique os dados restantes pela proximidade dos centros. Se a amostra é grande o suficiente, os centros das amostras não é muito diferente do centro de todos os dados

- batch vs online

para todos os dados:

 compute a atribuição

para todos os dados:

 compute o centro

Online k-means

Versão online:

para todos os dados

compute a atribuição

de cada ponto em direção ao centro um pouquinho

- big data: escolha os dados aleatoriamente - *stochastic gradient descent*
- stream learning: use o dado assim que ele chega e nunca mais - *online learning*

Variações sobre a atribuição: fuzzy C-means

- cada ponto pertence a um grupo com “intensidade” proporcional ao inverso de uma potencia da distancia (normalizado, para que as intensidades somem 1 no final)
- fuzzy c-means tem um parametro extra (m *fuzzyfication*) relacionado com a potencia da distancia. m grande torna os intensidade de cada ponto mais ou menos parecida, e portanto os grupos tem grande interseção.
- $m = 1$ faz a intensidade ser 1 para o grupo mais perto e 0 para os outros, portanto o k-means tradicional.
- $m = 2$ é normalmente usado.
- o centro é a media ponderada (pela intensidade) dos pontos.

Fuzzy C-means em R

Implementado pela função `cmean` do pacote `e1071` [link](#)

```
> library(e1071)
> cl=cmeans(iris[,1:4],3,m=2)
> cl
...
> head(cl$membership)
...
> cl5=cmeans(iris[,1:4],3,m=5)
> head(cl5$membership)
...
```

GMM - distancia que depende dos grupos

- Nas variações anteriores, a noção de distancia se mantem. E se tivermos uma definição de distancia que depende do grupo (ou melhor dos dados do grupo)?
- distancia de Mahalanobis - distancia dividido pelo desvio padrao dos dados naquela direção (aproximadamente) [▶ link](#)
- isto resolveria o problema de clusters “mais compactos” [▶ link](#)

GMM - graus de pertencer a um grupo

- GMM (Gaussian Mixture Models) além de incluir a noção de distancia de Mahalanobis, inclui também a noção de graus de pertencimento.
- cada grupo é modelado como uma gaussiana (mutlidimensional). O centro é a media da gaussiana
- a *matriz de covariança* é o equivalente para varias dimensões do desvio padrao da gaussiana.
- Gaussianas são elispoides onde a matriz de covariancia indica quao não esferico o elispoide e a direção do raio maior.
- cada ponto tem um grau de pertencer a cada grupo dado pela probabilidade (normalizada) do ponto na gaussiana correspondente.
- o novo centro e a nova matriz de covariancia são calculados pela media ponderada (pelo grau) de todos os pontos.
- [▶ link](#) r [▶ link](#)

GMM em R

Varios pacotes implementam variações do GMM. O mais simples é o `Mclust` do pacote `mclust` [▶ link](#)

```
> library(mclust)
> cl=Mclust(iris[,1:4],G=3)
> summary(cl,parameters=T)
...
> plot(cl,what="cla",dimens = c(2,3))
```

GMM em R

- GMM permite restrições no formato das gaussianas.
- esfericas ou elipsoidal
- mesmo tamanho, ou não
- mesmo formato se elipsoidal, ou não

```
> cl2=Mclust(iris[,-5],G=3,modelNames="VII")  
> plot(cl2,what="cla",dimens = c(2,3))
```

Pacotes do R mencionado nesta aula

- fpc - métricas
- mclust - GMM
- e1071 - fuzzy c-means
- flexclust - k-medianas

Tarefa

- Use as 4 primeiras dimensões do iris mas agora padronize cada uma das 4 dimensões
- repita a análise da variação do índice de Dunn e da silhouette para valores de k entre 2 e 20.
- faça a mesma análise mas as medidas externas de corrected Rand e variation of information. Use a dimensão 5 do iris que é a classe de cada dado.
- discuta se há um ou mais valores que parecem apropriados para o k .