

Úvod do shlukování v matlabu

R. Kessl

CS CAS, 2. March 2009

Outline

1 K-means

2 Hierarchické shlukování

K-means – Jak funguje ?

Mějme body $x_i \in R^n$ a číslo k určující počet shluků.

- ① Vytvoř počáteční centroidy c_i .
- ② Pro každý bod x_i spočítej příslušnost bodu ke clusteru c_i .
- ③ přeypočítej polohu každého centroidu c_i .

⇒ probíhá iterativně: postupně se upravují centroidy.

K-means

- ① v matlabu fce [IDX, C]=kmeans(data, počet shluků)
(další parametry viz. help)
- ② podstatné parametry: data, počet shluků, měřítko vzdálenosti.

Zkusme si udělat shluky na datech fisheriris.

```
load fisheriris;
[measIDs, measC]=kmeans(meas, 2);
gplotmatrix(meas, meas, measIDs);
silhouette(meas, measIDs);
```

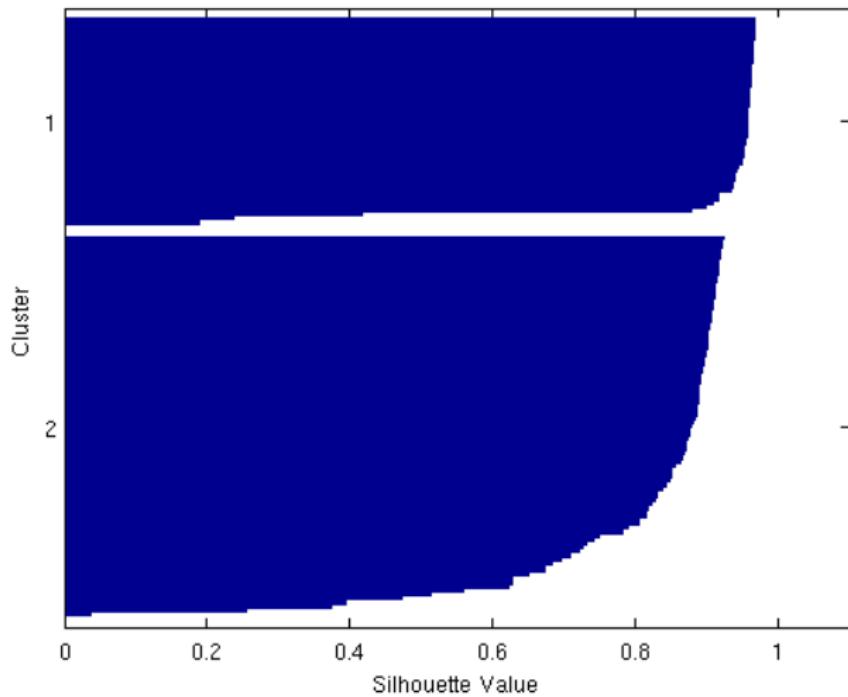
K-means - funkce silhouette

- pro bod x_i udává c_i číslo shluku do kterého x_i patří
- z matematického pohledu je funkce $Silhouette(x)$ měřítko příslušnosti bodu x do clusteru
- počítá se z příslušnosti x_i do **všech** clusterů

K-means - funkce silhouette

- funkce *silhouette* v *matlabu* ukáže jak moc patří jednotlivé body do shluků.
- *silhouette(data, shluky)*
- zobrazuje se každý bod v datech a jeho *silhouette* hodnota
- čím větší hodnota tím více patří bod ke shluku.
- body jsou seřazeny podle shluků a potom podle hodnoty funkce *silhouette*
- zkuste změnit vykreslit silhouette pro různý počet shluků.

K-means - funkce silhouette

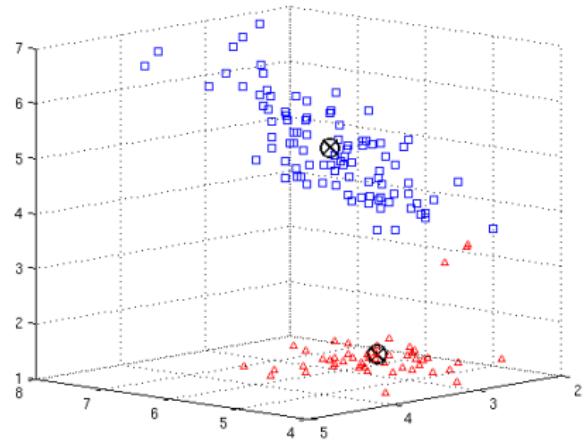


K-means - zobrazení dat ve 3D

- zkusme vizualizovat data, rozdělená na dva shluky

```
ptsymb = {'bs','r^','md','go','c+'};  
for i = 1:2  
    clust = find(measIDs==i);  
    plot3(meas(clust,1),meas(clust,2),meas(clust,3),ptsymb{i});  
    hold on  
end  
  
plot3(measC(:,1),measC(:,2),measC(:,3),'ko','MarkerSize', 14, 'LineWidth',2);  
plot3(measC(:,1),measC(:,2),measC(:,3),'kx','MarkerSize', 14, 'LineWidth',2);  
  
view(-137,10);  
grid on
```

K-means - zobrazení dat ve 3D

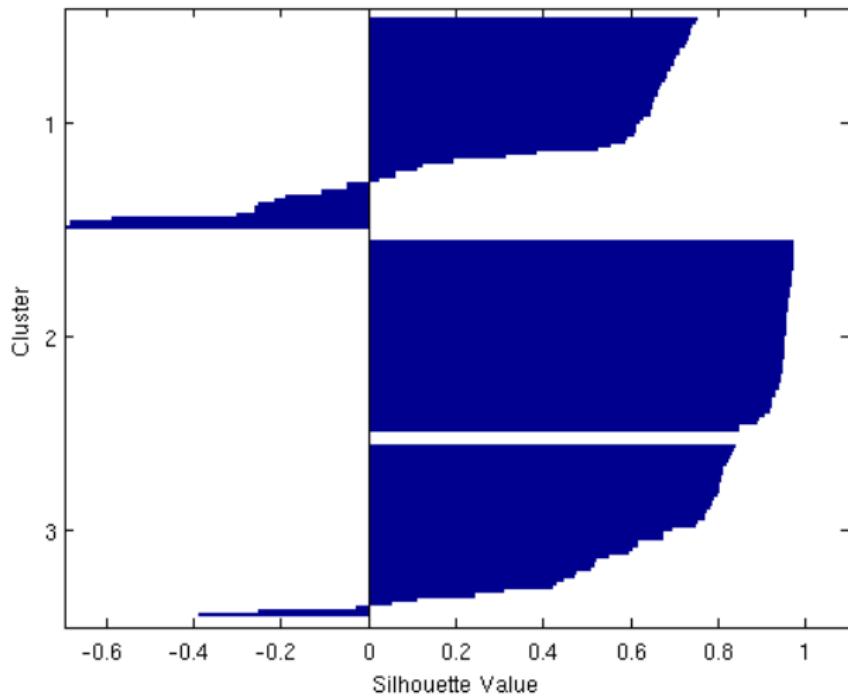


K-means - další parametry shlukování

- parametr 'display' specifikuje co se má během výpočtu vypisovat, zkuste zadat hodnotu iter
- Volba počtu iterací, tedy kolikrát se spustí kmeans s různými počátečními nastaveními centroidů: 'replicates', 5, 'display', 'final'. Ze všech pokusů se vybere ten nejlepší. (zkuste si)
- Volba počátečních centroidů: 'start' (zkuste si doma)
- změna měřítka vzdálenosti: 'dist', zkuste třeba 'cos'

```
[measIDs, measC]=kmeans(meas, 2, 'display', 'final', 'replicates', 5);
[measIDs, measC]=kmeans(meas, 3, 'display', 'final', 'replicates', 5);
[measIDs, measC]=kmeans(meas, 3, 'display', 'final', 'replicates', 5, 'dist', 'cos');
silhouette(meas, measIDs);
```

K-means - další parametry shlukování



K-means – srovnání hodnot silhouette

```
[measIDs,measC] = kmeans(meas,2,'dist','sqeuclidean');
[silh1] = silhouette(meas,measIDs,'sqeuclidean');

[measIDs, measC]=kmeans(meas, 3, 'replicates', 5, 'dist','sqeuclidean');
[silh2] = silhouette(meas,measIDs,'sqeuclidean');

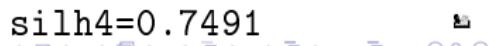
[measIDs, measC]=kmeans(meas, 3, 'dist','sqeuclidean');
[silh3] = silhouette(meas,measIDs,'sqeuclidean');

[measIDs, measC]=kmeans(meas, 3, 'dist','cos');
[silh4]=silhouette(meas, measIDs, 'cos');

[mean(silh1) mean(silh2) mean(silh3) mean(silh4)]
```

Jaký je rozdíl ve vytvořených shluknutí ?

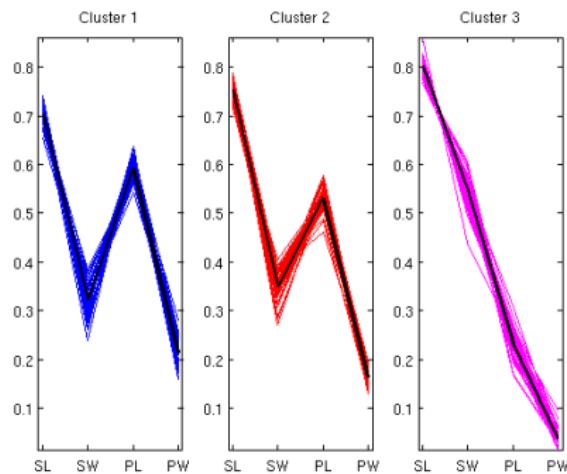
silh1=0.8504 silh2=0.7357 silh3=0.7357 silh4=0.7491



Rozdíl mezi velikostí listů

```
[measIDs, measC] = kmeans(meas, 3, 'dist', 'cos');
lnsymb = {'b-', 'r-', 'm-'};
names = {'SL', 'SW', 'PL', 'PW'};
meas0 = meas ./ repmat(sqrt(sum(meas.^2, 2)), 1, 4);
ymin = min(min(meas0));
ymax = max(max(meas0));
for i = 1:3
    subplot(1, 3, i);
    plot(meas0(measIDs == i, :)', lnsymb{i});
    hold on; plot(measC(i, :)', 'k-', 'LineWidth', 2); hold off;
    title(sprintf('Cluster %d', i));
    set(gca, 'Xlim', [.9 4.1], 'XTick', 1:4, 'XTickLabel', names, 'YLim' =>
        [ymin ymax])
end
```

Rozdíl mezi velikostí listů



Hierarchické shlukování

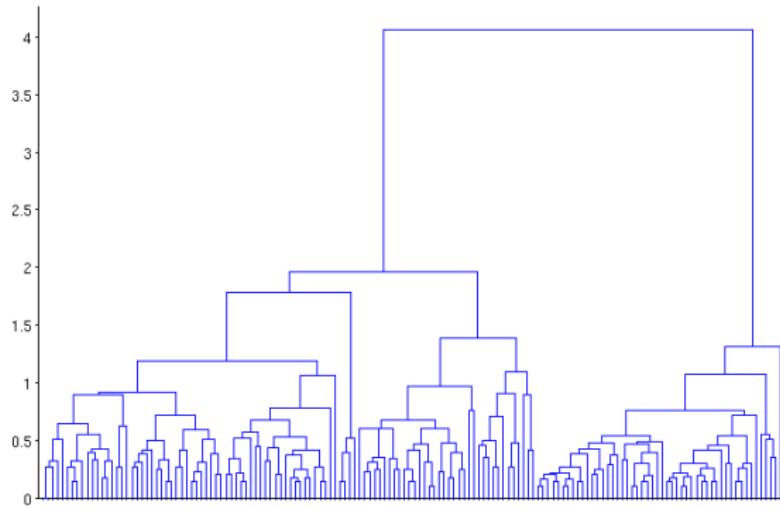
Jak probíhá shlukování ?

- ① Pro hierarchické shlukování potřebuji znát jejich *podobnost/vzdálenost*.
- ② Pro spočítání matic vzdáleností (každý-s-každým) \Rightarrow funkce pdist. $O(n^2)$.
- ③ Shluknutí objektů do binárního stromu \Rightarrow funkce linkage
- ④ cophenetická korelace: určuje jak moc je dendrogram shodný se skutečnými vzdálenostmi. Čím větší číslo, tím lépe.
- ⑤ Visualizace: dendrogram \Rightarrow funkce dendrogram

```
measPdist = pdist(meas, 'euclidean');
measTree = linkage(measPdist, 'average');
[h,nodes] = dendrogram(measTree,0);
set(gca, 'TickDir','out', 'TickLength',[.002 0], 'XTickLabel', []);

cophenet(measTree, measPdist)
```

Hierarchické shlukování



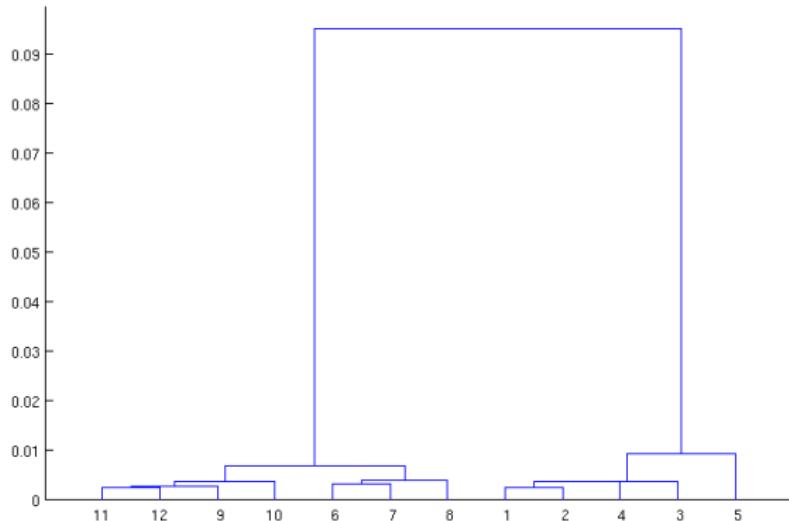
Hierarchické shlukování – pomocí cos vzdálenosti

```
measPdistCos = pdist(meas, 'cosine');
measTreeCos = linkage(measPdistCos, 'average');
cophenet(measTreeCos, measPdistCos)

[h,nodes] = dendrogram(measTreeCos,0);
set(gca, 'TickDir', 'out', 'TickLength',[.002 0], 'XTickLabel', []);

[h,nodes] = dendrogram(clustTreeCos,12);
[sum(ismember(nodes,[11 12 9 10])) sum(ismember(nodes,[6 7 8]))] ←
    sum(ismember(nodes,[1 2 4 3])) sum(nodes==5)]
```

Hierarchické shlukování – pomocí cos vzdálenosti



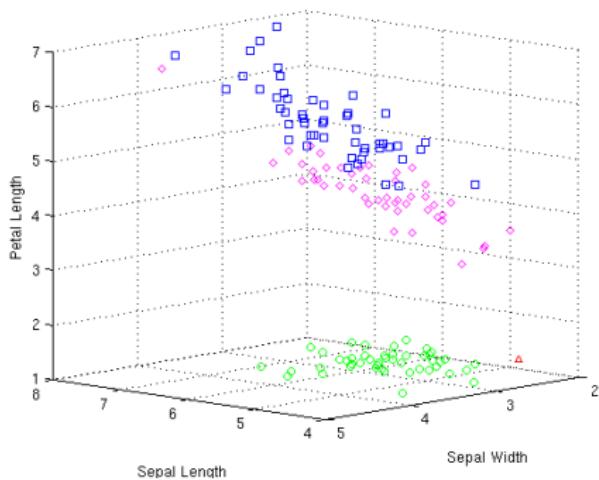
Cophenetický koeficient korelace: 0.9360

Hierarchické shlukování – zobrazení shluků

- modrý a růžový shluk leží blízko u sebe
- zelený shluk je dobře separovný od ostatních shluků

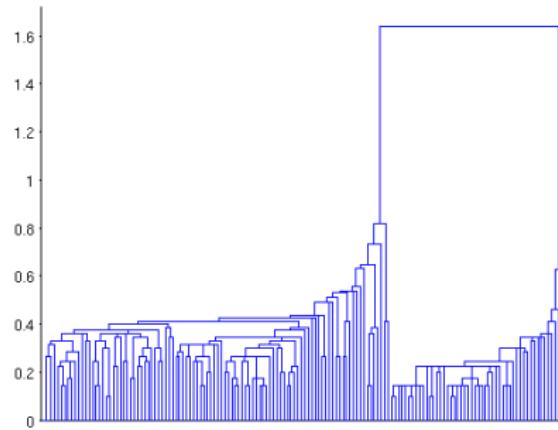
```
hidx = cluster(measTreeCos , 'criterion ', 'distance ', 'cutoff ', .006) ;
for i = 1:5
    clust = find(hidx==i);
    plot3(meas(clust ,1) ,meas( clust ,2) ,meas( clust ,3) ,ptsymb{i});
    hold on
end
hold off
xlabel('Sepal Length'); ylabel('Sepal Width'); zlabel('Petal ←
Length');
view(-137,10);
grid on
```

Hierarchické shlukování – zobrazení shluků



Hierarchické shlukování – single linkage

```
eucD = pdist(meas, 'euclidean');
clustTreeSng = linkage(eucD, 'single');
[h,nodes] = dendrogram(clustTreeSng,0);
set(gca, 'TickDir','out','TickLength',[.002 0], 'XTickLabel',[]);
```



Cophenetický koeficient korelace: 0.8639