

# Vícerozměrné statistické metody

Shluková analýza

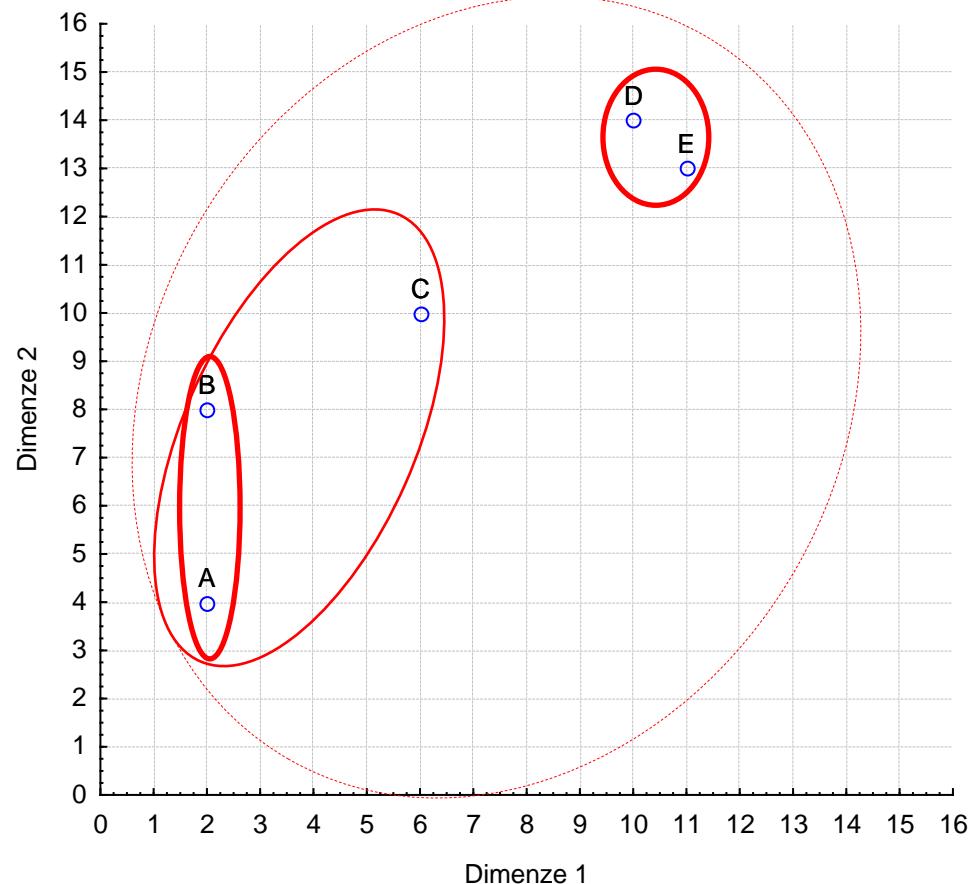
Jiří Jarkovský, Simona Littnerová

# Vícerozměrné statistické metody

Typy shlukových analýz

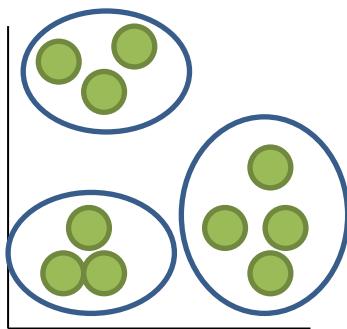
# Shluková analýza: cíle a postupy

- Shluková analýza se snaží o identifikaci shluků objektů ve vícerozměrném prostoru a následnou redukce vícedimenzionálního problému kategorizací objektů do zjištěných shluků
- Existuje řada různých metod pro shlukování dat lišících se:
  - Měřením vzdálenosti mezi objekty
  - Algoritmem spojování objektů do shluků
  - Interpretací výstupů
- Každá z metod má své vlastní předpoklady výpočtu a je nasaditelná pro různé typy úloh
- Porušení předpokladů nebo nasazení chybné metody může vést k zavádějícím výsledkům

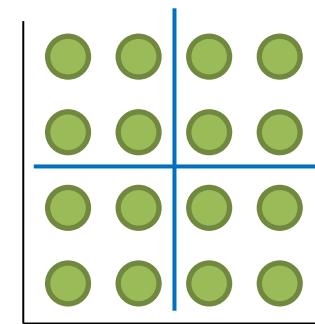


# Obecný princip hledání shluků v datech

- Vzájemnou pozici objektů ve vícerozměrném prostoru lze popsat jejich vzdáleností
- Dle vzdálenosti objektů je můžeme sloučovat do shluků a přiřazení objektů ke shlukům ve vícerozměrném prostoru následně využít pro zjednodušení jejich x-dimenzionálního popisu
- Smysluplnost výsledků shlukování závisí jednak na objektivní existenci shluků v datech, jednak na arbitrárně nastavených kritériích definice shluků



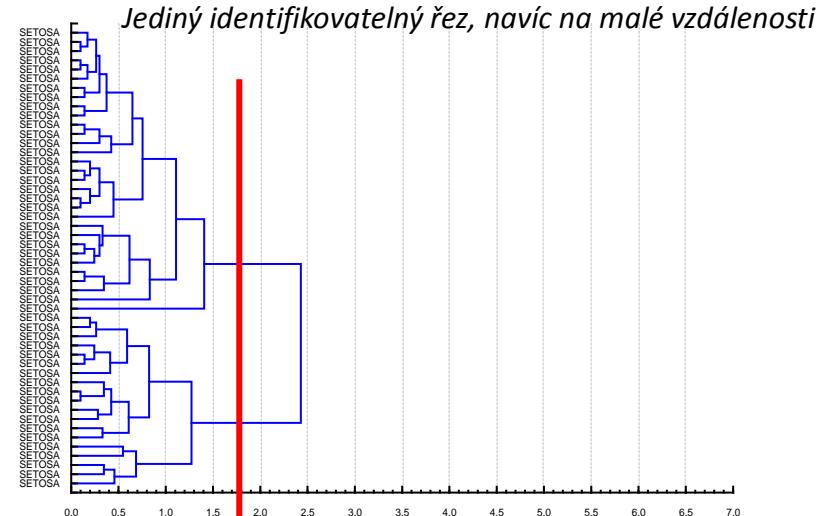
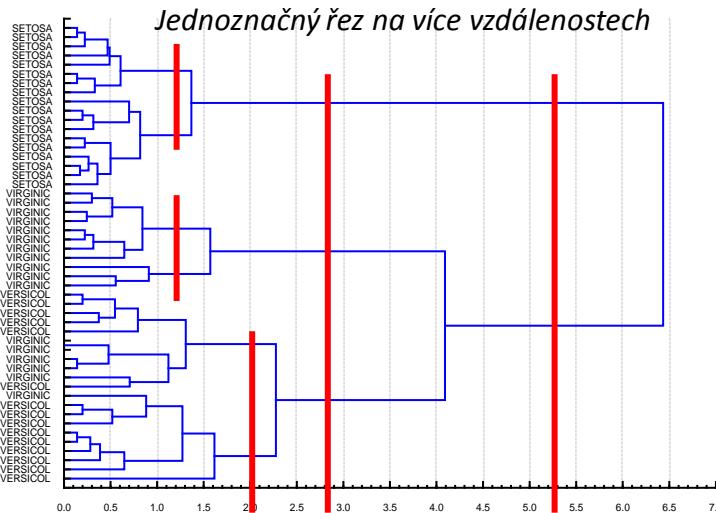
Jednoznačné odlišení existujících shluků v datech (obdoba multymodálního rozložení)



Shluková analýza je možná i v tomto případě, nicméně hranice shluků jsou dány pouze naším rozhodnutím.

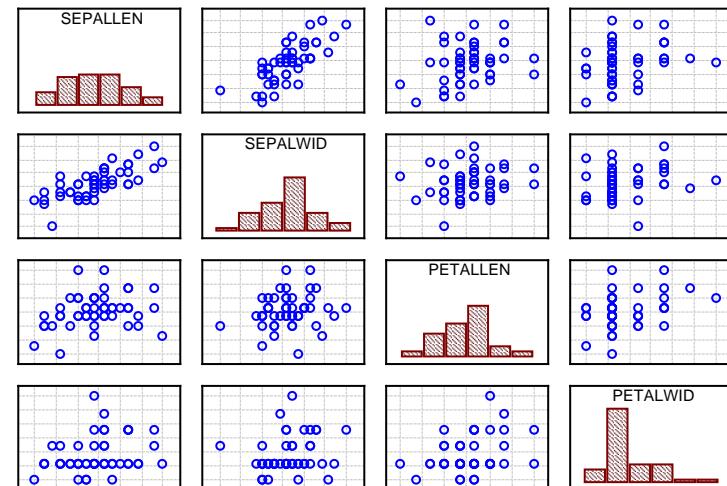
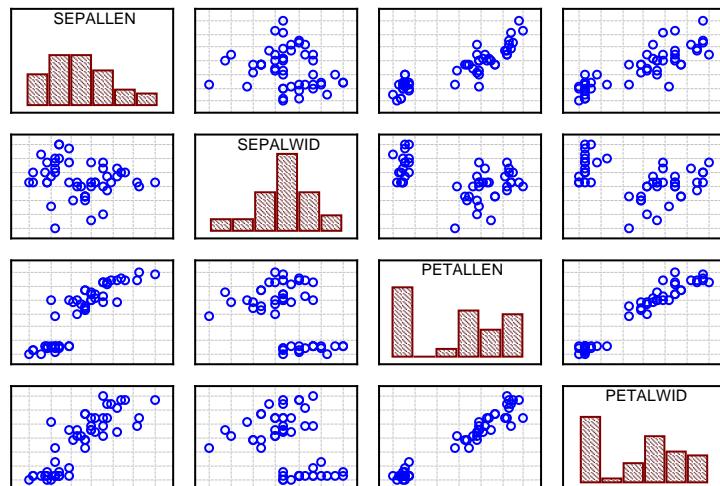
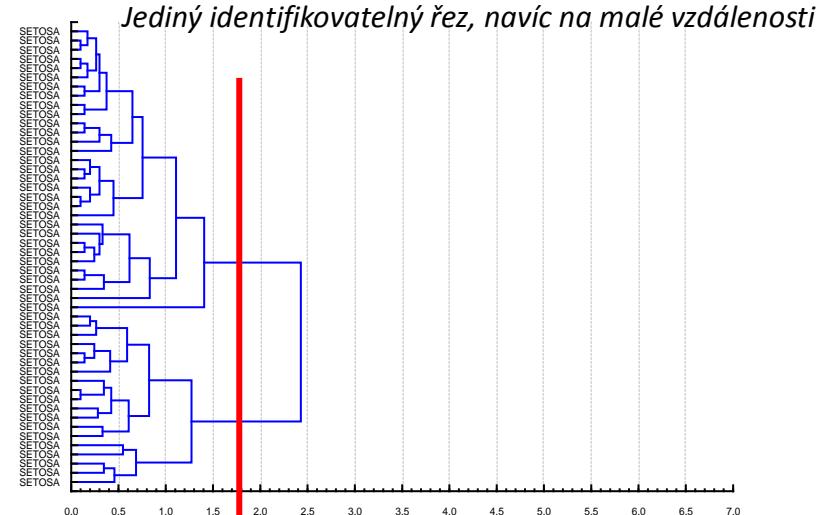
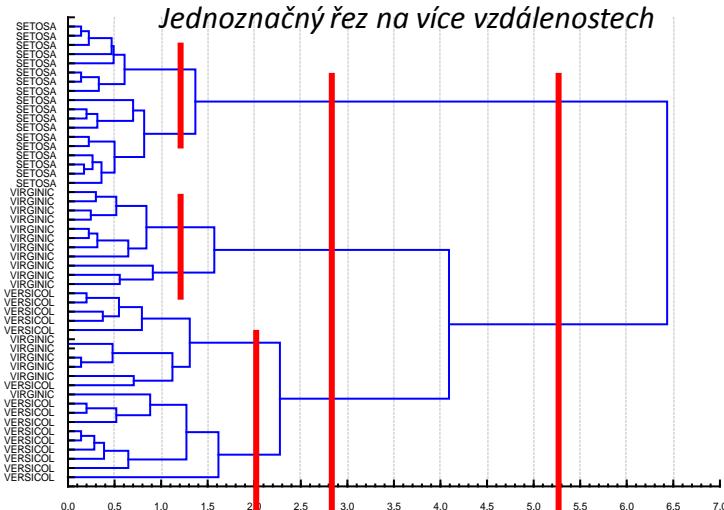
# Identifikace optimálního počtu shluků

- Cílem analýzy může být jednak zjistit vazby mezi objekty (dostatečným výstupem je dendrogram) nebo identifikovat v datech shluky, které budou využity v další analýze jako zjednodušení vícedimenzionálního problému
- Identifikace shluků ve výsledcích shlukové analýzy:
  - Expertní/intuitivní – hranice oddělení shluků je určena podle zkušeností analytika a praktického významu výstupu
  - Matematické metody (analýza mezishlukových/vnitroshlukových vzdáleností; silhouette metoda aj.) fungují dobře v případě existence přirozených shluků
  - V některých případech (při neexistenci přirozených shluků) je rozdělení souboru pouze arbitrární

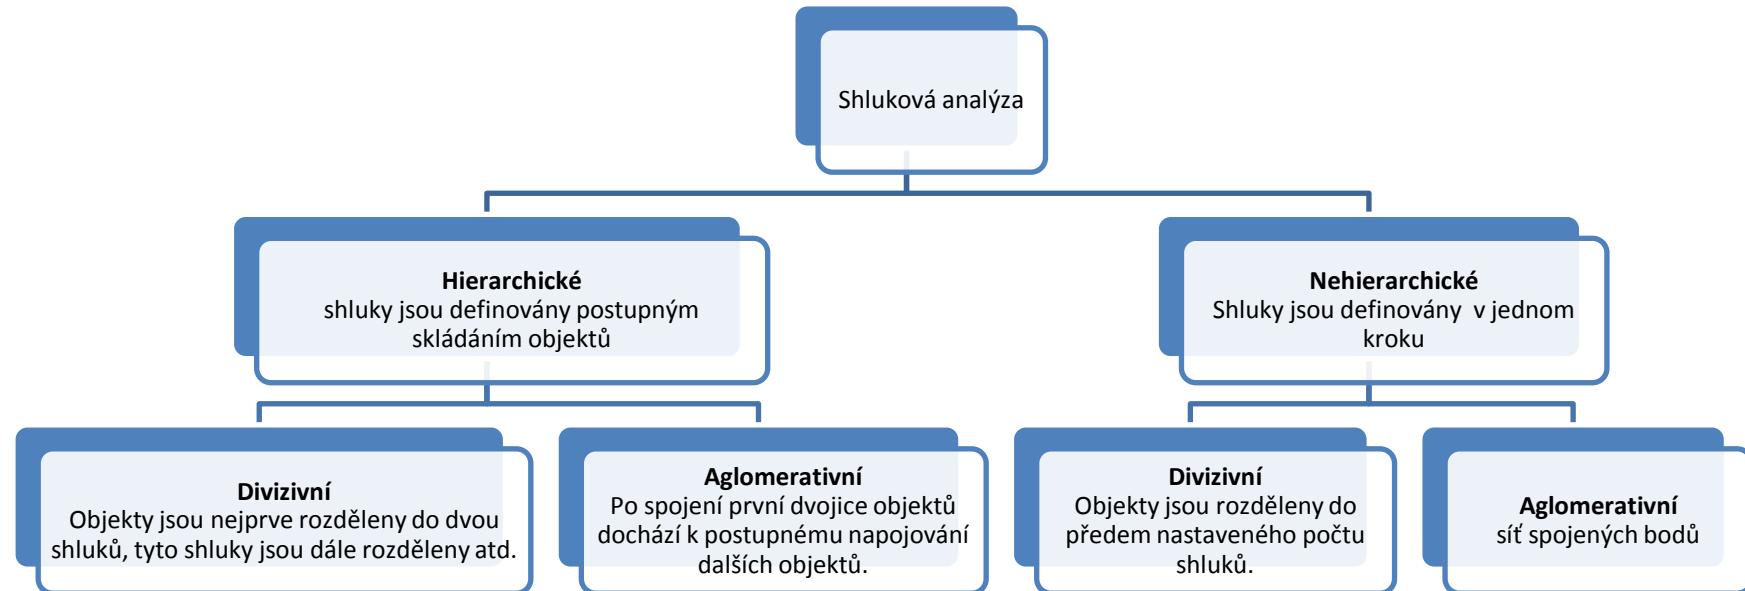


# Identifikace optimálního počtu shluků

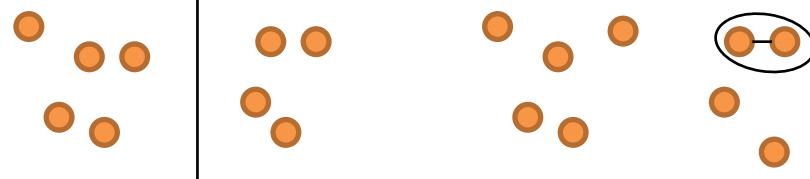
- Mezi shlukovou analýzou a pozici objektů ve vícerozměrném prostoru existuje vztah



# Shluková analýza: typy metod



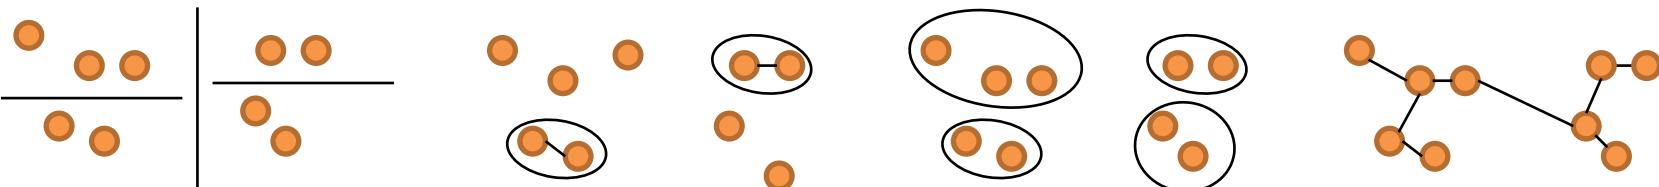
1. Krok



Kolik shluků chceme definovat? Například 4

Minimum spanning tree,  
Prim network

2. Krok



X. Krok

Atd.

Atd.

Výpočet ukončen

Výpočet ukončen

# Vícerozměrné statistické metody

Hierarchické agglomerativní shlukování

# Hierarchické agglomerativní shlukování

- Při tomto způsobu shlukování jsou postupně shlukovány nejpodobnější objekty až do doby, kdy jsou všechny objekty propojeny do jednoho shluku spojujícího všechny objekty v analyzovaném souboru
- Analýza má dva hlavní kroky
  - Výběr vhodné metriky vzdálenosti/podobnosti pro výpočet asociační matice (analýza může probíhat na libovolných metrikách vzdálenosti/podobnosti)
  - Výběr shlukovacího algoritmu, který podstatným způsobem ovlivňuje výsledky analýzy a možnosti její interpretace
- Algoritmus výpočtu postupuje v následujícím cyklu
  - Výpočet asociační matice
  - Spojení dvou nejpodobnějších objektů
  - Přepočítání asociační matice tak, že spojené objekty již nadále vystupují jako jedený objekt (v tomto kroku se uplatňuje zvolený shlukovací algoritmus, který definuje jak bude počítána vzdálenost/podobnost spojených objektů vůči ostatním objektům)
  - Spojení dvou nejpodobnějších objektů z přepočítané asociační matice
  - Atd. až do spojení všech objektů

# Hierarchické aglomerativní shlukování: schéma výpočtu

Výběr metriky podobnosti/vzdálenosti



Asociační matici



Výpočet podobnosti sloučené dvojice objektů k ostatním objektům

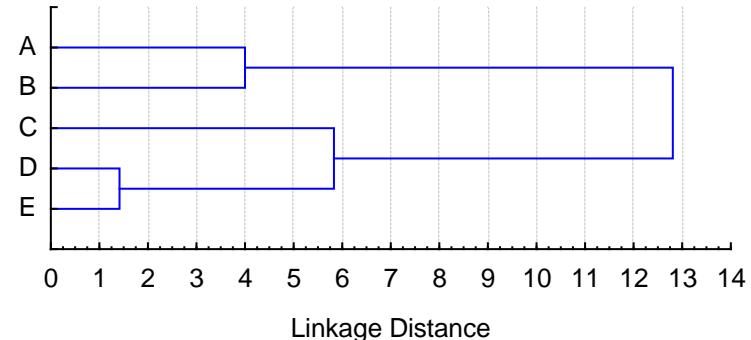
Nalezení dvojice nejpodobnějších objektů



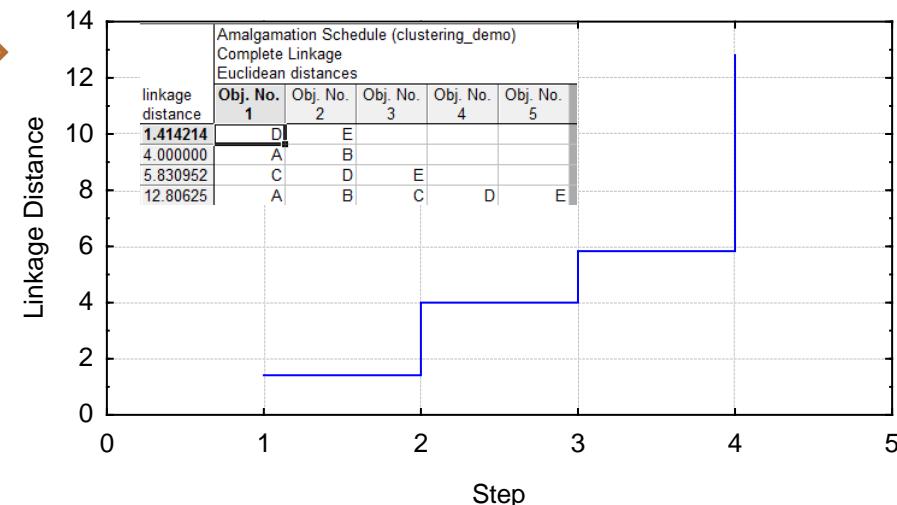
Výběr shlukovacího algoritmu

Ukončení výpočtu po spojení všech objektů

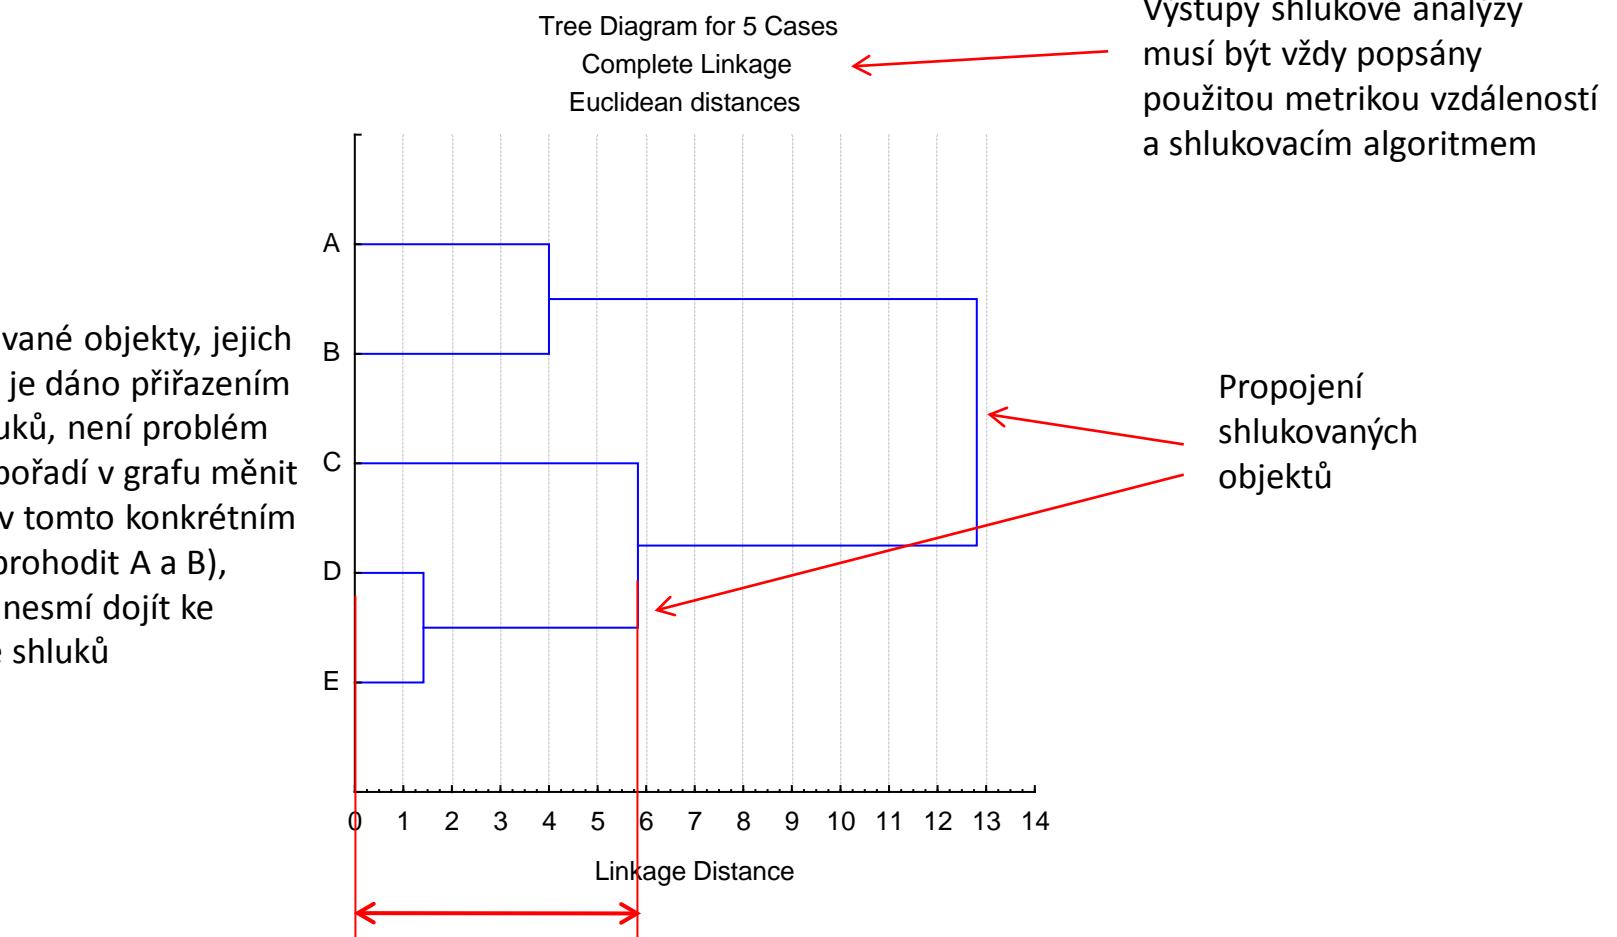
Dendrogram



Amalgamation schedule/graph



# Popis výstupů: dendrogram



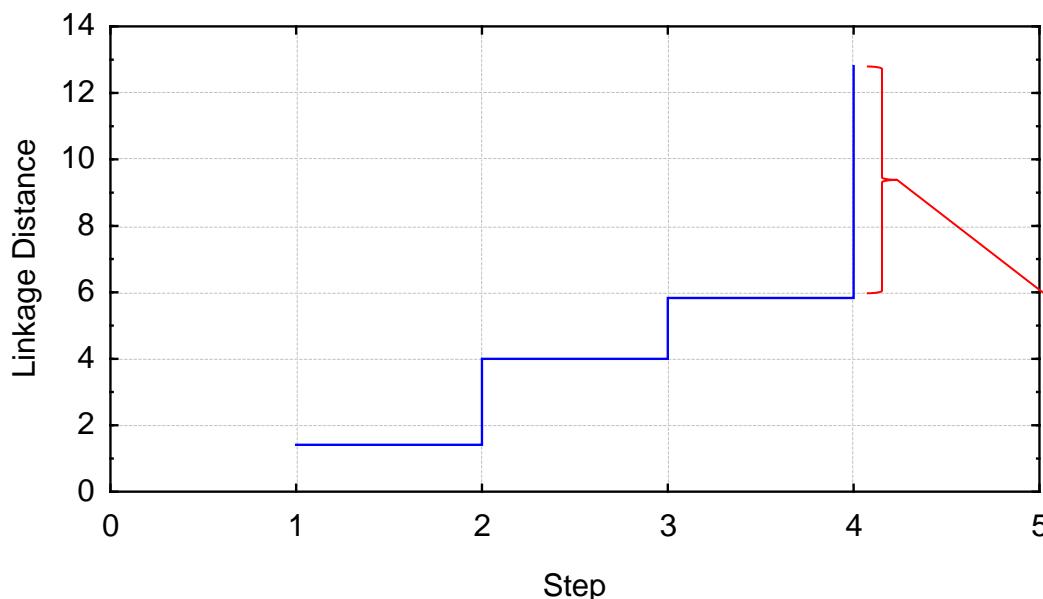
- je v rozměrech použité metriky vzdáleností/podobnosti a v tomto kontextu ji lze kvantitativně interpretovat
- interpretace vzdálenosti shlukování se liší podle použitého shlukovacího algoritmu
- někdy se uvádí ve škále 0-100%, kde 100% je maximální vzdálenost shlukování

# Popis výstupů: Amalgamation schedule/graph

- Popis postupu shlukování
- Využitelné pro identifikaci optimálního počtu shluků

|                  |          | Amalgamation Schedule (clustering_demo) |          |          |          |  |
|------------------|----------|---|----------|----------|----------|--|
|                  |          | Complete Linkage                        |          |          |          |  |
|                  |          | Euclidean distances                     |          |          |          |  |
| linkage distance | Obj. No. | Obj. No.                                | Obj. No. | Obj. No. | Obj. No. |  |
| 1.414214         | D        | E                                       |          |          |          |  |
| 4.000000         | A        | B                                       |          |          |          |  |
| 5.830952         | C        | D                                       | E        |          |          |  |
| 12.80625         | A        | B                                       | C        | D        | E        |  |

Objekty spojené v jednotlivých krocích shlukování



Grafické vyjádření kroků shlukování a vzdálenosti na nichž došlo k propojení objektů

Pokud je v grafu dlouhá vzdálenost bez napojení shluku, jde o možné místo zastavení shlukování a definici finálních shluků

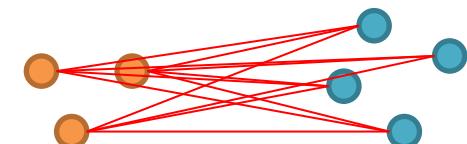
# Shlukovací algoritmy hierarchického agglomerativního shlukování I

- **Metoda nejbližšího souseda** (nearest neighbour, simple linkage) – spojení dle nejmenší vzdálenosti mezi objekty shluků



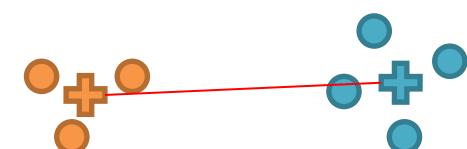
- **Průměrná vzdálenost** (pair group average) – spojení dle průměrné vzdálenosti mezi objekty shluků

- Vážená (weighted) – odstranění vlivu velikosti shluků, shluky bez ohledu na velikost přispívají k výpočtu spojovací vzdálenosti stejnou vahou
- Nevážená (unweighted) – výpočet spojovací vzdálenosti je ovlivněn velikostí spojovaných shluků

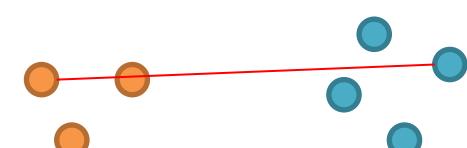


- **Středospojná vzdálenost** (pair group centroid) – spojení dle vzdálenosti centroidů shluků

- Vážená (weighted) – odstranění vlivu velikosti shluků, shluky bez ohledu na velikost přispívají k výpočtu spojovací vzdálenosti stejnou vahou
- Nevážená (unweighted) – výpočet spojovací vzdálenosti je ovlivněn velikostí spojovaných shluků

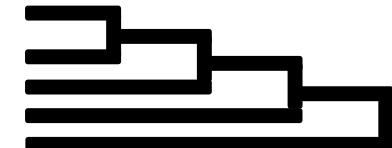


- **Metoda nejvzdálenějšího souseda** (farthest neighbour, complete linkage) – spojení dle největší vzdálenosti mezi objekty shluků

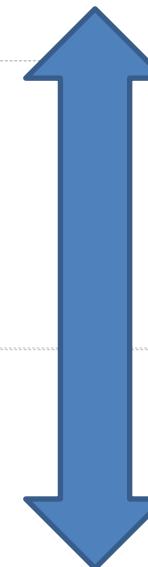


# Shlukovací algoritmy hierarchického agglomerativního shlukování II

- **Metoda nejbližšího souseda** (nearest neighbour, simple linkage)  
– spojení dle nejmenší vzdálenosti mezi objekty shluků – vede na nejvíce zřetězené dendrogramy

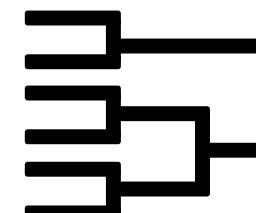


- **Průměrná vzdálenost** (pair group average) – spojení dle průměrné vzdálenosti mezi objekty shluků
- **Středospojná vzdálenost** (pair group centroid) – spojení dle vzdálenosti centroidů shluků



Přechod mezi oběma extrémy (metoda flexible clustering umožňuje dle nastavení zcela plynulý přechod)

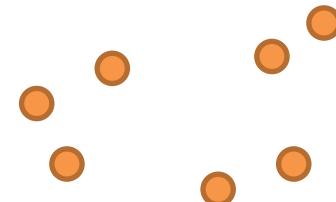
- **Metoda nejvzdálenějšího souseda** (farthest neighbour, complete linkage) – spojení dle největší vzdálenosti mezi objekty shluků – vede na dendrogramy s dobře oddělenými shluky



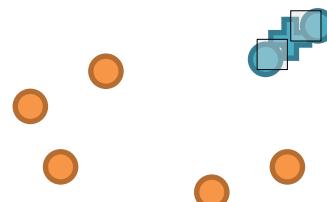
# Shlukovací algoritmy hierarchického agglomerativního shlukování III: Wardova metoda

- Principielně podobné ANOVA
- Shluky jsou vytvářeny tak aby nově vzniklý shluk přispíval co nejméně k sumě čtverců vzdáleností objektů od centroidů jejich shluků
- V počátečním kroku je každý objekt sám sobě shlukem a tedy vzdálenost od centroidu shluku je 0
- Pro výpočet vzdáleností od centroidu je používána Euklidovská vzdálenost
- Pro popis vzdálenosti shlukování je v dendrogramu možné použít řadu postupů (nezbytné ověřit jaký přístup je k dispozici v použitém SW):
  - Čtverce vzdáleností
  - Odmocnina čtverce vzdáleností
  - Podíl variability (čtverce vzdáleností) připadající na daný shluk
  - Aj.

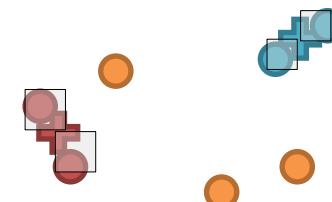
Krok 1: každý objekt je sám sobě centroidem



Krok 2: spojení objektů, které nejméně přispějí k sumě čtverců vzdáleností od centroidu



Krok 3: spojení objektů, které nejméně přispějí k sumě čtverců vzdáleností od centroidu



Krok 3: stejný postup až do spojení všech objektů

# Vícerozměrné statistické metody

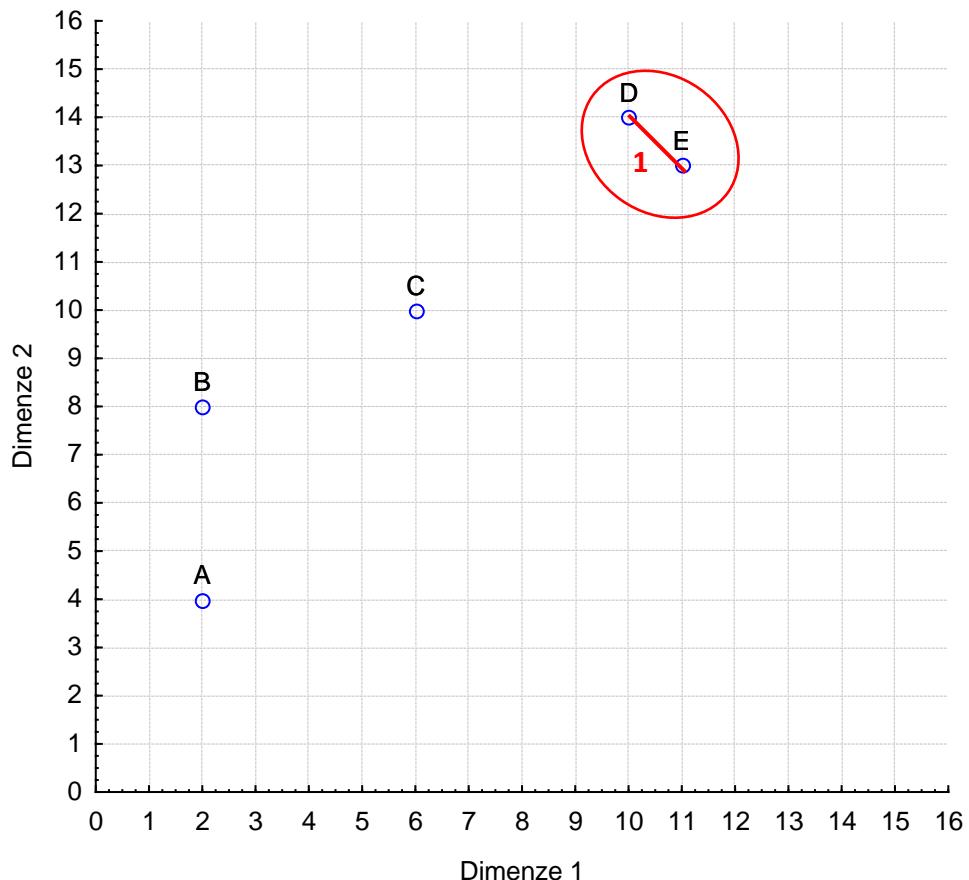
Hierarchické agglomerativní shlukování:  
Příklad výpočtu metody nejbližšího souseda

# Metoda nejbližšího souseda: 1. krok výpočtu

- Je vypočtena asociační matice

|   | A    | B    | C   | D    | E    |
|---|------|------|-----|------|------|
| A | 0.0  | 4.0  | 7.2 | 12.8 | 12.7 |
| B | 4.0  | 0.0  | 4.5 | 10.0 | 10.3 |
| C | 7.2  | 4.5  | 0.0 | 5.7  | 5.8  |
| D | 12.8 | 10.0 | 5.7 | 0.0  | 1.4  |
| E | 12.7 | 10.3 | 5.8 | 1.4  | 0.0  |

- Je definován shluk dvou nejbližších objektů  
**D-E**



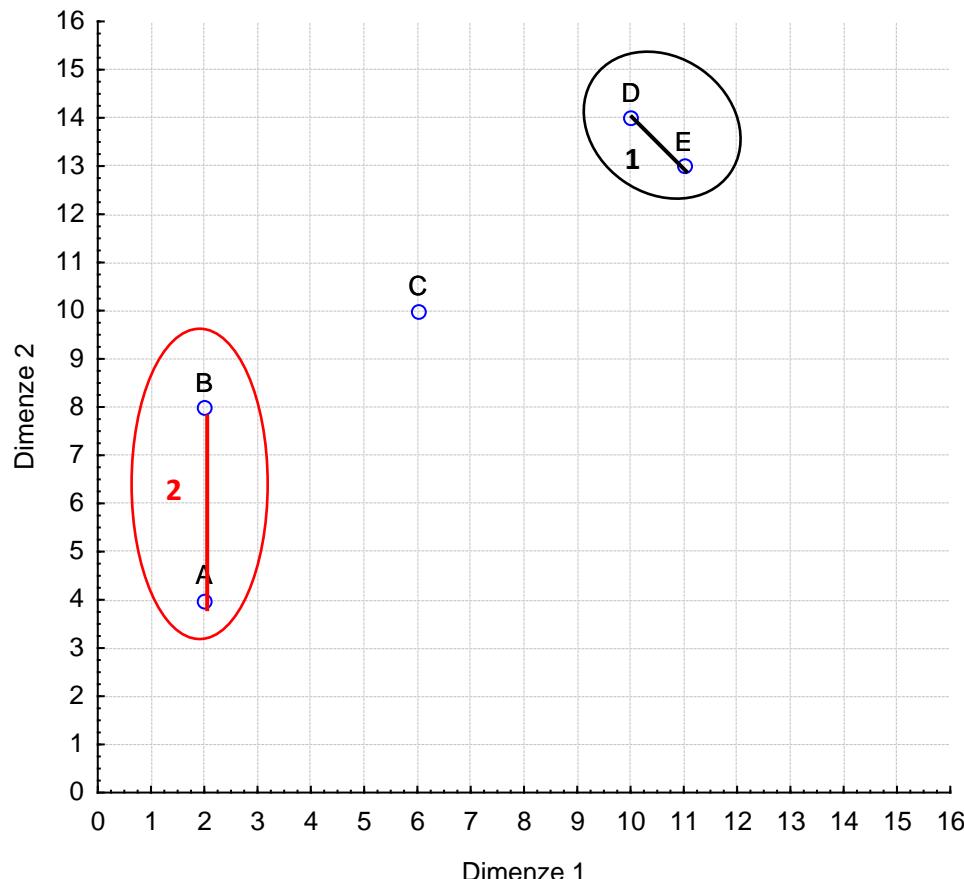
# Metoda nejbližšího souseda: 2. krok výpočtu

- Je vypočtena asociační matice, kde objekty D-E již vystupují jako jeden objekt, jehož vzdálenost od ostatních objektů je dána **nejmenší vzdáleností od jeho členů (D, E)**

|     | A    | B    | C   | D+E  |
|-----|------|------|-----|------|
| A   | 0.0  | 4.0  | 7.2 | 12.7 |
| B   | 4.0  | 0.0  | 4.5 | 10.0 |
| C   | 7.2  | 4.5  | 0.0 | 5.7  |
| D+E | 12.7 | 10.0 | 5.7 | 0.0  |

- Je definován shluk dvou nejbližších objektů

A-B

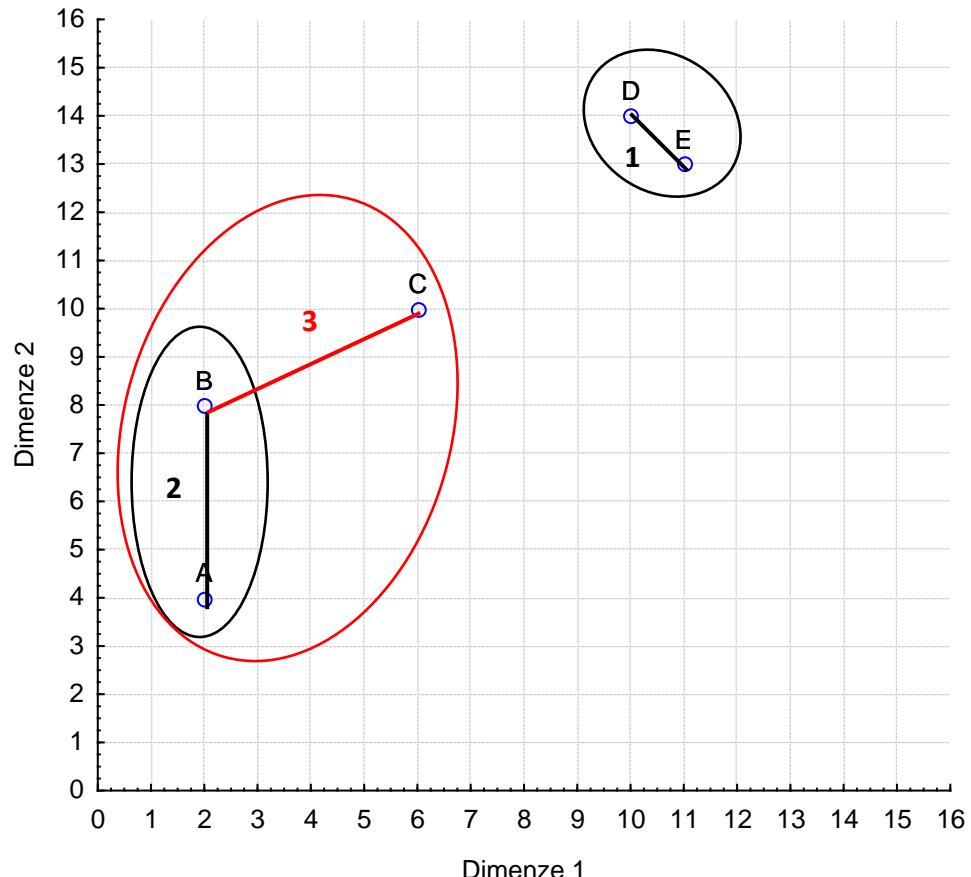


# Metoda nejbližšího souseda: 3. krok výpočtu

- Je vypočtena asociační matice, kde objekty A-B již vystupují jako jeden objekt, jehož vzdálenost od ostatních objektů je dána **nejmenší vzdáleností od jeho členů (A, B)**

|     | A+B  | C   | D+E  |
|-----|------|-----|------|
| A+B | 0.0  | 4.5 | 10.0 |
| C   | 4.5  | 0.0 | 5.7  |
| D+E | 10.0 | 5.7 | 0.0  |

- Je definován shluk dvou nejbližších objektů  
**(A-B)-C**

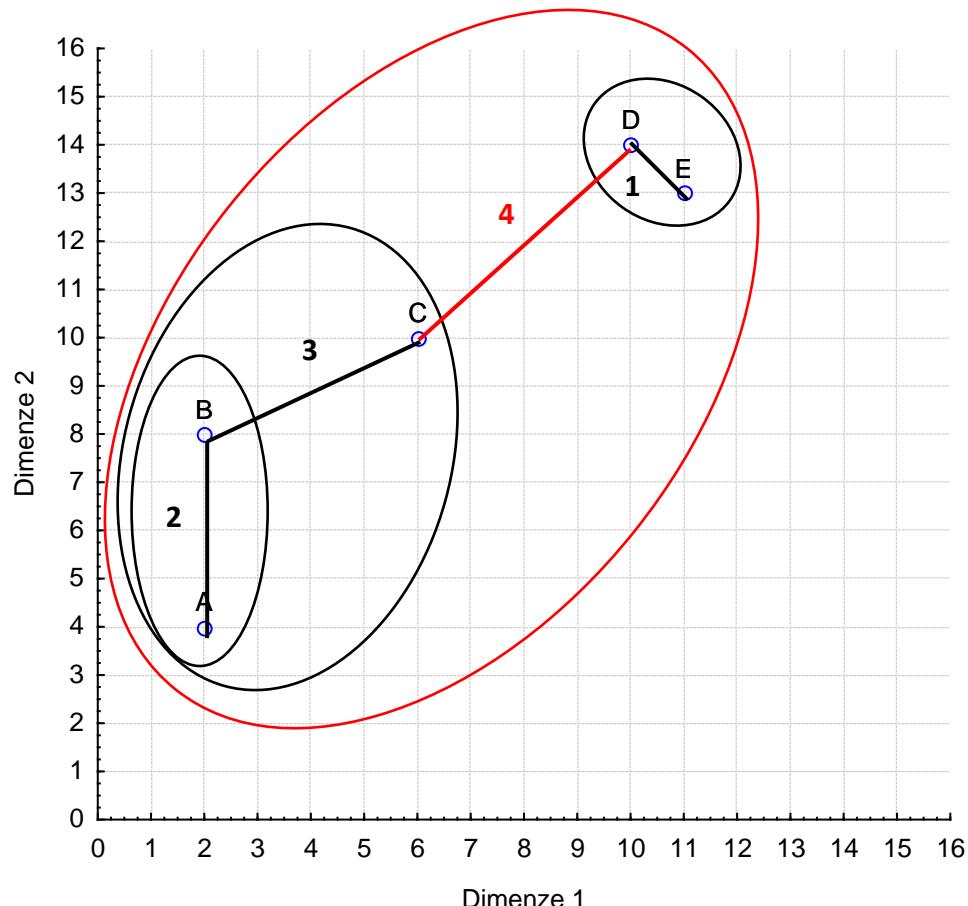


# Metoda nejbližšího souseda: 4. krok výpočtu

- Je vypočtena asociační matice, kde objekty (A-B)-C již vystupují jako jeden objekt, jehož vzdálenost od ostatních objektů je dána **nejmenší vzdáleností od jeho členů (A, B, C)**

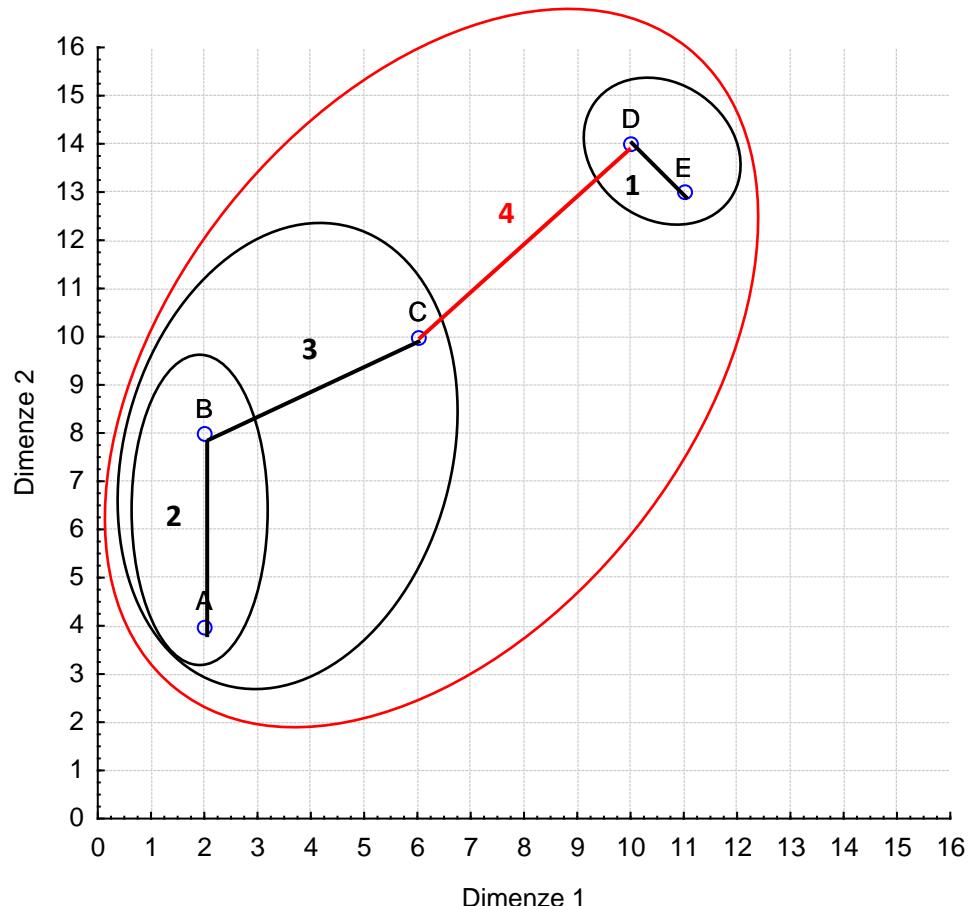
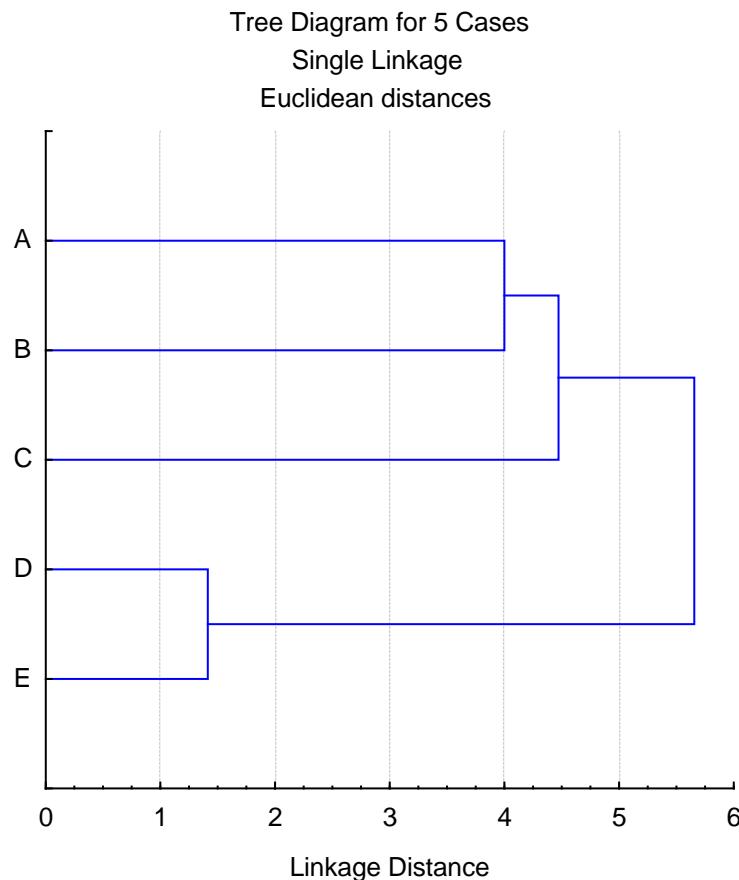
|       |     | A+B+C | D+E |
|-------|-----|-------|-----|
| A+B+C | 0.0 | 5.7   |     |
| D+E   | 5.7 | 0.0   |     |

- Je definován shluk dvou nejbližších objektů **((A-B)-C)-(D-E)**
- Všechny objekty jsou spojeny, algoritmus je ukončen



# Metoda nejbližšího souseda: výsledek analýzy

- Výsledek analýzy je vizualizován ve formě dendrogramu



# Vícerozměrné statistické metody

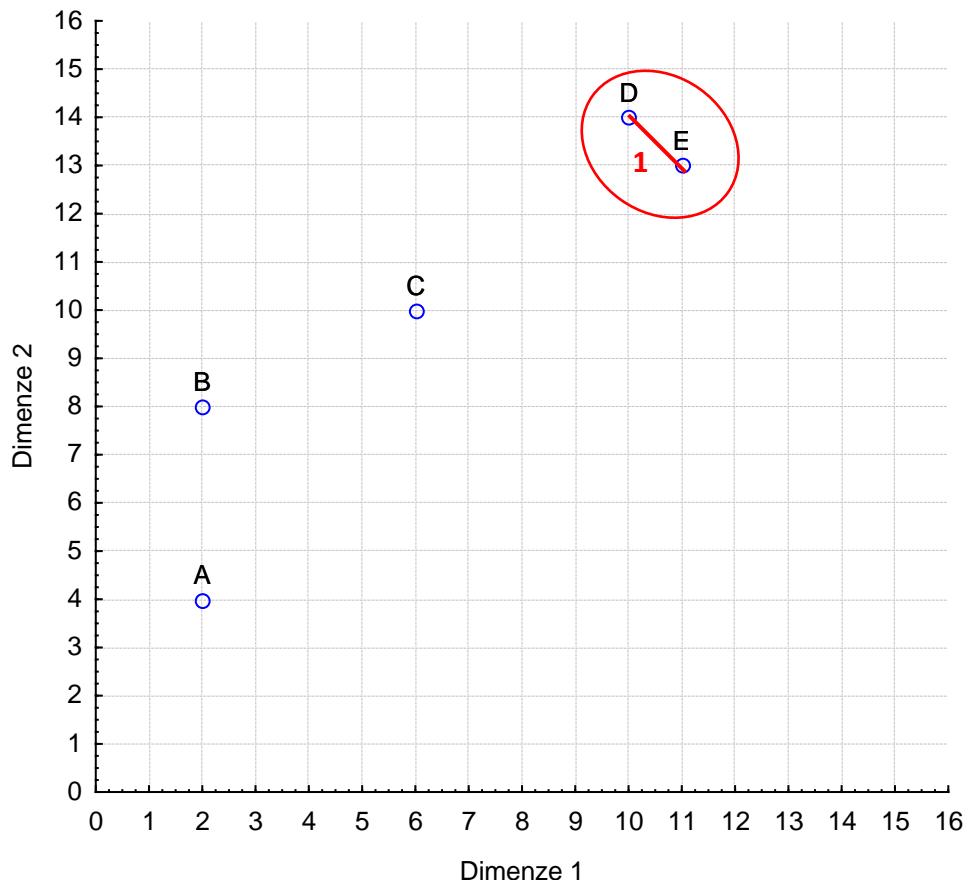
Hierarchické agglomerativní shlukování:  
Příklad výpočtu metody nejvzdálenějšího souseda

# Metoda nejvzdálenějšího souseda: 1. krok výpočtu

- Je vypočtena asociační matice

|   | A    | B    | C   | D    | E    |
|---|------|------|-----|------|------|
| A | 0.0  | 4.0  | 7.2 | 12.8 | 12.7 |
| B | 4.0  | 0.0  | 4.5 | 10.0 | 10.3 |
| C | 7.2  | 4.5  | 0.0 | 5.7  | 5.8  |
| D | 12.8 | 10.0 | 5.7 | 0.0  | 1.4  |
| E | 12.7 | 10.3 | 5.8 | 1.4  | 0.0  |

- Je definován shluk dvou nejbližších objektů  
**D-E**



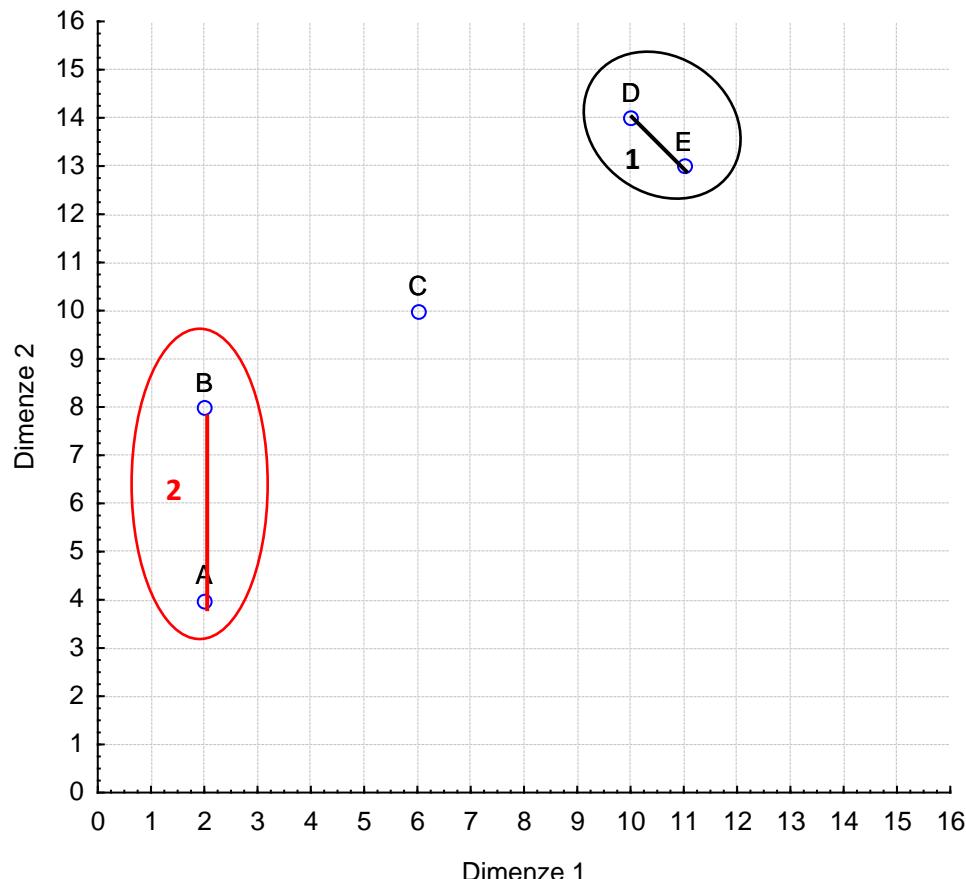
# Metoda nejvzdálenějšího souseda: 2. krok výpočtu

- Je vypočtena asociační matice, kde objekty D-E již vystupují jako jeden objekt, jehož vzdálenost od ostatních objektů je dána **největší vzdáleností od jeho členů (D, E)**

|     | A    | B    | C   | D+E  |
|-----|------|------|-----|------|
| A   | 0.0  | 4.0  | 7.2 | 12.8 |
| B   | 4.0  | 0.0  | 4.5 | 10.3 |
| C   | 7.2  | 4.5  | 0.0 | 5.8  |
| D+E | 12.8 | 10.3 | 5.8 | 0.0  |

- Je definován shluk dvou nejbližších objektů

A-B

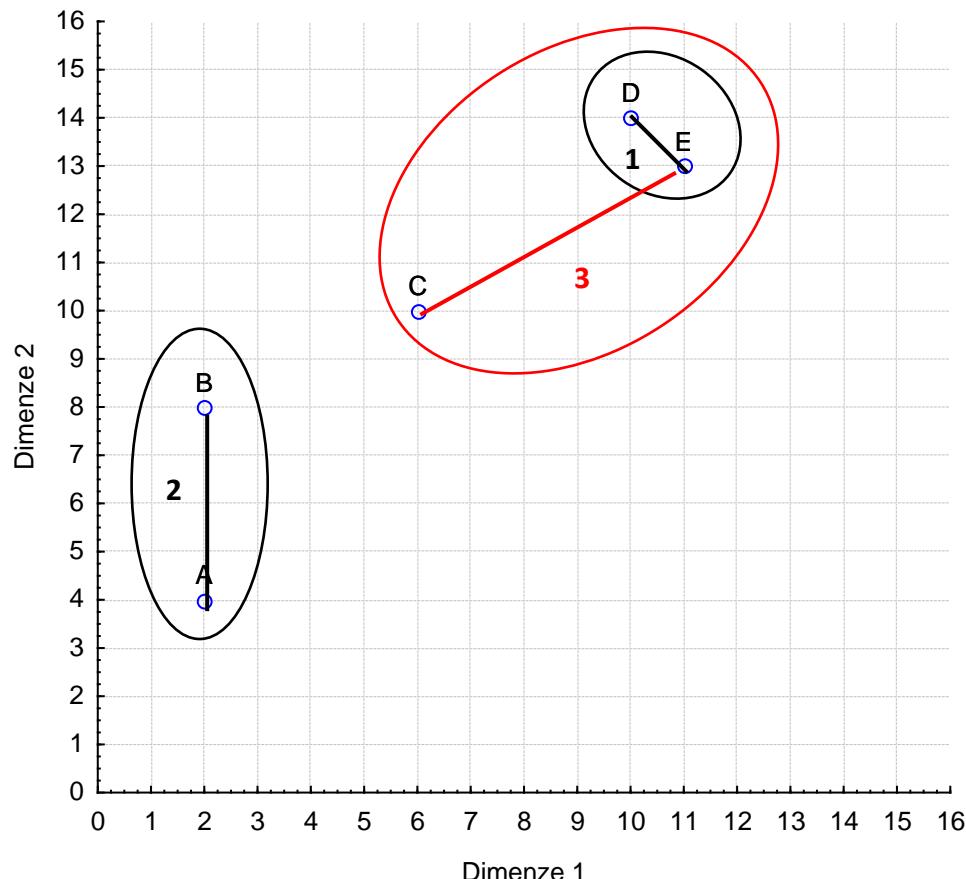


# Metoda nejvzdálenějšího souseda: 3. krok výpočtu

- Je vypočtena asociační matice, kde objekty A-B již vystupují jako jeden objekt, jehož vzdálenost od ostatních objektů je dána **největší vzdáleností od jeho členů (A, B)**

|     | A+B  | C   | D+E  |
|-----|------|-----|------|
| A+B | 0.0  | 7.2 | 12.8 |
| C   | 7.2  | 0.0 | 5.8  |
| D+E | 12.8 | 5.8 | 0.0  |

- Je definován shluk dvou nejbližších objektů  
**(D-E)-C**

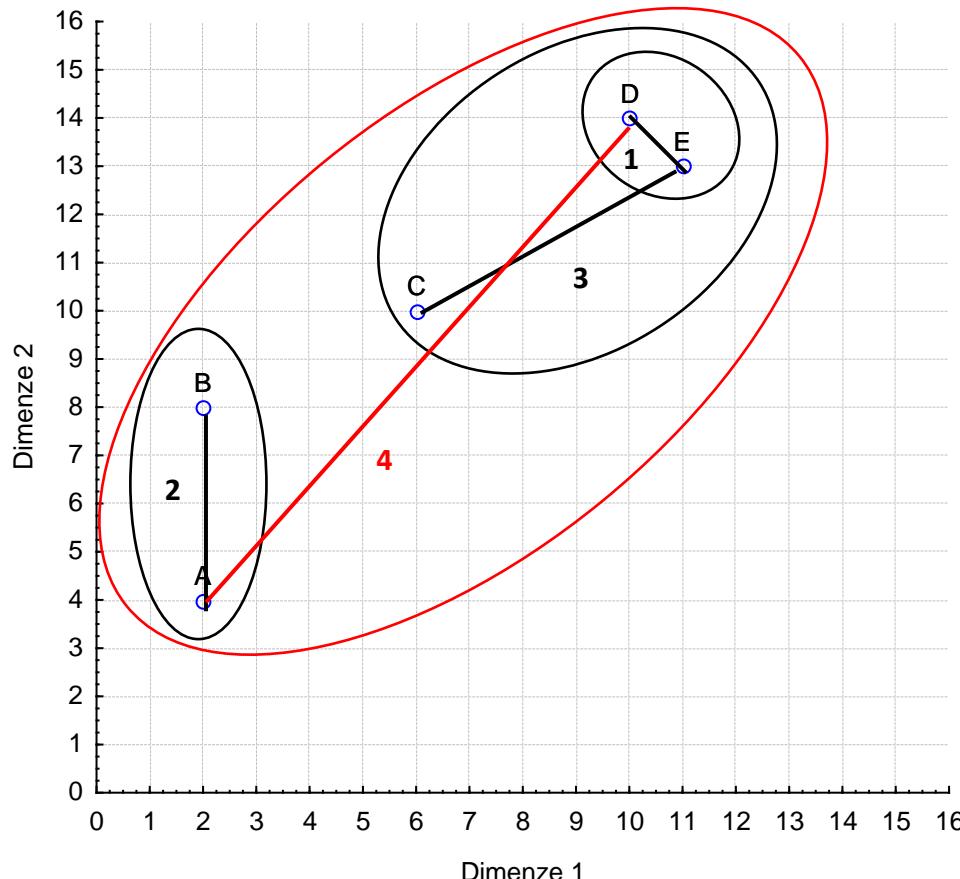


# Metoda nejvzdálenějšího souseda: 4. krok výpočtu

- Je vypočtena asociační matice, kde objekty (D-E)-C již vystupují jako jeden objekt, jehož vzdálenost od ostatních objektů je dána **největší vzdáleností od jeho členů (D, E, C)**

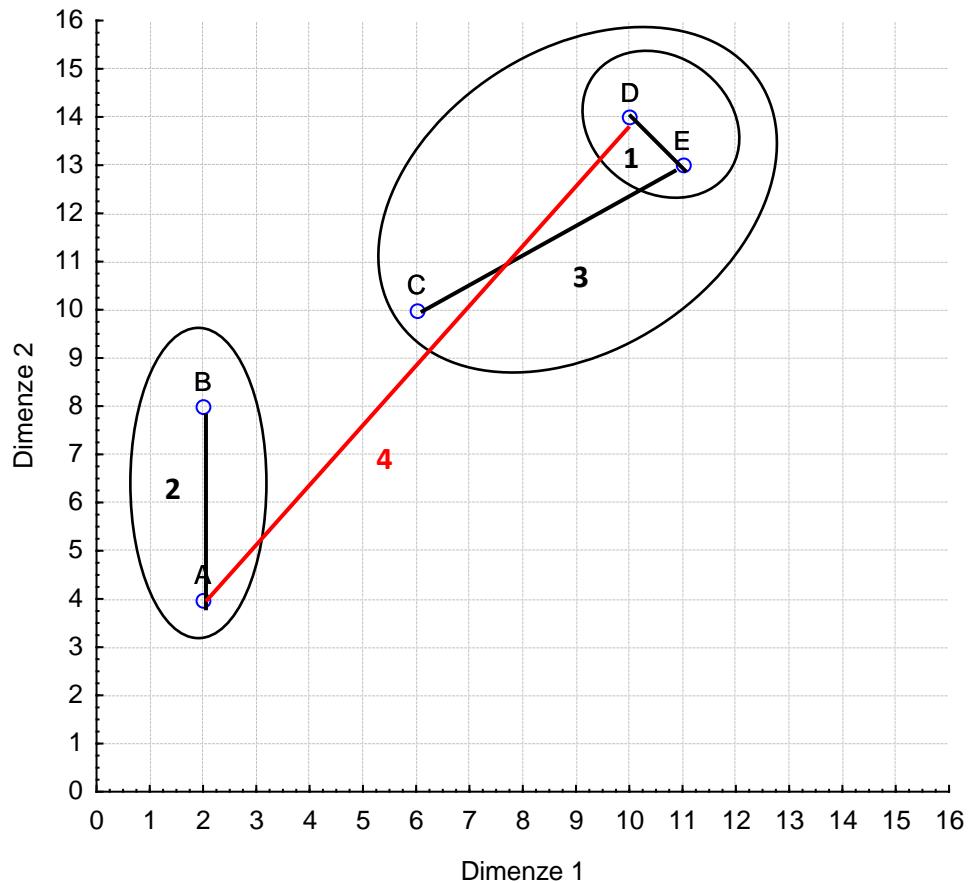
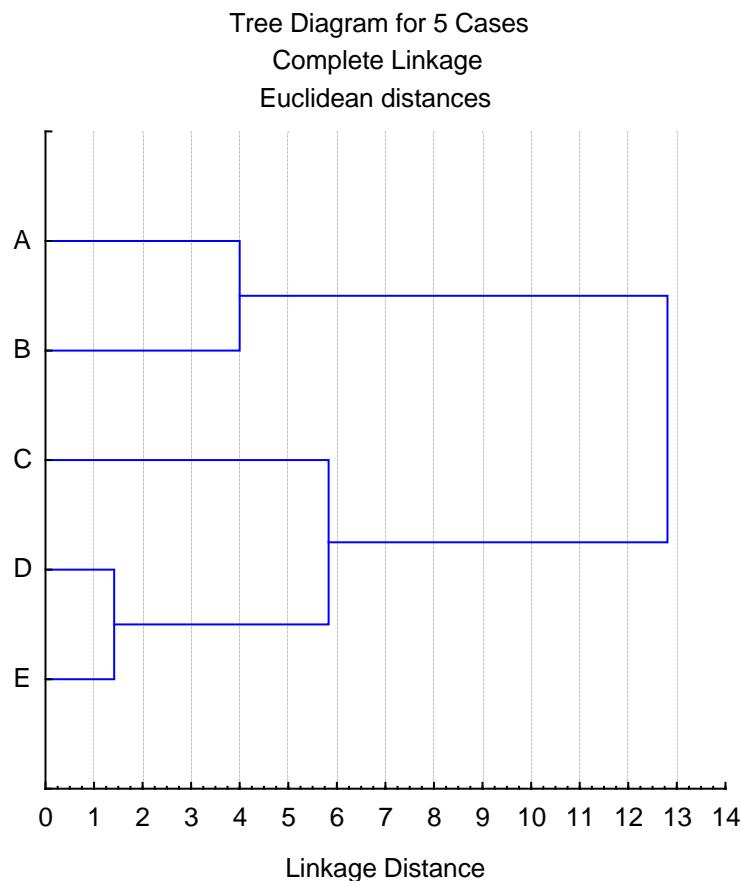
|       | A+B  | D+E+C |
|-------|------|-------|
| A+B   | 0.0  | 12.8  |
| D+E+C | 12.8 | 0.0   |

- Je definován shluk dvou nejbližších objektů **((D-E)-C)-(A-B)**
- Všechny objekty jsou spojeny, algoritmus je ukončen



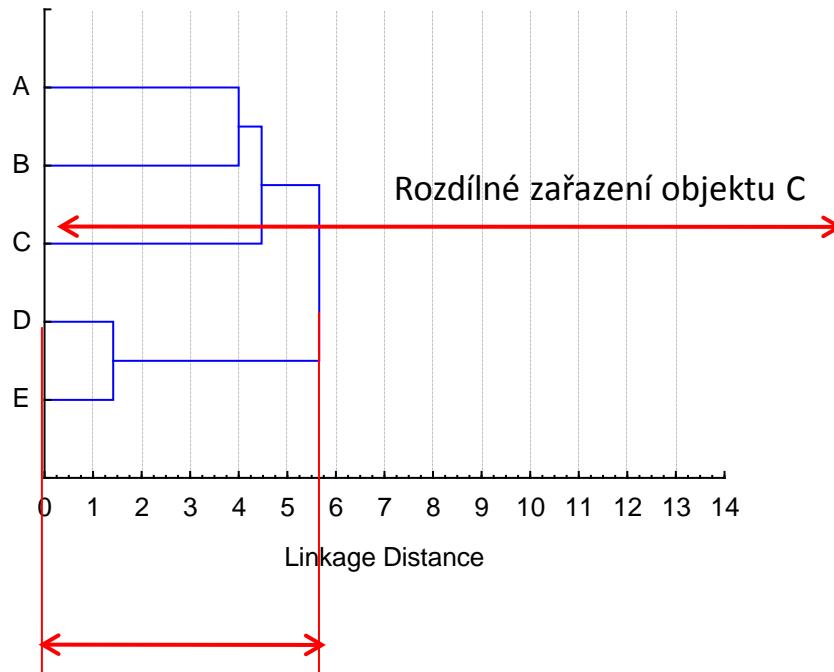
# Metoda nejvzdálenějšího souseda: výsledek analýzy

- Výsledek analýzy je vizualizován ve formě dendrogramu

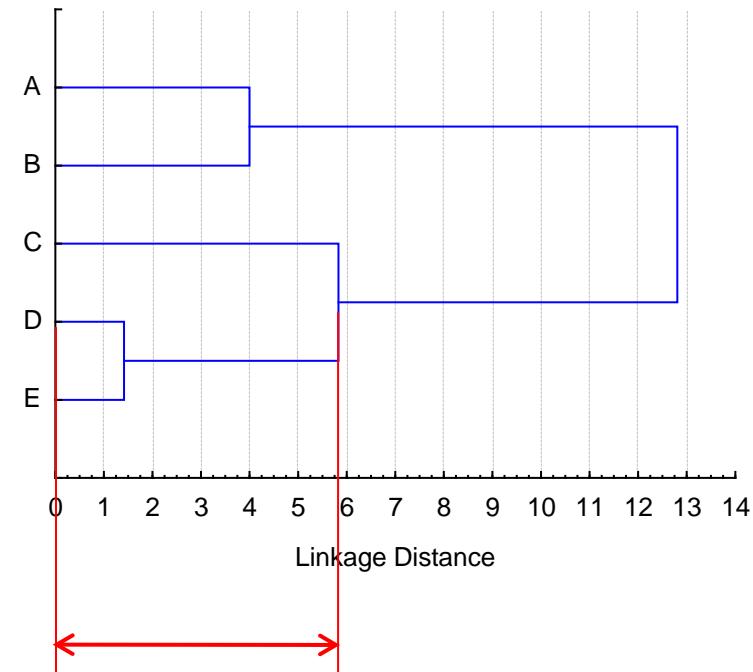


# Metoda nejbližšího a nejvzdálenějšího souseda: interpretace výsledků

*Metoda nejbližšího souseda*



*Metoda nejvzdálenějšího souseda*



## Vzdálenost na níž došlo ke spojení shluku:

- u metody nejbližšího souseda znamená nejmenší vzdálenost objektů shluku, tedy ve shluku mohou existovat objekty s větší vzdáleností

## Vzdálenost na níž došlo ke spojení shluku:

- u metody nejvzdálenějšího souseda znamená největší vzdálenost objektů shluku, tedy objekty ve shluku už mohou být k sobě pouze blíže nebo stejně než je tato vzdálenost

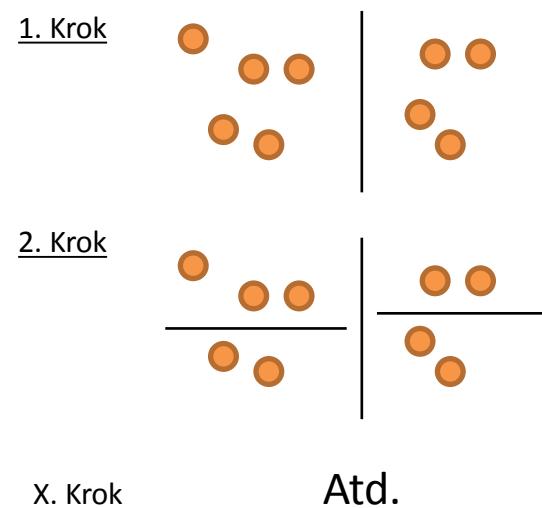
# Vícerozměrné statistické metody

Hierarchické divizivní shlukování

# Hierarchické divizivní shlukování: postup

- Hierarchická divizivní shlukování fungují na principu výpočtu ordinační analýzy a dělení objektů podle os ordinačního prostoru, tedy dle směrů největší variability v datech
- Shlukování může být zastaveno po rozdelení všech objektů do shluků, po předem daném počtu kroků nebo po dosažení kritéria minimálního rozdílu mezi shluky
- Typickým příkladem je metoda TWINSPAN používaná v analýzách biologických společenstev

*Obecný postup hierarchického divizivního shlukování*

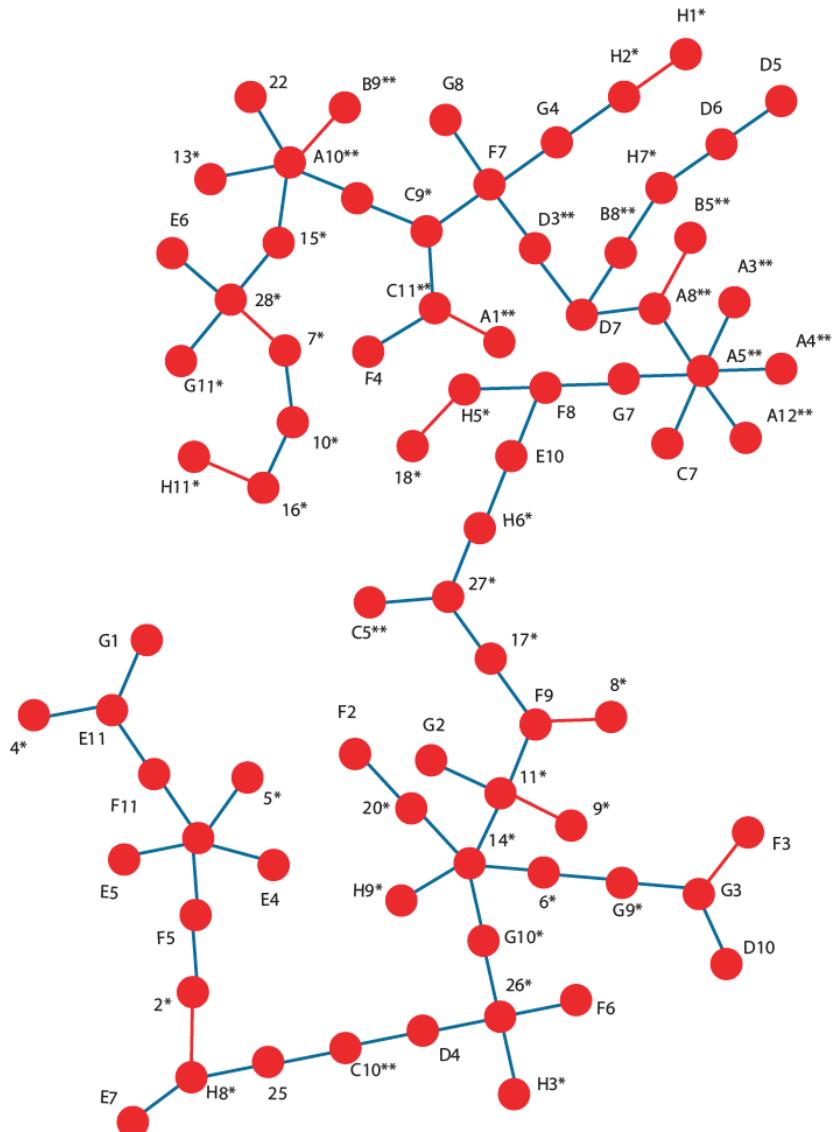


# Vícerozměrné statistické metody

Nehierarchické agglomerativní shlukování

# Nehierarchické agglomerativní shlukování: postup

- Do této skupiny lze zařadit metody hledající nejkratší spojnice mezi objekty ve vícerozměrném prostoru (i když lze vznést námitky proti nazývání těchto metod nehierarchickými)
- Metody hledají v asociační matici (prvním krokem je tak vždy výběr vhodné metriky vzdáleností/ podobnosti) propojení všech objektů s nejmenší sumou vzdáleností mezi propojenými objekty
- Na rozdíl od klasického hierarchického agglomerativního shlukování může být na jeden objekt napojeno několik dalších objektů
- Minimum spanning tree (Prim network)



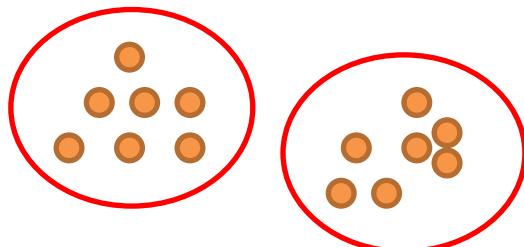
# Vícerozměrné statistické metody

Nehierarchické divizivní shlukování

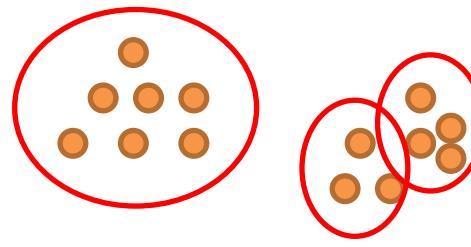
# Nehierarchické divizivní shlukování: postup

- Nejběžnější metodu je tzv. k-means clustering
- Metoda zařazuje objekty do shluků na principu ANOVA, analogií je Wardova metoda shlukování v hierarchickém aglomerativním shlukování
- Počet shluků je předem definován, výběr nevhodnějšího počtu shluků je prováděn buď expertně nebo pomocí matematických metod výběru optimálního počtu shluků (analýza vnitro a mezishlukových vzdáleností)
- V prvním kroku je určeno k objektům jako počáteční středy shluků (výběr může být náhodný, daný uživatelem nebo maximalizující počáteční vzdálenosti k objektů)
- Následně jsou objekty zařazeny do k shluků tak, aby byla minimalizována suma čtverců vzdáleností objektů k centroidům jejich shluků
- Výpočet vzdáleností probíhá na bázi Euklidovské vzdálenosti, pro k-means clustering na jiné metrice vzdálenosti/podobnosti je nezbytná kombinace s jinými metodami

*K-means k=2*



*K-means k=3*



Analýza vždy nalezne zadaný počet shluků, i když výsledek nemusí být vždy prakticky smysluplný