

Confronto tra Pattern

Sistemi informativi per le Decisioni

Slide a cura di Ing. Marco Patella



Motivazione

- Rilevazione di cambiamenti nei dati
 - Es.: comportamento di acquisto dei clienti nel tempo
- Confronto di collezioni di grandi dimensioni
 - Es.: analisi delle vendite mensili di un supermercato
- Confronto di algoritmi di Data Mining
 - Es.: confronto dei risultati ottenuti da due algoritmi di clustering
- Rilevazione di outlier o pattern “inattesi”
 - Es.: fraud detection



Esempio d'uso

- Un manager di una catena di supermercati vuole analizzare la tendenza delle vendite
- In particolare, si vuole capire se esiste un particolare supermercato le cui vendite differiscano significativamente da quelle degli altri supermercati
- L'analisi va effettuata in 3 direzioni:
 - Confrontando le vendite di ciascun prodotto
 - Confrontando gli scontrini (MBA)
 - Confrontando i prodotti che caratterizzano ogni customer segment



Obiettivo

- Dati due pattern, calcolarne la “similarità”

$$s(p_1, p_2)$$

- Tale definizione dipende dal tipo di pattern
- Intuitivamente, se i due pattern si riferiscono agli stessi dati, la similarità deve essere alta (~ 1)



Requisiti

■ Generalità

- Soluzione applicabile a qualsiasi tipo di pattern, indipendentemente dalla complessità

■ Flessibilità

- Il criterio di similarità non deve essere univoco

■ Semplicità

- Requisito fondamentale per l'utilizzabilità

■ Efficienza

- Definizione della similarità indipendentemente dai dati



FOCUS (Ganti et al., PODS '99)

- Un framework per misurare le differenze nelle caratteristiche dei dati
- Calcola una misura di deviazione tra due dataset per quantificare le differenze esistenti tra caratteristiche “interessanti” dei due dataset
- L'idea di base è che una vasta gamma di pattern possa essere descritta in termini di due componenti:
 - componente *struttura*
 - componente *misura*



Esempio: large itemsets

- Struttura: tutti i frequent itemset estratti dal dataset
- Misura: i corrispondenti supporti
- Esempio:

$(\{a\}, 0.5)$

$(\{b\}, 0.4)$

$(\{a,b\}, 0.25)$

$(\{b\}, 0.3)$

$(\{c\}, 0.5)$

$(\{b,c\}, 0.2)$

- Quanto sono simili i dataset originali?

Esempio: decision trees

- Struttura: tutte le regioni associate alle foglie dell'albero
- Misura: le corrispondenti misure (es., frazione di elementi in ciascuna classe)
- Esempio:

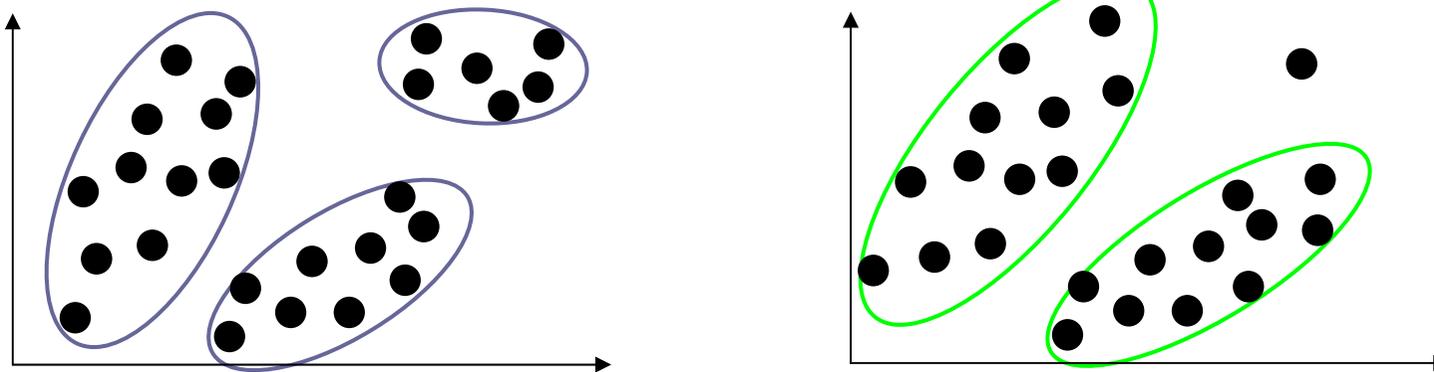
0.18 0.1	0.1 0.52
	0.0 0.1

0.1 0.0	0.05 0.55
	0.0 0.3

- Quanto sono simili i dataset originali?

Esempio: clustering

- Struttura: tutte le regioni associate ad ogni cluster
- Misura: le corrispondenti misure (es., supporto del cluster)
- Esempio:



- Quanto sono simili i dataset originali?



Come calcolare la differenza?

- Caso base: strutture identiche
- Esempio:

$(\{a\}, 0.5)$	$(\{a\}, 0.3)$
$(\{b\}, 0.4)$	$(\{b\}, 0.5)$
$(\{a,b\}, 0.25)$	$(\{a,b\}, 0.2)$

- Calcolo della differenza tra le componenti “comuni”
 - Es.: $|0.5-0.3|=0.2$, $|0.4-0.5|=0.1$, $|0.25-0.2|=0.05$
- Aggregazione delle differenze in un unico valore
 - Es.: $0.2+0.1+0.05=0.35$



... e se le strutture non sono identiche?

■ Esempio:

$(\{a\}, 0.5)$	$(\{a\}, 0.3)$
$(\{b\}, 0.4)$	$(\{b\}, 0.5)$
$(\{a,b\}, 0.25)$	

- Evidentemente, occorre calcolare il supporto per l'itemset (non large) $\{a,b\}$ sul secondo dataset
- Es.: $|0.5-0.3|=0.2$, $|0.4-0.5|=0.1$, $|0.25-0.1|=0.15$



Generalizzando...

- Calcolo del Greatest Common Refinement tra le strutture dei due pattern
- Calcolo delle misure sul GCR per entrambi i dataset
- Calcolo delle differenze nelle misure per i due modelli “indotti”
- Aggregazione delle differenze sui due modelli “indotti”



Esempio: large itemsets

$(\{a\}, 0.5)$

$(\{b\}, 0.4)$

$(\{a,b\}, 0.25)$

$(\{b\}, 0.3)$

$(\{c\}, 0.5)$

$(\{b,c\}, 0.2)$

- Calcoliamo il GCR:

- $\{\{a\}, \{b\}, \{c\}, \{a,b\}, \{b,c\}\}$

- Calcoliamo i supporti sui dataset originari:

$(\{a\}, 0.5)$

$(\{b\}, 0.4)$

$(\{a,b\}, 0.25)$

$(\{c\}, 0.1)$

$(\{b,c\}, 0.05)$

$(\{b\}, 0.3)$

$(\{c\}, 0.5)$

$(\{b,c\}, 0.2)$

$(\{a\}, 0.1)$

$(\{a,b\}, 0.05)$

Esempio: large itemsets (cont.)

({a}, 0.5)

({b}, 0.4)

({a,b}, 0.25)

({c}, 0.1)

({b,c}, 0.05)

({b}, 0.3)

({c}, 0.5)

({b,c}, 0.2)

({a}, 0.1)

({a,b}, 0.05)

- Calcoliamo le differenze sui nuovi modelli:

- $|0.5-0.1|=0.4$, $|0.4-0.3|=0.1$, $|0.1-0.5|=0.4$,
 $|0.25-0.05|=0.2$, $|0.05-0.2|=0.15$

- Aggreghiamo le differenze per ottenere il valore finale:

- $0.4+0.1+0.4+0.2+0.15 = 1.25$

Esempio: decision trees

0.18 0.1	0.1 0.52
	0.0 0.1

0.1 0.0	0.05 0.55
	0.0 0.3

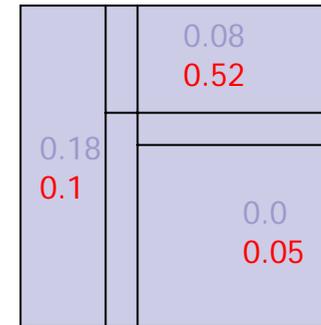
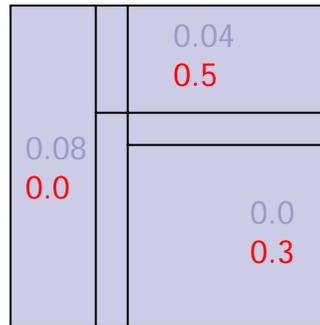
- Calcoliamo il GCR:
- Calcoliamo le misure sui dataset originari:

0.08 0.0	0.04 0.5
	0.0 0.3

0.18 0.1	0.08 0.52
	0.0 0.05

Confronto di pattern

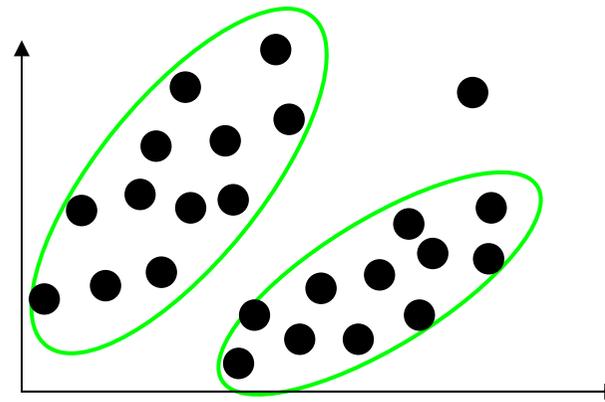
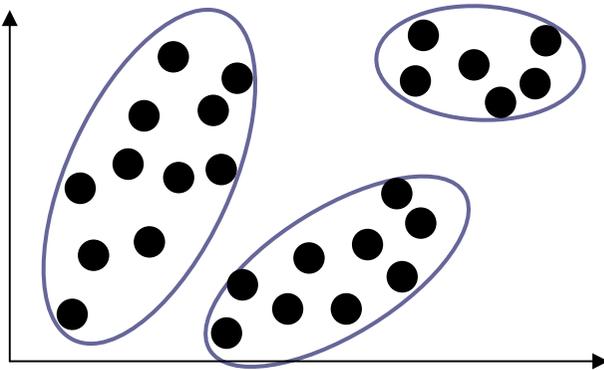
Esempio: decision trees (cont.)



- Calcoliamo le differenze sui nuovi modelli
- Aggregiamo le differenze per ottenere il valore finale

Esempio: clustering

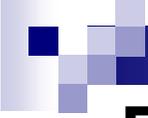
- Struttura: simile ai decision trees
- Misura: simile alle regole associative





FOCUS: limiti

- Scarsa generalità
 - Gestisce solamente pattern “a 2 livelli”
- Scarsa flessibilità
 - I criteri di differenza ed aggregazione possono variare
 - Il criterio GCR è fisso per ogni tipo di pattern
- Scarsa efficienza
 - È necessaria una scansione ulteriore dei dataset per calcolare le misure sul GCR

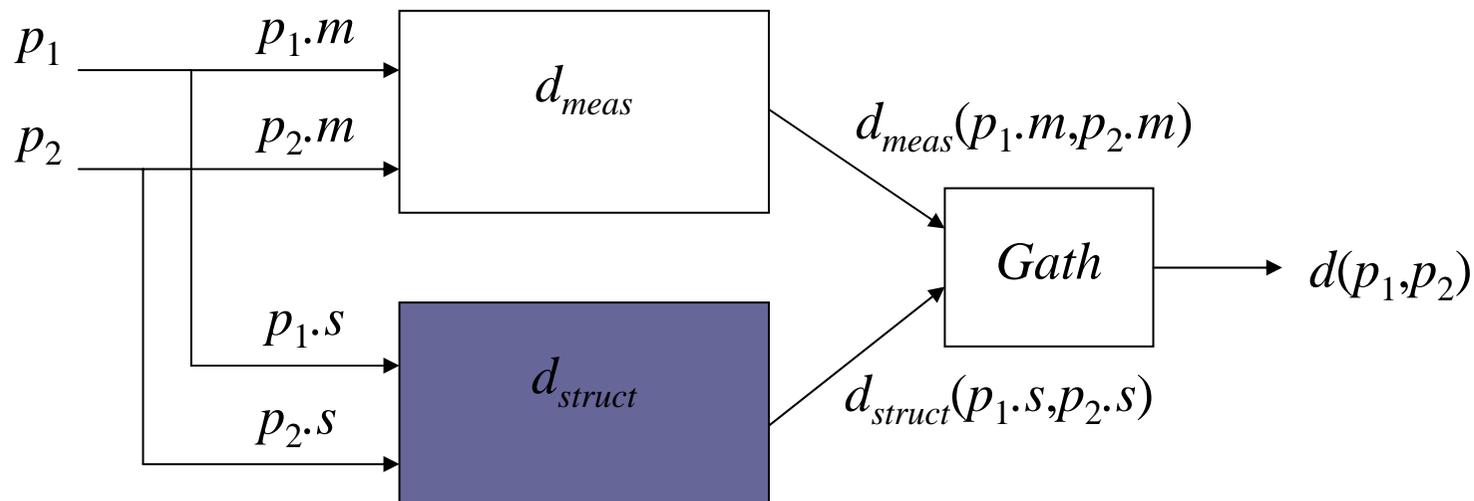


PANDA framework: (Bartolini, Ciaccia, Patella, Ntoutsi, Theodoridis, PKDD'04)

- Si basa sulla natura a 2 componenti (*struttura e misura*) dei pattern
- Gestisce pattern di arbitraria complessità
 - Un pattern complesso è un pattern la cui struttura include altri pattern
- La differenza (distanza) tra 2 pattern tiene conto dei 2 componenti:
 - distanza tra le strutture
 - distanza tra le misure
- La differenza tra pattern complessi tiene conto (ricorsivamente) della differenza tra i pattern componenti

Modello generale

- Un pattern è una rappresentazione compatta e ricca di semantica dei dati grezzi

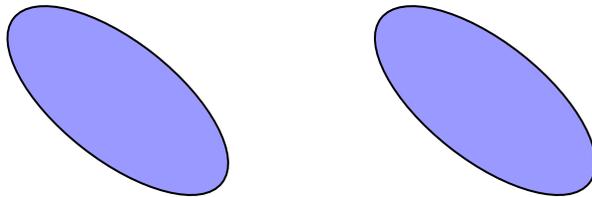


Esempio: large itemset

- Confrontiamo i due pattern
 - (*{pane, miele, latte}*, 0.1)
 - (*{burro, latte}*, 0.2)
- Supponiamo che:
 - $d_{meas} = |supp_1 - supp_2|$
 - $d_{struct} = 1 - \frac{|struct_1 \cap struct_2|}{|struct_1 \cup struct_2|}$
 - $d = (d_{meas} + d_{struct})/2$
- $d_{meas} = 0.1$, $d_{struct} = 0.75$, $d = 0.425$

Esempio: cluster

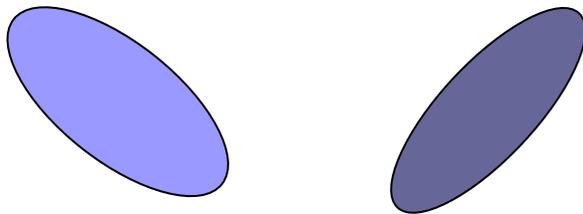
- Stessa struttura: consideriamo la misura



support = 0.1 support = 0.15

$$d_{meas} = |0.1 - 0.15| = 0.05$$
$$d_{struct} = 0$$

- Struttura diversa?



support = 0.1 support = 0.15

$$d_{meas} = 0.05$$
$$d_{struct} = ?$$



Distanza di Bhattacharyya

- Supponiamo di avere cluster ellittici
- Ogni cluster è definito dal centroide e dalla matrice di covarianza
- Distanza tra i centroidi:

$$(c_1 - c_2)^T (cov_1 + cov_2)^{-1} / 2 (c_1 - c_2)$$

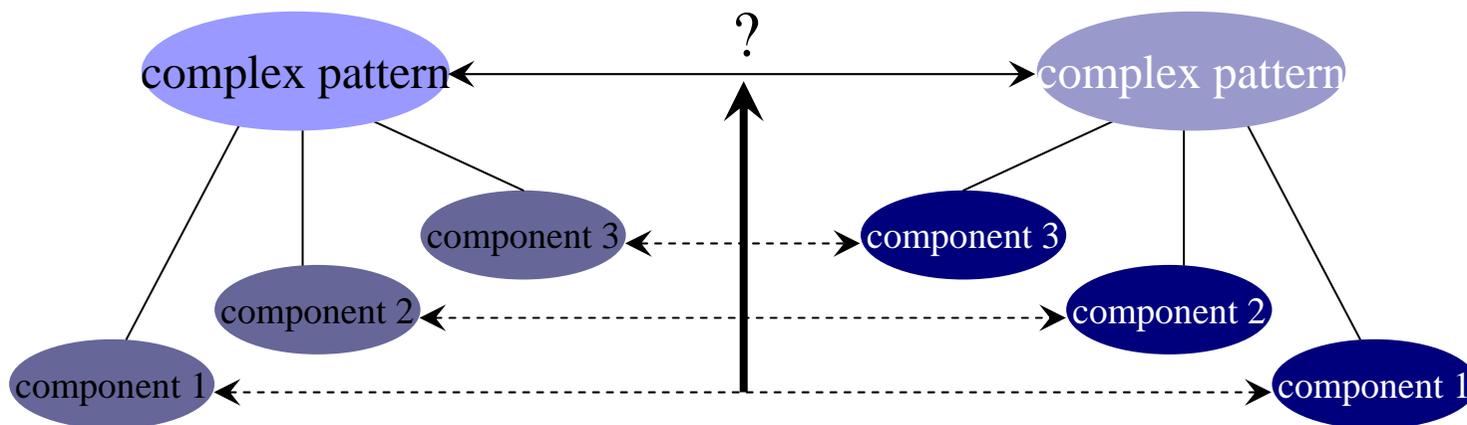
- Distanza tra le matrici:

$$\log(\det((cov_1 + cov_2) / 2) / \sqrt{\det(cov_1) \det(cov_2)})$$

- Distanza totale = $d_{cen} / 8 + d_{cov} / 2$

Confronto di pattern complessi

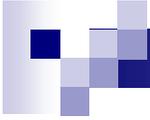
- In generale, occorre **ricorsivamente** confrontare i pattern componenti
- Vengono usate due astrazioni generali:
 - Tipo di accoppiamento
 - Logica di aggregazione





Accoppiamento

- Definisce come associare i pattern componenti dei due pattern complessi p_1 e p_2
- In generale, equivale a definire una matrice $\mathbf{X}_{n \times m} = (x_{ij})$ tale che $x_{ij} \in [0, 1]$
- x_{ij} rappresenta l'ammontare dell'accoppiamento tra l' i -esimo pattern componente di p_1 ed il j -esimo pattern componente di p_2



Tipi di accoppiamento

- 1-1

- $\sum_i x_{ij} \leq 1, \sum_j x_{ij} \leq 1, \sum_{ij} x_{ij} = \min\{N, M\}, x_{ij} \in \{0, 1\}$

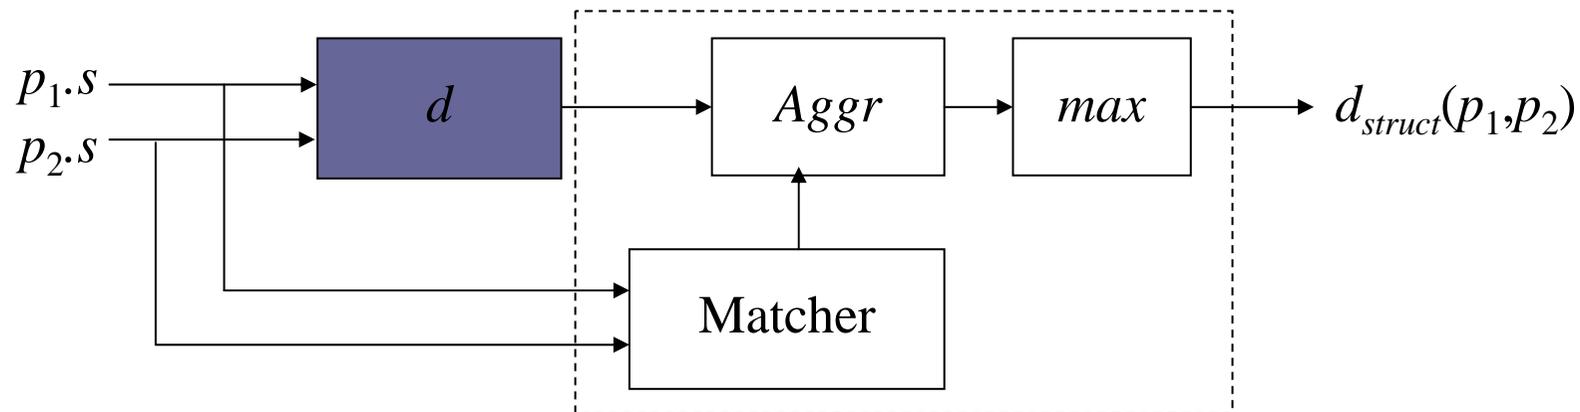
- N-M

- Nessun vincolo su X

- $x_{ij} \in \{0, 1\}$

Logica di aggregazione

- Una volta accoppiati i pattern componenti, come calcolare la differenza globale?
- Idea di base: selezionare il “miglior” accoppiamento
- $d_{struct} = \min_x \{Aggr(p_1, p_2, X)\}$





Esempio: large itemsets

- Sappiamo come confrontare due itemset
- Vogliamo confrontare set di itemsets

■ Es.: $(\{a\}, 0.5)$ $(\{b\}, 0.3)$
 $(\{b\}, 0.4)$ $(\{c\}, 0.5)$
 $(\{a,b\}, 0.25)$ $(\{b,c\}, 0.2)$

□ $d((\{b\}, 0.4), (\{b\}, 0.3)) = 0.05$

□ $d((\{a\}, 0.5), (\{c\}, 0.5)) = 0.5$

□ $d((\{a,b\}, 0.25), (\{b,c\}, 0.2)) = 0.19$

■ $d = (0.05 + 0.5 + 0.19) / 3 = 0.25$

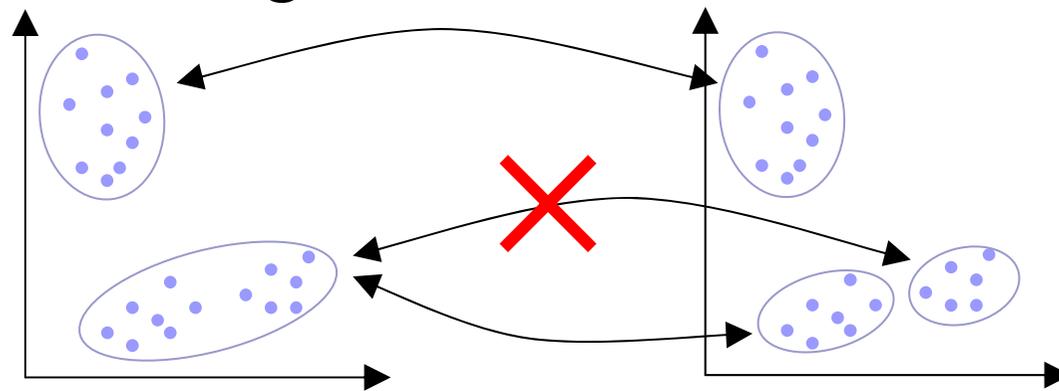


EMD (Earth Mover's Distance)

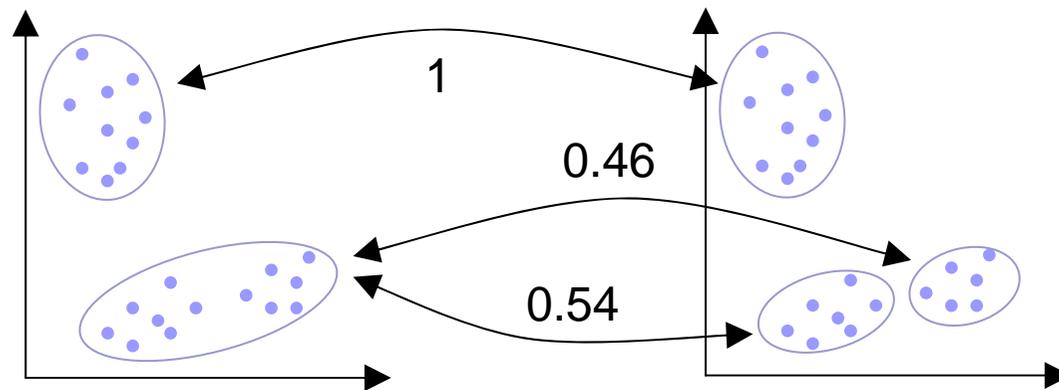
- Permette di accoppiare tra loro “pezzi” dei pattern componenti
- Ad ogni componente deve essere associato un peso (es.: supporto) w_i
 - $\sum_i x_{ij} \leq w_j, \sum_j x_{ij} \leq w_i$
 - $\sum_{ij} x_{ij} = \min\{\sum_i w_i, \sum_j w_j\},$
 - $x_{ij} \in [0, 1]$
 - $d_{struct} = \min_{\mathbf{x}} \{ \sum_i \sum_j d_{ij} x_{ij} \} / \min\{\sum_i w_i, \sum_j w_j\}$

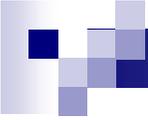
Esempio: clustering

- 1-1 matching



- EMD matching ($w_i = \text{supporto}$)





Esempio: decision trees

- Confronto tra due foglie dell'albero

- $d_{struct} = 1 - \frac{\cap \text{aree}}{\cup \text{aree}}$

- $d_{meas} = |supp_1 - supp_2|$

- Logica di aggregazione

- Una qualsiasi di quelle adottate in precedenza



Confronto PANDA/FOCUS

■ Vantaggi PANDA:

- Diversi criteri di accoppiamento
- Definizione ricorsiva di pattern complessi
 - Finora abbiamo visto solo 2 livelli di aggregazione
 - Cosa succederebbe con cluster di regole associative?
- Non è necessario tornare sui dati grezzi per calcolare la differenza tra pattern

■ In sommario:

- + flessibile
- + generale
- + efficiente