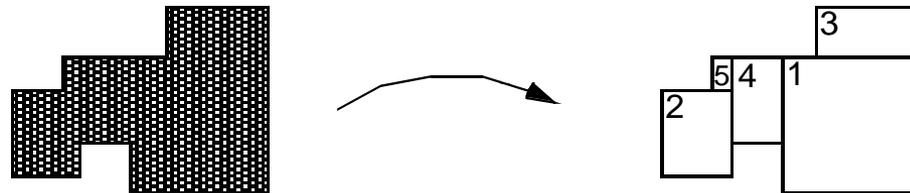


## 3.2.3 Überdeckungsmodell für 2D-Formen

- **Idee** [Jagadish. Proc. ACM Int. Conf. on Management of Data (SIGMOD) 1991]
  - Ähnlichkeitsmodell für 2D Objekte (leicht erweiterbar auf 3D)
  - Distanzfunktion: Flächeninhalt der symmetrischen Differenz zweier Formen.
  - Hier: Translations- und skalierungsinvariant, nicht jedoch rotationsinvariant.
  - Vorgehen: Repräsentation der Formen durch rechteckige Überdeckungen.
  - Speicherung der Rechtecksflächenmaßzahlen z.B. der Größe nach geordnet.



## – Objektmodell

- Formen sind als konturierte Objekte gegeben (d.h. Polygone)
- Extraktion von Formen aus Grauwertbildern möglich, solange klare Konturen bestimmt werden können (Probleme z.B. bei teilweise verdeckten Objekten)
- Polygone müssen nicht konvex sein (Einbuchtungen möglich)

## – Rechtecksüberdeckung

- **Additive Überdeckung**

Durch eine Folge von Rechtecken  $[R_1, R_2, \dots, R_k]$  ist eine Folge von additiven Überdeckungen  $[C_0, C_1, \dots]$  wie folgt definiert:

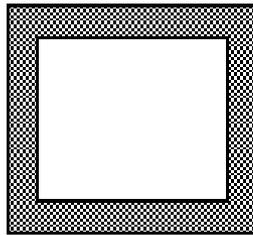
$$C_0 = \emptyset, \quad C_{i+1} = C_i \cup R_{i+1}$$

- **Allgemeine Überdeckung**

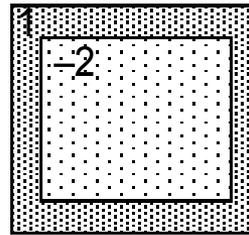
Neben dem Hinzufügen von Rechtecksflächen ( $\cup$ ) ist auch das Entfernen von Rechtecksflächen ( $-$ ) möglich:

$$C_0 = \emptyset, \quad C_{i+1} = C_i \cup R_{i+1} \quad \text{oder} \quad C_{i+1} = C_i - R_{i+1}$$

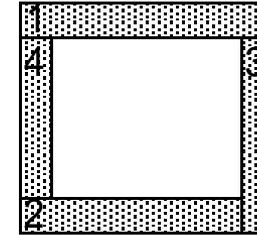
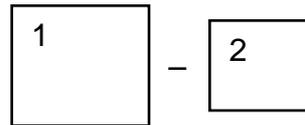
- Für endliche Formen  $S$  konvergieren (additive) Überdeckungssequenzen schon im Endlichen, d.h. es gibt ein  $K$ , so dass  $C_K = S$ , und wir definieren  $C_j = C_K$  für  $j \geq K$ .
- Überlappungen sind erlaubt, sollen aber möglichst gering ausfallen



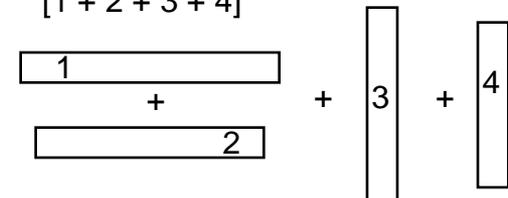
Form

Allgemeine  
Überdeckung

Sequenz:  
[1 - 2]

Additive  
Überdeckung

Sequenz:  
[1 + 2 + 3 + 4]



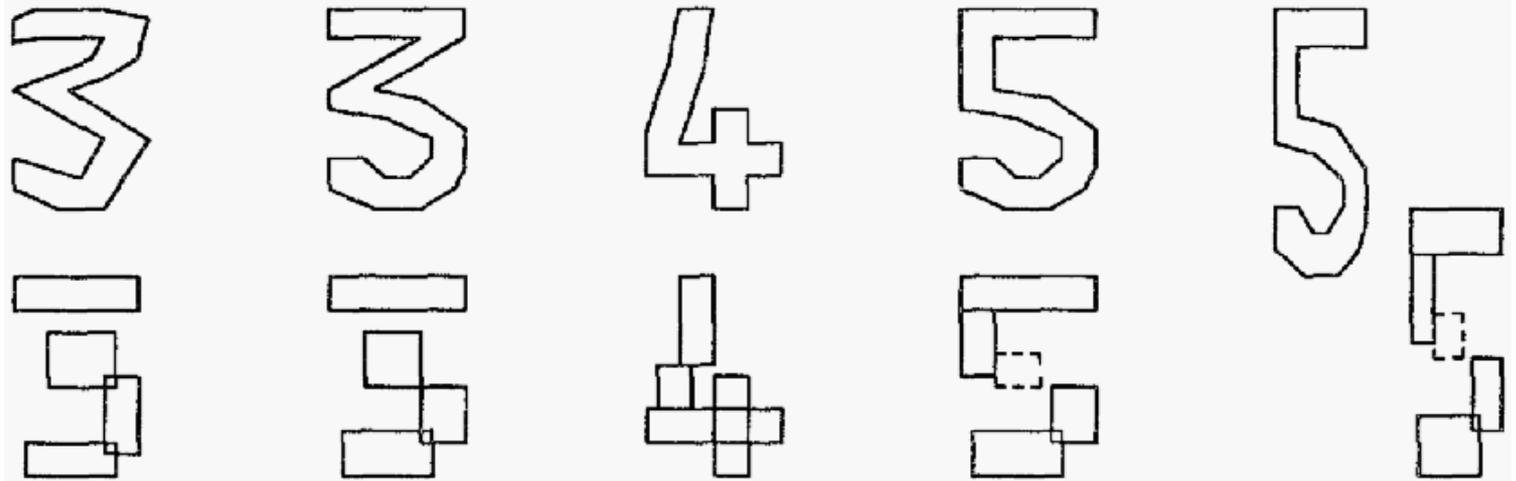
- Approximative Rechtecksüberdeckungen
  - Statt *alle* Rechtecke einer Überdeckung nur *wenige* speichern
  - Entfernen kleiner Rechtecke entspricht dem Beseitigen hochfrequenter Fehler wie Schmutzflecken oder Diskretisierungsfehlern (z.B. bei eingescannten Bildern, Voxelisierung, etc.)
- Approximationsqualität
  - Die ersten Rechtecke einer Überdeckung sollen schon eine möglichst gute Approximation der ursprünglichen Form liefern
  - Kumulatives Fehlerkriterium: Die Approximationsfehler der Überdeckungssequenz  $[C_0, C_1, \dots, S]$  werden sukzessive aufsummiert, die Gesamtsumme zählt:

$$\text{kumulativer Fehler} = \sum_{i=1}^n |S - C_i|$$

- Minimierung der Gesamtsumme:  
=> Minimierung der “frühen” Fehler  $|S - C_i|$  für kleine  $i$ , da diese mehrfach gewertet werden

- Beispiel [Jagadish. Proc. ACM Int. Conf. on Management of Data (SIGMOD) 1991]

Formen

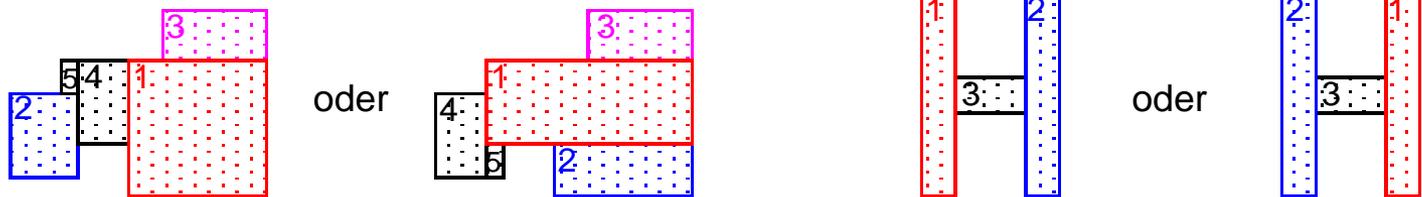


„erste“ Rechtecke der Überdeckungssequenz

- Probleme der Rechtecksüberdeckung

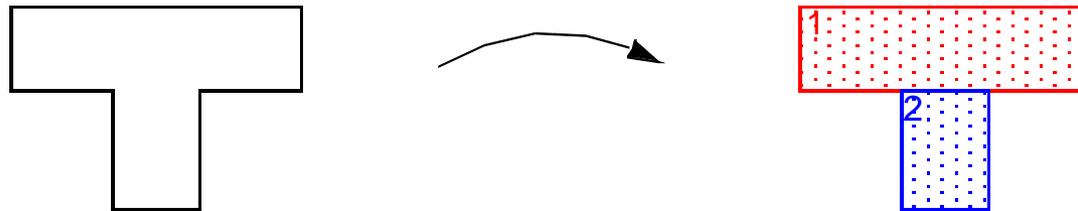
- Nicht-eindeutige Repräsentation

- » Es kann unterschiedliche optimale Zerlegungen eines Objektes geben
- » Insbesondere bei Symmetrie ist die Reihenfolge der Rechtecke nicht eindeutig
- » Lösung: Objekt mehrfach speichern oder mehrfache Anfragen für eine Form



- Rechteckige Formen

- » Wird eine Form schon durch wenige Rechtecke exakt beschrieben, besteht die Überdeckungssequenz ggf. aus weniger Elementen, als bei anderen Objekten
- » Lösung: speichere „dummy“ Rechtecke (ohne Ausdehnung)



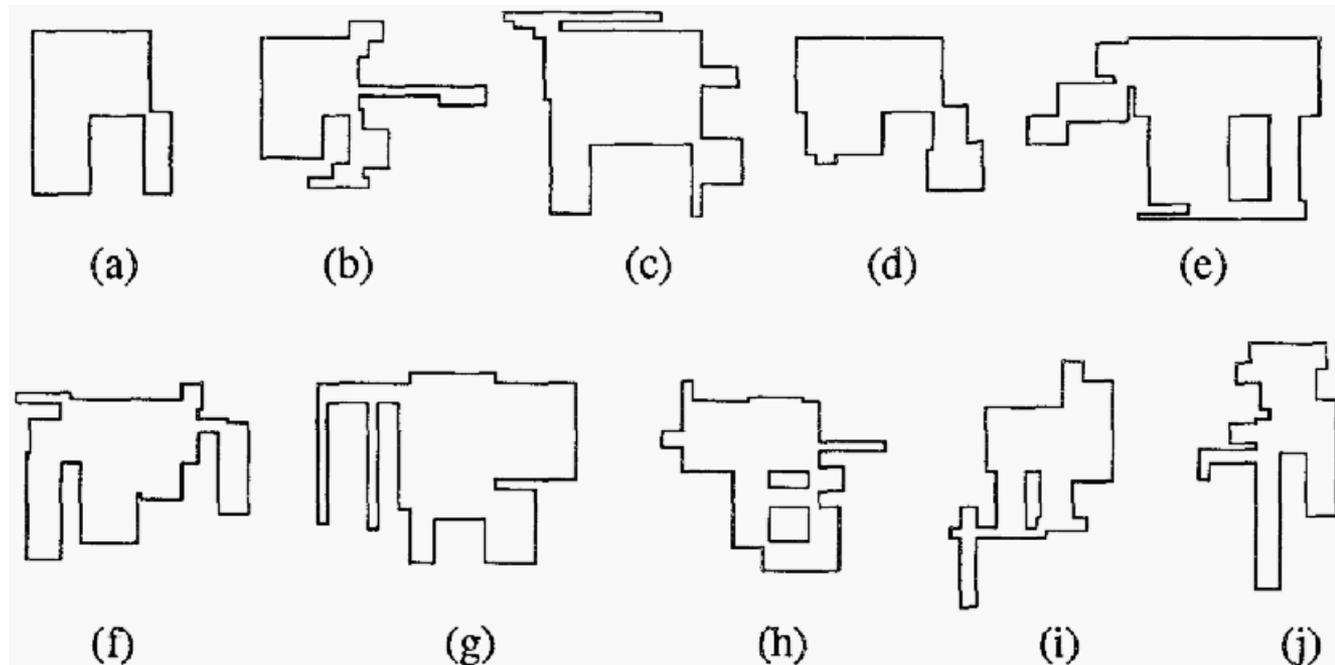
- Ähnlichkeitsanfragen

- Testbed

- » Datenbank: 16.000 synthetische Formen
    - » Form = Zusammensetzung von 10 zufällig erzeugten Rechtecken
    - » Additive Überdeckungen; jeweils die größten drei Rechtecke der Überdeckung in Index abgespeichert
    - » Anfragen: Bereichsanfragen um zufällig ausgewählte Formen der Datenbank

- Beispiel für das Ergebnis einer Ähnlichkeitsanfrage:

(a: Anfrageform; b – j: Ergebnisformen)



**Quelle:**

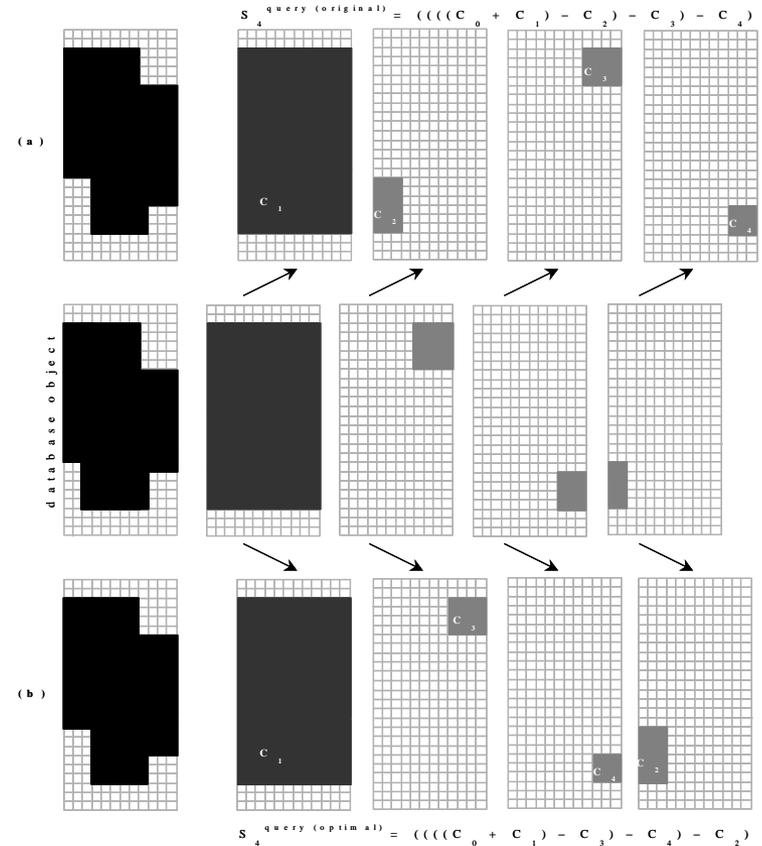
[Jagadish. Proc.  
ACM Int. Conf. on  
Management of  
Data (SIGMOD)  
1991]

# 3.2.4 Erweiterung des Überdeckungsmodell für 3D-Objekte

[Kriegel, Brecheisen, Kröger, Pfeifle, Schubert. Proc. ACM Int. Conf. on Management of Data (SIGMOD) 2003]

## – Motivation:

- Ähnlichkeitsmodell für voxelisierte 3D-CAD Daten
- Ziel: Größere Flexibilität beim Vergleich einzelner Überdeckungen innerhalb einer Überdeckungssequenz.
  - Löst das Problem der uneindeutigen Überdeckungssequenz ohne (Query-)Objekte mehrfach abzuspeichern

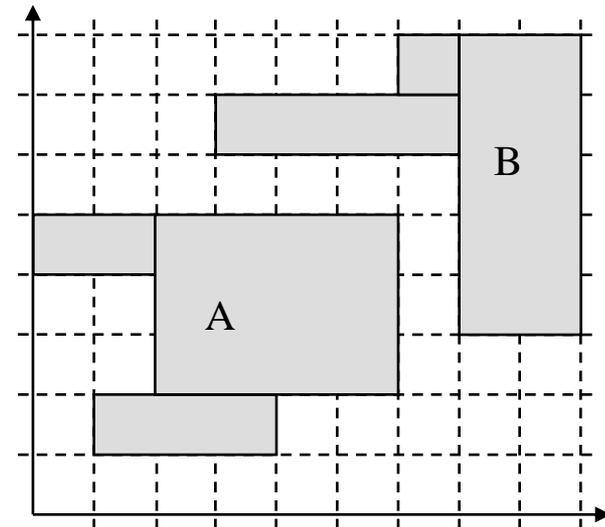


## – Idee:

- Objekt wird nicht mehr durch einen großen Feature-Vektor repräsentiert (Parameter der ersten  $k$  Überdeckungen)
- Objekt wird nun durch eine Menge von Feature Vektoren repräsentiert
  - Jede Überdeckung wird zu einem 2-D-dimensionalen Feature-Vektor
    - » Koordinaten für den Eckpunkt der Überdeckung (D Werte)
    - » Ausdehnungen der Überdeckungen entlang der Raumachsen (D Werte)
  - Überdeckungssequenz wird zu einer Menge von Feature Vektoren
  - 2D Beispiel

Mengen!!!

$$\left\{ \begin{array}{l} A = \{(1,1,3,1), (2,2,4,3), (0,4,2,1)\} \\ B = \{(7,3,2,4), (3,6,4,1), (6,7,1,1)\} \end{array} \right.$$



## – Abstand auf Punktmengen

### • Mengen Aufzählung

- Sei  $S$  eine endliche Menge
- Abbildung  $\pi(S)$  heißt **Aufzählung** von  $S$ , wenn jedem  $s \in S$  eine eindeutige Nummer zuordnet, d.h.  $\pi(s) = i \in \{1, \dots, |S|\}$
- $\Pi(S)$  bezeichnet die Menge aller möglichen Aufzählungen von  $S$

### • Minimal Matching Distance

- Distanz zwischen Punktmengen  $X$  und  $Y$
- Formal („Minimal Weight Perfect Matching Distance“):

Sei  $X = (x_1, \dots, x_{|X|})$ ,  $Y = (y_1, \dots, y_{|Y|})$ , wobei oBdA  $|X| \leq |Y|$

Sei  $w$  eine Gewichtsfunktion für nicht zugeordnete Punkte

$$\text{MinMatchDi} \quad \text{st}(X, Y) = \min_{\pi \in \Pi(Y)} \left( \underbrace{\sum_{i=1}^{|X|} \text{dist}(x_i, y_{\pi(i)})}_{\text{Jedem } x \text{ genau ein (unterschiedliches) } y \text{ zuordnen}} + \underbrace{\sum_{i=|X|+1}^{|Y|} w(y_{\pi(i)})}_{\text{Jedes noch nicht zugeordnete } y \text{ mit } w \text{ gewichten}} \right)$$

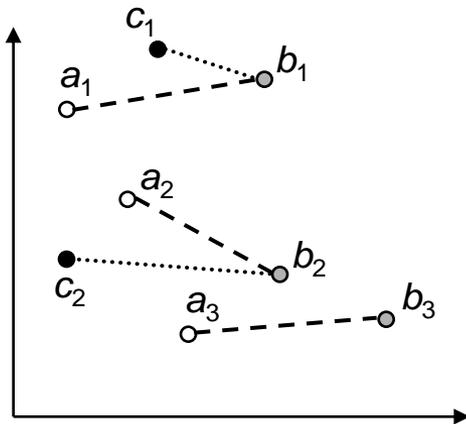
- Metrikeigenschaft hängt von der Gewichtsfunktion  $w$  ab

- Gewichtsfunktion basierend auf „Dummy-Vektoren“
  - »  $w(v)$  entspricht Distanz von  $v$  zum Null-Vektor, d.h.

$$w(v) = \text{dist}(v, 0)$$

- Intuition und Beispiel

- Punkte der Punktmenge  $X$  und  $Y$  sind Knoten in einem bipartiten Graphen
- Kanten  $(x,y)$  zwischen den Punkten  $x$  und  $y$  sind mit  $\text{dist}(x,y)$  gewichtet
- Perfektes Matching:
  - » Jeder Knoten in  $X$  ist mit genau einem Knoten aus  $Y$  verbunden
- Minimales (perfektes) Matching:
  - » Summe der Gewichte der Kanten des Matchings ist minimal



$$\text{MinMatchDist}(A,B) = \text{dist}(a_1,b_1) + \text{dist}(a_2,b_2) + \text{dist}(a_3,b_3)$$

$$\text{MinMatchDist}(C,B) = \text{dist}(c_1,b_1) + \text{dist}(c_2,b_2) + w(b_3)$$

$$\text{mit } w(b_3) = \text{dist}(0,b_3)$$

## – Anfragebearbeitung

- Motivation:
  - Berechnung des Minimalen Matchings ist teuer („Kuhn-Munkres-Algorithmus“:  $O(k^3)$ ,  $k$  = Anzahl der Überdeckungen)
- Lösung:
  - Filter/Refinement
  - Gesucht: billigere Distanz, die Lower Bounding Eigenschaft erfüllt
- Centroid Filter
  - Centroid ist der Schwerpunkt/Mittelpunkt einer Punktmenge
  - Lemma:
    - » Seien  $X$  und  $Y$  Mengen mit  $k$  Vektoren und  $c_X, c_Y$  die entsprechenden Centroide
    - » Dann gilt

$$k \cdot L_2(c_X, c_Y) \leq \text{MinMatch}(X, Y)$$

- » Verwalte Centroide in einem separaten Index
- » Filter: auf Centroid-Index

