

Seminar SS 2002

Multimediale Informationssysteme
Audio / Video Retrieval

AG Datenbanken und Informationssysteme,
Prof. Dr. Härder, Universität Kaiserslautern

Übersicht

Video-Retrieval

Beispiel-Video

Organisation

Datenbankanfragen

Frame Segment Trees

Automatische Indexierung

Audio-Retrieval


Suche auf Metadaten

Suche mit akustischen Merkmalen

Suche mit Noten

Suche in gesprochenem Text

Einleitung




Mehr als drei Milliarden Internetseiten
Täglich kommen ca. sieben Millionen Seiten hinzu



Der Anstieg der Audio- und Videodaten verhält sich gleich

Beispiel-Video



Organisation (1)

Definiton 1:

Ein Paar $(\text{ename}, \text{wert})$ ist eine *Eigenschaft*. ename ist der Name der *Eigenschaft*, wert ist eine Menge. Eine Instanz einer *Eigenschaft* lautet $\text{ename} = v, v \in \text{wert}$

Beispiel:

$(\text{Nummernschild}, X)$ beschreibt ein Nummernschild. X ist eine Menge,
Beinhaltend $\text{Ort} \times \text{Alpha}_2 \times \text{Num}_4$

$(\text{Größe}, R^+)$ beschreibt in positiven reellen Zahlen die Größe einer Person.

Organisation (2)

Definiton 2:

Eine *Objektbeziehung* in ein Paar (f_d, f_i) bei dem gilt:

1. f_d ist eine Menge von bildabhängigen Eigenschaften
2. f_i ist eine Menge von bildunabhängigen Eigenschaften
3. $f_i \neq f_d$

Beispiel:

Eine bildabhängige Eigenschaft ist Hemdfarbe.

➔ Die Farbe ändert sich durch Schatten, Lichteinstrahlung, etc.

Organisation (3)

Definiton 3:

Eine *Objektinstanz* ist ein Tripel (oid, os, ip) . Es gilt:

1. oid ist eine eindeutige Zuweisung für die *Objektinstanz* (Objekt-ID)
2. $os = (fd, fi)$ ist eine *Objektbeziehung*
3. ip ist eine Menge von Aussagen, bei denen gilt:
 1. Für jede *Eigenschaft* $(ename, wert)$ in fi enthält ip mindestens einen Inhalt von $(ename, wert)$
 2. Für jede *Eigenschaft* $(ename, wert)$ in fd und jedem Bild b des Videos enthält ip mindestens einen Inhalt von $(ename, wert)$

Beispiel:

Die Objektinstanz $(Person, fd_1, fi_1)$ hat folgende Inhalte:

$Person$ hat als Inhalt *Stefan F.*

fd hat als Inhalt *(hat, Koffer)* (Stefan F. hat den Koffer in Bild 1)

fi hat als Inhalt *(Größe, 187)* (Stefan F. ist 187cm groß)

Organisation – Ergebnis

Bild	Objekt	Bildabhängige Eigenschaften
1	Stefan F. Dope's Haus Koffer	besitzt(Koffer), wo(Gehweg_Anfang) Tür(geschlossen)
2	Stefan F. Jens Dope Dope's Haus Koffer	besitzt(Koffer), wo(Gehweg_Mitte) wo(in_Tür) Tür(offen)
3	Stefan F. Jens Dope Dope's Haus Koffer	besitzt(Koffer), wo(Gehweg_Ende) wo(in_Tür) Tür(offen)
4	Stefan F. Jens Dope Dope's Haus Koffer	wo(Gehweg_Mitte) besitzt(Koffer), wo(in_Tür) Tür(offen)
5	Stefan F. Dope's Haus Koffer	wo(Gehweg_Anfang) Tür(geschlossen)

Objekt	Bildunabhängige Eigenschaften	Inhalt
Stefan F.	Alter	27
	Größe	187 cm
Dope's Haus	Adresse	Gottlieb-Daimler-Str. 1 67663 Kaiserslautern
	Art	Holzhaus
	Farbe	Braun
Jens Dope	Alter	28
	Größe	189 cm
Koffer	Farbe	Rot
	Breite	40 cm
	Höhe	30 cm

Organisation (4)

Definiton 4:

Eine *Aktivitätsbeziehung* AktBez ist eine endliche Menge.

Wenn $(\text{ename}, \text{wert}_1)$ und $(\text{ename}, \text{wert}_2)$ in AktBez sind,
dann gilt: $\text{wert}_1 = \text{wert}_2$

Beispiel:

Die Aktivitätsbeziehung *übergeben* hat eine 3-Paar-Beziehung:

1. $(\text{Geber}, \text{Person})$: Die *Eigenschaft* Geber ist vom Typ Person (Stefan F.)
2. $(\text{Empfänger}, \text{Person})$: Die *Eigenschaft* Empfänger ist vom
Typ Person (Jens Dope)
3. $(\text{Gegenstand}, \text{Objekt})$: Beinhaltet den Wert des Gegenstands (Koffer)

Organisation (5)

Definiton 5:

Eine *Aktivität* ist ein Paar, beinhaltend


1. AktID (der Name der Aktivitätsbeziehung AktBez)
2. Für jedes Paar $(\text{ename}, \text{wert}) \in \text{AktBez}$ gilt: $\text{ename} = v, v \in \text{wert}$

Beispiel *Objektaustausch*:

Die *Aktivität* hat drei Paare $(\text{ename}, \text{wert})$:

$\{ (\text{Geber}, \text{Person}), (\text{Empfänger}, \text{Person}), (\text{Gegenstand}, \text{Objekt}) \}$

Datenbankanfragen (1)



Datenbankanfragen (2)

1. FindeVideoMitObjekt(o):

Bei der Übergabe eines Objekts o an die Funktion erhält man ein Tripel der Form:
(Video-ID, Start-Bild, End-Bild)

Beispiel: `FindeVideoMitObjekt(Koffer)`

Ergebnis: (ÜV , 0 , 3000)

Ebenso: 2. `FindeVideoMitAktivität(a)`

3. FindeObjekteInVideo(v,s,e):

Bei der Übergabe eines Videos v , eines Start-Bildes s und eines End-Bildes e erhält man eine Menge von Objekten.

Beispiel: `FindeObjekteInVideo(ÜV,2500,3250)`

Ergebnis: {(Stefan F.), (Jens Dope), (Koffer), (Dope's Haus)}

Ebenso: 4. `FindeAktivitätenInVideo(v,s,e)`

Datenbankanfragen (3)

5. FindeVideoMitAktivitätUndEigenschaften(a,e,z):

Bei der Übergabe einer Aktivität a, einer Eigenschaft e und deren Wert z erhält man ein Tripel der Form: (Video-ID , Start-Bild , End-Bild)

Beispiel: `FindeVideoMitAktivitätenUndEigenschaften(Sprechen,Person,‘Stefan F.’)`
Ergebnis: (ÜV , 2200 , 2500)

Ebenso: 6. `FindeVideoMitObjektUndEigenschaft(a,e,z)`

7. FindeAktivitätenUndEigenschaftenInVideo(v,s,e):

Bei der Übergabe eines Videos v und eines Segments [s,e] erhält man eine Menge der Form:
Aktivitätsname:Eigenschaft1=Wert1; Eigenschaft2=Wert2; ...; Eigenschaftk=Wertk

Beispiel: `FindeAktivitätenUndEigenschaftenInVideo(ÜV,1500,2000)`

Ergebnis: `übergeben:Empfänger=,Stefan F.’;Geber=,Jens Dope‘;Gegenstand=,Koffer‘`

Ebenso: 8. `FindeObjekteUndEigenschaftenInVideo(v,s,e)`

Datenbankanfragen – SQL (1)

Um die vorgenannten Funktionen zu nutzen muß die
Datenbanksprache SQL erweitert werden.

SELECT enthält
zusätzlich:

Video-ID : [s,e]

FROM enthält
zusätzlich:

video : <quelle><V>

WHERE enthält
zusätzlich:

Ausdruck IN
Funktionsaufruf

Video-ID: Eindeutige Kennung eines Videos

[s,e] : Segment mit Start-Bild s und End-Bild e

quelle : Videobibliothek

V : Laufvariable über die Videos in der Videobibliothek

Datenbankanfragen – SQL – Beispiele (1)

Finde alle Videos und Segmente aus der Videobibliothek ,videobib‘, in denen Jens Dope und Stefan F. zu sehen sind.

```
SELECT vid:[s,e]
FROM   video:videobib
WHERE  (vid,s,e) IN FindeVideoMitObjekt(,Jens Dope`) AND
       (vid,s,e) IN FindeVideoMitObjekt(,Stefan F.`)
```

Datenbankanfragen – SQL – Beispiele (2)

Finde alle Videos und Segmente aus der Videobibliothek ‚videobib‘, in denen Jens Dope einen Koffer von Stefan F. erhält.

```
SELECT vid:[s,e]
FROM   video:videobib
WHERE  (vid,s,e) IN FindeVideoMitObjekt('Jens Dope') AND
        (vid,s,e) IN FindeVideoMitObjekt('Stefan F.') AND
        (vid,s,e) IN FindeVideoMitAktivitätUndEigenschaft
                    (Austausch,Objekt,Koffer) AND
        (vid,s,e) IN FindeVideoMitAktivitätUndEigenschaft
                    (Austausch,Empfänger,'Jens Dope') AND
        (vid,s,e) IN FindeVideoMitAktivitätUndEigenschaft
                    (Austausch,Geber,'Stefan F.')
```

Frame Segment Tree (1)

Für jede Aktivität und jedes Objekt eines Bildes erfolgt ein Eintrag in der Datenbank

ineffizient



Speicherung nach Sequenzen

Auftreten interessanter Objekte im Überwachungsvideo

ID	Objekt	Sequenz	ID	Objekt	Sequenz
1	Jens Dope	0 – 125	4	Unbekanntes Auto	1000 – 1125
1	Jens Dope	250 – 3000	4	Unbekanntes Auto	1750 – 1875
2	Stefan F.	0 – 4000	4	Unbekanntes Auto	3000 – 3250
3	Koffer	0 – 3000	5	Passant	1500 – 2000
4	Unbekanntes Auto	500 – 625	5	Passant	2750 – 3250


Frame Segment Tree (2)

Aufbau des binären Frame-Segment-Trees:

1. Jeder Knoten im Baum repräsentiert ein Segment des gesamten Videos.
2. Jedes Blatt befindet sich auf der untersten Ebene. Das linke Blatt bezeichnet das Intervall $[s_1, s_2)$, das nächste das Intervall $[s_2, s_3)$, usw.
Wenn N ein Knoten zwei Kindknoten mit den Intervallen $[p_1, p_2)$ und $[p_2, p_3)$ hat, dann bezeichnet der Knoten N das Intervall $[p_1, p_3)$.
3. Jede Zahl in den Knoten wird als Adresse angesehen.
4. Die Zahl neben den Knoten bezeichnet die ID der Objekte.


Für die Konstruktion werden alle Anfangs- und Endbilder in einer Liste gespeichert.
Diese Liste wird von Duplikaten befreit und sortiert.

Frame Segment Tree (3)




Frame Segment Tree - Speicherung

Speicherung ist abhängig vom jeweiligen Knoten:



Speicherung ist abhängig von den Objekten:



Automatische Indexierung

Es gibt drei Hauptschnitte in Filmen

- a) Shot concatenation: Die Szenen werden aneinander gehängt
- b) Spatial composition: Die Szenen werden ineinander übergeblendet
- c) Chromatic composition: Entweder Ausblenden, oder Einblenden

Die automatische Indexierung kann den Einsatz des Menschen nicht übernehmen.

Audio-Retrieval

Es gibt vier Hauptsuchmethoden

1. Suche auf Metadaten
2. Suche auf akustischen Merkmalen
3. Suche mit Noten, bzw. Tonintervallen
4. Suche in gesprochenem Text

Suche auf Metadaten

Die Suche auf Metadaten erfolgt auf der Basis des Text-Retrieval

Zu den Audio-Daten wird eine Datenbank (z.B. Cddb) angelegt, die zusätzliche Informationen, wie Sängername, Gruppe, Erscheinungsjahr, etc. enthält.

Suche mit akustischen Merkmalen

- Suche erfolgt auf den „Rohdaten“ eines Audio-Signals
- Das Signal wird in einzelne Fenster a priori durch Eingabe einer bestimmten Fensterbreite oder a posteriori durch geeignete Mechanismen unterteilt.
- Man behandelt jedes Fenster einzeln und speichert die gewünschten Merkmale

Die bekanntesten Merkmale sind:

- a) Intensität
- b) Lautstärke
- c) Tonhöhe
- d) Helligkeit

Suche mit Noten

Die Suche erfolgt auf Basis des Taktes, Tempos oder der Noten

Erkennung der Noten aus dem Audiosignal:

Überlagerung vieler Instrumente führt zu Problemen


→ Verwendung von Audiodaten im MIDI-Format

Search by Humming:


Die Melodie wird als Folge von „S“, „U“ und „D“ gespeichert

→ Unabhängig von der Tonhöhe

Suche in gesprochenem Text



Ausblick



ENDE
