

Datenstrukturen und Datenorganisation

**unter besonderer Berücksichtigung von
Datenmodellierung**

Prof. Rudolf Bayer, Ph.D.

www3.in.tum.de

TU München, WS 2001/02

Inhaltsverzeichnis

- 1. Einleitung
- 1.1 Architektur von IV-Systemen
- 1.2 Anwendungsbeispiel OMNIS/Myriad
- 1.3 Vorlesungsziel
- 1.4 Abbildung E/R und objektorientierte Modelle
- 1.5 Speicher
- 1.6 UNIX File System
- 1.7 Rückblick über Datenstrukturen
- 1.8 Datenstrukturen und formale Sprachen

Kap. 1 Einleitung

Kap. 1.1 Architektur von IV-Systemen

Mehrschichten-Ansatz:

Anwendungen

Konzeptuelle Modelle

Logische Modelle

Physische Modellierung = Implementierung

Problem:

Geeignete Abbildung über alle Abstraktionsebenen?

3

Randbedingungen

- Anwendungen: t/s, DB-Größen, updates/s, Responsezeit, Archiv-Größe, Zuverlässigkeit (z.B. 24x7),
- Annahmen zur Ableitung solcher Kennzahlen?
- verfügbare Basistechnologien
- Kosten, Fertigstellungsdatum,

4

Beispiele für Anwendungen

Telekom Rechnungen	human genome
OMNIS/Elektra	GfK
Bank	Patentamt
Bayer. Staatsbibliothek	VW-Zulieferung JIT
VW-Reparaturen	
Amadeus	
Krankenversicherung AOK	

5

Beispiel Telekom Rechnungen

20 Mio Anschlüsse x 500 Anrufe/Monat
= 10^{10} Anrufe/Monat

DB Größe

100 B/Anruf $\sim 10^{12}$ B/Monat = 1 TB/Monat

Transaktionsrate

10^{10} Anrufe/Monat = 3×10^8 Anrufe/Tag $\sim 3 \times 10^3$ Anrufe/sec

Tagsüber $\sim 6 \times 10^3$ Anrufe/sec

insert into Anrufe

(Tel#, Datum, Start, Ende, Tel2#, Einheiten, Provider)

6

Telefon Rechnungen erstellen

```
select Tel#, provider, sum(Einheiten)
from Anrufe
group by Tel#, provider
```

Sortiere Anrufe nach (Tel#, provider, Datum, Start)

Frage: Zeit, um 1 TB Daten zu sortieren?

Alternative Architekturen zu einem zentralen System?

7

Beispiele für konzeptuelle Modelle

- E/R
- ME/R
- Objekt orientierte Modelle (oo)
- Html
- Xml
- UML
- Prozeß-Algebra
- Petri Netze
- Dexter Modell
- Amsterdam Modell

8

Beispiele für logische Modelle

- Hierarchische (IMS)
- Netzwerke (UDS)
- Relationale DBMS ~ 10 Mrd \$ Weltmarkt
- Deduktive DBMS (1980-1995), LOLA, NAIL!, ECRC, MCC
- Objektorientierte DBMS (Object Store, Versant, Ontos, Objectivity) ~ 100 Mio \$ Weltmarkt ~ 1%
- NF² (non first normal form), ähnlich zu XML

9

Beispiele für Basistechnologien

- Prozessoren + Multiprozessoren
- Speicher + Caches
- Busse (intern und extern)
- Festplatten und RAIDS
- Betriebssysteme und Prozesse, Threads
- Netze und Protokolle (Netzzugriff vs Plattenzugriff)
- Architekturen (Client-Server)

10

Kap.1.2 Anwendungsbeispiel: OMNIS/Myriad

Ziel: Literatur-Verwaltung,
multimediale Dokumenten-Verwaltung

Konzeptuelles Modell der Bibliotheken

Hierarchien von Dokumenten

Zeitschrift

Band

Heft

Aufsatz

Monographie

11

Maschinelles Austauschformat Bibliotheken MAB

Autoren*

Titel

Untertitel

Verleger

Jahr

Ort

Zeitschrift

Band*

Heft*

erste Seite

letzte Seite

Fingerprint ...

Ca. 950 einzelne Felder !!!

12

Konzeptuelles Modell von OMNIS/Elektra

- Vollständiger Text
- Dokument als Folge von Seitenbildern
- Treffer mit Kurzinformation

Methoden

- Recherchieren, Freitext
- Kurzinfo anzeigen
- Dokument bestellen, drucken, lesen, lokal speichern
- Bezahlen
- Zitieren

Hinweis: Modell geht weiter als heutige Realität in klassischen Bibliotheken, Methoden werden von unterschiedlichen Akteuren veranlaßt

13

Recherche: z.B. Freitext-Suche in 5 GB (konzeptuelle Ebene)

- exakte Einzelbegriffe
- Pattern-Match mit Wildcards:
datenbank%
dat%ba%
- Phrasensuche: relational algebra
query opti%
- Boolesche Kombinationen
dat%ba% & dat%stru%
datenba% & optimier%
- Nachbarschaftssuche
hierarchy space
- Struktursuche: Attributkombinationen
?Autor = 'Bayer' & ?Jahr ≤ 1986
& ?Jahr > 1978
& dat%ba% & synchroni_ation

14

Dokumenten DB, logisches Modell von OMNIS

Dok = (Text, DB-Satz, Image-Folge, Postscript-Datei)

noch zu ergänzen: Details des DB-Satzes, z.B. Dublin Core, MAB, UniMarc, ...

Text Repräsentation für Freitext Recherche:

My0 (Wort, W#) **My1** (W#, Doc#, Pos)

typische DB-Größe: 10^6 Dokumente

$5 \cdot 10^6$ Images x 40 KB = $2 \cdot 10^{11}$ Bytes = 200 GB

Text: $5 \cdot 10^6 \cdot 10^3$ B = 5 GB

Speicherung dieser DB?

15

Das physische Modell:

Erfassungsvorgang

1. Einscannen → Pixelbild = Image

- geeignete Datenstruktur? z.B. Spezialform von Quad-Tree
- Kompressionsalg., 1 x auf Server
- Dekompression: < 2sec auf PC 486
- Speicherung in DB
- Verschickung über Netz

16

2. Text erzeugen: OCR

OCR (Image) → Text fehlerhaft!!

- Abgleich 1 Seite Text \approx 200 Wörter mit Stammreduktion
Wörterbuch: 10^5 - 10^6 Einträge
- Korrekturvorschläge für ca. 10 Wörter
- Darstellung der Textseite?
- Darstellung des Wörterbuchs für Abgleich
- Darstellung des Wörterbuchs für Korrektur

17

3. Archivierung

- Indexierung des Textes
- Erzeugung von Strukturdaten
- Index warten
- Dok auf mehrere DBen verteilen

Gefragt:

- Datenstrukturen für alle Be- und Verarbeitungsvorgänge!
- Spezielle Anforderungen der Vorgänge berücksichtigen!

18

Arbeitsschritte/Zeitabschnitte	1.	2.	3.	4.	5.	6.
1. Mensch: Dokument einlegen Scan starten	D2			D3		
2. Rechner: scannen und speichern		D2			D3	
3. Mensch: Bereich wählen OCR starten			D2			D3
4. Rechner: OCR ausführen	D1			D2		
5. Mensch: korrigieren Maske füllen Archivierung starten		D1			D2	
6. Rechner: archivieren			D1			D2

19

Retrieval auf logischer Ebene

datenba%

select My1.Doc# **from** My0, My1

where My0.Wort **like** datenba% **and** My0.W# = My1.W#

hierarchy ... space

My01	My11	My12	My02
W#	Doc#	W#	
	Pos <	Pos	
	Pos+6 >	Pos	

20

```

select My11.Doc# from
    My0 My01, My1 My11, My1 My12, My0 My02
where My01.Wort = ,hierarchy‘ and
    My01.W# = My11.W# and
    My02.Wort = ,space‘ and
    My02.W# = My12.W# and
    My11.Doc# = My12.Doc# and
    My11.Pos < My12.Pos and
    My11.Pos+6 > My12.Pos

```

Physische Ebene: Datenstrukturen, schnelle Bearbeitung solcher Queries?

21

Kap. 1.3 Vorlesungsziel

Zwei zentrale Anliegen

- Anwendung modellieren
- Geeignete Datenstrukturen, um Komplexität mehrerer Operationen **gleichzeitig** niedrig zu halten:
 - Zeitkomplexität
 - Platzkomplexität

mit Randbedingungen von Anwendungen!

z.B. insert, update, delete, find, compress, decompress,
 bulk load, ... retrieve interval, sort (z.B. Sätze variabler
 bzw. fester Länge)

22

Def.: $O(\dots)$ - Notation, **Ordnung einer Funktion:**

Seien N_o, R_o nicht-neg. integer, real

Sei X entweder N_o oder R_o ,

$$g : X \rightarrow X$$

$$O(g)_{\text{def}} := \{f : x \rightarrow x \mid \exists c > 0,$$

$$\exists x_0 \in X, \forall x \geq x_0 : f(x) \leq c \cdot g(x)\}$$

Notationen:

$f \in O(g)$, $f = O(g)$, f hat Ordnung $O(g)$, f ist von Ordnung $O(g)$

Eigenschaften:

$$f_1 \in O(f) \wedge g_1 \in O(g) \Rightarrow f_1 \cdot g_1 \in O(f \cdot g)$$

$$f \in O(g) \wedge g \in O(h) \Rightarrow f \in O(h)$$

$$f \in O(g) \Rightarrow O(f) \subseteq O(g)$$

23