

3. Tabellen und Sichten

Datendefinition nach SQL

- **Datendefinition nach SQL¹**

- Elemente des SQL-Schemas
- Informations- und Definitionsschema
- Erzeugen von Basistabellen
- Integritätsbedingungen

- **Schemaevolution**

- Änderung von Tabellen
- Löschen von Objekten

- **Indexierung**

- Einrichtung und Nutzung von Indexstrukturen
- Indexstrukturen mit und ohne Clusterbildung
- Leistungsaspekte

- **Sichtkonzept**


- Semantik von Sichten
- Abbildung von Sichten
- Aktualisierung von Sichten

- **Was ist alles zu definieren, um eine "leere DB" zu erhalten?**

- **SQL-Umgebung (environment) besteht aus**

- einer Instanz eines DBMS zusammen mit
- einer Menge von Daten in Katalogen (als Tabellen organisiert)
- einer Reihe von Nutzern (authorization identifiers) und Programmen (modules)

- **Wichtige Elemente der SQL-Umgebung**



➔ Kataloge bestehen aus SQL-Schemata und können innerhalb einer SQL-Umgebung optional auf ein oder mehrere Cluster² verteilt werden

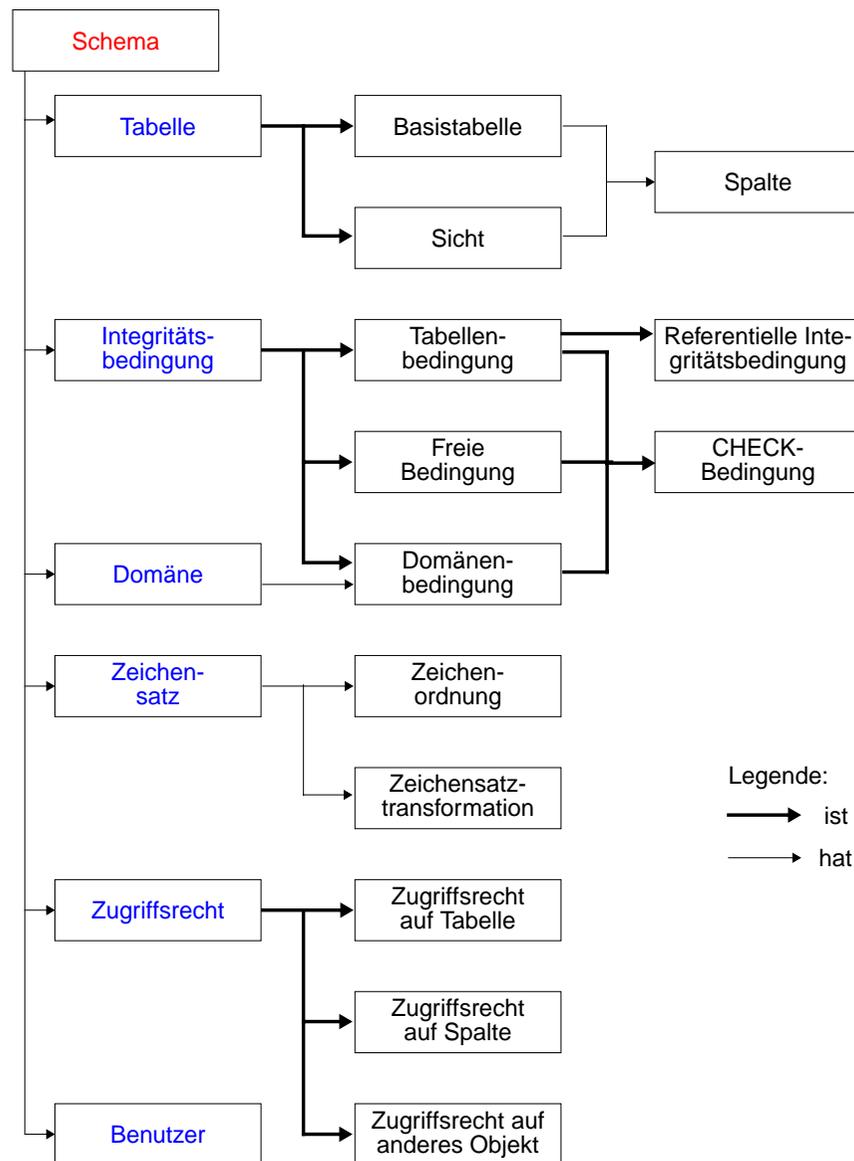
- **SQL-Schema**

- Katalog kann man als DB (in der DB) ansehen
- SQL-Schemata sind Hilfsmittel zur logischen Klassifikation von Objekten innerhalb einer solchen DB
- Datendefinitionsteil von SQL enthält Anweisungen zum Erzeugen, Verändern und Löschen von Schemaelementen

1. Synonyme: Relation – Tabelle, Tupel – Zeile, Attribut – Spalte, Attributwert – Zelle

2. Sinn dieser Clusterbildung ist die Zuordnung von genau einem Cluster zu jeder SQL-Sitzung und dadurch wiederum die Zuordnung einer Menge von Daten bzw. Katalogen zu dieser Sitzung

Elemente des SQL-Schemas




Informations- und Definitionsschema

• Ziel der SQL-Normierung

- möglichst große Unabhängigkeit der DB-Anwendungen von speziellen DBS
- einheitliche Sprachschnittstelle genügt **nicht!**
- **Beschreibung der gespeicherten Daten** und ihrer Eigenschaften nach einheitlichen und verbindlichen Richtlinien ist genauso wichtig

• Zweischichtiges Definitionsmodell für die Beschreibung der Daten



- bietet **einheitliche Sichten** in normkonformen Implementierungen
- ist **für den Benutzer zugänglich** und somit die definierte Schnittstelle zum Katalog


- beschreibt **hypothetische** Katalogstrukturen
- erlaubt „**Altsysteme**“ mit abweichenden Implementierungen normkonform zu werden

• Komplexe Strukturen³

- DEFINITION_SCHEMA umfaßt 24 Basistabellen und 3 Zusicherungen
- In den Tabellendefinitionen werden ausschließlich 3 Domänen verwendet: SQL_IDENTIFIER, CHARACTER_DATA und CARDINAL_NUMBER

3. Das nicht normkonforme Schema SYSCAT von DB2 enthält 37 Tabellen

Definitionsschema



3 - 5

Erzeugung von Basistabellen

• Definition einer Tabelle

- Definition aller zugehörigen Attribute mit Typfestlegung
- Spezifikation aller Integritätsbedingungen (Constraints)

D1: Erzeugung der neuen Tabellen Pers und Abt

CREATE TABLE Pers

(Pnr	INT	PRIMARY KEY,
Beruf	CHAR (30),	
PName	CHAR (30)	NOT NULL,
PAlder	Alter,	(* siehe Domaindefinition *)
Mgr	INT,	
Anr	Abtnr	NOT NULL, (* Domaindef. *)
W-Ort	CHAR (25)	DEFAULT ' ',
Gehalt	DEC (9,2)	DEFAULT 0.00,
		CHECK (Gehalt < 120000.00),

Constraint FK1 **FOREIGN KEY** (Anr) **REFERENCES** Abt
ON UPDATE CASCADE ON DELETE CASCADE,
Constraint FK2 **FOREIGN KEY** (Mgr) **REFERENCES** Pers (Pnr)
ON UPDATE SET DEFAULT ON DELETE SET NULL)

CREATE TABLE Abt

(Anr	Abtnr	PRIMARY KEY,
AName	CHAR (30)	NOT NULL,
Anzahl_Angest	INT	NOT NULL,
...		

CREATE ASSERTION A1

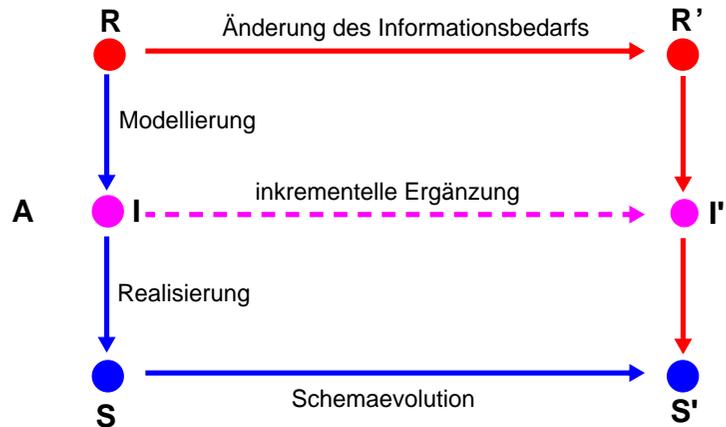
```
CHECK (NOT EXISTS
(SELECT * FROM Abt A
WHERE A.Anzahl_Angest <>
(SELECT COUNT (*) FROM Pers P
WHERE P.Anr = A.Anr)));
```

➔ Bei welchen Operationen und wann muß überprüft werden?

3 - 6

Evolution einer Miniwelt

- Grobe Zusammenhänge



R: Realitätsausschnitt (Miniwelt)

I: Informationsmodell
(zur Analyse und Dokumentation der Miniwelt)

S: DB-Schema der Miniwelt
(Beschreibung aller Objekt- und Beziehungstypen sowie aller Integritäts- und Zugriffskontrollbedingungen)

A: Abbildung aller wichtigen Objekte und Beziehungen sowie ihrer Integritäts- und Datenschutzaspekte

➔ Abstraktionsvorgang

- Schemaevolution:

- Änderung, Ergänzung oder Neudefinition von Typen und Regeln
- nicht alle Übergänge von S nach S' können automatisiert durch das DBS erfolgen

➔ gespeicherte Objekt- und Beziehungsmengen dürfen den geänderten oder neu spezifizierten Typen und Regeln nicht widersprechen

Schemaevolution

- Wachsender oder sich ändernder Informationsbedarf

- Erzeugen/Löschen von Tabellen (und Sichten)
- Hinzufügen, Ändern und Löschen von Spalten
- Anlegen/Ändern von referentiellen Beziehungen
- Hinzufügen, Modifikation, Wegfall von Integritätsbedingungen

➔ Hoher Grad an logischer Datenunabhängigkeit ist sehr wichtig!

- Zusätzliche Änderungen im DB-Schema

durch veränderte Anforderungen bei der DB-Nutzung

- Dynamisches Anlegen von Zugriffspfaden
- Aktualisierung der Zugriffskontrollbedingungen

- Dynamische Änderung einer Tabelle

Bei Tabellen können dynamisch (während ihrer Lebenszeit) Schemaänderungen durchgeführt werden

```
ALTER TABLE base-table
{ ADD [COLUMN] column-def
| ALTER [COLUMN] column
  {SET default-def | DROP DEFAULT}
| DROP [COLUMN] column {RESTRICT | CASCADE}
| ADD base-table-constraint-def
| DROP CONSTRAINT constraint {RESTRICT | CASCADE}}
```

➔ Welche Probleme ergeben sich?

Schemaevolution (2)

E1: Erweiterung der Tabellen Abt und Pers durch neue Spalten

```
ALTER TABLE Pers
  ADD Svnr INT UNIQUE
```

```
ALTER TABLE Abt
  ADD Geh-Summe INT
```

Abt	Anr	Aname	Ort
	K51	PLANUNG	KAISERSLAUTERN
	K53	EINKAUF	FRANKFURT
	K55	VERTRIEB	FRANKFURT

Pers	Pnr	Name	Alter	Gehalt	Anr	Mnr
	406	COY	47	50 700	K55	123
	123	MÜLLER	32	43 500	K51	-
	829	SCHMID	36	45 200	K53	777
	574	ABEL	28	36 000	K55	123

E2: Verkürzung der Tabelle Pers um eine Spalte

```
ALTER TABLE Pers
  DROP COLUMN Alter RESTRICT
```

- Wenn die Spalte die einzige der Tabelle ist, wird die Operation zurückgewiesen.
- Da RESTRICT spezifiziert ist, wird die Operation zurückgewiesen, wenn die Spalte in einer Sicht oder einer Integritätsbedingung (Check) referenziert wird.
- CASCADE dagegen erzwingt die Folgelöschung aller Sichten und Check-Klauseln, die von der Spalte abhängen.

Schemaevolution (3)

• Löschen von Objekten

```
DROP {TABLE base-table | VIEW view |
      DOMAIN domain | SCHEMA schema }
      {RESTRICT | CASCADE}
```

- Falls Objekte (Tabellen, Sichten, ...) nicht mehr benötigt werden, können sie durch die DROP-Anweisung aus dem System entfernt werden.
- Mit der CASCADE-Option können 'abhängige' Objekte (z. B. Sichten auf Tabellen oder anderen Sichten) mitentfernt werden
- RESTRICT verhindert Löschen, wenn die zu löschende Tabelle noch durch Sichten oder Integritätsbedingungen referenziert wird

E3: Löschen von Tabelle Pers

```
DROP TABLE Pers RESTRICT
```

PersConstraint sei definiert auf Pers:

1. ALTER TABLE Pers
DROP CONSTRAINT PersConstraint CASCADE
2. DROP TABLE Pers RESTRICT

• Durchführung der Schemaevolution

- Aktualisierung von Tabellenzeilen des SQL-Definitionsschemas
- „tabellengetriebene“ Verarbeitung der Metadaten durch das DBS

Indexierung

- Einsatz von Indexstrukturen

- Beschleunigung der Suche: Zugriff über Spalten (Schlüsselattribute)
- Kontrolle von Integritätsbedingungen (relationale Invarianten)
- Zeilenzugriff in der logischen Ordnung der Schlüsselwerte
- Gewährleistung der Clustereigenschaft für Tabellen

➔ **aber:** erhöhter Aktualisierungsaufwand und Speicherplatzbedarf

- Einrichtung von Indexstrukturen

- Datenunabhängigkeit des Relationenmodells erlaubt ein Hinzufügen und Löschen
- jederzeit möglich, um z. B. bei veränderten Benutzerprofilen das Leistungsverhalten zu optimieren
- "beliebig" viele Indexstrukturen pro Tabelle und mit unterschiedlichen Spaltenkombinationen als Schlüssel möglich
- Steuerung der Eindeutigkeit der Schlüsselwerte, der Clusterbildung
- Freiplatzanteil (PCTFREE) in jeder Indexseite beim Anlegen erleichtert das Wachstum

➔ **Spezifikation:** DBA oder Benutzer

- Nutzung einer vorhandenen Indexstruktur

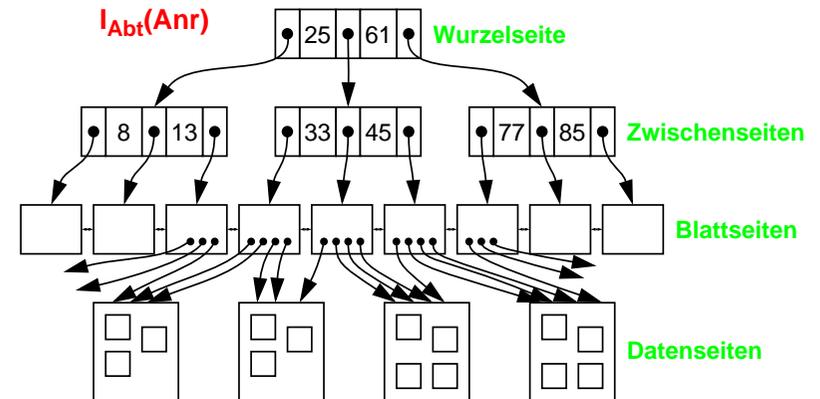
➔ **Entscheidung durch DBS-Optimierer**

- Im SQL-Standard keine Anweisung vorgesehen, jedoch in realen Systemen (z. B. IBM DB2):


```
CREATE [UNIQUE] INDEX index
ON base-table (column [ORDER] [,column[ORDER]] ...)
[CLUSTER] [PCTFREE]
```

Indexierung (2)

- Index mit Clusterbildung



- Index ohne Clusterbildung



Indexierung (3)

E4: Erzeugung einer Indexstruktur mit Clusterbildung auf der Spalte Anr von Abt

```
CREATE UNIQUE INDEX Persind1
ON Abt (Anr) CLUSTER
```

- Realisierung z. B. durch B*-Baum
(oder Hashing mit verminderter Funktionalität)
- **UNIQUE:** keine Schlüsselduplikate in der Indexstruktur
- **CLUSTER:** zeitoptimale sortiert-sequentielle Verarbeitung (Scan-Operation)


E5: Erzeugung einer Indexstruktur auf den Spalten Anr (absteigend) und Gehalt (aufsteigend) von Pers

```
CREATE INDEX Persind2
ON Pers (Anr DESC, Gehalt ASC)
```

- **Typische Implementierung einer Indexstruktur: B*-Baum**
(wird von allen DBS angeboten!)
 - ↳ **dynamische Reorganisation durch Aufteilen (Split) und Mischen von Seiten**
- **Wesentliche Funktionen**
 - direkter Schlüsselzugriff auf einen indexierten Satz
 - sortiert sequentieller Zugriff auf alle Sätze
(unterstützt Bereichsanfragen, Verbundoperation usw.)
- **Balancierte Struktur**
 - unabhängig von Schlüsselmenge
 - unabhängig von Einfügereihenfolge

Indexierung (4)

• Vereinfachtes Zahlenbeispiel zum B*-Baum



$$ES = \frac{S_L}{E_L} = \text{max. \# Einträge/Seite}$$

- h_B = Baumhöhe
- N_T = #Zeilenverweise im B*-Baum
- N_B = #Blattseiten im B*-Baum

$$N_{Tmin} = 2 \cdot \left(\frac{ES}{2}\right)^{h_B - 1} \leq N_T \leq ES^{h_B} = N_{Tmax}$$

➔ Welche Werte ergeben sich für $h_B = 3$ und $E_L = 20 \text{ B}$?

Sichtkonzept

- **Ziel: Festlegung**
 - welche Daten Benutzer sehen wollen
(Vereinfachung, leichtere Benutzung)
 - welche Daten sie nicht sehen dürfen (Datenschutz)
 - einer zusätzlichen Abbildung
(erhöhte Datenunabhängigkeit)
- **Sicht (View):** mit Namen bezeichnete, aus Tabellen abgeleitete, virtuelle Tabelle (Anfrage)
- **Korrespondenz zum externen Schema** bei ANSI/SPARC
(Benutzer sieht jedoch i. allg. mehrere Sichten (Views) und Tabellen)

```
CREATE VIEW view [ (column-commalist ) ]  
AS table-exp  
[WITH [ CASCADED | LOCAL] CHECK OPTION]
```

D2: Sicht, die alle Programmierer mit einem Gehalt < 30.000 umfaßt

CREATE VIEW


```
Arme_Programmierer (Pnr, Name, Beruf, Gehalt, Anr)  
AS SELECT Pnr, Name, Beruf, Gehalt, Anr  
FROM Pers  
WHERE Beruf = 'Programmierer' AND Gehalt < 30 000
```

D3: Sicht für den Datenschutz

```
CREATE VIEW Statistik (Beruf, Gehalt)  
AS SELECT Beruf, Gehalt  
FROM Pers
```

Sichtkonzept (2)

- **Sichten zur Gewährleistung von Datenunabhängigkeit**




- **Eigenschaften von Sichten**

- Sicht kann wie eine Tabelle behandelt werden
- Sichtsemantik:
„dynamisches Fenster“ auf zugrundeliegende Tabellen
- Sichten auf Sichten sind möglich
- eingeschränkte Änderungen:
aktualisierbare und nicht-aktualisierbare Sichten

Sichtkonzept (3)


- Zum Aspekt: Semantik von Sichten




- Sichtbarkeit von Änderungen – Wann und Was?

Wann werden welche geänderten Daten in der **Tabelle/Sicht** für die **anderen Benutzer** sichtbar?

Vor BOT
von T1, T2



Nach EOT
von T1, T2



Sichtkonzept (4)

- Abbildung von Sicht-Operationen auf Tabellen

- Sichten werden i. allg. nicht explizit und permanent gespeichert, sondern Sicht-Operationen werden in äquivalente Operationen auf Tabellen umgesetzt
- Umsetzung ist für Leseoperationen meist unproblematisch

Anfrage (Sichtreferenz):

```
SELECT Name, Gehalt
FROM Arme_Programmierer
WHERE Anr = 'K55'
```

Ersetzung durch:

```
SELECT Name, Gehalt
FROM
WHERE Anr = 'K55'
```

- Abbildungsprozeß auch über mehrere Stufen durchführbar

Sichtdefinitionen:

```
CREATE VIEW V AS SELECT ... FROM R WHERE P
CREATE VIEW W AS SELECT ... FROM V WHERE Q
```

Anfrage:

```
SELECT ... FROM W WHERE C
```

Ersetzung durch

```
SELECT ... FROM V WHERE Q AND C
```

und

```
SELECT ... FROM R WHERE Q AND P AND C
```

Sichtkonzept (5)

- Einschränkungen der Abbildungsmächtigkeit

- keine Schachtelung von Aggregat-Funktionen und Gruppenbildung (GROUP-BY)
- keine Aggregat-Funktionen in WHERE-Klausel möglich

Sichtdefinition:

```
CREATE VIEW Abtinfo (Anr, Gsumme) AS
SELECT Anr, SUM (Gehalt)
FROM Pers
GROUP BY Anr
```

Anfrage:

```
SELECT AVG (Gsumme) FROM Abtinfo
```

Ersetzung durch

```
SELECT
FROM Pers
GROUP BY Anr
```


D4: Löschen von Sichten:

```
DROP VIEW Arme_Programmierer
CASCADE
```

- Alle referenzierenden Sichtdefinitionen und Integritätsbedingungen werden mitgelöscht
- RESTRICT würde eine Löschung zurückweisen, wenn die Sicht in weiteren Sichtdefinitionen oder CHECK-Constraints referenziert werden würde.

Sichtkonzept (6)


- Änderbarkeit von Sichten



- Sichten über mehr als eine Tabelle sind i. allg. **nicht aktualisierbar!**

$$W = \Pi_{A2,A3,B1,B2} (R \bowtie S)$$

$A3 = B1$



- Änderbarkeit in SQL

- nur eine Tabelle (Basistabelle oder Sicht)
- Schlüssel muß vorhanden sein
- keine Aggregatfunktionen, Gruppierung und Duplikateliminiierung

Sichtkonzept (7)


- **Überprüfung der Sichtdefinition: WITH CHECK OPTION**

- Einfügungen und Änderungen müssen das die Sicht definierende Prädikat erfüllen. Sonst: Zurückweisung
- nur auf aktualisierbaren Sichten definierbar

- **Zur Kontrolle der Aktualisierung von Sichten**, die wiederum auf Sichten aufbauen, wurde die CHECK-Option verfeinert. Für jede Sicht sind drei Spezifikationen möglich:

- Weglassen der CHECK-Option
- WITH CASCADED CHECK OPTION oder äquivalent WITH CHECK OPTION
- WITH LOCAL CHECK OPTION

- **Vererbung der Prüfbedingung durch CASCADED**



Sichtkonzept (8)

- **Annahmen**

- Sicht S_A mit dem die Sicht definierenden Prädikat V_A wird aktualisiert
- S_I ist die höchste Sicht im Abstammungspfad von S_A , welche die Option CASCADED besitzt
- Oberhalb von S_I tritt keine LOCAL-Bedingung auf

- **Aktualisierung von S_A**

- als Prüfbedingung wird von S_I aus an S_A "vererbt":

$$V = V_I \wedge V_{I-1} \wedge \dots \wedge V_1$$

➔ **Erscheint irgendeine aktualisierte Zeile von S_A nicht in S_I , so wird die Operation zurückgesetzt**

- Es ist möglich, daß Zeilen aufgrund von gültigen Einfüge- oder Änderungsoperationen aus S_A verschwinden

- **Aktualisierte Sicht besitzt WITH CHECK OPTION**

- Default ist CASCADED
- Als Prüfbedingung bei Aktualisierungen ergibt sich $V = V_A \wedge V_N \wedge \dots \wedge V_I \wedge \dots \wedge V_1$
- Zeilen können jetzt aufgrund von gültigen Einfüge- oder Änderungsoperationen nicht aus S_A verschwinden

- **LOCAL hat eine undurchsichtige Semantik**

- Sie wird hier nicht diskutiert
- Empfehlung: nur Verwendung von CASCADED


Sichtbarkeit von Änderungen

Sichtkonzept (9)

Sichtenhierarchie:

S₂ mit V₁ ∧ V₂

S₁ mit V₁ und CASCADED



Aktualisierungsoperationen in S₂

I₁ und U₁ erfüllen das S₂-definierende Prädikat V₁ ∧ V₂

I₂ und U₂ erfüllen das S₁-definierende Prädikat V₁

I₃ und U₃ erfüllen das S₁-definierende Prädikat V₁ nicht

Welche Operationen sind erlaubt?

Insert in S₂:
 I₁ ✓
 I₂
 I₃

Update in S₂:
 U₁ ✓
 U₂
 U₃

Ohne Check-Option werden alle Operationen akzeptiert!

• Beispiel

Tabelle

Sicht 1 auf Pers

Sicht 2 auf AP1

Pers

AP1 mit Beruf = 'Prog.' AND Gehalt < '30K'

AP2 mit Gehalt > '20K'



• Operationen

- INSERT INTO AP2
VALUES (. . . , '15K')
- UPDATE AP2
SET Gehalt = Gehalt + '5K'
WHERE Anr = 'K55'
- UPDATE AP2
SET Gehalt = Gehalt - '3K'


• Welche Operationen sind bei den verschiedenen CHECK-Optionen gültig?

	1	2	3	4
a				
b				
c				

Generalisierung mit Sichtkonzept

Zusammenfassung

- Ziel: Simulation einiger Aspekte der Generalisierung



- Einsatz des Sichtkonzeptes

```

CREATE TABLE Sekretärin
  (ID      INT,
   Name    CHAR(20),
   Alter   INT,
   Sprache CHAR(15)
   ...);

INSERT INTO Sekretärin
VALUES (436, 'Daisy', 21, 'Englisch');

```

```

CREATE TABLE Ingenieur
  (ID      INT,
   Name    CHAR(20),
   Alter   INT,
   Erfahrung CHAR(15)
   ...);

INSERT INTO Ingenieur
VALUES (123, 'Donald', 37, 'SUN');

```

```

CREATE VIEW Angestellter
AS SELECT ID, Name, Alter
   FROM Sekretärin
   UNION
   SELECT ID, Name, Alter
   FROM Ingenieur;

```

```

CREATE VIEW Firmenangehöriger
AS SELECT ID, Name, Alter
   FROM Angestellter
   UNION
   SELECT ID, Name, Alter
   FROM Arbeiter;

```

- Datendefinition

- Zweischichtiges Definitionsmodell für die Beschreibung der Daten: Informationsschema und Definitionsschema
- Erzeugung von Tabellen
- Spezifikation von referentieller Integrität und referentiellen Aktionen
- CHECK-Bedingungen für Wertebereiche, Attribute und Tabellen

- Schemaevolution

Änderung/Erweiterung von Spalten, Tabellen, Integritätsbedingungen, ...

- Indexstrukturen als B*-Bäume

- mit und ohne Clusterbildung spezifizierbar
- Balancierte Struktur unabhängig von Schlüsselmenge und Einfügereihenfolge

➔ dynamische Reorganisation durch Aufteilen (Split) und Mischen von Seiten

- direkter Schlüsselzugriff auf einen indexierten Satz
- sortiert sequentieller Zugriff auf alle Sätze (unterstützt Bereichsanfragen, Verbundoperation usw.)

➔ Wie viele Indexstrukturen/Tabelle?

- Sichtenkonzept

- Erhöhung der Benutzerfreundlichkeit
- Flexibler Datenschutz
- Erhöhte Datenunabhängigkeit
- Rekursive Anwendbarkeit
- Eingeschränkte Aktualisierungsmöglichkeiten