3. Tabellen und Sichten

- **Datendefinition nach SQL**[1]
  - Elemente des SQL-Schemas
  - Informations- und Definitionsschema
  - Erzeugen von Basisrelationen
  - 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

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

Datendefinition nach SQL

- **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**

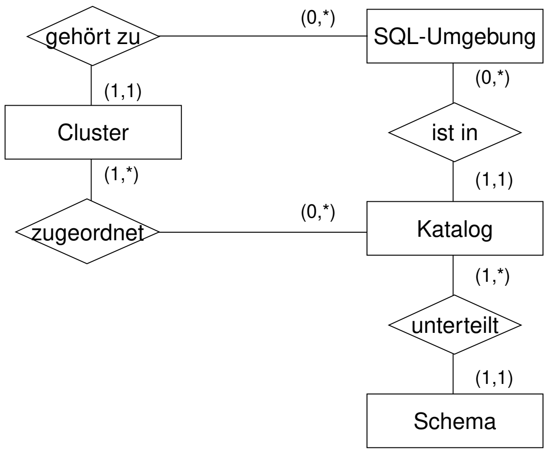

➥ Kataloge bestehen aus SQL-Schemata und können innerhalb einer SQL-Umgebung optional auf ein oder mehrere Cluster[1] verteilt werden

- **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. 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

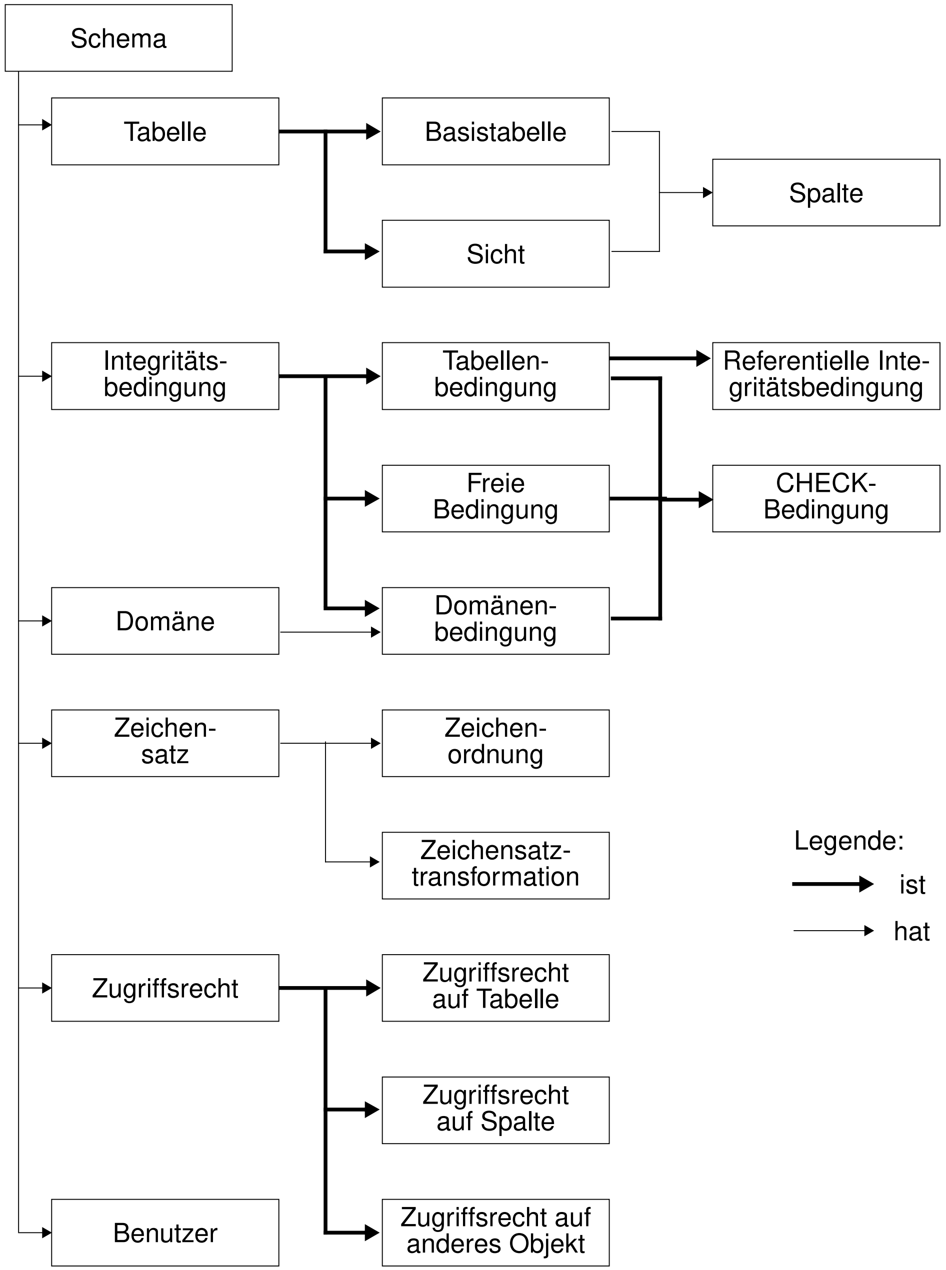

Informations- und Definitionsschema

- **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**

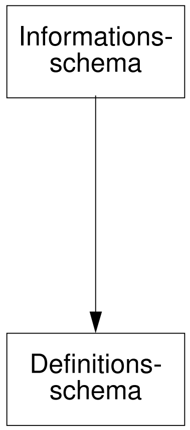

Informationsschema:
- bietet einheitliche Sichten in normkonformen Implementierungen
- ist für den Benutzer zugänglich und somit die definierte Schnittstelle zum Katalog

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

- **Komplexe Strukturen**[1]
  - DEFINITION_SCHEMA umfaßt 24 Basistabellen und 3 Zusicherungen
  - In den Tabellendefinitionen werden ausschließlich 3 Domänen verwendet: SQL_IDENTIFIER, CHARACTER_DATA und CARDINAL_NUMBER

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

Das Definitionsschema

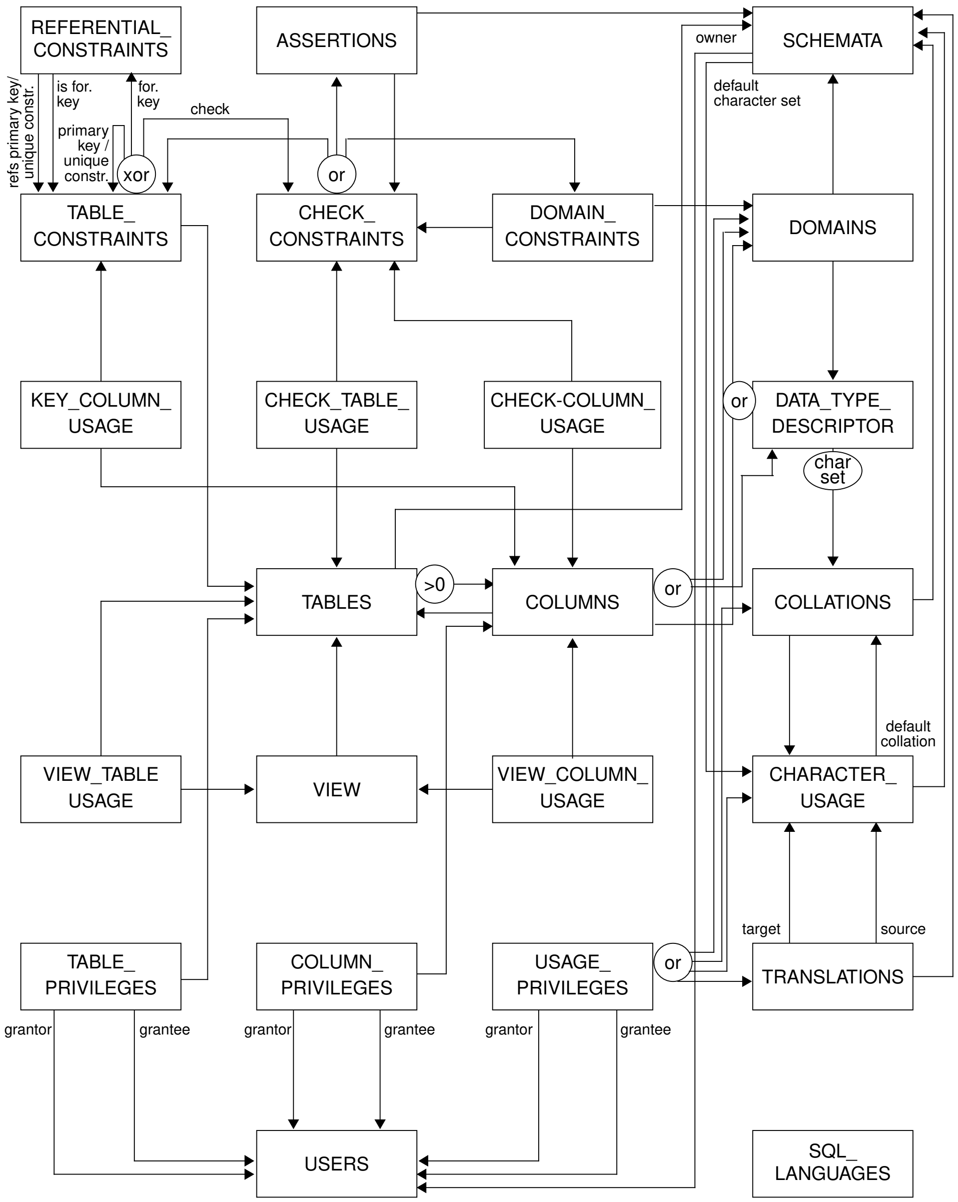

Erzeugung von Basisrelationen

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

D2: Erzeugung der neuen Relationen Pers und Abt

CREATE TABLE Pers

(Pnr	INT	**PRIMARY KEY**,
Beruf	CHAR (30),	
PName	CHAR (30)	**NOT NULL**,
PAlter	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?

Evolution einer Miniwelt

- **Grobe Zusammenhänge**

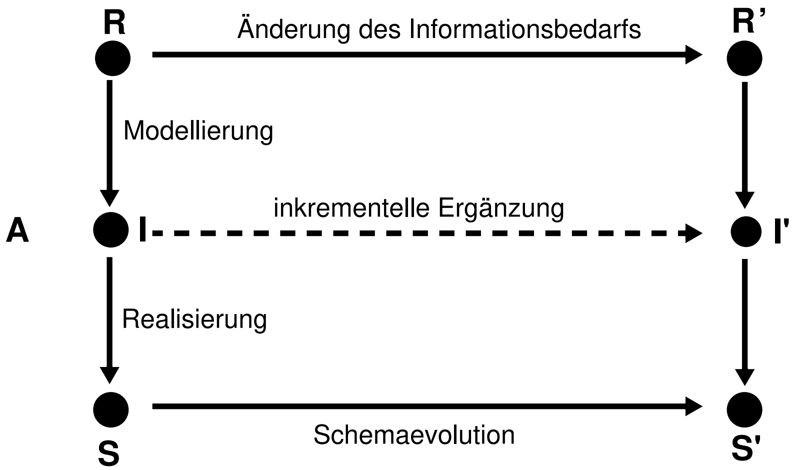

R:	Realitätsausschnitt (Miniwelt)
I:	Informationsmodell (zur Analyse und Dokumentation der Miniwelt)
S:	DB-Schema der Miniwelt (Beschreibung aller Objekt- und Beziehungstypen sowie aller Integritäts- und Zugriffskontrollbedingungen)
A:	Abbildung aller wichtigen Objekte und Beziehungen sowie ihrer Integritäts- 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 eines vorhandenen Index**

    ➥ Entscheidung durch DBS-Optimizer

- 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**

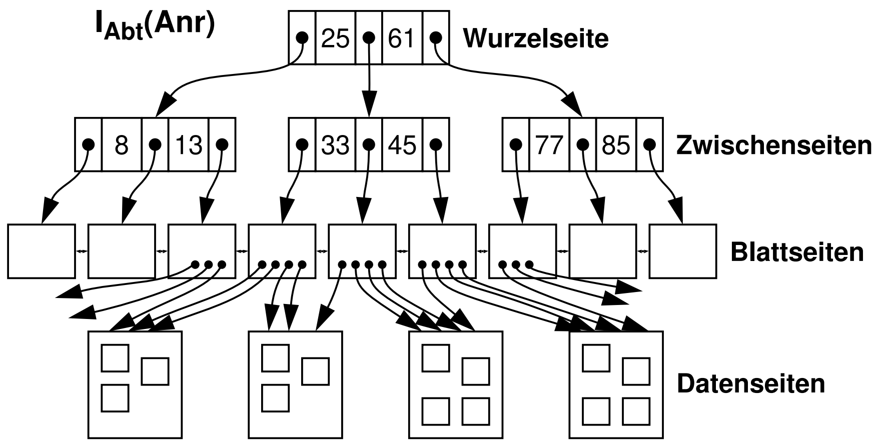

- **Index ohne Clusterbildung**

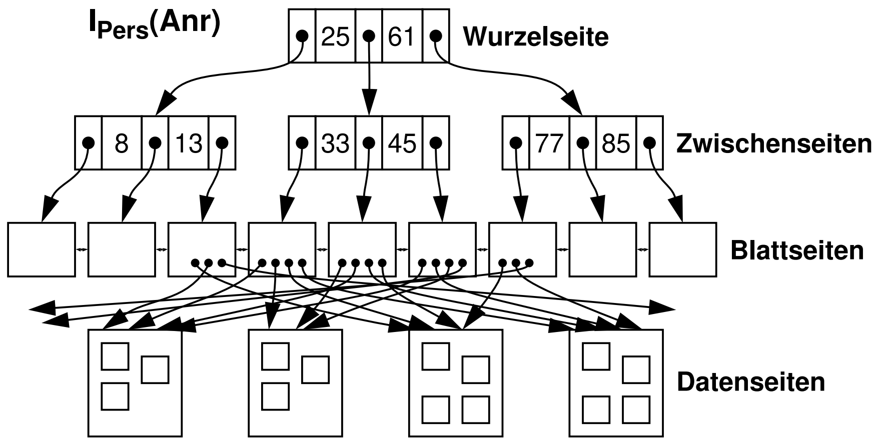

Indexierung (3)

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 im Index
- **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 eines Index: 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**

Seitenformat im B*-Baum

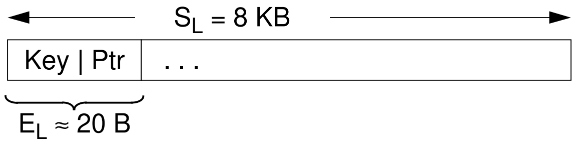

$$ES = \frac{S_L}{E_L} = \text{max. \# Einträge/Seite}$$

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 $E_L = 20$ 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]
```

D5: 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
```

D6: Sicht für den Datenschutz

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


Sichtkonzept (2)

- **Sichten zur Gewährleistung von Datenunabhängigkeit**

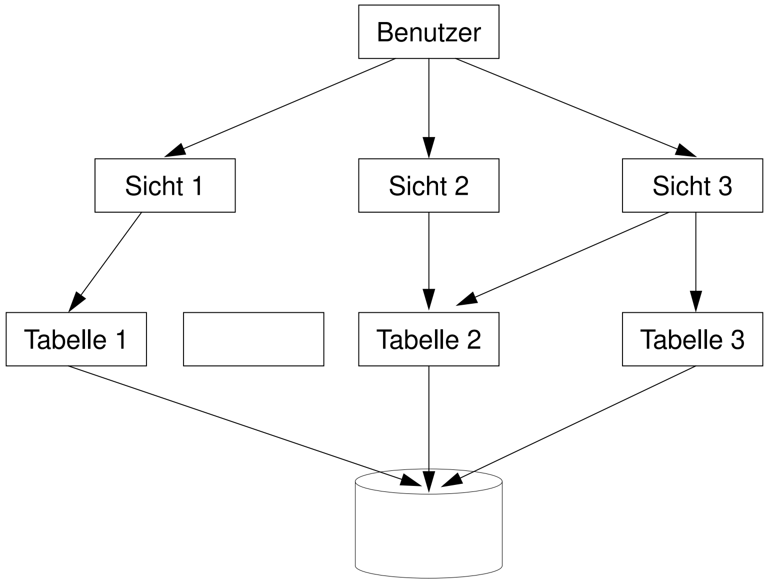

- **Eigenschaften von Sichten**
  - Sicht kann wie eine Tabelle behandelt werden
  - Sichtsemantik: „dynamisches Fenster“ auf zugrundeliegende Tabellen
  - Sichten auf Sichten sind möglich
  - eingeschränkte Änderungen: aktualisierbare und nicht-aktualisierbare Sichten

Sichtkonzept (3)

- **Zum Aspekt: Semantik von Sichten**

Sicht V als dynamisches Fenster

Tabelle R (	A1,	A2,	A3,	A4,	A5)
t1:	a_{11}	a_{12}	a_{13}	a_{14}	a_{15}
t4:	a_{41}	a_{42}	a_{43}	a_{44}	a_{45}

- **Sichtbarkeit von Änderungen - Wann und Was?**
  Wann werden welche geänderten Daten in der **Tabelle**/**Sicht** für die **anderen** Benutzer sichtbar?

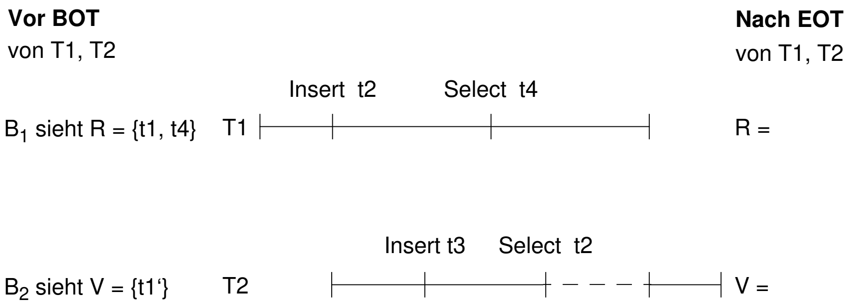

Sichtkonzept (4)

- **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**

Sichtendefinitionen:

```
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

Sichtendefinition:

```
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
```

- **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**

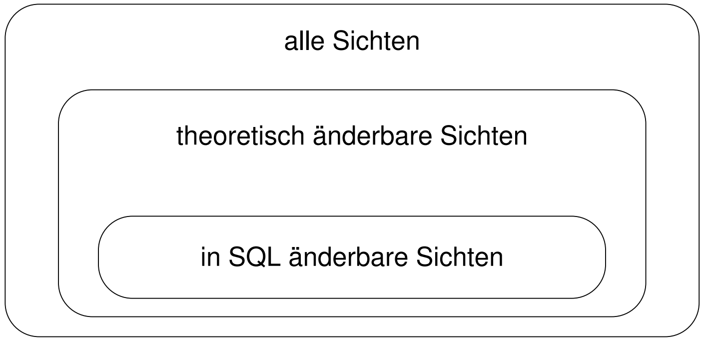

- Sichten über mehr als eine Tabelle sind i. allg. nicht aktualisierbar!

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

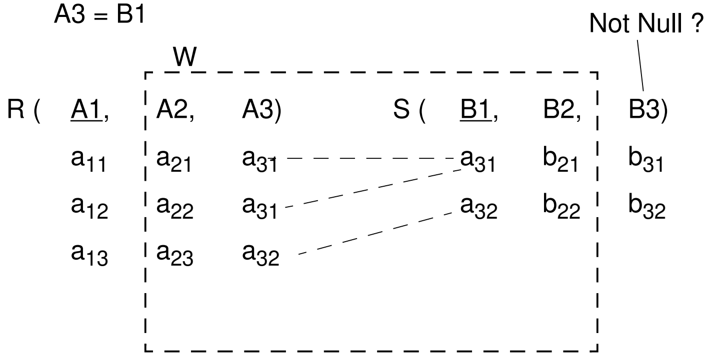

Einfügen ?

Ändern?

- **Änderbarkeit in SQL**
  - nur eine Tabelle (Basisrelation oder Sicht)
  - Schlüssel muß vorhanden sein
  - keine Aggregatfunktionen, Gruppierung und Duplikateliminierung

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**

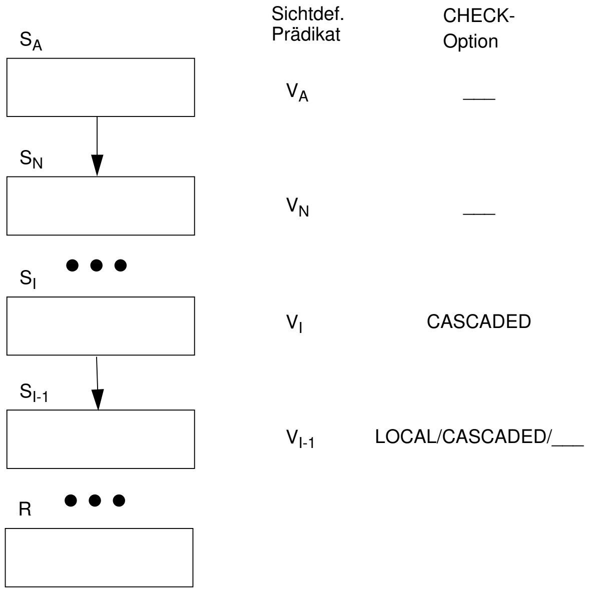

Sichtkonzept (8)

- **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, die 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”:
    $V = V_I \wedge V_{I-1} \wedge . . . \wedge V_1$

    ➥ 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
    $V = V_A \wedge V_N \wedge . . . \wedge V_I \wedge . . . \wedge V_1$
  - 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

Sichtenhierarchie:

S_2 mit $V_1 \wedge V_2$

S_1 mit V_1 und CASCA-DED

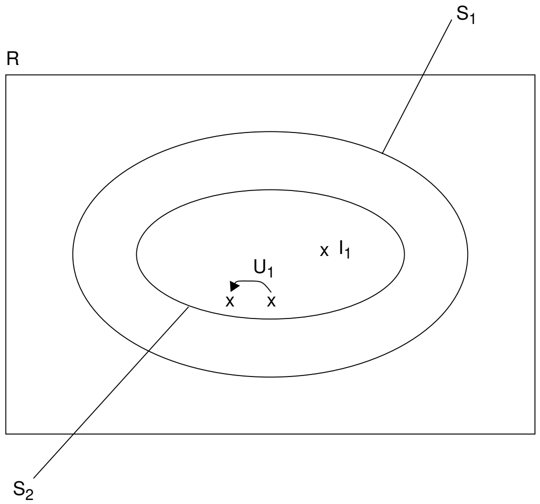

Aktualisierungsoperationen in S_2

I_1 und U_1 erfüllen das S_2-definierende Prädikat $V_1 \wedge V_2$

I_2 und U_2 erfüllen das S_1-definierende Prädikat V_1

I_3 und U_3 erfüllen das S_1-definierende Prädikat V_1 nicht

Welche Operationen sind erlaubt?

Insert in S2: I_1 ✔
I_2
I_3

Update in S2: U_1 ✔
U_2
U_3

Ohne Check-Option werden alle Operationen akzeptiert!

Sichtkonzept (9)

- **Beispiel**

Tabelle	Pers		
Sicht 1 auf Pers	AP1	mit	Beruf = 'Prog.' AND Gehalt < '30K'
Sicht 2 auf AP1	AP2	mit	Gehalt > '20K'

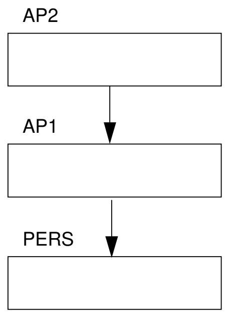

Sichtdef. Prädikat	CHECK-Optionen 1	2	3	4
> '20K'	—	—	CASC	CASC
< '30K'	—	CASC	—	CASC

- **Operationen**

a) INSERT INTO AP2
VALUES (. . . , '15K')

b) UPDATE AP2
SET Gehalt = Gehalt + '5K'
WHERE Anr = 'K55'

c) 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

- **Ziel: Simulation einiger Aspekte der Generalisierung**

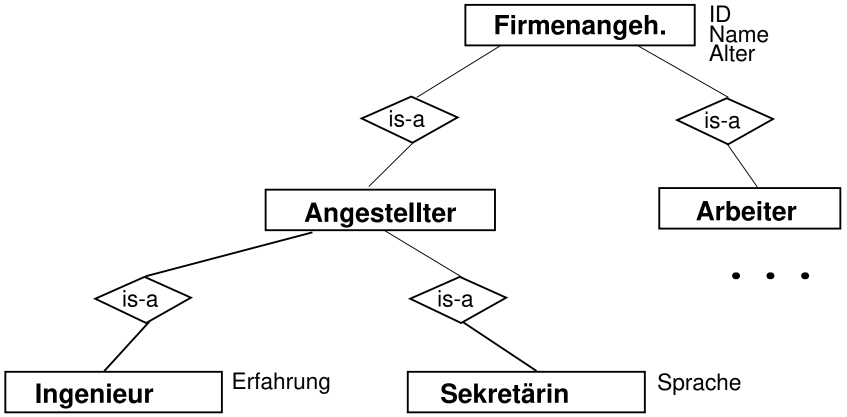

- **Einsatz des Sichtkonzeptes**

```
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;
```

Zusammenfassung

- **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