

## SQL

```

CREATE TABLE t (
  id INT PRIMARY KEY,
  c1 TEXT,
  name VARCHAR NOT NULL,
  price INT DEFAULT 0,
  PRIMARY KEY (id),
  FOREIGN KEY (c1) REFERENCES t2(c2),
  UNIQUE(id,name),
  CHECK(id > 0 AND price >= id)
);

DROP TABLE t; //Delete table
ALTER TABLE t ADD column; //Add new column
ALTER TABLE t DROP COLUMN c; //Drop column
ALTER TABLE t ADD constraint; //Add constraint
ALTER TABLE t1 RENAME TO t2; //Rename table
ALTER TABLE t DROP constraint; //Drop constraint
ALTER TABLE t1 RENAME c1 TO c2; //Rename column

INSERT INTO t(column_list) VALUES(value_list);
...SELECT column_list FROM t2;
UPDATE t SET c1= new_value;
UPDATE t SET c1 = new_value WHERE condition;
DELETE FROM t; //Delete all data
DELETE FROM t WHERE condition; //Delete subset

SELECT c1, c2 FROM t //Query data
SELECT c1, c2 FROM t1, t2 //cross join
SELECT * FROM t //Query all rows
SELECT DISTINCT... //Query distinct rows
...UNION [ALL] //Combine rows from queries
...INTERSECT //Return intersection
...MINUS //Subtract result

...WHERE condition //with condition
...IS [NOT] NULL
...[NOT] LIKE %xy_ //%=beliebig viele; $=ein Zeichen
...[NOT] IN value_list
...BETWEEN low AND high

...GROUP BY c1 //Group rows
...GROUP BY c1 HAVING condition; //Filter
...ORDER BY c1 ASC [DESC] //Sort result
...HAVING bedingung // !TODO
...LIMIT n OFFSET offset //return n rows

...INNER JOIN t2 ON condition
...LEFT JOIN t2 ON condition
...RIGHT JOIN t2 ON condition
...FULL OUTER JOIN t2 ON condition
...CROSS JOIN t2 //Cartesian product

CREATE VIEW v(c1,c2) AS SELECT c1, c2 FROM t;
CREATE RECURSIVE VIEW...
CREATE TEMPORARY VIEW...
...UNION [ALL]
...WITH [CASCADED | LOCAL] CHECK OPTION;
DROP VIEW view_name;

CREATE INDEX idx_name ON t(c1,c2);
CREATE UNIQUE INDEX idx_name ON t(c3,c4);
DROP INDEX idx_name;

CREATE OR MODIFY TRIGGER trigger_name
[BEFORE | AFTER] [INSERT | UPDATE | DELETE]
ON table_name FOR EACH [ROW | STATEMENT]
EXECUTE stored_procedure;
DROP TRIGGER trigger_name;

CREATE ASSERTION name CHECK (praedikat)
GRANT rechte ON tabelle TO nutzer [with grant option]
REVOKE rechte ON tabelle TO nutzer [restrict | cascade ]

//AGGREGATE FUNCTIONS
AVG //returns the average of a list
COUNT //returns the number of elements of a list
SUM //returns the total of a list

```

```

MAX //returns the maximum value in a list
MIN //returns the minimum value in a list

```

## NoSQL (MongoDB)

```

db.createUser({
  user: "dbadmin",
  pwd: "12345678",
  roles: [{ role: "dbOwner", db: "admin" }],
})

db.users.insert({
  userid: "123",
  age: 18,
  name: "vikash",
})

db.users
  .distinct("name") //show distinct value for
  .find(
    { //where clauses
      name: "vikash",
    },
    { //select fields
      name: 1,
      age: 1,
    }
  )
  .limit(2)
  .skip(5)
  .sort({
    age: 1,
  })
  .count() // number of documents in collection

db.users.update({
  name: "vikash",
}, {
  $set: { age: 19 }, //update field
  $inc: { age: 5 }, //increase field
}, {
  multi: true,
})

db.users.remove({})
db.users.remove({
  name: "vikash",
})

db.users.aggregate([
  { $match: {name: "vikash"} },
  { $group: { _id: "$age", num_usr: { $sum: 1 } } }
  { $sort: {age: 1} }
])

db.users.ensureIndex() //Create an index on field
db.users.dropIndex() //Drop an index from field

show dbs //show all database
dbName() //show current database
use usersdb //switch or create to database 'usersdb'

db.dropDatabase() //drop current database
db.getCollectionNames() //show all collections
db.createCollection("users") //create collection 'users'
db.users.drop() //drop collection 'users'

//Aggregate Functions
$name: "contr" // negate clause
$or: [{a},{b}] // a or b
$gt: x // greater than x
$lte: x // less than
$gte: x // greater than even
name: /ind/, // name is like %ind%

```

Datenunabhängigkeit:

- Stabilität der Benutzerschnittstelle gegen Änderungen

- physisch: Änderung der Dateioorganisation und Zugriffspfade haben keinen Einfluss auf das konzeptuelle Schema
- logisch: Änderung am konzeptuellen und gewissen externen Schemata haben keine Auswirkungen auf andere externe Schemata und Anwendungsprogramme

## Codd'sche Regeln

**Integration** einheitliche, nichtredundante Datenverwaltung  
**Operationen** Speichern, Suchen, Ändern  
**Katalog** Zugriffe auf DB-Beschreibungen im Data Dictionary  
**Benutzersichten**  
**Integritätssicherung** Korrektheit des Datenbankinhalts  
**Datenschutz** Ausschluss unauthorisierter Zugriffe  
**Transaktionen** mehrere DB-Operationen als Funktionseinheit  
**Synchronisation** parallele Transaktionen koordinieren  
**Datensicherung** Wiederherstellung von Daten nach Systemfehlern

Schemata:

- Konzeptuelles Schema (Ergebnis der Dateidefinition)
- Internes Schema (Festlegung Dateioorganisation/pfade = Index)
- Externes Schema (Ergebnis der Sichtdefinition)
- Anwendungsprogramm (Ergebnis der Programmierung)
  - Schema: Metadaten, Datenbeschreibung
  - Instanz: Anwenderdaten, Datenbankzustand

## 3 Schichten Architektur Klassifizierung

- Definitionskomponenten: Datendefinition, Dateioorganisation, Sichtdefinition
- Programmierkomponenten: DB-Programmierung mit eingebetteten DB-Operationen
- Benutzerkomponenten: Anwendungsprogramme, Anfrage und Update interaktiv
- Transformationskomponenten: Optimierer, Auswertung, Plattenzugriffsteuerung
- Data Dictionary (Datenwörterbuch): Aufnahme der Daten aus Definitionskomponenten, Versorgung der anderen Komponenten

## 5 Schichten Architektur Verfeinerung

- Datensystem: Übersetzung, Zugriffspfadwahl
- Zugriffssystem: Logische Zugriffspfade, Schemakatalog, Sortierung, Transaktionsverwaltung
- Speichersystem Speicherungsstrukturen, Zugriffspfadverwaltung, Sperrverwaltung, Logging, Recovery
- Pufferverwaltung: Systempufferverwaltung, Seitenersetzung, Seitenzuordnung
- Betriebssystem: Externspeicherverwaltung, Speicherzuordnung

## Relationenalgebra

**Selektion**  $\sigma_{\text{Bedingung}}(\text{Relation})$ : Auswahl von Zeilen (WHERE)**Projektion**  $\pi_{\text{Attributmeng}}(\text{Relation})$ : Auswahl von Spalten; entfernt doppelte Tupel; (SELECT DISTINCT)**Verbund**  $R_1 \bowtie R_2$ : verknüpft Tabellen über gleichbenannte Spalten, verschmilzt jew Tupel gleicher Werte; Tupel ohne Partner eliminiert (JOIN/ NATURAL JOIN)**Umbenennung**  $\beta_{\text{neu} \leftarrow \text{alt}}(R)$ : Ändern von Attributnamen (AS)**Vereinigung**  $r_1 \cup r_2$  von zwei Relationen  $r_1$  und  $r_2$  (UNION)

- Gesamtheit der beiden Tupelmengen
- Attributmengen beider Relationen müssen identisch sein

**Differenz**  $r_1 - r_2$  eliminiert die Tupel aus der ersten Relation, die auch in der zweiten Relation vorkommen (EXCEPT)**Durchschnitt**  $r_1 \cap r_2$ : ergibt die Tupel, die in beiden Relationen gemeinsam vorkommen (INTERSECT)**Quantoren/Mengenvergleiche**  $\Theta = \{all|any|some\}$ **Assertion** Prädikat, das eine Bedingung ausdrückt, die von der Datenbank immer erfüllt sein muss

- Trigger** Anweisung/Prozedur, die bei Eintreten eines bestimmten Ereignisses automatisch vom DBMS ausgeführt wird
- Sicht** virtuelle Relationen (bzw virtuelle Datenbankobjekte in anderen Datenmodellen)

## Datenbankmodelle im Überblick

- HM: hierarchisches Modell,
- NWM: Netzwerkmodell,
- RM: Relationenmodell
- NF 2: Geschachtelte (Non-First-Normal-Form) Relationen
- eNF 2: erweitertes NF 2 -Modell
- ER: Entity-Relationship-Modell, SDM: semantische Datenmodelle
- OODM/C++: objektorientierte Datenmodelle
  - OEM: objektorientierte Entwurfsmodelle (etwa UML),
  - ORDM: objektrelationale Datenmodelle

## ER Modell

**Entity** Objekt/Informationen

**Entity Typ** Gruppierung von Entitäts mit gleichen Eigenschaften

**Relation/Relationship** Menge aller Einträge

- beschreibt eine Beziehung zwischen Entitäten
- Menge von Zeilen einer Tabelle

**Attribut** repräsentiert eine Eigenschaft von Entitäten/Beziehungen

- Spalte/Spaltenüberschrift einer Tabelle

**Tupel** Zeile einer Tabelle

**Werte** primitive Datenelemente; Attributwert

**Schlüssel** identifizierende Eigenschaft von Entitäten

- minimale Menge von Attributen, die Tupel eindeutig identifizieren

**Schlüsselattribute** Teilmenge gesamter Attribute von Entity-Typen

- Auswahl des Primärschlüssels bei mehreren Schlüsselkandidaten
- Schlüssel durch Unterstreichen gekennzeichnet

**Primärschlüssel** ein beim Datenbankentwurf ausgezeichnete Schlüssel

**Fremdschlüssel** Attributmenge, die Schlüssel einer anderen Relation ist

**Beziehungstypen** Beziehungen zwischen Entitäten zu Beziehungstypen

**Kardinalitäten/Funktionalität** Einschränkung von Beziehungstypen bezüglich mehrfachen Teilnahme von Entitäten an Beziehung

**Stelligkeit/Grad** Anzahl der an einem Beziehungstyp beteiligten Entity Typen

Stelligkeit

**0,\*** legt keine Einschränkung fest (default)

**1:1** jedem Entity  $e_1$  ist maximal ein Entity  $e_2$  zugeordnet und umgekehrt

**1:N** jedem Entity  $e_1$  sind beliebig viele Entitäten  $E_2$  zugeordnet, aber zu jedem Entity  $e_2$  gibt es maximal ein  $e_1$

**N:1** invers zu 1:N, auf funktionale Beziehung

**M:N** keine Restriktionen

**Kardinalitätsangaben** partielle funktionale Beziehung:

- $lagerIn(Produkt[0, 1], Fach[0, 3])$
- totale funktionale Beziehung:  
 $liefert(Lieferant[0, *], Produkt[1, 1])$

## Normalformen

- legen Eigenschaften von Relationenschemata fest
- verbieten bestimmte Kombinationen von funkt. Abhängigkeiten
- sollen Redundanzen und Anomalien vermeiden

**Erste Normalform** nur atomare Attribute in den Relationenschemata, d.h. als Attributwerte sind Elemente von Standard-Datentypen wie integer/string erlaubt, aber keine Konstruktoren [array/set]

**Zweite Normalform** Zweite Normalform eliminiert derartige partielle Abhängigkeiten bei Nichtschlüsselattributen

- partielle Abhängigkeit liegt vor, wenn ein Attribut funktional schon von einem Teil des Schlüssels abhängt

**Dritte Normalform** eliminiert auch transitive Abhängigkeiten

- etwa Weingut  $\rightarrow$  Anbaugebiet und Anbaugebiet  $\rightarrow$  Region
- 3 NF betrachtet nur Nicht-Schlüsselattribute als Endpunkt transitiver Abhängigkeiten
- $A \in R$  heißt transitiv abhängig von X bezüglich F genau dann, wenn es ein  $Y \subseteq R$  gibt mit  $X \rightarrow Y, Y \not\rightarrow X, Y \rightarrow A, A \notin XY$

**Boyce-Kodd-Normalform** (Verschärfung der 3NF): Eliminierung transitiver Abhängigkeiten auch zwischen Primattributen

$\exists A \in R: A$  transitiv abhängig von einem  $K \in \mathbf{K}$  bezüglich F

**Minimalität** Global Redundanzen vermeiden

- andere Kriterien (wie Normalformen) mit möglichst wenig Schemata erreichen
- Beispiel: Attributmenge ABC, FD-Menge  $A \rightarrow B, B \rightarrow C$

**Vierte Normalform** erweitertes Relationenschema  $R = (R, \mathbf{K})$  ist in vierter Normalform (4NF) bezüglich M genau dann, wenn für alle  $X \rightarrow Y \in M^+$  gilt:  $X \rightarrow Y$  ist trivial oder  $X \supseteq K$  für ein  $K \in \mathbf{K}$

## Datenbankentwurf Anforderungsanalyse

- informale Beschreibung des Fachproblems
- Trennen der Informationen über Daten (Datenanalyse) von den Informationen über Funktionen (Funktionsanalyse)

## Konzeptioneller Entwurf

- formale Beschreibung des Fachproblems

- Sichtentwurf
- Sichtanalyse
- Sichtintegration

- Ergebnis: konzeptionelles Gesamtschema

- Integrationskonflikte

**Namenskonflikte** Homonyme/Synonyme

**Typkonflikte** verschiedene Strukturen für das gleiche Element

**Wertebereichskonflikte** verschiedene Wertebereiche für Element

**Bedingungskonflikte** verschiedene Schlüssel für ein Element

**Strukturkonflikte** gleicher Sachverhalt durch unterschiedliche Konstrukte

## Verteilungsentwurf

- sollen Daten auf mehreren Rechnern verteilt vorliegen, muss Art und Weise der verteilten Speicherung festgelegt werden
- horizontale Verteilung z.B. Kunden 1-100 und Kunden 101-200
- vertikale Verteilung z.B. Adresse in DB1, Konto in DB2

## Logischer Entwurf

- Datenmodell des ausgewählten DBMS
- Transformation des konzeptionellen Schemas
- Verbesserung des relationalen Schemas anhand von Gütekriterien

## Datendefinition

- Umsetzung des logischen Schemas in ein konkretes Schema
  - Datenbankdeklaration in der DDL des DBMS
  - Realisierung der Integritätsicherung
  - Definition der Benutzersichten

## Physischer Entwurf

- Ergänzen des physischen Entwurfs um Zugriffsunterstützung
  - Zugriffspfad: Datenstruktur für zusätzlichen schlüsselbasierten Zugriff auf Tupel
  - meist als B\*-Baum realisiert
- Sprachmittel: Speicherstruktursprache SSL

## Implementierung & Wartung

- Wartung; weitere Optimierung der physischen Ebene
- Anpassung an neue Anforderungen und Systemplattformen
- Portierung auf neue Datenbankmanagementsysteme...

## Kapazitätsändernde Abbildungen

- Kap.erhöhend:** Abbildung auf R mit genau einem Schlüssel
- Kap.vermindernd:** Relationenschema mit einem Schlüssel
- Kap.erhaltend:** mit Schlüssel beider Entity Typen im Relationenschema als neuer Schlüssel

## ER-auf-RM Abbildung

- neues Relationenschema mit allen Attributen des Beziehungstyps, zusätzlich Übernahme aller Primärschlüssel der Entity-Typen
- Festlegung der Schlüssel:
  - m:n-Beziehung: beide Primärschlüssel zusammen werden Schlüssel
  - 1:n-Beziehung: Primärschlüssel der n-Seite (Seite ohne Pfeilspitze) wird Schlüssel
  - 1:1-Beziehung: beide Primärschlüssel werden je ein Schlüssel, der Primärschlüssel wird dann aus diesen Schlüssel gewählt
- optionale Beziehungen  $[0, 1]$  o.  $[0, n]$  werden nicht verschmolzen
- bei Kardinalitäten  $[1, 1]$  oder  $[1, n]$  Verschmelzung möglich
  - 1 : n: Entity-Relationenschema der n-Seite integrieren
  - 1 : 1: beide Entity-Relationenschemata integrieren

## Transformationseigenschaften

- Abhängigkeitstreue (T1)
  - Menge der Abhängigkeiten äquivalent zu der Menge der Schlüsselbedingungen im resultierenden Datenbankschema
  - S charakterisiert vollständig F genau dann, wenn  $F \equiv \{K \rightarrow R | (R, \mathbf{K}) \in \mathbf{S}, \mathbf{K} \in \mathbf{K}\}$
- Verbundtreue (T2)
  - Originalrelationen können durch den Verbund der Basisrelationen wiedergewonnen werden
  - nicht verbundtreu  $F = \{A \rightarrow B, C \rightarrow B\}$
  - verbundtreu  $F = \{A \rightarrow B, B \rightarrow C\}$
- Mehrwertige Abhängigkeit (MVD)
  - innerhalb einer Relation r wird einem Attributwert von X eine Menge von Y-Werten zugeordnet, unabhängig von den Werten der restlichen Attribute  $\rightarrow$  Vierte Normalform
  - Beseitigung von Redundanzen: keine zwei MVDs zwischen Attributen
  - Elimination der rechten Seite einer der beiden mehrwertigen Abhängigkeiten,
  - linke Seite mit dieser rechten Seite in neue Relation kopiert
- Verbundabhängigkeit (JD): R kann ohne Informationsverlust in  $R_1, \dots, R_p$  aufgetrennt werden:  $\bowtie [R_1, \dots, R_p]$
- Inklusionsabhängigkeit (IND): auf der rechten Seite einer Fremdschlüsselabhängigkeit nicht unbedingt der Primärschlüssel

## Ableitungsregel

- F1: Reflexivität  $X \supseteq Y \Rightarrow X \rightarrow Y$
- F2: Augmentation  $\{X \rightarrow Y\} \Rightarrow XZ \rightarrow YZ$ , sowie  $XZ \rightarrow Y$
- F3: Transitivität  $\{X \rightarrow Y, Y \rightarrow Z\} \Rightarrow X \rightarrow Z$
- F4: Dekomposition  $\{X \rightarrow YZ\} \Rightarrow X \rightarrow Y$
- F5: Vereinigung  $\{X \rightarrow Y, X \rightarrow Z\} \Rightarrow X \rightarrow YZ$
- F6: Pseudotransitivität  $\{X \rightarrow Y, WY \rightarrow Z\} \Rightarrow WX \rightarrow Z$

F1-F3 bekannt als Armstrong-Axiome

- gültig (sound): Regeln leiten keine FDs ab, die logisch nicht impliziert
- vollständig (complete): alle implizierten FDs werden abgeleitet
- unabhängig (independent) oder auch bzgl.  $\subseteq$
- minimal: keine Regel kann weggelassen werden

B-Axiome oder RAP-Regeln

- R Reflexivität  $\{ \} \Rightarrow X \rightarrow X$
- A Akkumulation  $\{ X \rightarrow YZ, Z \rightarrow AW \} \Rightarrow X \rightarrow YZA$
- P Projektivität  $\{ X \rightarrow YZ \} \Rightarrow X \rightarrow Y$

**Membership Problem** Kann eine bestimmte FD  $X \rightarrow Y$  aus der vorgegebenen Menge  $F$  abgeleitet werden, d.h. wird sie von  $F$  impliziert?  $X \rightarrow Y \in F^+$

**Reduktionsoperationen** Entfernen überflüssiger Attribute auf linker bzw. rechter Seite von FDs.

**Unwesentliche Attribute** A heißt unwesentlich in  $X \rightarrow Y$  bzgl. F, wenn

- A kann aus der FD  $X \rightarrow Y$  entfernt werden, ohne dass sich die Hülle von F ändert
- FD  $X \rightarrow Y$  heißt linksreduziert, wenn kein Attribut in X unwesentlich ist
- FD  $X \rightarrow Y$  heißt rechtsreduziert, wenn kein Attribut in Y unwesentlich ist

**Minimale Überdeckung** Eine minimale Überdeckung ist eine Überdeckung, die eine minimale Anzahl von FDs enthält

**Äquivalenzklassen** FDs mit äquivalenten linken Seiten werden zu einer Äquivalenzklasse zusammengefasst

**Entwurfsverfahren**

- T1: S charakterisiert vollständig F
- S1: S ist in 3NF bezüglich F
- T2: Dekomposition von U in  $R_1, \dots, R_p$  ist verbundtreu bezüglich F
- S2: Minimalität, d.h.  $\exists S'' : S''$  erfüllt T1,S1,T2 und  $|S| < |S''|$

**Algebra & Kalkül**

**Anfrage** Folge von Operationen, die aus Basisrelationen eine Ergebnisrelation berechnet

**Sicht** Folge von Operationen, die unter Sichtnamen langfristig abgespeichert wird und unter diesem Namen wieder aufgerufen werden kann; ergibt eine Sichtrelation

**Snapshot** Ergebnisrelation einer Anfrage, die unter Snapshot-Namen abgelegt wird, aber nie ein zweites Mal berechnet wird

**Kriterien für Anfragesprachen**

- Ad-Hoc-Formulierung** Benutzer soll eine Anfrage formulieren können, ohne ein vollständiges Programm schreiben zu müssen
- Deskriptivität** Benutzer soll formulieren „Was will ich haben?“
- Mengenorientiertheit** jede Operation soll auf Mengen von Daten gleichzeitig arbeiten
- Abgeschlossenheit** Ergebnis ist wieder Relation und kann als Eingabe für nächste Anfrage verwendet werden
- Adäquatheit** alle Konstrukte des zugrundeliegenden Datenmodells werden unterstützt
- Orthogonalität** Sprachkonstrukte sind in ähnlichen Situationen auch ähnlich anwendbar
- Optimierbarkeit** Sprache besteht aus wenigen Operationen, für die es Optimierungsregeln gibt
- Effizienz** jede Operation ist effizient ausführbar (Komplexität  $\max \leq O(n^2)$ )
- Sicherheit** keine Anfrage, die syntaktisch korrekt ist, darf in eine Endlosschleife geraten oder ein unendliches Ergebnis liefern

**Eingeschränktheit** Anfragesprache darf keine komplette Programmiersprache sein

**Vollständigkeit** Sprache muss mindestens die Anfragen einer Standardsprache ausdrücken können

**Minimale Relationenalgebra**  $\Omega = \pi, \sigma, \bowtie, \beta, \cup, -$  **unabhängig** kein Operator kann weggelassen werden

**Relationale Vollständigkeit** jede andere Menge von Operationen genauso mächtig wie  $\Omega$

**strenge relationale Vollständigkeit** zu jedem Ausdruck mit Operatoren aus  $\Omega$  gibt es einen Ausdruck auch mit der anderen Menge von Operationen

**Verbundvarianten**

- Gleichverbund: Gleichheitsbedingung über explizit angegebene und evtl. verschiedene Attribute  $r(R) \bowtie_{C=D} r(S)$
- Theta-Verbund ( $\Theta$ -join): beliebige Verbundbedingung  $r(R) \bowtie_{C>D} r(S)$
- Semi-Verbund: nur Attribute eines Operanden erscheinen im Ergebnis  $r(L) \bowtie r(R) = \pi_L(r(L) \bowtie r(R))$
- äußere Verbunde (engl. outer join)
  - voller ä.V. übernimmt alle Tupel beider Operanden
  - linker ä.V. übernimmt alle Tupel des linken Operanden
  - rechter ä.V. übernimmt alle Tupel des rechten Operanden

**Anfragekalküle**

**Kalkül** eine formale logische Sprache zur Formulierung von Aussagen  
**Ziel** Kalkül zur Formulierung von Datenbank-Anfragen

**allgemeines Kalkül**

- Anfrage hat die Form  $\{ f(\bar{x}) | p(\bar{x}) \}$ 
  - x bezeichnet Menge von freien Variablen
  - Funktion f bezeichnet Ergebnisfunktion über  $\bar{x}$
  - p Selektionsprädikat über freien Variablen  $\bar{x}$

- Bestimme aller Belegungen der freien Variablen in x, für die das Prädikat p wahr wird.
- **Relationale Kalküle**
  - Bereichskalkül: Variablen nehmen Werte elementarer Datentypen (Bereiche) an
  - Bereichskalkül ist streng relational vollständig, d.h. zu jedem Term  $\tau$  der Relationenalgebra gibt es einen äquivalenten (sicheren) Ausdruck  $\eta$  des Bereichskalküls.
  - Atomare Formeln:  $\{ x_1, \dots, x_n | \phi(x_1, \dots, x_n) \}$

**Basiskalkül**

- Einschränkung des Bereichskalküls: nur Konstanten, keine Funktionen
- Tupelkalkül: Variablen variieren über Tupelwerte

**Semantisch sichere Anfragen** Anfragen, die für jeden Datenbankzustand  $\sigma(R)$  ein endliches Ergebnis liefern

**Syntaktisch sichere Anfragen** Anfragen, die syntaktischen Einschränkungen unterliegen, um die semantische Sicherheit zu erzwingen

**Transaktion, Integrität & Trigger**

**Typintegrität** Angabe von Wertebereichen zu Attributen; Erlauben/Verbieten von Nullwerten

**Schlüsselintegrität** Angabe eines Schlüssels für eine Relation

**Referentielle Integrität** die Angabe von Fremdschlüsseln

**Semantische Integrität** Korrekter (konsistenter) DB-Zustand nach Ende der Transaktion

**Ablaufintegrität** Fehler durch "gleichzeitigen Zugriff mehrerer Benutzer auf dieselben Daten vermeiden"

**Transaktionen fordern ACID Eigenschaften**

- Atomicity** Transaktion wird entweder ganz oder gar nicht ausgeführt
- Consistency** Datenbank ist vor Beginn und nach Beendigung einer Transaktion jeweils in einem konsistenten Zustand
- Isolation** Nutzer, der mit einer Datenbank arbeitet, sollte den Eindruck haben, dass er mit dieser Datenbank alleine arbeitet
- Durability** nach erfolgreichem Abschluss einer Transaktion muss das Ergebnis dieser Transaktion „dauerhaft“ in der Datenbank gespeichert werden

Kommandos einer Transaktionsprache

- Beginn einer Transaktion: Begin-of-Transaction-Kommando BOT
- commit: die Transaktion soll erfolgreich beendet werden
- abort: die Transaktion soll abgebrochen werden

Probleme im Mehrbenutzerbetrieb

**Nonrepeatable Read** gleiche Leseanweisung führt zu nicht wiederholbaren Ergebnissen

**Dirty read** rechnen mit Wert einer anderen Transaktion die abgebrochen wird

**Phantom-Problem** liest Wert anderer Transaktion ohne zu erkennen, dass andere Transaktion noch nicht abgeschlossen

**Lost Update** updates gehen verloren, wenn gleiche Variablen gleichzeitig beschrieben werden (oder kurz nacheinander)

**Deadlock** ein oder mehrere Transaktionen warten, einen LOCK auf Datenbankobjekte abzusetzen und behindern sich gegenseitig

**Startvation** Warteschlange für gesperrte Objekte unfair abgearbeitet. Transaktion wartet endlos

Isolationsebenen

- read uncommitted**
  - schwächste Stufe: Zugriff auf nicht geschriebene Daten, nur für read only Transaktionen
  - statistische und ähnliche Transaktionen (ungefährer Überblick, nicht korrekte Werte)
  - keine Sperren  $\rightarrow$  effizient ausführbar, keine anderen Transaktionen werden behindert

**read committed** nur Lesen endgültig geschriebener Werte, aber nonrepeatable read möglich

**repeatable read** kein nonrepeatable read, aber Phantomproblem kann auftreten

**serializable** garantierte Serialisierbarkeit

**Integritätsbedingungen in SQL**

**not null** Nullwerte verboten

**default** Angabe von Default-Werten

**check** (search-condition) festlegung lokaler Integritätsbedingungen innerhalb der zu definierenden Wertebereiche, Attribute und Relationenschemata

**primary key** Angabe eines Primärschlüssel

**foreign key** Angabe der referentiellen Integrität

**create domain** Festlegung eines benutzerdefinierten Wertebereichs

**Erhaltung der referentiellen Integrität**

**on update | delete** Angabe eines Auslöseereignisses, das die Überprüfung der Bedingung anstößt

**cascade | set null | set default | no action** Behandlung einiger Integritätsverletzungen pflanzt sich über mehrere Stufen fort

**deferred | immediate** legt Überprüfungszeitpunkt für eine Bedingung fest

**deferred** Zurückstellen an das Ende der Transaktion

**immediate** sofortige Prüfung bei jeder relevanten Datenbankänderung

**Sichten und Zugriffskontrolle**

- Sichten sind externe DB-Schemata folgend der 3-Ebenen-Schemaarchitektur
  - Sichtdefinition
  - Relationenschema (implizit oder explizit)
  - Berechnungsvorschrift für virtuelle Relation, etwa SQL-Anfrage
- Vorteile
  - Vereinfachung von Anfragen für den Benutzer der Datenbank, etwa indem oft benötigte Teilanfragen als Sicht realisiert werden
  - Möglichkeit der Strukturierung der Datenbankbeschreibung, zugeschnitten auf Benutzerklassen
  - logische Datenunabhängigkeit ermöglicht Stabilität der Schnittstelle für Anwendungen gegenüber Änderungen der Datenbankstruktur
  - Beschränkung von Zugriffen auf eine Datenbank im Zusammenhang mit der Zugriffskontrolle

## Änderungen auf Sichten

Kriterien

- Effektkonformität** Benutzer sieht Effekt als wäre die Änderung auf der Sichtrelation direkt ausgeführt worden
- Minimalität** Basisdatenbank sollte nur minimal geändert werden, um den erwähnten Effekt zu erhalten
- Konsistenzhaltung** Änderung einer Sicht darf zu keinen Integritätsverletzungen der Basisdatenbank führen
- Datenschutz** Wird die Sicht aus Datenschutzgründen eingeführt, darf der bewusst ausgeblendete Teil der Basisdatenbank von Änderungen der Sicht nicht betroffen werden

Klassifikation der Problembereiche

- Verletzung der Schemadefinition
- Datenschutz: Seiteneffekte auf nicht-sichtbaren Teil der Datenbank vermeiden
- nicht immer eindeutige Transformation: Auswahlproblem
- Aggregierungssichten: keine sinnvolle Transformation möglich
- elementare Sichtänderung soll genau einer atomaren Änderung auf Basisrelation entsprechen: 1:1-Beziehung zwischen Sichttupeln und Tupeln der Basisrelation

Einschränkungen für Sichtänderungen

- änderbar nur Selektions- und Projektionssichten
- 1:1-Zuordnung von Sichttupeln zu Basistupeln: kein distinct in Projektionssichten
- Arithmetik und Aggregatfunktionen im select-Teil sind verboten
- genau eine Referenz auf einen Relationsnamen im from-Teil erlaubt
- keine Unteranfragen mit „Selbstbezug“ im where-Teil erlaubt
- group by und having verboten

Statistische Datenbanken

- Einzeleinträge unterliegen Datenschutz, aber statistische Informationen allen Benutzern zugänglich
  - keine Anfragen, die weniger als n Tupel selektieren
  - statistische Anfragen nicht erlauben, die paarweise einen Durchschnitt von mehr als m vorgegebenen Tupeln betreffen
  - Data Swapping: Vertauschen von Attributwerten einzelner Tupel
  - Generalisierung: Attributwerte durch allgemeinere Werte ersetzen, die einer Generalisierungshierarchie entnommen sind (Alter 30-40, Weglassen von Stellen PLZ)
  - Löschen von Tupeln, welche die k-Anonymität verletzen und damit identifizierbar sind
- k-Anonymität: ein bestimmter Sachverhalt kann nicht zwischen einer vorgegebenen Anzahl k von Tupeln unterschieden werden

## Datenmodelle für NoSQL

**KV-Stores** binäre Relationen, bestehend aus einem Zugriffsschlüssel (dem Key) und den Nutzdaten (dem Value)

- binäre Daten ohne Einschränkung,
- Dateien oder Dokumente, → Document Databases
- oder schwachstrukturierte Tupel → Wide Column Store

**Wide Column** KV-Store mit schwachstrukturiertem Tupel als Value = Liste von Attributname-Attributwert-Paaren

- schwache Typisierung für Attributwerte (auch Wiederholgruppen)

- nicht alle Einträge haben die selben Attributnamen
- Hinzufügen eines neuen Attributs unproblematisch
- Nullwerte aus SQL ersetzt durch fehlende Einträge

**Document Stores** KV-Store mit (hierarchisch) strukturiertem Dokument als Value

- JSON-Format: geschachtelte Wide Column-Daten
- XML (eher unüblich auf KV-Stores)

**Graph Stores** spezielle Form der Datenrepräsentation = Graphen, insb. Beziehungen zwischen Objekten

**Tiefensuche (DFS)** zunächst rekursiv alle Kindknoten besuchen bevor alle Geschwisterknoten besucht werden (Bestimmung der Zusammenhangskomponente)

**Breitensuche (BFS)** zunächst alle Geschwisterknoten besuchen bevor die Kindknoten besucht werden (Bestimmung des kürzesten Weges)

**Subjekt-Prädikat-Objekt-Modell: RDF** • Sprache zur Repräsentation von Informationen über (Web-)Ressourcen

- zentraler Bestandteil von Semantic Web, Linked (Open) Data
- Repräsentation von Daten, aber auch Wissensrepräsentation (z.B. Ontologie)

**Property-Graph-Modell** Knoten und (gerichtete) Kanten mit Eigenschaften (Properties)

- Elemente: Nodes, Relationships, Properties, Labels
- Properties = Key-Value-Paare: Key (=String), Value (=Java-Datentypen + Felder)
- Nodes mit Labels (≈ Klassenname)
- Relationships: sind gerichtet, mit Namen und ggf. Properties
- Anfragen ( $e : ERZEUGER - [ : LiegtIn ] - > (a : ANBAUGEBIET \{ gebiet : "NapaValley" \})$ )
- match: Beispielmuster für Matching
- return: Festlegung der Rückgabedaten (Projektion)
- where: Filterbedingung für „gematchte“ Daten
- create: Erzeugen von Knoten oder Beziehungen
- set: Ändern von Property-Werten

Ontologie = formale Spezifikation einer Konzeptualisierung, d.h. einer Repräsentation von Begriffen (Konzepten) und deren Beziehungen

Vokabular: vordefinierte Klassen und Eigenschaften

## Anwendungsprogrammierung

### Programmiersprachenanbindung

- prozedurale oder CALL-Schnittstellen (call level interface)
- Einbettung einer DB-Sprache in Programmiersprachen
- Spracherweiterungen und neue Sprachentwicklungen

Datenbankzugriffsschnittstelle

Java JDBC

Embedded SQL für Java SQLJ

LINQ Language Integrated Query; Einbettung einer DB-Sprache in eine Programmiersprache (C#)

Hibernate Java-Framework für objekt-relationales Mapping

- DriverManager: Einstiegspunkt, Laden von Treibern
- Connection: Datenbankverbindung
- Statement: Ausführung von Anweisungen über eine Verbindung
- ResultSet: verwaltet Ergebnisse einer Anfrage, Zugriff auf einzelne Spalten

## Transaktionssteuerung

- Methoden von Connection
  - commit ()
  - rollback ()
- Auto-Commit-Modus
  - implizites Commit nach jeder Anweisung
  - Transaktion besteht nur aus einer Anweisung
  - Umschalten mittels setAutoCommit (boolean)

## Ausnahmebehandlung

- Auslösen einer Ausnahme (Condition) signal ConditionName;”
- Deklarieren von Ausnahmen

```
$declare fehlendes_weingut condition;
declare ungueltige_region
condition for sqlstate value "40123";

create function geschmack (rz int)
returns varchar(20)
begin
    return case
        when rz <= 9 then "Trocken"
        when rz > 9 and rz <= 18 then "Halbtrocken"
        when rz > 18 and rz <= 45 then "Lieblich"
        else "Suess"
    end
end
//Aufruf innerhalb einer Anfrage
select Name, Weingut, geschmack(Restzucker) from WEINE
where Farbe = "Rot" and geschmack(Restzucker) = "Trocken"
```

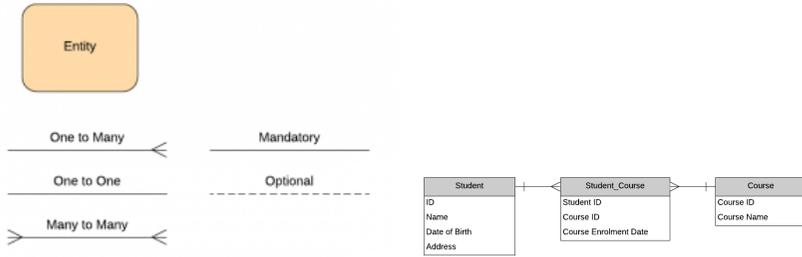
## Prozeduren Prozedurdefinition

```
create procedure weinliste (in erz varchar(30),
out wliste varchar(500))
begin
    declare pos integer default 0;
    for w as WeinCurs cursor for
        select Name from WEINE where Weingut = erz
    do xy
        end for;
    end;
// Nutzung ueber call-Anweisung
declare wliste varchar(500);
call weinliste ("Helena", wliste);
```

Eigenschaften von Prozeduren, die Anfrageausführung und -optimierung beeinflussen

- deterministic** Routine liefert für gleiche Parameter gleiche Ergebnisse
- no sql** Routine enthält keine SQL-Anweisungen
- contains sql** Routine enthält SQL-Anweisungen (Standard für SQL-Routinen)
- reads sql data** Routine führt SQL-Anfragen (select-Anweisungen) aus
- modifies sql data** Routine, die DML-Anweisungen (insert, update, delete) enthält

## Entity-Relationship-Diagramm



## relationale Algebra

$\sigma_{\{Datum=14.12.2017\}}(PRUEFUNG) \bowtie (\pi_{\{Matrikel, Name\}}(STUDENT))$

## Bereichskalkül

Bereichskalkül:  $KUNDE(x, y, z)$  vs. Tupelkalkül:  $KUNDE(k)$

Ein Ausdruck hat die Form:  $\{x_1, x_2, \dots | \phi(x_1, x_2, \dots)\}$

Beispiel: Kunden mit Bestellung

$KUNDE(kdnr, kname, adresse, ort)$  und  $AUFTRAG(auftragsnr, kdnr, warennr, menge)$

Kunden mit Bestellung:  $\{x, y, z | KUNDE(x, y, z, \_) \wedge AUFTRAG(\_, x, \_, \_)\}$

## SQL Anfrage

```
SELECT Matrikel, Name FROM Student WHERE Matrikel > 2010;
```

## Integrität

**Nutzerdefinierte Domäne** eines Attributs, d.h. bestimmte Werte

**Primärschlüssel PRIMARY KEY** nicht null, existiert und ist unique

**Fremdschlüssel FOREIGN KEY** wie primary key aus anderer tabelle

**CHECK-Bedingungen** werte vor insert prüfen

**ASSERTIONS**

**Trigger**

## CLOSURE-Algorithmus / RAP-Regeln

R	Reflexivität	$\{\} \Rightarrow X \rightarrow X$
A	Akkumulation	$\{X \rightarrow YZ, Z \rightarrow AW\} \Rightarrow X \rightarrow YZA$
P	Projektivität	$\{X \rightarrow YZ\} \Rightarrow X \rightarrow Y$

## Normalformen

**1.NF** Wertebereiche der Merkmale sind atomar (es gibt keine zusammengesetzten Werte).

**2.NF** 1. NF + Nichtschlüsselmerkmale sind von allen Schlüsselmerkmalen voll funktional abhängig.

**3.NF** 2. NF + kein Nichtschlüsselmerkmal ist von irgendeinem Schlüssel transitiv abhängig.

**Boyce Codd 3.NF** + entgernen funktionaler Abhängigkeiten

**4.NF** BC + Abhängigkeiten von mehrwertigen Attributmengen trivial und Attributmenge der Schlüsselkandidat

## Konsultation

Mehrere theoretische Fragen? Nicht multiple choice wie in Moodle sondern zB Definitionen erklären (was ist Transaktion/Sicht?)

ERD-Relationenschema bei 1:N Beziehung kommt Schlüssel von N Seite bei M:N Beziehung kommen Schlüssel von beiden Seiten bei 1:1 Beziehung kann Schlüssel von entweder einer oder der anderen Seite gewählt werden