Hasso Plattner Institut

IT Systems Engineering | Universität Potsdam

Datenbanksysteme I

SQL

Felix Naumann

SQL – Historie

- SEQUEL (1974, IBM Research Labs San Jose)
- SEQUEL2 (1976, IBM Research Labs San Jose)
  - System R
- SQL (1982, IBM)
- ANSI-SQL (SQL-86; 1986)
  - Erste genormte Version
- ISO-SQL (SQL-89); 1989;
  - drei Sprachebenen: Level 1, Level 2, + IEF
- (ANSI / ISO) SQL2 (als SQL-92 verabschiedet)
- (ANSI / ISO) SQL3 (als SQL-99 verabschiedet)
  - Objektrelationale Erweiterungen
- (ANSI / ISO) SQL:2003
- Trotz Standardisierung: teilweise Inkompatibilitäten zwischen Systemen der einzelnen Hersteller

SQL:2003

- Part 1: SQL/Framework (92 Seiten)
  - Überblick
- Part 2: SQL/Foundation (1310 Seiten)
  - Datenmodell, DDL, DML, Abfragen
- Part 3: SQL/CLI (Call-Level Interface; 414 Seiten)
  - Zugriff auf DBMS mittels Funktionsaufrufen
- Part 4: SQL/PSM (Persistent Stored Modules); 182 Seiten)
  - Prozedurale Erweiterungen
- Part 9: SQL/MED (Management of External Data; 504 Seiten)
  - Neue Datentypen und Funktionen
- Part 10: SQL/OLB (Object Language Bindings; 382 Seiten)
  - Java
- Part 11: SQL/Schemata (Information and Definition Schemata; 284 Seiten)
- Part 13: SQL/JRT (Java Routines und Types; 212 Seiten)
  - Externe Java Routinen
- Part 14: SQL/XML (XML-related Specifications; 154 Seiten)
  - XML Datentyp und Erweiterung von SQL um XQuery

Zusammen:
3534 Seiten

Motivation

- Verbreitetste Datenbankanfragesprache
- Ad-hoc und einfach
- Deklarativ
  - Nicht prozedural
  - Optimierbar
- Very-High-Level language
- Anfragen an relationale Algebra angelehnt
  - Hinzu kommt DML

- Achtung: Syntax kann sich von System zu System leicht unterscheiden.
- Achtung: Funktionalität kann sich von System zu System leicht unterscheiden.

Überblick

- Einfache Anfragen
- Anfragen über mehrere Relationen
- Geschachtelte Anfragen
- Operationen auf einer Relation
- Datenbearbeitung (DML)
- Schemata (DDL)
- Sichten

Beispielschema

- Filme(Titel, Jahr, Länge, inFarbe, StudioName, ProduzentID)
- spielt_in(FilmTitel, FilmJahr, Name)
- Schauspieler(Name, Adresse, Geschlecht, Geburtstag)
- Manager(Name, Adresse, ManagerID, Gehalt)
- Studios(Name, Adresse, VorsitzenderID)

Der Grundbaustein

SELECT …
FROM …
WHERE …

- SELECT *
  FROM Filme
  WHERE StudioName = ‚Disney‘ AND Jahr= 1990;

Lesereihenfolge (und Schreibreihenfolge):

- FROM: Relation(en) aus denen die Daten stammen
- WHERE: Bedingung(en) an die Daten
- SELECT: Schema der Ergebnisrelation
  - *: Alle Attribute der Inputrelationen

Ausführung

- Für jedes Tupel aus „Filme“ prüfe die Bedingungen und gebe gültige Tupel aus.

Projektion in SQL (SELECT)

Spezifikation in der SELECT Klausel

- SELECT *
  - Alle Attribute
- SELECT Titel, Jahr, inFarbe
  - Projektion auf die drei Attribute

Erweiterte Projektion

- Umbenennung:
  - SELECT Titel AS Name, Jahr AS Zeit
- Arithmetischer Ausdruck:
  - SELECT Titel, Länge * 0.016667 AS Stunden
- Konstanten:
  - SELECT Titel, Länge * 0.016667 AS Stunden, ‚std.‘ AS inStunden

Selektion in SQL

Spezifikation in der WHERE Klausel

- Bedingungen wie in einer Programmiersprache
- Sechs Vergleichsoperatoren
  - =, <>, <, >, <=, >=
- Operanden
  - Konstanten und Attributnamen
  - Auch Attribute, die nicht in der SELECT Klausel genannt werden.
- Arithmetische Ausdrücke für numerische Attribute
  - Z.B.: (Jahr -1930) * (Jahr-1930) < 100
- Konkatenation für Strings
  - ‚Star' || ‚Wars' entspricht ‚StarWars'

Selektion in SQL

Ergebnis ist Boole'scher Wert

- TRUE oder FALSE
- Können mit AND, OR und NOT verknüpft werden.
  - Klammerungen sind erlaubt.

Beispiele

- SELECT Titel
  FROM Filme
  WHERE Jahr > 1970 AND NOT inFarbe;
- SELECT Titel
  FROM Filme
  WHERE (Jahr > 1970 OR Länge < 90) AND StudioName = ‚MGM';

Stringvergleiche

- Datentypen
  - Array fester Länge, Buchstabenliste variabler Länge, Konstanten
- foo _ _ _ _ _ = foo = ‚foo‘
- Vergleiche mit <, >, <=, >=
  - Lexikographischer Vergleich
  - ‚fodder‘ < ‚foo‘; ‚bar‘ < ‚bargain‘
- Patternmatching
  - string LIKE pattern bzw. string NOT LIKE pattern
  - Pattern hat spezielle Zeichen
    - ‚%‘: Beliebige Sequenz von 0 oder mehr Zeichen
    - ‚_‘: Ein beliebiges Zeichen
  - SELECT Titel FROM Filme
    WHERE Titel LIKE ‚Star _ _ _ _‘;
    - Star Wars und Star Trek
  - SELECT Titel FROM Filme WHERE Titel LIKE ‚%‘‘s%‘;

Datum und Uhrzeit

Spezielle Datentypen und Repräsentationen

- Datumskonstante:
  - DATE ‚YYYY-MM-DD‘
  - DATE ‚1948-05-14‘
- Zeitkonstante
  - TIME ‚HH:MM:SS.S‘
  - TIME ‚15:00:02.5‘
- Zeitstempel
  - TIMESTAMP , 1948-05-14 15:00:02.5‘
- Zeitvergleiche
  - TIME ‚15:00:02.5‘ < TIME ‚15:02:02.5‘ ergibt TRUE
  - DATE ‚1948-05-14‘ >= DATE ‚1949-11-12‘ ergibt FALSE

Nullwerte

- Darstellung: NULL bzw. ⊥
- Mögliche Interpretationen
  - Unbekannter Wert
    - Geburtstag eines Schauspielers
  - Wert unzulässig
    - Ehegatte eines unverheirateten Schauspielers
  - Wert unterdrückt
    - Geheime Telefonnummer
- Regeln für Umgang mit Nullwerten
  - Arithmetische Operationen mit NULL ergeben NULL
  - Vergleich mit NULL ergibt Wahrheitswert UNKNOWN
  - NULL ist keine Konstante, sondern erscheint nur als Attributwert
- Beispiel (sei der Wert von x NULL):
  - x+3 ergibt NULL.
  - NULL+3 ist kein zulässiger Ausdruck.
  - x = 3 ergibt UNKNOWN.
- Abfrage von Nullwerten
  - Geburtstag IS NULL

Wahrheitswerte

and	true	unknown	false
true	true	unknown	false
unknown	unknown	unknown	false
false	false	false	false

or	true	unknown	false
true	true	true	true
unknown	true	unknown	unknown
false	true	unknown	false

not	
true	false
unknown	unknown
false	true

Eselsbrücke

- TRUE = 1, FALSE = 0, UNKNOWN = ½
- AND: Minimum der beiden Werte
- OR: Maximum der beiden Werte
- NOT: 1 – Wert
- Beispiel
  - TRUE AND (FALSE OR NOT(UNKNOWN))
    = MIN(1, MAX(0, (1 - ½)))
    = MIN(1, MAX(0, ½)
    = MIN(1, ½) = ½.

Wahrheitswerte

Titel	Jahr	Länge	inFarbe	Studio	ProduzentID
Total Recall	1990	NULL	True	Fox	12345

- Überraschendes Verhalten
  - SELECT *
    FROM Filme
    WHERE Länge <= 90 OR Länge > 90;

    UNKNOWN UNKNOWN

    UNKNOWN
  - Tupel erscheint nicht im Ergebnis.

Sortierung

ORDER BY Klausel ans Ende der Anfrage

- ORDER BY <Attributliste> DESC/ASC
- ASC (aufsteigend) ist default
- SELECT *
  FROM Filme
  WHERE StudioName = ‚Disney‘ AND Jahr = 1990
  ORDER BY Länge, Titel;

- SELECT *
  FROM Filme
  WHERE StudioName = ‚Disney‘ AND Jahr = 1990
  ORDER BY Länge ASC, Titel DESC;

Groß- und Kleinschreibung

In SQL wird Groß- und Kleinschreibung nicht beachtet

- From = FROM = from = FrOm
- Auch bei Attribut- und Relationennamen
- Aber
  - ‚FROM' ≠ ‚from' ≠ from

Überblick

- Einfache Anfragen
- Anfragen über mehrere Relationen
- Geschachtelte Anfragen
- Operationen auf einer Relation
- Datenbearbeitung (DML)
- Schemata (DDL)
- Sichten

Motivation

- Hauptkraft der Relationalen Algebra ist die Kombination von Relationen
- Erst mit mehreren Relationen sind viele interessante Anfragen möglich.

- Nennung der beteiligten Relationen in der FROM Klausel

Kreuzprodukt und Join

- Filme(Titel, Jahr, Länge, inFarbe, StudioName, ProduzentID)
- Manager(Name, Adresse, ManagerID, Gehalt)

- SELECT Name
  FROM Filme, Manager
  WHERE Titel = ‚Star Wars' AND ProduzentID = ManagerID;
- Semantik
  - Betrachte jedes Tupelpaar der Relationen Filme und Manager.
  - Wende Bedingung der WHERE Klausel auf jedes Tupelpaar an
  - Falls Bedingung erfüllt, produziere ein Ergebnistupel.
- Kreuzprodukt gefolgt von Selektion: Join

Uneindeutige Attributnamen

- Schauspieler(Name, Adresse, Geschlecht, Geburtstag)
- Manager(Name, Adresse, ManagerID, Gehalt)

Bei gleichen Attributnamen aus mehreren beteiligten Relationen:

- Relationenname als Präfix:
  - SELECT Schauspieler.Name, Manager.Name
    FROM Schauspieler, Manager
    WHERE Schauspieler.Adresse = Manager.Adresse;

- Präfix ist auch erlaubt wenn Attributname eindeutig ist.
  - Erleichtert das Lesen von SQL Anfragen

Tupelvariablen

Zur eindeutigen Kennzeichnung von Tupeln beteiligter Relationen

- „Alias" einer Relation
- Insbesondere: Bei der mehrfachen Verwendung einer Relation in einer Anfrage
- Gesucht: Schauspieler, die zusammen leben
  - SELECT Star1.Name, Star2.Name
    FROM Schauspieler Star1, Schauspieler Star2
    WHERE Star1.Adresse = Star2.Adresse
- Auch sinnvoll als abkürzenden Schreibweise
  - SELECT S.Name, M.Name
    FROM Schauspieler S, Manager M
    WHERE S.Adresse = M.Adresse;
- Ohne explizites Angeben einer Tupelvariablen wir der Attributname selbst als Tupelvariable verwendet.

Tupelvariablen

Name	Adresse	Geschlecht	Geburt
Carrie Fisher	123 Maple St., Hollywood	F	9/9/99
Mark Hamill	456 Oak Rd., Brentwood	M	8/8/88
Brad Pitt	123 Maple St., Hollywood	M	7/7/77

- SELECT Star1.Name, Star2.Name
  FROM Schauspieler Star1, Schauspieler Star2
  WHERE Star1.Adresse = Star2.Adresse;

Star1.Name	Star2.Name
Carrie Fisher	Carrie Fisher
Carrie Fisher	Brad Pitt
Brad Pitt	Carrie Fisher
Brad Pitt	Brad Pitt
Mark Hamill	Mark Hamill

- SELECT Star1.Name, Star2.Name
  FROM Schauspieler Star1, Schauspieler Star2
  WHERE Star1.Adresse = Star2.Adresse
  AND Star1.Name <> Star2.Name;

Star1.Name	Star2.Name
Carrie Fisher	Brad Pitt
Brad Pitt	Carrie Fisher

- SELECT Star1.Name, Star2.Name
  FROM Schauspieler Star1, Schauspieler Star2
  WHERE Star1.Adresse = Star2.Adresse
  AND Star1.Name < Star2.Name;

Star1.Name	Star2.Name
Brad Pitt	Carrie Fisher

Interpretation von Anfragen

Drei Interpretationsvarianten für Anfragen mit mehreren Relationen

- Nested Loops (geschachtelte Schleifen)
  - Bei mehreren Tupelvariablen: Eine geschachtelte Schleife für jede Variable
- Parallele Zuordnung
  - Alle Kombinationen werden parallel bezüglich der Bedingungen geprüft.
- Relationale Algebra
  - Bilde Kreuzprodukt
  - Wende Selektionsbedingungen auf jedes Resultat-Tupel an

Interpretation von Anfragen

- Gegeben drei Relationen: R(A), S(A) und T(A)
- Gesucht: $R \cap (S \cup T)$
  - SELECT R.A
    FROM R, S, T
    WHERE R.A = S.A OR R.A = T.A;

- Problemfall: T ist leer, hat also kein Tupel
- Vermeintliches Resultat: $R \cap S$
- Tatsächliches Resultat: leere Menge
  - Nested Loops
  - Parallele Zuordnung
  - Relationale Algebra

Mengenoperationen in SQL

- Vereinigung: UNION
- Schnittmenge: INTERSECT
- Differenz: EXCEPT
- Mengenoperationen nur zwischen (geklammerten) Anfrageergebnissen
  - Schauspieler(Name, Adresse, Geschlecht, Geburtstag)
  - Manager(Name, Adresse, ManagerID, Gehalt)

  - (SELECT Name, Adresse FROM Schauspieler
    WHERE Geschlecht = ‚F‘)
    INTERSECT
    (SELECT Name, Adresse FROM Manager
    WHERE Gehalt > 1.000.000);

Mengenoperationen in SQL

- Schauspieler(Name, Adresse, Geschlecht, Geburtstag)
- Manager(Name, Adresse, ManagerID, Gehalt)
- Filme(Titel, Jahr, Länge, inFarbe, StudioName, ProduzentID)
- spielt_in(FilmTitel, FilmJahr, Name)

- (SELECT Name, Adresse FROM Schauspieler)
  EXCEPT
  (SELECT Name, Adresse FROM Manager);
- (SELECT Titel, Jahr FROM Filme)
  UNION
  (SELECT FilmTitel AS Titel, FilmJahr AS Jahr FROM spielt_in)

Überblick

- Einfache Anfragen
- Anfragen über mehrere Relationen
- Geschachtelte Anfragen
- Operationen auf einer Relation
- Datenbearbeitung (DML)
- Schemata (DDL)
- Sichten

Motivation

Eine Anfrage kann Teil einer anderen Anfrage sein

- Beliebig tiefe Schachtelung

Anwendungsmöglichkeiten

- Subanfrage erzeugt einen einzigen Wert, der in der WHERE-Klausel mit einem anderen Wert verglichen werden kann.
- Subanfrage erzeugt eine Relation, die auf verschiedene Weise in WHERE-Klausel verwendet werden kann.
- Subanfrage erzeugt eine Relation, die in der FROM Klausel verwendet werden kann.
  - Wie jede normale Relation

Skalare Subanfragen

Allgemeine Anfrage produzieren Relationen.

- Mit mehreren Attributen
  - Zugriff auf ein bestimmtes Attribut ist möglich
- i.A. mit mehreren Tupeln
- Manchmal (garantiert) nur ein Tupel
  - „Skalare Anfrage“
  - Verwendung wie eine Konstante möglich

Skalare Subanfragen

- Manager(Name, Adresse, ManagerID, Gehalt)
- Filme(Titel, Jahr, Länge, inFarbe, StudioName, ProduzentID)
- Gesucht: Produzent von Star Wars
  - SELECT Name
    FROM Filme, Manager
    WHERE Titel = ‚Star Wars' AND Jahr = ‚1977'
    AND ProduzentID = ManagerID;
- Oder aber
  - SELECT Name
    FROM Manager
    WHERE ManagerID =
    (SELECT ProduzentID
    FROM Filme
    WHERE Titel = ‚Star Wars' AND Jahr = ‚1977');
- Wir erwarten genau ein Tupel als Ergebnis der Teilanfrage
  - Falls kein Tupel: Laufzeitfehler
  - Falls mehr als ein Tupel: Laufzeitfehler

Bedingungen mit Relationen

Bestimmte SQL Operatoren auf Relationen erzeugen Boole'sche Werte

- EXISTS R
  - TRUE, falls R nicht leer
- x IN R
  - TRUE falls x gleich einem Wert in R ist (R hat nur ein Attribut)
  - Verallgemeinerung auf Tupel gleich
  - x NOT IN R: TRUE falls x keinem Wert in R gleicht
- x > ALL R
  - TRUE falls x größer als jeder Wert in R ist (R hat nur ein Attribut)
  - Alternativ: <, >, <=, >=, <>, =
  - x <> ALL R: Entspricht x NOT IN R
- x > ANY R
  - TRUE falls x größer als mindestens ein Wert in R ist (R hat nur ein Attribut)
  - Alternativ: <, >, <=, >=, <>, =
  - x = ANY R: Entspricht x IN R
- Negation mit NOT ist immer möglich.

Bedingungen mit Tupeln

Verallgemeinerung von IN, ALL und ANY auf Tupel

- t IN R
  - TRUE falls t ein Tupel in R ist (mehr als ein Attribut möglich)
  - Setzt gleiche Schemata voraus
  - Setzt gleiche Reihenfolge der Attribute voraus
- t > ALL R
  - TRUE falls t größer als jedes Tupel in R ist
  - Vergleiche in Standardreihenfolge der Attribute
- t <> ANY R
  - TRUE falls R mindestens ein Tupel hat, das ungleich t ist

Bedingungen mit Tupeln

- SELECT Name
  FROM Manager
  WHERE ManagerID IN
  (SELECT ProduzentID
  FROM Filme
  WHERE (Titel, Jahr) IN
  (SELECT FilmTitel, FilmJahr
  FROM spielt_in
  WHERE SchauspielerName = ‚Harrison Ford‘
  ));
- Analyse am besten von innen nach außen
- Namen von Produzenten von Filmen mit Harrison Ford
- Alternative Formulierung
  - SELECT Name
    FROM Manager, Filme, spielt_in
    WHERE ManagerID = ProduzentID
    AND Titel = FilmTitel
    AND Jahr = FilmJahr
    AND SchauspielerName = ‚Harrison Ford‘;

Korrelierte Subanfragen

Bisher: Subanfragen einmalig ausführen und das Ergebnis weiterverwenden

- Korrelierte Subanfragen werden mehrfach ausgeführt, einmal pro Bindung der korrelierten Variable der äußeren Anfrage
- SELECT Titel, Jahr
  FROM Filme Alt
  WHERE Jahr < ANY
  (SELECT Jahr
  FROM Filme
  WHERE Titel = Alt.Titel);

Scope: Attributnamen gehören i.d.R. zur Tupelvariablen der aktuellen Anfrage. Sonst: Suche von innen nach außen.

  - Ausführung der Subanfrage für jedes Tupel in Filme
  - Alle mehrfachen Filme mit Ausnahme der jeweils jüngsten Ausgabe sind im Ergebnis.

SQL entfernt idR keine Duplikate!

Subanfragen in FROM-Klausel

Bisher: Nur Subanfragen in WHERE-Klausel

- Anstelle einfacher Relation steht eine geklammerte Subanfrage
- Es muss ein Alias vergeben werden.
- SELECT M.Name
  FROM Manager M, (SELECT ProduzentID AS ID
  FROM Filme, spielt_in
  WHERE Titel = FilmTitel
  AND Jahr = FilmJahr
  AND Schauspieler = ‚Harrison Ford') Produzent
  WHERE M.ManagerID = Produzent.ID;

Joins

Man kann Joins auch auf andere Weise ausdrücken.

- Besonders praktisch für Teilanfragen
- Filme CROSS JOIN spielt_in
  - Kreuzprodukt
  - Doppelte Attributnamen werden mit Präfix der Relation aufgelöst
- Filme JOIN spielt_in ON Titel = FilmTitel AND Jahr = FilmJahr
  - Theta-Join
  - SELECT Titel, Jahr, Länge, inFarbe, StudioName, ProduzentID, SchauspielerName
    FROM Filme JOIN spielt_in ON Titel = FilmTitel AND Jahr = FilmJahr;
  - Eliminiert redundante Attribute FilmTitel und FilmJahr
- Schauspieler NATURAL JOIN Manager
  - Natural Join; Eliminiert redundante Attribute

Outer Joins

- Schauspieler(Name, Adresse, Geschlecht, Geburtstag)
- Manager(Name, Adresse, ManagerID, Gehalt)
- Schauspieler NATURAL FULL OUTER JOIN Manager;
- Schauspieler NATURAL LEFT OUTER JOIN Manager;
- Schauspieler NATURAL RIGHT OUTER JOIN Manager;

- Filme FULL OUTER JOIN spielt_in
  ON Titel = FilmTitel AND Jahr = FilmJahr;
  - Widerspruch in sich? Es sollen schliesslich alle Tupel erhalten bleiben…
- Filme LEFT OUTER JOIN spielt_in
  ON Titel = FilmTitel AND Jahr = FilmJahr;
- Filme RIGHT OUTER JOIN spielt_in
  ON Titel = FilmTitel AND Jahr = FilmJahr;

Überblick

- Einfache Anfragen
- Anfragen über mehrere Relationen
- Geschachtelte Anfragen
- Operationen auf einer Relation
- Datenbearbeitung (DML)
- Schemata (DDL)
- Sichten

Duplikateliminierung

Relationale DBMS verwenden idR Multimengensemantik, nicht Mengensemantik.

- Duplikate entstehen durch
  - Einfügen von Duplikaten in Basisrelation
  - Veränderung von Tupeln in Basisrelation
  - Projektion in Anfragen
  - Durch Subanfragen (UNION)
  - Vermehrung von Duplikaten durch Kreuzprodukt
- Duplikateliminierung durch SELECT DISTINCT Attributnamen
  - Kosten sind hoch: Sortierung

Duplikateliminierung

- SELECT ManagerID, Name
  FROM Manager
  WHERE ManagerID IN
  (SELECT ProduzentID
  FROM Filme
  WHERE (Titel, Jahr) IN
  (SELECT FilmTitel, FilmJahr
  FROM spielt_in
  WHERE SchauspielerName =
  ‚Harrison Ford‘
  ));

- SELECT ManagerID, Name
  FROM Manager, Filme, spielt_in
  WHERE ManagerID =
  ProduzentID
  AND Titel = FilmTitel
  AND Jahr = FilmJahr
  AND SchauspielerName =
  ‚Harrison Ford‘;
- SELECT DISTINCT ManagerID,
  Name
  FROM Manager, Filme, spielt_in
  WHERE ManagerID =
  ProduzentID
  AND Titel = FilmTitel
  AND Jahr = FilmJahr
  AND SchauspielerName =
  ‚Harrison Ford‘;

Duplikateliminierung bei Mengenoperationen

- Mengenoperationen in SQL entfernen Duplikate
  - UNION, INTERSECT, EXCEPT
    - wandeln Multimengen in Mengen um und verwenden Mengensemantik
  - Duplikateliminierung verhindern durch ALL
    - (SELECT Titel, Jahr, FROM Filme)
      UNION ALL
      (SELECT FilmTitel AS Titel, FilmJahr AS Jahr FROM spielt_in);
    - Film mit drei Schauspielern erscheint also 4 Mal im Ergebnis
  - R INTERSECT ALL S
  - R EXCEPT ALL S

Aggregation

- Standardaggregationsoperatoren
  - SUM, AVG, MIN, MAX, COUNT
  - Angewendet auf einzelne Attribute in der FROM-Klausel
- Typische weitere Aggregationsoperatoren
  - VAR, STDDEV
- COUNT(*) zählt Anzahl der Tupel
  - in der Relation, die durch die FROM und WHERE Klauseln definiert wird.
- Kombination mit DISTINCT
  - COUNT(DISTINCT Jahr)
  - SUM(DISTINCT Gehalt)

Aggregation

- SELECT AVG(Gehalt)
  FROM Manager;
- SELECT COUNT(*)
  FROM spielt_in;
- SELECT COUNT(Schauspieler)
  FROM spielt_in;
- SELECT COUNT(DISTINCT Schauspieler)
  FROM spielt_in;

Gruppierung

- Gruppierung mittels GROUP BY nach der WHERE-Klausel
- SELECT StudioName, SUM(Länge)
  FROM Filme
  GROUP BY StudioName
- In SELECT-Klausel zwei Sorten von Attributen
  - Gruppierungsattribute
  - Aggregierte Attribute
  - Nicht-aggregierte Werte der SELECT-Klausel müssen in der GROUP BY-Klausel erscheinen.
  - Beide Sorten müssen nicht erscheinen
- SELECT StudioName
  FROM Filme
  GROUP BY StudioName
- SELECT SUM(Länge)
  FROM Filme
  GROUP BY StudioName

Gruppierung

Gruppierung bei mehreren Relationen wird am Schluss durchgeführt.

- SELECT Name, SUM(Länge)
  FROM Manager, Filme
  WHERE ManagerID = ProduzentID
  GROUP BY Name
- Reihenfolge der Ausführung
  - FROM-Klausel
  - WHERE-Klausel
  - GROUP BY-Klausel
  - SELECT-Klausel

Gruppierung

- Einschränkung der Ergebnismenge nach der Gruppierung durch HAVING
  - Einschränkung der Ergebnismenge
    - SELECT Name, SUM(Länge)
      FROM Manager, Filme
      WHERE ManagerID = ProduzentID
      AND Gehalt > 1000000
      GROUP BY Name
    - SELECT Name, SUM(Länge)
      FROM Manager, Filme
      WHERE ManagerID = ProduzentID
      GROUP BY Name
      HAVING SUM(Länge) > 1000
    - SELECT Name, SUM(Länge)
      FROM Manager, Filme
      WHERE ManagerID = ProduzentID
      GROUP BY Name
      HAVING SUM(Länge) > 1000
  - Aggregationen in HAVING Klausel beziehen sich nur auf aktuelle Gruppe.
  - Nur Gruppierungsattribute dürfen unaggregiert in HAVING Klausel erscheinen (wie bei SELECT-Klausel).

Zusammenfassung

Grundbausteine einer SQL Anfrage

- SELECT
- FROM
- WHERE
- GROUP BY
- HAVING
- ORDER BY

- SELECT … FROM … sind Pflicht.
  - Ausnahme: z.B. SELECT 7 + 3
- HAVING darf nur in Kombination mit GROUP BY erscheinen.

Überblick

- Einfache Anfragen
- Anfragen über mehrere Relationen
- Geschachtelte Anfragen
- Operationen auf einer Relation
- Datenbearbeitung (DML)
- Schemata (DDL)
- Sichten

Überblick

- Einfügen
  - **`INSERT INTO … VALUES…`**
- Löschen
  - **`DELETE FROM … WHERE …`**
- Ändern
  - **`UPDATE … SET … WHERE …`**

Einfügen

Grundbaustein

- **INSERT INTO** R(A_1, …, A_n) **VALUES** (v_1,…,v_n);

- Bei fehlenden Attributen
  - Default-Wert (NULL, falls nicht anders angegeben)
- Beispiel
  - **INSERT INTO spielt_in(FilmTitel, FilmJahr, Schauspieler) VALUES (`The Maltese Falcon', 1942, `Sydney Greenstreet');**
  - Reihenfolge der Werte und Attribute wird beachtet.
- Falls alle Attribute gesetzt werden:
  - **INSERT INTO spielt_in VALUES (`The Maltese Falcon', 1942, `Sydney Greenstreet');**
  - Reihenfolge entsprechend der Spezifikation des Schemas (CREATE TABLE …)

Einfügen per Anfrage

Füge in Studios alle Studios der Filme-Relation ein

- Filme(Titel, Jahr, Länge, inFarbe, StudioName, ProduzentID)
- Studios(Name, Adresse, VorsitzenderID)
-
```
INSERT INTO Studios(Name)
SELECT DISTINCT StudioName
FROM Filme
WHERE StudioName NOT IN
    (SELECT Name
     FROM Studios);
```

Adresse und VorsitzenderID bleiben NULL.

Ausführungsreihenfolge beim Einfügen

- Wann wird eingefügt?
  - Nach vollständiger Ausführung der SELECT FROM WHERE Anfrage?
  - Sofort?
    - Schnellere Implementation
  - Was passiert jeweils bei Anfrage 1?
  - Was passiert jeweils bei Anfrage 2?

```
INSERT INTO Studios(Name)
SELECT DISTINCT
StudioName
FROM Filme
WHERE StudioName NOT IN
(SELECT Name
 FROM Studios);
```

```
INSERT INTO Studios(Name)
SELECT StudioName
FROM Filme
WHERE StudioName NOT IN
(SELECT Name
 FROM Studios);
```

Löschen

Grundbaustein

- **DELETE FROM** *R* **WHERE …**
- Lösche alle Tupel in *R*, für die die Bedingung wahr ist.
- ```
  DELETE FROM spielt_in
  WHERE FilmTitel = ‚The Maltese Falcon‘
  AND FilmJahr = 1942
  AND Schauspieler = ‚Sydney Greenstreet‘;
  ```

- Tupel können im Gegensatz zum Einfügen nicht direkt angegeben werden, sondern müssen umschrieben werden.
- ```
  DELETE FROM Manager
  WHERE Gehalt < 10000000;
  ```
- Alle Manager-Tupel löschen: **`DELETE FROM Manager;`**

Verändern (update)

Grundbaustein

- **UPDATE** *R* **SET … WHERE …**
- SET Klausel
  - Wertzuweisungen
  - Komma-separiert
-
```
UPDATE Manager
SET Name = ‚Pres. ‘ || Name
WHERE ManagerID IN
    (SELECT PräsidentID FROM Studios);
```

Überblick

- Einfache Anfragen
- Anfragen über mehrere Relationen
- Geschachtelte Anfragen
- Operationen auf einer Relation
- Datenbearbeitung (DML)
- Schemata (DDL)
- Sichten

Überblick

- Datentypen
- Tabellen
- Default-Werte
- Indizes

Datentypen

Jedes Attribut muss einen Datentyp haben.

- CHAR(n)
  - String fester Länge (n)
- VARCHAR(n)
  - String variabler Länge, maximal n Zeichen

Sind kompatibel

- BIT(n) bzw. BIT VARYING(n)
  - Wie CHAR, aber Bits
- BOOLEAN
  - TRUE, FALSE oder UNKNOWN
- INT / INTEGER bzw. SHORTINT
- FLOAT / REAL bzw. DOUBLE PRECISION
- DECIMAL (n,d)
- DATE bzw. TIME

Tabellen

Grundbaustein zum Erzeugen

- **CREATE TABLE** *R* …
- **CREATE TABLE Schauspieler (**
  Name CHAR(30),
  Adresse VARCHAR(255),
  Geschlecht CHAR(1),
  Geburtstag DATE);
- Löschen
  - **DROP TABLE Schauspieler;**
- Verändern
  - **ALTER TABLE Schauspieler ADD Telefon CHAR(16);**
    - Nullwerte entstehen
  - **ALTER TABLE Schauspieler DROP Geburtstag;**

Default-Werte


- ```
  CREATE TABLE Schauspieler (
      Name CHAR(30),
      Adresse VARCHAR(255),
      Geschlecht CHAR(1) DEFAULT ‚?‘,
      Geburtstag DATE DEFAULT DATE ‚0000-00-00‘);
  ```

- ```
  ALTER TABLE Schauspieler ADD Telefon CHAR(16) DEFAULT
  ‚unbekannt‘;
  ```

Ausblick – Constraints und Trigger

Weitere Optionen für Tabellen

- **`PRIMARY KEY`**
- **`UNIQUE`**
- **`FOREIGN KEY … REFERENCES …`**
- **`NOT NULL`**
- **`CHECK`**
- **`CREATE ASSERTION`**
- **`CREATE TRIGGER`**

Siehe auch nächster Foliensatz.

Indizes

- Ein Index auf einem Attribut *A* ist eine Datenstruktur, die es dem DBMS erleichtert, Tupel mit einem bekannten Wert des Attributs zu finden.
  - Nicht SQL-Standard, aber in fast jedem DBMS verfügbar.

- Motivation
  - **SELECT ***
    FROM Filme
    WHERE StudioName = ‚Disney‘ AND Jahr = ‚1990‘;
  - Variante 1: Alle 10.000 Tupel durchsuchen und WHERE Bedingung prüfen
  - Variante 2: Direkt alle 200 Filme aus 1990 betrachten und auf ‚Disney‘ prüfen.
    - **CREATE INDEX JahrIndex ON Filme(Jahr);**
  - Variante 3: Direkt alle 10 Filme aus 1990 von ‚Disney‘ holen.
    - **CREATE INDEX JahrStudioIndex ON Filme(Jahr, Studioname);**

Indizes

- Indizes auf einzelnen Attributen
  - **`CREATE INDEX JahrIndex ON Filme(Jahr);`**
- Indizes auf mehreren Attributen
  - **`CREATE INDEX JahrStudioIndex ON Filme(Jahr, Studioname);`**
  - Reihenfolge wichtig! Warum?
- Löschen
  - **`DROP INDEX JahrIndex;`**

Indexwahl

- Tradeoff
  - Index beschleunigt Punkt- (und Bereichs-) Anfragen und Joinanfragen erheblich.
  - Index verlangsamt das Einfügen, Löschen und Verändern von Tupeln der Relation.
    - Index muss jeweils aktualisiert werden.
  - Indizes benötigen Speicherplatz.

- Wahl der besten Indizes ist eine der schwierigsten Aufgaben des Datenbankdesigns.
  - Vorhersage der *query workload* und update-Frequenz
  - Wahl der Attribute
    - Häufiger Vergleich mit Konstanten
    - Häufiges Joinattribut

Indexwahl – Vorüberlegungen

Relationen sind typischerweise über mehrere Diskblöcke gespeichert.

- Primäre Datenbankkosten sind die Anzahl der Diskblöcke, die in den Hauptspeicher gelesen werden müssen.
- Bei Punktanfragen mit Index müssen statt aller Blöcke nur ein Block gelesen werden.
- Aber Index selbst muss ebenfalls gespeichert und gelesen werden.
- Updates kostet sogar doppelt: Lesen und Schreiben

Indexwahl – Beispiel

- **spielt_in(FilmTitel, FilmJahr, Schauspieler)**
- Drei typische Anfragen
  - **SELECT FilmTitel, FilmJahr FROM spielt_in**
    WHERE Schauspieler = s;
  - **SELECT Schauspieler FROM spielt_in**
    WHERE FilmTitel = t AND FilmJahr = j;
  - **INSERT INTO spielt_in VALUES(t, y, s);**
- **spielt_in** ist auf 10 Blöcke verteilt.
- Durchschnittlich hat jeder Film 3 Schauspieler und jeder Schauspieler spielt in 3 Filmen.
  - Echte Daten später.
- 3 Schauspieler/Filme sind auf 3 Blöcke verteilt
- Index ist auf einem Block gespeichert.
- Lesen und Schreiben kostet 1, Update und Insert kosten 2.

Indexwahl – Beispiel

Anfrage	Kein Index	SchauspielerIndex	Film-Index	Beide Indizes
Schauspieler = s	10	4	10	4
FilmTitel = t AND FilmJahr = j	10	10	4	4
INSERT INTO spielt_in	2	4	4	6
Gesamtkosten	$2+8p_1+8p_2$	$4+6p_2$	$4+6p_1$	$6-2p_1-2p_2$

- p_1: Anteil Anfrage 1
- p_2: Anteil Anfrage 2
- $1-p_1-p_2$: Anteil Anfrage 3

Verteilung in IMDB (Real-World Daten)


- ```
  WITH
  m AS (select count(*) AS ZahlMovies FROM imdb.movie),
  actress AS( select count(*) AS ZahlActress FROM imdb.actress),
  actor AS (select count(*) AS ZahlActor FROM imdb.actor),
  actors AS (select (ZahlActress + ZahlActor) AS GesamtActors
  FROM actress, actor)
  SELECT DOUBLE(actors.GesamtActors) /DOUBLE(m.ZahlMovies)
  FROM m, actors
  ```
- Schauspieler pro Spielfilm: 8,7
- ```
  WITH
  actors AS (SELECT * FROM imdb.actor UNION
                SELECT * FROM imdb.actress),
  counts AS (SELECT name, count(movie_id) AS m
                 FROM actors GROUP BY name)
  SELECT AVG(DOUBLE(m)) FROM counts
  ```
- Spielfilme pro Schauspieler: 4,2

Überblick

- Einfache Anfragen
- Anfragen über mehrere Relationen
- Geschachtelte Anfragen
- Operationen auf einer Relation
- Datenbearbeitung (DML)
- Schemata (DDL)
- Sichten

Virtuelle Relationen

- Relationen aus **CREATE TABLE** Ausdrücken existieren tatsächlich (materialisiert, physisch) in der Datenbank.
  - Persistenz
  - Updates sind möglich
- Die Daten aus Sichten (*views*) existieren nur virtuell.
  - Sichten entsprechen Anfragen, denen man einen Namen gibt. Sie wirken wie physische Relationen.
  - Updates sind nur manchmal möglich.

Sichten in SQL

- **CREATE VIEW** *Name* **AS** *Anfrage*
- **CREATE VIEW ParamountFilme AS**

```
SELECT Titel, Jahr
FROM Filme
WHERE StudioName = ‚Paramount‘;
```

  - Auch mehr als eine Relation möglich!
- Semantik
  - Bei jeder Anfrage an die Sicht wird die SQL Anfrage der Sicht ausgeführt.
  - Die ursprüngliche Anfrage verwendet das Ergebnis als Relation.
- Daten der Sicht ändern sich mit der Änderung der zugrundeliegenden Relationen.
- Entfernen der Sicht: **DROP VIEW ParamountFilme**
  - Basisdaten bleiben unverändert.

Anfragen an Sichten

- **CREATE VIEW ParamountFilme AS**
  SELECT Titel, Jahr
  FROM Filme
  WHERE StudioName = ‚Paramount‘;
- **SELECT Titel**
  FROM ParamountFilme
  WHERE Jahr = 1979;
- Umwandlung der ursprünglichen Anfrage in eine Anfrage an Basisrelationen
  - **SELECT Titel**
    FROM Filme
    WHERE StudioName = ‚Paramount‘ AND Jahr = 1979;
  - Übersetzung durch DBMS
- Anfrage zugleich an Sichten und Basisrelationen möglich
  - **SELECT DISTINCT Schauspieler**
    FROM ParamountFilme, spielt_in
    WHERE Titel = FilmTitel AND Jahr = FilmJahr;

Anfragen an Sichten

- Filme(Titel, Jahr, Länge, inFarbe, StudioName, ProduzentID)
- Manager(Name, Adresse, ManagerID, Gehalt)
- ```
  CREATE VIEW FilmeProduzenten AS
      SELECT Titel, Name
      FROM Filme, Manager
      WHERE ProduzentID = ManagerID;
  ```
- Anfrage
  - ```
    SELECT Name
    FROM FilmeProduzenten
    WHERE Titel = ‚Gone with the Wind‘
    ```
- Übersetzung
  - ```
    SELECT Name
    FROM Filme, Manager
    WHERE ProduzentID = ManagerID
    AND Titel = ‚Gone with the Wind‘;
    ```
    ```

Attributumbenennung in Sichten

- Umbenennung von Attributen
  - ```
    CREATE VIEW FilmeProduzenten(FilmTitel,
    Produzentenname) AS
    SELECT Titel, Name
    FROM Filme, Manager
    WHERE ProduzentID = ManagerID;
    ```

- Oder Sicht einfach nur zur Umbenennung
  - ```
    CREATE VIEW Movies(title, year, length, inColor,
    studio, producerID) AS
           SELECT *
           FROM Filme;
    ```

Diskussion

Vorteile

- Vereinfachung von Anfragen
- Strukturierung der Datenbank
- Logische Datenunabhängigkeit
  - Sichten stabil bei Änderungen der Datenbankstruktur
- Beschränkung von Zugriffen (Datenschutz)
- Später: Optimierung durch materialisierte Sichten

Probleme

- Automatische Anfragetransformation schwierig
- Durchführung von Änderungen auf Sichten
- Updatepropagierung für materialisierte Sichten

Anfrageplanung mit Sichten

Baumdarstellung von Anfragen

- Blätter repräsentieren Relationen
  - Basisrelationen
  - Sichten
- Ersetzung der Sichten durch die Sichtdefinition
  - Als Subanfrage

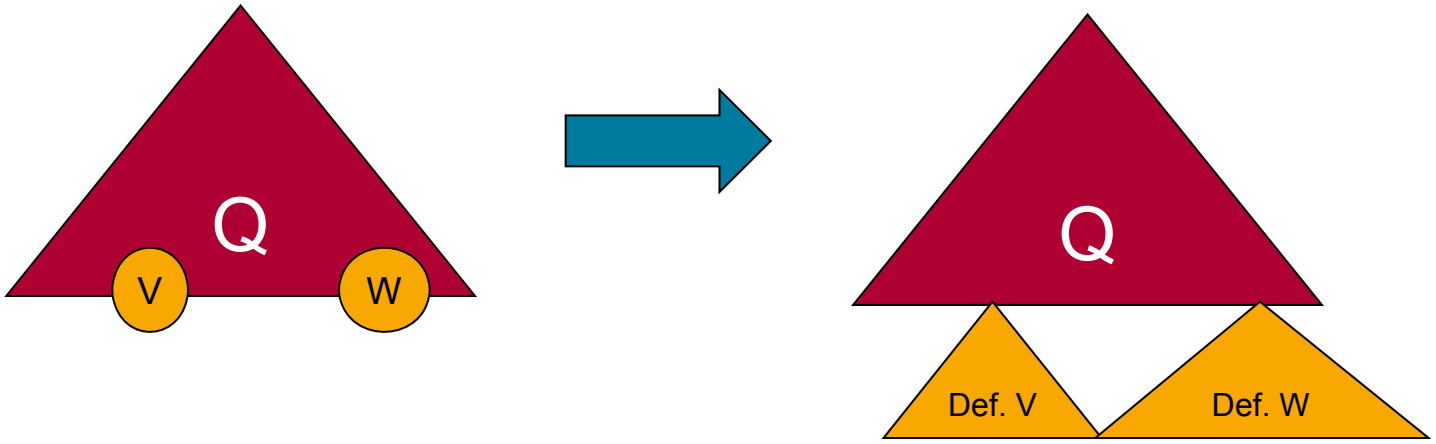

Anfrageplanung mit Sichten

- Sicht
  - **CREATE VIEW ParamountFilme AS SELECT Titel, Jahr FROM Filme WHERE StudioName = ‚Paramount‘;**
- Anfrage
  - **SELECT Titel FROM ParamountFilme WHERE Jahr = 1979;**

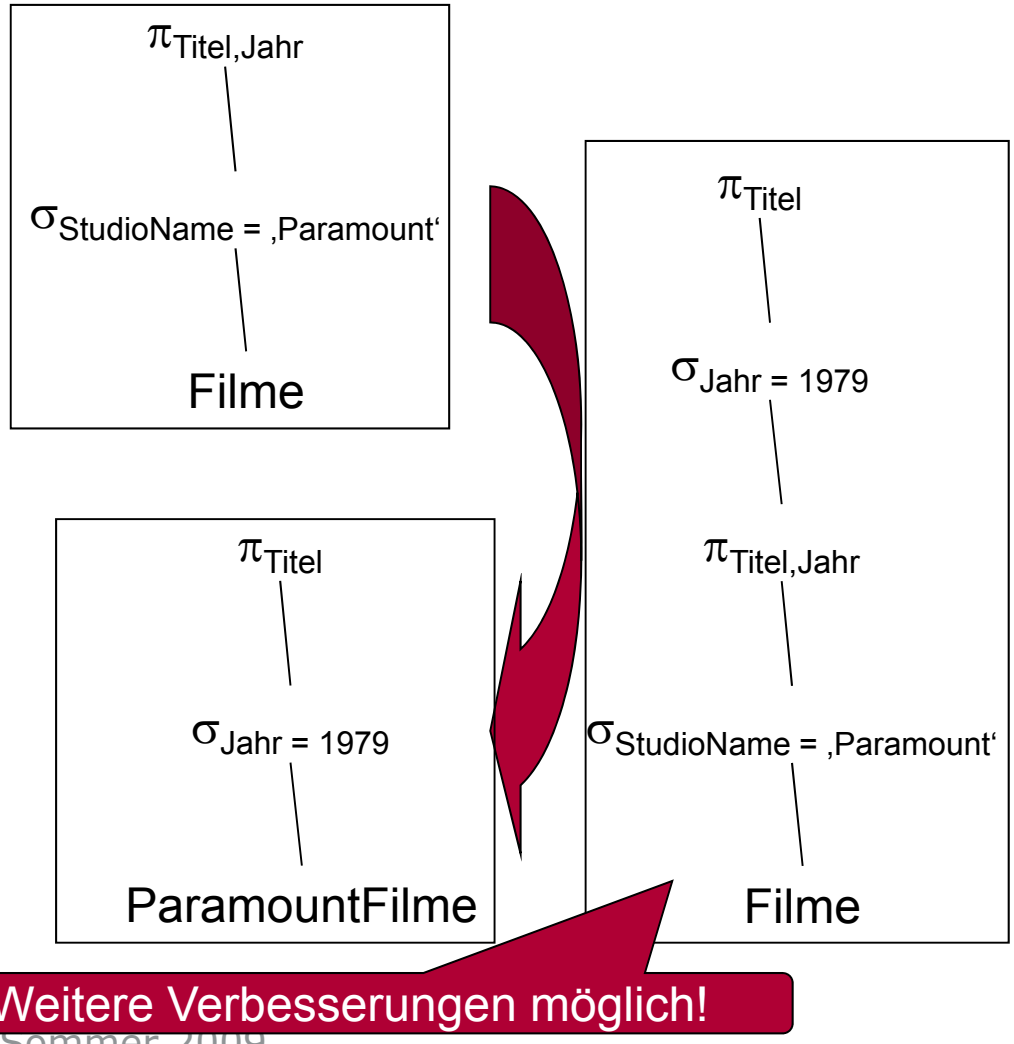

Materialisierte Sichten

Viele Anfragen an eine Datenbank wiederholen sich häufig

- Business Reports, Bilanzen, Umsätze
- Bestellungsplanung, Produktionsplanung
- Kennzahlenberechnung

Viele Anfragen sind Variationen mit gemeinsamem Kern

=> Einmaliges Berechnen der Anfrage als Sicht

=> Automatische, transparente Verwendung in folgenden Anfragen

=> Materialisierte Sicht (*materialized view*, MV)

Drei Folien nach Prof. Ulf Leser, HU Berlin

MV – Themen und Probleme

Wahl von Views zur Materialisierung

- MVs kosten: Platz und Aktualisierungsaufwand
- Wahl der optimalen MVs hängt von Workload ab
- Auswahl der „optimalen" Menge von MVs

Automatische Aktualisierung von MVs

- Aktualisierung bei Änderungen der Basisrelationen
- U.U. schwierig: Aggregate, Joins, Outer-Joins, ...
- Algorithmen zur inkrementellen Aktualisierung

Automatische Verwendung von MV

- *„Answering Queries using Views"*
- Umschreiben der Anfrage notwendig
- Schwierigkeit hängt von Komplexität der Anfrage / Views ab
- Algorithmen zur transparenten und kostenoptimalen Verwendung der materialisierten Sichten

„Answering Queries using Views“

Gegeben

- Eine Anfrage Q
- Eine Menge V von Sichten

Fragen

- Kann man Q **überhaupt** unter Verwendung von V beantworten?
- Kann man Q **nur** mit V beantworten?
- Kann man Q mit V **vollständig** beantworten?
- Ist es günstig, Sichten aus V zur Beantwortung von Q zu verwenden? Welche?

Zusammenfassung

- Die Anfragesprache SQL
- Der SFW Block
- Subanfragen
  - In FROM und WHERE
  - EXISTS, IN, ALL, ANY
- Mengenoperationen
  - UNION, INTERSECT, EXCEPT
- Joins und Outerjoins
- Nullwerte
- Mengen vs. Multimengen
- Gruppierung und Aggregation
  - MIN, MAX, COUNT
  - GROUP BY, HAVING
- Datenbankveränderungen
  - INSERT, UPDATE, DELETE
- Schemata und Datentypen
  - CREATE TABLE
  - ALTER TABLE
- Indizes
- Sichten
  - Updates und Anfragen
  - Materialisierte Sichten