

Zusammenfassung von Kemper/Eickler, Datenbanksysteme, 5. Auflage, Kapitel 4-14

Geschrieben von Christian Pöcher

Veröffentlicht unter Creative Commons Attribution-ShareAlike 2.0 Germany License.
(<http://creativecommons.org/licenses/by-sa/2.0/de/>) ==> Erweitert und verbessert die Zusammenfassung!

Kap 4: Relationale Anfragesprachen

- * Anfragesprachen, wie SQL, sind deklarativ.
- * Schema definieren: CREATE TABLE ...
- * Schema ändern: ALTER TABLE ... [ADD |ALTER COLUMN] ...
- * Datensatz einfügen: INSERT INTO ... VALUES ...
- * Anfrage: SELECT DISTINCT ... FROM ... WHERE ... ORDER BY ... [DESC|ASC]
- * Aggregatfunktionen: AVG, MIN, MAX, SUM, COUNT
- * HAVING: Geht nur bei GROUP BY, selektiert ganze Gruppen.
- * Mengenoperatoren: UNION, INTERSECT, EXCEPT, IN, NOT IN
- * Datensatz ändern: UPDATE ... SET ...
- * Datensatz löschen: DELETE FROM ... WHERE ...
- * Änderungen werden erst in tempoäre Tabelle oder in
- * SQL hat keinen Allquantor, Existenzquantor durch EXISTS
- * SQL hat relationales Tupelkalkül als Grundlage
- * null bedeutet "korrekter Wert nicht bekannt"
- * dreiwertige Logik: true, false, unknown
- * vier Arten Joins: cross join, natural join, (inner) join, left/right/full outer join
- * SQL nicht Touring-vollständig: Keine Rekursion möglich! Keine transitive Hülle
- * Sichten: CREATE VIEW ... AS ...
- * Zweck von Sichten: a) Daten für bestimmte Benutzer (un-)zugänglich machen, b) vereinfachte Schreibweise für Anfragen
- * Sichten sind update-fähig, wenn a) keine Aggregatfunktionen, DISTINCT, HAVING benutzt werden, b) Schlüssel der Basisrelation enthalten ist und c) nur eine Tabelle verwendet wird.
- * Generalisierung kann erreicht werden, wenn Obertyp oder Untertyp durch Views definiert werden.
- * Einbettung in Wirtssprachen durch Strings (JDBC) oder Metasprache und Präprozessor (SQLJ)

Zusammenfassung Kapitel 5: Datenintegrität

- * Syntaktische Integritätsbedingungen schon durch Tabellendefinition bestimmt, jetzt semantische Integritätsbedingungen
- * vier Arten: a) referentielle I., b) statische I. durch CHECK, c) Constraints, d) Trigger
- * referentielle Integrität: Fremdschlüssel null oder Fremdschlüssel = Primärschlüssel eines Datensatzes der referenzierten Tabelle
- * statische Integrität: CHECK (Note BETWEEN 0.7 AND 5.0)
- * CHECK auch ok, wenn Antwort unknown
- * Constraints: In Tabellendefinition CONSTRAINT Name CHECK (EXISTS (SELECT ...))
- * Trigger: 4 Teile, a) Name, b) Auslöser (BEFORE UPDATE ON ... FOR EACH ROW), c) einschränkende Bedingung (WHEN), d) Prozeduraler Code

Zusammenfassung Kapitel 6: Relationale Entwurfstheorie

- * jetzt: Konzeptuelle Feinabstimmung, Güte des Schemas verbessern
- * Functional Dependency (FD): alpha --> beta gilt, wenn Werte von beta durch Werte von alpha bestimmt werden.
- * FDs stellen eine semantische Konsistenzbedingung dar, d.h. sie müssen durch das DBMS erzwungen werden.
- * alpha ist Superschlüssel, wenn alpha --> R, d.h. die Werte von alpha bestimmen alle anderen Attributwerte

- * alpha ist Kandidatenschlüssel, wenn $\alpha \rightarrow R$
- * beta ist voll funktional von alpha abhängig ($\alpha \rightarrow \beta$), wenn $\alpha \rightarrow \beta$ und alpha nicht mehr verkleinert werden kann.
- * F+ Hülle der FDs, Herleitung durch Armstrong Axiome:
 - a) Falls beta Teilmenge von alpha, gilt $\alpha \rightarrow \beta$
 - b) Verstärkung: $\alpha \rightarrow \beta \Rightarrow \alpha \gamma \rightarrow \beta \gamma$
 - c) Transitivität
- * Mengen von funktionalen Abhängigkeiten sind äquivalent, wenn ihre Hüllen gleich sind. Man schreibt $F=G$.
- * F_c heisst kanonische Überdeckung zu F, wenn
 - a) $F_c = F^+$
 - b) Man kann weder alpha noch beta verkleinern, es gibt keine überflüssigen Attribute.
 - c) Jede linke Seite in F_c ist eindeutig.
- * Berechnung der kanonischen Überdeckung durch
 - a) Linksreduktion (Kann man bei FD $\alpha \rightarrow \beta$ ein A von alpha entfernen?)
 - b) Rechtsreduktion (B bei beta entfernbar?)
 - c) Entferne FDs der Form $\alpha \rightarrow \{ \}$
 - d) Fasse FDs mit gleicher linken Seite durch Vereinigungsregel zusammen.
- * Drei Anomalien:
 - a) Update: Wenn Information redundant, dann kann bei Update eines vergessen werden. Zusätzlich höherer Speicher- und CPU-Bedarf
 - b) Einfüge: Informationen zweier Entities werden vermischt. Auffüllen mit NULL nötig.
 - c) Löschen: unabsichtliches Löschen von Daten wegen Vermischung
- * Korrektheitskriterien für Schemazerlegungen:
 - a) Verlustlosigkeit: nach Projektion und natürlichem Join muss wieder das gleiche rauskommen.
 - b) Abhängigkeitserhaltung: alle FDs müssen auch nach Zerteilung gelten.
- * 1NF: Alle Attribute haben atomare Wertebereiche
- * 2NF: Jedes Nichtschlüssel-Attribut ist voll funktional abhängig von jedem Kandidatenschlüssel
- * 3NF: Für jede FD $\alpha \rightarrow B$ gilt mind. eine der Bedingungen:
 - a) B ist Element von alpha (FD ist trivial)
 - b) B ist in einem Kandidatenschlüssel enthalten.
 - c) alpha ist Superschlüssel der Relation.
- * Berechnung der 3NF:
 - 1) Berechne kanonische Überdeckung.
 - 2) Kreiere für jede FD ein Relationsschema.
 - 3) Wähle Schlüssel.
 - 4) Eliminiere Schematas, die vollständig in anderem Schema enthalten sind.
- * BCNF: Wie 3NF, aber ohne Bedingung b). Nicht abhängigkeitsbewahrend.
- * multivalued dependencies (MVD): beta ist mehrwertig abhängig alpha ($\alpha \twoheadrightarrow \beta$) gdw. man kann bei gleichem alpha-Wert die beta-Werte vertauschen und das resultierende Tupel ist weiter in der Relation.
- * Zerlegungen von Relationen mit MVDs: R kann in R1, R2 zerlegt werden, wenn a) $R = R1$ vereinigt mit R2 und b) R1 geschnitten R2 $\twoheadrightarrow R1$ oder R1 geschnitten R2 $\twoheadrightarrow R2$
- * $\alpha \twoheadrightarrow \beta$ ist trivial, wenn beta Teilmenge von alpha oder $\beta = R - \alpha$
- * 4NF: Für jede MVD gilt: a) MVD ist trivial oder b) alpha ist Superschlüssel für R. Nicht abhängigkeitsbewahrend.

Zusammenfassung Kap 7 Indexstrukturen

- * ISAM: Wie Daumenindex. Suchen in $\log(n)$, Insert und Delete kann Index komplett nach rechts verschieben. Bild siehe S.206
- * B-Baum vom Grad k: Jeder Knoten ausser der Wurzel hat zwischen k und 2k Einträge. Blätter alle gleich weit von Wurzel entfernt. Zugriffe sehr stark logarithmisch.
- * B+-Baum: "hohler Baum", Daten nur in Blättern.
- * Hashing: Index durch Hashfunktion, z.B. $h(x) = x \bmod p$. Problem: Überlaufende Seiten führen zu Ineffizienz.
- * Erweiterbares Hashing: $h(x)$ wird binär dargestellt. Prefix als Verzeichniseintrag. Reicht eine Seite nicht mehr aus, wird weitere Stelle zu Prefix hinzugenommen. => doppelte Anzahl

Seiten.

- * R-Baum: Boxen um n-dimensional Daten bauen.
- * Range Queries können von Hashes nicht gut bearbeitet werden. Bei Exact Match Queries sind sie aber Bäumen überlegen.

Zusammenfassung Kap 8 Anfragebearbeitung

- * Ziel: Anfrageoptimierung, dazu logische und physische Optimierung
- * Regeln zur logischen Optimierung schreiben Anfrage in RA um, z.B. kann Selektion und Kreuzprodukt zu einem Join zusammengefasst werden
- * exakte Optimierung so schwer wie das originale Problem, aber Optimierungsheuristiken möglich:
 - Aufbrechen von Selektionen
 - Verschieben der Selektionen nach unten im Baum
 - Zusammenfassen von Selektionen und Kreuzprodukten zu Joins
 - Reihenfolge der Joins, so dass kleine Zwischenergebnisse
 - Einfügen von Projektionen
 - Verschieben der Projektionen nach unten im Baum
- * Implementierung von Joins:
 - nested loops
 - seitenorientiertes nested loops
 - Merge Join (zwei Pointer wandern runter)
 - Hash Join
- * Durch Kostenmodelle werden Implementierungen ausgewählt und daraus Auswertungspläne erstellt.
- * Statistiken werden durch ANALYSE gesammelt
- * den Auswertungsplan kriegt man mit EXPLAIN

Zusammenfassung Kap9 Transaktionsverwaltung

- * Transaktion: Arbeitseinheit in einer Anwendung
- * ACID:
 - Atomicity: Transaktion als kleinste, nicht teilbare Einheit, "ganz oder gar nicht"
 - Constistency: Nach Beendigung von Transaktion ist Datenbasis konsitent
 - Isolation: nebenläufige Transaktionen beeinflussen sich nicht
 - Durability: Wirkungen abgeschlossener Transaktionen bleiben dauerhaft bestehen
- * Recovery: kümmert sich um Atomicity und Durability
- * Mehrbenutzersynchronisation: kümmert sich um Isolation

Kapitel 10: Fehlerbehandlung

=====

- * lokales Undo: treten im normalen Betrieb auf, z.B. durch Fehler im Anwendungsprogramm oder durch ABORT.
- * globales Undo: Nach Hauptspeicherverlust nicht abgeschlossene Transaktionen rückgängig machen.
- * globales Redo: Nach Hauptspeicherverlust abgeschlossene Transaktionen auf Festplatte schreiben.
- * steal/not steal: Pufferspeicher, der durch aktive Transaktionen benötigt ist kann (nicht) ersetzt werden. Macht globales Undo nötig.
- * force/not force: Änderungen einer Transaktion werden bei COMMIT (nicht) auf die Festplatte geschrieben. Macht globales Redo nötig.
- * Einbringstrategie:
 - update-in-place: Seite auf Festplatte wird überschrieben.
 - Twin-Block: zwei Seiten und Markierung welche Seite aktuell ist.
- * Log:
 - LSN: Sequenz Number

- TransaktionsID
- PageID
- PrevLSN: vorheriger Log aus gleicher Transaktion.
- * Write Ahead Logging (WAL): Erst Logs schreiben, dann Daten auf Festplatte schreiben.
- * Wiederanlauf:
 - Analyse des Logs, Bestimme Winner und Looser
 - Redo von Winnern und Loosern
 - Undo von Loosern

Kapitel 11: Mehrbenutzersynchronisation

=====

- * Interleaving von Transaktionen kann Wartezeiten überbrücken.
- * Lost Update: T1 überschreibt Änderungen von T2.
- * Dirty Read: T1 liest Daten von T2 bevor T2 zurückgesetzt wird.
- * Phantom Read: T1 erstellt Daten, die von T2 nicht mehr berücksichtigt werden.
- * Schedule: Ablauf einer verzahnten Ausführung mehrerer Transaktionen. Bestimme partielle Ordnung für Konfliktoperationen.
- * Schedules serialisieren: Vertauschen von Operationen, bis Transaktionen nacheinander laufen.
- * serialisierbare Schedules: Ein Schedule ist serialisierbar, wenn es äquivalent zu einer seriellen Historie ist.
- * Serialisierbarkeitstheorem: Schedule ist serialisierbar, gdw. wenn der Serialisierungsgraph azyklisch ist.
- * Rücksetzbare Schedules: Ermöglichen ABORT ohne andere Transaktionen in Mitleidenschaft zu ziehen. Problematisch ist, wenn T1 schreibt und T2 das danach liest.
- * Schedules ohne kaskadierendes Rücksetzen: Änderungen von T1 werden erst nach COMMIT freigegeben.
- * Scheduleklassen: S. 308
- * Locks: Shared/Read, eXclusive/Write
- * Two Phase Locking:
 - Jedes Objekt muss vor Benutzung gesperrt werden
 - Keine Transaktion fordert Sperren zweimal an
 - Lock nicht gekriegt -> Warteschlange
 - Erst Wachstumsphase, dann Schrumpfungsphase
- * strenges 2PL: Alle Locks werden erst beim Ende der Transaktion freigegeben.
- * 2PL garantiert Serialisierbarkeit, strenges 2PL schützt vor kaskadierenden Rollback
- * Deadlock-Erkennung:
 - Time-out
 - Wartegraph (Zykel = Deadlock)
 - Preclaim (Alle Locks am Anfang nehmen)
 - Zeitstempel (wound-wait, wait-die)
- * Wound-Wait: T1 fordert Lock an, das T2 hat. Wenn T1 älter als T2, verwunde T2. Sonst wartet T1.
- * Wait-Die: Wenn T1 älter als T2, wartet T1. Sonst stirbt T1.
- * Isolation-Levels:
 - read uncommitted (liest auch uncommitted values)
 - read committed (Problem: non repeatable read)
 - repeatable read
 - serializable

Kapitel 12: Sicherheitsaspekte

=====

- * drei Arten:
 - Identifikation
 - Zugriffskontrolle
 - Auditing (Logs angucken)
- * Discretionary Access Control (DAC): Quintupel (Objekte, Benutzer, Rechte, Filterprädikat, Weitergabeflag)

- * Mandatory Access Control (MAC): Jeder User hat ein Clearance-Level. Objekte haben ein Classification-Level.
- * Multilevel Datenbanken:
 - Jedes Attribut und das ganze Tupel zusätzlich haben Classification.
 - Polyinstatierung: Tupel darf mit mehreren Sicherheitseinstufungen vorkommen.

Zusammenfassung Kapitel 13: OODB

- * Schwachpunkte relationaler DBs:
 - Anwendungsobjekt wird auf unterschiedliche Relationen segmentiert.
 - Künstliche Schlüsselattribute
 - Kein Verhalten
 - Impedance Mismatch: Mengenorientiert vs. Satzorientiert
- * Vorteile OO-Modellierung:
 - Information Hiding: Operationen ausführbar ohne Kenntnis der Repräsentation der Daten
 - Transformationen entfallen (Mengenorientiert vs. Satzorientiert)
 - Objektidentität statt künstlicher Schlüssel
- * Drei Bestandteile eines Objektes:
 - Identität (OID)
 - Typ
 - Wert
- * Drei Bestandteile eines Objekttyps:
 - Strukturbeschreibung (Attribute)
 - Verhaltensbeschreibung (Operationen)
 - Generalisierungs-/Spezialisierungsbeziehungen
- * Nachteile von "identity through contents":
 - Objekte mit gleichem Wert müssen nicht identisch sein.
 - künstliche Schlüssel müssen vom Benutzer gewartet werden, obwohl keine Anwendungssemantik.
 - Schlüssel dürfen nicht verändert werden
- * OIDs = Objekt-Referenzen
- * Beziehungen in ODMG über RELATIONSHIP und INVERSE
CLASS Professoren {
 RELATIONSHIP Räume residiertIn INVERSE Räume::beherrbergt;
};
- * Soll eine Seite N-wertig sein definiert man
RELATIONSHIP set <Vorlesungen> liest inverse Vorlesungen::gelesenVon
- * INVERSE garantiert Symmetrie
- * Extent ist die Menge aller Instanzen eines Objekts
- * Vererbung möglich wo Substituierbarkeit gegeben ist:
Eine Untertyp-Instanz ist überall dort einsetzbar, wo eine Obertyp-Instanz gefordert ist.
- * dynamisches Binden: erst zur Laufzeit wird bestimmt welche Implementierung einer Operation gewählt wird.

Zusammenfassung Kapitel 14: Objektrelationale DBs

- * Erweiterungen:
 - Large Objects
 - # CLOBs: Character Large Objects
 - # BLOBs: Binary Large Objects
 - Mengenwertige Attribute
 - Geschachtelte Relationen
 - User Defined Types (UDTs)
 - # wertbasierter Typ
 - # row Types
 - OID/Referenzen/Pfadausdrücke
 - Vererbung

- Operationen

- * Locator: Pointer auf LOBs, Operationen werden nur logisch ausgeführt
- * Vergleich bei UDTs nur mit gleichen Typen möglich
- * Vererbung durch CREATE TYPE ProfessorenTyp UNDER AngestelltenTyp ...