Abschnitt: Datenbanken

Folien basieren auf:

Database System Concepts
Avi Silberschatz, Henry F. Korth, S. Sudarshan
McGraw-Hill, ISBN 0-07-295886-3

Bzw. einer Vorlesung aus dem WS 2007/8

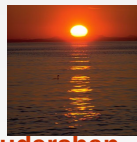

Überblick über das Gebiet Datenbanken

- Beispiel/Aufhänger
- Sinn und Zweck von Datenbanksystemen
- "Sichten" auf die Daten
- Datenbanksprachen
- Relationale Datenbanken
- Datenbankdesign
- Datenspeicherung und -abfrage
- Transaktionsmanagement
- Datenbankarchitekturen
- Datenbankbenutzer und -administratoren
- Gesamtstruktur eines DBMS
- Geschichte der Datenbanksysteme

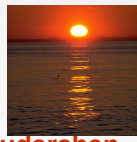

Beispiel

- Die Verwaltungsabläufe an einer Universität sind heutzutage immer noch hochgradig papierbasiert
- Schrittweise werden einzelne Ämter/Abteilungen auf elektronische Datenver- und bearbeitung umgestellt;
  Beispiel:
  - Prüfungsamt verwaltet Prüfungstermine, Noten und Daten der Studenten in Ihrer zugekauften Software XY
  - Das Bafög-Amt hat seine eigene Software YZ, um die Bafög-Empfänger unter den Studenten zu verwalten
  - Das Studentenwerk hat ....
- Zieht ein Student um, meldet er seine Adreßänderung vielleicht beim Bafög-Amt, vergisst aber Prüfungsamt und Studentenwerk
  - Inkonsistenter Datenbestand
  - Redundanzen

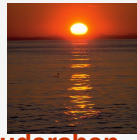

Beispiel

- Idealerweise (?) sollte es eine zentrale Instanz geben, welche alle Daten, die einen bestimmten Studenten betreffen, speichert/verwaltet
  - Database Management System
  - Datenschutz/Privatsphäre
- Stellen bzw. Ämter, welche auf Studentendaten zugreifen möchten, sollten nur auf die Studentendaten Zugriff haben, welche für ihre Arbeit relevant sind
  - sog. “Views”
- Updates wie z.B. Adressänderungen sind für alle sofort sichtbar
- Herausforderungen
  - Koordination gemeinsamer Zugriffe (Transaktionsmanagement)
  - Konsistenzerhaltung
  - Datensicherung
  - Performance

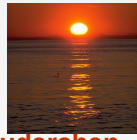

Datenbank Management System (DBMS)

- ein DBMS umfaßt
  - eine Kollektion von Daten ("Datenbank")
  - Programme, diese Kollektion von Daten zu verwalten
- DBMS Anwendungen:
  - Banken: alle Banktransaktionen
  - Fluggesellschaften: Reservierungen, Fahrpläne
  - Universitäten: Immatrikulation, Notenvergabe
  - Vertrieb: Kunden, Produkte, Verkäufe
  - Online-Shops: Bestellung, Tracking, Empfehlungen
  - Produzierendes Gewerbe: Produktion, Inventar, Bestellungen ...
  - Personalverwaltung: Arbeitnehmerdaten, Gehälter, Steuern
  - Webseiten/Content Management Systeme
- Wir treffen Datenbanken in allen Lebensbereichen an

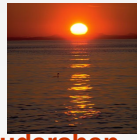

Zweck von DBMS

- Früher speicherten Datenbankanwendungen ihre Daten direkt im Filesystem
- Nachteile:
  - Datenredundanz und -inkonsistenz
    - Viele Datenformate, Wiederholung derselben Information in vielen Dateien
  - Probleme beim Datenzugriff
    - Operationen auf den Daten müssen individuell programmiert werden
  - Datenisolation — konkurrierende, nicht-kompatible Datenformate
  - Integritätsprobleme
    - Integritätsbedingungen (z.B.. Kontostand > 0) sind im Programmcode versteckt anstatt explizit aufgeführt
    - Schwierigkeiten, neue Bedingungen hinzuzufügen oder bestehende zu ändern

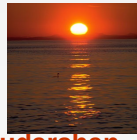

Zweck von DBMS (Forts.)

- Nachteile der Nutzung des Filesystems (Forts.)
  - Atomizität von Änderungen
    - Fehler können die Datenbank in einem inkonsistenten Status zurücklassen, in welchem Änderungen nur partiell ausgeführt wurden
    - Beispiel: Überweisung von Geldern von einem Konto auf das andere sollte entweder vollständig ausgeführt werden oder gar nicht
  - Gleichzeitiger Zugriff durch mehrere Benutzer
    - Gleichzeitiger Zugriff für gute Performanz unersetzlich
    - Unkontrollierte, gleichzeitige Zugriffe können zu Inkonsistenzen führen
      - Bsp: Zwei Leute ändern Kontostand gleichzeitig
  - Sicherheitsprobleme
    - Schwierig, Datenzugriff einzuschränken
- DBMS lösen all diese Probleme

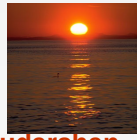

Abstraktionsebenen

- **Physikalische Ebene:** beschreibt wie ein Datensatz (z.B. Kunde) gespeichert wird.
- **Logische Ebene:** beschreibt die Daten, die in der Datenbank gespeichert sind, und die Relationen zwischen den Daten.

```
type customer = record
        customer_id : string;
        customer_name : string;
        customer_street : string;
        customer_city : integer;
    end;
```

- **Sichtenebene:** Anwendungsprogramme verstecken Details der Datentypen. Sichten können auch aus Sicherheitsgründen Teile der Datentypen verstecken (z.B. Gehalt).

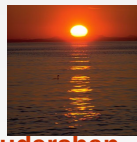

"Views" auf die Daten

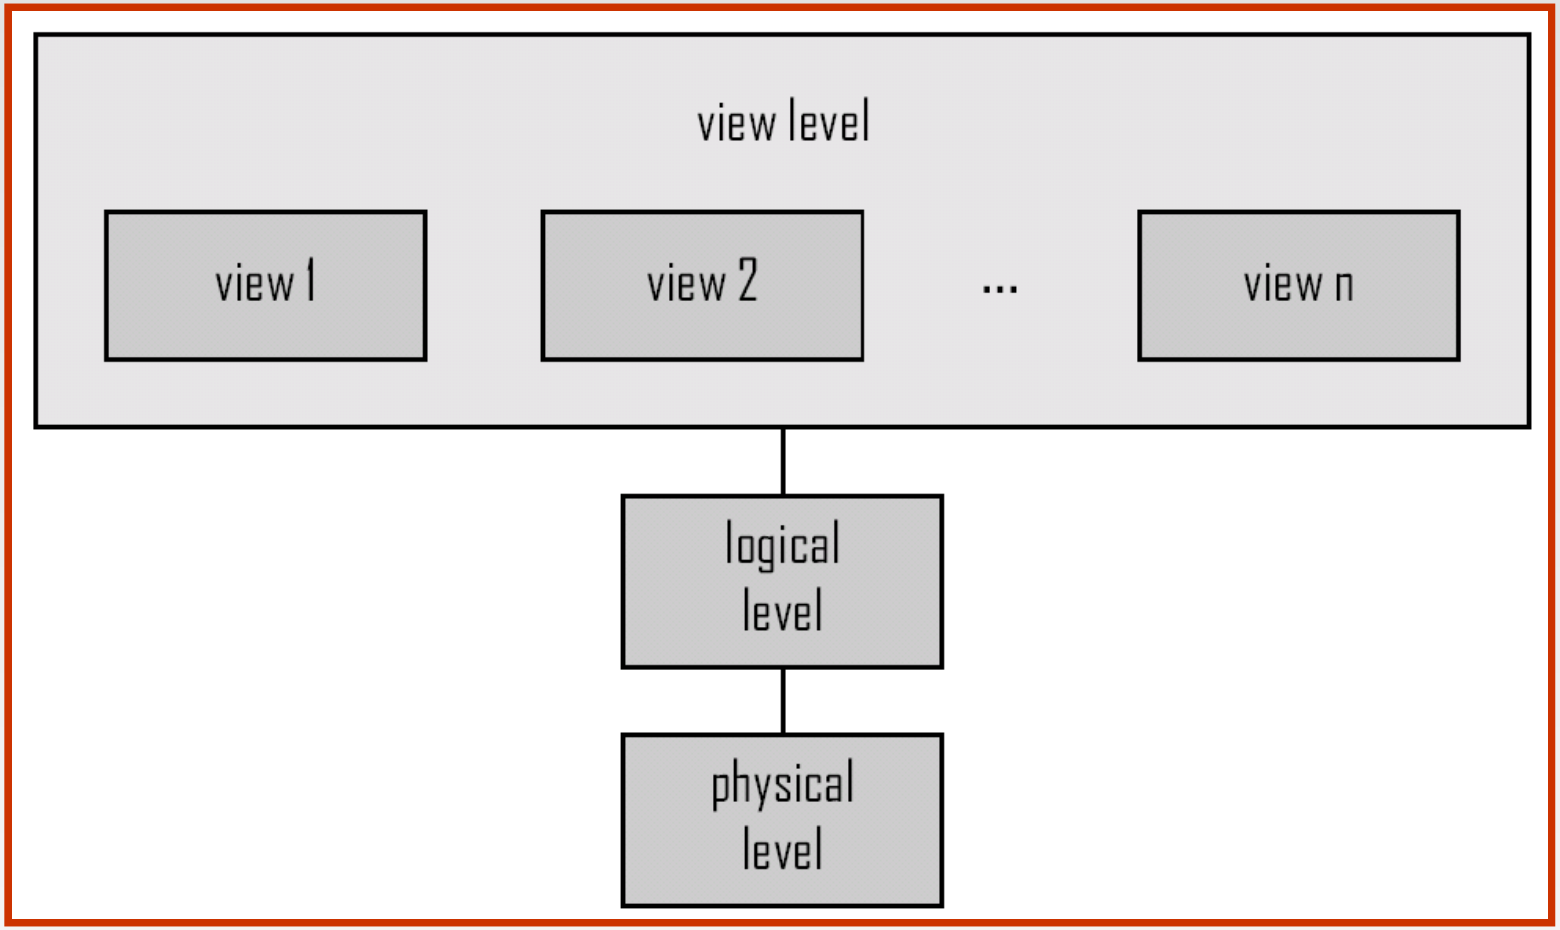

Instanzen und Schemata

- Ähnlich Typen und Variablen in Programmiersprachen
- **Schema** – die logische Struktur einer Datenbank
  - Bsp.: Die Datenbank besteht aus einer Menge von Kunden, Konten und der Beziehung zwischen diesen
  - Entspricht dem TYP einer Variable in einem Programm
  - **Physikalisches Schema**: Datenbankdesign auf physikalischer Ebene
  - **Logisches Schema**: Datenbankdesign auf logischer Ebene
- **Instanz** – der eigentliche Inhalt der Datenbank zu einem bestimmten Zeitpunkt
  - Entspricht dem WERT einer Variable in einem Programm
- **Physikalische Datenunabhängigkeit** – die Möglichkeit, das physikalische Schema zu ändern, ohne das logische Schema abändern zu müssen
  - Anwendungen hängen vom logischen Schema ab
  - Im Allgemeinen sollten die Schnittstellen zwischen den Ebenen und Komponenten wohldefiniert sein, sodass Änderungen in einem Teil keinen großen Einfluß auf andere Teile haben.

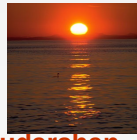

Datenmodellierung

- Handwerkszeug um Beschreibungen zu erstellen für
  - Daten
  - Beziehungen zwischen den Daten
  - Semantik der Daten
  - Einschränkungen über den Daten
- Relationales Modell
- Entity-Relationship Modell
- [Objektbasierte Datenmodelle (Objektorientiert und Objektrelational)]
- [Semistrukturierte Datenmodelle (XML)]

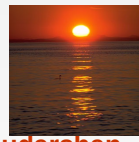

Data Manipulation Language (DML)

- Sprache, um auf die Daten zuzugreifen und sie zu manipulieren
  - DML wird oft auch Anfragesprache/Query Language genannt
- Zwei Sprachklassen
  - **Prozedural** – Benutzer spezif ziert, welche Daten gebraucht werden, und wie sie ermittelt werden können
  - **Deklarativ (nichtprozedural)** – Benutzer spezif ziert welche Daten gebraucht werden, ohne zu sagen, wie sie genau ermittelt werden sollen
- SQL ist die verbreitetste Anfragesprache

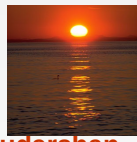

Data Definition Language (DDL)

- Spezifikationssprache, um Datenbankschema zu definieren

  Beispiel: **create table** *account* (
  account-number **char**(10),
  balance **integer**)

- DDL Compiler erzeugt eine Menge von Tabellen, im *data dictionary* gespeichert werden
- Data dictionary enthält auch Metainformationen(Daten über Daten)
  - Datenbankschema
  - Data *storage and definition* language
    - Spezifiziert die Speicherstruktur und die Zugriffsmethoden
  - Integritätsbedingungen
    - Bereichsbeschränkungen
    - Referentielle Integrität (Referenzbedingung in SQL)
    - Assertions
  - Zugriffsbeschränkungen

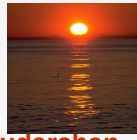

Relationales Modell

- Beispiel einer Tabelle im relationalen Modell

Attribute

customer_id	*customer_name*	*customer_street*	*customer_city*	*account_number*
192-83-7465	Johnson	12 Alma St.	Palo Alto	A-101
192-83-7465	Johnson	12 Alma St.	Palo Alto	A-201
677-89-9011	Hayes	3 Main St.	Harrison	A-102
182-73-6091	Turner	123 Putnam St.	Stamford	A-305
321-12-3123	Jones	100 Main St.	Harrison	A-217
336-66-9999	Lindsay	175 Park Ave.	Pittsfield	A-222
019-28-3746	Smith	72 North St.	Rye	A-201

Beispiel einer relationalen Datenbank

customer_id	*customer_name*	*customer_street*	*customer_city*
192-83-7465	Johnson	12 Alma St.	Palo Alto
677-89-9011	Hayes	3 Main St.	Harrison
182-73-6091	Turner	123 Putnam Ave.	Stamford
321-12-3123	Jones	100 Main St.	Harrison
336-66-9999	Lindsay	175 Park Ave.	Pittsfield
019-28-3746	Smith	72 North St.	Rye

(a) The *customer* table

account_number	*balance*
A-101	500
A-215	700
A-102	400
A-305	350
A-201	900
A-217	750
A-222	700

(b) The *account* table

customer_id	*account_number*
192-83-7465	A-101
192-83-7465	A-201
019-28-3746	A-215
677-89-9011	A-102
182-73-6091	A-305
321-12-3123	A-217
336-66-9999	A-222
019-28-3746	A-201

(c) The *depositor* table

SQL

- **SQL**: sehr verbreitete, nicht-prozedurale Anfragesprache
  - Bsp.: Finde den Namen des Kunden mit Kundennr. 192-83-7465

    select *customer.customer_name*
    from *customer*
    where *customer.customer_id* = ‘192-83-7465’
  - Bsp.: Finde die Kontostände aller Konten des Kunden mit Kundennr. 192-83-7465

    select *account.balance*
    from *depositor*, *account*
    where *depositor.customer_id* = ‘192-83-7465’ **and**
    depositor.account_number = account.account_number
- Anwendungsprogramme greifen auf Datenbanken typischerweise zu mittels
  - Spracherweiterungen, die es erlauben, SQL einzubetten
  - Anwendungsprogramminterfaces (API) (z.B., ODBC/JDBC), welche SQL Queries an eine Datenbank absetzen können

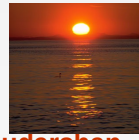

Datenbankdesign

Der Prozess die Gesamtstruktur der Datenbank zu entwerfen:

- Logisches Design – Entscheidung über das Datenbankschema.
  - Businessentscheidung – Welche Attribute sollten wir in der Datenbank speichern?
  - Informatikentscheidung – Welche Schemata sollten wir haben, und wie sollten die Attribute über die Schemata verteilt sein?
- Physikalisches Design – Entscheidung über die physikalische Implementierung der Datenbank

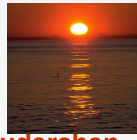

Das Entity-Relationship Modell

- Modellierung durch eine Menge von E*ntities u*nd *Relationships*
  - Entity/Entität: ein “Ding" oder "Objekt" welches von anderen Objekten unterscheidbar ist
    - wird durch eine Menge von *Attributen* beschrieben
  - Relationship/Relation: eine Assoziation zwischen. mehreren Entitäten
- Repräsentation mittels eines *Entity-Relationship Diagramms:*

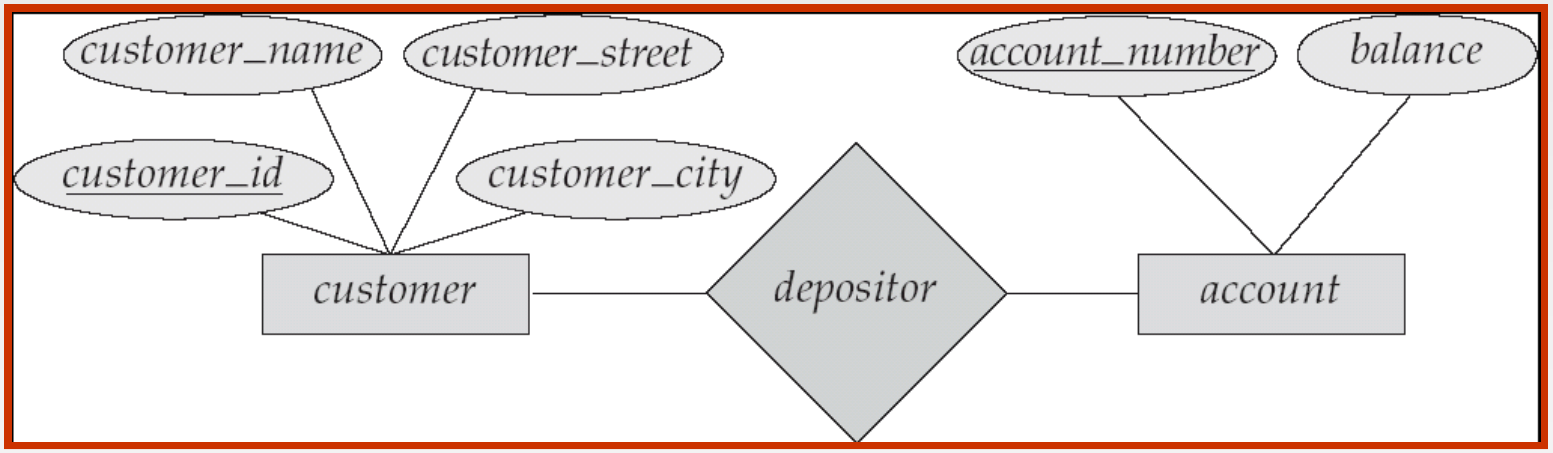

Storage Management

- Der **Storage manager** ist ein Programmmodul, welches die Schnittstelle zwischen den "rohen" Daten, die in der Datenbank gespeichert sind, und den Anwendungsprogrammen und Anfragen, die an das System geschickt werden.
- Der Storage Manager ist verantwortlich für:
  - Interaktionen mit dem Filemanager
  - Eff ziente Speicherung, Zugriff und Modif kation der Daten
- Aufgabengebiete:
  - Speicherzugriff
  - Dateiorganisation
  - Indizierung und Hashing

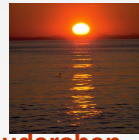

Query Processing

"Anfragenbearbeitung"

1. Parsen und Übersetzen der Anfrage
2. Optimierung der Anfrage
3. Auswertung

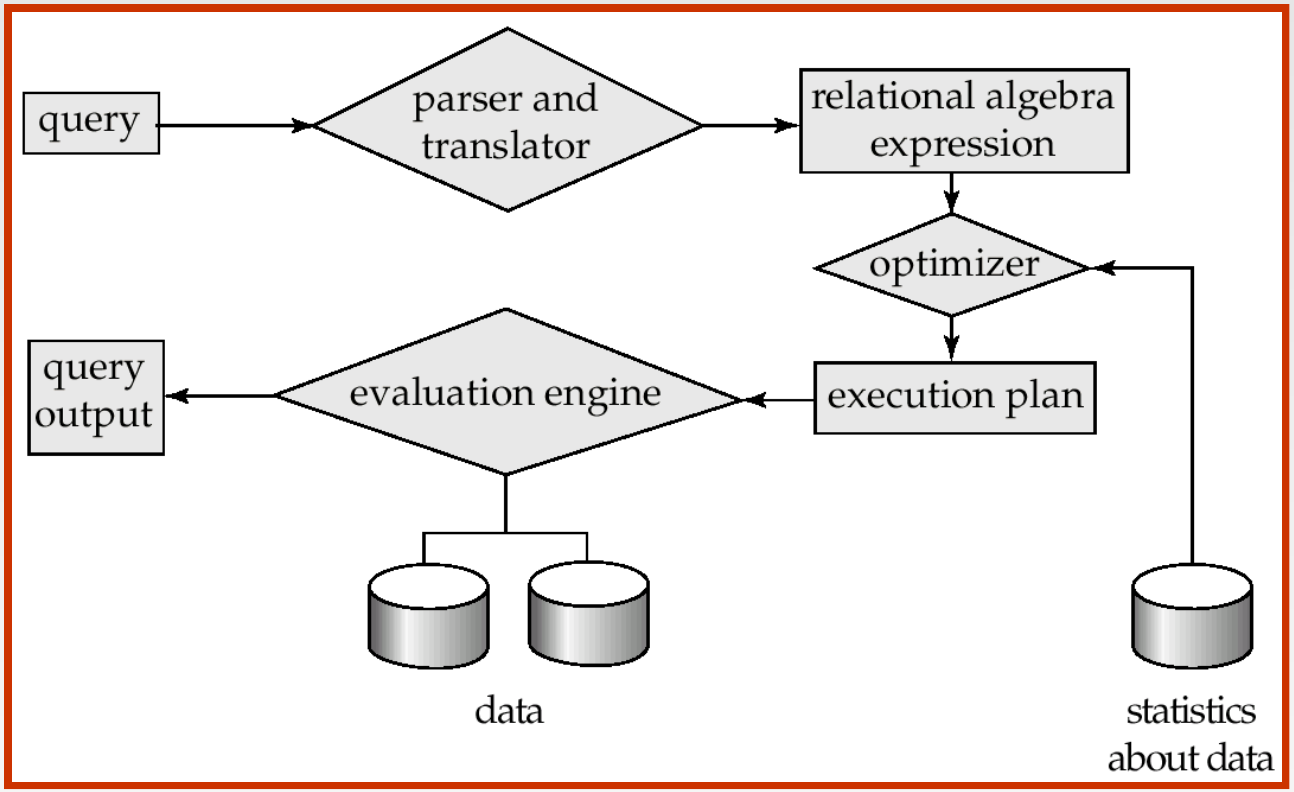

Query Processing (Forts.)

- Oft gibt es verschiedene Arten eine Anfrage auszuwerten
  - gleichwertige Ausdrücke
  - alternative Algorithmen für jede Operation
- Der Unterschied zwischen eff zienter und nicht-eff zienter Auswertung einer Anfrage ist enorm
- Oft wird zur Optimierung eine Schätzung der Kosten einer einzelnen Operation benötigt
  - hängt typischerweise stark von statistischen Informationen über die Relationen in der Datenbank ab
  - manchmal müssen Statistiken auch für Zwischenergebnisse berechnet/geschätzt werden, um den Aufwand komplexer Anfragen abschätzen zu können

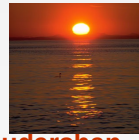

Transaction Management

- Eine **Transaktion** ist eine Menge von Operationen, die eine einzelne logische Funktion in einer Datenbankanwendung ausführt
- Die **Transaction-management Komponente** stellt sicher, dass die Datenbank in einem konsistenten Zustand verbleibt, auch im Falle von Systemfehlern (Stromausfall, OS-Abstürzen) und Transaktionsfehlern.
- Der **Concurrency-control Manager** überwacht die Interaktion zwischen nebenläuf gen Transaktionen, um die Konsistenz der Datenbank zu garantieren.

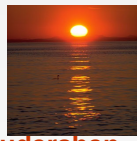

Datenbankarchitektur

Die Architektur eines DBMS wird stark beeinflußt vom zugrundeliegenden Rechnersystem, auf welchem die Datenbank ausgeführt wird:

- zentralisiert
- Client-server
- Parallel (multi-processor)
- verteilt

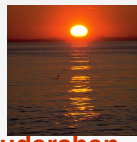

Datenbankbenutzer

Benutzer unterscheiden sich in der Art und Weise, wie sie mit dem System interagieren möchten

- **Anwendungsprogrammierer** – interagieren mit dem System durch DML-Aufrufe
- **Fortgeschrittene Benutzer** – stellen Anfragen in einer Anfragesprache (z.B. SQL)
- **Naïve Benutzer** – rufen eine der schon entwickelten Datenbankanwendungen auf
  - Beispiele: Leute, die Datenbanken über das Web anfragen, Bankangestellte, ...

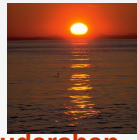

Datenbankadministrator

- Koordiniert alle Aktivitäten des DBMS; der DBMS Admin sollte einen guten Überblick über die Informationsressourcen und -bedürfnisse haben.
- Die Pflichten eines DBMS Admins schließen ein:
  - Schemadefinition
  - Festlegung der Speicherstruktur und der Zugrifsmethode
  - Änderungen an Schema oder physikalischer Organisation
  - Benutzerverwaltung der Datenbank
  - Spezifikation von Integritätsbedingungen
  - Überwachung der Performanz des Systems und ggf. Modifikation der Systemstruktur

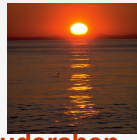

Systemstruktur

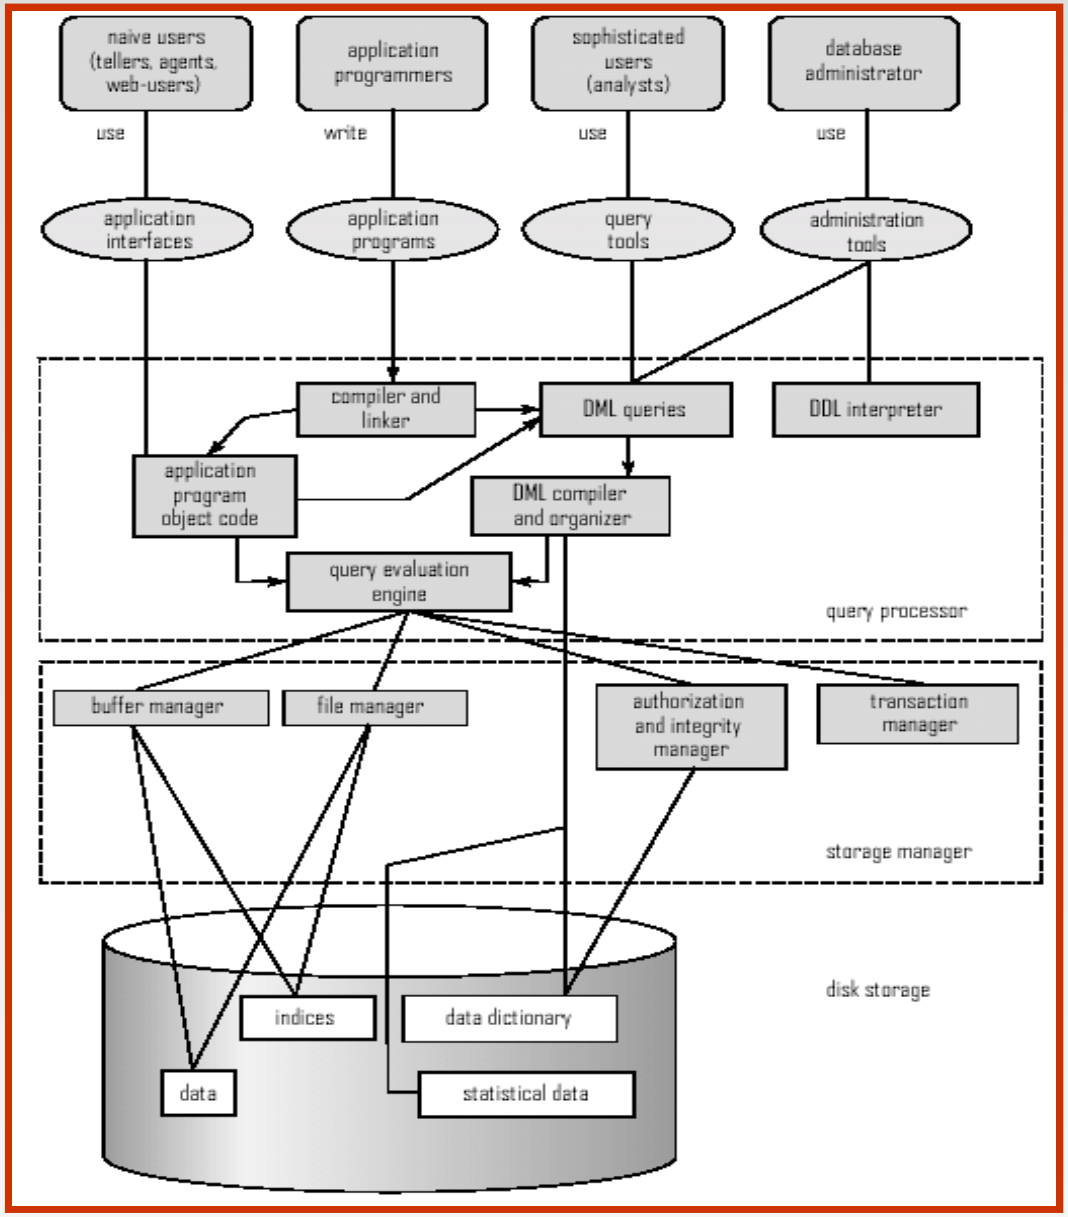

Geschichte der DBMS

- 1950s und frühe 1960s:
  - Datenverarbeitung mittels Magnetbänder zur Speicherung
    - nur sequentieller Zugriff
  - Lochkarten als Eingabemedium
- Späte 1960s und 1970s:
  - Festplatten erlauben direkten Datenzugriff
  - Ted Codd definiert das relationale Datenmodell
    - gewinnt später dafür den ACM Turing Award
    - IBM Research startet mit dem System R Prototype
    - UC Berkeley beginnt mit dem Ingres Prototype

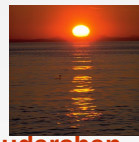

Geschichte (Forts.)

- 1980s:
  - Relationale DBMS Prototypen fanden Weg in kommerzielle Systeme
    - SQL wird Industriestandard
  - Parallele und verteilte DBMS
  - OO DBMS
- 1990s:
  - Große Datamining Anwendungen
  - Große Multiterabyte Datawarehouses
  - Erstes Erscheinen des Handels im "Netz"
- 2000s:
  - XML und XQuery Standards
  - Automatisierte DatenbankadministrationAutomated database administration

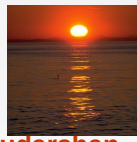

Grenzen der DBMS

- DBMS sind gut geeignet, Daten zu verwalten, welche
  - in homogener Form vorliegen
  - "von Natur aus" strukturiert sind
- ... und Anfragen zu beantworten welche
  - präzise das gewünschte Ergebnis formulieren
- Eine Unmenge an Daten liegt heutzutage jedoch vor in Form von
  - wissenschaftliche Publikationen
  - Ton-/Bildmaterial
  - Webseiten im Internet
- DBMS sind nicht besonders gut darin, diese Art von Daten zu verwalten

Information Retrieval Systeme

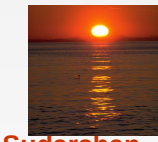

Beispiel: (Vereinfachter) Entwurf einer Datenbank

- Die Entitäten und Betriebsabläufe einer Universität sollen in einer Datenbank abgebildet werden
- Erster Schritt:
  - Skizzieren der abzubildenden Entitäten/Abläufe
- Zweiter Schritt:
  - Abbildung der Skizze in ein relationale Schemata
- Dritter Schritt:
  - Korrektur/Optimierung der relationalen Schemata
    - Minimierung von Redundanzen
    - Untersuchung auf Existenz von Primärschlüsseln
- Vierter Schritt:
  - Def nition von Views auf die Daten für die einzelnen Anwender/Anwendungen