Datenbanken

Dr. Özgür L. Özçep
Universität zu Lübeck
Institut für Informationssysteme

Tutoren:
Jule Drewalowski
Samuel Effler
Anna-Sophie Franke

Organisatorisches: Vorlesung

- Folien und gegebenenfalls Audio-/Videoaufzeichnungen werden über Moodle jeweils Montags bis 14.00 Uhr Nachmittag zur Verfügung gestellt
- **Vorlesungsslot** (Dienstag 10-12) als Webex-Textchat-Fragestunde zur Vorlesung
- Melden Sie sich für die Vorlesung in Moodle an
- Weitere Fragen zur Vorlesung können u.a. in den Übungsgruppen und im Forum von Moodle besprochen werden
- **Beginn**: am 7.4.2020

Organisatorisches: Übungen (1)

- **Start** : Donnerstag, 9. April 2020
- **Übungssitzungen**: Donnerstags als WebEx-Konferenz;
- Die **Eintragung in den Kurs** und in eine Übungsgruppe **über Moodle** ist **Voraussetzung**, um an dem Modul Datenbanken teilnehmen zu können und Zugriff auf die Unterlagen zu erhalten
- **Übungsaufgaben** werden dienstags um 18.00 Uhr über Moodle veröffentlicht
- **Abgabe der Lösungen** erfolgt bis Montag 12.00 Uhr in der jeweils folgenden Woche nach Ausgabe über Moodle als PDF
- Aufgaben sollen in **2-er oder 3-er Studentengruppen** bearbeitet werden (in Moodle in dieselbe Übungsgruppe (1-6) eintragen)

Organisatorisches: Übungen (2)

- **Übungsbetrieb**
  - Nutzung von Webex Meeting/Webex Team;
  - Von Tutoren moderiert
  - Siehe https://www.itsc.uni-luebeck.de/conferencing/webex.html
  - Machen Sie sich mit WebEx Meeting/Team vertraut
- Aufgaben werden von Tutoren korrigiert und die mit Korrekturen versehenen PDFs über Moodle zur Verfügung gestellt.

Organisatorisches: Übungen (3)

- **Blatt 1**: Ausgabe Dienstag, 7.4.2020; Abgabe 13.4.2020 bis 12.00Uhr; Besprechung am 16.4.2020
  - Abgabe für das erste Blatt ist noch nicht auf 2bzw. 3-er Studentengruppen eingestellt. Daher bitte unbedingt Namen und Übungsgruppennummern (1-6) auf Abgaben vermerken
  - Wir werden ab Blatt 2 dann die 2-bzw. 3-er Gruppen von Studenten in Moodle einrichten, so dass Abgaben in 2-bzw. 3-er Gruppen möglich
- Es gibt **0 PUNKTE** für
  - zu ähnliche Abgaben
  - Abgaben von Teams mit mehr als 3 Teilehmern
  - Abgaben von Teams aus unterschiedlichen Gruppen
  - Abgaben ohne Namen oder Gruppennummer.
  - Abgaben nach der Deadline

Rahmenbedingungen

- Übung und Klausurzulassung
  - 13 Übungsblätter, je 20 Punkte
  - Klausurzulassung bei 50% der erreichbaren Punkte
  - Klausurzulassungen aus vorherigen Semestern übertragbar (Email an {oezcep}(at)ifis.uni-luebeck.de)
  - Aktueller Punktestand unter Bewertungen im Moodle-Kurs
- Klausur
  - Alles aus der Vorlesung klausurrelevant; Ausnahmen werden in der Vorlesung oder in der Übung bekannt gegeben.
  - Schriftlich, benotet (80 Punkte, 40 zum Bestehen)
  - Anmeldung zur Klausur zum Ende des Semesters im Moodle Kurs

Literatur

A. Kemper, A. Eickler,
Datenbanksysteme: Eine Einführung,
9. Auflage, Oldenbourg Verlag, 2013.

R. Elmasri, S.B. Navathe,
Grundlagen von Datenbanksystemen: Bachelor-Ausgabe,
3. überarbeitete Auflage, Pearson Studium, 2009.

Ausblick über IFIS Module

- **Bachelor-Programm**
  - Algorithmen und Datenstrukturen
  - Datenbanken
  - Non-Standard-Datenbanken
  - Einführung in Web und Data Science
  - Neu ab SoSe 2021: Logikprogrammierung
- **Master-Programm**
  - Informationssysteme
  - Webbasierte Informationssysteme
  - Datenmanagement
    - Mobile und verteilte Datenbanken
    - Semantic Web
  - Web und Data Science/Intelligente Agenten
    - Web-Mining Agents

Kapitel 1: Einführung

Kennzeichen von Daten in Datenbanken

- lange Lebensdauer (Jahre, Jahrzehnte)
- reguläre Strukturen
- große Datenobjekte, große Datenmengen
- stetig anwachsende integrierte Bestände (Giga-, Tera-, Petabyte)

Decimal		
Value		SI
1000	k	kilo
1000^2	M	mega
1000^3	G	giga
1000^4	T	tera
1000^5	P	peta
1000^6	E	exa
1000^7	Z	zetta
1000^8	Y	yotta

Modelle und Abstraktion

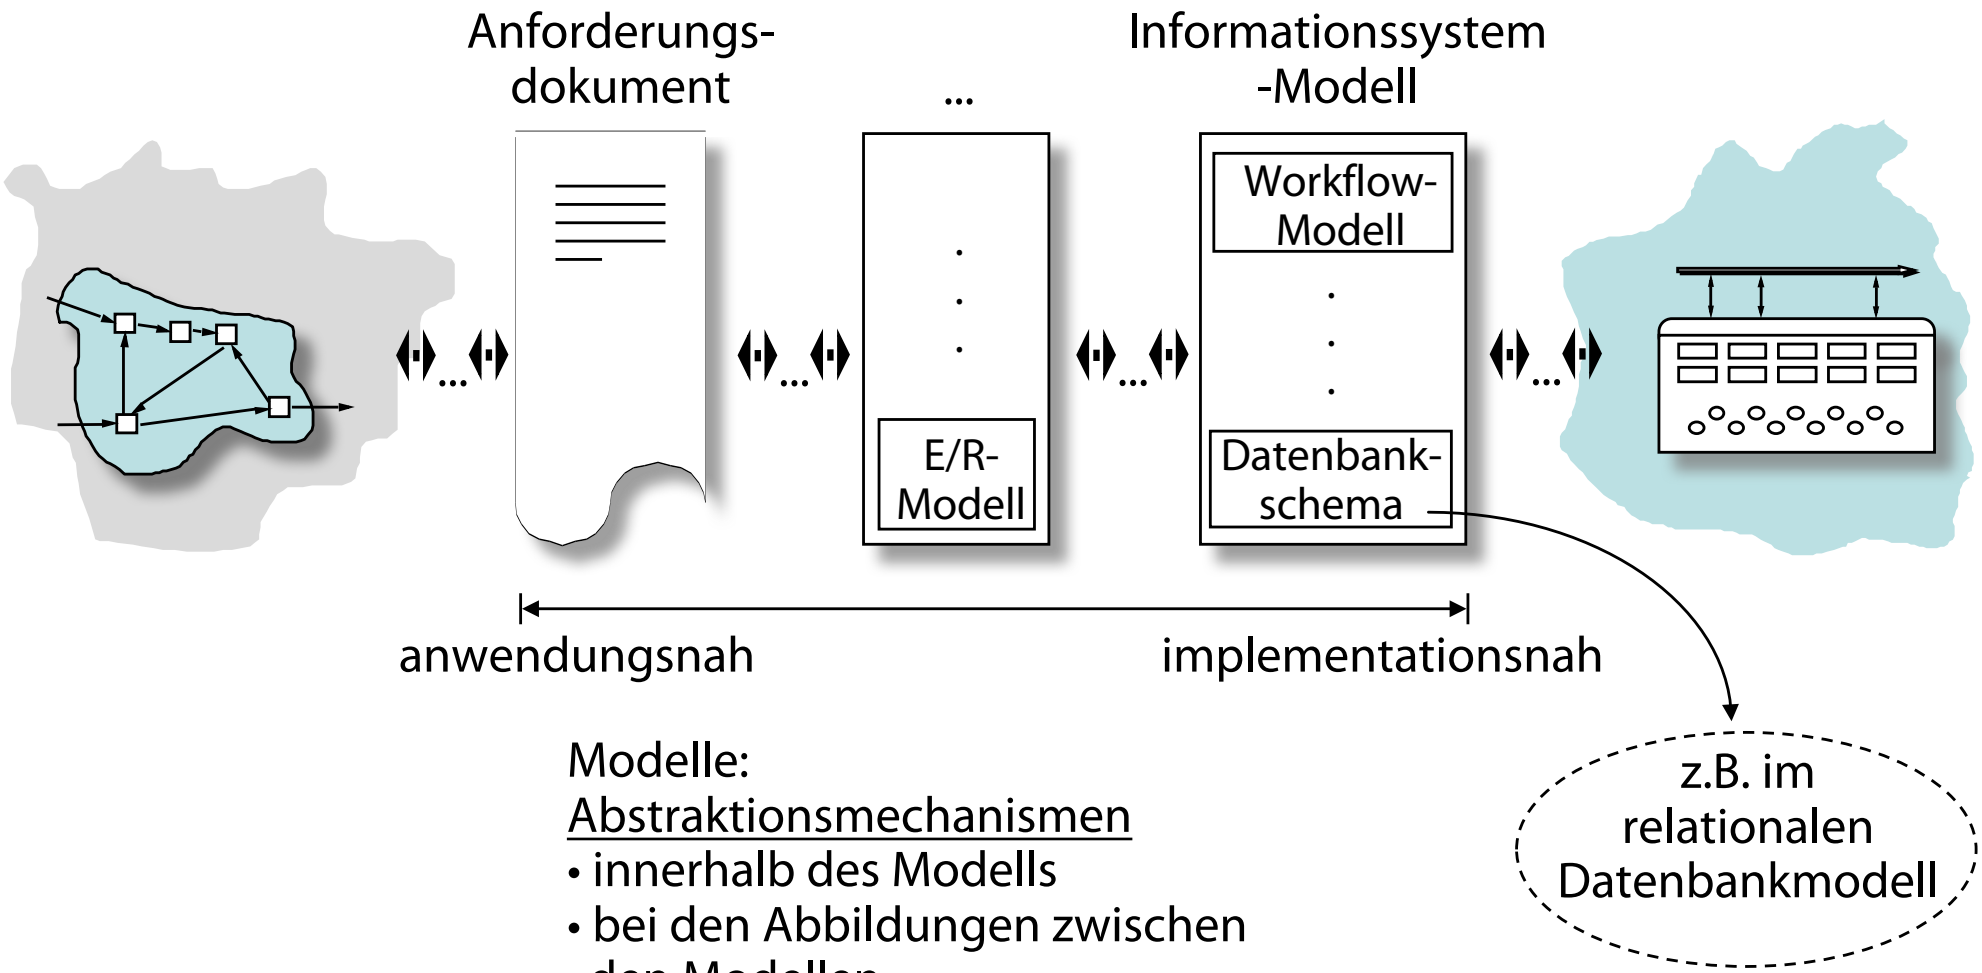

Modelle:
Abstraktionsmechanismen
- innerhalb des Modells
- bei den Abbildungen zwischen den Modellen

P. Chen, The Entity-Relationship Model - Toward a Unified View of Data, ACM Transactions on Database Systems 1 (1), pp. 9–36, 1976

E. F. Codd, A Relational Model of Data for Large Shared Data Banks, Communications of the ACM, Vol. 13, No. 6, June 1970, pp. 377-387, 1970

Bild Christoph Niemann: Abstraktometer

Erstes Beispiel einer (relationalen) Datenbank

- Datenbank für Inventar eines Weinkellers

Tabelle Weinkeller

Gestell	Sorte	Jahrgang	Anzahl_Flaschen
2	Franken	2009	5
1	Baden	2006	3
4	Rheinhessen	2007	10
1	Mosel	2013	2
2	Franken	2010	10

E. F. Codd, A Relational Model of Data for Large Shared Data Banks, Communications of the ACM, Vol. 13, No. 6, June 1970, pp. 377-387, 1970

Erste Anfrage

Info zu

Gestell, Sorte, Jahrgang von Weinen,

von denen der Weinkeller mindestens 4 Flaschen besitzt

Weinkeller

Gestell	Sorte	Jahrgang	Anzahl_Flaschen
2	Franken	2009	**5**
1	Baden	2006	3
4	Rheinhessen	2007	**10**
1	Mosel	2013	2
2	Franken	2010	**10**

```
SELECT Gestell, Sorte, Jahrgang
FROM   Weinkeller
WHERE Anzahl_Flaschen >= 4
```

Gestell	Sorte	Jahrgang
2	Franken	2009
4	Rheinhessen	2007
2	Franken	2010

Datenbanksysteme

Realisierung eines Informationssystems mit einer Datenbank:

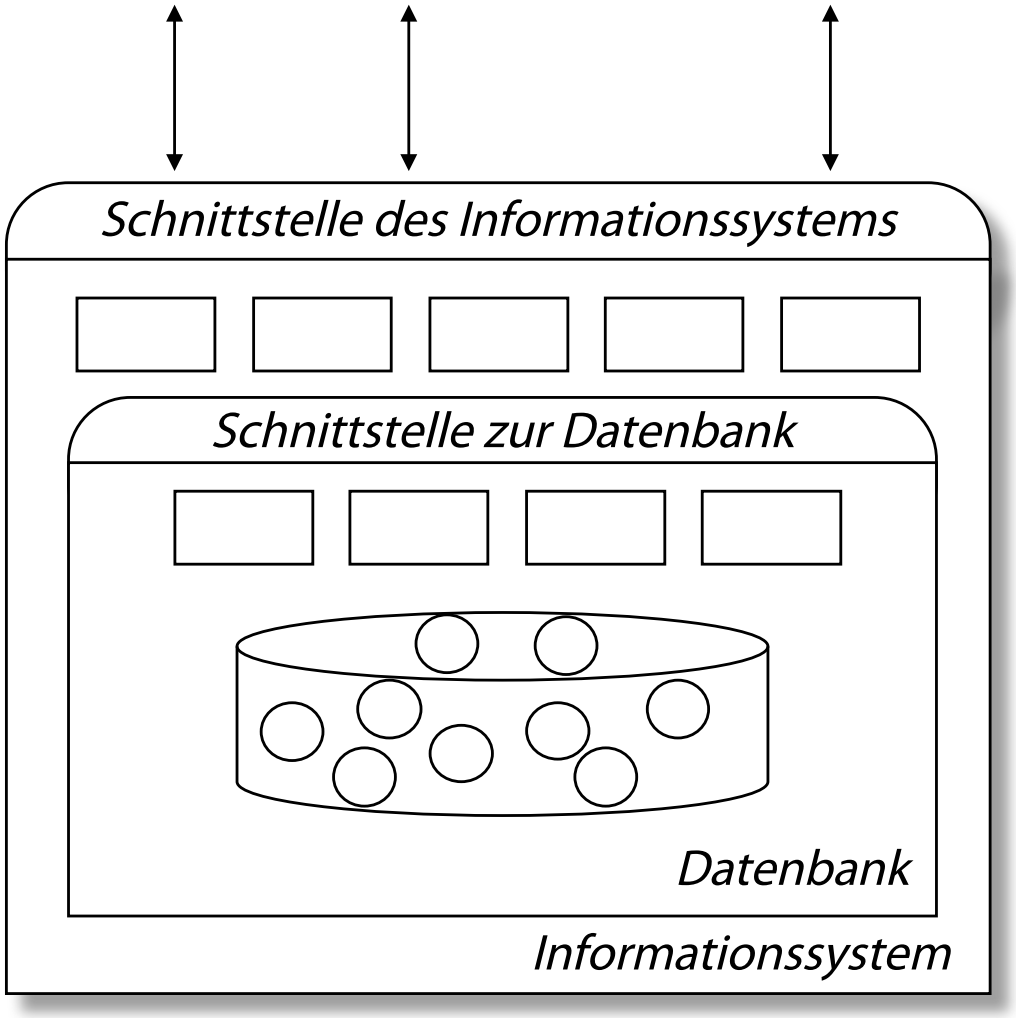

Algorithmen zur Informationsdarstellung, -verarbeitung und zur Integritätssicherung

Dienste des Datenbanksystems zur Datenspeicherung, -anfrage und Integritätssicherung (Datenbankschema)

Datenbankzustand

Generisches Datenbankmodell und -system

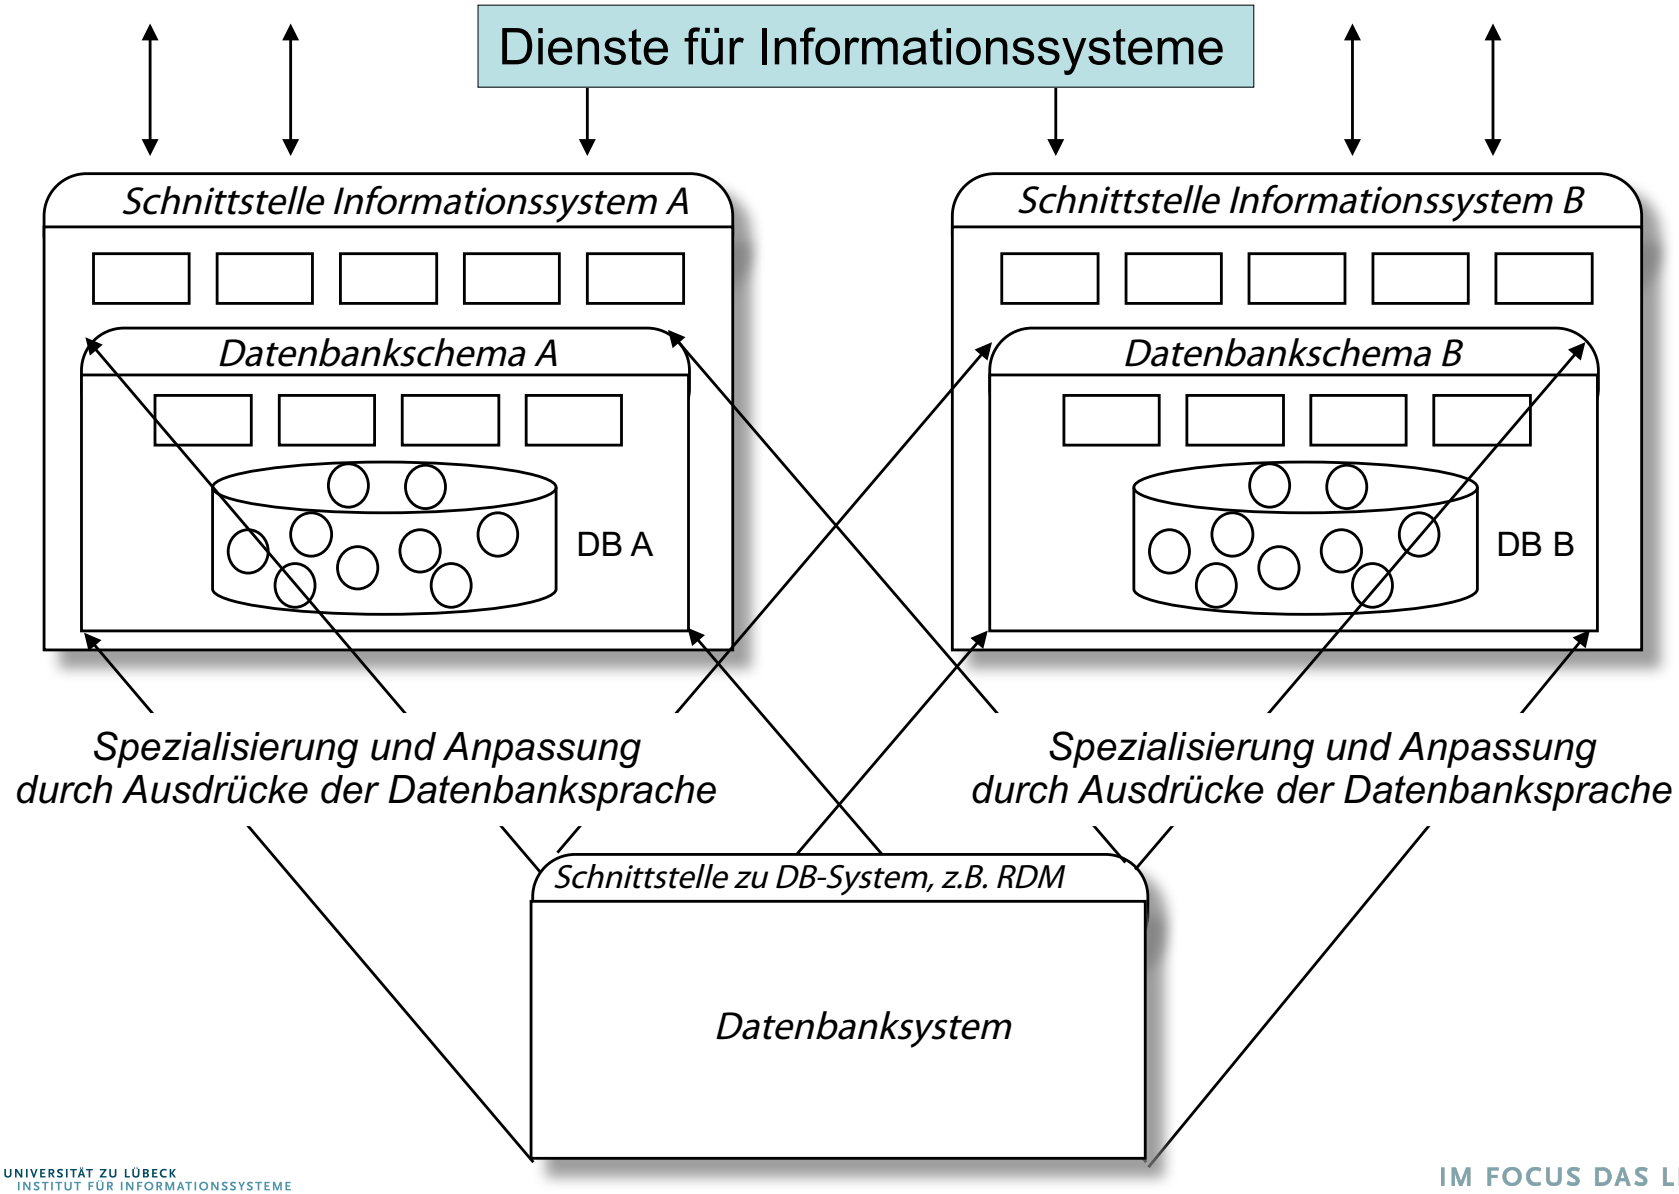

Sichten: DB-Subschemata und Subdatenbanken

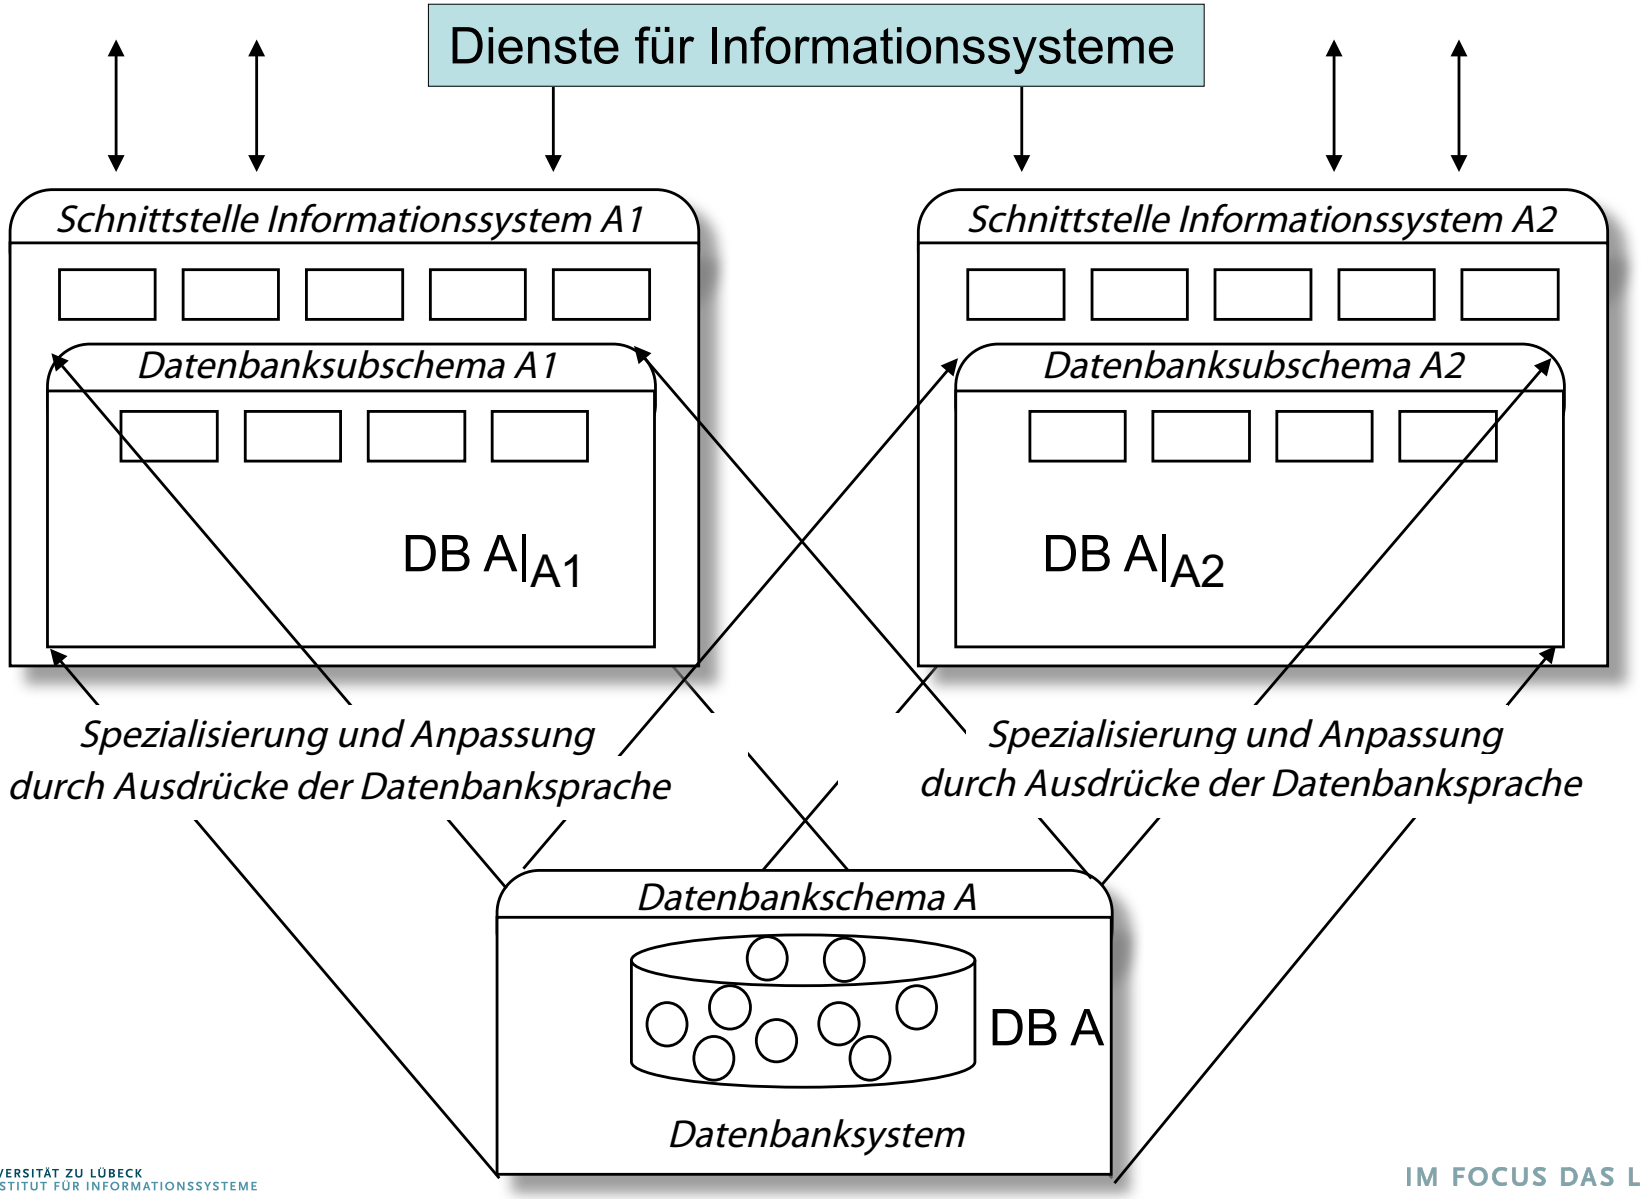

ANSI-SPARC-Architektur

ANSI: American National Standards Institute
SPARC: Standards Planning and Requirement Committee

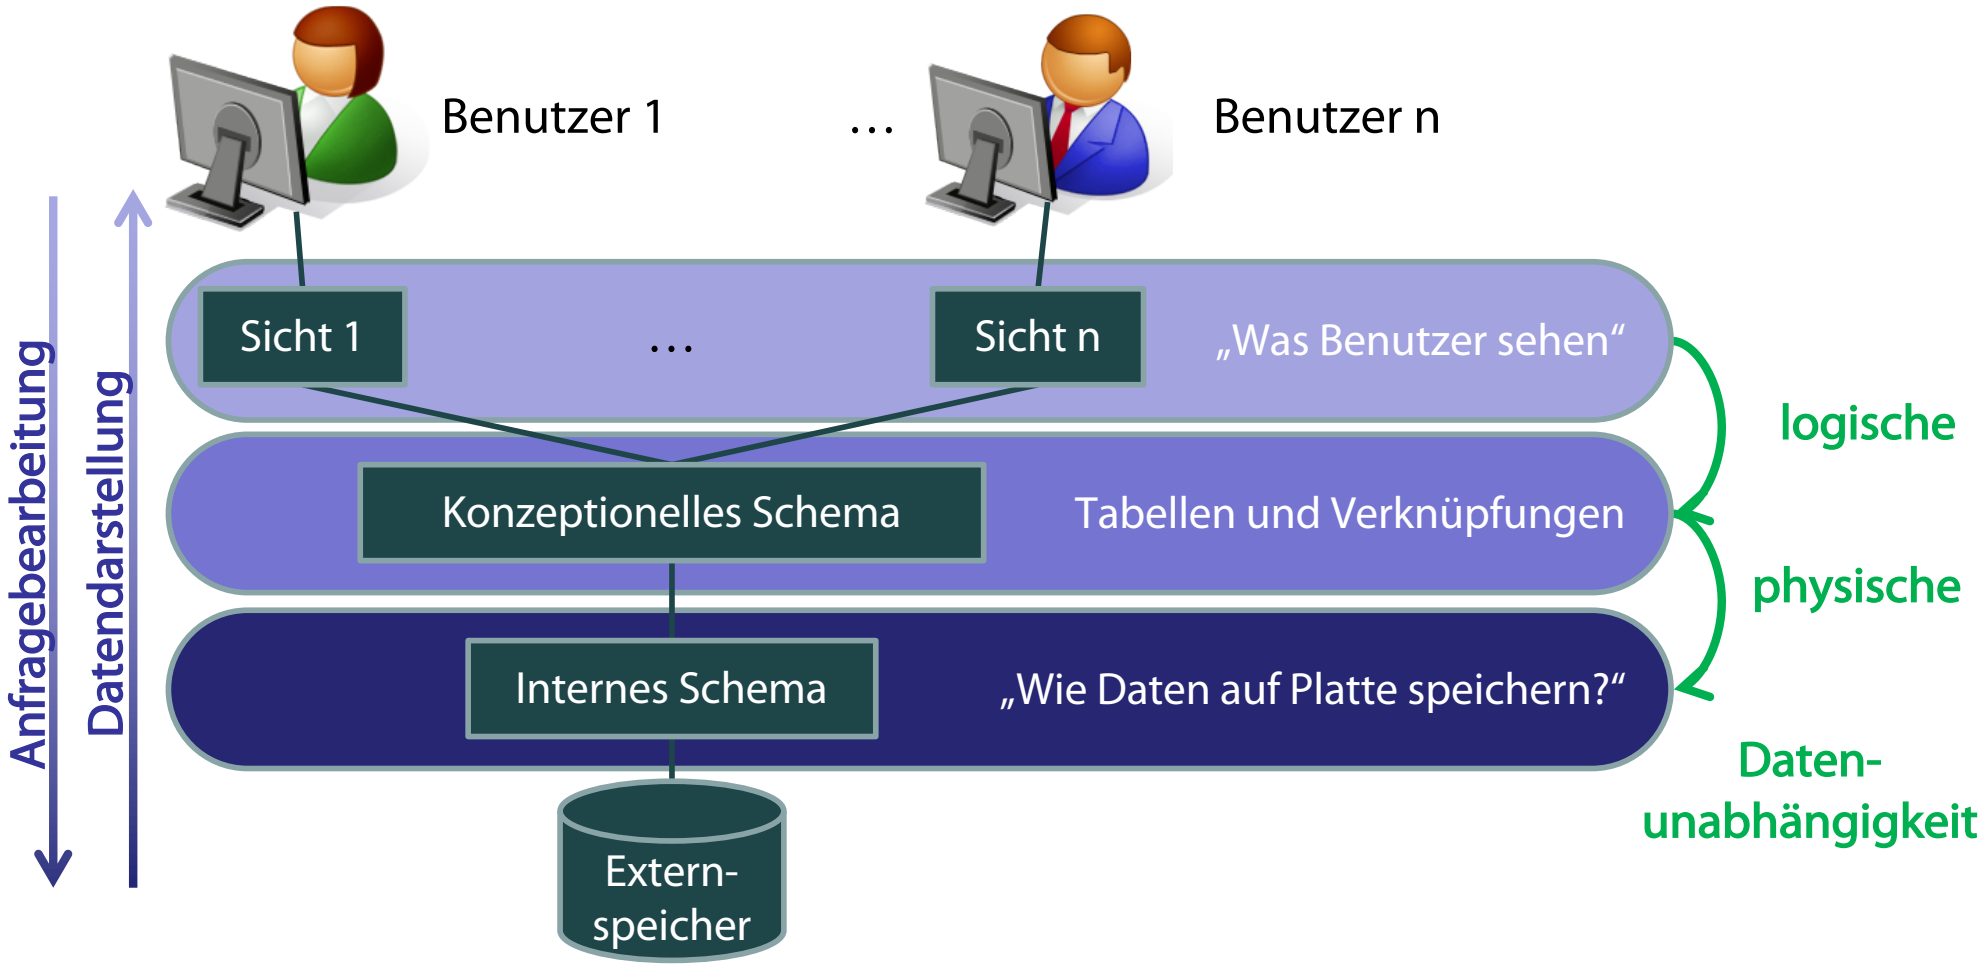

Jede Schicht ist unabhängig von deren unteren Schichten

ANSI/X3/SPARC Study Group on Data Base Management Systems, Interim Report. FDT, ACM SIGMOD bulletin. Volume 7, No. 2, 1975

Final report of the ANSI/X3/SPARC DBS-SG relational database task group. M. Brodie, J.W. Schmidt (Ed.), SIGMOD Rec. 12, 4, 1982

Datenunabhängigkeit

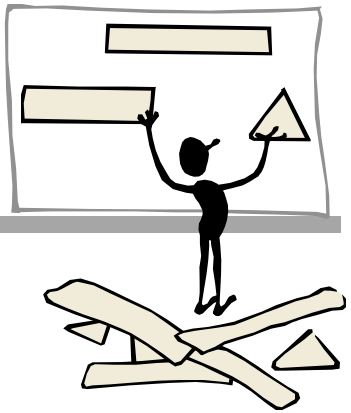

- Logisch
  - Konzeptionelles Schema kann (bedingt) geändert werden, ohne die Sichten zu verändern
    - Hinzufügen von Attributen und Tabellen zum konzeptionellen Schema
    - Verändern der Tabellenstruktur
- Physisch
  - Internes Schema kann geändert werden, ohne konzeptionelles Schema zu verändern
    - Veränderung des Speicherortes
    - Änderung des Speicherformates
    - Anlegen/Löschen von Indizes (für Anfrageoptimierung)

Kapitel 2: Entity-Relationship-Modellierung

- Objekte (Entitäten) mit ähnlichen Eigenschaften können zu Mengen (Entitätstypen, Klassen) zusammengefasst werden.
- Jedes Objekt ist "Instanz" einer oder mehrerer Klassen.
- Extension (Menge aller Instanzen einer Klasse)
- Objekte können in Beziehung gesetzt werden (Beziehungstyp, Relationship)

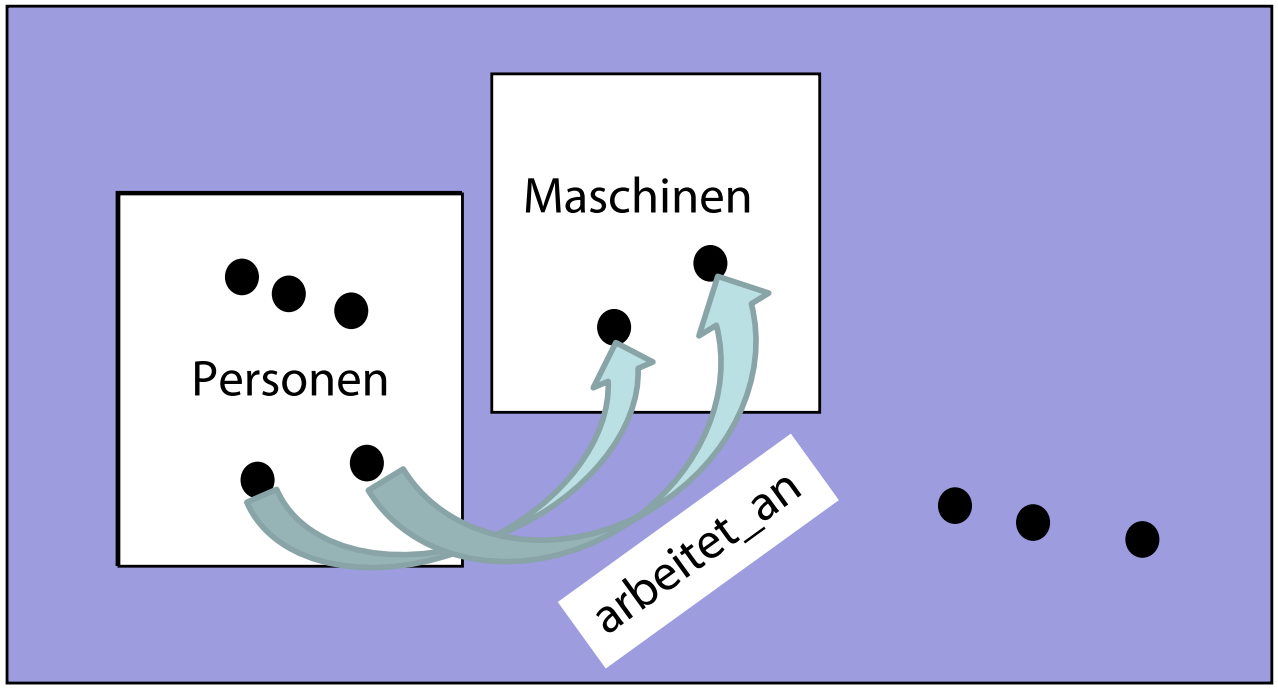

Grundlegende Elemente von ER-Diagrammen

- Objekttyp  (auch Entitätstyp oder Klasse genannt, Menge von Objekten)
- Werttyp 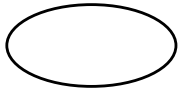 (für Basisdatentypen, Menge von „Werten“ bzw. Literale)
- Beziehungstyp 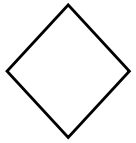 (Menge von Tupeln von Objekten)
- Die Elemente von ER-Diagrammen bilden einen bipartiten Graphen:

Verbindungen zwischen Symbolen der gleichen Typen sind nicht erlaubt.

P. Chen, The Entity-Relationship Model - Toward a Unified View of Data, ACM Transactions on Database Systems 1 (1), pp. 9–36, 1976

Objekte/Entitäten und Attribute

Beispiele:

- Ein Projekt wird beschrieben durch
  - eine Nummer
  - einen Titel
  - das Budget

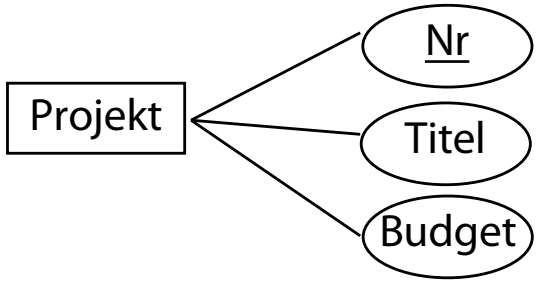

- Mathematische Bedeutung von „Projekt“: Menge von Tupeln von Werten
- Ein Tupel kann als „Aggregat“ von Basiswerten aufgefasst werden.

- Tupel können durch bestimmte Attribute eindeutig gekennzeichnet sein
  - In der Graphik sind diese Attribute unterstrichen
  - Wir nennen die Attribute „Schlüssel“
  - Mehr dazu gleich

Generalisierung und Spezialisierung (1)

- **Spezialisierung** bezeichnet die Verfeinerung einer Klasse (mehr Information/Anforderungen bzgl. der jeweiligen Individuen)
- **Generalisierung** ist die Vergröberung einer Klasse (weniger Information/Anforderungen bzgl. der jeweiligen Individuen)
- Spezielle Klassen (**Subklasse**) und allgemeine Klassen (**Superklasse**) bilden eine Subklassenhierarchie
  (→ Subtypisierung, Typhierarchie)
- **Instanzen** einer Klasse sind auch Instanzen der Superklasse
- Instanzen von Subklassen „**erben**“ die Eigenschaften der Superklasse und fügen evtl. neue hinzu
  (→ Vererbung von Beschreibungen für Tupelkomponenten)

Generalisierung und Spezialisierung (2)

Graphische Notation variiert

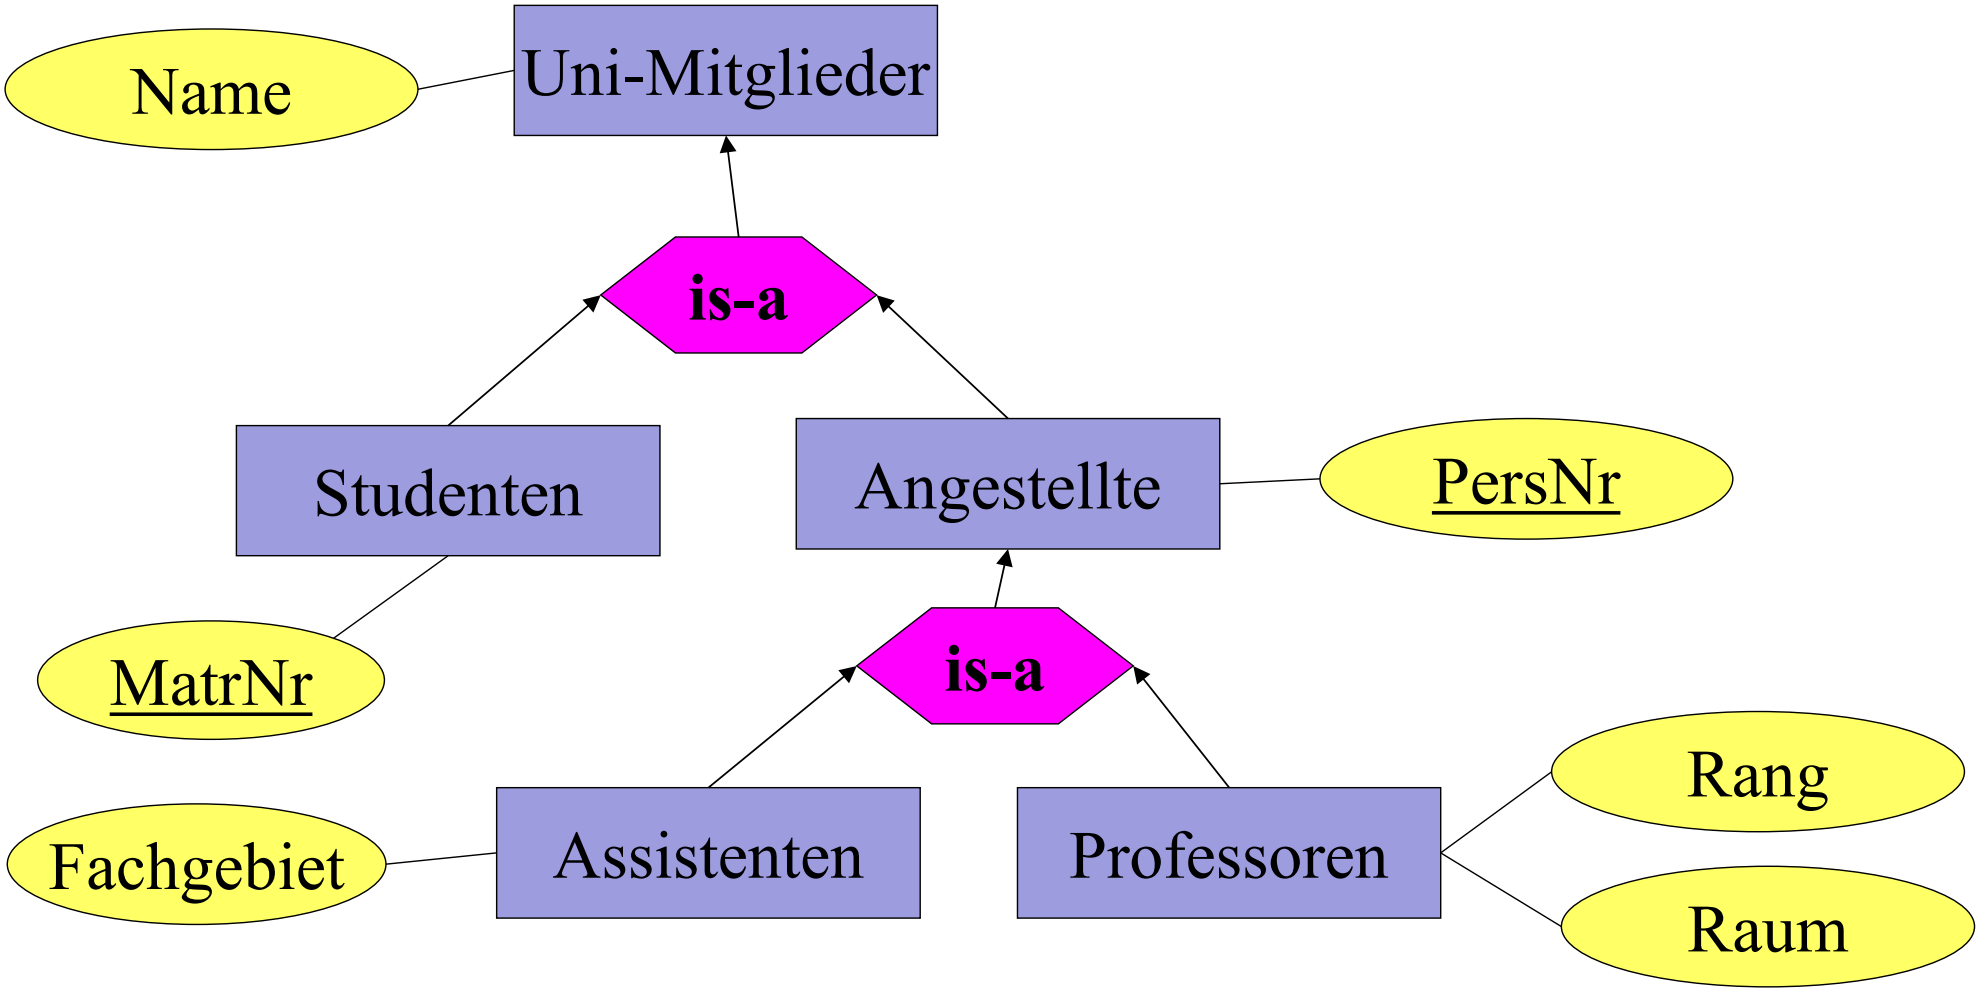

Generalisierung und Spezialisierung (3)

Erweiterte Entity-Relationship-Diagramme

Beispiel:

- Festangestellte und Werksstudenten sind Mitarbeiter.

  Festangestellte sind keine Werksstudenten
- Festangestellte haben die zusätzlichen Eigenschaften Gehalt und Einstelldatum.
- Werksstudenten haben die zusätzlichen Eigenschaften Beginn, Dauer und Vergütung

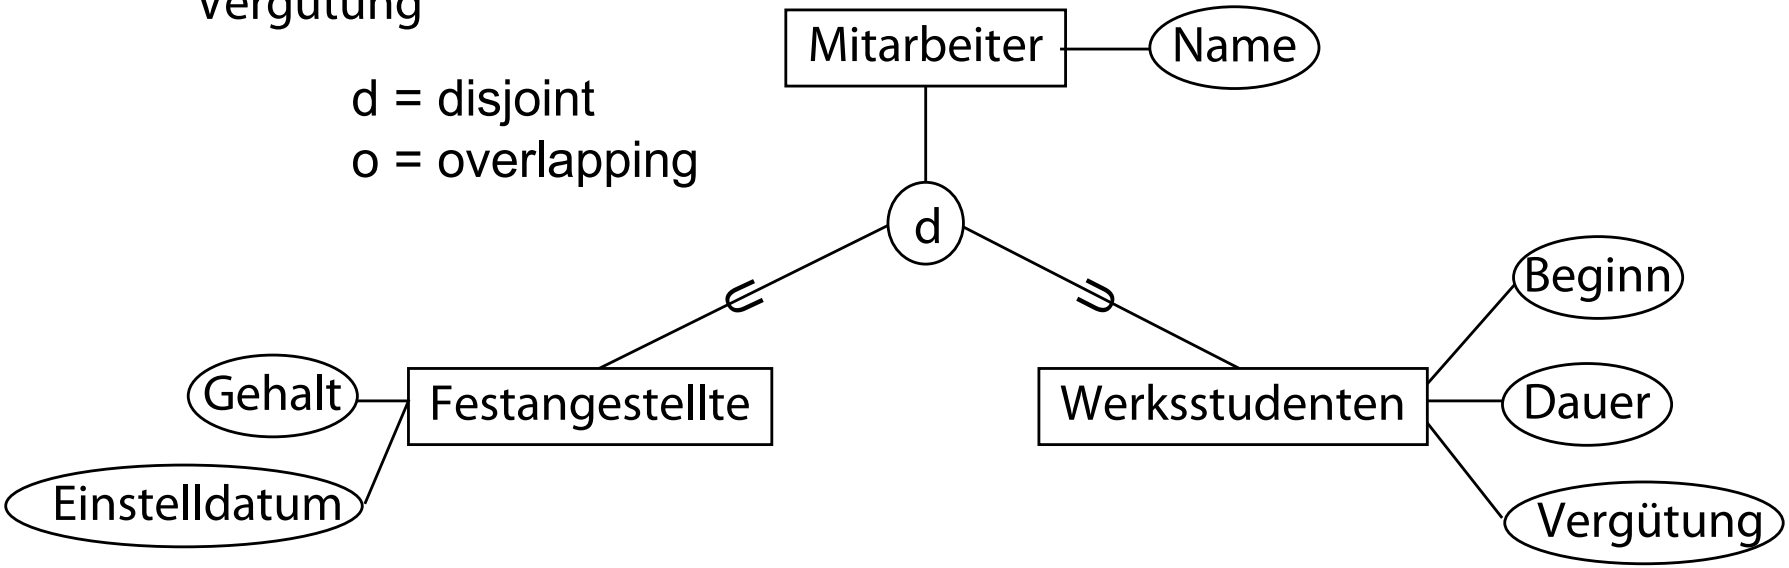

Generalisierung und Spezialisierung (4)

Erweiterte Entity-Relationship-Diagramme

Beispiel:

- Festangestellte und Werksstudenten sind Mitarbeiter.

  Festangestellte sind keine Werksstudenten
- Die Menge der Mitarbeiter ist gleich der (disjunkten) Vereinigung der Mengen Festangestellte und Werksstudenten, d.h. ein Mitarbeiter ist entweder festangestellt oder Werksstudent

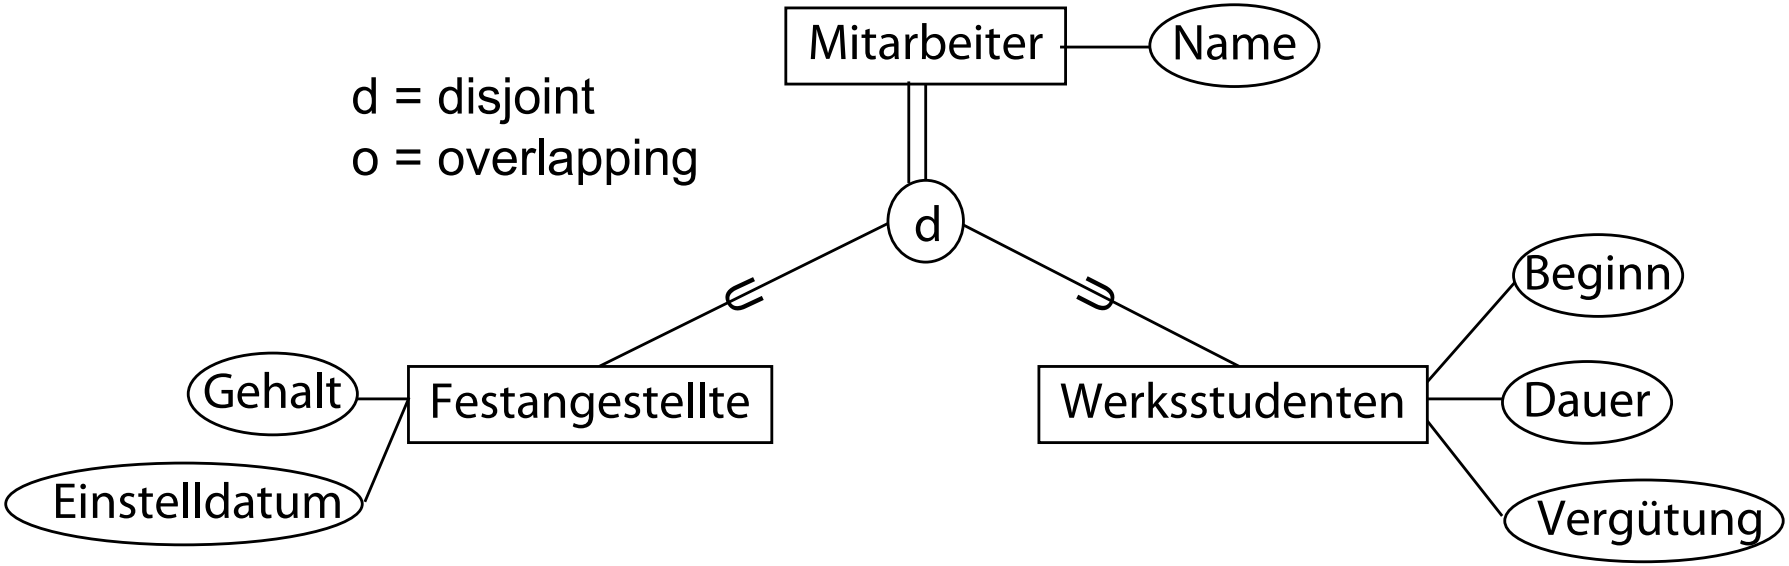

Assoziation / Relationship

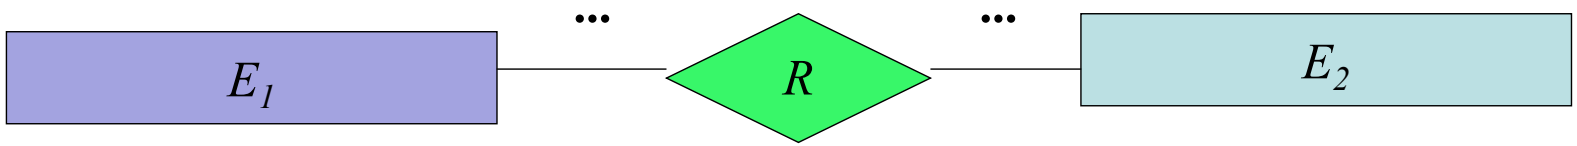

$$R \subseteq E_1 \times E_2$$

- Objekte können miteinander in Beziehung gesetzt (assoziiert) werden:
  - Binäre (ternäre, ...) Beziehungen assoziieren zwei (drei, ...) Klassen oder Objekte
  - Allgemein: n-äre Beziehungen zwischen n Klassen oder Objekten, wobei n der Grad der Beziehung ist
- Funktionalitätsangaben definieren Einschränkungen (siehe Bilder)

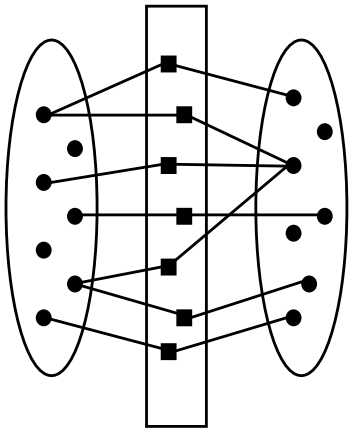

n:m

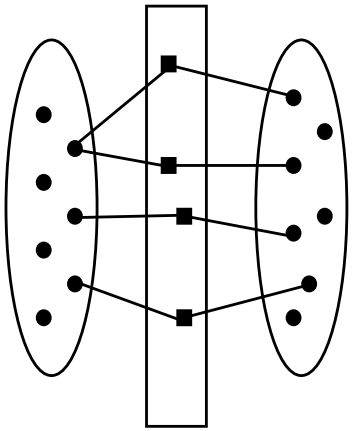

1:n

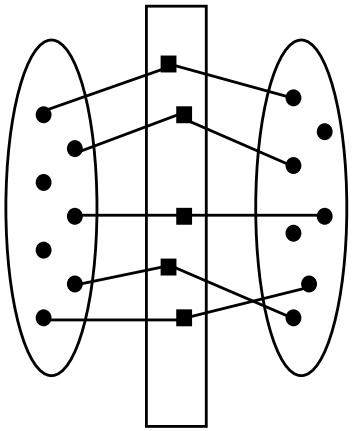

1:1

Assoziation / Relationship

Beispiele:

- Projekte werden von Abteilungen durchgeführt. Jedes Projekt muss (genau) einer Abteilung zugeordnet sein. Eine Abteilung kann mehrere Projekte ausführen.

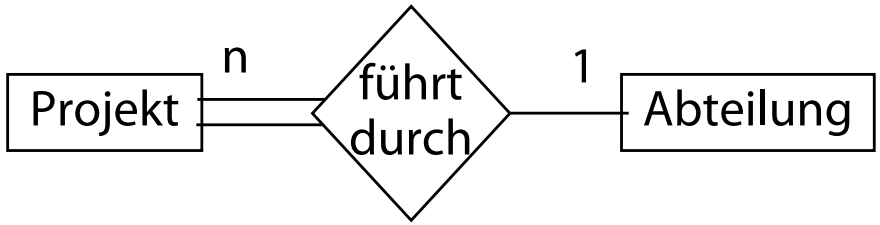

- An Projekten arbeiten Mitarbeiter. Ein Mitarbeiter kann an mehreren Projekten arbeiten. Jedes Projekt wird von beliebig vielen Mitarbeitern bearbeitet.

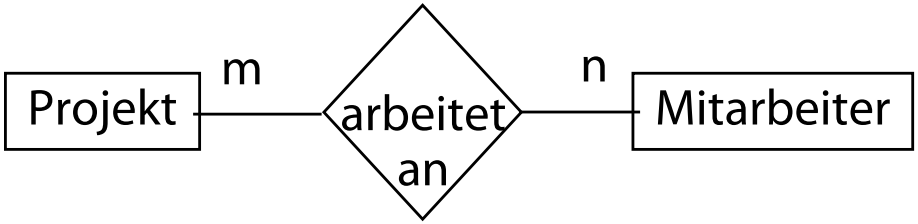

- Bemerkung:
  In der Literatur findet man auch andere Beschriftungsregeln.

Assoziation / Relationship

- **Totale Partizipation**: Jede Instanz einer Klasse muss mit einer Instanz der zweiten Klasse in Beziehung stehen (====)
- **Partielle Partizipation**: Eine Instanz einer Klasse kann in Beziehung zu einer Instanz der zweiten Klasse stehen (--------)
- Rollennamen (Namen für die Argumente der Relation) identifizieren die Menge der Instanzen, die mit einer anderen Instanz in Beziehung stehen.
- Rollen können als abgeleitete Attribute verstanden werden, die die Menge der Instanzen als Attributwerte besitzen.

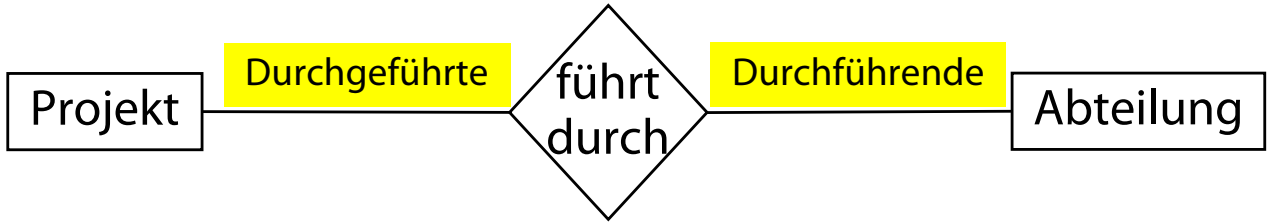

Lernziel 1:

- Gegeben: "Anforderungsdefinition"

> - An einer Universität werden verschiedene Vorlesungen angeboten, die Teil mehrerer Studienfächer sind.
> - Diese Vorlesungen werden von genau einem Dozenten gehalten.
> - Jeder Dozent ist Mitglied genau eines Fachbereiches.
> - Ein Fachbereich hat mehrere Studienfächer.
> - Die Vorlesungen werden von Studenten gehört, die jeweils ein oder mehrere Studienfächer belegt haben.
> - Zu jeder Vorlesung werden mehrere Klausuren angeboten, die von den Studenten geschrieben werden.

- Gesucht: ER-Diagramm

Lernziel 1:

- Gegeben: "Anforderungsdefinition"

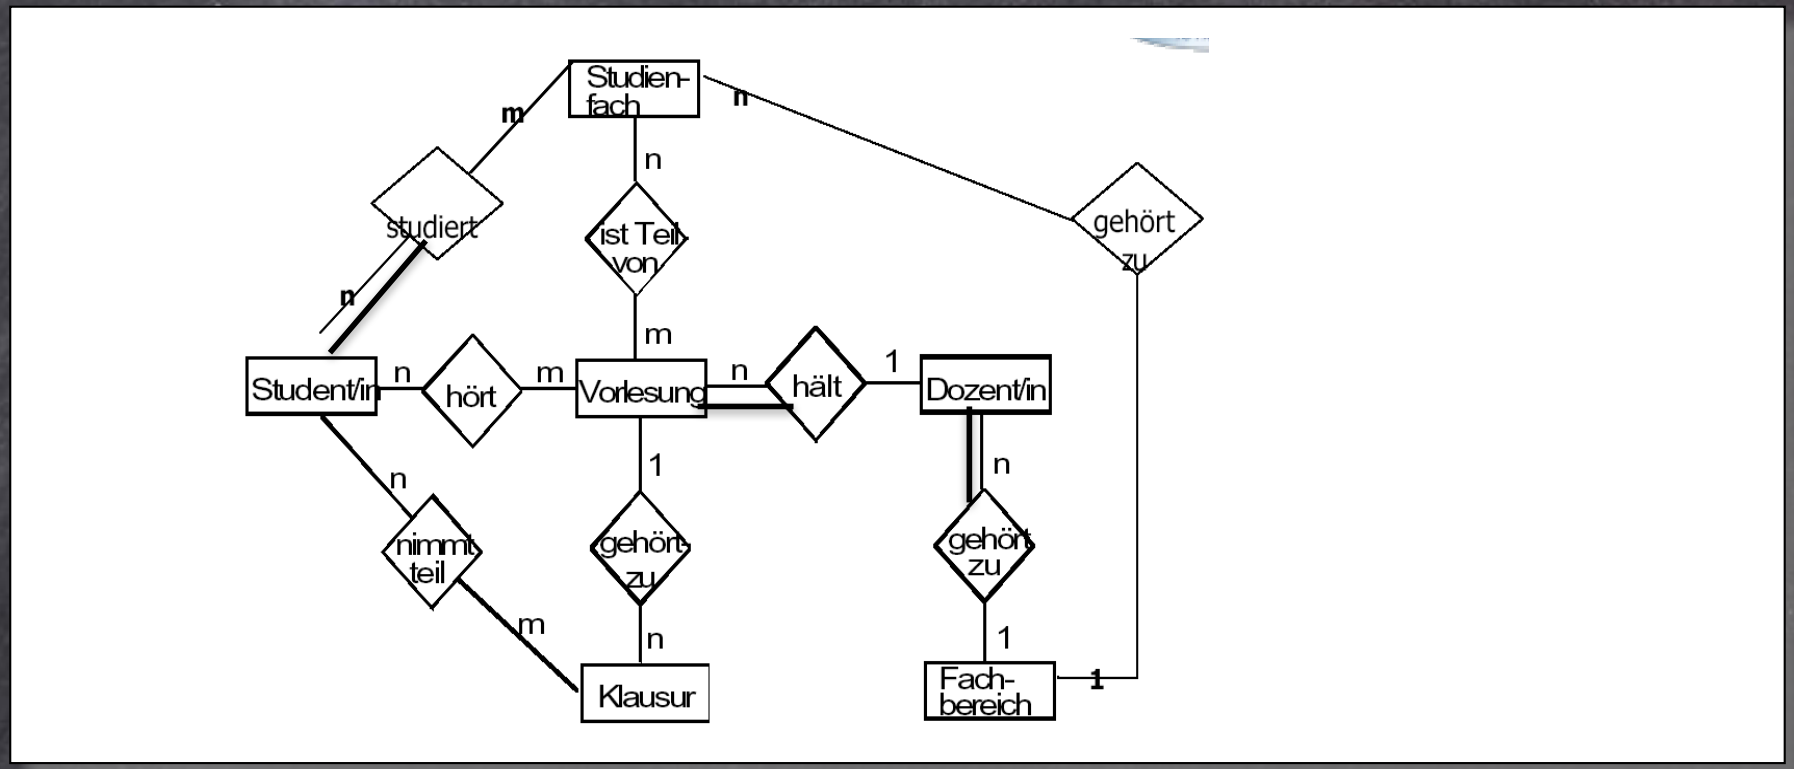

- Gesucht: ER-Diagramm

Lernziel 2: ER-Diagramm erläutern

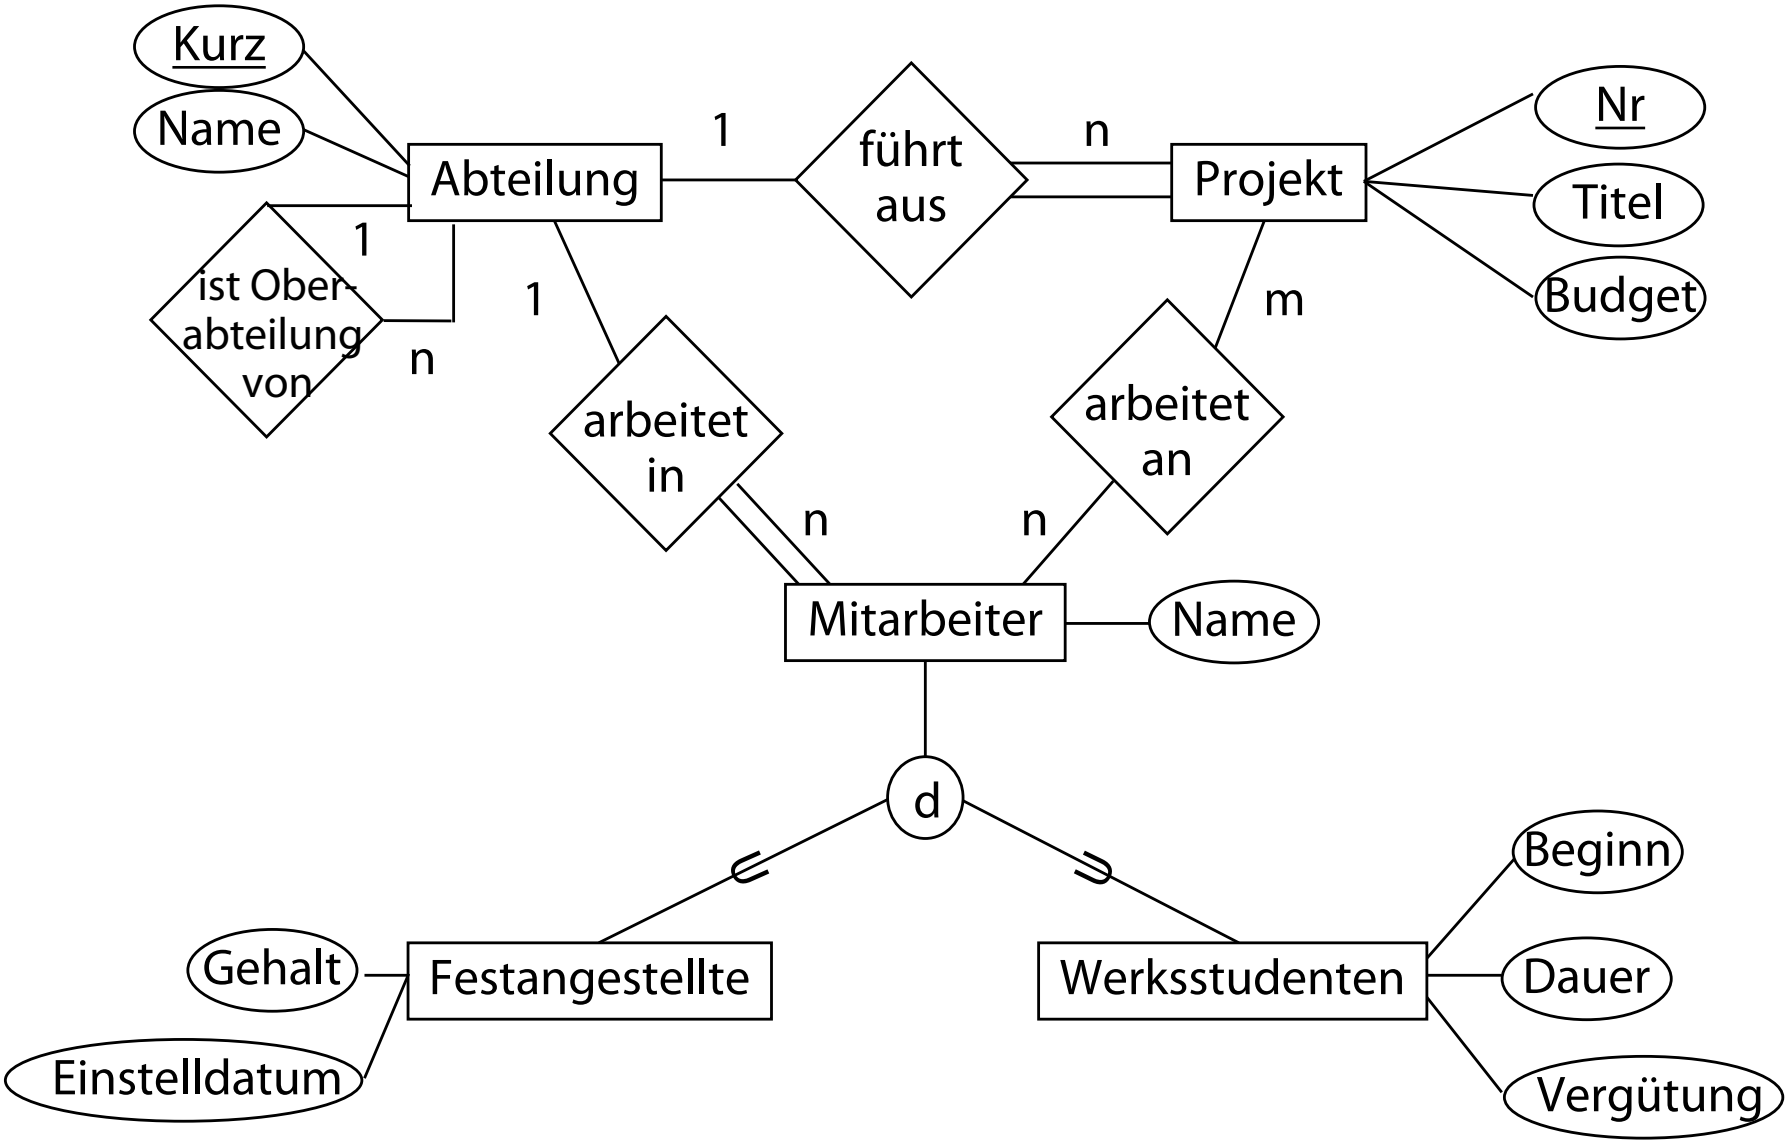

Aggregation und Dekomposition

- Objekte können zu übergeordneten Objekten aggregiert werden:
  - Beziehungen zwischen Komponenten und übergeordnetem Objekt
  - Übergeordnetes Objekt kann wiederum an Beziehungen teilnehmen.
- Im Vergleich zur "normalen" Assoziation wird die "Aggregation" in der Entity-Relationship-Modellierung nicht besonders unterstützt. Man verwende anwendungsspezifische Assoziationen

- Aggregation von Werten (z.B. Addition) werden gesondert behandelt

Aggregation (von Objekten)

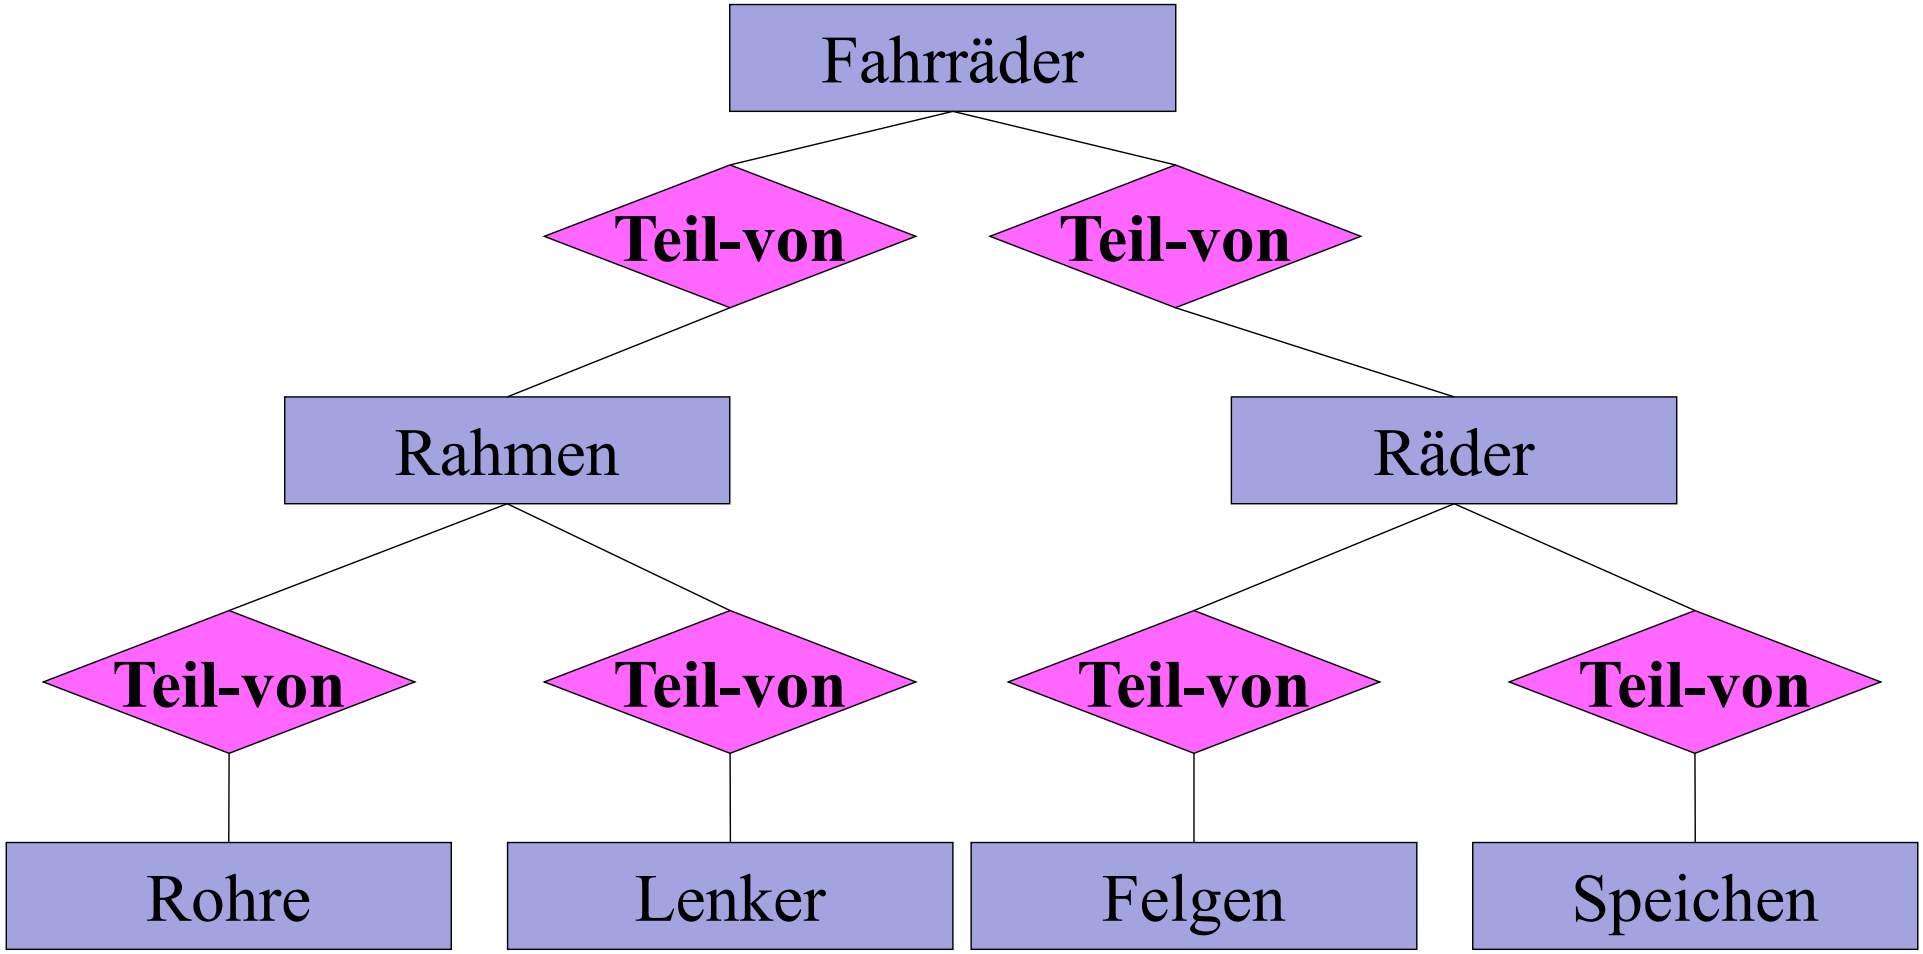

Identifikation und Schlüssel (1)

Zur **Identifikation** existieren zwei grundlegende Ansätze in Datenbankmodellen:

- **Referentielle Identifikation** bezeichnet direkte Verweise auf Objekte (→ Zeiger in Programmiersprachen).
- **Assoziative Identifikation** verwendet die Werte von Attributen oder Attributkombinationen, um sich eindeutig auf Objekte zu beziehen (→ Schlüssel: Ausweisnummer, Fahrgestellnummer, ...).
- In der Praxis benötigt man häufig beide Formen der Identifikation.

Schlüssel:

- Schlüssel sind Attribute oder Attributkombinationen mit innerhalb einer Klasse eindeutigen Werten und eignen sich deshalb zur Identifikation.
- Es kann mehrere Schlüsselkandidaten geben (Primärschlüssel, Sekundärschlüssel).
- Schlüssel stellen als Attributwerte Beziehungen zu anderen Objekten her (Fremdschlüssel).
- Durch Fremdschlüssel referenzierte Objekte müssen existieren (→ referentielle Integrität).

Identifikation und Schlüssel (2)

Beispiel: Projekte können durch eine Nummer eindeutig identifiziert werden.

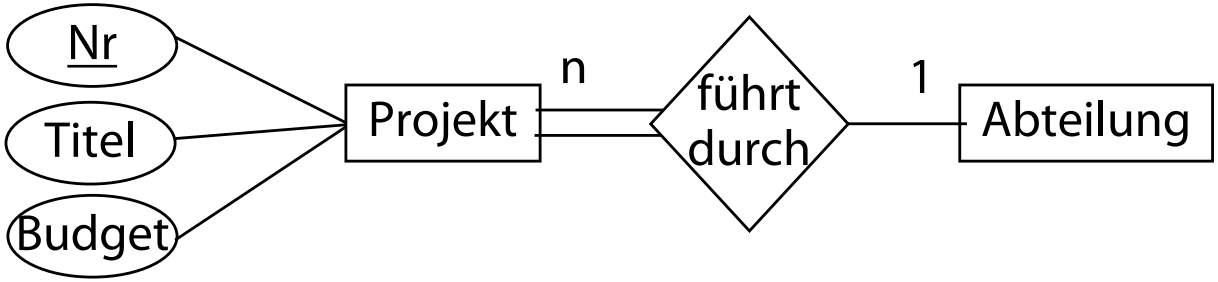

Dabei existieren zwei Möglichkeiten zur Identifikation von Projekten innerhalb der Assoziation "führt durch":

Referentielle Identifikation

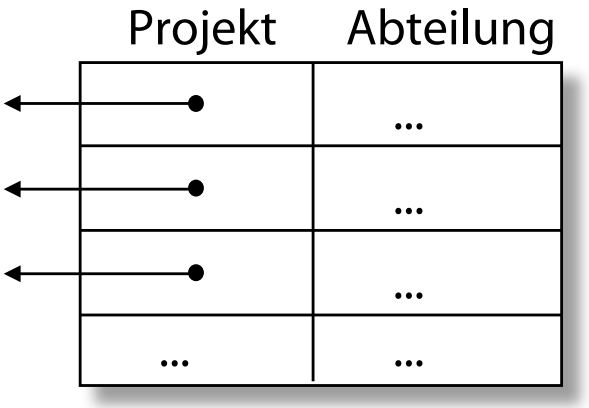

Assoziative Identifikation

Projekt	Abteilung
4711	...
4712	...
4713	...
....	...

Universitätsschema

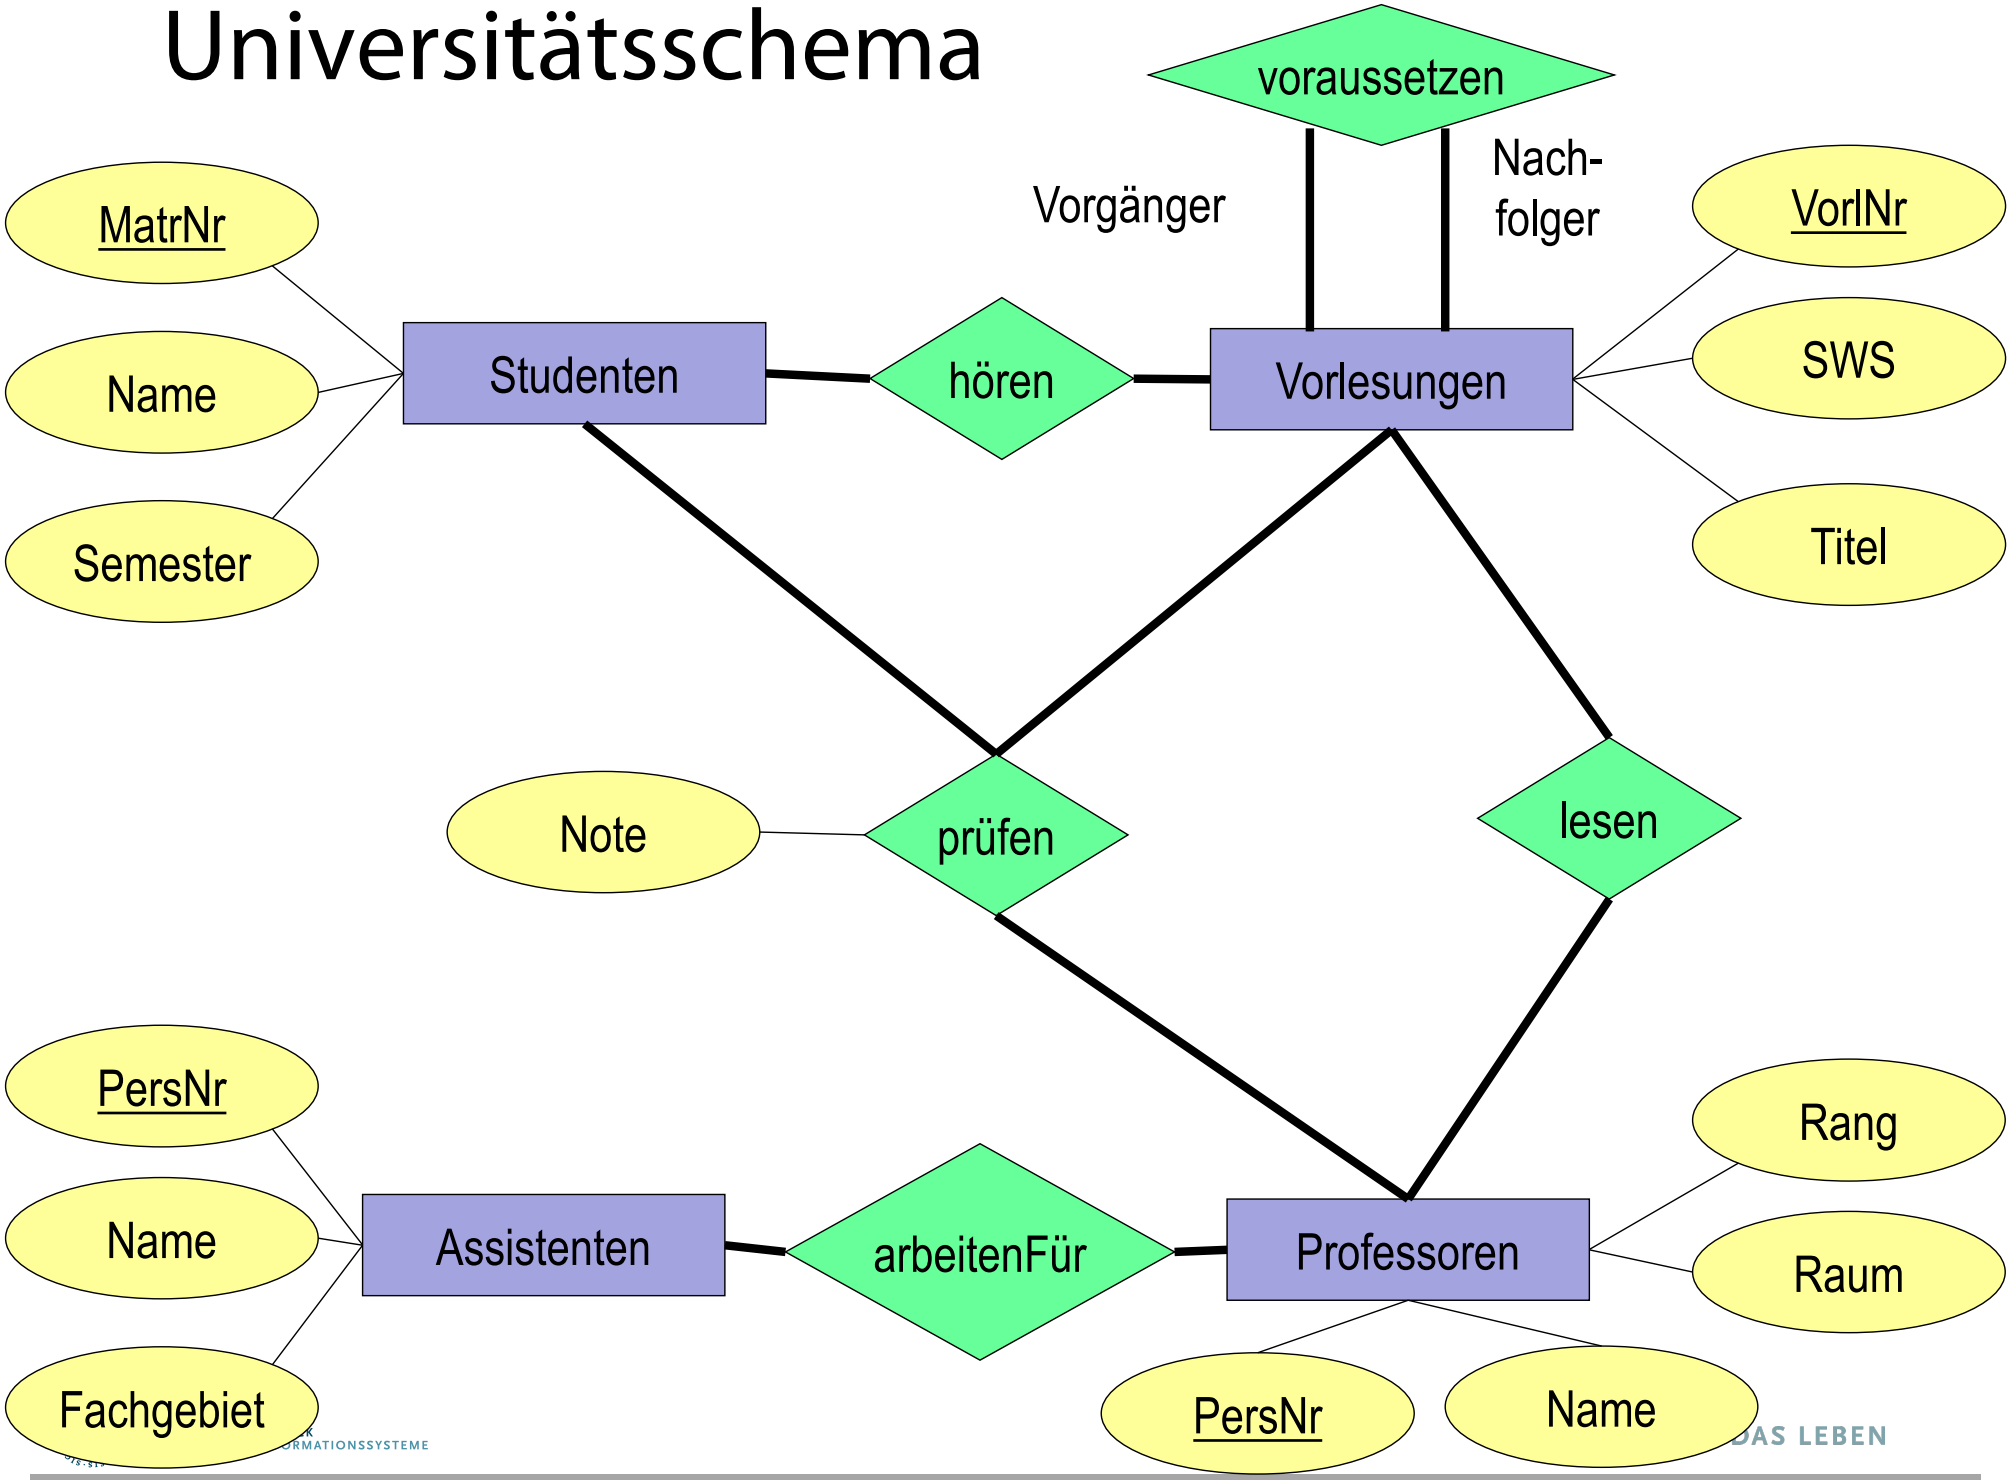

Funktionalitäten bei *n*-stelligen Beziehungen

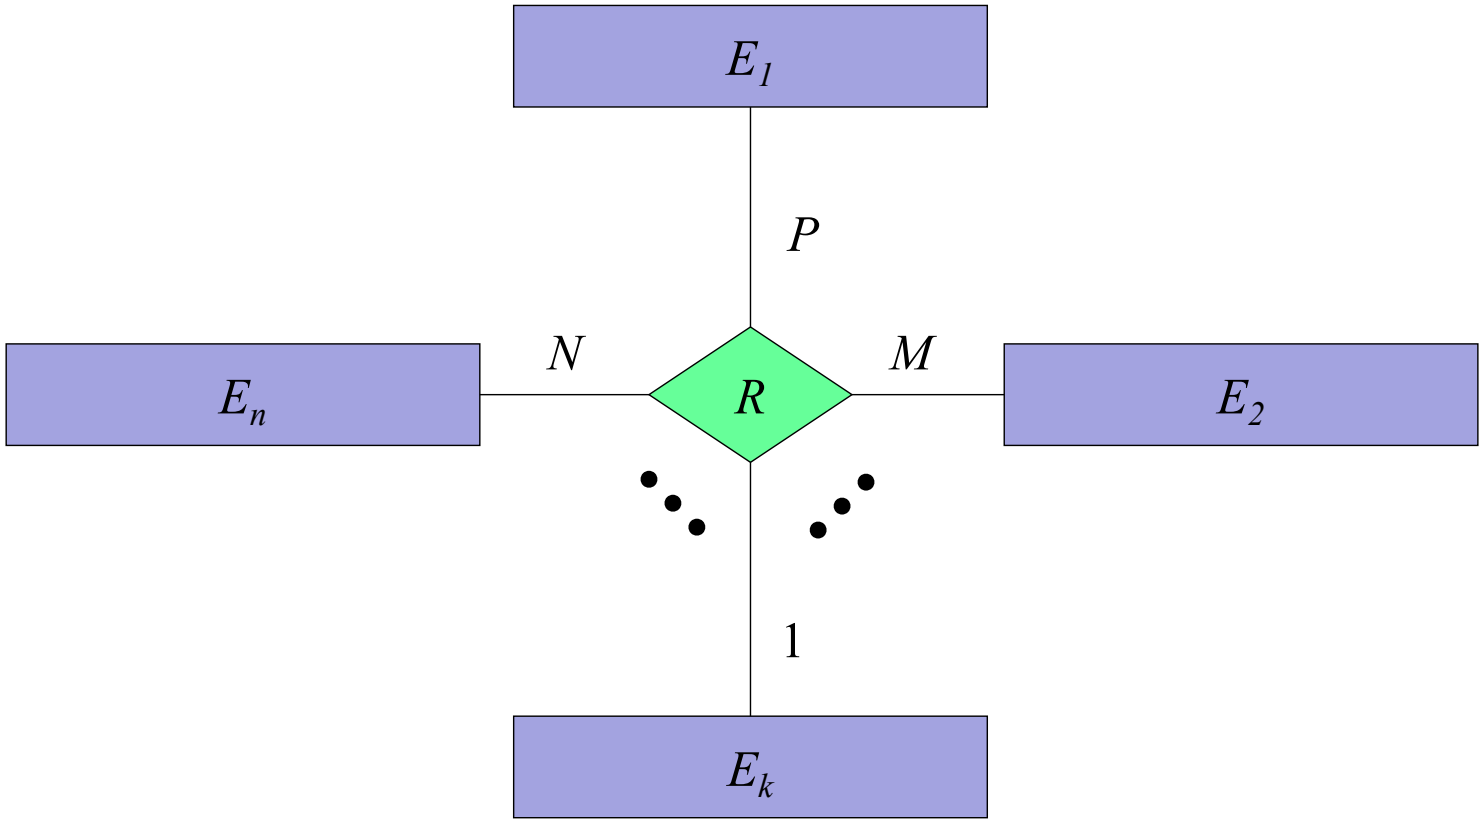

$$R : E_1 \times \ldots \times E_{k-1} \times E_{k+1} \times \ldots \times E_n \longrightarrow E_k$$

Beispiel-Beziehung: *betreuen*

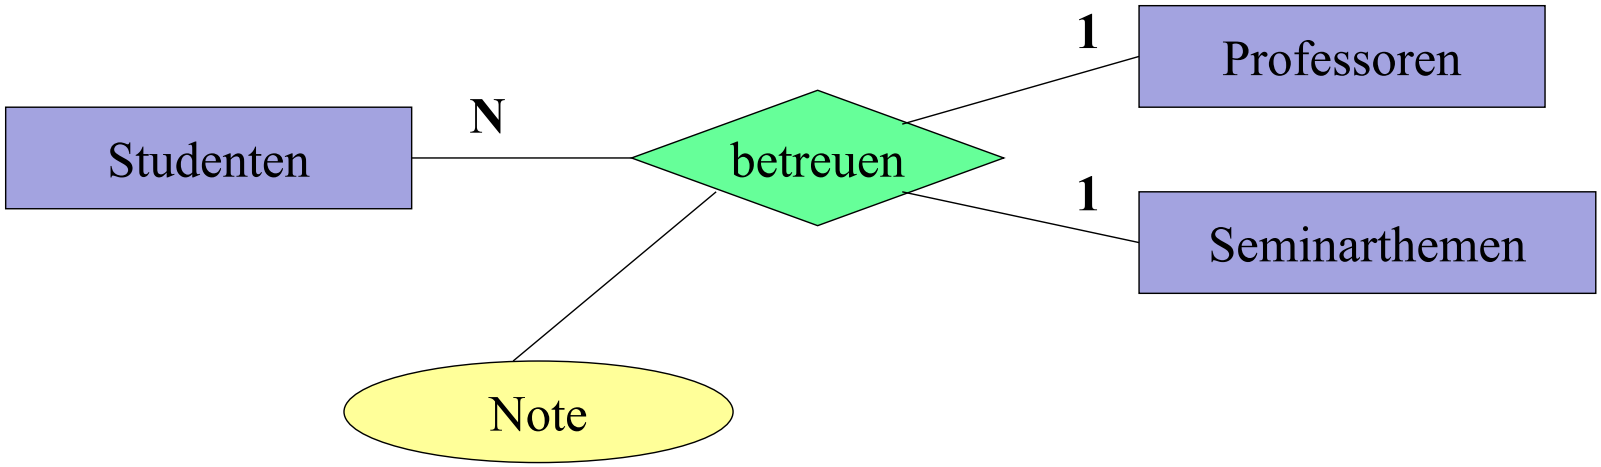

betreuen : Professoren x Studenten ⟶ Seminarthemen

betreuen : Seminarthemen x Studenten ⟶ Professoren

Dadurch erzwungene Konsistenzbedingungen

1. Studenten dürfen bei demselben Professor bzw. derselben Professorin nur ein Seminarthema "ableisten" (damit ein breites Spektrum abgedeckt wird).

2. Studenten dürfen dasselbe Seminarthema nur einmal bearbeiten – sie dürfen also nicht bei anderen Professoren ein schon einmal erteiltes Seminarthema nochmals bearbeiten.

Folgende Datenbankzustände nach wie vor möglich:

– Professoren können dasselbe Seminarthema „wiederverwenden“ – also dasselbe Thema auch mehreren Studenten erteilen.

– Ein Thema kann von mehreren Professoren vergeben werden – aber an unterschiedliche Studenten.

Funktionalitäten

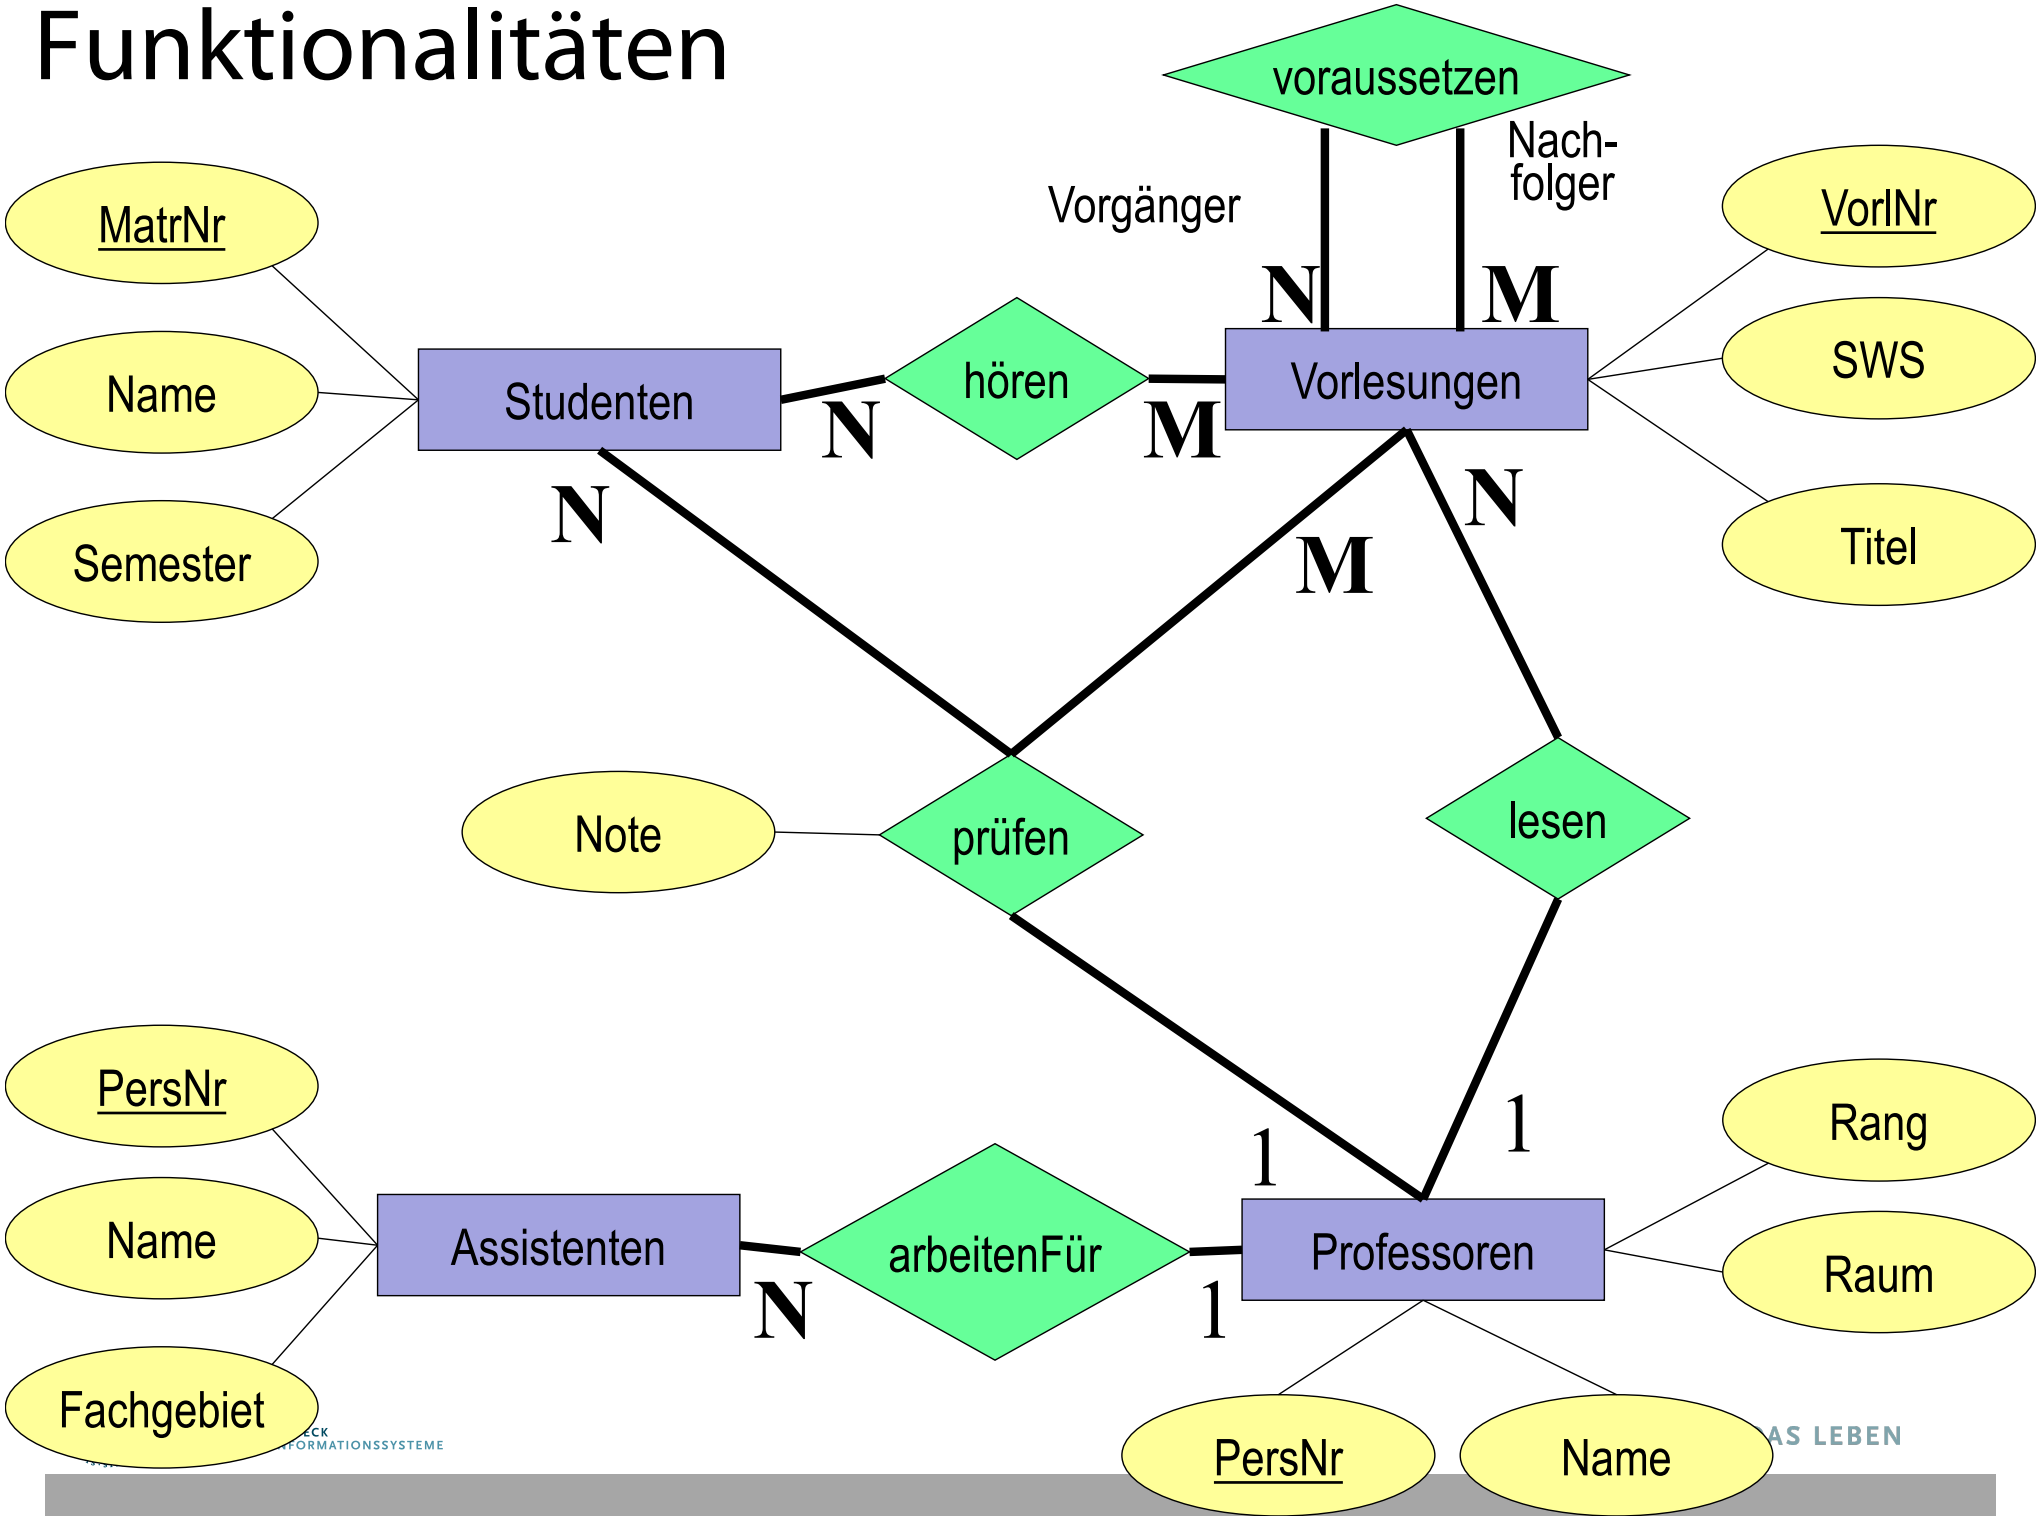

(Min, Max)-Notation / Kardinalitäten

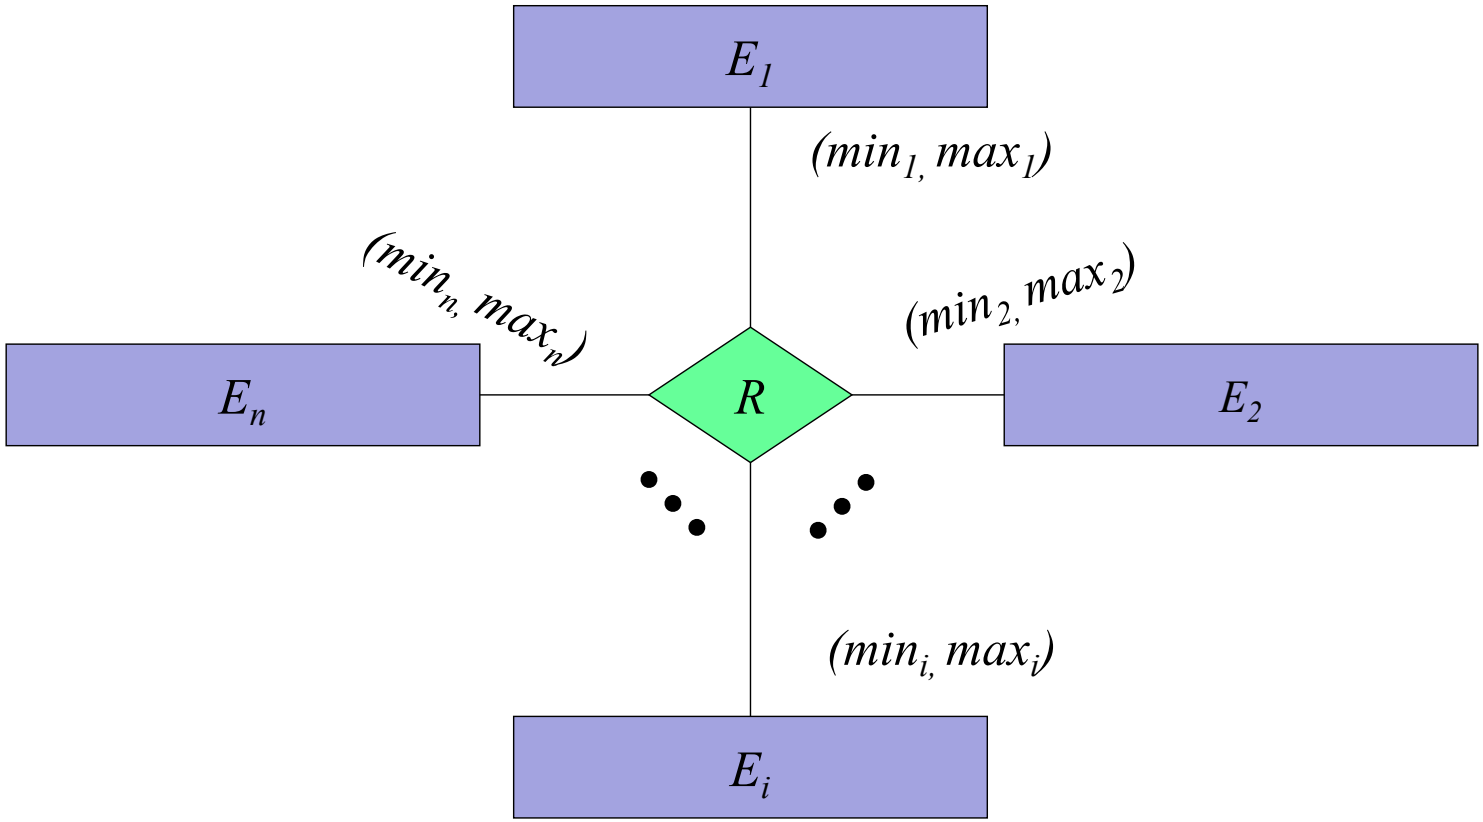

$R \subseteq E_1 \times \ldots \times E_i \times \ldots \times E_n$

Für jedes $e_i \in E_i$ gibt es

- Mindestens min_i Tupel der Art $(\ldots, e_i, \ldots)$ und
- Höchstens max_i viele Tupel der Art $(\ldots, e_i, \ldots) \in R$

Max = * bedeutet „keine Obergrenze“

Aufwachfrage:

- Was ist die schwächste (min,max)-Angabe?
- (0,*). Denn das bedeutet:
  (Minimal 0 Elemente, maximal beliebig viele Elemente)

Komplex-strukturierte Entities

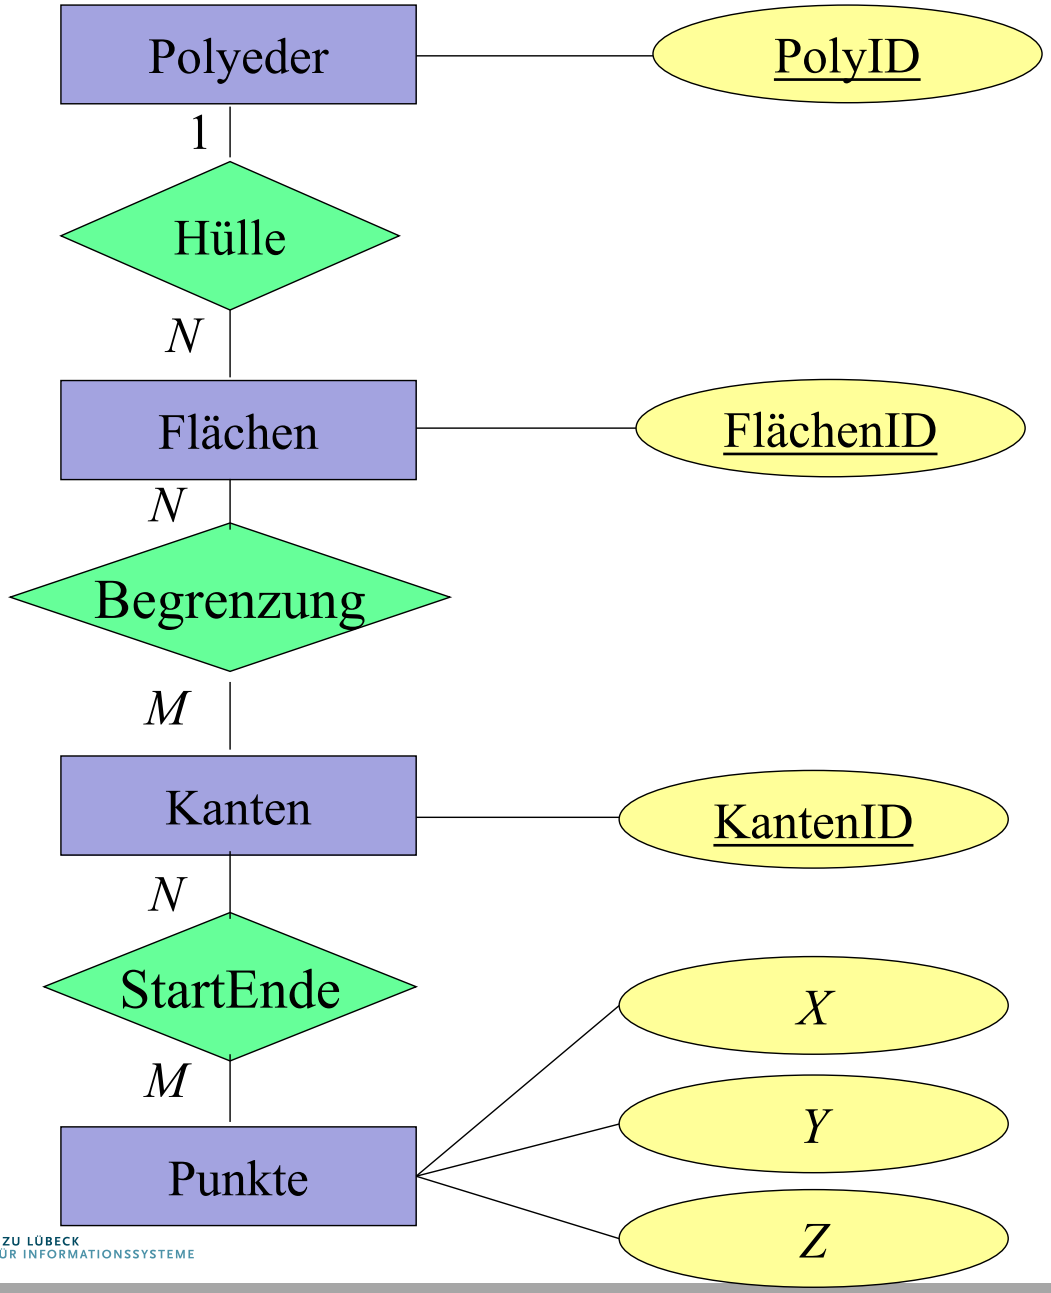

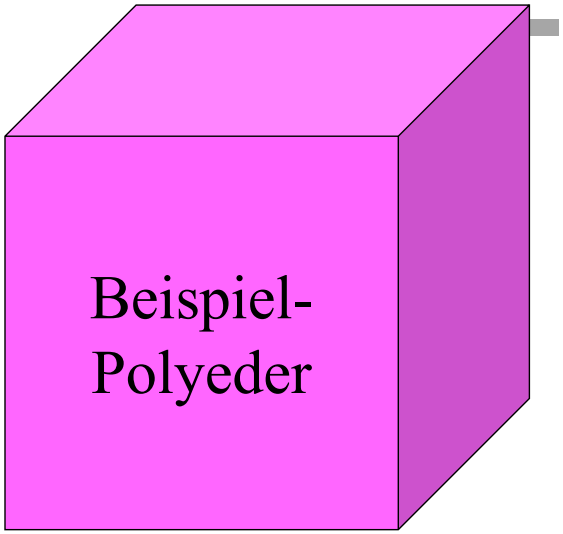

Komplex-strukturierte Entitäten

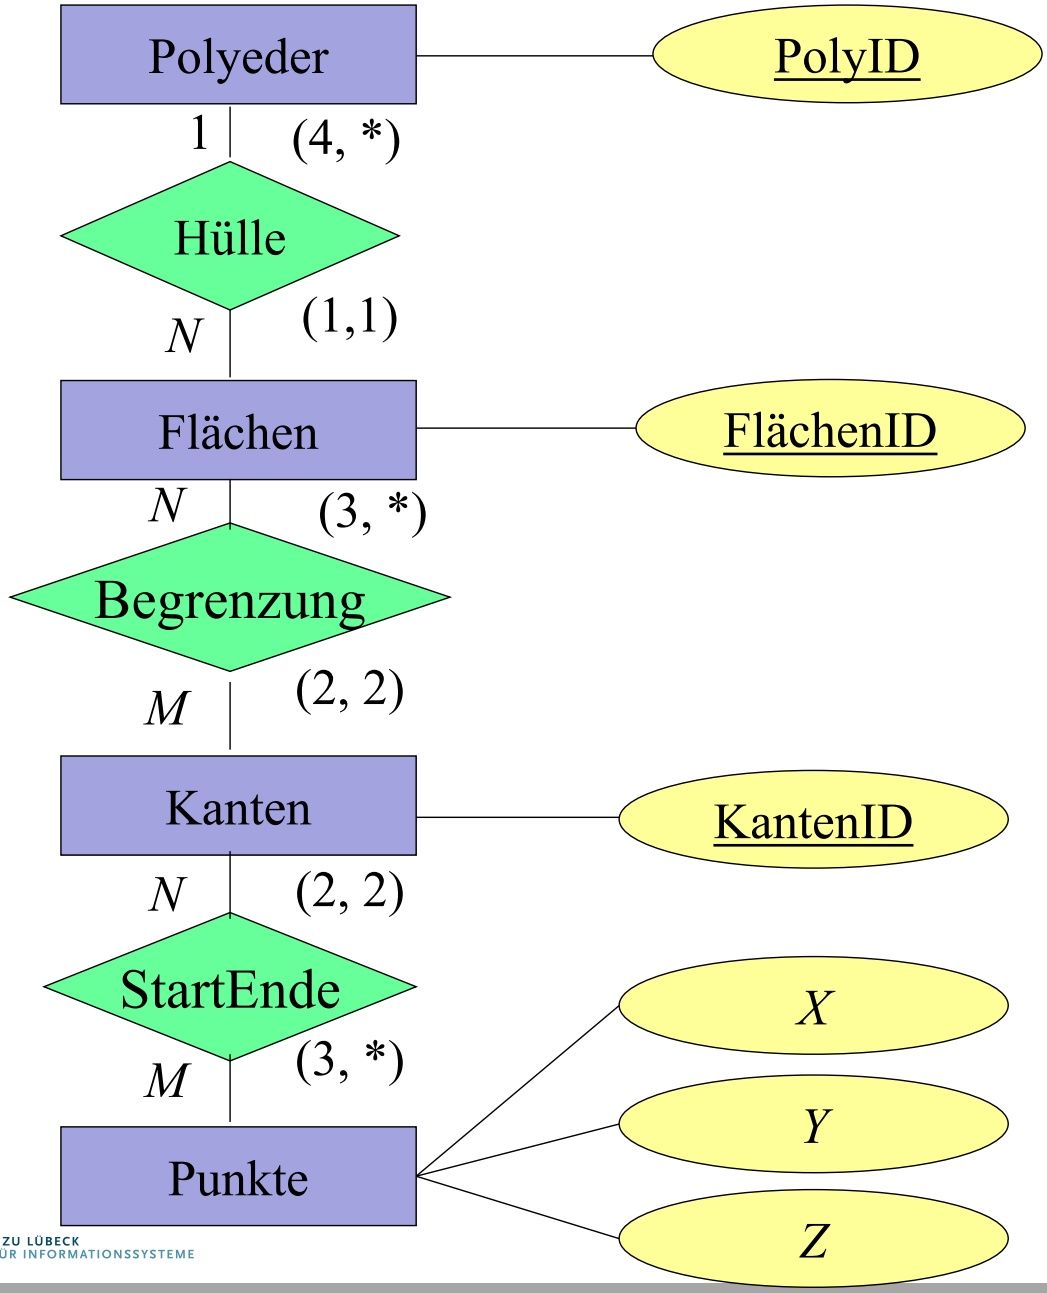

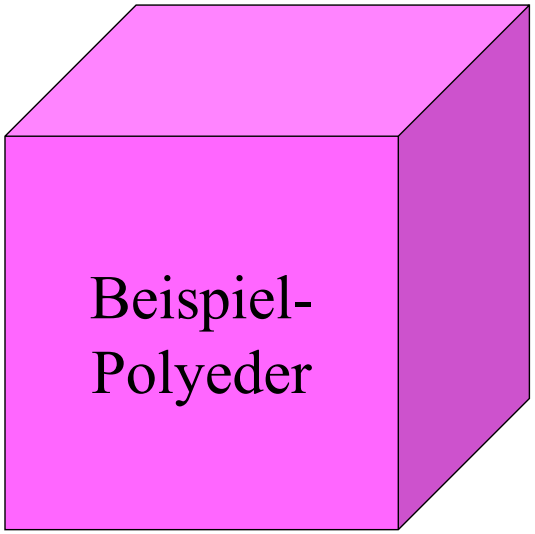

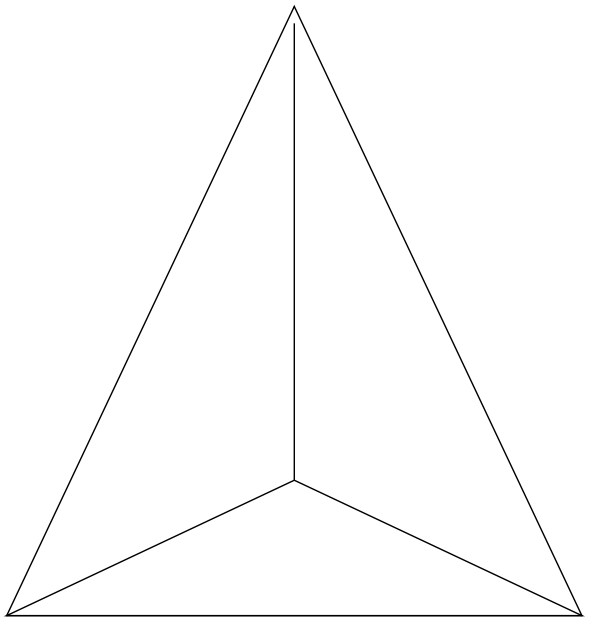

Schwache, existenzabhängige Entitäten

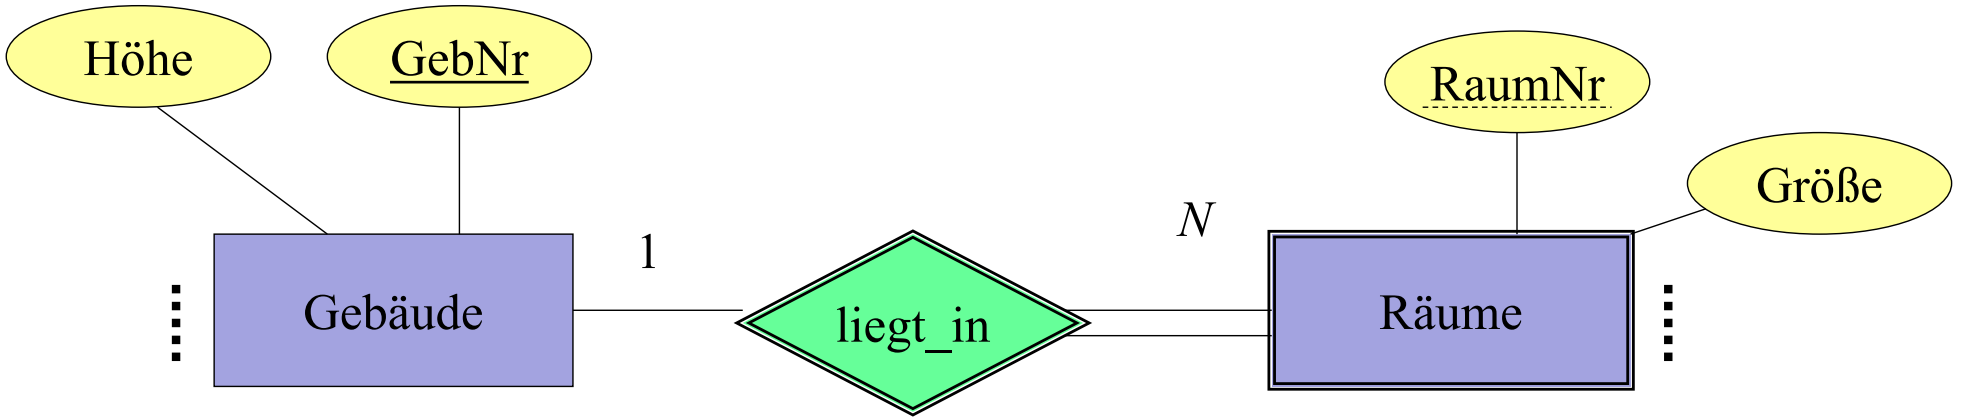

Beziehung zwischen „starkem" und „schwachem“ Typ ist immer 1:*N* (oder 1:1 in seltenen Fällen)

Warum kann das keine *N:M*-Beziehung sein?

RaumNr ist nur innerhalb eines Gebäudes eindeutig

Schlüssel ist: Kombination aus GebNr **und** RaumNr

Prüfungen als schwacher Entitytyp

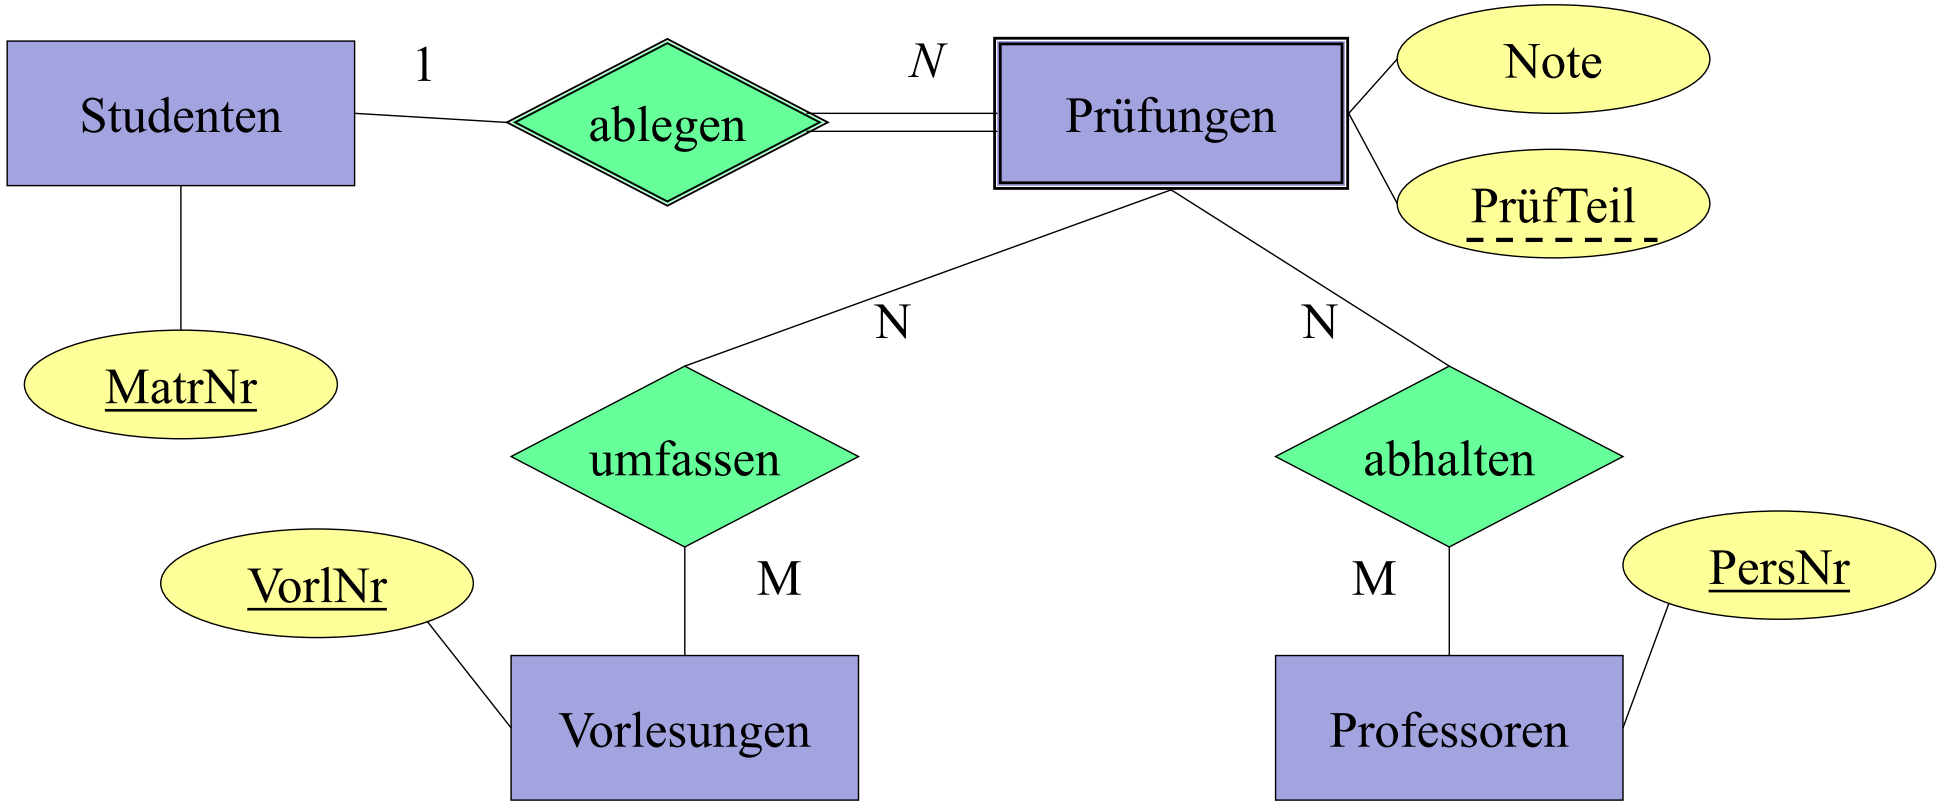

Mehrere Prüfer in einer Prüfung

Mehrere Vorlesungen werden in einer Prüfung abgefragt

Bild: Alice-Im-Wunderland-Katze

Zusammenfassung, Kernpunkte

Grundlagen von Datenbanksystemen

- Grob-Architektur eines Datenbanksystems
- Logisch-konzeptuelle Entwurfsebene: Entity-Relationship-Modell