

Datenbanken
Wintersemester 2012/13
Prof. Dr. W. May

1. Übungsblatt: ER-Modell und Relationales Modell

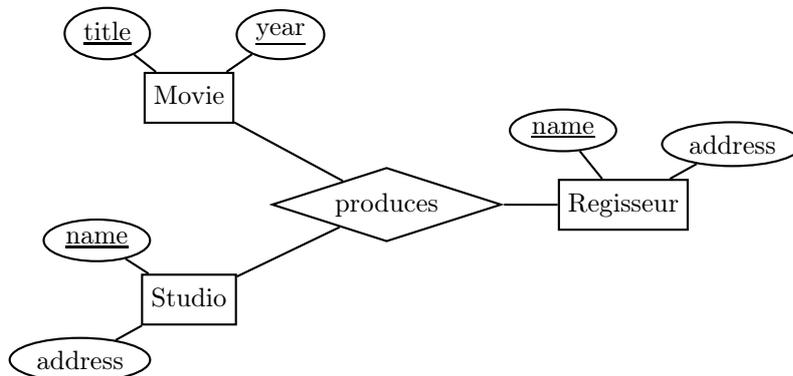
Besprechung voraussichtlich am 13.11./20.11.2012

Aufgabe 1 (ER-Modell: Film) Geben Sie ein ER-Modell für den folgenden Sachverhalt an: Filme werden in Filmstudios von Regisseuren gedreht. Filmstudios gehören einem Besitzer. In Filmen treten Schauspieler auf. Schauspieler erhalten eine Gage für jeden ihrer Verträge.

Entwickeln Sie zuerst ein einfaches Modell, und überlegen Sie dann, wie und ob Sie das Modell ergänzen könnten, um z.B. zu modellieren, dass sowohl Schauspieler als auch Regisseure und Besitzer von Filmstudios Personen sind, und manche Personen auch im selben Film oder in verschiedenen Filmen in mehreren dieser Rollen auftreten.

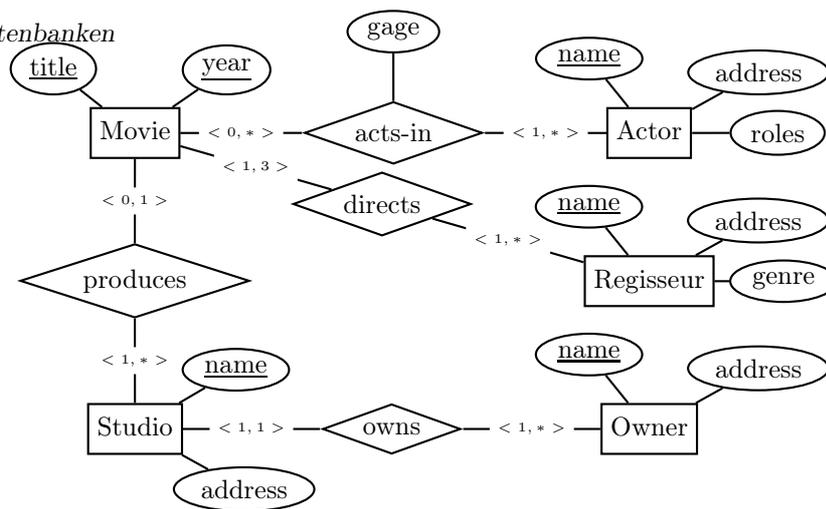
Nur die (bzw. eine) korrekte Lösung zu zeigen, wäre zu einfach und auch didaktisch nicht sinnvoll. Aus diesem Grund werden hier verschiedene Wege und Holzwege diskutiert.

Erster Ansatz: Man betrachtet den Satz "Filme werden in Filmstudios von Regisseuren gedreht." Naheliegend ist hier eine dreistellige Beziehung:



[Präsentation: Umsetzung in Relationen.] Man sieht an der Relation, bzw. an der anzustellenden Kardinalitätsbetrachtung, dass diese Modellierung nicht davor bewahrt, für einen Film, der von mehreren Regisseuren gemeinsam gedreht wird, auch unterschiedliche Studios zu speichern. Also sollte man diese Modellierung so nicht wählen.

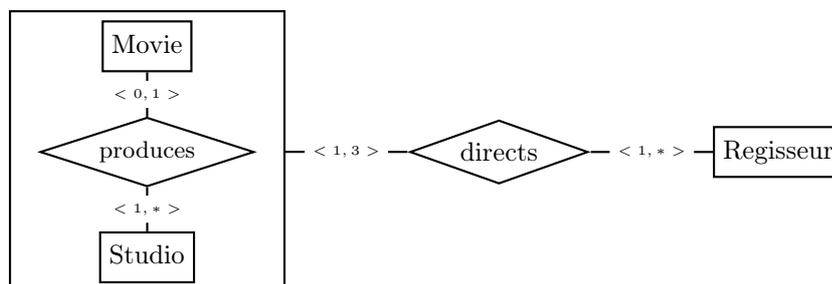
Naheliegend ist, die Beziehung in zwei zweispaltige Beziehungen (*Movie-Studio*) und (*Movie-Regisseur*) aufzulösen, womit man insgesamt die folgende "Musterlösung" erreicht:



Roles ist ein spezifisches Attribut von Schauspielern, das angibt, welche Arten von Rolle ein Schauspieler spielen kann (Erweiterung: die Beziehung *acts-in* ebenfalls *roles* zu erweitern, das angibt, welche Art von Rolle ein Schauspieler in diesem Film spielt). *Genre* ist ein spezifisches Attribut von Regisseuren, das angibt, welche Art von Filmen ein Regisseur dreht (auch hier kann man überlegen, *genre* als Attribut des Films zu nehmen).

Alternative Modellierung der linken Seite.

Eine mögliche Alternative ist, die dreistellige Beziehung *directs* aufzuspalten, indem man die Beziehung *produces* zwischen einem Studio und einem Film betrachtet, diese aggregiert (Produktion), und das Aggregat in eine *directs*-Beziehung mit Regisseuren stellt. *Owner* stehen weiterhin in Beziehung mit ihrem Studio, Schauspieler kann man wahlweise in Beziehung mit dem Film oder der Produktion stellen.



Hinweis: man erhält dasselbe relationale Modell, wenn man an der richtigen Stelle einbezieht, dass die 1:n-Beziehung zwischen Film und Studio dazu führt, dass der Schlüssel von *Production* nur $(title, year)$ ist. (Es ist somit auch eigentlich keine echte Aggregation, da jede Instanz der Aggregation auch genau einer Instanz des Entitätstyps "Film" entspricht.)

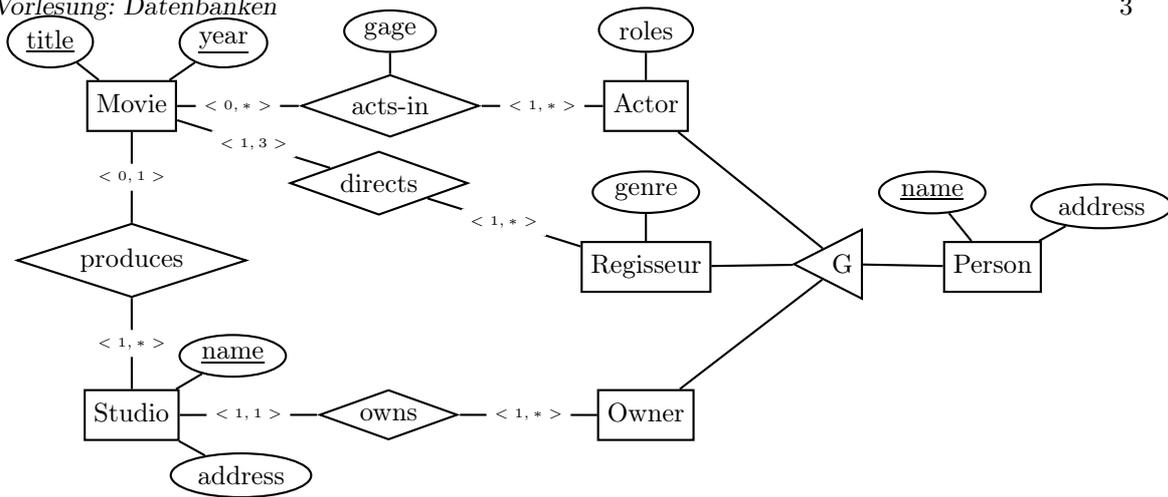
Hinweis: eine Aggregation (*Film, Regisseur*) und eine Beziehung des Aggregates zu *Studio* ist keine geeignete Modellierung, da dann für Filme, die von mehreren Regisseuren zusammen gedreht würden, auch verschiedene Studios angegeben werden könnten.

Modellierung mit Generalisierung "Person".

Betrachtet man bei der obigen Modellierung die Umsetzung ins relationale Modell, so stellt man fest, Information zu Personen, die z.B. sowohl als Regisseur als auch als Schauspieler gespeichert sind, *redundant* gehalten wird. Dies kostet nicht nur Platz, sondern kann auch zu inkonsistenten Datenbankzuständen führen:

Actor(AS, Hollywood Drive 42 - LosAngeles) und Regisseur(AS, Graben 1 - Wien).

Es ist daher sinnvoll, einen Entitätstyp *Person* als Generalisierung dieser Typen einzuführen:



Generalisierung bedeutet hier, dass

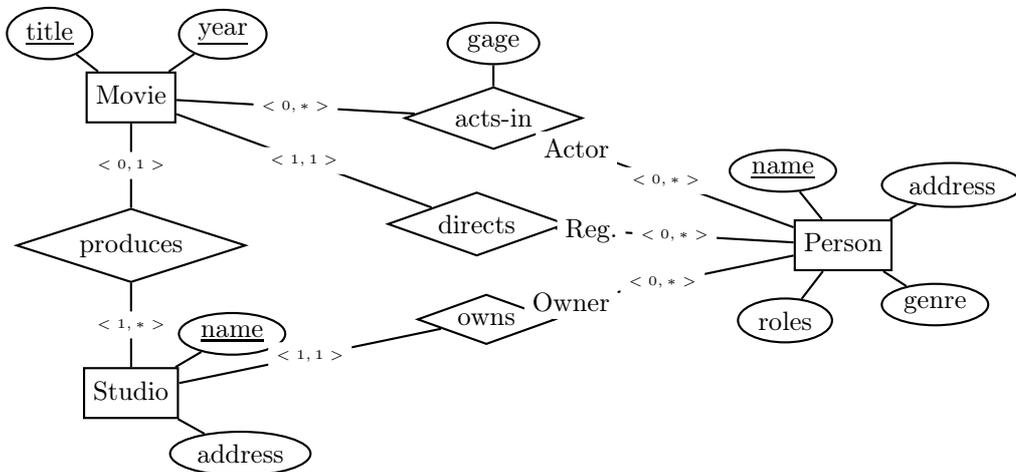
$$Persons = Actors + Regisseurs + Owners$$

ist. Würde man stattdessen eine Spezialisierung wählen, könnte man auch Personen haben, die nicht in eine dieser spezielleren Klassen fallen.

Bei einer Umsetzung ins relationale Modell erhält man je eine Tabelle für $Person(Name, Address)$, $Actor(Name, role)$ (ggf. mehrwertig), $Regisseur(Name, genre)$, die jeweils den Primärschlüssel $Name$ einer Person referenzieren.

Modellierung nur mit "Person" und Rollen.

Als dritte Möglichkeit könnte man nur Personen modellieren und ihre Rollen (in der Anwendungswelt) durch Rollen (bezeichner im ER-Modell) darstellen:



Die Attribute *roles* und *genre* müssen damit alle bei Person angesiedelt sein. Damit ist nicht klar, dass z.B. nur Schauspieler das Attribut *roles* besitzen. Außerdem sind potentiell viele Nullwerte in der Tabelle enthalten.

Aufgabe 2 (Kardinalitäten) Betrachten Sie einen binären Beziehungstyp



und die Kardinalitäten $(0, 1)$, $(1, *)$. Weisen Sie die Kardinalitäten in allen vier möglichen Weisen zu und geben Sie zu jeder Variante jeweils einen nichttrivialen Zustand an, der die Kardinalitäten erfüllt, bzw. einen, der sie verletzt.

Entitätsmenge für α : $\{A, B, C, D, E, F\}$

Entitätsmenge für β : $\{1, 2, 3, 4\}$

1. Fall:



Jedes α steht mit maximal einem β in Beziehung und umgekehrt.

Zulässiger Zustand:

A	2
B	4
F	1

Unzulässiger Zustand:

A	2
A	4
F	1

2. Fall:



Jedes α steht mit maximal einem β in Beziehung, aber jedes β muss mindestens mit einem α in Beziehung stehen. und umgekehrt.

Zulässiger Zustand:

A	2
B	4
C	3
E	3
F	1

Unzulässige Zustände:

A	2
B	4
B	3
F	1

A	2
B	4
F	1

3. Fall:



Anforderungen symmetrisch; mit den gegebenen Daten aber nicht erfüllbar: jedes α muss mit mindestens einem β in Beziehung stehen, aber jedes β darf nur mit maximal einem α in Beziehung stehen.

4. Fall:



Jedes α muss mindestens mit einem β in Beziehung stehen und umgekehrt.

Zulässiger Zustand:

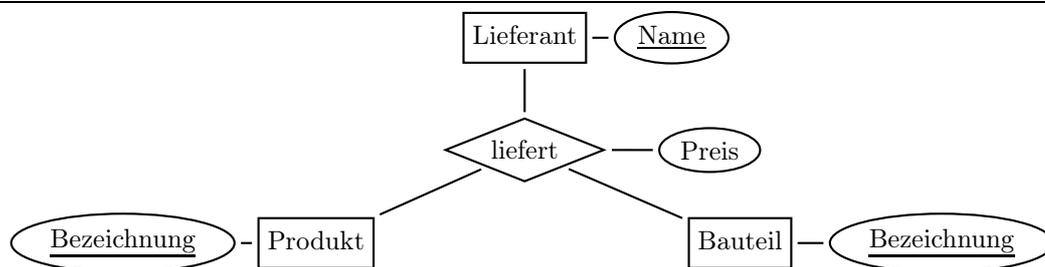
A	2
B	4
C	3
D	2
D	4
E	3
F	1

Unzulässiger Zustand:

A	2
B	4
B	3
F	1

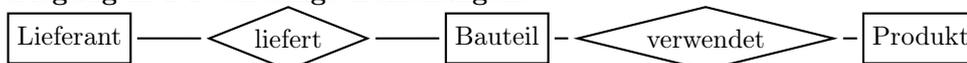
Aufgabe 3 (Dreistellige Beziehungen (Lieferant, Produkt, Bauteil)) Gegeben sei eine dreistellige Beziehung zwischen den Entitätstypen Lieferant, Produkt und Bauteil (*Firmen liefern Bauteile für Produkte*).

a) Geben Sie ein geeignetes ER-Modell an.



b) Lässt sich dieser Sachverhalt mit ausschliesslich binären Beziehungen darstellen?

1) Zerlegung in 2 zweistellige Beziehungen:



“Lieferant L liefert Bauteil B , und Produkt P benötigt Bauteil B ” bedeutet aber nicht notwendigerweise, dass P dieses Bauteil auch von L geliefert bekommt:

liefert		
L	P	B
Bosch	Golf	Einspritzpumpe
Bosch	Golf	Navigationssystem
Bosch	Auris	Einspritzpumpe
Sony	Auris	Navigationssystem

zerlegt in

LB	
L	B
Bosch	Einspritzpumpe
Bosch	Navigationssystem
Sony	Navigationssystem

und

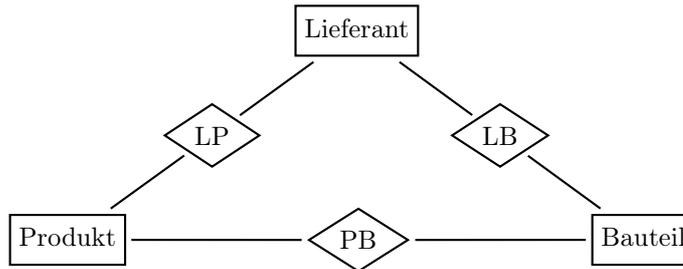
PB	
P	B
Golf	Einspritzpumpe
Golf	Navigationssystem
Auris	Einspritzpumpe
Auris	Navigationssystem

Bei Zusammenfassung erhält man auch die Tupel (Bosch, Navigationssystem, Auris) und (Sony, Navigationssystem, Golf), die nicht in der ursprünglichen Beziehung vorhanden waren.

Man hat offensichtlich den “dreistelligen” Zusammenhang “wer liefert wem was?” auseinandergerissen und dabei Informationen verloren (“nicht verlustfreie (=Verlust an Informationen) Zerlegung).

Unter der Annahme, dass der Preis nur vom Lieferanten und dem Bauteil abhängt (also nicht unterschiedliche Produkte/Kunden unterschiedliche Preise ausmachen können), kann er als Attribut zu *liefert* genommen werden. Anderenfalls hat man hier ein Problem, das ebenfalls darauf hindeutet, dass die Zerlegung nicht klappt (der Preis betrifft die individuelle Vereinbarung zwischen Lieferant, Abnehmer (bzw. das Zielprodukt) und das Bauteil).

2) Zerlegung in 3 zweistellige Beziehungen:



Zerlegung diesmal:

LB	
L	B
Bosch	Einspritzpumpe
Bosch	Navigationssystem
Sony	Navigationssystem

und

PB	
P	B
Golf	Einspritzpumpe
Golf	Navigationssystem
Auris	Einspritzpumpe
Auris	Navigationssystem

und

LP	
L	P
Siemens	Golf
Siemens	Auris
Sony	Auris

Fasst man diese Relationen durch Join zusammen, erhält man auch ein Tupel (Siemens, Auris, Navigationssystem) das nicht in der ursprünglichen Beziehung vorhanden war.

Auch hier wurde der “dreistellige” Zusammenhang “wer liefert wem was?” auseinandergerissen und kann auch durch die dritte Relation nicht voll wiederhergestellt werden.

Wieder kann unter der obigen Annahme der Preis als Attribut zu *liefert* genommen werden. Anderenfalls hat man hier wieder ein Problem, das darauf hindeutet, dass die Zerlegung nicht klappt.

c) Betrachten Sie nun dreistellige Beziehungen wieder allgemein. Gibt es Situationen, in denen eine Darstellung durch zwei binäre Beziehungstypen möglich ist? Können diese Situationen exakt durch Kardinalitäten definiert werden?

Beispiele siehe Aufgaben 1 und 4.

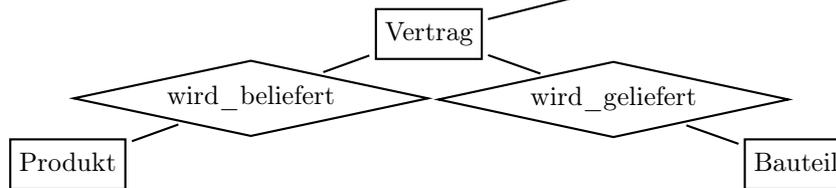
- wenn eine nicht volle funktionale Abhängigkeit innerhalb der dreistelligen Beziehung besteht.
- Das ist meistens dann der Fall, wenn man beim Versuch, der dreistelligen Beziehung hinreichend strenge Kardinalitäten hinzuzufügen scheitert. Eine Aufspaltung ist dann nicht nur möglich, sondern auch nötig.

c) Kann man dennoch dreistellige Beziehungen generell (unter Verwendung weiterer Hilfskonstrukte) durch zweistellige Beziehungen ersetzen?

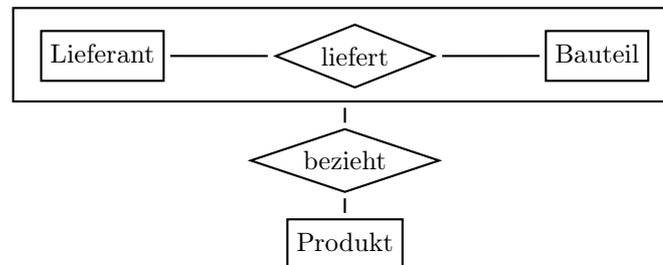
Ja. Jede Instanz der dreistelligen Beziehung wird als Entität betrachtet.

In diesem Beispiel ist das der “Vertrag”, zwischen Lieferant, Abnehmer (repräsentiert durch das Zielprodukt) bezüglich dem Bauteil.





Auch hier kann man eine Aggregation von Lieferant und Bauteil bilden:



Der Preis kann hier -je nach Situation- als Attribut zu *liefert* oder zu *bezieht* hinzugenommen werden.

Nimmt man ihn zu *bezieht*, so hat man dieselbe Semantik wie bei der ursprünglichen dreistelligen Beziehung. Gehört er zu *liefert*, so hat man mit der Aggregation eine stärkere Modellierung.

Man kann die Diskussion weiter treiben, wenn man modellieren will, dass ein Produkt eine bestimmte Menge eines Bauteils (z.B. (Golf, Rad, 4) benötigt. Hier wäre dann eine Aggregation von Produkt mit Bauteil sinnvoll, die in Beziehung zu einem Lieferanten steht. Dann kann jedoch der Preis wieder für unterschiedliche Produkte auch unterschiedlich sein. Ansonsten muss man zusätzliche Bedingungen textuell festhalten.

e) Vergleichen Sie Vor- und Nachteile der verschiedenen Zerlegungen? Lassen sich die verschiedenen Integritätsbedingungen mittels Kardinalitäten ausdrücken?

Vorteil der möglichen Zerlegung in zwei zweistellige Beziehungen:

- Redundanzvermeidung und dadurch weniger Fehlermöglichkeiten im entsprechenden relationalen Modell.

Eine Zerlegung ist genau dann möglich, wenn eine funktionale Abhängigkeit besteht (vgl. Film-Aufgabe). In diesem Fall sind bei der dreistelligen Beziehung entsprechende Relation (i) nicht alle Fremdschlüsselattribute Keys, (ii) das nicht-key-Attribut ist nicht vollständig funktional vom Key abhängig, sondern (ii) nur von einer Teilmenge des Keys (vgl. Courses-Lecturers-Students).

In diesem Fall müsste die Relation zerlegt werden (was exakt der Modellierung durch zweistellige Beziehungen entspricht). Dieser Aspekt wird gegen Ende der Vorlesung (Entwurfstheorie) nochmal behandelt.

- In einer dreistelligen Beziehung lassen sich die Integritätsbedingungen nicht mittels Kardinalitäten darstellen.

Zerlegung mit Hilfs-Entitätstyp: keine Vorteile in der Ausdruckskraft. Bei der Umsetzung in das relationale Modell sieht man auch, dass beide Varianten dasselbe relationale Modell erzeugen.

Man muss sehr genau die Semantik der Anwendung untersuchen, um zu entscheiden, mit welcher Modellierung man sie am genauesten trifft.

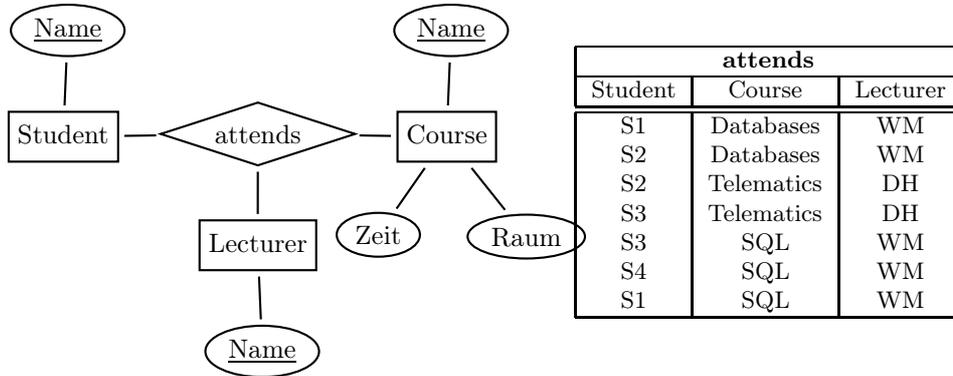
Aufgabe 4 (Lecturers, Courses, Students) Studenten hören Vorlesungen bei Dozenten. Vorlesungen findet zu einer bestimmten Zeit in einem bestimmten Raum statt.

Betrachten Sie verschiedene Szenarien:

- a) jede Vorlesung wird von *einem* Dozenten gehalten.

- b) Vorlesungen können auch von mehreren Dozenten gemeinsam gehalten werden; z.B. *Informatik I* von *Müller* von Oktober bis Weihnachten, und von *Meier* den Rest bis zum Semesterende.
- c) es gibt große (Anfänger)vorlesungen, die parallel von zwei oder mehr Dozenten in unterschiedlichen Hörsälen gehalten werden.

a) jede Vorlesung wird von *einem* Dozenten gehalten.



Man kann bei der Modellierung nicht ausdrücken, dass ein Kurs von genau einem Dozenten gehalten wird. Bei der dreistelligen Relation wäre ein Datenbankzustand, der sowohl (S1, DB, WM) und (S3, DB, DH) enthält, erlaubt.

Es gibt hier eine "funktionale Abhängigkeit" $Course \rightarrow Lecturer$ (ein Dozent kann trotzdem mehrere Vorlesungen halten). Man kann sinnvoll aufteilen in "reads" und "attends":

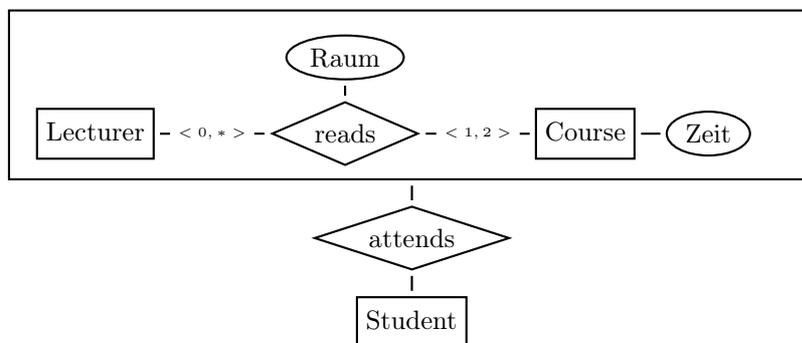


Im vorliegenden Fall ist die zerlegte Modellierung die klar bessere, da die Kardinalitäten der *reads*-Beziehung die funktionale Abhängigkeit ausdrücken.

- b) Wenn eine Vorlesung von mehreren Dozenten angeboten wird, kann die Modellierung dieselbe bleiben, nur die Kardinalität von "reads" bzgl. "Course" muss auf $\langle 1, * \rangle$ angepasst werden.
- c) Die obige Modellierung funktioniert nicht mehr, wenn große Vorlesungen parallel bei zwei Dozenten (selbe Zeit, unterschiedliche Räume) angeboten werden *Informatik I* Dienstags 14-16 von *Schmidt* in HS1 und parallel von *Schulze* in HS3.

Wie könnte man in diesem Fall modellieren, dass ein Student eine solche Vorlesung nur bei einem Dozenten hört?

Aggregation der *reads*-Beziehung zwischen Dozent und Vorlesung (entsprechend "Informatik I Kurs A/B"). Auch das Attribut "Raum" wird nun der Beziehung zugeordnet, während die (gemeinsame) Zeit beim Kurs verbleibt.



- die Anforderung, dass ein Student eine Vorlesung nur bei einem Dozenten hört, kann so nicht beschrieben werden. Dies muss zusätzlich durch Text angegeben werden.

Aufgabe 5 (Umsetzung in das relationale Modell: Film) In Aufgabe 1 haben Sie ein ER-Modell für eine kleine Filmdatenbank erstellt. Transformieren Sie dieses in ein relationales Modell.

Einfachste Modellierung

Annahme: roles wird als String als Kommaliste abgelegt

Movie: (title, year)

Studio: (name, address)

Actor: (name, address, roles)

Regisseur: (name, address, genre)

Owner: (name, address)

produces: (studio, title, year)

acts-in: (actor, title, year, gage)

directs: (regisseur, title, year)

owns: (owner, studio)

Alternative, um zu einem Schauspieler mehrere Rollencharakterisierungen ablegen zu können:

Actor: (name, address)

ActorRoles: (name, role)

Alternativen

Da ein Film jeweils nur in einem Studio gedreht werden kann (siehe Beziehungskomplexitäten im ER-Diagramm), kann man die *produces*-Beziehung in *Movie* mit hineinnehmen:

Movie: (title, year, studio)

Modelliert man Filmproduktion als Aggregation aus *Movie*, *Studio*, erhält man dafür genau die Relation

production: (title, year, studio)

Die Produktion steht nun in Beziehung zu Regisseuren, womit man hierfür die Relation

directs: (regisseur, title, year)

erhält.

Generalisierung als Personen

... verschiedene Möglichkeiten.

- Personen mit Name und Adresse, roles und genre jeweils in Relationen Actor bzw. Regisseur die als Fremdschlüssel den Namen einer Person haben. Die Fremdschlüsselbeziehungen der Relationen zu den Beziehungstypen referenzieren die Relationen Actor, Regisseur, Owner:

Movie: (title, year)

Studio: (name, address)

Person: (name, address)

Actor: (name, roles)

Regisseur: (name, genre)

Owner: (name)

produces: (studio, title, year)

acts-in: (actor, title, year, gage)

directs: (regisseur, title, year)

owns: (owner, studio)

Actor.name → *Person.name* (und analog)

acts-in.actor → *Actor.name*

Aufgrund der detaillierten Modellierung sind die Konsistenzbedingungen an die Datenbank sehr scharf.

- Die vier Relationen *Person*, *Actor*, *Regisseur*, *Owner* kosten relativ viel Platz, weil die Namen mehrfach abgelegt sind (als *Person(AS, LosAngeles)*, *Actor(AS, hero)* und *Regisseur(AS, action)*). Man kann sie einsparen, wenn man stattdessen *roles* und *genre* als Attribute zu *Person* nimmt und mit Nullwerten auffüllt (z.B. *Person(AS, LosAngeles, hero, action, NULL)*). Dies entspricht auch dem ER-Diagramm, wo nur der Entitätstyp *Person* verwendet wird, und mit Rollenbezeichnungen gearbeitet wird:

Movie: (*title*, *year*)

Studio: (*name*, *address*)

Person: (*name*, *address*, *roles*, *genre*)

produces: (*studio*, *title*)

acts-in: (*person as actor*, *title*, *year*, *gage*)

directs: (*person as regisseur*, *title*, *year*)

owns: (*person as owner*, *studio*)

acts.name → *Person.name* etc.

Man verliert die Integritätsbedingungen, dass nur Schauspieler das Attribut *roles* haben sowie dass die *acts*-Beziehung nur mit Schauspielern besteht (und analoges).

- Nun hat man ziemlich viele Nullwerte in *roles*, *genre*. Die meisten Personen werden Schauspieler sein. Man kann also z.B. das Attribut *roles* bei *Person* lassen, und *genre* wieder in separate Relationen für Regisseure (mit nur relativ wenigen Personen) legen:

Movie: (*title*, *year*)

Studio: (*name*, *address*)

Person: (*name*, *address*, *roles*)

Regisseur: (*name*, *genre*)

Owner: (*name*)

produces: (*studio*, *title*, *year*)

acts-in: (*person*, *title*, *year*, *gage*)

directs: (*regisseur*, *title*, *year*)

owns: (*owner*, *studio*)

Aufgabe 6 (Umsetzung in das relationale Modell: Dreistellige Relationen) In den Aufgaben 3 und 4 haben Sie mehrere ER-Modelle für dreistellige Beziehungen diskutiert. Transformieren Sie die sinnvollen Modelle in relationale Modelle.

Lieferant/Bauteil/Produkt als dreistellige Beziehung:

Lieferant: (Name, Adresse)

Bauteil: (Bezeichnung)

Produkt: (Name, Verkaufspreis)

liefert: (Lieferant, Bauteil, Produkt, Preis)

Fremdschlüssel:

liefert.Lieferant → Lieferant.Name

liefert.Produkt → Produkt.Name

liefert.Bauteil → Bauteil.Bezeichnung

Einführung eines zusätzlichen Entitätstyps:

Lieferant: (Name, Adresse)

Bauteil: (Bezeichnung)

Produkt: (Name, Verkaufspreis)

Vertrag: (Lieferant, Bauteil, Produkt)

Bei der Umsetzung der zusätzlichen Beziehungstypen muss jeweils der gesamte Schlüssel der Relation *Vertrag* als Fremdschlüssel aufgenommen werden. Als "automatische" Umsetzung ergibt sich damit:

liefert: (Lieferant, Lieferant, Bauteil, Produkt)

wird_geliefert(Bauteil, Lieferant, Bauteil, Produkt, Preis)

wird_beliefert(Produkt, Lieferant, Bauteil, Produkt)

Man sieht sofort, dass hier jeweils ein Attribut redundant ist, also gestrichen werden kann. Ausserdem sind alle diese Beziehungen 1:n-Beziehungen zwischen einem Vertrag und Lieferanten, Bauteilen bzw. Produkten. In der Vorlesung wurde gezeigt (Country/Capital), dass in diesem Fall die Beziehung in die auf der "1"-Seite stehende Relation (also *Vertrag*) mit hineingezogen werden kann. Damit ergibt sich in diesem Fall nicht viel neues für die *Vertrag*-Relation (da die Schlüssel der auf der "n"-Seite stehenden Entitätstypen *Lieferant*, *Bauteil* und *Produkt* bereits in *Vertrag* enthalten sind). Einzig das Attribut *Preis* kommt hinzu:

Vertrag: (Lieferant, Bauteil, Produkt, Preis)

Man erreicht dasselbe relationale Modell wie mit der ursprünglichen dreistelligen Beziehung (die Beziehung wird durch die Aufnahme der Fremdschlüssel praktisch in dieselbe Relation umgesetzt, wie der zusätzliche Entitätstyp).

Einführung einer Aggregation:

Als vierte Möglichkeit wurde eine Aggregation der "liefert"-Beziehung zwischen einem Lieferanten und einem Bauteil zu einem gegebenen Preis besprochen. Hierfür erhält man die folgenden Relationen:

Lieferant: (Name, Adresse)

Bauteil: (Bezeichnung)

Produkt: (Name, Verkaufspreis)

liefert: (Lieferant, Bauteil, Preis)

bezieht: (Lieferant, Bauteil, Produkt)

Die *bezieht*-Relation übernimmt dabei die Attribute *Lieferant* und *Bauteil* als Fremdschlüssel zur Referenzierung auf einen Eintrag in *liefert*. Wichtig ist hier, dass man eine andere referentielle Integritätsbedingung als bei der Modellierung als dreistellige Relation erhält, nämlich

bezieht.(Lieferant,Bauteil)→liefert(Lieferant,Bauteil)

bezieht.Produkt→Produkt.Name

Course/Lecturer/Student zerlegt (funktionale Abhängigkeit):

Lecturer: (Name, Address)

Course: (Name, CourseNo)

Student: (Name, Address, StudentNo)

reads: (Lecturer, CourseNo)

attends: (StudentNo, CourseNo)

Fremdschlüssel:

reads.Lecturer →Lecturer.Name

reads.CourseNo →Course.CourseNo

attends.StudentNo →Student.StudentNo

attends.CourseNo →Course.CourseNo

Ohne Zerlegung wäre das Schema der dreistelligen Relation

attends: (StudentNo, CourseNo, Lecturer)

wobei nicht wie zu erwarten alle drei Fremdschlüssel zusammen den neuen Key bilden, sondern das Attribut "Lecturer" auch nicht voll funktional vom Key abhängt, sondern man die funktionale Abhängigkeit ($\text{CourseNo} \rightarrow \text{Lecturer}$) hat. Nach dieser muss man die Relation aufspalten in $R_1(\text{CourseNo}, \text{Lecturer})$ und $R_2(\text{StudentNo}, \text{CourseNo})$, was genau dasselbe Ergebnis wie bei Zerlegung bereits im ER-Modell ergibt.

⇒ Wenn man ein gutes ER-Modell hat, muss man sich nicht mit funktionalen Abhängigkeiten und Normalisierungstheorie beschäftigen.

Aufgabe 7 (Umsetzung in das relationale Modell: Schlüsselbestimmung von Tabellen für Beziehungen)

In der Vorlesung wurde ein Kochrezept für die Umsetzung eines ER-Modells in ein relationales Modell angegeben. Dabei wurde für die Bestimmung der Schlüssel von Tabellen für Beziehungen auf die Übung verwiesen.

Analysieren Sie, welche Attribute einer solchen Tabelle Schlüssel sind. Beschränken Sie Ihre Betrachtung auf binäre Beziehungen. Welche unterschiedlichen Fälle müssen Sie dabei betrachten?

a) **Grundlegende Situation: R hat keine Attribute:**



A hat Schlüsselattribute AK_1, \dots, AK_i , B hat Schlüsselattribute BK_1, \dots, BK_j ; beide Relationen können weitere Attribute haben. R hat keine Attribute.

Die Relation R hat damit die Attribute AK_1, \dots, AK_i

(a) $b_{max} = 1$: Dies ist eine (aus Sicht von B) 1-zu- n -Beziehung (ein Land (A) hat n Provinzen (B), die nur zu ihm gehören).

Dann geht jedes b die Beziehung höchstens einmal ein. BK_1, \dots, BK_j sind Schlüssel der Tabelle $R(\underline{BK_1, \dots, BK_j}, AK_1, \dots, AK_i)$, auf die R abgebildet wird (im weiteren wird diese auch einfach als R bezeichnet).

Man kann R somit auch in die Tabelle für B mit aufnehmen (vgl. Country und Capital in Mondial). Ist $b_{min} = 1$, geht jedes b die Beziehung genau einmal ein; dann wird also jedes Tupel mit den entsprechenden Werten erweitert. Ist $b_{min} = 0$, so gibt es Tupel, die nicht in einer Beziehung R zu einem a stehen, hier hätten diese Spalten den Wert *null*. Je nachdem, wie hoch der Anteil solcher Tupel ist, lohnt es sich oder auch nicht, die Tabellen zusammenzufassen.

(b) $a_{max} = 1$ analog.

(c) $a_{max} = b_{max} = 1$, $a_{min} = 1$. Dann kann man R und A in die Tabelle von B mit aufnehmen! Falls $b_{min} = 0$, kann diese Tabelle dann b 's enthalten, zu denen es keine Werte der von A beibetragenen Spalten enthält. Falls auch $b_{min} = 1$ hat man zu jedem A genau ein B und umgekehrt.

(d) $a_{max} > 1$, $b_{max} > 1$. Dies ist eine n -zu- m -Beziehung. Diese kann man in keine der Tabellen mit hineinnehmen (weil man halt mehrere "Partner" ablegen muss). Alle AK und BK sind damit Schlüsselattribute von $R(\underline{BK_1, \dots, BK_j}, AK_1, \dots, AK_i)$.

(Strenggenommen muss man noch fordern, dass es keine Mehrfachbeziehungen (a, b) gibt, deren Anzahl relevant ist.)

b) **R hat auch Attribute R_1, \dots, R_k :**

(a) R hat nur skalare (d.h., nicht mengenwertige) Attribute (z.B. encompassed: Country, Continent, Percent), und jedes a geht jede Beziehung mit einem bestimmten b maximal einmal ein.

Dann gilt dasselbe wie in Fall (1):

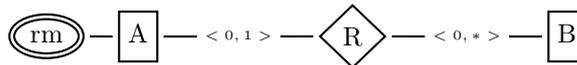
- i) $bmax = 1: R(\underline{BK_1, \dots, BK_j}, \underline{AK_1, \dots, AK_i}, R_1, \dots, R_k).$
- ii) $amax = 1: R(\underline{BK_1, \dots, BK_j}, \underline{AK_1, \dots, AK_i}, R_1, \dots, R_k).$
- i) $amax > 1$ und $bmax > 1: R(\underline{BK_1, \dots, BK_j}, \underline{AK_1, \dots, AK_i}, R_1, \dots, R_k).$

(b) R hat nur skalare (d.h., nicht mengenwertige) Attribute, aber jedes a kann jede Beziehung mit einem bestimmten b mehrmals eingehen. Dann muss man den Fall anwendungsabhängig tiefergehend analysieren (Theorie: funktionale Abhängigkeiten und nachfolgende Zerlegung), z.B.

- geschichtliche Daten zu Mitgliedschaften von Ländern in Organisationen ($o, c, candidate, von_1, bis_1$) und ($o, c, member, von_2, bis_2$): meistens würde $ismember(\underline{ccode, oabbrev, type}, \underline{von, bis})$ genügen.
- historische Daten zu Mitgliedschaften von Personen in Gremien ($o, c, \text{“Mitglied”/“Vertreter”}/\dots, von_1, bis_1$), wobei jeder Mitgliedschaftstyp in beliebigen Amtszeiten der Fall sein kann: dann wäre $ismember(\underline{person, gremium}, \underline{von, rolle, bis})$ wahrscheinlich die richtige Wahl.

(c) R hat auch ein mengenwertiges Attribut RM : RM muss (wie bei mehrwertigen Attributen von Entitätstypen) rausgezogen werden in eine Tabelle, die alle Keys von R , und ausserdem RM als zusätzlichen Schlüssel enthält.

Beispiel:



Die Beziehung selbst wird durch eine Relation $R(\underline{AK_1, \dots, AK_i}, \underline{BK_1, \dots, BK_j})$ repräsentiert (nur die AK sind Keys wegen $\langle 0, 1 \rangle$). Ausserdem hat man eine Relation $RRM(\underline{AK_1, \dots, AK_i}, \underline{RM})$.

(d) R hat mehrere mengenwertige Attribute. In einer Anwendung in Social Web z.B. eine n - m -Beziehung $telefoniert_mit(A, B)$ mit skalaren Attributen von, bis und mengenwertigen Attributen $RM_1 = \text{bespricht_Thema}$ und $RM_2 = \text{lästert_über}$. (natürlich telefoniert jedes a mit jedem b mehrmals, so dass auf jeden Fall $AK_1, \dots, AK_i, BK_1, \dots, BK_j$, und von Keys sind.

Dann benötigt man jeweils Tabellen $R_1(\underline{AK_1, \dots, AK_i}, \underline{BK_1, \dots, BK_j}, \underline{von, bis})$, $R_2(\underline{AK_1, \dots, AK_i}, \underline{BK_1, \dots, BK_j}, \underline{von, \text{bespricht_Thema}})$, und $R_3(\underline{AK_1, \dots, AK_i}, \underline{BK_1, \dots, BK_j}, \underline{von, \text{lästert_über}})$

(da das jeweilige Sachthema nicht an eine/mehrere belästerte Personen gebunden ist).

Dies führt auch schon unmittelbar zu 3-stelligen Beziehungen (die 3. Person als Lästerojekt), in denen man auch die *funktionalen Abhängigkeiten* untersuchen muss, um festzustellen, ob sie in zwei Tabellen aufgespalten werden müßte.

Aufgabe 8 (Umsetzung in das relationale Modell: Mondial) Betrachten Sie die Umsetzung aller Entitäts- und Beziehungstypen in das relationale Modell von Mondial.

- a) Entitätstypen,
- b) Beziehungstypen,
- c) ... und zur Kontrolle nochmal rückwärts: alle Relationen von Mondial.
Diese bekommen Sie z.B. mit der Anfrage

```
SELECT table_name FROM tabs;
```

Welche der Umsetzungen sind "einfach" dem Kochrezept entsprechend, welche enthalten Ausnahmen? Wie sind diese begründet?

Entitätstypen

- Continent: nach Kochrezept.
- Language, EthnicGrp, Religion: nach Kochrezept hätten die jeweiligen Relationen nur ein Attribut "Name". Man kann sie weglassen; alle Informationen sind in den Beziehungstabellen(!) "Language" (von "speak"), "EthnicGrp" (von "belong"), "Religion" (von "believe") enthalten.
- Organization: die 1:1-Beziehung "has_headquarter" wurde direkt mit hineingenommen (auf "City" mit dreistelligem Schlüssel (name, country, province)).
- Country: die 1:1-Beziehung "has_capital" wurde direkt mit hineingenommen (auf "City" mit dreistelligem Schlüssel (name, country, province)).
Ausserdem wurden Daten in die Tabellen "politics", "economy", "population" (jeweils auch mit Schlüssel code→country) ausgelagert.
- City: weak entity type (name, country, province) nach Kochrezept.
- Province: weak entity type (name, country) nach Kochrezept.
Ausserdem wurde die 1:1-Beziehung "has_capital" direkt mit hineingenommen (auf "City" mit dreistelligem Schlüssel (city(name), country, (province)name), wobei ((province)name, country) ja sowieso schon als Keys vorhanden sind.
- Lake: hier wurde zusätzlich die 1:1-Beziehung "to" als "river" mit aufgenommen.
- River: hier wurden zusätzlich die 1:1-Beziehungen "to" (zu einem Meer, See, oder einem anderen Fluss) und "has (Source)" und "(has) Estuary" mit aufgenommen.
Auch die Entitätstypen "Source" und "Estuary" wurden mit aufgenommen, da *jede* Quelle und Mündung ja zu einem Fluss gehört, und somit alle Entitäten dieser Klasse erfasst werden.
- Sea: nach Kochrezept.
- Island: nach Kochrezept.
- Mountain: nach Kochrezept.
- Desert: nach Kochrezept.
- Source, Estuary: beide in "River" einbezogen.

Beziehungstypen

- speak, belong, believe: s.o. unter "Country"
- encompasses: typische n:m-Beziehung nach Kochrezept in Tabelle "encompasses" umgesetzt.
- is_member: typische n:m-Beziehung mit Attributen nach Kochrezept in Tabelle "ismember" umgesetzt.
- dependent: 1:1-Beziehung in "politics" umgesetzt (und damit quasi in die Modellierung von "Country" integriert).
- has_headq_in: s.o. als 1:1-Beziehung in "Organization".
- is_capital: s.o. als 1:1-Beziehung in "Country" bzw. "Province".
- (Province) of (Country): als n:1-Beziehung in "Province" (wo es sowieso schon dabei ist, weil Province ein weak entity type ist).
- (City) in (Province): als n:1-Beziehung in "City" (wo es sowieso schon dabei ist, weil Province ein weak entity type ist).
- borders: typische n:m-Beziehung mit Attributen nach Kochrezept in Tabelle "borders" umgesetzt.
Eine Besonderheit hier ist die Tatsache, dass die Relation symmetrisch ist. Jede Nachbarschafts-

beziehung wird nur einmal gespeichert (d.h., nur CH-D, nicht auch noch D-CH).

- (City) at (Lake/River/Sea): im Prinzip nach Kochrezept, alle in “located” gesammelt. Durch das Sammeln hat man allerdings das Problem, dass man keinen Schlüssel definieren kann, weil bei jedem Eintrag ein oder mehrere Gewässer-Einträge null sein können.
- (City) on (Island): nach Kochrezept in “locatedon”.
- (“geo-Objects” Lake/River/Sea/Island/Mountain/Desert/Source/Estuary) in (Province): n:m-Beziehungen, jede einzeln nach Kochrezept in “geo_lake”, “geo_River”, “geo_Sea”, “geo_Island”, “geo_Mountain”, “geo_Desert” umgesetzt.
- merges (zwischen Meeren): typische n:m-Beziehung mit Attributen nach Kochrezept in Tabelle “mergeswith” umgesetzt.
Auc hier ist die Relation symmetrisch, jede Nachbarschaftsbeziehung wird nur einmal gespeichert.
- (Island) in (Sea/Lake/River): n:m-Beziehung nach Kochrezept in “islandin” umgesetzt und gesammelt (wie “located”).
- (Mountain) on (Island): n:1-Beziehung in “mountainon” umgesetzt. Hier hätte man sie auch als “island“-Attribut in “Mountain” mit aufnehmen können. Diese Spalte wäre aber bei vielen Bergen dann *null* gewesen.
- (River) has (Estuary) to (Gewässer): da zu jedem Fluss (maximal; manche versickern) genau eine Mündung gehört, wurden diese Beziehungen, sowie der Entitätstyp “Estuary” in die Relation “River” mit aufgenommen.
- (River) has (Source): wie bei “has (Estuary)”.

Bemerkungen

Das Attribut “Mountains” (“Gebirge”) tritt im ER-Modell mehrmals auf: in “Mountain” sowie in “Source”. Man hätte einen separaten Entitätstyp “Mountains” mit Attributen “Name” und vielleicht “height” und “area” modellieren können, und dann “(mountains) in (Province)” wie für alle Geo-Objekte, auch “(City) in (Mountains)” und “(Mountains) on (Island)” aufnehmen können.

Mondial-Relationen

... alle oben beschrieben.
