

Stephan Kleuker

Grundkurs Datenbankentwicklung

Von der Anforderungsanalyse
zur komplexen Datenbankanfrage

2. Auflage

► Mit Online-Service

STUDIUM



Stephan Kleuker

Grundkurs Datenbankentwicklung

Stephan Kleuker


Grundkurs Datenbankentwicklung

Von der Anforderungsanalyse
zur komplexen Datenbank Anfrage

2., erweiterte Auflage

Mit 99 Abbildungen

STUDIUM



**VIEWEG+
TEUBNER**

Bibliografische Information der Deutschen Nationalbibliothek
Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der
Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über
<<http://dnb.d-nb.de>> abrufbar.

Das in diesem Werk enthaltene Programm-Material ist mit keiner Verpflichtung oder Garantie irgendeiner Art verbunden. Der Autor übernimmt infolgedessen keine Verantwortung und wird keine daraus folgende oder sonstige Haftung übernehmen, die auf irgendeine Art aus der Benutzung dieses Programm-Materials oder Teilen davon entsteht.

Höchste inhaltliche und technische Qualität unserer Produkte ist unser Ziel. Bei der Produktion und Auslieferung unserer Bücher wollen wir die Umwelt schonen: Dieses Buch ist auf säurefreiem und chlorfrei gebleichtem Papier gedruckt. Die Einschweißfolie besteht aus Polyäthylen und damit aus organischen Grundstoffen, die weder bei der Herstellung noch bei der Verbrennung Schadstoffe freisetzen.

1. Auflage 2006
2., erweiterte Auflage 2011

Alle Rechte vorbehalten
© Vieweg+Teubner Verlag | Springer Fachmedien Wiesbaden GmbH 2011

Lektorat: Christel Roß | Maren Mithöfer

Vieweg+Teubner Verlag ist eine Marke von Springer Fachmedien.
Springer Fachmedien ist Teil der Fachverlagsgruppe Springer Science+Business Media.
www.viewegteubner.de



Das Werk einschließlich aller seiner Teile ist urheberrechtlich geschützt. Jede Verwertung außerhalb der engen Grenzen des Urheberrechtsgesetzes ist ohne Zustimmung des Verlags unzulässig und strafbar. Das gilt insbesondere für Vervielfältigungen, Übersetzungen, Mikroverfilmungen und die Einspeicherung und Verarbeitung in elektronischen Systemen.

Die Wiedergabe von Gebrauchsnamen, Handelsnamen, Warenbezeichnungen usw. in diesem Werk berechtigt auch ohne besondere Kennzeichnung nicht zu der Annahme, dass solche Namen im Sinne der Warenzeichen- und Markenschutz-Gesetzgebung als frei zu betrachten wären und daher von jedermann benutzt werden dürften.

Umschlaggestaltung: KünkelLopka Medienentwicklung, Heidelberg
Gedruckt auf säurefreiem und chlorfrei gebleichtem Papier
Printed in Germany

ISBN 978-3-8348-1481-4

Vorwort

Relationale Datenbanken sind Informatik-Grundwissen

Bücher mit dem Schwerpunkt auf der Entwicklung von relationalen Datenbanken werden bereits seit den 80iger Jahren des letzten Jahrhunderts geschrieben. Es stellt sich so die berechnigte Frage nach dem Sinn eines weiteren Buches. Schaut man auf die Bücher, die seit dieser Zeit geschrieben wurden, so fällt auf, dass Bücher zum Thema Datenbanken immer dicker und komplexer werden. Dies liegt daran, dass das Thema von Informatikern immer genauer verstanden wird und immer neue Einsatzmöglichkeiten für Datenbanken gefunden werden. Wichtige Themen sind dabei beispielsweise die Anbindung von Datenbanken an objektorientierte Programmiersprachen und die Verbindung zwischen Datenbanken und XML.

Man kann feststellen, dass sich dabei relationale Datenbanken als Fundament der Entwicklungen herausgestellt haben. Immer wieder gab es Prognosen, in denen die Ablösung relationaler Datenbanken durch neuere Systeme beschrieben wurden. Die Realität hat gezeigt, dass diese neuen Systeme ihre Berechnigung auf dem Markt haben, allerdings nur mehr oder minder große Nischen im Datenbankmarkt besetzen, wie es auch von C.J. Date, vielleicht dem renommiertesten Forscher zum Thema Datenbanken, in dem Artikel „Great News, The Relational Model Is Very Much Alive!“ [Dat00] beschrieben wird. Dies ist der eine Grund, warum dieses Grundlagenbuch entstanden ist.

Grundkurs für Bachelor

Der zweite, pragmatischere Grund für dieses Buch ist in der Situation in der Lehre an deutschsprachigen Hochschulen zu sehen. Der Bachelor-Abschluss wird als Standardabschluss eingeführt. Er ist der zeitlich erste berufsqualifizierende, akademische Abschluss, der nach drei bis vier Jahren erreicht werden soll. In jedem Studiengang, der Informatik zum Inhalt hat, wird typischerweise das Thema Datenbanken in einer Kernveranstaltung behandelt. Für eine solche Veranstaltung wird ein Buch benötigt, dass sich an den Fähigkeiten von Bachelor-Studierenden orientiert und eine grundlegende Einführung in die Datenbank-Thematik liefert. Diese Lücke schließt dieses Buch.

Datenbanken als Einstiegs-thema im Studium

In meiner Lehrpraxis als Fachhochschul-Professor hat sich gezeigt, dass es sinnvoll ist, das Thema Datenbanken früh im Studium zu behandeln, da kaum Informatik-Vorwissen benötigt wird. Aus diesem Grund baut dieses Buch auf dem Konzept des „Lernens an erklärten Beispielen“ auf, das durch Übungsaufga-

Aufbau des Buches

ben unterstützt wird. Aus der Sicht von Studierenden ist es ebenfalls sinnvoll, früh eine Einführung in Datenbanken zu bekommen, da sich das Thema sehr gut für Betriebspraktika oder den Gelderwerb mit Softwareentwicklung nebenbei eignet.

Da es sich um einen Grundkurs handelt, ist dieser abhängig vom Studienplan, um Praktika oder fortgeschrittene Veranstaltungen zu ergänzen. Die Möglichkeiten, dabei weitere Lehrbücher einzusetzen, ist sehr groß, exemplarisch seien folgende Werke genannt: [Dat04], [KE04], [HS00] zusammen mit [SH99].

Der Aufbau des Buches ist an den typischen Phasen einer Datenbankentwicklung orientiert. Dabei werden zwei Aspekte, die aus Sicht der Praxis besonders für den Erfolg einer Datenbankentwicklung wichtig sind, intensiver betrachtet. Dies sind zum einen die *Anforderungsanalyse*, zum anderen die *Erstellung von SQL-Anfragen*. Der erste Aspekt betrifft die Erhebung der Anforderungen, die durch die Datenbank erfüllt werden sollen. Genauestens muss an der Schnittstelle zwischen dem Kunden und den Entwicklern geklärt werden, welche Informationen in der Datenbank wie verarbeitet werden sollen. In den nächsten Schritten wird in diesem Buch beschrieben, wie man aus den dokumentierten Anforderungen zu Tabellen kommen kann, die das Herz jeder relationalen Datenbank bilden. Dabei gibt es einige durch Normalisierungsregeln formalisierbare Anforderungen, die die Nutzbarkeit der Tabellen wesentlich erhöhen. Ein großer Teil des Buches ist der Datenbanksprache SQL gewidmet, die den Standard zur Definition von Tabellen, Formulierung von Anfragen und Verwaltung des Zugriffs auf Tabellen darstellt. Der zweite für die Praxis wichtige Aspekt, der in diesem Buch betont wird, behandelt die Erstellung von SQL-Anfragen, die systematisch an vielen Beispielen schrittweise eingeführt wird. Das Buch wird mit Betrachtungen über Transaktionen, mit denen der gleichzeitige Zugriff mehrerer Nutzer geregelt wird, und zu Rechte-Systemen, mit denen festgelegt wird, wer was in der Datenbank darf, abgerundet. In einem abschließenden Ausblick wird aufgezeigt, in welchen Themenbereichen Vertiefungen zum Thema Datenbanken möglich sind.

Sinn der Randnotizen

Am Rand der Seiten dieses Buches finden sie einige Notizen, die es beim Nachschlagen erleichtern, Schwerpunkte wieder zu finden.

[} Optionale Textstellen*

In diesem Buch sind ein Kapitel, einige Unterkapitel und Absätze mit [*} gekennzeichnet. Diese Passagen können bei einer ersten Bearbeitung oder in Lehrveranstaltungen bei Studierenden, für die Informatik kein Kernfach ist, ausgelassen werden. Das Buch

*Auswahl von
Beispielen*

bleibt ohne diese Stellen uneingeschränkt lesbar. Die Erfahrung hat allerdings gezeigt, dass die eher theoretischen Überlegungen auch für Studierende ohne Schwerpunkt Informatik sehr hilfreich sein können, da Hintergründe erläutert werden, die das Denkmodell zum Thema Datenbanken abrunden.

Bei der Auswahl der Beispiele in diesem Buch wurde ein Kompromiss getroffen. Für einführende Erklärungen werden Tabellen eingesetzt, deren Daten mit einem Blick zu erfassen sind und sich so für die folgenden Beispiele im Auge festsetzen. Durchgehend durch die Kapitel, in denen nicht nur grundsätzliche Aussagen über Datenbank-Managementsysteme gemacht werden, dient dann ein relativ komplexes Beispiel als Anschauungsmaterial. Trotzdem sollte der Leser darauf gefasst sein, dass die Realität neue Herausforderungen bietet. Einige dieser Forderungen liegen aber nicht nur an der Komplexität, sondern auch daran, dass sich zu unerfahrene Personen an die Entwicklung dieser Systeme getraut haben. Nach der Lektüre des Buches sollten Sie in der Lage sein, solche Problemstellen zu identifizieren.

*Aufgaben zur
Nachbearbeitung*

Jedes Kapitel schließt mit zwei Arten von Aufgaben ab. Im ersten Aufgabenteil werden Wiederholungsfragen gestellt, die man nach intensiver Lektüre des vorangegangenen Kapitels beantworten sollte. Die Lösungen zu diesen Aufgaben kann man selbst im Buch nachschlagen. Der zweite Aufgabenteil umfasst Übungsaufgaben, in denen man gezielt das angelesene Wissen anwenden soll. Diese Übungsaufgaben sind in verschiedenen Lehrveranstaltungen erfolgreich eingesetzt worden. Im letzten Kapitel gibt es Lösungsvorschläge zu diesen Aufgaben.

Die Bilder und SQL-Skripten dieses Buches sowie weitere Information können von der Web-Seite

<http://home.edvsz.fh-osnabrueck.de/skleuker/DBBuch.html>

herunter geladen und unter Berücksichtigung des Copyrights genutzt werden.

Lust zum Experimentieren

Zum Abschluss wünsche ich Ihnen viel Spaß beim Lesen. Konstruktive Kritik wird immer angenommen. Bedenken Sie, dass das Lesen nur ein Teil des Lernens ist. Ähnlich wie in diesem Buch kleine Beispiele eingestreut sind, um einzelne Details zu klären, sollten Sie sich mit einem realen Datenbank-Managementsystem hinsetzen und meine, aber vor allem selbst konstruierte Beispiele durchspielen. Sie runden das Verständnis des Themas wesentlich ab.

Wiesbaden, Januar 2006

Stephan Kleuker

Danksagung

Ein Buch kann nicht von einer Person alleine verwirklicht werden. Zu einer gelungenen Entstehung tragen viele Personen in unterschiedlichen Rollen bei, denen ich hier danken möchte.

Mein erster Dank geht an Ehefrau Frau Dr. Cheryl Kleuker, die nicht nur die erste Kontrolle der Inhalte und Texte vorgenommen hat, sondern mir erlaubte, einen Teil der ohnehin zu geringen Zeit für die Familie in dieses Buchprojekt zu stecken.

Besonderer Dank gilt meinen Kollegen Prof. Dr.-Ing. Johannes Brauer und Uwe Neuhaus von der Fachhochschule NORDAKADEMIE in Elmshorn, die sich Vorversionen dieses Buches kritisch durchgelesen haben und viele interessante Anregungen lieferten. Viele Studierende, die Veranstaltungen zum Thema Datenbanken bei mir gehört haben, trugen durch ihre Fragen und Probleme wesentlich zu der Herangehensweise an die Themen des Buches bei.

Abschließend sei Dr. Reinald Klockenbusch und den weiteren Mitarbeitern des Verlags Vieweg für die konstruktive Mitarbeit gedankt, die dieses Buchprojekt erst ermöglichten.

Ergänzung zur 2. Auflage

Zunächst möchte ich den Lesern und Studierenden danken, die mit Hinweisen auf kleine Fehler und Ungenauigkeiten zur weiteren Erhöhung der Qualität dieses Buches beigetragen haben. Mit dieser Erweiterung möchte ich den Wunsch von Lehrenden und Studierenden erfüllen, dass dieses Buch ein vollständiges Bachelor-Modul abdecken soll. Die Erweiterung beinhaltet eine Einführung in Stored Procedures, Trigger und JDBC.

Die Lösungen zu den Aufgaben sind auf <http://home.edvsz.fh-osnabrueck.de/skleuker/DBBuch.html> und www.viewegteubner.de zum Download bereitgestellt.

Osnabrück, September 2010

Stephan Kleuker

Inhaltsverzeichnis

1	Warum Datenbanken?	1
1.1	Kreatives Datenchaos	1
1.2	Anforderungen an eine Datenbank	2
1.3	Anforderungen an ein Datenbank-Managementsystem	4
1.4	Ebenen eines Datenbank-Managementsystems	9
1.5	[*] Die weiteren Kapitel	13
1.6	Aufgaben	15
2	Anforderungsanalyse für Datenbanken	19
2.1	Überblick über den Software-Entwicklungsprozess	20
2.2	Anforderungsanalyse für Software	23
2.3	Anforderungsanalyse für Datenbanken	28
2.4	Entity-Relationship-Modell	34
2.5	[*] Abschlussbemerkungen zu Entity-Relationship-Modellen	45
2.6	Fallstudie	51
2.7	Aufgaben	56
3	Systematische Ableitung von Tabellenstrukturen	61
3.1	Einführung des Tabellenbegriffs	61
3.2	Übersetzung von Entity-Relationship-Modellen in Tabellen	64
3.3	Besondere Aspekte der Übersetzung	69
3.4	Fallstudie	72
3.5	Aufgaben	73
4	Normalisierung	75
4.1	Funktionale Abhängigkeit und Schlüsselkandidaten	75
4.2	Erste Normalform	84
4.3	Zweite Normalform	86
4.4	Dritte Normalform	89

4.5	Normalformen und die Übersetzung von Entity-Relationship-Modellen	91
4.6	[*] Boyce-Codd-Normalform	92
4.7	Fallstudie	97
4.8	Aufgaben	98
5	[*] Relationenalgebra.....	103
5.1	Elementare Operatoren auf Relationen	104
5.2	Ein Verknüpfungsoperator für Relationen	108
5.3	Aufgaben	111
6	Formalisierung von Tabellen in SQL.....	113
6.1	Tabellendefinition mit SQL	114
6.2	Einfügen, Löschen und Ändern von Daten	117
6.3	Datentypen in SQL	126
6.4	NULL-Werte und drei-wertige Logik	131
6.5	Constraints.....	135
6.6	Änderungen von Tabellenstrukturen	140
6.7	Fallstudie	142
6.8	Aufgaben	144
7	Einfache SQL-Anfragen	147
7.1	Ausgabe der eingegebenen Informationen.....	147
7.2	Auswahlkriterien in der WHERE-Bedingung	153
7.3	Nutzung von Aggregatsfunktionen.....	158
7.4	Anfragen über mehrere Tabellen	161
7.5	Fallstudie	169
7.6	Aufgaben	170
8	Gruppierungen in SQL	173
8.1	Gruppierung in einer Tabelle	174
8.2	Nutzung der HAVING-Zeile	178
8.3	Gruppierungen über mehreren Tabellen.....	181
8.4	Überblick über die Struktur von SQL-Anfragen	182

8.5	Fallstudie	184
8.6	Aufgaben	186
9	Verschachtelte Anfragen in SQL	189
9.1	Nutzung von Mengen-Operatoren.....	189
9.2	Teilanfragen in der SELECT-Zeile	196
9.3	Teilanfragen in der WHERE-Bedingung.....	198
9.4	Teilanfragen in der HAVING-Bedingung.....	209
9.5	Teilanfragen in der FROM-Zeile	211
9.6	[*] Verschiedene Join-Operatoren	215
9.7	Fallstudie	219
9.8	Aufgaben	221
10	Transaktionen	223
10.1	Änderungen verwalten	223
10.2	Typische Probleme beim parallelen Zugriff	227
10.3	Transaktionssteuerung.....	229
10.4	Aufgaben	231
11	Rechte und Views	233
11.1	Views	233
11.2	Rechte für die Datenbank-Administration.....	238
11.3	Rechte für die Projekt-Administration	240
11.4	Aufgaben	242
12	Stored Procedures und Trigger	243
12.1	Einführung in PL/SQL.....	244
12.2	Datenbankanfragen und Cursor in PL/SQL	258
12.3	Trigger	266
12.4	Aufgaben	275

13	Einführung in JDBC	279
13.1	Verbindungsaufbau	280
13.2	Anfragen über JDBC.....	283
13.3	Änderungen in Tabellen	287
13.4	Weitere SQL-Befehle in JDBC.....	291
13.5	Vorbereitete SQL-Befehle.....	292
13.6	PL/SQL mit JDBC nutzen	294
13.7	Aufgaben	299
14	Zusammenfassung und Ausblick	301
	Literaturverzeichnis	303
	Sachwortverzeichnis	305

Mit [*] markierte Kapitel, Unterkapitel und Absätze können beim ersten Lesen weggelassen werden. Sie können aber auch beim Anfänger zum detaillierteren Verständnis beitragen.

1

Warum Datenbanken?

Bevor Sie anfangen, ein längeres Buch zu einem fachlichen Thema zu lesen, sollten Sie sicher sein, dass es sinnvoll ist, sich mit diesem Thema zu beschäftigen. In diesem Kapitel wird kurz beschrieben, warum es zur Entwicklung des Themas Datenbanksysteme als eigenständigem Bereich in der Informatik kam. Im nächsten Schritt wird dann allgemein die Funktionalität erläutert, die man von einem solchen System erwarten kann. Die in die Erläuterungen einfließenden Beispiele werden im Buch in den einzelnen Kapiteln wieder aufgenommen und dort weiter im Detail betrachtet.

1.1

Kreatives Datenchaos

*Zeitlich und
räumlich ver-
teilte Daten*

Jeder, der schon einmal nach einiger Zeit mehrere Informationen zusammenstellen musste, kennt das Problem, dass die richtigen Informationen gefunden werden müssen. Soll z. B. ein gebrauchter MP3-Player verkauft werden, sollte das Zubehör vollständig sein und die Gebrauchsanleitung beiliegen. Der Kaufbeleg zur Dokumentation des früheren Preises könnte auch von Nutzen sein.

*Verwaltung
durch Laufzet-
tel*

Ähnliche Probleme haben auch Betriebe, die Informationen über ihr Geschäft verwalten wollen. Ein Versandhandel erhält Bestellungen von Kunden, die in einigen Fällen nicht sofort vollständig erledigt werden können. Die Nachlieferungen müssen geregelt werden. Klassisch gibt es dazu einen Stapel mit Zetteln, auf denen nicht erledigte Aufträge notiert sind. Es wird dann nach und nach versucht, diese Aufträge zu erfüllen. Erhält der Versandhandel eine eingehende Lieferung, muss er prüfen, ob es noch offene Aufträge für diesen Artikel gibt. Ist das der Fall, sollten die Kunden den Artikel erhalten, die am längsten warten mussten. Um diese Arbeit effizient ausführen zu können, kann der Stapel mit den nicht bearbeiteten Aufträgen nach den fehlenden Artikeln aufgeteilt werden. Was passiert aber, wenn mehrere Artikel nicht lieferbar sind?

*Datensortie-
rung*

Diese Zettelwirtschaft lässt sich beliebig kompliziert gestalten. Es ist einfach, die Zettel nach einem Kriterium, z. B. dem Namen des Kunden, zu sortieren. Schwierig wird es, wenn man gleich-

*verlorene oder
verfälschte Da-
ten*

zeitig wissen will, welche Artikel wie oft in den letzten Monaten verkauft wurden. Eine Möglichkeit ist die Erstellung von Kopien der Aufträge, die in einem Aktenordner für die jeweiligen Artikel gesammelt werden. Die zweite Möglichkeit ist das manuelle Übertragen von Bestellinformationen in ein zusätzliches Dokument. Beide Ansätze werden problematisch, wenn sie häufiger angewandt werden. Viele Informationen müssen verdoppelt werden, was fehleranfällig ist, wenn das Kopieren oder Übertragen vergessen wird und sehr schwer änderbar ist, wenn z. B. ein Kunde einen Artikel zurück schickt.

1.2

*Probleme von
Dateisystemen*

Anforderungen an eine Datenbank

Um die Verwaltung von Daten zu vereinfachen, wird dieser Prozess schrittweise immer mehr durch Software unterstützt. Dies fing an mit einfachen Dateien, in denen die Daten gespeichert wurden, was zu ähnlichen Problemen wie bei der im vorherigen Unterkapitel skizzierten Zettelwirtschaft führte. Aktuelle Systeme lösen die Problematik durch eine sinnvolle Strukturierung der Daten. Dabei ist der Datenbank-Entwickler für die Erstellung dieser Struktur zuständig, die von einer Datenbank-Software verwaltet wird.

*Daten und In-
formationen*

Man spricht von der Verwaltung von Daten und typischerweise nicht Informationen. Ein Datum ist ein einfacher Wert, wie die Zahl 42. Erst wenn die Bedeutung, also die Semantik eines Datums bekannt ist, wird daraus eine Information. Ein Nutzer der Datenbank erhält z. B. die Information, dass von einem Artikel noch 42 Stück im Lager vorhanden sind. Die Datenbank verwaltet dazu das Datum 42 und ein Datum mit dem Text „Bestand“, das dem Datum 42 zugeordnet werden kann.

Was sind die Grundanforderungen an eine Datenbank?

Forderung 1: Persistenz

Werden Daten in die Datenbank eingetragen, sollen sie gespeichert bleiben, auch wenn die Software, die die Daten eingetragen hat, beendet wurde. Die Daten können von einer anderen Software wieder bearbeitet werden.

In der typischen Programmierung sind Daten flüchtig, d. h. sie werden erzeugt und weiter bearbeitet, aber nach der Beendigung der Programmausführung kann man nicht mehr auf sie zugreifen. Durch das direkte Speichern von Daten auf einem Speichermedium oder einer Datenbank

werden die Daten später wieder verwendbar, also *persistent*.

Forderung 2: Anlegen von Datenschemata

Grundsätzlich können identische Daten verschiedene Bedeutungen haben. Ein Datum 42 kann für eine Artikelanzahl oder eine Hausnummer stehen. Aus diesem Grund muss man festhalten können, in welchem Zusammenhang ein Datum genutzt wird.

Artikel

Artikelnummer	Bezeichnung	Anzahl

Abb. 1.1: Tabelle als Datenschema für Artikel

In diesem Buch werden als Schema Tabellen genutzt. Die Daten werden in die einzelnen Zellen der Tabellen eingetragen, dabei gehören Daten in einer Zeile zusammen. Jede der Spalten enthält eine Beschreibung, welche Daten sie enthält. Ein einfaches Beispiel für ein *Datenschema* für Artikel, in dem noch keine Daten eingetragen sind, befindet sich in Abb. 1.1.

Forderung 3: Einfügen, Ändern und Löschen von Daten

Der Nutzer muss die Möglichkeit haben, Daten in die Datenschemata einzutragen, diese später zu ändern und, wenn gewünscht, auch wieder zu löschen.

Artikel

Artikelnummer	Bezeichnung	Anzahl
12345	Schnuller	42
12346	Latzhose	25
12347	Teddy	6

Abb. 1.2: Gefülltes Datenschema

Abb. 1.2 zeigt das vorher angelegte Datenschema, das beispielhaft mit Daten gefüllt wurde. Man spricht bei den einzelnen Zeilen dabei von *Datensätzen*. Jeder der drei eingetragenen Datensätze besteht aus drei einzelnen Daten.

Forderung 4: Lesen von Daten

Wichtigste Aufgabe bei der Nutzung einer Datenbank ist die Schaffung einer Möglichkeit, Daten aus der Datenbank wieder abzurufen. Es muss z. B. festgestellt werden können, ob es einen Eintrag in der Datenbank zur Artikelnummer 12347 gibt und welche zusätzlichen Daten zu diesem Artikel existieren.

Ein Softwaresystem, das alle genannten Grundforderungen erfüllt, wird *Datenbank*, abgekürzt DB, genannt. Diese Grundforderungen werden im folgenden Unterkapitel um Forderungen ergänzt, deren Erfüllung die Arbeit mit Datenbanken wesentlich erleichtert.

1.3

Anforderungen an ein Datenbank-Managementsystem

*Elementare Datenbanken
kaum nutzbar*

Mit etwas Programmiererfahrung ist es nicht schwierig, ein System zu schreiben, das die Forderungen an eine Datenbank aus dem vorherigen Unterkapitel erfüllt. Allerdings ist solch ein System nur sehr eingeschränkt nutzbar, da keine Zusammenhänge zwischen den Datenschemata berücksichtigt werden und es unklar ist, was passiert, wenn mehrere Personen gleichzeitig auf Daten zugreifen. Aus diesem Grund wird die eigentliche Datenbank in ein Datenbank-Managementsystem, kurz DBMS, eingebettet, das dem Nutzer neben der Funktionalität der Datenbank weitere Funktionalität bietet, wie in Abb. 1.3 skizziert.




Abb. 1.3: Kapselung der Datenbank im DBMS

Im Folgenden werden anhand von Beispielen die typischen Anforderungen an ein DBMS vorgestellt.

Eine Datenbank besteht typischerweise aus vielen Datenbankschemata. Zwischen den eingetragenen Informationen können *Abhängigkeiten* bestehen.

Artikel

Artikelnummer	Bezeichnung	Anzahl
12345	Schnuller	42
12346	Latzhose	25
12347	Teddy	6

Artikeleinkauf

Artikelnummer	Firma
12345	Babys Unlimited
12346	Cool Clothes AG
12347	Babys Unlimited

Abb. 1.4: Verknüpfte Daten

In Abb. 1.4 sind in der Tabelle Artikel einige Beispielartikel eingetragen. Die Tabelle Artikeleinkauf enthält die Informationen, von welcher Firma die Artikel bezogen werden. Es besteht eine Verknüpfung zwischen den Tabellen, da sich eine Artikelnummer in der zweiten Tabelle auf die Artikelnummer in der ersten Tabelle bezieht. Man kann so zu dem Namen eines Artikels die liefernde Firma ermitteln. Wichtig ist, dass diese Verknüpfung nicht zufällig aufgelöst werden kann. Wenn sich die Artikelnummer in der Tabelle Artikel ändern soll, so muss sich diese Nummer auch in der Tabelle Artikeleinkauf ändern.

*Beziehungen
zwischen Tabellen*

Artikel

Artikelnummer	Bezeichnung	Anzahl
12345	Schnuller	42
12346	Latzhose	25
12347	Teddy	6

Artikeleinkauf

Artikelnummer	FirmaNr
12345	1
12346	2
12347	1

Firma

FirmaNr	Firma
1	Babys Unlimited
2	Cool Clothes AG

Abb. 1.5: Verbesserte Tabellenstruktur

Problem durch Redundanz

Ein zweites Problem wird in Abb. 1.4 deutlich. Ändert sich der Name eines Zulieferers z. B. dadurch, dass die Firma aufgekauft wird, muss diese Änderung in allen betroffenen Zeilen durchgeführt werden. Dieses Problem ist allerdings alleine durch das Datenbankmanagement-System schwer zu lösen, da die hier genutzte Tabellenstruktur nicht optimal ist. Besser ist die in Abb. 1.5 gezeigte Struktur, bei der an einer zentralen Stelle der Firmenname geändert werden kann. Wichtig ist aber generell, dass die *redundanzfreie Datenhaltung*, d. h. es gibt nur eine Quelle jeden Datums, unterstützt wird. Wird die korrekte Veränderung von Verknüpfungsinformationen garantiert, wird dies mit dem Begriff *Integrität* beschrieben.

Forderung 5: Integrität und redundanzfreie Datenhaltung

Das Datenbank-Managementsystem unterstützt die Möglichkeit, dass ein Datum, das an verschiedenen Stellen benutzt wird, nur an einer Stelle definiert ist. Es wird sichergestellt, dass Änderungen dieses Datums dann alle Nutzungsstellen im System betreffen.

Problem bei paralleler Nutzung

Datenbanken werden häufig von vielen verschiedenen Nutzern, Menschen wie Software-Systemen, zur gleichen Zeit genutzt. Datenbanken gehören damit zu den Anwendungen, bei denen der Zugriff verschiedener Nutzer *synchronisiert* werden muss. Eine besondere Problematik entsteht, wenn der Zugriff auf dieselbe Information fast gleichzeitig stattfindet.

Abb. 1.6 zeigt ein Beispiel, bei der zwei Nutzer fast gleichzeitig eine Bestellung bearbeiten, in der der gleiche Artikel bestellt wird. Dabei soll die Artikelanzahl bei einer Bestellung automatisch um Eins reduziert werden. Damit sichergestellt ist, dass ein Artikel vorhanden ist, wird vorher überprüft, ob von diesem Artikel noch mindestens einer im Lager ist. Bei der parallelen Bearbeitung kann das in Abb. 1.6 beschriebene Problem auftreten. Beide Nutzer erhalten die Information, dass noch ein Artikel vorhanden ist. Nach der Ausführung der Bestellung ist die Artikelanzahl -1, da zwei Artikel versandt werden sollen. Der Sinn der Eingangsprüfung war aber, dass die Anzahl niemals negativ werden kann.




Abb. 1.6: Probleme beim parallelen Zugriff auf Daten

Ein Datenbank-Managementsystem sorgt dafür, dass die dargestellten Aktionen nicht ineinander vermischt auftreten können. Die Umsetzung kann sehr unterschiedlich sein und ist auch durch die folgende Forderung nicht vorgegeben. Eine mögliche Reaktion wäre, die Antwort auf die Frage bei der Bestellung 2 solange zu verzögern, bis alle Aktionen der Bestellung 1 abgelaufen sind. Eine alternative Reaktion des Datenbank-Managementsystems ist, dass die gewünschte Aktion nicht durchgeführt werden kann, da die Daten woanders genutzt werden.

Forderung 6: Koordination der parallelen Nutzung

Das Datenbank-Managementsystem muss dafür Sorge tragen, dass die Integrität der Datenbank durch die parallele Nutzung nicht verloren gehen kann. Jeder Nutzer muss bei der Durchführung seiner Aktionen den Eindruck haben, *alleine* die Datenbank zu nutzen.

Nach den bisherigen Forderungen kann jeder Nutzer jede Datenbankfunktionalität nutzen und auf jedes Datum zugreifen. Dies ist bei größeren Systemen nicht der Fall. Der Aufbau einer

Rechte bestimmter Nutzergruppen

Datenbank, d. h. das Anlegen der Datenschemata, soll nur Personen ermöglicht werden, die die Auswirkungen auf das Gesamtsystem kennen. Dies ist insbesondere auch bei Löschaktivitäten zu beachten. Weiterhin kann es sein, dass einige Nutzer nicht alle Informationen eines Datenschemas einsehen können sollen. Wird z. B. eine Datenbank zur Projektverwaltung entwickelt, müssen einige grundlegende Daten aller Mitarbeiter, wie Namen und Personalnummern, für die Datenbankentwicklung zugreifbar sein. Werden diese Informationen zu Mitarbeitern in einer Tabelle verwaltet, in der auch das Gehalt eingetragen ist, soll die vollständige Information wahrscheinlich den Datenbankentwicklern nicht zugänglich sein.

Forderung 7: Rechteverwaltung

Das Datenbank-Managementsystem ermöglicht es, die Rechte an der Erstellung und Löschung von Datenschemata sowie die Erstellung, Löschung und Veränderung von Daten für einzelne Nutzer individuell zu definieren. Das System stellt die Einhaltung der mit den Rechten verbundenen Einschränkungen sicher.

Auswirkungen eines Datenverlustes

Weder Computer noch Software können so erstellt werden, dass sie absolut ausfallsicher sind, also nur der Nutzer bestimmen kann, wann ein Programm beendet und der Computer ausgeschaltet werden kann. Gerade bei Datenbanken kann dies zu extrem problematischen Situationen führen. Falls im Versandhaus die eingehenden Bestellungen eines Tages verloren gehen, bedeutet dies neben einem Umsatzverlust einen finanziell ebenfalls schergewichtigen Image-Verlust, da das Unternehmen bei den betroffenen Kunden als unzuverlässig angesehen wird. Datenbank-Managementsysteme ermöglichen es, *Sicherungen* des aktuellen Datenbestandes herzustellen und diese möglichst schnell wieder einzuspielen.

Forderung 8: Datensicherung

Das Datenbank-Managementsystem ermöglicht es, Sicherungen des aktuellen Datenbestandes herzustellen und diese wieder in das System einzuspielen.

Die letzte Forderung wird in der Realität oft dadurch erweitert, dass auch Aktionen, die seit der letzten Sicherung abgeschlossen wurden, wieder eingespielt werden können sollen.

Meta- Informationen

Wenn man lange mit einem Datenbank-Managementsystem arbeitet, kann es leicht passieren, dass man die genaue Struktur eines Datenschemas oder einer Integritätsregel vergisst. Das Datenbank-Managementsystem soll diese Informationen Nutzern zur Verfügung stellen können. Als Fachbegriff werden hier häufig *Katalog* und *Data Dictionary* genutzt.

Forderung 9: Katalog

Das Datenbank-Managementsystem ermöglicht es bestimmten Nutzern, Informationen über die gesamte Struktur des Systems zu erhalten. Dazu gehören die vorhandenen Datenschemata, Integritätsbedingungen und Nutzerrechte.

Ein Softwaresystem, das alle genannten Forderungen erfüllt und den Zugriff auf die Datenbank-Funktionalität ermöglicht, wird *Datenbank-Managementsystem*, genannt.

In diesem Buch wird der Begriff Datenbank meist für ein Datenbank-Managementsystem genutzt. Das ist in der Praxis üblich, da für externe Nutzer des Datenbank-Managementsystems die Trennung von der eigentlichen Datenbank irrelevant ist. Diese Trennung ist wichtig für Personen, die sich mit der Entwicklung der Software von Datenbanken und Datenbank-Managementsystemen beschäftigen. Die Fragestellung, wie man eine Datenbank als Software realisiert, wird nicht in diesem Buch verfolgt. Die explizite Nutzung des Begriffs Datenbank-Managementsystem findet nur an Stellen statt, an denen darauf hingewiesen werden soll, dass es Unterschiede bei der Behandlung bestimmter Themen bei verschiedenen Anbietern von Datenbank-Managementsystemen gibt.

1.4

Ebenen eines Datenbank-Managementsystems

Am Ende des vorherigen Unterkapitels wurde bereits angedeutet, dass unterschiedliche Personenkreise an verschiedenen Aspekten einer Datenbank interessiert sind. Diese Interessen kann man bei der Betrachtung von Datenbanken eindeutig trennen, man spricht von Ebenen der Datenbank. Eine Übersicht der Ebenen ist in Abb. 1.7 dargestellt und wird im Folgenden genauer erklärt.




Abb. 1.7: Ebenen eines DBMS

physische Ebene

Die Funktionsvielfalt und viele Qualitätsaspekte hängen von der Implementierung der Datenbank ab. Dabei muss eine Software geschrieben werden, die alle aufgestellten Forderungen möglichst effizient erfüllt. Man kann sich vorstellen, dass eine Optimierung in Richtung der Erfüllung aller Anforderungen kaum möglich ist. Eine Datenbank, bei der man sehr schnell Daten einfügen kann, kann nicht gleichzeitig extrem schnell beim Auslesen der Daten sein, da in benutzten Datenstrukturen entweder das schnelle Einfügen, damit aber ein langsames Finden, oder ein schnelles Finden, damit aber ein langsames Einfügen unterstützen. Kompromisse mit guten Reaktionszeiten für beide Aufgaben sind möglich.

Die Realisierung und Wartung einer Datenbank findet auf der *physischen Ebene* statt. Hier werden u. a. die effiziente Speicherung und das schnelle Auffinden von Daten geregelt und weitere wichtige Grundlagen für die Performance des Systems gelegt.

Datenbank-Administrator

Damit ein Datenbank-Managementsystem für unterschiedliche Nutzungen effizient eingesetzt werden kann, sind viele Einstellungen, die stark die Schnelligkeit aber auch z. B. die Sicherheit im Absturzfall beeinflussen, von außen veränderbar. Personen, die sich auf dieser Ebene auskennen und die Verantwortung für diese Teile des Systems übernehmen, werden *Datenbank-Administratoren* genannt.

logische Ebene

Zentral für die fachliche Qualität einer Datenbank ist die Auswahl sinnvoller Tabellen und Verknüpfungen der Tabellen untereinander. Der Prozess, mit dem für den Endnutzer ein sinnvolles

System, basierend auf Tabellen, entwickelt wird, ist in den folgenden Kapiteln beschrieben. Die Tabellen sind also das Herzstück der eigentlichen Datenbank. Durch die Einhaltung der Forderungen aus dem vorherigen Unterkapitel wird bei einer sinnvollen Tabellenstruktur die effiziente Nutzbarkeit garantiert. Die Informationen über die Tabellen und ihre Verknüpfungen werden *als logische Ebene* bezeichnet.

Welche Firma?

Ausgabe

Firma	Anzahl gelieferter Artikel
Babys Unlimited	2

Abb. 1.8: Einfache Maske zur Datenabfrage

*individuelle
Nutzersicht*

*Darstellung be-
rechneter Werte*

externe Ebene

beteiligte Rollen

Nutzer einer Datenbank sind typischerweise nicht an der Art der Realisierung der Datenbank interessiert. Sie wollen ein effizientes und funktionierendes System. Nutzer dürfen häufig nicht alle Daten ändern und erhalten so ihre eigene *Sicht*, englisch *View*, auf das System. Neben ausgeblendeten Daten ist es auch möglich, dass der Nutzer Daten sieht, die nicht direkt auf der logischen Ebene vorhanden sind, sondern aus vorliegenden Daten berechnet werden. Ein Beispiel ist die Information zu jeder Firma, wie viele verschiedene Artikel sie liefert. Die Information wird nicht direkt auf der logischen Ebene verwaltet, da sie redundant wäre. Die Information kann aus den anderen Informationen berechnet werden. Typisch für diese *externe Ebene* sind Masken, bei denen der Nutzer Eingaben tätigen und sich berechnete Ausgaben ansehen kann. Ein einfaches Beispiel ist in Abb. 1.8 gezeigt.

In Abb. 1.9 wird zusammengefasst, wer der jeweilige Hauptnutzer einer Ebene und wer der Ersteller dieser Ebene ist. Dieses Buch beschäftigt sich hauptsächlich mit der Datenbank-Entwicklung. Einige grundlegende Informationen zur Datenbank-Administration werden ergänzt. Die Algorithmen und Ideen, die zur Entwicklung einer Datenbank-Software benötigt werden, werden z. B. in [SH99] dargestellt.




Abb. 1.9: Nutzer und Entwickler der Ebenen

Schichtenarchitektur von Software

Durch die Trennung in Ebenen kann man nicht nur verschiedene Interessens- und Aufgabenbereiche charakterisieren, es ist auch möglich, die Entwicklung zu strukturieren. Komplexe Softwaresysteme werden in mehreren Schichten entwickelt. Die Grundidee ist, dass jede Schicht eine Hauptaufgabe übernimmt und dass ihre Entwicklung möglichst unabhängig von den anderen Schichten erfolgen kann. Dabei ist eine Schicht dazu verpflichtet, die Forderungen einer darüber liegenden Schicht zu erfüllen, und kann dabei die Funktionalität der darunter liegenden Schicht nutzen.

Oberflächengestaltung

Diese Idee kann wie folgt auf die Datenbankentwicklung übertragen werden. In der externen Sicht geht es zentral um die Entwicklung der Oberflächen. Wichtig ist es, möglichst einfach nutzbare Oberflächen zu entwickeln, die die vom Nutzer mit der Software durchgeführten Arbeiten optimal unterstützt. Hier spielt das Themengebiet *Usability*, also die Gestaltung der Mensch-Maschine-Schnittstelle, siehe z. B. [SP05] und [RC02], eine zentrale Rolle. Diese Aufgabe kann von Oberflächen-Designern übernommen werden. Zu beachten ist, dass nicht nur Menschen direkt mit der Datenbank arbeiten müssen, sondern dass es hier alternativ oder zusätzlich um die Gestaltung funktionaler Schnittstellen zu anderen Systemen geht.

Tabellenstrukturen aus Nutzerforderungen ableiten

Alle Nutzer der Datenbank zusammen definieren, welche Aufgaben sie mit dem System erfüllen wollen. Hieraus ergeben sich die Anforderungen der logischen Ebene, in der die Strukturen der Datenbank entwickelt werden. Es muss geklärt werden, welche Daten benötigt werden und wie diese Daten verknüpft sind.

Der Entwickler auf der logischen Ebene braucht nicht über die Oberflächengestaltung nachzudenken. Das Resultat der logischen Ebene sind Tabellenstrukturen, die auf der physischen Ebene umgesetzt werden müssen.

Auf der physischen Ebene geht es um die Realisierung der gewünschten Tabellen im Datenbank-Managementsystem. Bei der Umsetzung muss nicht über die Sinnhaftigkeit des Modells nachgedacht werden, da diese Arbeit von der vorherigen Ebene abgenommen wurde. Es muss aber sichergestellt sein, dass die angelegten Tabellen die aufkommenden Datenmengen effizient verarbeiten können.

1.5 **[*] Die weiteren Kapitel**

Nachdem in den bisherigen Unterkapiteln beschrieben wurde, warum Datenbanken sinnvoll sind und welche Aufgaben ein Datenbank-Managementsystem übernimmt, soll hier als Ausblick für Neugierige kurz dargestellt werden, welchen Beitrag die einzelnen Kapitel zur systematischen Datenbankentwicklung liefern.

Kapitel 2

Im Kapitel 2 wird der erste zentrale Schritt beschrieben, der maßgeblich für den Erfolg eines Datenbank-Entwicklungsprojekts ist. Die Anforderungen der Nutzer müssen soweit im Detail durchdrungen werden, dass deutlich wird, welche Daten zur Erstellung der Datenbank benötigt werden. Weiterhin sind die Zusammenhänge zwischen den Daten relevant. Der Ersteller des Datenbankmodells muss dazu die Arbeitsweise des Nutzers und den späteren Einsatz des entwickelten Systems genau verstehen.

Kapitel 3

Das Ergebnis des Kapitels 2 ist eine Formalisierung der notwendigen Daten in einem Entity-Relationship-Modell. Im Kapitel 3 wird gezeigt, wie man systematisch aus solchen Diagrammen Tabellenstrukturen ableiten kann.

Kapitel 4

Bereits in diesem Kapitel wurde in Abb. 1.4 angedeutet, dass es gelungene und schlechte Tabellenstrukturen gibt. Durch die im Kapitel 4 beschriebenen Normalformen werden Indikatoren definiert, an denen man gelungene Tabellenstrukturen erkennen kann. Es wird weiterhin gezeigt, wie man Tabellenstrukturen durch Umformungen verbessern kann.

Kapitel 5

Das Kapitel 5 zur Relationenalgebra ist vollständig mit einem [*] gekennzeichnet, da es den Einstieg in theoretische Überlegungen über Datenbanken ermöglicht. Forschungen zum Thema Datenbanken setzen typischerweise nicht auf konkreten Datenbanken, sondern auf abstrakteren formalen Modellen auf. Interessanter-

weise hat die Lehrpraxis gezeigt, dass dieses Kapitel auch von Wirtschaftsingenieuren gut angenommen wird, da es die Möglichkeiten zur Nutzung von Datenbank-Anfragen sehr systematisch aufzeigt. Da die hier verwendete Notation keine Gemeinsamkeit mit irgendwelchen Programmiersprachen hat, kann so die Angst einiger Informatik-unerfahrener Studierender vor Programmiersprachen abgefangen werden.

Kapitel 6

Im Kapitel 6 wird beschrieben, wie man Tabellen und ihre Beziehungen untereinander in SQL festhalten kann. Weiterhin wird gezeigt, wie man Daten in die Tabellen füllt und sie ändert sowie löscht.

Kapitel 7,8,9

Die Formulierung von SQL-Anfragen bildet einen zweiten Schwerpunkt dieses Buches, dem die drei Kapitel 7, 8, und 9 gewidmet sind. SQL ist eine standardisierte Anfragesprache, mit der man vorher in der Datenbank abgespeicherte Daten systematisch für Auswertungen aufbereiten kann. Dies geht von einfachen Anfragen, bei denen nur die direkt eingetragenen Daten wieder sichtbar werden sollen, bis zu sehr mächtigen Auswertungen, in denen verschiedene Daten aus unterschiedlichen Tabellen zu neuen Erkenntnissen verknüpft werden.

SQL-Anfragen können logisch strukturiert entwickelt werden. Dieser schrittweisen Entwicklungsmöglichkeit folgt dieses Buch. Es zeigt, dass man mit etwas analytischem Geschick zu SQL-Anfragen kommen kann, die die Einsatzmöglichkeit der Datenbank wesentlich erhöhen. Wichtig ist dabei, dass kein Verständnis von Programmiersprachen wie C, C++, C#, COBOL oder Java notwendig ist.

SQL-Wissen maßgeblich für Projekte mit Datenbankbe- zug

Das Verständnis der Möglichkeiten von SQL-Anfragen hat auch eine zentrale, praxisrelevante Seite. Fast kein Software-Entwicklungsprojekt kommt ohne die Einbindung einer Datenbank aus. Dabei müssen häufig Zusammenhänge zwischen Daten in der Datenbank berechnet werden. Hat man keine fähigen SQL-Anfragschreiber, folgen diese häufig dem Ansatz, die Tabellen mit den notwendigen Informationen aus der Datenbank heraus zu lesen und die Zusammenhänge in der Programmiersprache mit einem eigenen Verfahren zu berechnen. Dieser Ansatz ist fehlerträchtig und verlangsamt Programme. Mit etwas SQL-Wissen würden die Zusammenhänge in einer Anfrage in der Datenbank berechnet und dann die Ergebnisse aus der Datenbank in die Programmiersprache eingelesen. Dieser Ansatz ist schneller und weniger fehleranfällig, da die Berechnung der Zusam-

menhänge einem Experten, nämlich der Datenbank überlassen wird.

Kapitel 10

Zum Verständnis von Datenbanken ist es wichtig zu erkennen, dass Datenbanken häufig von verschiedenen Nutzern zur gleichen Zeit genutzt werden können. Die Frage, was passiert, wenn mehrere Nutzer Tabellen gleichzeitig bearbeiten wollen, wird durch Transaktionen im Datenbank-Managementsystem geregelt. Die Probleme, die bei der gleichzeitigen Nutzung von Tabellen auftreten können und welche Lösungsansätze es zu ihrer Vermeidung gibt, werden im Kapitel 10 behandelt.

Kapitel 11

Wenn mehrere Nutzer die gleiche Datenbank nutzen, muss immer geregelt sein, wer was machen darf. Dahinter steht das im Kapitel 11 behandelte Rechtesystem.

1.6

Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Fragen aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu beantworten.

1. Nennen Sie typische Probleme, die bei einer Datenverwaltung ohne Software-Unterstützung auftreten können.
2. Nennen Sie die vier Forderungen, die eine Software erfüllen muss, damit es sich um eine Datenbank handelt. Veranschaulichen Sie die Forderungen durch Beispiele.
3. Nennen Sie die fünf zusätzlichen Forderungen, die eine Software erfüllen muss, damit es sich um ein Datenbank-Managementsystem handelt. Veranschaulichen Sie die Forderungen durch Beispiele.
4. Beschreiben Sie die drei Ebenen, die man bei einer Datenbank unterscheiden kann. Nennen Sie, wer sich mit der Erstellung der Ebenen beschäftigt und wer diese Ebenen nutzt.

Übungsaufgaben

1. In einem kleinen Unternehmen findet die Datenverwaltung ohne Software statt. Das Unternehmen wickelt Bestellungen ab, die mehrere Artikel umfassen können und in schriftlicher Form vorliegen. Um schnell reagieren zu können, werden auch nicht vollständige Bestellungen versandt und dem Kunden mitgeteilt, dass die weiteren Artikel nicht lieferbar sind. Der Kunde müsste bei Bedarf diese Artikel wieder neu

bestellen. Zur Analyse der Abläufe möchte man eine Übersicht haben, wie viele Bestellungen ein Kunde gemacht hat und wie hoch seine bisherige Bestellsomme war. Weiterhin soll bekannt sein, wie häufig ein Artikel bestellt wurde und wie häufig dieser Artikel nicht vorrätig war, obwohl eine Bestellung vorlag. Beschreiben Sie den Arbeitsablauf mit seinen möglichen Alternativen, so dass alle Informationen erfasst werden können.

2. Die Probleme, die auftreten können, wenn alle Daten ausschließlich in Textdateien verwaltet werden, sind im Kapitel skizziert worden. Überlegen Sie sich konkrete Probleme, die auftreten könnten, wenn ein Versandhaus alle Daten in Dateien verwalten würde. Überlegen Sie zusätzlich, was für eine Software dabei hilfreich wäre, wenn Sie keine Datenbank kaufen oder entwickeln dürften.
3. Sinn des vorgestellten Ebenenmodells ist es, dass bei verschiedenen Nutzungen und Änderungen der Datenbank möglichst wenig Ebenen betroffen sind. Geben Sie für die im Folgenden genannten Operationen an, auf welchen Ebenen Änderungen durchzuführen sind, also der Oberflächen-Designer, der Datenbank-Entwickler oder der Datenbank-Administrator aktiv werden müssen. Es ist möglich zu notieren, dass eine oder mehrere Ebenen hauptsächlich oder/und etwas betroffen sind. Gehen Sie von einer laufenden Datenbank aus.
 - a. In einer Eingabemaske soll ein Feld mit einer weiteren Auswahlmöglichkeit eingefügt werden. Die Information über die Auswahlmöglichkeiten ist bereits in den Tabellen vorhanden.
 - b. Das gesamte Datenbank-Managementsystem soll ausgetauscht werden.
 - c. Es sollen zusätzliche Informationen, wie das bisher nicht vorhandene Geburtsdatum eines Mitarbeiters, in einer neuen Tabelle aufgenommen werden.
 - d. Es wird eine neue Abhängigkeit zwischen den Daten entdeckt, die zusätzlich aufgenommen wird.
 - e. Es wird festgestellt, dass neben der Ausgabe einzelner Daten auch immer die Summe dieser Daten angezeigt werden soll.

- f. Es sollen neue Daten in die Datenbank eingetragen werden.
 - g. Zwei existierende Datenbanken mit identischer Tabellenstruktur, aber unterschiedlichen Inhalten, sollen zu einer Datenbank zusammengefasst werden.
 - h. Es sollen Daten in der Datenbank gelöscht werden.
 - i. Der Speicherplatz für eine Tabelle soll vergrößert werden.
 - j. Es soll eine neue Festplatte eingebaut werden, auf der Teile der Datenbank laufen sollen.
- 4.[*] Überlegen Sie sich, wie Sie eine einfache Datenbank in einer von Ihnen ausgewählten Programmiersprache realisieren würden. Gehen Sie vereinfachend davon aus, dass nur Tabellen mit drei Spalten angelegt werden. Es reicht aus, die Signaturen, d. h. die Kopfzeilen der Funktionen oder Methoden anzugeben.

Überlegen Sie im nächsten Schritt, welche der Forderungen an ein Datenbank-Managementsystem Sie umsetzen können.

2

Anforderungsanalyse für Datenbanken

Die Formulierung präziser Anforderungen ist entscheidend für den Erfolg eines Datenbank-Projektes. In diesem Kapitel lernen Sie, wie die Anforderungsanalyse als Teil eines Software-Entwicklungsprojekts sinnvoll durchgeführt und wie die Ergebnisse kompakt in einem Modell erfasst werden können.

Nutzbarkeit als zentraler Aspekt

Maßgeblich für den Erfolg von Software-Projekten ist, dass das resultierende Produkt vom Kunden bzw. späteren Nutzern akzeptiert wird. Dies beinhaltet neben der *funktionalen Korrektheit*, d. h. die Software stürzt nicht ab und hat auch sonst keine Fehler, die Nutzbarkeit der Software. Die *Nutzbarkeit* hängt dabei nicht nur von der Oberfläche sondern hauptsächlich davon ab, ob die Software die Arbeit, für die sie entwickelt wurde, erleichtert. Müssen für Eingaben sehr viele Eingabemasken verwandt werden, die nicht leicht zu finden sind und in denen man Standardwerte immer wieder erneut von Hand eintragen muss, ist eine Software wenig nützlich. Können z. B. einige Detailinformationen zu eingekauften Artikeln in einem Versandhaus nicht eingetragen werden, ist der Nutzen der Software stark reduziert.

A und O: Dialog mit dem Kunden

Um solche Probleme zu vermeiden, müssen Entwickler in Software-Projekten frühzeitig mit dem Kunden und den späteren Nutzern reden, um zu erfahren, was sie sich vorstellen. Dazu muss ein gewisses Verständnis der Arbeitsabläufe des Kunden, genauer dessen *Geschäftsprozesse* [Gad03], erworben werden, die mit der zu entwickelnden Software im Zusammenhang stehen.

Frage nach Daten und Zusammenhängen

Datenbanken werden typischerweise als Teile solcher Software-Projekte erstellt. Zentral für die Nutzbarkeit der Datenbank ist die Beantwortung der Frage, welche Daten mit welchen Zusammenhängen in der Datenbank verwaltet werden sollen. Diese Informationen sind ein Teilergebnis der Analyse der durch die Software zu unterstützenden Prozesse.

Da der Erfolg von Datenbanken eng mit dem Gesamterfolg von Software-Projekten verknüpft ist, wird im folgenden Unterkapitel zunächst der Software-Entwicklungsprozess genauer betrachtet. Diese Betrachtung wird dann für die Anforderungsanalyse ver-

feinert. Die detaillierte Anforderungsanalyse für Datenbanken und die daraus entstehenden Entity-Relationship-Modelle, sowie einige spezielle Betrachtungen zu Entity-Relationship-Modellen folgen im Anschluss. Vor der Beschreibung der Fallstudie, die in den folgenden Kapiteln weiter betrachtet wird, wird in einem mit [*] gekennzeichneten Unterkapitel kurz auf den Zusammenhang zwischen Entity-Relationship-Modellen und objektorientierten Modellen eingegangen.

2.1

Überblick über den Software-Entwicklungsprozess

In einer sehr abstrakten Sichtweise kann man den *Software-Entwicklungsprozess* in mehrere Phasen einteilen, in denen die Arbeit typischerweise von Personen in verschiedenen Rollen übernommen wird. Dabei ist es nicht unüblich, dass eine Person mehrere dieser Rollen übernehmen kann.




Abb. 2.1: Einfacher Software-Entwicklungsprozess

In Abb. 2.1 ist ein einfacher klassischer Software-Entwicklungsprozess skizziert. Es beginnt mit der *Anforderungsanalyse*, in der ein Analytiker versucht, mit dem Kunden die Aufgaben des zu erstellenden Systems zu präzisieren. Dieser Schritt ist maßgeblich für die Qualität des Projektergebnisses, da alle folgenden Arbeitsschritte von der Anforderungsanalyse abhängen. Neben den funktionalen Aufgaben sind weitere Randbedingungen zu klären, wie die Hardware, auf der das zu entwickelnde System laufen soll und mit welcher anderen Software des Kunden das neue System zusammen arbeiten muss.

Typischerweise findet im nächsten Schritt nicht direkt eine Implementierung statt. Stattdessen wird das zu entwickelnde System zunächst vom Designer im *Systemdesign* geplant. Die Planungen beinhalten z. B. die Aufteilung der zu erstellenden Software in kleinere Teilsysteme, die von fast unabhängig arbeitenden Implementierern realisiert werden sollen. Weiterhin ist zu entscheiden, welche Mittel überhaupt eingesetzt werden, um eine Erfüllung der technischen Anforderungen zu ermöglichen.

In der *Implementierungsphase* findet die Programmierung statt. Dabei werden meist schrittweise kleine Teilprogramme zu einem großen Programm integriert. Die Entwickler führen dabei für die von ihnen erstellten Programmteile kleine Tests aus.

In der eigentlichen *Testphase* wird mit verschiedenen Testfällen geprüft, ob das entwickelte System wirklich die Kundenanforderungen erfüllt. Dabei wird geprüft, ob typische Arbeitsabläufe möglich sind und ob auch Grenzsituationen und Fehleingaben korrekt behandelt werden.

Danach wird das System dem Kunden vorgeführt, der es selber testet und nach einem erfolgreichen Test die *Abnahme* durchführt. Es folgt dann die *Garantiephase*, in der die Entwicklung gefundene Fehler beheben muss.

Wasserfallmodell

Der beschriebene Entwicklungsprozess wird *Wasserfallmodell* genannt. In der Realität ist es meist nicht möglich, die Phasen konsequent nacheinander abzuarbeiten. Grundsätzlich muss es bei gefundenen Problemen möglich sein, in frühere Phasen zurück zu springen.

Unsicherheit bei Anforderungen

Ein wesentliches Problem komplexer Systeme ist, dass man am Anfang nicht hundertprozentig weiß, was das letztendliche System können soll. Es ist schwierig, Anforderungen so präzise zu formulieren, dass genau das Ergebnis heraus kommt, das der Ersteller der Anforderungen wirklich wünscht. Weiterhin ist es typisch, dass sich im Laufe eines längeren Projekts Anforderungen des Kunden ändern, da sich Randbedingungen im Unternehmen verändern oder weitere Wünsche erst später entdeckt werden.




Abb. 2.2: Ablauf einer inkrementellen Entwicklung

Ziel

Das Ziel eines Software-Entwicklungsprojekts ist es, den Kunden im ausgehandelten Finanzrahmen zufrieden zu stellen. Aus diesem Grund ist es wichtig, auf sich ändernde Anforderungen im Laufe der Entwicklung reagieren zu können. Es gibt verschiedene Entwicklungsmethoden, die diese Herausforderung angehen.

Ein Lösungsansatz mit der *inkrementellen Entwicklung* ist in Abb. 2.2 skizziert. Dabei wird die Entwicklung in mehrere Phasen zerlegt, wobei jede der Phasen die Schritte des Wasserfallmodells durchläuft. Teilaufgaben des zu entwickelnden Systems, die noch unklar sind, werden in späteren Inkrementen realisiert. In Folgeinkrementen ist es auch möglich, auf sich ändernde Nutzeranforderungen oder veränderte technische Randbedingungen zu reagieren. Ein Folgeinkrement kann meist schon vor dem endgültigen Abschluss des vorherigen Inkrements begonnen werden.

In [Bal00] findet man einen Überblick über verschiedene Software-Entwicklungsprozesse. Diese Ansätze unterscheiden sich u. a. in dem Aufwand, der in die Dokumentation der gesamten Entwicklung gesteckt wird. Für kleinere Projekte kann man in einem gut zusammen arbeitenden Team mit sehr wenig Doku-

Vorgehensmodelle

mentation auskommen [Bec00]. In größeren Projekten muss geplant werden, wer was wann macht und wo die Ergebnisse dokumentiert sind. Beispielhaft seien für einen solchen Ansatz der Rational Unified Process [Kru04] und das Vorgehensmodell des Bundes, das V-Modell XT [VM05], genannt.

2.2

Anforderungsanalyse für Software

Wir haben gesehen, dass die Anforderungsanalyse maßgeblich für den Projekterfolg ist. Dies soll im Folgenden weiter konkretisiert werden.

unpräzise Anforderungen

In einem Versandhaus soll eine Software zur Abwicklung von Bestellungen entwickelt werden. In der ersten Beschreibung steht folgender Satz „Das System soll die Abwicklung von Bestellungen nach dem üblichen Ablauf unterstützen.“. Dieser Satz ist nur eine sehr generelle Beschreibung von dem, was der Kunde wirklich möchte. Würde die Entwicklung des Designs und die Implementierung von dieser Anforderung ausgehen, hätten die Bearbeiter sehr große Freiheitsgrade. Sie könnten „wilde“ Annahmen machen, was ein „üblicher Ablauf“ ist. Da man aber ein System entwickeln möchte, das die Kundenwünsche erfüllt, muss in der Anforderungsanalyse nachgefragt werden, was der Satz bedeutet.

Implizites Wissen

Eine solche Nachfrage muss nicht sofort zu einem zufrieden stellenden Ergebnis führen. Der Hauptgrund ist meist, dass die Person auf der Kundenseite, die die Frage beantwortet, ihre Arbeit sehr genau kennt und dabei kleine Details vergisst, die aber derjenige, der die Anforderungen aufnimmt, nicht kennen muss. Dieses *implizite Wissen* des Kunden muss sichtbar gemacht werden. Findet zunächst eine Konzentration auf eingehende Bestellungen statt, so kann eine genauere Anforderung wie folgt lauten:

schrittweise Verfeinerung von Anforderungen

„Schriftlich eingehende Bestellungen werden zunächst formal überprüft und sollen dann in das zu entwickelnde System per Hand eingetragen werden.“

Diese Anforderung ist schon wesentlich präziser und zeigt, dass Bestellungen elektronisch erfasst werden sollen. Trotzdem muss erneut z. B. nachgefragt werden, was „formal überprüfen“ bedeutet. Ein Laie hat zwar sicherlich eine Vorstellung dieser Überprüfung, trotzdem ist nicht seine Sicht, sondern die Sichtweise des Kunden gefragt. Es ist sinnvoll, diesen Prozess der *Verfeinerung von Anforderungen* solange fortzuführen, bis der Kunde

Visualisierung von Prozessen

glaubt, dass das beauftragte Software-Entwicklungsunternehmen, der Auftragnehmer, die Aufgabe verstanden hat. Der Auftragnehmer selbst muss sich wiederum sicher sein, die relevanten Entwicklungsinformationen zu haben. Hilfreich ist es dabei, eine Notation zu verwenden, die Kunde und Auftragnehmer verstehen. Hierzu gibt es verschiedene Notationen, um Abläufe zu visualisieren.




Abb. 2.3: Typischer Ablauf der Bestellerfassung

Prozessmodell- lierung

Die Entwicklung dieser Abläufe erfolgt meist inkrementell. Es wird zunächst der *typische Ablauf* beschrieben. In Abb. 2.3 ist der Prozess für eine erfolgreiche Erfassung einer Bestellung beispielhaft dargestellt. In den abgerundeten Rechtecken stehen einzelne Prozessschritte. Falls das Ergebnis eines solchen Schritts eine Entscheidung ist, folgt eine Raute. An den ausgehenden Kanten einer solchen Raute steht das Ergebnis der Entscheidung.

Dieser typische Ablauf wird dann durch *alternative Abläufe* ergänzt, die beschreiben, was in Ausnahmefällen passieren kann. Diese Ausnahmen werden wieder Schritt für Schritt in das Prozessmodell übernommen. Das Ergebnis einer solchen Prozessaufnahme ist in Abb. 2.4 beschrieben.




Abb. 2.4: Detaillierte Bestellerfassung

Da Prozessbilder eine große Aussagekraft haben, allerdings häufig Details noch zu präzisieren sind, die ein Diagramm unnötig komplex machen würden, können Anforderungen auch als Text aufgenommen werden. In dem einführenden Beispiel wurde deutlich, dass eine möglichst präzise Wortwahl gefunden werden muss. So schön sich Fließtexte lesen lassen, so schlecht sind sie als Ausgangspunkt einer Software-Entwicklung geeignet. Während man beim Schreiben einer Geschichte möglichst die Wiederholung von Worten vermeiden sollte, kann diese gerade bei der Formulierung von Anforderungen hilfreich sein.

Wege zur systematischen Erfassung von Prozessen sind in [Gad03] und [OWS03] beschrieben. Generell sollte man bei der Dokumentation für jeden Prozess folgende Fragen beantworten:

- Welche Aufgabe soll der Prozess erfüllen?
- Welche Voraussetzungen müssen erfüllt sein, damit der Prozess ablaufen kann?
- Welche Ergebnisse soll der Prozess produzieren?

*Anforderungen
als spezielle
Textform*

Fragen zur Prozessdoku- mentation

- Wie sieht der typische Ablauf des Prozesses aus?
- Welche alternativen Abläufe gibt es neben dem typischen Ablauf?
- Wer ist für die Durchführung des Prozesses verantwortlich und wer arbeitet wie mit?
- Welche Mittel (Arbeitsmittel, andere Software) werden zur Durchführung des Prozesses benötigt?
- Welche anderen Prozesse werden zur erfolgreichen Abarbeitung benötigt?




Abb. 2.5: Schablone zur Anforderungserstellung nach [Rup02]

In [Rup02] wird ein Ansatz beschrieben, mit dem Anforderungen in natürlicher Sprache geschrieben werden, wobei alle Sätze einer Schablone beim Aufbau folgen müssen. Abb. 2.5 zeigt die Schablone.

rechtliche Ver- bindlichkeit

Die verschiedenen Möglichkeiten in der Textschablone haben folgende Bedeutung: Durch die Wahl von „muss“, „soll“ und „wird“ wird die rechtliche Verbindlichkeit einer Anforderung geregelt. Dabei spielen „muss“-Anforderungen die zentrale Rolle, da sie rechtlich verbindlich sind. Mit „soll“-Anforderungen wird beschrieben, dass es aus Sicht des Fordernden sinnvoll erscheint, diese Anforderung zu berücksichtigen, es aber durchaus diskutiert werden kann, ob sie erfüllt werden muss. Mit „wird“-Anforderungen deutet der Kunde an, dass es schön wäre, wenn diese Anforderung erfüllt wäre. Damit kann z. B. beschrieben werden, welche weiteren Funktionalitäten noch in Folgeprojekten eingebaut werden und dass Möglichkeiten zu diesem Einbau bedacht werden sollen.

wirtschaftliche Lösung?

Aus Sicht des Auftragnehmers könnte man auf die Idee kommen, sich ausschließlich auf „muss“-Anforderungen zu beschränken. Dies ist dann nicht sinnvoll, wenn man einen Kunden zufrieden

Funktionale Anforderungs- typen

stellen möchte, da man an einer langfristigen Zusammenarbeit interessiert ist.

In der Schablone werden drei Arten von Anforderungen unterschieden. Diese Arten mit ihrer Bedeutung sind:

Typ 1: *Selbständige Systemaktivität*, d. h. das System führt den Prozess selbständig durch. Ein Beispiel ist das Auslesen der Kundendaten aus dem Datenbestand, nachdem eine Kundennummer eingegeben wurde.

Typ 2: *Benutzerinteraktion*, d. h. das System stellt dem Nutzer die Prozessfunktionalität zur Verfügung. Ein Beispiel die Verfügbarkeit eines Eingabefeldes, um die Kundennummer einzugeben.

Typ 3: *Schnittstellenanforderung*, d. h. das System führt einen Prozess in Abhängigkeit von einem Dritten (zum Beispiel einem Fremdsystem) aus, ist an sich passiv und wartet auf ein externes Ereignis. Ein Beispiel ist die Fähigkeit des Systems, die Anfrage nach den Bestellungen des letzten Jahres von einer anderen Software anzunehmen.




Abb. 2.6: Zusammenhang zwischen Anforderungstypen

Anforderungen vom Typ 1 beschreiben die zentrale Funktionalität, die typischerweise von Anforderungen des Typs 2 oder 3 an-

Zusammenspiel der Anforderungen

gestoßen werden. Beim Typ 2 wird z. B. die Möglichkeit geboten, Daten einzugeben und eine Funktionalität aufzurufen. Die eigentliche Ausführung dieser Funktionalität, die die Ergebnisanzeige einschließen kann, wird mit einer Typ 1-Anforderung formuliert. Dieser Zusammenhang ist in Abb. 2.6 skizziert.

Für das Beispiel der Bestellannahme kann man für den Anfang folgende strukturierte Anforderungen formulieren.

Anf001: Im angezeigten Bestellformular muss das System dem Nutzer die Möglichkeit bieten, eine Adressinformation einzugeben. (Typ 2)

Anf002: Nach der Eingabe einer Adressinformation muss das System die Adresse auf Gültigkeit prüfen können. (Typ 1)

Anf003: Nach der Prüfung einer Adresse auf Gültigkeit muss das System dem Nutzer das Prüfergebnis anzeigen. (Typ 1)

Anf004: Nachdem die Prüfung einer Adresse auf Gültigkeit gescheitert ist, muss das System in der Lage sein, die Information in einer Log-Datei zu vermerken. (Typ 1)

Glossar

Selbst bei den detaillierten Anforderungen fällt auf, dass Fragen bleiben können. Sinnvoll ist es deshalb, ein *Glossar* anzulegen, in dem Begriffe wie „Adressinformation“ und „Gültigkeit einer Adresse“ definiert werden.

Die Anforderungen wurden nummeriert. Diese Information kann genutzt werden, um zu verfolgen, ob und wo eine Anforderung erfüllt wurde. Insgesamt kann man so ein systematisches, typischerweise werkzeugunterstütztes *Anforderungstracing* aufsetzen, bei dem man genau erkennen kann, welche Anforderung wie realisiert wurde und wo weiterhin der Einfluss von Veränderungen sichtbar werden kann.

Die Frage, wie detailliert eine Anforderungsanalyse gemacht werden soll, hängt stark von der Größe des Projekts, der Komplexität der zu lösenden Aufgabe und der Gefahr ab, dass durch eine Fehlfunktion Menschenleben oder die Existenz von Unternehmen gefährdet sind.

2.3

Anforderungsanalyse für Datenbanken

Das Finden der Anforderungen, die speziell die Datenbank-Entwicklung betreffen, ist eine Teilaufgabe der Anforderungsana-

Finden von Daten

lyse. Dabei muss der Datenbank-Entwickler nicht alle Details der zu unterstützenden Prozesse kennen, obwohl dies die Arbeit erleichtern kann. Aus Sicht der Datenbank-Entwicklung stellt sich zentral die Frage nach den Daten, die in den einzelnen Arbeitsschritten benutzt werden. Aus diesem Grund müssen die im vorherigen Unterkapitel entwickelten Anforderungen weiter verfeinert werden. Für eine Bestellung stellt sich z. B. die Frage, aus welchen Daten diese besteht.

Miniwelt modellieren

Generell ist es die erste Aufgabe bei der Datenbank-Entwicklung, ein Modell einer *Miniwelt* zu erstellen, das zur Aufgabenstellung passt. Es handelt sich um eine Miniwelt, in der nur die Daten beachtet werden, die für die zu entwickelnde Software relevant sind. Von einem Kunden interessiert z. B. sein Name und seine Anschrift, für ein Versandunternehmen sind aber seine Nasenlänge und die Form des Bauchnabels uninteressant. Die letztgenannten Eigenschaften der realen Welt werden in der zu erstellenden Miniwelt nicht berücksichtigt. Der Inhalt dieser Miniwelt wird in einem Modell zusammengefasst. Das Modell soll dann die weitere Entwicklung der Datenbank erleichtern.

Für den Modellierer stellt sich die Frage nach den Objekten der realen Welt, die für die Aufgabenstellung relevant sind, und ihre Beziehungen zueinander. Genauer stellt sich die Frage nach den Entitäten, die eine Rolle spielen.

Definition Entität: Eine *Entität* ist ein individuelles, eindeutig identifizierbares Objekt, das durch Eigenschaften charakterisiert werden kann.

Konkretes Beispiel für eine Entität ist eine Bestellung, die vom Kunden Meier am 14.12.05 gemacht wurde. Diese Bestellung hat z. B. die Eigenschaft, dass sie an einem Datum aufgegeben wurde. Die Bestellung wird dadurch eindeutig, dass sie eine eindeutige Bestellnummer bei der Annahme der Bestellung erhält.

Für jede Eigenschaft kann man einen Namen dieser Eigenschaft, wie „Datum“ und „Bestellnummer“ festhalten. Zu jedem der Eigenschaften kann man einen Datentypen angeben, der die Werte charakterisiert, die diese Eigenschaft bei einer Entität annehmen kann. Beispiele für solche Datentypen sind: ganze Zahl, Fließkommazahl, Text, Datum. Solche Eigenschaften werden bei Datenbanken „Attribute“ genannt.

Definition Attribut: Ein *Attribut* besteht aus einem Namen und einem Datentypen. Attribute werden zur Modellierung von Eigenschaften genutzt.

Für den Modellierer sind nicht die individuellen Bestellungen interessant, sondern die Information an sich, dass Bestellungen in die Datenbank aufgenommen werden sollen. Man spricht hierbei vom Entitätstypen.

Definition Entitätstyp: Ein *Entitätstyp* ist eine Schablone mit einem eindeutigen Namen. Sie dient zur Zusammenfassung von Entitäten. In der Schablone werden alle Attribute zusammengefasst, von denen die Entitäten konkrete Ausprägungen haben.




Abb. 2.7: Bestellung modelliert als Entitätstyp

Generell hat sich in der Software-Entwicklung gezeigt, dass graphische Aufbereitungen komplexerer Sachverhalte, das Verständnis wesentlich erhöhen können. In der Datenbankentwicklung haben sich dabei sogenannte *Entity-Relationship-Modelle* als sinnvolle Darstellung von Zusammenhängen zwischen Daten herausgestellt.

*Darstellung von
Entitäten und
Attributen*

*identifizierende
Attribute*

*Trennung von
Attributen und
Entitätstypen*

Entitätstypen werden in Entity-Relationship-Modellen in einem Rechteck dargestellt. Die zugehörigen Attribute stehen in Ovalen, die mit dem Rechteck verbunden sind. Typischerweise markiert man das Attribut oder die Kombination von Attributen, mit dessen Wert oder deren Werten man eine zum Entitätstyp gehörende Entität eindeutig identifizieren kann, durch Unterstreichung. Abb. 2.7 zeigt eine *Entity-Relationship-Modell-Darstellung* einer Bestellung. Die Aussage des Bildes ist, dass Bestellungen durch die Bestellnummer eindeutig werden und dass es zu jeder Bestellung ein Bestelldatum geben kann.

Eine Bestellung hat als weitere typische Eigenschaft den Kunden, von dem sie aufgegeben wurde. Dieser Kunde soll auch in der Datenbank aufgenommen werden. Jeder Kunde wird dabei durch seine Kundennummer eindeutig, er hat einen Namen und eine Adresse. Diese Attribute könnte man für den Entitätstypen Bestellung ergänzen. Bei genauerer Überlegung kann man aber feststellen, dass ein Kunde durchaus mehrere Bestellungen durchführen kann. Dann hätte jede Bestellungen-Entität die identischen Eigenschaftswerte für den Kunden. Dies ist kritisch, da

man bei der Datenbank-Entwicklung den zentralen Wunsch hat, dass es nur eine Quelle für eine Information gibt, was im vorherigen Kapitel als Problem mit redundanten Daten beschrieben wurde. Aus diesem Grund ist es sinnvoll, Kunde als eigenständigen Entitätstypen aufzunehmen. Man beachte, dass hier die Namen der Entitätstypen immer in der Einzahl stehen. Diese Konvention wird meist bei der Erstellung von Entity-Relationship-Modellen eingehalten, ist aber kein Zwang.




Abb. 2.8: Modell der Beziehung zwischen Kunde und Bestellung

*Modellierung
von Beziehungen*

Wird jetzt „Kunde“ als Entitätstyp modelliert, muss die *Beziehung* zur Bestellung in das Modell aufgenommen werden. Diese Beziehung wird benannt und im Modell als Raute dargestellt. Die Raute wird mit den betroffenen Entitätstypen verbunden. Weitere Details zu diesen Beziehungen, in Englisch „relations“, werden im folgenden Unterkapitel diskutiert. Das ergänzte Entity-Relationship-Modell, auch *ERM* genannt, für die Bestellverwaltung ist in Abb. 2.8 dargestellt.

Attribute können nur einen Wert annehmen

Jede Bestellung kann mehrere Artikel umfassen. Bestimmte Artikel gehören zu einer Bestellung. Diese Artikel eignen sich aber nicht als Attribute einer Bestellung, da eine Bestellung nicht nur einen, sondern mehrere Artikel umfassen kann. Aus diesem Grund wird ein Entitätstyp Artikel eingeführt, da grundsätzlich jedes Attribut nur einen Wert annehmen soll. Artikel sind durch ihre Artikelnummer eindeutig und haben einen Namen. Dabei wird auf eine Unterscheidung, welcher individuelle Artikel geliefert wird, verzichtet. Es gibt z. B. nur den Artikel „Teddy“ mit der Artikelnummer 12347. Eine Unterscheidung dieser Teddys, z. B. über eine Produktnummer, findet nicht statt. Dabei deutet der Begriff „Produktnummer“ bereits an, dass eine Aufnahme in das Entity-Relationship-Modell nicht schwierig ist.

*Attribute von
Beziehungen*

In einer Bestellung muss nicht jeder Artikel nur einmal bestellt werden. Was passiert, wenn in einer Bestellung gleich 42 Teddys geordert werden? Das Datum 42, genauer die Eigenschaft „Artikelmenge“, muss in das Modell aufgenommen werden. Dieses Attribut Artikelmenge kann nicht bei der Bestellung stehen. Dies

bedeutete, dass jeder Artikel 42-mal bestellt würde. Verallgemeinert könnte der Kunde dann von jedem Artikel pro Bestellung nur eine fest anzugebende Anzahl bestellen, was in der realen Welt kaum zutrifft. Würde die Artikelmenge als Attribut beim Artikel aufgenommen, bedeutete dies, dass jede Bestellung eine feste Anzahl dieses Artikels beinhaltet. Wenn jemand also Teddys bestellt, müsste er im Beispiel immer 42 Teddys bestellen. Dies entspricht nicht der Realität. Am Rande sei vermerkt, dass ein Attribut Artikelmenge für Artikel durchaus sinnvoll sein kann, dann aber mit einer ganz anderen Bedeutung. Die Artikelmenge könnte dann die Anzahl der im Lager befindlichen Artikel beschreiben.




Abb. 2.9: Beziehung mit Attribut

Darstellung von Beziehungen mit Attributen

Eine Lösung für die bestellte Artikelmenge ist, dieses Datum als *Eigenschaft der Beziehung*, auch Attribut der Beziehung genannt, aufzunehmen. Diese Information ist in das Entity-Relationship-Modell in Abb. 2.9 eingeflossen. Die Eigenschaft bezieht sich dabei auf eine konkrete Bestellung und einen konkreten Artikel. Macht ein Kunde eine zweite Bestellung, kann die Artikelmenge damit unterschiedlich sein, da die Bestellung eine andere Bestellnummer hat.

Modell und Dokumentation als Einheit

In der Abbildung gibt es bereits zwei Attribute mit dem Namen „Namen“. Dies ist generell kein Problem, obwohl man identische Namen nach Möglichkeit vermeiden sollte. Generell gehört zu einem Entity-Relationship-Modell eine kurze Dokumentation, in der die einzelnen Elemente, also Entitätstypen, Beziehungen und Attribute anschaulich beschrieben werden. In dem bisher entwickelten Modell ist dies vielleicht nicht notwendig, trotzdem ist es bei größeren Modellen sinnvoll, insbesondere dann, wenn eine

andere Person als der Modellierer mit dem entstandenen Modell weiter arbeiten soll.

Das kleine Beispiel hat gezeigt, dass das Finden der richtigen Entitätstypen, Beziehungen und Attribute keine triviale Aufgabe ist. Ein guter Ansatz ist es, vorhandene Dokumentationen, wie z. B. Anforderungen, Schritt für Schritt durchzuarbeiten und die gelesenen Informationen in das Modell zu übertragen. Eine sehr allgemeine Regel, mit der man zumindest einen ersten Ansatz findet, lautet:

Modellierung als Textanalyse

1. Analysiere alle Nomen im Text, sie könnten Entitätstypen oder aber Attribute sein.
2. Analysiere alle Verben im Text, sie können auf Beziehungen zwischen Entitätstypen hinweisen.
3. Analysiere alle Adjektive im Text, sie können auf Attribute hinweisen.

Ableitung offener Fragen

Da man in der deutschen Sprache sehr komplexe Schachtelsätze formulieren kann, sind die genannten Schritte nur ein sehr allgemeines Kochrezept. Bei dem Ansatz wird aber deutlich, dass man seine Informationsquellen schrittweise abarbeiten muss. Findet man z. B. Nomen, die nicht weiter charakterisiert werden, ist das ein Indiz, dass hier eine Klärung mit dem Kunden notwendig ist.

Unterscheidung Entitätstyp und Attribut

Häufiger steht man vor der Frage, ob es sich um ein Attribut oder um einen Entitätstypen handelt. Diese Frage ist nicht immer eindeutig zu beantworten. Beispiele, wie man zu klaren Antworten kommt, sind im vorherigen Text genannt. Werden gleiche Attributswerte häufiger für verschiedene Entitäten genutzt, ist dies ein starker Indikator für die Umformung des Attributes in einen Entitätstypen. Dies wäre z. B. der Fall, wenn man zu jedem Artikel noch eine Artikelgruppe, wie „Spielwaren“ oder „Bekleidung“ vermerken würde. Kann ein Attribut für eine Entität gleichzeitig mehrere Werte aufnehmen, so muss das Attribut in einen Entitätstypen umgewandelt werden. Durch die resultierende Beziehung zu dem neu entstehenden Entitätstypen wird deutlich, dass mehrere Werte angenommen werden können

Zerlegung von Attributen

Häufiger stellt sich auch die Frage, ob es sich um ein Attribut oder mehrere Attribute handelt. Ist eine Adresse ein Attribut oder handelt es sich bei Straße, Hausnummer, Postleitzahl und Ort um vier Attribute? Die Antwort auf solche Fragen hängt vom Zweck der Datenbank ab, der wieder mit dem Kunden zu klären ist.

Benutzt der Kunde z. B. die Adresse nur zum Versenden von Waren und Werbung, so ist eine Aufteilung unnötig. Möchte der Kunde aber analysieren, aus welchen Gebieten des Landes der Hauptteil seiner Kunden kommt, muss die Postleitzahl ein eigenständiges Attribut sein, denn aus technischer Sicht ist es sehr aufwändig, aus einer zusammengesetzten Adresse den Postleitzahlanteil zu berechnen. Noch weiterführende Informationen über die Erstellung von Entity-Relationship-Modellen findet man in [Jar03].

2.4

Entity-Relationship-Modell

Ergänzung des Modells

Im vorherigen Unterkapitel wurden alle zentralen Elemente eines Entity-Relationship-Modells eingeführt. Man kann diese Modelle um weitere Informationen ergänzen, die die spätere Entwicklung der Datenbank wesentlich erleichtern. Die hier benutzte Notation lehnt sich an [Che76] an, der die ersten Arbeiten zu diesem Thema veröffentlicht hat. Es gibt verschiedenen Varianten von Entity-Relationship-Modellen, die sich aber nicht wesentlich in ihrer Ausdruckskraft unterscheiden. Da es für diese Modelle leider keine weltweit akzeptierte Norm gibt, kann es leicht passieren, dass man in der Praxis erst die genutzte Notation verstehen muss. Ist dies erledigt, lassen sich Entity-Relationship-Modelle sehr einfach lesen.

Kardinalitäten

Im vorherigen Unterkapitel wurde bereits erwähnt, dass ein Kunde mehrere Bestellungen machen kann und dass zu jeder Bestellung ein Kunde gehört. Diese so genannten *Kardinalitäten* werden in das Modell aufgenommen.




Abb. 2.10: Beziehung mit Kardinalitäten

Abb. 2.10 zeigt den Zusammenhang zwischen Bestellung und Kunde mit Kardinalitäten. Um die Modelle nicht unnötig zu verkomplizieren, kann man vier verschiedene Kardinalitäten zur Modellierung nutzen. Sie reichen aus, da sie alle relevanten Informationen zur Datenbank-Erstellung beinhalten. Die Kardinalitäten sind:

- 1** eine Beziehung zu genau einer Entität
- C** eine Beziehung zu einer oder keiner Entität
- N** eine Beziehung zu einer oder mehreren Entitäten
- NC** eine Beziehung zu keiner, einer oder mehreren Entitäten




Abb. 2.11: Allgemeines Entity-Relationship-Modell

In Abb. 2.11 ist eine allgemeine Beziehung zwischen zwei Entitätstypen A und B beschrieben, dabei können X und Y für eine der vier genannten Kardinalitäten stehen. Die Abbildung beinhaltet folgende Aussagen:

*Kardinalitäten
lesen*

Jede Entität des Entitätstyps A steht in rel-Beziehung mit X Entitäten des Entitätstyps B.

Jede Entität des Entitätstyps B steht in rel-Beziehung mit Y Entitäten des Entitätstyps A.

Für das konkrete Beispiel in Abb. 2.10 heißt dies: Jeder Kunde macht eine oder mehrere Bestellungen. Jede Bestellung wurde von genau einem Kunden bestellt. Aus der Modellierung folgt unmittelbar, dass man Personen als Kunden erst aufnimmt, wenn sie eine Bestellung gemacht haben. Dies ist wieder mit dem Auftraggeber der Datenbank zu klären. Soll ein Kunde auch ohne Bestellung aufgenommen werden können, so müsste die Kardinalität NC genutzt werden.

*Unterschied
zwischen N
und NC*





Abb. 2.12: Bestellabwicklung mit Kardinalitäten

Zusammenhang von NC und MC

In Abb. 2.12 ist die Beziehung zwischen Bestellung und Artikel um Kardinalitäten ergänzt worden. Die Aussagen sind: Jede Bestellung beinhaltet mindestens einen Artikel, kann aber mehrere Artikel beinhalten. Jeder Artikel kann in beliebig vielen Bestellungen vorkommen. Hier wurde statt NC die Kardinalität MC genommen, um zu verdeutlichen, dass die hinter N stehende konkrete Zahl nicht identisch mit der hinter M stehenden konkreten Zahl sein muss. Durch das MC wird weiterhin deutlich, dass Artikel in der Datenbank sein können, die noch nicht bestellt wurden. Dies ist z. B. für Artikel üblich, die neu in das Sortiment aufgenommen werden.

Schreibweise 1:N

Insgesamt kann man zehn verschiedene Arten von Kardinalitäten-Paaren unterscheiden, wenn man z. B. N zu 1, kurz N:1 und 1:N als eine Verknüpfungsmöglichkeit ansieht. Abb. 2.13 enthält Beispiele für die möglichen Paare. Dabei ist es wichtig, eventuelle Randbedingungen zu kennen, die man in der Realität hinterfragen muss.



A	B	Y	X	rel
Ehemann	Ehefrau	1	1	verheiratet
Jeder Ehemann ist mit genau einer Frau verheiratet. Jede Ehefrau ist mit genau einem Mann verheiratet.				
Mann	Ehefrau	1	C	verheiratet
Jeder Mann ist nicht verheiratet oder hat eine Ehefrau. Jede Ehefrau ist mit genau einem Mann verheiratet.				
Mutter	Kind	1	N	geboren
Jede Mutter hat mindestens ein oder mehrere Kinder geboren. Jedes Kind wurde von genau einer Mutter geboren.				
Frau	Kind	1	NC	geboren
Jede Frau hat ein oder kein Kind oder mehrere Kinder geboren. Jedes Kind wurde von genau einer Frau geboren.				
Mitarbeiter	Firmen-Handy	C	C	besitzen
In einer Firma kann jeder Mitarbeiter ein Firmen-Handy haben, muss es aber nicht. Jedes Firmen-Handy ist entweder einem oder keinem Mitarbeiter zugeordnet.				

A	B	Y	X	rel
Handys ohne Zuordnung können z. B. bei Bedarf verliehen werden.				
Mentor	Künstler	C	N	unterstützt
Jeder Mentor unterstützt einen oder mehrere Künstler. Jeder Künstler kann einen oder keinen Mentor haben.				
See	Fluss	C	NC	münden
In jeden See können kein oder ein Fluss oder mehrere Flüsse münden. Jeder Fluss kann in genau einen See münden, muss es aber nicht.				
Student	Vorlesung	M	N	teilnehmen
Jeder Student nimmt an mindestens einer Vorlesung oder aber mehreren Vorlesungen teil. An jeder Vorlesung nimmt mindestens ein Student oder nehmen mehrere Studenten teil.				
Bestellung	Artikel	M	NC	beinhalten
Jede Bestellung beinhaltet einen oder mehrere Artikel. Jeder Artikel kann in keiner oder einer Bestellung oder in mehreren Bestellungen vorkommen.				
Artikel	Lager	MC	NC	lagern
Ein Artikel kann in keinem oder einem Lager oder mehreren Lagern gelagert sein. In jedem Lager können kein, ein oder mehrere Artikel lagern. Es wird berücksichtigt, dass Artikel ausverkauft sein können und dass Lagergebäude saniert werden müssen (deshalb immer das C).				

Abb. 2.13: Mögliche Paare von Kardinalitäten

*Kardinalitäten
müssen zur
Realität passen*

Die Beispiele machen bereits deutlich, dass sich ändernde Randbedingung dazu führen, dass das Modell und damit die gesamte Datenbank geändert werden muss. Möchte man eine historische Datenbank über Mormonen im 19. Jahrhundert anlegen, so muss man berücksichtigen, dass ein Ehemann mehrere Ehefrauen haben kann. Ein weiteres Beispiel ist die Wahl der Namen der Entitätsmengen Ehemann und Ehefrau. Durch die Öffnung der Gesellschaft und der Gesetzgebung können Männer andere Männer und Frauen andere Frauen heiraten. Dies wird dann problematisch, wenn man aus der Datenbank Briefe mit der Anrede „Sehr geehrte Frau X, sehr geehrter Herr Y“ generiert, was schnell zu Verstimmungen bei den Angeschriebenen führen kann.

Mit dem Entity-Relationship-Modell soll eine Miniwelt der Realität angelegt werden, die die Realität korrekt abbilden muss. Dies macht nicht nur die Wahl der Entitäten, sondern auch der Attri-

*Modellierung
von Namen*

bute schwierig. Möchte man die Namen von Menschen möglichst präzise modellieren, so dass die Datenbank zur Generierung von Briefen genutzt werden kann, muss man viele Fälle berücksichtigen. Diese Fälle umfassen die Verwaltung aristokratischer und akademischer Titel, mehrerer Vor- und Nachnamen und die Möglichkeit, dass Menschen nur einen Namen haben sowie dass in vielen Gegenden der Welt der Familienname immer vor dem Vornamen genannt wird.

Bei der Entwicklung einer Datenbank ist es wichtig, dass jede relevante Information genau einmal in der Datenbank vorkommt. Damit ist es auch bei der Modellierung zu vermeiden, dass eine Information zweimal dargestellt wird.




Abb. 2.14: Modell mit überflüssigem Zyklus

*fehlerhafte Zyk-
len in Modellen*

Ein Indikator für schlechte Modellierungen sind *Zyklen* im Entity-Relationship-Modell. Ein Zyklus besteht anschaulich, wenn man ausgehend von einem Entitätstyp die Verbindungslinien so entlang laufen kann, dass man bei dem Ausgangsentitätstypen wieder ankommt. Abb. 2.14 zeigt ein Beispiel. Man kann von Kunde starten und einmal durch das Diagramm zurück zum Kunden laufen. In diesem Fall zeigt der Zyklus ein Problem an, da die Beziehung „kauft“ keine neue Information enthält. Dadurch, dass Kunden Bestellungen machen und Bestellungen Artikel beinhalten, ist die Information, dass Kunden Artikel kaufen, bereits vorhanden.




Abb. 2.15: Modell mit sinnvollem Zyklus

*sinnvolle Zyk-
len in Modellen*

Generell sind Zyklen kritisch zu analysieren. Es ist sinnvoll, für ein Modell schriftlich festzuhalten, warum ein Zyklus kein Problem ist. Abb. 2.15 zeigt eine leichte Abänderung des Problems. Hier ist der enthaltene Zyklus unproblematisch, da durch die Beziehung „bevorzugt“ eine andere Information festgehalten wird. Diese Information könnte z. B. aus einer Kundenbefragung stammen, bei der Kunden auch Artikel nennen können, die zurzeit für sie nicht bezahlbar sind.




Abb. 2.16: Zusammenhang zwischen Einzel- und Gesamtpreis

*keine ausei-
nander herlei-
tbare Attribute*

Die zentrale Grundregel, dass jede Information in einem Entity-Relationship-Modell nur einmal dargestellt wird, ist auch bei der Auswahl der Attribute zu beachten. In Abb. 2.16 ist der Zusammenhang zwischen Bestellung und Artikel um Preisinformationen ergänzt worden. Jeder Artikel hat einen Einzelpreis. In dem Modell ist bei der Bestellung als Attribut der Gesamtpreis aufgenommen worden. Dies ist kritisch zu hinterfragen. Wenn sich der Gesamtpreis aus der Menge der gekauften Artikel und der Einzelpreise berechnet, darf der Gesamtpreis als abgeleitetes Attribut nicht vorkommen. In diesem Fall muss das Attribut gelöscht werden. Die Information, dass der Kunde der Datenbank über den Gesamtpreis informiert werden will, wird in der Dokumenta-

tion zum Entity-Relationship-Modell mit der Berechnungsformel festgehalten.

Es kann aber auch gute Gründe geben, den Gesamtpreis als Attribut stehen zu lassen. Ein Grund wäre, dass der Kunde für seine Bestellung individuell einen Rabatt heraushandeln kann. Der Gesamtpreis ist damit eine Eigenschaft der Bestellung. Wenn es für jeden Kunden einen festen, aber vom Kunden abhängigen Rabatt gibt, wäre dies eine Eigenschaft des Kunden. Der Rabatt würde ein Attribut des Kunden sein, das Attribut Gesamtpreis müsste gelöscht werden, da dieser aus den Artikelpreisen, der Menge des jeweiligen Artikels und dem Rabatt berechnet werden kann.

detaillierte Hinterfragung eines Attributs

Trotzdem könnte ein weiterer Grund für das Attribut Gesamtpreis sprechen. Die Einzelpreise der Artikel ändern sich typischerweise mit der Zeit. Diese Änderungen werden beim jeweiligen Artikel vermerkt. Würde es kein Attribut Gesamtpreis geben, würde bei Berechnungen immer von den aktuellen Artikelpreisen ausgegangen. Dies entspricht aber nicht unbedingt dem Gesamtpreis zum Bestelldatum.


Um diese Diskussion abzuschließen, muss man auf das Attribut Gesamtpreis wieder verzichten, wenn man sich alle Artikelpreise mit ihren Gültigkeitszeiträumen merkt. Diese Liste von Preisen führt zu einem neuen Entitätstypen Preis, der als Attribute den aktuellen Wert sowie den Start- und Endtermin enthält. Falls der Übergang der Preise zeitlich immer nahtlos ist, reicht die Information, bis wann ein Preis gültig ist.

Zusammenhang von 1:N und M:N


Aus Abb. 2.14 kann man erahnen, dass es eine Verwandtschaft zwischen M:N-Beziehungen und 1:N-Beziehungen geben kann. Grundsätzlich gilt, dass es möglich ist, jede M:N-Beziehung durch einen neuen Entitätstypen und zwei 1:N-Beziehungen zu ersetzen. Ähnliches gilt auch für Beziehungen, die eine NC-Kardinalität beinhalten.

Umwandlung von M:N in 1:N

In Abb. 2.17(a) sieht man die MC:N-Beziehung zwischen Bestellung und Artikel. In Abb. 2.17(b) befindet sich ein anderes Entity-Relationship-Modell, das nur 1:N- bzw. 1:NC-Beziehungen enthält. Durch den neuen Entitätstypen Bestellposten kann man festhalten, dass jede Bestellung mehrere Bestellposten enthält, jeder dieser Posten aber zu genau einer Bestellung gehört. Jeder Bestellposten beinhaltet Informationen zu genau einem Artikel, jeder Artikel kann aber in beliebig vielen Bestellposten vorkommen.



(a) Beispiel für eine MC:N-Beziehung




(b) Beispiel für eine aufgeteilte MC:N-Beziehung

Abb. 2.17: Aufteilung einer Beziehung

*Lesbarkeit als
Entscheidungs-
grundlage*

Für den Modellierer ist die Frage, ob eher M:N- oder mehr 1:N-Beziehungen genutzt werden, nicht sehr wichtig. Bei der späteren Nutzung der Entity-Relationship-Modelle ist der Unterschied in den resultierenden Tabellen sehr gering. Grundsätzlich steht bei der Modellierung die Lesbarkeit für den Modellierer und demjenigen, der das Modell beim Kunden abnimmt, im Vordergrund.

**Abb. 2.18:** Beispiel für rekursive Beziehung

*rekursive Be-
ziehungen*

Eigentlich nichts Besonderes, aber für Anfänger in der Modellierung irritierend ist, dass auch Entitätstypen mit sich selber in Beziehung stehen können. Ein Beispiel ist in Abb. 2.18 dargestellt, bei dem Länder an Länder grenzen können. Jedes Land kann beliebig viele Nachbarn haben und kann auch Nachbar von belie-

big vielen Ländern sein. Das Kürzel dient zur eindeutigen Identifizierung des Landes, z. B. ein „D“ für Deutschland. Eigenschaften dieser Grenze werden an der Beziehung als Attribut festgehalten. Wenn eine Beziehung sich auf nur einen Entitätstypen bezieht, spricht man von einer *rekursiven Beziehung*.




Abb. 2.19: Nicht-symmetrische rekursive Beziehung

nicht symmetrische rekursive Beziehung

benannte Beziehungspartner

Bei der Grenzbeziehung ist es nicht wichtig, in welcher Reihenfolge sie gelesen wird. Wenn ein Land A an ein Land B grenzt, dann grenzt auch B an A. Diese *Symmetrie* muss nicht bei allen rekursiven Beziehungen vorliegen. In Abb. 2.19 wird modelliert, dass ein Mitarbeiter Vorgesetzter eines Mitarbeiters oder mehrerer anderer Mitarbeiter sein kann. Jeder Mitarbeiter kann maximal einen Vorgesetzten haben. Das „maximal“ bezieht sich darauf, dass der oberste Chef keinen Vorgesetzten hat. Die Beziehung ist nicht symmetrisch, da, wenn A Vorgesetzter von B ist, B typischerweise nicht Vorgesetzter von A ist. Um dies in der Beziehung zu verdeutlichen, wird in der Nähe der Kardinalität ein Rollenname festgehalten. Das Diagramm kann damit wie folgt gelesen werden: Jeder Mitarbeiter hat einen oder keinen Mitarbeiter als Vorgesetzten. Jeder Mitarbeiter hat keinen, einen oder mehrere Mitarbeiter als Untergebenen.




Abb. 2.20: Mehrere Beziehungen zwischen zwei Entitätstypen

Es ist durchaus nicht ungewöhnlich, dass es zwischen zwei Entitätstypen verschiedene Beziehungen geben kann. In Abb. 2.20 ist festgehalten, dass es Mitarbeiter gibt, die ein Flugzeug fliegen

*verschiedene
Beziehungen
zwischen glei-
chen Entitäten*

können und Mitarbeiter, die ein Flugzeug warten können. Die Attribute sind nur beispielhaft angegeben. Es ist Zufall, dass die Kardinalitäten der Beziehungen übereinstimmen.

Bisher wurden Beziehungen zwischen zwei Entitätstypen betrachtet. Dies ist die in der Praxis verbreitetste Beziehungsart, die grundsätzlich das Ziel einer Modellierung sein sollte. In seltenen Fällen kann es sein, dass man drei oder mehr Entitätstypen in einer Beziehung beachten muss.




Abb. 2.21: Beispiel für Beziehung zwischen drei Entitätstypen

*Beziehungen
zwischen mehr
als zwei Entitä-
ten*

Dies soll durch ein plastisches Beispiel verdeutlicht werden, in dem dargestellt ist, was passiert, wenn Professoren nach überstandenen Semestern durch die Stadt ziehen. Sie gehen von Kneipe zu Kneipe und trinken dort Bier. Da Professoren eigen sind, trinken sie in Abhängigkeit von der Kneipe verschiedene Biersorten. Dies wird anschaulich in der folgenden Tabelle beschrieben, das zugehörige Entity-Relationship-Modell ist in Abb. 2.21 dargestellt.

Professor	Biersorte	Kneipe
Meier	Vareler Alt	Rote Bucht
Müller	Horster Pils	Gelber Fink
Meier	Horster Pils	Rote Bucht
Müller	Vareler Alt	Gelber Fink




Abb. 2.22: Versuch der Auflösung einer komplexen Beziehung

nicht jede Beziehung kann zwischen nur zwei Entitätstypen existieren

Es stellt sich die Frage, ob es nicht eine Modellierung mit nur zweistelligen Beziehungen gibt, wie sie in Abb. 2.22 beschrieben ist. Dies ist nicht möglich. Dazu betrachten wir die Tabellen, mit denen der Zusammenhang dann auch beschrieben werden könnte.

Professor	Biersorte
Meier	Vareler Alt
Müller	Horster Pils
Meier	Horster Pils
Müller	Vareler Alt

Biersorte	Kneipe
Vareler Alt	Rote Bucht
Horster Pils	Gelber Fink
Horster Pils	Rote Bucht
Vareler Alt	Gelber Fink

Professor	Kneipe
Meier	Rote Bucht
Müller	Gelber Fink
Meier	Gelber Fink
Müller	Rote Bucht

Aus diesen Tabellen folgt aber auch, dass Professor Meier ein Vareler Alt in der Roten Bucht trinken würde, was nach der Ursprungstabelle nicht der Fall ist. Es gibt auch keine andere Möglichkeit, die Information aus der Tabelle mit den drei Spalten in einer Tabelle oder mehreren Tabellen mit nur zwei Spalten darzustellen. Aus diesem Grund kann es Beziehungen geben, an denen mehr als zwei Entitätstypen beteiligt sind.




Abb. 2.23: Aufgelöste Beziehung zu drei Entitätstypen

*Auflösung von
Beziehungen
zwischen mehr
als zwei Enti-
tätstypen*

Grundsätzlich kann man Beziehungen zwischen mehr als zwei Entitätstypen vermeiden. Dazu muss man aber zusätzlich einen neuen Entitätstypen einführen. Das für die biertrinkenden Professoren resultierende Entity-Relationship-Modell ist in Abb. 2.23 dargestellt. Bei einer konkreten Modellierung muss die Frage, ob nur Beziehungen zwischen zwei Entitätstypen gewünscht sind, durch den Modellierer, typischerweise im Gespräch mit dem Kunden, geklärt werden. Wichtig ist, dass diese Entscheidung keine Auswirkung auf die weitere Entwicklung hat.

2.5

[*] Abschlussbemerkungen zu Entity-Relationship-Modellen

Die bisher gegebenen Informationen über Entity-Relationship-Modelle reichen aus, um Modelle selbst für große Projekte zu entwickeln. In diesem Unterkapitel wird gezeigt, dass es beim Lesen existierender Entity-Relationship-Modelle zu Problemen kommen kann, da unterschiedliche Notationen genutzt werden. Weiterhin gibt es Erweiterungsmöglichkeiten, die auch auf die bisher genutzte Darstellung von Entity-Relationship-Modellen angewandt werden können und in gewissen Situationen die Modellierung erleichtern. Abschließend wird der Zusammenhang zwischen Entity-Relationship-Modellen und Klassendiagrammen, die in der objektorientierten Software-Entwicklung genutzt werden, beschrieben.

*Notationen
meist unterei-
nander aus-
tauschbar*


In Abb. 2.24 sind verschiedene Notationen dargestellt, mit denen immer der gleiche Sachverhalt beschrieben werden soll. Bis auf die Bachman-Notation, in der man nur erkennt, ob höchstens eine Entität oder mehr Entitäten an der Beziehung beteiligt sind, kann man die verschiedenen Notationen ineinander überführen.

*Leseansatz für
unbekannte
Modelle*


Bei der numerischen Notation fällt auf, dass die Positionen der Kardinalitäten vertauscht wurden. Da es keine international anerkannte Norm für Entity-Relationship-Modelle gibt, sind noch viele andere Varianten von Notationen vertreten. Möchte man ein unbekanntes Entity-Relationship-Modell lesen, muss man zwei Entitätstypen identifizieren, deren Beziehung man kennt und die eine der Formen 1:N, C:N, 1:NC oder C:NC hat. Aus der für diesen Sachverhalt verwendeten Notation kann man dann schließen, wie die Notation generell aufgebaut ist.

*mehr Symbole
vermindern
Lesbarkeit*


Neben den bisher vorgestellten graphischen Elementen kann man weitere Symbole in Entity-Relationship-Modelle einbauen, um weitere Zusammenhänge zu beschreiben. Hierbei ist kritisch anzumerken, dass mit steigender Symbolzahl die Lesbarkeit sehr schnell sinkt und man deshalb weitere Fakten lieber in der zum Modell gehörenden Beschreibung festhält. Trotzdem sollen hier einige Erweiterungsmöglichkeiten kurz beschrieben werden.




(a) hier verwendete, an Chen angelehnte Notation




(b) Krähenfuß-Notation



(c) Pfeilnotation



(d) numerische Notation



(e) Bachman-Notation

Abb. 2.24: Notationen für Entity-Relationship-Modelle




Abb. 2.25: Darstellung abhängiger Attribute

Darstellung abhängiger Attribute

Abb. 2.25 zeigt, dass der Gesamtpreis aus anderen Informationen abgeleitet werden kann. Aus diesem Grund ist das Attribut gestrichelt eingezeichnet, damit man sieht, dass der Modellierer darüber nachgedacht hat, es sich aber um kein normales Attribut handelt.




Abb. 2.26: Existenzabhängige Entitätstypen

existenzabhängige Entitäten

Durch die doppelten Linien in Abb. 2.26 wird gezeigt, dass es sich beim Raum um einen vom Gebäude abhängigen Entitätstypen handelt. Dadurch wird festgelegt, dass, wenn ein Gebäude aus der Datenbank gelöscht wird, damit auch alle Räume, die zu diesem Gebäude gehören, gelöscht werden.




Abb. 2.27: Zusammenfassung gemeinsamer Entitätstypen-Eigenschaften

Hierarchie von Entitäten

Häufiger kann man für zwei Entitätstypen gemeinsame Attribute finden. Diese müssen in der bisher vorgestellten Modellierung dann auch doppelt aufgenommen werden. Gibt es in einem Unternehmen Piloten und Mechaniker als Mitarbeiter, haben diese gemeinsamen Eigenschaften, wie eine Mitarbeiternummer, einen Namen, eine Adresse und ein Gehalt. Weiterhin haben sie Eigenschaften, die sie unterscheiden, wie das Datum der nächsten Flugtauglichkeitsprüfung beim Piloten und das Datum der Gesellenprüfung beim Mechaniker. Statt die gemeinsamen Attribute doppelt aufzuführen, wird in Abb. 2.27 ein Entitätstyp als *Ober-typ* eingeführt, in dem die gemeinsamen Eigenschaften vereinigt sind. Durch das neue „is-a“ Symbol wird verdeutlicht, dass es sich bei Piloten und Mechanikern um Spezialisierungen eines Mitarbeiters handelt, die neben ihren eigenen Attributen auch die Attribute des Mitarbeiters haben.

Verwandtschaft von Klasse und Objekt mit Entitätstyp und Entität

In der Software-Entwicklung wird typischerweise ein objekt-orientierter Ansatz verfolgt, bei dem die Möglichkeit, die Ausführung gewisser Aufgaben an bestimmte Objekte zu delegieren, als wichtige Strukturierungsmöglichkeit im Vordergrund steht. Bei der objektorientierten Entwicklung ist der Klassen- und der Objektbegriff im Mittelpunkt. Objekte sind Individuen mit charakterisierenden Eigenschaften, die bestimmte Aufgaben erfüllen können. Klassen sind Schemata, die angeben, welche gemeinsamen Eigenschaften Objekte haben, die von dieser Klasse erzeugt werden. Aus dieser recht vagen Formulierung kann man bereits ab-

leiten, dass der Begriff „Klasse“ mit dem Begriff „Entitätstyp“ und der Begriff „Objekt“ mit dem Begriff „Entität“ verwandt ist. Deshalb kann man einige wesentliche Erfahrungen aus der Erstellung von Entity-Relationship-Modellen auf die objektorientierte Modellierung übertragen.

UML als Modellierungsstandard

Zur objektorientierten Modellierung werden Klassendiagramme genutzt. Diese Diagramme sind in der *Unified Modeling Language* (UML, siehe z. B. [Oes04]) der Object Management Group (OMG, www.omg.org) normiert. Die Normierung ermöglicht es, dass sich Modellierer schnell in die Modelle anderer Modellierer einarbeiten können.




Abb. 2.28: Beispielklasse in UML-Notation

Instanzvariablen und Methoden

Bei der Darstellung von Klassen in Klassendiagrammen werden die Eigenschaften, Instanzvariablen genannt, und die Aufgaben, Methoden genannt, aufgeführt, die Objekte dieser Klasse haben bzw. ausführen können. In Abb. 2.28 ist ein einfaches *Klassendiagramm* mit nur einer Klasse für eine Bestellung angegeben. Neben den von der Entity-Relationship-Modellierung bekannten Attributen bzw. Instanzvariablen ist angegeben, welche Aufgaben Objekte dieser Klasse übernehmen können. Es ist möglich, den Objekten mitzuteilen, dass sie weitere Artikel aufnehmen und Artikel wieder löschen können. Weiterhin ist ein Objekt in der Lage, den Gesamtpreis einer Bestellung zu berechnen.

Verwandschaft von Klassendiagramm und Entity-Relationship-Modell




Abb. 2.29: Klassendiagramm mit Assoziation

Bei der Darstellung der Klassen kann man auswählen, ob Instanzvariablen und Attribute dargestellt werden sollen. Lässt man diese Information weg, entspricht das Bild der Darstellung eines

*objektorientierte
Modellierung
komplexer als
reine Daten-
modellierung*

Entitätstypen. Weiterhin werden Linien zwischen Klassen gezeichnet, um Beziehungen, in der UML *Assoziationen* genannt, darzustellen. In Abb. 2.29 ist ein Beispiel dargestellt. Man kann das Wissen aus der Entity-Relationship-Modellierung zum Lesen des Diagramms nutzen. Jede Firma hat beliebig viele Angestellte als Mitarbeiter. Jeder Arbeiter kann bei keiner oder einer Firma, seinem Arbeitgeber, arbeiten. Die Rollennamen „Arbeitgeber“ und „Angestellter“ können weggelassen werden.

Dieser sehr kurze Einblick zeigt einen Zusammenhang zwischen den Ansätzen auf. Es soll aber nicht verschwiegen werden, dass zur objektorientierten Modellierung weiteres Wissen gehört. Es gibt viele Klassen, wie Steuerungsklassen, die man bei der Entity-Relationship-Modellierung nicht benötigt, die aber zentraler Bestandteil von Klassenmodellen sind. Einen guten Einblick in die objektorientierte Modellierung mit der UML erhält man in [Oes04].

2.6

Fallstudie

*Abwicklung
von IT-
Projekten*

In diesem Buch wird eine realistische, allerdings etwas vereinfachte Fallstudie genutzt, um ein durchgehendes Beispiel zur Entwicklung einer Datenbank zu zeigen. Dabei ist folgendes Ausgangsszenario beim Auftraggeber für die Datenbank gegeben:

Das Unternehmen wickelt Software-Entwicklungsprojekte ab, dabei treten in den Projekten immer wieder Probleme auf. Damit diese Probleme systematisch analysiert werden können, wird ein Risikomanagement-Prozess in der Firma eingeführt. Die Idee ist, bereits in der Planung über potenzielle Probleme, die Risiken, nachzudenken und gegebenenfalls frühzeitig Maßnahmen zu ergreifen, damit die Probleme nicht eintreten. Die Analyse, welche Risiken das Projekt hat, wird im Projektverlauf wiederholt, um immer frühzeitig Maßnahmen ergreifen zu können.

Projekt: Entwicklung eines Web-Shops für XY
Risiken mit letztem Bearbeitungsdatum: R1: Die Anforderungen für das Modul X sind unklar beschrieben (22.01.06) R2: Der Ansprechpartner beim Kunden wechselt häufig (22.01.06) R3: Das Verfahren, wie der Kunde das Produkt abnimmt, ist unklar (20.12.05) R4: Das Projektteam hat keine Erfahrungen mit dem neuen Werkzeug W zur Code-Generierung (20.12.05)
Ergriffene Maßnahmen (Sachstand): M1: Projektvertrag einem Rechtsanwalt zur Prüfung übergeben (Ergebnis bis 19.01.06 erwartet) M2: Schulung und Coaching für W vereinbart (ab 5.2.2006)

Abb. 2.30: Formblatt zum Management von Risiken

Ist-Analyse

neuer Prozess

Im ersten Schritt wurde eine Textschablone zur Erfassung und Bearbeitung der Risiken genutzt, eine Variante des Formblattes ist in Abb. 2.30 dargestellt. Ausgehend von diesem Formblatt führen die Datenbankentwickler die Diskussion der Anforderungen mit dem Kunden, der die Risikomanagementdatenbank wünscht. Das Ergebnis der Gespräche ist, dass die Daten und ihre Zusammenhänge verwaltet und der Prozess mit der Datenbank weiter verfeinert werden sollen. Man soll z. B. für abgeschlossene Projekte sehen, welche Risiken vermutet wurden, ob diese zu Problemen führten und welche Maßnahmen welchen Erfolg hatten. Leser, die am Risikomanagement direkt interessiert sind, seien auf [Wal04] oder [DL03] verwiesen.




Abb. 2.31: Entity-Relationship-Modell für Risikomanagementdatenbank

Dokumentation des Modells

Aus den Diskussionen wird das in Abb. 2.31 dargestellte Entity-Relationship-Modell entwickelt. Wichtig ist, dass die zugehörigen Randbedingungen in schriftlicher Form als Dokumentation festgehalten werden. In der Dokumentation stehen folgende Informationen:

Projekt

Entität Projekt: Die Entität steht für laufende wie auch für abgeschlossene Projekte. Jedes Projekt hat in der Firma eine eindeutige Projektnummer (ProNr) und einen Projektnamen (Name), der nicht eindeutig sein muss.

Risiko

Entität Risiko: Jedes Risiko soll eindeutig (RNr) nummeriert sein. Jedes Risiko hat eine Beschreibung (Text) des Risikos, zusätzlich wird festgehalten, wann geprüft werden soll (Prüfdatum), ob sich das Risiko und seine Randbedingungen verändert haben. Weiterhin wird zum Risiko geschätzt, wie hoch der maximale finanzielle Schaden ist (Auswirkung), wenn der Risikofall eintritt, und eine Wahrscheinlichkeit (Wkeit) in Prozent, wie wahrscheinlich ein Eintreffen des Risikos ist. Falls ein Projekt abgeschlossen ist, wird die Wahrscheinlichkeit immer auf 100 gesetzt und in der Auswirkung der real aufgetretene Schaden festgehalten.

bedroht
durch

Beziehung „bedroht durch“: Jedes Risiko gehört zu genau einem Projekt, wobei jedes Projekt beliebige Risiken haben kann.


Risikogruppe

Entität Risikogruppe: Um Risiken systematischer analysieren zu können, sollen die Risiken in Gruppen eingeteilt werden. Es soll so möglich sein, die Hauptrisikogebiete des Unternehmens zu

bestimmen, um in dem betroffenen Gebiet über generelle Verbesserungen in der Firma nachzudenken. Jede Gruppe wird durch eine Nummer (RGNr) identifiziert und hat einen eindeutigen Namen (Gruppe).



Beziehung „gehört zu“: Jedes Risiko soll genau einer Gruppe zugeordnet werden, wobei beliebig viele Risiken zu einer Gruppe gehören können.



Entität Maßnahme: Um das Eintreten von Risiken zu verhindern, sollen möglichst frühzeitig Maßnahmen ergriffen werden. Diese Maßnahmen werden eindeutig nummeriert (MNR), haben eine Beschreibung (Titel) und einen Verantwortlichen (Verantwortlich) für die Durchführung der Maßnahme.



Beziehung „bearbeitet durch“: Es wurde vereinbart, dass zu jedem Risiko mehrere Maßnahmen ergriffen werden können, dabei kann sich eine Maßnahme aber auch auf mehr als ein Risiko beziehen. Abhängig vom Risiko gibt es für jede Maßnahme ein Datum, wann geprüft werden soll (Prüfdatum), ob die Maßnahme erfolgreich ist. Da eine Maßnahme zu mehreren Risiken gehören kann, kann sie auch unterschiedliche Überprüfungsdaten haben. Dies ist sinnvoll, da eine Maßnahme für ein Risiko sinnvoll sein kann, während die gleiche Maßnahme für ein anderes Risiko keinen Erfolg hat. Zusätzlich wird noch der Status der Maßnahme bezüglich des Risikos festgehalten, dieser Status kann z. B. „offen“ für nicht abgeschlossene Maßnahmen, „Erfolg“ für erfolgreiche Maßnahmen und „Fehlschlag“ für nicht erfolgreiche Maßnahmen sein.

Neben der hier vorgestellten Datenanalyse werden mit der Anforderungsanalyse die Prozesse festgehalten, die mit dem zu entwickelnden System unterstützt werden sollen. Diese Prozesse sind wichtig für den Aufbau der Eingabemasken und der Festlegung, wann der Nutzer zu welcher Maske wechseln kann.

Ein Ergebnis der Anforderungsanalyse sind die Informationen, die die späteren Nutzer aus dem System gewinnen wollen. Datenbankentwickler können dann kritisch prüfen, ob die gewünschten Aufgaben mit dem entwickelten Datenmodell gelöst werden können. Die folgende Liste zeigt einen Ausschnitt der Aufgaben, die vom System erfüllt werden sollen.

Untersuchung individueller Daten

- Gib zu jedem Projekt die Projektrisiken aus.
- Gib zu jedem Projekt die getroffenen Risikomaßnahmen aus.
- Gib für jedes Projekt die betroffenen Risikogruppen aus.
- Gib zu jeder Risikogruppe die getroffenen Maßnahmen aus.

Statistische Auswertungen

- Gib zu jedem Projekt die Anzahl der zugehörigen Risiken und die durchschnittliche Wahrscheinlichkeit des Eintreffens aus.
- Gib zu jedem Projekt die Summe der erwarteten Zusatzkosten, berechnet aus dem maximalen Zusatzaufwand und der Eintrittswahrscheinlichkeit, aus.
- Gib zu jeder Maßnahme den frühesten Zeitpunkt zur Überprüfung an.
- Gib zu jeder Maßnahme an, zur Bearbeitung von wie viel Risiken sie eingesetzt werden soll.
- Gib die Risikogruppen aus, denen mindestens zwei Risiken zugeordnet wurden.
- Gib zu jedem Risiko die Anzahl der getroffenen Maßnahmen aus.

Plausibilitätsprüfung

- Gib zu jedem Projekt die Risikogruppen aus, für die es kein zugeordnetes Risiko im Projekt gibt.
- Gib die Risiken aus, für die keine Maßnahmen ergriffen wurden.

Mit einem erfahrenen Auge, das ein Entwickler z. B. nach der Lektüre dieses Buches hat, kann er feststellen, dass die Aufgaben höchstwahrscheinlich mit der aus dem Entity-Relationship-Modell zu entwickelnden Datenbank gelöst werden können.

2.7

Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu beantworten.

1. Beschreiben Sie die verschiedenen Phasen der Software-Entwicklung.
2. Was versteht man unter „inkrementeller Entwicklung“, wo liegen die Vorzüge dieses Ansatzes?
3. Welche typischen Probleme können auftreten, wenn Sie mit einem Kunden die Anforderungen an die zu erstellende Software aufnehmen wollen?
4. Was versteht man unter schrittweiser Verfeinerung von Anforderungen?
5. Welchen Zusammenhang gibt es zwischen Anforderungsanalyse und Geschäftsprozessen?
6. Beschreiben Sie den Ansatz, Anforderungen mit einer Anforderungsschablone zu erstellen.
7. Erklären Sie anschaulich die Begriffe Entität, Attribut und Entitätstyp.
8. Welche Möglichkeiten kennen Sie, bei der Modellierung Attribute und Entitätstypen zu unterscheiden?
9. Was versteht man unter einer Beziehung? Was bedeutet es, wenn Beziehungen Attribute haben?
10. Wie würden Sie bei der Erstellung eines Entity-Relationship-Modells vorgehen?
11. Wann ist es sinnvoll, statt eines Attributs Adresse mehrere Attribute, wie Straße, Hausnummer, Postleitzahl und Stadt aufzunehmen?
12. Wozu werden Kardinalitäten in Entity-Relationship-Modellen genutzt, welche werden unterschieden? Nennen Sie Beispiele für Einsatzmöglichkeiten von Kardinalitäten.
13. Was bedeutet es, dass man mit einem Entity-Relationship-Modell versucht, eine korrekte Miniwelt zu modellieren?
14. Warum können Zyklen in Entity-Relationship-Modellen auf Probleme hinweisen?

15. Wo greift die Grundregel, dass jede Information in einem Entity-Relationship-Modell nur einmal dargestellt werden soll?
16. Welchen Zusammenhang gibt es zwischen M:N- und 1:N-Beziehungen?
17. Was sind rekursive Beziehungen? Nennen Sie praktische Einsatzbeispiele.
18. Wann werden Beziehungen zwischen mehr als zwei Entitätstypen benötigt? Gibt es Modellierungsalternativen?

Übungsaufgaben

1. In einer Datenbank soll der Zusammenhang zwischen Mitarbeitern, ihrer Mitarbeit in Projekten und den Telefonen der Mitarbeiter erfasst werden. Jeder Mitarbeiter sei durch seine Mitarbeiternummer (MiNr) eindeutig identifiziert, weiterhin hat er einen Namen. Jedes Telefon sei durch seine Telefonnummer (TelNr) eindeutig identifiziert. Jedes Projekt sei durch seine Projektnummer (ProNr) eindeutig und hat einen Namen. Jeder Mitarbeiter kann in beliebig vielen Projekten mitarbeiten, in jedem Projekt arbeitet mindestens ein Mitarbeiter. Zu jeder der folgenden Teilaufgaben soll ein Entity-Relationship-Modell erstellt werden, bei dem zusätzlich der genannte Zusammenhang zwischen Telefonen und Mitarbeitern aufgenommen werden soll.
 - a. Jeder Mitarbeiter hat genau ein Telefon, jedes Telefon gehört zu genau einem Mitarbeiter.
 - b. Jeder Mitarbeiter kann mehrere Telefone unabhängig vom Projekt haben und hat mindestens eins, jedes Telefon gehört zu genau einem Mitarbeiter.
 - c. Ein oder mehrere Mitarbeiter müssen sich ein Telefon teilen, dabei hat jeder Mitarbeiter Zugang zu einem Telefon. Jedes Telefon gehört zu mindest einem Mitarbeiter (Idee: ein Telefon pro Büro).
 - d. Jeder Mitarbeiter kann mehrere Telefone haben, er wechselt für seine jeweilige Projektaufgabe z. B. das Büro. Dabei nutzt er pro Projekt genau ein Telefon. Jedes Telefon wird von mehreren Mitarbeitern genutzt.
 - e. Zu jedem Projekt gibt es genau ein Telefon, das von den Projektmitarbeitern genutzt wird.

Formulieren Sie die folgenden Sachverhalte in den Aufgabenstellungen als Entity-Relationship-Modelle. Falls sie keine Attribute im Text identifizieren können, geben sie zumindest immer ein identifizierendes Attribut an:

2. Durch den Namen eindeutig benannte Mutterkonzerne, die jeweils an genau einem Ort beheimatet sind, können beliebig viele Tochtergesellschaften haben, die durch ihren Namen eindeutig sind, eine Beschäftigtenzahl haben und seit einem genauen Datum zu genau einem Mutterkonzern gehören. Jede Tochtergesellschaft kann auf maximal einem Fachgebiet mit einer anderen Tochtergesellschaft zusammenarbeiten.
3. Eine Firma stellt verschiedene Produkte her, die sich im Namen unterscheiden und jeweils ein Gewicht und eine Leistung haben. Jedes Produkt besteht aus mindestens zwei verschiedenen Komponenten, die einen eindeutigen Namen, eine Farbe und ein Gewicht haben. Jede Komponente wird nur in einem Produkt benutzt. Beliebige Komponenten können in beliebigen Lagern gelagert werden. Die Lager sind durch ihren eindeutigen Ort bekannt und haben eine eigene Lagerkapazität. Jedes der Produkte kann auch in mehreren Lagern aufbewahrt werden, wobei die Lager auch verschiedene Produkte aufnehmen können.
4. Eine IT-Firma erstellt Software in verschiedenen Projekten. Die Entwicklungsinformationen zu den verschiedenen Projekten sollen festgehalten werden. Jedes Projekt, das durch seinen Namen eindeutig gekennzeichnet ist und einen Leiter hat, stellt einen oder mehrere SW-Module her. Jeder SW-Modul, der durch seinen Namen eindeutig erkennbar ist, gehört zu genau einem Projekt. Jeder SW-Modul kann aus mehreren anderen SW-Modulen bestehen, jeder SW-Modul kann in maximal einem übergeordneten SW-Modul genutzt werden. Zu jedem Projekt gehört eine Liste von Testfällen, die durch eine Nummer eindeutig identifizierbar sind und einen Ersteller haben. Jeder Testfall bezieht sich auf einen oder mehrere SW-Module, jeder SW-Modul sollte in mindestens einem Testfall vorkommen, was aber nicht immer garantiert ist. Es gibt Testfälle, die frühzeitig erstellt werden und erst wesentlich später SW-Modulen zugeordnet werden. Für jede Ausführung eines Testfalls wird der letzte Zeitpunkt der Ausführung, der Name des Testers und das Testergebnis festgehalten (auf eine Historie der Testfälle wird verzichtet),

dabei kann sich die Testausführung auf eine Teilmenge der zugeordneten Module beziehen.

5. Jeder Mensch, der durch seine Sozialversicherungsnummer (SNr) eindeutig ist und einen Vor- und Nachnamen hat, kann in höchstens einer Krankenkasse sein. Die Kasse ist durch ihren Namen eindeutig und hat einen Sprecher und kann maximal 100000 Menschen als Mitglieder aufnehmen. Jeder Mensch kann zu mehreren Ärzten gehen, die einen eindeutigen Namen und ein Fachgebiet haben. Ärzte können mehrere Menschen häufiger zu verschiedenen Terminen behandeln und können für verschiedene Kassen arbeiten, dabei haben sie mit jeder Kasse einen festen Stundensatz vereinbart. Für jede Kasse arbeiten verschiedene Ärzte. Jeder Arzt kann jeden Patienten (also Menschen) an beliebig viele (eventuell unterschiedliche) andere Ärzte überweisen. Beachten Sie, dass der gleiche Patient von einem Arzt bei verschiedenen Behandlungen an verschiedene Ärzte überwiesen werden kann. Bei jeder Behandlung kann nur maximal eine Überweisung erfolgen.

3

Systematische Ableitung von Tabellenstrukturen

klare Übersetzungsregeln

Relationale Datenbanken bauen zentral auf Tabellen auf. In diesem Kapitel lernen Sie, wie man Entity-Relationship-Modelle systematisch in Tabellen übersetzen kann.

Mit der Erstellung eines Entity-Relationship-Modells, wie sie im vorherigen Kapitel beschrieben wurde, ist ein wesentlicher Schritt zur Entwicklung einer hochwertigen Datenbank gemeistert. Die Folgeschritte sind einfacher, da man sie, im Gegensatz zum stark kreativen Vorgehen bei der Gewinnung von Nutzeranforderungen, klar formulieren kann.

Das Modell wird schrittweise in Tabellen überführt. Dazu gibt es ein formales Verfahren, das genau beschreibt, welche Übersetzungsschritte zu machen sind. Zunächst wird der Begriff der Tabelle präzisiert, um dann die Übersetzung vorzustellen. Vor der Fallstudie werden einige interessante Randfälle der Übersetzung diskutiert.

3.1

Einführung des Tabellenbegriffs

Anschaulich ist der Tabellenbegriff relativ leicht zu fassen, da jeder schon Kassenbons, Ergebnistabellen im Sport oder Telefonlisten gesehen hat. In Abb. 3.1 ist eine Tabelle zur Verwaltung von Bestellungen dargestellt.

Bestellung				
Kunde	Bestellnr	Bestelldatum	Status	bezahlt
42	1	27.02.06	abgeschlossen	wahr
66	2	28.02.06	abgeschlossen	falsch
89	3	28.02.06	Bearbeitung	falsch
42	4	28.02.06	Bearbeitung	falsch

Abb. 3.1: Beispiel für eine Tabelle

Sinn der Formalisierung

Um genauer mit dem Begriff „Tabelle“ argumentieren zu können, muss eine möglichst präzise Definition einer Tabelle gegeben werden. Diese präzise Begriffsfindung ermöglicht es später, ge-

*typische
Tabelleigenschaft*

naue Aussagen zum Umgang mit Tabellen zu formulieren. Im folgenden Text wird ein formaler mathematischer Ansatz angedeutet, wobei immer Wert auf eine praktische Veranschaulichung gelegt wird.

Betrachtet man die Tabelle aus Abb. 3.1 genauer, so kann man folgende Eigenschaften feststellen:

- Die Tabelle hat einen Namen.
- Die Tabelle hat Spaltenüberschriften, diese Überschriften können im bisher benutzten Vokabular als Attribute bezeichnet werden.
- In jeder Spalte stehen Werte, die zu diesem Attribut passen. Jeder Wert hat einen Datentyp, wobei in jeder Spalte nur Werte des gleichen Datentyps stehen.

Die drei Beobachtungen können zur Definition einer Tabelle mit ihrem Inhalt genutzt werden. Zunächst wird der Begriff Datentyp präzisiert, wobei hier eine recht allgemeine Charakterisierung gegeben wird, die z. B. für Programmiersprachen wesentlich verfeinert werden müsste.

Definition Datentypen: Ein *Datentyp* ist eine Menge von Werten. Es werden folgende Datentypen betrachtet:

Text: Ein Element des Datentyps Text ist eine beliebige Folge von Zeichen, die in einfachen Hochkommata eingeschlossen sind. Beispiele für Elemente aus Text sind: 'Hallo', 'ich hab Leerzeichen und komische (§#+&) Symbole', ''. Der zuletzt aufgeführte Text ist der leere Text, der kein Zeichen, auch kein Leerzeichen, enthält.

Zahl: Ein Element des Datentyps Zahl ist eine beliebige Zahl, dabei wird hier vereinfachend nicht zwischen ganzen und Fließkomma-Zahlen unterschieden. Beispiele für Elemente aus Zahl sind: 42, 34.56, 0.004, 3.15, 10000001.

Datum: Ein Element des Datentyps Datum ist ein beliebiges gültiges Datum, dabei wird hier vereinfachend von der Darstellung in der Form <Tag>.<Monat>.<Jahr> ausgegangen. Beispiele für Elemente aus Datum sind: 25.01.1966, 05.10.1967, 06.05.1989, 26.02.2000.

Boolean: In der Menge Boolean sind die Wahrheitswerte „wahr“ und „falsch“ zusammengefasst.

NULL

In der Realität passiert es häufig, dass man nicht sofort alle Daten in eine Tabelle eintragen kann. Dieses leere Feld entspricht einem Wert „undefiniert“, der im Datenbanksprachegebrauch auch NULL-Wert genannt wird.

Definition Datentypen für Tabellen: In Tabellen können die Datentypen Text, Zahl, Datum und Boolean genutzt werden, dabei ist jeder ursprüngliche Datentyp um einen Wert NULL ergänzt worden.

Aus der Definition folgt unmittelbar, dass der Datentyp Boolean für Tabellen drei Elemente beinhaltet. Diese sind „wahr“, „falsch“ und „NULL“.

Definition Tabelle: Eine *Tabelle* hat einen Namen, eine Menge von Attributen $\{Att_1, \dots, Att_n\}$, wobei jedes Attribut Att_i Teilmenge eines Datentyps für Tabellen ist, und einen Inhalt der Teilmenge des Kreuzproduktes der Attribute $Att_1 \times \dots \times Att_n$.

Spaltenüberschriften sind Attribute

Diese sehr mathematische Definition bedarf einer genauen Erläuterung. Die Attribute entsprechen den Spaltenüberschriften der Tabelle. Dabei wird jedem Attribut ein konkreter Datentyp zugeordnet. Im Beispiel könnte Bestellnr die Menge Zahl selber sein. Da man aber wahrscheinlich keine negativen und Fließkommazahlen haben möchte, steht Bestellnr für eine Teilmenge von Zahl.

Kreuzprodukt als Basis der Tabelleninhalte

Durch das *Kreuzprodukt* $Att_1 \times \dots \times Att_n$ wird die Menge aller möglichen Einträge beschrieben, die theoretisch in der Tabelle stehen können. Elemente dieses Kreuzproduktes werden auch *n-Tupel* genannt. Jedes dieser n-Tupel entspricht einer Zeile der Tabelle.

Beispiel: Das Attribut Kunde sei eine Teilmenge des Datentyps Zahl, die genau drei Elemente umfasst, genauer $Kunde = \{42, 69, 88\}$. Das Attribut Zahlungsfähig sei eine Teilmenge des Datentyps Boolean, der nur die Werte „wahr“ und „falsch“ umfasst.

Das Kreuzprodukt von Kunde und Zahlungsfähig beinhaltet dann alle Kombinationen dieser Werte. Es gilt:

$Kunde \times Zahlungsfähig = \{(42, wahr), (69, wahr), (88, wahr), (42, falsch), (69, falsch), (88, falsch)\}$

Statt dieser vielleicht ungewöhnlichen Tupel-Notation, kann man das Kreuzprodukt auch wie in Abb. 3.2 gezeigt darstellen. In dieser Darstellung sind alle möglichen Wert-

kombinationen genannt, die in einer realen Tabelle auftreten können.

Kunde	Zahlungsfähig
42	wahr
69	wahr
88	wahr
42	falsch
69	falsch
88	falsch

Abb. 3.2: Tabellenartige Darstellung des Kreuzproduktes

Zahlungsmoral	
Kunde	Zahlungsfähig
42	wahr
69	falsch
88	falsch

Abb. 3.3: Tabelle als Teilmenge des Kreuzprodukts

Typische Tabellen enthalten dann nicht alle Einträge des Kreuzprodukts, wie es in Abb. 3.3 beschrieben ist. Die Abb. zeigt ein konkretes Beispiel mit der Tabelle Zahlungsmoral.

3.2

Übersetzung von Entity-Relationship-Modellen in Tabellen

Drei Ziele der Übersetzung

Bei der Übersetzung von Entity-Relationship-Modellen in Tabellen gibt es drei zentrale Ziele:

1. Bei der Füllung der Tabellen mit Daten sollen redundante Daten vermieden werden.
2. Wenn es nicht aus praktischer Sicht notwendig ist, sollen keine NULL-Werte zur Füllung der Tabellen notwendig werden.
3. Es soll unter Berücksichtigung von 1. und 2. eine möglichst minimale Anzahl von Tabellen entstehen.

Das erste Ziel bedeutet z. B., dass der Kundenname nur an einer Stelle steht. Will man Informationen mit dem Kunden verknüpfen, wird nur seine Kundennummer als Referenz genutzt.

*NULL-Wert-
Behandlung ist
aufwändig und
fehlerträchtig*

Das zweite Ziel bedeutet, dass man genau überlegen soll, ob man optionale Werte wirklich benötigt. Hat jeder Mitarbeiter entweder keinen oder einen Firmenwagen, sind Spalten mit Daten zu den Firmenwagen in einer Mitarbeitertabelle zu vermeiden, da für Mitarbeiter ohne Wagen NULL-Werte, z. B. beim KFZ-Kennzeichen eingetragen werden müssen. In der praktischen Umsetzung in den folgenden Kapiteln wird deutlich, dass die Arbeit durch NULL-Werte wesentlich erschwert werden kann.

Das dritte Ziel ergänzt die anderen beiden Ziele. Würde dieses Ziel alleine stehen, könnte man alle Daten in eine große Tabelle eintragen, die dann redundante Informationen und NULL-Werte enthalten würde. Durch das dritte Ziel soll die Tabellenanzahl gering gehalten werden, da dies später die Arbeit erleichtern und verkürzen kann.




Abb. 3.4: Beispielmmodell für Übersetzung

Die Übersetzung eines Entity-Relationship-Modells in Tabellen folgt einem klaren Verfahren, was mit Hilfe des Modells aus Abb. 3.4 beschrieben werden soll. Als Besonderheit muss man die Nummer der bearbeitenden Abteilung (AbtNr) und den Titel eines Projekts kennen, um das Projekt genau identifizieren zu können.

1. Schritt: Übersetzung der Entitätstypen

Jeder Entitätstyp wird in eine Tabelle übersetzt, wobei die Attribute des Entitätstypen zu den Attributen der Tabelle werden. Abb. 3.5 zeigt die aus Abb. 3.4 abgeleiteten Tabellen. Dabei wurden beispielhaft einige Daten ergänzt.

Mitarbeiter		Firmenhandy	
<u>MiNr</u>	Name	<u>TelNr</u>	Typ
42	Egon	01777	Nokus
43	Erwin	01700	Erika
44	Erna	01622	Simen

Projekt		Kunde	
<u>AbtNr</u>	<u>Titel</u>	<u>KNr</u>	Name
1	DBX	54	Bonzo
1	Jovo	55	Collecto
2	DBX		

Abb. 3.5: Übersetzung der Entitäten

*Entitätstypen
als Tabellen*

Die Informationen über die identifizierenden Attribute, die im Modell als unterstrichene Attribute eingetragen wurden, werden in die Tabelle übernommen. Für eine Präzisierung dieser „identifizierenden Attribute“ sei auf das folgende Kapitel hingewiesen.

2. Schritt: Übersetzung von 1:1-Beziehungen

Mitarbeiter			
<u>MiNr</u>	Name	<u>TelNr</u>	Typ
42	Egon	01777	Nokus
43	Erwin	01700	Erika
44	Erna	01622	Simen

Abb. 3.6: Übersetzung von 1:1-Beziehungen

*Tabellenzu-
sammenlegung
bei 1:1-
Beziehungen*

Durch 1:1-Beziehungen wird eine enge Bindung zwischen Entitätstypen beschrieben, da eine Paar-Bildung zwischen den jeweiligen Entitäten vorliegt. Diese Informationen werden in einer Tabelle vereinigt. Dabei kann aus den zur Verfügung stehenden identifizierenden Attributen eine der beiden Möglichkeiten ausgewählt werden. Abb. 3.6 zeigt, dass die Tabellen Mitarbeiter und Firmenhandy zusammengefasst wurden. Hätte die Beziehung Attribute, würden diese mit in die Tabelle aufgenommen. Die beiden anderen Tabellen werden nicht verändert.

3. Schritt: Übersetzung von 1:N Beziehungen

Jedes Projekt hat nach Modell genau einen Kunden. Diese Information über den zum Projekt gehörenden Kunden wird in die

Tabelle Projekt übernommen. Zur Übersetzung der Beziehung „beauftragt“ werden die identifizierenden Attribute des Kunden zusätzlich in die Tabelle Projekt mit eingetragen.

Projekt				Kunde	
<u>AbtNr</u>	<u>Titel</u>	<u>KNr</u>	<u>Auftragsdatum</u>	<u>KNr</u>	<u>Name</u>
1	DBX	54	26.02.06	54	Bonzo
1	Jovo	54	06.05.06	55	Collecto
2	DBX	55	27.02.06		

Abb. 3.7: Übersetzung von 1:N-Beziehungen

Verknüpfungs-
informationen
bei 1:N ergän-
zen

Weiterhin werden die Attribute der Beziehung mit in die Tabelle aufgenommen. Die Spalte KNr wird dann auch *Fremdschlüssel* genannt, da über ihre Werte auf jeweils genau einen Kunden geschlossen werden kann. Abb. 3.7 zeigt die neue Projekttabelle mit der unveränderten Kundentabelle. Die Tabelle Mitarbeiter bleibt unverändert.

4. Schritt: Übersetzung von M:N-Beziehungen

Mitarbeiter				Bearbeitung			
<u>MiNr</u>	<u>Name</u>	<u>TelNr</u>	<u>Typ</u>	<u>MiNr</u>	<u>AbtNr</u>	<u>Titel</u>	<u>Rolle</u>
42	Egon	01777	Nokus	42	1	DBX	Design
43	Erwin	01700	Erika	42	1	Jovo	Review
44	Erna	01622	Simen	43	2	DBX	Analyse
				44	1	Jovo	Design
				44	2	DBX	Review

Projekt				Kunde	
<u>AbtNr</u>	<u>Titel</u>	<u>KNr</u>	<u>Auftragsdatum</u>	<u>KNr</u>	<u>Name</u>
1	DBX	54	26.02.06	54	Bonzo
1	Jovo	54	06.05.06	55	Collecto
2	DBX	55	27.02.06		

Abb. 3.8: Übersetzung von M:N-Beziehungen

Verknüpfungs-
tabellen für
M:N

Bei M:N-Beziehungen können mehrere Entitäten auf der einen Seite mit mehreren Entitäten auf der anderen Seite in Beziehung stehen. Im Beispiel können verschiedene Mitarbeiter in verschiedenen Projekten mitarbeiten, wobei auch in jedem Projekt mehrere Mitarbeiter tätig sein können. Um solche Beziehungen in Tabellen zu übersetzen, wird eine neue Tabelle angelegt, deren

Name möglichst eng mit dem Namen der Beziehung korrespondiert. Da Verbformen als Tabellennamen seltener sind, wird meist nach einem verwandten Nomen gesucht. In diese Tabelle werden die identifizierenden Attribute beider in Beziehung stehender Entitätstypen als Spalten aufgenommen. Attribute der Beziehung werden in der Tabelle ergänzt. Die identifizierenden Attribute dieser Tabelle setzen sich aus den identifizierenden Attributen der einzelnen Entitätstypen zusammen. In Abb. 3.8 ist das vollständige Ergebnis der Übersetzung des Entity-Relationship-Modells dargestellt. Es wurde die Tabelle Bearbeitung ergänzt.

Umgang mit C und NC


Bei den genannten Schritten fällt auf, dass sie keine Übersetzungsinformationen für die Kardinalitäten C und NC enthalten. Der Ansatz hierfür ist, dass für den Übersetzungsschritt C und NC als N interpretiert werden, wodurch immer das beschriebene Übersetzungsverfahren angewandt werden kann. Der Umgang mit NC und C soll jetzt genauer untersucht werden.

Analyse von M:NC-Beziehungen

Die M:N-Beziehung zwischen Projekt und Mitarbeiter könnte in eine M:NC-Beziehung abgeändert werden. Dies ist sinnvoll, wenn es Mitarbeiter gibt, die in keinem Projekt mitarbeiten, z. B. auf Stabsstellen sitzen. Für diese Mitarbeiter folgt einfach, dass es keinen Eintrag mit ihrer Mitarbeiternummer in der Tabelle Bearbeitung gibt. Es muss keine zusätzliche Verarbeitung dieser Information stattfinden.

Ändert man das Beispiel so, dass jeder Mitarbeiter ein Firmenhandy haben kann, aber nicht muss, wird also die Beziehung in 1:C umgewandelt, kann man die Lösung aus der 1:1-Übersetzung nicht übernehmen, da dann NULL-Werte in den Zeilen bei den Mitarbeitern ohne Handy stünden. Aus der anzuwendenden 1:N-Übersetzung folgt, dass es eine eigene Tabelle für die Firmenhandys gibt und zusätzlich bei ihnen als Fremdschlüssel die Mitarbeiternummer (MiNr) des besitzenden Mitarbeiters eingetragen wird.

Ändert man das Beispiel weiter, so dass es auch Handys gibt, die keinem Mitarbeiter zugeordnet sind, also es sich um eine C:C-Beziehung handelt, kann die zuletzt vorgeschlagene Lösung nicht genutzt werden, da in der Handytabelle NULL-Werte bei den Handys ohne Besitzer stehen würden. Die C:C-Beziehung wird deshalb wie eine M:N-Beziehung behandelt. Neben den Tabellen Mitarbeiter und Firmenhandy wird eine Tabelle Handybesitz ergänzt, in der für Mitarbeiter, die ein Handy besitzen, die Mitarbeiternummer und die Telefonnummer (TelNr.) stehen.

**Abb. 3.9:** Übersetzung einer komplexen Beziehung

*Behandlung
komplexer Be-
ziehungen*

*Attribute sollten
eindeutige Na-
men haben*

Beziehungen, die mehr als zwei Entitätstypen verknüpfen, werden ähnlich zu M:N-Beziehungen übersetzt. Aus der Beziehung wird eine neue Tabelle, die als Spalten alle identifizierenden Attribute der beteiligten Entitätstypen erhält. Ein Übersetzungsbeispiel befindet sich zusammen mit dem Modell in Abb. 3.9. Weiterhin deutet die Abbildung ein Problem an, das entsteht, wenn mehrere Attribute den gleichen Namen haben. Dies ist für Entity-Relationship-Modelle kein Problem, wird aber zum Problem bei der Übersetzung. Aus diesem Grund verzichten Modellierer häufiger auf gleiche Attributnamen bei unterschiedlichen Entitätstypen. Da Spalten in Tabellen nicht den gleichen Namen haben dürfen, muss eine Umbenennung, wie im Beispiel angedeutet, stattfinden.

3.3

Besondere Aspekte der Übersetzung

Das Übersetzungsverfahren wurde im vorherigen Unterkapitel vollständig beschrieben. In diesem Unterkapitel wird analysiert, welchen Einfluss leicht unterschiedliche Entity-Relationship-Modelle auf die resultierenden Tabellen haben. Diese Erkenntnisse können im Umkehrschluss die Erstellung von Entity-Relationship-Modellen erleichtern.

Zentrale Aussage dieses Unterkapitels ist, dass die im vorherigen Kapitel aufgezeigten Modellierungsalternativen zu fast identischen Tabellen führen.






Abb. 3.10: Aus Alternativmodell abgeleitete Tabellen

Für die Beziehung aus Abb. 3.9, die mehr als zwei Entitätstypen betrifft, wurde bereits eine alternative Modellierungsmöglichkeit beschrieben, die nur Beziehungen zwischen zwei Entitätstypen beinhaltet. Dieses alternative Entity-Relationship-Modell und die daraus abgeleiteten Tabellen sind in Abb. 3.10 dargestellt. Man erkennt im Vergleich mit der vorherigen Lösung, dass die Tabelle, die ursprünglich aus der komplexen Beziehung abgeleitet wurde, jetzt in ähnlicher Form existiert. Es wurde nur zusätzlich ein identifizierendes Attribut eingefügt.

**Abb. 3.11:** Übersetzung einer MC:N-Beziehung**Abb. 3.12:** Übersetzung des äquivalenten Modells

*zwei 1:N- statt
einer M:N-
Beziehung*

Bei der Modellierung wurde gezeigt, dass man statt einer M:N-Beziehung auch zwei 1:N-Beziehungen nutzen kann. Werden diese Modelle in Tabellen übersetzt, erhält man die gleiche Anzahl an Tabellen, einzig ein neues identifizierendes Attribut wird ergänzt. Dieser Zusammenhang wird auch in Abb. 3.11 und Abb. 3.12 dargestellt, in denen Modelle mit der gleichen Aussage in Tabellen übersetzt werden.

Generell bleibt festzuhalten, dass es ein eindeutiges Ergebnis bei der Übersetzung eines Entity-Relationship-Modells in Tabellen

Tabellen in Modell überset- zen

gibt. Eine eindeutige Rückübersetzung von Tabellen in ein Entity-Relationship-Modell ist häufig aber nicht möglich, da es Interpretationsspielräume gibt, ob eine Tabelle von einer Beziehung oder einem Entitätstypen stammt. Will man z. B. die Tabellen aus Abb. 3.12 zurück in ein Modell übersetzen, kann auch das Modell aus Abb. 3.11 das Ergebnis sein, bei dem das Attribut PstNr ein zusätzliches Attribut der Beziehung „beinhaltet“ wäre.

3.4

Fallstudie

Ausgehend vom Entity-Relationship-Modell in Abb. 2.31 werden die in Abb. 3.13 und Abb. 3.14 dargestellten Tabellen abgeleitet, die zur Veranschaulichung mit einigen Daten gefüllt wurden.

Projekt

ProNr	Name
1	GUI
2	WebShop

Risikogruppe

RGNr	Gruppe
1	Kundenkontakt
2	Vertrag
3	Ausbildung

Risiko

RNr	Pro- jekt	Text	Gruppe	Auswirkung	Wkeit	Prüf- datum
1	1	Anforderungen unklar	1	50000	30	25.01.06
2	1	Abnahmeprozess offen	2	30000	70	26.02.06
3	2	Ansprechpartner wechseln	1	20000	80	06.05.06
4	2	neue Entwick- lungsumgebung	3	40000	20	05.10.06

Abb. 3.13: Abgeleitete Tabellen der Fallstudie (Teil 1)

Um die Tabelle Risiko lesbarer zu machen, findet die Verknüpfung des Risikos mit dem zugehörigen Projekt mit einer Spalte mit dem anschaulicheren Namen Projekt statt, in der die zugehö-

rige Projektnummer, also ProNr aus der Tabelle Projekt, eingetragen wird. Weiterhin wird die zum Risiko gehörende Gruppe in die Spalte Gruppe eingetragen, die sich auf eine RGNr in Risikogruppe bezieht.

Maßnahme

MNr	Titel	Verantwortlich
1	Vertragsprüfung	Meier
2	Werkzeugschulung	Schmidt

Zuordnung

Risiko	Massnahme	Prüfdatum	Status
1	1	20.01.06	offen
2	1	20.02.06	offen
4	2	30.07.06	offen

Abb. 3.14: Abgeleitete Tabellen der Fallstudie (Teil 2)

Die Tabelle Zuordnung ist aus der Beziehung „bearbeitet durch“ entstanden, dabei bezieht sich die Spalte Risiko auf einen Wert in der Spalte RNr der Tabelle Risiko und Maßnahme auf einen Wert in der Spalte MNr der Tabelle Maßnahme.

3.5

Aufgaben

Wiederholungsfragen


Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu beantworten.

1. Wie kann man den Begriff Tabelle genau beschreiben?
2. Was versteht man unter Datentypen?
3. Erklären Sie anschaulich den Begriff Kreuzprodukt.
4. Wozu gibt es NULL-Werte? Wie viele verschiedene gibt es davon?
5. Nennen Sie die drei zentralen Ziele der Übersetzung von Entity-Relationship-Modellen.
6. Beschreiben Sie die Übersetzung der verschiedenen Beziehungstypen aus Entity-Relationship-Modellen in Tabellen.

7. Wie werden Beziehungen mit C- bzw. NC-Kardinalitäten übersetzt? Warum wird dieser Weg gewählt?
8. Wie werden Beziehungen zwischen mehr als zwei Entitätstypen übersetzt?
9. Beschreiben Sie unterschiedliche Modellierungen für den gleichen Sachverhalt und deren Auswirkungen auf die aus der Übersetzung resultierenden Tabellen.


Übungsaufgaben

1. Übersetzen Sie mit dem vorgestellten Verfahren das folgende Entity-Relationship-Modell in Tabellen.



Geben Sie zwei Änderungen an dem Modell an, die Sie für praxisnäher halten würden, schauen Sie auf die Kardinalitäten.

2. Gegeben sei folgendes allgemeine Entity-Relationship-Modell.



Geben Sie für alle Kombinationen von Kardinalitäten für x und y, also insgesamt 16 Möglichkeiten, die Tabellen an, die Ergebnis der Übersetzung sind.

4

Normalisierung

*Normalformen
als Qualitätsin-
dikatoren*

Schlecht aufgebaute Tabellen können den Einsatz und die Weiterentwicklung einer Datenbank wesentlich erschweren. In diesem Kapitel lernen Sie Qualitätskriterien für Tabellen kennen, wie diese überprüft werden und welche Reperaturmöglichkeiten man gegebenenfalls hat.

In den vorangegangenen Kapiteln wurden die Bedeutung von Tabellen und die Notwendigkeit, keine redundanten Daten in einer Datenbank zu halten, betont. In diesem Kapitel wird ein systematischer Ansatz gezeigt, mit dem man untersuchen kann, ob Tabellen potenzielle Probleme enthalten, die die spätere Arbeit wesentlich erschweren können. Hinter dem Ansatz stecken so genannte Normalformen, wobei jede Normalform auf einen kritischen Aspekt in den Tabellen hinweist.

*dritte Normal-
form ist Pflicht
in der Praxis*

Bevor man sich intensiver mit Normalformen beschäftigen kann, müssen einige Begriffe geklärt werden, die in den Definitionen der Normalformen genutzt werden. Nach der Begriffsklärung werden die erste, zweite und dritte Normalform vorgestellt. Dabei ist die Forderung, dass Tabellen in dritter Normalform sein müssen, die zentrale Forderung in der Praxis. In einem eingeschobenen Unterkapitel wird gezeigt, dass erfahrene Modellierer bereits bei der Erstellung von Entity-Relationship-Modellen darauf achten können, dass die aus der Übersetzung resultierenden Tabellen in dritter Normalform sind.

Auch mit Tabellen in der dritten Normalform kann es noch Probleme geben. Diese Probleme und ihre Behandlung durch weitere Normalformen werden in einem mit [*] gekennzeichneten Unterkapitel behandelt.

4.1

Funktionale Abhängigkeit und Schlüsselkandidaten

In Abb. 4.1 ist eine Tabelle dargestellt, in der festgehalten wird, welcher Mitarbeiter in welcher Abteilung arbeitet und an welchen Projekten er beteiligt ist. Aus dem Gespräch mit dem Kunden der Datenbank ist bekannt, dass ein Mitarbeiter immer zu

genau einer Abteilung gehört und dass mehrere Mitarbeiter in verschiedenen Projekten arbeiten können.

Projektmitarbeit

MiNr	Name	AbtNr	Abteilung	ProNr	Projekt
1	Egon	42	DB	1	Infra
1	Egon	42	DB	2	Portal
2	Erna	42	DB	2	Portal
2	Erna	42	DB	3	Frame
3	Uwe	43	GUI	1	Infra
3	Uwe	43	GUI	3	Frame

Abb. 4.1: Beispieltabelle mit redundanten Daten

*Potenzielle
Probleme mit
Tabellen*

Eine solche Tabelle trifft man in der Praxis häufiger an, wenn Tabellenkalkulationsprogramme zur Verwaltung von Daten genutzt werden. An diesem Beispiel sieht man bereits, dass typische Operationen auf Datenbanken relativ komplex sein können. Beispiele sind:

Löschen: Soll der Mitarbeiter Egon, also im Datenbank-Sprachgebrauch eine Entität, aus der Tabelle gelöscht werden, müssen zwei Zeilen aus der Datenbank entfernt werden. Dies kann bei manueller Änderung durch das Übersehen von Einträgen zu Problemen führen.

Ändern: Soll das Projekt Infra in Infrastruktur umbenannt werden, müssen wieder zwei Zeilen geändert werden. Dies kann bei manueller Änderung durch das Übersehen von Einträgen zu Problemen führen.

Einfügen: Soll ein neuer Mitarbeiter Udo für die Abteilung 42 eingetragen werden, der bei den Projekten Portal und Frame mitarbeiten soll, dann müssen zwei Zeilen eingetragen werden. Da zwei Projekte beteiligt sind, ist dies zunächst kein Problem. Problematisch kann der manuelle Eintrag aber werden, wenn man sich z. B. bei der Eingabe des Abteilungsnamens vertippt.

*Gefühl für
schlechte Tabellen*

Mit einem gewissen „Datenbankgefühl“ spürt man, dass statt einer Tabelle mehrere Tabellen benötigt werden. Es stellt sich die Frage, wie man dieses Gefühl formalisieren kann. Dazu wird zunächst der Begriff „funktionale Abhängigkeit“ definiert.

Für mathematisch unerfahrene Leser sei angemerkt, dass in den Definitionen häufig von *Attributmengen* die Rede ist. Dies bezeichnet anschaulich die Überschriften der Spalten in den Tabel-

len. Weiterhin muss bedacht werden, dass jede Menge im Spezialfall genau ein Attribut enthalten kann.

Definition funktionale Abhängigkeit: Gegeben sei eine Tabelle. Eine Menge von Attributen B der Tabelle ist *funktional abhängig* von einer Menge von Attributen A der Tabelle, wenn es zu jeder konkreten Belegung der Attribute aus A nur maximal eine konkrete Belegung der Attribute aus B geben kann. Für funktionale Abhängigkeiten wird die Schreibweise $A \rightarrow B$ genutzt.

Bevor diese Definition genauer analysiert wird, muss der Begriff Belegung geklärt werden. Anschaulich handelt es dabei um die Daten, die in einer Tabelle für eine Attributkombination eingetragen sein können.

Definition Belegung von Attributen: Gegeben seien die Attribute $A_1, \dots, A_n$ einer Tabelle T . Alle Elemente aus $A_1 \times \dots \times A_n$ werden mögliche *Belegungen* der Attribute genannt. In der Tabelle T sind die für diese Tabelle konkreten Belegungen aufgeführt.

In der Tabelle Projektmitarbeit gibt es folgende Belegungen von MiNr und Name: (1, Egon), (2, Erna) und (3, Uwe).

Anschaulich besagt eine funktionale Abhängigkeit $A \rightarrow B$, dass, wenn man eine Belegung der Attribute aus A kennt, man dazu genau eine Belegung der Attribute aus B finden kann.

Wenn garantiert ist, dass jeder Mitarbeiter eine eindeutige Mitarbeiternummer (MiNr) hat, dann gilt die funktionale Abhängigkeit

$$\{\text{MiNr}\} \rightarrow \{\text{Name}\}$$

Veranschaulichung von funktionaler Abhängigkeit

Wird vom Mitarbeiter 3 gesprochen, ist eindeutig, dass ein Uwe gemeint ist. Dass viele Nummern nicht vergeben sind, ist dabei kein Problem. Wichtig bei diesem Sachverhalt ist, dass man aus dem Anwendungsbereich weiß, dass jeder Mitarbeiter eine eindeutige Nummer erhält. Es gilt:

Anmerkung: Aus gegebenen Tabellen mit ihren Inhalten kann nie auf eine funktionale Abhängigkeit $A \rightarrow B$ geschlossen werden. An den konkreten Einträgen kann man höchstens erkennen, dass eine funktionale Abhängigkeit nicht gegeben ist. Funktionale Abhängigkeiten können nur aus dem *Wissen über den Anwendungsbereich* abgeleitet werden.

Diese Anmerkung kann man sich wie folgt veranschaulichen: Aus den gegebenen Daten könnte man schließen, dass auch $\{\text{Name}\} \rightarrow \{\text{MiNr}\}$ gilt. Fällt der Name Egon, weiß man, dass vom Mitarbeiter mit der Nummer 1 die Rede ist. Dies gilt aber nur, solange nur ein Mitarbeiter Egon heißt. Wird ein neuer Mitarbeiter mit dem gleichen Namen und natürlich anderer Mitarbeiternummer eingestellt, ist der Schluss vom Namen auf die Mitarbeiternummer nicht mehr möglich.

Sichert der Kunde der Datenbank zu, dass der neue Egon sich dran gewöhnen muss, immer „Egon Zwo“ genannt zu werden und so auch in der Datenbank eingetragen werden soll, gilt auch $\{\text{Name}\} \rightarrow \{\text{MiNr}\}$.

*Widerlegung
einer funktio-
nalen Abhän-
gigkeit*

Durch einen Blick auf die Tabelle Projektmitarbeit kann man allerdings direkt erkennen, dass $\{\text{ProNr}\} \rightarrow \{\text{Abteilung}\}$ nicht gelten kann, da es zur Projektnummer (ProNr) 1 die Abteilungen DB und GUI gibt.

*Analyse der De-
finition der
funktionalen
Abhängigkeit*

Betrachtet man die Definition der funktionalen Abhängigkeit aus mathematischer Sicht, so kann man aus $\{\text{MiNr}\} \rightarrow \{\text{Name}\}$ auch auf die funktionale Abhängigkeit $\{\text{MiNr}, \text{ProNr}\} \rightarrow \{\text{Name}\}$ schließen. Wenn man die Mitarbeiternummer und die Projektnummer kennt, kennt man auch den zugehörigen Namen des Mitarbeiters, da man ja die dafür notwendige Mitarbeiternummer hat. Die Menge auf der linken Seite muss also keineswegs minimal sein.

Mathematisch gilt weiterhin $\{\text{Name}\} \rightarrow \{\text{Name}\}$, da man, wenn man den Namen kennt, eindeutig auf den Namen schließen kann. Sind dabei z. B. mehrere Egons in der Tabelle, ist dies kein Problem, da die Aussage nur bedeutet, dass wenn man weiß, dass der Mitarbeiter Egon heißt, dann weiß man, dass der Mitarbeiter Egon heißt. Diese merkwürdig klingende und praktisch irrelevant aussehende Abhängigkeit kann das Verständnis einzelner Definitionen in Extremfällen erleichtern.

*Transitivität der
funktionalen
Abhängigkeit*

Praktisch sinnvoller ist die Möglichkeit des so genannten „transitiven Schließens“. Anschaulich bedeutet dies, dass, wenn man aus der Mitarbeiternummer auf die Abteilungsnummer (AbtNr) schließen kann, also $\{\text{MiNr}\} \rightarrow \{\text{AbtNr}\}$ gilt und man aus der Abteilungsnummer auf den Abteilungsnamen schließen kann, also $\{\text{AbtNr}\} \rightarrow \{\text{Abteilung}\}$ gilt, man auch von der Mitarbeiternummer direkt auf den Abteilungsnamen schließen kann, also $\{\text{MiNr}\} \rightarrow \{\text{Abteilung}\}$ gilt.

Rechenregeln für funktionale Abhängigkeit

Die hier beispielhaft angedeuteten Rechenregeln werden in der folgenden Anmerkung verallgemeinert zusammengefasst. Dabei steht „ $\cup$ “ für die Vereinigung zweier Mengen, also die Menge, die entsteht, wenn man alle Elemente der beiden Mengen in einer neuen Menge zusammenfasst.

Anmerkung: Seien A, B, C und D Attributmengen einer Tabelle, dann gelten folgende Aussagen:

$$A \rightarrow A$$

$$\text{aus } A \rightarrow B \text{ folgt } A \cup C \rightarrow B$$

$$\text{aus } A \rightarrow B \text{ folgt } A \cup C \rightarrow B \cup C$$

$$\text{aus } A \rightarrow B \cup C \text{ folgt } A \rightarrow B \text{ und } A \rightarrow C$$

$$\text{aus } A \rightarrow B \text{ und } B \rightarrow C \text{ folgt } A \rightarrow C$$

$$\text{aus } A \rightarrow B \text{ und } A \rightarrow C \text{ folgt } A \rightarrow B \cup C$$

$$\text{aus } A \rightarrow B \text{ und } C \rightarrow D \text{ folgt } A \cup C \rightarrow B \cup D$$

$$\text{aus } A \rightarrow B \text{ und } B \cup C \rightarrow D \text{ folgt } A \cup C \rightarrow D$$

Zur weiteren Veranschaulichung ist es empfohlen, sich Beispiele auszudenken und die resultierenden funktionalen Abhängigkeiten nachzuvollziehen.

Aus dem beschriebenen und für Anfänger irritierenden Beispiel $\{\text{MiNr}, \text{ProNr}\} \rightarrow \{\text{Name}\}$ folgt, dass die Menge auf der linken Seite beliebig wachsen kann und man nicht sofort erkennt, welche Information, hier $\{\text{MiNr}\} \rightarrow \{\text{Name}\}$, wirklich wichtig ist. Man ist also an möglichst kleinen Mengen auf der linken Seite interessiert. Dieser Wunsch wird im Begriff „volle funktionale Abhängigkeit“ formalisiert.

Definition volle funktionale Abhängigkeit: Gegeben sei eine Tabelle. Eine Menge von Attributen B der Tabelle ist *voll funktional abhängig* von einer Menge von Attributen A der Tabelle, wenn $A \rightarrow B$ gilt und für jede echte Teilmenge A' von A nicht $A' \rightarrow B$ gilt.

Unter einer echten Teilmenge von A versteht man dabei eine Menge, die nur Elemente enthält, die auch in A vorkommen, wobei mindestens eines der Elemente aus A fehlt. Die Menge $\{1, 2, 3\}$ hat z. B. die echten Teilmengen $\{2, 3\}$, $\{1, 3\}$, $\{1\}$, $\{2\}$, $\{3\}$ und $\{\}$, dabei bezeichnet $\{\}$ die leere Menge, die kein Element enthält.

Berechnung voll funktionaler andere Rechen- regeln für volle funktionale Abhängigkeit

Aus der Definition einer Teilmenge kann man auch leicht ableiten, wie man aus einer funktionalen Abhängigkeit eine volle funktionale Abhängigkeit berechnet. Für $A \rightarrow B$ versucht man, jedes einzelne Attribut aus A zu entfernen und prüft, ob noch immer eine funktionale Abhängigkeit vorliegt. Kann man kein Element aus A entfernen, liegt eine volle funktionale Abhängigkeit vor. Falls ein Element entfernt werden kann, muss die Prüfung auf Minimalität der Menge erneut vorgenommen werden. Bei diesen Prüfungen kann es durchaus passieren, dass man aus einer funktionalen Abhängigkeit mehrere volle funktionale Abhängigkeiten herausrechnen kann. Es kann z. B. aus $\{X,Y,Z\} \rightarrow \{U\}$ folgen, dass es die vollen funktionalen Abhängigkeiten $\{X,Y\} \rightarrow \{U\}$ und $\{X,Z\} \rightarrow \{U\}$ gibt. Hieraus folgt auch, dass die in der letzten Anmerkung vorgestellten Rechenregeln für die funktionale Abhängigkeit nicht alle auf die volle funktionale Abhängigkeit übertragen werden können.

Mit diesem Ansatz kann man z. B. bestimmen, dass $\{\text{MiNr}, \text{ProNr}\} \rightarrow \{\text{Name}\}$ keine volle funktionale Abhängigkeit ist. Man kann die Menge $\{\text{MiNr}, \text{ProNr}\}$ verkleinern. Es folgt, dass $\{\text{MiNr}\} \rightarrow \{\text{Name}\}$ eine volle funktionale Abhängigkeit ist. Generell kann man dazu folgende Anmerkung nutzen.

Anmerkung: Gilt $A \rightarrow B$ und enthält A nur ein Element, dann handelt es sich auch um eine volle funktionale Abhängigkeit.

Für die Tabelle Projektmitarbeit gelten folgende volle funktionale Abhängigkeiten: $\{\text{MiNr}\} \rightarrow \{\text{Name}\}$, $\{\text{AbtNr}\} \rightarrow \{\text{Abteilung}\}$, $\{\text{ProNr}\} \rightarrow \{\text{Projekt}\}$.

identifizierende Attribute

Bereits bei der Einführung der Entity-Relationship-Modelle wurden einige Attribute als identifizierend unterstrichen. Diese dort gegebene informelle Beschreibung wird durch die folgenden Definitionen konkretisiert. Zunächst wird der Schlüssel-Begriff formalisiert. Dabei sei bemerkt, dass bei Datenbanken häufig von Schlüsseln die Rede ist, genauer aber von den später hier definierten Schlüsselkandidaten gesprochen werden muss.

Definition Schlüssel: Gegeben sei eine Tabelle und eine Menge M , die alle Attribute der Tabelle enthält. Gegeben sei weiterhin eine Attributsmenge A der Tabelle. Wenn $A \rightarrow M$ gilt, dann heißt A *Schlüssel* der Tabelle.

Anschaulich ist eine Attributsmenge ein Schlüssel, wenn man aus den Attributen aus A eindeutig alle Belegungen der Attribute der Tabelle berechnen kann. Für die Tabelle Projektmitarbeit gilt

$\{\text{MiNr}, \text{ProNr}\} \rightarrow \{\text{MiNr}, \text{ProNr}, \text{Name}, \text{AbtNr}, \text{Abteilung}, \text{Projekt}\}$

also ist $\{\text{MiNr}, \text{ProNr}\}$ ein Schlüssel von Projektmitarbeit. Betrachtet man die Schlüssel-Definition genauer, kann man feststellen, dass dort nur funktionale Abhängigkeiten zur Definition genutzt werden, also keine Minimalität gefordert ist. Daraus folgt, dass die Tabelle Projektmitarbeit noch weitere Schlüssel hat. Dies sind:

$\{\text{MiNr}, \text{ProNr}, \text{Name}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Abteilung}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Projekt}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{AbtNr}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Name}, \text{Abteilung}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Name}, \text{Projekt}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Name}, \text{AbtNr}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Abteilung}, \text{Projekt}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Abteilung}, \text{AbtNr}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Projekt}, \text{AbtNr}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Name}, \text{Abteilung}, \text{Projekt}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Name}, \text{Abteilung}, \text{AbtNr}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Name}, \text{Projekt}, \text{AbtNr}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{Abteilung}, \text{Projekt}, \text{AbtNr}\}$
 $\{\text{MiNr}, \text{ProNr}, \text{AbtNr}, \text{Name}, \text{Abteilung}, \text{Projekt}\}$

Diese Überlegung kann noch wie folgt verallgemeinert werden.

Jede Tabelle hat Schlüssel

Anmerkung: Jede Tabelle hat mindestens einen Schlüssel. Dies ist die Menge aller Attribute der Tabelle.

In der Praxis ist man an möglichst kleinen Schlüsseln interessiert. Dabei spielt die volle funktionale Abhängigkeit eine wichtige Rolle.

Definition Schlüsselkandidat: Gegeben sei eine Tabelle und eine Menge M, die alle Attribute der Tabelle enthält. Gegeben sei weiterhin eine Attributsmenge A der Tabelle. Wenn $A \rightarrow M$ gilt und dies eine volle funktionale Abhängigkeit ist, dann heißt A *Schlüsselkandidat* der Tabelle.

aus Schlüsseln Schlüsselkandidaten berechnen

Für die Tabelle Projektmitarbeit folgt unmittelbar, dass sie nur den einen Schlüsselkandidaten $\{\text{MiNr}, \text{ProNr}\}$ hat. Aus dem beschriebenen Verfahren, mit dem aus funktionalen Abhängigkeiten die vollen funktionalen Abhängigkeiten berechnet werden, können aus Schlüsseln die Schlüsselkandidaten berechnet wer-

den. Dabei kann es passieren, dass aus einem Schlüssel mehrere Schlüsselkandidaten berechnet werden können. Dies soll an einem konkreten Beispiel gezeigt werden.

Student			
MatNr	Name	Fachbereich	FBNr
42	Udo	Informatik	1
43	Ute	Informatik	2
44	Erwin	BWL	1
45	Egon	BWL	2
46	Erna	Informatik	3

Abb. 4.2: Tabelle mit mehreren Schlüsselkandidaten

*unterschiedlich
große Schlüsselkandidaten*

Für die Tabelle aus Abb. 4.2 soll folgendes gelten. Jeder Student bekommt eine eindeutige Matrikelnummer (MatNr). Weiterhin erhält jeder Student in seinem Fachbereich eine eindeutige Fachbereichsnummer (FBNr) zugeordnet. Ohne nachzudenken gilt:

$\{\text{MatNr}, \text{Name}, \text{Fachbereich}, \text{FBNr}\} \rightarrow$

$\{\text{MatNr}, \text{Name}, \text{Fachbereich}, \text{FBNr}\}$

Zunächst kann man die Menge auf der linken Seite um den Namen reduzieren, da zur Berechnung z. B. die MatNr ausreicht. Es gilt:

$\{\text{MatNr}, \text{Fachbereich}, \text{FBNr}\} \rightarrow \{\text{MatNr}, \text{Name}, \text{Fachbereich}, \text{FBNr}\}$

Danach kann man zwei Alternativen zur Verkleinerung der Menge nutzen. Letztendlich gilt:

$\{\text{MatNr}\} \rightarrow \{\text{MatNr}, \text{Name}, \text{Fachbereich}, \text{FBNr}\}$

$\{\text{Fachbereich}, \text{FBNr}\} \rightarrow \{\text{MatNr}, \text{Name}, \text{Fachbereich}, \text{FBNr}\}$

Es folgt, dass die Tabelle Student zwei Schlüsselkandidaten hat, da nur die Minimalität der jeweiligen Menge auf der linken Seite gefordert wird.

Für die folgenden Unterkapitel wird die nächste Definition benötigt.

Definition Schlüsselattribute und Nichtschlüsselattribute: Gegeben sei eine Tabelle. Die Menge der *Schlüsselattribute* der Tabelle enthält alle Attribute, die in mindestens einem Schlüsselkandidaten der Tabelle vorkommen. Die Menge der *Nichtschlüsselattribute* der Tabelle enthält alle Attribute, die in keinem Schlüsselkandidaten vorkommen.

Durch die Definition ist sichergestellt, dass jedes Attribut in genau einer der Mengen vorkommt. Für die Tabelle Student ist {MatNr, Fachbereich, FBNr} die Menge der Schlüsselattribute und {Name} die Menge der Nichtschlüsselattribute. Für die vorher benutzte Tabelle Projektmitarbeit ist {MiNr, ProNr} die Menge der Schlüsselattribute und {Name, AbtNr, Abteilung, Projekt} die Menge der Nichtschlüsselattribute.

Bei Datenbanken ist häufig von Primärschlüsseln die Rede. Der Begriff wird an dieser Stelle eingeführt, da er zu den vorgestellten Definitionen passt und für Diskussionen in den FolgeUnterkapiteln benötigt wird.

Definition Primärschlüssel: Gegeben sei eine Tabelle. Ein *Primärschlüssel* ist ein willkürlich ausgewählter Schlüsselkandidat der Tabelle.

*Willkür bei
Wahl eines
Primärschlüs-
sels*

Der Begriff „willkürlich“ in der Definition beschreibt, dass bei einer Tabelle, die mehrere Schlüsselkandidaten hat, man als verantwortlicher Datenbankentwickler einen dieser Schlüsselkandidaten zum Primärschlüssel erklären kann. In der graphischen Darstellung der Tabellen werden dann die Attribute des Primärschlüssels unterstrichen. In diesem Buch wird darauf hingewiesen, wenn es sich dabei nur um einen möglichen Primärschlüssel handelt, es also Alternativen geben würde. Wenn eine Tabelle nur einen Schlüsselkandidaten hat, wird von *dem* Primärschlüssel gesprochen.

*unterstrichene
Attribute*

*Regeln zur
Wahl des Pri-
märschlüssels*

Für die theoretischen Überlegungen ist es egal, welcher Schlüsselkandidat zum Primärschlüssel erklärt wird. In der Praxis kann diese Auswahl aber Auswirkungen auf die Performance haben. Es wird typischerweise der Schlüsselkandidat genutzt, der möglichst viele der folgenden Eigenschaften erfüllt:

- Die Belegungen der Attribute werden sich im Verlaufe der Tabellennutzung nicht oder zumindest nur selten ändern.
- Die Datentypen der Attribute verbrauchen wenig Speicherplatz und können deshalb schnell gefunden werden. Besonders geeignet sind Attribute mit ganzzahligen Werten. Attribute mit Fließkommawerten oder kurzen Texten sind auch geeignet.
- Der Primärschlüssel soll möglichst wenige Attribute enthalten.

Bei der Tabelle Student würde man sich für den Primärschlüssel {MatNr} entscheiden, der ganzzahlig ist und nur einmal bei der Einschreibung des Studenten vergeben wird.

Problem mit
ergänzten
Schlüsseln

Projektmitarbeit						
INr	MiNr	Name	AbtNr	Abteilung	ProNr	Projekt
1	1	Egon	42	DB	1	Infra
2	1	Egon	42	DB	2	Portal
3	2	Erna	42	DB	2	Portal
4	2	Erna	42	DB	3	Frame
5	3	Uwe	43	GUI	1	Infra
6	3	Uwe	43	GUI	3	Frame

Abb. 4.3: Tabelle mit künstlichem ergänzten Primärschlüssel

Um die Regeln für Schlüssel einzuhalten, werden in Tabellen häufig neue Spalten eingeführt, die einfach fortlaufende Nummern enthalten. Dies ist teilweise Geschmackssache, da neue künstliche Attribute die Lesbarkeit nicht erhöhen. Das sieht man an dem Beispiel in Abb. 4.3, bei dem in der Tabelle Projektmitarbeit eine laufende Nummer (INr) ergänzt wurde. Die Tabelle wird nicht einfacher, weiterhin kann man mit einem ungeübten Blick denken, dass eine Tabelle mit einem so einfachen Primärschlüssel sicherlich keine Probleme enthalten kann. Es sei vermerkt, dass diese Tabelle jetzt zwei Schlüsselkandidaten hat und keines der in den folgenden Unterkapiteln diskutierten Probleme gelöst wird.

4.2

Anschauung
der ersten Nor-
malform

Erste Normalform

Für die erste Normalform werden die Definitionen des vorherigen Unterkapitels nicht benötigt. Die erste Normalform garantiert informell, dass man mit ordentlichen Tabellen arbeitet, also Spalten, die nur einfache Werte der erlaubten Datentypen enthalten.

Projektmitarbeit				
MiNr	Name	AbtNr	Abteilung	Projekte
1	Egon	42	DB	{{(1,Infra),(2,Portal)}}
2	Erna	42	DB	{{(2, Portal, (3, Frame)}}
3	Uwe	43	GUI	{{(1,Infra), (3,Frame)}}

Abb. 4.4: Beispieltabelle nicht in erster Normalform

Probleme beim
Verstoß gegen
erste Normal-
form

Abb. 4.4 zeigt eine Tabelle, die nicht in erster Normalform ist, da es eine Spalte gibt, in der nicht einfache Werte, sondern Listen von Werten eingetragen sind. Solche Listen können mit klassischen Datenbankmanagementsystemen nur schwer bearbeitet werden. Selbst die einzelnen Listeneinträge setzen sich wieder aus zwei Werten zusammen, was zusätzlich schwer zu verarbei-

ten ist. Wegen dieser Probleme werden Tabellen in erster Normalform gefordert.

Definition erste Normalform: Eine Tabelle ist in *erster Normalform*, wenn zu jedem Attribut ein für Spalten zugelassener einfacher Datentyp gehört.

Zur Erinnerung sei erwähnt, dass folgende einfache Datentypen betrachtet werden: Text, Zahl, Datum und Boolean.

Projektmitarbeit

MiNr	Name	AbtNr	Abteilung	ProNr	Projekt
1	Egon	42	DB	1	Infra
1	Egon	42	DB	2	Portal
2	Erna	42	DB	2	Portal
2	Erna	42	DB	3	Frame
3	Uwe	43	GUI	1	Infra
3	Uwe	43	GUI	3	Frame

Abb. 4.5: In erste Normalform transformierte Tabelle

Transformation
in die erste
Normalform

Jede Tabelle kann leicht in eine Tabelle in erster Normalform umgewandelt werden, die den gleichen Informationsgehalt hat. Für jeden Listeneintrag werden die restlichen Informationen der Zeile kopiert und so eine neue Zeile erstellt. Die Zeile mit dem Listeneintrag kann dann gelöscht werden. Spalten, in denen Wertepaare oder noch komplexere Tupel stehen, werden also in Spalten mit einfachen Einträgen aufgeteilt. In Abb. 4.5 ist die Beispieltabelle in die erste Normalform umgeformt worden.

Bestellzettel				
BestellNr		17		
Name		Meier		
ProdNr	PName	Farbe	Anzahl	EPreis
42	Schraube	weiß	30	1,98
		blau	40	
45	Dübel	weiß	30	2,49
		blau	40	

Abb. 4.6: Einfacher, teilweise ausgefüllter Bestellzettel

Umsetzung von Formularen

Das Problem mit der ersten Normalform tritt häufig in der Praxis auf, wenn man *Formulare* elektronisch erfassen möchte. Abb. 4.6 zeigt einen Ausschnitt aus einem Bestellformular.

Bestellung

BestellNr	Name	ProdNr	PName	Farbe	Anzahl	EPreis
17	Meier	42	Schraube	weiß	30	1,98
17	Meier	42	Schraube	blau	40	1,98
17	Meier	45	Dübel	weiß	30	2,49
17	Meier	45	Dübel	blau	40	2,49

Abb. 4.7: In erste Normalform transformiertes Formular

Bei der Umsetzung eines solchen Formulars ist zu beachten, dass alle Informationen in die resultierende Tabelle übernommen werden. Typischerweise werden einige Daten, wie hier der Name, sehr oft kopiert. Die aus dem Formular abgeleitete Tabelle ist in Abb. 4.7 dargestellt.

4.3

Zweite Normalform

Mit der zweiten Normalform wird eine wichtige Problemquelle bei redundanter Datenhaltung in der Tabelle angegangen.

Projektmitarbeit

<u>MiNr</u>	Name	AbtNr	Abteilung	<u>ProNr</u>	Projekt
1	Egon	42	DB	1	Infra
1	Egon	42	DB	2	Portal
2	Erna	42	DB	2	Portal
2	Erna	42	DB	3	Frame
3	Uwe	43	GUI	1	Infra
3	Uwe	43	GUI	3	Frame

Abb. 4.8: Aktuelle Tabelle Projektmitarbeit

In Abb. 4.8 ist die Tabelle Projektmitarbeit dargestellt. Da sie nur einen Schlüsselkandidaten hat, kann dieser einfach eingezeichnet werden. Betrachtet man die Tabelle genauer und geht auf die bekannten funktionalen Abhängigkeiten ein, so erkennt man, dass es Nichtschlüsselattribute gibt, die nur von Teilen des Schlüsselkandidaten abhängen, genauer gilt $\{MiNr\} \rightarrow \{Name\}$ und $\{ProNr\} \rightarrow \{Projekt\}$. Dies bedeutet, dass in der Tabelle Details enthalten sind, die nichts mit dem gesamten Schlüsselkandidaten zu tun haben. Eine solche Tabelle ist nicht in zweiter Normalform.

Definition zweite Normalform: Sei eine Tabelle in erster Normalform. Dann ist diese Tabelle in *zweiter Normalform*, wenn jede nicht leere Teilmenge der Nichtschlüsselattribute von jedem Schlüsselkandidaten voll funktional abhängig ist.

Die Definition kann auch wie folgt gelesen werden: Jedes Nichtschlüsselattribut ist von jedem ganzen Schlüsselkandidaten funktional abhängig.

Prüfung auf zweite Normalform

Zur praktischen Überprüfung, ob eine Tabelle in zweiter Normalform ist, geht man jedes Nichtschlüsselattribut einzeln durch und prüft, ob es wirklich von jedem Schlüsselkandidaten voll funktional abhängig ist.

Im Beispiel der Tabelle Projektmitarbeit gibt es nur den Schlüsselkandidaten {MiNr, ProNr}. Eine schrittweise Überprüfung ergibt hier den Extremfall, dass alle Nichtschlüsselattribute nicht vom Schlüsselkandidaten, sondern nur von einer Teilmenge des Schlüsselkandidaten voll funktional abhängig sind. Es gilt {MiNr} → {Name, AbtNr, Abteilung} und {ProNr} → {Projekt}.

Projektmitarbeit	
MiNr	ProNr
1	1
1	2
2	2
2	3
3	1
3	3

Projekt	
ProNr	Projekt
1	Infra
2	Portal
3	Frame

Mitarbeiter

MiNr	Name	AbtNr	Abteilung
1	Egon	42	DB
2	Erna	42	DB
3	Uwe	43	GUI

Abb. 4.9: In zweite Normalform transformierte Tabellen

Umwandlung in zweite Normalform

Ist eine Tabelle nicht in zweiter Normalform, kann man die Tabelle semantikerhaltend in eine Menge von Tabellen umformen, die die gleichen Aussagen ergeben. Dazu wird für jede Teilmenge eines Schlüsselkandidaten, von dem ein oder mehrere Nicht-

*Verknüpfung
von Tabellen*

schlüsselattribute abhängen, eine neue Tabelle mit der Teilmenge des Schlüsselkandidaten und der abhängigen Nichtschlüsselattribute erstellt.

Das Ergebnis der Transformation der Tabelle Projektmitarbeit ist in Abb. 4.9 dargestellt. Man sieht, dass die Ursprungstabelle Projektmitarbeit reduziert um vier Spalten erhalten bleibt. Weiterhin sind zwei Tabellen ergänzt worden. Durch eine in den folgenden Kapiteln genauer diskutierte Kombination der Tabellen kann man die ursprüngliche Information wieder berechnen. Aus der Tabelle Projektmitarbeit erhält man die Information, dass Egon im Projekt mit der Projektnummer (ProNr) 1 arbeitet. Durch einen Blick auf die Tabelle Projekt kann man dann den Namen des Projekts herausfinden.

Generell erhält man durch die beschriebene Transformation Tabellen, die alle in zweiter Normalform sind. Bei der Bearbeitung mehrerer Tabellen ist es wichtig, dass jede Tabelle einzeln betrachtet wird.

Bei einer Analyse der Definition der zweiten Normalform fällt auf, dass diese nur verletzt werden kann, wenn es einen Schlüsselkandidaten gibt, der mehr als ein Attribut enthält, da sonst kein Unterschied zwischen voller funktionaler und funktionaler Abhängigkeit existiert.

Anmerkung: Jede Tabelle in erster Normalform, die nur einelementige Schlüsselkandidaten hat, ist in zweiter Normalform.

Student				
MatNr	Name	Fachbereich	Leiter	FBNr
42	Udo	Informatik	Schmidt	1
43	Ute	Informatik	Schmidt	2
44	Erwin	BWL	Schulz	1
45	Egon	BWL	Schulz	2
46	Erna	Informatik	Schmidt	3

Abb. 4.10: Tabelle mit zwei Schlüsselkandidaten

In Abb. 4.10 ist die Tabelle Student wiederholt, in der noch eine Spalte Leiter für den Fachbereichsleiter ergänzt wurde. Weiterhin gelten die Überlegungen aus dem vorherigen Unterkapitel, dass die Tabelle die Schlüsselkandidaten {MatNr} und {Fachbereich, FBNr} hat. Ist diese Tabelle in zweiter Normalform? Die Menge

*vereinfachte
Variante der
zweiten Nor-
malform*

*Problem mit der
vereinfachten
zweiten Nor-
malform*

der Nichtschlüsselattribute ist {Name, Leiter}. Durch die Abhängigkeit {Fachbereich} $\rightarrow$ {Leiter} ist die Tabelle nicht in zweiter Normalform. Für die zuletzt genannte funktionale Abhängigkeit muss eine neue Tabelle ergänzt werden.

Das letzte Beispiel ist deshalb interessant, da es in der Literatur eine Variante der Definition der zweiten Normalform gibt, in der nur gefordert wird, dass alle Nichtschlüsselattribute voll vom Primärschlüssel abhängig sein müssen. Dabei umfasst die Menge der Nichtschlüsselattribute die Menge aller Attribute, die nicht im Primärschlüssel vorkommen.

Diese Definition ist in der Praxis leichter zu handhaben, da man nicht über alle Schlüsselkandidaten nachdenken muss und sich auf den markierten Primärschlüssel konzentrieren kann. Da der Primärschlüssel aber willkürlich aus der Menge der Schlüsselkandidaten ausgewählt wird, kann dies zu Problemen führen. Betrachtet man die Tabelle Student und entscheidet sich für den Primärschlüssel {MatNr}, so wäre dann diese Tabelle in der modifizierten zweiten Normalform.

In diesem Buch wird deshalb die formal fundiertere, aber etwas schwerer zu verstehende Standardvariante der zweiten Normalform genutzt.

4.4

Dritte Normalform

Mit der zweiten Normalform kann man nicht alle Redundanzen vermeiden. Einen weiteren wichtigen Schritt zur Vermeidung vieler praxisrelevanter Redundanzen ermöglicht die Nutzung der dritten Normalform.

Mitarbeiter

<u>MiNr</u>	Name	AbtNr	Abteilung
1	Egon	42	DB
2	Erna	42	DB
3	Uwe	43	GUI

Abb. 4.11: Tabelle nicht in dritter Normalform

In Abb. 4.11 ist die im letzten Unterkapitel berechnete Tabelle Mitarbeiter dargestellt, die in zweiter Normalform ist. Man erkennt, dass die Information über die Abteilung, genauer den Abteilungsnamen, redundant z. B. in den ersten beiden Zeilen

steht. Der Grund ist, dass in der Tabelle zwei unabhängige Informationen über Mitarbeiter und Abteilungen in einer Tabelle vermischte wurden. Dies wird in der dritten Normalform nicht erlaubt sein.

Definition dritte Normalform: Eine Tabelle in zweiter Normalform ist in *dritter Normalform*, wenn es keine zwei nicht gleiche und nicht leere Teilmengen A und B der Nichtschlüsselattribute gibt, für die $A \rightarrow B$ gilt.

Vereinfacht bedeutet die Definition, dass es keine funktionalen Abhängigkeiten zwischen Nichtschlüsselattributen geben darf. Alle Nichtschlüsselattribute sind ausschließlich von den Schlüsselkandidaten funktional abhängig.

Im Beispiel der Tabelle Mitarbeiter gilt $\{\text{AbtNr}\} \rightarrow \{\text{Abteilung}\}$, deshalb ist die Tabelle nicht in dritter Normalform.

Mitarbeiter			Abteilung	
<u>MiNr</u>	Name	AbtNr	<u>AbtNr</u>	Abteilung
1	Egon	42	42	DB
2	Erna	42	43	GUI
3	Uwe	43		

Abb. 4.12: In dritte Normalform transformierte Tabellen

Umwandlung in dritte Nor- malform

Analog zur Umwandlung einer Tabelle, die nicht in zweiter Normalform ist, in Tabellen mit gleicher Bedeutung in zweiter Normalform, kann eine Tabelle, die nicht in dritter Normalform ist, in Tabellen in dritter Normalform übersetzt werden. Bei einer vollen funktionalen Abhängigkeit $A \rightarrow B$ zwischen Nichtschlüsselattributen werden die zu B gehörenden Spalten aus der Ursprungstabelle gelöscht und eine neue Tabelle mit den Spalten aus A und B angelegt. Das Ergebnis der Umwandlung der Tabelle Mitarbeiter ist in Abb. 4.12 dargestellt.

Da für einen Verstoß gegen die dritte Normalform mindestens zwei von einander funktional abhängige Nichtschlüsselattribute benötigt werden, gilt Folgendes:

Anmerkung: Wenn eine Tabelle in zweiter Normalform ist und die Menge ihrer Nichtschlüsselattribute höchstens ein Element enthält, ist sie auch in dritter Normalform.

4.5

Normalformen und die Übersetzung von Entity-Relationship-Modellen

*Lesbarkeit und
Tabellenauftei-
lung*

Wenn man die vorgestellten Umwandlungen in die zweite und dritte Normalform betrachtet, fällt auf, dass einzelne Tabellen immer weiter in neue Tabellen aufgeteilt werden. Dies kann als problematisch angesehen werden, da mit steigender Tabellenanzahl die Lesbarkeit des Gesamtsystems aus allen Tabellen merklich sinkt. Auf der anderen Seite kann man aber mit den Überlegungen des folgenden Unterkapitels feststellen, dass es weitere Quellen für Redundanzen geben kann, die zu weiteren Aufteilungen der Tabellen führen. In der Praxis wird deshalb meist die dritte Normalform als Standardform angesehen, die bei der Ableitung der Tabellen erreicht werden soll.

*Einfluss der
Modellierung
auf Normal-
form*

Wenn man die Tabellen aus dem vorherigen Kapitel betrachtet, die bei der Übersetzung der Entity-Relationship-Modelle entstehen, fällt auf, dass diese alle bereits in dritter Normalform sind. Dies ist kein Zufall, da man durch eine geschickte Modellierung verhindern kann, dass überhaupt Tabellen entstehen können, die nicht in dritter Normalform sind. Da man bei der Modellierung aber häufig noch nicht alle Randbedingungen kennt, ist es trotzdem notwendig zu prüfen, ob die Tabellen die ersten drei Normalformen einhalten.

Den Zusammenhang zwischen der Übersetzung von Entity-Relationship-Modellen und dem Erreichen der dritten Normalform kann man auch dadurch verdeutlichen, dass man sich überlegt, wie ein Entity-Relationship-Modell aussehen müsste, um gegen Normalformen zu verstoßen.




Abb. 4.13: Sehr schlecht zu transformierendes ERM

*keine Attribute
mit Wertelisten*

Das Entity-Relationship-Modell aus Abb. 4.13 würde zu einer Tabelle führen, die nicht in zweiter Normalform wäre. Die resultierende Tabelle wurde bereits in Abb. 4.4 dargestellt. Dieses Problem wird dadurch vermieden, dass man sich bei der Modellierung daran hält, dass Attribute nicht für Listen von Werten stehen sollen.




Abb. 4.14: Schlecht zu transformierendes ERM

In Abb. 4.14 ist ein Entity-Relationship-Modell dargestellt, das bei der Übersetzung in die Tabelle aus Abb. 4.8 übersetzt wird und damit zu einer Tabelle führt, die nicht in zweiter Normalform ist.




Abb. 4.15: Gut zu transformierendes Entity-Relationship-Modell

keine wertgleichen Belegungen für mehrere Attribute

Hält man sich an die Regel, dass bei Attributen, die häufig für verschiedene Entitäten die gleichen Werte haben, das Attribut in einen Entitätstypen umgewandelt werden soll, kann man bei der Übersetzung in Tabellen ziemlich sicher sein, dass man Tabellen in zweiter und dritter Normalform erhält. Das „ziemlich“ deutet an, dass es Randbedingungen geben kann, die bei der Modellierung noch nicht bekannt waren bzw. über die noch gar nicht nachgedacht wurde, die doch zu Tabellen nicht in dritter Normalform führen können. In Abb. 4.15 ist ein Entity-Relationship-Modell dargestellt, das bei der Übersetzung zu Tabellen in dritter Normalform führt.

4.6

[*] Boyce-Codd-Normalform

Probleme trotz dritter Normalform

Hat man Tabellen in der dritten Normalform, sind bereits viele Probleme beseitigt. Es gibt aber weiterhin Tabellen, die redundante Informationen enthalten und trotzdem in dritter Normalform sind.

Betreuung			
Schüler	Lehrer	Fach	Note
Erkan	Müller	Deutsch	2
Erkan	Schmidt	Sport	1
Leon	Müller	Deutsch	4
Leon	Meier	Englisch	5
Lisa	Schmidt	Sport	1
Lisa	Mess	Deutsch	1
David	Mess	Deutsch	4

Abb. 4.16: Beispieltabelle Betreuung

In der Tabelle in Abb. 4.16 ist dargestellt, welcher Schüler welchen Lehrer in welchem Fach und welche Note er aktuell hat. Es wird davon ausgegangen, dass die Namen der Schüler und Lehrer eindeutig sind. Statt eindeutiger Namen kann man sich vorstellen, dass die Tabellen Verwaltungszahlen enthalten, z. B. Erkan die Nummer 42 hat.

Weiterhin gibt es folgende Randbedingungen:

1. Jeder Schüler hat pro Fach, in dem er unterrichtet wird, genau einen Lehrer, der ihm die Note gibt.
2. Jeder Lehrer unterrichtet nur ein Fach.

Diese Tabelle soll jetzt genauer analysiert werden. Dazu werden zunächst die vollen funktionalen Abhängigkeiten bestimmt:

aus 1: {Schüler, Fach} → {Lehrer, Note}

aus 2.: {Lehrer} → {Fach}

weiterhin auch {Schüler, Lehrer} → {Note}

Weitere Abhängigkeiten lassen sich aus den angegebenen Abhängigkeiten berechnen.

Es gibt zwei Schlüsselkandidaten, nämlich {Schüler,Fach} und {Schüler,Lehrer}. Damit ist die Menge der Schlüsselattribute {Schüler, Lehrer, Fach} und die Menge der Nichtschlüsselattribute {Note}.

Die Tabelle ist in zweiter Normalform, da das einzige Nichtschlüsselattribut voll funktional abhängig von den beiden Schlüsselkandidaten ist. Man beachte, dass die zweite Normalform durch {Lehrer} → {Fach} nicht verletzt wird, da es sich bei Fach um ein Schlüsselattribut handelt.

*schrittweise
Analyse einer
Tabelle*

Die Tabelle ist in dritter Normalform, da es nur ein Nichtschlüsselattribut gibt. Obwohl alle Normalformen erfüllt sind, hat man das „Gefühl“, dass die Tabelle nicht optimal ist. Dagegen spricht z. B. die Information „Müller unterrichtet Deutsch“, die mehrfach in der Tabelle vorkommt. Um dieses Problem systematisch zu bearbeiten, wurde die Boyce-Codd Normalform entwickelt. Dabei wird die folgende Hilfsdefinition benutzt.

Definition Determinante: Seien A und B zwei nicht leere Attributmengen einer Tabelle. Haben A und B keine Elemente gemeinsam und gilt $A \rightarrow B$, dann heißt A *Determinante* (in der Tabelle).

Definition Boyce-Codd-Normalform: Eine Tabelle in zweiter Normalform ist in *Boyce-Codd Normalform*, wenn jede Determinante der Tabelle einen Schlüsselkandidaten als Teilmenge enthält.

Anschaulich fordert die Definition, dass es nur funktionale Abhängigkeiten zwischen Schlüsselattributen und Nichtschlüsselattributen geben darf. Funktionale Abhängigkeiten innerhalb der Schlüsselmenge und zwischen Mengen von Nichtschlüsselattributen sind verboten.

Boyce-Codd-Normalform garantiert dritte Normalform

Anmerkung: Ist eine Tabelle in Boyce-Codd-Normalform, so ist sie automatisch auch in dritter Normalform. Wäre sie nicht in dritter Normalform, würde es eine funktionale Abhängigkeit $A \rightarrow B$ zwischen zwei unterschiedlichen Mengen von Nichtschlüsselattributen geben. Damit wäre A eine Determinante, die einen Schlüsselkandidaten enthalten muss. Da dies bei einer Menge von Nichtschlüsselattributen nicht der Fall sein kann, muss die Tabelle auch in dritter Normalform sein.

Die Tabelle Betreuung verstößt gegen die Boyce-Codd-Normalform, denn durch $\{\text{Lehrer}\} \rightarrow \{\text{Fach}\}$ wird $\{\text{Lehrer}\}$ zur Determinante, aber die Menge $\{\text{Lehrer}\}$ enthält keinen Schlüsselkandidaten, da $\{\text{Lehrer}\}$ als einzig sinnvolle Teilmenge kein Schlüsselkandidat ist.

Betreuung			Fachgebiet	
Schüler	Lehrer	Note	Lehrer	Fach
Erkan	Müller	2	Müller	Deutsch
Erkan	Schmidt	1	Schmidt	Sport
Leon	Müller	4	Meier	Englisch
Leon	Meier	5	Mess	Deutsch
Lisa	Schmidt	1		
Lisa	Mess	1		
David	Mess	4		

Abb. 4.17: Tabellen in Boyce-Codd-Normalform

*Umformung in
Boyce-Codd-
Normalform*

Analog zu den vorherigen Normalformen wird ein Verstoß gegen die Boyce-Codd-Normalform dazu genutzt, die zum Verstoß beitragenden Attribute aus der Ausgangstabelle zu löschen und die gefundene funktionale Abhängigkeit in einer neuen Tabelle zu notieren. Die neuen Tabellen basieren dabei auf vollen funktionalen Abhängigkeiten. Das Ergebnis der Aufteilung der Tabelle Betreuung ist in Abb. 4.17 dargestellt.

*Zusammen-
hang zur ver-
einfachten
zweiten Nor-
malform*

Am Rande sei vermerkt, dass man durch die vorgestellte alternative Definition der zweiten Normalform, die nur vom Primärschlüssel ausgeht, bei der Wahl des Primärschlüssels {Schüler, Lehrer} für die Ausgangstabelle Betreuung gegen diese zweite Normalform, wegen {Lehrer} → {Fach} verstoßen würde. Es würde sofort eine Aufteilung stattfinden. Würde stattdessen „willkürlich“ {Schüler, Fach} als Primärschlüssel gewählt, wäre die Tabelle auch bei der alternativen Definition in dritter Normalform.

*Gründe für
weitere Normal-
formen*

Neben der Boyce-Codd-Normalform gibt es in der Literatur viele Varianten von Normalformen. Die Ausgangssituation dieser Normalformen ist immer, dass man Tabellen konstruieren kann, die die vorgestellten Normalformen einhalten und für die man trotzdem argumentieren kann, dass die Tabellen nicht optimal sind.

Sprachkenntnisse		
<u>Mitarbeiter</u>	<u>Programmiersprache</u>	<u>Fremdsprache</u>
Heinz	Java	Englisch
Heinz	Java	Spanisch
Heinz	C#	Englisch
Heinz	C#	Spanisch
Erwin	Cobol	Englisch
Erwin	Mumps	Englisch
Erwin	C#	Englisch

Abb. 4.18: Tabelle mit mehrwertigen Abhängigkeiten

Problem trotz
Boyce-Codd-
Normalform

In Abb. 4.18 ist eine Tabelle dargestellt, in der zu Mitarbeitern ihre Programmiersprachen- und Fremdsprachenkenntnisse zusammengefasst sind. Eine genaue Analyse zeigt, dass diese Tabelle genau einen Schlüsselkandidaten hat, der alle drei Attribute enthält. Kennt man nur die Werte zweier Attribute, kann man immer eine Menge von Werten im dritten Attribut zugeordnet bekommen. Aus Heinz und Java kann man z. B. auf Englisch und Spanisch schließen. Die Tabelle erfüllt mit dem einzigen Schlüssel und der leeren Menge an Nichtschlüsselattributen alle vorgestellten Normalformen. Trotzdem „spürt“ man, dass die Tabelle nicht in Ordnung ist, denn es werden Daten doppelt dargestellt, und zwei unabhängige Informationen sind festgehalten.

Programmierenkenntnis		Fremdsprachenkenntnis	
<u>Mitarbeiter</u>	<u>Programmiersprache</u>	<u>Mitarbeiter</u>	<u>Fremdsprache</u>
Heinz	Java	Heinz	Englisch
Heinz	C#	Heinz	Spanisch
Erwin	Cobol	Erwin	Englisch
Erwin	Mumps		
Erwin	C#		

Abb. 4.19: Tabellen in vierter Normalform

mehrwertige
Abhängigkeiten

Interessant ist, dass man aus Heinz und C# auf die gleichen Sprachen, Englisch und Spanisch, schließen kann. Man spricht hierbei von einer *mehrwertigen Abhängigkeit*. Diese Art der Abhängigkeit wird, in der vierten Normalform behandelt. Die resultierenden Tabellen in vierter Normalform sind in Abb. 4.19 dargestellt.

4.7

Fallstudie

Es werden jetzt die aus dem Entity-Relationship-Modell aus Abb. 2.31 abgeleiteten Tabellen genauer untersucht. Weiterhin wird ein Primärschlüssel aus den Schlüsselkandidaten gewählt. Der Primärschlüssel ist unterstrichen.

Projekt

<u>ProNr</u>	Name
--------------	------

Die Tabelle Projekt hat den einzigen Schlüsselkandidaten {ProNr}, da sich Projektnamen beim Kunden wiederholen können. Die Tabelle ist in dritter Normalform.

Risikogruppe

<u>RGNr</u>	Gruppe
-------------	--------

Die Tabelle Risikogruppe hat zwei Schlüsselkandidaten, {RGNr} und {Gruppe}, da vereinbart ist, dass die Gruppennamen eindeutig sind. Die Spalte RGNr wurde eingeführt, damit der Gruppentext nicht immer abgetippt werden muss und da dieser Text eventuell später noch verändert wird. Die Tabelle ist in dritter Normalform.

Risiko

<u>RNr</u>	Projekt	Text	Gruppe	Auswirkung	Wkeit	Pruefdatum
------------	---------	------	--------	------------	-------	------------

Die Tabelle Risiko hat folgende Schlüsselkandidaten: {RNr} und {Projekt, Text}. Es wird davon ausgegangen, dass die Texte pro Projekt eindeutig sind. Ein Verstoß gegen die zweite Normalform würde vorliegen, wenn {Text} → {Gruppe} gelten würde, man also aus der Risikobeschreibung eindeutig auf die Gruppe schließen könnte. Da die Gruppenzuordnung beim ersten Einsatz der Datenbank den Projektleitern, die die Datenbank nutzen, freigestellt ist, gilt diese funktionale Abhängigkeit aber nicht. Für eine langfristige Nutzung der Datenbank kann darüber nachgedacht werden, diese Tabelle aufzuteilen, um später nicht gegen die zweite Normalform zu verstoßen. Die Tabelle ist in dritter Normalform.

Maßnahme

<u>MNr</u>	Titel	Verantwortlich
------------	-------	----------------

Die Tabelle Maßnahme hat nur den Schlüsselkandidaten {MNr} und ist in dritter Normalform.

Zuordnung

Risiko	Maßnahme	Pruefdatum	Status
--------	----------	------------	--------

Die Tabelle Zuordnung hat nur den Schlüsselkandidaten {Risiko, Maßnahme} und ist in dritter Normalform.

Für die Tabellen gilt weiterhin, dass sie in Boyce-Codd-Normalform sind.

4.8

Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu bearbeiten.

1. Beschreiben Sie anschaulich, warum man sich mit dem Thema Normalisierung beschäftigt.
2. Nennen Sie typische Probleme, die bei Tabellen auftreten können, wenn sie nicht in zweiter oder dritter Normalform sind.
3. Erklären Sie die Begriffe „funktionale Abhängigkeit“ und „volle funktionale Abhängigkeit“.
4. Welche Aussagen über funktionale Abhängigkeiten kann man Tabellen generell ansehen, welche nicht?
5. Welche Möglichkeiten hat man, aus gegebenen funktionalen Abhängigkeiten weitere funktionale Abhängigkeiten zu berechnen?
6. Erklären Sie die Begriffe Schlüssel und Schlüsselkandidat.
7. Gibt es Attribute, die gleichzeitig zu den Schlüsselattributen und den Nichtschlüsselattributen gehören können?
8. Welchen Zusammenhang gibt es zwischen den Begriffen „Schlüssel“ und „Primärschlüssel“?
9. Wie ist die erste Normalform definiert?
10. Wie formt man eine Tabelle, die nicht in erster Normalform ist, in eine Tabelle in erster Normalform um?
11. Wie ist die zweite Normalform definiert?
12. Was versteht man unter einer Aufteilung einer Tabelle in mehrere Tabellen, die den gleichen Informationsgehalt haben?

13. Wie formt man eine Tabelle, die nicht in zweiter Normalform ist, in Tabellen in zweiter Normalform um?
14. Wie ist die dritte Normalform definiert?
15. Wie formt man eine Tabelle, die nicht in dritter Normalform ist, in Tabellen in dritter Normalform um?
16. Wann ist es sehr wahrscheinlich, dass man bei der Umwandlung eines Entity-Relationship-Modells sofort zu Tabellen in dritter Normalform kommt?
17. Geben Sie ein Beispiel für eine Tabelle in dritter Normalform an, bei der es trotzdem sinnvoll wäre, diese aufzuteilen. Wie würde die Aufteilung aussehen?
18. [*] Wie ist die Boyce-Codd-Normalform definiert?
19. [*] Wie formt man eine Tabelle, die nicht in Boyce-Codd-Normalform ist, in Tabellen in Boyce-Codd-Normalform um?

Übungsaufgaben

1. In einigen Supermärkten kann man häufiger Ansagen der Form: „Die 46 bitte die 23.“ hören. Erklären Sie aus Sicht eines Datenbank-Experten, was wohl hinter dieser Ansage steckt.
2. Warum ist der Satz „Ein Schlüsselkandidat ist der Schlüssel mit den wenigsten Elementen.“ falsch?
3. Wie viele Schlüssel und wie viele Schlüsselkandidaten kann eine Tabelle mit drei Attributen maximal haben?
4. [*] In diesem Kapitel wurde gezeigt, dass sich die Rechenregeln für die funktionale Abhängigkeit nicht direkt auf die volle funktionale Abhängigkeit übertragen lassen. Nennen Sie drei Rechenregeln, die für die volle funktionale Abhängigkeit gelten. Hinweis: Schauen Sie sich die existierenden Regeln an. Teilweise kann man sie übertragen, wenn man die Vorbedingungen genauer fasst.

Beachten Sie bei den folgenden Aufgaben, dass genau das beschriebene Verfahren verwendet werden soll.

5. In einer Firma wird folgende Tabelle „Aufgabenliste“ zur Verwaltung von Aufträgen genutzt:

AuftragsNr	Eingangsdatum	ProduktNr	ProduktName	Preis	Lieferant
1	11.02.2003	10	Reis	0.51	Meier
1	11.02.2003	12	Mais	0.53	Müller
2	11.02.2003	10	Reis	0.51	Meier
2	11.02.2003	11	Hirse	0.51	Schmidt

Dabei gelten folgende funktionale Abhängigkeiten:

- (1) {AuftragsNr} -> {Eingangsdatum}
- (2) {ProduktNr} -> {ProduktName, Preis, Lieferant}
- (3) {Produktname} -> {Preis, Lieferant}

Weitere funktionale Abhängigkeiten lassen sich aus den angegebenen Abhängigkeiten berechnen, weiterhin können die Mengen auf den linken Seiten nicht verkleinert werden.

- a) Geben Sie die möglichen Schlüsselkandidaten für die Tabelle an.
 - b) Formen Sie die Tabelle in Tabellen in zweiter Normalform und dann in dritter Normalform um, die die gleiche Aussagekraft haben.
 - c) Was würde sich bei Ihren Tabellen ändern, wenn es mehrere Lieferanten für ein Produkt geben würde, also (3) durch {Produktname, Lieferant} -> {Preis} ersetzt würde?
6. Nehmen Sie an, dass zur Verwaltung von Studierenden folgende Tabelle genutzt wird, dabei arbeitet jeder Student parallel in genau einer Firma und hat dort einen betrieblichen Betreuer:

MatNr	Name	TelefonNr	Studium	Firma	Betreuer	Fach	Note

Dabei gelten folgende funktionale Abhängigkeiten (weitere Abhängigkeiten lassen sich aus diesen berechnen)

- I. {MatNr} -> {Name, TelefonNr, Studium, Firma, Betreuer}
 - II. {TelefonNr} -> {MatrNr}
 - III. {MatNr, Fach} -> {Note}
 - IV. {TelefonNr, Fach} -> {Note}
 - V. {Firma} -> {Betreuer}
- a) Begründen Sie formal, warum {TelefonNr} -> {Firma} gilt.
 - b) Nennen Sie alle Schlüsselkandidaten.

- c) Bringen Sie die Tabelle mit dem Standardverfahren in die zweite Normalform.
- d) Bringen Sie die Tabellen aus c) mit dem Standardverfahren in die dritte Normalform.
7. Gegeben sei der folgende Ausschnitt aus einer Projektverwaltungstabelle:

PNr	TelNr	Projekt	PBudget	Rolle	VAbt
1	13	EAI	42	Entwickler	EBUIS
1	13	EAI	42	Entwickler	INFRA
1	13	ODB	15	Spezifizierer	INFRA
1	13	ODB	15	Spezifizierer	SERVICE
2	14	EAI	42	Spezifizierer	EBUIS
2	14	EAI	42	Spezifizierer	INFRA
2	14	WEB	15	Designer	INFRA

Für diese Tabelle gelten folgende Regeln:

- D) Jeder Mitarbeiter wird eindeutig durch seine Personalnummer (PNr) identifiziert.
 - II) Jeder Mitarbeiter hat genau eine Telefonnummer (TelNr), jede Telefonnummer ist genau einem Mitarbeiter zugeordnet.
 - III) Jeder Mitarbeiter kann an mehreren Projekten (Projekt) mitarbeiten, in jedem Projekt können mehrere (und muss mindestens ein Mitarbeiter) mitarbeiten.
 - IV) Der Projektname (Projekt) ist innerhalb der betrachteten Firma eindeutig, d. h. es gibt keine zwei Projekte mit gleichem Namen.
 - V) Jedem Projekt ist ein Projektbudget (PBudget) zugeordnet.
 - VI) Jeder Mitarbeiter kann in verschiedenen Projekten verschiedene Rollen annehmen, hat aber pro Projekt dann nur eine Rolle.
 - VII) Für jedes Projekt gibt es mindestens eine, eventuell auch mehrere verantwortliche Abteilungen (VAbt).
- a) Geben Sie vier volle funktionale Abhängigkeiten an, wobei keine aus den anderen Dreien berechnet werden kann.
- b) Warum gilt nicht {Projekt, VAbt} -> {Rolle}?
- c) Geben Sie sämtliche Schlüsselkandidaten an.
- d) Ist die Tabelle in zweiter Normalform? Wenn nicht, transformieren Sie die Tabelle in Tabellen in zweiter Normalform.

- e) Sind ihre Tabellen aus d) in dritter Normalform? Wenn nicht, transformieren Sie die Tabellen in Tabellen in dritter Normalform.
 - f) [*] Sind ihre Tabellen aus e) in Boyce-Codd-Normalform? Wenn nicht, transformieren Sie die Tabellen in Tabellen in Boyce-Codd-Normalform.
8. [*] Folgende Tabelle wird zur Verwaltung von Projekten genutzt.

ProNr	MiNr	TelNr	Arbeit
42	20	4711	50

Sie enthält die Projektnummer (ProNr), die Mitarbeiternummer (MiNr), die Telefonnummer des Mitarbeiters (TelNr) und den prozentualen Anteil der Arbeitszeit (Arbeit) des Mitarbeiters, die er für das Projekt aufbringt.

Generell gilt, dass jeder Mitarbeiter in mehreren Projekten arbeiten kann und in Projekten mehrere Mitarbeiter arbeiten können. Bringen Sie die Tabelle für jede Teilaufgabe schrittweise in Boyce-Codd-Normalform, beachten Sie dabei jeweils folgende weitere Randbedingungen.

- a) Jeder Mitarbeiter hat genau eine Telefonnummer, jede Nummer gehört zu genau einem Mitarbeiter.
- b) Jeder Mitarbeiter hat genau eine Telefonnummer, eine Nummer kann zu mehreren Mitarbeitern gehören.
- c) Jeder Mitarbeiter kann mehrere Telefone haben, dabei hat er in jedem Projekt, in dem er mitarbeitet, genau eine Nummer, jedes Telefon gehört zu genau einem Mitarbeiter.
- d) Jeder Mitarbeiter kann mehrere Telefone haben, dabei hat er in jedem Projekt, in dem er mitarbeitet, genau eine Nummer, jedes Telefon kann zu mehreren Mitarbeitern gehören.
- e) Jedes Projekt hat genau ein Telefon, das ausschließlich von den Mitarbeitern des Projekts genutzt wird.

*Formalisierung
der Verknüpfung
von Tabellen*

In diesem Kapitel wird Ihnen gezeigt, dass die Bearbeitung von Tabellen auf einem mathematischen Fundament aufbaut. Diese Formalisierung ermöglicht es, exakte Aussagen über Datenbanken und ihre Bearbeitung zu formulieren.

Bisher wurden Tabellen definiert und es wurde informell beschrieben, wie man Informationen aus einzelnen Tabellen verknüpfen kann. Diese Form der Verknüpfung wird in diesem Kapitel mit einem mathematischen Ansatz genauer beschrieben. Besondere mathematische Fähigkeiten oder spezielle Kenntnisse werden nicht benötigt. Eventuell könnte das Kapitel ausgelassen werden, da vergleichbare Erkenntnisse auch aus den folgenden Kapiteln auf einem anderen Weg gewonnen werden können.

Trotzdem bleibt das Kapitel auch für Leser ohne große Informatikkenntnisse nützlich, da man in diesem Kapitel den Ansatz zur Nutzung relationaler Datenbanken wahrscheinlich leichter versteht, als wenn man sich direkt mit SQL beschäftigen muss. Das wurde durch Erfahrungen in der Lehre mehrfach bestätigt.

Sinn von Formalisierungen

Dieses Kapitel zeigt eine formale Grundlage der Datenbanktheorie. Durch solche Theorien wird es möglich, exakte und nachweisbare Aussagen über Datenbanken zu formulieren. Im akademischen Umfeld werden praktische Beispiele zur Illustration genutzt, die Forschung findet auf Basis mathematisch fundierter Grundlagen statt.

Anfragen stellen

Im folgenden Unterkapitel werden grundlegende Operatoren beschrieben, die zur Bearbeitung von Relationen bzw. Tabellen, genauer zur Berechnung neuer Relationen aus gegebenen Relationen, genutzt werden. Weiterhin werden komplexere Verknüpfungsmöglichkeiten eingeführt. Insgesamt wird man so in die Lage versetzt, Anfragen an die gegebenen Relationen zu formulieren, mit denen man durch die Verknüpfung der Informationen weitere Kenntnisse gewinnen kann. Angemerkt sei, dass in der deutschen Literatur statt Anfrage auch häufiger der Begriff „Abfrage“ auftritt.

In diesem Kapitel wird der Begriff Relation und nicht wie sonst in diesem Buch Tabelle genutzt, um den mathematischen Hintergrund zu betonen.

5.1

Elementare Operatoren auf Relationen

Relation

Eine Relation R bzw. Tabelle ist nach der Tabellendefinition aus dem Unterkapitel „3.1 Einführung des Tabellenbegriffs“ eine Teilmenge des Kreuzproduktes $Att_1 \times \dots \times Att_n$. Dies wird $R \subseteq Att_1 \times \dots \times Att_n$ geschrieben. Jedes Attribut Att_i hat dabei einen zugeordneten Datentyp, die Attribute haben unterschiedliche Namen. Für elementare Verknüpfungen muss man definieren, wann zwei Relationen gleichartig aufgebaut sind.

Definition Vereinigungsverträglichkeit: Zwei Relationen $R \subseteq Att_1 \times \dots \times Att_n$ und $S \subseteq Btt_1 \times \dots \times Btt_n$ heißen *vereinigungsverträglich*, wenn für jedes i die Attribute Att_i und Btt_i den gleichen Datentypen bzw. einen gemeinsamen *Obertypen* haben. Als Obertypen kommen alle für Tabellen erlaubten Datentypen in Frage.

Obertyp

Der Teil der Definition mit den Obertypen bezieht sich darauf, dass ein Attribut z. B. als Datentyp alle Zahlen größer 100 und ein anderes Attribut als Datentyp alle Zahlen kleiner 1000 hat. Diese Detailinformation stört die Vereinigungsverträglichkeit nicht, da man Zahl als Obertypen wählen kann.

Als erste Operatoren auf Relationen werden klassische Mengenoperatoren vorgestellt.

Definition Mengenoperatoren für Relationen: Seien R und S vereinigungsverträgliche Relationen, dann kann man wie folgt neue Relationen berechnen:

Schnittmenge: $R \cap S = \{ r \mid r \in R \text{ und } r \in S \}$

Vereinigung: $R \cup S = \{ r \mid r \in R \text{ oder } r \in S \}$

Differenz: $R - S = \{ r \mid r \in R \text{ und nicht } r \in S \}$

Dabei steht $r \in R$ für ein Tupel aus der Relation R , anschaulich für eine Zeile aus R . Für Anfragen an Datenbanken haben die Operatoren folgende anschauliche Bedeutung:

Schnittmenge: Es wird nach Einträgen gesucht, die in beiden Relationen vorkommen.

Vereinigung: Es sollen alle Einträge der Relationen zusammen betrachtet werden.

Differenz: Es wird nach Einträgen gesucht, die nur in der ersten, aber nicht in der zweiten Relation vorkommen.

VK			VK2		
Verkäufer	Produkt	Käufer	Verkäufer	Produkt	Käufer
Meier	Hose	Schmidt	Müller	Hemd	Schmidt
Müller	Rock	Schmidt	Müller	Rock	Schmidt
Meier	Hose	Schulz	Meier	Rock	Schulz

$VK \cup VK2$			$VK \cap VK2$		
Verkäufer	Produkt	Käufer	Verkäufer	Produkt	Käufer
Meier	Hose	Schmidt	Müller	Rock	Schmidt
Müller	Rock	Schmidt			
Meier	Hose	Schulz			
Müller	Hemd	Schmidt			
Meier	Rock	Schulz			

$VK - VK2$					
Verkäufer	Produkt	Käufer	Verkäufer	Produkt	Käufer
Meier	Hose	Schmidt			
Meier	Hose	Schulz			

Abb. 5.1: Beispiele für Mengenoperatoren

In Abb. 5.1 sind einfache Beispiele für diese Operatoren aufgeführt, die einzelnen Tabellen sollen für einfache Verkäufe stehen. Zu beachten ist, dass es sich bei Relationen um Mengen handelt, d. h. es kommt keine Zeile doppelt vor.

Mit dem folgenden Operator ist es möglich, aus den verschiedenen Attributen diejenigen Attribute auszuwählen, die einen für eine Aufgabenstellung interessieren.

Definition Projektion: Sei $R \subseteq \text{Att}_1 \times \dots \times \text{Att}_n$ eine Relation und $\text{Btt}_1, \dots, \text{Btt}_j$ unterschiedliche Attribute aus $\{\text{Att}_1, \dots, \text{Att}_n\}$. Dann ist die *Projektion* von R auf $\text{Btt}_1, \dots, \text{Btt}_j$ geschrieben $\text{Proj}(R, [\text{Btt}_1, \dots, \text{Btt}_j])$, die Relation, die man erhält, wenn man alle Spalten aus R löscht, die nicht in $\text{Btt}_1, \dots, \text{Btt}_j$ vorkommen. Durch die Reihenfolge der $\text{Btt}_1, \dots, \text{Btt}_j$ wird die Reihenfolge der Attribute in der Ergebnisrelation vorgegeben.

Der Projektionsoperator ist alleine nicht besonders interessant, er wird im Zusammenhang mit Verknüpfungen wichtig, wenn die Ergebnisspalten ausgewählt werden. Beispiele für die Nutzung des Projektionsoperators sind in Abb. 5.2 dargestellt.

VK			Proj(VK,[Käufer,Produkt])	
Verkäufer	Produkt	Käufer	Käufer	Produkt
Meier	Hose	Schmidt	Schmidt	Hose
Müller	Rock	Schmidt	Schmidt	Rock
Meier	Hose	Schulz	Schulz	Hose
Proj(VK,[Verkäufer])			Proj(VK $\cap$ VK2, [Produkt])	
Verkäufer			Produkt	
Meier			Rock	
Müller				

Abb. 5.2: Beispiele für Projektionen

*Operatoren be-
rechnen aus
Relationen
neue Relatio-
nen*

Generell ist es wichtig, dass die Ergebnisse der Operatoren wieder neue Relationen sind. Auf diese Relationen können dann weitere Operatoren angewandt werden. Dies wird in Abb. 5.2 mit $\text{Proj}(\text{VK} \cap \text{VK2}, [\text{Produkt}])$ deutlich. Hinter dieser Berechnung steckt die Anfrage nach den Namen aller Produkte, die in den Tabellen VK und VK2 aus der vorherigen Abbildung gemeinsam vorkommen.

Der folgende Operator dient zur Umbenennung von Relationen. Er wird später bei größeren Anfragen benötigt.

Definition Umbenennung: Sei R eine Relation, dann bezeichnet $\text{Ren}(R,T)$ eine Relation mit gleichem Inhalt wie R, die T genannt wird. Ren steht dabei für „rename“.

Durch die Mengenoperatoren und die Projektion konnten bereits einfache Anfragen formuliert werden. Für komplexere Anfragen wird ein Auswahloperator benötigt, der aus einer gegebenen Relation die Tupel, also Zeilen, berechnet, die für das Ergebnis relevant sind.

Definition Auswahl: Sei R eine Relation, dann bezeichnet $\text{Sel}(R,\text{Bed})$ eine Relation, die alle Zeilen aus R beinhaltet, die die Bedingung Bed erfüllen. Sel steht für „select“.

*Aufbau von
Bedingungen*

Bedingungen können dabei wie folgt für eine Relation R aufgebaut sein, Att_i und Att_j seien Attribute von R:

- $\text{Att}_i <\text{op}> <\text{Konstante}>$, dabei kann $<\text{op}>$ für folgende Vergleichsoperatoren stehen: =, <, >, <=, >, >=, es wird „<>“ für ungleich verwendet, $<\text{Konstante}>$ muss ein Wert des zum Attribut gehörenden Datentyps sein.
- $\text{Att}_i <\text{op}> \text{Att}_j$, Vergleich der Belegungen der Attribute, die einen gemeinsamen Obertypen haben müssen.

Seien Bed_1 und Bed_2 zwei Bedingungen, dann sind auch folgendes Bedingungen:

$\text{Bed}_1 \text{ AND } \text{Bed}_2$, beide Bedingungen sollen erfüllt sein;

$\text{Bed}_1 \text{ OR } \text{Bed}_2$, mindestens eine der Bedingungen soll erfüllt sein;

$\text{NOT } \text{Bed}_1$, die Bedingung soll nicht erfüllt sein;

(Bed_i) , Bedingungen in Klammern werden zuerst ausgewertet.

Auf eine genaue Einführung in die hinter den Formeln stehende Aussagenlogik [Sch04] wird verzichtet, einige Details aus Datenbanksicht werden im Unterkapitel „6.4 NULL-Werte und dreiwertige Logik“ beschrieben.

*Berechnung des
Auswablergebnisses*

Grundsätzlich wird bei der Berechnung jede Zeile der Relation betrachtet und geprüft, ob sie die Bedingung erfüllt. Ist das der Fall, wird die Zeile in das Ergebnis übernommen. Die Anfrage, nach allen Verkäufen, die Meier gemacht hat, lautet:

$\text{Sel}(\text{VK}, \text{VK.Verkäufer} = \text{'Meier'})$

Das Ergebnis ist

Verkäufer	Produkt	Käufer
Meier	Hose	Schmidt
Meier	Hose	Schulz

Um ein Attribut möglichst präzise zu benennen, wird der Name der Tabelle, gefolgt von einem Punkt, vor das Attribut geschrieben. Texte stehen zur Verdeutlichung, dass es sich um Texte handelt, in einfachen Hochkommata.

Ist man nur an den Käufern interessiert, die bei Meier gekauft haben, kann man die resultierende Relation in einer Projektion nutzen.

*Verknüpfung
von Operatoren*

$\text{Proj}(\text{Sel}(\text{VK}, \text{VK.Verkäufer} = \text{'Meier'}), [\text{Käufer}])$

Das Ergebnis ist

Käufer
Schmidt
Schulz

*Aufbau einfacher
Anfragen*

Diese Anfrage gibt einen wichtigen Aufschluss über den Aufbau von Anfragen. Typischerweise werden zunächst mit einer Auswahl alle Zeilen berechnet, die für das Ergebnis interessant sind, und dann die Details für das Ergebnis heraus projiziert.

Um den Umbenennungsoperator einmal vorzustellen, hätte die Anfrage auch wie folgt mit gleichem Ergebnis lauten können:

$\text{Proj}(\text{Sel}(\text{Ren}(\text{VK}, \text{Verkauf}), \text{Verkauf.Verkäufer} = \text{'Meier'}), [\text{Käufer}])$

Die Anfrage nach allen Verkäufen, die Meier gemacht hat und die nicht den Kunden Schulz betreffen, lautet wie folgt:

$\text{Sel}(\text{VK}, \text{VK.Verkäufer} = \text{'Meier'} \text{ AND } \text{VK.Käufer} \neq \text{'Schulz'})$

Das Ergebnis ist

Verkäufer	Produkt	Käufer
Meier	Hose	Schmidt

5.2

Ein Verknüpfungsoperator für Relationen

Mit den bisher vorgestellten Operatoren kann man einzelne Relationen sehr detailliert bearbeiten. Bis jetzt können aber nur verschiedene Relationen verknüpft werden, die vereinigungsverträglich sind. Die Verknüpfungsmöglichkeit soll jetzt auf verschiedene Tabellen erweitert werden, dabei ist das bei der Einführung von Tabellen im Unterkapitel 3.1 vorgestellte Kreuzprodukt sehr hilfreich. Zunächst wird als Hilfsdefinition die Verknüpfung zweier Zeilen definiert.

Definition Verknüpfung von Tupeln: Seien R und S Relationen mit $r = (r_1, \dots, r_n) \in R$ und $s = (s_1, \dots, s_m) \in S$. Dann ist die Verknüpfung oder *Konkatenation* von r mit s , geschrieben $r \circ s$, definiert als $(r_1, \dots, r_n, s_1, \dots, s_m)$.

Anschaulich werden die beiden Zeilen einfach hintereinander geschrieben.

Definition Kreuzprodukt: Seien R und S Relationen, dann ist das *Kreuzprodukt* von R und S , geschrieben $R \times S$, definiert durch: $R \times S = \{ r \circ s \mid r \in R \text{ und } s \in S \}$

Anschaulich wird jede Zeile der einen Relation mit jeder Zeile der anderen Relation verknüpft.

Für Mathematikinteressierte sei darauf hingewiesen, dass das Kreuzprodukt in der Mathematik etwas anders definiert ist. Das Ergebnis sind immer Paare (r, s) , genauer $((r_1, \dots, r_n), (s_1, \dots, s_m))$, mit $r \in R$ und $s \in S$.

VK			PL		
Verkäufer	Produkt	Käufer	Produkt	Preis	Klasse
Meier	Hose	Schmidt	Hose	100	B
Müller	Rock	Schmidt	Rock	200	A
Meier	Hose	Schulz			

VK × PL					
Verkäufer	Produkt	Käufer	Produkt	Preis	Klasse
Meier	Hose	Schmidt	Hose	100	B
Meier	Hose	Schmidt	Rock	200	A
Müller	Rock	Schmidt	Hose	100	B
Müller	Rock	Schmidt	Rock	200	A
Meier	Hose	Schulz	Hose	100	B
Meier	Hose	Schulz	Rock	200	A

Abb. 5.3: Berechnetes Kreuzprodukt

In Abb. 5.3 ist das Ergebnis der Berechnung eines Kreuzprodukts dargestellt. Dabei soll PL für eine Produktliste stehen.

Bei einer Analyse des Ergebnisses fällt auf, dass die resultierende Relation anschaulich unsinnige Zeilen enthält. Dies wird z. B. daran deutlich, dass sich die Zeilen einmal auf ein Produkt Hose in der zweiten Spalte und ein Produkt Rock in der vierten Spalte beziehen. Will man nur „sinnvolle“ Zeilen sehen, so kann der Auswahloperator angewandt werden, dabei wird in der Bedingung die Verknüpfung zwischen den Tabellen beschrieben. Die Anfrage

Sel(VK×PL, VK.Produkt=PL.Produkt)

liefert:

Verkäufer	Produkt	Käufer	Produkt	Preis	Klasse
Meier	Hose	Schmidt	Hose	100	B
Müller	Rock	Schmidt	Rock	200	A
Meier	Hose	Schulz	Hose	100	B

Wie bereits im vorherigen Unterkapitel beschrieben, kann dann eine Projektion genutzt werden, um die interessierenden Informationen heraus zu filtern. Ist man an den Preisen aller Produkte interessiert, die Schmidt gekauft hat, kann man dies mit folgender Anfrage erfragen:

unsinnige Zeilen im Kreuzprodukt

Proj (Sel(VK×PL, VK.Produkt=PL.Produkt
AND VK.Käufer='Schmidt'), [Preis])

Das Ergebnis ist:

Preis
100
200

*Umformungen
in der Relatio-
nenalgebra*

Um eine Einsatzmöglichkeit der Relationenalgebra aufzuzeigen, kann man sich überlegen, dass man nicht zuerst das Kreuzprodukt berechnet, sondern sich zuerst in VK auf den Käufer Schmidt konzentriert und dann die Verknüpfung mit PL durchführt. Die Anfrage lautet dann:

Proj (Sel(Ren(Sel(VK, VK.Käufer='Schmidt'), TMP)×PL,
TMP.Produkt=PL.Produkt) , [Preis])

Die Umbenennung wird genutzt, um dem Zwischenergebnis einen Namen zu geben. Diese Anfrage liefert das gleiche Ergebnis wie vorher, man kann aber untersuchen, welcher Weg einfacher zu berechnen ist. In der Praxis nutzen eingesetzte Datenbankmanagementsysteme Erkenntnisse aus der Relationenalgebra, um Anfragen so umzuformen, dass sie möglichst schnell berechnet werden können.

*Vorgehen bei
der Erstellung
von Anfragen*

Aus dem einfachen Beispiel kann man die typische Vorgehensweise bei der Formulierung einer Anfrage ableiten:

1. Bestimme alle Relationen, die für die Berechnung wichtig sind.
2. Berechne das Kreuzprodukt dieser Relationen, formuliere die Verknüpfung der Relationen in einer Auswahl.
3. Ergänze noch, wenn nötig, die Auswahl um spezielle Randbedingungen.
4. Projiziere aus dem berechneten Ergebnis den Anteil heraus, der zur Beantwortung der Anfrage benötigt wird.

Insgesamt schafft die Relationenalgebra die Möglichkeit, den Begriff der Anfrage zu konkretisieren. Weiterhin kann die mathematische Fundierung der Relationenalgebra genutzt werden, um Zusammenhänge zwischen verschiedenen Anfragen formal zu untersuchen.

5.3 Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu beantworten.

1. Welche Eigenschaft haben alle vorgestellten Operatoren gemeinsam?
2. Welche Grundvoraussetzung muss zur Nutzung von Mengenoperatoren erfüllt sein? Wie sind diese Operatoren definiert?
3. Beschreiben Sie anschaulich den Projektionsoperator.
4. Beschreiben Sie anschaulich den Auswahloperator.
5. Wie ist das Kreuzprodukt definiert?
6. Nennen Sie Gründe, warum man sich mit der Relationenalgebra beschäftigen sollte.
7. Beschreiben Sie die typische Vorgehensweise bei der Erstellung von Anfragen in der Relationenalgebra.

Übungsaufgaben

1. Wie viele Elemente kann die Vereinigung zweier vereinigungsverträglicher Relationen haben, wenn beide Relationen jeweils vier Elemente beinhalten?
2. Gegeben seien folgende Relationen

Projekt	
ProNr	Name
1	Schachtel
2	Behang

Aufgabe		
AufNr	Arbeit	ProNr
1	knicken	1
2	kleben	1
3	knicken	2
4	färben	2

Maschine		
Mname	Dauer	AufNr
M1	2	1
M2	3	1
M1	3	2
M3	2	3
M1	1	4
M4	3	4

Formulieren Sie folgende Anfragen in der Relationenalgebra:

- a) Geben Sie die Namen aller möglichen Arbeiten an.
- b) Geben Sie zu jedem Projektnamen die zugehörigen Arbeiten an. Das Ergebnis ist eine Relation mit den Attributen „Name“ und „Arbeit“.

- c) Welche Maschinen werden zum Knicken genutzt?
- d) Geben Sie zu jedem Projektnamen die Maschinen aus, die genutzt werden.
- e) Geben Sie alle Projekte (deren Namen) aus, bei denen geknickt und gefärbt wird.

6

Formalisierung von Tabellen in SQL

Constraints zur Qualitätsverbesserung

Nachdem in den vorangegangenen Kapiteln theoretische Grundlagen gelegt wurden, wird Ihnen in diesem Kapitel gezeigt, wie man mit Hilfe von SQL Tabellen in Datenbanken definieren kann, so dass eine Bearbeitung mit der Datenbank-Software möglich wird.

Wichtig ist bei der Definition von Tabellen, dass nicht nur die Struktur der Tabellen in die Datenbank übertragen wird, sondern spezielle Randbedingungen, so genannte *Constraints*, für die Tabellen definiert werden können. Mit diesen Constraints können Primär- und Fremdschlüsseleigenschaften sowie weitere Randbedingungen definiert werden, deren Einhaltung bei jeder Änderung der Tabelle vom Datenbank-Managementsystem überprüft werden. Constraints sind damit eine wertvolle Möglichkeit dafür zu sorgen, dass die eingetragenen Daten gewisse Qualitätskriterien erfüllen. Neben der reinen Definition von Tabellen wird auch vorgestellt, wie man Daten in die Tabellen einträgt, diese Daten ändert und löscht sowie nachträglich Tabellen verändern kann.

SQL als Definitionssprache

Die verschiedenen Teilstücke, die zu einer vollständigen Tabellendefinition beitragen, werden in den folgenden Unterkapiteln schrittweise erklärt. Dabei wird die standardisierte Sprache SQL eingesetzt. SQL ist ein wichtiger Standard, wobei man trotz der Standardisierung für das individuell eingesetzte Datenbank-Managementsystem überprüfen muss, ob alle vorgestellten Befehle genau in der vom Standard geforderten Form unterstützt werden.

Entwicklung von SQL

SQL wurde als Standard schrittweise entwickelt. Neben der eigentlichen Sprachentwicklung, die bereits nach der Erfindung von relationalen Datenbanken in den 1970ern anging, sind 1989, 1992, 1999 und 2003 als Meilensteine zu nennen, in denen der SQL-Standard definiert und weiter entwickelt wurde. Man kann SQL in drei Sprachanteile aufteilen, die in diesem und den folgenden Kapiteln betrachtet werden:

- Definitionssprache: SQL zur Definition von Tabellen

- Bearbeitungssprache: Anfragen formulieren, Tabelleninhalte ändern
- Steuerungssprache: Eigenschaften der Datenbank definieren, wie Rechte der Nutzer festlegen und den parallelen Zugriff koordinieren

SQL wird weiterentwickelt

Neben den rein relationalen Datenbanken, die Schwerpunkte der Versionen von 1989 und 1992 waren, wurden immer mehr Ergänzungen definiert, die über den relationalen Anteil hinausgehen und die Arbeit mit einer Datenbank auf SQL-Basis wesentlich vereinfachen. Der gesamte Standard umfasst mittlerweile mehr als 3000 Seiten und wurde deshalb in einen Kernbereich und in die erweiterte Funktionalität aufgeteilt. Dieses Buch bezieht sich in den folgenden Unterkapiteln und Kapiteln auf den Kernbereich.

einheitliche Notation wichtig

Zur Schreibweise: Hier und in den folgenden Kapiteln werden SQL-Schlüsselwörter in Großbuchstaben geschrieben, z. B. CREATE. Abhängig vom benutzten Datenbank-Managementsystem können Schlüsselwörter groß, klein oder gar in gemischter Form geschrieben werden. Wichtig ist die Unterscheidung von Groß- und Kleinschreibung innerhalb von Texten, so sind 'Hallo' und 'hallo' unterschiedliche Daten. Generell sollte man sich für eine einheitliche Schreibweise für Schlüsselwörter und Tabellen sowie die Verwendung von Einrückungen entscheiden. Diese Entscheidungen sind vor dem Start großer Projekte zu vereinheitlichen.

6.1

Tabellendefinition mit SQL

Verkäufer				Kunde		
<u>Vnr</u>	Name	Status	Gehalt	<u>Knr</u>	Name	Betreuer
1001	Udo	Junior	1500	1	Egon	1001
1002	Ute	Senior	1900	2	Erwin	1001
1003	Uwe	Senior	2000	3	Erna	1002

Abb. 6.1: Einfaches Verkaufsbeispiel

Abb. 6.1 zeigt zwei einfache Tabellen, die in diesem Kapitel in SQL definiert werden sollen. Neben dem markierten Primärschlüssel gibt es eine Fremdschlüsselbeziehung, wie im Unterkapitel „3.2 Übersetzung von Entity-Relationship-Modellen in Tabel-

len“ erklärt, die festlegt, dass jeder Kunde einen existierenden Verkäufer als Betreuer haben muss.

Die Struktur und die Information lassen sich direkt in die SQL-Definitionssprache übertragen:

```
CREATE TABLE Verkaeufer(  
  Vnr INTEGER,  
  Name VARCHAR(6),  
  Status VARCHAR(7),  
  Gehalt INTEGER,  
  PRIMARY KEY (Vnr)  
)
```

und

```
CREATE Table Kunde(  
  Knr INTEGER,  
  Name Varchar(6),  
  Betreuer INTEGER,  
  PRIMARY KEY (Knr),  
  CONSTRAINT FK_Kunde  
    FOREIGN KEY (Betreuer)  
    REFERENCES Verkaeufer(Vnr)  
)
```

Erzeugung von Tabellen

Generell werden Tabellen durch den Befehl „CREATE TABLE <Tabellenname>“ erzeugt. Danach folgt in runden Klammern die Definition der Tabelle, wobei die einzelnen Eigenschaften durch Kommas getrennt sind. Zeilenumbrüche werden zur Übersichtlichkeit eingefügt, haben aber keine Bedeutung.

An einigen Stellen kann die Reihenfolge der Eigenschaften verändert werden. Diese Möglichkeiten werden hier nicht im Detail erläutert. Ziel dieses Unterkapitels ist es, eine sinnvolle langfristig lesbare Tabellendefinition zu erhalten. In größeren Projekten ist es dabei nicht unüblich, weitere Konventionen für Schreibweisen einzuführen. So könnten alle Attribute des Primärschlüssels mit „p_“ beginnen, so dass auch bei der späteren Nutzung in Anfragen sofort deutlich ist, dass es sich um Primärschlüssel handelt.

Definition von Attributen (Spalten)

Die einzelnen Tabellenspalten werden durch die Angabe des Namens, gefolgt von der Angabe des Datentyps, festgelegt. Die Auswahl der passenden Datentypen kann wichtig für die Qualität der entstehenden Datenbank sein. Eine genauere Betrachtung der Datentypen erfolgt im Unterkapitel 6.3. Hier werden zunächst zwei zentrale Typen genutzt: INTEGER kann beliebige ganzzahlige Zahlenwerte aufnehmen. Mit VARCHAR(x) ist ein Typ gegeben, der maximal x Zeichen aufnehmen kann, was dem

bisher „Text“ genannten Datentyp entspricht. In Programmiersprachen wird dafür häufig der Typ String genutzt.

Nach der Übersetzung der Spalten können weitere Eigenschaften der Tabelle, so genannte Constraints, definiert werden. Diese können weggelassen werden, erhöhen aber bei der späteren Nutzung die Qualität der entstehenden Datenbank erheblich, da das Datenbank-Managementsystem die Einhaltung dieser Regeln überprüft.

*Definition von
Primärschlüs-
seln*

Mit der Angabe „PRIMARY KEY (<Spaltenname1>, ..., <SpaltennameN>)“ wird festgelegt, dass sich der Primärschlüssel aus den aufgeführten Attributen zusammensetzt. Das Datenbank-Managementsystem garantiert, dass für den Primärschlüssel jeder eingetragene Wert eindeutig ist und keine NULL-Werte enthält. Im Kapitel 4 wurde definiert, dass der Entwickler willkürlich einen möglichst einfach nutzbaren Schlüsselkandidaten zum Primärschlüssel erklären kann, wenn es mehrere Schlüsselkandidaten gibt.

*Auswahl des
Primärschlüs-
sels*

In der Tabelle Kunde sieht man den typischen Aufbau einer Fremdschlüssel-Definition. Mit „CONSTRAINT <constraintname>“ wird eine Randbedingung definiert, die vom Datenbank-Managementsystem geprüft wird. Detaillierte Angaben zu den Constraints stehen im Unterkapitel „6.5 Constraints“.

*Definition von
Fremdschlüs-
seln*

Fremdschlüssel werden in der untergeordneten Tabelle definiert, d. h. in der Tabelle, die sich auf eine andere Tabelle bezieht. Die allgemeine Syntax einer solchen Definition sieht wie folgt aus:

```
FOREIGN KEY (<meinSpaltenname1>, ... ,  
              <meinSpaltennameN>)  
REFERENCES <übergeordneteTabelle>  
            (<dortigerSpaltenname1>, ... ,  
             <dortigerSpaltennameN>)
```

*Reihenfolge Ta-
bellendefinition*

Man gibt zunächst an, wie die Spalten in der zu definierenden Tabelle heißen und danach auf welche Tabelle und welche Spalten dort sich die vorher genannten Spalten beziehen. Dabei bezieht sich <meinSpaltennameX> immer auf <dortigerSpaltennameX>. Eine Tabelle kann Fremdschlüsselbeziehungen zu verschiedenen Tabellen haben. Diese Beziehungen werden jeweils als eigenständige Constraints angegeben. Fremdschlüsselbeziehungen können sich nur auf definierte Primärschlüssel anderer Tabellen beziehen. Diese Tabellen müssen vor der Tabelle, in der das Constraint definiert wird, erzeugt werden.

Das Datenbank-Managementsystem überprüft bei Eintragungen in die Tabelle Kunde, ob ein Verkäufer mit dem für Betreuer übergebenen Wert existiert. Eine Besonderheit ist, dass für den Betreuer auch ein NULL-Wert eingegeben werden kann, wodurch das Constraint nicht verletzt wird. Genauere Betrachtungen zu NULL-Werten werden im Unterkapitel „6.4 NULL-Werte und drei-wertige Logik“ gemacht.

Bei der Nutzung der Fremdschlüssel stellt sich die Frage, was passiert, wenn der übergeordnete Datensatz, hier z. B. der Verkäufer mit der Vnr 1001, gelöscht wird. Die möglichen Alternativen werden im folgenden Unterkapitel vorgestellt.

6.2

Einfügen, Löschen und Ändern von Daten

*Einfügen von
Daten in Tabellen*

Nachdem das Tabellengerüst erzeugt wurde, sollen jetzt Daten in die Tabellen gefüllt und später verändert werden können. Zum Einfügen von Daten wird der INSERT-Befehl genutzt. In der einfachsten Form dieses Befehls ist es wichtig, die Reihenfolge der Attribute in der Tabellendefinition zu kennen. Die Daten der Tabelle Verkäufer aus Abb. 6.1 können wie folgt eingefügt werden:

```
INSERT INTO Verkäufer
VALUES (1001, 'Udo', 'Junior', 1500);
INSERT INTO Verkäufer
VALUES (1002, 'Ute', 'Senior', 1900);
INSERT INTO Verkäufer
VALUES (1003, 'Uwe', 'Senior', 2000)
```

Die generelle Form des Befehls lautet:

```
INSERT INTO <Tabellenname>
VALUES (<WertFürSpalte1>, ... , <WertFürLetzteSpalte>)
```

Zur Trennung von SQL-Befehlen wird in diesem Buch ein Semikolon genutzt. Das Trennsymbol für Befehle ist im Standard nicht festgeschrieben und kann in Datenbank-Managementsystemen variieren.

Es muss für jede Spalte ein Wert angegeben werden. Etwas flexibler ist die Variante des INSERT-Befehls, bei der die Spalten angegeben werden, in die Werte eingetragen werden sollen. Zwei Beispiele sind:

*Einfügen in
einzelne Spalten*

```
INSERT INTO Verkäufer (Vnr, Name, Status)
VALUES (1004, 'Ulf', 'Junior');
INSERT INTO Verkäufer (Vnr, Gehalt, Name)
VALUES (1005, 1300, 'Urs')
```

Die generelle Form lautet:

```
INSERT INTO <Tabellenname> (<Spaltenname1>, ... ,  
                             <SpaltennameK>)  
VALUES (<WertFürAngegebeneSpalte1>, ... ,  
        <WertFürAngegebeneSpalteK>)
```

*NULL-Werte
beim Einfügen*

Es stellt sich die Frage, was mit Spalten passiert, die nicht im INSERT-Befehl genannt sind. Dabei gibt es zwei Alternativen:

- Sind die Attribute in der bisher bekannten Form definiert, wird in die Spalten ein NULL-Wert eingetragen.
- Ist das Attribut mit einem Standard-Wert definiert, wird dieser Standardwert genommen. Die Definition eines Attributs mit einem Standardwert sieht beispielhaft wie folgt aus:

```
Status VARCHAR(7) DEFAULT 'Junior'
```

*Definition von
Standardwerten*

Nachdem man Werte in die Tabellen eingetragen hat, möchte man sich diese gerne ansehen. Dazu muss eine Anfrage an die Datenbank formuliert werden. Ohne weiteren Details von Anfragen aus den folgenden Kapiteln vorzugreifen, sei hier eine einfache Anfrageform zur Ausgabe des vollständigen Tabelleninhalts angegeben. Sie lautet

```
SELECT * FROM <Tabellenname>
```

*Ansehen von
Tabelleninhalten*

Gehen wir davon aus, dass das Attribut Status mit dem angegebenen Standardwert definiert ist, bekommt man als Ergebnis der Anfrage

```
SELECT * FROM Verkaeuer
```

folgende Ausgabe

VNR	NAME	STATUS	GEHALT
-----	-----	-----	-----
1001	Udo	Junior	1500
1002	Ute	Senior	1900
1003	Uwe	Senior	2000
1004	Ulf	Junior	
1005	Urs	Junior	1300

Man erkennt, dass NULL-Werte hier einfach als leere Ausgaben erscheinen, die damit in der Ausgabe nicht vom leeren Text '' zu unterscheiden sind.

*Kontrolle beim
Einfügen*

Versucht man einen Tabelleneintrag zu machen, der gegen eine der Constraints, z. B. gegen die Eindeutigkeit des Primärschlüssels verstößt, so wird die Aktion mit einer Fehlermeldung abgebrochen. Wird z. B. folgende Eingabe versucht


```
INSERT INTO Verkaeuer
VALUES (1001, 'Alf', 'Senior', 3000)
```

kann die Reaktion wie folgt aussehen

```
Verstoß gegen Eindeutigkeit, Regel
(SCOTT.SYS_C003014)
```

Durch den „Verstoß gegen die Eindeutigkeit“ wird die Verletzung der gewünschten Primärschlüsseleigenschaft angezeigt. Im Detail steht Scott für den Eigentümer der Tabelle, d. h. die Tabelle wurde unter dem Nutzer Scott angelegt und SYS_C0003014 für den intern vergebenen Namen für das Primärschlüssel-Constraint.

Zur Vervollständigung der Tabellen gehören folgende Einträge in die Tabelle Kunde.

```
INSERT INTO Kunde VALUES(1, 'Egon', 1001);
INSERT INTO Kunde VALUES(2, 'Erwin', 1001);
INSERT INTO Kunde VALUES(3, 'Erna', 1002)
```

*Verstoß gegen
Fremdschlüssel-
selbedingung*

Versucht man, einen Kunden mit einem Betreuer einzutragen den es nicht gibt, z. B.

```
INSERT INTO Kunde VALUES(4, 'Edna', 999);
```

wird der Eintrag nicht vorgenommen und man erhält z. B. die Fehlermeldung

```
Verstoß gegen Constraint (SCOTT.FK_KUNDE).
Übergeordn. Schlüssel nicht gefunden
```

Man beachte, dass hier der Name des verletzten Constraints angegeben wird.

Interessant ist der Fall, bei dem ein NULL-Wert für die Referenz zum Betreuer angegeben wird. Diese Möglichkeit wird also explizit in SQL erlaubt. D. h., die folgenden Befehle

```
INSERT INTO Kunde VALUES(4, 'Edna', NULL);
SELECT * FROM Kunde
```

führen zu folgender Ausgabe

KNR	NAME	BETREUER
1	Egon	1001
2	Erwin	1001
3	Erna	1002
4	Edna	

*Einfügen von
Anfrageergeb-
nissen*

Neben den vorgestellten INSERT-Varianten, gibt es eine dritte Variante, bei der das Ergebnis einer Anfrage zeilenweise in eine Tabelle eingetragen wird. Die Syntax lautet:

```
INSERT INTO <Tabellenname> <Anfrage>
```

*Warnung vor
INSERT mit
Anfrage*

Anfragen werden detailliert ab dem folgenden Kapitel besprochen. Zu dieser Einfügemöglichkeit ist sehr kritisch anzumerken, dass dabei eine Kopie von schon existierenden Daten erzeugt wird und man dem Problem der Redundanz Tür und Tor öffnet. Diese Einfügemöglichkeit ist nur mit sehr viel Bedacht einzusetzen. Oftmals gibt es andere Lösungsmöglichkeiten, wie den Einsatz von Views, siehe Kapitel 11.

Nachdem Daten in Tabellen eingetragen wurden, kann der Wunsch bestehen, die Inhalte zu ändern. Hierfür steht der UPDATE-Befehl zur Verfügung. Soll für die Tabelle Kunde bei der Kundin mit der Knr 4 der Name auf Edwina geändert und ihr als Betreuer der Verkäufer mit der Vnr 1002 zugeordnet werden, kann dies mit folgendem Befehl geschehen:

*Ändern von
Tabelleneinträ-
gen*

```
UPDATE Kunde  
  SET Name='Edwina',  
      Betreuer=1002  
 WHERE Name='Edna '
```

Die allgemeine Syntax sieht wie folgt aus:

```
UPDATE <Tabellenname>  
  SET <Spaltenname> = <Wert> | <Anfrage>, ...  
    <SpaltennameJ> = <Wert> | <Anfrage>  
 WHERE <Bedingung>
```

Bei der Ausführung wird für jede Zeile der betroffenen Tabelle untersucht, ob die Bedingung erfüllt ist. Ist dies der Fall, wird die im SET-Block beschriebene Änderung durchgeführt. Dies geschieht nur, wenn kein Constraint verletzt wird, sonst gibt es eine Fehlermeldung, und keine Änderung wird ausgeführt.

*Nutzung von
Anfragen in
Änderungen*

Die mit <Anfrage> beschriebene Möglichkeit, einen Wert berechnen zu lassen, wird in den späteren Unterkapiteln deutlicher, in denen der Aufbau und das Ergebnis von Anfragen beschrieben werden. Man kann sich hier bereits vorstellen, dass nur Anfragen genutzt werden können, die exakt ein Ergebnis zurück liefern. Eine genauere Beschreibung der Möglichkeiten, die Bedingung anzugeben, erfolgt ebenfalls in den weiteren Unterkapiteln. Grundsätzlich stehen in der Bedingung zu überprüfende Eigenschaften von Attributwerten, die mit AND und OR verknüpft sowie mit NOT negiert werden können.

Betrachtet man die letzte Änderung der Tabelle kritisch, so kann man feststellen, dass die Bedingung nicht optimal ist. Falls es mehrere Kunden mit dem Namen Edna gäbe, würden die be-

schriebenen Änderungen für alle diese Kunden vorgenommen. Eine wesentlich bessere Bedingung wäre $\text{Knr}=4$ gewesen.

*Auswertung
von SET*

Lässt man die WHERE-Bedingung ganz weg, wird sie als „wahr“ interpretiert, d. h. die Änderungen beziehen sich auf alle Zeilen. Innerhalb des SET-Blocks wird zunächst für jede Zuweisung die rechte Seite ausgewertet und dann der Wert des auf der linken Seite genannten Attributs entsprechend verändert. Dies ermöglicht auch eine Änderung eines Attributwertes in Abhängigkeit von seinem alten Wert. Durch den folgenden Befehl kann man z. B. das Gehalt aller Verkäufer um 5% erhöhen.

*Änderung in
Abhängigkeit
von alten Wer-
ten*

```
UPDATE Verkaeufer
SET Gehalt=Gehalt * 1.05
```

Die resultierende Tabelle sieht wie folgt aus:

VNR	NAME	STATUS	GEHALT
1001	Udo	Junior	1575
1002	Ute	Senior	1995
1003	Uwe	Senior	2100
1004	Ulf	Junior	
1005	Urs	Junior	1365

Man erkennt, dass irgendwelche Operationen auf NULL-Werten, hier z. B. die Multiplikation, keinen Effekt haben. Das Ergebnis bleibt NULL.

Nach dem Einfügen und Verändern fehlt noch als dritter Befehl der Befehl zum Löschen von Daten. Dies geschieht durch DELETE. Will man z. B. den Kunden mit der Knr 3 löschen, so kann man dies durch folgenden Befehl erreichen:

*Löschen von
Daten*

```
DELETE FROM Kunde
WHERE Knr=3
```

Die allgemeine Syntax lautet:

```
DELETE FROM <Tabellenname>
WHERE <Bedingung>
```

*Berechnung der
zu löschenden
Zeilen*

Für die ausgewählte Tabelle wird für jede Zeile geprüft, ob die Auswertung der Bedingung „wahr“ ergibt. Ist dies der Fall, so wird versucht, die Zeile zu löschen. Sollte für eine Zeile die Bedingung erfüllt sein und kann diese wegen irgendwelcher Randbedingungen nicht gelöscht werden, gibt es eine Fehlermeldung und es findet kein Löschvorgang statt.

Diese Situation soll durch ein Beispiel konkretisiert werden. Dabei wird von folgenden Tabelleninhalten ausgegangen:

```
SELECT * FROM Verkaeuer;
SELECT * FROM Kunde
```

führen zu folgenden Ausgaben

VNR	NAME	STATUS	GEHALT
1001	Udo	Junior	1575
1002	Ute	Senior	1995
1003	Uwe	Senior	2100
1004	Ulf	Junior	
1005	Urs	Junior	1365

KNR	NAME	BETREUER
1	Egon	1001
2	Erwin	1001
4	Edwina	1002

Jetzt soll der Verkäufer mit der Vnr 1001 gelöscht werden. Der Befehl lautet

*Löschproblema-
tik bei abhän-
gigen Werten*

```
DELETE FROM Verkaeuer
WHERE Vnr=1001
```

Die Ausgabe dazu kann wie folgt aussehen:

```
Verstoß gegen Constraint (SCOTT.FK_KUNDE).
Untergeordneter Datensatz gefunden.
```

*zum Löschen
abhängige Ta-
bellen kennen*

Das Datenbank-Managementsystem erkennt, dass es in der Tabelle Kunde mindestens einen davon abhängigen Datensatz gibt und verweigert die Ausführung des Löschbefehls. Man kann daraus ableiten, dass der Fremdschlüssel zwar in der Tabelle Kunde definiert wird, diese Information der Datenabhängigkeit aber auch ein nicht direkt sichtbares Constraint für die Tabelle Verkaeuer liefert. D. h., dass die Kenntnis der Definition der Tabelle Verkaeuer alleine nicht ausreicht, um bestimmen zu können, ob eine gewisse Löschoperation ausgeführt werden kann.

Mit dem bisherigen Wissen ist es aber trotzdem möglich, den Verkäufer mit der Vnr 1001 zu löschen. Dazu müssen zunächst die Betreuerinformationen in der Tabelle Kunde, die sich auf 1001 beziehen auf einen anderen Wert, also die VNr von einem anderen Verkäufer oder NULL, gesetzt werden. Danach kann der Verkäufer mit der Vnr 1001 ohne Probleme gelöscht werden. Die zugehörigen SQL-Befehle lauten:

```

UPDATE Kunde
  SET Betreuer=NULL
  WHERE Betreuer=1001;
DELETE FROM Verkaeuer
  WHERE Vnr=1001

```

Das hier vorgestellte Verfahren ist grundsätzlich immer anwendbar, man muss allerdings beachten, dass in realen Projekten die Datenabhängigkeit wesentlich komplexer sein kann. Die Änderungen der Tabelle Kunde könnten sich z. B. auf weitere Tabellen fortpflanzen, vergleichbar dem Domino-Prinzip, bei dem ein Stein angestoßen wird und alle davon abhängigen Steine auch nacheinander umfallen. Da diese Datenanalyse von Hand eventuell sehr aufwändig ist, gibt es eine Alternative bei der Definition von Fremdschlüsseln. Diese Definition sieht für die Tabelle Kunde wie folgt aus:

```

CREATE Table Kunde(
  Knr INTEGER,
  Name Varchar(7),
  Betreuer INTEGER,
  PRIMARY KEY (Knr),
  CONSTRAINT FK_Kunde
    FOREIGN KEY (Betreuer)
      REFERENCES Verkaeuer(Vnr)
    ON DELETE CASCADE
)

```

*Fremdschlüssel
mit Lösch-
fortpflanzung*

Durch den Zusatz ON DELETE CASCADE wird der Fremdschlüssel in der Form erweitert, dass, wenn der übergeordnete Datensatz gelöscht wird, damit auch alle davon abhängigen Datensätze in dieser Tabelle gelöscht werden.

Ausgehend von der gleichen Situation, die vor dem gescheiterten DELETE-Befehl vorlag, führt das folgende SQL-Skript

```

DELETE FROM Verkaeuer
  WHERE Vnr=1001;
SELECT * FROM Verkaeuer;
SELECT * FROM Kunde

```

zu folgender Ausgabe

VNR	NAME	STATUS	GEHALT
1002	Ute	Senior	1995
1003	Uwe	Senior	2100
1004	Ulf	Junior	
1005	Urs	Junior	1365

KNR	NAME	BETREUER
-----	-----	-----
4	Edwina	1002

Dominoeffekt bei Löschfortpflanzung

Man sieht, dass alle Kunden mit dem Betreuer 1001 gelöscht wurden. Diese Form der Fremdschlüsseldefinition führt alle Löscharbeiten automatisch aus. Dabei gilt weiterhin, dass die gesamte Aktion nicht durchgeführt wird, falls es an nur einer Stelle Widerstand gegen das Löschen geben sollte, da ein Constraint verletzt wird.

Pro und Contra der Löschfortpflanzung

Beim aufmerksamen Lesen des letzten Beispiels fällt kritisch auf, dass es häufig nicht gewünscht wird, dass Kundeninformationen verloren gehen. Man muss sich bei der Implementierung der Tabellenstrukturen möglichst für eine einheitliche Art der Fremdschlüsseldefinition mit oder ohne ON DELETE CASCADE entscheiden. Wenn man weiß, dass später auch unerfahrene Personen Zugang zu kritischen Daten haben müssen, sollte man genau überlegen, ob das eigentlich sehr praktische ON DELETE CASCADE wirklich die bessere Lösung ist, da der vorher beschriebene Dominoeffekt, dem man ohne diese Ergänzung von Hand abarbeiten muss, mit ON DELETE CASCADE schnell zu gravierenden und meist nur schwer wieder behebbaren Datenverlusten führen kann.

Im SQL-Standard gibt es folgende Möglichkeiten, die Reaktion beim DELETE in den FOREIGN KEYS nach ON DELETE zu spezifizieren:

- Reaktionsmöglichkeiten beim Löschen von Daten*
- NO ACTION: entspricht der Ursprungseinstellung, das Löschen wird abgelehnt, wenn ein abhängiger Datensatz existiert
 - CASCADE: entspricht der vorgestellten Löschfortpflanzung
 - SET NULL: für abhängige Datensätze wird die Referenz auf den gelöschten Datensatz automatisch auf NULL gesetzt
 - SET DEFAULT: wenn es einen Default-Wert gibt, wird dieser im abhängigen Datensatz eingetragen; existiert ein solcher Wert nicht, wird der Löschvorgang nicht durchgeführt

Fortpflanzung bei Aktualisierungen

Beim kritischen Lesen fällt auf, dass man die Überlegungen zum DELETE auch zum UPDATE anstellen kann. Dazu ist anzumerken, dass der SQL-Standard Möglichkeiten wie ON UPDATE CASCADE vorsieht, dieses aber nur bei wenigen großen Datenbank-Managementsystemen implementiert ist. Die Möglichkeiten und Argumentationen zum Für und Wider lassen sich dabei di-

Löschen von Tabellen

rekt von der Diskussion zum DELETE auf eine Diskussion zum UPDATE übertragen.

Vergleichbare Überlegungen wie zu DELETE und UPDATE kann man auch zum Löschen von Tabellen anstellen. Mit dem Befehl

```
DROP TABLE <Tabellenname> RESTRICT
```

wird die Tabelle mit dem Namen <Tabellenname> nur gelöscht, wenn es keine anderen Tabellen gibt, die von dieser Tabelle abhängig sind. D. h. es gibt keine andere Tabelle, in der ein Fremdschlüssel auf die zu löschende Tabelle referenziert. Gibt es solch eine Tabelle, wird der Löschbefehl nicht durchgeführt.

Die Nutzung des Schlüsselworts RESTRICT macht das Löschen sehr sicher, da man so nicht zufällig eine zentrale Tabelle mit vielen Abhängigkeiten löschen kann. Allerdings bedeutet dies auch für Löschvorgänge, bei denen mehrere Tabellen gelöscht werden sollen, dass man zunächst die Tabelle herausfinden muss, auf die es keine Verweise gibt und dann die weiteren Tabellen schrittweise löscht. Dies kann man sich wie eine Kette von Dominos vorstellen, bei der man vorsichtig die letzten Dominos entfernt, da man möchte, dass die Dominoschlange beim Umkippen in eine andere Richtung läuft.

Alternativ gibt es den Befehl

```
DROP TABLE <Tabellenname> CASCADE
```

mit dem garantiert wird, dass die Tabelle mit dem Namen <Tabellenname> gelöscht wird. Durch das CASCADE wird ausgedrückt, dass Tabellen, die Referenzen auf die zu löschende Tabelle haben, so verändert werden, dass diese Referenzen gelöscht werden. Dies bedeutet konkret, dass Constraints mit Fremdschlüsseln, die sich auf die zu löschende Tabelle beziehen, mit gelöscht werden. Dabei bleiben aber alle anderen Daten in der vorher abhängigen Tabelle erhalten, man kann sicher sein, dass die zu löschende Tabelle mit allen Spuren im System gelöscht wird.

Generell gibt es auch den kürzeren Befehl

```
DROP TABLE <Tabellenname>
```

dabei ist allerdings zu beachten, dass dieser abhängig vom Datenbank-Managementsystem einmal in der Form mit RESTRICT und in einem anderen System in der Form mit CASCADE interpretiert wird.

6.3 Datentypen in SQL

Basistypen

selbstdefinierte Typen

In den vorherigen Unterkapiteln wurden bereits einige Datentypen benutzt, die sehr häufig in Datenbanken zu finden sind. In diesem Unterkapitel werden wichtige Informationen zu weiteren Typen zusammengefasst. Dabei ist zu beachten, dass neben den Basistypen in den schrittweisen Erweiterungen des Standards Möglichkeiten zur Definition eigener Typen aufgenommen wurden. Mit diesen Typen wird aber häufig gegen die erste Normalform verstoßen. Sie sind dann sinnvoll, wenn man genau weiß, welche Auswertungen mit der Datenbank gemacht werden sollen. Generell gilt, dass die Arbeit mit eigenen Typen das spätere Erstellen von Anfragen leicht komplizierter machen kann. Mit den in diesem Unterkapitel vorgestellten Typen können ohne Probleme alle Standardtabellen typischer Datenbank-Einsatzbereiche beschrieben werden.

häufige Abweichungen vom Standard

Selbst bei den Standarddatentypen muss man aufpassen, ob und teilweise unter welchen Namen sie im Datenbank-Managementsystem unterstützt werden. Einen guten Überblick über das standardisierte Verhalten und die Umsetzung in führenden Datenbank-Managementsystemen findet man in [Tür03].

SQL als getypte Sprache

Generell gilt, dass man ohne Typen bzw. mit nur einem allgemeinen Typen auskommen kann. Dies ist ein Typ, der Texte beliebiger Länge aufnehmen kann. Man kann Zahlen, z. B. '123' und Wahrheitswerte wie 'true' einfach als Texte oder Strings interpretieren. Dieser Ansatz wird in SQL nicht gewählt, da man als Randbedingung präziser angeben möchte, welcher Typ erwartet wird. Weiterhin erleichtert die Nutzung der Typen die Werteänderungen. Es ist z. B. zunächst unklar, was ein Minus-Zeichen für Texte bedeuten soll. Geht man davon aus, dass Zahlen gemeint sind, müssten die Texte zunächst in Zahlen verwandelt, dann subtrahiert und letztendlich das Ergebnis in einen String zurück verwandelt werden.

Simulation weiterer Datentypen als Texte

Es bleibt aber festzuhalten, dass man eventuell nicht vorhandene Datentypen durch Texte simulieren kann. Dieser Ansatz ist z. B. bei einigen größeren Datenbank-Managementsystemen notwendig, wenn man Wahrheitswerte darstellen möchte, da der SQL-Standardtyp BOOLEAN nicht immer vorhanden ist.

Warnung vor Spezialtypen einzelner Systeme

Generell sollte man vor der Erstellung einer Tabelle deshalb prüfen, welche der vorgestellten Datentypen genutzt werden können und welche Typen es noch zusätzlich im Datenbank-Managementsystem gibt. Dabei ist daran zu denken, dass man

mit jedem benutzten Typen, der nicht unter diesem Namen zum Standard gehört, Schwierigkeiten beim Wechsel oder der parallelen Nutzung eines anderen Datenbank-Managementsystems bekommen kann.

Für die Definition ganzer Zahlen sind folgende Typen vorgesehen: `SMALLINT`, `INTEGER`, `BIGINT`.

SMALLINT

INTEGER

BIGINT

Neben der Festlegung, dass es sich um eine ganze Zahl handeln soll, kann man noch angeben, wie viel Speicherplatz verwendet werden darf. Nimmt man wenig Speicherplatz, z. B. mit dem Datentypen `SMALLINT`, geschieht die Nutzung dieser Spalten etwas schneller, man kann aber weniger Zahlenwerte darstellen. Die Grenzen für diese Zahlen werden vom Datenbank-Managementsystem festgelegt und können variieren. Die einzige Festlegung ist, dass `SMALLINT` nicht mehr Speicherverbrauch als `INTEGER` hat. `BIGINT` kann dann mindestens so große Zahlen wie `INTEGER`, typischerweise größere Zahlen aufnehmen.

*Bestimmung
der passenden
Typen*

Für die Praxis heißt dies, dass man sich bei der Erstellung einer Tabelle fragen muss, was der größte Wert ist, der in dieser Spalte eingetragen werden soll. Danach kann der passende Typ ausgewählt werden.

Zur Definition von Kommazahlen gibt es folgende Typen im Standard: `DECIMAL`, `NUMERIC`, `FLOAT`, `REAL`, `DOUBLE PRECISION`.

Der Unterschied zwischen den Typen ist wieder der benutzte Speicherplatz und die benutzte Genauigkeit. Wichtig ist dabei, dass beliebige reelle Zahlen im Computer nur angenähert dargestellt werden können und es so zu Ungenauigkeiten kommen kann. Aus diesem Grund ist es sinnvoll, bei Geldbeträgen, die z. B. auf einen Zehntel-Cent genau sein müssen, den Datentypen `INTEGER` zu verwenden, um dann genau in Zehntel-Cent zu rechnen.

DECIMAL

NUMERIC

Unter den Kommazahlen gibt es als Besonderheit die Festkommazahlen, wobei bei `DECIMAL(p, q)` oder mit gleicher Bedeutung bei `NUMERIC(p, q)` durch `p` die Genauigkeit und durch `q` die Anzahl der Nachkommastellen festgelegt werden. Dies wird in folgendem kleinen Beispiel verdeutlicht:

```
CREATE TABLE Typtest (
  Nummer Integer,
  n NUMERIC(5,2),
  PRIMARY KEY (Nummer)
)
```

In diese Tabelle werden folgende Werte eingetragen:

```
INSERT INTO Typtest VALUES (1,999.99);
INSERT INTO Typtest VALUES (2,-999.99);
SELECT * FROM Typtest
```

Das Ergebnis ist:

NUMMER	N
1	999,99
2	-999,99

Jetzt werden die Werte durch 10 geteilt:

```
UPDATE Typtest
SET n=n/10
```

Die folgende Anfrage

```
SELECT * FROM Typtest
```

führt zum Ergebnis

NUMMER	N
1	100
2	-100

*Probleme mit
Rundungen*

Da nur mit zwei Stellen hinter dem Komma gerechnet wird, fand eine Rundung z. B. von 99,999 auf 100 statt. Mit dem folgenden Test kann man feststellen, dass in der Datenbank auch intern nicht mit 99,999 gerechnet wird. Die Tabelleninhalte werden mit 10 multipliziert.

```
UPDATE Typtest
SET n=n*10
```

Das Datenbank-Managementsystem antwortet in der Form

```
FEHLER in Zeile 2:
Wert größer als angegebene Stellenzahl für diese
Spalte zulässt
```

Es würde als Ergebnis der Berechnung z. B. 1000 herauskommen, da aber nur drei Vor- und zwei Nachkommastellen zur Verfügung stehen, kann das Ergebnis nicht in die Tabelle eingetragen werden.

Bei FLOAT, REAL und DOUBLE PRECISION handelt es sich um Fließkommazahlen, die sehr hohe Werte annehmen können, allerdings gegebenenfalls viele Stellen abschneiden. Dies wird mit folgendem SQL-Skript verdeutlicht.

FLOAT

REAL

*DOUBLE PRE-
CISION*

```
CREATE TABLE Typtest2(
  Nummer Integer,
```

```

r REAL,
PRIMARY KEY (Nummer)
);
INSERT INTO TYPtest2 VALUES (1,999.99);
INSERT INTO TYPtest2 VALUES (2,-9999.99);
UPDATE TYPtest2
SET r=r+1E24;
UPDATE TYPtest2
SET r=r-1E24;
SELECT * FROM TYPtest2
```

Die Ausgabe ist:

NUMMER	R
1	0
2	0

Ungenauigkeit
beim Rechnen

Dabei steht 1E24 für $1 \cdot 10^{24}$. Die kleinen Werte sind bei der Addition und nachfolgenden Subtraktion des gleichen Wertes verloren gegangen. Dies könnte z. B. dann ärgerlich sein, wenn irrtümlich ein sehr hoher Betrag auf ein „kleines“ Gehaltskonto überwiesen und schnell wieder abgebucht wird. Kleine Kontoinhalte gehen verloren. Aus diesem Grund ist die vorher erwähnte Maßnahme, genau über den Datentyp bei Geldbeträgen nachzudenken, sehr wichtig.

CHAR
VARCHAR

Als Datentypen für Texte stehen CHAR(q) und VARCHAR(q) zur Verfügung. Dabei gibt q die genaue bzw. maximale Anzahl von Zeichen an. Größere Texte können nicht aufgenommen werden. Bei CHAR werden intern immer q Zeichen, bei VARCHAR werden nur die Zeichen des tatsächlich eingetragenen Textes abgespeichert. CHAR ist in der Regel schneller in der Verarbeitung, kann aber wesentlich mehr Speicherplatz beanspruchen, was dann unter anderem auch die Verarbeitungszeit wieder negativ beeinflussen kann.

DATE
TIME

Zur Verarbeitung von Tagen gibt es den Typen DATE und für Zeiten TIME. Dabei hängt es vom Datenbank-Managementsystem ab, wie ein Datum formatiert ist und ob vielleicht Zeitinformationen auch im Datum enthalten sind. Eine recht einfache Nutzungsmöglichkeit von DATE ist mit folgender Tabelle dargestellt:

```

CREATE TABLE TYPtest3(
  Nummer Integer,
  d DATE,
  PRIMARY KEY (Nummer)
);
```

```
INSERT INTO TYPTtest3
      VALUES (1,'15.10.1915');
INSERT INTO TYPTtest3 VALUES (2,'14.12.19');
INSERT INTO TYPTtest3 VALUES (3,'26.2.2000');
INSERT INTO TYPTtest3
      VALUES (4,DATE'1966-01-25');
SELECT * FROM Typttest3
```

Die Ausgabe ist:

NUMMER	D
1	15.10.15
2	14.12.19
3	26.02.00
4	25.01.66

In diesem Fall werden die Texte im INSERT-Befehl direkt vom Datenbank-Managementsystem in Werte vom Typ Datum umgesetzt, dabei werden sogar verschiedene Schreibweisen unterstützt. Allerdings gibt es bei der Ausgabe eine Standardeinstellung, die hier besagt, dass das Jahr nur zweistellig dargestellt wird. Dies kann abhängig vom Datenbank-Managementsystem geändert werden.

alternative Datumsformate

Bei anderen Datenbank-Managementsystemen muss explizit formuliert werden, dass ein Text in ein Datum umgewandelt werden muss. Dies geschieht z. B. durch TO_DATE('26.02.00') oder wie im Beispiel durch das Schlüsselwort DATE vor dem Text.

CLOB
BLOB

Neben den bisher vorgestellten Datentypen gibt es spezielle Datentypen, mit denen sehr lange Zeichenfolgen aufgenommen werden können. Handelt es sich dabei um reine Text-Informationen, also druckbare Zeichen, wird der Datentyp CLOB verwendet. CLOB steht für „Character Large Object“. Sollen Binärdaten, wie z. B. ausführbare Dateien oder Bilder gespeichert werden, wird ein BLOB, „Binary Large Object“ definiert. Bei beiden Typen wird in Klammern nach dem Typen der maximale Speicherbedarf angegeben, so steht BLOB (4M) z. B. für ein Attribut, das eine maximal vier Megabyte große Binärdatei aufnehmen kann. Auf CLOBs und BLOBs sind nicht alle Operationen möglich, die man für Texte verwenden kann. Diese Attribute dienen hauptsächlich zur Aufnahme von Daten und werden in Anfragen nicht durchsucht.

Zur Füllung von CLOBs und BLOBs bieten die Datenbank-Managementsysteme Lösungen an, mit denen Dateien zeichenweise in die Attribute eingelesen werden können.

XML

Ein weiterer Datentyp im SQL-Standard ist XML. Hier können Daten im XML-Format, also Texte, die dem Aufbau von XML-Dokumenten genügen, abgespeichert werden. Die Unterstützung dieses Datentypen und die dazu angebotenen Bearbeitungsfunktionen sind in den Datenbank-Managementsystemen sehr unterschiedlich.

6.4

NULL-Werte und drei-wertige Logik

*Formulierung
von WHERE-
Bedingungen*

Im Unterkapitel 6.2 wurden Änderungen und Löschungen davon abhängig gemacht, welchen konkreten Wert ein Attribut hat. Diese Überprüfung ist meist relativ einfach. Betrachtet man die Bedingung

`Vnr > 1003 AND Gehalt >= 2000`

die besagt, dass die Verkäufer-Nummer höher als 1003 und das Gehalt mindestens 2000 sein müssen, so kann sie für jede Zeile grundsätzlich ganz einfach ausgewertet werden. Gilt z. B. `Vnr=1004` und `Gehalt=2500`, ist die Bedingung erfüllt, da alle Teilbedingungen erfüllt sind. Gilt `Vnr=1003` und `Gehalt=2000`, ist die Bedingung nicht erfüllt, da das erste Teilprädikat nach falsch ausgewertet wird und die Auswertung des zweiten Teilprädikats nach wahr dann bei AND-Vernüpfungen keine Rolle spielt. Insgesamt kann man Bedingungen durch folgende Regeln wie folgt definieren:

*Syntax von
WHERE-
Bedingungen*

```

<bedingung> := <Spaltenname> <op> <wert>
<bedingung> := <bedingung> AND <bedingung>
<bedingung> := <bedingung> OR <bedingung>
<bedingung> := NOT <bedingung>
<bedingung> := (<bedingung>)
op:= < | <= | > | >= | = | <>

```

Die Regeln besagen, dass sich einfache Bedingungen aus einem Spaltennamen und einem Wertevergleich zusammensetzen. Dabei steht „<>“ z. B. für „ungleich“, wobei meist auch „!=“ genutzt werden kann. Komplexere Bedingungen werden aus anderen Bedingungen zusammengesetzt, indem sie mit AND oder OR verknüpft werden. Einzelne Bedingungen können mit NOT ne-

giert werden. Um bei komplexeren Bedingungen, die sich aus mehr als zwei Bedingungen zusammensetzen, zu regeln, in welcher Reihenfolge die Auswertung stattfindet, kann man Bedingungen in Klammern setzen. Dabei wird die innerste Bedingung, die keine Klammern enthält, zuerst ausgewertet.

[*] Experten wissen, dass es neben der Klammerregel weitere Auswertungsregeln gibt, z. B. dass AND vor OR ausgewertet wird. Weiterhin findet die Auswertung von links nach rechts statt. Da man sich beim Wechsel des Datenbank-Managementsystems nicht sicher sein kann, dass diese Regeln genau so umgesetzt werden, sollte man auf Klammern, mit denen man die Auswertungsreihenfolge bestimmt, nicht unbedingt verzichten.

Zwei-wertige
Logik

X	Y	NOT X	X AND Y	X OR Y
w	w	f	w	w
w	f	f	f	w
f	w	w	f	w
f	f	w	f	f

Abb. 6.2: Wahrheitstafel der zwei-wertigen Logik

Zur Erklärung der so genannten Booleschen Verknüpfungen werden typischerweise Wahrheitstabeln wie in Abb. 6.2 genutzt, dabei steht „w“ für „wahr“ und „f“ für falsch.

Auswertungs-
probleme mit
NULL-Werten

Bei einer kritischen Betrachtung des vorhergehenden Textes fällt auf, dass von der „eigentlich einfachen Auswertung“ geschrieben wird. Ein Problem tritt auf, wenn ein Attribut den Wert NULL hat. Wie soll `Gehalt >= 2000` ausgewertet werden, wenn Gehalt den Wert NULL hat?

Zur Lösung dieses Problems wird die bisher vorgestellte zweiwertige Logik mit „wahr“ und „falsch“ durch eine dreiwertige Logik ersetzt. Alle bisherigen Überlegungen sind übertragbar, die Logik wird im Fall solcher Vergleiche wie `NULL >= 2000` um den dritten Wahrheitswert „unbekannt“ ergänzt.

Drei-wertige
Logik

X	Y	NOT X	X AND Y	X OR Y
w	w	f	w	w
w	f	f	f	w
w	u	f	u	w
f	w	w	f	w
f	f	w	f	f

f	u	w	f	u
u	w	u	u	w
u	f	u	f	u
u	u	u	u	u

Abb. 6.3: Wahrheitstafel der drei-wertigen Logik

Diese sinnvolle Erweiterung hat weitreichende Konsequenzen. Zunächst müssen die aus Abb. 6.2 bekannten Fälle um den Wert „unbekannt“ ergänzt werden. Das Resultat ist in Abb. 6.3 beschrieben, „u“ steht für „unbekannt“. Weiterhin gilt, dass ein AND nur nach „wahr“ ausgewertet wird, wenn beide Teilbedingungen „wahr“ sind, ist eine „falsch“, so ist auch das Ergebnis „falsch“. In den restlichen Fällen kommt unbekannt heraus. Ähnlich konsequent ist die Umsetzung beim OR, das „wahr“ wird, wenn eine Teilbedingung „wahr“ ist, und „falsch“ wird, wenn beide Teilbedingungen nach „falsch“ ausgewertet werden.

*Unterscheidung
„wahr“ und
„nicht falsch“*

Für die vorgestellten SQL-Befehle hat die drei-wertige Logik die Auswirkung, dass man klar formulieren muss, ob man den Fall der Auswertung nach „wahr“ oder nach „nicht falsch“ meint, da letzteres auch „unbekannt“ einschließt. Für die bisher vorgestellten Befehle UPDATE und DELETE gilt, dass sie nur ausgeführt werden, wenn die WHERE-Bedingung nach „wahr“ ausgewertet wird. Dies soll durch folgendes kleines Spielbeispiel verdeutlicht werden.

Die Liste der Verkäufer wird wie folgt ergänzt und ausgegeben:

```
INSERT INTO Verkaeufer
VALUES (1006, 'Uta', NULL, 1500);
SELECT * FROM Verkaeufer
```

VNR	NAME	STATUS	GEHALT
-----	-----	-----	-----
1002	Ute	Senior	1995
1003	Uwe	Senior	2100
1004	Ulf	Junior	
1005	Urs	Junior	1365
1006	Uta		1500

Danach werden ein UPDATE- und ein DELETE-Befehl ausgeführt. Zu beachten ist, dass es Zeilen gibt, bei denen die WHERE-Prädikate nach „wahr“ und andere, bei denen die Prädikate nach „nicht falsch“, genauer „unbekannt“, ausgewertet werden.

```
DELETE FROM Verkaeuer
WHERE Gehalt>2000;
UPDATE Verkaeuer
SET Status='Senior'
WHERE Status='Junior';
SELECT * FROM Verkaeuer
```

Dies führt zu folgender Ausgabe:

VNR	NAME	STATUS	GEHALT
1002	Ute	Senior	1995
1004	Ulf	Senior	
1005	Urs	Senior	1365
1006	Uta		1500

Man sieht, dass Auswertungen nach „unbekannt“ nicht dazu geführt haben, dass Änderungen in den betroffenen Zeilen durchgeführt wurden.

X	X>42	X=NULL	X IS NULL	X IS NOT NULL
18	f	u	f	w
66	w	u	f	w
NULL	u	u	w	f

Abb. 6.4: Überprüfung auf NULL-Werte

Überprüfung
auf NULL-Werte

Bei Änderungen oder auch Überprüfungen möchte man häufiger gewisse Aktionen davon abhängig machen, ob ein Attributwert NULL ist. Der direkte Ansatz mit Status=NULL führt nicht zum Erfolg, da NULL-Werte in SQL wegen ihrer Besonderheit anders geprüft werden müssen. Solche direkten Überprüfungen haben immer in der Auswertung das Ergebnis „undefiniert“. Die korrekte Überprüfung auf NULL-Werte findet in SQL mit Status IS NULL bzw. Status IS NOT NULL statt. Die letzte Bedingung ist gleichwertig zu NOT (Status IS NULL). Die unterschiedlichen Auswertungen von Bedingungen bezüglich der NULL-Werte sind in Abb. 6.4 dargestellt.

Änderung von
NULL-Einträgen

Sollen die Lücken, also die NULL-Werte, in der Tabelle Verkaeuer sinnvoll gefüllt werden, so kann man z. B. folgende UPDATE-Befehle nutzen:

```
UPDATE Verkaeuer
SET Gehalt=1300
WHERE Gehalt IS NULL;
UPDATE Verkaeuer
SET Status='Junior'
WHERE Status IS NULL;
SELECT * FROM Verkaeuer
```


Die resultierende Tabelle sieht wie folgt aus.:

VNR	NAME	STATUS	GEHALT
1002	Ute	Senior	1995
1004	Ulf	Senior	1300
1005	Urs	Senior	1365
1006	Uta	Junior	1500

6.5

Constraints

Bereits im ersten Unterkapitel „6.1 Tabellendefinition mit SQL“ wurden mit der Angabe des Primärschlüssels und der Fremdschlüssel erste Randbedingungen, so genannte *Constraints* definiert. In diesem Unterkapitel werden weitere Möglichkeiten ergänzt, so dass möglichst nur gewünschte Daten eingetragen werden können.

*Vermeidung
von NULL-
Einträgen*

Nachdem bereits die Problematik mit NULL-Werten gezeigt wurde, ist es sinnvoll anzugeben, dass eine Spalte keine NULL-Werte enthalten darf. Dies soll natürlich nur geschehen, wenn auch in der Realität für diese Spalte keine NULL-Werte zu erwarten sind. Für Constraints, die sich nur auf ein Attribut beziehen, gibt es zwei verschiedene Möglichkeiten, dies in der Tabellendefinition festzuhalten. Diese Möglichkeiten werden in der folgenden Definition gezeigt.

```
CREATE TABLE Verkaeuer(
  Vnr INTEGER,
  Name VARCHAR(6) NOT NULL,
  Status VARCHAR(7) DEFAULT 'Junior'
  CONSTRAINT StatusHatWert
  Check(Status IS NOT NULL),
  Gehalt INTEGER,
  PRIMARY KEY (Vnr),
  CONSTRAINT GehaltImmerAngegeben
  CHECK(Gehalt IS NOT NULL)
)
```

Die einfachste Möglichkeit besteht darin, direkt nach der Attributdefinition „NOT NULL“ zu ergänzen. Alternativ kann nach der Attributdefinition mit Attributnamen, Typ und der optionalen Angabe eines Standardwertes ein Constraint definiert werden. Diese Constraints haben folgende Syntax:

```
CONSTRAINT <ConstraintName> CHECK ( <Bedingung> )
```

*Benennungsmöglichkeit für
Constraints*

Dabei kann „CONSTRAINT <ConstraintName>“ weggelassen werden. Bei Datenbankmanagement-Systemen, die eng dem SQL-Standard folgen, gibt es diese Möglichkeit zur Constraint-

Benennung sogar nicht. Grundsätzlich ist es sinnvoll, hier einen möglichst lesbaren Namen zu vergeben, da der Name auch in Fehlermeldungen erscheint. Constraintnamen müssen über alle Tabellen unterschiedlich sein. Um dies zu gewährleisten, fangen in größeren Projekten Constraintnamen häufig mit dem Namen der Tabelle an.

Spalten- und Tabellenconstraints

Neben der Möglichkeit, Constraints für Spalten anzugeben, kann man auch Constraints für die gesamte Tabelle definieren. Im obigen Beispiel sieht man, dass das Constraint für Gehalt getrennt von der Definition des Attributes angegeben wird.

Generell können alle *Spaltenconstraints* auch als *Tabellenconstraints* angegeben werden. In der Praxis muss man sich vor der Definition der Tabellen auf einen einheitlichen Stil einigen. Typisch ist es, Angaben, wie „NOT NULL“ direkt beim Attribut stehen zu lassen und komplexere Spaltenconstraints nach der Definition der Attribute aufzuführen.

Primärschlüssel können nicht NULL sein

Bei der Tabellendefinition fällt auf, dass für Vnr keine Angabe „NOT NULL“ erfolgt. Dies ist bei Primärschlüsseln nicht notwendig, da dies bereits durch die Schlüsseleigenschaft garantiert wird.

Für den Aufbau der Bedingungen und den Umgang mit NULL-Werten gelten die im Unterkapitel „6.4 NULL-Werte und dreiwertige Logik“ beschriebenen Regeln. Möchte man z. B. garantieren, dass die Verkäufersnummer Vnr immer größer-gleich 1000 ist, kann man dies entweder direkt beim Attribut

```
Vnr INTEGER CONSTRAINT Vierstellig  
CHECK (Vnr >= 1000)
```

oder als zusätzliches Constraint getrennt von der Attributdefinition definieren:

```
CONSTRAINT Vierstellig CHECK (Vnr >= 1000)
```

Prüfung von Constraints

Für die Beachtung von Constraints bei Veränderungen der Tabelleninhalte gelten die gleichen Regeln wie bei Fremdschlüsseln. Wird ein Constraint nach „false“ ausgewertet, wird die gesamte Aktion auf der Tabelle abgebrochen. Zu beachten ist, dass einzelne Datenbank-Managementsysteme einen anderen Ansatz haben und fordern, dass Constraints erfüllt sein müssen, also nach „wahr“ ausgewertet werden müssen. D. h., bei der Standarddefinition verstoßen Auswertungen nach „unbekannt“ nicht gegen Constraints, bei anderen Datenbank-Managementsystemen füh-

*Constraints für
mehrere Spalten*

ren Constraint-Auswertungen nach „unbekannt“ zum Abbruch der Aktion.

Neben den Constraints, die sich nur auf eine Spalte beziehen, kann es auch Constraints geben, die Werte in mehreren Spalten berücksichtigen. Diese Tabellenconstraints müssen als eigenständige Constraints nach der Definition der Attribute angegeben werden.

*Übersetzung
von Wenn-
Dann-
Bedingungen*

Als Beispiel soll ein Constraint für die Tabelle Verkäufer ergänzt werden, dass jemand mit dem Status Junior maximal 2000 verdient. Diese informelle Formulierung muss in eine logische Bedingung übertragen werden. Ohne hier eine detaillierte Einführung in die Logik zu geben, hier sei z. B. auf [Sch04] verwiesen, muss man sich überlegen, welche einzelnen Bedingungen eine Rolle spielen. Diese sind `Status='Junior'` und `Gehalt<=2000`. Der erste Gedanke zur Formulierung des Constraints könnte wie folgt lauten.

```
CONSTRAINT SchlechteFormalisierung
CHECK (Status='Junior' AND Gehalt<=2000)
```

Dieser Ansatz ist nicht gelungen, da bei einer genauen Analyse der Bedingung folgt, dass nur noch Einträge möglich sind, bei denen der `Status='Junior'` ist beziehungsweise Status den Wert NULL hat. Ist das nicht der Fall, wird das Constraint garantiert nach „falsch“ ausgewertet, was zum Abbruch der Eintrags- oder Änderungsaktion führt.

In Abb. 6.5 wird genauer analysiert, was für eine Bedingung eigentlich gesucht wird. Wichtig ist das Resultat, dass, wenn der Status nicht Junior ist, das gewünschte Constraint nicht verletzt werden kann. Die letzte Spalte in der Abbildung zeigt, dass man das gleiche Ergebnis erhält, wenn man die Bedingung aus der Kopfzeile auswertet.

Status= 'Junior'	Gehalt <=2000	Wenn Status Ju- nior, dann maxi- males Gehalt 2000	NOT (Status= 'Junior') OR Gehalt<=2000
w	w	w	w
w	f	f	f
w	u	u	u
f	w	w	w
f	f	w	w
f	u	w	w
u	w	w	w
u	f	u	u
u	u	u	u

Abb. 6.5: Analyse einer Wenn-Dann-Bedingung

Man kann festhalten, dass Constraints der Form „Wenn A gilt, dann muss auch B gelten“ immer in der Form „NOT(A) OR B“ übersetzt werden können. Das gesuchte Constraint lautet also:

```
CONSTRAINT GehaltsgrenzeJunior
CHECK (NOT (Status='Junior')
      OR Gehalt<=2000)
```

UNIQUE zur
Kennzeichnung
eindeutiger In-
halte

Im Kapitel 4 wurde beschrieben, dass eine Tabelle mehrere Schlüsselkandidaten haben kann und dass man dann für die weitere Realisierung einen konkreten Schlüsselkandidaten als Primärschlüssel auswählt. Diese Information, dass ein weiterer Schlüssel vorliegt, kann durch das UNIQUE-Constraint ausgedrückt werden. Durch die Angabe von UNIQUE wird garantiert, dass es in den dazu genannten Spalten nur einmal diesen Wert bzw. das Werte-Tupel gibt. Ist nur eine Spalte betroffen, kann das Constraint wieder als Spaltenconstraint ergänzt werden. Sollen mehrere Constraints direkt nach der Definition eines Attributes stehen, werden diese direkt ohne trennendes Komma hintereinander geschrieben. Ein Beispiel für die Tabelle Verkäufer könnte sein, dass die Namen der Verkäufer alle unterschiedlich sein sollen. Die zugehörige Zeile lautet

```
Name VARCHAR(6) NOT NULL UNIQUE
```

Dabei hat „NOT NULL“ nicht direkt etwas mit UNIQUE zu tun, es wurde im Beispiel nur ergänzt um zu zeigen, wie mehrere Constraints hintereinander stehen können. Die alternative Schreibweise „UNIQUE NOT NULL“ wäre auch korrekt.

Die gleiche Bedingung kann man auch als Tabellenconstraint angeben. Die gleichwertige Formulierung lautet:

CONSTRAINT EindeutigerName UNIQUE (Name)

X	Y
27	42
27	NULL
NULL	42
NULL	NULL

UNIQUE (X, Y) ergibt „wahr“

UNIQUE (X) ergibt „falsch“

UNIQUE (Y) ergibt „falsch“

Abb. 6.6: Auswertung von UNIQUE

Bei UNIQUE können auch mehrere Spaltennamen angegeben werden. Die Forderung lautet dann, dass die entstehenden Wertkombinationen eindeutig sein sollen. Ein Beispiel ist in Abb. 6.6 angegeben.

Mächtigkeit von Constraints

Betrachtet man, was man alles mit den vorgestellten Constraints beschreiben kann, so sieht man, dass sie wesentlich zur Umsetzung der referenziellen Integrität beitragen und eine gewisse Qualität für die Daten garantieren können.

Die vorgestellten Constraints beziehen sich immer genau auf eine Zeile der Tabelle, was die Ausdrucksmächtigkeit stark einschränkt. Möchte man die Erlaubnis, Daten in eine Tabelle einzutragen, davon abhängig machen, dass die Daten zusammen in der Tabelle eine weitere Eigenschaft haben, z. B. dass der Durchschnitt nicht unter einen bestimmten Wert sinken soll, ist dies mit den vorgestellten Constraints nicht möglich. Noch weitergehende Forderungen, in denen andere Tabellen und ihre Inhalte in die Überprüfung mit einbezogen werden, können ebenfalls mit den vorgestellten Constraints nicht umgesetzt werden.

Assertion

Verschiedene Datenbank-Managementsysteme bieten weitere Möglichkeiten, Überprüfungen zu definieren. Hierzu gehören Zusicherungen, so genannte *Assertions*, in denen Regeln definiert werden können, die mehrere Tabellen zusammen erfüllen sollen und die bei Änderungen vergleichbar wie Constraints überprüft werden können.

Trigger

Eine weitere mächtige Möglichkeit bieten *Trigger*. Diese reagieren, wenn ein bestimmtes Ereignis, wie das Einfügen, Ändern oder Löschen von Daten eintritt und eine weitere definierbare Nebenbedingung zutrifft. Die Reaktion von Triggern kann sehr unterschiedlich sein. Sie können wie Constraints und Assertions überprüfen, ob das Ereignis erlaubt werden soll. Trigger haben aber auch die Möglichkeit, Datenänderungen nach ihren Wün-

schen wieder zu verändern und weitere Aktionen in anderen Tabellen anzustoßen. Ein konkretes Beispiel ist, dass bei einer Einfüge-Aktion der Name des Nutzers und der eingefügte Wert in eine Protokolltabelle eingetragen werden.

6.6

Änderungen von Tabellenstrukturen

Tabellenstrukturen sollen nicht geändert werden

Ergänzung von Tabellen oft unproblematisch

Im Kapitel 2 wurde gesagt, dass Software häufig inkrementell entwickelt wird. Dabei wird in jedem Inkrement neue Funktionalität entwickelt und mit der vorhandenen verknüpft. Dies bedeutet für Tabellen, dass sie verändert werden müssen, neue Spalten hinzukommen, alte gelöscht werden und sich Constraints verändern. Generell bleibt dazu allerdings festzuhalten, dass man möglichst wenige Veränderungen an Tabellen vornehmen sollte, da diese nicht immer möglich sind und durch die aufgebauten Abhängigkeiten zwischen den Tabellen sehr fehlerträchtig sein können. Für die inkrementelle Entwicklung heißt dies, dass man statt auf Tabellenveränderungen eher auf Ergänzungen existierender Tabellen und dem Hinzufügen neuer Tabellen bei steigender Funktionalität zielen sollte.

Betrachtet werden wieder die Tabellen aus Abb. 6.1. Es soll eine Spalte „Klasse“ in der Tabelle Verkaeufer ergänzt werden, in der die Gehaltsklasse steht. Dabei sollen Personen mit einem Gehalt kleiner 1600 in der Klasse A, mit einem Gehalt kleiner 2000 in der Klasse B und die restlichen Personen in der Klasse C eingeordnet werden. Der Befehl zur Veränderung der Tabellenstruktur heißt ALTER. Werden nur Informationen ergänzt, sieht die Syntax genau wie bei der Definition der Tabelle aus. Im Folgenden wird noch ein Constraint hinzugefügt, so dass als Gehaltsklasse nur A, B und C zugelassen sind.

```
ALTER TABLE Verkaeufer ADD(
    Klasse VARCHAR(1),
    CONSTRAINT Klassenwerte CHECK (Klasse='A'
                                   OR Klasse ='B' OR Klasse ='C')
)
```

Die Anfrage

```
SELECT * FROM Verkaeufer
```

ergibt:

VNR	NAME	STATUS	GEHALT	KLASSE
1001	Udo	Junior	1500	
1002	Ute	Senior	1900	
1003	Uwe	Senior	2000	

Spalten ergänzen und füllen erfolgt getrennt

Bei der Ergänzung einer Spalte kann ein Default-Wert angegeben werden. Ist dies nicht der Fall, wird die Spalte mit NULL-Werten gefüllt, d. h. ein Constraint NOT NULL ist nicht nutzbar. Die Füllung der neuen Spalte erfolgt durch normale UPDATE-Befehle, z. B.:

```
UPDATE Verkaeuer
  SET Klasse='A'
  WHERE Gehalt<1600;
UPDATE Verkaeuer
  SET Klasse='B'
  WHERE Gehalt<2000 AND Gehalt>=1600;
UPDATE Verkaeuer
  SET Klasse='C'
  WHERE Gehalt>=2000
```

Die Anfrage

```
SELECT * FROM Verkaeuer
```

ergibt:

VNR	NAME	STATUS	GEHALT	KLASSE
1001	Udo	Junior	1500	A
1002	Ute	Senior	1900	B
1003	Uwe	Senior	2000	C

Erst nachdem Werte in der Tabelle ergänzt wurden, kann man die Definition der Gehaltsklassen mit ihren Grenzen als zusätzliche Constraints hinzufügen.

Constraints können wie folgt gelöscht werden:

```
ALTER TABLE DELETE <Constraintname>
```

*Notwendigkeit
Constraints
auszuschalten*

Neben dem Hinzufügen und Löschen von Constraints können diese ein- und ausgeschaltet werden. Dies ist sinnvoll, wenn man Veränderungen machen möchte, bei denen kurzfristig gegen ein Constraint verstoßen werden muss. Dies ist für das Beispiel der Fall, wenn man die Verkäufersnummer Vnr ändern möchte. Diese soll z. B. fünfstellig werden, wobei bei vorhandenen Nummern einfach eine eins davor geschrieben, also 10000 hinzuaddiert werden soll. Da Vnr ein Fremdschlüssel in der Tabelle Kunde ist, kann die gewünschte Änderung nicht direkt in der Tabelle Verkaeuer stattfinden. Die Veränderung kann aber auch nicht in der Tabelle Kunde starten, da hier nur existierende Verkäufer referenziert werden dürfen.

Zur Durchführung der Änderung muss das Constraint für den FOREIGN KEY zwischenzeitlich abgeschaltet werden. Danach

werden die Änderungen in den dann unverknüpften Tabellen durchgeführt und das Constraint wieder angeschaltet. Die zugehörigen SQL-Befehle lauten:

```
ALTER TABLE Kunde
    DISABLE CONSTRAINT FK_Kunde;
UPDATE Verkaeuer
    SET VNR=VNR+10000;
UPDATE Kunde
    SET Betreuer=Betreuer+10000;
ALTER TABLE Kunde
    ENABLE CONSTRAINT FK_Kunde;
SELECT * FROM Verkaeuer;
SELECT * FROM Kunde
```

Die Ausgabe ist:

VNR	NAME	STATUS	GEHALT	KLASSE
11001	Udo	Junior	1500	A
11002	Ute	Senior	1900	B
11003	Uwe	Senior	2000	C

KNR	NAME	BETREUER
1	Egon	11001
2	Erwin	11001
3	Erna	11002

*Vernetzung von
Constraints be-
achten*

Bei den Änderungen an den Constraints ist zu beachten, dass die Beziehungen über mehrere Tabellen vernetzt sein können und man die Constraints dann auch alle deaktivieren und wieder aktivieren muss. Hier wird auch deutlich, dass es sinnvoll ist, den Constraints eigene Namen zu geben. Im anderen Fall muss man systemabhängig feststellen, welchen internen Namen die Constraints bekommen haben.

6.7

Fallstudie

Die zum Abschluss im Kapitel 3 gezeigten Tabellen können direkt in Tabellendefinitionen umgewandelt werden. Das Ergebnis ist:

```
CREATE TABLE Projekt(
    ProNr INTEGER,
    Name VARCHAR(8),
    PRIMARY KEY (ProNr)
);

INSERT INTO Projekt VALUES(1, 'GUI');
INSERT INTO Projekt VALUES(2, 'WebShop');
```



```
CREATE TABLE Risikogruppe(  
  RGNr INTEGER,  
  Gruppe VARCHAR(13),  
  PRIMARY KEY(RGNr)  
);  
  
INSERT INTO Risikogruppe VALUES(1, 'Kundenkontakt');  
INSERT INTO Risikogruppe VALUES(2, 'Vertrag');  
INSERT INTO Risikogruppe VALUES(3, 'Ausbildung');  
  
CREATE TABLE Risiko(  
  RNr INTEGER,  
  Projekt INTEGER,  
  Text VARCHAR(25),  
  Gruppe INTEGER,  
  Auswirkung INTEGER,  
  WKeit INTEGER,  
  Pruefdatum DATE,  
  PRIMARY KEY (RNr),  
  CONSTRAINT FKRisko1 FOREIGN KEY (Projekt)  
    REFERENCES Projekt(ProNr),  
  CONSTRAINT FKRisko2 FOREIGN KEY (Gruppe)  
    REFERENCES Risikogruppe (RGNr),  
  CONSTRAINT PAuswirkung CHECK(Auswirkung >=0),  
  CONSTRAINT WKeitProzent  
    CHECK(WKeit>=0 AND WKeit<=100)  
);  
  
INSERT INTO Risiko VALUES(1,1,'Anforderungen  
unklar',1,50000,30,'25.01.06');  
INSERT INTO Risiko VALUES(2,1,'Abnahmeprozess  
offen',2,30000,70,'26.02.06');  
INSERT INTO Risiko VALUES(3,2,'Ansprechpartner  
wechseln',1,20000,80,'06.05.06');  
INSERT INTO Risiko VALUES(4,2,'neue  
Entwicklungsumgebung',3,40000,20,'05.10.06');  
  
CREATE TABLE Massnahme(  
  MNr INTEGER,  
  Titel VARCHAR(16),  
  Verantwortlich VARCHAR(7),  
  PRIMARY KEY (Mnr)  
);  
  
INSERT INTO Massnahme  
  VALUES(1,'Vertragspruefung','Meier');  
INSERT INTO Massnahme  
  VALUES(2,'Werkzeugschulung','Schmidt');  
  
CREATE TABLE Zuordnung(  

```

```
Risiko INTEGER,
Massnahme INTEGER,
Pruefdatum DATE,
Status VARCHAR(10),
PRIMARY KEY (Risiko, Massnahme),
CONSTRAINT FKZuordnung1 FOREIGN KEY (Risiko)
REFERENCES Risiko(RNr),
CONSTRAINT FKZuordnung2 FOREIGN KEY
(Massnahme) REFERENCES Massnahme(MNr),
CONSTRAINT Statuswerte CHECK (Status='offen'
OR Status='Fehlschlag' OR Status='Erfolg')
);

INSERT INTO Zuordnung
VALUES (1,1,'20.01.06','offen');
INSERT INTO Zuordnung
VALUES (2,1,'20.02.06','offen');
INSERT INTO Zuordnung
VALUES (4,2,'30.07.06','offen');
```

6.8

Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu beantworten.

1. Erklären Sie, warum sich der SQL-Standard kontinuierlich ändert und wie er in der Praxis umgesetzt wird.
2. Wie werden Tabellen in SQL definiert, wie sehen Schlüssel und Fremdschlüssel aus, wozu gibt es Constraints?
3. Was ist bei Fremdschlüsseln im Zusammenhang mit NULL-Werten zu beachten?
4. Wie werden Daten in Tabellen eingefügt, geändert und gelöscht?
5. Welche Reaktionen können beim Einfügen, Ändern und Löschen auftreten, damit die referenzielle Integrität der Datenbank gewährleistet wird?
6. Welche Möglichkeiten gibt es, Fremdschlüssel zu definieren, welchen Einfluss hat dies auf das Löschen von Daten?
7. Welche Standarddatentypen in SQL kennen Sie, warum gibt es unterschiedliche Typen für Zahlen und Texte?
8. Wofür gibt es CLOBs und BLOBs?

9. Warum hat SQL eine drei-wertige Logik, was ist das überhaupt?
10. Wie werden Constraints ausgewertet?
11. Wie verhalten sich NULL-Werte in mathematischen Operationen wie Plus und Geteilt?
12. Wie kann man NULL-Werte in Spalten ändern?
13. Wie werden „Wenn-dann“-Constraints übersetzt?
14. Wozu gibt es das Schlüsselwort UNIQUE?
15. Wie kann man Tabellen verändern?
16. Wie kann man Werte verändern, die für Fremdschlüssel-Verknüpfungen genutzt werden?

Übungsaufgaben

Gegeben seien folgende Tabellen zur Projektverwaltung:

Projekt

PrNr	PrName	PrLeiter
1	Notendatenbank	Wichtig
2	Adressdatenbank	Wichtig
3	Fehlzeitendatenbank	Wichtig

Arbeitspaket

PrNr	PakNr	PakName	PakLeiter
1	1	Analyse	Wichtig
1	2	Modell	Wichtig
1	3	Implementierung	Mittel
2	4	Modell	Durch
2	5	Implementierung	Mittel
3	6	Modell	Schnitt
3	7	Implementierung	Hack

Arbeit

PakNr	MiName	Anteil
1	Wichtig	50
1	Klein	30
2	Winzig	100
3	Hack	70
4	Maler	40
4	Schreiber	30
6	Maler	30
6	Schreiber	40
7	Hack	50

1. Geben Sie für die drei Tabellen SQL-Befehle zur Erzeugung der Tabellen und des Inhalts an. Beachten Sie auch Fremdschlüssel, diese sollen zur Löschweitergabe genutzt werden. Für die Tabelle Arbeitspaket sollen folgende Bedingungen aufgenommen werden:

- Kein Eintrag darf leer sein.
 - Die Person Winzig darf nie Arbeitspaketleiter sein.
 - Alle Arbeitspakete mit dem Namen Analyse dürfen nie von der Person Hack geleitet werden.
 - Alle Arbeitspakete mit dem Namen Implementierung müssen von der Person Mittel oder der Person Hack geleitet werden.
2. Wie löscht man das Projekt Notendatenbank, was passiert dabei sonst noch in der Datenbank?
 3. Wie kann das Projekt Fehlzeitendatenbank in Anwesenheitsdatenbank umbenannt werden, wobei die Projektnummer gleichzeitig auf 11 geändert wird?

7

Einfache SQL-Anfragen

Zentrale Aufgabe von Datenbanken ist es, dass sie die Kombination der enthaltenen Informationen ermöglichen. In diesem Kapitel erhalten Sie eine Einführung in die Erstellung von SQL-Anfragen, die zur Verknüpfung der Informationen genutzt werden.

Nachdem im vorherigen Kapitel gezeigt wurde, wie man in SQL Tabellen und ihre Inhalte definiert, soll in diesem und den beiden Folgekapiteln gezeigt werden, wie man durch Anfragen Informationen aus der Datenbank gewinnen kann. Zunächst geht es nur darum, die aktuell in den Tabellen eingetragenen Informationen abzurufen. Danach soll gezeigt werden, wie man durch die Kombination von Tabellen und die geschickte Formulierung von Verknüpfungsbedingungen zu weiteren Erkenntnissen kommen kann.

In diesem Kapitel wird zunächst die grundlegende Struktur von SQL-Anfragen vorgestellt, dabei wird von der Auswertung einer Tabelle bis zur einfachen Verknüpfung mehrerer Tabellen gegangen. Weiterhin werden kleinere Varianten in der Ergebnispräsentation gezeigt.

7.1 Ausgabe der eingegebenen Informationen

Gehege			Tier			Art	
<u>GNr</u>	Gname	Flaeche	<u>GNr</u>	<u>Tname</u>	Gattung	<u>Gattung</u>	MinFlaeche
1	Wald	20	1	Laber	Baer	Baer	8
2	Feld	10	1	Sabber	Baer	Hase	2
3	Weide	9	2	Klopfer	Hase	Schaf	5
			3	Bunny	Hase		
			2	Harald	Schaf		
			3	Walter	Schaf		

Abb. 7.1: Beispieltabellen für Anfragen

*Einfache
SELECT-
Anfrage*

In Abb. 7.1 sind die Tabellen dargestellt, die in diesem Kapitel genauer betrachtet werden sollen. Es gibt verschiedene Gehege mit einer bekannten Größe, es gibt verschiedene Tiergattungen,

von denen der minimale Platzanspruch als Fläche bekannt ist und einige Tiere, die in den Gehegen leben.

Mit der ersten Anfrage sollen alle Namen der eingetragenen Gehege ausgegeben werden. Die zugehörige Anfrage lautet:

```
SELECT Gname
FROM Gehege
```

Das Ergebnis sieht wie folgt aus:

```
GNAME
-----
Wald
Feld
Weide
```

Zur Formulierung einer Anfrage muss bekannt sein, in welchen Tabellen die relevanten Informationen stehen. Dies ist im einfachsten hier betrachteten Fall genau eine Tabelle. Diese Tabelle wird in der FROM-Zeile angegeben. In der SELECT-Zeile steht, welche Attribute, also Spaltenüberschriften, für die Ausgabe interessant sind.

*Reihenfolge der
Anfragerstellung*

An der vorherigen Beschreibung erkennt man bereits, dass man bei der Erstellung von SQL-Anfragen typischerweise erst die FROM-Zeile füllt und dann die SELECT-Zeile schreibt. Für die weiteren Überlegungen ist interessant, dass man als Ergebnis der Anfrage wieder eine Tabelle erhält, von der zwar der Name unbekannt ist, die aber genau eine Spalte mit dem Spaltennamen Gname hat. Die resultierende Tabelle wird nicht gespeichert, das Ergebnis kann nach Beendigung der Anfrage zunächst nicht weiter verarbeitet werden.

*Grundsätzlich:
volle Attributs-
benennung*

Die erste Anfrage ist völlig in Ordnung, allerdings soll als Vorgriff auf die Erstellung komplexerer Anfragen ab jetzt bereits zum ausgewählten Attribut immer die zugehörige Tabelle angegeben werden. Die zugehörige Anfrage lautet:

```
SELECT Gehege.Gname
FROM Gehege
```

Diese Anfrage ergibt genau das gleiche Ergebnis wie die erste Anfrage. Der Vorteil ist, dass man aus der SELECT-Zeile herauslesen kann, zu welcher Tabelle das Attribut gehört. Dies ist zunächst nur etwas mehr Schreibarbeit, wird aber bei komplexeren Anfragen notwendig werden.

Mit der nächsten Anfrage sollen alle Gattungen ausgegeben werden, die in den Gehegen aktuell leben. Die zugehörige Anfrage lautet.

```
SELECT Tier.Gattung
FROM Tier
```

Das Ergebnis ist:

```
GATTUNG
-----
Baer
Baer
Hase
Hase
Schaf
Schaf
```

Standard-Anfrageergebnis mit Doppelten

Vermeidung von mit doppelten Ausgaben

Beim Ergebnis fällt auf, dass die Informationen doppelt ausgegeben werden. Es findet keine automatische Aussortierung doppelter Werte statt. Dies sollte etwas verwundern, da das Ergebnis wieder eine Tabelle ist und in Tabellen doppelte Werte vermieden werden sollen. Diese Vermeidung von Doppelten bei der Ausgabe muss man explizit in SQL angeben. Dazu benutzt man das Schlüsselwort `DISTINCT`, das, wenn nötig, immer direkt hinter `SELECT` steht. Will man Doppelte im Beispiel vermeiden, so lautet die Anfrage:

```
SELECT DISTINCT Tier.Gattung
FROM Tier
```

Das Ergebnis ist:

```
GATTUNG
-----
Baer
Hase
Schaf
```

Doppelte werden in Ergebnissen von SQL-Anfragen nicht sofort gelöscht, da der Anfragersteller eventuell daran interessiert ist, dass die Anfrage mehrfach beantwortet werden kann. Bei komplexeren Anfragen besteht die Möglichkeit, die Anzahl der gleichen Werte zu zählen, was bei einer automatischen Eliminierung der Doppelten nicht mehr möglich wäre.

mehrere Ergebnisattribute in Anfrage

Statt nur eines Attributes, können auch mehrere Attribute bei der Ausgabe berücksichtigt werden, diese Attribute sind in der `SELECT`-Zeile mit Kommata zu trennen. Soll der Tiername zusammen mit der Gattung ausgegeben werden, ist dies durch folgende Anfrage möglich:

```
SELECT Tier.Tname, Tier.Gattung
FROM Tier
```

Das Ergebnis lautet:

TNAME	GATTUNG
-----	-----
Laber	Baer
Sabber	Baer
Klopfer	Hase
Bunny	Hase
Harald	Schaf
Walter	Schaf

*Ausgaben gan-
zer Tabellen*

Möchte man sich den gesamten Tabelleninhalt ansehen, so muss statt der Attribute ein `*` stehen. Der gesamte Inhalt der Tabelle Gehege kann wie folgt ausgegeben werden:

```
SELECT *
FROM Gehege
```

Das Ergebnis lautet:

GNR	GNAME	FLAECHE
-----	-----	-----
1	Wald	20
2	Feld	10
3	Weide	9

Zu beachten ist, dass mit dem `*` immer alle Einträge ausgegeben werden. Möchte man auch nur ein Attribut weglassen, müssen alle Attribute explizit in der `SELECT`-Zeile genannt werden.

*Berechnungen
in der SELECT-
Zeile*

Neben der Auswahl der auszugebenden Attribute kann man in der `SELECT`-Zeile auch einige Operationen auf den Attributen durchführen. Für Zahlenwerte besteht die Möglichkeit, diese mit den mathematischen Standardfunktionen `+`, `-`, `*` und `/` zu verknüpfen. Bei Texten gibt es die spezielle Möglichkeit, diese durch den Konkatenations-Operator `||` zusammen zu hängen. Dabei können Attribute mit Attributen und Konstanten verknüpft werden. Geht man davon aus, dass der Zoo eine Gesamtfläche von 50 hat, berechnet die folgende Anfrage den prozentualen Anteil eines jeden Geheges an der Gesamtfläche.

```
SELECT Gehege.Gname, (Gehege.Flaeche/50)*100
FROM Gehege
```

Das Ergebnis der Anfrage lautet:

GNAME	(GEHEGE.FLAECHE/50)*100
-----	-----

Wald	40
Feld	20
Weide	18

Verknüpfung von Texten

Möchte man die Gattung eines Tieres zusammen mit dem Tiernamen, getrennt durch zwei Doppelpunkte ausgeben, so liefert folgende Anfrage das gewünschte Ergebnis.

```
SELECT Tier.Gattung || '::' || Tier.Tname
FROM Tier
```

Das Ergebnis der Anfrage lautet:

```
TIER.GATTUNG||'::'
-----
Baer::Laber
Baer::Sabber
Hase::Klopfer
Hase::Bunny
Schaf::Harald
Schaf::Walter
```

In den Ergebnissen der letzten Anfragen fällt auf, dass als Spaltenüberschriften der Ergebnisse die Berechnungsvorschrift gewählt wurde, die bei der Ausgabe eventuell verkürzt dargestellt wird. Dies ist bis jetzt eher ein ästhetisches Problem, wird aber später problematisch, wenn berechnete Tabellen in komplexeren Anfragen genutzt werden sollen. Hier ist es sinnvoll, Spalten im Ergebnis umzubenennen. Dies ist relativ einfach in der `SELECT`-Zeile möglich. Dazu muss der gewünschte Ergebnisname nach dem Attribut oder der berechneten Spalte genannt werden. Eine Umbenennung von `Gname` in `Gatter` im Ergebnis ist z. B. durch

Umbenennung von Ergebnis- spalten

```
SELECT Gehege.Gname Gatter
```

möglich. Im SQL-Standard kann vor dem Ergebnisspaltennamen ein `AS` stehen. In diesem Punkt unterscheiden sich Datenbank-Managementsysteme, da einige ein `AS` fordern, weitere das `AS` als Fehler kennzeichnen und die restlichen beide Varianten zulassen. In der zweiten Variante würde die `SELECT`-Zeile wie folgt heißen:

```
SELECT Gehege.Gname AS Gatter
```

Diese Umbenennungen erfolgen in gleicher Form auch bei berechneten Spalten. Ein Beispiel liefert folgende Anfrage.

```
SELECT Gehege.Gname Gatter,
       Gehege.Flaeche*10000 Quadratzentimeter
FROM Gehege
```

Das Ergebnis der Anfrage ist:

GATTER	QUADRATZENTIMETER
Wald	200000
Feld	100000
Weide	90000

Erzeugung weiterer Ergebnis-spalten

Neben der Umbenennung ist es auch möglich, in der SELECT-Zeile neue Spalten mit Werten zu definieren. Diese neuen Werte werden dann in alle Ergebniszeilen eingebaut. Wird auf eine Umbenennung im Ergebnis verzichtet, wird der Wert als Spaltenname genutzt. Der Nutzen dieser Möglichkeit wird erst in späteren Kapiteln eingehender besprochen. Eine Anfrage zur Anschauung lautet:

```
SELECT 'Unser Zoo' Zooname, Tier.Tname Tiername,
       2005 Einzug, 42
FROM Tier
```

Das Ergebnis der Anfrage ist:

ZOONAME	TIERNAME	EINZUG	
Unser Zoo	Laber	2005	42
Unser Zoo	Sabber	2005	42
Unser Zoo	Klopfer	2005	42
Unser Zoo	Bunny	2005	42
Unser Zoo	Harald	2005	42
Unser Zoo	Walter	2005	42

Ausgabe- muss nicht Eingabe-reihenfolge sein

Hersteller von Datenbank-Managementsystemen können selbst entscheiden, in welcher Reihenfolge eingegebene Daten abgespeichert werden. Um bei Anfragen eine schnellere Laufzeit zu garantieren, müssen die Daten in der Datenbank nicht in der Reihenfolge vorliegen, in der sie gespeichert wurden. Bei den bisherigen Beispielen war es Zufall, dass die Ausgabereihenfolgen den Reihenfolgen der Dateneingaben entsprachen.

Sortierung von Ausgaben

Um eine feste Ausgabereihenfolge zu garantieren, kann man die SQL-Anfrage um eine Zeile mit ORDER BY erweitern in der angegeben wird, nach welchem Attribut die Ausgabe sortiert werden soll. Dabei kann nach dem Attribut ASCENDING oder ASC für eine aufsteigende und DESCENDING oder DESC für eine absteigende Reihenfolge stehen. Ohne zusätzliche Angabe wird automatisch ASC als Sortierreihenfolge angenommen. Die folgende Anfrage ermöglicht es, die Gehege mit aufsteigender Größe auszugeben.

```
SELECT Gehege.Gname, Gehege.Flaeche
FROM Gehege
ORDER BY Gehege.Flaeche ASC
```

Das Ergebnis lautet:

GNAME	FLAECHE
Weide	9
Feld	10
Wald	20

*Möglichkeiten
für Sortier-
richtung*

Mit folgender Anfrage werden die Gattungen absteigend bezüglich ihres Flächenbedarfs ausgegeben.

```
SELECT Art.Gattung, Art.MinFlaeche
FROM Art
ORDER BY Art.MinFlaeche DESC
```

Das Ergebnis lautet:

GATTUNG	MINFLAECHE
Baer	8
Schaf	5
Hase	2

*mehrere Sor-
tierkriterien zu-
sammen*

Man kann die Sortierkriterien auch verknüpfen, dabei wird zunächst nach dem erstgenannten Kriterium sortiert; sind dann Werte gleich, wird das nächste Sortierkriterium genutzt. Mit der folgenden Anfrage werden alle Tiere absteigend nach ihrer Gattung und bei gleicher Gattung aufsteigend nach ihrem Namen sortiert.

```
SELECT *
FROM Tier
ORDER BY Tier.Gattung DESC, Tier.Tname ASC
```

Das Ergebnis lautet:

GNR	TNAME	GATTUNG
2	Harald	Schaf
3	Walter	Schaf
3	Bunny	Hase
2	Klopfer	Hase
1	Laber	Baer
1	Sabber	Baer

7.2

*Bedeutung von
WHERE-
Bedingungen*

Auswahlkriterien in der WHERE-Bedingung

Bisher wurden einzelne Spalten aus den gegebenen Tabellen selektiert. Meist ist man aber an genau den Tabelleninhalten interessiert, die bestimmte Auswahlkriterien erfüllen. Ein Beispiel ist

die Anfrage nach den Namen aller Schafe. Die zugehörige SQL-Anfrage lautet:

```
SELECT Tier.Tname
FROM Tier
WHERE Tier.Gattung='Schaf'
```

Das Ergebnis der Abfrage ist:

```
TNAME
-----
Harald
Walter
```

Die Auswahlkriterien werden in der WHERE-Bedingung festgelegt. Der grundsätzliche Aufbau einer solchen Bedingung ist im Unterkapitel „6.4 NULL-Werte und drei-wertige Logik“ beschrieben. Die Möglichkeiten, die sich durch die geschickte Formulierung der WHERE-Zeile ergeben, werden auch zentrales Thema der beiden folgenden Kapitel sein.

zusammengesetzte Bedingungen

Ein Beispiel für eine zusammengesetzte Bedingung liefert die Anfrage nach Gattungen, die mindestens eine Fläche von 4 beanspruchen, aber keine Bären sind. Die Anfrage lautet:

```
SELECT Art.Gattung
FROM Art
WHERE Art.MinFlaeche>=4
AND Art.Gattung<>'Baer'
```

Das Ergebnis der Anfrage ist:

```
GATTUNG
-----
Schaf
```

Textanalyse

Neben den bisher vorgestellten exakten Vergleichen mit Textwerten wie 'Baer' bietet SQL die Möglichkeit, nach Teiltextritten suchen zu lassen. In der Informatik werden für solche Textvergleiche sehr häufig reguläre Ausdrücke, siehe z. B. [EMS00], genutzt, die im SQL-Standard aber nur ansatzweise unterstützt werden. In diesem Bereich gibt es häufig individuelle Ergänzungen in verschiedenen Datenbank-Managementsystemen. Im Standard gibt es zwei Möglichkeiten, dabei steht ein % für beliebig viele Zeichen und ein _ für genau ein beliebiges Zeichen. Der Textvergleich erfolgt mit dem Schlüsselwort LIKE. Sucht man nach Tiernamen, die ein „a“ enthalten, so möchte man am Anfang des Namens beliebige Zeichen, gefolgt von einem „a“, dem dann wieder beliebige Zeichen folgen können. Die zugehörige Anfrage lautet:

```
SELECT Tier.Tname
FROM Tier
WHERE Tier.Tname LIKE '%a%'
```

Das Ergebnis ist:

```
TNAME
-----
Laber
Sabber
Harald
Walter
```

Generell muss bei solchen Textvergleichen die Groß- und Kleinschreibung beachtet werden. Ein Tier mit Namen „Anton“ würde mit der letzten Anfrage nicht gefunden werden.

Sucht man nach Tiernamen, deren dritter Buchstabe ein „n“ ist, so möchte man am Anfang genau zwei beliebige Zeichen haben, denen ein „n“ folgt, dem dann beliebige Zeichen folgen können. Die zugehörige Anfrage lautet:

```
SELECT Tier.Tname
FROM Tier
WHERE Tier.Tname LIKE '__n%'
```

Das Ergebnis ist:

```
TNAME
-----
Bunny
```

Um deutlich zu machen, dass Texte verglichen werden, kann man statt `Art.Gattung<>'Baer'` auch

`Art.Gattung NOT LIKE 'Baer'` oder

`NOT (Art.Gattung LIKE 'Baer')` schreiben.

Fluchtsymbole

Bei kritischer Betrachtung stellt sich die Frage, wie man direkt nach den Zeichen % und _ suchen kann. In diesem Fall muss man ein Zeichen mit `ESCAPE` als so genanntes *Fluchtsymbol* auswählen. Dieses Zeichen hat dann die Bedeutung, dass es selber nicht beachtet wird und dass das nächste Zeichen direkt gesucht, also nicht interpretiert werden soll. Zur Suche nach dem %-Zeichen in unseren Tiernamen benötigen wir am Anfang beliebig viele Zeichen, dann ein %, das in der folgenden Anfrage durch das hier ausgewählte Fluchtsymbol / gekennzeichnet ist, dem dann wieder beliebige Zeichen folgen können. Die zugehörige Anfrage, die im konkreten Beispiel keine Ergebniszeile liefert, lautet:

```
SELECT Tier.Tname
FROM Tier
WHERE Tier.Tname LIKE '%/%%' ESCAPE '/'
```

Sollte man auch noch nach dem Zeichen / suchen wollen, so muss im Vergleichstext // stehen, dabei wird das erste Zeichen als Fluchtsymbol gedeutet und sorgt dafür, dass nach dem direkt folgenden Zeichen gesucht wird.

Operationen auf Attributen

Oftmals ist man sich nicht sicher, ob wirklich alle Namensbestandteile groß geschrieben sind. Für dieses Problem stellt der SQL-Standard einige Funktionen zur Verfügung, mit denen Texte lokal bearbeitet werden können. Die Anzahl und Mächtigkeit solcher Funktionen, die es auch für andere Datentypen geben kann, hängt vom Datenbank-Managementsystem ab. Will man z. B. nach den Namen aller Schafe suchen, weiß aber nicht mehr, ob die Gattungen klein oder groß geschrieben sind, kann man Texte in kleine Buchstaben mit der Funktion LOWER umwandeln. Die Funktionen können auch in der Ausgabe genutzt werden, wie folgende Anfrage zeigt:

Groß- und Kleinschreibung ändern

```
SELECT LOWER(Tier.Tname)
FROM Tier
WHERE LOWER(Tier.Gattung)='schaf'
```

Das Ergebnis der Anfrage ist:

```
LOWER(T
-----
harald
walter
```

Neben LOWER können Texte mit UPPER in Großbuchstaben verwandelt werden.

Im Ergebnis der Anfrage wurde die Spaltenüberschrift abgeschnitten, da sie der maximalen Länge der Texte laut Tabellendefinition angepasst wurde. Hier ist es sinnvoll, die Spalten im Ergebnis umzubenennen.

Ein ergänzendes Beispiel liefert die folgende Anfrage

```
SELECT UPPER(Tier.Tname) Gross,
       LOWER (Tier.Tname) Klein, Tier.Tname Normal
FROM Tier
```

Das Ergebnis der Anfrage ist:

GROSS	KLEIN	NORMAL
-----	-----	-----
LABER	laber	Laber
SABBER	sabber	Sabber

KLOPFER	klopfer	Klopfer
BUNNY	bunny	Bunny
HARALD	harald	Harald
WALTER	walter	Walter

Umgang mit NULL-Werten in WHERE- Bedingung

Die Auswertung einer SQL-Anfrage läuft so, dass für alle Tabellenzeilen geprüft wird, ob die WHERE-Bedingung nach „wahr“ ausgewertet werden kann. Ist das der Fall, wird die Zeile ins Ergebnis übernommen. Zur Ergebnisausgabe werden dann die in der SELECT-Zeile genannten Attribute ausgewählt. Wichtig ist im Zusammenhang mit NULL-Werten, dass ausschließlich Zeilen für das Ergebnis in Frage kommen, für die eine Auswertung der WHERE-Bedingung nach „wahr“ erfolgt. Auswertungen nach „unbekannt“ gehen nicht in das Ergebnis ein. Dies soll durch folgendes Beispiel verdeutlicht werden:

Es wird folgende Tabelle mit drei Einträgen konstruiert:

```
CREATE TABLE Person(
  Pnr INTEGER,
  Name VARCHAR(5),
  Gehalt INTEGER,
  PRIMARY KEY (Pnr)
);
INSERT INTO Person VALUES (1, 'Eddy', 2500);
INSERT INTO Person VALUES (2, 'Egon', NULL);
INSERT INTO Person VALUES (3, 'Erna', 1700)
```

Die Anfrage nach Personen, die weniger als 2000 verdienen lautet:

```
SELECT Person.Name
FROM Person
WHERE Person.Gehalt < 2000
```

Das Ergebnis ist:

```
NAME
-----
Erna
```

Man sieht, dass NULL < 2000 nach „unbekannt“ ausgewertet wird und dass der zugehörige Name nicht im Ergebnis erscheint. Ist man in diesem Fall daran interessiert, auch die NULL-Werte zu berücksichtigen, ist dies explizit anzugeben. Die Anfrage lautet dann:

```
SELECT Person.Name
FROM Person
WHERE Person.Gehalt < 2000
OR Person.Gehalt IS NULL
```

Das zugehörige Ergebnis ist:

```
NAME
-----
Egon
Erna
```

7.3

Nutzung von Aggregatsfunktionen

In SQL gibt es relativ einfache Funktionen, die gewisse statistische Auswertungen erlauben. Die Möglichkeiten des SQL-Standards werden hier vorgestellt.

*Maximumsbe-
rechnung*

Die größte Gehegefläche wird durch folgende Anfrage bestimmt.

```
SELECT MAX(Gehege.Flaeche)
FROM Gehege
```

Das Ergebnis lautet:

```
MAX(GEHEGE.FLAECHE)
-----
20
```

Im Zusammenhang mit dieser Anfrage möchte man typischerweise auch den Namen des Ergebnisses ausgeben. Der erste Lösungsansatz lautet:

*typischer Fehler
bei Nutzung
von Aggregats-
funktionen*

```
SELECT Gehege.Gname, MAX(Gehege.Flaeche)
FROM Gehege
```

Dieser Ansatz ist falsch und stellt bei der ersten Beschäftigung mit SQL einen häufig auftretenden Fehler dar. Das Problem ist, dass jetzt jeder Gehege-Name und nur ein Maximalwert ausgegeben werden soll.

Ein vorstellbarer Ansatz, dass der Maximalwert in jede Spalte eingetragen werden soll, wird in SQL so nicht unterstützt. Wie man den Namen zum größten Gehege systematisch findet, ist ein Thema im Kapitel 9.

Typischerweise werden Ergebnisspalten von Aggregatsfunktionen umbenannt, um ein lesbareres Ergebnis zu erhalten. Die folgende Anfrage gibt die kleinste Fläche eines Geheges aus:

*Minimumsbe-
rechnung*

```
SELECT MIN(Gehege.Flaeche) KleinsteFlaeche
FROM Gehege
```

Das Ergebnis lautet:

```
KLEINSTEFLAECHE
-----
9
```


Die Gesamtfläche aller Gehege wird durch folgende Anfrage berechnet:

```
SELECT SUM(Gehege.Flaeche) Gesamtflaeche
FROM Gehege
```

Das Ergebnis lautet:

```
GESAMTFLAECHE
-----
39
```

*zählen mit und
ohne Doppelten
und NULL-
Werten*

Mit der COUNT-Funktion wird die Zahl der Zeilen im Ergebnis berechnet. Die Gesamtzahl aller Tiere kann also durch folgende Anfrage berechnet werden:

```
SELECT COUNT(*) Tieranzahl
FROM Tier
```

Das Ergebnis der Anfrage lautet:

```
TIERANZAHL
-----
6
```

*zählen ohne
NULL-Werte*

Man kann in den Klammern von COUNT ein Attribut angeben. Dann werden alle Zeilen gezählt, in denen das Attribut nicht den Wert NULL hat. Die folgende Anfrage hat dabei das exakt gleiche Ergebnis wie die vorherige Anfrage.

```
SELECT COUNT(Tier.Gattung) Tieranzahl
FROM Tier
```

Beim Zählen kann man explizit fordern, dass doppelte Werte weggelassen werden. Dazu wird in den Klammern von COUNT das bereits bekannte Schlüsselwort DISTINCT dem Spaltennamen vorangestellt. Die Anzahl unterschiedlicher, im Zoo vertretener Gattungen kann damit wie folgt bestimmt werden:

```
SELECT COUNT(DISTINCT Tier.Gattung) Arten
FROM Tier
```

Das Ergebnis lautet:

```
ARTEN
-----
3
```

Gehaelter	
Name	Gehalt
Olaf	2000
Otto	
Omar	
Onno	2000
Oka	1000

Abb. 7.2: Analyse von COUNT bei NULL-Werten

Beim COUNT stellt sich die Frage, wie mit NULL-Werten umgegangen wird. Dies soll durch folgendes kleines Beispiel verdeutlicht werden. Dabei wird die Tabelle aus Abb. 7.2 zunächst in SQL umgesetzt:

```
CREATE TABLE Gehaelter(  
  Name VARCHAR(5),  
  Gehalt INTEGER,  
  PRIMARY KEY (Name)  
);  
INSERT INTO Gehaelter VALUES('Olaf', 2000);  
INSERT INTO Gehaelter VALUES('Otto', NULL);  
INSERT INTO Gehaelter VALUES('Omar', NULL);  
INSERT INTO Gehaelter VALUES('Onno', 2000);  
INSERT INTO Gehaelter VALUES('Oka', 1000);
```

Folgende Anfrage zeigt die COUNT-Varianten:

```
SELECT COUNT(*) A,  
       COUNT(Gehaelter.Gehalt) B,  
       COUNT(DISTINCT Gehaelter.Gehalt) C  
FROM Gehaelter
```

Das Ergebnis lautet

A	B	C
5	3	2

Man erkennt, dass NULL-Werte durch die Angabe einer konkreten Spalte nicht berücksichtigt werden.

*Durchschnitts-
berechnung*

Durch die Funktion AVG, englisch für „average“, wird der Durchschnitt von Spaltenwerten berechnet. Diese Berechnung macht wie bei SUM nur Sinn, wenn Zahlenwerte in der Tabelle stehen. Die durchschnittliche Gehegegröße wird durch folgende Anfrage berechnet:

```
SELECT AVG(Gehege.Flaeche) Durchschnitt
FROM Gehege
```

Das Ergebnis der Anfrage ist:

```
DURCHSCHNITT
-----
13
```

Bei der Berechnung von AVG werden NULL-Werte ignoriert, deshalb kann eine Berechnung

Summe aller Spaltenelemente / Anzahl aller Zeilen

zu Ergebnissen kommen, die von der AVG-Berechnung abweichen können. Dies wird durch folgende Anfrage verdeutlicht, in der auch der Zusammenhang zu COUNT dargestellt ist.

```
SELECT AVG(Gehaelter.Gehalt) Schnitt,
       SUM(Gehaelter.Gehalt)/COUNT(*) Schnitt2,
       SUM(Gehaelter.Gehalt)/
         COUNT(Gehaelter.Gehalt) Schnitt3
FROM Gehaelter;
```

Das Ergebnis der Anfrage lautet:

```
      SCHNITT      SCHNITT2      SCHNITT3
-----
1666,66667      1000 1666,66667
```

7.4

Anfragen über mehrere Tabellen

Bisher bezogen sich alle Anfragen auf eine Tabelle. Die meisten interessanten Anfragen beziehen sich aber darauf, dass Informationen aus verschiedenen Tabellen verknüpft werden. Ein Beispiel ist die Anfrage nach den Namen der Tiere zusammen mit der Information über den Namen des Geheges, in dem sie leben. Die zugehörige SQL-Anfrage lautet:

```
SELECT Tier.Tname, Gehege.Gname
FROM Tier,Gehege
WHERE Tier.GNr=Gehege.GNr
```

Das Ergebnis ist:

```
TNAME      GNAME
-----
Laber      Wald
Sabber     Wald
Harald     Feld
Klopfer    Feld
Bunny      Weide
Walter     Weide
```

typische Struktur einer Anfrage über mehrere Tabellen

*Kreuzprodukt-
berechnung in
SQL*

Bei komplexeren Anfragen spielt zunächst der Inhalt der FROM-Zeile eine wichtige Rolle. Hier sind durch Kommata getrennt alle Tabellen anzugeben, die zur Berechnung des Ergebnisses der Anfrage benötigt werden. Aus den dort angegebenen Tabellen wird das Kreuzprodukt berechnet. Dies ist eine Tabelle, in der jeder Eintrag der einen Tabelle mit jedem Eintrag der anderen Tabelle verknüpft wird. Stehen Tabellen mit 5 und mit 7 Zeilen in der FROM-Zeile, so ist das Zwischenergebnis eine Tabelle mit 35 Zeilen. Dies kann man auch durch folgende syntaktisch korrekte SQL-Anfrage verdeutlichen:

```
SELECT *
FROM Tier, Gehege
```

Das Ergebnis der Anfrage ist:

GNR	TNAME	GATTUNG	GNR	GNAME	FLAECHE
---	----	-----	---	----	-----
1	Laber	Baer	1	Wald	20
1	Sabber	Baer	1	Wald	20
2	Klopfer	Hase	1	Wald	20
3	Bunny	Hase	1	Wald	20
2	Harald	Schaf	1	Wald	20
3	Walter	Schaf	1	Wald	20
1	Laber	Baer	2	Feld	10
1	Sabber	Baer	2	Feld	10
2	Klopfer	Hase	2	Feld	10
3	Bunny	Hase	2	Feld	10
2	Harald	Schaf	2	Feld	10
3	Walter	Schaf	2	Feld	10
1	Laber	Baer	3	Weide	9
1	Sabber	Baer	3	Weide	9
2	Klopfer	Hase	3	Weide	9
3	Bunny	Hase	3	Weide	9
2	Harald	Schaf	3	Weide	9
3	Walter	Schaf	3	Weide	9

*Standardweg
der Tabellen-
verknüpfung*

Dieses Zwischenergebnis der Anfrage enthält noch einige für die weiteren Überlegungen unsinnige Zeilen. Diese können durch die WHERE-Bedingung aus dem Ergebnis herausgehalten werden. Typisch, wie im Beispiel der vorgestellten Anfrage, ist, dass man in der WHERE-Bedingung zunächst die Art der Verknüpfung der Tabellen angibt. Dabei beschreibt

```
WHERE Tier.GNr=Gehege.GNr
```

dass der Schlüssel der einen Tabelle der Fremdschlüssel der anderen Tabelle ist, also diese Werte gleich sein müssen. Diese Art der Tabellenverknüpfung tritt in SQL-Anfragen sehr häufig auf.

*Kreuzprodukt
von FROM-
Zeilen-
Einträgen*

In der FROM-Zeile können theoretisch beliebig viele Tabellen stehen, Einschränkungen werden durch das ausgewählte Datenbank-Managementsystem gemacht. Zu beachten ist aber, dass intern immer das Kreuzprodukt aller beteiligten Tabellen berechnet wird, was schnell zu einem enormen Aufwand führen kann. Das Thema „Anfrageoptimierung“ wird zwar in diesem Buch nicht behandelt, man kann aber davon ausgehen, dass jedes bessere Datenbank-Managementsystem optimierte Ansätze hat, das Kreuzprodukt zu bearbeiten, statt zunächst im Speicher das vollständige Kreuzprodukt zu berechnen. Unterschiedliche Optimierungsansätze der existierenden Systeme sorgen für schnellere Berechnungen der Anfrageergebnisse.

*Ausgabe einzelner Tabellen
mit **

Bisher wurde gezeigt, dass mit einem * in der SELECT-Zeile alle Werte ausgegeben werden. Wird mehr als eine Tabelle genutzt, kann man durch <Tabellenname>.* erreichen, dass nur alle Elemente dieser Tabelle angezeigt werden. Als Beispiel wird die vorherige Anfrage leicht modifiziert.

```
SELECT Tier.*, Gehege.Gname
FROM Tier,Gehege
WHERE Tier.GNr=Gehege.GNr
```

Das Ergebnis der Anfrage ist:

GNR	TNAME	GATTUNG	GNAME
1	Laber	Baer	Wald
1	Sabber	Baer	Wald
2	Harald	Schaf	Feld
2	Klopfer	Hase	Feld
3	Bunny	Hase	Weide
3	Walter	Schaf	Weide

Mit der folgenden Anfrage sollen zu jedem Gehegenamen die Gattungen der darin lebenden Tiere ausgegeben werden, die höchstens eine Fläche von 6 verbrauchen.

```
SELECT DISTINCT Gehege.Gname, Art.Gattung
FROM Gehege, Tier, Art
WHERE Gehege.Gnr=Tier.Gnr
AND Tier.Gattung= Art.Gattung
AND Art.MinFlaeche<=6
```

Das Ergebnis der Anfrage ist:

GNAME	GATTUNG
Feld	Hase
Feld	Schaf
Weide	Hase
Weide	Schaf

Zentrales Kochrezept zur Erstellung einfacher Anfragen

Die WHERE-Bedingung kann in zwei Teile zerlegt werden. Der erste Teil beschäftigt sich mit der Verknüpfung der Tabellen. Der zweite Teil steht für die Formulierung besonderer Randbedingungen.

Der grundsätzliche Ansatz zur Formulierung einfacher SQL-Anfragen kann wie folgt zusammengefasst werden:

- (1) Es werden die für die Anfrage erforderlichen Tabellen gesucht und in die FROM-Zeile geschrieben.
- (2) Es wird die Verknüpfung der benutzen Tabellen in der WHERE-Bedingung festgelegt. Typisch ist die Verknüpfung von Primär- und Fremdschlüsseln, die einzelnen Bedingungen werden meist mit AND verknüpft.
- (3) Falls es die Anfrage erfordert, werden die weiteren Anforderungen in Teilbedingungen übersetzt. Die resultierende Teilbedingung wird typischerweise mit AND mit der Bedingung aus (2) verknüpft.
- (4) Es werden die Informationen, z. B. Attribute ausgewählt, die für die Ergebnisausgabe wichtig sind, und in die SELECT-Zeile geschrieben.
- (5) Bei Bedarf wird in der ORDER BY-Zeile angegeben, in welcher Reihenfolge die Ausgaben erfolgen sollen.

Die Schritte (4) und (5) können vorgezogen werden. Sie finden aber typischerweise nach (1) statt.

Lokale Umbenennung von Tabellen in Anfragen

In einem vorherigen Unterkapitel wurde bereits beschrieben, wie man die Spaltennamen im Ergebnis ändern kann. Weiterhin gibt es die Möglichkeit, Tabellennamen lokal für eine Anfrage umzubenennen. Diese Umbenennung findet nur für die Anfrage statt und ist nach der Ausführung der Anfrage nicht mehr nutzbar. Die lokale Umbenennung einer Tabelle findet in der FROM-Zeile direkt nach der Angabe des Tabellennamens statt. Eine FROM-Zeile mit Umbenennung kann lauten:

```
FROM Gehege G, Tier T
```

Wieder abhängig vom verwendeten Datenbank-Managementsystem muss, kann oder darf nicht zwischen dem Tabellennamen und dem lokalen Namen das Schlüsselwort AS stehen. Die vorherige Zeile muss also bei einigen Datenbank-Managementsystemen wie folgt lauten:

```
FROM Gehege AS G, Tier AS T
```

Wichtig ist, dass in der gesamten Anfrage nur noch der lokal vergebene Name genutzt werden kann. Dies gilt auch für die SELECT-Zeile. Es ist also ratsam, die vorher gegebene Konstruktionsbeschreibung zur Erstellung von Anfragen auch beim Lesen von Anfragen zu nutzen. Eine Beispielanfrage, in der gleichzeitig auch die Umbenennung der Ergebnisspalten genutzt wird, lautet:

```
SELECT G.Gname Gebiet, T.Tname Schaf
FROM Gehege G, Tier T
WHERE G.Gnr= T.Gnr
AND T.Gattung='Schaf'
```

Das Ergebnis der Anfrage ist:

```
GEBIET  SCHAF
-----
Feld    Harald
Weide   Walter
```

Auf den ersten Blick sieht es so aus, dass die lokalen Umbenennungen nur die Lesbarkeit verschlechtern. Um dies zu vermeiden, kann man längere, also „sprechende“, Namen verwenden. Die Umbenennung ist aber in gewissen Anfragen notwendig, wie die folgenden Beispiele zeigen.

*Anfrage mit
mehrfachem
Bezug auf eine
Tabelle*

Es soll eine Anfrage geschrieben werden, mit der die Nummern aller Gehege ausgegeben werden, in denen zwei unterschiedliche Gattungen leben. Nach der Konstruktionsvorschrift fällt auf, dass zur Lösung nur die Tabelle Tier benötigt wird. Dies bringt die Lösungsfindung aber wenig voran, da man zwei Informationen aus der Tabelle benötigt. Für diese zwei Einträge muss gelten, dass sie im gleichen Gehege leben und dass sie unterschiedliche Gattungen haben. An dieser Stelle ist es sinnvoll, die lokale Umbenennung einzusetzen, da man so zwei lokale Kopien der gleichen Tabelle zur Verfügung hat. In der WHERE-Bedingung müssen nur die genannten Randbedingungen umgesetzt werden. Die Anfrage lautet:

```
SELECT T1.Gnr
FROM Tier T1, Tier T2
WHERE T1.Gnr=T2.Gnr
AND T1.Gattung <> T2.Gattung
```

Das Ergebnis der Anfrage ist:

```
GNR
-----
2
3
2
3
```

Hintergrund der doppelten Ergebnisse

Es fällt auf, dass es doppelte Ausgaben gibt, die man mit DISTINCT verhindern könnte. Der Grund für die doppelte Ausgabe ist, dass jeder Eintrag der Tabelle Tier mit jedem Eintrag der Tabelle Tier im Kreuzprodukt kombiniert wird. D. h. es gibt eine Zeile mit den Inhalten (2,Hase) und (2, Schaf) und eine weitere Zeile mit den Inhalten (2,Schaf) und (2,Hase), was zur doppelten Ausgabe führt. In diesem Fall hätte man die Doppelten auch vermeiden können, indem die letzte Teilbedingung durch `T1.Gattung < T2.Gattung` ersetzt werden würde.

Möchte man statt der Gehegenummer den Namen des Geheges ausgeben, muss man die Tabelle Gehege mit in die FROM-Zeile aufnehmen und mit den anderen Tabellen verknüpfen. Dabei reicht `Gehege.Gnr=T1.Gnr` aus, da aus `T1.Gnr=T2.Gnr` auch `Gehege.Gnr=T2.Gnr` folgt. Die Anfrage lautet:

```
SELECT Gehege.Gname
FROM Tier T1, Tier T2, Gehege
WHERE T1.Gnr=T2.Gnr
      AND Gehege.Gnr=T1.Gnr
      AND T1.Gattung < T2.Gattung
```

Das Ergebnis der Anfrage ist:

```

GNAME
-----
Feld
Weide
```

Ein zweites Beispiel für die Nutzung einer lokalen Umbenennung ist die Anfrage nach den Gehegenummern, die in der Tabelle Tier mindestens zweimal vorkommen. Wieder werden zwei Einträge der Tabelle Tier benötigt, die sich auf das gleiche Gehege beziehen, aber zu unterschiedlichen Tieren gehören. Die zugehörige Anfrage lautet:

```
SELECT T1.Gnr
FROM Tier T1, Tier T2
WHERE T1.Gnr=T2.Gnr
      AND T1.Tname < T2.Tname
```

Das Ergebnis der Anfrage ist:

```

GNR
-----
1
2
3
```

Da jeder Eintrag mit jedem kombiniert wird, kann die Teilbedingung `T1.Tname < T2.Tname` nicht weggelassen werden. Im

berechneten Kreuzprodukt wird jede Zeile auch mit sich selbst kombiniert, so dass ohne die Teilbedingung eine Zeile mit den Einträgen (1, Laber) und (1, Laber) auch zu einer Ausgabe geführt hätte, ohne dass ein zweiter Eintrag für die Gehegenummer 1 existiert.

Überlegungen zu Kreuzpro- duktberech- nungen

Bei der Auswertung der SQL-Anfrage wird das Kreuzprodukt der beteiligten Tabellen berechnet. Ist jetzt eine der Tabellen leer, so hat dies den Effekt, dass auch das gesamte Kreuzprodukt leer ist, da es keine Kombinationsmöglichkeiten mit dieser Tabelle gibt. Daraus folgt unmittelbar, dass es auch keine Ergebniszeilen geben kann. Dieser eigentlich logische Zusammenhang hat aber für die Praxis und für theoretische Betrachtungen eine besondere Bedeutung. Das durch das beschriebene Verfahren erhaltene Ergebnis entspricht nicht immer den logisch berechneten. Dies kann durch ein recht einfaches Beispiel deutlich gemacht werden. Dazu wird eine kleine inhaltlich sinnlose Tabelle ohne eingetragene Zeilen definiert:

unerwartete leere Ergebnisse

```
CREATE TABLE LeererUnsinn(  
  X VARCHAR(4)  
);
```

Diese Tabelle wird jetzt in einer Anfrage genutzt, in der sie nicht weiter berücksichtigt wird.

```
SELECT Tier.Tname  
FROM Tier, LeererUnsinn
```

Durch die Bildung des Kreuzprodukts erhält man ein Ergebnis der folgenden Art:

Es wurden keine Zeilen ausgewählt

Das obige Beispiel ist eher einfach geraten. Man kann sich überlegen, dass das Datenbank-Managementsystem bei einer internen Optimierung der Anfrage vor der Ausführung erkennt, dass die leere Tabelle überflüssig ist und deshalb ignoriert wird. Aus einem formalen Gesichtspunkt muss man sich hier aber die Frage stellen, ob man diese Optimierung erlauben soll. Eine Grundregel der Optimierung sollte sein, dass das Ergebnis der Berechnung mit und ohne Optimierung gleich sein muss.

Abteilung 1		Mitarbeiter			Abteilung 2	
MiNr	Leiter	MiNr	Name	Chef	MiNr	Leiter
1	Erna	401	Udo	1		
2	Edna	402	Ute	3		

Abb. 7.3: Tabellen für kritisches Anfrageergebnis

*WHERE-
Bedingungen
mit OR und lee-
re Tabellen*

Ein größeres Problem mit einer leeren Tabelle kann man aber auch in einem komplexeren und realitätsnäheren Beispiel beobachten. Gegeben seien die Tabellen aus Abb. 7.3, in der Mitarbeiter einen Vorgesetzten aus verschiedenen Abteilungen haben können. Dabei sind hier nur die für das Beispiel relevanten Tabellen angegeben. Mit einiger Erfahrung sollte man die nicht optimale Gestaltung der Tabellen erkennen. Trotzdem kann eine solche Situation mit der Aufteilung inhaltlich zusammengehöriger Tabellen in einer über längere Zeit entwickelten und ergänzten Datenbank auftreten. Die Tabelle Abteilung 2 hat im Beispiel keine Einträge. Mit der folgenden Anfrage möchte man die Namen aller Mitarbeiter herausfinden, deren Chef in der Abteilung 1 oder in der Abteilung 2 arbeitet.

```
SELECT Mitarbeiter.Name
FROM Mitarbeiter, Abteilung1, Abteilung2
WHERE Mitarbeiter.Chef=Abteilung1.MiNr
OR Mitarbeiter.Chef=Abteilung2.MiNr
```

Das wohl befürchtete, aber wahrscheinlich nicht gewünschte Ergebnis ist:

Es wurden keine Zeilen ausgewählt

Die folgende Anfrage, die eigentlich ein Teilergebnis der ersten Anfrage bezogen auf die Abteilung 1 liefert, bringt das erwartete Ergebnis.

```
SELECT Mitarbeiter.Name
FROM Mitarbeiter, Abteilung1
WHERE Mitarbeiter.Chef=Abteilung1.MiNr
```

Das Ergebnis der Anfrage ist:

```
NAME
-----
Udo
```

*Vor Anfrageers-
tellung prüfen,
ob Tabellen leer
sind*

Man erkennt daran, dass man vor der Erstellung von Anfragen prüfen muss, ob eine der beteiligten Tabellen leer ist. In diesem Fall muss eine andere Anfrage genommen werden. Diese Prüfung ist bei den bisher beschriebenen Anfragen noch leicht möglich, sie kann aber bei den komplexeren Anfragen in den Folge-

kapiteln zu einigen Problemen und irritierenden Fehlern führen. Es muss grundsätzlich für jede Anfrage sichergestellt sein, dass sie sich nicht auf eine leere Tabelle bezieht.

7.5

Fallstudie

Mit den bisher vorgestellten SQL-Möglichkeiten können folgende gewünschte Anfragen aus dem Unterkapitel „2.6 Fallstudie“ formuliert werden.

Gib zu jedem Projekt die Projektrisiken aus.

```
SELECT Projekt.Name, Risiko.Text
FROM Projekt, Risiko
WHERE Projekt.ProNr=Risiko.Projekt
```

Ausgabe:

NAME	TEXT
-----	-----
GUI	Anforderungen unklar
GUI	Abnahmeprozess offen
WebShop	Ansprechpartner wechseln
WebShop	neue Entwicklungsumgebung

Gib zu jedem Projekt die getroffenen Risikomaßnahmen aus.

```
SELECT DISTINCT Projekt.Name,
                Massnahme.Titel
FROM Projekt, Risiko, Massnahme, Zuordnung
WHERE Projekt.ProNr=Risiko.Projekt
      AND Risiko.RNr= Zuordnung.Risiko
      AND Massnahme.MNr=Zuordnung.Massnahme
```

Ausgabe:

NAME	TITEL
-----	-----
GUI	Vertragspruefung
WebShop	Werkzeugschulung

Gib für jedes Projekt die betroffenen Risikogruppen aus.

```
SELECT DISTINCT Projekt.Name, Risikogruppe.Gruppe
FROM Projekt, Risiko, Risikogruppe
WHERE Projekt.ProNr=Risiko.Projekt
      AND Risiko.Gruppe= Risikogruppe.RGNr
```

Ausgabe:

NAME	GRUPPE
-----	-----
GUI	Kundenkontakt
GUI	Vertrag
WebShop	Ausbildung
WebShop	Kundenkontakt

Gib zu jeder Risikogruppe die getroffenen Maßnahmen aus.

```
SELECT Risikogruppe.Gruppe, Massnahme.Titel
FROM Risiko, Risikogruppe, Massnahme, Zuordnung
WHERE Risiko.Gruppe= Risikogruppe.RGNr
      AND Risiko.RNr= Zuordnung.Risiko
      AND Massnahme.MNr=Zuordnung.Massnahme
```

Ausgabe:

GRUPPE	TITEL
-----	-----
Kundenkontakt	Vertragspruefung
Vertrag	Vertragspruefung
Ausbildung	Werkzeugschulung

7.6

Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu beantworten.

1. Wozu wird DISTINCT benötigt?
2. Wozu kann der * in SELECT-Zeilen genutzt werden?
3. Welche Berechnungsmöglichkeiten gibt es in der SELECT-Zeile?
4. Wie kann man Ergebnisspalten umbenennen?
5. Wie kann man neue Spalten bei der Berechnung von Tabellen erzeugen?
6. Welche Möglichkeiten zur Sortierung der Ausgabe gibt es?
7. Welche Möglichkeiten zur Textbearbeitung, z. B. dem Finden von Teilwörtern, gibt es in SQL?
8. Wie wird mit NULL-Werten in WHERE-Bedingungen umgegangen?
9. Was sind Aggregatsfunktionen, was ist bei ihrer Nutzung zu beachten?
10. Wie kann man mehrere Tabellen in SQL verknüpfen?
11. Erklären Sie den Aufbau und Ablauf der Auswertung einfacher SQL-Anfragen.
12. Beschreiben Sie ein generelles Vorgehen zur Erstellung einer SQL-Anfrage.

13. Wie kann man eine Tabelle in Anfragen mehrmals nutzen, wieso kann dies sinnvoll sein?
14. Welche Besonderheit ist bei der Nutzung von OR-Bedingungen und der Verknüpfung mehrerer Tabellen zu beachten?

Übungsaufgaben

Gegeben seien folgende Tabellen zur Notenverwaltung (Primärschlüssel sind unterstrichen):

Student		Pruefung			Veranstaltung		
<u>MatNr</u>	Name	<u>MatNr</u>	<u>Fach</u>	Note	<u>Kürzel</u>	Titel	Dozent
42	Simson	42	Wahl1	3,0	Wahl1	Controlling	Hinz
43	Milhuse	42	DB	1,7	Wahl2	Java	Hinz
44	Monz	43	Wahl2	4,0	DB	Datenbanken	Kunz
		43	DB	1,3			
		44	Wahl1	5,0			

Formulieren Sie die folgenden Textzeilen jeweils als SQL-Anfragen.

1. Geben Sie die Namen der Studierenden aus, die eine Prüfung im Fach „Wahl1“ gemacht haben.
2. Geben Sie den Titel der Veranstaltungen und die zugehörige Note für alle Prüfungen, die Simson gemacht hat, aus.
3. Geben Sie eine Liste aller Titel von Veranstaltungen mit den bisher in den Prüfungen erreichten Noten (Ausgabe: Titel, Note) aus.
4. Geben Sie die Anzahl der Studierenden aus, die bereits eine Prüfung im Fach „DB“ gemacht haben.
5. Geben Sie die Namen aller Dozenten aus, die mindestens zwei Veranstaltungen anbieten.
6. Geben Sie die Durchschnittsnote für alle Fächer zusammen aus, die von Hinz unterrichtet wurden.
7. Geben Sie die Namen aller Studierenden aus, die mindestens genauso gut wie Simson in DB waren, aber nicht Simson sind.
8. Geben sie die Namen aller Studierenden aus, die mindestens eine Prüfung bei Hinz gemacht haben. Gehen Sie davon aus, dass der veranstaltende Dozent auch Prüfer ist.

8

Gruppierungen in SQL

*statistische
Auswertungen*

Im vorherigen Kapitel wurden alle wichtigen Sprachkonstrukte von SQL zur einfachen Verknüpfung von Tabellen vorgestellt. SQL-Anfragen bieten neben der reinen Tabellenverknüpfung auch die Möglichkeit, Auswertungen für einzelne Attribute oder für mehrere Attribute durchzuführen. Damit kann man z. B. in einer Anfrage herausfinden, wie oft verschiedene Attributswerte in einer Spalte vorkommen. Für diesen Ansatz wird das SQL-Sprachkonstrukt `GROUP BY` genutzt, das Ihnen in diesem Kapitel genauer vorgestellt werden soll.

Weiterhin wird gezeigt, wie man die bisherigen Erkenntnisse über die Erstellung recht komplexer Anfragen mit den Gruppierungsmöglichkeiten kombinieren kann.

Teilweise kann man Anfragen mit Gruppierungen auch ohne Gruppierungen schreiben. Diese Möglichkeiten mit den unterschiedlichen Konzepten werden anhand mehrerer Beispiele diskutiert.

Gehege			Tier			Art	
<u>GNr</u>	Gname	Flaeche	<u>GNr</u>	Tname	Gattung	<u>Gattung</u>	MinFlaeche
1	Wald	30	1	Laber	Baer	Baer	8
2	Feld	20	1	Sabber	Baer	Hase	2
3	Weide	15	2	Klopfer	Hase	Schaf	5
			3	Bunny	Hase		
			2	Runny	Hase		
			2	Hunny	Hase		
			2	Harald	Schaf		
			3	Walter	Schaf		
			3	Dörthe	Schaf		

Abb. 8.1: Erweiterte Zoo-Tabelle

Als Beispiel dient eine leicht abgewandelte Variante der Zoo-Datenbank aus dem vorherigen Kapitel, die in Abb. 8.1 nur in den Einträgen etwas geändert wurde.

8.1

Gruppierung in einer Tabelle

*Vorgehensweise
ohne Gruppierung*

Bisher wurden Berechnungen nur über gesamte Tabellen durchgeführt. Der Ansatz wurde im Unterkapitel „7.3 Nutzung von Aggregatsfunktionen“ vorgestellt. Nachdem unser Zoo im Beispiel Zuwachs bekommen hat, ist man auch an anderen Fragen interessiert. Ein Beispiel ist die Frage nach der Anzahl der Tiere pro Gattung. Soll diese Anfrage mit dem bisherigen Wissen beantwortet werden, so muss man mit einer ersten Anfrage feststellen, welche Gattungen im Zoo vertreten sind:

```
SELECT DISTINCT Tier.Gattung
FROM Tier
```

Das Ergebnis der Anfrage lautet:

```
GATTUNG
-----
Baer
Hase
Schaf
```

Im zweiten Schritt findet dann eine Auswertung pro Gattung von Hand statt, die z. B. für die Schafe wie folgt aussieht:

```
SELECT COUNT(*) Schafanzahl
FROM Tier
WHERE Tier.Gattung='Schaf'
```

Das Ergebnis ist:

```
SCHAFANZAHL
-----
3
```

*Zentrales Ziel
des Profis: keine
Zwischenergebnisse
notieren*

Dieser Ansatz ist für Anfrage-Experten unbefriedigend. Grundsätzlich versucht man Anfragen-Probleme mit einer Anfrage zu lösen, ohne dass von Hand Zwischenergebnisse notiert werden müssen. Das Problem ist aber, dass bis jetzt nur Berechnungen auf ganzen Tabellen möglich sind. Dieses Problem löst der Ansatz der Gruppierung mit GROUP BY. Die Idee besteht darin, dass man angibt, dass pro anzugebendem Attribut Berechnungen durchgeführt werden.

Die Anfrage mit GROUP BY lautet:

```
SELECT Tier.Gattung, COUNT(*) Tieranzahl
FROM Tier
GROUP BY Tier.Gattung
```

Das Ergebnis ist:

GATTUNG	TIERANZAHL
-----	-----
Baer	2
Hase	4
Schaf	3

Schrittweise Berechnung der Gruppierungsergebnisse

Zur Auswertung der Anfrage kann man sich folgende Schritte vorstellen: Zunächst wird die Tabelle nach dem Gruppierungsattribut sortiert. Anschaulich entspricht dies dem Ergebnis der Anfrage

```
SELECT *
FROM Tier
ORDER BY Tier.Gattung
```

Das Ergebnis ist:

Visualisierung der Gruppierung

GNR	TNAME	GATTUNG	
-----	-----	-----	
1	Laber	Baer	Baer-Gruppe
1	Sabber	Baer	
2	Klopfer	Hase	Hase-Gruppe
3	Bunny	Hase	
2	Runny	Hase	
2	Hunny	Hase	
2	Harald	Schaf	Schaf-Gruppe
3	Walter	Schaf	
3	Dörthe	Schaf	

Im anschließenden Schritt findet, wie im Ergebnis angedeutet, die Gruppierung statt. Für jede dieser Gruppen können dann die bekannten Aggregatsfunktionen angewandt werden.

Vorgehensweise zur Erstellung von Gruppierungsanfragen

Aus der beschriebenen Abarbeitung kann man auch ein Verfahren zur Erstellung von GROUP BY-Anfragen ableiten. Man überlegt sich zunächst eine Anfrage ohne GROUP BY, die alle notwendigen Informationen für das Endergebnis enthält. Im zweiten Schritt findet dann die Gruppierung statt, und man kann festlegen, welche Informationen für das Ergebnis interessant sind.

Ein weiteres Beispiel liefert die Anfrage nach der Anzahl der Hasen pro Gehegenummer. Zunächst erstellt man eine Anfrage, in der alle Hasen erfasst werden. Dabei wird zusätzlich bezüglich des passenden Gruppierungsattributs sortiert.

Gruppierung mit WHERE-Bedingung

```
SELECT *
FROM Tier
WHERE Tier.Gattung='Hase'
ORDER BY Tier.GNr
```


Das Ergebnis der Anfrage ist:

GNR	TNAME	GATTUNG
2	Hunny	Hase
2	Klopfer	Hase
2	Runny	Hase
3	Bunny	Hase

Danach wird diese Anfrage ohne die SELECT- und ORDER BY-Zeilen in eine GROUP BY-Anfrage eingebettet. In der resultierenden SELECT-Zeile wird das Gruppierungsattribut und die gewünschte Aggregatsfunktion eingetragen.

```
SELECT Tier.GNr, COUNT(*) Hasenzahl
FROM Tier
WHERE Tier.Gattung='Hase'
GROUP BY Tier.GNr
```

Das Ergebnis der Anfrage ist:

*Gruppen ohne
Elemente sind
nicht im Ergeb-
nis*

GNR	HASENZAHL
2	3
3	1

Beim Ergebnis fällt auf, dass Gruppen, für die keine Elemente vorhanden sind, nicht erscheinen. Um diese Gruppierungswerte auch sichtbar zu machen, muss man verschiedene Anfragen verknüpfen, dies wird im folgenden Kapitel diskutiert.

*Attribute in SE-
LECT-Zeilen bei
Gruppierungen*

Bei den SELECT-Zeilen der Anfragen mit Gruppierungen fällt auf, dass dort eine Mischung aus Attributen und Aggregatsfunktionen steht. Dieser Ansatz ist bei der Erklärung der Aggregatsfunktionen im Unterkapitel „7.3 Nutzung von Aggregatsfunktionen“ durchgestrichen worden. Bei Gruppierungen ist dies kein Problem, da in der SELECT-Zeile ausschließlich Attribute stehen dürfen, die auch in der GROUP BY-Zeile stehen. Natürlich können diese Attribute in der SELECT-Zeile auch weggelassen werden. Es können auch mehrere Berechnungen auf einer Gruppe ausgeführt werden.

*Gruppierung
nach mehreren
Attributen*

In dem folgenden Beispiel wird die Anzahl der jeweiligen Gattungen pro Gehegenummer gezählt. Es werden also zwei Attribute in der GROUP BY-Zeile benötigt. Die Gruppierung erfolgt dann nach dem Wertepaar. Die Anfrage lautet:

```
SELECT Tier.GNr, Tier.Gattung,
       COUNT(*) Tieranzahl
FROM Tier
GROUP BY Tier.GNr, Tier.Gattung
```

Das Ergebnis ist:

GNR	GATTUNG	TIERANZAHL
1	Baer	2
2	Hase	3
2	Schaf	1
3	Hase	1
3	Schaf	2

Abrechnungsfragment

Posten	Artikel	Anzahl
1	Ball	3
2	Form	
3		4
4	Eimer	
5		
6	Ball	4
7	Eimer	3
8		
9	Eimer	
10	Ball	3

Abb. 8.2: Fragmente einer Abrechnung

*Gruppierungen
nach NULL-
Werten sind
möglich*

Abschließend soll noch das Verhalten bezüglich NULL-Werten betrachtet werden. Dazu wird die Tabelle aus Abb. 8.2 genutzt. Die folgende Anfrage prüft, wie häufig die Paare Artikel und Anzahl auftreten.

```
SELECT Abrechnungsfragment.Artikel,
       Abrechnungsfragment.Anzahl, COUNT(*)
FROM Abrechnungsfragment
GROUP BY Abrechnungsfragment.Artikel,
         Abrechnungsfragment.Anzahl
```

Das Ergebnis ist:

ARTIKEL	ANZAHL	COUNT(*)
		2
	4	1
Ball	3	2
Ball	4	1
Form		1
Eimer		2
Eimer	3	1

Man erkennt, dass eine Gruppierungsmöglichkeit bezüglich der NULL-Werte gegeben ist.

8.2

Nutzung der HAVING-Zeile

Im vorherigen Kapitel wurden zunächst die Möglichkeiten der SELECT- und der FROM-Zeile und dann der WHERE-Bedingung vorgestellt. Vergleichbar zur Einführung im vorherigen Unterkapitel, ergänzt die HAVING-Zeile die GROUP BY-Zeile um eine andere Form der WHERE-Bedingung.

HAVING-Bedingung zur Auswahl von Gruppen

In dieser so genannten HAVING-Bedingung können allerdings nur Attribute stehen, die auch in der GROUP BY-Zeile genannt werden. Weiterhin dürfen in der HAVING-Bedingung Aggregatsfunktionen, die sich auf die jeweilige Auswertung der Gruppe beziehen, stehen. Dies soll mit einigen Beispielen verdeutlicht werden.

Mit der ersten Anfrage sollen die Nummern der Gehege ausgegeben werden, in denen mindestens drei Tiere leben. Die Anfrage lautet:

```
SELECT Tier.GNr
FROM Tier
GROUP BY Tier.GNr
HAVING COUNT(*)>=3
```

Das Ergebnis der Anfrage ist:

```
      GNR
-----
        2
        3
```

Auswertung mit HAVING-Bedingung

Bei der Auswertung wird zunächst die im vorherigen Kapitel vorgestellte Gruppierung durchgeführt und danach alle Gruppen für die Ergebnisaufbereitung ausgewählt, die dann auch die HAVING-Bedingung erfüllen.

Grundsätzlich gilt, dass die verwendeten Aggregatsfunktionen der HAVING-Bedingung und der SELECT-Zeile nicht übereinstimmen müssen. Weiterhin müssen Attribute der GROUP BY-Zeile nicht in der SELECT-Zeile zur Ausgabe genutzt werden.

Mit der nächsten Anfrage sollen die Anzahlen der Tiere pro Gattung mit der Gattung zusammen ausgegeben werden. Dabei soll die Anzahl der Tiere höchstens 3 sein und es sollen keine Schafe berücksichtigt werden. Die Anfrage lautet:

```

SELECT Tier.Gattung, COUNT(*) Tieranzahl
FROM Tier
GROUP BY Tier.Gattung
HAVING Tier.Gattung<>'Schaf'
AND COUNT(*)<=3

```

Das Ergebnis der Anfrage ist:

```

GATTUNG TIERANZAHL
-----
Baer                2

```

*Gruppierungs-
attribute in
WHERE oder
HAVING*

In der letzten Anfrage wurde ein Attribut aus der GROUP BY-Zeile in der HAVING-Bedingung genutzt. Bei der Auswertung werden also zunächst Gruppen bezüglich der Gattungen gebildet und dann mit der HAVING-Bedingung eine Gattung aussortiert. Alternativ hätte man die Teilbedingung für das Gruppenattribut auch in die WHERE-Bedingung einbauen können. Die folgende Anfrage führt zum gleichen Ergebnis.

```

SELECT Tier.Gattung, COUNT(*) Tieranzahl
FROM Tier
WHERE Tier.Gattung<>'Schaf'
GROUP BY Tier.Gattung
HAVING COUNT(*)<=3

```

Die Frage, welcher der beiden Ansätze gewählt werden sollte, lässt sich als Geschmackssache ansehen. Der Ansatz, das Attribut in der HAVING-Bedingung zu nennen, hat den kleinen Vorteil, dass man direkt sieht, dass sich die Bedingung auf die Auswahl der Gruppen auswirkt. Die andere Anfrage wird meist etwas schneller berechnet.

Bei den letzten drei Beispielen wird man an ein Beispiel aus dem Unterkapitel „7.4 Anfragen über mehrere Tabellen“ erinnert, bei denen mehrere Einträge einer Tabelle betrachtet werden. Die folgende Anfrage gibt z. B. die Gehege aus, in denen mindestens zwei Tiere der gleichen Gattung leben.

```

SELECT DISTINCT T1.Gnr
FROM Tier T1, Tier T2
WHERE T1.Gnr=T2.Gnr
AND T1.Gattung=T2.Gattung
AND T1.Tname<>T2.Tname

```

Das Ergebnis der Anfrage ist:

```

GNR
-----
1
2
3

```

Die Grundidee ist, die gleiche Tabelle zweimal in der FROM-Zeile zu nutzen, um zwei unterschiedliche Einträge mit den gewünschten Daten zu finden. Sucht man nach Gehegen mit mindestens drei Tieren der gleichen Gattung, so lautet die Anfrage mit dieser Idee wie folgt.

```
SELECT DISTINCT T1.Gnr
FROM Tier T1, Tier T2, Tier T3
WHERE T1.Gnr=T2.Gnr
      AND T2.Gnr=T3.Gnr
      AND T1.Gattung=T2.Gattung
      AND T2.Gattung=T3.Gattung
      AND T1.Tname<>T2.Tname
      AND T1.Tname<>T3.Tname
      AND T2.Tname<>T3.Tname
```

Das Ergebnis der Anfrage ist:

```
          GNR
-----
          2
```

Man kann sich vorstellen, dass dieser Ansatz für größere Zahlen sehr aufwändig wird. Mit der Gruppierung gibt es eine alternative Anfragemöglichkeit, in der die gewünschte Anzahl sehr flexibel in der HAVING-Zeile abgeändert werden kann. Die Anfrage lautet:

```
SELECT Tier.Gnr
FROM Tier
GROUP BY Tier.Gnr, Tier.Gattung
HAVING COUNT(*)>=3
```

Das Ergebnis ist das Gleiche, wie bei der vorherigen Anfrage. Dadurch, dass die Gattung auch in die GROUP BY-Zeile aufgenommen wurde, wird sichergestellt, dass pro Gehege nur die gleichen Gattungen gezählt werden.

Eine Anfrage nach Gehegen, in denen mindestens drei unterschiedliche Gattungen leben, kann durch eine Gruppierung mit geschickter Nutzung der COUNT-Funktion gelöst werden. Der Ansatz ist, nur unterschiedliche Gattungen pro Gehege zu zählen. Die Anfrage, die im konkreten Beispiel keine Ergebniszeile liefert, lautet:

```
SELECT Tier.Gnr
FROM Tier
GROUP BY Tier.Gnr
HAVING COUNT(DISTINCT Tier.Gattung)>=3
```

Zählen von unterschiedlichen Werten einer Gruppe

8.3

Gruppierungen über mehreren Tabellen

Die Ideen der Gruppierung lassen sich direkt auf Anfragen über mehrere Tabellen übertragen. Wieder muss erst nach der geeigneten Anfrage gesucht werden, in der dann nach ausgewählten Attributen gruppiert wird. Danach können Gruppen mit der HAVING-Bedingung ausgewählt werden. ORDER BY sorgt zusätzlich für eine Sortierung. Mit der SELECT-Zeile werden dann die für das Ergebnis interessanten Informationen ausgewählt.

*Konstruktion
einer Gruppierungsanfrage
über mehrere
Tabellen*

Ein typisches Beispiel ist die Frage nach der Fläche, die durch die Tiere in jedem Gehege verbraucht wird. Es soll zu jedem Gehegenamen die verbrauchte Fläche bestimmt werden. Zunächst wird eine Anfrage benötigt, in der alle Informationen stehen. Diese Anfrage sieht wie folgt aus:

```
SELECT Gehege.Gname, Tier.Gattung,
       Art.MinFlaeche
FROM Gehege, Tier, Art
WHERE Gehege.Gnr=Tier.Gnr
      AND Tier.Gattung=Art.Gattung
ORDER BY Gehege.Gname
```

Das Ergebnis der Anfrage ist:

GNAME	GATTUNG	MINFLAECH
-----	-----	-----
Feld	Hase	2
Feld	Hase	2
Feld	Schaf	5
Feld	Hase	2
Wald	Baer	8
Wald	Baer	8
Weide	Hase	2
Weide	Schaf	5
Weide	Schaf	5

Das Sortierkriterium wird in die GROUP BY-Zeile übernommen und die notwendige Berechnung in der SELECT-Zeile durchgeführt.

```
SELECT Gehege.Gname,
       SUM(Art.MinFlaeche) Verbraucht
FROM Gehege, Tier, Art
WHERE Gehege.Gnr=Tier.Gnr
      AND Tier.Gattung=Art.Gattung
GROUP BY Gehege.Gname
```

Das Ergebnis der Anfrage ist:

GNAME	VERBRAUCHT
-----	-----
Feld	11
Wald	16
Weide	12

Randbedingungen bei Gruppierungen

Wichtig ist, dass in der SELECT-Zeile, in der HAVING-Bedingung und in der ORDER BY-Zeile nur Attribute direkt genannt werden dürfen, die in der GROUP BY-Zeile zur Gruppierung genutzt werden. Weiterhin können in der SELECT-Zeile, in der HAVING-Bedingung und in der ORDER BY-Zeile Aggregatsfunktionen stehen, in denen die Werte pro Gruppe verarbeitet werden. Dabei können an unterschiedlichen Stellen verschiedene Aggregatsfunktionen genutzt werden. Mit der folgenden Anfrage wird bestimmt, welche Gattung im Zoo insgesamt wie viel Fläche beansprucht, dabei müssen von der Gattung aber mindestens drei Tiere im Zoo leben.

```
SELECT Tier.Gattung, SUM(Art.MinFlaeche) Bedarf
FROM Tier, Art
WHERE Tier.Gattung=Art.Gattung
GROUP BY Tier.Gattung
HAVING COUNT(*)>=3
ORDER BY SUM(Art.MinFlaeche)
```

Das Ergebnis der Anfrage ist:

GATTUNG	BEDARF
-----	-----
Hase	8
Schaf	15

8.4

Überblick über die Struktur von SQL-Anfragen

In diesem und dem vorherigen Kapitel wurden alle Sprachkonstrukte eingeführt, die zur Erstellung von SQL-Anfragen existieren. Im folgenden Kapitel wird „nur noch“ gezeigt, wie man Anfrageergebnisse geschickt verknüpfen kann.

Dadurch, dass die Struktur von Anfragen vollständig bekannt ist, ist es jetzt möglich, jede SQL-Anfrage von ihrem Aufbau her zu verstehen. Im folgenden Kapitel wird dann gezeigt, dass man die Grundstruktur durch weitere Details anreichern kann, was SQL insgesamt zu einer sehr mächtigen Sprache macht.

Schlüsselwort	Auswertungsreihenfolge	Inhalt
SELECT	6	Attribute, Aggregatsfunktionen
FROM	1	Liste von Tabellen, deren Kreuzprodukt betrachtet wird
WHERE	2	Boolesche Bedingung, zur Auswahl von Zeilen des Kreuzproduktes
GROUP BY	3	Liste von Attributen, nach denen gruppiert wird
HAVING	4	Boolesche Bedingung mit Attributen aus der GROUP-BY-Zeile oder Aggregatsfunktionen zur Auswahl von Gruppen
ORDER BY	5	Attribute (oder Aggregatsfunktionen bei GROUP BY) für Sortierreihenfolge bei der Ausgabe

Abb. 8.3: Struktur und Abarbeitung von SQL-Anfragen

Abb. 8.3 zeigt den allgemeinen Aufbau einer SQL-Anfrage und die Reihenfolge, in der die einzelnen Elemente bearbeitet werden. Diese Bearbeitungsreihenfolge lässt sich sehr gut auf die Erstellung von Anfragen übertragen. Benötigt man eine Anfrage, bei der Auswertungen bezüglich einzelner Attributwerte berechnet werden sollen, so ist der Einsatz einer GROUP BY-Anfrage sinnvoll. Dabei kann man folgendes „Kochrezept“ zur Erstellung nutzen.

Zentrales Kochrezept zur Erstellung von Anfragen mit Gruppierungen

Der grundsätzliche Ansatz zur Formulierung einfacher SQL-Anfragen kann wie folgt zusammengefasst werden:

- (1) Es werden die für die Anfrage interessanten Tabellen gesucht und in die FROM-Zeile geschrieben.
- (2) Es wird die Verknüpfung der benutzen Tabellen in der WHERE-Bedingung festgelegt. Typisch ist die Verknüpfung von Primär- und Fremdschlüsseln, die einzelnen Bedingungen werden mit AND verknüpft.
- (3) Falls es die Anfrage erfordert, werden die weiteren Anforderungen in Teilbedingungen übersetzt. Die resultierende Teilbedingung wird mit AND mit der Bedingung aus (2) verknüpft.
- (4) Attribute, für die eine Auswertung erfolgen soll, werden in die GROUP BY-Zeile aufgenommen. Dabei ist es sinnvoll, sich das bis zum Schritt (3) erreichte Ergebnis sortiert nach

dem Gruppierungsattribut oder den Gruppierungsattributen vorzustellen.

- (5) Falls gewisse Gruppen nicht im Ergebnis auftreten sollen, werden sie durch die Formulierung einer HAVING-Bedingung ausgeschlossen. Nur Gruppen, die diese Bedingung erfüllen, werden zur Ergebnisdarstellung genutzt.
- (6) Es werden die Informationen, z. B. Attribute und Berechnungen durch Aggregatsfunktionen, ausgewählt, die für die Ergebnisausgabe wichtig sind und in die SELECT-Zeile geschrieben. Zu beachten ist, dass nur Attribute aus der GROUP BY-Zeile in der SELECT-Zeile, der HAVING-Bedingung und der ORDER BY-Zeile stehen dürfen.
- (7) Bei Bedarf wird in der ORDER BY-Zeile angegeben, in welcher Reihenfolge die Ausgaben erfolgen sollen.

Die Schritte (6) und (7) können vertauscht werden.

8.5

Fallstudie

Mit den bisher vorgestellten SQL-Möglichkeiten können folgende gewünschte Anfragen zu statistischen Auswertungen aus dem Unterkapitel „2.6 Fallstudie“ formuliert werden.

Gib zu jedem Projekt die Anzahl der zugehörigen Risiken und die durchschnittliche Wahrscheinlichkeit des Eintreffens aus.

```
SELECT Projekt.Name, COUNT(*) Risikoanzahl,  
       AVG(Risiko.Wkeit) Wahrscheinlichkeit  
FROM Projekt, Risiko  
WHERE Projekt.ProNr=Risiko.Projekt  
GROUP BY Projekt.ProNr, Projekt.Name
```

In der Gruppierung wurden zwei Spalten aufgenommen, da es möglich ist, dass es mehrere Projekte mit gleichen Namen geben kann. Durch die Aufnahme der Spalte Projekt.ProNr wird sichergestellt, dass verschiedene Projekte mit gleichen Namen im Ergebnis getrennt auftreten. Dieser Trick wird auch bei den folgenden Anfragen teilweise verwendet.

Ausgabe:

NAME	RISIKOANZAHL	WAHRSCHEINLICHKEIT
GUI	2	50
WebShop	2	50

Gib zu jedem Projekt die Summe der erwarteten Zusatzkosten, berechnet aus dem maximalen Zusatzaufwand und der Eintrittswahrscheinlichkeit, aus.

```
SELECT Projekt.Name,
       SUM(Risiko.Auswirkung*Risiko.Wkeit/100)
                                     Mehraufwand
FROM Projekt, Risiko
WHERE Projekt.ProNr=Risiko.Projekt
GROUP BY Projekt.ProNr, Projekt.Name
```

Ausgabe:

NAME	MEHRAUFWAND
GUI	36000
WebShop	24000

Gib zu jeder Maßnahme den frühesten Zeitpunkt zur Überprüfung an.

```
SELECT Massnahme.Titel,
       MIN (Zuordnung.Pruefdatum) PDatum
FROM Massnahme, Zuordnung
WHERE Massnahme.MNr= Zuordnung.Massnahme
GROUP BY Massnahme.Titel
```

Ausgabe:

TITEL	PDATUM
Vertragspruefung	20.01.06
Werkzeugschulung	30.07.06

Gib zu jeder Maßnahme an, zur Bearbeitung von wie vielen Risiken sie eingesetzt werden soll.

```
SELECT Massnahme.Titel, COUNT(*) Risikoanzahl
FROM Risiko, Massnahme, Zuordnung
WHERE Risiko.RNr= Zuordnung.Risiko
      AND Massnahme.MNr=Zuordnung.Massnahme
GROUP BY Massnahme.MNr, Massnahme.Titel
```

Ausgabe:

TITEL	RISIKOANZAHL
Vertragspruefung	2
Werkzeugschulung	1

Gib die Risikogruppen aus, denen mindestens zwei Risiken zugeordnet wurden.

```
SELECT Risikogruppe.Gruppe
FROM Risiko, Risikogruppe
WHERE Risiko.Gruppe=Risikogruppe.RGNr
GROUP BY Risikogruppe.Gruppe
HAVING COUNT(*)>=2
```

Ausgabe:

```
GRUPPE
-----
Kundenkontakt
```

Die Anfrage „Gib zu jedem Risiko die Anzahl der getroffenen Maßnahmen aus.“ kann noch nicht vollständig formuliert werden, da es auch Risiken geben kann, zu denen noch keine Maßnahmen ergriffen wurden. Da das Ergebnis „0“ bei Gruppenberechnungen nicht auftreten kann, wird diese Anfrage erst im folgenden Kapitel vollständig formuliert.

8.6

Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu beantworten.

1. Welche Probleme gibt es, wenn man keine Gruppierungen nutzt?
2. Warum sollte man auf handgeschriebene Zwischenergebnisse bei der Anfrageerstellung verzichten?
3. Wie kann man die Auswertung einer Gruppierung in SQL veranschaulichen?
4. Was ist bei der Erstellung einer SELECT-Zeile bei der Nutzung von Gruppierungen zu beachten?
5. Welche Auswirkungen haben NULL-Werte auf Gruppierungen?
6. Wozu dient die HAVING-Zeile, wann wird sie ausgewertet?
7. Wie sieht der allgemeine Aufbau einer SQL-Anfrage aus, in welchen Schritten wird sie ausgewertet?

Übungsaufgaben

Gegeben seien die Tabellen aus den Aufgaben zu Kapitel 7. Formulieren Sie folgende Anfragen.

1. Geben Sie eine Liste aller Veranstaltungstitel mit den in den bisherigen zugehörigen Prüfungen erreichten Durchschnittsnoten aus.
2. Geben Sie eine Liste mit den Namen aller Dozenten und der Anzahl der bisher in einem Fach des Dozenten abgelegten Prüfungen aus.
3. Geben Sie die Namen aller Studierenden aus, deren Durchschnittsnote in den abgelegten Prüfungen besser als 2,5 ist.

Gegeben seien die folgenden Tabellen mit Informationen über Bons, die in einem Supermarkt an verschiedenen Kassen erstellt werden. Formulieren Sie folgende Anfragen, beachten Sie dabei, dass nicht alle Anfragen mit Gruppierungen gelöst werden müssen.

Bon

BonID	Kasse	Verkaeuer
1	1	Müller
2	2	Meier
3	2	Müller

Bonposition

BPID	BonID	ProdID	Anzahl
1	1	1	2
2	1	2	1
3	1	3	5
4	2	1	3
5	2	4	4
6	3	1	2
7	3	3	3

Produkt

ProdID	Pname	Preis
1	Wodka	5
2	Whisky	7
3	Cola	2
4	Wasser	1

4. Geben Sie die Namen aller Produkte (Pname) aus, die verkauft werden können.
5. Geben Sie die Namen aller Produkte (Pname) aus, die auf dem Bon mit der BonID 1 verkauft werden.
6. Geben Sie eine Liste aller Einzelverkäufe (Anzahl, Pname) aus, die Müller durchgeführt hat, z. B. (Wodka, 2).

7. Geben Sie eine Liste aller Produkte (Pname) aus, die auf mindestens zwei verschiedenen Bons verkauft werden.
8. Geben Sie für jedes Produkt aus, wie häufig es insgesamt (Pname, Gesamtzahl) verkauft wurde.
9. Geben Sie für jeden Bon die Gesamtsumme aller Verkäufe (BonID, Gesamtsumme) aus.

9

Verschachtelte Anfragen in SQL

Anfragen in
Anfragen

Unterschiedli-
che Ansätze für
gleiche Lösung

Nachdem in den letzten beiden Kapiteln alle Grundlagen für einfache Anfragen, die unterschiedlichen syntaktischen Möglichkeiten und die verschiedenen Herangehensweisen an die Anfragen-erstellung gezeigt wurden, steht in diesem Kapitel die Möglichkeit zur Verknüpfung von Anfragen im Mittelpunkt. Es wird gezeigt, wie einzelne Anfragen mit ihren Ergebnissen in andere Anfragen eingebaut werden können. Sie lernen dabei schrittweise sehr mächtige, aber auch komplexe Anfragen zu erstellen.

Dabei werden unterschiedliche Stile und Vorgehensweisen diskutiert, wie man für die gleiche Aufgabe zu unterschiedlichen Lösungsansätzen kommen kann. Dies ist interessant, weil der „einfachste Lösungsweg“ bei nicht-trivialen Anfragen nicht nur vom Wissen über SQL, sondern auch von den Denkstrukturen des Anfragenschreibers abhängt und so ein individueller Lösungsweg entwickelt werden kann.

Gehege			Tier			Art	
<u>GNr</u>	Gname	Flaeche	<u>GNr</u>	<u>Tname</u>	Gattung	<u>Gattung</u>	MinFlaeche
1	Wald	30	1	Laber	Baer	Baer	8
2	Feld	20	1	Sabber	Baer	Hase	2
3	Weide	15	2	Klopfer	Hase	Schaf	5
			3	Bunny	Hase		
			2	Runny	Hase		
			2	Hunny	Hase		
			2	Harald	Schaf		
			3	Walter	Schaf		
			3	Dörthe	Schaf		

Abb. 9.1: Anschauungsbeispiel für dieses Kapitel

Als Anschauungsbeispiel dienen wie im vorherigen Kapitel die in Abb. 9.1 dargestellten Tabellen.

9.1

Nutzung von Mengen-Operatoren

Mengenlehre in
der Mathematik

In der Mathematik gibt es drei zentrale Rechenoperationen auf Mengen. Mit der Vereinigung werden die Elemente zweier Men-

gen in einer Menge zusammengefasst. Den Durchschnitt zweier Mengen bildet eine Menge der Elemente, die in beiden Ausgangsmengen vorkommt. Zieht man von einer Menge eine andere Menge ab, erhält man eine Menge der Elemente der ersten Menge, die nicht in der zweiten Menge vorkommen.

Mengen enthalten keine doppelten Elemente, SQL-Tabellen eventuell schon

Diese drei Operationen kann man auch auf Tabellen anwenden. Dabei ist der Umgang mit mehrfach vorhandenen Werten zu beachten. Bei mathematischen Mengen können nach der Definition einer Menge keine doppelten Elemente auftreten. Dies ist allerdings in SQL-Tabellen erlaubt. Aus diesem Grund gibt es jeden Mengenoperator in zwei Ausführungen. In der ersten Ausführung wird die Mengeneigenschaft berücksichtigt, d. h. im Ergebnis kann jede Zeile nur einmal auftreten. In der zweiten Ausführung werden die Anzahlen der vorhandenen Elemente berücksichtigt. Ist z. B. ein Element in der einen Tabelle dreimal und in der anderen Tabelle zweimal vorhanden, ist das Element in der Vereinigung fünfmal vorhanden. In der Mathematik spricht man hier von Multimengen.

Diese Erklärung soll zunächst mit mehreren Beispielen veranschaulicht werden. Danach wird der praktische Nutzen noch genauer erläutert.

Vereinigung durch UNION

Möchte man alle Gattungen bestimmen, die in den Gehegen mit den Nummern 2 und 3 leben, so kann man die Menge der Gattungen bestimmen, die im Gehege mit der Nummer 2 leben und die Menge mit den Gattungen aus der Nummer 3 vereinigen. Die zugehörige Anfrage lautet in SQL:

```
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=2
UNION
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=3
```

Das Ergebnis der Anfrage ist:

```
GATTUNG
-----
Hase
Schaf
```

Alternative Berechnung von UNION

Man kann sich leicht überlegen, dass eine Vereinigung eng mit dem OR in der WHERE-Bedingung verwandt ist. Die folgende Anfrage führt zum gleichen Ergebnis, dabei sind die einzelnen

WHERE-Bedingungen mit OR verknüpft, und DISTINCT sorgt dafür, dass keine Mehrfachnennungen möglich sind.

```
SELECT DISTINCT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=2
OR Tier.Gnr=3
```

Aus dem Beispiel lassen sich bereits die Randbedingungen ableiten, die erfüllt sein müssen, damit Mengenoperationen angewandt werden können. Die resultierenden Tabellen der Teilanfragen müssen im Ergebnis die gleiche Spaltenanzahl haben. Weiterhin müssen die Spalten vom Typ her zusammen passen. Also Zahlen zu Zahlen und Texte zu Texten. Zusätzlich müssen die Einträge noch von den Datentypen zusammen passen, z. B. kann ein Text der Länge 10 nicht in ein VARCHAR(5)-Feld eingetragen werden, was anders herum durchaus möglich ist. Es finden keine Umwandlungen zwischen Zahlen und Texten statt.

*Vereinigung
durch UNION
ALL*

Werden mit UNION ALL doppelte Elemente nicht gelöscht, so kann man der Vereinigung ansehen, wie viele Tiere der Gattungen in den Gehegen zusammen vorhanden sind. Die Anfrage lautet:

```
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=2
UNION ALL
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=3
```

Das Ergebnis der Anfrage ist:

```
GATTUNG
-----
Schaf
Hase
Hase
Hase
Hase
Schaf
Schaf
```

*Durchschnitt
mit INTERSECT*

Betrachtet man den Durchschnitt der Ergebnisse der letzten beiden Teilanfragen, ohne Doppelte zu beachten, erhält man die Antwort auf die Frage, welche Gattungen in beiden Gehegen vorkommen.


```
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=2
INTERSECT
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=3
```

Das Ergebnis der Anfrage ist das gleiche wie vorher, da in beiden Gehegen Hasen und Schafe vorkommen:

```
GATTUNG
-----
Hase
Schaf
```

Interessant ist, dass der Durchschnitt nicht direkt mit dem AND in der WHERE-Bedingung verwandt ist. Betrachtet man die folgende Anfrage

```
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=2
AND Tier.Gnr=3
```

so enthält das Ergebnis keine Zeilen, da eine Zeile der Tabelle Tier nicht gleichzeitig verschiedene Gehegennummern enthalten kann. Beim Durchschnitt ist zu beachten, dass zwei unterschiedliche Zeilen betroffen sind. Dies führt zu dem bereits vorgestellten Ansatz, bei dem zwei Einträge der Tabelle Tier, also diese Tabelle doppelt in der FROM-Zeile berücksichtigt werden muss.

Alternative Berechnung von INTERSECT

```
SELECT DISTINCT T1.Gattung
FROM Tier T1, Tier T2
WHERE T1.Gnr=2
AND T2.Gnr=3
AND T1.Gattung=T2.Gattung
```

Man erhält das gleiche Ergebnis wie bei der SQL-Anfrage mit INTERSECT.

Ein alternativer Ansatz mit einer Gruppierung ist nicht einfacher, da hier zwei Gruppen verglichen werden müssen.

Beim Durchschnitt können auch mehrfache Elemente berücksichtigt werden. Im folgenden Beispiel wird berechnet, welche Gattungen wie häufig gleichzeitig in beiden Gehegen vorkommen. Die Anfrage lautet:

Durchschnitt mit INTERSECT ALL

```
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=2
INTERSECT ALL
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=3
```

Das Ergebnis der Anfrage ist:

```
GATTUNG
-----
Hase
Schaf
```

*Mengendiffe-
renz mit EX-
CEPT*

Die beiden bisher vorgestellten Operationen sind symmetrisch, d. h. man kann die Positionen der Teilanfragen vertauschen. Dies ist bei der Mengendifferenz nicht mehr der Fall. Diese wird nach Standard mit EXCEPT berechnet, es gibt allerdings Datenbank-Managementsysteme, die stattdessen das Schlüsselwort MINUS nutzen. Die folgende Anfrage liefert die Gattungen, die im Gehege mit der Nummer 2, aber nicht im Gehege mit der Nummer 3 vorkommen.

```
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=2
EXCEPT
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=3
```

*Keine einfache
Alternative zu
EXCEPT*

Das Ergebnis enthält keine Zeilen. Die Anfrage mit dem gleichen Ergebnis ohne Mengenoperation kann mit dem bisherigen Wissen nicht formuliert werden. Eine alternative Formulierung steht im Unterkapitel „9.3 Teilanfragen in der WHERE-Bedingung“. Ein alternativer Ansatz, der nicht zum Erfolg führt, ist die Anfrage

```
SELECT DISTINCT T1.Gattung
FROM Tier T1, Tier T2
WHERE T1.Gnr=2
AND T2.Gnr=3
AND T1.Gattung<>T2.Gattung
```

Die Anfrage liefert als Ergebnis

```
GATTUNG
-----
Hase
Schaf
```

was nicht dem vorherigen Ergebnis entspricht. Das Problem ist, dass hier nicht zwei Zeilen betrachtet werden müssen, sondern die Kombination einer Zeile mit einem Eintrag mit der Gehegennummer 2 und allen Zeilen, die zur Gehegennummer 3 gehören. Der Vergleich mit einer unbestimmten Anzahl von Zeilen ist mit dem bisher beschriebenen SQL-Anfragemöglichkeiten nicht realisierbar.

Auch bei der Mengendifferenz kann die Elementanzahl berücksichtigt werden. Die folgende Anfrage

Mengendifferenz mit EXCEPT ALL

```
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=2
EXCEPT ALL
SELECT Tier.Gattung
FROM Tier
WHERE Tier.Gnr=3
```

liefert folgendes Ergebnis:

```
GATTUNG
-----
Hase
Hase
```

In der Gegenüberstellung möglicher Anfragen, die zum gleichen Ergebnis führen, hat man bereits gesehen, dass sich durch die Kombination sehr einfacher Anfragen relativ komplexe Anfragen formulieren lassen, für die man sonst den Trick mit der doppelt genannten Tabelle in der FROM-Zeile nutzen müsste. Ein typisches Einsatzfeld von Mengenoperationen ist die Überprüfung der Vollständigkeit von Daten..

Überprüfung auf Vollständigkeit mit EXCEPT

Die Anfrage nach Gattungen, die in der Tabelle Art eingetragen sind, aber nicht in der aktuellen Tierliste vorkommen, lautet:

```
SELECT Art.Gattung
FROM Art
EXCEPT
SELECT Tier.Gattung
FROM Tier
```

Die Antwort enthält keine Ausgabe. Würde eine Gattung ausgegeben, so könnte sie aus der Tabelle Art gelöscht werden. Zu beachten ist, dass EXCEPT nicht symmetrisch ist, also auch die Frage nach Gattungen, die in der Tier-Tabelle stehen, aber nicht in der Tabelle Art eingetragen sind, Sinn macht.

```
SELECT Tier.Gattung
FROM Tier
EXCEPT
SELECT Art.Gattung
FROM Art
```

Im konkreten Beispiel wird wieder keine Zeile ausgegeben. Sind die Tabellen mit FOREIGN KEY-Beziehungen definiert, muss dies auch so sein, da es immer einen Bezug zu einem Eintrag in der Tabelle Art geben muss.

*Überprüfung
von zwei Tabel-
len auf inhalt-
liche Gleichheit*

Generell kann man aus den Betrachtungen einen Ansatz herleiten, der für zwei Tabellen T1 und T2 bestimmt, ob diese den gleichen Inhalt haben. Bildet man die Mengendifferenzen der Tabellen, so müssen beide Differenzen leer sein, also die Anfrage

```
(SELECT *
FROM T1
EXCEPT
SELECT *
FROM T2)
UNION
(SELECT *
FROM T2
EXCEPT
SELECT *
FROM T1)
```

darf keine Ausgabezeile liefern. Falls man Tabellen mit mehrfachen Einträgen hat, muss EXCEPT ALL genutzt werden.

Personal		
PNr	Name	Status
1	Anton	Junior
2	Berti	
3	Conni	
4	Det	Senior

Abb. 9.2: Beispieltabelle mit NULL-Werten

*Vermeidung
von NULL-
Werten in Aus-
gaben*

Eine weitere Einsatzmöglichkeit der Mengenoperationen besteht darin, in Ausgaben Attributwerte abzuändern. Konkret könnte der Wunsch bestehen, NULL-Werte in der Ausgabe durch Standardwerte zu ersetzen. Abb. 9.2 zeigt eine Tabelle, in der für einige Personen vergessen wurde, einen Statuswert anzugeben. In einer Ausgabe soll allerdings kein leeres Feld, sondern der Text „unbekannt“ angezeigt werden. Der Ansatz ist, zunächst die Per-

sonen auszugeben, für die ein Statuswert bekannt ist, und diese Ausgabe dann mit einem Ergebnis einer Anfrage zu vereinigen, in der nur Personen betrachtet werden, deren Status-Wert NULL ist. Für den NULL-Wert wird dann nicht der Status-Wert ausgegeben, sondern in der SELECT-Zeile ein Standardwert definiert. Die Möglichkeit Spalten in der Ausgabe zu ergänzen, wurde im Unterkapitel „7.1 Ausgabe der eingegebenen Informationen“ beschrieben. Die Anfrage lautet:

```
SELECT *
  FROM Personal
 WHERE Personal.Status IS NOT NULL
UNION
SELECT Personal.Pnr, Personal.Name,
        'unbekannt'
  FROM Personal
 WHERE Personal.Status IS NULL
```

Das Ergebnis der Anfrage ist:

	PNR	NAME	STATUS
	1	Anton	Senior
	2	Berti	unbekannt
	3	Conni	unbekannt
	4	Det	Senior

Es sei daran erinnert, dass das Datenbank-Managementsystem ohne Angabe einer ORDER BY-Zeile selbst die Reihenfolge in der Ausgabe bestimmen kann.

9.2

Teilanfragen in der SELECT-Zeile

Teilanfrageergebnis als eigene Ergebnisspalte

Im vorherigen Unterkapitel wurde erneut wie im Kapitel 7 gezeigt, dass man zusätzliche Spalten in Ergebnistabellen erzeugen kann. Diese Idee kann auch genutzt werden, um vorher berechnete Ergebnisse einer Teilanfrage anzuzeigen.

Einzeilige und einspaltige Tabellen als Wert interpretiert

Der Ansatz beruht darauf, dass in SQL einzeilige und einspaltige Ergebnistabellen wie der eingetragene Wert behandelt werden können. Ein Beispiel zeigt die folgende Anfrage, bei der neben den Einträgen der Gehegetabelle noch zusätzlich die insgesamt von den Gehegen verbrauchte Fläche angezeigt werden soll. Die Anfrage lautet:

```
SELECT Gehege.*,
        (SELECT SUM(Gehege.Flaeche)
         FROM Gehege) Gesamtflaeche
  FROM Gehege
```

Das Ergebnis der Anfrage ist:

	GNR	GNAME	FLAECHE	GESAMTFLAECHE
	1	Wald	30	65
	2	Feld	20	65
	3	Weide	15	65

Grundsätzlich kann man davon ausgehen, dass zunächst die innere Anfrage ausgewertet wird und im nächsten Schritt die Auswertung der umgebenden Anfrage geschieht.

*Berechnungen
mit Unterabfra-
geergebnissen*

Statt der einfachen Ausgabe in einer zusätzlichen Spalte, können die Ergebnisse einer Anfrage in einer SELECT-Zeile auch zur Berechnung genutzt werden. Dabei kann der berechnete Wert, wie andere Werte auch, mit anderen Attributwerten verknüpft werden. Mit der folgenden Anfrage wird der Anteil jedes Geheges an der Gesamtfläche ausgegeben.

```
SELECT Gehege.Gname,
       Gehege.Flaeche*100/
       (SELECT SUM(Gehege.Flaeche)
        FROM Gehege) Anteil
FROM Gehege
```

Das Ergebnis der Anfrage ist:

GNAME	ANTEIL
Wald	46,1538462
Feld	30,7692308
Weide	23,0769231

*Verantwortung
des Anfrageers-
tellers für kor-
rekte Ergebnis-
form*

Wichtig bei dieser Form der Schachtelung der Anfragen ist die Verantwortung des Nutzers dafür, dass das Ergebnis der inneren Anfrage genau der gewünschten Form entspricht. Ist dies nicht der Fall, erhält man bei der Ausführung der Anfrage eine Fehlermeldung, wie folgende Anfrage zeigt, bei der eine Verknüpfung mit einer einspaltigen, aber dreizeiligen Ergebnistabelle versucht wird.

```
SELECT Gehege.Gname,
       (SELECT Art.Gattung
        FROM Art)
FROM Gehege
```

Eine typische Reaktion des Systems kann wie folgt aussehen.

```
Unterabfrage für eine Zeile liefert mehr als eine
Zeile
```

Falls die Unterabfrage kein Ergebnis liefert, wird eine Spalte mit NULL-Werten erzeugt, wie folgendes Beispiel zeigt.

```
SELECT Gehege.Gname,
       (SELECT Art.Gattung
        FROM Art
        WHERE Art.MinFlaeche=7) G7
FROM Gehege
```

Das Ergebnis der Anfrage ist:

```
GNAME  G7
-----
Wald
Feld
Weide
```

Insgesamt kann man die Möglichkeit, Anfragen in die SELECT-Zeile einzubauen, als nützlich, aber nicht besonders mächtig ansehen.

9.3

Teilanfragen in der WHERE-Bedingung

Die im vorherigen Unterkapitel vorgestellte Idee, in SQL einzeilige und einspaltige Tabellen als den Wert aufzufassen, der in dem einen Eintrag steht, kann auch in WHERE-Bedingungen genutzt werden. Bisher war es nicht möglich, zu der Größe des größten Geheges auch den Namen dieses Geheges auszugeben. Diese Möglichkeit wird durch folgende Anfrage geschaffen.

Teilanfragen in direkten Größenvergleichen verwenden

```
SELECT Gehege.Gname, Gehege.Flaeche
FROM Gehege
WHERE Gehege.Flaeche=(SELECT MAX(Gehege.Flaeche)
                      FROM Gehege)
```

Das Ergebnis der Anfrage ist:

```
GNAME      FLAECHE
-----
Wald              30
```

Man beachte, dass die Minimum- und Maximum-Berechnung auch auf Texten möglich ist. Das Tier mit dem alphabetisch zuerst vorkommenden Namen, zusammen mit seiner Gattung, kann durch folgende Anfrage bestimmt werden.

```
SELECT Tier.Tname, Tier.Gattung
FROM Tier
WHERE Tier.Tname= (SELECT MIN(Tier.Tname)
                  FROM Tier)
```

Das Ergebnis der Anfrage ist:

```
TNAME      GATTUNG
-----
Bunny      Hase
```

Sollte es mehrere Tiere mit diesem Namen geben, so würden alle Tiere in einer mehrzeiligen Ausgabe ausgegeben werden. Es kann dabei nicht nur auf Gleichheit, sondern auch mit <, <=, >, >= und <> überprüft werden. Mit der folgenden Anfrage werden alle Gattungen ausgegeben, die mindestens soviel Fläche verbrauchen wie der Durchschnitt aller Gattungen.

```
SELECT Art.Gattung
FROM Art
WHERE Art.MinFlaeche>=
      (SELECT AVG(Art.MinFlaeche)
       FROM Art)
```

Das Ergebnis der Anfrage ist:

```
GATTUNG
-----
Baer
Schaf
```

Beachtung der Form des Ergebnisses der Teilanfrage

Wieder ist der Anfragensteller dafür verantwortlich, dass die Teilanfrage ein passendes Ergebnis liefert. Dabei ist typischerweise genau ein Ergebnis sinnvoll. Falls kein Ergebnis vorliegt, wird mit dem NULL-Wert verglichen. Dies ist selten sinnvoll und kann zu ungewöhnlichen Ergebnissen führen. In dem folgenden Beispiel werden in der Teilanfrage alle Gattungen bestimmt, die genau eine MinFläche von 6 benötigen. In der umgebenden Anfrage werden alle Tiere ausgegeben, die zu dieser Gattung gehören.

Leere Ergebnisse bei Teilanfragen erlaubt

```
SELECT Tier.Tname
FROM Tier,Art
WHERE Tier.Gattung=Art.Gattung
      AND Art.Gattung=(SELECT Art.Gattung
                       FROM Art
                       WHERE Art.MinFlaeche=6)
```

Das Ergebnis hat keine Ausgabezeilen, da bei „=NULL“ immer der Wert undefiniert als Ergebnis herauskommt. Wird „=6“ in der letzten Anfrage durch „>=5“ ersetzt, erhält man eine Fehlermeldung der folgenden Art:

```
Unterabfrage für eine Zeile liefert mehr als
eine Zeile
```

Vergleich mit Ergebnislisten von Teilanfragen

Neben den Vergleichen mit einzeiligen und einspaltigen Anfrageergebnissen gibt es auch die Möglichkeit, mit einer einspaltigen Liste von Werten zu vergleichen. Dazu wird in der Teilanfrage eine einspaltige Tabelle berechnet und dann ein Vergleich mit jedem Element dieser Spalte durchgeführt. Es gibt zwei Varianten. In der ersten Variante soll der Vergleich mit allen Elementen

Schrittweise Konstruktion einer Anfrage

erfolgreich sein, erkennbar am Schlüsselwort ALL. In der zweiten Variante soll der Vergleich mit mindestens einem Element der Liste erfolgreich sein, erkennbar am Schlüsselwort ANY.

Mit der ersten Beispielanfrage wird nach den Namen der Gehege gesucht, die mindesten so groß sind wie alle Gehege, in denen Hasen leben. Dazu wird zunächst mit einer Teilanfrage eine Liste der Gehegegrößen erstellt, in denen Hasen leben. Die Teilanfrage lautet:

```
SELECT Gehege.Flaeche
FROM Gehege, Tier
WHERE Gehege.Gnr= Tier.Gnr
      AND Tier.Gattung='Hase'
```

Das Ergebnis dieser Anfrage ist:

```
FLAECHE
-----
      20
      15
      20
      20
```

Diese Anfrage wird in einer Anfrage eingesetzt, in der für auszugebende Gehege gefordert wird, dass ihre Fläche größer-gleich als alle Werte ist, die in der vorher berechneten Liste stehen.

```
SELECT Gehege.Gname
FROM Gehege
WHERE Gehege.Flaeche >= ALL
      (SELECT Gehege.Flaeche
       FROM Gehege, Tier
       WHERE Gehege.Gnr= Tier.Gnr
          AND Tier.Gattung='Hase')
```

Das Ergebnis der Anfrage ist:

```
GNAME
-----
Wald
Feld
```

Vergleich mit ANY

Ist man an Gehegen interessiert, die mindestens so groß sind wie ein Gehege, in denen ein Hase lebt, kann der Vergleich mit ANY stattfinden, da nur nach irgendeinem Gehege mit Hasen gesucht wird, das nicht größer ist.

Die zugehörige Anfrage lautet:

```
SELECT Gehege.Gname
FROM Gehege
WHERE Gehege.Flaeche >= ANY
      (SELECT Gehege.Flaeche
       FROM Gehege, Tier
       WHERE Gehege.Gnr= Tier.Gnr
        AND Tier.Gattung='Hase')
```

Das Ergebnis der Anfrage ist:

```
GNAME
-----
Wald
Feld
Weide
```

*Zusammen-
hang ALL und
ANY mit MAX
und MIN*

Betrachtet man die letzten beiden Anfragen kritisch, so kann man feststellen, dass man Anfragen ohne ANY und ALL formulieren kann, in denen man die MIN- und MAX-Berechnung einsetzt. Die folgenden zwei Anfragen führen nämlich zu den gleichen Ergebnissen.

```
SELECT Gehege.Gname
FROM Gehege
WHERE Gehege.Flaeche >=
      (SELECT MAX(Gehege.Flaeche)
       FROM Gehege, Tier
       WHERE Gehege.Gnr= Tier.Gnr
        AND Tier.Gattung='Hase')
```

und

```
SELECT Gehege.Gname
FROM Gehege
WHERE Gehege.Flaeche >=
      (SELECT MIN(Gehege.Flaeche)
       FROM Gehege, Tier
       WHERE Gehege.Gnr= Tier.Gnr
        AND Tier.Gattung='Hase')
```

Dieser Zusammenhang zwischen ALL und MAX sowie ANY und MIN ist sehr häufig festzustellen. Er gilt immer, wenn keine NULL-Werte auftreten. In diesen Fällen ist es eine Frage des Geschmacks und der Performance des Datenbank-Management-systems, welche Form gewählt wird. Sind NULL-Werte vorhanden, so gilt die aufgezeigte enge Bindung nicht. Dazu wird die Tabelle aus Abb. 9.3 betrachtet.

Personal2

PNr	Name	Status	Gehalt
1	Anton	Junior	2000
2	Berti		4000
3	Conni		1000
4	Det	Senior	3000
5	Edi	Junior	

Abb. 9.3: Tabelle mit NULL-Werten

Es sollen die Namen des Personals ausgegeben werden, das mindestens soviel verdient, wie alle mit dem Status „Junior“. Die Anfrage lautet.

```
SELECT Personal2.Name
FROM Personal2
WHERE Personal2.Gehalt >= ALL
      (SELECT Personal2.Gehalt
       FROM Personal2
       WHERE Personal2.Status='Junior')
```

*NULL-Werte bei
ALL und ANY
beachten*

Eventuell auf den ersten Blick überraschend wird keine Zeile ausgegeben. Der Grund hierfür ist, dass der Vergleich mit jedem Gehalt eines Juniors stattfindet. Dabei ist ein Gehaltswert NULL. Vergleiche mit NULL ergeben „unbekannt“, damit ist die Forderung, dass die Bedingung für jedes Teilergebnis nach „wahr“ ausgewertet wird, nicht immer erfüllt und es wird keine Ergebniszeile berechnet. Die folgende Anfrage nutzt die Maximumsbe-
rechnung.

```
SELECT Personal2.Name
FROM Personal2
WHERE Personal2.Gehalt >=
      (SELECT MAX(Personal2.Gehalt)
       FROM Personal2
       WHERE Personal2.Status='Junior')
```

Das Ergebnis der Anfrage ist:

```
NAME
-----
Anton
Berti
Det
```

Es werden Zeilen ausgegeben, da bei der MAX-Berechnung keine NULL-Werte berücksichtigt werden. Diese Anfrage führt also zum gleichen Ergebnis, als wenn in der vorherigen Teilanfrage NULL-Werte ausgeschlossen würden. Die Anfrage lautet dann:

```
SELECT Personal2.Name
FROM Personal2
WHERE Personal2.Gehalt >= ALL
      (SELECT Personal2.Gehalt
       FROM Personal2
       WHERE Personal2.Status='Junior'
       AND Personal2.Gehalt IS NOT NULL)
```

Vergleichbare Betrachtungen kann man bezüglich NULL-Werten auch für „<= ANY“ durchführen. Man kann daraus ableiten, dass man ANY und ALL nicht einsetzt, wenn man „unerwartet“ auf NULL-Werte treffen könnte.

IN als Alternative zur OR-Verknüpfung

Das Schlüsselwort IN kann in WHERE-Bedingungen auch ohne Teilanfrage genutzt werden. In diesem Fall ersetzt es eine OR-Verknüpfung. In der Syntax steht auf der linken Seite ein Attribut oder ein Wert, der in der Liste, die auf der rechten Seite steht, enthalten sein muss. Möchte man die Namen aller Tiere herausfinden, die ein Bär oder ein Schaf sind, kann dies mit folgender Anfrage geschehen.

```
SELECT Tier.Tname
FROM Tier
WHERE Tier.Gattung = 'Baer'
      OR Tier.Gattung = 'Schaf'
```

Alternativ kann hier auch der IN-Operator genutzt werden.

```
SELECT Tier.Tname
FROM Tier
WHERE Tier.Gattung IN ('Baer','Schaf')
```

Die beiden letzten Anfragen führen beide zum folgenden Ergebnis.

```
TNAME
-----
Laber
Sabber
Harald
Walter
Dörthe
```

IN zur Überprüfung mit berechneter Liste

Statt die Menge auf der rechten Seite direkt anzugeben, kann man diese Menge auch durch eine Anfrage berechnen. Das Ergebnis der Anfrage muss in diesem Fall eine einspaltige Tabelle sein. Es wird geprüft, ob der Wert auf der linken Seite in dieser Liste vorkommt. In der folgenden Anfrage werden die Namen aller Tiere im Zoo gesucht, deren Gattung im Gehege Feld vor-

kommt. Dazu wird zunächst die Liste der Gattungen berechnet, die im Gehege Feld vorkommen. Die Teilanfrage lautet:

```
SELECT Tier.Gattung
FROM Gehege, Tier
WHERE Gehege.Gnr=Tier.Gnr
      AND Gehege.Gname='Feld'
```

Das Ergebnis dieser Anfrage ist:

```
GATTUNG
-----
Hase
Hase
Hase
Schaf
```

Doppelte werden bei IN-Überprüfung ignoriert

Diese Teilanfrage kann jetzt in eine größere Anfrage eingebaut werden, in der für alle Tiere des Zoos überprüft wird, ob ihre Gattung in der berechneten Liste vorkommt. Dabei ist es für das Ergebnis egal, ob in der Teilanfrage nach dem SELECT ein DISTINCT steht oder nicht, da Doppelte bei der Untersuchung mit IN automatisch ignoriert werden. Die Anfrage lautet:

```
SELECT Tier.Tname
FROM Tier
WHERE Tier.Gattung IN
      (SELECT Tier.Gattung
       FROM Gehege, Tier
       WHERE Gehege.Gnr=Tier.Gnr
            AND Gehege.Gname='Feld')
```

Das Ergebnis der Anfrage ist:

```
TNAME
-----
Klopfer
Bunny
Runny
Hunny
Harald
Walter
Dörthe
```

Direkter Bezug von äußerer und innerer Anfrage

Bei den bisherigen verschachtelten Anfragen war es möglich, zuerst die innere Anfrage zu berechnen und dieses Ergebnis dann in der Berechnung der gesamten Anfrage zu nutzen. Dieser Ansatz kann nicht immer gewählt werden. Sollen mit Hilfe von IN die Namen der Gehege ausgegeben werden, in denen ein Hase vorkommt, so lautet der erste Ansatz in der WHERE-Bedingung

```
WHERE 'Hase' IN
      (SELECT Tier.Gattung
       FROM Tier
       WHERE <untersuchtes Gehege>=Tier.Gnr)
```

D. h. das untersuchte Gehege ist abhängig von einem Eintrag in der Tabelle Gehege. Diese Verbindung wird durch folgende Anfrage hergestellt.

```
SELECT Gehege.Gname
FROM Gehege
WHERE 'Hase' IN (SELECT Tier.Gattung
                 FROM Tier
                 WHERE Gehege.Gnr=Tier.Gnr)
```

Das Ergebnis der Anfrage ist:

```
GNAME
-----
Feld
Weide
```

*Abarbeitung
geschachtelter
Anfragen*

Anschaulich erkennt man, dass in der äußeren Anfrage eine Untersuchung für alle Gehege startet. Für jedes dieser Gehege wird dann in der WHERE-Bedingung untersucht, ob sich ein Hase in diesem Gehege befindet. Zu diesem Zweck muss in der inneren Anfrage auf das äußere Gehege Bezug genommen werden. Grundsätzlich gilt, dass alle Tabellen der äußeren Anfrage auch in der inneren Teilanfrage zugänglich sind. Dabei müssen auch lokale Umbenennungen der Tabellen in der inneren Teilanfrage berücksichtigt werden.

*Typische Fehlerquelle bei der
Schachtelung
von Anfragen*

Bei der Erstellung solcher geschachtelten Anfragen machen Anfänger häufig den Fehler, die Information aus der äußeren Anfrage in der inneren Anfrage zu wiederholen. Die letzte Anfrage sieht dann in falscher Form wie folgt aus:

```
SELECT Gehege.Gname
FROM Gehege
WHERE 'Hase' IN (SELECT Tier.Gattung
                 FROM Gehege,Tier
                 WHERE Gehege.Gnr=Tier.Gnr)
```

Diese Anfrage wird mit folgendem, zunächst irritierenden Ergebnis ausgeführt:

```
GNAME
-----
Wald
Feld
Weide
```

Analyse einer funktionierenden, aber sinnlosen Anfrage

Es ist zu beachten, dass die Gehege-Information in der inneren Anfrage die Gehege-Information der äußeren Anfrage überdeckt, diese ist nicht sichtbar. Die Gehege-Information der inneren Anfrage hat also nichts mit der äußeren Anfrage zu tun. Mit der inneren Anfrage wird eine Liste aller in der Tabelle Tier vorkommenden Gattungen berechnet. Durch den IN-Operator wird geprüft, ob Hase in dieser Liste vorkommt, was der Fall ist. In der äußeren Anfrage wird somit für jedes Gehege geprüft, ob ein Hase in der Liste aller Tiere vorkommt. Der Zusammenhang zwischen dem in der äußeren Anfrage konkret betrachteten Gehege und der inneren Anfrage ist völlig verloren gegangen. Damit ist die Antwort Wald auch korrekt, da in der WHERE-Bedingung überhaupt nur überprüft wird, ob es Hasen in der Tabelle Tier gibt.

Zur Vervollständigung sei erwähnt, dass man in diesem Fall auch ohne den IN-Operator auskommen kann. Die alternative korrekte Anfrage mit dem gleichen Ergebnis ist:

```
SELECT DISTINCT Gehege.Gname
FROM Gehege, Tier
WHERE Gehege.Gnr=Tier.Gnr
      AND Tier.Gattung='Hase'
```

Möglichkeit, die Kombination von Attributen mit IN zu prüfen

Abhängig von der SQL-Implementierung des Datenbank-Managementsystems können nicht nur einfache Attribute mit IN gesucht werden, sondern auch Paare von Attributen, dabei muss die Anzahl der Attribute auf der linken Seite mit der Spaltenanzahl des Ergebnisses der Teilanfrage übereinstimmen. Ein Beispiel ist die Anfrage nach den Namen der Gehege, in denen ein Schaf namens Harald vorkommt.

```
SELECT Gehege.Gname
FROM Gehege
WHERE ('Harald','Schaf') IN
      (SELECT Tier.Tname, Tier.Gattung
       FROM Tier
       WHERE Gehege.Gnr=Tier.Gnr)
```

Diese Anfrage kann natürlich auch ohne Anfragenschachtelung gestellt werden. Sie lautet dann:

```
SELECT Gehege.Gname
FROM Gehege, Tier
WHERE Gehege.Gnr=Tier.Gnr
      AND Tier.Tname='Harald'
      AND Tier.Gattung='Schaf'
```

Das Ergebnis der beiden letzten Anfragen ist:

```
GNAME
-----
Feld
```

Für NULL-Werte ist zu beachten, dass „NULL IN ...“ unabhängig von der Liste nach „undefiniert“ ausgewertet wird.

*Grundidee der
EXISTS-
Auswertung*

Eine weitere Möglichkeit zur Auswahl in der WHERE-Bedingung bietet der EXISTS-Operator. Dieser Operator wird nach „wahr“ ausgewertet, wenn die im EXISTS-Operator geschachtelte Anfrage mindestens eine Ergebniszeile liefert. Falls keine Ergebniszeile geliefert wird, wird der Operator nach „falsch“ ausgewertet. Ohne auf die syntaktischen Details einzugehen, bleibt festzuhalten, dass die Inhalte der Ergebnisse der inneren Anfragen beim EXISTS-Operator keine Rolle spielen. Es ist nur wichtig, ob keine oder mindestens eine Ergebniszeile geliefert wird.

*Bezug zwischen
äußerer und
innerer Anfrage*

Ähnlich wie beim IN-Operator, ist ein enger Bezug zwischen äußerer und innerer Anfrage notwendig. Es wird für Elemente der äußeren Anfrage überprüft, ob sie eine zusätzliche Eigenschaft erfüllen. Ein Beispiel ist die Anfrage nach den Gehegen, in denen mindestens auch ein Hase lebt, für die bereits alternative Ansätze vorgestellt wurden. Unter Nutzung des EXISTS-Operators lautet die Anfrage:

```
SELECT Gehege.Gname
FROM Gehege
WHERE EXISTS (SELECT *
              FROM Tier
              WHERE Tier.Gnr=Gehege.Gnr
                 AND Tier.Gattung='Hase')
```

Das Ergebnis der Anfrage ist

```
GNAME
-----
Feld
Weide
```

Wieder ist wichtig, dass in der inneren Anfrage auf die außen betrachteten Gehege Bezug genommen wird, damit ein innerer Zusammenhang der Anfrage gewährleistet ist. Die bei der Vorstellung des IN-Operators aufgezeigte Fehlerquelle, die Tabelle Gehege erneut in der inneren Anfrage aufzuführen, ist auch für Anfragen mit EXISTS typisch.

*Mengenunter-
suchungen mit
EXISTS*

Am Anfang dieses Unterkapitels wurde bei der Vorstellung des EXCEPT-Operators bei den Mengenbetrachtungen gezeigt, dass

es keine einfache Alternative zur Formulierung der Anfrage gibt. Mit dem EXISTS-Operator wird eine Alternative angeboten. Dies ist besonders deshalb interessant, da einige größere Datenbank-Managementsysteme nicht EXCEPT, dafür aber EXISTS unterstützen.

Es wurden die Gattungen gesucht, die im Gehege mit der Nummer 2, aber nicht im Gehege mit der Nummer 3 vorkommen. Diese Anfrage kann wie folgt formuliert werden.

```
SELECT T1.Gattung
FROM Tier T1
WHERE T1.Gnr=2
      AND NOT EXISTS (SELECT *
                      FROM Tier T2
                      WHERE T2.Gnr=3
                      AND T1.Gattung=T2.Gattung)
```

Als Ergebnis wird wie erwartet keine Zeile ausgegeben. Da hier zweimal der Bezug zur Tabelle Tier aufgebaut wird, müssen die Tabellen lokal umbenannt werden. Damit kann wieder in der inneren Teilanfrage ein Bezug zur Tier-Information der äußeren Anfrage aufgebaut werden.

Mit der nächsten Anfrage werden die Namen der Gehege ausgegeben, in denen nur eine Gattung lebt.

```
SELECT Gehege.Gname
FROM Gehege, Tier T1
WHERE Gehege.Gnr=T1.Gnr
      AND NOT EXISTS (SELECT *
                      FROM Tier T2
                      WHERE T2.Gnr=T1.Gnr
                      AND T1.Gattung<>T2.Gattung)
```

*Doppelte Ver-
neinungen und
EXISTS-
Nutzung*

Der Aufbau der Anfrage mag zunächst leicht irritieren. Es hat eine logische Umformung stattgefunden. Konkret wird nach Gehegen gesucht, bei denen für alle Tiere im Gehege gilt, dass sie die gleiche Gattung haben. Dies ist aber gleichwertig zu der Suche nach Gehegen, in denen es kein Tier gibt, das eine andere Gattung wie ein anderes Tier dieses Geheges hat. Diese etwas verschachtelte Umformulierung wurde zur Erstellung der Anfrage genutzt.

Das Ergebnis der Anfrage lautet

```
GNAME
-----
Wald
Wald
```

Zusammenhang zwischen EXISTS in SQL und Prädikatenlogik

[*] Leser der Erklärung der letzten Anfrage mit einer Grundlagen-ausbildung in Mathematik oder Logik werden den Zusammenhang des EXISTS-Operators in SQL mit dem Existenz-Quantor der Prädikatenlogik, siehe z. B. [Sch04] für eine Einführung, erkennen. Typisch für die Prädikatenlogik ist die Formulierung „Es gibt ein Gehege aus der Menge aller Gehege, das folgende Eigenschaft hat ...“. Eine mathematische Notation ist z. B.:

$\exists g \in \text{Gehege: hat_Eigenschaft}(g)$

Das Ergebnis dieser Formel ist eine Menge von Gehegen, die man mit dem Ergebnis einer Anfrage vergleichen kann. Aus der Prädikatenlogik ist auch bekannt, dass man Aussagen der Form „Für alle Elemente der Menge X gilt die Eigenschaft e.“ logisch äquivalent umformen kann in die Aussage „Es gibt kein Element der Menge X, das die Eigenschaft e nicht hat“. In der mathematischen Notation kann dies wie folgt aussehen, dabei steht $\equiv$ für „diese Aussagen sind logisch äquivalent“:

$\forall x \in X: e(x) \quad \equiv \quad \text{NOT}(\exists x \in X: \text{NOT}(e(x)))$

Der Ansatz, dass All-Quantoren durch Existenz-Quantoren beschrieben werden können, wurde auch in der letzten SQL-Anfrage genutzt. Wegen dieser Umformungsmöglichkeit ist in fast allen Datenbank-Managementsystemen auch keine Implementierung eines im SQL-Standard angegebenen ALL-Operators vorhanden.

9.4

Verwandtschaft zwischen HAVING und WHERE bei Teilanfragen

Teilanfragen in der HAVING-Bedingung

Die HAVING-Bedingung ist eng verwandt mit der WHERE-Bedingung. Mit der HAVING-Bedingung werden Gruppen für das Ergebnis der Anfrage ausgewählt, mit der WHERE-Bedingung einzelne Zeilen. Aus diesem Grund können die Überlegungen zu Teilanfragen in der WHERE-Bedingung direkt auf die Teilanfragen in der HAVING-Bedingung übertragen werden. Zu beachten ist, dass ein Vergleich mit Eigenschaften der Gruppen stattfindet und als einziger wichtiger Unterschied, dass kein Bezug zu Tabellen der äußeren Anfrage möglich ist. Eine weitere Randbedingung ergibt sich aus den unterschiedlichen SQL-Implementierungen in den Datenbank-Managementsystemen, die nicht alle theoretischen Möglichkeiten der HAVING-Bedingung unterstützen. Teilweise sind überhaupt keine Teilanfragen in der HAVING-Bedingung erlaubt.

*Teilanfrage in
HAVING-
Bedingung mit
eigener Berech-
nung*

Mit der folgenden Anfrage sollen die Gehege gesucht werden, deren Tiere zusammen auch im kleinsten Gehege leben könnten. Dazu wird in der HAVING-Bedingung ein Vergleich mit der zu bestimmenden kleinsten Gehegefläche durchgeführt. Anschaulich passen z. B. die beiden Bären im Gehege Wald mit ihrem Bedarf von 16 nicht in das kleinste Gehege mit einer Fläche von 15. Die zugehörige Anfrage lautet:

```
SELECT Gehege.Gname
FROM Gehege, Tier, Art
WHERE Gehege.Gnr=Tier.Gnr
AND Tier.Gattung=Art.Gattung
GROUP BY Gehege.Gname
HAVING SUM(Art.Minflaeche)<=
        (SELECT MIN(Gehege.Flaeche)
         FROM Gehege)
```

Das Ergebnis der Anfrage ist

```
GNAME
-----
Feld
Weide
```

*eingeschränkter
Bezug auf äu-
ßere Anfrage*

In der Einleitung dieses Unterkapitels wurde beschrieben, dass kein Bezug zur äußeren Anfrage bezüglich der Tabellen in der inneren Anfrage aufgebaut werden darf. In Teilanfragen dürfen entweder nur vollständig neue Berechnungen, wie im vorherigen Beispiel gezeigt, oder Elemente stehen, die auch sonst bereits in der HAVING-Bedingung stehen durften. Dies sind Aggregatsfunktionen für Berechnungen in den jeweiligen Gruppen und Attribute, die in der GROUP BY-Zeile genannt werden. Folgende Anfrage ist z. B. nicht möglich.

```
SELECT Gehege.Gname, SUM(Art.Minflaeche)
FROM Gehege, Tier, Art
WHERE Gehege.Gnr=Tier.Gnr
AND Tier.Gattung=Art.Gattung
GROUP BY Gehege.Gname
HAVING EXISTS (SELECT *
                FROM Tier T2
                WHERE Gehege.Gnr=T2.Gnr
                AND T2.Gattung='Baer')
```

Generell hat die Anfrage einen Sinn, da der Flächenverbrauch der Tiere in den Gehegen berechnet werden soll und in der inneren Anfrage zusätzlich überprüft wird, ob ein Bär im Gehege lebt. Eine zugehörige Fehlermeldung besagt aber, dass ein Zugriff auf Gehege.Gnr nicht erlaubt ist, da das Attribut nicht in der GROUP BY-Zeile steht. Im konkreten Fall kann diese Infor-

mation in die GROUP BY-Zeile aufgenommen werden, da der Gehege-Name alleine und die Gehegenummer im Beispiel eindeutig sind. Das resultierende Ergebnis ist

GNAME	SUM(ART.MINFLAECHE)
Wald	16

Dieser Ansatz ist nicht immer möglich, typische Lösungsansätze für diese Problematiken findet man im folgenden Unterkapitel.

9.5

Teilanfragen in der FROM-Zeile

Zwischenergebnisse in der FROM-Zeile verwalten

Teilanfragen in der FROM-Zeile ermöglichen eine strukturierte Entwicklung von Anfragen. Dabei ist daran zu denken, dass es grundsätzlich unerwünscht ist, dass bei Anfragen Zwischenergebnisse „heimlich“ notiert werden. Man sollte nie fest davon ausgehen, dass es z. B. nur drei Gehege mit den bekannten Namen gibt.

Anfragergebnisse sind Tabellen

Aus den bisherigen Erklärungen zu den SQL-Anfragen folgt allerdings konsequent, dass in den folgenden Beispielen nichts Neues passieren kann. Es werden nur die Aussagen „In der FROM-Zeile stehen nur Tabellen“ und „Das Ergebnis jeder SQL-Anfrage ist eine Tabelle“ zusammengesetzt.

Schrittweise Entwicklung komplexer Anfragen

Die Grundidee ist, eine komplexe Aufgabenstellung für eine Anfrage in einfachere Teilanfragen zu zerlegen. Diese Teilanfragen liefern Tabellen als Ergebnisse. Diese Teilanfragen werden dann in der FROM-Zeile als benötigte Tabellen angegeben und zur Lösung der Gesamtaufgabe genutzt.

Dieser Ansatz soll mit einem einfachen Beispiel genauer betrachtet werden, für das man allerdings auch schon mit den vorher beschriebenen Ansätzen eine sinnvolle Anfrage hätte schreiben können. Es soll berechnet werden, wie viel Fläche in jedem Gehege von Hasen verbraucht wird. Statt lange an einer komplexeren Lösung zu basteln, kann man sich überlegen, zunächst die Anzahl der Hasen pro Gehege zu zählen. Dies geschieht mit der folgenden Anfrage.

```
SELECT Gehege.Gname Gehege-Name,
       COUNT(*) Hasenanzahl
FROM Gehege, Tier
WHERE Gehege.Gnr=Tier.Gnr
      AND Tier.Gattung='Hase'
GROUP BY Gehege.Gname
```

Das Ergebnis dieser Anfrage ist:

GEHEGE	HASENANZAHL
-----	-----
Feld	3
Weide	1

*Teilergebnis in
FROM-Zeile
einbauen*

Im nächsten Schritt muss die berechnete Hasenanzahl mit dem Flächenverbrauch des Hasen multipliziert werden. Dazu wird die Tabelle Art und die gerade neu berechnete Tabelle, genauer ihre Anfrage, in die FROM-Zeile aufgenommen. Der Rest ist die Standardarbeit bei der Anfragenerstellung. In der WHERE-Bedingung findet, wenn nötig, die Verknüpfung der Tabellen und die Nennung von Randbedingungen statt, und in der SELECT-Zeile wird das gewünschte Ergebnis berechnet.

```
SELECT Hasentabelle.Gehegename,
       Hasentabelle.Hasenanzahl*Art.MinFlaeche
       Hasenflaechenverbrauch
FROM Art,
     (SELECT Gehege.Gname Gehegename,
          COUNT(*) Hasenanzahl
      FROM Gehege, Tier
      WHERE Gehege.Gnr=Tier.Gnr
            AND Tier.Gattung='Hase'
      GROUP BY Gehege.Gname) Hasentabelle
WHERE Art.Gattung='Hase'
```

Das Ergebnis der Anfrage ist:

GEHEGE	HASENFLAECHENVERBRAUCH
-----	-----
Feld	6
Weide	2

Man hätte ohne diese Schachtelung auskommen können, allerdings verlangt die Erstellung der folgenden Anfrage, die zum gleichen Ergebnis führt, mehr SQL-Erfahrung.

```
SELECT Gehege.Gname Gehege,
       COUNT(*)*Art.MinFlaeche Hasenflaechenverbrauch
FROM Gehege, Tier, Art
WHERE Gehege.Gnr=Tier.Gnr
      AND Tier.Gattung=Art.Gattung
      AND Tier.Gattung='Hase'
GROUP BY Gehege.Gname, Art.MinFlaeche
```

Im Ergebnis der Anfrage fällt auf, dass ein Gehege fehlt, da in diesem kein Hase lebt. Bei der Erklärung der Mengen-Operatoren im Unterkapitel „9.1 Nutzung von Mengen-Operatoren“ wurde gezeigt, wie man Zeilen, die kein Ergebnis produzie-

ren, mit einer Mengenvereinigung anhängen kann. Dieser Ansatz kann auch in der Teilanfrage genutzt werden.

```
SELECT Hasentabelle.GehegeName,
       Hasentabelle.Hasenanzahl*Art.MinFlaeche
       Hasenflaechenverbrauch
FROM Art,
( SELECT Gehege.GName GehegeName,
  COUNT(*) Hasenanzahl
  FROM Gehege, Tier
  WHERE Gehege.Gnr=Tier.Gnr
    AND Tier.Gattung='Hase'
  GROUP BY Gehege.GName
UNION
SELECT Gehege.GName, 0
  FROM Gehege
  WHERE NOT EXISTS(SELECT *
                   FROM Tier
                   WHERE Gehege.Gnr=Tier.Gnr
                   AND Tier.Gattung='Hase')
) Hasentabelle
WHERE Art.Gattung='Hase'
```

Das Ergebnis der Anfrage ist:

GEHEGE	HASENFLAECHENVERBRAUCH
Feld	6
Wald	0
Weide	2

*Umbenennun-
gen fördern
Lesbarkeit*

Das Beispiel zeigt, wie man systematisch die Erstellung einfacher Anfragen zum Zusammenbau einer komplexen Anfrage nutzen kann. Die Spalten- und Tabellenumbenennungen in der FROM-Zeile sind nicht an allen Stellen notwendig, können aber generell zur Erhöhung der Lesbarkeit beitragen.

Mit der nächsten Anfrage soll berechnet werden, welchen Anteil jedes Tier an der insgesamt für Gehege zur Verfügung stehenden Fläche hat. Eine vergleichbare Anfrage wurde bereits im Unterkapitel „9.2 Teilanfragen in der SELECT-Zeile“ betrachtet, dabei wurde die Gesamtfläche in der SELECT-Zeile in einer Teilanfrage berechnet. Ein vergleichbarer Ansatz ist auch mit einer Teilanfrage in der FROM-Zeile möglich. Dabei wird die Gesamtfläche in einer einzeiligen und einspaltigen Tabelle berechnet.

```
SELECT Gehege.GName, Tier.TName,
       Art.Minflaeche/Alle.Gesamtflaeche*100
       Gehegeanteil
FROM Gehege, Tier, Art,
( SELECT SUM(Gehege.Flaeche)
```

```

                                Gesamtflaeche
                                FROM Gehege) Alle
WHERE Gehege.Gnr=Tier.Gnr
AND Tier.Gattung=Art.Gattung

```

Das Ergebnis der Anfrage ist:

GNAME	TNAME	GEHEGEANTEIL
-----	-----	-----
Wald	Laber	12,3076923
Wald	Sabber	12,3076923
Feld	Klopfer	3,07692308
Weide	Bunny	3,07692308
Feld	Runny	3,07692308
Feld	Hunny	3,07692308
Feld	Harald	7,69230769
Weide	Walter	7,69230769
Weide	Dörthe	7,69230769

In der folgenden Anfrage soll schrittweise berechnet werden, wie viel Fläche in den einzelnen Gehegen noch frei ist. Dazu wird zunächst berechnet, wie viel Fläche schon verbraucht ist und im zweiten Schritt mit der vorhandenen Gesamtfläche verglichen. Die geschachtelte Anfrage lautet:

```

SELECT Gehege.Gname,
       Gehege.Flaeche-Belegung.Verbraucht Frei
FROM Gehege,
     (SELECT Gehege.Gname,
            SUM(Art.Minflaeche) Verbraucht
      FROM Gehege,Tier,Art
     WHERE Gehege.Gnr=Tier.Gnr
           AND Tier.Gattung=Art.Gattung
     GROUP BY Gehege.Gname) Belegung
WHERE Gehege.Gname=Belegung.Gname

```

Das Ergebnis der Anfrage ist:

GNAME	FREI
-----	-----
Feld	9
Wald	14
Weide	3

*Schachtelung
unterstützt
schrittweise
Anfragenerstel-
lung*

Wieder wäre eine Berechnung ohne Schachtelung möglich, allerdings müssen zur Erstellung einer solchen Anfrage immer sehr viele Details zur gleichen Zeit berücksichtigt werden. Teilanfragen in der FROM-Zeile stellen deshalb eine sinnvolle Alternative in der Anfragenentwicklung dar.

9.6

[*] Verschiedene Join-Operatoren

Bei der Verknüpfung der Tabellen in den vorherigen Unterkapiteln und Kapiteln fällt auf, dass man häufig Teilbedingungen, wie `Gehege.Gnr=Tier.Gnr`, formuliert. Dies kann als etwas mühselig angesehen werden. Aus diesem Grund wurden Alternativen für die Auswahl und Verknüpfung der Tabellen in der `FROM`-Zeile entwickelt. Weitere Operatoren ermöglichen es, häufiger benötigte Anfrage-Strukturen kompakter hinzuschreiben.

Dieses Unterkapitel wurde mit einem [*] markiert, da er für Personen, die sich das erste Mal mit Datenbanken beschäftigen, irritierend wirken kann. Grundsätzlich gilt, dass durch die vorgestellten Join-Operatoren keine neuen Ausdrucksmöglichkeiten gewonnen werden. Alle Ergebnisse der Join-Operatoren können auch mit den bisher vorgestellten SQL-Anfragen berechnet werden. Zu beachten ist aber, dass einzelne Datenbank-Managementsysteme in ihren Dokumentationen die hier vorgestellte Form der Join-Operatoren bevorzugen und vereinzelt das Komma zur Trennung der ausgewählten Tabellen nicht mehr möglich ist. Weiterhin können JOIN-Operatoren helfen, die Arbeit für erfahrene Anfragen-Ersteller zu verkürzen.

Joins als abkürzende Schreibweise für Experten

Verkäufer		Verkauf		
VNR	Name	Nr	VNr	Produkt
1	Udo	1	1	Hose
2	Uwe	2	1	Rock
3	Ulf	3	2	Schal
		4		Anzug

Abb. 9.4: Beispieltabellen für JOIN-Erklärung

Die unterschiedlichen Join-Operatoren werden mit einem einfachen Beispiel vorgestellt. In den Tabellen in Abb. 9.4 gibt es eine Tabelle mit Daten zu Verkäufern und Daten zu zuletzt gemachten Verkäufen. Alle Verkäufe werden durch Nr durchnummeriert. Der Verkäufer, der einen Kunden beraten hat, wird mit in die Verkaufsinformation aufgenommen. Es ist aber auch möglich, dass ein Kunde direkt zur Kasse geht und kein Verkäufer als Berater vermerkt wird.

Beide Tabellen sind über VNr verknüpft, was bis jetzt in der `WHERE`-Bedingung mit `Verkäufer.VNr=Verkauf.VNr` beschrieben wurde. Diese Verknüpfungsbedingung kann wie folgt ausgelagert werden.

JOIN


```
SELECT *
FROM Verkaeufuer JOIN Verkauf
ON Verkaeufuer.VNr=Verkauf.VNr
```

das Ergebnis ist:

VNR	NAME	NR	VNR	PRODUKT
1	Udo	1	1	Hose
1	Udo	2	1	Rock
2	Uwe	3	2	Schal

Diese und die folgenden Anfragen können durch WHERE-Bedingungen ergänzt werden, die hier nur aus Vereinfachungsgründen weggelassen wurden.

LEFT JOIN

Sollen im Ergebnis immer alle Einträge der linken Tabelle sichtbar werden, egal ob es zugehörige Werte in der rechten Tabelle gibt, kann ein LEFT JOIN genutzt werden. Gibt es keine zugehörigen Werte, werden NULL-Werte in den Spalten eingetragen. Im Beispiel möchte man z. B. wissen, wer was verkauft hat, dabei sollen alle Verkäufer im Ergebnis sichtbar werden. Die Anfrage lautet wie folgt:

```
SELECT *
FROM Verkaeufuer LEFT JOIN Verkauf
ON Verkaeufuer.VNr=Verkauf.VNr
```

Das Ergebnis ist:

VNR	NAME	NR	VNR	PRODUKT
1	Udo	1	1	Hose
1	Udo	2	1	Rock
2	Uwe	3	2	Schal
3	Ulf			

RIGHT JOIN

Ist man, statt an den Verkäufern, an allen Verkäufen interessiert, kann man hier den RIGHT JOIN nutzen.

```
SELECT *
FROM Verkaeufuer RIGHT JOIN Verkauf
ON Verkaeufuer.VNr=Verkauf.VNr
```

Das Ergebnis ist:

VNR	NAME	NR	VNR	PRODUKT
1	Udo	2	1	Rock
1	Udo	1	1	Hose
2	Uwe	3	2	Schal
		4		Anzug

FULL JOIN

Möchte man alle Verkäufer und alle Verkäufe im Ergebnis sehen, kann der FULL JOIN genutzt werden.

```
SELECT *
FROM Verkaeuer FULL JOIN Verkauf
ON Verkaeuer.VNr=Verkauf.VNr
```

Das Ergebnis ist:

VNR	NAME	NR	VNR	PRODUKT
1	Udo	2	1	Rock
1	Udo	1	1	Hose
2	Uwe	3	2	Schal
3	Ulf	4		Anzug

Nutzung
gleichnamiger
Attribute zur
automatischen
Verknüpfung

Haben die Spalten den gleichen Namen, wie es in dem Beispiel der Fall ist, kann dies wie folgt zur Verknüpfung angegeben werden:

```
SELECT *
FROM Verkaeuer JOIN Verkauf USING (VNR)
```

Das Ergebnis ist:

VNR	NAME	NR	PRODUKT
1	Udo	1	Hose
1	Udo	2	Rock
2	Uwe	3	Schal

NATURAL JOIN

Es fällt auf, dass die doppelte Spalte nicht mehr in der Ausgabe erscheint. Diese Idee wird ebenfalls bei den NATURAL JOINS genutzt, bei denen davon ausgegangen wird, dass die beteiligten Tabellen Spalten gleichen Namens und gleichen Typs haben, sowie dass bei der Verknüpfung diese Werte übereinstimmen sollen. Die folgende Anfrage liefert deshalb das gleiche Ergebnis wie die vorherige Anfrage.

```
SELECT *
FROM Verkaeuer NATURAL JOIN Verkauf
```

NATURAL LEFT JOIN

Bei den NATURAL JOINS kann man sich ebenfalls entscheiden, ob man Zeilen einer Tabelle, die nicht in mindestens einer Ver-

knüpfung genutzt werden, auch im Ergebnis sehen möchte. Dies wird an folgenden Anfragen und deren Ergebnissen verdeutlicht.

```
SELECT *
FROM Verkaeufer NATURAL LEFT JOIN Verkauf
```

Das Ergebnis ist:

VNR	NAME	NR	PRODUKT
1	Udo	1	Hose
1	Udo	2	Rock
2	Uwe	3	Schal
3	Ulf		

*NATURAL
RIGHT JOIN*

```
SELECT *
FROM Verkaeufer NATURAL RIGHT JOIN Verkauf
```

Das Ergebnis ist:

VNR	NAME	NR	PRODUKT
1	Udo	2	Rock
1	Udo	1	Hose
2	Uwe	3	Schal
		4	Anzug

*NATURAL FULL
JOIN*

```
SELECT *
FROM Verkaeufer NATURAL FULL JOIN Verkauf
```

Das Ergebnis ist:

VNR	NAME	NR	PRODUKT
1	Udo	1	Hose
1	Udo	2	Rock
2	Uwe	3	Schal
3	Ulf		
		4	Anzug

*Ergebnisse von
Joins ohne Join
berechenbar*

Es bleibt festzuhalten, dass man die Anfrageergebnisse der in diesem Unterkapitel vorgestellten JOINS auch erhalten kann, wenn man nur die davor vorgestellten Standardanfragemöglichkeiten nutzt. Gerade bei den Anfragen, in denen auch NULL-Werte im Ergebnis sind, sind die alternativen Anfragen allerdings recht aufwändig. Möchte man die letzte Anfrage mit den bisherigen Anfragemöglichkeiten berechnen, kann man sich überlegen, dass man zunächst die verknüpften Werte berechnet, dann alle Verkäufer ergänzt, die nichts verkauft haben, und dann alle Ver-

käufe hinzufügt, an denen kein Verkäufer beteiligt war. Die Anfrage lautet dann:

```

SELECT Verkaeuf.VNr, Verkaeuf.Name,
       Verkauf.Nr, Verkauf.Produkt
FROM Verkaeuf, Verkauf
WHERE Verkaeuf.VNr=Verkauf.VNr
UNION
SELECT Verkaeuf.VNr, Verkaeuf.Name,
       NULL Nr, NULL Produkt
FROM Verkaeuf
WHERE NOT EXISTS(SELECT *
                  FROM Verkauf
                  WHERE Verkaeuf.VNr=Verkauf.VNr)
UNION
SELECT NULL VNr, NULL Name,
       Verkauf.Nr, Verkauf.Produkt
FROM Verkauf
WHERE NOT EXISTS(SELECT *
                  FROM Verkaeuf
                  WHERE Verkaeuf.VNr=Verkauf.VNr)

```

9.7

Fallstudie

Die letzten noch offenen Anfragen, die im einleitenden Unterkapitel „2.6 Fallstudie“ beschrieben wurden, können jetzt formuliert werden.

Gib zu jedem Risiko die Anzahl der getroffenen Maßnahmen aus. Dabei ist zu beachten, dass auch Risiken aufgeführt werden, für die es noch keine Maßnahmen gibt. Aus diesem Grund besteht die Anfrage aus zwei Teilanfragen, im ersten Teil findet die statistische Auswertung mit einer Gruppierung, im zweiten Teil die Suche nach Risiken ohne Maßnahmen statt.

```

SELECT Risiko.Text,
       COUNT(*) Massnahmenanzahl
FROM Risiko, Zuordnung
WHERE Risiko.RNr= Zuordnung.Risiko
GROUP BY Risiko.Text
UNION
SELECT Risiko.Text, 0
FROM Risiko
WHERE NOT EXISTS (SELECT *
                  FROM Zuordnung
                  WHERE Risiko.RNr= Zuordnung.Risiko)

```

Ausgabe:

TEXT	MASSNAHMENANZAHL
-----	-----
Abnahmeprozess offen	1
Anforderungen unklar	1
Ansprechpartner wechseln	0
neue Entwicklungsumgebung	1

Gib zu jedem Projekt die Risikogruppen aus, für die es kein zugeordnetes Risiko im Projekt gibt. In der inneren Anfrage werden von allen Risikogruppen die Risikogruppen abgezogen, die in einem zu untersuchenden Projekt vorkommen. Das zu untersuchende Projekt wird in der äußeren Anfrage festgelegt.

```
SELECT Projekt.Name, Risikogruppe.Gruppe
FROM Projekt, Risikogruppe
WHERE Risikogruppe.RGNr IN (
    SELECT Risikogruppe.RGNr
    FROM Risikogruppe
MINUS
    SELECT Risiko.Gruppe
    FROM Risiko
    WHERE Risiko.Gruppe=Risikogruppe.RGNr
    AND Risiko.Projekt=Projekt.ProNr)
```

Ausgabe:

NAME	GRUPPE
-----	-----
WebShop	Vertrag
GUI	Ausbildung

Gib die Risiken aus, für die keine Maßnahmen ergriffen wurden.

```
SELECT Risiko.Text
FROM Risiko
WHERE Risiko.RNr IN (
    SELECT Risiko.RNr
    FROM Risiko
MINUS
    SELECT Zuordnung.Risiko
    FROM Zuordnung)
```

Ausgabe:

TEXT

Ansprechpartner wechseln

9.8**Aufgaben****Wiederholungsfragen**

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu beantworten.

1. Welche Mengenoperatoren können wie in SQL-Anfragen eingesetzt werden?
2. Wie wird mit doppelten Einträgen in Ergebnissen bei Mengenoperationen in SQL umgegangen?
3. Wie kann man prüfen, ob zwei Tabellen den gleichen Inhalt haben?
4. Wie kann man in Anfragen im Ergebnis sichtbar machen, dass es zu einer Gruppierung keinen resultierenden Wert gibt?
5. Wie können Teilanfragen in der SELECT-Zeile genutzt werden?
6. Wie können Teilanfragen in der WHERE-Zeile genutzt werden?
7. Wozu können ALL und ANY vor Teilanfragen in der WHERE-Zeile genutzt werden?
8. Wozu kann IN in Teilanfragen in der WHERE-Zeile genutzt werden?
9. Wozu kann EXISTS in Teilanfragen in der WHERE-Zeile genutzt werden?
10. Was versteht man unter der Verknüpfung von äußerer und innerer Anfrage?
11. Wie können Teilanfragen in der HAVING-Zeile genutzt werden?
12. Wie können Teilanfragen in der FROM-Zeile genutzt werden, was ist typischerweise bei der Nutzung zu beachten?
13. [*] Welche JOIN-Operatoren gibt es, wie ist ihr Zusammenhang zu den bisher vorgestellten Anfragen?

Übungsaufgaben

Gegeben seien folgende Tabellen zur Beschreibung, welche Filme in welchen Kinos laufen (die jeweiligen Schlüssel sind mar-

kiert, die Angaben in der Tabelle Kino bedeuten z. B., dass es im Gloria 3 Säle mit jeweils 200 Plätzen gibt).

Film			Vorführung		Kino		
<u>FID</u>	<u>Titel</u>	<u>Laenge</u>	<u>Film</u>	<u>Kino</u>	<u>Name</u>	<u>Plaetze</u>	<u>Saele</u>
1	Die Nase	90	1	Gloria	Gloria	200	3
2	Die Hand	85	2	Gloria	Apollo	300	2
3	Der Arm	120	3	Gloria			
4	Das Bein	75	2	Apollo			
			4	Apollo			

Formulieren Sie folgende Anfragen in SQL, dabei wird das Wissen der letzten drei Kapitel benötigt:

1. Geben Sie die Namen aller Kinos aus, in denen der Film „Die Hand“ läuft.
2. Geben Sie zu jedem Kino die Gesamtzahl aller zur Verfügung stehenden Plätze aus (Ausgabe: Kinoname, Gesamtplatzzahl).
3. Geben Sie die Titel der Filme aus, die in mindestens zwei Kinos laufen.
4. Geben Sie die Namen aller Kinos aus, in denen „Die Nase“ nicht läuft.
5. Geben Sie zu jedem Kino die Länge des längsten Films aus, der in diesem Kino läuft (Ausgabe: Kinoname, maximale Länge).
6. Geben Sie zu jedem Filmtitel die maximale Anzahl von Zuschauern aus, die den Film gleichzeitig sehen können (Ausgabe: Filmtitel, maximale Besucherzahl; gehen Sie davon aus, dass alle Vorführungen gleichzeitig und nur einmal am Tag stattfinden, ein Film in einem Kino nicht in mehreren Sälen läuft).
7. Geben Sie für jeden Film und jedes Kino an, ob dieser Film in diesem Kino läuft oder nicht (Ausgabe: Filmtitel, Kino, Anzahl). Dabei soll eine Anzahl>0 ausgegeben werden, wenn der Film in dem Kino läuft, und sonst soll Anzahl=0 ausgegeben werden.

10

Transaktionen

*Eindruck eines
Einnutzer-
Systems*

Datenbanken werden meist von vielen Nutzern fast gleichzeitig genutzt. Dieses Kapitel zeigt Ihnen die möglichen Gefahren und Lösungsansätze.

In den bisherigen Kapiteln wurde implizit angenommen, dass man alleine am System arbeitet. Dies ist bei großen Datenbanken typischerweise nicht der Fall. Um die Arbeit nicht unnötig zu verkomplizieren, sollte das Datenbank-Managementsystem dafür sorgen, dass der Nutzer auf andere Nutzer keine Rücksicht nehmen muss. In diesem Kapitel wird gezeigt, dass diese Aufgabe zwar grundsätzlich vom Datenbank-Managementsystem übernommen wird, es aber sinnvoll ist, sich über kritische Situationen Gedanken zu machen. Wenn zwei Nutzer die gleiche Zeile gleichzeitig verändern wollen, ist es nicht möglich, beiden Nutzern das Gefühl zu geben, alleine an der Datenbank zu arbeiten.

Im folgenden Unterkapitel wird zunächst die Möglichkeit zur Transaktionssteuerung für einen einzelnen Nutzer vorgestellt. Danach werden typische Probleme gezeigt, die bei der gleichzeitigen Nutzung der gleichen Tabellen auftreten können und welche Lösungsmöglichkeiten es für diese Probleme gibt.

10.1

Änderungen verwalten

*Änderungen
rückgängig
machen*

Wurden bisher Änderungen an den Tabellen vorgenommen, konnte man davon ausgehen, dass diese Änderungen direkt in der Datenbank durchgeführt wurden. Dieser einfache Ansatz hat dann Probleme, wenn eine größere Anzahl von Änderungen durchgeführt werden soll, es aber möglich ist, dass man nach einigen Teilschritten feststellt, dass die Änderungen doch nicht durchgeführt werden sollen.

Bisher müsste man sich alle Folgen von INSERT-, UPDATE- und DELETE-Befehlen merken, um dann diese Änderungen mit einer neuen Folge von SQL-Befehlen wieder rückgängig zu machen. Dies ist gerade durch die Nutzung komplexer WHERE-Bedingungen und die verschiedenen Verknüpfungsmöglichkeiten durch die Fremdschlüsselbeziehungen sehr aufwändig und potenziell fehlerträchtig.

Transaktion

Aus diesem Grund wird im SQL-Standard die Möglichkeit zur *Transaktionssteuerung* spezifiziert. Dabei ist eine Transaktion eine Menge von SQL-Befehlen zur Veränderung von Tabelleninhalten, die ein Nutzer zusammen durchführen und die er vor einer endgültigen Ausführung abbrechen können möchte.

Transaktionssteuerung nur für Tabellenänderungen

Zu beachten ist, dass sich die Transaktionssteuerung auf Veränderungen existierender Tabellen bezieht, Befehle zum Erzeugen und Löschen von Tabellen sind explizit ausgeschlossen.

Zur Transaktionssteuerung stehen dem Nutzer grundsätzlich folgende Befehle zur Verfügung:

BEGIN TRANSACTION: Mit diesem Befehl wird eine Transaktion gestartet. Häufiger wird auf die Angabe des Befehls explizit verzichtet, da man beim Start des Systems und durch ein **COMMIT** oder **ROLLBACK** automatisch eine neue Transaktion beginnt.

COMMIT: Die vorher eingegebenen Befehle zur Veränderung von Tabellen sollen endgültig in die Datenbank übernommen werden. Die Transaktion wird damit abgeschlossen.

ROLLBACK: Die Änderungen an den Tabellen, die seit dem Ende der letzten Transaktion durchgeführt wurden, sollen verworfen werden. Es sollen keine Änderungen in der eigentlichen Datenbank stattfinden.

SAVEPOINT: Mit diesem Befehl kann in der laufenden Transaktion ein Sicherungspunkt gesetzt werden. Mit dem nächsten **ROLLBACK**-Befehl wird dann zu der Situation zurück gesprungen, die zum Zeitpunkt des **SAVEPOINT**-Befehls vorlag. Mit einem weiteren **ROLLBACK** würde dann die gesamte Transaktion verworfen.

In verschiedenen Datenbank-Managementsystemen gibt es die Möglichkeit, statt eines **SAVEPOINTS** mehrere durch den Befehl **SAVEPOINT <name>** anzulegen und dann mit **ROLLBACK TO SAVEPOINT <name>** zu diesem Sicherungspunkt zurück zu springen.

COMMIT garantiert keine Ausführung

Interessant ist die Aussage, dass mit **COMMIT** versucht wird, die Änderungen endgültig in die Datenbank zu übernehmen. Dieser Versuch kann scheitern, wenn ein zweiter Nutzer Änderungen an den gleichen Tabellen vornehmen möchte. In diesem Fall führt das Datenbank-Managementsystem automatisch ein **ROLLBACK** durch und verwirft die gesamte Transaktion.

Werden neue Tabellen angelegt, Tabellen gelöscht oder bricht ein Nutzer die Datenbank-Verbindung ab, wird typischerweise automatisch ein COMMIT durchgeführt. Dies kann aber in der Konfiguration von Datenbank-Managementsystemen eingestellt werden.

Der beispielhafte Ablauf von Tabellenänderungen mit Transaktionssteuerung wird mit dem folgenden SQL-Skript und der zugehörigen Ausgabe gezeigt.

```
CREATE TABLE Mitarbeiter(
  MNR INTEGER,
  Name VARCHAR(6),
  Gehalt INTEGER,
  PRIMARY KEY(MNR)
);
INSERT INTO Mitarbeiter VALUES(1, 'Egon', 70);
INSERT INTO Mitarbeiter VALUES(2, 'Uwe', 60);
SAVEPOINT;
INSERT INTO Mitarbeiter VALUES(3, 'Ute', 80);
SELECT * FROM Mitarbeiter;
ROLLBACK;
SELECT * FROM Mitarbeiter;
ROLLBACK;
INSERT INTO Mitarbeiter VALUES(4, 'Udo', 70);
COMMIT;
SELECT * FROM Mitarbeiter
```

Die erste Ausgabe liefert:

MNR	NAME	GEHALT
1	Egon	70
2	Uwe	60
3	Ute	80

Danach wird zum vorher festgelegten Sicherungspunkt zurück gesprungen, die Ausgabe liefert:

MNR	NAME	GEHALT
1	Egon	70
2	Uwe	60

Dann wird zum Ausgangspunkt der Transaktion zurück gesprungen und danach ein neuer Mitarbeiter namens „Udo“ angelegt. Die Ausgabe liefert:

MNR	NAME	GEHALT
4	Udo	70

Transaktionssteuerung ist systemabhängig

Die Realisierung der Transaktionssteuerung wird im SQL-Standard offen gelassen und ist Aufgabe der Hersteller der Datenbank-Managementsysteme. Ein häufig gewähltes Verfahren ist der Schattenspeicher. Dabei werden alle Änderungen einer Transaktion lokal in einem Zwischenspeicher gehalten und erst bei einem COMMIT in die eigentliche Datenbank übertragen.




Abb. 10.1: Schattenspeicher-Verfahren

Schattenspeicher-Verfahren

In Abb. 10.1 wird das *Schattenspeicher-Verfahren* verdeutlicht. Der Nutzer ändert das Gehalt von Uwe auf 100. Diese Information wird lokal im Speicher zur Transaktion vermerkt. In der eigentlichen Datenbank findet die Änderung noch nicht statt. Fragt der Nutzer die Mitarbeitertabelle in der laufenden Transaktion ab, wird er trotzdem das Gehalt 100 bei Uwe sehen, da alle Anfragen durch den Schattenspeicher laufen. Interessant und schwierig an diesem Ansatz ist, wenn ein zweiter Nutzer gleichzeitig die Tabelle Mitarbeiter bearbeitet, da er die Änderungen des ersten Nutzers typischerweise nicht sehen kann. Die dahinter stehenden Probleme und ihre Lösungsansätze werden in den folgenden Unterkapiteln diskutiert.

10.2 Typische Probleme beim parallelen Zugriff

Hat das Datenbankmanagementsystem keine ordentliche Verwaltung von Transaktionen, kann es zu den folgenden Problemen kommen. Zur Erklärung wird ein Befehl

```
SELECT Mitarbeiter.Gehalt
INTO :X
FROM Mitarbeiter
WHERE Mitarbeiter.MiNr=1
```

lokale Variablen in Datenbanken

genutzt. Für die Zeile INTO :X wird davon ausgegangen, dass eine Variable :X im System definiert wurde, die vom Typ her zum Ergebnis der Anfrage, hier zur Spalte Mitarbeiter.Gehalt, passt. Eine solche Variablendeklaration ist in verschiedenen Datenbank-Managementsystemen möglich, ist aber sparsam eingesetzt worden, da Ergebnisse von Anfragen nicht in zusätzlichen Variablen verwaltet werden sollten. Der Ansatz wird hier vorgestellt, der als Platzhalter dafür dienen kann, dass eine Applikation einen Wert aus der Datenbank liest und nach einer Bearbeitung wieder, eventuell an anderer Stelle, in die Datenbank schreiben will.

Nutzer 1

```
SELECT Mitarbeiter.Gehalt
INTO :X
WHERE Mitarbeiter.MiNr=1
```

Nutzer 2

```
SELECT Mitarbeiter.Gehalt
INTO :Y
WHERE Mitarbeiter.MiNr=1
```

```
UPDATE Mitarbeiter
SET Gehalt=:X+10
WHERE Mitarbeiter.MiNr=1
```

```
UPDATE Mitarbeiter
SET Gehalt=:Y+20
WHERE Mitarbeiter.MiNr=1
```

Datenbankinhalt

Mitarbeiter

MiNr	Name	Gehalt
1	Uwe	70

Mitarbeiter

MiNr	Name	Gehalt
1	Uwe	80

Mitarbeiter

MiNr	Name	Gehalt
1	Uwe	90

Abb. 10.2: Lost Update

Lost Update

In Abb. 10.2 ist ein Beispiel für eine verloren gegangene Änderung, ein „Lost Update“, beschrieben. Beide Nutzer wollen das Gehalt des Mitarbeiters mit der MiNr 1 ändern. Dazu lesen sie den aktuellen Wert jeweils in eine Variable. Diese Variable wird dann zur Aktualisierung des Datenbankeintrags genutzt. Da das

Lesen der zweiten Variable vor der schreibenden Änderung des ersten Nutzers stattfindet, geht die Änderung des ersten Nutzers verloren. Solch eine Situation kann z. B. auftreten, wenn ein Mitarbeiter zwei Prämien aus unterschiedlichen Gründen erhalten soll und dann eine Prämie verloren geht.

<u>Nutzer 1</u>	<u>Nutzer 2</u>	<u>Datenbankinhalt</u>						
		Mitarbeiter						
		<table><tr><th>MiNr</th><th>Name</th><th>Gehalt</th></tr><tr><td>1</td><td>Uwe</td><td>70</td></tr></table>	MiNr	Name	Gehalt	1	Uwe	70
MiNr	Name	Gehalt						
1	Uwe	70						
UPDATE Mitarbeiter		Mitarbeiter						
SET Gehalt=Gehalt+20		<table><tr><th>MiNr</th><th>Name</th><th>Gehalt</th></tr><tr><td>1</td><td>Uwe</td><td>90</td></tr></table>	MiNr	Name	Gehalt	1	Uwe	90
MiNr	Name	Gehalt						
1	Uwe	90						
WHERE Mitarbeiter.MiNr=1		Mitarbeiter						
	UPDATE Mitarbeiter	<table><tr><th>MiNr</th><th>Name</th><th>Gehalt</th></tr><tr><td>1</td><td>Uwe</td><td>110</td></tr></table>	MiNr	Name	Gehalt	1	Uwe	110
MiNr	Name	Gehalt						
1	Uwe	110						
	SET Gehalt=Gehalt+20							
	WHERE Mitarbeiter.MiNr=1							
ROLLBACK		Mitarbeiter						
		<table><tr><th>MiNr</th><th>Name</th><th>Gehalt</th></tr><tr><td>1</td><td>Uwe</td><td>70</td></tr></table>	MiNr	Name	Gehalt	1	Uwe	70
MiNr	Name	Gehalt						
1	Uwe	70						
	COMMIT	Mitarbeiter						
		<table><tr><th>MiNr</th><th>Name</th><th>Gehalt</th></tr><tr><td>1</td><td>Uwe</td><td>110</td></tr></table>	MiNr	Name	Gehalt	1	Uwe	110
MiNr	Name	Gehalt						
1	Uwe	110						

Abb. 10.3: Dirty Read

Dirty Read

Phantom Read

In Abb. 10.3 ist ein Beispiel für das Lesen eines nicht bestätigten Wertes, ein „Dirty Read“, beschrieben, das nur durch die im vorherigen Unterkapitel vorgestellte Transaktionssteuerung auftreten kann. Dabei ist allerdings zu beachten, dass man eine ähnliche Situation erreicht, wenn der Nutzer 1 statt eines ROLLBACKs den Wert mit einem UPDATE-Befehl wieder zurücksetzt. Dieses eng mit dem Dirty Read verwandte Problem wird auch „Phantom Read“ genannt. Der Name ist passend, da während der Aktionen des Nutzers 2 ein Datum erscheint, vom Nutzer 2 genutzt wird und wieder verschwindet ohne dass der Nutzer 2 nachvollziehen kann, was eigentlich passiert ist.

Im beschriebenen Fall will der Nutzer 1 das Gehalt von Uwe um 20 erhöhen, danach nutzt der Nutzer 2 den neuen Wert, um das Gehalt um 20 zu erhöhen. Nutzer 1 entscheidet sich zur Rücknahme der Änderung, so dass der Nutzer 2 mit einem nicht bestätigten Wert gearbeitet hat. Eine solche Situation kann z. B. auftreten, wenn zwei Sachbearbeiter das gleiche Personal bear-

beiten und ein Fehler bei der Trennung der Kompetenzen vorliegt.

Nutzer 1

```
UPDATE Mitarbeiter
SET Gehalt=Gehalt+10
WHERE Mitarbeiter.MiNr=1
```

Nutzer 2

```
SELECT SUM(Mitarbeiter.Gehalt)
  INTO :X
  FROM Mitarbeiter

UPDATE Mitarbeiter
SET Gehalt=Gehalt+10
WHERE Mitarbeiter.MiNr=2

SELECT SUM(Mitarbeiter.Gehalt)
  INTO :Y
  FROM Mitarbeiter
```

Datenbankinhalt

Mitarbeiter

MiNr	Name	Gehalt
1	Uwe	70
2	Ulli	60

Mitarbeiter

MiNr	Name	Gehalt
1	Uwe	80
2	Ulli	60

Mitarbeiter

MiNr	Name	Gehalt
1	Uwe	80
2	Ulli	70

Abb. 10.4: Unrepeatable Read

Unrepeatable
Read

Ein drittes typisches Problem, ist die Nichtwiederholbarkeit lesender Operationen, „Unrepeatable Read“ genannt. In Abb. 10.4 ist ein Beispiel dargestellt. Der Nutzer 2 lässt sich zweimal die Summe der Gehälter berechnen. Dies kann z. B. dann sinnvoll sein, wenn eine Softwarekomponente die Berechnungen einer anderen Komponente überprüfen möchte. Diese Prüfung, ob :X und :Y den gleichen Wert haben, scheitert in diesem Fall, da der Nutzer 1 einen Wert in der Tabelle geändert hat. Sinnvoll wäre es, wenn der Nutzer 2 innerhalb einer Transaktion immer die gleichen Werte sehen würde, das Ergebnis der Summenberechnung sollte entweder immer 130 oder 150 sein, aber niemals das Zwischenergebnis 140.

10.3

Transaktionssteuerung

Um die im vorherigen Unterkapitel vorgestellten Probleme zu vermeiden, wird vom Datenbank-Managementsystem eine Transaktionssteuerung gefordert. Details dieser Steuerung kann der Nutzer dabei für seine Transaktionen einstellen. Generell soll der Nutzer das Gefühl haben, dass seine Transaktionen das hier zu

erklärende „ACID-Prinzip“ nutzen. Der Standard überlässt es den Herstellern der Datenbank-Managementsysteme, wie sie dieses Prinzip durchsetzen.

ACID ist dabei eine Abkürzung, die sich aus folgenden Forderungen zusammensetzt.

Atomicity

Das „A“ steht für Atomicity, zu Deutsch Atomarität. Transaktionen sind unteilbar, sie finden entweder ganz oder gar nicht statt. Innerhalb einer Transaktion kann eine andere Transaktion keinen Einfluss haben. Für die vorgestellten Probleme heißt das im Lost Update-Beispiel der Abb. 10.2, dass die Transaktionen hintereinander stattfinden, also zwar in beliebiger Reihenfolge, aber immer mit dem Ergebnis, dass das Gehalt auf 100 gesetzt wird. Bei dem Dirty Read-Beispiel in Abb. 10.3 müssen die beiden Transaktionen wieder in beliebiger Reihenfolge stattfinden. Das Ergebnis wäre immer, dass das Gehalt auf 90 gesetzt wird. Im Fall des Unrepeatable Read-Beispiels aus Abb. 10.3 würde das Ergebnis sein, dass der Nutzer 2 entweder in beiden Fällen 130 oder in beiden Fällen 150 berechnet.

Consistency

Das „C“ steht für Consistency, zu Deutsch Konsistenz. Eine Transaktion geht von einer Datenbank aus, die alle Konsistenzregeln erfüllt. Wird die Transaktion dann ausgeführt, ist die Datenbank danach wieder in einem Zustand, in dem alle Regeln erfüllt sind.

Isolation

Das „I“ steht für Isolation, was zu Deutsch auch als Isolation übersetzt werden kann. Isolation garantiert, dass alle Zwischenergebnisse, die während einer laufenden Transaktion erreicht werden, von anderen Transaktionen nicht gelesen und verändert werden können.

Durability

Das „D“ steht für Durability, zu Deutsch Dauerhaftigkeit. Die Dauerhaftigkeit garantiert, dass Ergebnisse einer Transaktion persistent sind, also auf Dauer gespeichert werden. Die Ergebnisse einer Transaktion können nur durch eine andere Transaktion verändert werden.

Der Nutzer kann die Genauigkeit der Transaktion steuern. Dazu kann beim Start der Transaktion ein so genannter Isolationsgrad mit

SET TRANSACTION LEVEL <Nummer>

gesetzt werden. Häufig werden statt der Nummern auch Schlüsselwörter genutzt, die aber in Datenbank-Managementsystemen variieren können.

Level	Name	mögliche Problemfälle
0	READ UNCOMMITTED	Dirty Read, Unrepeatable Read, Phantom Read
1	READ COMMITTED	Unrepeatable Read, Phantom Read
2	REPEATABLE READ	Phantom Read
3	SERIALIZABLE	keine

Abb. 10.5: Isolationslevel

Gründe für niedrigen Isolationslevel

Die genauen Werte können der Abb. 10.5 entnommen werden. Die typische Standard-Einstellung ist der Wert 3, mit dem ACID-Transaktionen garantiert werden. Wenn man weiß, dass man nur lesende Zugriffe hat beziehungsweise kein zweiter Nutzer auf die gleichen Tabellen zugreifen will, kann es aus Performance-Gründen sinnvoll sein, einen anderen Isolationslevel für eine Transaktion einzustellen. Der Level muss typischerweise für jede Transaktion neu eingestellt werden, wenn nicht der Standardwert des Datenbanksystems genutzt werden soll.

Auswirkungen von Transaktionssteuerungen

Aus Nutzersicht ist zu beachten, dass eine ordentliche Transaktionssteuerung einige Rechenzeit benötigt. Weiterhin kann es sein, dass eine Transaktion bei einem COMMIT lange warten muss bis sie endlich ausgeführt wird, da die Transaktionssteuerung auf das Ende einer anderen Transaktion wartet. Weiterhin ist es möglich, dass eine Transaktion abgebrochen oder trotz COMMIT ein ROLLBACK ausgeführt wird, da ein Konflikt mit einer anderen Transaktion vorliegt. Im Extremfall können sich Transaktionen gegenseitig blockieren, wenn z. B. die eine Transaktion die Tabelle A geändert hat und dann die Tabelle B ändern will und eine andere Transaktion B geändert hat und auf A zugreifen möchte. Man spricht dabei von einem *Deadlock*, der entweder vom Nutzer durch den Abbruch einer Transaktion oder vom Datenbank-Managementsystem durch den Ablauf einer Zeitschranke, in der eine Transaktion weiter voran schreiten muss, aufgelöst wird.

10.4

Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu bearbeiten.

- 1. Was versteht man unter einer Transaktion?
- 2. Welche Steuerungselemente für Transaktionen gibt es?

3. Wie funktioniert das Schattenspeicherverfahren?
4. Beschreiben Sie anschaulich die drei typischen Probleme, die bei der parallelen Datenbanknutzung auftreten können.
5. Was versteht man unter dem ACID-Prinzip?
6. Was sind Isolationsgrade, wozu können sie genutzt werden?

Übungsaufgaben

1. Ein Nutzer A führt auf einer Datenbank folgende SQL-Befehle aus:

```
INSERT INTO T1(Name,Alt)
VALUES('Heinz', 42);
UPDATE T1 SET Alt=Alt+1
```

Ein zweiter Nutzer B führt auf der gleichen Datenbank folgende SQL-Befehle aus:

```
INSERT INTO T1(Name,Alt)
VALUES('Verena', 33);
UPDATE T1 SET Alt=Alt+1
```

Gehen Sie davon aus, dass die Tabelle T1 mit den Spalten Name und Alt erfolgreich angelegt wurde und leer ist, bevor A und B tätig werden, die am Ende COMMIT eingeben.

- a. Welche Endzustände können in der Tabelle T1 erreicht werden, wenn die Datenbank keine Transaktionssteuerung hat, dabei seien einzelne INSERT und UPDATE nicht unterbrechbar?
 - b. Welche Endzustände können in der Tabelle T1 erreicht werden, wenn die Datenbank eine vollständige Transaktionssteuerung hat?
2. In Abb. 10.1 wird das Schattenspeicher-Verfahren vorgestellt.
 - a. Überlegen Sie, welche Auswirkungen dieses Verfahren auf die drei Problemfälle hat.
 - b. Überlegen Sie im nächsten Schritt einen möglichen Ansatz, mit dem man ACID-Transaktionen erreichen könnte.

11

Rechte und Views

Anfrageergebnisse als Tabellen

Oft enthalten Datenbanken sehr komplexe Tabellen und Informationen, die nicht jedem Nutzer zugänglich sein sollen. In diesem Kapitel lernen Sie, wie man Informationen für Nutzer filtern und gegen unberechtigte Zugriffe sichern kann.

Häufig werden viele Daten in einer Tabelle zusammengefasst, von denen nur wenige für konkrete Aufgaben benötigt werden. Oft ist es auch der Fall, dass die restlichen Daten vom Bearbeiter der Aufgabe nicht eingesehen werden dürfen. Dies sind zwei Gründe, warum Views in SQL eingeführt wurden. Mit ihnen ist es weiterhin möglich, Anfrageergebnisse wie einfache Tabellen in weiteren Anfragen zu nutzen.

Rechte zur Tabellennutzung

Durch Views ist es nur eingeschränkt möglich, Rechte an Tabellen zu verwalten. Sinnvoll ist es, diese Rechte explizit an Nutzer verteilen zu können. Dabei kann man allgemein Rechte zur Einführung und Löschung neuer Tabellen oder auch Nutzer und die Benutzung von Tabellen unterscheiden. Diese Unterteilung findet sich bei Datenbanken mit zwei Rollen, dem Datenbank-Administrator und dem Projekt-Administrator, wieder. Die Möglichkeiten dieser Rollen werden in diesem Kapitel vorgestellt.

11.1

Views

aufwändige wiederholte Nutzung von Abfragen

In den Kapiteln zu SQL wurde gezeigt, dass man Ergebnisse von Anfragen wie normale Tabellen nutzen kann. Diese Ergebnisse können in die FROM-Zeile übernommen werden und sind z. B. durch Umbenennungen leicht nutzbar.

Das praktische Problem mit diesem Ansatz ist, dass man Anfragen zur Nutzung immer wieder in neue Anfragen hineinkopieren muss. Zwar gibt es Werkzeuge, mit denen man Anfragen verwalten kann, trotzdem wird der Such- und Kopieraufwand schnell recht groß und fehlerträchtig.

Mitarbeiter			Qualifikation	
MiNr	Name	Gehalt	MiNr	Faehigkeit
42	Georg	10000	43	Cobol
43	Jörg	9000	44	Java
44	Stephan	1000	45	Cobol
45	Uwe	1500	45	Java

Abb. 11.1: Beispieltabellen für View-Erklärung

Aufbau eines Views

Eine Lösungsmöglichkeit für dieses Problem sind *Views* oder *Sichten*, mit denen man dem Ergebnis einer Anfrage einen Namen zuordnen kann. Dieser Name kann dann wie eine Tabelle genutzt werden. In Abb. 11.1 stehen zwei Tabellen mit Grunddaten zu Mitarbeitern und ihren Qualifikationen. Will man häufiger mit der Liste der Mitarbeiternummern (MiNr) arbeiten, die als Javaprogrammierer bekannt sind, kann man die zugehörige Anfrage wie folgt in einen View verwandeln.

```
CREATE VIEW Javaprogrammierer AS
SELECT Mitarbeiter.MiNr
FROM Mitarbeiter,Qualifikation
WHERE Mitarbeiter.MiNr=Qualifikation.MiNr
AND Qualifikation.Faehigkeit='Java'
```

Die Syntax zur View-Erstellung ist damit auch deutlich, vor der Anfrage steht einfach:

```
CREATE VIEW <View_name> AS
```

Nutzung von Views

Nach der Definition des Views kann Javaprogrammierer wie eine normale Tabelle in Anfragen genutzt werden. Die Anfrage nach dem Durchschnittsgehalt von Javaprogrammierern lautet z. B.:

```
SELECT AVG(Mitarbeiter.Gehalt) Javaschnitt
FROM Mitarbeiter, Javaprogrammierer
WHERE Mitarbeiter.MiNr=Javaprogrammierer.MiNr
```

Das Ergebnis ist:

```
JAVASCHNITT
-----
1250
```

Views sind wie Tabellen persistent, d. h. nachdem sie einmal definiert wurden, kann man sie auch bei nachfolgenden Verbindungen mit der Datenbank immer wieder nutzen. Will man einen View löschen, wird folgender Befehl genutzt:

```
DROP VIEW <View_Name>
```

Löschen von Views

Views sind logische Tabellen

Wichtig ist, dass es sich bei Views um rein logische Tabellen handelt, d. h. es wird für den View keine Tabelle in der Datenbank angelegt, stattdessen wird die zur View gehörende Anfrage gespeichert. Das bedeutet auch, dass jedes Mal wenn der View genutzt wird, eine Berechnung der Anfrage stattfindet. Dies ist bei der Geschwindigkeit von Anfragen, die Views nutzen, zu beachten.

View hat immer aktuelle Daten

Der Vorteil davon, dass Views ein logisches Konstrukt sind, ist, dass man sich um Veränderungen nicht kümmern muss, da der View immer auf den aktuellsten Datenbestand zurückgreift. Dies wird mit folgendem Beispiel deutlich, bei dem zunächst ein neuer Java-Entwickler ergänzt

```
INSERT INTO Qualifikation VALUES(42,'Java')
```

und dann wieder die Frage nach dem Durchschnittsgehalt gestellt wird.

```
SELECT AVG(Mitarbeiter.Gehalt) Javaschnitt
FROM Mitarbeiter, Javaprogrammierer
WHERE Mitarbeiter.MiNr=Javaprogrammierer.MiNr
```

Das Ergebnis ist:

```
JAVASCHNITT
-----
4166,66667
```

materialized Views

In einigen Datenbank-Managementsystemen ist es möglich, Views zu kennzeichnen, so dass statt der Anfrage das Anfrageergebnis gespeichert wird. Diese Views werden dann auch „materialized Views“ genannt. Dies entspricht der Möglichkeit, eine Tabelle zu definieren

```
CREATE TABLE Javakoenner(
  MiNr NUMBER
)
```

Tabelle über INSERT füllen

und dann über einen INSERT-Befehl zu füllen. Man sieht im folgenden Befehl die Möglichkeit, SQL-Anfragen in INSERT-Befehlen zu nutzen.

```
INSERT INTO Javakoenner
SELECT Mitarbeiter.MiNr
FROM Mitarbeiter, Qualifikation
WHERE Mitarbeiter.MiNr=Qualifikation.MiNr
AND Qualifikation.Faehigkeit='Java'
```

Materialized Views und der vorgestellte Ansatz zur Berechnung einer temporären Tabelle haben den zentralen Nachteil, dass man selbst dafür verantwortlich ist, dass die Inhalte bei Ände-

temporäre Tabellen widersprechen Datenbankanforderungen

rungen der in der Anfrage genutzten Tabellen aktualisiert werden. Generell ist von dem Ansatz zur Berechnung von temporären Tabellen dringend abzuraten, da sie eine zentrale Quelle für inkonsistente Datenbanken sind. Dieser Ansatz wird nur in speziellen Systemen genutzt, bei denen die Anfrage sehr viel Rechenzeit benötigt und der Nutzer der temporären Tabelle nicht unbedingt alle Änderungen mitbekommen muss. Grundsätzlich sind diese temporären Tabellen nach ihrer Nutzung sofort zu löschen.

Ein wichtiger Unterschied zwischen Tabellen und Views besteht beim Verhalten gegenüber INSERT-Befehlen. Anschaulich wird dies schon beim genannten Beispiel deutlich. Der folgende Befehl

```
INSERT INTO Javaprogrammierer VALUES(43)
```

Views für Tabellenänderungen meist ungeeignet

führt zu einer Ablehnung durch das Datenbank-Managementsystem. Diese kann z. B. wie folgt lauten:

```
Kann keine Spalte, die einer Basistabelle zugeordnet wird, verändern
```

Da es sich bei einem View nur um eine logische Tabelle handelt, müssen INSERT-Befehle auf die dem View zu Grunde liegenden Basistabellen zugreifen. Es kann aber viele Gründe geben, warum dieser Zugriff nicht sinnvoll möglich ist:

- Die einzutragenden Werte enthalten keine Angaben zum Primärschlüssel der Basistabelle. Ein Eintrag muss abgelehnt werden.
- Die einzutragenden Werte füllen nicht alle Spalten der Basistabelle. Dies ist dann ein Problem, wenn es eine Bedingung gibt, dass in dieser Spalte keine NULL-Werte stehen dürfen. Generell können Verstöße gegen weitere Constraints zum Problem werden.
- Wenn in dem SELECT-Befehl, der zu dem View gehört, Berechnungen gemacht werden, z. B. mit „SELECT A+B X...“ und ein Wert für X eingetragen werden soll, ist nicht erklärbar, wie dieser auf A und B aufgeteilt werden soll.

Aus diesen Gründen sind INSERT-, UPDATE- und DELETE-Befehle für Views, die mindestens zwei Basistabellen haben, nicht zulässig.

über Views änderbare Tabellen

Für Views, die sich nur auf eine Tabelle beziehen, sind Aktualisierungen möglich, wenn keines der genannten Probleme auf-

tritt. Ein Beispiel ist der folgende View, der den Namen und die Mitarbeiternummer der Tabelle Mitarbeiter enthält.

```
CREATE VIEW Basisdaten AS
  SELECT Mitarbeiter.MiNr, Mitarbeiter.Name
  FROM Mitarbeiter
```

Dieser View kann zur Änderung der Basistabelle genutzt werden, da der Primärschlüssel im View enthalten ist und auch keine anderen Bedingungen verletzt werden.

Die Ausführung der folgenden Befehle

```
DELETE FROM Basisdaten
WHERE MiNr<44
```

und

```
INSERT INTO Basisdaten VALUES (46, 'Erna')
```

führt bei der einfachen Anfrage

```
SELECT * FROM Basisdaten
```

zu folgender Ausgabe:

```
      MINR NAME
-----
      44 Stephan
      45 Uwe
      46 Erna
```

und bei

```
SELECT * FROM Mitarbeiter
```

zu dem Ergebnis:

```
      MINR NAME      GEHALT
-----
      44 Stephan      1000
      45 Uwe          1500
      46 Erna
```

Views zum Datenschutz

Die zuletzt vorgestellten Views, basierend auf einer Basistabelle, haben den Vorteil, dass man Nutzern Rechte zur Änderung dieser „Tabelle“ geben kann, ohne Rechte zur Veränderung oder zum Lesen der Ursprungstabelle zu vergeben. Man kann so verhindern, dass das Gehalt für bestimmte Nutzer sichtbar wird, und trotzdem können diese eine Variante der Tabelle Mitarbeiter wie eine normale Tabelle nutzen. Die Möglichkeiten zur Rechtevergabe werden in den folgenden Unterkapiteln vorgestellt.

11.2

Rechte für die Datenbank-Administration

Gründe für Rechtssysteme

Mit einem Rechtssystem ist es möglich, genau anzugeben, wer welche Operation auf der Datenbank, genauer auf einzelnen Objekten der Datenbank, durchführen kann. Dies ist aus verschiedenen Gründen sinnvoll und teilweise notwendig. Oft werden in einem Datenbank-Managementsystem verschiedene Projekte gleichzeitig realisiert. Dabei sollen sich Entwickler auf die Tabellen konzentrieren, die für ihr Projekt relevant sind. Gerade irrtümliche Verknüpfungen zwischen Tabellen unterschiedlicher Projekte oder Veränderungen der Datenbestände müssen vermieden werden.

Schutz personenbezogener Daten

Wie bei den Views bereits angedeutet, soll oft nicht jeder an alle Informationen herankommen. Dies ist besonders bei der Bearbeitung personenbezogener Daten und den zugehörigen Datenschutzrichtlinien zu beachten.

Aufgaben des Datenbank-Administrators

Bereits in Abb. 1.9 wurden mit den Datenbank-Administratoren und den Datenbank-Entwicklern zwei zentrale Rollen für Datenbankprojekte identifiziert. Die Aufgaben eines Datenbank-Administrators können dabei wie folgt zusammengefasst werden:

1. Einrichtung des Datenbank-Managementsystems und Gewährleistung des laufenden Betriebs.
2. Kontinuierliche Optimierung der Datenbank und Anpassung an neue Situationen. Dazu gehören z. B. die Prüfung, ob genügend Speicherplatz vorhanden ist, die Datenbank noch schnell genug ist und das Ergreifen von Maßnahmen wie der Einbindung neuer Festplatten und des Umzugs der Datenbank auf einen neuen Server.
3. Einrichtung von Projekten in der Datenbank. Häufig wird hierfür auch der Begriff *Domäne* genutzt. Eine Domäne ist eine logische Datenbank, die sich für den Nutzer von außen wie die Datenbank verhält, wobei mehrere Domänen in einer realen Datenbank verwaltet werden können.
4. Die Einrichtung von Nutzern und Vergabe von Rechten.

Domäne

Gerade für die letzten beiden Aufgaben muss geklärt werden, wer was darf. Typischerweise wird bei der Installation der Datenbank ein Datenbank-Administrator als Rolle eingerichtet. Diese Rolle kann dann die dritte und vierte Aufgabe in Angriff nehmen und die weiteren Rechtevergaben durchführen.

Regeln zur Rechtevergabe

Generell gibt es in SQL zwei Befehle, um Rechte auf der Datenbank zu verwalten. Dabei ist zu beachten, dass man nur Rechte einrichten kann, die man selber besitzt und für die man das Recht hat, diese Rechte weiter zu geben. Die allgemeine Form zur Rechtevergabe durch den Administrator ist

```
GRANT <Recht> TO <User>
```

Dieser Befehl kann durch WITH ADMIN OPTION ergänzt werden, womit dem User das Recht zur Weitergabe des Rechts eingeräumt wird. Typische Rechte sind: CREATE TABLE, DROP TABLE, CREATE VIEW, DROP VIEW.

Der Befehl zur Wegnahme des Rechts ist:

```
REVOKE <Recht> FROM <User>
```

Als <User> kann neben der Angabe eines konkreten, in der Datenbank eingerichteten Nutzers auch PUBLIC stehen, dabei wird das Recht allen eingerichteten Nutzern der Datenbank eingeräumt.

Einrichtung von Rollen

Die meisten Datenbank-Managementsysteme erlauben die Einrichtung von so genannten *Rollen*, damit nicht jedem Nutzer die Rechte individuell eingeräumt werden müssen. Die Idee ist eine Rolle, z. B. durch

```
CREATE ROLE projektadministrator
```

zu erzeugen. Dieser Rolle werden dann Rechte zugeordnet, z. B.

```
GRANT CREATE TABLE, CREATE VIEW  
TO projektadministrator
```

Nutzer nehmen Rollen ein

Man sieht, dass man statt einem Recht auch eine Liste von Rechten angeben kann. Jetzt können Nutzern eine oder mehrere Rollen zugeordnet werden. Die Nutzer haben dann die Rechte dieser Rollen. Ein Beispiel ist

```
GRANT projektadministrator TO Egon, Herta42
```

Einrichtung von Nutzern

Der Datenbank-Administrator richtet die Nutzer für die Datenbank ein und gibt ihnen meist allgemeine Rechte, wie eine Verbindung zur Datenbank aufzubauen. Die Befehle dazu variieren in den Datenbank-Managementsystemen. Ein möglicher Befehl kann wie folgt aussehen:

```
CREATE USER Egon  
IDENTIFIED BY ottilie01  
QUOTA 5M ON system
```


Dabei wird ein Nutzer mit einem Passwort und einer maximalen Menge von Speicher, die er verbrauchen darf, in der logischen Datenbank mit dem Namen system eingerichtet. Damit die Datenbank genutzt werden kann, muss noch erlaubt werden, dass eine Verbindung zur Datenbank aufgebaut wird. Dies erfolgt z. B. durch

```
GRANT CREATE SESSION TO Egon
```

Rolle des Projekt-Administrators

Bei großen Projekten übergibt der Datenbank-Administrator meist die Rechte zur Erzeugung, Löschung und Nutzung von Tabellen an einen Projekt-Administrator, der dann die Rechte im Projekt regelt. Dies wird im folgenden Unterkapitel beschrieben. In kleineren Unternehmen oder bei kleinen Projekten ist es häufig der Fall, dass die Rolle des Datenbank- und des Projektadministrators in einer Person vereinigt wird. Damit gibt es dann einen zentralen Ansprechpartner zur Datenbanknutzung.

11.3

Rechte für die Projekt-Administration

Aufgaben des Projekt-Administrators

In Projekten ist es häufig der Fall, dass eine Person, der *Projekt-administrator*, für alle Themen zuständig ist, die sich auf die Datenbankobjekte des Projekts beziehen. Dazu kann er Tabellen anlegen, löschen und ändern sowie Rechte zur Bearbeitung der Tabellen vergeben. Grundsätzlich gilt, dass jeder Nutzer nur die Rechte erhält, die er im Projekt benötigt. Dadurch wird gewährleistet, dass irrtümliche Veränderungen an Tabellen, z. B. durch unerfahrene Nutzer, seltener auftreten und dass der Datenschutz gewährleistet ist.

detaillierte Zugriffsrechte auf Tabellen

Die Rechte an Tabellen können dabei sehr detailliert vergeben werden. Die konkreten Rechte sind:

SELECT: Das Recht, eine Anfrage an die Tabelle zu stellen.

INSERT: Das Recht, Einträge in die Tabelle zu machen. Dabei ist es gegebenenfalls möglich, dieses Recht auf einzelne Spalten zu beschränken.

UPDATE: Das Recht, Einträge in der Tabelle zu verändern. Dabei ist es gegebenenfalls möglich, dieses Recht auf einzelne Spalten zu beschränken.

DELETE: Das Recht, Zeilen aus der Tabelle zu löschen.

Die etwas erweiterten Befehle zur Rechtevergabe und Rücknahme von Rechten sind:

```
GRANT <Recht> ON <Object> TO <User>
```

REVOKE <Recht> ON <Object> FROM <User>

Weitergabemöglichkeit für Rechte

Man kann erlauben, dass Rechte weitergegeben werden können, die Ergänzung ist hier WITH GRANT OPTION. Bei den Rechten kann ALL angegeben werden, womit alle Rechte am Objekt gegeben oder entzogen werden. Objekte können Tabellen und Views oder andere Objekte sein, die die Datenbank zur Verfügung stellt, die in diesem Buch aber nicht besprochen wurden. Die Möglichkeit, Rechte an Rollen zu vergeben, gibt es wie im vorherigen Unterkapitel beschrieben.

Tabelle	Tabelle1	Tabelle2	Tabelle3	Tabelle4	Tabelle5
Rolle					
Projektmanager	S	S	S	S	
ModulentwicklungA	A	A	S		
ModulentwicklungB		S	A	A	
Qualitätssicherung	A	A	A	A	
WerkzeugX					A

S = SELECT (nur lesen) A = ALL (beliebige Veränderung)

Abb. 11.2: Rechte-Rollen-Matrix

Rechte-Rollen-Matrix

Am Anfang der Projektrealisierung wird typischerweise über eine *Rechte-Rollen-Matrix* nachgedacht. In dieser Matrix werden dann die konkreten Rechte einer Rolle festgehalten. Nutzern der Datenbank werden dann die Rechte einer oder mehrerer Rollen zugeordnet. In Abb. 11.2 ist ein Beispiel für solch eine Matrix angegeben. Das Projektmanagement darf sich von der Existenz der Tabellen überzeugen, diese aber nicht verändern. Die Entwickler der jeweiligen Module dürfen einige Tabellen verändern, auf andere, die sie in Anfragen benötigen, nur lesend zugreifen. Das Testteam darf alle Tabellen bearbeiten, um die Funktionsfähigkeit des Systems zu prüfen. Weiterhin wird ein Entwicklungswerkzeug genutzt, das seine Modelle auch in der Datenbank speichert, diese Software benötigt ebenfalls Rechte. Natürlich ist dies nur ein Beispiel für mögliche Rollen und Begründungen, warum welche Rechte zu welchen Rollen gehören.

Argumentationsbeispiel zur Rechtevergabe

11.4 Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu bearbeiten.

1. Beschreiben Sie die Einsatzmöglichkeiten von Views.
2. Was ist bei der Arbeit mit Views zu beachten, insbesondere, wenn sie als „normale“ Tabellen angesehen werden?
3. Warum ist die Idee, eine Tabelle mit Hilfe einer Anfrage zu füllen, kritisch?
4. Welche Aufgaben hat ein Datenbank-Administrator?
5. Welche Aufgabe hat ein Projekt-Administrator für die im Projekt genutzte Datenbank?
6. Wozu gibt es Rechte-Systeme?
7. Welche Befehle gibt es zur Vergabe und zum Zurücknehmen von Rechten?
8. Wozu gibt es ein Rollenkonzept?
9. Wozu gibt es Rechte-Rollen-Matrizen, wie werden sie entwickelt?

Übungsaufgaben

Gegeben seien die Tabellen aus den Übungen zu Kapitel 9.

1. Schreiben Sie einen View in dem der Titel des Films und der Name des Kinos steht, in dem dieser Film läuft.
2. Nutzen Sie den View aus der Aufgabe 1, um auszugeben, in wie vielen Kinos jeder Film läuft.
3. Nutzen Sie den View aus der Aufgabe 1, um zu berechnen, ob alle Säle der Kinos genutzt werden. Die Ausgabe soll aus dem Namen des Kinos und der Anzahl der nicht genutzten Säle bestehen.
4. Kann Ihr View aus der Aufgabe 1 für Einfüge- und Änderungsoperationen genutzt werden?
5. Überlegen Sie sich ausgehend von der Rechte-Rollen-Matrix in Abb. 11.2 weitere Rollen, die in einem Projekt sinnvoll sein können. Überlegen Sie dabei auch, was für Werkzeuge eventuell in der Entwicklung eingesetzt werden, die ebenfalls die Datenbank nutzen und Rechte benötigen.

Der bisherige Text orientierte sich am SQL-Standard, so dass die vermittelten Kenntnisse fast vollständig auf alle größeren Datenbankmanagementsysteme übertragen werden können. Für die Themen dieses Kapitels gilt zwar auch, dass sie für alle Datenbankmanagementsysteme behandelt werden, diese Behandlung aber meist vom Standard abweicht. Der pragmatische Grund dafür ist, dass die vorgestellten Ideen bereits relativ früh in den Datenbanken großer Hersteller realisiert wurden und dass der Standard später entwickelt wurde. Um kompatibel mit älteren Lösungen der Nutzer zu bleiben, hat eine vollständige Anpassung an den Standard bei den Herstellern nicht stattgefunden.

Aus diesen Gründen wird in diesem und dem folgenden Kapitel die Datenbank von Oracle betrachtet. Dabei werden die zu Lehr- und Lernzwecken freie Variante OracleXE (<http://www.oracle.com/technetwork/database/express-edition/overview/index.html>) und das zugehörige Werkzeug SQLDeveloper betrachtet. Weitere Informationen sind von der Web-Seite des Buches erhältlich.

Zunächst steht die Frage im Raum, warum die bisher beschriebenen relationalen Datenbanken nicht als Lösungen ausreichen. Dabei sind folgende kritische Punkte zu nennen.

Grenzen relationaler Datenbanken

- Nutzer der Datenbank müssen immer noch einige Rechte auf den Tabellen haben, was z. B. die Abänderung von Tabellen erschwert und dem Nutzer Detailsichten in das System bietet, die er eventuell nicht haben soll.
- Neben der reinen Datenhaltung kann es sinnvoll sein, den Nutzern weitere Funktionalität anzubieten, damit diese nicht von allen Nutzern individuell realisiert werden muss.
- Die Möglichkeiten zur Steuerung der Integrität sind mit den bisher bekannten Hilfsmitteln FOREIGN KEYS und CONSTRAINTs relativ eingeschränkt. Kontrollmechanismen, die mehrere Tabellen berücksichtigen, sind erstrebenswert.

Die ersten beiden Punkte werden durch sogenannte Stored Procedures, der letzte Punkt mit sogenannten Triggern realisiert. Zur Realisierung werden zunächst die Grundlagen der in Oracle in-

nerhalb der Datenbank genutzten Programmiersprache PL/SQL und dann die Erstellung von Stored Procedures und Triggern gezeigt.

Gehege			Tier			Art	
<u>GNr</u>	<u>Gname</u>	<u>Flaeche</u>	<u>GNr</u>	<u>Tname</u>	<u>Gattung</u>	<u>Gattung</u>	<u>MinFlaeche</u>
1	Wald	30	1	Laber	Baer	Baer	8
2	Feld	20	1	Sabber	Baer	Hase	2
3	Weide	15	2	Klopfer	Hase	Schaf	5
			3	Bunny	Hase		
			2	Runny	Hase		
			2	Hunny	Hase		
			2	Harald	Schaf		
			3	Walter	Schaf		
			3	Dörthe	Schaf		

Abb. 12.1: Erweiterte Zoo-Tabelle

Als Ausgangsbeispiel werden die bereits bekannten Zoo-Tabellen aus Abb. 12.1 genutzt.

12.1

Einführung in PL/SQL

PL/SQL ist klassische Programmiersprache

PL/SQL ist von seinem Konzept eine klassische prozedurale Programmiersprache, die verwandt mit Sprachen wie Modula 2, Pascal und C ist. Wie in diesen Sprachen auch, stehen Funktionen und Prozeduren, auch als spezielle Funktionen ohne Rückgabeparameter betrachtbar, zur Verfügung.

keine Ausgaben

PL/SQL wird zur Programmierung in der Datenbank benutzt, es handelt sich damit um eine serverseitige Programmierung, wobei der Nutzer als Client typischerweise an einem anderen Rechner Dienste des Servers nutzt. Dies hat als wichtige Konsequenz den Unterschied zwischen PL/SQL und den genannten Programmiersprachen, dass eine Ausgabefunktion nur eingeschränkt Sinn macht, da nicht sichergestellt werden kann, ob und wie eine Ausgabe erfolgt. Statt der Nutzung einer Ausgabefunktion wird dem Client das Ergebnis eines Funktionsaufrufs als Ergebnis übergeben, so dass der Client für die Aufbereitung und eventuelle Ausgabe des Ergebnisses verantwortlich ist. Eine Ausgabe auf dem Server hat meist keinen Nutzen, da nicht immer ein Administrator vor der Datenbank sitzt. Weiterhin interessiert es den Administrator typischerweise nicht, welche Funktionalität vom Nutzer aktuell ausgeführt wird. Da eine Ausgabefunktionalität

aber bei der Programmentwicklung hilfreich ist, wird sie hier mit genutzt. Später wird gezeigt, wie man Ergebnisse an den Datenbanknutzer übermitteln kann.

Der grundsätzliche Aufbau einer Prozedur sieht wie folgt aus.

```
CREATE [OR REPLACE]
PROCEDURE <Prozedurname> [( <Parameterliste> ) ] IS
    <LokaleVariablen>
BEGIN
    <Prozedurrumpf>
END;
```

Die eckigen Klammern deuten Teile an, die weggelassen werden können. Durch das „CREATE OR REPLACE“ wird garantiert, dass die Prozedur beim Kompilieren neu angelegt und eine eventuell vorhandene alte Version überschrieben wird. Bei der Parameterliste ist zu beachten, dass bei einer leeren Parameterliste auch die Klammern weggelassen werden. Die folgende Prozedur dient zum Einfügen neuer Tiere in die Tier-Tabelle.

```
CREATE OR REPLACE PROCEDURE NeueArt
    (gattung VARCHAR, minflaeche INTEGER) IS
BEGIN
    INSERT INTO Art VALUES (gattung,minflaeche);
END;
```

*typische
PL/SQL-
Prozedur*

Im Prozedurrumpf stehen alle bekannten SQL-Befehle zur Verfügung, dabei sind auch die Steuerungsmöglichkeiten für Transaktionen mit COMMIT und ROLLBACK nutzbar.

Weiterhin sieht man, dass in der Parameterliste keine Dimensionen angegeben werden dürfen, also VARCHAR statt z. B. die detailliertere Angabe VARCHAR (7) genutzt werden muss.

Der Aufruf der Prozedur hängt von der Entwicklungsumgebung ab. Typisch ist für PL/SQL, dass der Befehl

```
EXECUTE NeueArt ('Reh', 4);
```

ausgeführt werden kann. Bei der Ausführung werden alle vorher eingegebenen Constraints berücksichtigt. Bei einem Verstoß wird die Ausführung abgebrochen und die Datenbank zurück in den Zustand vor der Ausführung gesetzt.

Auf den ersten Blick stellt sich die Frage, warum man einen einfachen INSERT-Befehl in eine PL/SQL-Prozedur stecken soll. Dafür gibt es zwei zentrale, sehr gute Gründe.

Vorteile von PL/SQL- Prozeduren

1. Für Prozeduren können mit GRANT und REVOKE die Erlaubnis zur Ausführung der Prozeduren gesteuert werden. Dabei reicht es aus, die Rechte an der Ausführung der Prozedur zu haben, damit die Eintragung in die Tabelle Tier geschieht. Es besteht keine Notwendigkeit mehr, dass Datenbanknutzer direkte Rechte an den Tabellen haben, wodurch ein zusätzliches Sicherheitsniveau erreicht wird.
2. Sind alle Tabellen in Prozeduren gekapselt, so kann man für den Nutzer unsichtbar die Struktur der Tabellen ändern, z. B. neue Spalten ergänzen. Es müssen dann nur, was auch aufwändig werden kann, alle Prozeduren angepasst werden, die diese Tabelle nutzen. Nutzer der Datenbank müssen dann aber nicht informiert werden, so dass z. B. die Software beim Client nicht geändert werden muss.

```
CREATE OR REPLACE PROCEDURE Hallo IS
BEGIN
    DBMS_OUTPUT.PUT('Hallo ');
    DBMS_OUTPUT.PUT_LINE('Welt');
END;
```

Die Prozedur Hallo zeigt eine minimale PL/SQL-Prozedur, die keine Tabellen nutzt und nur einen Text ausgibt. Diese Ausgabe muss abhängig vom genutzten Werkzeug mit einem Befehl der Form SET SERVEROUTPUT ON meist eingeschaltet werden. Ein

```
EXECUTE Hallo;
```

liefert als Ausgabe

```
Hallo Welt
```

Der Unterschied zwischen PUT und PUT_LINE ist, dass bei PUT_LINE nach der Textausgabe noch ein Zeilenumbruch passiert. Die folgende leicht abgeänderte Form zeigt, dass man Texte und Texte sowie Texte mit Variablen durch || verknüpfen kann.

```
CREATE OR REPLACE PROCEDURE Hallo2
(name VARCHAR, alt INTEGER, beruf VARCHAR)
IS
BEGIN
    DBMS_OUTPUT.PUT_LINE(name||' ist '
        ||alt||' Jahre und '||beruf
        ||' von Beruf.');
```

Der Aufruf

```
EXECUTE Hallo2('Urs',23,NULL);
```

mit der Ausgabe

```
Urs ist 23 Jahre und von Beruf.
```

zeigt, dass NULL-Werte bei Ausgaben nicht erscheinen, auch nicht als einfaches Leerzeichen ausgegeben werden.

Wie in anderen Programmiersprachen auch, gibt es Befehle für Alternativen und Schleifen. Dabei zeigt sich, dass Anfänger meist mehr Probleme mit der etwas gewöhnungsbedürftigen Syntax als mit der eigentlichen Programmierung bei einfachen Übungen haben.

PL/SQL- Alternative

Die Alternative sieht allgemein wie folgt aus:

```
IF <Bedingung>
  THEN <Block>
  [ ELSIF <Bedingung> THEN <Block> ]
  ...
  [ ELSIF <Bedingung> THEN <Block> ]
  [ ELSE <Block> ]
END IF;
```

Bedingungen müssen nicht in Klammern stehen. Blöcke stehen für einfache Folgen von PL/SQL-Befehlen. Dabei kann ein Block auch mit BEGIN beginnen und mit END enden. Es handelt sich dann um einen lokalen Block, bei dem man am Anfang lokale Variablen deklarieren kann, die nicht außerhalb benutzt werden dürfen. Blöcke dürfen an beliebigen Stellen stehen, an denen auch Anweisungen erlaubt sind.

PL/SQL- Zuweisung

Die folgende Prozedur führt einige der genannten Varianten vor. Beim konkreten Einsatz würde man auf den lokalen Block hier verzichten, also BEGIN und END einfach streichen. Weiterhin sieht man, dass eine Zuweisung mit dem Zeichen := erfolgt und wie eine lokale Variable zaehler mit dem Startwert 0 deklariert wird. Bei lokalen Variablen werden die bereits bekannten Datentypen von den Tabellen genutzt, hier werden auch Angaben, wie die maximale Länge eines Textes benötigt. Die Überprüfung auf Null-Werte erfolgt wie bei Anfragen mit dem Vergleich IS NULL.

Das Programm erwartet drei Parameter. Für jeden Parameter, der den Wert NULL hat, wird die Zählvariable zaehler um Eins erhöht. Die Variable name2 wird mit dem Wert der Variablen na-

me initialisiert und. falls name NULL sein sollte, durch „Unbekannt“ ersetzt.

```
CREATE OR REPLACE PROCEDURE Hallo3
(name VARCHAR, alt INTEGER, beruf VARCHAR)
IS
    zaehler INTEGER DEFAULT 0;
    name2 VARCHAR(10) DEFAULT name;
BEGIN
    IF name IS NULL THEN
        BEGIN
            zaehler:=zaehler+1;
            name2:='Unbekannt';
        END;
    END IF;
    DBMS_OUTPUT.PUT(name2);

    IF beruf IS NULL AND alt IS NULL
    THEN
        zaehler:=zaehler+2;
        DBMS_OUTPUT.PUT_LINE('.');
    ELSIF alt IS NULL THEN
        zaehler:=zaehler+1;
        DBMS_OUTPUT.PUT_LINE(' ist '||beruf||'.');
    ELSIF beruf IS NULL THEN
        zaehler:=zaehler+1;
        DBMS_OUTPUT.PUT_LINE(' ist '||alt
                                ||' Jahre alt.');
```

```
    ELSE
        IF alt<25
        THEN
            DBMS_OUTPUT.PUT_LINE(' ist schon '
                                ||beruf||'.');
        ELSE
            DBMS_OUTPUT.PUT_LINE(' ('||alt
                                ||') ist '||beruf||'.');
```

```
        END IF;
    END IF;
    DBMS_OUTPUT.PUT_LINE(zaehler
                        ||' fehlende Angaben');
END;
```

*systematisches
Testen von
Programmen*

Wie jedes sonstige Programm auch, müssen PL/SQL-Prozeduren systematisch getestet werden. Dies geschieht hier exemplarisch durch die folgenden Testfälle, die auch die genaue Funktionalität weiter verdeutlichen. Zum professionellen Testen gibt es Entwicklungsumgebungen mit Debug-Möglichkeiten.

```
EXECUTE Hallo3(NULL,NULL,NULL);
EXECUTE Hallo3('Urs',NULL,NULL);
EXECUTE Hallo3(NULL,23,NULL);
EXECUTE Hallo3(NULL,NULL,'Berater');
EXECUTE Hallo3('Urs',NULL,'Berater');
EXECUTE Hallo3('Urs',23,NULL);
EXECUTE Hallo3(NULL,23,'Berater');
EXECUTE Hallo3('Urs',23,'Berater');
EXECUTE Hallo3('Ute',29,'Beraterin');
```

Die zugehörige Ausgabe lautet:

```
Unbekannt.
3 fehlende Angaben
Urs.
2 fehlende Angaben
Unbekannt ist 23 Jahre alt.
2 fehlende Angaben
Unbekannt ist Berater.
2 fehlende Angaben
Urs ist Berater.
1 fehlende Angaben
Urs ist 23 Jahre alt.
1 fehlende Angaben
Unbekannt ist schon Berater.
1 fehlende Angaben
Urs ist schon Berater.
0 fehlende Angaben
Ute (29) ist Beraterin.
0 fehlende Angaben
```

Als Schleifen stehen die WHILE-Schleife und die FOR-Schleife mit einer leicht gewöhnungsbedürftigen Syntax zur Verfügung. Die Syntax der WHILE-Schleife lautet wie folgt.

PL/SQL-WHILE-Schleife

```
WHILE <Bedingung>
LOOP
  <Block>
END LOOP;
```

Die folgende Prozedur zeigt eine recht einfache Schleifenanwendung, mit der der Text text anzahl-Mal ausgegeben wird.

```
CREATE OR REPLACE PROCEDURE whileBsp
  (text VARCHAR, anzahl INTEGER)
IS
  zaehler INTEGER DEFAULT 1;
BEGIN
  WHILE zaehler<=anzahl
  LOOP
    DBMS_OUTPUT.PUT_LINE(zaehler||'. '||text);
```

```
        zaehler:=zaehler+1;
    END LOOP;
END;
```

Der Aufruf

```
EXECUTE whileBsp('ohne Dich alles doof',4);
```

erzeugt folgende Ausgabe.

```
1. ohne Dich alles doof
2. ohne Dich alles doof
3. ohne Dich alles doof
4. ohne Dich alles doof
```

Die FOR-Schleife hat folgende Syntax

PL/SQL-FOR-Schleife

```
FOR <Laufvariable> IN [REVERSE] <Start> .. <Ende>
LOOP
    <Block>
END LOOP;
```

Die Variable <Laufvariable> ist automatisch vom Typ INTEGER und darf nicht vorher deklariert werden. Die Variable läuft die Werte von einschließlich <Start> bis einschließlich <Ende> durch, wobei sie nach jedem Durchlauf um eins erhöht wird. Wird das Schlüsselwort REVERSE genutzt, zählt die Laufvariable rückwärts, zur Terminierung muss dann <Ende> kleiner-gleich <Start> sein.

Die vorherige Prozedur hätte auch wie folgt geschrieben werden können.

```
CREATE OR REPLACE PROCEDURE forBsp
    (text VARCHAR, anzahl INTEGER)
IS
BEGIN
    FOR zaehler IN 1 .. anzahl
    LOOP
        DBMS_OUTPUT.PUT_LINE(zaehler||'. '||text);
    END LOOP;
END;
```

Der Aufruf

```
EXECUTE forBsp('mit Dir alles toll',3);
```

führt zu folgender Ausgabe.

```
1. mit Dir alles toll
2. mit Dir alles toll
3. mit Dir alles toll
```

Vergleichbar zu Pascal und C bietet PL/SQL RECORDS, in C struct genannt, als zusammengesetzte Datentypen an. So wird es u. a. möglich, einzelne Daten zu einem Typen kompakt zusammen zu fassen. Ansätze zur Objektorientierung, die mittlerweile auch in PL/SQL umgesetzt werden können, werden in diesem Buch aus Platzgründen und da sie sich in den Stored Procedure-Ansätzen verschiedener Datenbanken relativ stark unterscheiden, nicht betrachtet.

Die generelle Form der Typ-Deklaration sieht wie folgt aus.

PL/SQL-RECORD

```

TYPE <Typname> IS RECORD (
    <Attributsname1> <Typ1>,
    ...
    <AttributsnameN> <TypN>
);

```

PL/SQL-Kommentare

Deklariert man eine Variable *r* vom Typ *Typname*, so kann man über die Punktnotation auf die einzelnen Attribute, also *r.<Attributname1>* zugreifen. Die folgende Prozedur dient zur Analyse der Semantik von Records, man sieht weiterhin, dass man kurze Kommentare mit `--` beginnend einfügen kann. Die Kommentare gehen dann bis zum Zeilenende. Längere Kommentare beginnen mit `/*` und enden mit `*/`.

```

CREATE OR REPLACE PROCEDURE RecordTest
IS
    TYPE T1 IS RECORD (
        X NUMBER,
        Y NUMBER
    );
    TYPE T2 IS RECORD (
        X NUMBER,
        Y NUMBER
    );
    A T1;
    B T1 DEFAULT A;
    C T2;
BEGIN
    A.x:=1;
    A.y:=2;
    -- DBMS_OUTPUT.PUT_LINE(A); geht nicht
    DBMS_OUTPUT.PUT_LINE('A.x= '||A.x);
    DBMS_OUTPUT.PUT_LINE('A.y= '||A.y);
    DBMS_OUTPUT.PUT_LINE('B.x= '||B.x);
    DBMS_OUTPUT.PUT_LINE('B.y= '||B.y);
    DBMS_OUTPUT.PUT_LINE(B.y); -- leere Zeile
    B.x:=1;
    B.y:=2;

```

```
-- IF A=B ist verboten
IF A.x=B.x AND A.y=B.y
    THEN DBMS_OUTPUT.PUT_LINE('A gleich B');
    ELSE DBMS_OUTPUT.PUT_LINE('A ungleich B');
END IF;
A:=B;
B.x:=2;
IF A.x=B.x AND A.y=B.y
    THEN DBMS_OUTPUT.PUT_LINE('A gleich B');
    ELSE DBMS_OUTPUT.PUT_LINE('A ungleich B');
END IF;
-- nicht erlaubt C:=A;
END;
```

Die Prozedur wird mit

```
EXECUTE RecordTest;
```

ausgeführt und hat folgende Ausgaben.

```
A.x= 1
A.y= 2
B.x=
B.y=

A gleich B
A ungleich B
```

Man kann daraus ableiten, dass man Record-Variablen nur attributsweise Werte zuweisen kann, dass nicht initialisierte Variablen den Startwert NULL haben, dass auch die Ausgabe nur attributsweise möglich ist und dass bei einer Zuweisung alle Werte kopiert werden, also keine Referenzen zwischen den Attributen aufgebaut werden.

Bisher wurden nur Prozeduren vorgestellt, allerdings lassen sich alle Überlegungen direkt auf Funktionen übertragen. Die allgemeine Syntax sieht wie folgt aus.

*PL/SQL-
Funktion*

```
CREATE [OR REPLACE] FUNCTION <Funktionsname>
    (<Parameterliste>) RETURN <Ergebnistyp> IS
    <LokaleVariablen>
BEGIN
    <Funktionsrumpf>
END;
```

Der Funktionsrumpf wird durch einen RETURN-Befehl, der von einem Wert oder einer Variable vom Typ <Ergebnistyp> gefolgt wird, beendet. Als Beispiel soll folgende einfache Funktion dienen, mit der überprüft wird, wieviele Teiler eine Zahl hat.

```

CREATE OR REPLACE FUNCTION AnzahlTeiler
(zahl INTEGER)
RETURN INTEGER IS
    ergebnis INTEGER DEFAULT 0;
BEGIN
    FOR I IN 1..zahl
    LOOP
        if zahl mod i=0
        THEN
            ergebnis:=ergebnis+1;
        END IF;
    END LOOP;
    RETURN ergebnis;
END;

```

Dabei steht mod für den Rest bei der ganzzahligen Division, also z. B. 7 mod 3 ergibt 1. Der direkte Aufruf von Funktionen geschieht mit einem Oracle-spezifischen Trick, mit dem man auch an weitere Systeminformationen gelangen kann. Dazu gibt es eine Pseudo-Tabelle DUAL, die zwar keinen Inhalt hat, bei deren Nutzung aber die in der SELECT-Zeile aufgerufene Funktionalität in besonderer Form bearbeitet wird. Der Aufruf der Funktion sieht wie folgt aus.

```
SELECT AnzahlTeiler(42) FROM DUAL;
```

Die zugehörige Ausgabe lautet wie folgt.

```

ANZAHLTEILER(42)
-----
8

```

Genau wie in Pascal oder C können Funktionen und Prozeduren andere Funktionen und Prozeduren aufrufen, was durch das folgende kleine Beispiel verdeutlicht werden soll. Man beachte, dass kein Schlüsselwort EXECUTE benutzt werden darf.

```

CREATE OR REPLACE PROCEDURE Primzahl
(zahl INTEGER)
IS
BEGIN
    IF anzahlTeiler(zahl)=2
    THEN
        DBMS_OUTPUT.PUT_LINE('ist Primzahl');
    ELSE
        DBMS_OUTPUT.PUT_LINE('keine Primzahl');
    END IF;
END;

```

Die Aufrufe

```
EXECUTE Primzahl(42);  
EXECUTE Primzahl(43);
```

liefern

```
keine Primzahl  
ist Primzahl
```

PL/SQL erlaubt wie z. B. die Programmiersprachen C++ und Java die Behandlung von Ausnahmen, wobei eine engere Verwandtschaft zum C++-Ansatz besteht. Die Ausnahmebehandlung ist gerade für PL/SQL interessant, da sie die Reaktion auf unerwünschte Ereignisse ermöglicht und weiterhin systematisch auf die Ausnahme reagiert werden kann.

PL/SQL- Ausnahmebe- handlung

Die Möglichkeiten des Exception-Handling, wie die Ausnahmebehandlung üblicherweise genannt wird, soll an einem kleinen Beispiel verdeutlicht werden. Zunächst ist EXCEPTION ein ganz normaler Datentyp, von dem Variablen angelegt werden können. Eine Ausnahme wird durch den Befehl RAISE ausgelöst. Bei einer Ausnahme wird der normale Ablauf des Prozedur- oder Funktionsblocks verlassen und in den eventuell vorhandenen Teil des Blocks zur Ausnahmebehandlung gesprungen. Falls die Ausnahme hier nicht bearbeitet wird, wird die Prozedur oder Funktion verlassen und die Ausnahme zur Behandlung an die aufrufende Prozedur oder Funktion weitergereicht. Falls es auf oberster Ebene keine Ausnahmebehandlung gibt, bricht die gesamte Ausführung mit einer Fehlermeldung ab. Es wird folgende, nicht ganz nette Funktion betrachtet.

```
CREATE OR REPLACE FUNCTION noHeinz(name VARCHAR)  
RETURN VARCHAR  
IS  
    heinz EXCEPTION;  
BEGIN  
    IF name='Heinz'  
    THEN  
        RAISE heinz;  
    ELSE  
        RETURN name;  
    END IF;  
END;
```

Die Funktion soll offensichtlich alle Heinz herausfiltern. Weiterhin kann die Funktion nicht auf Ausnahmen reagieren. Dies zeigen die beiden folgenden Aufrufe, wobei wieder deutlich wird, dass die Befehle unabhängig voneinander abgearbeitet werden.

Einzelne Fehler führen nicht dazu, dass das gesamte Skript mit den Befehlen nicht ausgeführt wird.

```
SELECT noHeinz('Erwin') FROM DUAL;
SELECT noHeinz('Heinz') FROM DUAL;
```

und die zugehörigen Ergebnisse.

```
NOHEINZ(ERWIN)
-----
Erwin

Error starting at line 2 in command:
SELECT noHeinz('Heinz') FROM DUAL
Error report:
SQL Error: ORA-06510: PL/SQL: Unbehandelte
benutzerdefinierte Exception
ORA-06512: in "KLEUKER.NOHEINZ", Zeile 8
```

Man kann Ausnahmen in einer sogenannten Exception Section fangen, die vor dem eigentlichen END steht und folgenden Aufbau hat.

*systematische
Ausnahmenbe-
handlung*

```
WHEN <Exceptiontyp1>
  THEN <Block1>
...
[WHEN <ExceptiontypN>
  THEN <BlockN>
WHEN OTHERS
  THEN <BlockM>]
```

Die Exception Section wird von oben nach unten abgearbeitet. Passt die Ausnahme vom Typ her zu dem Exceptiontyp, dann wird der zugehörige Block ausgeführt und die Prozedur oder Funktion normal verlassen. Falls kein Exceptiontyp zutrifft, können mit WHEN OTHERS beliebige Ausnahmen gefangen werden. Auf diese Zeilen wird oft verzichtet, da man auf eine unklare Ausnahme kaum sinnvoll reagieren kann. Wird eine Ausnahme insgesamt nicht behandelt, wird sie, wie vorher beschrieben, an die aufrufende Funktionalität weitergegeben. Bei geschachtelten Aufrufen kann so eventuell ein aufrufendes Programm auf die Ausnahme reagieren. Reagiert niemand, führt dies zu einer Fehlermeldung des DBMS, wie im vorherigen Beispiel gezeigt.

Das Verhalten soll mit einem kleinen Beispiel verdeutlicht werden, wobei ein kleiner Überraschungseffekt eingebaut ist.


```
CREATE OR REPLACE PROCEDURE heinzTest
IS
    heinz EXCEPTION;
BEGIN
    DBMS_OUTPUT.PUT_LINE(noHeinz('Egon'));
    DBMS_OUTPUT.PUT_LINE(noHeinz('Heinz'));
    DBMS_OUTPUT.PUT_LINE(noHeinz('Erwin'));
EXCEPTION
    WHEN heinz THEN
        DBMS_OUTPUT.PUT_LINE('Ein Heinz');
    WHEN OTHERS THEN
        DBMS_OUTPUT.PUT_LINE('Wat nu?');
END;
```

Die Ausführung mit

```
EXECUTE heinzTest;
```

führt zu folgender Ausgabe.

```
Egon
Wat nu?
```

Die Reaktion beim Parameter „Egon“ entspricht den Erwartungen. Da bei „Heinz“ eine Ausnahme auftritt, ist es auch klar, dass es keine Ausgabe zu „Erwin“ gibt. Überraschend ist aber zunächst, dass die Ausgabe „Wat nu?“ und nicht „Ein Heinz“ erscheint. Mit etwas Programmiererfahrung lässt sich das Problem leicht lösen. In der Funktion `noHeinz` wird eine lokale Variable `heinz` vom Typ `Exception` deklariert, die innerhalb der Funktion genutzt werden kann. Außerhalb der Funktion ist die lokale Variable aber unbekannt, so dass die `Exception` in `heinzTest` nur zufällig den gleichen Namen hat, aber sonst in keiner Beziehung zu dieser `Exception` steht.

Möchte man diesen Ansatz nutzen, müsste man Ausnahmen global erklären, was hier aber nicht betrachtet werden soll. Globale Ausnahmen werden von PL/SQL aber bereits zur Verfügung gestellt, so kann man z. B. auf die Ausnahme `ZERO_DIVIDE` reagieren, falls unerlaubt durch 0 geteilt wurde. Statt den Ausnahmemechanismus direkt zu nutzen, stellt PL/SQL einen komfortableren Ansatz zur Verfügung, bei dem ein Oracle-Ansatz vom Entwickler mit benutzt wird. Dazu wird der Befehl

```
RAISE_APPLICATION_ERROR (<Nummer>,<Fehlertext>)
```

genutzt, dabei muss die Nummer zwischen -21000 und -20000 liegen, da die anderen Nummern für das System reserviert sind. Das folgende Beispiel zeigt eine Kombination der erwähnten Ausnahmemechanismen.

*Nutzung des
existierenden
Fehlermechanismus*

```
CREATE OR REPLACE PROCEDURE exTest
IS
    I INTEGER DEFAULT 0;
BEGIN
    BEGIN
        I:=I/I;
        DBMS_OUTPUT.PUT_LINE('Nicht Erreicht');
    EXCEPTION
        WHEN ZERO_DIVIDE THEN
            DBMS_OUTPUT.PUT_LINE(''||SQLCODE||':'||
                                ||SQLERRM);
    END;

    DBMS_OUTPUT.PUT_LINE(''||SQLCODE||':'||
                        ||SQLERRM);
    RAISE_APPLICATION_ERROR(-20101,
                            'keine Lust mehr');
    EXCEPTION
        WHEN OTHERS THEN
            DBMS_OUTPUT.PUT_LINE(''||SQLCODE||':'||
                                ||SQLERRM);
            IF SQLCODE=-20101
            THEN
                DBMS_OUTPUT.PUT_LINE('stimmt nicht');
            END IF;
    END;
END;
```

Zunächst wird durch 0 geteilt, so dass eine Systemausnahme auftritt, die in der zum Block gehörenden Exception Section gefangen wird. Das Programm wird dann nach diesem Block fortgesetzt. Man sieht, dass man auf die globalen Systemvariablen `SQLCODE` und `SQLERRM` zugreifen kann, um die Nummer und den Text der letzten Fehlermeldung einzusehen. Danach wird der neue Mechanismus genutzt, um eine eigene Ausnahme mit der Nummer -20101 zu erzeugen, die dann in der zugehörigen Exception Section gefangen wird. Diese Ausnahmen kann man zur Behandlung dann über die Fehlernummer identifizieren und so darauf reagieren. Die zu

```
EXECUTE exTest;
```

gehörige Ausgabe, evtl. in einem speziellen Fenster für Systemmeldungen, sieht wie folgt aus.

```
-1476::ORA-01476: Divisor ist Null
0::ORA-0000: normal, successful completion
-20101::ORA-20101: keine Lust mehr
stimmt nicht
```

Dieser Abschnitt hat nur eine kompakte Einführung in zentrale Sprachelemente von PL/SQL gegeben, die für die folgenden Abschnitte benötigt werden. PL/SQL bietet noch weitere Sprachfeatures, wie die Aufteilung von Prozeduren auf Module und eine spezielle Art um Arrays zu deklarieren. Hierfür sind die in Englisch verfassten und frei zugänglichen Oracle-Handbücher (<http://www.oracle.com/technology/documentation/index.html>) als Nachschlagewerke empfehlenswert.

12.2

Datenbankanfragen und Cursor in PL/SQL

Im vorherigen Unterkapitel wurde die Programmiersprache PL/SQL vorgestellt, die aus Sicht moderner Programmiersprachen wie Java und C# leicht antiquiert wirkt. Nun soll der Bezug zur Datenbank präzisiert werden. PL/SQL bietet dabei spezielle Sprachkonstrukte, die die saubere Bearbeitung von Datenbanken wesentlich erleichtern kann.

*PL/SQL-
Nutzung von
Anfrage-
Ergebnissen*

Möchte man in einer Prozedur auf genau einen Wert aus den vorhandenen Tabellen zugreifen, so kann man den erweiterten SELECT-Befehl der Form

```
SELECT <Ausgabe>
INTO <Variable>
FROM ... (übliche Struktur einer SQL-Anfrage)
```

nutzen. Dabei muss die Variable <Variable> vom Typ her zur <Ausgabe> passen. Falls die Anfrage mehr als ein Ergebnis liefert, wird die Ausführung mit einer Ausnahme abgebrochen.

Um einen genau passenden Datentypen für eine Variable zu erhalten, kann man explizit fordern, dass der Datentyp einer Spalte einer Tabelle genutzt wird. Auf diesen Typen kann mit

```
<Tabellenname>.<Spaltenname>%TYPE
```

zugegriffen werden.

Mit der folgenden Prozedur wird der Flächenverbrauch einer Gattung berechnet und ausgegeben.

```
CREATE OR REPLACE PROCEDURE Verbrauch
(gat Art.Gattung%TYPE)
IS
    ergebnis Art.MinFlaeche%Type;
BEGIN
    SELECT SUM(Art.MinFlaeche)
    INTO ergebnis
    FROM Tier, Art
    WHERE Tier.Gattung=Art.Gattung
```

```
        AND Art.Gattung=gat;
        DBMS_OUTPUT.PUT_LINE(gat || ' verbraucht '
                               ||ergebnis||'.');
    END;
```

Die folgenden Aufrufe

```
EXECUTE Verbrauch('Baer');
EXECUTE Verbrauch('Gnu');
```

liefern

```
Baer verbraucht 16.
Gnu verbraucht .
```

Man erkennt, dass Aggregatsfunktionen, die auf keinen Werten arbeiten, da es hier z. B. keine Gnus im Zoo gibt, den Wert NULL und nicht wie eventuell gehofft die Zahl 0 zurückgeben. Dies entspricht aber auch dem Ergebnis der Anfrage, wenn direkt mit

```
SELECT SUM(Art.MinFlaeche)
FROM Tier, Art
WHERE Tier.Gattung=Art.Gattung
AND Art.Gattung='Gnu';
```

nach Gnus gesucht wird. Das Ergebnis ist eine leere Tabelle und nicht der eventuell genauso plausible Wert 0. Würde man das SUM durch COUNT ersetzen, wäre das Ergebnis allerdings die Zahl 0. Wichtig ist die daraus resultierende Schlussfolgerung, dass man am Besten vor einer SELECT-INTO-Anfrage prüft, ob ein sinnvolles Ergebnis zu erwarten ist. Alternativ ist bei der Nutzung von Aggregatsfunktionen das Ergebnis im nächsten Schritt auf NULL zu prüfen.

Das folgende Beispiel zeigt die Reaktionen bei der Ausführung von PL/SQL, wenn beim SELECT-INTO nicht ein Wert berechnet werden kann. Dazu wird eine Funktion geschrieben, die zu einer übergebenen Gattung den eindeutigen Namen des Tieres zurückliefern soll. Ist kein Tier oder sind mehrere Tiere dieser Gattung vorhanden, führt die Ausführung zu Problemen. Die Funktion sieht wie folgt aus.

```
CREATE OR REPLACE FUNCTION tiername
(gat Art.Gattung%Type)
RETURN Tier.Tname%Type
IS
    ergebnis Tier.Tname%Type;
BEGIN
    SELECT Tier.Tname
    INTO ergebnis
    FROM Tier
```

```

        WHERE Tier.Gattung=gat;
        RETURN ergebnis;
    END;

```

Die folgenden Aufrufe

```

SELECT tiername('Gnu') FROM DUAL;
SELECT tiername('Baer') FROM DUAL;

```

führen zu folgenden Ausgaben.

```

TIERNAME (GNU)
-----

```

```

1 rows selected

```

*SELECT INTO
darf nicht meh-
rere Zeilen lie-
fern*

```

Error starting at line 2 in command:
SELECT tiername('Baer') FROM DUAL
Error report:
SQL Error: ORA-01422: Exakter Abruf gibt mehr als
die angeforderte Zeilenzahl zurück
ORA-06512: in "KLEUKER.TIERNAME", Zeile 7

```

Die erste Ausgabe zeigt, dass bei nicht vorhandenen Werten es keine Fehlermeldung gibt, es wird der Wert NULL zurückgegeben, auf den gegebenenfalls geprüft werden muss. Bei zu vielen Werten gibt es eine Fehlermeldung.

Statt nur eine Variable bei der INTO-Zeile anzugeben, kann man hier auch mehrere Variablen angeben, die dann von den Datentypen her genau zu den ausgewählten Ausgabewerten der SELECT-Zeile passen müssen. Die folgende Prozedur gibt die Daten zu einem Tier aus, wobei zunächst geprüft wird, ob der Tiername genau einmal vorhanden ist.

```

CREATE OR REPLACE PROCEDURE tierdaten
    (tiername Tier.Tname%Type)
IS
    zaehler integer;
    gehege Tier.Gnr%Type;
    gat Tier.Gattung%Type;
BEGIN
    SELECT COUNT(*)
    INTO zaehler
    FROM Tier
    WHERE Tier.Tname=tiername;
    IF zaehler<>1
    THEN
        DBMS_OUTPUT.PUT_LINE('Name nicht '
                                || 'eindeutig');
    ELSE
        SELECT Tier.Gnr, Tier.Gattung

```

```

        INTO gehege, gat
      FROM Tier
      WHERE Tier.Tname=tiername;
      DBMS_OUTPUT.PUT_LINE(tiername||' ('||
        gat||') in Gehege '||gehege||'.');
    END IF;
  END;
```

Die folgenden Aufrufe

```

EXECUTE tierdaten('Laber');
EXECUTE tierdaten('Horst');
```

liefern

```

Laber (Baer) in Gehege 1.
Name nicht eindeutig
```

Soll eine vollständige Zeile einer Tabelle in einer Ergebnisvariablen festgehalten werden, gibt es eine weitere komfortable Lösung. Durch

*Nutzung von
Spaltentypen*

```
<Tabellenname>%ROWTYPE
```

ist ein Record-Datentyp definiert, der genau zu einer Zeile der Tabelle passt. Die vorherige Prozedur sollte also wesentlich eleganter wie folgt programmiert werden.

```

CREATE OR REPLACE PROCEDURE tierdaten2
  (tiername Tier.Tname%Type)
IS
  zaehler integer;
  info Tier%ROWTYPE;
BEGIN
  SELECT COUNT(*)
  INTO zaehler
  FROM Tier
  WHERE Tier.Tname=tiername;
  IF zaehler<>1
  THEN
    DBMS_OUTPUT.PUT_LINE('Name nicht '
      || 'eindeutig');
  ELSE
    SELECT *
    INTO info
    FROM Tier
    WHERE Tier.Tname=tiername;
    DBMS_OUTPUT.PUT_LINE(tiername||' ('
      ||info.Gattung||') in Gehege '
      ||info.Gnr||'.');
  END IF;
END;
```

mehrere Ergebniszeilen mit Cursor

Ist man nicht nur an einzelnen Tabellenzeilen interessiert, muss man eine Möglichkeit haben, die resultierende Ergebnistabelle abzuarbeiten. Hierzu werden sogenannte Cursor benutzt, die es erlauben, das Ergebnis einer Anfrage schrittweise abzuarbeiten. Es ist nicht möglich, auf alle Zeilen des Ergebnisses gleichzeitig zuzugreifen. Der aktuelle Zugriff ist immer nur auf eine Zeile möglich, wobei man den Cursor anweisen kann, zur nächsten Ergebniszeile zu gehen. Weiterhin kann man überprüfen, ob der Cursor schon alle Ergebnisse durchlaufen hat. Programmiererfahrene Leser sollten eine enge Verwandtschaft von Cursors zu Iteratoren erkennen, die zur Abarbeitung von Collections wie z. B. Listen genutzt werden.

Cursor werden als spezieller Datentyp für eine konkrete Anfrage wie folgt definiert.

Cursor-Definition

```
CURSOR <Cursorname> [ (Parameterliste) ] IS
    <Datenbankanfrage>;
```

Durch die Definition eines Cursors wird die zugehörige Anfrage noch nicht ausgeführt. Dies passiert erst bei der Nutzung des Cursors, die z. B. durch

Cursor-Ausführung

```
OPEN <Cursorname> [ (Argumente) ];
```

geschieht. Die Ergebnisse des Cursors können dann zeilenweise eingelesen werden. Zum Einlesen wird eine Variable benötigt, die zum Ergebnis des Cursors passt. Der zugehörige Record-Typ heißt <Cursorname>%ROWTYPE, so dass eine passende Variable durch

```
<Variablenname> <Cursorname>%ROWTYPE;
```

deklariert wird.

Das eigentliche Einlesen einer Ergebniszeile geschieht mit dem Befehl

```
FETCH <Cursorname> INTO <Variablenname>;
```

Danach kann der erhaltene Record wie bereits bekannt bearbeitet werden. Nachdem ein Cursor abgearbeitet wurde, ist er mit

```
CLOSE <Cursorname>;
```

schleichende Fehlermöglichkeit

wieder zu schließen. Dies bedeutet für das System, dass die zur Bearbeitung bereit gestellten Systemressourcen anderweitig genutzt werden können. Vergisst man das CLOSE, kann es im System nach wiederholter Nutzung der umgebenden Prozedur zu Speicherengpässen führen, die das System verlangsamen oder

die Ausführung verhindern. Datenbankmanagementsysteme stellen typischerweise Werkzeuge zur Überwachung der einzelnen Verbindungen zur Verfügung, so dass es Möglichkeiten zur Nachverfolgung gibt, an denen man erkennt, dass Verbindungen nicht geschlossen wurden. Alternativ kann man dies auch an Parametern des jeweiligen Betriebssystems eventuell erkennen.

Befehl	Bedeutung
<Cursorname>%ISOPEN	Wurde der Cursor schon geöffnet?
<Cursorname>%FOUND	Wurde bei der letzten FETCH-Operation eine neue Zeile gefunden?
<Cursorname>%NOTFOUND	Wurde bei der letzten FETCH-Operation keine neue Zeilen gefunden?
<Cursorname>%ROWCOUNT	Liefert die Anzahl der bereits gelesenen Zeilen.

Abb. 12.2: Befehle zur Cursor-Steuerung

Zur Cursor-Steuerung stehen die in Abb. 12.2 genannten Befehle zur Verfügung.

Die folgende Prozedur gibt alle zu einer Gattung bekannten Informationen aus.

```

CREATE OR REPLACE PROCEDURE gattungsinfo
(gat Art.Gattung%Type)
IS
    CURSOR tiere(g Art.Gattung%Type) IS
        SELECT *
        FROM Tier
        WHERE Tier.Gattung=g;
    viech tiere%ROWTYPE;
    anzahl integer;
BEGIN
    SELECT COUNT(*)
    INTO anzahl
    FROM Tier
    WHERE Tier.Gattung=gat;
    IF anzahl=0
    THEN
        DBMS_OUTPUT.PUT_LINE('nicht vorhanden');
    ELSE
        DBMS_OUTPUT.PUT_LINE('Es gibt folgende '
                               ||anzahl||' Tiere:');
        OPEN tiere(gat);
        FETCH tiere INTO VIECH;
        WHILE tiere%FOUND
        LOOP
            DBMS_OUTPUT.PUT_LINE(tiere%ROWCOUNT

```



```

        ||'. '||viech.Tname||' in Gehege '
        ||viech.Gnr||'.');
    FETCH tiere INTO VIECH;
END LOOP;
END IF;
CLOSE tiere;
END;

```

Die folgenden Aufrufe

```

EXECUTE gattungsinfo('Gnu');
EXECUTE gattungsinfo('Hase');

```

liefern

```

nicht vorhanden

Es gibt folgende 4 Tiere:
1. Klopfer in Gehege 2.
2. Bunny in Gehege 3.
3. Runny in Gehege 2.
4. Hunny in Gehege 2.

```

*CURSOR mit
WHILE-Schleife*

Das Beispiel zeigt den klassischen Weg, wenn ein Cursor innerhalb einer WHILE-Schleife genutzt wird. Vor dem Schleifenanfang wird die erste Zeile gelesen und immer am Anfang der WHILE-Schleife geprüft, ob beim letzten FETCH eine neue Zeile gelesen wurde.

Neben der WHILE-Schleife gibt es auch eine FOR-Schleife zur effizienten Nutzung von Cursors, die etwas kürzer, aber dafür weniger flexibel ist. Die zugehörige Syntax der Schleife sieht wie folgt aus.

*CURSOR mit
FOR-Schleife*

```

FOR <Variable> IN <Cursorname> [(Argumente)]
LOOP
    <Schleifenrumpf>
END LOOP;

```

Die <Variable> darf vorher nicht deklariert werden und bekommt automatisch den Typ <Cursorname>%ROWTYPE. Der Cursor wird automatisch am Anfang der Schleife geöffnet und es findet ein FETCH in <Variable> statt. Die Schleife durchläuft genau alle Elemente des Cursors. Am Ende der Schleife wird der Cursor automatisch geschlossen. Die folgende Prozedur ist eine leichte Abwandlung der vorherigen Prozedur, bei der nicht geprüft wird, ob es überhaupt Tiere der Gattung gibt.

```

CREATE OR REPLACE PROCEDURE gattungsinfo2
(gat Art.Gattung%Type)
IS

```

```

CURSOR tiere(g Art.Gattung%Type) IS
  SELECT *
  FROM Tier
  WHERE Tier.Gattung=gat;
BEGIN
  DBMS_OUTPUT.PUT_LINE('Von '||gat||' gibt es:');
  FOR viech IN tiere(gat)
  LOOP
    DBMS_OUTPUT.PUT_LINE(tiere%ROWCOUNT||'. '
                          ||viech.Tname||' in Gehege '
                          ||viech.Gnr||'.');
  END LOOP;
END;
```

Die folgenden Aufrufe

```

EXECUTE gattungsinfo2('Gnu');
EXECUTE gattungsinfo2('Hase');
```

liefern

```

Von Gnu gibt es:

Von Hase gibt es:
1. Klopfer in Gehege 2.
2. Bunny in Gehege 3.
3. Runny in Gehege 2.
4. Hunny in Gehege 2.
```

Cursor können nach dem Schließen erneut geöffnet werden, dabei wird die zugehörige Anfrage erneut ausgeführt. Ein geöffneter Cursor kann nicht ein zweites Mal geöffnet werden. Falls es hierzu eine Notwendigkeit geben sollte, müsste ein zweiter identischer Cursor definiert werden.

Wie bereits erwähnt, können beliebige INSERT, UPDATE und DELETE-Befehle als normale Programmierbefehle in PL/SQL genutzt werden. Es kann aber auch sinnvoll sein, dass man Änderungen direkt an den Stellen durchführen möchte, an denen gerade der Cursor steht. Dies geht natürlich nur, wenn sich der Cursor auf genau eine Tabelle und jedes Ergebnis auf eine Spalte bezieht. In diesem Fall kann man die Definition des Cursors um die Angabe FOR UPDATE ergänzen, so dass man in einem UPDATE-Befehl auf die aktuelle Cursor-Position mit WHERE CURRENT OF <Cursorname> zugreifen kann.

Cursor mit Aktualisierungsmöglichkeit

Im Beispiel sollen die Namen der ausgewählten Gattung um den Zusatz des Gattungsnamen ergänzt werden. Die zugehörige Prozedur sieht wie folgt aus.

```
CREATE OR REPLACE PROCEDURE langerName
(gat Art.Gattung%Type)
IS
  CURSOR wahl(g Art.Gattung%Type) IS
    SELECT *
    FROM Tier
    WHERE Tier.Gattung=g
    FOR UPDATE;
BEGIN
  FOR viech IN wahl(gat)
  LOOP
    UPDATE Tier
      SET Tname=Tname||Gattung
      WHERE CURRENT OF wahl;
    END LOOP;
  END;
```

Das Ausführen von

```
EXECUTE langerName('Hase');
SELECT *
FROM Tier
WHERE Tier.Gattung='Hase';
```

liefert

GNR	TNAME	GATTUNG
-----	-----	-----
2	KlopferHase	Hase
3	BunnyHase	Hase
2	RunnyHase	Hase
2	HunnyHase	Hase

PL/SQL-Programme laufen in Transaktionen und können diese steuern, erhalten sie z. B. keinen COMMIT-Befehl, kann man die Änderungen mit einem ROLLBACK rückgängig machen, was für den folgenden Abschnitt für die letzte ausgeführte Prozedur angenommen wird.

12.3

Trigger

Um die Qualität der Daten zu sichern, stehen bis jetzt nur das saubere Design der Datenbank, der Einsatz von FOREIGN KEYS und die Nutzung von CONSTRAINTS als Hilfsmittel zur Verfügung. Die wesentliche Einschränkung von CONSTRAINTS ist, dass sie nur auf einer Tabelle arbeiten und keinen Bezug zu anderen Tabellen oder zu weiteren in der Tabelle eingetragenen Daten aufbauen können. Diese Einschränkungen werden mit den Triggern fallen gelassen.

*Event**Condition**Action*

Trigger funktionieren dabei nach dem sogenannten Event-Condition-Action Paradigma, was heißt, dass ein Trigger auf ein bestimmtes Ereignis, also Event, wartet, dann prüft, ob eine weitere Bedingung, also Condition, erfüllt ist und dann eine Aktion, also Action, ausführt.

Als Ereignisse stehen alle möglichen Änderungen der Tabellen zur Verfügung, die mit INSERT, UPDATE und DELETE bearbeitet werden. Die Aktionen bestehen grundsätzlich aus PL/SQL-Programmen. Die generelle Form von Triggern sieht wie folgt aus.

Defintion von Triggern

```
CREATE [OR REPLACE] TRIGGER <Triggername>
  {BEFORE | AFTER}
  {INSERT | DELETE | UPDATE} [OF {Spaltenliste}]
  [OR {INSERT | DELETE | UPDATE} [OF {Spaltenliste}]]
  ...
  [OR {INSERT | DELETE | UPDATE} [OF {Spaltenliste}]]
  ON <Tabellenname>
  [FOR EACH ROW]
  [WHEN <Bedingung>]
  <PL/SQL-Block>;
```

Dabei stehen in geschweiften Klammern stehende, mit senkrechten Strichen abtrennte Teile für Alternativen, von denen eine gewählt werden muss.

Die gesamten Alternativen werden anhand von Beispielen diskutiert. Eine typische Aufgabe von Triggern ist es, Änderungen in der Datenbank zu protokollieren. Dazu wird jetzt eine einfache Tabelle zur Protokollierung genutzt, die festhält, wer welches Tier in das System eingetragen hat. Zur Feststellung des Ausführenden des INSERT-Befehls wird die Systeminformation USERNAME in der Systemtabelle USER_USERS genutzt. Die Protokolltabelle soll folgende Form haben.

```
CREATE TABLE Zooprotokoll(
  nr INT,
  wann DATE,
  wer VARCHAR(255),
  gehege INTEGER,
  tiername VARCHAR(12),
  PRIMARY KEY(nr)
);
```

Die Nummerierung der Einträge soll automatisch erfolgen. Zu diesem Zweck kann man sogenannte Sequenzzähler in Oracle definieren, ihre Syntax ist wie folgt.

*automatische
Zählvariable*

```
CREATE SEQUENCE <Sequenzname>
  INCREMENT BY <inc>
  START WITH <start>;
```

Der Sequenzzähler startet mit dem Wert <start>. Auf den aktuellen Wert des Zählers kann mit

```
<Sequenzzähler>.CURRVAL
```

zugegriffen werden. Mit

```
<Sequenzzähler>.NEXTVAL
```

wird der Wert des Zählers um <inc> erhöht und zurückgegeben. Dabei muss am Anfang zunächst einmal NEXTVAL benutzt werden, damit dann CURRVAL nutzbar wird. Der Wert eines Zählers lässt sich wie folgt direkt abfragen.

```
SELECT <Sequenzzähler>.CURRVAL FROM DUAL;
```

Konkret wird folgender Zähler definiert.

```
CREATE SEQUENCE zoozaehler
  INCREMENT BY 1
  START WITH 1;
```

Die Anfragen

```
SELECT zoozaehler.NEXTVAL FROM DUAL;
SELECT zoozaehler.CURRVAL FROM DUAL;
```

liefern

```
NEXTVAL
-----
1

CURRVAL
-----
1
```

Die Idee des Protokolltriggers besteht darin, dass bevor ein Eintrag in die Tabelle Tier gemacht wird, ein Eintrag in der Tabelle Zooprotokoll erfolgt. Der Trigger hat dann folgende Form, wobei aus der Systemvariablen SYSDATE das aktuelle Datum gelesen wird.

```
CREATE OR REPLACE TRIGGER neuestTier
  BEFORE INSERT
  ON TIER
  FOR EACH ROW
  DECLARE
    datum DATE;
```

```

        nutzer USER_USERS.USERNAME%Type;
BEGIN
    SELECT SYSDATE
        INTO datum
        FROM DUAL;
    SELECT USER_USERS.USERNAME
        INTO nutzer
        FROM USER_USERS;
    INSERT INTO Zooprotokoll VALUES
        (zoozaehler.NEXTVAL,datum,nutzer,:NEW.Gnr,
         :NEW.Tname);
END;

```

Werden dann folgende Zeilen ausgeführt

```

INSERT INTO Gehege VALUES(4,'Heide',80);
INSERT INTO Tier VALUES(4,'Sauber','Baer');
INSERT INTO Tier VALUES(4,'Huber','Baer');
SELECT * FROM Zooprotokoll;

```

gibt es das folgende Ergebnis.

NR	WANN	WER	GEHEGE	TIERNAME
1	20.09.10	KLEUKER	4	Sauber
2	20.09.10	KLEUKER	4	Huber

Triggervarianten

Mit BEFORE und AFTER kann gesteuert werden, wann ein Trigger ausgeführt werden soll. Dies geschieht entweder vor der endgültigen Ausführung oder nach der Ausführung des Ereignisses, das den Trigger auslöst. Im Beispiel hätte man genauso gut AFTER nutzen können, da es egal ist, wann der Eintrag erfolgt. Ein BEFORE-Trigger ist grundsätzlich flexibler, da man z. B. mit einer Ausnahme die eigentliche Aktion, hier also das Einfügen, abbrechen kann.

Dieser Trigger reagiert nur auf INSERT-Befehle, durch eine OR-Verknüpfung kann dieser Trigger auch zusätzlich auf DELETE und UPDATE reagieren. Nur bei UPDATE gibt es noch die zusätzlichen Möglichkeiten, mit OF {Spaltenliste} die Reaktion noch weiter nur auf die genannten Spalten zu reduzieren.

Die Angabe FOR EACH ROW gibt an, dass der Trigger für jede Zeile, die betroffen ist, ausgeführt werden soll. Dies ist nur bei Befehlen interessant, die mehrere Zeilen betreffen, was aber bei INSERT durch die Angabe, dass die Ergebnisse einer Anfrage eingetragen werden sollen, auch der Fall sein kann.

Die Angabe von FOR EACH ROW und die Nutzung von BEFORE ermöglicht auch den genauen Zugriff auf die geänderten Werte,

dafür gibt es zwei spezielle Variablen :NEW und :OLD, die jeweils vom Typ <Tabellenname>%ROWTYPE sind. Dadurch kann auf die neu eingetragenen Werte und bei UPDATE und DELETE auf die alten Werte der jeweils betroffenen Zeile zugegriffen werden. Nur bei einem BEFORE-Trigger können so auch die neuen Werte noch verändert werden.

Die WHEN-Zeile erlaubt die Angabe einer Bedingung, die zusätzlich zum auslösenden Ereignis geprüft werden soll. Dabei ist die Zeile nur bei Triggern mit FOR EACH ROW erlaubt und bezieht sich auf die aktuell behandelte Zeile. Die veränderten Werte können auch in der WHEN-Bedingung referenziert werden, dabei werden hier allerdings irritierend NEW und OLD statt :NEW und :OLD genutzt. Beim vorgestellten Trigger könnte man z. B. verhindern, dass neue Hasen auch in die Protokolltabelle eingetragen werden. Dazu wird nach FOR EACH ROW die Zeile

```
WHEN (NEW.Gattung<>'Hase')
```

ergänzt. Man beachte die syntaktisch notwendigen Klammern. Die WHEN-Bedingung macht die Ausführung etwas kürzer, da schnell festgestellt werden kann, ob der Trigger ausgeführt werden muss. Prinzipiell kann man die Prüfung der Bedingung auch in den PL/SQL-Teil der Aktion des Triggers einbauen.

*Trigger einmal
pro Zeile oder
pro Aktion*

Der Bedeutung der Zeile FOR EACH ROW soll jetzt mit einem kleinen Beispiel verdeutlicht werden. Dazu wird zunächst folgende Spieltabelle angelegt.

```
CREATE TABLE Tr(  
  X NUMBER,  
  Y NUMBER  
);  
INSERT INTO Tr VALUES (1,3);  
INSERT INTO Tr VALUES (1,4);  
INSERT INTO Tr VALUES (1,5);  
SELECT * FROM Tr;
```

Die Ausgabe lautet wie folgt.

X	Y
1	3
1	4
1	5

Dann wird ein Trigger angelegt, der sich nur auf die gesamte Tabelle und nicht die einzelnen Zeilen bezieht.

```

CREATE OR REPLACE TRIGGER TrOhneEach
BEFORE UPDATE
ON Tr
BEGIN
    DBMS_OUTPUT.PUT_LINE('TrOhneEach');
END;

```

Dazu kommt ein zweiter sehr ähnlicher Trigger, der sich aber auf jede betroffene Zeile bezieht, weiterhin zeigt er eine Spielerei mit der Veränderung der eingetragenen Werte.

```

CREATE OR REPLACE TRIGGER TrMitEach
BEFORE UPDATE
ON Tr
FOR EACH ROW
BEGIN
    DBMS_OUTPUT.PUT_LINE('TrMitEach');
    :NEW.X := :NEW.Y;
    :NEW.Y := :OLD.X;
END;

```

Die Ausführung der folgenden Befehle

```

UPDATE TR
SET Y=Y+1
WHERE X=1;
SELECT * FROM Tr;

```

ergibt dann folgendes Ergebnis.

```

TrOhneEach
TrMitEach
TrMitEach
TrMitEach

```

X	Y
4	1
5	1
6	1

Man erkennt, dass der TriggerMitEach dreimal, d. h. für jede betroffene Zeile, ausgeführt wurde.

Das folgende Beispiel zeigt einen Trigger, der das Hinzufügen oder Ändern einer Art nur erlaubt, wenn es überhaupt ein Gehege gibt, in das ein solches Tier mit seinem Flächenanspruch eingefügt werden kann. Dies zeigt die Möglichkeit, in Triggern auf mehrere Tabellen zuzugreifen und eine Aktion gegebenenfalls abzurechnen. Ein Cursor bestimmt für jedes Gehege die noch freie Fläche, dazu wird von der Gesamtfläche des Geheges die

*Trigger für
mehrere Tabel-
len*

Summe der minimal notwendigen Flächen der einzelnen Tiere abgezogen. Danach wird in einer Schleife der maximal freie Platz in der Variablen maxFreierPlatz berechnet und geprüft, ob der Flächenbedarf der neuen Art nicht größer als die freie Fläche ist. Durch andere SQL-Anfragen wäre es durchaus möglich, den Trigger anders zu gestalten. Der Trigger hat folgende Form.

```
CREATE OR REPLACE TRIGGER neueArt
BEFORE INSERT OR UPDATE
ON ART
FOR EACH ROW
DECLARE
    maxFreierPlatz INTEGER DEFAULT 0;
    CURSOR verbraucht IS
        SELECT Gehege.Flaeche-SUM(Art.MinFlaeche) frei
        FROM Gehege,Tier,Art
        WHERE Gehege.Gnr=Tier.Gnr
            AND Tier.Gattung=Art.Gattung
        GROUP BY Gehege.GNr, Gehege.Flaeche ;
BEGIN
    FOR g IN verbraucht
    LOOP
        IF maxFreierPlatz < g.frei
        THEN
            maxFreierPlatz:=g.frei;
        END IF;
    END LOOP;

    IF maxFreierPlatz<:NEW.MinFlaeche
    THEN
        RAISE_APPLICATION_ERROR(-20999,
            'passt nirgendwo rein');
    END IF;
END;
```

Werden folgende Befehle ausgeführt,

```
INSERT INTO ART VALUES('Gnu',12);
INSERT INTO ART VALUES('Elefant',100);
SELECT * FROM Art;
```

führt dies zu folgender Ausgabe.

```
1 rows inserted
Error report:
SQL Error: ORA-20999: passt nirgendwo rein
ORA-06512: in "KLEUKER.NEUEART", Zeile 19
ORA-04088: Fehler bei der Ausführung von Trigger
'KLEUKER.NEUEART'
```

Trigger für Views

GATTUNG	MINFLAECHE

Baer	8
Hase	2
Schaf	5
Reh	4
Gnu	12

Bisher wurden Trigger direkt für existierende Tabellen definiert. In einer leicht abgewandelten Form ist es aber auch möglich, Trigger für Views zu definieren und sie so für Nutzer als vollständig nutzbare Tabellen erscheinen zu lassen. Dies sind sogenannte *INSTEAD OF*-Trigger, da sie anstatt dem vermeintlich direkten Zugriff auf den View tätig werden. Die generelle Syntax sieht wie folgt aus, man sieht, dass es keine *WHEN*-Bedingung geben kann.

```
CREATE [OR REPLACE] TRIGGER <Triggername>
  INSTEAD OF
  {INSERT | DELETE | UPDATE} [OF {Spaltenliste}]
  ON <Viewname>
  [FOR EACH ROW]
  <PL/SQL-Block>;
```

Für ein Beispiel wird zunächst ein View konstruiert, der einen vollständigen Überblick über den Zoo liefert.

```
CREATE OR REPLACE VIEW Gesamt AS
  SELECT Tier.TName, Tier.Gattung,
         Art.MinFlaeche, Gehege.GNr, Gehege.GName
  FROM Gehege, Tier, Art
 WHERE Gehege.Gnr=Tier.GNr
        AND Tier.Gattung=Art.Gattung;
```

Dieser View kann nicht verändert werden, da er sich aus mehreren Tabellen zusammensetzt. Mit einem *INSTEAD OF*-Trigger kann man es aber schaffen, dass *INSERT*-Befehle für diesen View erlaubt sind. Der Trigger analysiert dabei die neu eingetragenen Werte und insofern Aktualisierungen der Basistabellen notwendig sind, werden diese vorgenommen. Der Trigger sieht wie folgt aus.

```
CREATE OR REPLACE TRIGGER tierInGesamt
  INSTEAD OF INSERT
  ON Gesamt
  FOR EACH ROW
  DECLARE
    zaehler INTEGER;
  BEGIN
```

```
SELECT COUNT(*)
INTO zaehler
FROM Gehege
WHERE Gehege.GNr=:NEW.GNr;
IF zaehler=0 /* dann neues Gehege */
THEN
    INSERT INTO Gehege VALUES (:NEW.GNr,
                                :NEW.GName,50);
END IF;
SELECT COUNT(*)
INTO zaehler
FROM Art
WHERE Art.Gattung=:NEW.Gattung;
IF zaehler=0 /* dann neue Art */
THEN
    INSERT INTO Art VALUES (:NEW.Gattung,
                             :NEW.MinFlaeche);
END IF;
INSERT INTO Tier VALUES (:NEW.GNr,:NEW.TName,
                          :NEW.Gattung);
END;
```

Die Ausführung der folgenden Befehle

```
INSERT INTO Gesamt
VALUES ('Egon','Uhu',5,5,'Halle');
SELECT *
FROM Gesamt
WHERE Gesamt.GNr=5;
SELECT * FROM Gehege;
```

führt zu folgender Ausgabe.

TNAME	GATTUNG	MINFLAECHE	GNR	GNAME
-----	-----	-----	-----	-----
Egon	Uhu	5	5	Halle

GNR	GNAME	FLAECHE
-----	-----	-----
1	Wald	30
2	Feld	20
3	Weide	15
4	Heide	80
5	Halle	50

Um den View vollständig nutzbar zu machen, können auch INSTEAD OF-Trigger für DELETE und UPDATE in ähnlicher Form geschrieben werden.

Werden sehr viele Trigger in einem System genutzt, kann das die Bearbeitungszeit stark negativ beeinflussen, da z. B. ein Trigger mit FOR EACH ROW für jeden Eintrag abgearbeitet werden

*Gefährliche
Ketten von
Triggern*

muss. Bei sehr vielen Triggern kann es ein weiteres Problem geben, da ein Trigger, der z. B. ein INSERT-Statement ausführt, dadurch einen neuen Trigger anstoßen kann. Durch diesen Mechanismus können Ketten von Triggerrufen entstehen, die dann schrittweise abgearbeitet werden müssen. Führt ein INSERT-Trigger einer Tabelle B dabei ein INSERT auf einer Tabelle A aus, was dann einen Trigger anstößt, der ein INSERT auf B ausführt, kann es zu Zyklen in der Triggerausführung kommen, was letztendlich zu Endlosschleifen führen könnte. Um dieses Problem zu meiden, werden Tabellen, auf denen gerade ein Trigger läuft, gesperrt und falls bei der weiteren Triggerausführung erneut auf die Tabelle zurückgegriffen wird, wird die gesamte Aktion mit einer Fehlermeldung abgebrochen.

12.4

Aufgaben

Wiederholungsfragen

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu bearbeiten.

1. Wozu gibt es Stored-Procedures?
2. Erklären Sie anschaulich den typischen Aufbau einer Stored Procedure.
3. Warum machen Ausgaben in Stored Procedures nur eingeschränkt Sinn?
4. Wozu dient in Oracle die Tabelle Dual?
5. Erklären Sie die Nutzung des SELECT-Befehls innerhalb einer Stored Procedure. Wozu werden %TYPE und %ROWTYPE genutzt?
6. Erklären Sie die Funktionsweise der Ausnahmebehandlung in PL/SQL.
7. Erklären Sie die Funktionsweise und Nutzungsmöglichkeiten von Cursoren.
8. Erklären Sie, wie Trigger funktionieren.
9. Wozu wird FOR EACH ROW in Triggern genutzt, was hat dies mit der Nutzung von :NEW und :OLD zu tun?
10. Welche Probleme können bei der Trigger-Entwicklung auftreten?

11. Welchen Zusammenhang gibt es zwischen Triggern und Views?

Übungsaufgaben

Für die folgenden Aufgaben sollen folgende Tabellen genutzt werden.

```
CREATE TABLE Kunde (
    KNR NUMBER(5),
    Vorname VARCHAR(10),
    Name VARCHAR(10) NOT NULL,
    Geschlecht VARCHAR(1),
    Land VARCHAR(3),
    PRIMARY KEY(KNR),
    CONSTRAINT Kunde1
        CHECK(Geschlecht IN ('M','W'))
);
CREATE TABLE Auftrag(
    KNR NUMBER(5),
    Datum DATE,
    Betrag NUMBER(7,2) NOT NULL,
    Mahnungsanzahl NUMBER(1) DEFAULT 0,
    Mahntermin DATE NOT NULL,
    PRIMARY KEY(KNR,Datum),
    CONSTRAINT Auftrag1 CHECK(Mahnungsanzahl<4),
    CONSTRAINT Auftrag2 FOREIGN KEY(KNR)
        REFERENCES Kunde(KNR)
);
CREATE TABLE Eintreiber(
    KNR NUMBER(5),
    Rechnungsdatum DATE,
    Uebergabetermin DATE,
    PRIMARY KEY(KNR,Rechnungsdatum)
);
```

Dabei soll ein Mahntermin in der Tabelle Auftrag den frühesten Termin angeben, zu dem die nächste Mahnung verschickt werden kann.

1. Schreiben Sie eine Prozedur `ein fuegen(Kundennummer, Vorname, Name, Geschlecht, Land)`, die einen Wert in die Tabelle Kunde einfügt. Was passiert, wenn Sie keinen oder einen ungültigen Wert für Geschlecht oder einen bereits vergebenen Schlüssel eingeben?
2. Schreiben Sie eine Prozedur `ein fuegen2(Vorname, Name, Geschlecht, Land)`, die einen Wert in die Tabelle Kunde einfügt. Dabei soll die Kundennummer automatisch berechnet werden (versuchen Sie es ohne SEQUENCE), überprüfen Sie vorher, ob es überhaupt

schon einen Tabelleneintrag gibt und reagieren Sie wenn nötig.

3. Schreiben Sie eine Prozedur `auftragEintragen`(Kundennummer,Betrag,Datum) mit der ein neuer Auftrag eingetragen wird. Der erste Mahntermin ist sieben Tage nach dem Verkauf. In Oracle erfolgt die Umwandlung eines VARCHAR vc in ein Datum mit `TO_DATE(vc)`, z.B. `TO_DATE('11.01.11')`. Bei einer Datumsvariable bedeutet +7 die Erhöhung um sieben Tage.
4. Schreiben Sie eine Prozedur `auftragEintragen2`(Name,Geschlecht,Betrag,Datum), mit der ein Auftrag für einen neuen Kunden eingetragen wird, es sind also mehrere Tabellen betroffen. Bedenken Sie, dass Prozeduren auch andere Prozeduren aufrufen können.
5. Schreiben Sie eine Funktion `anrede`(Kundennummer), die zu einer gegebenen Kundennummer, die "richtige" Anrede für einen Brief ausgibt. Die Anrede ist meist "Sehr geehrte Frau <Name>," oder "Sehr geehrter Herr <Name>," bei Chinesen wird weiterhin statt <Name> immer <Name> <Vorname> ausgegeben. Falls das Geschlecht nicht bekannt ist, lautet die Anrede "Sehr geehrte/r Kundin/Kunde,".

Zur Erinnerung: Strings werden in Oracle mit || verbunden.

Aufrufmöglichkeit für Funktionen:

```
SELECT anrede(101) FROM DUAL;
```

In PL/SQL gibt es den Datentyp `BOOLEAN`.

Sie dürfen selbstgeschriebene Prozeduren und Funktionen in anderen Aufgabenteilen nutzen.

6. Schreiben Sie eine PL/SQL-Prozedur, die mit Hilfe eines Cursors alle Kundennamen ausgibt.
7. Schreiben Sie eine Prozedur `auftragEintragen3`(Kundennummer,Betrag,Datum), mit der ein Auftrag für einen Kunden eingetragen wird und zusätzlich mit einer Fehlermeldung (`APPLICATION ERROR`) abbricht, wenn der Kunde schon vorher drei offene Aufträge hatte. (Ein Auftrag ist offen, solange er in der Tabelle Auftrag steht.)
8. Schreiben Sie einen Trigger, der garantiert, dass für Kunden, für die ein Eintrag in der Tabelle Eintreiber vorliegt, keine Aufträge angenommen werden.

9. Schreiben Sie einen Trigger, der bei dem Eintrag eines Auftrags eine Warnung ausgibt, falls für den Kunden eine Mahnung läuft.

Ergänzen Sie folgende Tabelle:

```
CREATE Table Kundenstatistik(  
    KNR NUMBER(5),  
    Gesamt NUMBER(7,2),  
    Skonto NUMBER,  
    PRIMARY KEY(KNR)  
);
```

10. Schreiben Sie einen Trigger, der beim Eintrag eines neuen Kunden automatisch einen Eintrag mit der KNR und den Werten 0 und 0 in der Tabelle Kundenstatistik anlegt.
11. Schreiben Sie einen Trigger, der bei jedem neuen Auftrag die Gesamtbestellsumme in Kundenstatistik für den Kunden erhöht und den Skontowert in Prozent berechnet. Der Skonto-Wert ergibt sich aus Gesamtbestellsumme/1000, darf aber 10 nicht überschreiten. Dieser Skontowert soll bereits beim ersten eingehenden Auftrag für den Kunden berücksichtigt werden (nicht für die Gesamtbestellsumme in der Kundenstatistik). Erfolgt z. B. eine erste Bestellung für 2000, dann muss der Kunde nur 1960 zahlen (1960 wird in Auftrag eingetragen, 2000 wird als Gesamtbestellsumme in der Kundenstatistik eingetragen). Der Skontobetrag (hier 40) soll außerdem vom Trigger als Text auf dem Bildschirm ausgegeben werden.

Würde der gleiche Kunde dann eine Bestellung von 3000 machen, wäre seine Gesamtbestellsumme aus der Spalte Gesamt 5000, was einen Skontowert von 5 ergibt. Der Kunde müsste dann nur $3000 - (5/100 * 3000) = 2850$ bezahlen, was auch in der Tabelle Auftrag so eingetragen wird.

Nachdem eine optimale Datenbank entwickelt wurde, wird diese typischerweise von anderer Software genutzt. Ausnahmen stellen Personen dar, die den Datenbestand direkt mit SQL-Anfragen analysieren.

embedded SQL

Damit die Applikationssoftware auf die Datenbank zugreifen kann, sind verschiedene Ansätze möglich. Ein Ansatz ist die Einbettung von SQL-Befehlen in die sonst genutzte Programmiersprache. Dabei muss definiert werden, in welchen Variablen der Programmiersprache die Anfrageergebnisse später zugreifbar sind. Der Compiler muss dann die Übersetzung der eingebetteten SQL-Befehle unterstützen, wobei meist diese Befehle zuerst übersetzt und dann mit dem restlichen Programm verlinkt werden.

DB-Hersteller muss JDBC realisieren

Eine Alternative stellt die Möglichkeit dar, aus der Programmiersprache mit Mitteln der Programmiersprache eine Verbindung zur Datenbank aufzubauen, so dass sich das Programm wie ein „normaler“ Datenbanknutzer verhalten kann, also Anfragen stellt, Tabellen ändert und über den Erfolg der Arbeitsschritte informiert wird. Dieser Weg wird in Java mit JDBC betreten. Java hat dazu eine eigene Klassenbibliothek bestehend aus Schnittstellenbeschreibungen, die zur Verwaltung von Datenbankverbindungen konzipiert wurde. Die Umsetzung dieser Konzepte ist allerdings die Aufgabe der Datenbankhersteller, so dass die Unterstützung von JDBC im Detail sehr unterschiedlich aussehen kann. Es gilt aber, dass, wenn eine vorgegebene Funktionalität realisiert wird, diese dann der im Java-Konzept beschriebenen Bedeutung folgt.

Zu JDBC sind schon einige Bücher geschrieben worden. Der Standard wird weiter entwickelt, 2006 liegt die Version 4 vor. Dabei wird in neuen Versionen die Funktionalität erweitert, allerdings bleiben die Basiskonzepte erhalten. Genau diese Basiskonzepte, mit denen man von Java aus systematisch mit einer Datenbank arbeiten kann, werden in diesem Kapitel vorgestellt. Bei größeren Projekten, die sich zentral um eine Datenbank gruppieren, sollte weitere Literatur zu JDBC und dessen Umset-

zung im jeweils verwendeten Datenbankmanagementsystem mit einbezogen werden.

Dieses Kapitel beschreibt schrittweise eine Möglichkeit zum Verbindungsaufbau, zum Stellen von Anfragen und zur weiteren Nutzung der Datenbank. Tiefgreifende Java-Kenntnisse werden nicht benötigt, grundlegende Erfahrungen in objektorientierter Programmierung sollten ausreichen.

13.1 Verbindungsaufbau

Zunächst muss man sich für die jeweilige Datenbank den passenden JDBC-Treiber besorgen, der üblicherweise von der Datenbank-Herstellerseite verfügbar ist. Der Datenbanktreiber muss geladen werden, wozu die Klasse `DriverManager` zur Verfügung steht. Der Befehl lautet

```
DriverManager.registerDriver(  
    new oracle.jdbc.driver.OracleDriver());
```

Zum Verbindungsaufbau werden folgende Informationen benötigt:

*Verbindungs-
aufbau: Dri-
verManager*

- genaue Bezeichnung des Treibers, der sich meist aus den Teilen `jdbc:<DBProtokollname>:<Protokollart>` zusammensetzt, wobei die `<Protokollart>` nicht immer angegeben werden muss
- genaue Bezeichnung der Datenbank-Instanz, wobei zu beachten ist, dass in einer Datenbank mehrere logische Datenbankinstanzen mit unterschiedlichen Namen existieren können
- die benutzte Port-Nummer der Datenbank, die Datenbank nutzt diesen Port als Server, um Verbindungen anzunehmen
- Nutzernamen
- Passwort

Nutzt man eine Oracle XE-Version auf dem eigenen lokalen Rechner, so lautet für den Treiber `ojdbc14.jar` die Bezeichnung `jdbc:oracle:thin`. In der XE-Version kann ohnehin nur eine Datenbank existieren, die automatisch den Namen XE erhält, Oracle nutzt standardmäßig den Port 1521.

Aus diesen Informationen kann der sogenannte Connection-String zusammengesetzt werden. In unserem Beispiel lautet er

```
"jdbc:oracle:thin:@127.0.0.1:1521:XE"
```

*Verbindung:
Connection*

Mit diesem String kann dann eine Verbindung zur Datenbank aufgebaut werden, die vom Typ Connection ist. Der Aufruf lautet

```
Connection con = DriverManager.getConnection(
    "jdbc:oracle:thin:@127.0.0.1:1521:XE",
    nutzer, password);
```

Dieses Objekt stellt die physikalische Verbindung zur Datenbank dar und kann von verschiedenen Objekten genutzt werden. Man kann das Objekt auch nutzen, um Meta-Informationen, z. B. über den Namen der Datenbank, ihre Version und ihr genaues Verhalten, abzufragen. Das Metaobjekt erhält man wie folgt.

```
DatabaseMetaData dbmd=con.getMetaData();
```

Generell ist es wichtig, dass nicht mehr benötigte Verbindungen geschlossen werden, um Ressourcen zu sparen. Wird das Schließen vergessen, so merkt man dies häufig nicht. Erst wenn mehrere Verbindungen offen bleiben, wird ein System langsamer oder kann nicht mehr genutzt werden, da immer nur eine beschränkte Zahl von Verbindungen zur Verfügung steht. Das Schließen geschieht mit

```
con.close();
```

Jede Datenbankaktion kann scheitern, da z. B. die Verbindung verloren wurde oder eine Aktion nicht ausführbar ist. In diesem Fall werden eine oder mehrere SQLExceptions erzeugt. Für diese Exceptions gibt es eine next()-Methode, um zu eventuell weiteren Exceptions zu kommen. Weiterhin gibt es Möglichkeiten, die Fehlerquelle genauer zu analysieren.

Die bisher vorgestellten Ideen werden jetzt in einer Beispielklasse zusammengefasst, die in diesem Kapitel um weitere Methoden ergänzt wird.

```
package dbverbindung;

import java.sql.Connection;
import java.sql.DatabaseMetaData;
import java.sql.DriverManager;
import java.sql.SQLException;

public class DBVerbindung {

    private Connection con=null;
    private String dbAdresse="127.0.0.1"; //localhost
    private String dbInstanz="XE"; //XE-Version

    public void verbinden(String nutzer, String password){
        try {
```

```

        DriverManager.registerDriver(
            new oracle.jdbc.driver.OracleDriver());
        con=DriverManager.
        getConnection("jdbc:oracle:thin:@"+dbAdresse
            +":1521:"+dbInstanz,nutzer,password);
    } catch (SQLException e) {
        ausnahmeAusgeben(e);
    }
}

private void ausnahmeAusgeben(SQLException e){
    while (e!=null){
        System.err.println("ORACLE Fehlercode: "+e.getErrorCode());
        System.err.println("SQL State: "+e.getSQLState());
        System.err.println(e);
        e=e.getNextException();
    }
}

public void verbindungTrennen(){
    if (con==null){
        System.out.println("eh keine Verbindung vorhanden");
        return;
    }
    try {
        con.close();
    } catch (SQLException e) {
        ausnahmeAusgeben(e);
    }
}

public void verbindungAnalysieren(){
    if (con==null){
        System.out.println("keine Verbindung vorhanden");
        return;
    }
    try {
        DatabaseMetaData dbmd=con.getMetaData();
        System.out.println("DB-Name: "+ dbmd.getDatabaseProductName()
            +"\nDB-Version: "+dbmd.getDatabaseMajorVersion()
            +"\nDB-Release: "+dbmd.getDriverMinorVersion()
            +"\nTransaktionen erlaubt: "+dbmd.supportsTransactions()
            +"\nbeachtet GroßKlein :"+dbmd.storesMixedCaseIdentifiers()
            +"\nunterstützt UNION :"+dbmd.supportsUnion()
            +"\nmax. Prozedurname: "+dbmd.getMaxProcedureNameLength());
    } catch (SQLException e) {
        ausnahmeAusgeben(e);
    }
}
}

```

```

public static void main(String[] s){
    DBVerbindung db=new DBVerbindung();
    db.verbinden("Kleuker","Kleuker");
    db.verbindungAnalysieren();
    db.verbindungTrennen();
}
}

```

Die Methode `verbindungAnalysieren()` zeigt einen sehr kleinen Ausschnitt aus den vorhandenen Metadaten, so kann man mit `storesMixedCaseIdentifiers()` feststellen, ob bei Tabellen und Spalten Groß- und Kleinschreibung unterschieden wird. Bei einer erfolgreichen Verbindung zur Datenbank kann die Ausgabe wie folgt aussehen.

```

DB-Name: Oracle
DB-Version: 10
DB-Release: 2
Transaktionen erlaubt: true
beachtet Großklein :false
unterstützt UNION :true
max. Prozedurname: 30

```

Weiterhin erlaubt das `Connection`-Objekt die Steuerung von Transaktionen. Dies geschieht durch die Aufrufe

```

con.commit();
con.rollback();

```

Man kann das sogenannte Autocommit mit

```

con.setAutoCommit(true);

```

*Autocommit per
default gesetzt*

einschalten oder mit dem Parameterwert `false` ausschalten. Die Nutzung von Autocommit ist wie nach den Diskussionen über die Transaktionssteuerung bekannt, nur in begründeten Ausnahmefällen sinnvoll einsetzbar. Trotzdem ist die Standardeinstellung bei Oracle der Wert `true`.

13.2

Anfragen über JDBC

Um eine Anfrage ausführen zu können, muss man sich zunächst ein `Statement`-Objekt von dem `Connection`-Objekt durch

*Anfrage: State-
ment*

```

Statement stmt=con.createStatement();

```

holen. Dieses `Statement`-Objekt kann u. a. zur Ausführung von Anfragen genutzt werden. Der zugehörige Aufruf lautet

```

ResultSet rs=stmt.executeQuery(anfrage);

```

Dabei muss anfrage vom Typ String sein. Dieser String sieht dann genauso aus, wie es bei der Erstellung von SQL-Anfragen diskutiert wurde. Da man Strings mit Stringoperationen flexibel zusammensetzen kann, können hier Anfragen aus Parametern zusammengesetzt werden. Der große Nachteil dieses Ansatzes ist, dass die Korrektheit der Anfrage erst bei der Ausführung des Programms festgestellt werden kann.

Das Ergebnis der Anfrage ist ein Objekt vom Typ ResultSet, das eng verwandt mit den im vorherigen Kapitel vorgestellten Cursor ist. Wieder kann das Ergebnis zeilenweise durchlaufen und verarbeitet werden.

Anfrageergebnis: ResultSet

Zur Analyse der grundsätzlichen Eigenschaften des ResultSets stehen wieder Metadaten zur Verfügung, die man mit

```
ResultSetMetaData rsmd= rs.getMetaData();
```

erhält. Man kann diese Metadaten u. a. danach befragen, aus wie vielen Spalten das Ergebnis besteht, welchen Typ und welchen Namen diese Spalten haben. Es ist standardmäßig nicht vorgesehen, dass man die Anzahl der berechneten Zeilen erhält, was aber auf später vorgestellten Umwegen möglich wird. Dieser Ansatz wird hier erwähnt, um den Lesern die Versuchung zu ersparen, das gesamte Anfrageergebnis in einem Array zu speichern. Dies sollte vermieden werden, da es häufig dazu führt, dass datenbankunerfahrene Entwickler die Funktionalität der Datenbank erneut für diese Arrays implementieren. So werden z. B. alle Tier-Informationen gelesen und dann das Array nach Bären durchsucht, statt dieses sofort in die SQL-Anfrage zu schreiben.

nie alle Daten zur Verarbeitung aus der Datenbank lesen

Das ResultSet wird wie ein Iterator durchlaufen, dabei springt das ResultSet mit rs.next() zur nächsten Zeile. Der Aufruf rs.next() muss am Anfang einmal erfolgen, damit die erste Zeile eingelesen wird. Wenn keine Zeile mehr eingelesen wurde, liefert der Aufruf rs.next() den Wert false, ansonsten true zurück.

Um auf die Inhalte der Spalten der aktuellen ResultSet-Zeile zugreifen zu können, stehen verschiedene get-Methoden zur Verfügung. Jede dieser Methoden benötigt als Parameter entweder die Spaltennummer oder den Namen der Spalte. Bei den Spaltennummern ist zu beachten, dass die Nummerierung mit eins und nicht wie der Informatik sonst üblich mit der Zahl null beginnt.

Es stehen für jeden Datenbank-Datentypen zugehörige Java-Typen zur Verfügung, wobei es im Detail, z. B. bei der Wertege-

Konvertierungsprobleme beachten

nauigkeit, Probleme geben kann. Wird ein nicht ganz passender Datentyp gewählt, findet im ResultSet automatisch eine Konvertierung statt. Zum Datentypen INTEGER der Datenbank gehört z.B. die Klasse `java.math.BigDecimal`, mit der auch sehr große Zahlen verwaltet werden können. Auf solchen Spalten ist aber auch der Aufruf `rs.getInt(spalte)` erfolgreich. Als allgemeinste Methode steht `rs.getObject(spalte)` zur Verfügung, wobei man das erhaltene Objekt später konvertieren muss. Eine häufig genutzte Variante ist das Einlesen beliebiger Werte mit `rs.getString(spalte)`, da jedes Objekt in Java durch seine `toString()`-Methode in einen String umwandelbar ist. Dieser String kann dann mit Java-Methoden analysiert werden.

Bei der Analyse der Ergebnisse muss beachtet werden, dass auch NULL-Werte in der Tabelle stehen können. Da z. B. eine `getInt()`-Methode immer einen int-Wert liefert, kann man nicht erkennen, ob die Zahl Null oder der Datenbankwert NULL gelesen wurde. Dazu kann man nach dem Lesen eines Wertes den Aufruf `rs.isNull()` nutzen, der genau dann `true` liefert, wenn bei der letzten Leseaktion ein NULL-Wert gelesen wurde.

Die vorgestellten Ideen werden in der folgenden Methode zusammengefasst, dabei werden die eingelesenen Daten immer als Strings angenommen, da jeder Datentyp in einen String konvertierbar ist.

```
public void anfragen(String anfrage){
    if (con==null){
        System.out.println("keine Verbindung");
        return;
    }
    try {
        Statement stmt=con.createStatement();
        ResultSet rs= stmt.executeQuery(anfrage);

        //Matadaten des Anfrageergebnisses
        ResultSetMetaData rsmd= rs.getMetaData();
        int spalten=rsmd.getColumnCount();
        for(int i=1;i<=spalten;i++) // nicht i=0
            System.out.println(i+". Spaltenname: "
                +rsmd.getColumnName(i)
                +"\n Spaltentyp: "
                +rsmd.getColumnTypeName(i)
                +"\n Javatyp: "
                +rsmd.getColumnClassName(i)+"\n");

        //Ergebnisausgabe
```

```
        while(rs.next()){
            for(int i=1;i<=spalten; i++){
                System.out.print(rs.getString(i)+" ");
                System.out.print("\n");
            }
        } catch (SQLException e) {
            ausnahmeAusgeben(e);
        }
    }
}
```

Die folgenden Zeilen im Hauptprogramm

```
String anfrage=
    "SELECT Tier.Tname, Tier.Gattung, Gehege.GNr,"
    +" Gehege.GName "
    +"FROM Gehege,Tier "
    +"WHERE Gehege.Gnr=Tier.Gnr "
    +" AND Tier.Gattung='Baer'";
db.anfragen(anfrage);
```

führen zu folgender Ausgabe.

```
1. Spaltenname: TNAME
   Spaltentyp: VARCHAR2
   Javatyp: java.lang.String

2. Spaltenname: GATTUNG
   Spaltentyp: VARCHAR2
   Javatyp: java.lang.String

3. Spaltenname: GNR
   Spaltentyp: NUMBER
   Javatyp: java.math.BigDecimal

4. Spaltenname: GNAME
   Spaltentyp: VARCHAR2
   Javatyp: java.lang.String
```

```
Sabber Baer 1 Wald
Laber Baer 1 Wald
Huber Baer 4 Heide
Sauber Baer 4 Heide
```

Falls man z. B. zwischen der SELECT-Zeile und der FROM Zeile das Leerzeichen vergisst, gibt das Programm folgende Fehlermeldung aus.

```
ORACLE Fehlercode: 923
SQL State: 42000
java.sql.SQLException: ORA-00923: Schlüsselwort
FROM nicht an erwarteter Stelle gefunden
```

Neben der vorgestellten Anfragemöglichkeit gibt es weitere Varianten Anfragen zu erstellen, die schneller ausgeführt werden können; dies passiert z. B. mit PreparedStatement-Objekten, wie im Unterkapitel 13.5 beschrieben wird.

13.3

Änderungen in Tabellen

Das vorherige Unterkapitel hat gezeigt, wie man Anfragen stellt und die Ergebnisse ausgibt. Unter bestimmten Umständen können ResultSets auch zur Änderung der Daten genutzt werden. Dazu muss man ResultSet-Objekte so konfigurieren, dass sie veränderbar sind, so dass man an der aktuellen Cursor-Position Daten ändern, Zeilen ergänzen und Zeilen löschen kann. Dabei werden alle Konsistenzregeln der Datenbank beachtet und nicht ausführbare Aktionen mit einer SQLException beantwortet.

änderbare ResultSets

Damit ein ResultSet veränderbar ist, muss es zunächst möglich sein, aus dem Ergebnis der Anfrage auf die ursprünglichen Tabellen schließen zu können. Dieses Problem ist bereits bei den Änderungsmöglichkeiten für Views diskutiert worden. Konkret bedeutet dies, dass sich die Anfrage nur auf genau eine Tabelle beziehen darf. Weiterhin ist kein „SELECT *“ erlaubt, es müssen alle Spalten genannt werden.

Um dann änderbare Anfrageergebnisse zu erhalten, müssen bei der Erzeugung der Statement-Objekte zwei Parameter bei

```
Statement stmt=con.createStatement(<int>,<int>);
```

übergeben werden. Der erste Parameter gibt an, wie das ResultSet abgearbeitet wird. Es gibt u. a. folgende globale Klassenvariablen für den ersten Parameter.

TYPE_FORWARD_ONLY: ResultSet wird sequenziell durchlaufen

TYPE_SCROLL_INSENSITIVE: es kann beliebig im ResultSet manövriert werden, Änderungen in der Datenbank am ursprünglich berechneten Ergebnis werden nicht bemerkt

TYPE_SCROLL_SENSITIVE: es kann beliebig im ResultSet manövriert werden, Änderungen in der Datenbank am ursprünglich berechneten Ergebnis werden bemerkt

Für den zweiten Parameter gibt es folgende globale Klassenvariablen in ResultSet.

CONCUR_READ_ONLY: es wird nur im ResultSet gelesen

CONCUR_UPDATABLE: ResultSet kann bearbeitet werden

Man beachte, dass nicht unbedingt alle Parameter vom jeweiligen Datenbanktreiber in der jeweiligen JDBC-Realisierung unterstützt werden.

Hat man ein veränderbares `ResultSet`, stehen `update`-Methoden zum Ändern der Spaltenwerte zur Verfügung. Dabei müssen immer zwei Parameter angegeben werden, die genaue Spalte und der neue Wert. So verändert `rs.updateString("Name", "Heinz")`, den Wert in der Spalte „Name“ in der aktuellen Position des `ResultSet`s auf den Wert „Heinz“. Die `String`-Methode ist wieder recht flexibel, da so die Umwandlung des Wertes in den passenden Datentyp dem Treiber überlassen wird. Präziser kann man z. B., mit `rs.updateInt(2, 42)` den Wert der zweiten Spalte, die von einem ganzzahligen Typ sein muss, auf 42 abändern.

Zur Übernahme der Änderungen in die Datenbank muss die Methode `rs.updateRow()` genutzt werden. Ob diese Änderung nur das `ResultSet` oder letztendlich die Datenbank betrifft, hängt von der `Autocommit`-Einstellung der Datenbank ab. Änderungen können vor einem `updateRow()` mit dem Methodenaufruf `rs.cancelRowUpdates()` zurückgesetzt werden.

Methode	Bedeutung
<code>boolean next()</code>	geht zum nächsten Datensatz
<code>boolean previous()</code>	geht zum vorherigen Datensatz
<code>void beforeFirst()</code>	positioniert <code>ResultSet</code> vor dem ersten Ergebnis
<code>void afterLast()</code>	positioniert <code>ResultSet</code> nach dem letzten Ergebnis
<code>boolean first()</code>	positioniert <code>ResultSet</code> auf das erste Ergebnis
<code>boolean last()</code>	positioniert <code>ResultSet</code> auf das letzte Ergebnis
<code>boolean absolute(int pos)</code>	positioniert <code>ResultSet</code> bei positivem <code>pos</code> auf die <code>pos</code> -te Ergebniszeile, bei negativem <code>pos</code> auf die <code>pos</code> -te Zeile vom letzten Ergebnis an rückwärts gezählt
<code>boolean relative(int pos)</code>	positioniert <code>ResultSet</code> bei positivem <code>pos</code> auf die <code>pos</code> -te folgende Zeile, bei negativem <code>pos</code> wird <code>pos</code> -Zeilen von der aktuellen Position rückwärts gegangen
<code>int getRow()</code>	gibt die aktuelle Nummer der Ergebniszeile an

Abb. 13.1: Befehle zur Steuerung im `ResultSet`

Damit man im `ResultSet` verschiedene Zeilen direkt ansteuern kann, stehen die in Abb. 13.1 beschriebenen Methoden zur Ver-

fügung, dabei geben Boolesche Ergebniswerte immer an, ob die angesprungene Zeile existiert.

In einem veränderbaren ResultSet kann mit

```
rs.deleteRow()
```

die aktuelle Zeile gelöscht werden. Weiterhin steht eine spezielle zusätzliche virtuelle Zeile zur Verfügung, in der man neue Zeileinträge konstruieren kann. Diese Zeile wird mit

```
rs.moveToInsertRow()
```

*neue Zeilen
einfügen*

erreicht, in der dann die bereits erwähnten update-Methoden genutzt werden können. Die Zeile wird mit

```
rs.insertRow()
```

in die Datenbank geschrieben. Mit der Methode

```
rs.MoveToCurrentRow()
```

kann man von der zusätzlichen Zeile wieder zurück an die ursprüngliche Position des ResultSets kehren.

Die folgenden Methoden zeigen Beispiele zur Nutzung der vorgestellten Methoden, dabei werden mit der einen Methode alle Gehege um x Einheiten verändert und mit der anderen ein neues Gehege angelegt. Für diese Methoden sei auch auf das folgende Unterkapitel hingewiesen, da man auch von Java aus direkt UPDATE- und INSERT-Befehle ausführen kann.

```
public void gehegegroesseAendern(int x){
    if (con==null){
        System.out.println("keine Verbindung");
        return;
    }
    try {
        Statement stmt=con.createStatement(
            ResultSet.TYPE_SCROLL_INSENSITIVE,
            ResultSet.CONCUR_UPDATABLE);
        ResultSet rs= stmt.executeQuery(
            "SELECT Gehege.Gnr, Gehege.Flaeche "
            +"FROM Gehege");
        while(rs.next()){
            rs.updateInt(2,rs.getInt(2)+x);
            rs.updateRow();
        }
    } catch (SQLException e) {
        ausnahmeAusgeben(e);
    }
}
```

```
public void gehegeErgaenzen(int nummer,
                             String name, int flaeche){
    if (con==null){
        System.out.println("keine Verbindung");
        return;
    }
    try {
        Statement stmt=con.createStatement(
            ResultSet.TYPE_SCROLL_INSENSITIVE,
            ResultSet.CONCUR_UPDATABLE);
        ResultSet rs=stmt.executeQuery(
            "SELECT Gehege.Gnr, Gehege.Flaeche, "
            +"Gehege.GName "
            +"FROM Gehege");
        rs.moveToInsertRow();
        rs.updateInt("Gnr",nummer);
        rs.updateInt("Flaeche",flaeche);
        rs.updateString("GName",name);
        rs.insertRow();
    } catch (SQLException e) {
        ausnahmeAusgeben(e);
    }
}
```

Die folgenden Aufrufe in der main()-Methode

```
String anfrage2="SELECT * FROM Gehege";
db.anfragen(anfrage2);
db.gehegegrosesseAendern(10);
db.gehegeErgaenzen(42,"Wüste",15);
db.anfragen(anfrage2);
```

liefern folgende relevante Ausgaben.

```
1 Wald 30
2 Feld 20
3 Weide 15
4 Heide 80
5 Halle 50

1 Wald 40
2 Feld 30
3 Weide 25
42 Wüste 15
4 Heide 90
5 Halle 60
```

13.4

Weitere SQL-Befehle in JDBC

Insofern man die Berechtigung hat, kann man mit Statement-Objekten nicht nur Anfragen ausführen und ihre Ergebnisse bearbeiten, man kann auch weitere SQL-Befehle ausführen. Dafür steht für ein Statement-Objekt stmt die Methode

```
stmt.executeUpdate(<Befehl>)
```

Ausführung beliebiger SQL-Befehle

zur Verfügung, wobei es sich bei <Befehl> um einen gewöhnlichen SQL-Befehl in der Form eines Strings handelt. Die folgende Methode zeigt, wie man eine Tabelle anlegen kann, deren Spaltennamen sich aus dem übergebenen Array ergeben und die alle den Typ INTEGER haben. Weiterhin wird diese Tabelle mit Zufallszahlen zwischen 0 und 100 gefüllt. Die Anzahl der Zeilen wird als Parameter übergeben.

```
public void neueTabelle(String name,
                        String[] spalten, int zeilen){
    if (con==null){
        System.out.println("keine Verbindung");
        return;
    }
    try {
        Statement stmt=con.createStatement();

        StringBuffer sb=
            new StringBuffer("CREATE TABLE ");
        sb.append(name);
        sb.append("(");
        for(int i=0;i<spalten.length-1;i++){
            sb.append(spalten[i]);
            sb.append(" INTEGER,");
        }
        sb.append(spalten[spalten.length-1]);
        sb.append(" INTEGER)");
        System.out.println(sb); // zur Info
        stmt.executeUpdate(sb.toString());

        for(int i=0;i<zeilen;i++){
            StringBuffer in=
                new StringBuffer("INSERT INTO ");
            in.append(name);
            in.append(" VALUES(");
            for(int j=0;j<spalten.length-1;j++){
                in.append((int) (Math.random()*100));
                in.append(",");
            }
            in.append((int) (Math.random()*100));
            in.append(")");
        }
    }
}
```

```
        System.out.println(in); // zur Info
        stmt.executeUpdate(in.toString());
    }
    con.commit();
} catch (SQLException e) {
    ausnahmeAusgeben(e);
}
}
```

Die folgenden Zeilen in der main()-Methode

```
String spalten[]={"A","B","C","D","E"};
db.neueTabelle("XY",spalten,4);
db.anfragen("SELECT * FROM XY");
```

führen zu folgender Ausgabe.

```
CREATE TABLE XY(A INTEGER,B INTEGER,C INTEGER,D
INTEGER,E INTEGER)
INSERT INTO XY VALUES(60,27,43,24,77)
INSERT INTO XY VALUES(27,69,30,34,47)
INSERT INTO XY VALUES(3,55,55,25,35)
INSERT INTO XY VALUES(0,34,55,76,24)
60 27 43 24 77
27 69 30 34 47
3 55 55 25 35
0 34 55 76 24
```

13.5 Vorbereitete SQL-Befehle

Bei den bisher ausgeführten SQL-Befehlen ist es immer der Fall, dass der Befehl als String übergeben wird. Dieser Ansatz ist ziemlich flexibel, da man diesen String vorher berechnen und damit individuell zusammensetzen kann. Neben der Gefahr, dass ein falscher SQL-Befehl übergeben wird, besteht aber auch das Problem, dass der Befehl wieder vollständig neu von der Datenbank bearbeitet werden muss. Hier bietet JDBC eine Optimierungsmöglichkeit; man kann einen SQL-Befehl an die Datenbank überreichen, indem man einzelne Werte offen lässt, die dann zur konkreten Ausführung übergeben werden. Dazu werden PreparedStatement-Objekte genutzt. Die Erzeugung eines solchen Befehls sieht wie folgt aus, dabei können die Parameter, die die spätere Änderung des Ergebnisses erlauben, bei preparedStatement auch genutzt werden.

*vordefinierte
Befehle: PreparedStatement*

```
PreparedStatement prep=con.prepareStatement(
    "SELECT Tier.Tname"
    + " FROM Tier"
    + " WHERE Tier.Gattung=? AND Tier.Gnr=?");
```

Man erkennt, dass ein „normaler“ SQL-Befehl genutzt wird und an den Stellen, an denen man Werte ändern möchte, Fragezeichen gesetzt werden. Dadurch, dass die Datenbank die Grundstruktur des Befehls kennt, kann die Anfrage grundsätzlich vorbereitet werden. Dies geht natürlich nur, wenn die Anfragestruktur überhaupt erkennbar ist, so ist ein String, der nur aus Fragezeichen besteht, theoretisch möglich, lässt aber kaum sinnvolle Möglichkeiten zur Vorbereitung der Befehlsausführung zu.

Um den Befehl zu nutzen, müssen den Fragezeichen Werte zugeordnet werden. Dazu werden die Fragezeichen von links nach rechts mit eins beginnend durchnummeriert. Diese Parameter können dann mit set-Methoden belegt werden, wobei durch die Wahl der set-Methode deutlich wird, um welchen Typen es sich bei den Parametern handelt.

```
prep.setString(1, "Baer");  
prep.setInt(2, 3);
```

Prepared Statements werden genau wie andere Befehle ausgeführt, es stehen z. B. die Methoden `executeQuery()`, `execute()` und `executeUpdate()` zur Verfügung.

Im folgenden Beispiel wird davon ausgegangen, dass es folgende Exemplarvariable gibt.

```
private PreparedStatement prepared;
```

Die Exemplarvariable wird durch folgende Methode verändert.

```
public void statementVorbereiten(String anfrage){  
    if (con==null){  
        System.out.println("keine Verbindung");  
        return;  
    }  
    try {  
        prepared=con.prepareStatement(anfrage);  
    } catch (SQLException e) {  
        ausnahmeAusgeben(e);  
    }  
}
```

Die folgende Methode erlaubt die flexible Nutzung eines vorbereiteten Statements.

```
public void tiereInGehege(String gattung,  
                           int gehege){  
    if (con==null){  
        System.out.println("keine Verbindung");  
        return;  
    }  
}
```

```
    }
    try {
        prepared.setString(1,gattung);
        prepared.setInt(2,gehege);
        ResultSet rs=prepared.executeQuery();
        System.out.print("[ ");

        for(;rs.next();){
            System.out.print(rs.getString(1)+" ");
            System.out.println("]");
        } catch (SQLException e) {
            ausnahmeAusgeben(e);
        }
    }
}
```

Die folgenden Aufrufe z. B. in der main-Methode

```
db.statementVorbereiten(
    "SELECT Tier.Tname"
    + " FROM Tier"
    + " WHERE Tier.Gattung=? AND Tier.Gnr=?");
db.tiereInGehege("Schaf",2);
db.tiereInGehege("Schaf",3);
```

liefern dann folgende Ergebnisse.

```
[ Harald ]
[ Walter Dörthe ]
```

13.6 PL/SQL mit JDBC nutzen

Stored Procedures und Funktionen können ebenfalls von JDBC ausgenutzt werden. Dabei wird die Idee vom PreparedStatement aufgegriffen und Parameter zur Ein- und Ausgabe mit Fragezeichen in einem String markiert. Zusätzlich muss für diese Parameter der Typ festgelegt werden.

Als Beispiel wird eine Funktion genutzt, die für eine Gattung zählt, wie viele Tiere es davon gibt. Diese Funktion kann auch direkt über JDBC in die Datenbank geschrieben werden. Dies erfolgt beispielhaft mit folgender Methode, wobei es eher ungewöhnlich ist, dieses mit einer Exemplarmethode zu machen. Als Besonderheit weigert sich die Funktion, Hasen zu zählen.

*Stored Procedure
mit JDBC an-
legen*

```
public void plSQLFunktionAnlegen() {
    if (con==null){
        System.out.println("keine Verbindung");
        return;
    }
    try {
```

```

Statement stmt=con.createStatement();
stmt.executeUpdate(
    "CREATE OR REPLACE FUNCTION "
    + "  anzahlTiere(g Tier.Gattung%TYPE) "
    + "RETURN INTEGER "
    + "IS "
    + "  ergebnis INTEGER; "
    + "BEGIN"
    + "  IF g='Hase'"
    + "  THEN "
    + "      RAISE_APPLICATION_ERROR(-20300,"
    + "      'Hasen nicht zählbar');"
    + "  END IF;"
    + "  SELECT COUNT(*) "
    + "    INTO ergebnis"
    + "    FROM Tier"
    + "    WHERE Tier.Gattung=g;"
    + "  RETURN ergebnis;"
    + "END;\n"
);
} catch (SQLException e) {
    ausnahmeAusgeben(e);
}
}

```

Zum Aufruf der Funktion wird ein CallableStatement-Objekt benötigt. Dabei wird dieses Objekt analog zum PreparedStatement erzeugt, wobei der zu nutzende Aufruf mit prepareCall übergeben wird. Die Einbettung der Nutzung der Funktion ist in folgender Methode beschrieben.

```

public int tiereZaehlen(String gattung){
    int ergebnis=0;
    if (con==null){
        System.out.println("keine Verbindung");
        return 0;
    }
    try {
        CallableStatement stmt=con.prepareCall(
            "{? = call anzahlTiere(?)}" );
        stmt.registerOutParameter(1,Types.INTEGER);
        stmt.setString(2,gattung);
        stmt.execute();
        ergebnis=stmt.getInt(1);
    } catch (SQLException e) {
        if (e.getErrorCode()==20300)
            ergebnis=-1;
        else{
            ausnahmeAusgeben(e);
        }
    }
}

```



```
        ergebnis=Integer.MIN_VALUE;
    }
}
return ergebnis;
}
```

Die Methode zeigt, dass der Aufruf vergleichbar zum PreparedStatement erfolgt. Dabei wird hier die Standardschreibweise von JDBC zum Aufruf genutzt. Alternativ hätte man auch folgenden Befehl nutzen können.

```
CallableStatement stmt=con.prepareCall(
    "BEGIN ? := anzahlTiere(?); END;");
```

Bei der Nutzung des Standards sind die geschweiften Klammern und das kleinzuschreibende „call“ zu beachten. Werden Stored Procedures aufgerufen, wird die Zuweisung, hier „? =“, weggelassen.

Stored Procedures mit JDBC ausführen

Für Parameter, die zurückgegeben werden, ist der Typ mit `registerOutParameter()` anzugeben. Die Typen sind als Konstanten in `java.sql.Types` festgelegt. Dabei existieren die Werte: `ARRAY`, `BIGINT`, `BINARY`, `BIT`, `BLOB`, `BOOLEAN`, `CHAR`, `CLOB`, `DATALINK`, `DATE`, `DECIMAL`, `DISTINCT`, `FLOAT`, `INTEGER`, `JAVA_OBJECT`, `LONGVARBINARY`, `LONGVARCHAR`, `NULL`, `NUMERIC`, `OTHER`, `REAL`, `REF`, `SMALLINT`, `STRUCT`, `TIME`, `TIMESTAMP`, `TINYINT`, `VARBINARY`, `VARCHAR`. Ob diese Typen von der jeweiligen Datenbank unterstützt werden und wie Typen der Datenbank auf diese Typen abgebildet werden, kann leicht variieren. Für datenbankspezifische Typen steht u. a. `OTHER` zur Verfügung, wobei Objekte dann durch Casten in den passenden Typ umgewandelt werden können. Der Typ `REF` ermöglicht es, Referenzen zurückzugeben, so können z. B. Referenzen (oder auch Zeiger genannt) auf einen Cursor das Ergebnis einer PL/SQL-Prozedur sein. Man kann dann über Java mit einem `ResultSet` auf die Ergebnisse des Cursors zugreifen.

In der vorgestellten Methode wird auch eine Möglichkeit gezeigt, wie man systematisch auf Fehlermeldungen der Datenbank reagieren kann. Dazu wird der Fehlercode aus der `SQLException` herausgelesen und verarbeitet. Man beachte dabei, dass in der PL/SQL-Prozedur der Wert `-20300` genutzt wird, dieser aber als positiver Wert `20300` in der `SQLException` steht.

Werden die folgenden Zeilen in einem Hauptprogramm ausgeführt,

```
db.plSQLFunktionAnlegen();
System.out.println("Bären: "+db.tiereZaehlen("Baer"));
System.out.println("Hasen: "+db.tiereZaehlen("Hase"));
```

so werden folgende Ergebnisse ausgegeben.

```
Bären: 4
Hasen: -1
```

Cursor zurück- geben

Mit einem vergleichbaren Ansatz ist es auch möglich, statt einzelner Werte eine Menge von Werten als Ergebnis zuliefern. Dabei wird wieder der Ansatz mit dem Cursor benutzt. Weiterhin muss der Cursor dann als „IN OUT“-Parameter gekennzeichnet werden. Hier wird später ein spezielles Java-Objekt übergeben, das nach dem Aufruf eine Referenz auf das Ergebnis enthält. Eine Prozedur, die solch einen speziellen Cursor vom Typ SYS_REFCURSOR zurückgibt, ist in folgender Java-Methode enthalten, man erkennt, dass der zugehörige Cursor in der Prozedur nur geöffnet wird.

```
public void plSQLProzedurAnlegen() {
    if (con == null) {
        System.out.println("keine Verbindung");
        return;
    }
    try {
        Statement stmt = con.createStatement();
        stmt.executeUpdate("CREATE OR REPLACE "
            + "PROCEDURE ALLETIEREEINERGATTUNG("
            + "    g IN Tier.Gattung%TYPE,"
            + "    tiercursor IN OUT SYS_REFCURSOR) IS "
            + "BEGIN"
            + "    OPEN tiercursor FOR"
            + "        SELECT Tier.TNAME, Gehege.GNAME"
            + "        FROM Tier, Gehege"
            + "        WHERE Tier.GNR=Gehege.GNR"
            + "        AND Tier.GATTUNG=g;"
            + "END;\n");
    } catch (SQLException e) {
        ausnahmeAusgeben(e);
    }
}
```

Die Prozedur wird vergleichbar zum Prepared Statement genutzt. Man muss für den Cursor nur definieren, von welchem Typ dieses Ergebnis sein soll. Danach kann man den Cursor als normales ResultSet über die Methode getObject aus dem Ergebnis herauslesen. Eine mögliche Nutzung der letzten Prozedur kann dann in Java wie folgt aussehen.

```
public void tiereEinerGattungAnzeigen(String gattung){
    if (con==null){
        System.out.println("keine Verbindung");
        return;
    }
    try {
        System.out.println("Tiere der Gattung "
            +gattung+":");
        CallableStatement cstmt=con.prepareCall(
            "{CALL AlleTiereEinerGattung(?,?)}");
        cstmt.setString(1,gattung);
        cstmt.registerOutParameter(2,OracleTypes.CURSOR);
        cstmt.execute();
        ResultSet rset=(ResultSet) cstmt.getObject(2);
        while(rset.next()){
            System.out.println(rset.getString(1)+" in Gehege "
                +rset.getString(2));
        } catch (SQLException e) {
            ausnahmeAusgeben(e);
        }
    }
}
```

Werden folgende Zeilen im Hauptprogramm ausgeführt,

```
db.plSQLProzedurAnlegen();
db.tiereEinerGattungAnzeigen("Hase");
db.tiereEinerGattungAnzeigen("Elch");
db.tiereEinerGattungAnzeigen("Baer");
```

so werden folgende Ergebnisse ausgegeben.

```
Tiere der Gattung Hase:
Hunny in Gehege Feld
Runny in Gehege Feld
Klopfer in Gehege Feld
Bunny in Gehege Weide
Tiere der Gattung Elch:
Tiere der Gattung Baer:
Sabber in Gehege Wald
Laber in Gehege Wald
Huber in Gehege Heide
Saubert in Gehege Heide
```

Abschließend sei angemerkt, dass der resultierende Cursor von Java aus nicht zur Veränderung der Datensätze genutzt werden kann. Dies gilt auch, wenn die Verbindung beschreibbar ist und sich der Cursor nur auf eine Tabelle bezieht. Dies ist allerdings einer der Bereiche, der sich in nachfolgenden JDBC-Realisierungen ändern kann.

13.7**Aufgaben****Wiederholungsfragen**

Versuchen Sie zur Wiederholung folgende Aufgaben aus dem Kopf, d. h. ohne nochmaliges Blättern und Lesen zu bearbeiten.

1. Warum besteht der JDBC-Standard im Wesentlichen aus Interfaces?
2. Wie wird eine Datenbankverbindung mit JDBC aufgebaut?
3. Was versteht man unter Meta-Daten einer Verbindung und eines ResultSets?
4. Welche Aufgaben erfüllt ein Connection-Objekt?
5. Wie kann eine Anfrage ausgeführt und ihr Ergebnis analysiert werden?
6. Warum muss das Exception-Handling bei der Datenbanknutzung immer sauber programmiert werden?
7. Wie kann man mit JDBC Datensätze verändern?
8. Wie kann man mit JDBC beliebige SQL-Befehle ausführen?
9. Wozu sind PreparedStatement-Objekte hilfreich?
10. Welche Probleme entstehen, da fast alle Informationen als Strings an die Datenbank weitergeleitet werden?
11. Wie kann man Stored Procedures und Funktionen von JDBC aus ausführen?

Übungsaufgaben

1. Schreiben Sie ein Programm, mit dem sich ein Nutzer an der Datenbank anmelden und dann SQL-Anfragen abschicken kann, die dann beantwortet werden (reiner Textmodus). Etwaige Fehlermeldungen (SQLExceptions) sollen ausgegeben werden. Eine Formatierung der Ausgabe ist nicht notwendig. Ein Beispieldialog sieht wie folgt aus, Eingaben sind umrandet.

```
Login: kleuker
Passwort: kleuker
SELECT-Befehl eingeben [ohne Return]
(Ende mit "ende")
SELECT * FROM Gehehge
```

```
Meldung: ORA-00942: Tabelle oder View  
nicht vorhanden  
ORACLE Fehlercode: 942  
SQL State: 42000
```

```
SELECT-Befehl eingeben [ohne Return]  
(Ende mit "ende")
```

```
SELECT * FROM Gehege
```

GNr	Gname	Flaeche
1	Wald	30
2	Feld	20
3	Weide	15

```
SELECT-Befehl eingeben [ohne Return]  
(Ende mit "ende")
```

```
ENDE
```

2. Prüfen Sie genau, wie sich Ihr Programm aus Aufgabe 1 verhält, wenn Sie in Ihrem Programm CREATE TABLE, INSERT, UPDATE, DELETE und DROP TABLE als syntaktisch korrekte Befehle eingeben. Dokumentieren Sie Ihre Beobachtungen.

*Rückblick auf
Entwicklungsweg*

In diesem Buch wurde der klassische Weg der Datenbankentwicklung beschrieben. Es wurde gezeigt, dass die Anforderungen, welche Daten betrachtet werden müssen, im intensiven Dialog mit den Nutzern des resultierenden Systems ermittelt werden. Das erhaltene Modell kann dann automatisch in Tabellenstrukturen übersetzt werden, wobei für die resultierenden Tabellen geprüft werden muss, dass sie gewisse Qualitätseigenschaften haben. Diese Eigenschaften wurden in Normalformen formalisiert. Nachdem die Tabellen und Daten in die Datenbank eingetragen wurden, können die enthaltenen Informationen in Anfragen verknüpft werden. Ein detailliertes Verständnis von der Erstellung von SQL-Anfragen ist die Grundlage einer effektiven Datenbanknutzung. Bei der Nutzung ist weiterhin zu beachten, dass ein Datenbankmanagementsystem die komplexen Probleme, die auftreten können, wenn mehrere Nutzer gleichzeitig die Datenbank nutzen, zum großen Teil selber lösen kann, aber beim Nutzer hierfür trotzdem ein Grundverständnis vorhanden sein muss. Zusätzlich wurde für die resultierenden Systeme gezeigt, dass es sinnvoll ist, ein Rechtemanagement aufzusetzen und die Datenbank vor illegalen oder nur irrtümlichen Aktionen zu schützen. Abschließend wurde gezeigt, wie die Funktionalität eines Datenbanksystems erweitert werden kann. Dazu besteht innerhalb des Systems die Möglichkeit mit Stored Procedures und Triggern, sowie außerhalb des Systems von beliebigen Programmiersprachen, als Beispiel Java, auf die Datenbank zuzugreifen und z. B. eine graphische Oberfläche zu ergänzen.

*Verknüpfung
einer Datenbank
mit weiterer
Software*

Das in diesem Buch vermittelte Wissen reicht aus, um erfolgreich in großen Datenbankprojekten mitzuarbeiten und praktisch Erlerntes mit der Theorie zu verknüpfen. Trotzdem handelt es sich bei diesem Buch nur um einen Grundkurs, in dem Grundlagen gelegt werden, da in großen Projekten nicht nur über eine Datenbankentwicklung, sondern auch über das Zusammenspiel mit einem zu entwickelnden Software-System nachgedacht werden muss.

Abhängig von der Situation, ob eine gegebene Datenbank in eine Software eingebettet werden muss oder eine neue Datenbank

Neuentwicklung einer Datenbank in einem Software-Projekt

parallel zur Software entwickelt wird, gibt es hierzu viele weiterführende Ansätze. Soll auf eine existierende Datenbank zugegriffen werden, gibt es für jede bekanntere Programmiersprache Möglichkeiten, auf die Datenbank zuzugreifen. Bei diesem Zugriff spielt es meist eine besondere Rolle, möglichst präzise SQL-Anfragen zu stellen, die sofort die gewünschte Lösung berechnen. Eine Verarbeitung ungenauer Anfrageergebnisse kann die Rechenzeit der Software, die die Datenbank nutzt, wesentlich erhöhen.

Wird eine Datenbank zusammen mit neuer Software entwickelt, gibt es noch mehr Lösungsansätze, die zum Start eines Projektes evaluiert werden sollten. Eine Möglichkeit besteht darin, die Datenbank fast getrennt von der restlichen Software zu entwickeln und dann den im vorigen Absatz erwähnten Ansatz zur Nutzung der Datenbank in der Software zu wählen. In den meisten Projekten wird aber eine möglichst gleichzeitige Entwicklung der Datenbank und der umgebenden Software angestrebt. Hier gibt es abhängig von der verwendeten Programmiersprache und weiteren Randbedingungen Ansätze, bei denen die Datenbank „nebenbei“ entwickelt wird. Dies ist dann möglich, wenn bei der Software-Entwicklung eine sorgfältige Datenmodellierung durchgeführt wurde und ein mächtiges Framework die Verwaltung der Daten übernimmt. JEE [Mer04] mit der JPA (Java Persistence API) und Dot-Net [VOJ02] sind Beispiele für solche Frameworks.

Die letzten Absätze sollen nur andeuten, dass es sich beim Thema Datenbanken um ein spannendes Thema handelt, dessen Fundamente in diesem Buch vorgestellt wurden, das sich aber mit neuen Technologien immer weiter entwickelt.

Literaturverzeichnis

- [Bal00] H. Balzert, Lehrbuch der Software-Technik, Band 1: Software-Entwicklung, 2. Auflage, Spektrum Akademischer Verlag, Heidelberg Berlin Oxford, 2000
- [Bec00] K. Beck, Extreme Programming, Addison-Wesley, München, 2000
- [Che76] P. Chen, The Entity-Relationship Model – Toward a Unified View of Data, in: ACM Transactions on Database Systems, Band 1, Nr. 1, Seiten 9-36, 1976
- [Dat00] C.J. Date, Great News, The Relational Model Is Very Much Alive, <http://www.dbdebunk.com>, August 2000
- [Dat04] C.J. Date, An Introduction to Database Systems, 8. Ausgabe, Addison Wesley, USA, 2004
- [DL03] T. DeMarco, T. Lister, Bärenango – Mit Risikomanagement Projekte zum Erfolg führen, Hanser, München Wien, 2003
- [EMS00] H. Eirund, B. Müller, G. Schreiber, Formale Beschreibungsverfahren der Informatik, Teubner, Wiesbaden, 2000
- [Gad03] A. Gadatsch, Grundkurs Geschäftsprozess-Management, 3. Auflage, Vieweg, Wiesbaden, 2003
- [HS00] A. Heuer, G. Saake, Datenbanken: Konzepte und Sprachen, 2.Auflage, MITP, Bonn, 2000
- [Jar03] H. Jarosch, Grundkurs Datenbankentwurf, 2. Auflage, Vieweg, Wiesbaden, 2003
- [KE04] A. Kemper, A. Eickler, Datenbanksysteme, 5. Auflage, Oldenbourg, München, 2004
- [Kru04] P. Kruchten, The Rational Unified Process, 2. Auflage, Addison-Wesley, USA, 2004
- [Mer04] E. Merker, Grundkurs Java-Technologien, Vieweg, Wiesbaden, 2004
- [Oes04] B. Oestereich, Analyse und Design mit UML 2, 7. Auflage, Oldenbourg, München, 2004
- [OWS03] B. Oestereich, C. Weiss, C. Schröder, T. Weilkiens, A. Lenhard, Objektorientierte Geschäftsprozessmodellierung mit der UML, dpunkt, Heidelberg, 2003
- [RC02] M.B. Rosson, J.M. Carrol, Usability Engineering, Morgan Kaufmann, USA, 2002

- [Rup02] C. Rupp, SOPHIST GROUP, Requirements-Engineering und -Management, 2. Auflage, Hanser, München Wien, 2002
- [Sch04] U. Schöning, Logik für Informatiker, 5. Auflage, Spektrum Akademischer Verlag, Heidelberg Berlin Oxford, 2004
- [Schu04] M. Schubert, Datenbanken: Theorie, Entwurf und Programmierung relationaler Datenbanken, Teubner, Wiesbaden, 2003
- [SH99] G. Saake, A. Heuer, Datenbanken: Implementierungstechniken, MITP, Bonn, 1999
- [SP05] B. Shneiderman, C. Plaisant, Designing The User Interface, 4. Auflage, Addison-Wesley, USA, 2005
- [Tür03] C. Türker, SQL:1999 & SQL:2003, dpunkt, Heidelberg, 2003
- [VM05] <http://www.kbst.bund.de/-,279/V-Modell.htm>, Das neue V-Modell® XT - Der Entwicklungsstandard für IT-Systeme des Bundes, Stand Juni 2005
- [VOJ02] C.F. Vasters, A. Oellers, B. Javidi, J.M. Freiberger, B.A. DePetrillo, .NET-Crashkurs, 2. Auflage, Microsoft Press, Unterschleißheim, 2002
- [Wal04] E. Wallmüller: Risikomanagement für IT- und Software-Projekte, Hanser, München Wien, 2004

Sachwortverzeichnis

%

% 154

–

– 154

A

Abfrage *Siehe* Anfrage

Abhängigkeit

 funktional 77

 mehrwertig 96

 voll funktional 79

Abnahme 21

ACID-Prinzip 230

Aggregatsfunktion 158

ALL 200

ALTER TABLE 140

Anforderung

 Änderung 21

 Arten funktionaler 27

 in natürlicher Sprache 26

Anforderungsanalyse 20

 Bestimmung relevanter Daten 29

 implizites Wissen 23

 Textanalyse 33

 Verfeinerung 23

Anforderungstracing 28

Anfrage *Siehe auch* SQL-Anfrage

 Erstellung in Relationenalgebra 110

 in Relationenalgebra 107

ANY 200

AS 151, 164

ASCENDING 152

Assertion 139

Attribut 29

 Belegung 77

Datentyp 62

 einer Beziehung 32

 Gefahr der Redundanz 39

 identifizierend 30, *Siehe* Schlüssel

 unterstrichen 83

Attributmenge 76

Auswahl 106

Autocommit 283

AVG 160

B

Bachmann-Notation 45

BEGIN TRANSACTION 224

Belegung 77

Beziehung 31

 Attribut 32

 mehrstellig 43

 rekursiv 42

 symmetrisch 42

 Zusammenhang M zu N und 1 zu N 40

Boyce-Codd-Normalform 94

C

CHAR 129

COMMIT 224

Constraint 113, 135, 266

CONSTRAINT 116

 Benennung 135

 Überprüfung 119, 136

COUNT 159

CREATE ROLE 239

CREATE TABLE 115

CREATE VIEW 234

Cursor 262

D

Data Dictionary 9
Dateisystem 2
Datenabhängigkeit 5
Datenbank 4
 Grundanforderungen 2
Datenbank-Administrator 10
 Aufgaben 238
Datenbank-Managementsystem 4, 9
 Datensicherung 8
 Zugriffskontrolle 8
 Zugriffssteuerung 7
Datensatz 3
Datenschema 3
Datenschutz 237, 238
Datentyp 62, 126
Datum 2
 ändern 120
 eintragen 117
 flüchtig 2
 löschen 121
 persistent 3
DB 4
DBMS *Siehe* Datenbank-
 Managementsystem
DBMS_OUTPUT 246
Deadlock 231
DEFAULT 118
DELETE FROM 121
DESCENDING 152
Determinante 94
Differenz 104
Dirty Read 228
DISABLE CONSTRAINT 142
DISTINCT 149
Domäne 238
drei-wertige Logik 133
dritte Normalform 90
DROP TABLE 125
DROP VIEW 234

E

Ebene
 Ersteller 11
 extern 11
 logisch 11
 Nutzer 11
 physisch 10
ENABLE CONSTRAINT 142
Entität 29
Entitätstyp 30
 gemeinsame Attribute 49
 Unterscheidung zum Attribut 33
Entity-Relationship-Modell 30
 abhängige Attribute 48
 Dokumentation 32
 Gefahr der Redundanz 38
 Kardinalität 34
 Notationen 45
 Übersetzung in Tabellen 64
 Zusammen zu Klassendiagrammen 51
 Zyklus 38
ERM *Siehe* Entity-Relationship-Modell
erste Normalform 85
ESCAPE 156
Event-Condition-Action-Paradigma 267
EXCEPT 193
EXCEPT ALL 194
EXISTS 207
externe Ebene 11

F

Festkommazahlen 127
Fließkommazahlen 128
flüchtige Daten 2
Fluchtsymbol 155
FOREIGN KEY 116
Formular 86
Fremdschlüssel 67, 116
FROM 148, 211
FULL JOIN 217
funktionale Abhängigkeit 77
 Rechenregeln 79
 Transitivität 78
 volle 79
funktionale Korrektheit 19

G

ganze Zahlen 127
 Garantiephase 21
 Geschäftsprozess 19
 alternativer Ablauf 24
 typischer Ablauf 24
 Glossar 28
 GRANT 239
 große Datenobjekte 130
 GROUP BY 174
 Gruppierung 174
 Umgang mit NULL-Werten 177

H

HAVING 178, 210

I

identifizierende Attribute 30
 Implementierung 21
 IN 203
 Information 2
 inkrementelle Entwicklung 22
 INSERT INTO 117
 Integrität 6
 INTERSECT 192
 INTERSECT ALL 192
 IS NULL 134
 Isolationsgrad 230

J

JDBC 279
 Anfrage ausführen 283
 Autocommit 283
 CallableStatement 295
 Connection 281
 Cursor-Ergebnis 297
 DatabaseMetaData 281
 DriverManager 280
 PreparedStatement 292
 ResultSet 283
 ResultSetMetaData 284

Statement 283
 Stored Procedure 294
 Tabellen anlegen 291
 Zeilen hinzufügen 289
 JOIN 215

K

Kardinalität 34
 Katalog 9
 Klassendiagramm 50
 Konkatenation 108
 Krähenfuß-Notation 45
 Kreuzprodukt 63, 108, 162
 Laufzettel 1
 LEFT JOIN 216
 LIKE 154

L

logische Ebene 11
 logische Tabelle 235
 Löschfortpflanzung 123
 Lost Update 227
 LOWER 156

M

manuelle Datenverarbeitung 2
 MAX 158
 mehrstellige Beziehung 43
 mehrwertige Abhängigkeit 96
 Metadaten 9
 MIN 158
 Miniwelt 29

N

NATURAL FULL JOIN 218
 NATURAL JOIN 217
 NATURAL LEFT JOIN 218
 NATURAL RIGHT JOIN 218
 Nichtschlüsselattribut 82
 Normalform

Boyce-Codd 94
dritte 90
erste 85
Variante der zweiten 89
vierte 96
zweite 87
Notwendigkeit mehrstelliger Beziehungen 44
NULL 63, 119, 133
 in Gruppierungen 177
 Prüfung darauf 134
 Verhalten in Berechnungen 121
numerische Notation 45
Nutzbarkeit 19

O

Oberflächenentwicklung 12
Obertyp 49, 104
objektorientierte Entwicklung 49
ON DELETE CASCADE 123
ORDER BY 152

P

paralleler Zugriff 6, 227
Persistenz 2
Pfeilnotation 45
Phantom Read 228
physische Ebene 10
PL/SQL 244
 Alternative 247
 Ausnahmen 254
 CLOSE 262
 Cursor 262
 Cursor-FOR-Schleife 264
 EXCEPTION 254
 FETCH 262
 FOR-Schleife 250
 Funktion 252
 Kommentare 251
 OPEN 262
 Prozedur 245
 RAISE_APPLICATION_ERROR 256
 RECORD 251
 ROWTYPE 261

SELECT INTO 258
SEQUENCE 267
Trigger *Siehe* Trigger
WHILE-Schleife 249
Zuweisung 247
Prädikatenlogik 209
Primärschlüssel 83, 116
PRIMARY KEY 116
Projektadministrator 240
Projektion 105

R

Randbedingung *Siehe* Constraint
Rechengenauigkeit 128, 129
Rechte-Rollen-Matrix 241
Rechteverwaltung 239
Rechteweitergabe 241
Redundanz 6
redundanzfreie Datenhaltung 6
rekursive Beziehung 42
Relation *Siehe* Beziehung
Relationenalgebra 104
REVOKE 239
RIGHT JOIN 216
Risikomanagement 52
ROLLBACK 224
Rolle 239

S

SAVEPOINT 224
Schattenspeicher-Verfahren 226
Schlüssel 80
 künstlich erzeugt 84
Schlüsselattribut 82
Schlüsselkandidat 81
Schnittmenge 104
SELECT 148, 196
SELECT * 118
SET TRANSACTION LEVEL 230
Sicherungspunkt 224
Sicht 11, 234
Software-Entwicklungsprozess 20
Sortierung von Ergebnissen 152
Spaltenconstraint 136

-
- SQL 113
 - Festkommazahlen 127
 - Fließkommazahlen 128
 - ganze Zahlen 127
 - Notationskonventionen 115
 - SQL-Anfrage
 - Auswertung 157
 - Berechnung in SELECT-Zeile 150
 - einfach 148
 - Einfluss leerer Tabellen 167
 - Ergebnissortierung 152
 - Ergebnisspalten erzeugen 152
 - Gruppierung 174
 - lokale Umbenennung 164
 - mehrfache Tabellennutzung 165
 - Mengenoperation 190
 - Rezept zur Erstellung 164, 183
 - SELECT in SELECT 196
 - Textanalyse 154
 - über mehrere Tabellen 161
 - Umbenennung von Ergebnisspalten 151
 - Vermeidung doppelter Ergebnisse 149
 - Stored Procedure 243
 - in JDBC 294
 - SUM 159
 - Systemdesign 21
 - in WHERE 198
 - notwendige Form 199
 - Verknüpfung mit äußerer Anfrage 205
 - Test 21
 - Transaktionssteuerung 224
 - Trigger 139, 243, 267
 - NEW 270
 - OLD 270
 - FOR EACH ROW 269
 - für Views 273
 - INSTEAD OF 273
 - Tupel 63
 - Verknüpfung 108
-

U

- Umbenennung 106
- UML 50
- Unified Modeling Language 50
- UNION 190
- UNION ALL 191
- UNIQUE 138
- Unrepeatable Read 229
- UPDATE 120
- UPPER 156
- Usability 12
- USING 217

T

-
- Tabelle 3, 62, 63
 - Ableitung aus ERM 64
 - ändern 140
 - logisch 235
 - löschen 125
 - Nichtschlüsselattribut 82
 - Primärschlüssel 83
 - Schlüssel 80
 - Schlüsselattribut 82
 - Schlüsselkandidat 81
 - zerlegen 87
 - Tabellenconstraint 136
 - Tabellenkalkulation 76
 - Teilanfrage
 - in FROM 211
 - in HAVING 210
 - in SELECT 196

V

-
- VARCHAR 129
 - Vereinigung 104
 - Vereinigungsverträglichkeit 104
 - Verknüpfung mit leeren Tabellen 167
 - Verknüpfung von Sortierkriterien 153
 - verschachtelte Anfragen 205
 - View 11, 234
 - aktuelle Berechnung 235
 - Datenänderungsproblematik 236
 - materialized 235
 - volle funktionale Abhängigkeit 79
 - Vorgehensmodell 23

W

Wasserfallmodell 21
Wenn-Dann-Bedingung 138
WHERE-Bedingung 131, 154, 198
 Auswertung 132
 Syntax 131

Z

Zugriff
 parallel 6, 227
zweite Normalform 87
 Variante 89
zwei-wertige Logik 132