

The background of the entire cover is a close-up photograph of a wood grain, showing various shades of brown and tan with distinct, wavy patterns. The text is overlaid on this background.

WPROWADZENIE DO

SYSTEMÓW BAZ DANYCH

Wydanie VII

ELMASRI • NAVATHE

Helion 

Tytuł oryginału: Fundamentals of Database Systems (7th Edition)

Tłumaczenie: Tomasz Walczak

z wykorzystaniem fragmentów „Wprowadzenie do systemów baz danych” w przekładzie Bartłomieja Garbacza, Bartłomieja Moczulskiego i Mikołaja Szczepaniaka

ISBN: 978-83-283-4695-6

Authorized translation from the English language edition, entitled: FUNDAMENTALS OF DATABASE SYSTEMS, Seventh Edition, ISBN 0133970779; by Ramez Elmasri; and by Shamkant B. Navathe; published by Pearson Education, Inc. Copyright © 2016, 2011, 2007 by Ramez Elmasri and Shamkant B. Navathe.

All rights reserved. No part of this book may be reproduced or transmitted in any form or by any means, electronic or mechanical, including photocopying, recording or by any information storage retrieval system, without permission from Pearson Education, Inc.

Polish language edition published by HELION SA, Copyright © 2019.

All rights reserved. No part of this book may be reproduced or transmitted in any form or by any means, electronic or mechanical, including photocopying, recording or by any information storage retrieval system, without permission from the Publisher.

Wszelkie prawa zastrzeżone. Nieautoryzowane rozpowszechnianie całości lub fragmentu niniejszej publikacji w jakiegokolwiek postaci jest zabronione. Wykonywanie kopii metodą kserograficzną, fotograficzną, a także kopiowanie książki na nośniku filmowym, magnetycznym lub innym powoduje naruszenie praw autorskich niniejszej publikacji.

Wszystkie znaki występujące w tekście są zastrzeżonymi znakami firmowymi bądź towarowymi ich właścicieli.

Autor oraz Helion SA dołożyli wszelkich starań, by zawarte w tej książce informacje były kompletne i rzetelne. Nie biorą jednak żadnej odpowiedzialności ani za ich wykorzystanie, ani za związane z tym ewentualne naruszenie praw patentowych lub autorskich. Autor oraz Helion SA nie ponoszą również żadnej odpowiedzialności za ewentualne szkody wynikłe z wykorzystania informacji zawartych w książce.

Helion SA

ul. Kościuszki 1c, 44-100 Gliwice

tel. 32 231 22 19, 32 230 98 63

e-mail: helion@helion.pl

WWW: <http://helion.pl> (księgarnia internetowa, katalog książek)

Drogi Czytelniku!

Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres

<http://helion.pl/user/opinie/wprsy7>

Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Printed in Poland.

- [Kup książkę](#)
- [Poleć książkę](#)
- [Oceń książkę](#)

- [Księgarnia internetowa](#)
- [Lubię to! » Nasza społeczność](#)

Spis treści

Przedmowa	25
O autorach	33
I. Wprowadzenie do baz danych	35
1. Bazy danych i ich użytkownicy	37
1.1. Wprowadzenie	38
1.2. Przykład	41
1.3. Właściwości rozwiązań opartych na bazach danych	44
1.3.1. Samoopisująca natura systemów baz danych	45
1.3.2. Oddzielenie programów od danych oraz abstrakcja danych	46
1.3.3. Obsługa wielu perspektyw dla tych samych danych	48
1.3.4. Współdzielenie danych oraz wielodostępne przetwarzanie transakcji	49
1.4. Aktorzy na scenie	50
1.4.1. Administratorzy bazy danych	50
1.4.2. Projektanci bazy danych	50
1.4.3. Użytkownicy końcowi	51
1.4.4. Analitycy systemowi i programiści aplikacji (inżynierowie oprogramowania)	52
1.5. Pracownicy poza sceną	52
1.6. Zalety stosowania rozwiązań opartych na systemach zarządzania bazami danych	53
1.6.1. Kontrola nadmiarowości	53
1.6.2. Ograniczanie możliwości uzyskania nieautoryzowanego dostępu	55
1.6.3. Zapewnianie miejsca trwałego przechowywania dla obiektów stosowanych w programach	56
1.6.4. Zapewnianie struktur przechowywania dla efektywnego przetwarzania zapytań	56
1.6.5. Zapewnianie możliwości tworzenia kopii bezpieczeństwa i odzyskiwania danych	57
1.6.6. Zapewnianie interfejsów dla wielu użytkowników	57
1.6.7. Reprezentowanie skomplikowanych relacji pomiędzy danymi	57
1.6.8. Wymuszanie więzów integralności	58
1.6.9. Zezwalanie na wnioskowanie i podejmowanie działań w oparciu o zdefiniowane reguły	59

1.6.10. Dodatkowe własności wynikające ze stosowania rozwiązań opartych na bazach danych	59
1.7. Krótka historia praktycznych zastosowań baz danych	60
1.7.1. Wczesne zastosowania baz danych oparte na systemach hierarchicznych i sieciowych	60
1.7.2. Zapewnianie elastyczności w rozwiązaniach opartych na relacyjnych bazach danych	61
1.7.3. Aplikacje obiektowe i konieczność wprowadzenia bardziej skomplikowanych baz danych	62
1.7.4. Wykorzystywana w handlu elektronicznym wymiana danych za pośrednictwem internetu z użyciem XML-a	62
1.7.5. Rozszerzanie możliwości współczesnych systemów baz danych z myślą o nowych zastosowaniach	63
1.7.6. Powstanie systemów przechowywania big data i baz NOSQL	64
1.8. Kiedy nie należy używać systemów zarządzania bazami danych	64
1.9. Podsumowanie	65
Pytania powtórkowe	66
Ćwiczenia	66
Wybrane publikacje	67
2. Architektura systemów baz danych i związane z nimi pojęcia	69
2.1. Modele danych, schematy i egzemplarze	70
2.1.1. Kategorie modeli danych	71
2.1.2. Schematy, egzemplarze i stany baz danych	72
2.2. Trójwarstwowa architektura i niezależność danych	74
2.2.1. Architektura trójwarstwowa	74
2.2.2. Niezależność danych	76
2.3. Języki i interfejsy baz danych	77
2.3.1. Języki systemów zarządzania bazami danych	77
2.3.2. Interfejsy systemów zarządzania bazami danych	80
2.4. Środowisko systemu bazy danych	82
2.4.1. Moduły składające się na system zarządzania bazą danych	82
2.4.2. Narzędzia systemu bazy danych	85
2.4.3. Narzędzia, środowiska aplikacji oraz mechanizmy komunikacji	86
2.5. Architektury systemów zarządzania bazami danych	
— scentralizowane i typu klient-serwer	87
2.5.1. Scentralizowane architektury systemów zarządzania bazami danych	87
2.5.2. Podstawowe architektury typu klient-serwer	87
2.5.3. Dwuwarstwowe architektury typu klient-serwer dla systemów zarządzania bazami danych	90
2.5.4. Trójwarstwowe i n-warstwowe architektury typu klient-serwer dla aplikacji internetowych	90
2.6. Klasyfikacja systemów zarządzania bazami danych	92
2.7. Podsumowanie	95
Pytania powtórkowe	96
Ćwiczenia	97
Wybrane publikacje	97

II. Konceptyjne modelowanie danych i projektowanie baz danych

99

3. Modelowanie danych zgodnie z modelem związków encji	101
3.1. Stosowanie wysokopoziomowych, konceptyjnych modeli danych podczas projektowania bazy danych	103
3.2. Przykładowa aplikacja bazy danych	105
3.3. Typy encji, zbiory encji, atrybuty i klucze	106
3.3.1. Encje i atrybuty	107
3.3.2. Typy encji, zbiory encji, klucze i zbiory wartości	109
3.3.3. Początkowy projekt konceptyjny bazy danych FIRMA	113
3.4. Typy związków, zbiory związków, role i ograniczenia strukturalne	114
3.4.1. Typy, zbiory i egzemplarze związków	115
3.4.2. Stopień związku, nazwy ról oraz związki rekurencyjne	115
3.4.3. Ograniczenia dla typów związków	118
3.4.4. Atrybuty typów związków	121
3.5. Słabe typy encji	122
3.6. Udoskonalanie projektu ER dla bazy danych FIRMA	123
3.7. Diagramy ER, konwencje nazewnictwa oraz zagadnienia związane z projektowaniem	124
3.7.1. Podsumowanie notacji diagramów związków encji (ER)	124
3.7.2. Prawidłowe nazewnictwo konstrukcji schematu	125
3.7.3. Decyzje projektowe związane z tworzeniem schematu konceptyjnego ER	127
3.7.4. Notacje alternatywne względem tradycyjnych diagramów związków encji (ER)	128
3.8. Przykładowa inna notacja: diagramy klas UML	129
3.9. Typy związków stopnia wyższego niż drugi	132
3.9.1. Wybór pomiędzy związkami binarnymi a trójskładnikowymi (lub wyższych stopni)	132
3.9.2. Ograniczenia związków trójskładnikowych (i wyższych stopni)	136
3.10. Inny przykład — baza danych UNIWERSYTET	137
3.11. Podsumowanie	139
Pytania powtórkowe	140
Ćwiczenia	141
Ćwiczenia laboratoryjne	147
Wybrane publikacje	149
4. Rozszerzony model związków encji	151
4.1. Podklasy, nadklasy i dziedziczenie	152
4.2. Specjalizacja i generalizacja	154
4.2.1. Specjalizacja	154
4.2.2. Generalizacja	155
4.3. Ograniczenia i właściwości hierarchii specjalizacji i generalizacji	157
4.3.1. Ograniczenia dotyczące specjalizacji i generalizacji	157
4.3.2. Hierarchie i kraty specjalizacji i generalizacji	160
4.3.3. Stosowanie procesów specjalizacji i generalizacji podczas udoskonalania schematów konceptyjnych	163
4.4. Modelowanie typów UNII w oparciu o kategorie	164
4.5. Przykład schematu EER dla bazy danych UNIWERSYTET oraz formalne definicje dla modelu EER	166
4.5.1. Inny przykład bazy danych UNIWERSYTET	166
4.5.2. Wybory projektowe związane ze specjalizacją i generalizacją	169
4.5.3. Formalne definicje pojęć stosowanych w modelu EER	170

4.6. Przykładowa inna notacja: reprezentowanie specjalizacji-generalizacji na diagramach klas języka UML	171
4.7. Abstrakcja danych, reprezentacja wiedzy oraz zagadnienia związane z ontologią	173
4.7.1. Klasyfikacja i tworzenie egzemplarzy	174
4.7.2. Identyfikacja	175
4.7.3. Specjalizacja i generalizacja	176
4.7.4. Agregacja i asocjacja	176
4.7.5. Ontologia i sieć semantyczna	178
4.8. Podsumowanie	179
Pytania powtórkowe	180
Ćwiczenia	181
Ćwiczenia laboratoryjne	188
Wybrane publikacje	190

III. Relacyjny model danych i SQL

193

5. Relacyjny model danych i ograniczenia relacyjnych baz danych	195
5.1. Pojęcia z modelu relacyjnego	196
5.1.1. Dziedziny, atrybuty, krotki i relacje	197
5.1.2. Właściwości relacji	199
5.1.3. Notacja modelu relacyjnego	203
5.2. Ograniczenia modelu relacyjnego i schematy relacyjnych baz danych	203
5.2.1. Ograniczenia dziedziny	204
5.2.2. Ograniczenia klucza i ograniczenia wartości pustych	205
5.2.3. Relacyjne bazy danych i schematy relacyjnych baz danych	206
5.2.4. Integralność encji, integralność odwołań i klucze obce	209
5.2.5. Pozostałe typy ograniczeń	210
5.3. Operacje aktualizacji, transakcje i obsługa naruszeń więzów integralności	212
5.3.1. Operacja wstawiania	212
5.3.2. Operacja usuwania	214
5.3.3. Operacja aktualizacji	215
5.3.4. Transakcje	216
5.4. Podsumowanie	216
Pytania powtórkowe	217
Ćwiczenia	218
Wybrane publikacje	222
6. Podstawy języka SQL	223
6.1. Definicje danych i typy danych języka SQL	225
6.1.1. Stosowane w języku SQL pojęcia schematu i katalogu	226
6.1.2. Polecenie CREATE TABLE języka SQL	226
6.1.3. Typy danych atrybutów oraz dziedziny wartości w standardzie SQL	229
6.2. Określanie ograniczeń w języku SQL	231
6.2.1. Definiowanie ograniczeń i wartości domyślnych dla atrybutów	232
6.2.2. Definiowanie ograniczeń klucza i więzów integralności odwołań	233
6.2.3. Nadawanie nazw definiowanym ograniczeniom	235
6.2.4. Stosowanie klauzuli CHECK do określania ograniczeń dla krotek	235
6.3. Podstawowe zapytania języka SQL	236
6.3.1. Struktura podstawowych zapytań języka SQL: SELECT-FROM-WHERE	236
6.3.2. Niejednoznaczne nazwy atrybutów, mechanizm nazw zastępczych (aliasów) oraz zmienne krotek	239
6.3.3. Nieokreślona klauzula WHERE i zastosowania symbolu gwiazdki	241

6.3.4. Tabele i zbiory w języku SQL	242
6.3.5. Dopasowywanie podciągów znaków do wzorca oraz operacje arytmetyczne	244
6.3.6. Sortowanie wyników zapytań	246
6.3.7. Omówienie i podsumowanie prostych zapytań języka SQL	246
6.4. Dostępne w języku SQL polecenia INSERT, DELETE i UPDATE	247
6.4.1. Polecenie INSERT	247
6.4.2. Polecenie DELETE	249
6.4.3. Polecenie UPDATE	250
6.5. Dodatkowe własności języka SQL	250
6.6. Podsumowanie	252
Pytania powtórkowe	252
Ćwiczenia	253
Wybrane publikacje	255

7. Jeszcze o języku SQL — złożone zapytania, wyzwalacze, perspektywy i modyfikowanie schematów **257**

7.1. Bardziej skomplikowane zapytania języka SQL pobierające dane	257
7.1.1. Operacje porównania z wartością pustą (NULL) oraz logika trójwartościowa	258
7.1.2. Zapytania zagnieżdżone, krotki oraz porównywanie zbiorów i wielozbiorów	260
7.1.3. Zagnieżdżone zapytania skorelowane	262
7.1.4. Dostępne w języku SQL funkcje EXISTS i UNIQUE	263
7.1.5. Jawne deklarowanie zbiorów i zmienianie nazw atrybutów w języku SQL	265
7.1.6. Tabele połączone w języku SQL	266
7.1.7. Funkcje agregujące w języku SQL	268
7.1.8. Grupowanie: klauzule GROUP BY i HAVING	270
7.1.9. Inne konstrukcje języka SQL: WITH i CASE	273
7.1.10. Zapytania rekurencyjne w języku SQL	274
7.1.11. Omówienie i podsumowanie zapytań języka SQL	275
7.2. Definiowanie ograniczeń w postaci asercji i działań w postaci wyzwalaczy	277
7.2.1. Definiowanie ogólnych ograniczeń w postaci asercji w języku SQL	277
7.2.2. Wprowadzenie do wyzwalaczy w języku SQL	278
7.3. Perspektywy (tabele wirtualne) w języku SQL	280
7.3.1. Pojęcie perspektywy w języku SQL	280
7.3.2. Definiowanie perspektyw w języku SQL	280
7.3.3. Implementacja perspektyw i mechanizm ich aktualizowania	282
7.3.4. Perspektywy jako mechanizm uwierzytelniania	284
7.4. Dostępne w języku SQL polecenia zmiany schematu	285
7.4.1. Polecenie DROP	285
7.4.2. Polecenie ALTER	286
7.5. Podsumowanie	287
Pytania powtórkowe	289
Ćwiczenia	289
Wybrane publikacje	291

8. Algebra relacyjna i rachunek relacji **293**

8.1. Relacyjne operacje unarne: selekcja i projekcja	295
8.1.1. Operacja selekcji	295
8.1.2. Operacja projekcji	297
8.1.3. Sekwencje operacji i operacja ZMIANA NAZWY	299
8.2. Operacje algebry relacyjnej pochodzące z teorii zbiorów	301
8.2.1. Operacje sumy, części wspólnej i różnicy	301
8.2.2. Operacja iloczynu (produktu) kartezjańskiego	303

8.3. Binarne operacje na relacjach: złączenie i dzielenie	305
8.3.1. Operacja złączenia	305
8.3.2. Odmianny operacji złączenia: operacje równo-złączenia i złączenia naturalnego	307
8.3.3. Kompletny zbiór operacji algebry relacyjnej	309
8.3.4. Operacja dzielenia	310
8.3.5. Notacja drzew zapytań	313
8.4. Dodatkowe operacje relacyjne	314
8.4.1. Uogólniona projekcja	314
8.4.2. Funkcje agregujące i mechanizm grupowania	314
8.4.3. Rekurencyjne operacje domknięcia	316
8.4.4. Operacje złączenia zewnętrznego	317
8.4.5. Operacja sumy zewnętrznej	319
8.5. Przykłady zapytań w algebrze relacyjnej	320
8.6. Relacyjny rachunek krotek	323
8.6.1. Zmienne krotek i relacje zakresowe	324
8.6.2. Wyrażenia i wzory w relacyjnym rachunku krotek	325
8.6.3. Kwantyfikatory uniwersalne i egzystencjalne	327
8.6.4. Przykładowe zapytania w relacyjnym rachunku krotek	328
8.6.5. Notacja używana dla grafów zapytań	329
8.6.5. Wzajemne przekształcanie kwantyfikatorów uniwersalnych i egzystencjalnych	330
8.6.7. Stosowanie kwantyfikatorów uniwersalnych w zapytaniach	331
8.6.8. Bezpieczne wyrażenia	333
8.7. Relacyjny rachunek dziedzin	334
8.8. Podsumowanie	336
Pytania powtórkowe	338
Ćwiczenia	338
Ćwiczenia laboratoryjne	343
Wybrane publikacje	346
9. Projektowanie relacyjnych baz danych przez odwzorowywanie modelu ER i EER w model relacyjny	347
9.1. Projektowanie relacyjnych baz danych w oparciu o odwzorowywanie modelu ER w model relacyjny	348
9.1.1. Algorytm odwzorowujący model ER w model relacyjny	348
9.1.2. Omówienie i podsumowanie odwzorowania konstrukcji modelu ER w odpowiednie konstrukcje modelu relacyjnego	355
9.2. Odwzorowania konstrukcji modelu EER w relacje	357
9.2.1. Odwzorowywanie specjalizacji i generalizacji	357
9.2.2. Odwzorowywanie współdzielonych podklas (konstrukcji dziedziczenia wielokrotnego)	360
9.2.3. Odwzorowywanie kategorii (typów unii)	361
9.3. Podsumowanie	361
Pytania powtórkowe	362
Ćwiczenia	362
Ćwiczenia laboratoryjne	364
Wybrane publikacje	365

IV. Techniki programowania baz danych**367**

10. Wprowadzenie do technik programowania w języku SQL	369
10.1. Przegląd technik i zagadnień z obszaru programowania baz danych	370
10.1.1. Strategie programowania baz danych	371
10.1.2. Niezgodność impedancji	372
10.1.3. Typowa sekwencja operacji składających się na interakcję w programowaniu baz danych	373
10.2. Osadzony język SQL, dynamiczny język SQL oraz język SQLJ	374
10.2.1. Wyszukiwanie pojedynczych krotek za pomocą poleceń osadzonego języka SQL	375
10.2.2. Przetwarzanie wyników zapytań za pomocą kursorów	379
10.2.3. Określanie zapytań w czasie wykonywania programu — stosowanie dynamicznego języka SQL	381
10.2.4. SQLJ: Osadzanie poleceń języka SQL w języku Java	383
10.2.5. Używanie iteratorów do przetwarzania wyników zapytań w standardzie SQLJ	385
10.3. Programowanie baz danych z wywołaniami funkcji i bibliotekami klas: SQL/CLI oraz JDBC	388
10.3.1. Programowanie baz danych z wykorzystaniem interfejsu SQL/CLI oraz języka C w roli nadrzędnego języka programowania	389
10.3.2. JDBC: biblioteka klas języka SQL służąca do programowania w języku Java	393
10.4. Procedury składowane w bazie danych i technika SQL/PSM	398
10.4.1. Procedury i funkcje składowane w bazie danych	399
10.4.2. SQL/PSM: Rozszerzenie standardu SQL o możliwość określania trwale składowanych modułów	400
10.5. Porównanie trzech opisanych podejść	402
10.6. Podsumowanie	403
Pytania powtórkowe	403
Ćwiczenia	404
Wybrane publikacje	404
11. Programowanie internetowych baz danych z użyciem języka PHP	405
11.1. Prosty przykład zastosowania PHP	406
11.2. Przegląd podstawowych mechanizmów języka PHP	408
11.2.1. Zmienne, typy danych i konstrukcje programistyczne języka PHP	409
11.2.2. Tablice w PHP	410
11.2.3. Funkcje w języku PHP	412
11.2.4. Zmienne i formularze serwera PHP	414
11.3. Przegląd programowania baz danych za pomocą PHP	415
11.3.1. Nawiązywanie połączenia z bazą danych	415
11.3.2. Pobieranie danych z formularzy i wstawianie rekordów	417
11.3.3. Zapytania pobierające dane z tabel bazy	418
11.4. Krótki przegląd technologii programowania internetowych baz danych w Javie	419
11.5. Podsumowanie	420
Pytania powtórkowe	420
Ćwiczenia	421
Wybrane publikacje	421

V. Podejścia obiektowe, obiektowo-relacyjne i XML: zagadnienia, modele, języki i standardy 423

12. Bazy obiektowe i obiektowo-relacyjne	425
12.1. Przegląd pojęć obiektowych	427
12.1.1. Wprowadzenie do pojęć i cech obiektowych	427
12.1.2. Tożsamość obiektów i porównanie obiektów z literałami	429
12.1.3. Złożone struktury typów obiektów i literałów	430
12.1.4. Enkapsulacja operacji i trwałość obiektów	432
12.1.5. Hierarchia typów i dziedziczenie	436
12.1.6. Inne pojęcia obiektowe	438
12.1.7. Podsumowanie zagadnień dotyczących obiektowych baz danych	440
12.2. Rozszerzenia obiektowe w standardzie SQL	440
12.2.1. Typy definiowane przez użytkownika za pomocą polecenia CREATE TYPE i obiekty złożone	443
12.2.2. Identyfikatory obiektów oparte na odwołaniach	444
12.2.3. Tworzenie tabel z wykorzystaniem UDT	444
12.2.4. Enkapsulacja operacji	445
12.2.5. Dziedziczenie i przeciążanie funkcji	446
12.2.6. Określanie związków za pomocą odwołań	446
12.3. Model obiektowy ODMG i język definiowania obiektów ODL	447
12.3.1. Przegląd modelu obiektowego ODMG	448
12.3.2. Dziedziczenie w modelu obiektowym ODMG	453
12.3.3. Wbudowane interfejsy i klasy w modelu obiektowym	454
12.3.4. Obiekty atomowe (definiowane przez użytkownika)	456
12.3.5. Ekstensje, klucze i obiekty-fabryki	458
12.3.6. Język definicji obiektów ODL	460
12.4. Projektowanie koncepcyjne obiektowej bazy danych	465
12.4.1. Różnice pomiędzy koncepcyjnym projektowaniem obiektowych i relacyjnych baz danych	465
12.4.2. Odwzorowywanie schematu EER na schemat obiektowy	466
12.5. Obiektowy język zapytań OQL	468
12.5.1. Proste zapytania OQL, punkty wejścia bazy danych i zmienne iterujące	469
12.5.2. Wyniki zapytań i wyrażenia ścieżkowe	470
12.5.3. Inne cechy OQL	472
12.6. Przegląd wiązania z językiem C++ w standardzie ODMG	476
12.7. Podsumowanie	478
Pytania powtórkowe	479
Ćwiczenia	480
Wybrane publikacje	481
13. XML — rozszerzalny język znaczników	483
13.1. Dane strukturalne, półstrukturalne i niestructuralne	484
13.2. Hierarchiczny (drzewiasty) model danych w dokumentach XML	488
13.3. Dokumenty XML, DTD i schematy	491
13.3.1. Dobrze uformowane i prawidłowe dokumenty XML oraz XML DTD	491
13.3.2. Schematy XML	494
13.4. Zapisywanie dokumentów XML w bazach i ich pobieranie	499
13.5. Języki związane ze standardem XML	500
13.5.1. XPath, czyli określanie ścieżek w dokumentach XML	500
13.5.2. XQuery: definiowanie zapytań w XML	502

13.5.3. Inne języki i protokoły związane ze standardem XML	504
13.6. Pobieranie dokumentów XML z relacyjnych baz danych	505
13.6.1. Tworzenie hierarchicznych perspektyw w formacie XML dla danych płaskich lub zapisanych w grafie	505
13.6.2. Przerwywanie cykli w celu zamiany grafów w drzewa	509
13.6.3. Dodatkowe kroki związane z tworzeniem dokumentu XML na podstawie bazy danych	510
13.7. XML/SQL: funkcje języka SQL generujące dane w formacie XML	511
13.8. Podsumowanie	512
Pytania powtórkowe	513
Ćwiczenia	513
Wybrane publikacje	514

VI. Teoria projektowania baz danych i normalizacja **515**

14. Podstawy zależności funkcyjnych i normalizacji w relacyjnych bazach danych	517
14.1. Nieformalne wskazówki dotyczące projektowania schematów relacji	519
14.1.1. Wymuszanie jednoznacznej semantyki atrybutów relacji	519
14.1.2. Nadmiarowe informacje w krotkach oraz anomalie aktualizacji	521
14.1.3. Wartości null w krotkach	525
14.1.4. Generowanie fałszywych krotek	526
14.1.5. Podsumowanie i omówienie wskazówek projektowych	528
14.2. Zależności funkcyjne	528
14.2.1. Definicja zależności funkcyjnej	529
14.3. Postaci normalne oparte na kluczach głównych	532
14.3.1. Normalizacja relacji	532
14.3.2. Praktyczne zastosowania postaci normalnych	533
14.3.3. Definicje kluczy i atrybutów należących do kluczy	534
14.3.4. Pierwsza postać normalna	535
14.3.5. Druga postać normalna	539
14.3.6. Trzecia postać normalna	540
14.4. Definicje ogólne drugiej i trzeciej postaci normalnej	542
14.4.1. Definicja ogólna drugiej postaci normalnej	542
14.4.2. Definicja ogólna trzeciej postaci normalnej	544
14.4.3. Interpretacja definicji ogólnej trzeciej postaci normalnej	544
14.5. Postać normalna Boyce'a-Codda	545
14.5.1. Dekompozycja relacji niebędących w BCNF	547
14.6. Zależności wielowartościowe i czwarta postać normalna	549
14.6.1. Formalna definicja zależności wielowartościowej	549
14.7. Zależności złączeniowe i piąta postać normalna	552
14.8. Podsumowanie	553
Pytania powtórkowe	555
Ćwiczenia	556
Ćwiczenia laboratoryjne	560
Wybrane publikacje	560
15. Algorytmy projektowania relacyjnych baz danych i dodatkowe zależności	563
15.1. Inne zagadnienia z obszaru zależności funkcyjnych: reguły wnioskowania, równoważności i pokrycie minimalne	564
15.1.1. Reguły wnioskowania dla zależności funkcyjnych	565
15.1.2. Równoważność zbiorów zależności funkcyjnych	569
15.1.3. Zbiory minimalne zależności funkcyjnych	570

15.2. Właściwości dekompozycji relacyjnych	573
15.2.1. Dekompozycja relacji i niewystarczalność postaci normalnych	573
15.2.2. Właściwość zachowania zależności dekompozycji	574
15.2.3. Właściwość złączenia bezstratnego (nieaddytywnego) dekompozycji	575
15.2.4. Testowanie dekompozycji binarnych pod względem występowania właściwości złączenia nieaddytywnego	577
15.2.5. Kolejne dekompozycje o złączeniach nieaddytywnych	578
15.3. Algorytmy projektowania schematów relacyjnych baz danych	579
15.3.1. Dekompozycja na schematy w trzeciej postaci normalnej z zachowaniem zależności i właściwością złączenia nieaddytywnego (bezstratnego)	579
15.3.2. Dekompozycja ze złączeniem nieaddytywnym na schematy w postaci normalnej Boyce'a-Codda	582
15.4. Problemy związane z wartościami pustymi i krotkami zawieszonymi oraz inne projekty relacyjne	584
15.4.1. Problemy związane z wartościami pustymi i krotkami zawieszonymi	584
15.4.2. Omówienie algorytmów normalizacyjnych i innych projektów relacyjnych	586
15.5. Dalsze omówienie zależności wielowartościowych i 4NF	588
15.5.1. Reguły wnioskowania dla zależności funkcyjnych i wielowartościowych	588
15.5.2. Jeszcze o czwartej postaci normalnej	589
15.5.3. Dekompozycja ze złączeniem nieaddytywnym na relacje w czwartej postaci normalnej	591
15.6. Inne zależności i postaci normalne	592
15.6.1. Zależności złączeniowe i piąta postać normalna	592
15.6.2. Zależności zawierania	592
15.6.3. Zależności funkcyjne oparte na funkcjach i procedurach arytmetycznych	593
15.6.4. Postać normalna klucza dziedziny	594
15.7. Podsumowanie	595
Pytania powtórkowe	595
Ćwiczenia	596
Ćwiczenia laboratoryjne	598
Wybrane publikacje	598

VII. Struktury plikowe, funkcje mieszające, indeksowanie i projekty fizyczne baz danych **601**

16. Składowanie danych na dysku, podstawowe struktury plikowe, funkcje mieszające i nowoczesne struktury składowania	603
16.1. Wprowadzenie	604
16.1.1. Hierarchie pamięciowe i urządzenia składowania danych	605
16.1.2. Przechowywanie baz danych	607
16.2. Drugorzędne urządzenia pamięciowe	609
16.2.1. Opis sprzętowy napędów dyskowych	609
16.2.2. Zwiększanie wydajności dostępu do danych na dysku	615
16.2.3. Pamięć masowa SSD	616
16.2.4. Taśmowe urządzenia pamięciowe	617
16.3. Buforowanie bloków	619
16.3.1. Zarządzanie buforem	620
16.3.2. Strategie zastępowania danych w buforze	622
16.4. Rozmieszczanie rekordów plików na dysku	623
16.4.1. Rekordy i typy rekordów	623
16.4.2. Pliki oraz rekordy o stałej i zmiennej długości	624

16.4.3. Rozmieszczenie rekordów w blokach i rekordy segmentowane oraz niesegmentowane	626
16.4.4. Alokowanie bloków pliku na dysku	627
16.4.5. Nagłówki plików	627
16.5. Operacje wykonywane na plikach	627
16.6. Pliki nieuporządkowanych rekordów (pliki stertowe)	631
16.7. Pliki uporządkowanych rekordów (pliki posortowane)	632
16.8. Techniki mieszania	636
16.8.1. Mieszanie wewnętrzne	636
16.8.2. Mieszanie zewnętrzne dla plików na dysku	639
16.8.3. Techniki mieszania umożliwiające dynamiczne rozszerzanie plików	642
16.9. Inne podstawowe metody organizacji plików	647
16.9.1. Pliki rekordów mieszanych	647
16.9.2. B-drzewa i inne struktury danych służące jako podstawowe metody organizacji	648
16.10. Zapewnianie równoległego dostępu do dysku przy użyciu architektury RAID	648
16.10.1. Zwiększanie niezawodności przy użyciu architektury RAID	650
16.10.2. Poprawianie wydajności przy użyciu architektury RAID	651
16.10.3. Metody organizacji i poziomy architektury RAID	651
16.11. Nowoczesne architektury składowania danych	653
16.11.1. Sieci obszarów składowania danych	653
16.11.2. Technologia NAS	654
16.11.3. iSCSI i inne sieciowe protokoły składowania danych	655
16.11.4. Technologia Automated Storage Tiering	656
16.11.5. Obiektowa pamięć masowa	656
16.12. Podsumowanie	657
Pytania powtórkowe	658
Ćwiczenia	660
Wybrane publikacje	663
17. Struktury indeksowe dla plików i fizyczne projekty baz danych	665
17.1. Rodzaje jednopoziomowych indeksów uporządkowanych	666
17.1.1. Indeksy główne	667
17.1.2. Indeksy klastrowania	670
17.1.3. Indeksy drugorzędne	673
17.1.4. Podsumowanie	677
17.2. Indeksy wielopoziomowe	677
17.3. Dynamiczne indeksy wielopoziomowe z użyciem B-drzew i B ⁺ -drzew	681
17.3.1. Drzewa wyszukiwania i B-drzewa	682
17.3.2. B ⁺ -drzewa	687
17.4. Indeksy na wielu kluczach	696
17.4.1. Indeks uporządkowany na wielu atrybutach	697
17.4.2. Mieszanie partycjonowane	697
17.4.3. Pliki matrycowe	697
17.5. Inne rodzaje indeksów	699
17.5.1. Indeksy oparte na mieszanii	699
17.5.2. Indeksy bitmapowe	699
17.5.3. Indeksowanie oparte na funkcji	702
17.6. Ogólne zagadnienia związane z indeksami	703
17.6.1. Indeksy logiczne a fizyczne	703
17.6.2. Tworzenie indeksu	704
17.6.3. Dostrajanie indeksów	705
17.6.4. Dodatkowe kwestie związane ze składowaniem relacji i indeksów	706

17.7. Fizyczne projektowanie baz danych w przypadku baz relacyjnych	708
17.7.1. Czynniki wpływające na fizyczny projekt bazy danych	708
17.7.2. Decyzje dotyczące fizycznego projektu bazy danych	710
17.8. Podsumowanie	711
Pytania powtórkowe	713
Ćwiczenia	714
Wybrane publikacje	716

VIII. Przetwarzanie i optymalizacja zapytań

719

18. Strategie przetwarzania zapytań	721
18.1. Translacja zapytań języka SQL do postaci wyrażeń algebry relacji i innych operacji	724
18.1.1. Dodatkowe operatory złączeń częściowych i antyzłączeń	725
18.2. Algorytmy sortowania zewnętrznego	727
18.3. Algorytmy operacji selekcji	729
18.3.1. Możliwości implementacji operacji SELECT	729
18.3.2. Metody wyszukiwania dla selekcji na podstawie warunku koniunktywnego	731
18.3.3. Metody wyszukiwania dla selekcji na podstawie alternatywy logicznej	733
18.3.4. Szacowanie selektywności warunku	733
18.4. Implementacja operacji JOIN	734
18.4.1. Metody implementacji złączeń	735
18.4.2. Wpływ dostępnej przestrzeni bufora i pliku używanego w pętli zewnętrznej na wydajność operacji złączenia w pętli zagnieżdżonej	738
18.4.3. Wpływ współczynnika selekcji złączenia na wydajność tej operacji	739
18.4.4. Ogólna postać partycjonowanego złączenia mieszającego	741
18.4.5. Hybrydowe złączanie mieszające	742
18.5. Algorytmy operacji projekcji i teoriomnogościowych	743
18.5.1. Stosowanie antyzłączeń w operacji SET DIFFERENCE (EXCEPT lub MINUS w języku SQL)	744
18.6. Implementacja operacji agregujących oraz złączeń różnego rodzaju	745
18.6.1. Implementacja operacji agregujących	745
18.6.2. Implementacja różnego rodzaju złączeń	746
18.7. Łączenie operacji poprzez mechanizm potokowy	748
18.7.1. Iteratory używane do implementowania operacji fizycznych	749
18.8. Algorytmy równoległego przetwarzania zapytań	750
18.8.1. Równoległość na poziomie operatorów	751
18.8.2. Równoległość w jednym zapytaniu	754
18.8.3. Równoległość w wielu zapytaniach	754
18.9. Podsumowanie	755
Pytania powtórkowe	755
Ćwiczenia	756
Wybrane publikacje	756
19. Optymalizacja zapytań	757
19.1. Drzewa zapytań i heurystyki optymalizacji zapytań	758
19.1.1. Notacja drzew zapytań i grafów zapytań	758
19.1.2. Heurystyczna optymalizacja drzew zapytań	760
19.2. Wybór planów wykonania zapytań	767
19.2.1. Różne sposoby wykonywania zapytań	767
19.2.2. Optymalizacja podzapytań zagnieżdżonych	768
19.2.3. Scalanie podzapytań (perspektyw)	770
19.2.4. Perspektywy zmaterializowane	772

19.3. Wykorzystanie selektywności w optymalizacji kosztowej	775
19.3.1. Składowe koszty wykonywania zapytań	776
19.3.2. Informacje z katalogu używane w funkcjach kosztu	777
19.3.3. Histogramy	778
19.4. Funkcje kosztu dla operacji SELECT	778
19.4.1. Przykład optymalizacji selekcji na podstawie wzorów szacowania kosztów	781
19.5. Przykłady funkcji kosztu dla operacji JOIN	783
19.5.1. Selektywność i liczność złączeń częściowych i antyzłączeń	785
19.5.2. Przykład optymalizacji złączenia na podstawie funkcji kosztu	786
19.5.3. Zapytania dotyczące wielu relacji i porządkowanie złączeń	787
19.5.4. Optymalizacja fizyczna	789
19.5.5. Określanie kolejności złączeń za pomocą programowania dynamicznego	790
19.6. Przykład ilustrujący kosztową optymalizację zapytań	792
19.7. Dodatkowe zagadnienia związane z optymalizacją zapytań	794
19.7.1. Wyświetlanie planu wykonania zapytania uzyskanego przez system	794
19.7.2. Szacowanie wielkości wyników dla innych operacji	795
19.7.3. Zapis planu w pamięci podręcznej	796
19.7.4. Optymalizacja z wykorzystaniem pierwszych k wyników	796
19.8. Przykład optymalizacji zapytań w hurtowniach danych	796
19.9. Optymalizacja zapytań w bazach Oracle	799
19.9.1. Optymalizator fizyczny	799
19.9.2. Globalny optymalizator zapytań	799
19.9.3. Optymalizacja adaptacyjna	800
19.9.4. Przetwarzanie tablicowe	801
19.9.5. Wskazówki	801
19.9.6. Zarysy	802
19.9.7. Zarządzanie planami wykonywania instrukcji języka SQL	802
19.10. Semantyczna optymalizacji zapytań	803
19.11. Podsumowanie	804
Pytania powtórkowe	804
Ćwiczenia	805
Wybrane publikacje	806

IX. Przetwarzanie transakcji, sterowanie współbieżne i odtwarzanie baz danych

809

20. Wprowadzenie do problematyki i teorii przetwarzania transakcji	811
20.1. Wprowadzenie do problematyki przetwarzania transakcji	812
20.1.1. Systemy jedno- i wieloużytkownikowe	812
20.1.2. Transakcje, elementy baz danych, operacje odczytu i zapisu oraz buforu SZBD	813
20.1.3. Uzasadnienie potrzeby stosowania sterowania współbieżnego	815
20.1.4. Uzasadnienie potrzeby odtwarzania	818
20.2. Pojęcia dotyczące transakcji i systemu	819
20.2.1. Stany transakcji i dodatkowe operacje	819
20.2.2. Dziennik systemowy	821
20.2.3. Punkt zatwierdzenia transakcji	822
20.2.4. Strategie zastępowania bufora specyficzne dla SZBD	823
20.3. Pożądane właściwości transakcji	824
20.4. Charakteryzowanie harmonogramów na podstawie możliwości odtwarzania	825
20.4.1. Harmonogramy (historie) transakcji	825
20.4.2. Charakterystyka harmonogramów według możliwości odtwarzania	827

20.5. Charakterystyka harmonogramów według ich szeregowości	829
20.5.1. Harmonogramy szeregowe, nieszeregowe oraz konfliktowo-szeregowe	830
20.5.2. Sprawdzanie występowania szeregowości konfliktowej harmonogramu	834
20.5.3. Wykorzystywanie szeregowości do sterowania współbieżnego	837
20.5.4. Równowaga perspektywiczna i szeregowość perspektywiczna	839
20.5.5. Inne rodzaje równowagi harmonogramów	840
20.6. Obsługa transakcji w języku SQL	841
20.7. Podsumowanie	843
Pytania powtórkowe	844
Ćwiczenia	845
Wybrane publikacje	846
21. Techniki sterowania współbieżnego	847
21.1. Techniki blokowania dwufazowego dla celów sterowania współbieżnego	848
21.1.1. Rodzaje blokad i systemowe tabele blokad	848
21.1.2. Gwarantowanie szeregowości blokowania dwufazowego	853
21.1.3. Problem zakleszczenia i zagłodzenia	856
21.2. Sterowanie współbieżne w oparciu o uporządkowanie według znaczników czasu	860
21.2.1. Znaczniki czasu	860
21.2.2. Algorytm uporządkowania według znaczników czasu	860
21.3. Techniki wielowersyjnego sterowania współbieżnego	862
21.3.1. Technika wielowersyjna oparta na porządkowaniu według znaczników czasu	863
21.3.2. Wielowersyjne blokowanie dwufazowe z użyciem blokad certyfikujących	864
21.4. Sterowanie współbieżne z użyciem technik walidacyjnych (optymistycznych) i izolacji snapshotów	866
21.4.1. Walidacyjne (optymistyczne) sterowanie współbieżne	866
21.4.2. Sterowanie współbieżne oparte na izolacji snapshotów	868
21.5. Ziarnistość elementów danych i blokowanie z wieloma poziomami ziarnistości	869
21.5.1. Kwestie dotyczące poziomu ziarnistości w przypadku blokowania	869
21.5.2. Blokowanie z wieloma poziomami ziarnistości	870
21.6. Użycie blokad dla celów sterowania współbieżnego w przypadku indeksów	872
21.7. Inne kwestie związane ze sterowaniem współbieżnym	874
21.7.1. Wstawianie, usuwanie i rekordy fantomowe	875
21.7.2. Transakcje interaktywne	876
21.7.3. Zatrzaski	876
21.8. Podsumowanie	876
Pytania powtórkowe	877
Ćwiczenia	878
Wybrane publikacje	879
22. Techniki odtwarzania baz danych	881
22.1. Pojęcia związane z odtwarzaniem	882
22.1.1. Zarys problematyki odtwarzania i podział algorytmów odtwarzania na odrębne kategorie	882
22.1.2. Zapisywanie w pamięci podręcznej (buforowanie) bloków dyskowych	883
22.1.3. Rejestrowanie zapisów z wyprzedzeniem, technika zabierania oraz wymuszania	885
22.1.4. Punkty kontrolne w dzienniku systemowym oraz tworzenie przybliżonych punktów kontrolnych	887
22.1.5. Wycofywanie transakcji i wycofywanie kaskadowe	888
22.1.6. Działania transakcji niewpływające na bazy danych	890
22.2. Techniki odtwarzania NO-UNDO/REDO oparte na aktualizacjach odroczonej	890
22.3. Techniki odtwarzania oparte na aktualizacjach natychmiastowych	893

22.4. Stronicowanie z przesłaniem	895
22.5. Algorytm odtwarzania ARIES	897
22.6. Odtwarzanie w systemach wielu baz danych	901
22.7. Tworzenie kopii bezpieczeństwa bazy danych i odtwarzanie po awariach katastroficznych	902
22.8. Podsumowanie	903
Pytania powtórkowe	904
Ćwiczenia	905
Wybrane publikacje	908

X. Rozproszone bazy danych, systemy NOSQL i big data **911**

23. Zagadnienia z obszaru rozproszonych baz danych	913
23.1. Zagadnienia z obszaru rozproszonych baz danych	914
23.1.1. Co sprawia, że baza danych jest rozproszona?	914
23.1.2. Przezroczystość	915
23.1.3. Stabilność i dostępność	916
23.1.4. Skalowalność i odporność na podział	917
23.1.5. Autonomia	917
23.1.6. Zalety rozproszonych baz danych	917
23.2. Techniki fragmentacji, replikacji i alokacji danych w projekcie rozproszonej bazy danych	918
23.2.1. Fragmentacja danych i sharding	918
23.2.2. Replikacja i alokacja danych	921
23.2.3. Przykłady fragmentacji, alokacji i replikacji danych	922
23.3. Techniki sterowania współbieżnego i odtwarzania danych w rozproszonych bazach danych	925
23.3.1. Rozproszone sterowanie współbieżne oparte na wyróżnionej kopii danych	925
23.3.2. Rozproszone sterowanie współbieżne oparte na głosowaniu	927
23.3.3. Rozproszone odtwarzanie danych	927
23.4. Przegląd zarządzania transakcjami w rozproszonych bazach danych	928
23.4.1. Protokół zatwierdzania dwufazowego	929
23.4.2. Protokół zatwierdzania trójfazowego	929
23.4.3. Obsługa zarządzania transakcjami w systemie operacyjnym	930
23.5. Przetwarzanie zapytań i optymalizacja w rozproszonych bazach danych	930
23.5.1. Przetwarzanie zapytań rozproszonych	931
23.5.2. Koszty przesyłu danych w przetwarzaniu zapytań rozproszonych	931
23.5.3. Rozproszone przetwarzanie zapytań z użyciem złączeń częściowych	933
23.5.4. Dekompozycja zapytań i aktualizacji	934
23.6. Rodzaje rozproszonych systemów baz danych	937
23.6.1. Zarządzanie federacyjnymi systemami baz danych	938
23.7. Architektury rozproszonych baz danych	940
23.7.1. Architektura równoległa a rozproszona	940
23.7.2. Ogólna architektura czystych baz rozproszonych	942
23.7.3. Architektura federacyjnych baz danych	942
23.7.4. Przegląd trójwarstwowej architektury klient-serwer	944
23.8. Zarządzanie rozproszonym katalogiem	946
23.9. Podsumowanie	947
Pytania powtórkowe	948
Ćwiczenia	949
Wybrane publikacje	951

24. Bazy danych NOSQL i systemy składowania big data	955
24.1. Wprowadzenie do systemów NOSQL	955
24.1.1. Powstanie systemów NOSQL	955
24.1.2. Cechy systemów NOSQL	957
24.1.3. Kategorie systemów NOSQL	959
24.2. Twierdzenie CAP	960
24.3. Dokumentowe systemy NOSQL i baza MongoDB	961
24.3.1. Model danych z systemu MongoDB	962
24.3.2. Operacje CRUD w systemie MongoDB	965
24.3.3. Cechy systemu rozproszonego MongoDB	965
24.4. Magazyny NOSQL z parami klucz-wartość	967
24.4.1. Przegląd systemu DynamoDB	967
24.4.2. Rozproszony magazyn danych z parami klucz-wartość — Voldemort	968
24.4.3. Przykładowe inne magazyny z parami klucz-wartość	971
24.5. Kolumnowe systemy NOSQL	972
24.5.1. Model danych i wersjonowanie w systemie HBase	972
24.5.2. Operacje CRUD w systemie HBase	974
24.5.3. Zagadnienia związane ze składowaniem danych i systemem rozproszonym w HBase	974
24.6. Grafowe bazy NOSQL i system Neo4j	975
24.6.1. Model danych w systemie Neo4j	975
24.6.2. Język zapytań Cypher w systemie Neo4j	977
24.6.3. Cechy interfejsów i systemu rozproszonego w Neo4j	979
24.7. Podsumowanie	980
Pytania powtórkowe	981
Wybrane publikacje	982
25. Technologie z obszaru big data oparte na modelu MapReduce i systemie Hadoop	983
25.1. Czym jest big data?	986
25.2. Wprowadzenie do technologii MapReduce i Hadoop	988
25.2.1. Tło historyczne	988
25.2.2. Model MapReduce	989
25.2.3. Wersje Hadoopa	993
25.3. System HDFS	993
25.3.1. Wymagania wstępne związane z systemem HDFS	994
25.3.2. Architektura systemu HDFS	994
25.3.3. Operacje wejścia-wyjścia na plikach i zarządzanie replikami w systemie HDFS	996
25.3.4. Skalowalność systemu HDFS	997
25.3.5. Ekosystem Hadoopa	998
25.4. Model MapReduce: dodatkowe szczegóły	999
25.4.1. Środowisko uruchomieniowe MapReduce	999
25.4.2. Przykład: złączenia w modelu MapReduce	1002
25.4.3. Apache Hive	1006
25.4.4. Zalety technologii Hadoop i MapReduce	1008
25.5. Hadoop 2 (nazywany też YARN)	1009
25.5.1. Uzasadnienie powstania platformy YARN	1009
25.5.2. Architektura platformy YARN	1012
25.5.3. Inne platformy w YARN	1015
25.6. Ogólne omówienie	1017
25.6.1. Hadoop i MapReduce a równoległe relacyjne SZBD	1017
25.6.2. Big data w chmurach obliczeniowych	1019

25.6.3. Problemy z lokalnością danych i optymalizacja zasobów w aplikacjach z obszaru big data działających w chmurze	1021
25.6.4. YARN jako platforma usług z obszaru danych	1022
25.6.5. Wyzwania związane z technologiami z obszaru big data	1023
25.6.6. Przyszłość	1024
25.7. Podsumowanie	1026
Pytania powtórkowe	1027
Wybrane publikacje	1028

XI. Zaawansowane modele, systemy i zastosowania baz danych

1031

26. Rozszerzone modele danych: wprowadzenie do aktywnych, czasowych, przestrzennych, multimedialnych i dedukcyjnych baz danych	1033
26.1. Wyzwalacze i inne pojęcia związane z aktywnymi bazami danych	1035
26.1.1. Uogólniony model aktywnych baz danych i wyzwalacze w Oracle	1035
26.1.2. Projektowanie i implementacja aktywnych baz danych	1039
26.1.3. Przykładowe aktywne reguły poziomu wyrażenia w systemie STARBURST	1042
26.1.4. Możliwe zastosowania aktywnych baz danych	1044
26.1.5. Wyzwalacze w SQL-99	1044
26.2. Koncepcja czasowych baz danych	1045
26.2.1. Reprezentacja czasu, kalendarze i wymiary czasu	1046
26.2.2. Wprowadzenie czasu do relacyjnych baz danych z obsługą wersji krotek	1048
26.2.3. Czas w obiektowych bazach danych z obsługą wersji atrybutów	1053
26.2.4. Konstruowanie zapytań czasowych i język TSQL2	1055
26.2.5. Szeregi czasowe	1057
26.3. Zagadnienia z obszaru przestrzennych baz danych	1058
26.3.1. Wprowadzenie do przestrzennych baz danych	1058
26.3.2. Typy i modele danych przestrzennych	1059
26.3.3. Operatory i zapytania przestrzenne	1060
26.3.4. Indeksowanie danych przestrzennych	1062
26.3.5. Eksploracja danych przestrzennych	1063
26.3.6. Zastosowania danych przestrzennych	1065
26.4. Zagadnienia z obszaru multimedialnych baz danych	1065
26.4.1. Automatyczna analiza obrazów	1067
26.4.2. Wykrywanie obiektów na obrazach	1068
26.4.3. Semantyczne opisywanie obrazów	1069
26.4.4. Analizy danych audio	1069
26.5. Wprowadzenie do dedukcyjnych baz danych	1070
26.5.1. Przegląd dedukcyjnych baz danych	1070
26.5.2. Notacja języków Prolog i Datalog	1071
26.5.3. Notacja języka Datalog	1073
26.5.4. Forma klauzulowa i klauzule Horna	1074
26.5.5. Interpretacja reguł	1075
26.5.6. Programy w języku Datalog i ich bezpieczeństwo	1077
26.5.7. Zastosowanie operacji relacyjnych	1081
26.5.8. Wykonywanie zapytań nierekurencyjnych	1081
26.6. Podsumowanie	1083
Pytania powtórkowe	1085
Ćwiczenia	1086
Wybrane publikacje	1089

27. Wprowadzenie do wyszukiwania informacji i danych w internecie	1093
27.1. Zagadnienia z obszaru wyszukiwania informacji (WI)	1093
27.1.1. Wprowadzenie do wyszukiwania informacji	1094
27.1.2. Porównanie baz danych i systemów WI	1097
27.1.3. Krótka historia WI	1098
27.1.4. Tryby interakcji w systemach WI	1099
27.1.5. Ogólny proces WI	1100
27.2. Modele wyszukiwania	1101
27.2.1. Model logiczny	1101
27.2.2. Model oparty na przestrzeni wektorowej	1102
27.2.3. Model probabilistyczny	1104
27.2.4. Model semantyczny	1106
27.3. Typy zapytań w systemach WI	1107
27.3.1. Zapytania oparte na słowach kluczowych	1107
27.3.2. Zapytania logiczne	1107
27.3.3. Zapytania do wyszukiwania fraz	1108
27.3.4. Zapytania z określaniem odległości słów	1108
27.3.5. Zapytania z symbolami wieloznacznymi	1108
27.3.6. Zapytania w języku naturalnym	1109
27.4. Wstępne przetwarzanie tekstu	1109
27.4.1. Usuwanie słów pomijanych	1109
27.4.2. Stemming	1109
27.4.3. Korzystanie z tezaury	1110
27.4.4. Inne etapy przetwarzania: cyfry, myślniki, znaki przestankowe, wielkość znaków	1111
27.4.5. Wydobywanie informacji	1112
27.5. Indeksy odwrócone	1112
27.5.1. Wprowadzenie do systemu Lucene	1114
27.6. Miary oceny adekwatności wyników wyszukiwania	1115
27.6.1. Czułość i precyzja	1116
27.6.2. Średnia precyzja	1118
27.6.3. Krzywa czułość/precyzja	1118
27.6.4. Miara F	1118
27.7. Wyszukiwanie i analizy w sieci WWW	1119
27.7.1. Analizy danych internetowych i ich związki z WI	1119
27.7.2. Analizy struktury sieci WWW	1121
27.7.3. Analizowanie struktury odsyłaczy na stronach internetowych	1122
27.7.4. Analizy treści w sieci WWW	1123
27.7.5. Podejścia analizowania treści w sieci WWW	1125
27.7.6. Analizy użytkowania witryn	1126
27.7.7. Praktyczne zastosowania analiz użytkowania witryn	1128
27.8. Trendy w wyszukiwaniu informacji	1129
27.8.1. Wyszukiwanie fasetowe	1129
27.8.2. Wyszukiwanie społecznościowe	1130
27.8.3. Wyszukiwanie informacji w dialogach	1131
27.8.4. Probabilistyczne modelowanie tematu	1131
27.8.5. Systemy odpowiadania na pytania	1132
27.9. Podsumowanie	1135
Pytania powtórkowe	1136
Wybrane publikacje	1138
28. Elementy eksploracji danych	1141
28.1. Przegląd technologii eksploracji danych	1142
28.1.1. Eksploracja danych kontra hurtownie danych	1142
28.1.2. Eksploracja danych jako część procesu odkrywania wiedzy	1142

28.1.3. Cele eksploracji danych i odkrywania wiedzy	1143
28.1.4. Rodzaje wiedzy odkrywanej w procesie eksploracji danych	1145
28.2. Reguły asocjacyjne	1146
28.2.1. Model koszyka klienta supermarketu, poziom wsparcia i poziom ufności	1146
28.2.2. Algorytm Apriori	1148
28.2.3. Algorytm próbkujący	1150
28.2.4. Drzewa częstych wzorców i algorytm ich tworzenia	1151
28.2.5. Algorytm partycjonujący	1155
28.2.6. Pozostałe typy reguł asocjacyjnych	1156
28.2.7. Dodatkowe problemy związane z regułami asocjacyjnymi	1159
28.3. Klasyfikacja	1160
28.4. Grupowanie	1163
28.5. Strategie rozwiązywania pozostałych problemów związanych z eksploracją danych	1166
28.5.1. Odkrywanie wzorców sekwencyjnych	1166
28.5.2. Odkrywanie wzorców w szeregach czasowych	1167
28.5.3. Regresja	1167
28.5.4. Sieci neuronowe	1168
28.5.5. Algorytmy genetyczne	1169
28.6. Zastosowania technik eksploracji danych	1170
28.7. Komercyjne narzędzia eksploracji danych	1170
28.7.1. Interfejs użytkownika	1171
28.7.2. Interfejs programowy aplikacji	1171
28.7.3. Kierunki przyszłego rozwoju	1171
28.8. Podsumowanie	1173
Pytania powtórkowe	1173
Ćwiczenia	1174
Wybrane publikacje	1176
29. Przegląd hurtowni danych i rozwiązań OLAP	1177
29.1. Wprowadzenie, definicje i terminologia	1177
29.2. Właściwości hurtowni danych	1179
29.3. Modelowanie danych dla hurtowni danych	1181
29.4. Budowanie hurtowni danych	1187
29.5. Typowe funkcje hurtowni danych	1191
29.6. Hurtownie danych kontra perspektywy	1192
29.7. Trudności z implementowaniem hurtowni danych	1193
29.8. Podsumowanie	1194
Pytania powtórkowe	1195
Wybrane publikacje	1195

XII. Dodatkowe zagadnienia z obszaru baz danych: bezpieczeństwo

1197

30. Bezpieczeństwo w bazach danych	1199
30.1. Wprowadzenie do bezpieczeństwa baz danych	1200
30.1.1. Rodzaje zabezpieczeń	1200
30.1.2. Środki kontroli	1201
30.1.3. Bezpieczeństwo a administrator bazy danych	1203
30.1.4. Ochrona dostępu, konta użytkowników i audyty bazy danych	1204
30.1.5. Dane wrażliwe i typy ujawnień	1205
30.1.6. Związki między bezpieczeństwem a prywatnością informacji	1206

30.2. Dyspozycyjna kontrola dostępu polegająca na nadawaniu i odbieraniu uprawnień	1207
30.2.1. Typy uprawnień dyspozycyjnych	1207
30.2.2. Określanie uprawnień przy użyciu perspektyw	1208
30.2.3. Cofanie uprawnień	1209
30.2.4. Propagacja uprawnień poprzez opcję GRANT	1209
30.2.5. Przykład	1209
30.2.6. Określanie ograniczeń propagacji uprawnień	1211
30.3. Realizacja zabezpieczeń wielopoziomowych	
za pomocą obowiązkowej kontroli dostępu i zabezpieczeń opartych na rolach	1212
30.3.1. Porównanie dyspozycyjnego i obowiązkowego modelu bezpieczeństwa	1215
30.3.2. Kontrola dostępu oparta na rolach	1215
30.3.3. Zabezpieczenia oparte na etykietach i kontrola dostępu na poziomie wierszy	1217
30.3.4. Kontrola dostępu dla danych w formacie XML	1218
30.3.5. Polityki kontroli dostępu dla aplikacji sieciowych i mobilnych	1219
30.4. Wstrzykiwanie kodu w języku SQL	1220
30.4.1. Metody wstrzykiwania kodu w języku SQL	1221
30.4.2. Zagrożenia związane ze wstrzykiwaniem kodu w języku SQL	1222
30.4.3. Techniki ochrony przed wstrzykiwaniem kodu w języku SQL	1223
30.5. Wprowadzenie do bezpieczeństwa statystycznych baz danych	1224
30.6. Wprowadzenie do kontroli przepływu	1225
30.6.1. Ukryte kanały	1226
30.7. Szyfrowanie i infrastruktura klucza publicznego	1227
30.7.1. Szyfry DES i AES	1228
30.7.2. Algorytmy z kluczem symetrycznym	1228
30.7.3. Szyfrowanie kluczem publicznym (asymetrycznym)	1228
30.7.4. Podpis cyfrowy	1230
30.7.5. Certyfikaty cyfrowe	1230
30.8. Problemy z prywatnością i jej zachowywanie	1231
30.9. Wyzwania związane z utrzymaniem bezpieczeństwa baz danych	1232
30.9.1. Jakość danych	1232
30.9.2. Prawa własności intelektualnej	1232
30.9.3. Odporność baz danych	1233
30.10. Zabezpieczenia oparte na etykietach w bazach Oracle	1233
30.10.1. Technologia wirtualnych prywatnych baz danych	1234
30.10.2. Architektura zabezpieczeń opartych na etykietach	1234
30.10.3. Współdziałanie etykiet danych i etykiet użytkowników	1235
30.11. Podsumowanie	1236
Pytania powtórkowe	1237
Ćwiczenia	1239
Wybrane publikacje	1239

Dodatki **1241**

A. Alternatywne notacje modeli związków encji **1243**

B. Parametry dysków **1247**

C. Omówienie języka QBE **1251**

Bibliografia **1259**

Skorowidz **1319**

2

Architektura systemów baz danych i związane z nimi pojęcia

Architektura pakietów systemów zarządzania bazami danych ewoluowała od wczesnych systemów monolitycznych, w których cały pakiet oprogramowania SZBD był ściśle zintegrowanym systemem, do współczesnych pakietów tego typu, które składają się z modułów i są konstruowane w oparciu o model klient-serwer. Widoczny ostatnio wzrost ilości danych wymagających składowania doprowadził do powstania systemów baz danych o architekturze rozproszonej, składających się z tysięcy komputerów zarządzających magazynami danych. Ewolucja systemów zarządzania bazami danych odzwierciedla pojawiające się w technice komputerowej trendy, które sprawiły, że wielkie scentralizowane komputery zostały zastąpione setkami rozproszonych stacji roboczych i komputerów osobistych połączonych za pośrednictwem sieci komunikacyjnej z serwerami rozmaitych typów — serwerami WWW, serwerami baz danych, serwerami plików, serwerami aplikacji itp. Nowe środowiska **chmur obliczeniowych** obejmują tysiące dużych serwerów zarządzających tzw. **big data** na potrzeby użytkowników internetu.

W podstawowej architekturze systemu zarządzania bazą danych typu klient-serwer funkcjonalność tego systemu jest dzielona pomiędzy dwa typy modułów¹. **Moduł klienta** jest zwykle projektowany w taki sposób, aby możliwe było jego uruchamianie w urządzeniach mobilnych, na stacjach roboczych lub komputerach osobistych. Moduły klienta są zwykle używane do obsługi aplikacji wykorzystujących bazę danych oraz do udostępniania odpowiednich interfejsów. Oznacza to, że tak naprawdę to moduł klienta obsługuje działania użytkownika na bazie danych i udostępnia mu przyjazny interfejs — np. aplikację na urządzenia mobilne albo oparty na formularzach lub menu graficzny interfejs użytkownika (ang. *Graphical User Interface* — *GUI*) w komputerach osobistych. Drugi rodzaj modułów — tzw. **moduły serwera** — obsługuje zazwyczaj przechowywanie danych, operacje dostępu do danych, operacje przeszukiwania danych i inne, podobne funkcje. Architekturę typu klient-serwer omówimy bardziej szczegółowo w podrozdziale 2.5. Wcześniej musimy poświęcić chwilę na przestudiowanie podstawowych zagadnień, które umożliwią nam lepsze zrozumienie architektur współczesnych baz danych.

W tym rozdziale zaprezentujemy terminologię i podstawowe pojęcia, które będą wykorzystywane w książce. Rozpoczniemy (w podrozdziale 2.1) od omówienia modeli danych oraz zdefiniowania pojęć schematów i egzemplarzy, które mają zasadnicze znaczenie podczas rozważań na temat systemów baz danych. Następnie, w podrozdziale 2.2 omówimy

¹ W podrozdziale 2.5 przekonamy się, że istnieją różne odmiany tej prostej, *dwuwarstwowej* architektury klient-serwer.

trójwarstwową architekturę systemów zarządzania bazami danych (ang. *three-schema DBMS*) oraz niezależność danych — w ten sposób dojdziemy do problemu oczekiwanych działań systemu zarządzania bazą danych z perspektywy jej użytkownika. W podrozdziale 2.3 opisujemy typy interfejsów i języków oferowanych przez większość współczesnych systemów zarządzania bazami danych. Podrozdział 2.4 poświęcono omówieniu środowiska oprogramowania systemu bazy danych. W podrozdziale 2.5 zawarto przegląd rozmaitych typów architektur typu klient-serwer. I wreszcie w podrozdziale 2.6 zaprezentowaliśmy klasyfikację typów pakietów systemów zarządzania bazami danych. Podrozdział 2.7 zawiera podsumowanie tego rozdziału.

Materiał zawarty w podrozdziałach od 2.4 do 2.6 dotyczy bardziej szczegółowych zagadnień, które nie muszą być omawiane w trakcie podstawowego kursu wprowadzającego w świat baz danych.

2.1. Modele danych, schematy i egzemplarze

Jedną z podstawowych właściwości rozwiązań opartych na bazach danych jest to, że ich użytkownicy korzystają z abstrakcji danych. **Abstrakcja danych** oznacza ukrywanie szczegółów struktury i przechowywania danych oraz podkreślanie najważniejszych ich aspektów, co pozwala lepiej zrozumieć informacje. Jedną z głównych cech podejścia wykorzystującego bazy jest zapewnianie abstrakcji danych, dzięki czemu różni użytkownicy mogą korzystać z nich na preferowanym poziomie szczegółowości. **Model danych** — czyli zbiór pojęć, które można wykorzystywać do opisywania struktury bazy danych — zapewnia środki niezbędne do osiągnięcia oczekiwanego poziomu abstrakcji². Przez *strukturę bazy danych* rozumiemy typy danych, związki i ograniczenia dotyczące danych. Większość modeli danych zawiera także zbiór **podstawowych operacji**, które umożliwiają otrzymywanie i aktualizowanie informacji zawartych w bazie danych.

Poza podstawowymi operacjami zdefiniowanymi w modelu danych, coraz bardziej popularne staje się dołączanie do tego modelu także elementów określających **aspekty dynamiczne i zachowania** aplikacji bazodanowych. Dzięki temu projektanci baz danych mogą stosunkowo łatwo określać zbiory poprawnych **operacji definiowanych przez użytkowników**, które będą bez problemów wykonywane na obiektach bazy danych³. Przykładem takich operacji definiowanych przez użytkowników może być procedura `OBLICZ_ŚROC`, którą można stosować dla obiektów przechowywanych w pliku `STUDENT`. Z drugiej strony, uniwersalne operacje wstawiania, usuwania, modyfikowania i odczytywania dowolnych rodzajów obiektów są zwykle dołączane do *podstawowych operacji modelu danych*. Elementy definiujące zachowania są nie tylko zasadniczym elementem obiektowych

² Słowo *model* jest niekiedy wykorzystywane w odniesieniu do konkretnego opisu bazy danych lub do schematu — przykładowo, można się spotkać z wyrażeniem *model danych marketingowych*. W tej książce nie będziemy używać słowa *model* w tym znaczeniu.

³ Dołączanie elementów opisujących zachowanie baz danych odzwierciedla kierunek rozwoju systemów tego typu, który przewiduje, że działania związane z projektowaniem baz danych i projektowaniem oprogramowania z czasem zostaną połączone w zbiór tych samych czynności. Określanie zachowania oprogramowania tradycyjnie było elementem projektowania oprogramowania.

modeli danych (patrz rozdział 12.), ale także zostały z powodzeniem wprowadzone do bardziej tradycyjnych modeli danych. Przykładowo, modele obiektowo-relacyjne (patrz rozdział 12.) rozszerzają tradycyjny model relacyjny między innymi o elementy tego typu. W podstawowym modelu relacyjnym możliwe jest dodawanie zachowań do relacji za pomocą trwałych modułów składowanych, nazywanych zwykle procedurami składowanymi (patrz rozdział 10.).

2.1.1. Kategorie modeli danych

Istnieje wiele różnych modeli danych, które możemy skategoryzować np. według elementów wykorzystywanych do opisywania struktury bazy danych. Przykładowo, **wysokopoziomowe** i **konceptyjne modele danych** opierają się na rozwiązaniach, które są zbliżone do abstrakcyjnego sposobu postrzegania danych przez wielu użytkowników, natomiast **niskopoziomowe** i **fizyczne modele danych** opierają się na szczegółowych opisach metod przechowywania danych na dysku komputera (zwykle na dyskach magnetycznych). Niskopoziomowe modele danych są przeznaczone przede wszystkim dla specjalistów w zakresie sprzętu komputerowego, nie dla typowych użytkowników końcowych systemów baz danych. Pomiedzy wspomnianą parą skrajnych rozwiązań istnieje klasa **reprezentacyjnych** (lub **implementacyjnych**⁴) **modeli danych**, które z jednej strony opierają się na pojęciach zrozumiałych dla przeciętnego użytkownika końcowego, ale jednocześnie nie odbiegają znacząco od sposobu organizowania danych na fizycznym nośniku w komputerze. Reprezentacyjne modele danych ukrywają co prawda niektóre szczegóły związane z przechowywaniem danych, ale mogą być implementowane w systemach komputerowych w sposób bezpośredni.

Konceptyjne modele danych opierają się na elementach takich jak encje, atrybuty czy związki. Pojedyncza **encja** reprezentuje obiekt lub pojęcie z mini-świata (np. pracownika lub projekt), które zostało opisane w bazie danych. **Atrybut** reprezentuje pewną interesującą własność, która dodatkowo opisuje daną encję — może to być np. nazwisko lub pensja pracownika. **Związek** pomiędzy dwoma (lub więcej) encjami reprezentuje łączące je powiązanie — przykładowo, może to być związek *pracuje nad*, który łączy encje reprezentujące pracownika i projekt. W rozdziale 3. zaprezentujemy model związków encji (ang. *Entity-Relationship*, w skrócie *ER*), który jest popularnym wysokopoziomowym konceptyjnym modelem danych. W rozdziale 4. omówimy dodatkowe elementy charakterystyczne dla konceptyjnego modelowania danych, w tym generalizację, specjalizację oraz kategorie (typy unii).

W tradycyjnych, komercyjnych systemach zarządzania bazami danych wykorzystuje się najczęściej reprezentacyjne lub implementacyjne modele danych. Takie modele obejmują zarówno popularny obecnie **relacyjny model danych**, jak i bardziej tradycyjne, **sieciowe** i **hierarchiczne modele danych**, które były powszechnie stosowane w przeszłości. Część 3. tej książki poświęcono relacyjnemu modelowi danych, charakterystycznym dla niego operacjom i językom, a także niektórym technikom programowania aplikacji operujących na relacyjnych bazach danych. Standard języka SQL dla relacyjnych baz danych opisano w rozdziałach 6. i 7. Reprezentacyjne modele danych reprezentują dane za

⁴ Określenie *implementacyjny model danych* nie jest standardowym pojęciem. Wprowadziliśmy je tutaj na potrzeby opisu modeli danych dostępnych w komercyjnych systemach bazodanowych.

pomocą struktur rekordów, stąd czasami są nazywane **modelami danych opartymi na rekordach**.

Obiektowe modele danych należy traktować jak zupełnie nową rodzinę wysokopoziomowych implementacyjnych modeli danych, które są nieco bliższe koncepcyjnym modelom danych. Ogólne właściwości obiektowych baz danych i standardu *ODMG* (ang. *Object Data Management Group*) zaproponowanego przez grupę o tej samej nazwie omówimy w rozdziale 12. Obiektowe modele danych są często wykorzystywane także w roli wysokopoziomowych modeli koncepcyjnych (w szczególności dotyczy to dziedziny inżynierii oprogramowania).

Fizyczne modele danych opisują sposób przechowywania danych na komputerze w postaci plików, zatem reprezentują takie informacje jak formaty rekordów, uporządkowanie rekordów czy ścieżki dostępu. **Ścieżka dostępu** jest strukturą, która zwiększa efektywność operacji przeglądania bazy danych w poszukiwaniu konkretnych rekordów (np. dzięki indeksowaniu lub mieszaniu). Techniki fizycznego przechowywania danych i struktury dostępowe omówimy w rozdziałach 16. i 17. **Indeks** to przykładowa ścieżka umożliwiająca bezpośredni dostęp do danych za pomocą pojęcia z indeksu lub słowa kluczowego. Taka struktura przypomina indeks z końcowej części tej książki, przy czym może być uporządkowana liniowo, hierarchicznie (za pomocą struktury drzewiastej) lub w jeszcze inny sposób.

Inną kategorią są **samoopisujące się modele danych**. W systemach opartych na takich modelach opis danych jest połączony z ich wartościami. W tradycyjnych systemach SZBD opis (schemat) jest oddzielony od danych. Modele z tej kategorii to **XML** (rozdział 12.), a także liczne **magazyny danych typu klucz-wartość** i **systemy NOSQL** (rozdział 24.), opracowane ostatnio na potrzeby zarządzania big data.

2.1.2. Schematy, egzemplarze i stany baz danych

W każdym modelu danych bardzo ważne jest rozróżnienie *opisu* bazy danych od *samej bazy danych*. Opis bazy danych jest najczęściej nazywany **schematem bazy danych** — w założeniu taki schemat powstaje podczas projektowania bazy danych i nie powinien ulegać częstym zmianom⁵. W większości modeli danych istnieją pewne konwencje prezentowania schematów w postaci diagramów. Graficzna prezentacja schematu jest nazywana **diagramem schematu**. Na rysunku 2.1 zademonstrowano diagram schematu dla bazy danych zaprezentowanej w poprzednim rozdziale na rysunku 1.2 — diagram przedstawia jedynie strukturę poszczególnych typów rekordów, zatem nie obejmuje rzeczywistych egzemplarzy tych rekordów. Każdy obiekt w tego typu schemacie (np. `STUDENT` lub `PRZEDMIOT`) nazywamy **konstrukcją schematu**.

Diagram schematu przedstawia tylko *niektóre aspekty* reprezentowanego schematu bazy danych, w tym nazwy typów rekordów i elementów danych oraz niektóre rodzaje ograniczeń. Pozostałe aspekty schematu bazy danych w ogóle nie są wyrażane na tego

⁵ Zmiany schematów baz danych są często nieuniknione w przypadku zmian wymagań leżących u podstaw danego rozwiązania. Nowsze systemy baz danych oferują nawet specjalne operacje stworzone z myślą o modyfikowaniu schematów.

typu diagramach; przykładowo, na rysunku 2.1 nie są widoczne ani typy danych poszczególnych elementów danych, ani związki łączące poszczególne pliki. Na diagramach schematów nie jest reprezentowanych wiele typów ograniczeń. Warto pamiętać, że ograniczenia w postaci „studenci informatyki muszą zdać egzamin z przedmiotu *INF1310* zanim zostanie im zaliczony drugi rok” są dosyć trudne do reprezentowania w postaci graficznej.



RYSunEK 2.1. Diagram schematu dla bazy danych przedstawionej na rysunku 1.2

Rzeczywiste informacje przechowywane w bazie danych mogą się dosyć często zmieniać. Przykładowo, zawartość bazy danych zaprezentowanej na rysunku 1.2 zmienia się za każdym razem, gdy dodajemy nowego studenta lub wpisujemy nową ocenę dla istniejącego studenta. Informacje przechowywane w bazie danych w konkretnym momencie czasu są nazywane **stanem bazy danych** lub **migawką bazy danych (snapshot)**. Stan bazy danych jest także nazywany *bieżącym* zbiorem zawartych w niej **wystąpień** lub **egzemplarzy**. W danym stanie bazy danych każda konstrukcja schematu musi zawierać własny bieżący *zbiór wystąpień*; przykładowo, konstrukcja **STUDENT** będzie zawierała zbiór encji (rekordów) reprezentujących pojedynczych studentów, który będzie stanowił jej egzemplarze. Wiele stanów baz danych można konstruować w taki sposób, aby odpowiadały konkretnym schematom baz danych. Za każdym razem, gdy dodajemy lub usuwamy rekord albo przynajmniej zmieniamy wartość elementu danych w istniejącym rekordzie, zmieniamy stan bazy danych — a więc wprowadzamy bazę danych w nowy stan.

Rozróżnienie pomiędzy schematem bazy danych a stanem bazy danych jest bardzo ważne. Kiedy **definiujemy** nową bazę danych, określamy w systemie zarządzania bazą danych jedynie jej schemat. Na tym etapie baza danych znajduje się w tzw. *pustym stanie* (nie zawiera żadnych informacji). Bazę danych wprowadzamy w *stan początkowy* w momencie, w którym po raz pierwszy **wypełniamy** ją początkowymi danymi. Od tej pory każda zastosowana dla naszej bazy danych operacja aktualizacji powoduje, że otrzymujemy inny stan bazy danych. Warto pamiętać, że w każdym momencie można wyznaczyć dla bazy danych jej *stan bieżący*⁶. Za zapewnienie, aby każdy stan bazy danych był **stanem pra-**

⁶ Stan bieżący bazy danych jest także nazywany *bieżącą migawką bazy danych*. Nazywano go też egzemplarzem bazy danych, jednak określenie *egzemplarz* wolimy stosować do poszczególnych rekordów.

widłowym (zgodnym z ograniczeniami i strukturą ze schematu), odpowiada po części system zarządzania bazą danych. Oznacza to, że szczególnie ważne jest zdefiniowanie na potrzeby systemu zarządzania bazą danych jej prawidłowego schematu — schemat bazy danych musi więc być projektowany z wyjątkową ostrożnością. System zarządzania bazą danych przechowuje konstrukcje zdefiniowanego schematu wraz z ograniczeniami (nazywanymi łącznie **metadany**) w swoim katalogu, dzięki czemu oprogramowanie systemu zarządzania bazą danych może się do takiego schematu odwoływać za każdym razem, gdy jest to konieczne. Schemat bazy danych jest niekiedy nazywany **intensją**, natomiast stan bazy danych jest nazywany ekstensją (**rozwinięciem**) określonego schematu.

Chociaż (jak już wspominaliśmy) schemat bazy danych nie powinien ulegać częstym zmianom, nierzadko okazuje się, że modyfikacje wprowadzone w wymaganiach wymuszają zastosowanie zmian także w schemacie. Przykładowo, możemy zdecydować, że każdy z rekordów danego pliku musi dodatkowo zawierać jeszcze jeden element danych — taka zmiana mogłaby polegać np. na dodaniu do schematu pliku `STUDENT` (patrz rysunek 2.1) elementu danych `DataUrodzenia`. Takie działania są niekiedy nazywane **ewolucją schematu**. Większość współczesnych systemów zarządzania bazami danych oferuje pewne operacje ułatwiające przeprowadzanie ewolucji danych, gdy baza już działa.

2.2. Trójwarstwowa architektura i niezależność danych

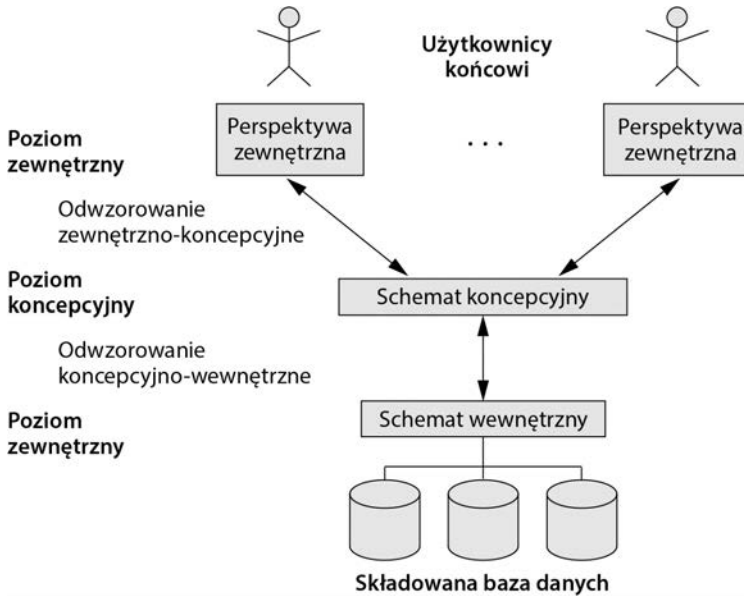
Oto trzy z czterech wymienionych w podrozdziale 1.3 ważnych cech rozwiązań opartych na bazach danych: (1) wykorzystywanie katalogu do przechowywania opisu (schematu) bazy danych, (2) oddzielenie programów od danych (tzw. niezależność programu od danych i niezależność programu od operacji) oraz (3) obsługa wielu perspektyw użytkowników. W tym podrozdziale omówimy jedną z popularnych architektur systemów baz danych, powszechnie znaną jako **architektura trójwarstwowa**⁷, która została zaproponowana z myślą o ułatwieniu uzyskiwania (i wizualnego przedstawiania) tych własności w praktyce. W dalszej części tego podrozdziału omówimy pojęcia związane z niezależnością danych.

2.2.1. Architektura trójwarstwowa

Celem opracowania architektury trójwarstwowej (patrz rysunek 2.2) było oddzielenie aplikacji użytkownika od fizycznej bazy danych. Architektura trójwarstwowa przewiduje możliwość definiowania schematów na następujących trzech poziomach:

- (1) **Poziom wewnętrzny** zawiera **wewnętrzny schemat**, który opisuje fizyczną strukturę przechowywania bazy danych. Wewnętrzny schemat wykorzystuje fizyczny model danych i opisuje wszystkie szczegóły związane z przechowywaniem informacji zawartej w bazie danych oraz z jej ścieżkami dostępu.

⁷ Architektura trójwarstwowa jest także nazywana *architekturą ANSI/SPARC* od skrótów organizacji, która to rozwiązanie zaproponowała (Tsichritzis i Klug, 1978).



RYSUNEK 2.2. Architektura trójwarstwowa

- (2) **Poziom koncepcyjny** zawiera **schemat koncepcyjny**, który opisuje strukturę całej bazy danych na potrzeby społeczności końcowych użytkowników bazy danych. Schemat koncepcyjny ukrywa szczegóły fizycznych struktur przechowywania danych i koncentruje się na opisywaniu encji, typów danych, związków, operacji użytkownika oraz ograniczeń. Do opisywania schematów koncepcyjnych podczas implementowania systemu bazy danych wykorzystuje się zwykle reprezentacyjny model danych. *Implementacyjny schemat koncepcyjny* opiera się często na *koncepcyjnym projekcie schematu* w wysokopoziomowym modelu danych.
- (3) **Poziom zewnętrzny** (nazywany także **poziomem perspektyw**) zawiera wiele **schematów zewnętrznych** lub **schematów użytkownika**. Każdy taki schemat zewnętrzny opisuje tylko tę część bazy danych, która znajduje się w obszarze zainteresowań konkretnej grupy użytkowników, i ukrywa przed tą grupą użytkowników pozostałe części bazy danych. Podobnie jak w poprzednim przypadku, każdy schemat zewnętrzny jest zazwyczaj implementowany w oparciu o reprezentacyjny model danych, często bazujący na zewnętrznym projekcie schematu w wysokopoziomowym modelu danych.

Architektura trójwarstwowa jest wygodnym narzędziem, za pomocą którego użytkownik może łatwo wizualizować poziomy schematów wykorzystywanego systemu bazy danych. Większość systemów zarządzania bazami danych nie oddziela tych trzech poziomów od siebie całkowicie — obsługuje architekturę tego typu tylko do pewnego stopnia. Niektóre starsze systemy zarządzania bazami danych mogą dołączać do schematów koncepcyjnych także szczegóły warstwy fizycznej. Trójwarstwowa architektura ANSI zajmuje ważne miejsce w rozwoju technologii bazodanowych, ponieważ wyraźnie odgranicza w kontekście projektowania baz poziomy zewnętrzny (użytkowników), koncepcyjny (bazy danych) i wewnętrzny (składowania danych). Nawet dziś ta architektura

znajduje zastosowania w projektowaniu SZBD. W większości systemów SZBD, które obsługują perspektywy użytkownika, schematy zewnętrzne są definiowane w oparciu o ten sam model danych, na bazie którego opisano schemat poziomu koncepcyjnego (w relacyjnych SZBD, takich jak Oracle lub SQL Server, używany jest do tego SQL).

Warto pamiętać, że wymienione trzy poziomy schematów stanowią wyłącznie *opisy* właściwych danych; informacje są zapisywane jedynie na poziomie fizycznym. W architekturze trójwarstwowej każda grupa użytkowników odwołuje się wyłącznie do własnego schematu zewnętrznego. Oznacza to, że system zarządzania bazą danych musi przekształcić żądanie zdefiniowane na schemacie zewnętrznym w odpowiednie żądanie na schemacie koncepcyjnym, po czym przekształcić otrzymany wynik w prawidłowe żądanie na schemacie wewnętrznym, które umożliwi przetwarzanie rzeczywistych informacji przechowywanych w bazie danych. Jeśli żądanie dotyczy odczytania wybranych informacji zawartych w bazie danych, dane wyciągnięte z bazy muszą zostać ponownie sformatowane do postaci odpowiadającej zewnętrznej perspektywie użytkownika. Zachodzące pomiędzy wspomnianymi trzema poziomami procesy przekształcania żądań i uzyskanych wyników są nazywane **odwzorowaniami**. Tego typu operacje mogą być kosztowne czasowo, co powoduje, że niektóre SZBD (w szczególności te, które w założeniu mają obsługiwać niewielkie bazy danych) w ogóle nie obsługują zewnętrznych perspektyw. Jednak nawet w takich systemach wykonywanie pewnych operacji odwzorowywania okazuje się niezbędne podczas przekształcania żądań pomiędzy poziomem koncepcyjnym a poziomem wewnętrznym.

2.2.2. Niezależność danych

Omówioną przed chwilą architekturę trójwarstwową możemy wykorzystać podczas omawiania pojęcia **niezależności danych**, które można zdefiniować jako możliwość modyfikowania schematu na jednym poziomie systemu bazy danych bez konieczności wprowadzania zmian w schemacie znajdującym się na kolejnym (wyższym) poziomie. Możemy zdefiniować dwa typy niezależności danych:

- (1) **Logiczna niezależność danych** oznacza możliwość zmiany schematu koncepcyjnego bez konieczności modyfikowania schematów zewnętrznych ani aplikacji. Zmiana schematu koncepcyjnego może mieć na celu rozbudowę bazy danych (przez dodanie nowego typu rekordu lub nowego elementu danych), modyfikację ograniczeń lub odchudzenie bazy danych (przez usunięcie typu rekordu lub elementu danych). W tym ostatnim przypadku schematy zewnętrzne odwołujące się wyłącznie do danych, które nie są usuwane i pozostają w bazie danych, w ogóle nie powinny podlegać zmianom. Przykładowo, schemat zewnętrzny z rysunku 1.5(a) nie powinien ulec zmianie na skutek zaprezentowanych na rysunku 1.6(a) modyfikacji w pliku RAPORT_OCEN (względem stanu przedstawionego na rysunku 1.2). System zarządzania bazą danych, który zapewnia logiczną niezależność danych, musi jedynie odpowiednio zmodyfikować definicję perspektywy i właściwe reguły odwzorowywania. Po logicznej reorganizacji schematu koncepcyjnego programy aplikacji, które odwołują się do konstrukcji schematu zewnętrznego, mogą pracować tak samo jak wcześniej. Ewentualne zmiany ograniczeń mogą być stosowane dla schematu koncepcyjnego bez wpływu ani na schematy zewnętrzne, ani na aplikacje.

- (2) **Fizyczna niezależność danych** oznacza możliwość zmiany schematu wewnętrznego bez konieczności modyfikowania schematu koncepcyjnego. Oznacza to, że konieczność zmian nie dotyczy także schematów zewnętrznych. Zmiany w schematach wewnętrznych mogą się natomiast okazać niezbędne z uwagi na potrzebę reorganizacji niektórych plików fizycznych (np. przez stworzenie dodatkowych struktur dostępu) w celu poprawienia wydajności operacji odczytywania lub aktualizacji danych. Jeśli po wprowadzeniu zmian baza danych zawiera dokładnie takie same dane jak przedtem, modyfikowanie schematu koncepcyjnego nie powinno być konieczne. Przykładowo, dodanie ścieżki dostępu, która ma poprawić szybkość wyszukiwania żądanych rekordów z pliku KURS (patrz rysunek 1.2) według wartości elementów danych *Semestr* i *Rok*, nie powinno wymagać modyfikowania takich zapytań jak „wymień wszystkie kursy omawiane w semestrze jesiennym roku 1998”, chociaż dzięki nowej ścieżce dostępu wspomniane zapytanie będzie szybciej wykonywane przez system zarządzania bazą danych.

Fizyczna niezależność danych występuje w większości środowisk bazodanowych i plikowych, w których fizyczne szczegóły (takie jak dokładna lokalizacja danych na dysku oraz sprzętowe aspekty kodowania, rozmieszczania, kompresji, podziału i scalania rekordów) są ukryte przed użytkownikami. Aplikacje nie znają tych szczegółów. Trudniej jest osiągnąć logiczną niezależność danych, ponieważ ma ona umożliwiać wprowadzanie zmian struktury i ograniczeń bez wpływu na aplikacje, co jest dużo bardziej restrykcyjnym wymogiem.

Katalog każdego wielowarstwowego SZBD musi być stale rozszerzany w taki sposób, aby zawierał informacje niezbędne do odwzorowywania żądań i danych pomiędzy różnymi poziomami. Systemy zarządzania bazami danych wykorzystują do takiego odwzorowywania dodatkowe oprogramowanie, które odwołuje się do odpowiednich reguł w katalogach. Mamy więc do czynienia z niezależnością danych, ponieważ zmiana schematu na jednym poziomie nie wiąże się z koniecznością zmiany schematu na kolejnym, wyższym poziomie — niezbędne modyfikacje należy jedynie wprowadzić w regułach *odwzorowywania* na obu poziomach. Oznacza to, że aplikacje odwołujące się do schematu na wyższym poziomie w ogóle nie muszą być zmieniane.

2.3. Języki i interfejsy baz danych

W podrozdziale 1.4 omówiliśmy różne kategorie użytkowników końcowych wykorzystujących systemy zarządzania bazami danych. Takie systemy muszą oczywiście udostępniać odpowiednie języki i interfejsy dla każdej z tych kategorii. W tym podrozdziale omówimy rozmaite typy języków i interfejsów oferowanych poszczególnym kategoriom użytkowników przez systemy zarządzania bazami danych.

2.3.1. Języki systemów zarządzania bazami danych

Kiedy już zakończy się faza projektowania bazy danych i zostanie wybrany system zarządzania bazą danych, w którym nowa baza danych będzie implementowana, najważniejszym zadaniem jest opracowanie koncepcyjnego i wewnętrznego schematu tej bazy danych

oraz reguł odwzorowywania pomiędzy tymi poziomami. W wielu systemach zarządzania bazami danych, w których nie ma ścisłego rozgraniczenia pomiędzy utrzymywanymi poziomami, do definiowania obu schematów przez administratorów i projektantów baz danych wykorzystuje się jeden język, nazywany **językiem definicji danych** (ang. *Data Definition Language* — *DDL*). Takie systemy zarządzania bazami danych zawierają specjalne kompilatory języka DDL, które odpowiadają za przetwarzanie instrukcji opisujących konstrukcje schematu oraz za umieszczanie takiego przetworzonego opisu w katalogu SZBD.

W tych systemach zarządzania bazami danych, w których jest utrzymywany ścisły podział pomiędzy poziomem koncepcyjnym a poziomem wewnętrznym, język DDL wykorzystuje się wyłącznie do określania schematu koncepcyjnego. Do określania schematu wewnętrznego wykorzystywany jest wówczas inny język, nazywany **językiem definicji składowania** (ang. *Storage Definition Language* — *SDL*). Reguły odwzorowywania pomiędzy tymi dwoma schematami mogą być definiowane za pomocą odpowiednich instrukcji jednego z tych języków. Obecnie w większości relacyjnych SZBD *nie występuje konkretny język* używany jako SDL. Schemat wewnętrzny jest definiowany za pomocą funkcji, parametrów i specyfikacji dotyczących składowania plików. Administratorzy baz danych mogą dzięki temu wybierać sposoby indeksowania i odwzorowywania danych na mechanizmy ich przechowywania. Prawdziwa architektura trójwarstwowa będzie oczywiście wymagała jeszcze jednego języka — **języka definicji perspektyw** (ang. *View Definition Language* — *VDL*), za pomocą którego projektant lub administrator bazy danych będzie mógł określać perspektywy użytkownika wraz z ich odwzorowaniami do schematu koncepcyjnego — jednak w większości systemów zarządzania bazami danych *do definiowania schematu koncepcyjnego i zewnętrznego wykorzystuje się język DDL*. W relacyjnych SZBD jako VDL stosowany jest SQL, używany do definiowania **perspektyw** użytkowników lub aplikacji za pomocą wcześniej przygotowanych zapytań (patrz rozdziały 6. i 7.).

Kiedy już schematy bazy danych zostaną prawidłowo skompilowane, a sama baza danych zostanie wypełniona właściwymi danymi, użytkownicy muszą jeszcze otrzymać jakieś mechanizmy, które umożliwią im operowanie na gotowej bazie danych. Typowe działania w tym zakresie obejmują odczytywanie, wstawianie, usuwanie i modyfikowanie danych. W tym celu systemy zarządzania bazami danych udostępniają odpowiedni zbiór operacji lub tzw. **język manipulowania danymi** (ang. *Data Manipulation Language* — *DML*).

We współczesnych systemach zarządzania bazami danych wymienione przed chwilą rodzaje języków zwykle *nie są od siebie ściśle oddzielane* — zamiast tego, stosuje się jeden uniwersalny, zintegrowany język, który zawiera konstrukcje niezbędne do definiowania schematu koncepcyjnego, do definiowania perspektyw oraz do operowania na danych. Jedynie język definicji składowania jest zwykle wyodrębniany, ponieważ wykorzystuje się go do definiowania fizycznych struktur przechowywania danych głównie po to, aby poprawić wydajność systemu bazy danych, za co zwykle odpowiada administrator bazy danych. Typowym przykładem wspomnianego wszechstronnego języka bazy danych jest stosowany w relacyjnych bazach danych język SQL (patrz rozdziały 6. i 7.), który nie tylko stanowi połączenie języków DDL, VDL i DML, ale także obejmuje instrukcje dla specyfikacji ograniczeń, modyfikowania schematu i wielu innych zadań. Wczesne wersje SQL-a zawierały język SDL, jednak w pewnym momencie zarzucono pomysł umieszczenia tego języka w tej formie w SQL-u i pozostawiono wyłącznie obsługę poziomu koncepcyjnego i zewnętrznego.

Istnieją dwa główne typy języków manipulowania danymi (DML). **Wysokopoziomowy (nieproceduralny)** język DML może być wykorzystywany do stosunkowo związłego definiowania skomplikowanych operacji na bazie danych. Wiele systemów zarządzania bazami danych obsługuje zarówno te konstrukcje wysokopoziomowego języka DML, które zostaną wpisane przez użytkownika w odpowiednim terminalu, jak i te, które programista osadzi w kodzie uniwersalnego języka programowania. W tym drugim przypadku konstrukcje języka DML muszą być tak oznaczone w kodzie programu, aby prekompilator mógł je wyodrębnić i przekazać do przetworzenia przez system zarządzania bazą danych. **Niskopoziomowy (proceduralny)** język DML *musi* być osadzany w kodzie napisanym w uniwersalnych językach programowania. Język DML tego typu jest zwykle wykorzystywany do odczytywania z bazy danych pojedynczych rekordów lub obiektów i ich odrębnego przetwarzania. Oznacza to, że odczytywanie i przetwarzanie poszczególnych rekordów należących do całego zbioru wymaga użycia konstrukcji (np. pętli) wykorzystywanego języka programowania. Z tego powodu niskopoziomowe języki DML są często nazywane językami typu **record-at-a-time**. Wysokopoziomowe języki DML, w tym SQL, mogą określać i odczytywać wiele rekordów za pomocą pojedynczej konstrukcji i w związku z tym są nazywane językami typu **set-at-a-time** lub **set-oriented**. Zapytanie zdefiniowane w wysokopoziomowym języku DML zwykle określa tylko to, *które* dane mają zostać odczytane, nie określa natomiast *sposobu* ich odczytania — takie języki są w związku z tym często nazywane językami **deklaratywnymi**.

W sytuacji, gdy polecenia języka DML (niezależnie od tego, czy jest to język wysokopoziomowy, czy niskopoziomowy) są osadzane w uniwersalnym języku programowania, język ten jest nazywany **językiem nadrzędnym**, natomiast język DML jest nazywany **podjęzykiem danych**⁸. Z drugiej strony, wysokopoziomowy język DML wykorzystywany przez użytkownika w sposób odrębny jest nazywany **językiem zapytań**. Generalnie, zarówno polecenia odczytywania, jak i polecenia aktualizacji wysokopoziomowego języka DML mogą być wykorzystywane bezpośrednio przez użytkownika, zatem są traktowane jak części języka zapytań⁹.

Dorywczy użytkownicy końcowi wykorzystują zwykle wysokopoziomowe języki zapytań do określania swoich żądań, natomiast programiści korzystają najczęściej z języków DML w formie instrukcji osadzonych. Niedoświadczeni użytkownicy parametryczni wykorzystują zwykle specjalnie przygotowane **przyjazne interfejsy użytkownika** bazy danych — takie interfejsy mogą również być stosowane przez użytkowników doraźnych i inne osoby, które nie chcą się uczyć szczegółów związanych z używaniem wysokopoziomowych języków zapytań. Omówimy te typy interfejsów w kolejnym punkcie.

⁸ W obiektowych bazach danych język nadrzędny i podjęzyk danych tworzą zwykle jeden zintegrowany język — przykładowo, język programowania C++ z pewnymi rozszerzeniami obsługuje funkcje bazy danych. Niektóre relacyjne systemy zarządzania bazami danych dodatkowo udostępniają zintegrowane języki — przykładowo, system Oracle oferuje język PL/SQL.

⁹ Zgodnie z ogólnie przyjętym znaczeniem słowa *zapytanie* należałoby go używać wyłącznie w odniesieniu do operacji odczytywania danych, a nie do aktualizacji.

2.3.2. Interfejsy systemów zarządzania bazami danych

Poniżej wymieniono przyjazne interfejsy użytkownika oferowane przez systemy zarządzania bazami danych.

Interfejsy oparte na menu dla klientów WWW lub przeglądarek. Interfejsy tego typu prezentują użytkownikom listy dostępnych opcji, nazywane **menu**, które przeprowadzają użytkowników przez proces formułowania żądań. Wykorzystywane w ten sposób menu eliminują konieczność zapamiętywania konkretnych poleceń i składni języka zapytań; zamiast tego zapytanie jest tworzone krok po kroku przez wybieranie kolejnych opcji z menu wyświetlanych przez oprogramowanie systemu bazy danych. W przypadku **interfejsów internetowych** (opartych na stronach WWW) bardzo popularne są tzw. menu rozwijane. Takie menu są także popularne w **interfejsach przeglądania**, które umożliwiają użytkownikom przeszukiwanie zawartości bazy danych (choćby w celach orientacyjnych).

Aplikacje dla urządzeń mobilnych. Takie interfejsy umożliwiają użytkownikom urządzeń mobilnych dostęp do danych. Przykładowo, banki, systemy rezerwacji i firmy ubezpieczeniowe udostępniają aplikacje umożliwiające użytkownikom dostęp do danych za pomocą telefonów komórkowych i innych urządzeń mobilnych. Takie aplikacje mają wbudowane zaprogramowane interfejsy, które zwykle pozwalają użytkownikom zalogować się za pomocą nazwy i hasła, a następnie udostępniają ograniczone menu z opcjami mobilnego dostępu do danych, a także z operacjami takimi jak opłacanie rachunków (w bankach) lub dokonywanie rezerwacji (w serwisach internetowych obsługujących rezerwacje).

Interfejsy oparte na formularzach. Interfejsy oparte na formularzach wyświetlają każdemu użytkownikowi formularz. Użytkownicy mogą wypełniać wszystkie pola takiego **formularza**, aby wstawić nowe dane, lub tylko niektóre z nich, aby system zarządzania bazą danych zwrócił właściwe dane wypełniające pozostałe pola. Formularze są zwykle projektowane i programowane z myślą o niedoświadczonych użytkownikach i pełnią rolę interfejsu dla wykonywanych przez nich podstawowych transakcji. Wiele systemów zarządzania bazami danych oferuje specjalne **języki definiowania formularzy**, ułatwiające programistom tworzenie tego typu struktur. SQL*Forms to oparty na formularzach język, w którym zapytania są tworzone za pomocą formularza projektowanego na podstawie schematu relacyjnej bazy danych. Oracle Forms to komponent pakietu produktów firmy Oracle udostępniający bogaty zestaw funkcji do projektowania i budowania aplikacji z użyciem formularzy. Niektóre systemy udostępniają narzędzia, za pomocą których użytkownicy końcowi mogą interaktywnie budować proste formularze w środowisku graficznym.

Graficzne interfejsy użytkownika. Graficzny interfejs użytkownika (ang. *Graphical User Interface — GUI*) przeważnie wyświetla użytkownikowi schemat bazy danych w formie graficznej. Użytkownik może wówczas tworzyć zapytania przez operowanie diagramem. W wielu przypadkach graficzne interfejsy użytkownika opierają się zarówno na menu, jak i na formularzach.

Interfejsy języka naturalnego. Interfejsy tego typu akceptują żądania pisane w języku naturalnym (najczęściej angielskim) i próbują je *zrozumieć* i odpowiednio przetworzyć. Interfejsy języka naturalnego zawierają zwykle nie tylko własne *schematy*, które są zbliżone do koncepcyjnego schematu bazy danych, ale także słowniki ważnych słów. Podczas interpretowania otrzymanego żądania interfejs języka naturalnego odwołuje się zarówno do słów zdefiniowanych w tym schemacie, jak i do zbioru standardowych słów zawartych w jego słowniku. Jeśli proces interpretacji żądania zakończy się powodzeniem, interfejs języka naturalnego generuje odpowiednie zapytanie wysokopoziomowe i przekazuje je do przetworzenia do systemu zarządzania bazą danych; w przeciwnym przypadku nawiązywany jest dialog z użytkownikiem, mający na celu uszczegółowienie żądania.

Przeszukiwanie baz na podstawie słów kluczowych. Te interfejsy przypominają nieco wyszukiwarki internetowe, które przyjmują słowa w języku naturalnym (np. angielskim lub polskim) i dopasowują je do dokumentów z konkretnej witryny (w wyszukiwarkach lokalnych) lub stron WWW z całego internetu (w wyszukiwarkach takich jak Google lub Ask). Stosuje się tu predefiniowane indeksy słów i funkcje rankingowe do pobierania i wyświetlania dokumentów w kolejności wyznaczonej przez poziom dopasowania. W ustrukturyzowanych bazach relacyjnych tego rodzaju dające pełną swobodę interfejsy tekstowe do tworzenia zapytań nie są na razie częste, choć niedawno powstała dziedzina badań dotycząca **zapytań opartych na słowach kluczowych** w kontekście baz relacyjnych.

Głosowe przekazywanie danych wejściowych i wyjściowych. Coraz popularniejsze staje się ograniczone wykorzystanie mowy do podawania zapytań oraz zwracania odpowiedzi lub wyników. Aplikacje z ograniczonym słownikiem (np.: informacji z książki telefonicznej, o odlotach i przylotach czy o kontaktach do kart kredytowych) pozwalają na wejściu i na wyjściu stosować mowę, aby umożliwić klientom dostęp do danych. Wejściowe dane głosowe są wykrywane na podstawie biblioteki predefiniowanych słów i używane do określenia parametrów przekazywanych do zapytania. Na wyjściu wykonywana jest podobna konwersja tekstu lub liczb na mowę.

Interfejsy dla użytkowników parametrycznych. Użytkownicy parametryczni, tacy jak kasjerzy bankowi, często wielokrotnie wykonują stosunkowo niewielki i stały zbiór operacji. Przykładowo, kasjer może za pomocą jednego przycisku funkcyjnego uruchamiać rutynowe i powtarzalne transakcje, takie jak wpłaty lub wypłaty, a także odpowiadać na zapytania o stan konta. Analitycy systemowi i programiści odpowiednio projektują i implementują specjalny interfejs dla każdej znanej klasy takich niedoświadczonych użytkowników. Tworzone w ten sposób interfejsy obsługują zwykle niewielki zbiór skróconych poleceń, ponieważ celem jest zminimalizowanie liczby naciskanych klawiszy niezbędnej do wywołania poszczególnych żądań.


Interfejsy dla administratorów baz danych. Większość systemów baz danych zawiera uprzywilejowane polecenia, które mogą być wykorzystywane wyłącznie przez administratorów. Należą do nich polecenia tworzenia kont użytkowników, ustawiania parametrów systemowych, przypisywania uprawnień do kont użytkowników, modyfikowania schematu oraz reorganizowania struktur przechowywania bazy danych.

2.4. Środowisko systemu bazy danych

System zarządzania bazą danych jest skomplikowanym systemem oprogramowania. W tym podrozdziale omówimy typy składników programowych, które połączone tworzą SZBD, wraz z rodzajami oprogramowania systemu komputerowego, z którymi SZBD współpracuje.

2.4.1. Moduły składające się na system zarządzania bazą danych

Na rysunku 2.3 przedstawiono w uproszczonej formie typowe składniki systemu zarządzania bazą danych. Rysunek jest podzielony na dwie części. Górna przedstawia różnych użytkowników środowiska bazy danych i ich interfejsy. W dolnej widoczne są wewnętrzne moduły SZBD odpowiedzialne za składowanie danych i przetwarzanie transakcji.



RYSunEK 2.3. Moduły składające się na system zarządzania bazą danych i związane z nimi interakcje

Sama baza danych i katalog systemu zarządzania bazą danych są zwykle przechowywane na dysku. Dostęp do dysku jest kontrolowany głównie przez **system operacyjny** (ang. *Operating System* — *OS*), który ustala kolejność wykonywania operacji odczytu-zapisu. Liczne systemy zarządzania bazami danych zawierają własne **moduły zarządzania buforami**, służące do szeregowania operacji odczytu i zapisu na dysku. Te moduły są używane, ponieważ zarządzanie zawartością bufora ma istotny wpływ na wydajność. Przyspieszenie odczytów i zapisów znacząco zwiększa wydajność. Znajdujący się na wyższym poziomie i należący do systemu zarządzania bazą danych moduł **menadżera składowanych danych** kontroluje dostęp do informacji umieszczonych na dysku niezależnie od tego, czy są to informacje znajdujące się w bazie danych, czy w katalogu.

Przyjrzyj się najpierw górnej części rysunku 2.3. Widoczne są tam interfejsy dla administratorów bazy danych, użytkowników doraźnych (którzy formułują zapytania za pomocą interaktywnych interfejsów), programistów aplikacji (tworzących programy za pomocą nadrzędnych języków programowania) i użytkowników parametrycznych (wprowadzających dane przez podawanie parametrów predefiniowanych transakcji). Administratorzy bazy danych definiują i dostrajają bazę, wprowadzając zmiany w jej definicji za pomocą języka DDL i poleceń wymagających wysokich uprawnień.

Kompilator języka DDL przetwarza zdefiniowane w tym języku specyfikacje schematów i zapisuje opisy przetworzonych schematów (metadane) w katalogu systemu zarządzania bazą danych. Katalog zawiera takie informacje jak nazwy i rozmiary poszczególnych plików, nazwy i typy danych poszczególnych elementów danych, szczegóły przechowywania każdego z plików, informacje o regułach odwzorowywania pomiędzy schematami, specyfikacje ograniczeń oraz wiele dodatkowych rodzajów informacji, które są niezbędne do pracy rozmaitych modułów systemu zarządzania bazą danych.

Użytkownicy doraźni i osoby, które sporadycznie potrzebują danych z bazy, komunikują się z nią za pomocą interfejsu do zgłaszania **interaktywnych zapytań** (patrz rysunek 2.3). *Nie przedstawiliśmy tu bezpośrednio* żadnych opartych na menu, formularzu lub rozwiązaniach mobilnych interakcji, które zwykle są używane do automatycznego generowania interaktywnych zapytań lub dostępu do transakcji zapuszkowanych. Takie zapytania są parsowane i sprawdzane pod kątem poprawności składni oraz nazw plików i elementów danych przez **kompilator zapytań**, który kompiluje je do wewnętrznej postaci. Zapytania w wewnętrznej postaci są optymalizowane (patrz rozdziały 18. i 19.). **Optymalizator zapytań** odpowiada m.in. za zmianę układu operacji, eliminowanie nadmiarowości i wykorzystanie wydajnych algorytmów wyszukiwania w trakcie przetwarzania zapytania. Optymalizator sprawdza w katalogu systemu statystyczne i fizyczne informacje o składowanych danych oraz generuje kod wykonywalny, który przeprowadza operacje potrzebne do obsługi zapytania i kieruje wywołania do procesora wykonawczego.

Programiści aplikacji piszą programy w językach nadrzędnych takich jak Java, C i C++. Te programy są przekazywane do prekompilatora. **Prekompilator** wyodrębnia polecenia języka DML z kodu aplikacji napisanego w języku nadrzędnym. Takie polecenia są następnie przekazywane do kompilatora języka DML, który kompiluje je do postaci kodu obiektów wykorzystywanych w operacjach dostępu do bazy danych. Reszta programu jest przesyłana do kompilatora języka nadrzędnego. Kody obiektów dla poleceń języka DML pozostają jednak połączone ze skompilowanym programem języka nadrzędnego i tworzą tzw. zapuszkowane transakcje, których kod zawiera wywołania operacji wy-

konawczego procesora bazy danych. Do pisania programów bazodanowych coraz częściej stosuje się języki skryptowe takie jak PHP i Python. Zapuszkowane transakcje są wykonywane wielokrotnie przez użytkowników parametrycznych za pomocą komputerów osobistych lub aplikacji mobilnych. Tacy użytkownicy określają tylko parametry transakcji. Każde wywołanie jest wtedy uznawane za odrębną transakcję. Przykładem jest tu transakcja płatności w banku, gdzie jako parametry można podać numer konta, odbiorcę i kwotę.

W dolnej części rysunku 2.3 **wykonawczy procesor bazy danych** uruchamia (1) uprzywilejowane polecenia, (2) wykonywalne plany zapytań i (3) zapuszkowane transakcje z parametrami wykonawczymi. Ten procesor korzysta z **katalogu systemu** i może aktualizować zapisane w nim statystyki. Używa też **menedżera danych składowanych**, który z kolei korzysta z podstawowych usług systemu operacyjnego do wykonywania niskopoziomowych operacji wejścia-wyjścia (odczytu i zapisu) z wykorzystaniem dysku i pamięci głównej. Wykonawczy procesor bazy obsługuje też inne aspekty przenoszenia danych, takie jak zarządzanie buforami w pamięci głównej. Niektóre SZBD mają własny moduł zarządzania buforami, natomiast inne korzystają w tym obszarze z systemu operacyjnego. Na rysunku systemy **sterowania współbieżnego** oraz **tworzenia kopii bezpieczeństwa i odtwarzania bazy** są przedstawione jako odrębny moduł. Na potrzeby transakcji te komponenty są integrowane z działaniem wykonawczego procesora bazy danych.

Popularnym rozwiązaniem jest wykorzystywanie **programu klienta**, który uzyskuje dostęp do systemu zarządzania bazą danych, działając na innym komputerze niż ten, na którym znajduje się baza danych. Pierwszy komputer jest wówczas nazywanym **komputerem klienta**, natomiast drugi komputer nosi nazwę **serwera bazy danych**. W niektórych przypadkach klient wykorzystuje dodatkowo komputer pośredniczący, nazywany **serwerem aplikacji**, który w imieniu klienta uzyskuje bezpośredni dostęp do serwera bazy danych. Omówimy to zagadnienie bardziej szczegółowo w podrozdziale 2.5.

Rysunek 2.3 nie ma ilustrować żadnego konkretnego systemu zarządzania bazą danych, a jedynie przedstawiać typowe związki pomiędzy modułami SZBD. System zarządzania bazą danych wykorzystuje usługi systemu operacyjnego w momencie uzyskiwania dostępu do informacji zapisanych na dysku — w bazie danych lub w katalogu. Jeśli dany system komputerowy jest współużytkowany przez wielu użytkowników, system operacyjny odpowiada za właściwe zaplanowanie kolejności obsługi otrzymywanych żądań dostępu oraz prawidłowe zarządzanie czasem przyznawanym procesowi systemu zarządzania bazą danych i innym działającym procesom. Z drugiej strony, jeśli dany system komputerowy jest przeznaczony przede wszystkim do zapewnienia odpowiedniego środowiska działania dla serwera bazy danych, system zarządzania bazą danych będzie kontrolował buforowanie stron dyskowych w głównej pamięci. System zarządzania bazą danych odpowiada także za dostarczanie niezbędnych interfejsów nie tylko dla kompilatorów uniwersalnych, nadrzędnych języków programowania, ale także dla serwerów aplikacji i programów klienckich działających na innych komputerach i komunikujących się za pośrednictwem interfejsu sieciowego.

2.4.2. Narzędzia systemu bazy danych

Poza opisanymi przed chwilą modułami programowymi większość systemów zarządzania bazami danych dodatkowo udostępnia **narzędzia baz danych**, które ułatwiają ich administratorom zarządzanie systemami baz danych. Do najczęściej stosowanych typów i funkcji oferowanych przez narzędzia tego typu należą:

- **Wczytywanie:** Narzędzia wczytujące są wykorzystywane do kopiowania zawartości zewnętrznych plików z danymi (np. plików tekstowych lub plików sekwencyjnych) do bazy danych. Narzędzia tego typu otrzymują na wejściu bieżący (źródłowy) format pliku z danymi oraz oczekiwaną (docelową) strukturę pliku bazy danych, i na tej podstawie automatycznie formatują i zapisują odpowiednie informacje w bazie danych. Wraz z rosnącą popularnością systemów zarządzania bazami danych, konieczność przenoszenia danych pomiędzy różnymi pakietami tego typu staje się w wielu organizacjach codziennością. Niektórzy producenci oferują nawet **narzędziami konwersji** generujące — w oparciu o opisy (schematy wewnętrzne) istniejącego formatu składowania informacji i docelowego formatu przechowywania informacji w bazie danych — odpowiednie programy wczytujące.
- **Tworzenie kopii zapasowej:** Narzędzia tego typu tworzą kopię zapasową bazy danych (takie działania polegają zwykle na wykonaniu rzutu całej bazy danych i zapisaniu go na taśmie lub innym nośniku). Kopia zapasowa może być następnie wykorzystana do przywrócenia bazy danych w przypadku katastrofalnej awarii dysku. Często stosuje się technikę tworzenia przyrostowych kopii zapasowych, w której rejestrowane są wyłącznie zmiany, jakie miały miejsce od ostatniej operacji utworzenia takiej kopii. Wykonywanie przyrostowej kopii zapasowej jest co prawda bardziej skomplikowane, ale pozwala oszczędzić przestrzeń na wykorzystywanym nośniku.
- **Reorganizacja plików:** Narzędzia tego typu mogą być wykorzystywane do reorganizowania plików baz danych z wykorzystaniem innej struktury i nowych ścieżek dostępu, najczęściej z myślą o poprawie wydajności.
- **Monitorowanie wydajności:** Takie narzędzia monitorują obciążenie bazy danych i na tej podstawie generują odpowiednie dane statystyczne dla administratora tej bazy. Administrator bazy danych może wykorzystać te statystyki podczas podejmowania decyzji np. w kwestii ewentualnej reorganizacji plików albo dodanie lub usunięcia indeksów celem poprawy wydajności.

Systemy zarządzania bazami danych mogą także oferować funkcje sortowania plików, obsługi kompresji danych, monitorowania operacji dostępu wykonywanych przez użytkowników, obsługi interfejsów sieciowych oraz wykonywania innych przydatnych zadań.

2.4.3. Narzędzia, środowiska aplikacji oraz mechanizmy komunikacji

Projektanci, użytkownicy i SZBD mogą korzystać także z innych przydatnych narzędzi. W fazie projektowania systemów baz danych można wykorzystywać narzędzia typu CASE¹⁰. Do narzędzi, które mogą być przydatne w wielkich organizacjach, należy także rozszerzony **system słownika danych**, nazywany także **systemem repozytorium danych**. Poza danymi katalogowymi na temat schematów i ograniczeń słownik danych może zawierać także inne informacje, takie jak decyzje projektowe, standardy wykorzystywania bazy danych, opisy aplikacji i dane o użytkownikach. Systemy tego typu są także nazywane **repozytoriami danych**. W razie potrzeby użytkownicy lub administrator bazy danych mogą mieć *bezpośredni* dostęp do informacji zawartych w takim repozytorium. Rozwiązania obsługujące słowniki danych przypominają co prawda katalogi systemów zarządzania bazami danych, jednak zawierają więcej różnych informacji i są udostępniane przede wszystkim użytkownikom, nie oprogramowaniu SZBD (jak w przypadku katalogów).

Środowiska wytwarzania aplikacji, takie jak systemy PowerBuilder (firmy Sybase) czy JBuilder (Borland), są dość popularne. Takie systemy oferują środowisko ułatwiające szybkie wytwarzanie aplikacji baz danych, a także upraszczają wiele aspektów opracowywania systemów baz danych, w tym projektowania baz danych, tworzenia graficznych interfejsów użytkownika, przygotowywania zapytań i operacji aktualizujących, oraz budowania aplikacji.

Systemy zarządzania bazami danych potrzebują także interfejsów do **oprogramowania komunikacyjnego**, które ma umożliwić zdalnym użytkownikom korzystanie z systemu bazy danych i dostęp do zawartych tam danych za pośrednictwem komputerowych terminali, stacji roboczych lub ich lokalnych komputerów osobistych. Komputery takich użytkowników są połączone z serwerem bazy danych za pomocą odpowiedniego sprzętu komunikacyjnego — routerów internetowych, linii telefonicznych, sieci rozległych, sieci lokalnych lub urządzeń komunikacji satelitarnej. Wiele komercyjnych systemów baz danych oferuje specjalne pakiety komunikacyjne, które współpracują z systemami zarządzania bazami danych. Systemy tego typu zintegrowane z systemami komunikacyjnymi są nazywane systemami **DB/DC**. Niektóre rozproszone systemy zarządzania bazami danych są dodatkowo fizycznie instalowane na wielu komputerach. W takim przypadku do łączenia komputerów wykorzystuje się sieci komunikacyjne. Najczęściej są to **sieci lokalne** (ang. *Local Area Network* — LAN), jednak mogą to być także inne typy sieci komputerowych.

¹⁰ Chociaż CASE oznacza wspomaganą komputerowo inżynierię oprogramowania (ang. *Computer-Aided Software Engineer*), wiele narzędzi typu CASE jest wykorzystywanych przede wszystkim do projektowania baz danych.

2.5. Architektury systemów zarządzania bazami danych — scentralizowane i typu klient-serwer

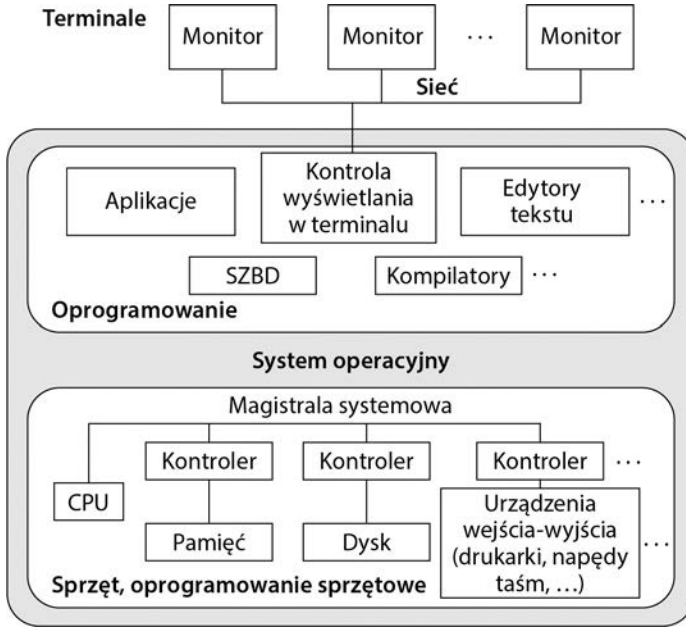
2.5.1. Scentralizowane architektury systemów zarządzania bazami danych

Architektury systemów zarządzania bazami danych ewoluowały zgodnie z ogólnymi trendami panującymi w świecie systemów komputerowych. Wcześniejsze architektury opierały się na centralnych komputerach, które obsługiwały przetwarzanie dla wszystkich funkcji systemu, włącznie z udostępnianiem aplikacji użytkowników i programów pełniących rolę interfejsów użytkowników, a także całą funkcjonalność systemu zarządzania bazą danych. Stosowanie takich rozwiązań wynikało z faktu, że większość użytkowników uzyskiwała dostęp do tych systemów za pośrednictwem komputerowych terminali, które nie oferowały wystarczającej mocy obliczeniowej, i które w związku z tym pełniły wyłącznie rolę sprzętu wyświetlającego otrzymywane dane. Wszystkie operacje związane z przetwarzaniem danych były wówczas zdalnie wykonywane w centralnym systemie komputerowym, a terminale odpowiadały jedynie za wyświetlanie otrzymanych z tego komputera informacji i instrukcji sterujących — terminale były połączone z centralnym komputerem za pośrednictwem rozmaitych typów sieci komunikacyjnych.

Wraz z postępującym spadkiem cen sprzętu komputerowego większość użytkowników zastąpiła swoje terminale komputerami osobistymi (ang. *Personal Computer* — *PC*) oraz stacjami roboczymi, a później także urządzeniami mobilnymi. Systemy baz danych początkowo wykorzystywały te komputery w taki sam sposób, w jaki wcześniej używały terminali wyświetlających, zatem nadal mieliśmy do czynienia ze **scentralizowanymi** systemami zarządzania bazami danych, w których obsługa wszystkich funkcji, wykonywanie programów aplikacji oraz przetwarzanie interfejsu użytkownika odbywało się na jednym komputerze. Na rysunku 2.4 przedstawiono fizyczne składniki architektury scentralizowanej. Systemy zarządzania bazami danych z czasem zaczęły wykorzystywać moce przetwarzania dostępne po stronie użytkownika, co doprowadziło ostatecznie do opracowania architektury systemów zarządzania bazami danych typu klient-serwer.


2.5.2. Podstawowe architektury typu klient-serwer

W pierwszej kolejności omówimy ogólną architekturę typu klient-serwer, dopiero potem przystąpimy do analizy jej zastosowań w systemach zarządzania bazami danych. **Architektura typu klient-serwer** została opracowana z myślą o środowiskach komputerowych z dużą liczbą komputerów osobistych, stacji roboczych, serwerów plików, drukarek, serwerów baz danych, serwerów WWW, serwerów poczty elektronicznej i innego sprzętu połączonych ze sobą za pomocą sieci komputerowej. Zasadniczym elementem tej koncepcji jest definiowanie **wyspecjalizowanych serwerów** realizujących tylko określone funkcje. Przykładowo, istnieje możliwość połączenia wielu komputerów osobistych lub niewielkich stacji roboczych w roli klientów **serwera plików**, który utrzymuje pliki wykorzystywane na komputerach klienckich. W tym samym środowisku możemy przydzielić innemu komputerowi rolę **serwera wydruków** i połączyć go z różnymi drukarkami — wszystkie generowane przez klientów żądania drukowania będą wówczas przekazywane właśnie do




RYSUNEK 2.4. Fizycznie scentralizowana architektura

tego komputera. Także **serwery WWW** lub **serwery poczty elektronicznej** należą do kategorii serwerów wyspecjalizowanych. W ten sposób zasoby oferowane przez wyspecjalizowane serwery mogą być jednocześnie udostępniane wielu **komputerom klienckim**. Takie komputery oferują swoim użytkownikom nie tylko odpowiednie interfejsy umożliwiające wygodne i efektywne wykorzystywanie funkcjonalności wyspecjalizowanych serwerów, ale także lokalną moc przetwarzania umożliwiającą pracę z lokalnymi aplikacjami. Koncepcję stosowania wyspecjalizowanych serwerów można przenieść także na grunt samego oprogramowania, gdzie wyspecjalizowane pakiety — takie jak oprogramowanie typu *CAD* (ang. *Computer-Aided Design*) — może się znajdować na określonych serwerach i być udostępniane jednocześnie wielu klientom. Na rysunku 2.5 przedstawiono architekturę typu klient-serwer na poziomie logicznym, natomiast na rysunku 2.6 zademonstrowano uproszczony diagram pokazujący, jak wyglądałaby fizyczna architektura takiego środowiska. Niektóre komputery pełniłyby w takim systemie jedynie rolę urządzeń klienckich (przykładowo, może to dotyczyć urządzeń mobilnych albo też komputerów osobistych lub stacji roboczych z zainstalowanym wyłącznie oprogramowaniem klienckim). Inne komputery w tak skonstruowanym środowisku byłyby dedykowanymi serwerami, a jeszcze inne oferowałyby zarówno funkcjonalność klienta, jak i serwera.



RYSUNEK 2.5. Logiczna dwuwarstwowa architektura typu klient-serwer



RYСУNEK 2.6. Fizyczna dwuwarstwowa architektura typu klient-serwer

Koncepcja architektury typu klient-serwer przewiduje istnienie całej infrastruktury sieciowej obejmującej wiele komputerów osobistych, stacji roboczych i urządzeń przenośnych oraz znacznie mniej liczną grupę serwerów połączonych ze sobą za pomocą sieci bezprzewodowej, lokalnej lub innego typu. **Klient** w takiej infrastrukturze ma zwykle postać takiego komputera użytkownika, który oferuje pewne możliwości zarówno w zakresie obsługi interfejsu użytkownika, jak i w kwestii lokalnego przetwarzania. Kiedy klient zażąda dostępu do dodatkowych funkcji lub zasobów (np. do bazy), które nie są utrzymywane na jego lokalnym komputerze, komputer kliencki nawiąże połączenie z odpowiednim serwerem oferującym środki niezbędne do zrealizowania tego żądania. **Serwer** jest systemem obejmującym sprzęt i oprogramowanie, które pozwalają udostępnić komputerom klienckim takie usługi jak dostęp do plików, drukowanie, archiwizowanie czy dostęp do bazy danych. Niektóre komputery mogą mieć zainstalowane wyłącznie oprogramowanie klienckie, inne wyłącznie oprogramowanie serwera, jeszcze inne mogą natomiast zawierać zarówno oprogramowanie klienta, jak i oprogramowanie serwera (patrz rysunek 2.6). Znacznie bardziej popularnym rozwiązaniem jest jednak wykorzystywanie oprogramowania klienta i serwera na różnych komputerach. Na podstawie architektury klient-serwer stworzono dwa główne typy architektur systemów zarządzania bazami danych: **dwuwarstwową** i **trójwarstwową**¹¹. Omówimy je w kolejnych punktach.

¹¹ Istnieje jeszcze wiele innych odmian architektury klient-serwer. W tym miejscu omówimy tylko wspomnianą parę podstawowych architektur tego typu.

2.5.3. Dwuwarstwowe architektury typu klient-serwer dla systemów zarządzania bazami danych


W relacyjnych systemach zarządzania bazami danych, których większość była początkowo systemami scentralizowanymi, do warstwy klienta w pierwszej kolejności przeniesiono takie elementy jak interfejs użytkownika oraz aplikacje. Ponieważ SQL (patrz rozdziały 6. i 7.) z czasem zyskał pozycję standardowego języka relacyjnych systemów zarządzania bazami danych, takie posunięcie stworzyło logiczny punkt podziału pomiędzy klientem a serwerem. Oznacza to, że obsługa zapytań i transakcji pozostały po stronie serwera. W związku z tym w rozwiązaniach zbudowanych zgodnie z tą architekturą serwer jest często nazywany **serwerem zapytań** lub **serwerem transakcji**. W relacyjnych systemach zarządzania bazami danych taki serwer jest również często nazywany **serwerem SQL**.

W takich architekturach programy interfejsu użytkownika i aplikacje mogą działać po stronie klienta. Kiedy okaże się, że niezbędny jest dostęp do systemu zarządzania bazą danych, odpowiedni program nawiąże połączenie z takim systemem (działającym po stronie serwera); kiedy odpowiednie połączenie zostanie utworzone, program klienta będzie mógł się komunikować z systemem zarządzania bazą danych. Standard nazywany **otwartym łączem baz danych** (ang. *Open Database Connectivity — ODBC*) oferuje **interfejs programowy aplikacji** (ang. *Application Programming Interface — API*), który umożliwia programom działającym po stronie klienta wywoływanie systemu zarządzania bazą danych — jedynym wymaganiem jest zainstalowanie na komputerach klienta i serwera odpowiedniego oprogramowania. Większość producentów systemów zarządzania bazami danych oferuje w swoich pakietach specjalne sterowniki ODBC. Oznacza to, że pojedynczy program klienta może się łączyć z wieloma relacyjnymi systemami zarządzania bazami danych i wysyłać — za pośrednictwem interfejsu API standardu ODBC — zapytania i żądania transakcji, które będą następnie przetwarzane po stronie serwerów baz danych. Uzyskane w ten sposób wyniki zapytań zostaną odesłane do programu klienta, który może je dodatkowo przetworzyć lub od razu zaprezentować użytkownikowi. Istnieje także powiązany standard (nazwany **JDBC**) dla języka programowania Java. Zastosowanie takiego rozwiązania umożliwia dostęp do systemów zarządzania bazami danych z poziomu programu klienta napisanego w języku Java za pośrednictwem standardowego interfejsu.

Opisane w tym punkcie architektury są nazywane **architekturami dwuwarstwowymi**, ponieważ składniki oprogramowania są dzielone pomiędzy dwa systemy: klienta i serwera. Zaletą tego typu architektur jest ich prostota i bezproblemowa zgodność z istniejącymi systemami informatycznymi. Rozwój internetu (w szczególności popularność stron WWW) odmienił nieco role klientów i serwera, doprowadzając ostatecznie do powstania architektury trójwarstwowej.

2.5.4. Trójwarstwowe i n-warstwowe architektury typu klient-serwer dla aplikacji internetowych

Wiele aplikacji internetowych wykorzystuje model nazywany **architekturą trójwarstwową**, która dodaje pomiędzy klientem a serwerem bazy danych jeszcze jedną warstwę pośredniczącą (patrz rysunek 2.7(a)).



RYSUNEK 2.7. Logiczna trójwarstwowa architektura typu klient-serwer i wybrane standardowe pojęcia

Taka **środkowa** warstwa pośrednicząca jest niekiedy nazywana **warstwą aplikacji** lub **serwerem WWW**, w zależności od jej rzeczywistego zastosowania. Taki serwer pełni rolę pośrednika przechowującego reguły biznesowe (procedury lub ograniczenia), które są wykorzystywane do udostępniania danych z serwera bazy danych. Dodatkowa warstwa może także zwiększyć bezpieczeństwo bazy danych przez sprawdzanie danych uwierzytelniających klienta jeszcze przed przekazaniem otrzymanych żądań do serwera bazy danych. Komputery warstwy klienta zawierają interfejsy użytkownika i przeglądarki internetowe. Serwer pośredniczący przyjmuje i przetwarza żądania nadesłane przez klienta, po czym przesyła je dalej do serwera bazy danych (w postaci zapytań i poleceń). Następnie przekazuje (częściowo) przetworzone dane z serwera bazy danych do klientów, gdzie dane te mogą być dalej przetwarzane i filtrowane w celu ich zaprezentowania użytkownikom. Zatem rolę trzech warstw pełnią: *interfejs użytkownika*, *reguły aplikacji* oraz *dostęp do danych*. Na rysunku 2.7(b) pokazane jest inne ujęcie architektury trójwarstwowej używanej przez producentów baz danych i innych pakietów aplikacji. Warstwa prezentacji wyświetla tu informacje użytkownikowi i umożliwia wprowadzanie danych. Warstwa logiki biznesowej obsługuje reguły i ograniczenia pośrednie, stosowane przed przekazaniem danych w górę (do użytkownika) lub w dół (do SZBD). Dolna warstwa obejmuje wszystkie usługi zarządzania danymi. Warstwa pośrednia może też pełnić funkcję serwera WWW, który pobiera wyniki zapytań z serwera bazy danych i formatuje je do postaci dynamicznych stron WWW wyświetlanych za pomocą przeglądarki po stronie klienta. Maszyną klienta jest zwykle komputer osobisty lub urządzenie mobilne podłączone do internetu.

Zaproponowano także inne architektury. Warstwy pomiędzy użytkownikiem a składowanymi danymi można podzielić na bardziej szczegółowe komponenty, co skutkuje powstaniem architektur *n*-warstwowych (gdzie *n* to cztery lub pięć). Warstwa logiki biznesowej jest zwykle podzielona na wiele warstw. Oprócz możliwości udostępniania kodu i danych w sieci aplikacje *n*-warstwowe mają tę zaletę, że każdą warstwę można obsługiwać niezależnie oraz zastosować dla niej odpowiedni procesor lub system opera-

cyjny. Producenci pakietów ERP (ang. *enterprise resource planning*) i CRM (ang. *customer relationship management*) często stosują *warstwę pośrednią*, aby uwzględnić moduły frontonu (klientów) komunikujące się z licznymi bazami zapleczka (serwerami).

Postęp w obszarze technologii szyfrowania i deszyfrowania sprawił, że przesyłanie w postaci zaszyfrowanej poufnych danych z serwera do klienta (gdzie zostaną one odszyfrowane) jest teraz znacznie bezpieczniejsze. Operacja deszyfrowania może się opierać na odpowiednim sprzęcie lub na zaawansowanym oprogramowaniu. Wspomniana technologia zapewnia wyższy poziom bezpieczeństwa danych, problemem pozostaje jednak bezpieczeństwo komunikacji w sieci. Warto też pamiętać, że podczas przesyłania ogromnych ilości danych z serwerów do klientów za pośrednictwem sieci przewodowych lub bezprzewodowych pomocne są rozmaite technologie kompresji danych.

2.6. Klasyfikacja systemów zarządzania bazami danych

Podczas klasyfikowania systemów zarządzania bazami danych bierze się zwykle pod uwagę wiele kryteriów. Pierwszym jest **model danych**, na którym opiera się dany SZBD. Najczęściej spotykanym modelem tego typu wykorzystywanym w wielu współczesnych komercyjnych systemach zarządzania bazami danych jest **relacyjny model danych**. Oparte na nim systemy są nazywane **systemami SQL-owymi**. **Obiektowy model danych** co prawda został już zaimplementowany w kilku komercyjnych systemach, jednak nie jest na razie popularny. W nowszych **systemach typu big data** (inne nazwy to **systemy składowania danych typu klucz-wartość** lub **systemy NOSQL**) używane są różne modele danych: **oparte na dokumentach**, **oparte na grafach**, **oparte na kolumnach** i **typu klucz-wartość**. Wiele starszych rozwiązań nadal opiera się na **hierarchicznych** lub **sieciowych modelach danych**.

Relacyjne systemy zarządzania bazami danych stale ewoluują i są wzbogacane o nowe rozwiązania — dotyczy to zwłaszcza wielu cech charakterystycznych dla obiektowych baz danych. Taki kierunek rozwoju relacyjnych baz danych zaowocował powstaniem nowej klasy systemów zarządzania bazami danych, nazwanych **obiektowo-relacyjnymi** SZBD. Systemy zarządzania bazami danych możemy więc podzielić na kategorie według zastosowanego modelu danych: relacyjnego, obiektowego, obiektowo-relacyjnego, NOSQL, klucz-wartość, hierarchicznego, sieciowego itp.

Niektóre eksperymentalne SZBD są oparte na modelu XML. Jest to **drzewiasty model danych**. Są to tzw. **natywne XML-owe SZBD**. W kilku komercyjnych relacyjnych SZBD dodano XML-owe interfejsy i magazyny danych.

Drugim istotnym kryterium podziału systemów zarządzania bazami danych jest obsługiwana przez nie **liczba użytkowników**. Systemy **jednodostępne** obsługują w tym samym czasie tylko jednego użytkownika i są wykorzystywane przede wszystkim na komputerach osobistych. **Systemy wielodostępne**, do których należy większość współczesnych systemów zarządzania bazami danych, umożliwiają jednoczesną pracę wielu użytkownikom.

Trzecim kryterium jest **liczba węzłów**, pomiędzy które baza danych jest rozpraszana. System zarządzania bazą danych jest **scentralizowany**, jeśli dane są przechowywane na jednym komputerze. Scentralizowany system zarządzania bazą danych może co prawda

obsługiwać wielu użytkowników pracujących przy wielu komputerach, jednak sam system tego typu wraz z udostępnianą bazą danych musi się znajdować na jednym komputerze. **Rozproszony** system zarządzania bazą danych (ang. *Distributed Database Management System — DDBMS*) może wykorzystywać bazę danych i moduły oprogramowania SZBD działające na wielu różnych węzłach połączonych za pomocą sieci. Systemy big data są często wysoce rozproszone i działają w setkach węzłów. Dane są nieraz replikowane w wielu węzłach, dlatego awaria jednego z nich nie powoduje niedostępności danych.

Homogeniczne rozproszone systemy zarządzania bazami danych wykorzystują to samo oprogramowanie na wielu komputerach. W systemach **heterogenicznych** w każdym węźle używane może być inne oprogramowanie. Można też opracować **oprogramowanie warstwy pośredniej**, aby uzyskać dostęp do wielu autonomicznych, już istniejących baz danych zarządzanych przez heterogeniczne systemy SZBD. Kolejnym krokiem w tym kierunku są **federacyjne** systemy zarządzania bazami danych (tzw. **systemy wielo-bazodanowe**), w których wykorzystuje się wiele luźno powiązanych ze sobą systemów zachowujących w całej tej strukturze część lokalnej autonomii. W wielu rozproszonych systemach zarządzania bazami danych stosuje się architekturę typu klient-serwer, co opisano w podrozdziale 2.5.

Czwartym kryterium jest **koszt** systemu zarządzania bazą danych. Trudno jest zaproponować klasyfikację SZBD opartą na kosztach. Obecnie dostępne są otwarte (bezpłatne) produkty tego typu, np. MySQL i PostgreSQL, wzbogacane przez niezależnych producentów o dodatkowe usługi. Popularne relacyjne SZBD są dostępne w postaci bezpłatnych 30-dniowych wersji próbnych i wersji osobistych, które mogą kosztować tylko kilkaset złotych i udostępniać wiele funkcji. Bardzo rozbudowane systemy są sprzedawane w postaci modułowej z komponentami do obsługi dystrybucji danych, replikacji, przetwarzania równoległego, mechanizmów mobilnych itd. Konfiguracja takich produktów wymaga zdefiniowania licznych parametrów. Ponadto omawiane systemy są sprzedawane w formie licencji. Licencje na lokalizacje umożliwiają nieograniczone użytkowanie systemu bazy danych i uruchamianie go w dowolnej liczbie egzemplarzy w siedzibie klienta. Inny rodzaj licencji ogranicza liczbę jednoczesnych użytkowników lub stanowisk w danej lokalizacji. Niezależne wersje dla pojedynczych użytkowników (np. systemu Microsoft Access) są sprzedawane na sztuki albo dodawane do konfiguracji komputera stacjonarnego lub laptopa. Za dodatkową opłatą udostępniane są funkcje hurtowni i drażenia danych, a także obsługa innych typów danych. Instalacja i utrzymanie dużego systemu bazy danych może kosztować miliony złotych rocznie.

Systemy zarządzania bazami danych możemy sklasyfikować także według dostępnych opcji w zakresie **typów ścieżek dostępu** do przechowywanych plików. Przykładowo, jedna z dobrze znanych rodzin systemów tego typu opiera się na odwróconych strukturach plików. Wreszcie, system zarządzania bazą danych może być rozwiązaniem **uniwersalnym** lub **wyspecjalizowanym**. W sytuacjach, gdy kluczowe wymaganie dotyczy wydajności systemu, warto rozważyć zaprojektowanie i budowę wyspecjalizowanego SZBD dla konkretnego zastosowania, który bez wprowadzenia istotnych zmian nie będzie mógł być wykorzystywany do innych zastosowań. Wiele opracowanych w przeszłości systemów zarządzania bazami danych wykorzystywanych w biurach rezerwacji biletów lotniczych lub przez operatorów telefonicznych było właśnie rozwiązaniami wyspecjalizowanymi. Tak powstały systemy **przetwarzania transakcji na bieżąco** (ang. *Online Transaction Processing — OLTP*), które muszą obsługiwać ogromną liczbę współbieżnych transakcji, nie powodując przy tym zbyt dużych opóźnień.

Spróbujmy teraz krótko omówić model danych — główne kryterium klasyfikacji systemów zarządzania bazami danych. Podstawowy **relacyjny model danych** reprezentuje bazę danych w postaci zbioru tabel, z których każda może być składowana w osobnym pliku. Baza danych zademonstrowana na rysunku 1.2 jest bardzo zbliżona do reprezentacji relacyjnej. Większość relacyjnych baz danych wykorzystuje wysokopoziomowy język zapytań SQL i obsługuje (choć w ograniczonym wymiarze) perspektywy użytkownika. Model relacyjny wraz z jego językami i operacjami techniki programowania relacyjnych aplikacji omówimy w rozdziałach od 5. do 8.; techniki programowania relacyjnych aplikacji omówimy w rozdziałach 10. i 11.

Obiektowy model danych definiuje bazę danych w oparciu o obiekty, ich własności oraz ich operacje. Obiekty z taką samą strukturą i zachowaniem należą do jednej **klasy**, natomiast same klasy są organizowane w **hierarchie** (nazywane także **grafami acyklicznymi**). Operacje dla poszczególnych klas są konstruowane na bazie predefiniowanych procedur nazywanych **metodami**. Modele wykorzystywane w wielu relacyjnych systemach zarządzania bazami danych zostały przystosowane do obsługi pojęć typowych dla obiektowych baz danych oraz funkcji innych systemów i są w związku z tym nazywane systemami **obiektowo-relacyjnymi** lub **rozszerzonymi systemami relacyjnymi**. Obiektowe bazy danych oraz systemy obiektowo-relacyjne omówimy w rozdziale 12.

Systemy big data są oparte na różnych modelach danych. Najczęściej stosowane są cztery z nich. **Model danych typu klucz-wartość** łączy z każdą wartością (może nią być rekord lub obiekt) unikatowy klucz i zapewnia bardzo szybki dostęp do wartości na podstawie klucza. **Model danych oparty na dokumentach** wykorzystuje format JSON (ang. *Java Script Object Notation*) i przechowuje dane jako dokumenty przypominające nieco złożone obiekty. **Model danych oparty na grafie** przechowuje obiekty jako węzły grafu, a relacje między obiektami jako krawędzie grafu skierowanego. **Kolumnowe modele danych** przechowują kolumny wierszy pogrupowane na stronach dysku, aby umożliwić szybki dostęp do danych i przechowywanie ich w wielu wersjach. Niektóre z tych modeli są opisane szczegółowo w rozdziale 24.

Model XML-owy powstał jako standard wymiany danych w internecie i był używany do zaimplementowania kilku prototypowych natywnych systemów XML-owych. W XML-u używane są hierarchiczne struktury drzewiaste. Ten model łączy mechanizmy baz danych z rozwiązaniami z modeli reprezentacji dokumentów. Dane są tu reprezentowane jako elementy. Za pomocą znaczników dane można zagnieżdżać i tworzyć w ten sposób złożone struktury drzewiaste. Ten model koncepcyjnie przypomina model obiektowy, choć stosowana jest tu inna terminologia. Mechanizmy XML-owe zostały dodane do wielu komercyjnych SZBD. Omówienie XML-a prezentujemy w rozdziale 13.

Dwoma znacznie starszymi, historycznie ważnymi modelami danych, uważanymi obecnie za **przestarzałe**, są modele sieciowy i hierarchiczny. **Model sieciowy** reprezentuje dane w postaci typów rekordów i umożliwia (choć w ograniczonym zakresie) reprezentowanie relacji typu 1:N, tzw. **typu zbiorowego**. Relacja 1:N (jeden do wielu) łączy jeden egzemplarz rekordu z wieloma innymi za pomocą wskaźników. Model sieciowy, znany także jako model CODASYL DBTG¹², jest ściśle związany z językiem typu *record-at-a-time*, któ-

¹² Skrót CODASYL DBTG pochodzi od nazwy komitetu Conference of Data Systems Languages Data Base Task Group, który zdefiniował model sieciowy i jego język.

regu instrukcje muszą być osadzone w kodzie nadrzędnego języka programowania. Sieciowy język DML został zaproponowany w pracy 1971 Database Task Group (DBTG) Report jako rozszerzenie języka COBOL.

Model hierarchiczny reprezentuje dane w postaci hierarchicznej struktury drzewiastej. Każda taka hierarchia reprezentuje wiele powiązanych ze sobą rekordów. Dla modelu hierarchicznego nie istnieje standardowy język. Popularnym hierarchicznym językiem DML jest DL/1 z systemu IMS. Był to najpopularniejszy SZBD w latach 1965 – 1985. Używany w nim język DML (DL/1) był przez długi czas w zasadzie standardem w branży¹³.

2.7. Podsumowanie

W tym rozdziale wprowadziliśmy podstawowe terminy wykorzystywane w systemach baz danych. Zdefiniowaliśmy pojęcie modelu danych i wyróżniliśmy trzy główne kategorie modeli tego typu:

- wysokopoziomowe modele danych (nazywane też koncepcyjnymi), które opierają się na encjach i związkach;
- niskopoziomowe modele danych (nazywane też fizycznymi);
- reprezentacyjne modele danych (nazywane też implementacyjnymi), które opierają się na rekordach lub obiektach.

W rozdziale zdefiniowaliśmy pojęcie schematu (opisu) bazy danych, które oddzieliśmy od samej bazy. Schemat bazy danych nie jest zbyt często modyfikowany, natomiast stan bazy danych zmienia się za każdym razem, gdy wstawimy, usuniemy lub zmodyfikujemy dane. Następnie opisaliśmy architekturę trójwarstwową systemów zarządzania bazami danych, która umożliwia stosowanie aż trzech poziomów schematów bazy danych:

- schemat wewnętrzny, który opisuje fizyczną strukturę przechowywania bazy danych;
- schemat koncepcyjny, który jest wysokopoziomowym opisem całej bazy danych;
- schemat zewnętrzny, który opisuje perspektywy różnych grup użytkowników.

System zarządzania bazą danych, który ściśle oddziela te trzy poziomy, musi zawierać reguły odwzorowywania pomiędzy poszczególnymi schematami, aby właściwie przekształcać żądania i wyniki przekazywane z jednego poziomu do drugiego. Większość systemów zarządzania bazami danych nie oddziela tych trzech poziomów całkowicie. Wykorzystaliśmy w tym rozdziale architekturę trójwarstwową głównie po to, aby zdefiniować pojęcia logicznej i fizycznej niezależności danych.

W dalszej części tego rozdziału omówiliśmy najważniejsze typy języków i interfejsów obsługiwanych przez systemy zarządzania bazami danych. Język definicji danych (DDL) jest wykorzystywany do definiowania schematu koncepcyjnego bazy danych. W większości systemów tego typu język DDL jest ponadto wykorzystywany do definiowania per-

¹³ Kompletnie rozdziały na temat modeli sieciowych i hierarchicznych z drugiego wydania tej książki są dostępne w witrynie tej pozycji: <http://www.aw.com/elmasri>.

spektyw użytkownika, a niekiedy także struktur składowania; w innych systemach do określania struktur składowania danych mogą być używane odrębne języki lub funkcje. We współczesnych implementacjach systemów relacyjnych różnice między opisanymi funkcjami zanikają, ponieważ SQL działa jak uniwersalny język do wykonywania wielu zadań, w tym do definiowania perspektyw. We wczesnych wersjach SQL-a znajdował się język definiowania struktur składowania (język SDL), jednak obecnie w relacyjnych SZBD zwykle implementuje się go w formie specjalnych poleceń dla administratorów baz danych. System SZBD kompiluje wszystkie definicje schematów i umieszcza ich opisy w swoim katalogu.

Do określania operacji odczytywania i aktualizowania danych wykorzystuje się język manipulowania danymi (DML). Języki tego typu mogą być wysokopoziomowe (*set-oriented*, lub nieproceduralne) lub niskopoziomowe (*record-oriented*, lub proceduralne). Wysokopoziomowe języki DML można albo osadzać w kodzie nadrzędnego języka programowania, albo wykorzystywać w roli języków autonomicznych; w tym drugim przypadku języki tego typu są często nazywane językami zapytań.

Omówiliśmy także różne typy interfejsów udostępnianych przez systemy zarządzania bazami danych oraz rozmaite kategorie użytkowników systemów tego typu, dla których tworzone są poszczególne interfejsy. Dalej opisaliśmy środowisko systemu zarządzania bazą danych, typowe moduły programowe takiego systemu oraz narzędzia ułatwiające użytkownikom i administratorom wykonywanie ich zadań. W dalszej części tego rozdziału zaprezentowano przegląd architektur dwu- i trójwarstwowych używanych w aplikacjach bazodanowych.

W ostatnich fragmentach sklasyfikowaliśmy systemy zarządzania bazami danych według kilku kryteriów: modelu danych, liczby użytkowników, liczby węzłów, typów ścieżek dostępu oraz kosztów. Omówiliśmy dostępność SZBD i dodatkowych modułów — od rozwiązań darmowych w postaci oprogramowania otwartego po konfigurację, których utrzymanie kosztuje miliony złotych rocznie. Wspomnieliśmy też o różnorodnych licencjach na SZBD i powiązane produkty. Najważniejszym kryterium podziału systemów zarządzania bazami danych jest oczywiście stosowany model danych. W tym rozdziale omówiliśmy krótko główne modele danych wykorzystywane we współczesnych komercyjnych systemach tego typu.

Pytania powtórkowe

- 2.1. Zdefiniuj następujące pojęcia: *model danych*, *schemat bazy danych*, *stan bazy danych*, *schemat wewnętrzny*, *schemat koncepcyjny*, *schemat zewnętrzny*, *niezależność danych*, *język DDL*, *język DML*, *język SDL*, *język VDL*, *język zapytań*, *język nadrzędny*, *podjęzyk danych*, *narzędzie bazy danych*, *katalog*, *architektura typu klient-serwer*, *architektura trójwarstwowa* i *architektura n-warstwowa*.
- 2.2. Przedstaw główne kategorie modeli danych. Jakie są podstawowe różnice między modelami relacyjnym, obiektowym a XML-owym?
- 2.3. Jaka jest różnica pomiędzy schematem bazy danych a stanem bazy danych?
- 2.4. Opisz architekturę trójwarstwową. Wyjaśnij, dlaczego niezbędne jest stosowanie reguł odwzorowywania pomiędzy poziomami schematu. W jaki sposób różne języki definiowania schematu wspomagają stosowanie tej architektury?

- 2.5. Jaka jest różnica pomiędzy logiczną niezależnością danych a fizyczną niezależnością danych? Którą z nich trudniej jest osiągnąć? Dlaczego?
- 2.6. Jaka jest różnica pomiędzy proceduralnymi a nieproceduralnymi językami DML?
- 2.7. Przedstaw różne typy przyjaznych dla użytkownika interfejsów oraz kategorie użytkowników, które zazwyczaj korzystają z poszczególnych typów.
- 2.8. Z jakimi innymi pakietami oprogramowania komputerowego współpracują systemy zarządzania bazami danych?
- 2.9. Jaka jest różnica pomiędzy dwu- i trójwarstwowymi architekturami typu klient-serwer?
- 2.10. Przedstaw niektóre typy przydatnych programów i narzędzi baz danych wraz z oferowanymi przez nie funkcjami.
- 2.11. Jakie dodatkowe funkcje obejmuje architektura n -warstwowa ($n > 3$)?

Ćwiczenia

- 2.12. Omów rodzaje potencjalnych użytkowników bazy danych z rysunku 1.2. Jakich typów aplikacji będą potrzebowali poszczególni użytkownicy? Do której z kategorii użytkowników należałoby ich przypisać i jakich typów interfejsów będą ci użytkownicy potrzebowali?
- 2.13. Wybierz znane Ci zastosowanie bazy danych. Zaprojektuj odpowiedni schemat i przedstaw przykładową bazę danych dla tego zastosowania (zgodnie z notacją użytą na rysunkach 2.1 i 1.2). Jakiego rodzaju dodatkowych informacji i ograniczeń chciałbyś użyć do reprezentowania tego schematu? Przemyśl role wielu różnych użytkowników swojej bazy danych i dla każdego z nich zaprojektuj osobną perspektywę.
- 2.14. Gdybyś miał zaprojektować internetowy system rezerwacji biletów lotniczych, którą architekturę SZBD z podrozdziału 2.5 byś wybrał? Dlaczego? Z jakiego powodu inne architektury nie będą dobrym wyborem?
- 2.15. Przyjrzyj się rysunkowi 2.1. Obok ograniczeń wiążących wartości kolumn z jednej tabeli z kolumnami innej tabeli występują też ograniczenia dotyczące wartości kolumn (pojedynczych lub ich kombinacji) tabeli. Jedno z takich ograniczeń powoduje, że kolumna lub grupa kolumn musi mieć unikatowe wartości w skali wszystkich wierszy tabeli. Na przykład w tabeli STUDENT unikatowa musi być wartość kolumny NumerIndeksu (aby zapobiec posiadaniu identycznego numeru przez dwóch studentów). Wskaż w innych tabelach kolumny lub grupy kolumn, które muszą być unikatowe w skali wszystkich wierszy danej tabeli.

Wybrane publikacje

Wiele książek poświęconych bazom danych, włącznie z publikacjami Date'a (2004), Ramakrishnana i Gehrke'a (2003), Garcia-Moliny i in. (2002, 2009) oraz Abiteboula i in. (1995), zawiera szczegółowe omówienie rozmaitych zaprezentowanych w tym rozdziale zagadnień związanych z bazami danych. Książka autorstwa Tsichritzisa i Lochovsky'ego (1982)

była jedną z pierwszych publikacji na temat modeli danych. Zarówno książka napisana przez Tsichritzisa i Kluga (1978), jak i książka autorstwa Jardine'a (1977) prezentowały architekturę trójwarstwową, której koncepcję zaproponowano po raz pierwszy w raporcie komisji DBTG CODASYL (1971) i później w raporcie Amerykańskiego Instytutu Normalizacyjnego — ANSI (1975). Dogłębną analizę relacyjnego modelu danych i niektórych z jego potencjalnych rozszerzeń można znaleźć w książce Codda (1990). Cattell i in. (2000) zawarli w swojej książce propozycję standardu dla obiektowych baz danych. Wiele materiałów opisujących język XML jest dostępnych w internecie, np. XML (2005).

Przykładami programów narzędziowych wykorzystywanych z bazami danych są: narzędzia Connect, Analyze i Transform firmy ETI (<http://www.eti.com>) oraz przeznaczone dla administratorów baz danych narzędzie DB Artisan firmy Embarcadero Technologies (<http://www.embarcadero.com>).

PROGRAM PARTNERSKI

— GRUPY HELION —

1. ZAREJESTRUJ SIĘ
2. PREZENTUJ KSIĄŻKI
3. ZBIERAJ PROWIZJĘ

Zmień swoją stronę WWW w działający bankomat!

Dowiedz się więcej i dołącz już dzisiaj!

<http://program-partnerski.helion.pl>

GRUPA
Helion

Baza danych? Stosuj tylko najskuteczniejsze rozwiązania!

Mijają lata, a bazy danych wciąż stanowią serce większości systemów informatycznych. Rozwój technologii jednak sprawia, że zaprojektowanie systemu baz danych, jego wdrożenie i administrowanie nim wymaga biegłości w wielu dziedzinach. Niezbędne są solidne podstawy modelowania i projektowania baz danych, umiejętność posługiwania się językami i modelami udostępnianymi przez systemy zarządzania bazami danych, a także znajomość technik implementacji samych systemów. Od profesjonalisty wymaga się również wiedzy o najnowszych technologiach, takich jak NoSQL i oczywiście big data. Ważnym uzupełnieniem tej szerokiej gamy jest też znajomość technologii powiązanych z systemami bazodanowymi.

Ta książka jest siódmym, zaktualizowanym wydaniem klasycznego podręcznika do nauki baz danych. Jest to szczegółowa prezentacja najważniejszych aspektów systemów i aplikacji bazodanowych oraz powiązanych technologii. To znakomity podręcznik dla studentów i świetne kompendium dla praktyków. Sporo miejsca poświęcono w nim systemom rozproszonym oraz technologiom opartym na systemie Hadoop i modelu MapReduce. Nie zabrakło opisu takich zagadnień jak model IR, wyszukiwanie z użyciem słów kluczowych, porównanie baz danych z modelem IR, modele wyszukiwania, ocena wyszukiwania i algorytmy rankingowe. Wykładowcom przyda się szereg ułatwiających pracę dydaktyczną diagramów, prezentacji i rysunków.

W książce między innymi:

- wprowadzenie do modeli, systemów i języków z obszaru baz danych
- model związków encji i programowanie baz danych
- bazy relacyjne, obiektowo-relacyjne, obiektowe i XML w bazach danych
- algorytmy przetwarzania zapytań i techniki optymalizacji
- bezpieczeństwo baz danych

Ramez Elmasri jest profesorem na Uniwersytecie Tekszańskim. Posiada znaczący dorobek naukowy w dziedzinie baz danych, a jego książki są standardowymi podręcznikami na wielu uczelniach świata. Wypromował kilkunastu doktorów i ponad dwustu magistrów.

Shamkant Navathe jest profesorem w Instytucie Technologii w Georgii. Zajęcia dydaktyczne z wiedzy o bazach danych prowadzi od 1975 roku. Interesuje się również bioinformatyką. Ponadto jest niezależnym konsultantem, doradzającym wielu znaczącym przedsiębiorstwom.

  helion.pl	<i>Sprawdź nasze szkolenia!</i>  AKADEMIA IT & BUSINESS WWW.SZKOLENIA.HELION.PL	KOD KORZYŚCI Sięgnij po więcej!   ISBN 978-83-283-4695-6  9 788328 346956
INFORMATYKA W NAJLEPSZYM WYDANIU		Cena: 179,00 zł