

Bazy danych

3. Normalizacja baz danych

P. F. Góra

<http://th-www.if.uj.edu.pl/zfs/gora/>

2011/12

Pierwsza postać normalna

Tabela jest w pierwszej postaci normalnej (1PN), jeżeli

1. Tabela posiada klucz.
2. Wszystkie składowe krotek są atomowe.

Można powiedzieć, że pierwsza postać normalna jest warunkiem tego, żeby w ogóle można było mówić o sytemie *relacyjnym*. Warunek posiadania klucza jest równoważny temu, że *tabela jest zbiorem krotek*.

Atomowość danych

Atomowość danych oznacza, że składowych krotek nie można podzielić. **Warunek atomowości uniemożliwia to, żeby składowymi krotek były złożone struktury danych**, takie jak tablice, listy itp.

W zasadzie wymóg atomowości nakazuje dzielić też atrybuty, które *można podzielić*, na części logicznie niepodzielne. Na przykład zamiast atrybutu “Imię i Nazwisko”, powinniśmy mieć dwa atrybuty: “Imię”, “Nazwisko”. Można sobie jednak wyobrazić sytuacje, w których taki podział byłby niepotrzebny lub niewskazany*. O ile zatem pierwsza postać normalna z całą pewnością wyklucza złożone struktury danych, o tyle interpretacja pojęcia “można podzielić” może niekiedy zależeć od natury samych danych, które reprezentować ma konstruowana przez nas baza danych.

*Rozważmy na przykład nazwy osobowe z Chin czy Korei.

Anomalie baz danych

- **Redundancja** — ta sama informacja jest niepotrzebnie przechowywana w kilku krotkach.
- **Anomalia modyfikacji** — informacja zostanie zmodyfikowana w pewnych krotkach, a w innych nie. Która informacja jest wówczas prawdziwa?
- **Anomalia usuwania** — usuwanie części informacji powoduje utratę innej informacji, której nie chcielibyśmy stracić.
- **Anomalia dołączania** — wprowadzenie pewnej informacji jest możliwe tylko wtedy, gdy jednocześnie wprowadzamy jakąś inną informację, która może być obecnie niedostępna.

Celem normalizacji baz danych jest unikanie powyższych anomalii.

Bezstratne złączenie

Normalizację baz danych (powyżej 1PN) przeprowadza się dzieląc tabele “wertykalnie” na tabele potomne. Tabele te jednak **muszą** pozwalać na pełne odtworzenie wyjściowej informacji po dokonaniu złączenia. Niedopuszczalne jest także, aby złączenia kreowały informację fałszywą.

Dekompozycję tabeli R na tabele $R_1, R_2, \dots, R_n$ nazywamy **dekompozycją bezstratnego złączenia** (ze względu na pewien zbiór zależności funkcyjnych), jeśli naturalne złączenie $R_1, R_2, \dots, R_n$ jest równe tabeli R .

Dekompozycja tabeli R na dwie tabele R_1, R_2 jest dekompozycją bezstratnego złączenia, jeśli spełniony jest jeden z dwu warunków (symbol $\rightarrow$ oznacza zależność funkcyjną):

$$(R_1 \cap R_2) \rightarrow (R_1 \setminus R_2)$$

lub

$$(R_1 \cap R_2) \rightarrow (R_2 \setminus R_1)$$

Innymi słowy, wspólna część atrybutów R_1, R_2 musi zawierać klucz kandydujący R_1 lub R_2 .

Przykład negatywny

Przypuśćmy, że w pewnej tabeli przechowujemy informację na temat studentów zapisujących się na kurs baz danych. Przykładowa instancja tabeli mogłaby wyglądać tak:

T_0

NrStudenta	NrKursu	DataZapisu	Sala	Prowadzący
1010057	K202	01.10.2011	A1	Góra
1010132	K203	01.10.2011	A2	Łachwa
1015678	K202	01.10.2011	A2	Łachwa
1020159	K204	04.10.2011	A1	Góra
1026789	K205	11.10.2011	C2	Oramus

Rozbijamy tę tabelę na dwie, dzieląc je “wzdłuż” kolumny DataZapisu.

T_1

NrStudenta	NrKursu	DataZapisu
1010057	K202	01.10.201
1010132	K203	01.10.2011
1015678	K202	01.10.2011
1020159	K204	04.10.2011
1026789	K205	11.10.2011

T_2

DataZapisu	Sala	Prowadzący
01.10.2011	A1	Góra
01.10.2011	A2	Łachwa
01.10.2011	A2	Łachwa
04.10.2011	A1	Góra
11.10.2011	C2	Oramus

Dokonujemy złączenia tabel T_1 i T_2 . Okazuje się, że dzielenie pierwotnej tabeli “wzdłuż” kolumny `DataZapisu` to był kiepski pomysł. Otrzymujemy

$$T_1 \bowtie T_2 \neq T_0$$

NrStudenta	NrKursu	DataZapisu	Sala	Prowadzący
1010057	K202	01.10.2011	A1	Góra
1010132	K203	01.10.2011	A1	Góra
1015678	K202	01.10.2011	A1	Góra
itd				

Zaznaczone krotki nie występują w pierwotnej tabeli. Na skutek podziału tabeli nie spełniającego warunku bezstratnego złączenia, utraciliśmy informację o tym, kto kogo uczy.

Druga postać normalna

Tabela jest w drugiej postaci normalnej (2PN), jeżeli

1. Tabela jest 1PN.
2. Wszystkie atrybuty niekluczowe zależą funkcyjnie od pełnego klucza.

Atrybuty niekluczowe mają zależeć od *pełnego* klucza, a nie od jego podzbioru właściwego (który nie musi być kluczem!).

Wszystkie tabele 1PN, które mają klucze jednokolumnowe, są automatycznie 2PN.

Przykład

Założmy, że zależności funkcyjne pomiędzy pewnymi atrybutami mają postać $A, B \rightarrow C$, $A \rightarrow D$. Poniższa tabela (podkreślenia oznaczają klucz)

<u>A</u>	<u>B</u>	C	D
a_1	b_1	c_1	d_1
a_1	b_2	c_2	d_1
a_1	b_3	c_3	d_1
a_2	b_1	c_4	d_2

nie jest 2PN, gdyż atrybut D zależy *tylko* od atrybutu A , a więc od części klucza, nie od całego klucza. Zauważmy jednocześnie, że wartość d_1 przechowywana jest niepotrzebnie w trzech różnych krotkach.

Po rozbiciu powyższej tabeli na dwie tabele będące w 2PN, wartość d_1 przechowywana jest tylko w *jednej* krotce.

<u>A</u>	<u>B</u>	<u>C</u>
a_1	b_1	c_1
a_1	b_2	c_2
a_1	b_3	c_3
a_2	b_1	c_4

<u>A</u>	<u>D</u>
a_1	d_1
a_2	d_2

Proszę pomyśleć, że w początkowym przykładzie d_1 mogłoby występować nie w 3, ale w 300 lub w 3000 krotek.

Trzecia postać normalna

Tabela jest w trzeciej postaci normalnej (3PN), jeżeli

1. Tabela jest 2PN.
2. Dla wszystkich atrybutów tabeli zachodzi:
Jeżeli $A_1, A_2, \dots, A_n \rightarrow A_m$, to albo $\{A_1, A_2, \dots, A_n\}$ jest nadkluczem, albo A_m jest elementem innego klucza.

Trzecia postać normalna jest postacią najczęściej występującą w zastosowaniach praktycznych. Druga część warunku definicyjnego (“albo A_m jest elementem innego klucza”) ma znaczenie tylko wówczas, gdy w tabeli występują zależności cykliczne (lub częściowe zależności cykliczne).

Zależności przechodnie

Jeżeli w tabeli nie występują zależności cykliczne, powiada się, że **3PN zakazuje wsytpowania zależności przechodnich**. Istotnie, przyjmijmy, że spełnione są zależności funkcyjne $A \rightarrow B$, $B \rightarrow C$, $A \rightarrow C$; ostatnia z tych zależności wynika z dwu pierwszych na zasadzie przechodniości. Następująca tabela

<u>A</u>	B	C

jest 2PN, ale **nie** jest 3PN, gdyż zachodzi zależność $B \rightarrow C$, zaś atrybut B nie jest nadkluczem. Sprowadzenie do 3PN oznacza rozbicie powyższej tabeli na dwie tabele:

<u>A</u>	B

<u>B</u>	C

Przykład

Niech zależności funkcyjne będą takie, jak na poprzednim ekranie. Rozważmy następującą instancję pierwszej tabeli:

$\underline{A}$	B	C
a_1	b_1	c_1
a_2	b_1	c_1
a_3	b_1	c_1
a_4	b_2	c_2

Wielkość c_1 przechowywana jest w trzech krotkach. Po sprowadzeniu do 3PN

<u>A</u>	B
a_1	b_1
a_2	b_1
a_3	b_1
a_4	b_2

<u>B</u>	C
b_1	c_1
b_2	c_2

wartość c_1 przechowywana jest tylko w jednej krotce.

Cykliczne zależności funkcyjne

Przykładem cyklicznych zależności funkcyjnych jest $A \rightarrow B, B \rightarrow C, C \rightarrow A$. W takiej sytuacji atrybuty A, B, C są sobie równoważne — określenie wartości jednego z nich, jednoznacznie ustala wartość dwu pozostałych. **Każda** z trzech tabel

<u>A</u>	B	C

A	<u>B</u>	C

A	B	<u>C</u>

jest 3PN, gdyż co prawda występują zależności przechodnie, ale atrybuty niekluczowe są elementami *innych kluczy* (de facto są innymi kluczami).

Uwaga! Przy cyklicznych zależnościach funkcyjnych jak poprzednio, tabele rozdzielone w ten sposób:

<u>A</u>	B

<u>B</u>	C

<u>C</u>	A

technicznie rzecz biorąc **także** są 3PN, a nie zawierają zależności przechodnich. Jednak taki projekt **nie zapobiega redundancji**, przeciwnie, wymusza ją, gdyż każda wartość każdego z atrybutów A , B , C jest przechowywana dwa razy. Projekty z poprzedniej strony są z tego względu zdecydowanie lepsze.

Procedura postępowania

1. Dany jest zbiór atrybutów, które chcemy reprezentować, i zbiór zależności funkcyjnych pomiędzy atrybutami.
2. Znajdujemy bazę minimalną zbioru zależności funkcyjnych.
3. Mając bazę minimalną, sumujemy zależności funkcyjne o takich samych lewych stronach i dla każdej wysumowanej zależności tworzymy tabelę z odpowiednią lewą stroną zależności jako kluczem.

Taki sposób postępowania prowadzi do projektu bazy, w której tabele są 3PN.

Procedura szukania bazy minimalnej

1. Każdy atrybut musi występować z lewej lub z prawej strony jednej zależności funkcyjnej w zbiorze.
2. Jeśli jakaś zależność funkcyjna jest włączona do zbioru, nie wszystkie zależności funkcyjne potrzebne do jej wyprowadzenia mogą występować w tym zbiorze.
3. Jeśli jakaś zależność funkcyjna zostaje wyłączona ze zbioru, zależności funkcyjne potrzebne do jej wyprowadzenia muszą zostać doń dołączone.

Jeżeli w zbiorze zależności funkcyjnych występują (częściowe) cykle, może istnieć więcej niż jedna baza minimalna.

Postać normalna Boyce'a-Codda

Tabela jest w postaci normalnej Boyce'a-Codda (BCNF, PNBC), jeżeli

1. Tabela jest 2PN.
2. Dla każdej zależności nietrywialnej, jeżeli $A_1, A_2, \dots, A_n \rightarrow A_m$, to zbiór $\{A_1, A_2, \dots, A_n\}$ jest nadkluczem.

PNBC jest “silniejszą” wersją 3PN. Każda tabela będąca PNBC jest także 3PN, ale wynikanie odwrotne nie musi zachodzić.

Do czego dążymy?

Przeprowadzając normalizację bazy danych, **staramy się jednocześnie** spełnić **trzy** warunki:

1. Bezstratne złączenie.
2. Zachowanie wszystkich zależności funkcyjnych.
3. PNBC.

Czy zawsze jest to możliwe?

Rozważmy tabelę

A	B	C

z następującymi zależnościami funkcyjnymi:

$$C \rightarrow A$$

$$A, B \rightarrow C$$

(Na przykład: A — nazwa banku, B — nazwisko klienta uprawnionego do *personal banking*, C — nazwisko bankiera. Pierwsza zależność mówi, że każdy bankier pracuje w określonym banku, druga, że każdego uprawnionego klienta w danym banku obsługuje określony bankier. Ale klient może mieć konta w więcej niż jednym banku. . .)

Powyższa tabela nie jest PNBC, gdyż C nie może być nadkluczem. Jednak żadne rozbiecie na dwie tabele dwuatrybutowe albo nie zachowuje kompletu zależności funkcyjnych, albo nie jest dekompozycją bezstratnego złączenia, albo jedno i drugie. W tej sytuacji zadowalamy się niższą postacią normalną. **Zachowanie kompletu zależności funkcyjnych oraz bezstratność złączeń muszą mieć priorytet!** Nie każdą tabelę daje się znormalizować do PNBC.

Normalizacja a wydajność

Normalizacja baz danych dostarcza **mechanizmu** pozwalającego unikać anomalii. Ma to jednak swoją cenę: **Dostęp do danych w bazie znormalizowanej może być wolniejszy**, gdyż RDBMS musi wykonywać złączenia.

Dlatego w wielkich bazach danych zoptymalizowanych na odczyt (na przykład w hurtowniach danych) często rezygnuje się z wyższych postaci normalnych, przechowując dane w tabelach 1PN. **To** także ma swoją cenę: Wprowadzając dane do takich tabel lub modyfikując istniejące dane należy dołożyć szczególnej staranności, aby nie dopuścić do anomalii usuwania lub dołączania, a szczególnie do anomalii modyfikacji (redundancja jest w tego typu bazy niejako wbudowana).