

# Bazy danych

## 3. Zależności funkcyjne

P. F. Góra

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

2020

**Zależności funkcyjne** (ang. *functional dependencies*) to jedno z najważniejszych pojęć teoretycznych w relacyjnym modelu baz danych.

**Definicja.** Niech  $A_1, A_2, \dots, A_n, B_1, B_2, \dots, B_m, C_1, C_2, \dots$  będą atrybutami pewnej tabeli R. Oznaczmy  $X = \{A_1, A_2, \dots, A_n\}$ ,  $Y = \{B_1, B_2, \dots, B_m\}$ ,  $Z = \{C_1, C_2, \dots\}$ . Mówimy, że zbiór atrybutów  $Y$  **zależy funkcyjnie** od zbioru atrybutów  $X$  wtedy i tylko wtedy, gdy każda ustalona wartość  $X$  jest **jednoznacznie** powiązana z dokładnie jedną wartością  $Y$ .

Zależności funkcyjne zapisujemy w postaci

$$A_1, A_2, \dots, A_n \rightarrow B_1, B_2, \dots, B_m$$

lub w skrócie

$$X \rightarrow Y$$

*Alternatywnie* możemy powiedzieć, że wynik rzutowania

$$\pi_{X,Y}(R)$$

określa  $Y$  jako funkcję  $X$ .

*Alternatywnie*, jeżeli dwie krotki w tabeli  $R$  są zgodne w atrybutach  $A_1, \dots, A_n$  **muszą** być zgodne w atrybutach  $B_1, B_2, \dots, B_m$ .

$$X \rightarrow Y$$

$X$	$Y$	$Z$
$x$	$y$	$z_1$
$x$	$y$	$z_2$
jeżeli są zgodne tutaj...	...to muszą być zgodne tutaj	

Na przykład spodziewamy się, że w “osobowej” bazie danych obowiązuje zależność funkcyjna PESEL  $\rightarrow$  Nazwisko. Jeżeli dwie krotki mają taki sam numer PESEL, *muszą* odnosić się do osób mających to samo Nazwisko.

Zauważmy, że odwrotna zależność funkcyjna w ogólności nie musi zachodzić. W powyższym przykładzie dwie osoby — powiedzmy, matka i córka — mogą mieć to samo nazwisko, ale różne numery PESEL.

- Zależności funkcyjne stanowią więź nałożony na dopuszczalne wartości danych (na przykład *nie wolno* stworzyć dwóch krotek o takich samych PESEL-ach, ale różnych Nazwiskach).
- Zależności funkcyjne “odkrywamy” (lub arbitralnie narzucamy) w procesie analizy tego fragmentu rzeczywistości, który projektowana baza danych ma modelować.
- Zależności funkcyjne należą do schematu bazy.
- Zależności funkcyjne są matematycznym modelem więzów jednoznaczności w modelu relacyjnym baz danych.
- O zależnościach funkcyjnych nie można wnioskować jedynie na podstawie instancji (faktycznych wystąpień) tabel.

## Zależności trywialne

- Zależność funkcyjną  $A_1, A_2, \dots, A_n \rightarrow B$  nazywam *trywialną*, jeśli atrybut  $B$  jest równy któremuś atrybutowi  $A_{1,2,\dots,n}$ .
- Jeśli przyjmiemy “skrótowy” zapis zależności z wielocłonową prawą stroną, zależność jest
  - *Trywialna*, jeśli zbiór złożony z atrybutów  $B$  jest podzbiorem zbioru złożonego z atrybutów  $A$
  - *Nietrywialna*, jeśli co najmniej jeden  $B$  nie jest  $A$
  - *Całkowicie nietrywialna*, jeśli żadnen  $B$  nie jest  $A$ .

## Reguły wnioskowania (aksjomaty Armstronga)

**zwrotność:** Jeżeli  $\{B_1, B_2, \dots, B_m\} \subseteq \{A_1, A_2, \dots, A_n\}$ , to  
 $A_1, A_2, \dots, A_n \rightarrow B_1, B_2, \dots, B_m$ .

**rozszerzenie:** Jeżeli  $A_1, A_2, \dots, A_n \rightarrow B_1, B_2, \dots, B_m$ , to  
 $A_1, A_2, \dots, A_n, C_1, C_2, \dots, C_k \rightarrow B_1, B_2, \dots, B_m, C_1, C_2, \dots, C_k$  dla  
dowolnych  $C_1, C_2, \dots, C_k$ .

**przechodność:** Jeżeli  $A_1, A_2, \dots, A_n \rightarrow B_1, B_2, \dots, B_m$  oraz  
 $B_1, B_2, \dots, B_m \rightarrow C_1, C_2, \dots, C_k$ , to  $A_1, A_2, \dots, A_n \rightarrow C_1, C_2, \dots, C_k$ .

## Dodatkowe reguły wnioskowania

Można udowodnić, że poniższe reguły wnioskowania wynikają wprost z aksjomatów Armstronga:

- Relacja zwrotna:  $X \rightarrow X$
- Rozszerzanie: jeżeli  $X \rightarrow Y$ , wtedy  $X, Z \rightarrow Y$
- Sumowanie: jeżeli  $X \rightarrow Y$  oraz  $X \rightarrow Z$ , wtedy  $X \rightarrow Y, Z$
- Rozkład: jeżeli  $X \rightarrow Y$  oraz  $Z \subseteq Y$ , to  $X \rightarrow Z$
- Przechodność: jeżeli  $X \rightarrow Y$  oraz  $Y \rightarrow Z$ , to  $X \rightarrow Z$
- Pseudoprzechodność: jeżeli  $X \rightarrow Y$  oraz  $Y, Z \rightarrow W$ , to  $X, Z \rightarrow W$ .



## Domknięcia

Niech  $\{A_1, A_2, \dots, A_n\}$  będzie pewnym zbiorem atrybutów,  $S$  niech będzie zbiorem zależności funkcyjnych. **Domknięciem zbioru  $\{A_1, A_2, \dots, A_n\}$  nad  $S$**  nazywamy taki zbiór atrybutów  $B$ , że jeśli jego elementy spełniają wszystkie zależności funkcyjne z  $S$ , to spełniają także zależność  $A_1, A_2, \dots, A_n \rightarrow B$ , a zatem zależność  $A_1, A_2, \dots, A_n \rightarrow B$  wynika z  $S$ .

Domknięcie oznaczam  $cl\{A_1, A_2, \dots, A_n\}$ .

Mówiąc niezbyt ściśle, domknięcie to zbiór wszystkich atrybutów determinowanych, w sensie zależności funkcyjnych, przez atrybuty zbioru wyjściowego.

## Algorytm obliczania domknięcia

1. Na początku  $X$  oznacza zbiór  $\{A_1, A_2, \dots, A_n\}$ .
2. Znajdujemy wszystkie zależności funkcyjne postaci  $B_1, B_2, \dots, B_m \rightarrow C$ , gdzie  $B_i$  należą do  $X$ , a  $C$  nie należy. Dołączamy  $C$  do  $X$ .
3. Powtarzamy krok 2 tak długo, jak długo do  $X$  można dołączyć jakiś nowy atrybut. Ponieważ  $X$  może się tylko rozszerzać, zaś zbiór atrybutów jest skończony, po skończonej liczbie kroków nastąpi moment, w którym do  $X$  nie da się niczego dołączyć.
4. W tym momencie  $X = \text{cl}\{A_1, A_2, \dots, A_n\}$ .

Powyżej przedstawiony algorytm jest poprawny i intuicyjnie prosty, ale nie jest efektywny — może być algorytmem kwadratowym (w czasie) w najgorszym przypadku.

Znacznie rozsądniej jest tak uporządkować zależności funkcyjne, aby każda była używana (“odpalana”) dokładnie w tym momencie, w którym wszystkie atrybuty jej lewej strony znajdują się w “kandydacie”  $X$ .

Dla dużych baz (i tabel) domknięć nie oblicza się ręcznie! Istnieje specjalny software, który to robi.

## Przykład

Rozważmy zbiór atrybutów  $\{A, B, C, D, E, F\}$ . Załóżmy, że w tym zbiorze zachodzą zależności  $A, B \rightarrow C$ ,  $B, C \rightarrow A, D$ ,  $D \rightarrow E$ ,  $C, F \rightarrow B$ . Obliczmy  $\text{cl}\{A, B\}$ .

$X = \{A, B\}$ . Wszystkie atrybuty poprzednika zależności  $A, B \rightarrow C$  są w  $X$ , więc do  $X$  dołączamy  $C$ .  $X = \{A, B, C\}$ .

Lewa strona zależności  $B, C \rightarrow A, D$  jest w  $X$ ,  $A$  jest już w  $X$ , więc do  $X$  dołączamy  $D$ .  $X = \{A, B, C, D\}$ .

Na mocy zależności  $D \rightarrow E$ , dołączamy do  $X$  atrybut  $E$ .  $X = \{A, B, C, D, E\}$ .

Zależności  $C, F \rightarrow B$  nie możemy wykorzystać, ponieważ  $F \notin X$  i nie ma jak dołożyć  $F$  do  $X$ .

Ostatecznie  $\text{cl}\{A, B\} = \{A, B, C, D, E\}$ .

## Bazy zależności funkcyjnych

Każdy zbiór zależności funkcyjnych pewnego zbioru atrybutów, z którego można wyprowadzić wszystkie inne zależności funkcyjne zachodzące pomiędzy elementami tego zbioru, nazywam **bazą zbioru zależności funkcyjnych**. Jeśli żaden podzbiór bazy nie jest bazą (nie umożliwia wyprowadzenia wszystkich relacji), bazę tę nazywam **bazą minimalną**.

## Przykład

Mam atrybuty  $A, B, C$  i zależności  $A \rightarrow B, A \rightarrow C, B \rightarrow A, B \rightarrow C, C \rightarrow A, C \rightarrow B$ . Można teraz wyprowadzić zależności nietrywialne  $A, B \rightarrow C, A, C \rightarrow B, B, C \rightarrow A$  (oraz zależności trywialne). Bazą minimalną jest zbiór  $\{A \rightarrow B, B \rightarrow A, B \rightarrow C, C \rightarrow B\}$ .

Inną bazą minimalną jest  $A \rightarrow B, B \rightarrow C, C \rightarrow A$ .

Pytanie:

**Po co jemy tę żabę?!**

## Klucze

Mówimy, że zbiór atrybutów  $\{A_1, A_2, \dots, A_n\}$  tworzy **klucz** pewnej tabeli, jeśli wszystkie pozostałe atrybuty z tej tabeli są funkcyjnie zależne od wskazanego zbioru.

Dwie **różne** krotki nie mogą mieć tych samych kluczy (jeśli mają takie same klucze, muszą mieć równe także pozostałe atrybuty, a zatem *nie* są różne). Jeżeli przyjmujemy, że tabele są zbiorami krotek — w zbiorze każdy element występuje co najwyżej raz — widzimy, że klucz jednoznacznie identyfikuje krotkę.



Klucz o tej własności, że żaden jego podziór właściwy nie jest kluczem, nazywamy **kluczem minimalnym**.

Terminologia alternatywna: W niej to, co powyżej nazwaliśmy kluczem minimalnym, nazywa się po prostu kluczem, natomiast każdy nadzbiór klucza nazywamy **nadkluczem**.

Zauważmy, że zbiór  $cl\{A_1, A_2, \dots, A_n\}$  zawiera wszystkie atrybuty pewnej tabeli wtedy i tylko wtedy, gdy  $\{A_1, A_2, \dots, A_n\}$  jest (nad)kluczem tej tabeli.

Sprawdzenie, czy dany zbiór elementów stanowi klucz tabeli, sprowadza się do sprawdzenia,

- czy wszystkie atrybuty tabeli należą do domknięcia klucza kandydującego,
- czy jakiś właściwy podzbiór klucza kandydującego także nie ma tej właściwości.

**Obliczanie domknięć nad zadanym zbiorem zależności funkcyjnych jest formalnym narzędziem służącym do identyfikowania kluczy tabel.**