

## Bazy danych 2022

na podstawie slajdów Przemysławy Kanarek

14 marca 2022

# Przykład 1

## Baza danych

$S = (\underline{indeks}, \underline{nazwisko}, \underline{rok}), P = (\underline{nazwa}, \underline{typ}), O = (\underline{indeks}, \underline{przed}, \underline{data}, \underline{stop})$

- $x \in S \wedge (\exists y)(y \in O \wedge y.indeks = x.indeks \wedge y.stop = 5 \wedge y.przed = 'BD')$
- $\{x \mid x \in S \wedge (\exists y)(y \in O \wedge y.indeks = x.indeks \wedge y.stop = 5 \wedge y.przed = 'BD')\}$
- $\{z^{[nazwisko, indeks]} \mid (\exists x)(x \in S \wedge z.indeks = x.indeks \wedge z.nazwisko = x.nazwisko \wedge (\exists y)(y \in O \wedge y.indeks = x.indeks \wedge y.stop = 5 \wedge y.przed = 'BD'))\}$

## Znaczenie zapytań

- $x$  - student, który dostał 5.0 z  $BD$ .
- Wszyscy studenci, którzy dostali 5.0 z  $BD$ .
- Nazwiska i indeksy studentów, którzy dostali 5.0 z  $BD$ .

## Przykład 2

### Baza danych

$S = (\underline{indeks}, \underline{nazwisko}, \underline{rok})$ ,  $P = (\underline{nazwa}, \underline{typ})$ ,  $O = (\underline{indeks}, \underline{przed}, \underline{data}, \underline{stop})$

- 2a.  $\{x \mid x \in S \wedge \neg(\exists y)(y \in O \wedge y.indeks = x.indeks \wedge y.stop = 5)\}$   
 2b.  $\{x \mid x \in S \wedge \neg(\exists y)(y \in O \wedge y.indeks = x.indeks \wedge y.stop \neq 5)\}$   
 2c.  $\{x \mid x \in S \wedge (\exists y)(y \in O \wedge y.indeks = x.indeks \wedge y.przed = 'BD' \wedge \neg(\exists y_1)(y_1 \in O \wedge y_1.indeks \neq x.indeks \wedge y_1.przed = 'BD' \wedge y_1.stop > y.stop))\}$

### Znaczenie zapytań

- 2a. Studenci, którzy nie dostali żadnej piątki.  
 2b. Studenci, którzy mają tylko piątki.  
 2c. Studenci, którzy mają najlepszą ocenę z Baz danych.

## Zapytanie relacyjnego rachunku krotek

### Formuła rrk — opisuje własności krotek

Formuła atomowa:

- $R(t)$  lub  $t \in R$ , gdzie  $R$  to relacja z bazy danych, a  $t$  to zmienna (krotkowa);
- $t.a = c$ , gdzie  $a$  jest atrybutem  $t$ ; równość można zastąpić przez:  
 $\neq, <, \leq, >, \geq$ , a  $c$  jest stałą lub atrybutem innej zmiennej krotkowej;

Formuła:

- formuła atomowa,
- $(\phi)$ ,  $\neg(\phi)$ ,  $\phi \vee \psi$ ,  $\phi \wedge \psi$ , gdzie  $\phi$  i  $\psi$  są formułami;
- $(\exists t)(\phi(t))$  lub  $(\forall t)(\phi(t))$ , gdzie  $\phi$  jest formułą, a  $t$  jej zmienną wolną.

### Zapytanie rrk — wybiera krotki mające daną własność

$$\{x \mid \phi(x)\} \quad \{x^{[A_1, A_2, \dots, A_k]} \mid \phi(x)\},$$

gdzie  $x$  jest zmienną krotkową, a  $\phi$  jest formułą relacyjnego rachunku krotek, w której  $x$  jest jedyną zmienną wolną;

# Przykład 1

## Baza danych

$S = (\textit{indeks}, \textit{nazwisko}, \textit{rok})$ ,  $P = (\textit{nazwa}, \textit{typ})$ ,  $O = (\textit{indeks}, \textit{przed}, \textit{data}, \textit{stop})$

1.  $S(x_1, x_2, x_3) \wedge (\exists y_1, y_2, y_3, y_4)((O(y_1, y_2, y_3, y_4) \wedge y_1 = x_1 \wedge y_2 = 'BD' \wedge y_4 = 5)$
- 1a.  $S(x_1, x_2, x_3) \wedge (\exists y_3)(O(x_1, 'BD', y_3, 5))$
2.  $\{x_1, x_2, x_3 \mid S(x_1, x_2, x_3) \wedge (\exists y_3)(O(x_1, 'BD', y_3, 5))\}$
3.  $\{x_1, x_2 \mid (\exists x_3)(S(x_1, x_2, x_3) \wedge (\exists y_3)(O(x_1, 'BD', y_3, 5)))\}$
- 3a.  $\{ind, naz \mid (\exists rok)(S(ind, naz, rok) \wedge (\exists dat)(O(ind, 'BD', dat, 5)))\}$

## Znaczenie zapytań

1.  $x$  - student, który dostał 5.0 z  $BD$ .
2. Wszyscy studenci, którzy dostali 5.0 z  $BD$ .
3. Nazwiska i indeksy studentów, którzy dostali 5.0 z  $BD$ .

## Przykład 2

### Baza danych

$S = (\underline{\text{indeks}}, \text{nazwisko}, \text{rok}), P = (\underline{\text{nazwa}}, \text{typ}), O = (\underline{\text{indeks}}, \underline{\text{przed}}, \underline{\text{data}}, \text{stop})$

2a.  $\{(i, n, r) \mid S(i, n, r) \wedge \neg(\exists p, d)(O(i, p, d, 5))\}$

2b.  $\{(i, n, r) \mid S(i, n, r) \wedge \neg(\exists p, d, s)(O(i, p, d, s) \wedge s \neq 5)\}$

2c.  $\{(i, n, r) \mid S(i, n, r) \wedge (\exists d, s)(O(i, 'BD', d, s) \wedge \neg(\exists i_1, d_1, s_1)(O(i_1, 'BD', d_1, s_1) \wedge i \neq i_1 \wedge s_1 > s))\}$

### Znaczenie zapytań

2a. Studenci, którzy nie dostali żadnej piątki.

2b. Studenci, którzy mają tylko piątki.

2c. Studenci, którzy mają najlepszą ocenę z Baz danych.

## Zapytanie relacyjnego rachunku dziedzin

### Formuła rrd — opisuje własności wektorów zmiennych dziedzinowych

Formuła atomowa:

- $R(x_1, x_2, \dots, x_k)$  lub  $(x_1, x_2, \dots, x_k) \in R$ , gdzie  $R$  to relacja o arności  $k$ ,  $x_1, x_2, \dots, x_k$  to zmienne lub stałe (dziedzinowe);
- $x = c$ , gdzie  $x$  jest zmienną; równość można zastąpić przez:  $\neq, <, \leq, >, \geq$ , a  $c$  jest stałą lub zmienną;

Formuła:

- formuła atomowa,
- $(\phi), \neg(\phi), \phi \vee \psi, \phi \wedge \psi$ , gdzie  $\phi$  i  $\psi$  są formułami;
- $(\exists t_1, t_2, \dots, t_\ell)(\phi(t_1, t_2, \dots, t_\ell))$  lub  $(\forall t_1, t_2, \dots, t_\ell)(\phi(t_1, t_2, \dots, t_\ell))$ , gdzie  $\phi$  jest formułą, a  $t_1, t_2, \dots, t_\ell$  jej zmiennymi wolnymi.

### Zapytanie rrd — wybiera wektory wartości zmiennych mające daną własność

$$\{x_1, x_2, \dots, x_\ell \mid \phi(y_1, y_2, \dots, y_k)\},$$

gdzie  $\phi$  jest formułą relacyjnego rachunku krotek, a  $x_1, x_2, \dots, x_\ell$  to zmienne dziedzinowe i stałe, wśród których występują wszystkie zmienne wolne  $\phi$ :  $y_1, y_2, \dots, y_k$  i tylko takie zmienne;

## Niezależność od dziedziny (domain independence)

### Trudny przykład

$E(\text{osoba}, \text{temat})$  to baza ekspertów z określonych tematów. Poszukujemy pary ekspertów, którzy razem tworzą zespół znający się na wszystkich tematach.

$$\{a, b \mid (\forall d)((\exists c)(E(c, d)) \Rightarrow E(a, d) \vee E(b, d))\}$$

$$\{x \mid P(x) \wedge (\forall y)L(x, y)\}$$

$$\{x \mid \neg(\exists y)E(x, y)\}$$

### Co jest nie tak?

- Szukamy takich par  $(a, b)$ , że dla każdego tematu  $d$  (czyli zmiennej występującej w drugiej kolumnie  $E$ )  $a$  lub  $b$  jest ekspertem w tym temacie (występuje w parze z  $d$  w relacji  $E$ ).
- Jeśli nie ma tematów ( $E$  jest pusta), to **każda para wartości  $(?, ?)$**  spełnia formułę zapytania.
- Jeśli jest jeden ekspert *Wszystkowiedzący* znający się na wszystkim, to **każda para** ('*Wszystkowiedzący*',  $?$ ) spełnia formułę zapytania.
- W obu przypadkach wynik **zależy od przyjętego uniwersum!**
- AAAAAAAAAAAAA! Przecież to może być zbiór nieskończony!



## Niezależność od dziedziny (domain independence)

Niech  $\phi_B(\mathcal{A})$  oznacza zbiór krotek będący wynikiem zapytania  $\phi$  obliczonego na bazie  $\mathcal{A}$  przy założeniu, że dziedzina (zbiór możliwych wartości zmiennych) to  $B$ .

### Dziedzina formuły

Zbiór  $D$  nazwiemy **dziedziną (aktywną)** formuły  $\phi$ , gdy jest to zbiór wszystkich wartości występujących we wszystkich kolumnach wszystkich relacji wspomnianych w  $\phi$  oraz wszystkich stałych występujących jawnie w  $\phi$ .

Zapytanie  $\phi$  jest *dziedzinowo niezależne* wtedy i tylko wtedy gdy nie istnieje:

- taka baza danych  $\mathcal{A}$  oraz
- dwie dziedziny  $D_1$  i  $D_2$  zawierające dziedzinę formuły  $\phi$  takie, że  $\phi_{D_1}(\mathcal{A}) \neq \phi_{D_2}(\mathcal{A})$ .

## Niezależność od dziedziny (domain independence)

Formuły, które zależą od dziedziny są niebezpieczne!

Sprawdzenie czy formuła jest dziedzinowo niezależna jest nierozstrzygalne!

Czy zapytania algebry relacji są dziedzinowo niezależne?

# Formuły bezpieczne

Niech  $D$  będzie dziedziną formuły  $\phi$ .

## Kwantyfikatory ograniczone

Formuła  $\phi$  jest bezpieczna, jeśli poniższe modyfikacje nie wpływają na jej wartość:

- $(\exists x)\phi(x)$  można zamienić na  $(\exists x \in D)\phi(x)$ , czyli  $(\exists x)D(x) \wedge \phi(x)$ ;
- $(\forall x)\phi(x)$  można zamienić na  $(\forall x \in D)\phi(x)$ , czyli  $(\forall x)D(x) \Rightarrow \phi(x)$ ;
- $\{x \mid \phi(x)\}$  można zamienić na  $\{x \in D^k \mid \phi(x)\}$ , gdzie  $k$  jest arnością  $x$ , a  $D^k$  to iloczyn kartezyjski  $k$  kopii  $D$ .

Co to ma wspólnego z tym, że formuła jest niezależna od dziedziny? Istnieją takie ograniczenia składni, które dają gwarancję bezpieczeństwa.

## Twierdzenie

*Języki zapytań dla modelu relacyjnego:*

- *algebra relacji,*
- *relacyjny rachunek krotek i relacyjny rachunek dziedzin*

*nie są sobie równoważne.*

Każde wyrażenie algebry relacji zwraca zbiór skończony!

## Twierdzenie (Twierdzenie)

*Języki zapytań dla modelu relacyjnego:*

- *algebra relacji,*
- *relacyjny rachunek krotek ograniczony do formuł bezpiecznych i*
- *relacyjny rachunek dziedzin ograniczony do formuł bezpiecznych*

*są sobie równoważne.*

**Proste ćwiczenie 1:** Dla każdego wyrażenia algebry relacji istnieje równoważna mu bezpieczna formuła w relacyjnym rachunku krotek.

**Bardzo proste ćwiczenie 2:** Dla każdej bezpiecznej formuły w relacyjnym rachunku krotek istnieje równoważna mu bezpieczna formuła w relacyjnym rachunku dziedzin.

**Twierdzenie 1:** Dla każdej bezpiecznej formuły w relacyjnym rachunku dziedzin istnieje równoważne mu wyrażenie algebry relacji.

Pokażemy, że dla każdego  $\phi(x_1, \dots, x_k)$  — bezpiecznej formuły relacyjnego rachunku dziedzin o zmiennych wolnych  $x_1, x_2, \dots, x_k$  istnieje wyrażenie algebry relacji  $W_\phi$ , którego wartością jest  $\{x_1, x_2, \dots, x_k \mid \phi(x_1, x_2, \dots, x_k)\}$ .

- 1 Zdefiniujemy dziedzinę  $\phi$ :

$$D_\phi = \{c_1, c_2, \dots, c_\ell\} \cup \bigcup_{\pi A \in \text{attr}(R_i)} (R_i),$$

gdzie  $c_1, c_2, \dots, c_\ell$  to wszystkie stałe występujące w  $\phi$ , a  $R_1, R_2, \dots, R_m$  to symbole wszystkich relacji występujących w  $\phi$ .

- 2 Przekształćmy formuły atomowe występujące w  $\phi$  tak, by nie zawierały stałych i powtarzających się zmiennych:

$$R(x, y, x, 13) \rightarrow (\exists z, u) R(x, y, z, u) \wedge x = z \wedge u = 13$$

- 3 Przekształćmy  $\phi$  w ten sposób, by nie zawierała spójników  $\wedge$  i kwantyfikatorów  $\forall$ .

# Podstawa indukcji

- dla  $\phi(x, y, z) \equiv R(x, y, z)$  definiujemy

$$W_\phi = R, \text{ ewentualnie } W_\phi = \rho_{x,y,z}(R)$$

- dla  $\phi(x) \equiv x > \text{const}$  definiujemy

$$W_\phi = \sigma_{x > \text{const}}(\rho_x(D))$$

- dla  $\phi(x) \equiv x = \text{const}$  definiujemy

$$W_\phi = \sigma_{x = \text{const}}(\rho_x(D)) \text{ lub } \rho_x(\{\text{const}\})$$

- dla  $\phi(x, y) \equiv x \neq y$  definiujemy

$$W_\phi = \sigma_{x \neq y}(\rho_x(D) \times \rho_y(D))$$

## Krok indukcyjny

- dla  $\phi(x) \equiv \neg\psi(x)$  i wyrażenia  $W_\psi$  z atrybutem  $x$  definiujemy

$$W_\phi = \rho_x(D) \setminus W_\psi$$

- dla  $\phi(x, y, z) \equiv \psi(x, y) \vee \eta(y, z)$  i wyrażeń  $W_\psi$  i  $W_\eta$  z atrybutami odpowiednio:  $x, y$  oraz  $y, z$  definiujemy

$$W_\phi = (W_\psi \times \rho_z(D)) \cup (\rho_x(D) \times W_\eta)$$

- dla  $\phi(x) \equiv (\exists y)\psi(x, y)$  i wyrażenia  $W_\psi$  z atrybutami  $x, y$  definiujemy

$$W_\phi = \pi_x(W_\psi)$$



# Wnioski

- 1 Mamy trzy równoważne języki zapytań dla modelu relacyjnego:
  - ▶ Dwa z nich, rachunki relacyjne, są deklaratywne — formułując zapytanie podajemy jego znaczenie, a nie sposób obliczania.
  - ▶ Jeden z nich, algebra relacji, jest imperatywny — pisząc wyrażenie podajemy sposób wyliczania, ale znaczenie wyrażenia nie musi być jasne.
- 2 Moc, czyli możliwości ekspresji rachunków relacyjnych, jest bardzo dobrze znana:
  - ▶ to logika pierwszego rzędu, w której można opisać wiele własności,
  - ▶ nie można jednak wyrazić np. domknięcia tranzytywnego, do czego potrzebne jest kwantyfikowanie po relacjach (powiedzenie, że "istnieje relacja, taka że..."),
  - ▶ łatwiej zastanawiać się czy zapytania są równoważne lub zawierają się w sobie (optymalizacje!).

## Zapytania koniunkcyjne

- Wiele naturalnych własności można wyrazić wyrażeniami algebry relacji używającymi wyłącznie selekcji, projekcji, złączeń i przemianowań.
- Fragmentowi temu odpowiadają zapytania koniunkcyjne, są to formuły rrd/rrk postaci

$$\varphi(\vec{x}) = \exists \vec{y} \bigwedge_i R_i(\vec{x}, \vec{y})$$