Bazy Danych

Andrzej M. Borzyszkowski
Instytut Informatyki

Uniwersytetu Gdańskiego

materiały dostępne elektronicznie
http://inf.ug.edu.pl/~amb

Architektura systemów zarządzania bazą danych

Architektura SZBD

Trzy poziomy architektury

1. wewnętrzny
   - fizyczne przechowywanie danych
   - typy rekordów, indeksy, reprezentacja pól, kolejność przechowywania
2. pojęciowy (koncepcyjny)
   - reprezentacja całej zawartości informacyjnej bazy
   - również reguły spójności
3. zewnętrzny
   - perspektywa konkretnego użytkownika
   - typy, pola, rekordy widziane przez pewnego użytkownika mogą być różne dla różnych użytkowników

Architektura SZBD – schemat

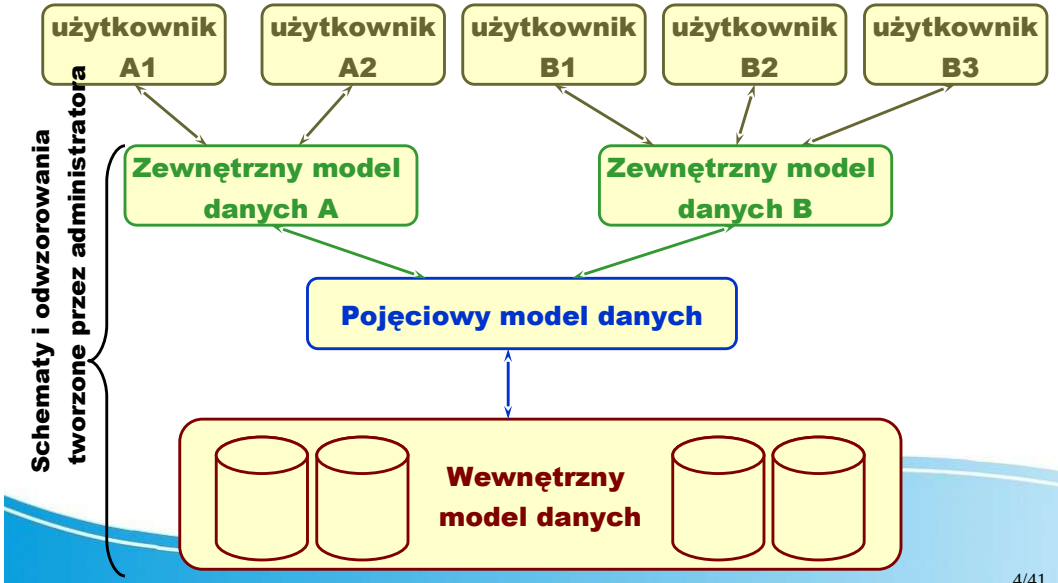

Architektura SZBD – klient-serwer

- Serwer jest systemem zarządzania bazą danych
- Klientami są aplikacje poziomu zewnętrznego

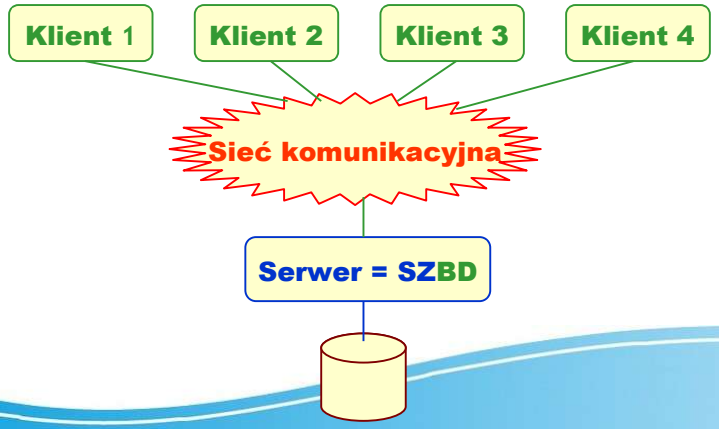

Programowanie po stronie serwera

Konieczność rozszerzenia języka zapytań

- Rozszerzenia możliwości standardowych zapytań
  - zależą od konkretnej implementacji SZBD
  - większość (wszystkie?) implementacje mają jakieś rozszerzenia
  - PostgreSQL też ma, nawet dużo możliwości
- Czego SQL nie zapewni:

```
CREATE TABLE BoM (id int PRIMARY KEY,
    name varchar(22), part_of int REFERENCES
      BoM(id))
```

  - jest tabelą z *rekursywnym* kluczem obcym

```
SELECT Sub.id
    FROM BoM M INNER JOIN BoM Sub ON
      M.id=Sub.part_of
    WHERE M.id=1
```

  - wyświetla numery podzespołów, ale tylko bezpośrednich

Przykład

```
 id | name          | id |        name
----+---------------+----+--------------------
  1 | rower         |  2 | rama
  1 | rower         |  3 | kierownica
  1 | rower         |  5 | wspornik kierownicy
  1 | rower         |  6 | koło przednie
  1 | rower         |  7 | koło tylne
  1 | rower         | 11 | hamulce przednie
  1 | rower         | 12 | hamulce tylne
  1 | rower         | 13 | kaseta
  1 | rower         | 14 | przerzutka tylna
```

- można sięgnąć jeden poziom głębiej

```
 id |     name      | id |          name
----+---------------+----+------------------------
  3 | kierownica    |  4 | chwyty kierownicy
  6 | koło przednie |  8 | opona
  6 | koło przednie |  9 | dętka
  6 | koło przednie | 15 | piasta koła przedniego
  6 | koło przednie | 16 | szprycha
  6 | koło przednie | 17 | obręcz
```

Rekursja

- W standardowym SQL *nie ma* możliwości zażądania wyświetlenia wszystkich podzespołów na nieograniczonej głębokości
  - uwaga: standard SQL3 przewiduje taką możliwość
- W dowolnym języku programowania bez problemu można napisać pętlę (lub procedurę rekursywną) przeglądającą drzewo na całej głębokości

```
wyświetl(int mat){
    print mat;
    for Sub in BoM if Sub.part_of=mat wyświetl(Sub.id);
    }
wyświetl(1);
```


Rekursja w Postgresie

```
WITH RECURSIVE Sub(id, name, part_of) AS (
    SELECT id, name, part_of FROM BoM WHERE id = 1
UNION ALL
    SELECT M.id, M.name, M.part_of
    FROM Sub, BoM M
    WHERE Sub.id = M.part_of
)
SELECT id, name
FROM Sub
```

- tworzy na bieżąco (wirtualnie) tabelę podzespołów zespołu o podanym numerze i wyświetla wszystkie te podzespoły

Operatory/funkcje/procedury

- Powód rozszerzeń
  - niewystarczalność SQL
  - wydajność, wygoda, etc.
- Rodzaje rozszerzeń
  - operatory
  - funkcje
  - procedury uruchamiane podczas startu bazy danych
  - procedury wyzwalane
- Możliwe języki programowania
  - SQL
  - PL/pgSQL
  - C
  - PL/Tcl, PL/Perl, PL/Python, i wiele innych

Operatory

```
SELECT * FROM towar WHERE (cena*100)%100=99
SELECT * FROM towar WHERE opis ~'^[IL].*x'
```

- operatory arytmetyczne (+ * / % ^ @ |/), logiczne, napisowe (||), binarne (>> << & | #)
- relacje arytmetyczne, napisowe (~ ~*)
- **ISNULL, LIKE,**
- operatory dotyczące czasu, adresów IP, ...
- można sprawdzić w powłoce psql
  - \do, \df

Funkcje

- Operują na liczbach, napisach, datach, adresach IP, ...
- Wiele funkcji ma wspólną nazwę, ale działa na innych typach
  - czasami działają tak samo, użytkownik nie zauważa typowania
  - czasami są to zupełnie różne funkcje
    - dodawanie liczb vs. konkatenacja napisów
    - dzielenie liczb rzeczywistych vs. dzielenie liczb całkowitych
- Przykłady funkcji wbudowanych

  matematyczne: log(x), pi(), random()

  napisowe: char_length(s), lower(s), trim(trailing ' ' from s)

Funkcje, c.d.

- Pożyteczne funkcje wbudowane:
  - ascii(s), chr(n) – zamiana liter i liczb wg kodu ASCII
  - ltrim(s), rtrim(s), btrim(s) – obcina spacje w końcach napisu
  - lpad(s,n), rpad(s,n) – wypełnia spacjami na końcu napisu
  - char_length(s), bit_length(x) – długości
  - lower(s), upper(s), initcap(s) – zamiana wielkości liter
  - substr(s,n,len), position(s1 IN s2) – podnapisy
  - translate (s, wzorzec, zamiennik) – zamiana liter
- date_part('jednostka',czas)
  - year, month, day, hour, minute, second
  - dow (dzień tygodnia), doy (dzień w roku), week
  - epoch (sekundy od 1.I.1970)
- Zamiana typu: to_char, to_date, to_number, to_timestamp

Definiowanie własnych funkcji

```
CREATE FUNCTION nazwa ([typ [,...]])
    RETURNS typ_wyniku
    AS definicja funkcji w jakimś języku
    LANGUAGE nazwa_języka


CREATE FUNCTION plus_raz(int4)
    RETURNS int4
    AS '
    BEGIN
    RETURN $1+1;  -- można też dać nazwę dla argumentu
                  -- ALIAS liczba FOR $1
    END
    ' LANGUAGE 'plpgsql'
```


Definiowanie funkcji c.d.

- Język
  - musi być znany Postgresowi, tzn. musi być uruchomiony do działania
  - od wersji 10 domyślnie uruchamiany jest język PL/pgSQL
  - **CREATE EXTENSION SQL**
  - **SELECT * FROM pg_language**
  - **DROP language 'plpgsql'**
  - w bazie danych przechowywany jest kod funkcji, kompilacja nastąpi przy pierwszym wywołaniu
  - wniosek: dopiero wówczas ujawnią się błędy

Funkcje c.d.

- Sprawdzanie funkcji

  SELECT prosrc FROM pg_proc WHERE proname='plus_raz';
- Usuwanie funkcji

  DROP FUNCTION plus_raz(int4)
  - być może są inne funkcje plus_raz; nie zostaną one usunięte
  - "prawdziwa" nazwa funkcji zawiera jej typ
- Apostrof
  - może być potrzebny w definicji funkcji, wówczas podwójny
  - albo definicję objąć $$

Definiowanie funkcji c.d.

- Można wprowadzać nazwy dla parametrów formalnych (wcześniejsze wersje Postgresa nie pozwalały na to)
- Zamiast CREATE można użyć REPLACE albo CREATE OR REPLACE
  - ale nie zmieni się w ten sposób typów argumentu/ wyniku
- Parametr może być zadeklarowany jako
  - wejściowy IN (wartość)
  - wyjściowy OUT (zapis), INOUT
  - jeśli występują parametry wyjściowe, to można zrezygnować z RETURNS

```
CREATE FUNCTION pisz(IN int, OUT int, OUT text) AS $$
    SELECT $1, CAST($1 AS text)||' jest też tekstem'
    $$ LANGUAGE 'SQL'
SELECT pisz(44)
SELECT * FROM pisz(44)
```


Język PL/pgSQL

- Program składa się z bloków, każdy ma swe lokalne deklaracje

DECLARE deklaracje BEGIN instrukcje END

  - komentarze identyczne jak w SQL -- /* */
  - zakres deklaracji zmiennych oczywisty
  - zmienna może być inicjalizowana
  - zmienna może być zadeklarowana jako stała (constant), wówczas musi być inicjalizowana
  - typ zmiennej może odwołać się do innego typu
    - jeden integer :=1;
    - pi constant float8 := pi();
    - mójopis towar.opis%TYPE :='jakiś tekst'
    - nowy_klient klient%ROWTYPE;
    - wiersz record (typ ujawni się w momencie użycia)

Zmienne wierszowe

```
DECLARE nowy_k, stary_k klient%ROWTYPE;
BEGIN
  nowy_k.miasto := 'Gdynia';
  nowy_k.ulica_dom := 'Tatrzańska 2';
  nowy_k.kod_pocztowy := '81-111';
  SELECT * INTO stary_k FROM klient WHERE
   nazwisko='Miszke';
  IF NOT FOUND THEN ----------
  END IF;
END
```

  - SELECT powinien zwrócić najwyżej jeden wiersz, dalsze zostaną zignorowane
  - chyba, że użyto **SELECT * INTO STRICT __**, wówczas błąd
  - istnieją sterowania FOR, LOOP, CONDITIONAL, RETURN (obowiązkowy), RAISE

Sterowanie

- Instrukcje warunkowe
  - **IF (_) THEN ___**
    ELSEIF (_) THEN __
    ELSE ___
    END IF
- Wyrażenia warunkowe
  - **NULLIF** (wejście, wartość)

zamienia określoną wartość na NULL

  - **CASE**
    WHEN _____ THEN ____
    WHEN _____ THEN ____
    ELSE _____
    END

Pętle

- Pętle

  LOOP n:=n+1; EXIT już WHEN n>1000; END LOOP;
  WHILE n<=1000 LOOP n:=n+1 END LOOP;
  FOR i IN 1..1000 LOOP _____ END LOOP;
  FOR wiersz IN SELECT ___ LOOP __ END LOOP;
  EXIT
  - albo warunkowo: **EXIT WHEN** (coś się stało)
  - **EXIT** *z_miejsca*, opuszcza nie tylko bieżącą pętlę, ale i pętle wyżej położone, aż do etykiety *z_miejsca*

Wynik działania procedury

- **RETURN**, normalne zakończenie działania
  - oznacza koniec obliczeń, nawet przed końcem bloku
  - *musi* wystąpić, brak **RETURN** jest błędem
  - **RETURN NEXT** nie kończy obliczeń, dodaje tylko kolejny wynik gdy spodziewamy się wyniku **SETOF** *typ*
- Wyjątki/komunikaty

  RAISE DEBUG, zapisuje komunikat do pliku logów

  RAISE NOTICE, wyświetla komunikat na ekran

  RAISE EXCEPTION, j.w. + przerywa działanie procedury

  RAISE NOTICE ''wartość = %'', zmienna
  - po zdefiniowaniu w funkcji i wywołaniu wyświetli na ekranie komunikat o wartości zmiennej
  - można podstawiać za % wyłącznie napisy

Nazwy dynamiczne

- **EXECUTE ''UPDATE'' ||quote_ident (tu zmienna) || ''SET''...**

pozwala ułożyć zapytanie z elementów nieznanych w momencie pisania programu

nazwy tabel czy kolumn mogą zależeć od innych wartości

- Jest to bardzo nieefektywne, PostgreSQL nie może optymalizować zapytania przed wykonaniem
- **FOR wiersz in EXECUTE ''SELECT'' _____**

  LOOP _____ END LOOP;

Kursory

- Nazwa dla zbioru wierszy wynikowych

```
DECLARE     kursor CURSOR FOR SELECT _______;
BEGIN OPEN kursor;
LOOP FETCH kursor INTO wiersz
  EXIT WHEN NOT FOUND;
  PERFORM _______ ;
END LOOP;
CLOSE kursor;
```

  - wiersz musi być odpowiedniego typu, albo **RECORD**, albo **%ROWTYPE**, albo ciąg pojedynczych zmiennych dla każdego atrybutu

Kursory, c.d.

- Kursor może mieć parametr

```
DECLARE     kursor CURSOR (parametr typu) FOR SELECT
_______ parametr ___;
BEGIN OPEN kursor (parametr);
```

  - parametr może być wartością, np. użytą w **WHERE**
  - ale nie może być np. nazwą tabeli
- Można zdefiniować wskaźnik na kursor

```
DECLARE ten_kursor REFCURSOR; -- i inne kursory też
BEGIN OPEN kursor;            -- otwiera konkretny kursor
ten_kursor := kursor;
```


SQL też jest językiem

- Nie ma zmiennych ani sterowania (pętli, warunkowych)
- Nie ma **RETURN** (zwracane są dane z *ostatniego* **SELECT**-a wewnątrz definicji)
  - ale można zadeklarować typ wyjściowy jako void, wówczas stosuje się polecenia **SQL INSERT** czy **UPDATE**
- Są parametry, parametry aktualne zastępują $1, itd z definicji

```
CREATE FUNCTION przykład (text)
    RETURNS SETOF klient AS'
    SELECT * FROM klient WHERE miasto=$1
    ' LANGUAGE SQL
```

- Typem danych wejściowych może być nazwa tabeli (tzn. na wejściu znajdzie się wiersz z tej tabeli)
  - również dane wyjściowe mogą utworzyć wiersz takiego typu

Definiowanie operatorów

- W zasadzie operatory są funkcjami
  - tyle, że wygodna składnia do wywołania
- Definicja operatora wymaga definicji funkcji, która ma policzyć wartość operatora

```
CREATE OPERATOR + (
    leftarg = <typ_lewego>,
    rightarg = <typ_prawego>,
    procedure = <nazwa funkcji, która policzy wynik>
);
```

  - jeśli operator jest unarny, to należy opuścić jeden z argumentów

Procedury wyzwalane

Procedury wyzwalane

- Nazwa: *trigger,* trygier, wyzwalacz
- Jak?
  - procedury są wyzwalane “automatycznie” przez zdarzenia w bazie danych
- Dlaczego?
  - poprawność danych (pojedynczych, zależnych od innych)
  - śledzenie zmian, audyt, raport, zapis zmian
  - naruszenie postaci normalnej, kopie danych, dane wynikowe
  - dane bieżące vs. archiwalne
  - spowodowane ergonomią, wydajnością, specjalny format danych dla innych aplikacji

Przykłady „dlaczego” – poprawność

- Przykłady pętli w diagramach związków i encji w projektach:
  - lekarz <wykonuje> zabieg
    lekarz <ma> specjalizację
    zabieg <wymaga> specjalizacji

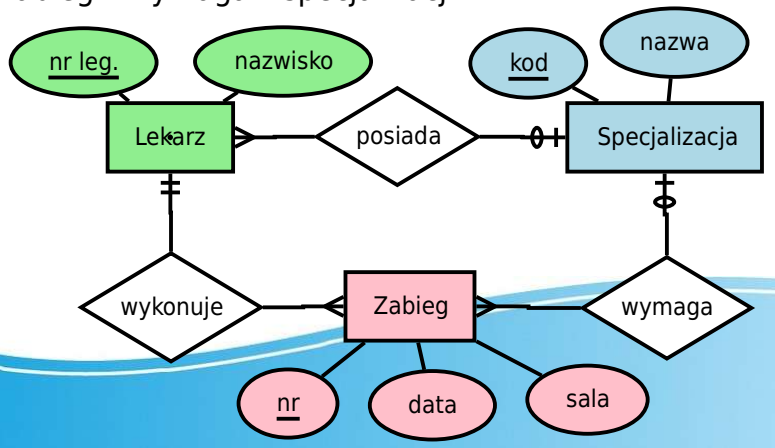

Przykłady „dlaczego” – poprawność c.d.

- Przykłady pętli c.d.:
  - nauczyciel <uczy> klasa, przedmiot (związek 3 encji)
  - nauczyciel <jest wychowawcą> klasa
    - tylko jeśli uczy jakiegoś przedmiotu w klasie
  - klub <jest gościem> w meczu
  - klub <jest gospodarzem> w meczu
    - ale nie może być jednym i drugim
- Formalna poprawność danych
  - pesel ma 11 cyfr

Przykłady „dlaczego” – BCNF, rozkład

- Istnieje rozkład odwracalny relacji SZKOŁA na
  Lektor (LEKTOR, JĘZYK)
  PRIMARY KEY (LEKTOR)
  Zapis (STUDENT, LEKTOR)
  - jedyna zależność funkcyjna to { LEKTOR }→{ JĘZYK }
  - brakuje zależności { STUDENT, JĘZYK }→{ LEKTOR }
  - nie można aktualizować obu relacji i zagwarantować zachowania brakującej zależności funkcyjnej
- Wniosek: nie zawsze jest możliwy rozkład odwracalny na relacje spełniające BCNF z zachowanie zależności funkcyjnych
  - ale można zdefiniować procedurę wyzwalaną zapewniającą zachowanie brakującej zależności funkcyjnej
  - aktualizacja zapisów jest możliwa pod warunkiem, że student nie zapisał się do dwóch grup tego samego języka

Przykłady „dlaczego” – archiwizacja

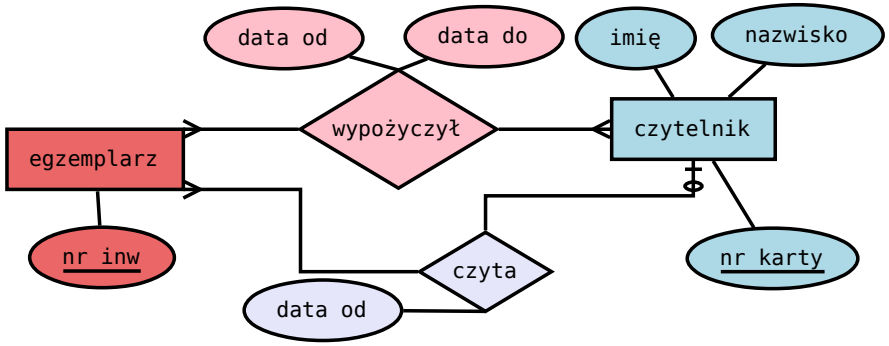

- W projekcie biblioteki używa się związku <czyta>
  - zapisując czas automatycznie
  - po zwrocie książki zapisywane jest wypożyczenie
  - po zmianie ceny towaru zapisywana jest odrębnie dawna cena
  - po usunięciu faktury dane są archiwizowane

Przykłady „dlaczego” – dane wynikowe, kopie

- Dane o towarach wprowadzane w centrali firmy
  - są automatycznie kopiowane w oddziałach
- Zamówienie złożone przez klienta
  - zmienia atrybut „łącznie suma zamówień”
  - warto mieć pod ręką dane zbiorcze by łatwiej obliczyć rabat dla kolejnego zamówienia
  - gol w meczu zmienia wynik meczu, zmienia pozycję klubu w lidze, zmienia statystyki i ranking piłkarza

Definiowanie procedur wyzwalanych

- **CREATE TRIGGER nazwa BEFORE|AFTER**
  INSERT|DELETE|UPDATE ON nazwa_tablicy
  FOR EACH ROW|STATEMENT
  EXECUTE PROCEDURE nazwa_funkcji(arg)
- procedura używana w definicji wyzwalacza musi być wcześniej zdefiniowana
  - typ wynikowy musi być TRIGGER
  - zwraca albo NULL, albo wiersz pasujący do typu tabeli występującej w wyzwalaczu
  - formalnie nie ma argumentów, naprawdę argumenty odczytuje z tablicy tg_argv[] o wielkości tg_nargs
  - może odwoływać się do new i old, nowa i stara wartość zmienianego wiersza (dla wyzwalaczy FOR EACH ROW)

Przykład: odnowienie zapasów

```
CREATE TRIGGER uzupelnij_trig
    AFTER INSERT OR UPDATE ON zapas
    FOR EACH ROW EXECUTE PROCEDURE
      uzupelnij_trig_proc(13);
```

- jeśli zostanie dokonana zmiana w tabeli zapasów, to zostanie wywołana procedura uzupelnij_trig_proc, która bada, czy zapasy nie są zbyt małe i być może trzeba złożyć zamówienie (do specjalnej tabeli nowych zamówień)

```
CREATE FUNCTION uzupelnij_trig_proc()
    RETURNS TRIGGER AS $$
    DECLARE
        prog INTEGER;
        wiersz RECORD;
```

ciąg dalszy na następnym slajdzie

Przykład, c.d.

```
BEGIN
    prog := tg_argv[0];
    RAISE NOTICE ''próg wynosi %'', prog;
    IF new.ilosc < prog
    THEN
      SELECT * INTO wiersz FROM towar
        WHERE nr = new.towar_nr;
      INSERT INTO nowe_zamowienie
        VALUES (wiersz.nr, wiersz.opis, prog-new.ilosc,
  now());
        RAISE NOTICE 'trzeba zamówić towar: %', wiersz.opis;
    END IF;
    RETURN NULL;
END; $$ LANGUAGE plpgsql
```


Reguły

- Mogą mieć podobne skutki jak wyzwalacze

```
CREATE RULE name AS ON [UPDATE | INSERT | DELETE]
    TO table [ WHERE condition ]
    DO [ ALSO | INSTEAD ] { NOTHING | command |
    ( command ; command ... ) }
```

  - np.: archiwizacja danych

```
CREATE RULE archiwizuj AS ON UPDATE
    TO towar WHERE old.cena<>new.cena
    DO INSERT INTO towar_log
        VALUES (old.nr, old.cena, now())
```

  - gdzie tabela towar_log musiała być przedtem odpowiednio zdefiniowana
  - **ALSO** jest domyślne, **INSTEAD** musi być jawnie wyrażone

Reguły dla perspektyw

- Reguły mogą być jedyną możliwością aktualizacji perspektyw
  - załóżmy, że mamy zadeklarowaną perspektywę

```
CREATE VIEW towar_zysk AS
    SELECT *, cena - koszt AS zysk FROM towar
```

  - w niektórych implementacjach nie ma możliwości usuwania wierszy z perspektywy
  - ale można zdefiniować regułę

```
CREATE RULE towar_zysk_del AS
    ON DELETE TO towar_zysk
    DO INSTEAD DELETE FROM towar WHERE nr=old.nr
```

  - wówczas polecenie usuwania z perspektywy usunie odpowiadający wiersz w tabeli
  - analogicznie wstawianie czy aktualizacja wiersza

Reguły vs. wyzwalacze

- Reguła powoduje (może spowodować) wykonanie kolejnego polecenia SQL
  - polecenie dotyczące wielu wierszy może być dobrze zoptymalizowane przez SZBD
  - reguła jest analizowana przed rzeczywistym wykonaniem i może prowadzić do błędu rekursywnego wywołania
- Wyzwalacze używają funkcji, a te mogą więcej niż polecenia SQL
  - np. integralność referencyjna wymaga sprawdzenia istnienia danych i ew. zgłoszenie błędu