POZNAN UNIVERSITY OF TECHNOLOGY

Hurtownie danych - przegląd technologii

Robert Wrembel
Poznan University of Technology
Institute of Computing Science
Robert.Wrembel@cs.put.poznan.pl
www.cs.put.poznan.pl/rwrembel

Designing DW System
(R. Kimball's Method)

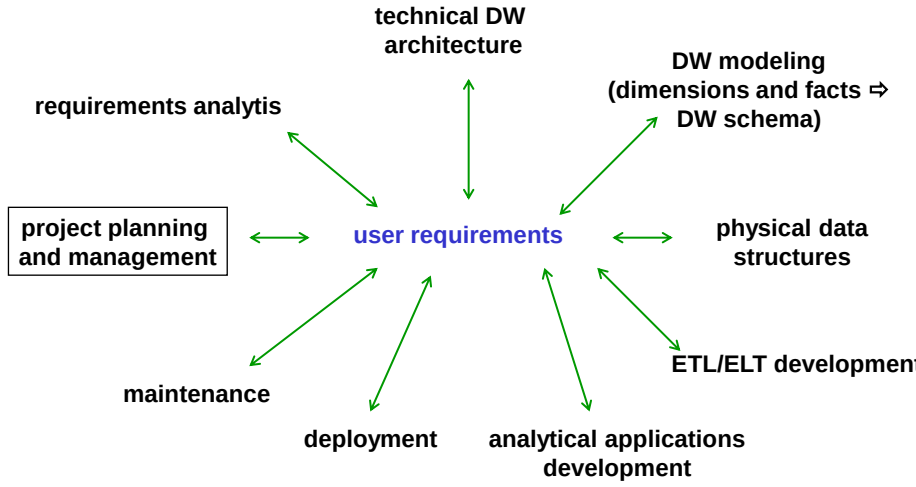

Modelowanie hurtowni danych

- Model wielowymiarowy
- Implementacja ROLAP
- Implementacja MOLAP
- Modelowanie ROLAP
- Zarządzanie modyfikacjami danych
  - Slowly Changing Dimensions

Dane przechowywane w HD

- Dane bieżące
- Dane historyczne

Kategorie analizowanych danych

- **Fakty**
  - informacje podlegające analizie
    - sprzedaż, rozmowy telefoniczne
    - charakteryzowane ilościowo za pomocą miar
    - liczba sprzedanych sztuk towaru, czas trwania rozmowy
- **Wymiary**
  - ustalają kontekst analizy
    - sprzedaż czekolady (produkt) w Auchan (sklep) w poszczególnych miesiącach roku (czas)
  - składają się z poziomów, które tworzą hierarchię

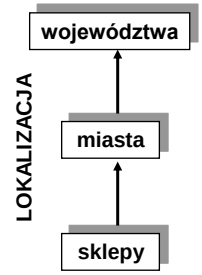

ROLAP, MOLAP, HOLAP

- Model relacyjny (ROLAP)
  - schemat gwiazdy (ang. star schema)
  - schemat płatka śniegu (ang. snowflake schema)
  - schemat konstelacji faktów (ang. fact constellation schema)
  - schemat gwiazda-płatek śniegu (ang. starflake schema)
- Model wielowymiarowy (MOLAP, MDOLAP)
- Model hybrydowy (HOLAP)

ROLAP - Schemat gwiazdy

- **Fakty (tabela faktów)**
  - **miary**
- **Wymiar (tabela wymiaru)**

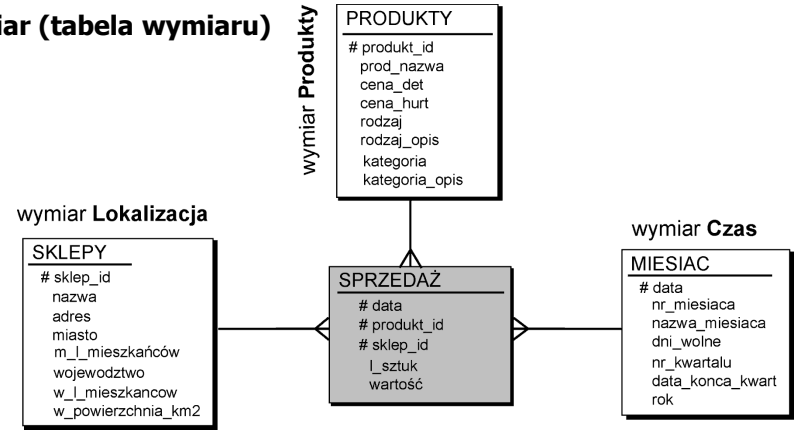

Struktura wymiaru

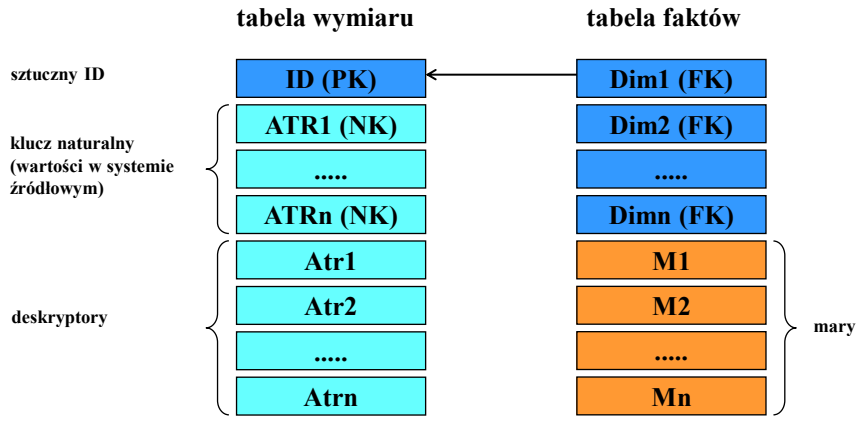

ROLAP - Schemat płatka śniegu

- **Wymiar (tabela wymiaru)**
  - **poziom (tabela poziomu)**
  - **hierarchia wymiaru**

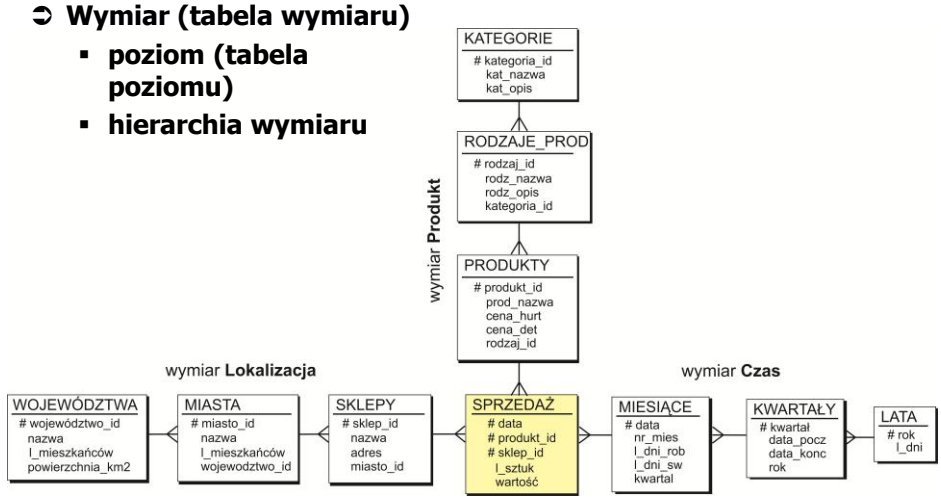

Schemat gwiazda-płatek śniegu

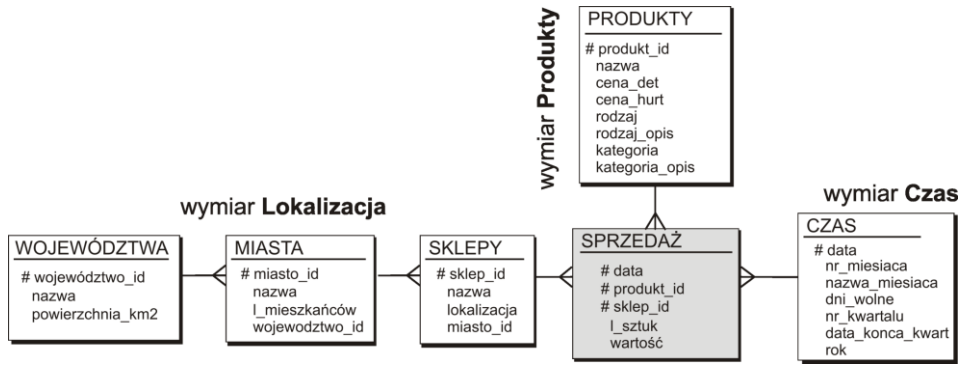

Schemat gwiazda-płatek śniegu

- Część wymiarów znormalizowanych
  - poziomy wyższe wykorzystywane rzadko
  - oszczędność miejsca
- Część wymiarów zdenormalizowanych
  - wszystkie poziomy wymiarów wykorzystywane często
  - efektywność zapytań
- ang. starflake schema

Modelowanie wymiarów – gwiazda/płatek śniegu (1)

- Gwiazda: tabela wymiarów jest zdenormalizowana
- Zaleta:
  - operacja roll-up wykonywana szybko (bez konieczności łączenia z tabelą poziomu nadrzędnego)
- Wada:
  - na skutek redundancji danych rozmiar tabeli może być duży
    - np. wymiar Czas z ziarnem 1sek i horyzontem czasowym wymiaru 10 lat ⇨ 300 000 000 rekordów
    - astronomia, fizyka jądrowa, telekomunikacja
- Płatek śniegu: tabele wymiaru są znormalizowane
  - mniejszy rozmiar poszczególnych tabel poziomów
  - operacja roll-up wykonywana wolniej (konieczność łączenia tabel poziomów)

Modelowanie wymiarów – gwiazda/płatek śniegu (2)

➲ **W praktyce:**

- **atrybuty różnych poziomów często wykorzystywane w operacji roll-up ⇨ umieszczenie w tej samej zdenomralizowanej tabeli poziomu najniższego**
- **atrybuty rzadko wykorzystywane w roll-up ⇨ umieszczenie w znormalizowanych tabelach poziomów wyższych**

Schemat konstelacji faktów

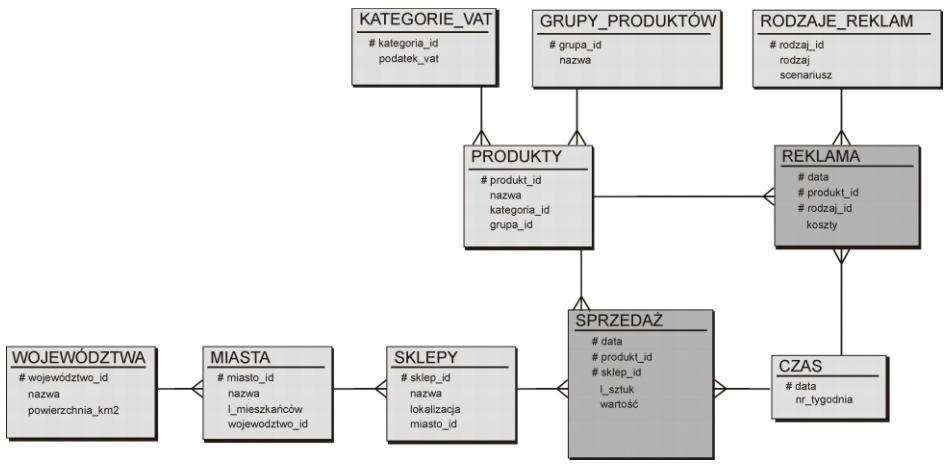

Tabela faktów

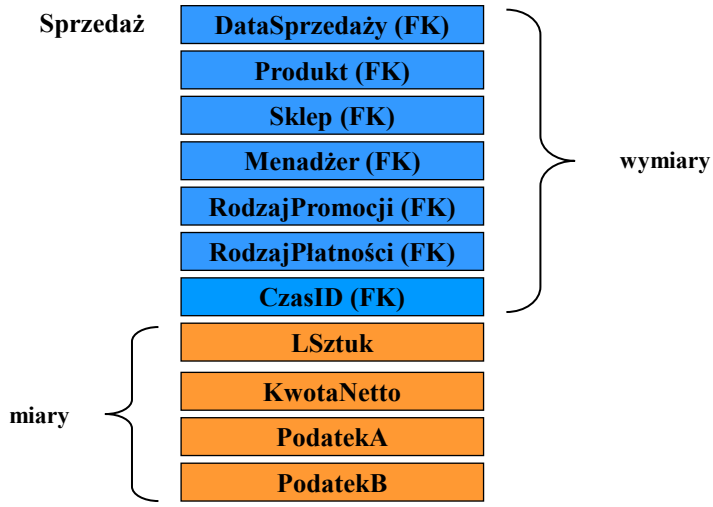

Tabela faktów

- **Tabela faktów bez miar (ang. factless fact)**
  - **przechowuje pojedyncze fakty, z których każdy reprezentuje zdarzenie**

Wymiar Czasu

- Występuje w większości schematów
- Definiowana na początku budowy HD
- Ziarno - zazwyczaj dzień
  - DataID
    - sztuczny identyfikator; wartości 1, 2, ..., n
    - wartość numeryczna 11032008 (11-03-2008)

DataID (PK)
Data
NazwaDnia
NrDniaTyg
NrDniaMies
NrDniaRok
NrDniaFiskMies
NrDniaFiskRok
CzyOstatniDzienTyg
CzyOstatniDzienMies
NrTygodniaRok
NazwaMies
NrMiesRok
Kwartal
Półrocze
Rok
NrTygodniaRokFisk
NazwaMiesFisk
NrMiesRokFisk
KwartalFisk
PółroczeFisk
RokFisk
CzyŚwięto
CzyDzieńRoboczy
CzyWeekend
RodzajŚwięta

Wymiar Czasu

- Rejestrowanie czasu z dokładnością > dni
  - znacznik czasowy w tabeli faktów

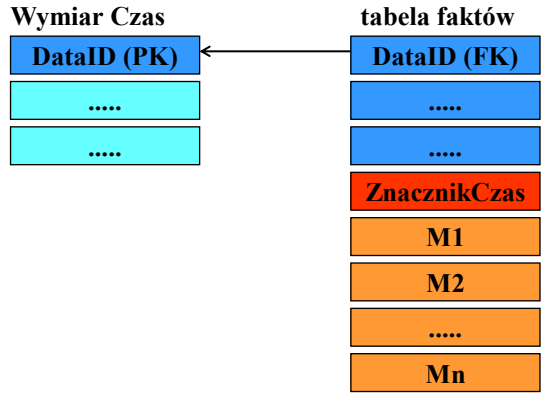

Role wymiarów

- Ten sam wymiar jest łączony wielokrotnie z tabelą faktów, np. wymiar Czasu

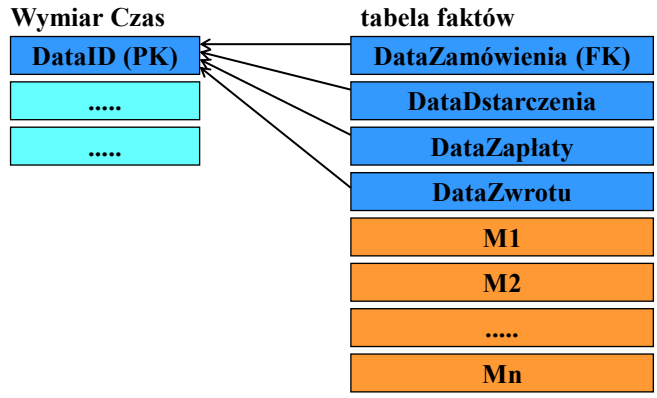

Role wymiarów

- Wymiar w tabeli faktów (fact dimension)

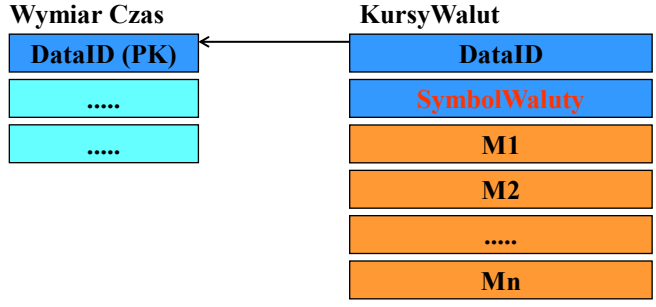

- Miara pełniąca rolę wymiaru
  - długość odcinka podróży

Generowanie sztucznych ID

- **Baza danych**
  - **wyzwalacz - pogarsza efektywność HD i ETL**
  - **sekwencja - rozwiązanie akceptowalne**
- **Sposób generowania**
  - **wartości numeryczne - zadowalająca efektywność**
  - **wartości znakowe**
    - **konkatenacja klucza naturalnego i znacznika czasowego (data i czas utworzenia w systemie źródłowym lub wczytania do HD)**
      - niska efektywność
      - duży rozmiar wartości (kilkanaście B)

Sztuczne ID

- **Numeryczne**
  - **brak semantyki**
  - **chronologia wstawiania wartości reprezentowana kolejnymi wartościami**
  - **odizolowanie wartości w HD od zmian wartości danych w źródłach**
  - **dobrze wspierają integrację danych z wielu źródeł**
  - **dobrze wspierają historię zmian instancji wymiaru**

Agregacja (1)

- Ścieżka agregacji

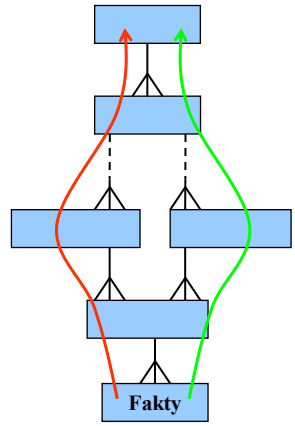

Agregacja (2)

- Agregowalność (summarizability)
  - możliwość agregowania wartości na poziomie wyższym (np. Miasto) w oparciu o agregaty z poziomu niższego (np. Sklep)
- Kryteria poprawnej agregowalności
  - rozłączność zbioru instancji
    - związek 1:M pomiędzy poziomem nadrzędnym i podrzędnym
    - instancja poziomu podrzędnego jest powiązana tylko z jedną instancją poziomu nadrzędnego
  - kompletność
    - wszystkie instancje poziomów należą do instancji wymiaru
    - każda instancja poziomu podrzędnego jest powiązana z instancją poziomu nadrzędnego
  - właściwa funkcja agregująca
    - zastosowanie właściwej funkcji agregującej dla danego typu miary

Agregacja (3)

- Typy miar (kryterium agregowalności)
  - addytywne (addtitive, flow, rate) ⇨ zapewniają poprawną agregowalność dla wszystkich wymiarów
    - np. liczba sprzedanych sztuk towaru ⇨ możliwe agregowanie w wymiarze czasu, klienta, produktu, sklepu, dostawcy, ...
  - częściowo addytywne (semiadditive, stock, level) ⇨ zapewniają poprawną agregowalność dla niektórych wymiarów
    - np. liczba sztuk towaru w magazynie ⇨ możliwe agregowanie w wymiarze magazynu (Magazyn → Miasto → Region), agregowanie w wymiarze czasu daje nieinterpretowalne wyniki
  - nieaddytywne (nonadditive, value-per-unit) ⇨ nie podają interpretowalnych wartości zagregowanych w żadnym z wymiarów
    - np. cena netto, kurs wymiany, kurs akcji dla SUM

Agregacja (4)

- Typy miar (kryterium własności funkcji agregującej)
  - dystrybutywne (distributive)
    - niezależne wyniki działania funkcji F na n podzbiorach zbioru danych Z są agregowane do jednego wyniku, który jest identyczny z wynikiem działania F na całym zbiorze Z
    - agregat na poziomie wyższym może być obliczony na podstawie agregatów na poziomie niższym
    - count, min, max, sum
  - algebraiczne (algebraic)
    - obliczana na podstawie wyników działania funkcji dystrybutywnych
    - avg, stdev
  - holistyczne (holistic)
    - do obliczenia wyników potrzebne są wszystkie dane elementarne
    - median

Hierarchie wymiarów

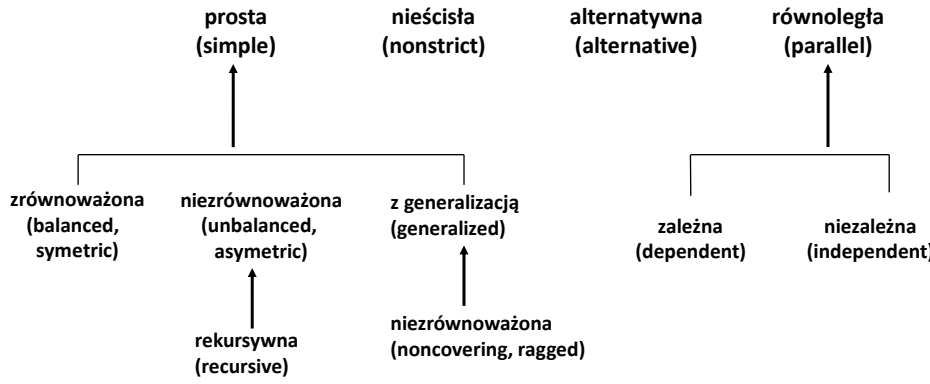

- Malinowski E., Zimanyi E.: Advanced Data Warehouse Design. From Conventional to Spatial and Temporal Applications. Springer Verlag, 2008

Hier. zrównoważona

- Posiada jedną ścieżkę agregacji w schemacie
- Związek 1:M obustronnie obowiązkowy pomiędzy poziomem nadrzędnym, a podrzędnym

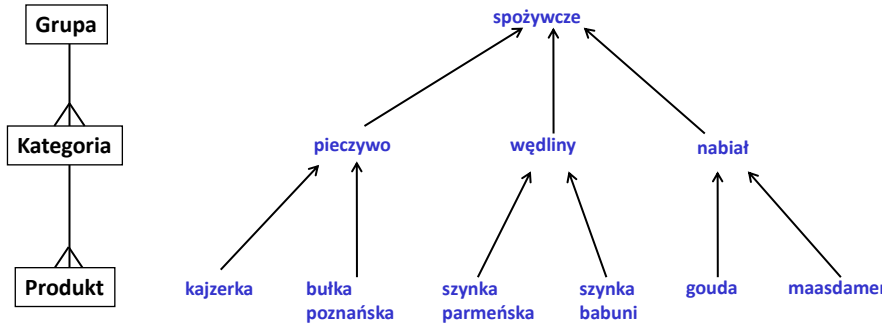

Hier. niezrównoważona (1)

- Posiada jedną ścieżkę agregacji w schemacie
- Związek 1:M pomiędzy poziomem nadrzędnym, a podrzędnym, opcjonalny od strony poziomu nadrzędnego

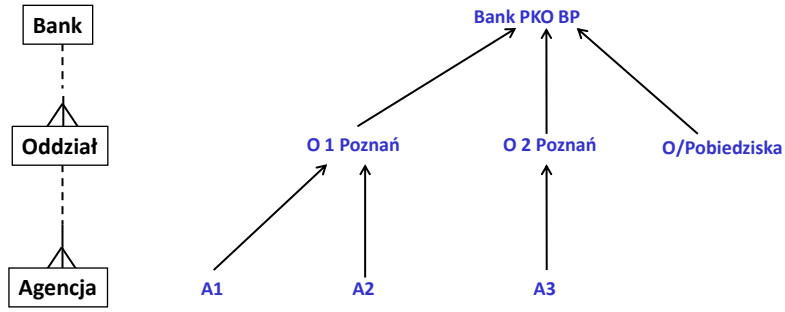

Hier. niezrównoważona (2)

- Szczególny przypadek ⇨ hierarchia niezrównoważona rekursywna

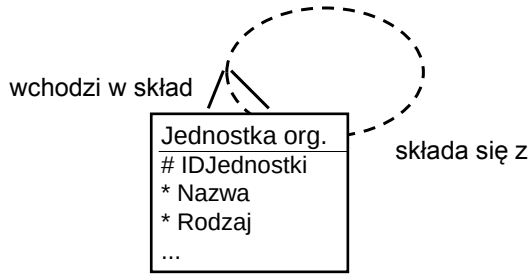

Hier. z generalizacją

- Poziomy wymiaru są powiązane związkami generalizacji (nadtyp-podtyp)
- Podtypy mogą posiadać własne hierarchie
- Na poziomie schematu istnieje wiele ścieżek współdzielących przynajmniej poziom najniższy
- Część poziomów może być specyficzna dla ścieżki
- Część poziomów może być wspólna dla kilku ścieżek
- Każda instancja poziomu należy tylko do jednej ścieżki

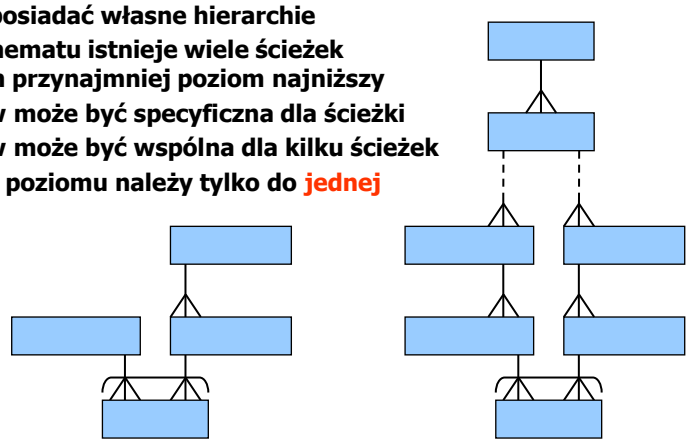

Hier. z generalizacją

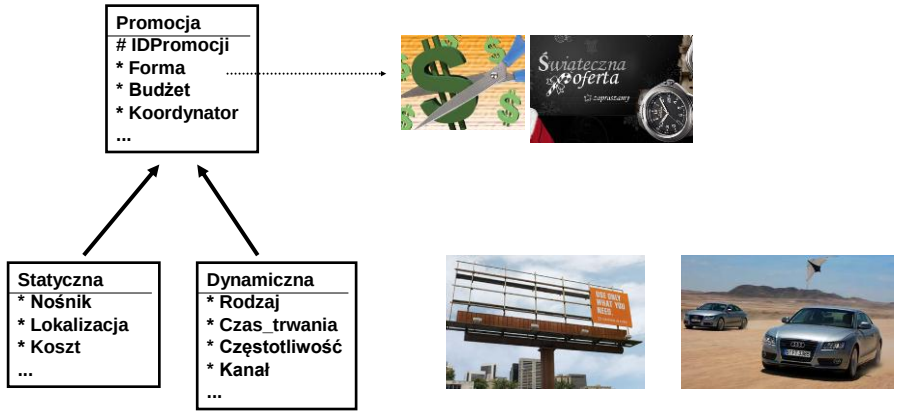

Hier. z generalizacją

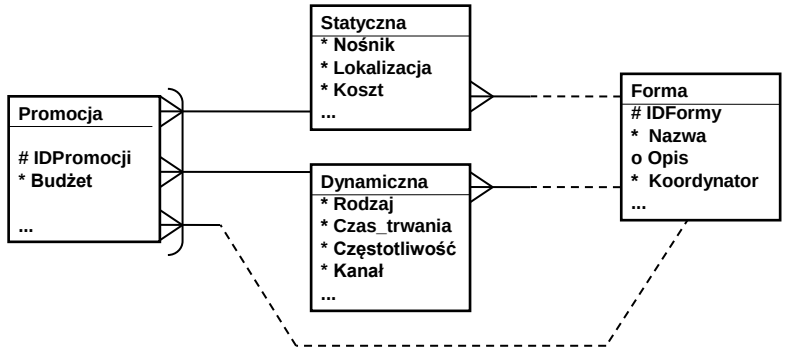

- **Specjalizacja częściowa ⇨ hierarchia niezrównoważona**
- **Specjalizacja nierozłączna ⇨problem z obliczaniem agregatów (agregowanie n razy tych samych wartości)**
  - **specjalizowana procedura agregująca**
  - **zlikwidowanie specjalizacji nierozłącznej w hierarchii wymiaru**

Hier. ścisła

- **Na poziomie schematu wymiaru istnieją wyłącznie związki 1:M pomiędzy poziomem wyższym (1), a niższym (M)**

Hier. nieścisła (1)

- Na poziomie schematu wymiaru istnieje przynajmniej jeden związek M:N pomiędzy poziomami

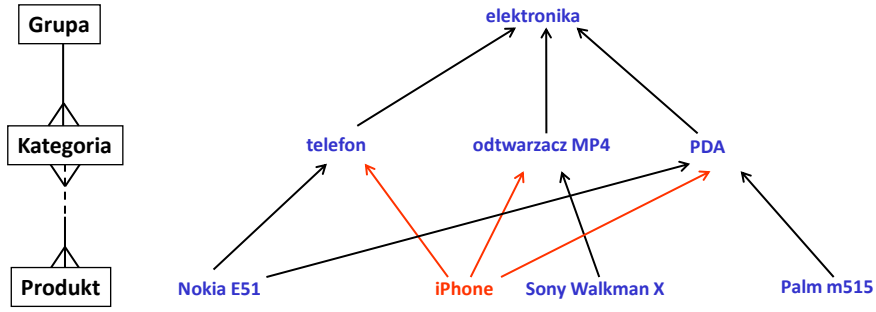

- Problem agregowania n razy tego samego produktu
  - sprzedaż elektroniki ⇨ iPhone liczony 3 razy

Hier. nieścisła (2)

- Rozwiązania
  - wprowadzenie nowej kategorii, np. smartphone: {iPhone}
  - wybór jednej kategorii (głównej) do której należy produkt w ścieżce agregacji
  - dystrybucja wartości miar dla produktu pomiędzy kategorie
    - przyjęta odgórnie, np. telefon 40%, odtwarzacz MP4 20%, PDA 40%
    - równomierna: wartość miary podzielona przez liczbę kategorii do których należy produkt, np. 1/3 dla iPhone
  - transformacja nieścisłej hierarchii do ścisłej

Hier. nieścisła (3)

- Transformacja nieścisła ⇨ ścisła
  - możliwa jeśli znamy dokładną dystrybucję wartości miary, np. ile pracownik zarabia w konkretnym projekcie

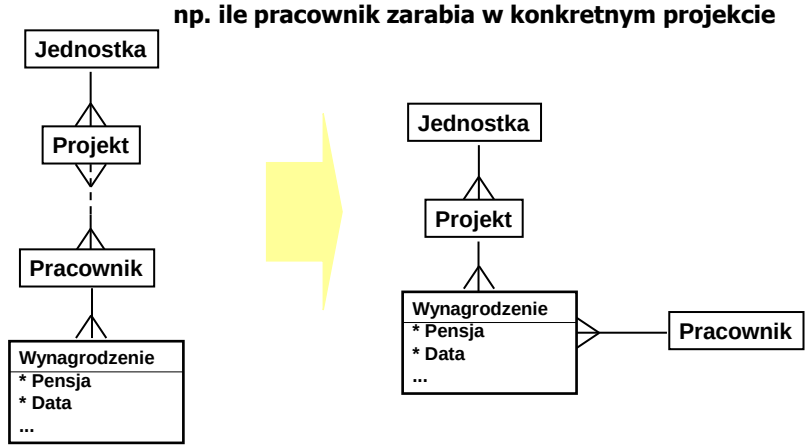

Hier. nieścisła (4)

- Problem
  - zliczenie pracowników jednostek

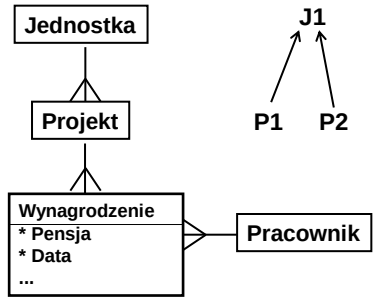

	Projekt	Pracownik	Wynagrodzenie
J1 (3)	P1	Prac1	80
	P1	Prac2	50
	P2	Prac1	80
	P2	Prac2	30
	P2	Prac3	40
J2 (5)	P3	Prac4	60
	P3	Prac5	20
	P3	Prac2	20
	P4	Prac1	30
	P4	Prac3	50
	P4	Prac5	40

Hier. alternatywna (1)

- Złożona z hierarchii prostych współdzielących przynajmniej poziom najniższy
- Ścieżki analizy nie są wyłączne
- Agregacja każdą ścieżką dla poziomów współdzielonych daje identyczne wyniki, np. sprzedaż roczna
- Instancja wymiaru jest grafem ⇨ instancja podrzędna (czas) jest powiązana z kilkoma instancjami nadrzędnymi (miesiąc, tydzień), a każda z instancji nadrzędnych należy do innego poziomu
- Każda ścieżka agregacji prowadzi do tych samych instancji poziomów najniższego i najwyższego

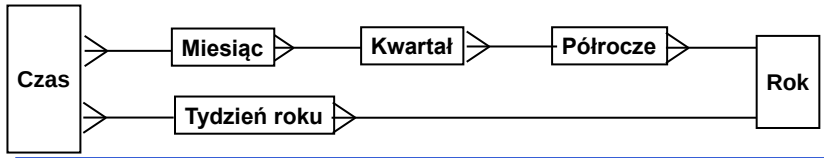

Hier. alternatywna (2)

- Problem
  - jednoczesna analiza danych wzdłuż obu ścieżek agregacji może prowadzić do źle interpretowanych wyników
  - np. sprzedaż w 1 kwartale 2009 i 50 tygodniu 2009 ⇨ brak danych
  - rozwiązanie: wybór jednej ścieżki agregacji w danej analizie

Hier. równoległe (1)

- Niezależne (parallel independent hierarchies) ⇨ przypadek standardowy
  - brak współdzielenia poziomów pomiędzy hierarchiami
  - każda hierarchia stanowi inne kryterium analizy, np. Produkt, Klient, Czas

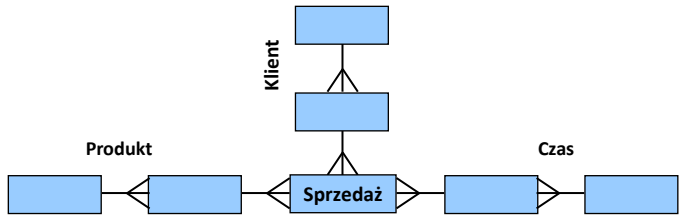

Hier. równoległe (2)

- Zależne (parallel dependent hierarchies)
  - współdzielenie poziomów pomiędzy hierarchiami
  - każda hierarchia stanowi inne kryterium analizy

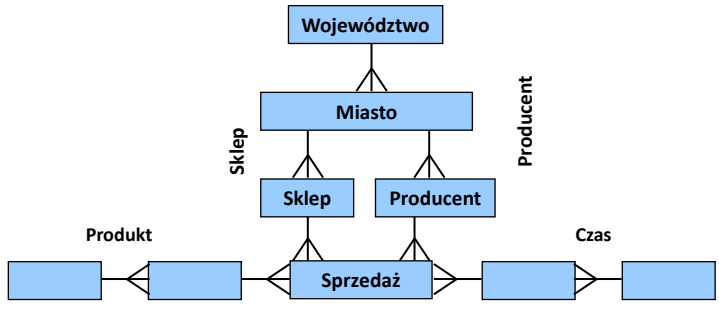

  - analiza danych w kontekście obu hierarchii, np. wskaźniki sprzedaży w poszczególnych miastach danego producenta

Hier. równoległe (3)

- agregacja danych na poziomach wspólnych, np. miasto, daje różne wyniki dla różnych ścieżek agregacji

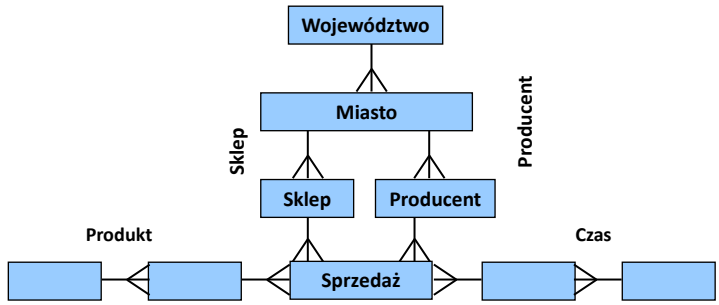

Praktyka

➲ W praktyce maksymalna liczba wymiarów to 15-18

Narzędzia do modelowania

- DB2 Data Warehouse Center,
- Sybase Warehouse Studio,
- Microsoft Data Warehousing Framework,
- SAP Data warehouse management,
- NCR Teradata Warehouse Builder,
- Oracle Designer6i/9i

Model wielowymiarowy

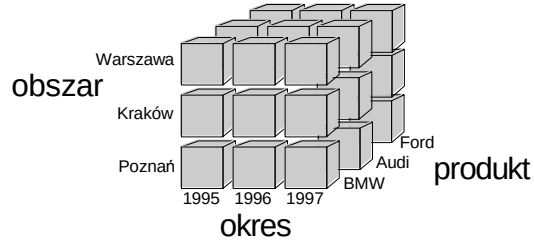

- "Wielowymiarowa kostka" (data cube, hypercube)
- Operacje
  - drill-down / roll-up
  - slice, dice
  - rotate (pivot)
  - drill-accross
  - drill-through

Drill-down / roll-up

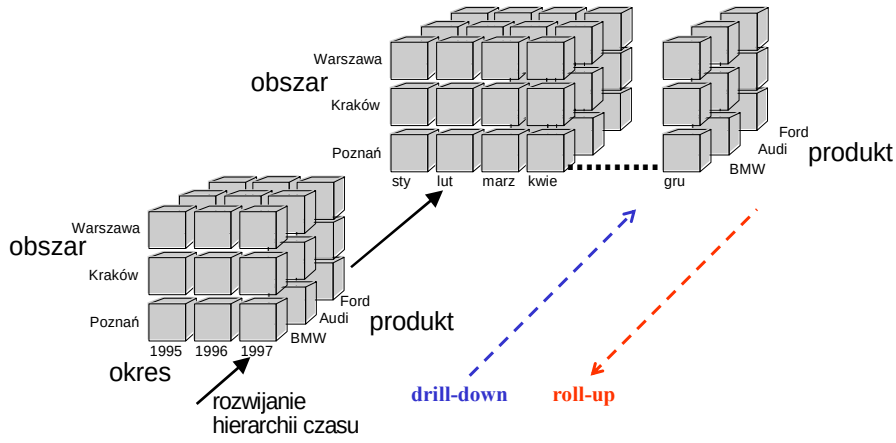

Slice, dice

➲ **Slice ⇨ warunki selekcji nałożone na jeden wymiar**

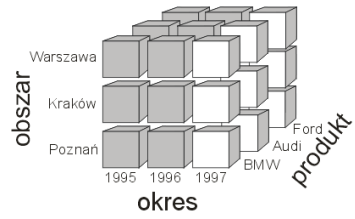

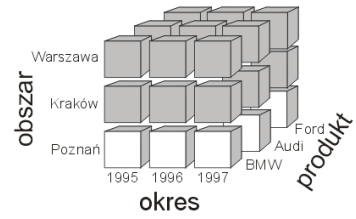

➲ **Dice ⇨ warunki selekcji nałożone n wymiarów**

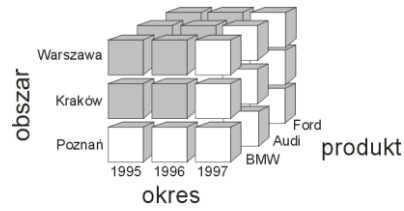

Rotate (pivot)

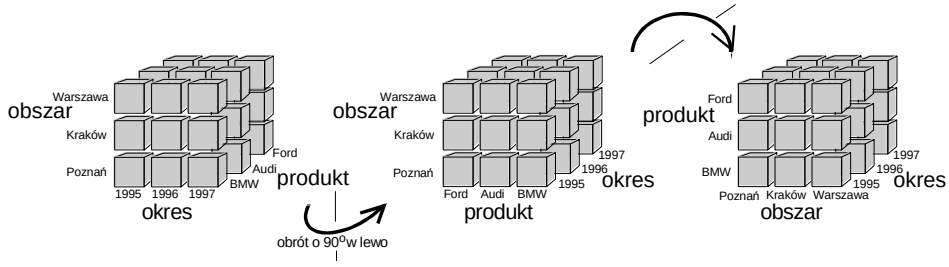

Drill-across

➲ **Analiza danych z kilku kostek ⇨ kostki muszą mieć przynajmniej jeden wymiar wspólny**

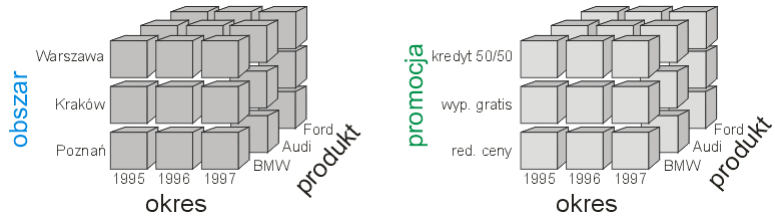

Drill-through

- Odczytanie i analiza danych elementarnych z centralnej HD (impl. ROLAP)

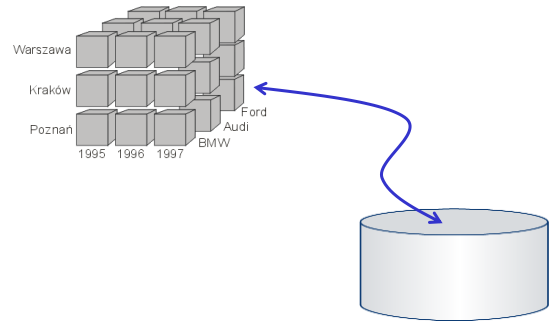

ROLAP a MOLAP

- Implementacja relacyjna ⇨ ROLAP
- Implementacja wielowymiarowa ⇨ MOLAP

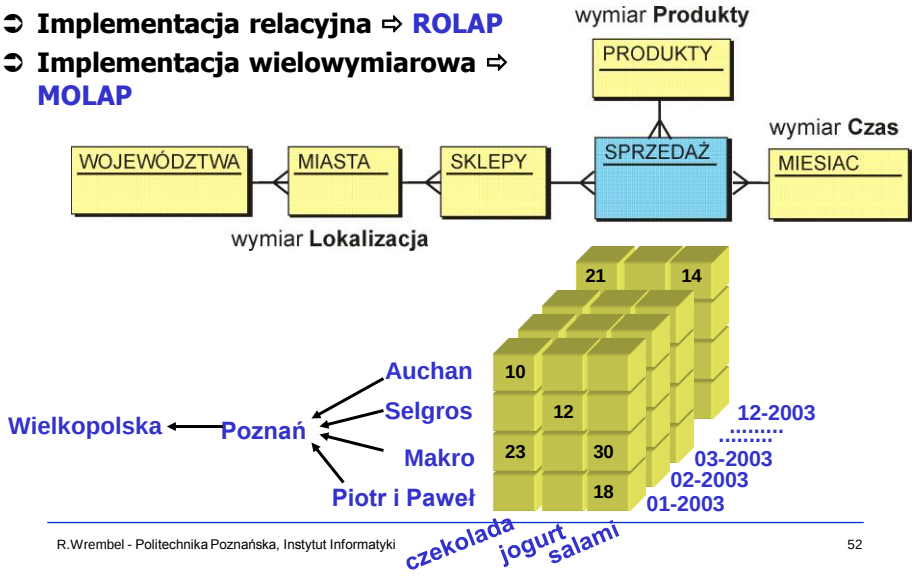

Agregowanie danych w kostce

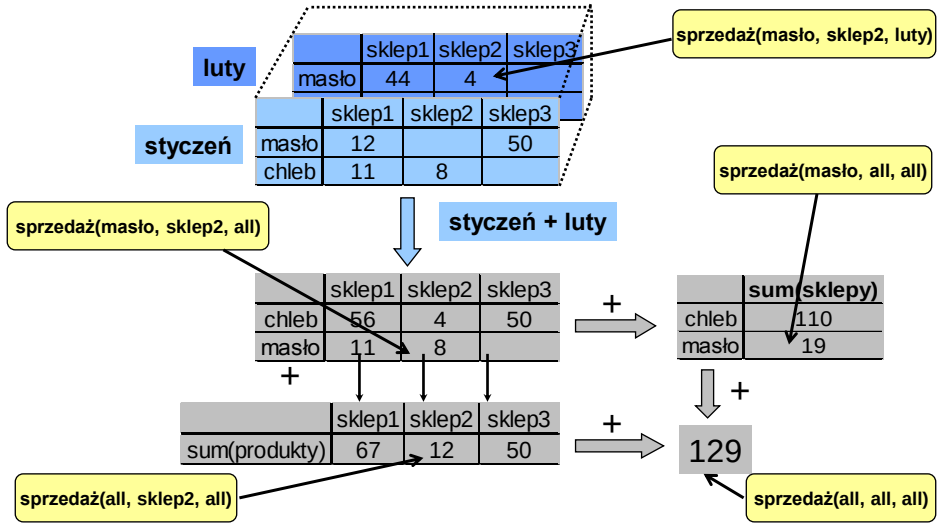

Agregowanie w hierarchii wymiaru

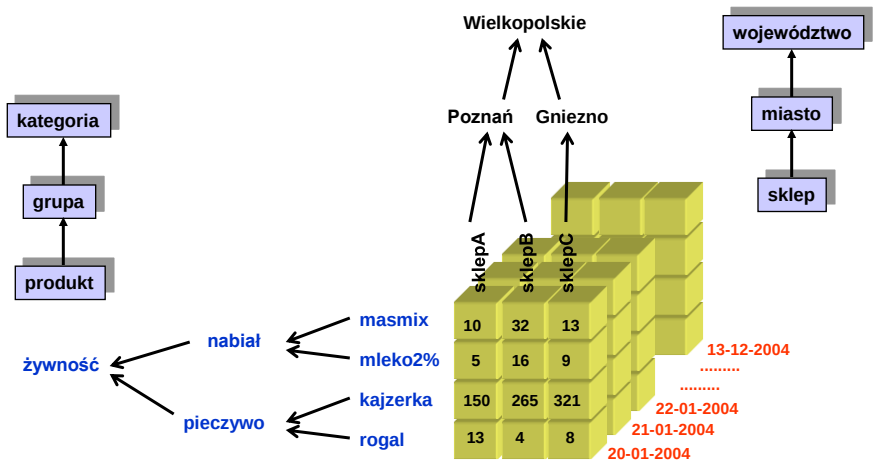

Implementacja MOLAP

- Tablica wielowymiarowa
- Tablica haszowa (SQL Server)
- BLOB (Oracle)
- Quad tree
- K-D tree

HOLAP

- Dane elementarne i "słabo zagregowane" ➔ ROLAP
- Dane zagregowane (tematyczne HD) ➔ MOLAP

Modelowanie ROLAP

Problematyka

- Zidentyfikowanie faktów
- Zidentyfikowanie kluczowych wymiarów
- Zaprojektowanie tabel faktów
- Zaprojektowanie tabel wymiarów

ROLAP – zidentyfikowanie faktów

- **Zidentyfikowanie kluczowych typów transakcji w systemie produkcyjnym (realizują kluczowe akcje/operacje w obszarze działania przedsiębiorstwa)**
  - **handel: transakcje sprzedaży**
  - **bankowość: kursy walut, operacje na rachunkach**
  - **giełda: wahania kursów akcji, operacje giełdowe**
  - **ubezpieczenia: wykupienie polisy, zmiana warunków polisy, zgłoszenie szkody, wypłacenie odszkodowania**
  - **telekomunikacja: zrealizowanie rozmowy przez abonenta, podłączenie telefonu, zawarcie umowy, zmiana abonamentu, płatności za abonament**
  - **opieka zdrowotna: przyjęcie pacjenta do szpitala, forma leczenia, wynik leczenia**

ROLAP – zidentyfikowanie wymiarów

- **Zidentyfikowanie kluczowych wymiarów dla faktów (określenie kontekstu analizy faktów)**
  - **handel:**
    - **analiza sprzedaży w poszczególnych miastach i okresach czasowych**
  - **bankowość:**
    - **wahania kursów walut w poszczególnych dniach**
    - **analiza przyrostu liczby nowych rachunków w poszczególnych miesiącach z podziałem na rodzaje rachunków**
  - **giełda:**
    - **wahania kursów akcji poszczególnych firm w poszczególnych dniach**
    - **liczba zawartych transakcji kupna lub sprzedaży w jednostce czasu i łączne kwoty tych operacji**
  - **ubezpieczenia:**
    - **analiza przyrostu/spadku liczby polis poszczególnych rodzajów w miastach w poszczególnych miesiącach**
  - **telekomunikacja:**
    - **analiza rozkładu czasu rozmów poszczególnych klientów w czasie doby**

ROLAP – projektowanie schematu tabeli faktów (1)

- Poziom szczegółowości informacji ⇨ rozmiar tabeli faktów
  - rejestrowanie kwoty zakupu pojedynczego produktu
  - rejestrowanie sumarycznej kwoty zakupu całego koszka
  - rejestrowanie sumarycznej kwoty zakupu w miesiącu
- Horyzont czasowy danych
  - jak długo przechowywać informacje na najwyższym poziomie szczegółowości?
  - opracowanie strategii agregowania danych starszych
    - raporty roczne ⇨ najczęściej wystarczają agregaty sumujące fakty z dokładnością do miesiąca
    - raporty agregujące dane sprzed kilku lat ⇨ najczęściej wystarczają agregaty sumujące fakty z dokładnością do miesiąca, kwartału, lub roku

ROLAP – projektowanie schematu tabeli faktów (2)

- Właściwy zbiór atrybutów tabeli faktów
- Usunięcie zbędnych atrybutów ⇨ rozmiar tabeli faktów
  - czy atrybut wnosi nową/niezbędną wiedzę o fakcie?
  - czy wartość atrybutu można wyliczyć?
- Minimalizacja rozmiarów atrybutów
  - przykład: telekomunikacja
    - tabela wymiaru Abonenci zawiera $8*10^6$ abonentów
    - każdy abonent dzwoni średnio 2 razy dziennie
    - roczny horyzont czasowy tabeli faktów
    - zmniejszenie długości rekordów tabeli faktów o 10B ⇨ zyskujemy 54GB

ROLAP – klucze podstawowe i obce

- Klucze naturalne
  - nr rejestracyjny pojazdu, VIN, nr rachunku, NIP, PESEL
- Klucze sztuczne – generowane automatycznie przez system
  - nr klienta, id produktu, nr transakcji
- Połączenie tabeli wymiaru i faktów za pomocą klucza podstawowego-obcego
  - pokaż liczbę szkód pojazdu o numerze rejestracynym xxx w ostatnim roku ⇨ zapytanie wyłącznie do tabeli faktów
- Jeśli wartość klucza podstawowego może się zmienić ⇨ wysoki koszt uaktualnienia faktów
  - sytuacja mało prawdopodobna
  - uwaga: nr rachunku!

Reprezentowanie czasu w tabeli faktów (1)

- Sztuczny identyfikator (data_id)
  - konieczność łączenia z tabelą wymiaru czasu
- Naturalny identyfikator (data, timestamp) – składowanie fizycznej daty
  - sposób bardziej efektywny
  - większość analiz wykonuje się w wymiarze czasu
  - zapytanie nie zawiera połączenia z tabelą wymiaru czasu
- Składowanie przesunięcia czasowego
- Składowanie zakresów dat

Reprezentowanie czasu w tabeli faktów (2)

- Składowanie przesunięcia czasowego
  - partycjonowane tabele faktów

Platnosci_styczen2004

klient_id	kwota	nr_dnia
100	57.60	1
203	123.90	1
4005	99.00	2
205	79.40	3
111	205.90	3
5008	432.00	13
23	332.40	14
567	87.00	31

Platnosci_luty2004

klient_id	kwota	nr_dnia
100	57.60	1
203	123.90	2
4005	99.00	3
205	79.40	4
111	205.90	5
5008	432.00	28
23	332.40	29
567	87.00	29

Reprezentowanie czasu w tabeli faktów (3)

- Składowanie przesunięcia czasowego
- Wada:
  - konieczność konwersji daty z zapytania użytkownika do postaci przesunięcia czasowego
    - perspektywa
- Zaleta:
  - podział dużej tabeli na mniejsze, z których każda może być adresowana w zapytaniu niezależnie
  - mniejszy rozmiar atrybutu reprezentującego datę (1B)

Reprezentowanie czasu w tabeli faktów (4)

- Składowanie zakresów dat
  - np. atrybuty: data_od, data_do
  - stan magazynu supermarketu
  - sprzedaż w okresie
- Wada: bardziej złożone zapytanie testujące warunki początku i końca okresu
- Zaleta: zmniejszenie liczby rekordów w tabeli faktów
- Zaleta: rozszerzenie zakresu ważności rekordu poprzez zmodyfikowanie wartości data_do
  - np. liczba produktów w magazynie nie ulega zmianie w danym dniu ⇨ zmodyfikuj wartość data_do dla tego produktu

Model ogólny

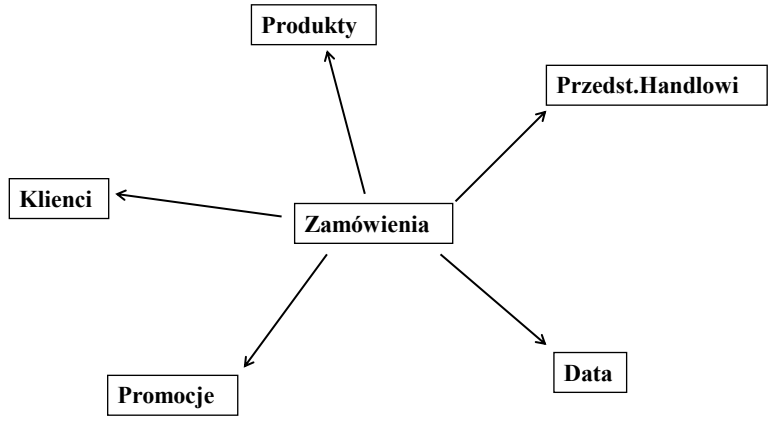

Wymiary wolnozmienne - problem

- Nowe instancje wymiaru
  - np. nowe sklepy, produkty, taryfy
- Modyfikacje wartości atrybutów
  - np. zmiana ceny brutto produktu, zmiana widełek w taryfikatorze mandatów
- Zmiana struktury instancji wymiaru
  - np. zmiana klasyfikacji produktu do innej grupy
  - zmiana struktury organizacyjnej (województwa, WE PP)
- Konieczność uaktualniania instancji wymiarów
- Rozwiązanie: R. Kimball ⇨ Slowly Changing Dimensions

Ćwiczenie - operator aukcji internetowych

Wymagane analizy:

- Liczba otwartych aukcji w danym okresie
- Liczba zakończonych aukcji w danym okresie
- Ranking sprzedawców/kupujących z punktu widzenia opinii
- Ranking sprzedawców/kupujących z punktu widzenia kwot sprzedaży
- Porównanie zysków operatora w kolejnych okresach (miesiąc, kwartał, półrocze, rok)
- Porównanie liczby zakończonych aukcji w poszczególnych okresach z podziałem na kraje