

Teoretyczne podstawy informatyki



Wykład 8: Relacyjny model danych

Relacyjny model danych

- ❑ Jednym z najważniejszych zastosowań komputerów jest przechowywanie i przetwarzanie informacji.
- ❑ Relacyjny model danych opiera się na idei organizowania danych w zbiory dwuwymiarowych tabel nazywanych „relacjami”.
- ❑ Jest to uogólnienie modelu danych opartego na zbiorach, rozszerzającego relacje binarne do relacji o dowolnej krotności.
- ❑ Relacyjny model danych został pierwotnie opracowany z myślą o bazach danych oraz o systemach zarządzania bazami danych.
- ❑ Obecne zastosowania wykraczają poza ten pierwotny zakres.

Relacje

- ❑ Chociaż założyliśmy, że w ogólności elementy należące do zbiorów są niepodzielne, w praktyce często korzystnym rozwiązaniem jest przypisanie elementom pewnych struktur.
- ❑ Ważną strukturą dla elementów jest **lista o stałej długości** zwana **krotką**. Każdy element takiej listy nazywamy składową **krotki**.
- ❑ Zbiór elementów, z których każdy jest krotką o takiej samej liczności - powiedzmy **k**- nazywamy **relacją**. Licznością takiej relacji jest **k**. Jeśli **liczność wynosi 2** mówimy o **krotce lub relacji binarnej**.

Iloczyn kartezjański $A \times B$

- ❑ Jest to zbiór par, z których pierwszy element pochodzi ze zbioru **A**, drugi ze zbioru **B**, czyli


$$A \times B = \{(a,b) : a \in A \text{ oraz } b \in B\}$$

- ❑ Iloczyn kartezjański nie ma własności przemienności, $A \times B \neq B \times A$ (dla $A \neq B$)
- ❑ **K**-elementowy iloczyn kartezjański $A_1 \times A_2 \times A_3 \dots \times A_k$ to zbiór **k-tupli** (a_1, a_2, \dots, a_n)

Specyficzne własności relacji binarnych


□ Przechodność

- Niech R będzie relacją binarną na dziedzinie D .
- Mówimy, że **relacja jest przechodnia** jeśli zawsze gdy prawdziwe jest zarówno aRb i bRc , prawdziwe jest także aRc .
Np. relacja $>$



□ Zwrotność


- Niech R będzie relacją binarną na dziedzinie D .
- Mówimy, że **relacja jest zwrotną** jeśli dla każdego elementu a należącego do dziedziny, relacja zawiera parę aRa . Dla tych samych elementów dziedziny mogą też istnieć inne pary aRb .
Np. relacja \geq



Specyficzne własności relacji binarnych


□ Symetria

- Niech R będzie relacją binarną na dziedzinie D .
- Mówimy, że **relacja jest symetryczna** jeśli jest odwrotnością samej siebie tzn. zarówno aRb i bRa ,
Np. relacja \neq




□ Antysymetria

- Niech R będzie relacją binarną na dziedzinie D .
- Mówimy, że **relacja jest antysymetryczna** jeśli aRb i bRa są jednocześnie prawdziwe **tylko** gdy $a=b$.
- Nie jest konieczne, by prawdziwe było aRa dla każdej wartości a należącej do dziedziny relacji antysymetrycznej.
Np. relacja $\geq, >$



nigdy



opcjonalnie

Specyficzne własności relacji binarnych

□ Relacja porządku częściowego i całkowitego

- Relacja porządku częściowego jest to relacja binarna spełniająca własność **przechodności i antysymetrii**.
- Mówimy że jest to **relacja porządku całkowitego** jeśli poza przechodnością i antysymetrią spełnia także warunek, że wszystkie pary elementów należących do jej dziedziny są porównywalne.
- Oznacza to, że jeśli **R** jest relacją porządku całkowitego oraz jeśli **a** i **b** są dowolnymi elementami tej dziedziny, to albo **aRb**, albo **bRa** jest prawdziwe (mówimy wtedy że relacja jest **spójna**).
- Należy zauważyć że każdy porządek całkowity jest **zwrotny**, ponieważ możemy przyjąć **a** i **b** będące tym samym elementem – wymaganie porównywalności oznacza że **aRa**.

□ Relacja równoważności

- Relacja równoważności to relacją binarną, która jest **zwrotna, symetryczna i przechodnia**.
- Dzieli ona swoją dziedzinę na **klasy równoważności**.

Relacyjny model danych

- Relacyjny model danych wykorzystuje pojęcie relacji (ang. **relation**) które jest bardzo mocno związane z przedstawioną wcześniej definicją z teorii zbiorów, jednak różni się w kilku szczegółach:

- W relacyjnym modelu danych informacja jest przechowywana w tabelach.
- Kolumny tabeli mają nadane konkretne nazwy i są atrybutami relacji.
- Każdy wiersz w tabeli jest nazywany krotką i reprezentuje jeden podstawowy fakt.
- Pojęcie relacji odwołuje się do każdej krotki.

Atrybuty relacji: Zajęcia, StudentID, Ocena

Krotki to:

(CS101, 12345, 5.0)

(CS101, 67890, 4.0)

...

| zajęcia | student ID | ocena |
|---------|------------|-------|
| CS101 | 12345 | 5.0 |
| CS101 | 67890 | 4.0 |
| EE200 | 12345 | 3.0 |
| EE200 | 22222 | 4.5 |
| CS101 | 33333 | 2.0 |
| PH100 | 67890 | 3.5 |

Relacyjny model danych

- Tabele możemy rozpatrywać w dwóch aspektach:
 - jako zbiór nazw kolumn
 - jako zbiór wierszy zawierających informacje.
- Pojęcie „relacji” odwołuje się do zbioru wierszy.
- Każdy wiersz reprezentuje jedną „krotkę” należącą do relacji, ich uporządkowanie nie ma znaczenia.
- Żadne dwa wiersze nie mogą mieć tych samych wartości we wszystkich kolumnach.
- Zbiór nazw kolumn (atrybutów) nazywamy schematem (ang. scheme) relacji.
- Kolejność atrybutów w schemacie relacji nie ma znaczenia, musimy jednak znać powiązania pomiędzy atrybutami i kolumnami w tabeli.

| zajęcia | student ID | ocena |
|---------|------------|-------|
| CS101 | 12345 | 5.0 |
| CS101 | 67890 | 4.0 |
| EE200 | 12345 | 3.0 |
| EE200 | 22222 | 4.5 |
| CS101 | 33333 | 2.0 |
| PH100 | 67890 | 3.5 |

Reprezentowanie relacji

- Podobnie jak w przypadku zbiorów istnieje wiele różnych sposobów reprezentowania relacji za pomocą struktur danych.
- Tabela** postrzegana jako zbiór wierszy **powinna być zbiorem struktur** zawierających pola odpowiadające nazwom kolumn.

```
struct ZSO {  
    char Zajecia[5];  
    int StudentID;  
    char Ocena[3]; }
```

- Sama **tabela** może być reprezentowana za pomocą:
 - tablicy struktur tego typu**
 - listy jednokierunkowej złożonej z takich struktur.**
- Możemy identyfikować jeden lub więcej atrybutów jako „dziedzinę” relacji i traktować pozostałe atrybuty jako przeciwdziedzinę.

| zajęcia | student ID | ocena |
|---------|------------|-------|
| CS101 | 12345 | 5.0 |
| CS101 | 67890 | 4.0 |
| EE200 | 12345 | 3.0 |
| EE200 | 22222 | 4.5 |
| CS101 | 33333 | 2.0 |
| PH100 | 67890 | 3.5 |

Reprezentowanie relacji

- Zbiór relacji nazywamy **bazą danych**.
- Jedną z decyzji którą należy podjąć przy projektowaniu bazy danych to sposób w jaki przechowywane informacje powinny być rozłożone pomiędzy tabele.
- Najskuteczniejsze operacje na bazie danych polegają na wykorzystaniu wielu relacji do reprezentowania powiązanych ze sobą i wzajemnie skoordynowanych typów danych.
- Wykorzystując właściwe struktury danych możemy efektywnie przechodzić z jednej relacji do drugiej i pozyskiwać w ten sposób informacje z bazy danych której nie moglibyśmy otrzymać z pojedynczej relacji.
- **Zbiór schematów** dla różnych relacji w jednej bazie danych nazywamy schematem bazy danych.
 - **schemat bazy danych** - określa sposób organizowania informacji,
 - **zbiór krotek w każdej relacji** - stanowi właściwe informacje które są przechowywane.

Schemat bazy danych

| Zajęcia | Dzień | Godzina |
|---------|-------|---------|
| CS101 | Pn | 9.00 |
| CS101 | S | 9.00 |
| EE200 | Pt | 8.30 |
| EE200 | W | 13.00 |
| CS101 | Pt | 9.00 |
| PH100 | C | 8.15 |

| Zajęcia | Wymagania |
|---------|-----------|
| CS101 | CS100 |
| EE200 | EE005 |
| EE200 | CS100 |
| CS120 | CS101 |
| CS121 | CS120 |
| CS205 | CS101 |
| CS206 | CS121 |
| CS206 | CS205 |

| Zajęcia | Student ID | Ocena |
|---------|------------|-------|
| CS101 | 12345 | 5.0 |
| CS101 | 67890 | 4.0 |
| EE200 | 12345 | 3.0 |
| EE200 | 22222 | 4.5 |
| CS101 | 33333 | 2.0 |
| PH100 | 67890 | 3.5 |

| Zajęcia | Klasa |
|---------|---------|
| CS101 | Aula |
| EE200 | Hala |
| PH100 | Laborat |

Zapytania na bazie danych

- **Operacja insert(t, R)**
 - **Dodajemy krotkę t do relacji R** , jeśli relacja R nie zawiera jeszcze takiej krotki.
 - Operacja działa w podobny sposób jak operacja insert dla słowników i relacji binarnych.
- **Operacja delete(X, R)**
 - W tym przypadku X jest specyfikacją kilku krotek.
 - Składa się z elementów, po jednym dla każdego z atrybutów relacji R ; każdy element (składowa) może być
 - wartością
 - symbolem $*$, co oznacza że dozwolona jest dowolna wartość.
 - Efektem wykonania tej operacji jest usunięcie wszystkich krotek zgodnych ze specyfikacją X .
Np. delete((„CS101”,*,*),Zajęcia-StudentID-Ocena)
- **Operacja lookup(X, R)**
 - Wynikiem tej operacji jest zbiór krotek z relacji R , które są zgodne ze specyfikacją X .

Klucze

- Wiele relacji w bazie danych możemy traktować jak funkcję odwzorowującą jeden zbiór atrybutów na pozostałe atrybuty.
 - Przykładowo, relacje **Zajęcia – StudentID – Ocena** możemy traktować jak **funkcję**, której dziedziną jest zbiór par **Zajęcia-StudentID**, a przeciwdziedzina wartość atrybutu **Ocena**.
- Ponieważ funkcje są prostszymi strukturami danych niż relacje, pomocna może być znajomość zbioru atrybutów, które mogą tworzyć dziedzinę funkcji. Taki zbiór atrybutów nazywamy **kluczem**.
- **Klucz relacji**
 - Jest to zbiór złożony z jednego lub większej liczby takich atrybutów, że relacja nigdy nie będzie zawierała dwóch krotek, których wartości będą takie same we wszystkich kolumnach należących do klucza.

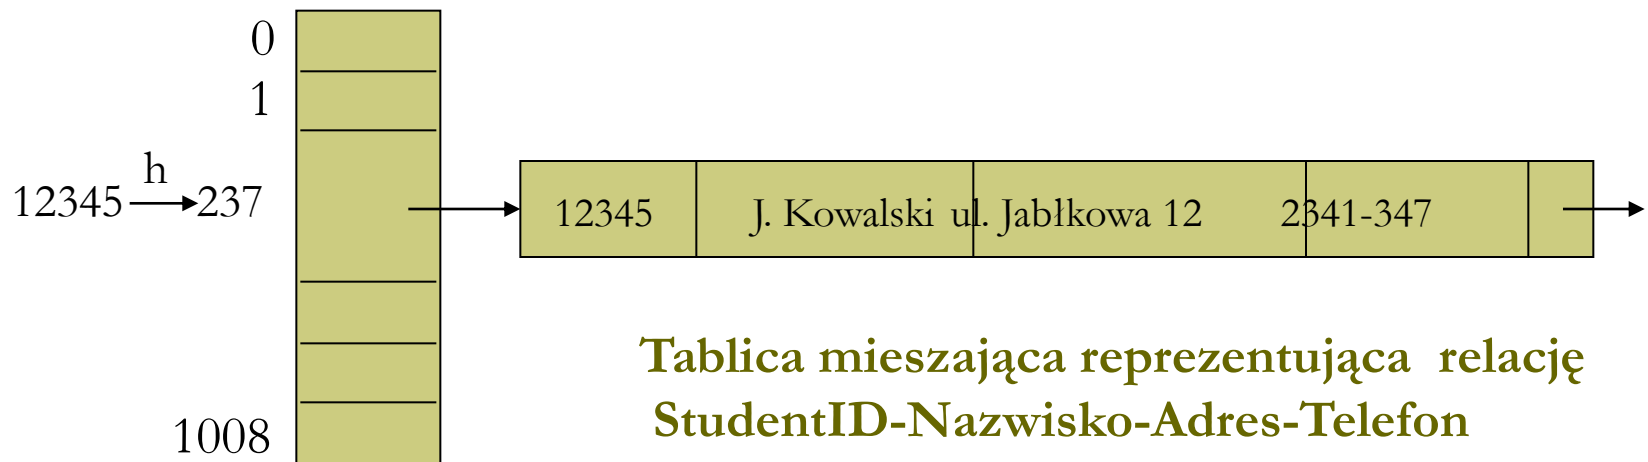
Główne struktury przechowywania danych w relacjach

1. Drzewo przeszukiwania binarnego z relacją „mniejszy od” na wartościach dziedziny, która wyznacza pozycje krotek w drzewie. Struktura może znacznie ułatwić wykonywanie operacji, w których daną jest wartość z dziedziny.
 2. Tablica wykorzystywana jako wektor własny z wartościami z dziedziny pełniącymi funkcję indeksu tablicy.
 3. Tablica mieszająca, w której mieszamy wartości z dziedziny w celu wyznaczenia właściwej komórki.
- Wybraną strukturę nazywamy **strukturą indeksu głównego** (ang. **primary index structure**) relacji.
 - **Główny** bo lokalizacja komórek jest wyznaczana przez tę strukturę.
 - **Index** jest strukturą danych ułatwiającą znajdowanie komórek dla danej wartości jednej lub kilku składowych szukanej komórki.

Struktura indeksu głównego

- Kluczem jest atrybut StudentID, będzie on dziedziną.
- Musimy wybrać funkcję mieszającą, np. $h(x) = x \% 1009$.
- Tablica złożona z 1009 nagłówek zwiera listę jednokierunkową struktur.

```
typedef struct TUPLE * TUPLELIST;
struct TUPLE {
    int StudentID;
    char Nazwisko[30];
    char Adres[60];
    char Telefon[8];
    TUPLELIST next;
};
typedef TUPLELIST HASHTABLE[1009];
```





Tablica mieszająca reprezentująca relację StudentID-Nazwisko-Adres-Telefon


Struktura indeksu drugorzędnego

- Nie służy do pozycjonowania krotek wewnątrz całej struktury tylko do szybkiego znajdowania lokalizacji krotki której jedno z pól ma wartość zgodną z poszukiwaną.
- **Indeksem drugorzędnym jest relacja binarna.**
 - Indeks drugorzędny na atrybucie **A** relacji **R** jest zbiorem par **(n, p)**, gdzie:
 - **n** jest wartością atrybutu **A**
 - **p** jest wskaźnikiem do jednej z krotek ze struktury indeksu głównego dla relacji **R**, w której składowa **A** ma wartość **n**.

Struktura indeksu głównego i drugorzędneho



Struktura indeksu głównego




```
typedef struct KROTKA * KROTKALIST;
struct KROTKA {
    int StudentID;
    char Nazwisko[30];
    char Adres[60];
    char Telefon[8];
    KROTKALIST next;
};
typedef KROTKALIST HASHTABLE[2];
```

- ❑ **Tablica mieszająca o atrybucie StudentID**, pełniąca funkcję **indeksu głównego**.
- ❑ Krotki z informacją dotyczącą studenta przechowywane w formie struktur **KROTKA** w liście jednokierunkowej zajmującej pojedynczą komórkę tablicy mieszającej.

Struktura indeksu drugorzędnego

- ❑ **NODE** jest węzłem drzewa binarnego z dwoma polami, **Nazwisko** i **toKrotka**, czyli wartość elementu nazwisko i wskaźnik do krotki gdzie jest przechowywana inna informacja dotycząca tego studenta.
- ❑ Pozostałe dwa pola to **wskaźniki do lewego i prawego dziecka węzła**.

```
typedef struct NODE * TREE;
struct NODE {
    char Nazwisko[30];
    KROTKALIST toKrotka;
    TREE leftChild;
    TREE rightChild;
};
```



➤ **struktura indeksu drugorzędnego**

Analizowanie struktury indeksu drugorzędnego

- Jeżeli dla danej relacji istnieje jeden lub więcej indeksów drugorzędnych, operacje wstawiania i usuwania krotek stają się nieco trudniejsze.
 - **Wstawianie:**

Jeśli wstawiamy nową krotkę z wartością **n** atrybutu **A**, musimy utworzyć parę **(n, p)**, gdzie **p** wskazuje na nowy element w strukturze indeksu głównego.
Następnie, musimy wstawić tę samą parę **(n, p)** do struktury indeksu drugorzędnego.
 - **Usuwanie:**

Kiedy usuwamy krotkę z wartością **n** atrybutu **A**, musimy najpierw zachować wskaźnik –nazwijmy go **p** – do usuwanej krotki.
Następnie przechodzimy do struktury indeksu drugorzędnego i sprawdzamy wszystkie pary z pierwszą składową zawierającą wartość **n**, aż znajdziemy tę, której druga składowa ma wartość **p**.
Znaleziona w ten sposób para jest teraz usuwana ze struktury indeksu drugorzędnego.

Poruszanie się wśród wielu relacji

- Do tej pory rozważaliśmy wyłącznie operacje na pojedynczych relacjach, takie jak znajdowanie krotki dla danych wartości jednej lub kilku jej składowych.
- Możliwości modelu relacyjnego można jednak w pełni docenić w momencie, gdy rozważamy operacje wymagające „poruszania się”, lub „przechodzenia” z jednej relacji do drugiej.

- Aby znaleźć odpowiedź na pytanie:

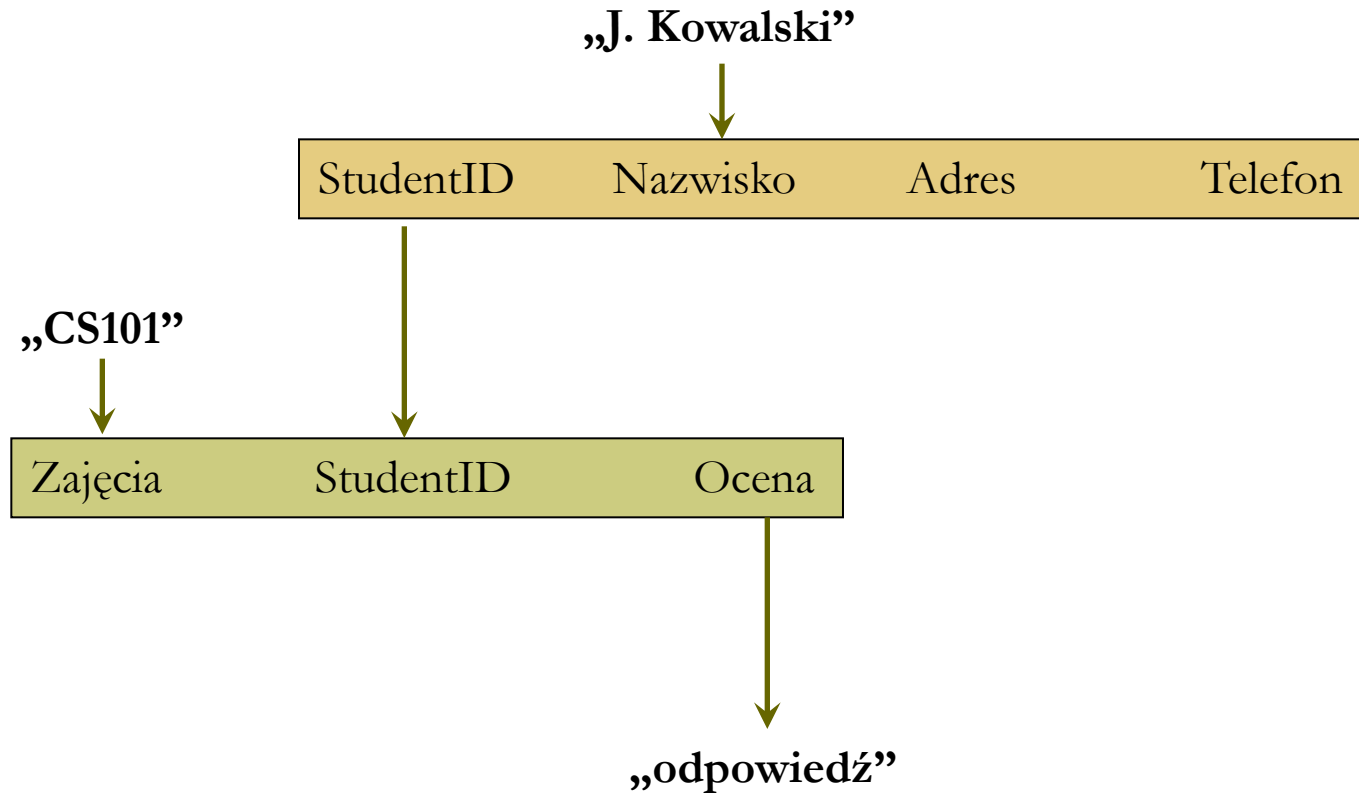
„Jaką ocenę uzyskał J. Kowalski z przedmiotu CS101?”

musimy:

1. odwołać się do relacji StudentID-Nazwisko-Adres-Telefon i przelożyć dane nazwisko „J. Kowalski” na odpowiedni numer indeksu (możliwość istnienia duplikatu nazwiska ale nie numeru indeksu),
2. odwołać się do relacji Zajęcia-StudentID-Ocena i wyznaczyć krotkę mającą w polu Zajęcia wartość „CS101” a w polu numer indeksu wyznaczoną poprzednio wartość,
3. odczytać wartość umieszczoną w polu Ocena.

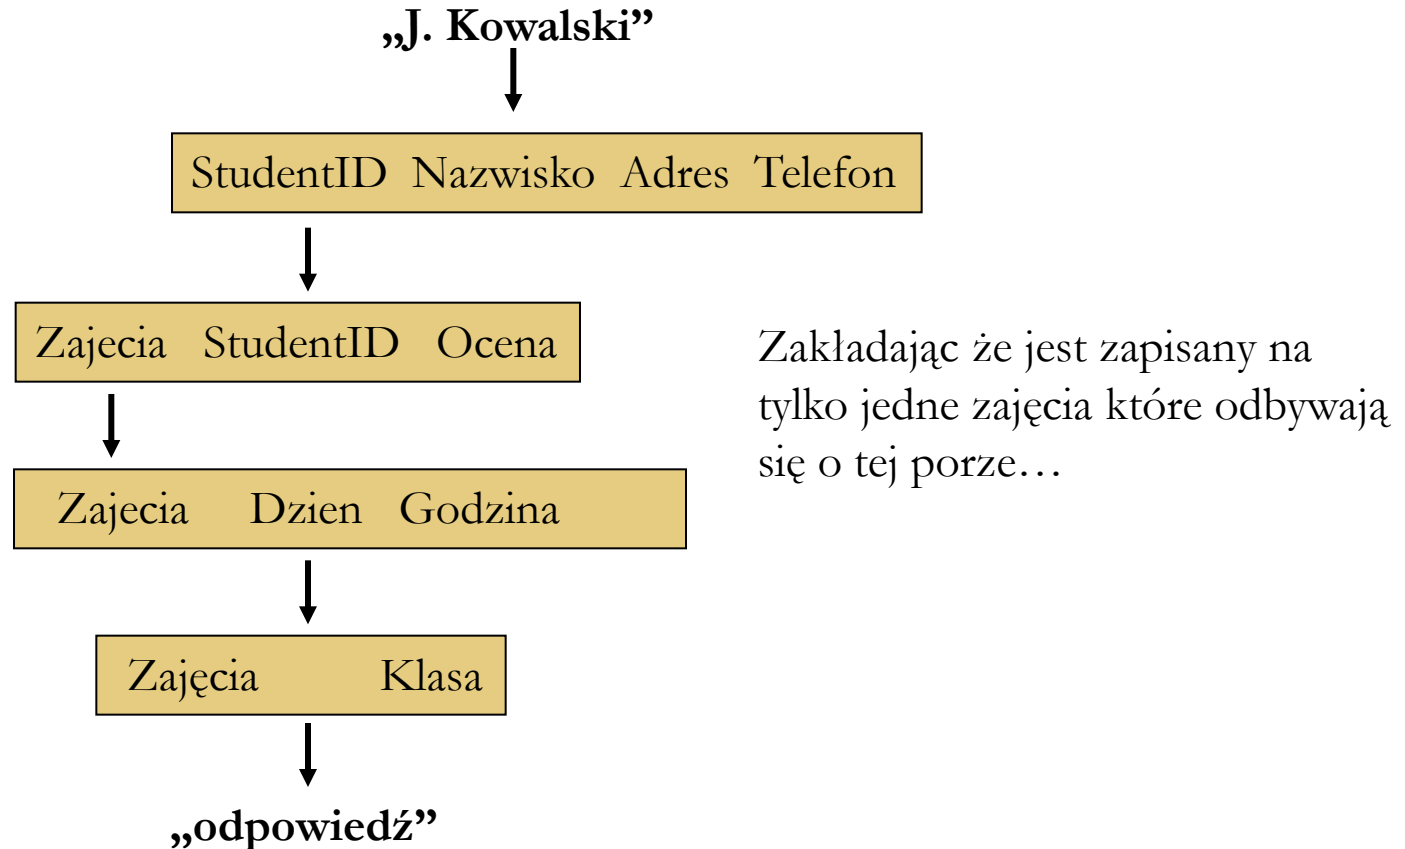
Diagram wykonania zapytania:

„Jaka ocenę uzyskał J. Kowalski z przedmiotu CS101?”



- Czas realizacji zapytania będzie dużo krótszy jeżeli wykorzystamy indeksowanie drugorzędne → patrz ćwiczenia.

Diagram wykonania zapytania:
„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano? ”



- Indeksowanie drugorzędowe bardzo przyspiesza czas wykonania.

Projektowanie

□ Projektowanie I : wybór schematu baz danych

- rozdzielamy informacje budując kilka relacji (krotek) zamiast umieszczać je w jednej dużej krotce,
- nie należy rozdzielać atrybutów reprezentujących powiązane ze sobą informacje.

□ Projektowanie II : wybór klucza

- jeden z ważniejszy aspektów projektowania bazy danych,
- nie istnieje „jedyna” właściwa metoda wybierania klucza.

□ Projektowanie III: wybór indeksu głównego

- ma zdecydowany wpływ na szybkość z jaką możemy wykonywać „typowe” zadanie.

□ Projektowanie IV: kiedy tworzyć indeks drugorzędny?

- utworzenie ułatwia wykonywanie operacji wyszukiwania krotki dla danej wartości jednej lub więcej składowych,
- każdy indeks drugorzędny wymaga dodatkowego czasu wstawiania i usuwania informacji z relacji.

Podsumowanie

- Istnieje wiele istotnych własności **relacji binarnych**.
Do najważniejszych należą: **zwrotność, przechodniość, symetria i antysymetria**.
Relacja porządku częściowego, porządku całkowitego oraz relacja równoważności to specyficzne rodzaje relacji binarnych;
- Dwuwymiarowe tabele zwane relacjami, są uniwersalnym sposobem przechowywania informacji.
Wiersze relacji nazywamy **krotkami**, zaś kolumny noszą nazwę **atrybutów**.
- „**Indeks główny**” reprezentuje krotki relacji w formie struktury danych i rozdziela je w taki sposób, by ułatwić (przyśpieszyć) operacje wykorzystujące dane wartości należące do „dziedziny” indeksu;

Podsumowanie

- „**Kluczem**” relacji jest zbiór atrybutów, które jednoznacznie określają wartości wszystkich pozostałych atrybutów tej samej relacji.
Klucz jest często wykorzystywany jako dziedzina indeksu głównego;
- „**Indeksy drugorzędowe**” są strukturami danych ułatwiającymi operacje, w których dane są wartości konkretnych atrybutów nie będących zazwyczaj częścią indeksu głównego.
Ułatwiają szybkie odczytanie lub zmodyfikowanie informacji zawartych w tabeli.

Algebra relacyjna

- Algebra relacyjna (*ang. relational algebra*) to specjalny język opracowany w celu ułatwienia i sformalizowania zapytań realizowanych w bazach danych.
- Umożliwia przekształcanie wyrażeń realizujących zapytania za pomocą odpowiednich praw algebraicznych.

Operandy algebry relacyjnej

- W algebrze relacyjnej operandami są relacje.
- Operandy mogą być albo stałymi (konkretnymi relacjami) albo zmiennymi reprezentującymi nieznaną relację.
- Każdy operand jest zgodny ze specyficznym schematem – jest listą atrybutów będących nazwami kolumn relacji.
- Przykład:
 - Schematem relacji jest $\{A, B, C\}$, zaś należące do niej krotki to $(0,1,2)$, $(0,3,4)$ oraz $(5,2,3)$.

| A | B | C |
|---|---|---|
| 0 | 1 | 2 |
| 0 | 3 | 4 |
| 5 | 2 | 3 |

Operatory dla zbiorów w algebrze relacyjnej

□ Suma, przecięcie oraz różnica zbiorów

- Dodatkowe założenie w stosunku do tego co już znamy z operacji na zbiorach to to, że schematy operandów muszą być takie same.

relacja R

| A | B |
|---|---|
| 0 | 1 |
| 2 | 3 |

relacja S

| A | B |
|---|---|
| 0 | 1 |
| 4 | 5 |

$R \cup S$

| A | B |
|---|---|
| 0 | 1 |
| 2 | 3 |
| 4 | 5 |

$R \cap S$

| A | B |
|---|---|
| 0 | 1 |

$R \setminus S$

| A | B |
|---|---|
| 2 | 3 |

- Relacje są zbiorami nie mogą więc zawierać dwóch lub więcej kopii tej samej krotki.

Operator selekcji (*ang. selection operator*)

- Operuje na pojedynczej relacji będącej jego operandem, ale zawiera także dodatkowe wyrażenia warunkowe stanowiące jego parametry.
- Operator selekcji zapisujemy w postaci:

$$\sigma_C(R)$$

R – relacja

C – warunek

- Warunek **C** może zawierać stałe, jak i operandy będące atrybutami ze schematu relacji **R**.
- Operatorami wykorzystywanymi w warunku **C** są typowe wyrażenia warunkowe z języka programowania **C**, czyli wyrażenia złożone z porównań arytmetycznych oraz logicznych łączników.
- Wynikiem operacji jest relacja której schemat jest identyczny ze schematem relacji **R**.
- W relacji tej umieszczamy wszystkie krotki **t** z relacji **R**, dla których warunek **C** jest prawdziwy po podstawieniu za każdy atrybut **A** właściwej dla niej składowej krotki **t**.

Przykład: Relacja ZSO Zajęcia-StudentID-Ocena

| Zajęcia | Student ID | Ocena |
|---------|------------|-------|
| CS101 | 12345 | 5.0 |
| CS101 | 67890 | 4.0 |
| EE200 | 12345 | 3.0 |
| EE200 | 22222 | 4.5 |
| CS101 | 33333 | 2.0 |
| PH100 | 67890 | 3.5 |

Operator selekcji

$\sigma_{\text{Zajęcia} = \text{„CS101”}}$ (ZSO)

| Zajęcia | Student ID | Ocena |
|---------|------------|-------|
| CS101 | 12345 | 5.0 |
| CS101 | 67890 | 4.0 |
| CS101 | 33333 | 2.0 |

Operator rzutowania (*ang. projection operator*)

- Operuje na pojedynczej relacji będącej jego operandem, ale zawiera także dodatkowe wyrażenia warunkowe stanowiące jego dodatkowe parametry.
- Operator rzutowania zapisujemy w postaci:

$$\pi_{B_1, B_2, \dots, B_n}(R)$$

R – relacja

B_1, B_2, \dots, B_n - atrybuty

- Jeśli R jest relacją ze zbiorem atrybutów $\{A_1, A_2, \dots, A_k\}$ oraz (B_1, B_2, \dots, B_n) jest listą pewnych atrybutów A , to $\pi_{B_1, B_2, \dots, B_n}(R)$, czyli **rzutowanie relacji R na atrybuty B_1, B_2, \dots, B_n** jest zbiorem krotek utworzonych przez wybranie z każdej krotki t tylko atrybutów B_1, B_2, \dots, B_n .
- Jedna lub więcej krotek może posiadać te same wartości atrybutów B_1, B_2, \dots, B_n .
- Jako wynik operacji rzutowania pojawia się tylko jedna taka krotka.

Przykład: Relacja ZSO Zajęcia-StudentID-Ocena

| zajęcia | student ID | ocena |
|---------|------------|-------|
| CS101 | 12345 | 5.0 |
| CS101 | 67890 | 4.0 |
| EE200 | 12345 | 3.0 |
| EE200 | 22222 | 4.5 |
| CS101 | 33333 | 2.0 |
| PH100 | 67890 | 3.5 |

Operator rzutowania

$\pi_{\text{StudentID}} (\sigma_{\text{Zajęcia} = \text{„CS101”}} (\text{ZSO}))$

| Student ID |
|------------|
| 12345 |
| 67890 |
| 33333 |

Operator łączenia (*ang. join operator*)

- Umożliwia nam przechodzenie z jednej relacji do drugiej.
- Operator łączenia zapisujemy w postaci **&&**
- Przypuśćmy, że mamy dwie relacje **R** i **S**, których zbiory atrybutów (schematy) mają odpowiednio postać $\{A_1, A_2, \dots, A_n\}$ oraz $\{B_1, B_2, \dots, B_m\}$
- Z obu zbiorów wybieramy po jednym atrybucie – powiedzmy **A_i** i **B_j** – i te atrybuty są parametrami naszej operacji złączenia, której argumentami są relacje **R** i **S**.
- Złączenie relacji R i S zapisujemy:

$$\begin{array}{ccc} & \&\& & \\ \mathbf{R} & & & & \mathbf{S} \\ & \mathbf{A}_i = \mathbf{B}_j & & & \end{array}$$

i jest utworzone w wyniku porównania każdej krotki **r** z relacji **R** z każdą krotką **s** z relacji **S**.

- Jeśli składowa **r** odpowiadająca atrybutowi **A_i** jest równa składowej **s** odpowiadającej atrybutowi **B_j** to tworzymy jedną krotkę.
- Schemat złączonej relacji jest $\{A_1, A_2, \dots, A_n, B_1, B_2, \dots, B_{j-1}, B_{j+1}, \dots, B_m\}$
- A więc atrybut **B_j** się nie pojawia.
- Jeżeli atrybuty **A_i** i **B_j** mają tę samą nazwę to mówimy o złączeniu naturalnym.

Przykład

ZDG

| Zajęcia | Dzień | Godzina |
|---------|-------|---------|
| CS101 | Pn | 9.15 |
| CS101 | S | 9.15 |
| EE200 | Pt | 8.30 |
| EE200 | W | 13.00 |
| CS101 | Pt | 9.15 |

ZK

| Zajęcia | Klasa |
|---------|---------|
| CS101 | Aula |
| EE200 | Hala |
| PH100 | Laborat |


Operacja łączenia
&&
ZK Zajęcia = Zajęcia ZDG

| Zajęcia | Klasa | Dzień | Godzina |
|---------|-------|-------|---------|
| CS101 | Aula | Pn | 9.15 |
| CS101 | Aula | S | 9.15 |
| EE200 | Hala | Pt | 8.30 |
| EE200 | Hala | W | 13.00 |
| CS101 | Aula | Pt | 9.15 |

Drzewa wyrażeń dla algebry relacyjnej

Drzewo wyrażenia algebry relacyjnej:

$\pi_{\text{Dzień, Godzina}} (\sigma_{\text{Klasa} = \text{„Aula”}} (\text{ZK} \ \&\& \ \text{ZDG}))$



Wynik po realizacji drzewa wyrażenia

| Dzień | Godzina |
|-------|---------|
| Pn | 9.15 |
| S | 9.15 |
| Pt | 9.15 |

SQL – język oparty na algebrze relacyjnej

- Wiele współczesnych systemów baz danych wykorzystuje język **SQL** (*ang. Structured Query Language* – strukturalny język zapytań) do wyrażania zapytań.

Operacja: $\pi_{\text{StudentID}} (\sigma_{\text{Zajęcia} = \text{„CS101”}} (\text{ZSO}))$

```
SELECT StudentID
FROM ZSO
WHERE Zajęcia=„CS101”
```

Operacja: $\pi_{\text{Dzień, Godzina}} (\sigma_{\text{Klasa} = \text{„Aula”}} (\text{ZK} \ \&\& \ \text{ZDG}))$

```
SELECT Dzień, Godzina
FROM ZK, ZDG
WHERE ZK.Zajęcia = ZGD.Zajęcia AND Klasa = „Aula”
```

Implementowanie operacji algebry relacyjnej

□ Suma, przecięcie i różnica:

- Można implementować analogicznie jak dla zbiorów.
- Należy przewidzieć sposób eliminacji duplikatów na pewnym etapie tych operacji.
- Można wykorzystać indeks.

□ Rzutowanie:

- Operacja wymaga przejścia wszystkich krotek i stworzenia kopii pozbawionych składowych odpowiadających atrybutom, których nie ma na liście rzutowania.
- Po wyznaczeniu rzutowania, np. $S = \pi_L(R)$, dla pewnej relacji R i liście atrybutów L , musimy wyeliminować duplikaty (stosujemy jedna z omówionych już metod).

Implementowanie operacji algebry relacyjnej

□ Selekcja:

- Wykonywanie operacji selekcji $S = \sigma_C(R)$ na relacji R , dla której nie zdefiniowano żadnych indeksów.
- Musimy przeanalizować wszystkie krotki w tej relacji w celu sprawdzenia warunku C .
- Jeżeli takie indeksy istnieją oraz można je wykorzystać do całkowitego lub częściowego sprawdzenia warunku C to bardzo przyspiesza to czas wykonania operacji.

□ Łączenie:

- Istnieje szereg metod łączenia, różniących się czasem wykonania.
- Tylko wymienimy: złączenie pętli zagnieżdżonej (*ang. nested loop join*), złączenie indeksowe (*ang. index-join*), złączenie przez sortowanie (*ang. sort-join*).
- Złączenie indeksowe wymaga istnienia indeksu na jednym z atrybutów wykorzystywanych do łączenia, złączenie przez sortowanie może być wykonywane na dowolnych relacjach.

Prawa algebraiczne dla relacji

- Podobnie jak w przypadku innych algebr, przekształcanie wyrażeń algebry zapytań umożliwia często „optymalizację” zapytań.
- Oznacza to, że możemy przekształcić kosztowne obliczeniowo wyrażenie w równoważne, którego obliczenie charakteryzuje się niższym kosztem.
- Podczas gdy przekształcanie wyrażeń arytmetycznych lub logicznych umożliwia niekiedy uzyskanie oszczędności rzędu kilku operacji, właściwe przekształcenia zastosowane do algebry relacyjnej może w znacznym stopniu skrócić czas potrzeby do wyznaczenia wartości wyrażenia.

Prawa dla łączenia:

- Operator łączenia jest w pewnym sensie przemienne, w innym nie jest. Jeżeli istotna jest kolejność atrybutów to nie jest, **S && R** ma inne kolumny niż **R && S**.
- Operator łączenia nie zawsze spełnia warunki prawa łączności.

Prawa algebraiczne dla relacji

□ Prawa dla selekcji:

- Najbardziej przydatne prawa algebry relacyjnej dotyczą operatora selekcji. Staramy się dokonywać selekcji na jak najwcześniejszym etapie.

- **Prawa przenoszenia selekcji** (*ang. selection pushing*)

$$(\sigma_C (R \ \&\& \ S)) == (\sigma_C (R) \ \&\& \ S)$$

$$(\sigma_C (R \ \&\& \ S)) == (R \ \&\& \ \sigma_C (S))$$

- **Prawo podziału selekcji** (*ang. selection splitting*)

$$\sigma_{C \ \text{AND} \ D} (R) == \sigma_C (\sigma_D (R))$$

- **Prawo przemienności selekcji**

$$\sigma_C (\sigma_D (R)) == \sigma_D (\sigma_C (R))$$

- **Operacje selekcji możemy przenosić poniżej sumy, przecięcia i różnicy zbiorów.**

„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

- Wykonanie tego zapytania wymaga przechodzenia pomiędzy czterema relacjami:
 - ZSO (Zajęcia-StudentID-Ocena)
 - SNAT (StudentID-Nazwisko-Adres-Telefon)
 - ZDG (Zajęcia-Dzień-Godzina)
 - ZK (Zajęcia-Klasa)
- Aby wykonać wyrażenie algebraiczne dla tego zapytania rozpocznijmy od złączenia „naturalnego” dla wszystkich czterech relacji.
 - ZSO && SNAT (porównując StudentID)
 - (ZSO && SNAT) && ZDG (porównując Zajęcia)
 - ((ZSO && SNAT) && ZDG) && ZK (porównując Zajęcia)
- Relacja wynikowa to: **{Zajęcia, StudentID, Ocena, Nazwisko, Adres, Telefon, Dzień, Godzina, Klasa}**


„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

π Klasa

σ Nazwisko = „J. Kowalski” AND Dzień=„M” AND Godzina=„9.00”


Skonstruowaliśmy olbrzymią relację oraz ograniczyliśmy zbiór danych do 1 krotki

Wykonaliśmy operacje rzutowania na jedną składową.




„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

Przenieść operacje selekcji
poniżej najwyższej operacji
łączenia z relacja ZK

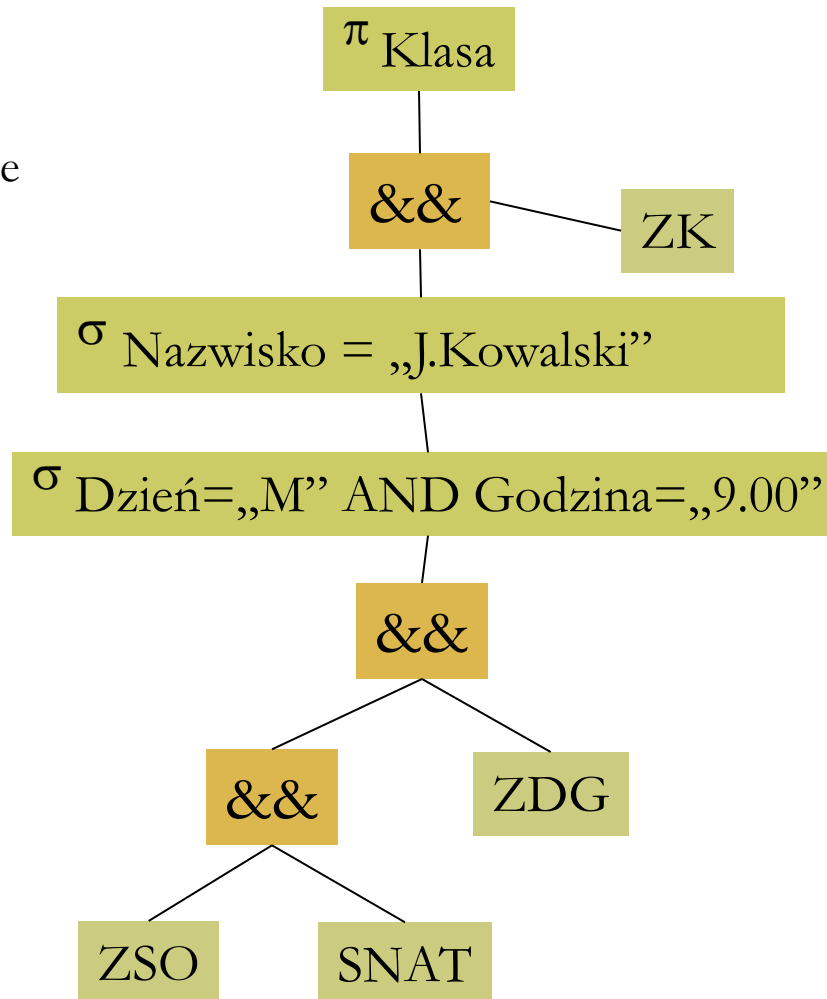


σ Nazwisko = „J.Kowalski” AND Dzień=„M” AND Godzina=„9.00”



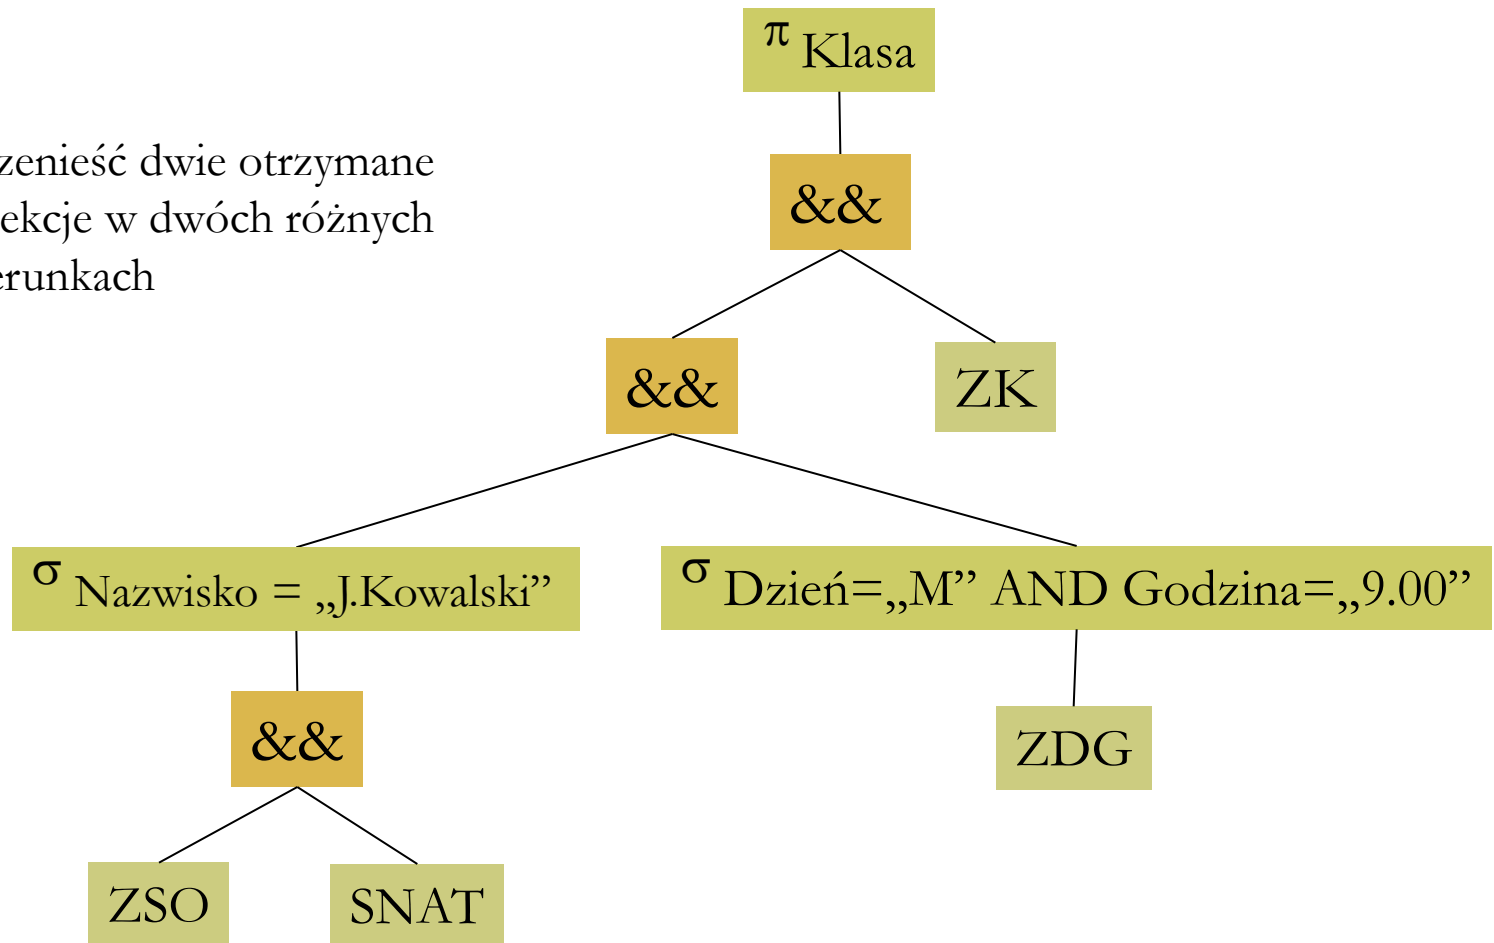
„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

Rozdziel selekcje



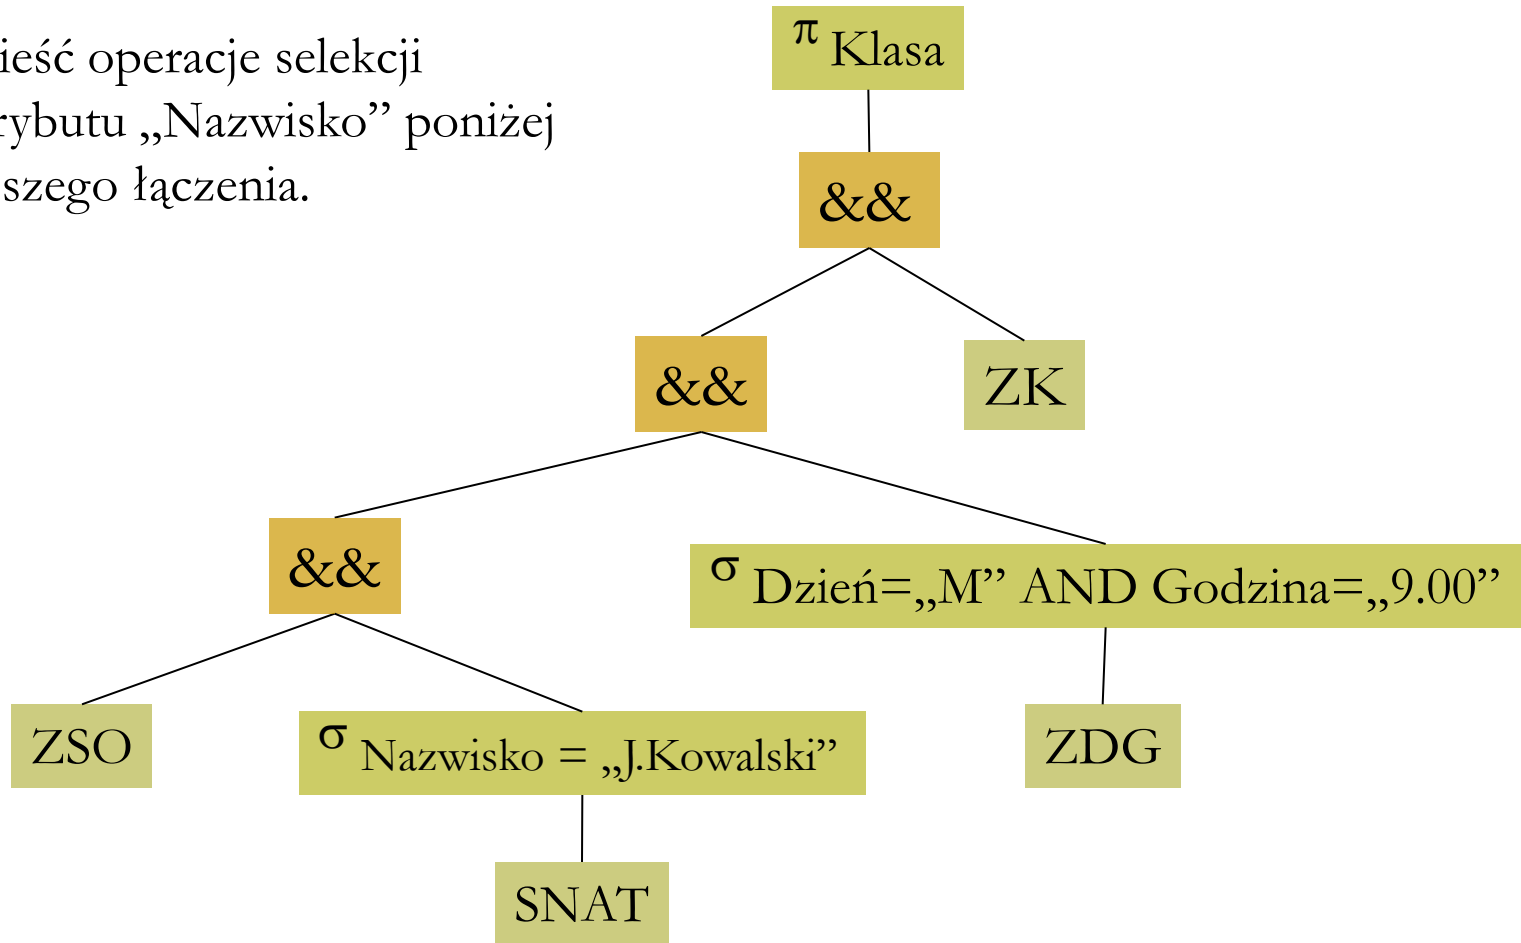
„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

Przenieść dwie otrzymane selekcje w dwóch różnych kierunkach



„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

Przenieść operacje selekcji dla atrybutu „Nazwisko” poniżej najniższego łączenia.



Prawa dla rzutowania

- Rzutowanie możemy przenosić poniżej sum:
 - $\pi_L (R \cup S) = (\pi_L (R) \cup \pi_L (S))$
- ale nie poniżej przecięć:
 - $\pi_L (R \cap S) \neq (\pi_L (R) \cap \pi_L (S))$
- **Prawo przenoszenia rzutowania:**

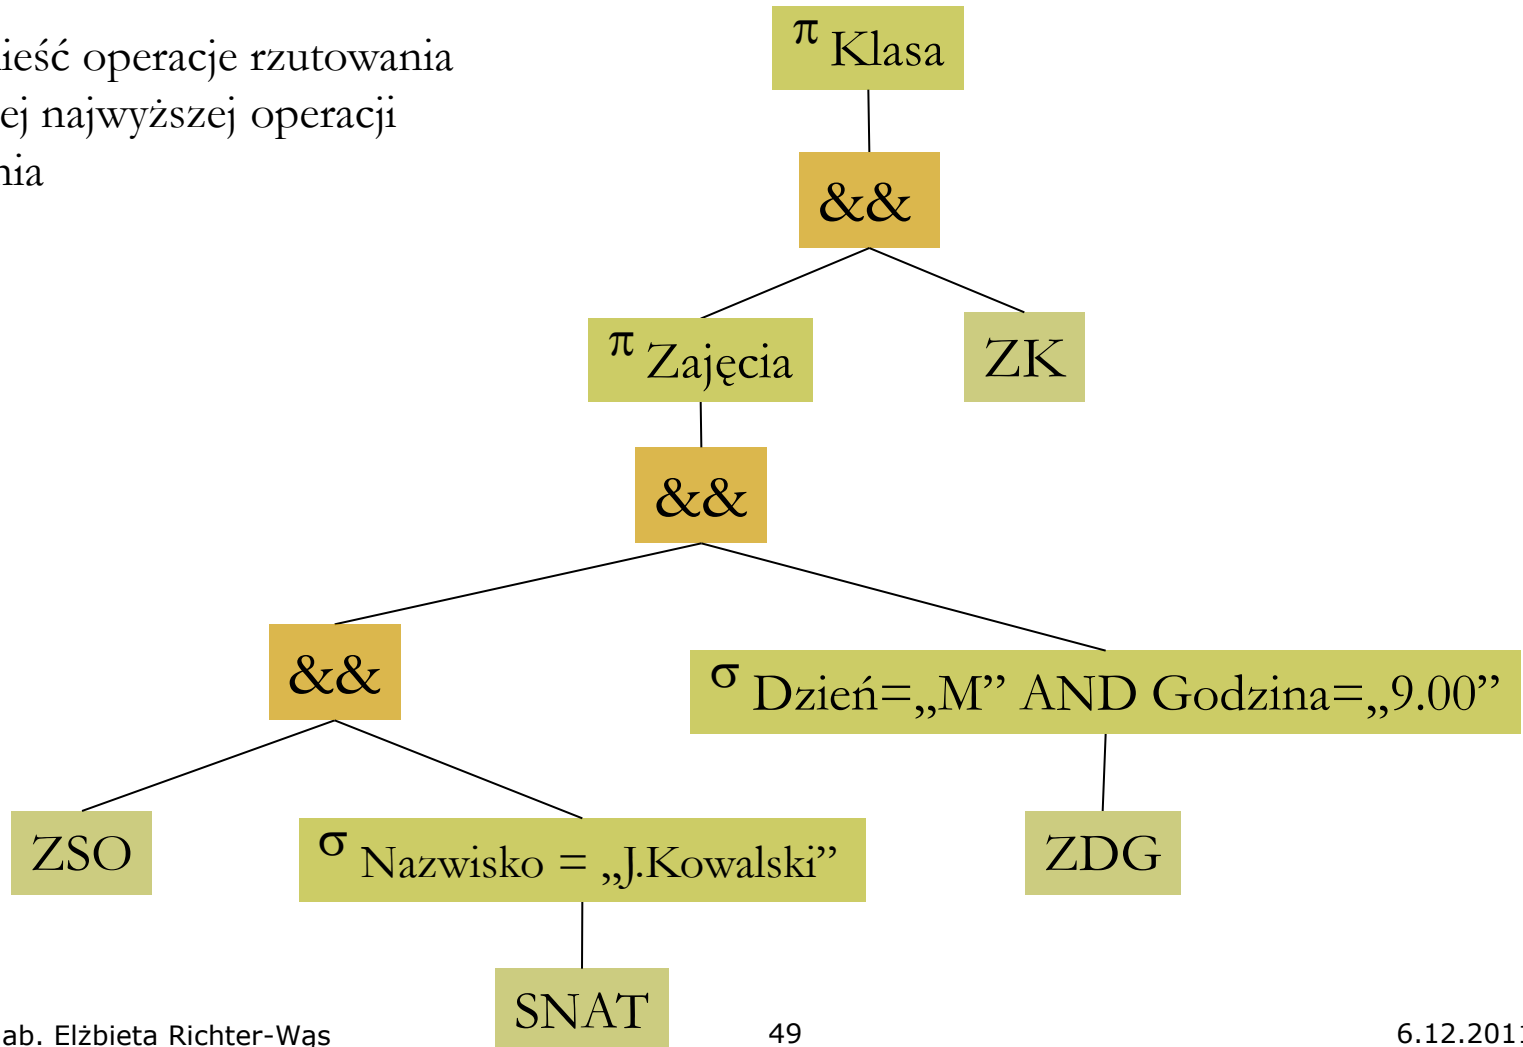
$$(\pi_L (R \underset{A=B}{\&\&} S)) = (\pi_L (\pi_M (R) \underset{A_i=B_j}{\&\&} \pi_N (S)))$$

M – lista atrybutów z listy **L**, które należą do schematu relacji **R**, plus atrybut **A**, jeśli nie ma go na liście **L**

N – lista atrybutów z listy **L**, które należą do schematu relacji **R**, plus atrybut **B**, jeśli nie ma go na liście **L**

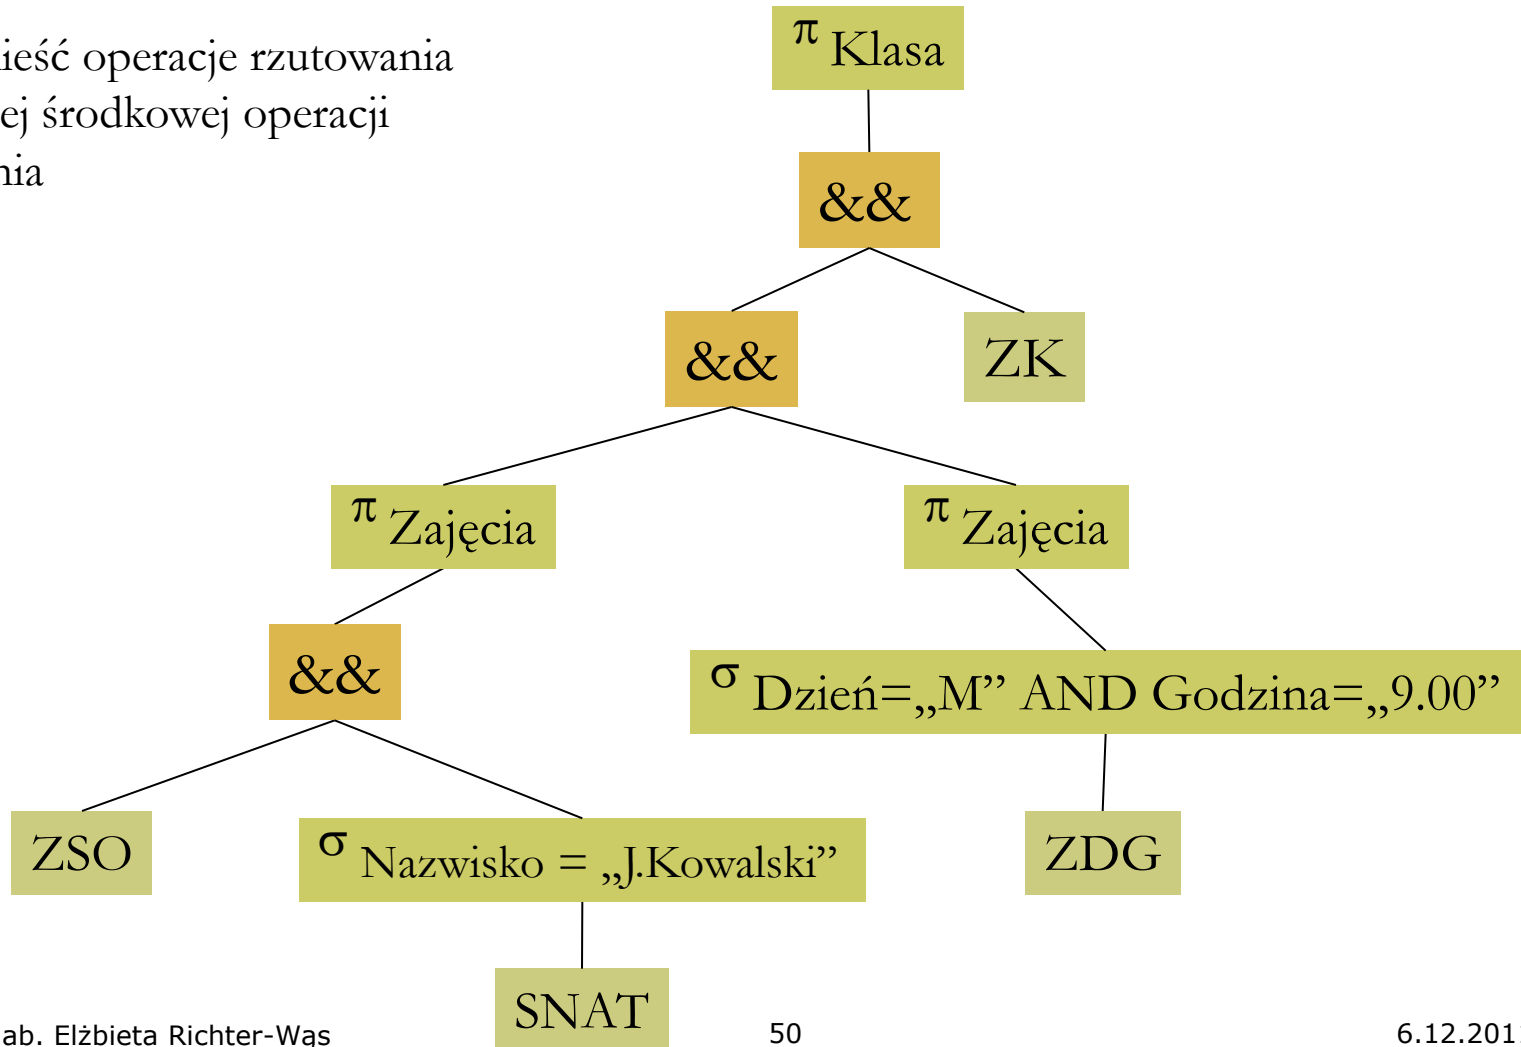
„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

Przenieść operacje rzutowania
poniżej najwyższej operacji
łączenia



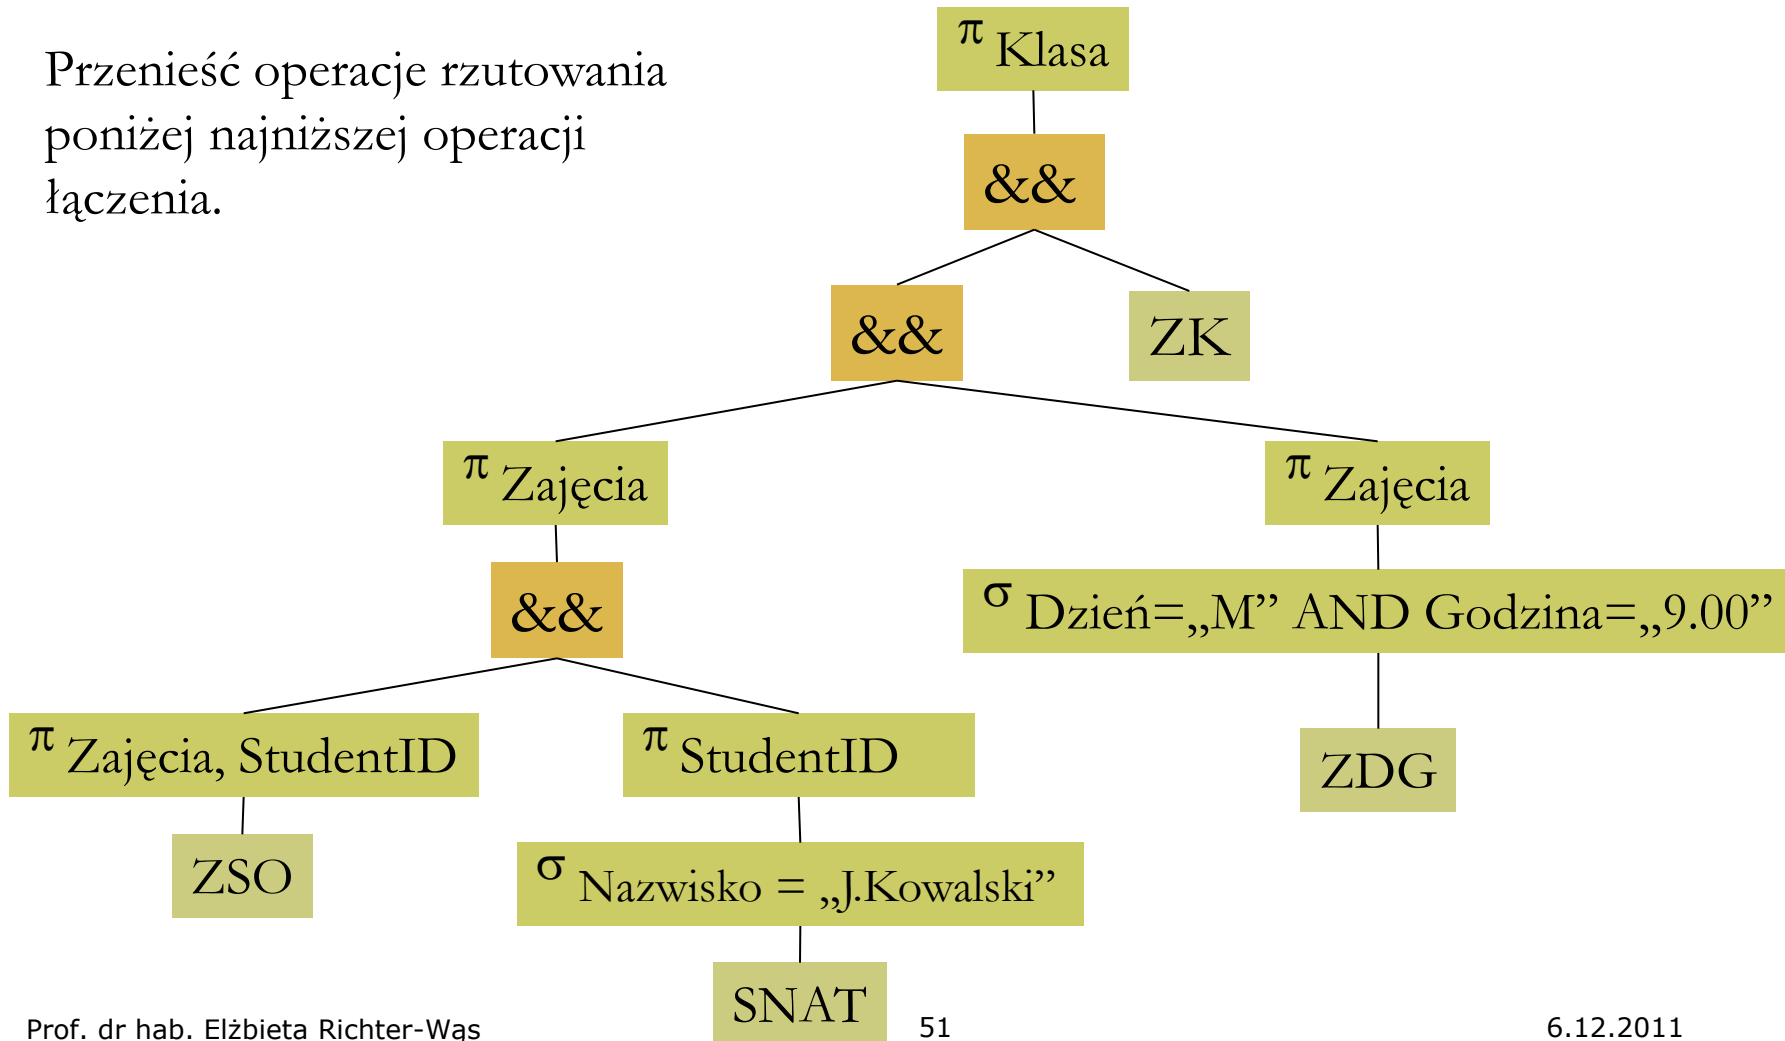
„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

Przenieść operacje rzutowania
poniżej środkowej operacji
łączenia



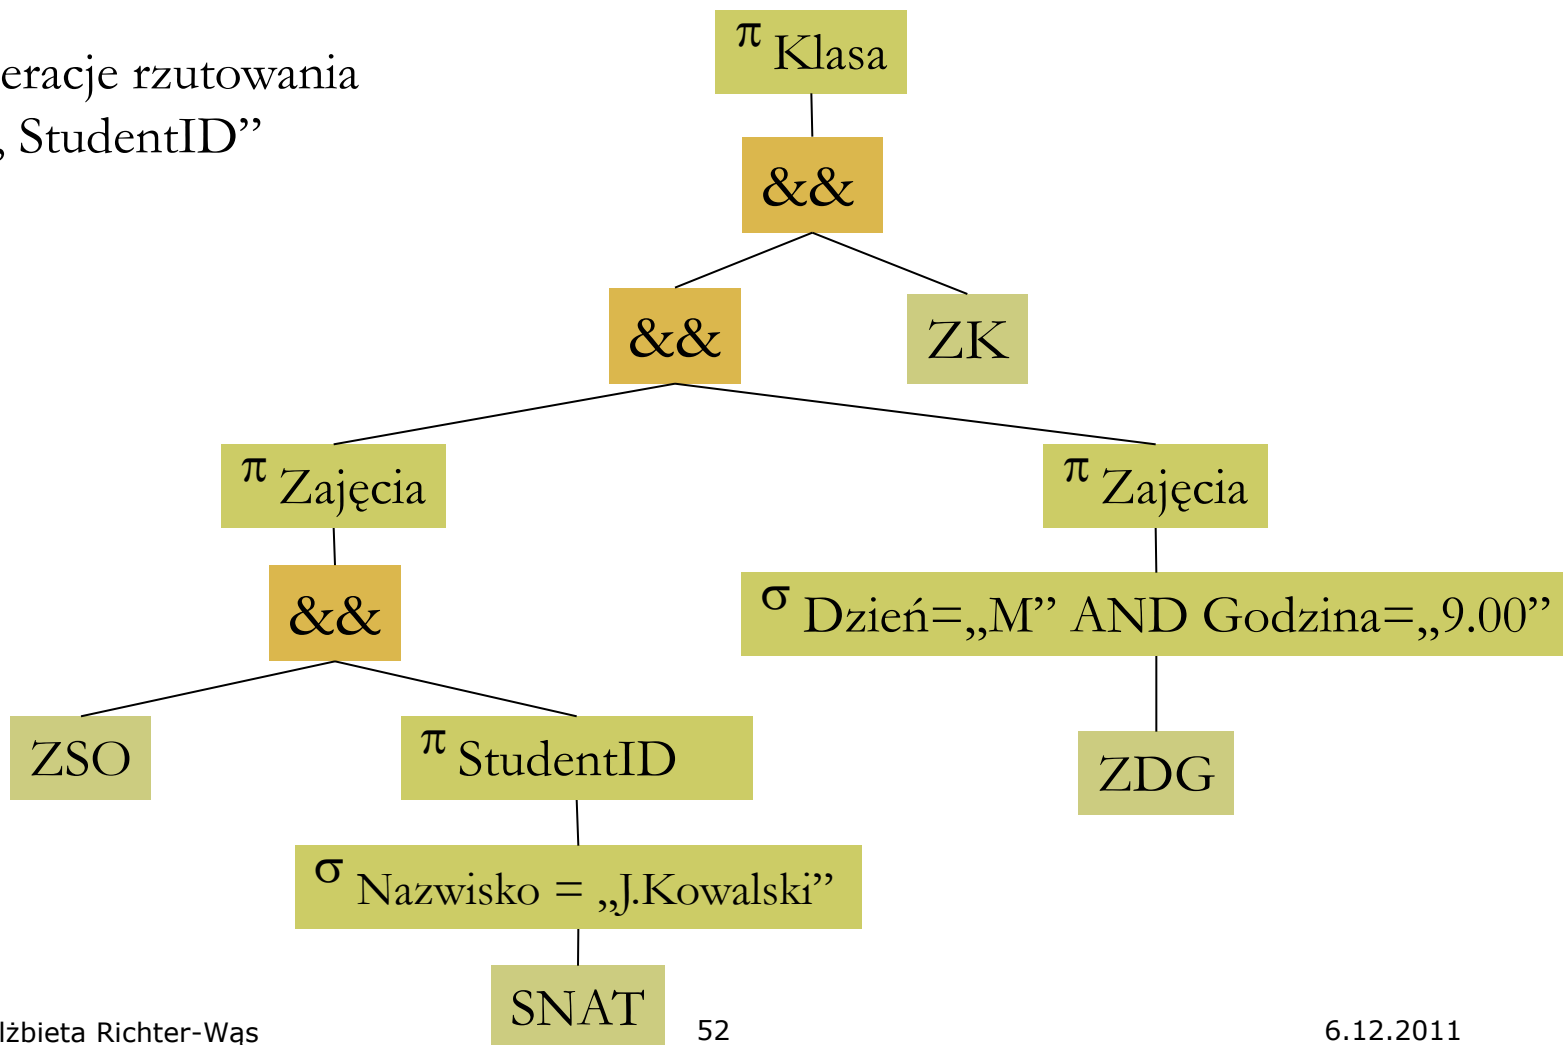
„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

Przenieść operacje rzutowania
poniżej najniższej operacji
łączenia.



„Gdzie przebywa J. Kowalski w poniedziałek o 9-tej rano?”

Usuń operacje rzutowania
„Zajęcia, StudentID”



Podsumowanie

- ❑ Algebra relacyjna jest wysoko poziomową notacją definiowania operacji zapytań dotyczących jednej lub wielu relacji.
Głównymi operacjami tej algebry są: **suma, przecięcie, różnica, selekcja, rzutowanie i złączenie**.
Jest silną notacją wyrażania zapytań bez podawania szczegółów dotyczących planowanych operacji na otrzymanych danych.
- ❑ Istnieje wiele sposobów efektywnego implementowania operacji złączenia.
- ❑ Optymalizacja wyrażeń algebry relacyjnej może w znaczący sposób skrócić czas wyznaczania ich wartości, jest więc istotnym elementem wszystkich języków opartych na algebrze relacyjnej wykorzystywanych w praktyce do wyrażania zapytań.
- ❑ Istnieje wiele sposobów skracania czasu obliczania danego wyrażenia.
Najlepsze efekty przynosi przenoszenie operacji selekcji w dół drzewa wyrażenia.