

Języki i środowiska przetwarzania danych rozproszonych

Optymalizacja poprzez
modyfikację zapytań

Wykładowca: **Tomasz Kowalski**

Wstęp - Jak bardzo LINQ jest deklaratywne?

❄ Przykład *maxQuery*, zapytanie złożone:

```
from Product p in products where  
    (from Product p2 in products select p2.unitPrice).Max()  
    == p.unitPrice  
select p.productName
```

❄ Przy założeniu ewaluacji LINQ to Objects:

- Dwie zagnieżdżone pętle iterujące:
 - zewnętrzna po *p*,
 - wewnętrzna po *p2*.
- Zapytanie zagnieżdżone będzie ewaluowane dla każdego produktu *p*.
- Złożoność obliczeniowa kwadratowa (zamiast oczekiwanej liniowej).

❄ Czy **optymalizacja** działania takiej konstrukcji jest prostym zadaniem?

Tuning zapytania – trudności/wyzwania

- ❄ Podstawowe założenia optymalizacji:
 - poprawna dla możliwych danych wejściowych,
 - dla tego samego stanu źródła danych ten sam rezultat zapytania,
 - nie gorszy czas działania w kluczowych miejscach.
- ❄ Potencjalne wyzwania optymalizacji laziness-seeking constructs:
 - zmiana stanu źródła danych w czasie wykonania,
 - zachowanie miejsca wykonania zapytania (nie w miejscu definicji),
 - nieskończone źródła danych (np. unikanie materializacji),
 - itd..
- ❄ Czy tuning ma brać uwagę efekty uboczne?
- ❄ Zachowanie innych właściwości konstrukcji właściwych dla języka.

Cechy funkcyjnych Collection Pipeline

☸ Zestaw cech zależy od konkretnego języka

☸ Java 8 Streams API:

- **No storage**
- **Functional in nature**
- **Laziness-seeking**
- **Possibly unbounded**
- **Consumable**



No storage & Possibly Unbounded



❄ to dane **iterowalne** (no storage) reprezentujące różne typy danych:

- dane skończone
 - kolekcje utrwalone
 - bazy danych (sql, nosql)
 - pliki XML
 - kolekcje ulotne
 - tablice/kolekcje obiektów w pamięci
- dane nieskończone (**possibly unbounded**)
 - dane generowane
 - liczby losowe
 - liczby pierwsze
 - strumień I/O
 - zdarzenia (akcje GUI)
 - pisanie na klawiaturze
 - ruchy i akcje mysz
 - big-data (np. transakcje, komentarze, tweety)



Functional in nature & Laziness-seeking

- ❄ operacje na kolekcjach nie modyfikują danych:
 - np. filtracja nie usuwa elementów ze źródła danych
 - minimalizacja efektów ubocznych
 - ułatwia optymalizację zapytań



- ❄ dwa typy „laziness-seeking” operatorów :
 - pełne **lazy evaluation** – np. *filter* i *map*
 - tylko **deferred execution** (pełna materializacja na żądanie) – np. w LINQ *GroupBy* oraz *OrderBy*

Consumable

- ❌ zapytania collection pipeline mogą być **jednorazowe** np.
 - ewaluacja natychmiastowa (**eager evaluation**) – np. operatory *map* i *filter* w python.
- ❌ Czy zapytania LINQ są **consumable**?
 - NIE
- ❌ Czy leniwa ewaluacja może być **consumable**?
 - OCZYWIŚCIE (np. Java 8 Streams)
 - jedna instancja iteratora na strumień

Tuning niezależnego pod-zapytania (1)

❄ Przykład ze wstępu bez syntax-sugar:

```
var maxQuery = products.Where(p =>
    products.Max(p2 => p2.unitPrice) == p.unitPrice).
    Select(p => p.productName);
```

❄ Naiwna optymalizacja (rozbicie na dwie instrukcje)

```
var nestedMaxPrice = products.Max(p2 => p2.unitPrice);
var maxQuery = products.
    Where(p => nestedMaxPrice == p.unitPrice).
    Select(p => p.productName);
```

❄ Wady rozwiązania:

- ***nestedMaxPrice*** materializowane nie obok miejsca wykonania ***maxQuery***, więc rezultat ***maxQuery*** polega na potencjalnie nieaktualnej wartości ***nestedMaxPrice***,
- ...?

Tuning niezależnego pod-zapytania (2)

❄ Przykład ze wstępu bez syntax-sugar:

```
var maxQuery = products.Where(p =>
    products.Max(p2 => p2.unitPrice) == p.unitPrice).
    Select(p => p.productName);
```

❄ Natychmiastowa materializacja w ramach funkcji:

```
var nestedMaxPrice = products.Max(p2 => p2.unitPrice);
return products.
    Where(p => nestedMaxPrice == p.unitPrice).
    Select(p => p.productName).ToList();
```

❄ Wady rozwiązania:

- każde wykonanie zapytania tworzy nowe iteratory (drobiazg),
- mniejsza deklaratywność (kwestia względna),
- **dla pustej kolekcji products zapytanie zmodyfikowane rzuci wyjątkiem!**

Tuning niezależnego pod-zapytania (3)

❄ Odroczenie wykonania pod-zapytania:

```
var maxPriceThunk =  
    new Lazy<Double>(() => products.Max(p2 => p2.unitPrice));  
return products.  
    Where(p => maxPriceThunk.Value == p.unitPrice).  
    Select(p => p.productName).ToList();
```

❄ **Thunk** – obiekt w pamięci reprezentujący niewykonane (zawieszone w czasie) obliczenie (wykorzystywane w strategii call-by-need).

❄ Wady rozwiązania (w przypadku ogólnym):

- klienta zapytania może interesować nie cały rezultat ale np. kilka pierwszych elementów (spowolnienie działania programu),
- nie jest to tuning zawsze bezpieczny, bo materializuje wynik zapytania a potencjalnie źródło danych może być nieskończone,
- zmiana algorytmu (wpływ na występujące efekty uboczne).

Pod-zapytanie skorelowane.

❄ Przykład *uniqueQuery*, zapytanie złożone:

```
var uniqueQuery = products.Where(p =>  
    products.Where(p2 =>  
        p.category.Equals(p2.category)).Count() == 1).  
Select(p => p.productName);
```

❄ Przy założeniu ewaluacji LINQ to Objects:

- Dwie zagnieżdżone pętle iterujące:
 - zewnętrzna po *p*,
 - wewnętrzna po *p2*.
- Zapytanie zagnieżdżone będzie ewaluowane dla każdego produktu *p*.
- Złożoność obliczeniowa kwadratowa.
- Możliwa implementacja quasi-liniowego rozwiązania.

❄ Jak zoptymalizować przy użyciu LINQ?

Tuning skorelowanego pod-zapytania (1)

❄ Przykład *uniqueQuery*, zapytanie złożone:

```
var uniqueQuery = products.Where(p =>
    products.Where(p2 =>
        p.category.Equals(p2.category)).Count() == 1).
    Select(p => p.productName);
```

❄ Alternatywne zapytanie przy użyciu **GroupBy**:

```
var uniqueQueryAlt = products.GroupBy(p => p.category).
    Where(prodGroup => prodGroup.Count() == 1).
    SelectMany(prodGroup =>
        prodGroup.Select(p => p.productName))
```

❄ Wady rozwiązania:

- grupowanie wymaga materializacji (dodatkowa pamięć),
- kolejność rezultatów może być inna niż w oryginale,
- dla kategorii **null** oryginalne zapytanie rzuca wyjątkiem (inna semantyka).

Tuning skorelowanego pod-zapytania (2)

- ❄ Zastosowanie indeksu (**Lookup** w C#) + podział na dwie instrukcje + odroczenie + ToList + funkcja:

```
var productsLookupThunk = new Lazy<Double>(  
    () => products.ToLookup(p2 => p2.category));  
return products.Where(p =>  
    productsLookupThunk.Value[p.category].Count() == 1).  
    Select(p => p.productName).ToList();
```

- ❄ Wady rozwiązania:

- indeks wymaga materializacji (dodatkowa pamięć),
- dla kategorii **null** oryginalne zapytanie rzuca wyjątkiem (inna semantyka).

- ❄ Zachowuje kolejność oryginalnego rezultatu.

- ❄ Prostsza reguła transformacji (**Lookup** zastępuje **Where**)!

Podsumowanie

- ❌ Ograniczona deklaratywność z uwagi na wydajność zapytań.
- ❌ Niemożliwa w pełni przezroczysta optymalizacja:
 - zamierzone i niezamierzone (przez dewelopera) efekty uboczne,
 - zbyt małe możliwości wyrazu LINQ.
- ❌ Rafy semantyczne optymalizacji:
 - leniwa, odroczone lub natychmiastowa ewaluacja,
 - wyjątki,
 - materializacja a nieskończone źródła danych.