

TEORETYCZNE PODSTAWY INFORMATYKI

10/10/2016

WFAiS UJ, Informatyka Stosowana
I rok studiów, I stopień

Wykład 3

2

Złożoność obliczeniowa algorytmów

- **Notacja „wielkie 0”**
- **Notacja Ω i Θ**
- **Algorytm Hornera**
- **Przykłady rzędów złożoności**
- **Klasy złożoności algorytmów**
- **Funkcje niewspółmierne**
- **Analiza czasu działania algorytmu**
 - ▣ **Instrukcje proste; instrukcje warunkowe; bloki instrukcji**
- **Efektywność algorytmu**

Złożoność obliczeniowa

3

- **Złożoność obliczeniowa:**
 - **Jest to miara służąca do porównywania efektywności algorytmów.**
 - **Mamy dwa kryteria efektywności:**
 - **Czas,**
 - **Pamięć**
- **Do oceny efektywności stosujemy jednostki logiczne wyrażające związek między rozmiarem danych N (wielkość pliku lub tablicy) a ilością czasu T potrzebną na ich przetworzenie.**

Złożoność asymptotyczna

4

- Funkcja wyrażająca zależność między N a T jest zwykle bardzo skomplikowana, a jej obliczenie ma znaczenie jedynie w odniesieniu do dużych rozmiarów danych
- Przybliżona miara efektywności to tzw. **złożoność asymptotyczna**.

Które człony są ważne?

5

$$\text{Funkcja: } f(n) = n^2 + 100n + \log_{10} n + 1000$$

n	f(n)	n^2	$100 \cdot n$	$\log_{10} n$	1000
1	1 101	0.1%	9%	0.0%	91%
10	2 101	4.8%	48%	0.05%	48%
100	21 002	48%	48%	0.001%	4.8%
10^3	1 101 003	91%	9%	0.0003%	0.09%
10^4		99%	1%	0.0%	0.001%
10^5		99.9%	0.1%	0.0%	0.0000%

- **n** – rozmiar danych,
- **f(n)** – ilość wykonywanych operacji

Dla dużych wartości n funkcja rośnie jak n^2 , pozostałe składniki mogą być zaniedbane.

Notacja „wielkie O”

6

Definicja:

$f(n)$ jest $O(g(n))$, jeśli istnieją liczby dodatnie c i n_0 takie że:
 $f(n) < c \cdot g(n)$ dla wszystkich $n \geq n_0$.

Przykład:

□ $f(n) = n^2 + 100n + \log_{10} n + 1000$

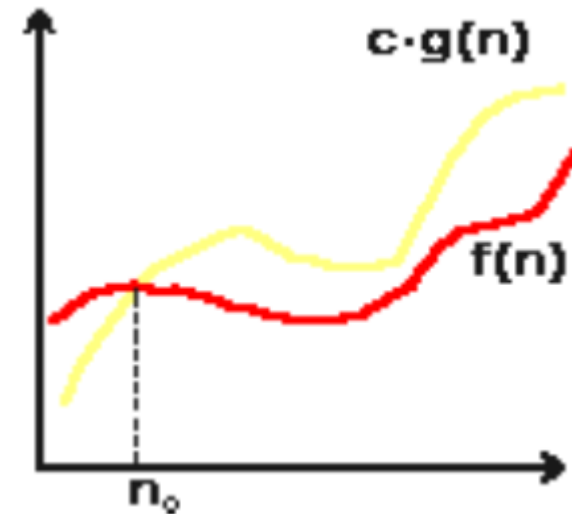
możemy przybliżyć jako:

$$f(n) \approx n^2 + 100n + O(\log_{10} n)$$

albo jako:

$$f(n) \approx O(n^2)$$

- Notacja „wielkie O” ma kilka pozytywnych własności które możemy wykorzystać przy szacowaniu efektywności algorytmów.



Własności notacji „wielkie O”

7

- **Własność 1 (przechodność):**
 - Jeśli $f(n)$ jest $O(g(n))$ i $g(n)$ jest $O(h(n))$, to $f(n)$ jest $O(h(n))$
- **Własność 2:**
 - Jeśli $f(n)$ jest $O(h(n))$ i $g(n)$ jest $O(h(n))$, to $f(n)+g(n)$ jest $O(h(n))$
- **Własność 3:**
 - Funkcja an^k jest $O(n^k)$
- **Własność 4:**
 - Funkcja n^k jest $O(n^{k+i})$ dla dowolnego dodatniego i

Własności notacji „wielkie O”

8

- Z tych wszystkich własności wynika, że dowolny wielomian jest „wielkie O” dla n podniesionego do najwyższej w nim potęgi, czyli :

$$f(n) = a_k n^k + a_{k-1} n^{k-1} + \dots + a_1 n + a_0 \text{ jest } O(n^k)$$

(jest też oczywiście $O(n^{k+i})$ dla dowolnego dodatniego i)

Własności notacji „wielkie O”

9

□ Własność 5:

□ Jeśli $f(n) = c g(n)$, to $f(n)$ jest $O(g(n))$

□ Własność 6:

□ Funkcja $\log_a n$ jest $O(\log_b n)$ dla dowolnych a i b większych niż 1

□ Własność 7:

□ $\log_a n$ jest $O(\log_2 n)$ dla dowolnego dodatniego a

Własności notacji „wielkie O”

10

- Jedną z najważniejszych funkcji przy ocenianiu efektywności algorytmów jest **funkcja logarytmiczna**.
- Jeżeli można wykazać że złożoność algorytmu jest rzędu logarytmicznego, algorytm można traktować jako bardzo dobry.
- Istnieje wiele funkcji lepszych w tym sensie niż logarytmiczna, jednak zaledwie kilka spośród nich, jak $O(\log_2 \log_2 n)$ czy $O(1)$ ma praktyczne znaczenie.

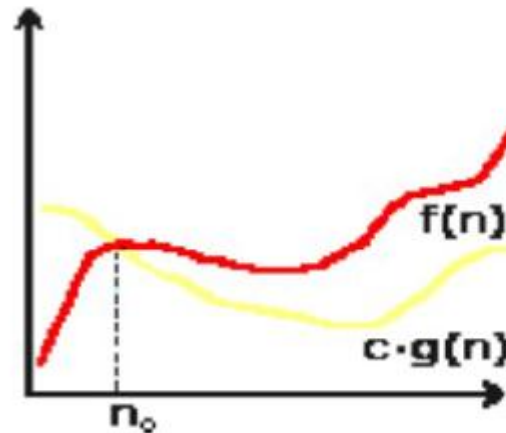
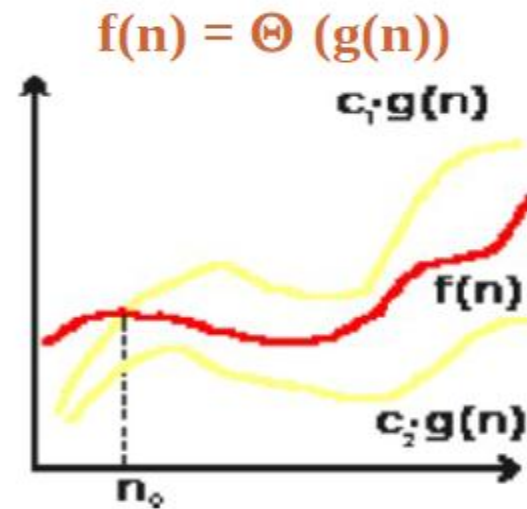
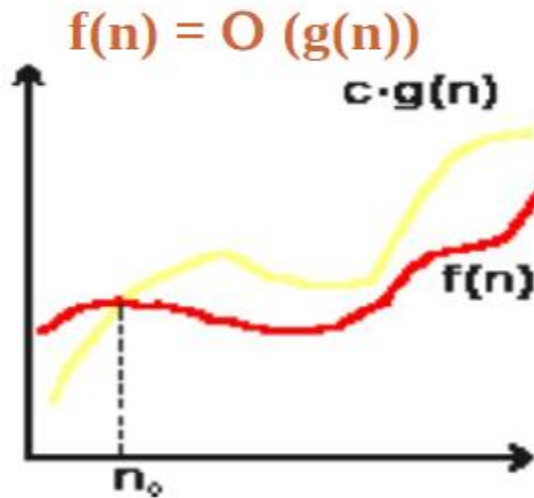
Notacja Ω i Θ

11

- Notacja „**wielkie O** ” odnosi się do górnych ograniczeń funkcji. Istnieje symetryczna definicja dotycząca dolnych ograniczeń
- **Definicja**
 - $f(n)$ jest $\Omega(g(n))$, jeśli istnieją liczby dodatnie c i n_0 takie że, $f(n) \geq c g(n)$ dla wszystkich $n \geq n_0$.
- **Równoważność**
 - $f(n)$ jest $\Omega(g(n))$ wtedy i tylko wtedy, gdy $g(n)$ jest $O(f(n))$
- **Definicja**
 - $f(n)$ jest $\Theta(g(n))$, jeśli istnieją takie liczby dodatnie c_1 , c_2 i n_0 takie że, $c_1 g(n) \leq f(n) \leq c_2 g(n)$ dla wszystkich $n \geq n_0$.

Notacja O , Ω i Θ

12



$f(n) = \Omega(g(n))$

Algorytm Hornera

13

- Załóżmy, że mamy policzyć wartość wielomianu postaci:

$$f(x) = a_0x^n + a_1x^{n-1} + \dots + a_{n-1}x + a_n$$

dla danych liczb a_0, a_1, \dots, a_n , w danym punkcie x_0 .

- Algorytm polegający na **bezpośrednim liczeniu** ze wzoru wymaga **n dodawań** i **$(n-2)$ potęgowań** lub **$(2n-1)$ mnożeń** co prowadzi do niedokładności obliczeń (błąd względny i bezwzględny).
 - ▣ Warto poszukać innego rozwiązania.

Algorytm Hornera

14

Przedstawiamy wielomian w postaci:

$$f(x) = (\dots((a_0x + a_1)x + a_2)x + \dots + a_{n-1})x + a_n$$

to otrzymujemy następującą metodę na obliczanie wielomianu:

$$b_0 = a_0$$

$$b_1 = b_0x_0 + a_1$$

$$b_2 = b_1x_0 + a_2$$

$$b_n = b_{n-1}x_0 + a_n$$

gdzie b_i oznacza wartość i -tego nawiasu dla x równego x_0 , a b_n szukaną wartość wielomianu

Algorytm Hornera

15

- **Otrzymana metoda to tzw. Algorytm Hornera obliczania wartości wielomianu.**
- **Algorytm ten jest numerycznie poprawny i jest jedynym algorytmem który minimalizuje liczbę dodawań i mnożeń przy obliczaniu wartości wielomianu wg. podanej postaci.**

O czym należy pamiętać

16

- **Celem wprowadzonych wcześniej notacji O , Θ , Ω zapisu (notacji) jest porównanie efektywności rozmaitych algorytmów zaprojektowanych do rozwiązania tego samego problemu.**
- **Ale jeżeli będziemy tylko rozważać notację „wielkie O ” do reprezentowania złożoności algorytmów, to niektóre z nich możemy zdyskwalifikować zbyt pochwopnie.**

Pamiętaj o dużych stałych

17

Przykład:

- ❑ Załóżmy, że mamy dwa algorytmy rozwiązujące pewien problem, wykonywana przez nie liczba operacji to odpowiednio $10^8 n$ i $10n^2$. Pierwsza funkcja jest $O(n)$, druga $O(n^2)$.
- ❑ Opierając się na informacji dostarczonej przez notację „**wielkie O**” odrzucilibyśmy drugi algorytm ponieważ funkcja kosztu rośnie zbyt szybko.
- ❑ To prawda ... ale dopiero dla odpowiednio dużych n , ponieważ dla $n < 10^7$ drugi algorytm wykonuje mniej operacji niż pierwszy.
- ❑ Istotna jest więc też stała (10^8), która w tym przypadku jest zbyt duża aby notacja była znacząca.

Przykłady rzędów złożoności

18

- **Algorytmy można klasyfikować ze względu na złożoność czasową lub pamięciową.**
- **W związku z tym wyróżniamy wiele klas algorytmów.**
 - ▣ **Algorytm stały:** czas wykonania pozostaje taki sam niezależnie od ilości przetwarzanych elementów.
 - ▣ **Algorytm kwadratowy:** czas wykonania wynosi $O(n^2)$.
 - ▣ **Algorytm logarytmiczny:** czas wykonania wynosi $O(\log n)$.
 - ▣ **itd ...**
- **Analiza złożoności algorytmów jest niezmiernie istotna i nie można jej lekceważyć argumentując potencjalną szybkością obliczeń komputera. Nie sposób jej przecenić szczególnie zastanawiając się nad doбором struktury danych.**

Najczęstsze złożoności

19

- $\log(n)$ – złożoność logarytmiczna
- n – złożoność liniowa
- $n \log(n)$ – złożoność liniowo-logarytmiczna
- n^k – złożoność wielomianowa
- 2^n – złożoność wykładnicza
- $n!$ – złożoność wykładnicza ponieważ $n! > 2^n$ już dla $n=4$.

Klasy złożoności algorytmów

20

- Czasy wykonania logarytmów na komputerze działającym z szybkością 1 instrukcja / μs .

klasa	złożoność	liczba operacji i czas wykonania			
		n	10	10 ³	
stały	$O(1)$	1	1 μs	1	1 μs
logarytmiczny	$O(\log n)$	3.32	3 μs	9.97	10 μs
liniowy	$O(n)$	10	10 μs	10 ³	1ms
kwadratowy	$O(n^2)$	10 ²	100 μs	10 ⁶	1s
wykładniczy	$O(2^n)$	1024	10ms	10 ³⁰¹	>> 10 ¹⁶ lat

Funkcje niewspółmierne

21

- **Bardzo wygodna jest możliwość porównywania dowolnych funkcji $f(n)$ i $g(n)$ za pomocą notacji „wielkie O”**

- albo $f(n) = O(g(n))$

- albo $g(n) = O(f(n))$

Albo jedno i drugie czyli $f(n) = \Theta(g(n))$.

- **Istnieją pary funkcji niewspółmiernych (ang. incommensurate), z których żadne nie jest „wielkim O” dla drugiej.**

Funkcje niewspółmierne

22

□ Przykład:

Rozważmy funkcję $f(n)=n$ dla nieparzystych n oraz $f(n)=n^2$ dla parzystych n .

- Oznacza to, że $f(1)=1$, $f(2)=4$, $f(3)=3$, $f(4)=16$, $f(5)=5$ itd...
 - Podobnie, niech $g(n)=n^2$ dla nieparzystych n oraz $g(n)=n$ dla parzystych n .
 - W takim przypadku, funkcja $f(n)$ nie może być $O(g(n))$ ze względu na parzyste argumenty n , analogicznie $g(n)$ nie może być $O(f(n))$ ze względu na nieparzyste elementy n .
- Obie funkcje mogą być ograniczone jako $O(n^2)$.

Analiza czasu działania programu

23

- Mając do dyspozycji definicję „**wielkie O**” oraz własności (1)-(7) będziemy mogli, wg. kilku prostych zasad, skutecznie analizować czasy działania większości programów spotykanych w praktyce.
- Efektywność algorytmów ocenia się przez szacowanie ilości czasu i pamięci potrzebnych do wykonania zadania, dla którego algorytm został zaprojektowany.
- Najczęściej jesteśmy zainteresowani **złożonością czasową**, mierzoną zazwyczaj liczbą przypisań i porównań realizowanych podczas wykonywania programu.
- Bardzo często interesuje nas tylko **złożoność asymptotyczna**, czyli czas działania dla dużej ilości analizowanych zmiennych.

Czas działania instrukcji prostych

24

- Przyjmujemy zasadę że czas działania pewnych prosty operacji na danych wynosi $O(1)$, czyli jest niezależny od rozmiaru danych wejściowych.
 - ▣ Operacje arytmetyczne, np. (+), (-)
 - ▣ Operacje logiczne (&&)
 - ▣ Operacje porównania (<=)
 - ▣ Operacje dostępu do struktur danych, np. indeksowanie tablic (A[i])
 - ▣ Proste przypisania, np. kopiowanie wartości do zmiennej.
 - ▣ Wywołania funkcji bibliotecznych, np. `scanf` lub `printf`
- Każdą z tych operacji można wykonać za pomocą pewnej (niewielkiej) liczby rozkazów maszynowych.

Czas działania pętli „for”

25

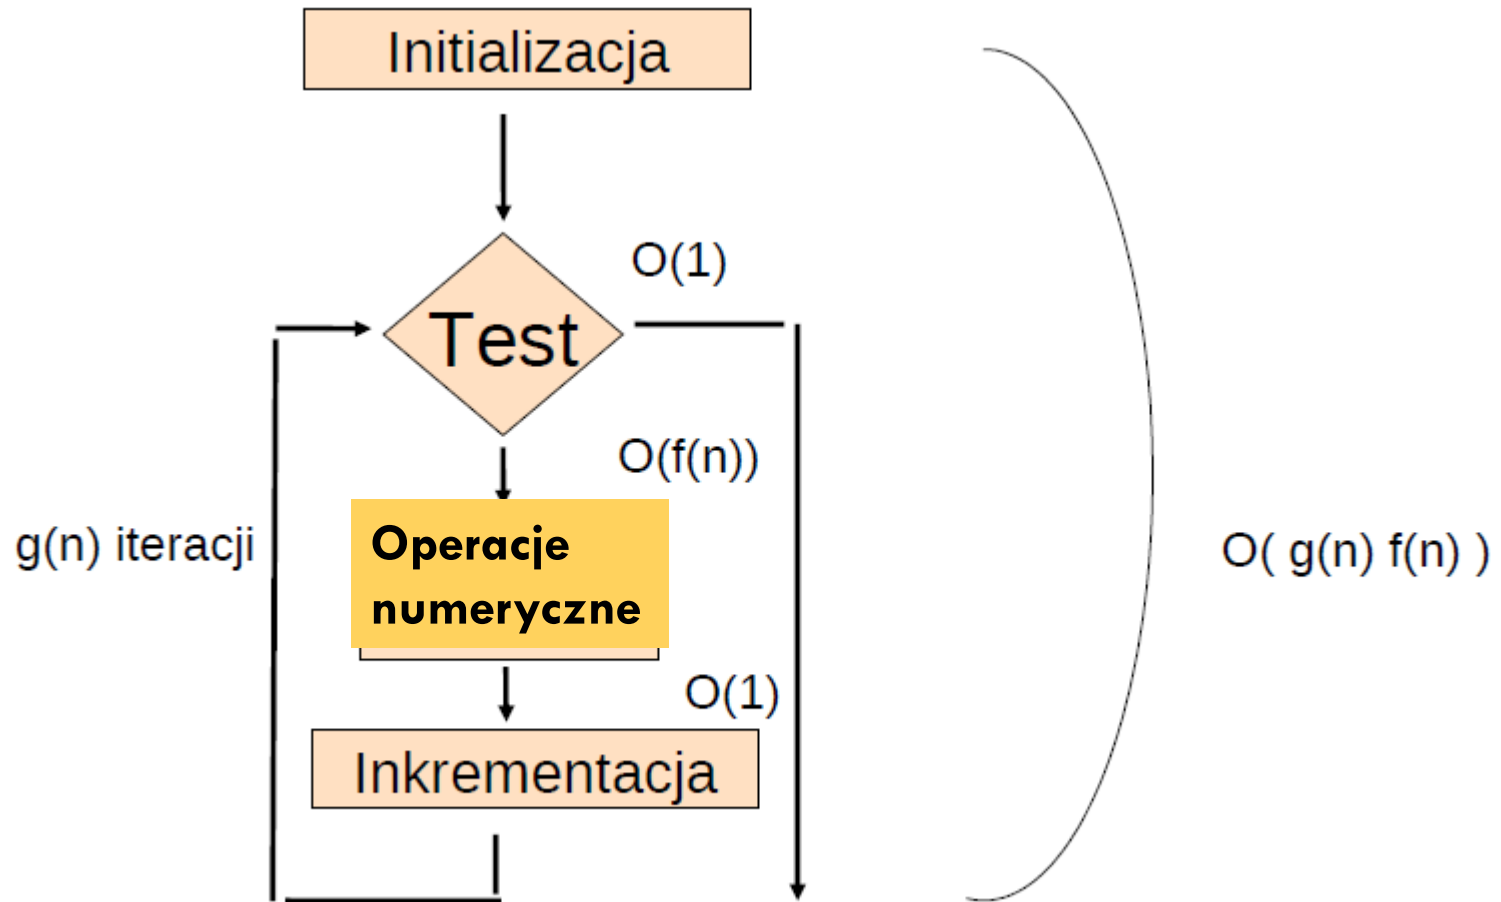
□ Przykład 1: Prosta pętla

```
for (i=sum=0; i<n; i++) sum += a[i];
```

- Powyższa pętla powtarza się n razy, podczas każdego jej przebiegu realizuje dwa przypisania:
 - aktualizujące zmienną „sum”
 - zmianę wartości zmiennej „i”
- Mamy zatem $2n$ przypisań podczas całego wykonania pętli.
- Złożoność asymptotyczna algorytmu jest $O(n)$.

Czas działania pętli „for”

26



Czas działania pętli „for”

27

□ Przykład 1: Dwie proste pętle

```
for (i=sum1=0; i<n; i++) sum1 += a[i];  
for (i=sum2=0; i<n; i++) sum2 += 2 * a[i];
```

- Każda pętla powtarza się n razy, podczas każdego jej przebiegu realizuje dwa przypisania:
 - aktualizujące zmienną „sum”
 - zmianę wartości zmiennej „i”
- Mamy zatem $2n$ przypisań podczas całego wykonania pętli pierwsze oraz $2n$ dla pętli drugiej. Razem $4n$.
- Złożoność asymptotyczna algorytmu jest $O(n)$.

Czas działania pętli „for”

28

□ Przykład 2: Pętla zagnieżdżona

```
for (i=0; i<n; i++) {  
    for (j=1, sum=a[0]; j<=i; j++)  
        sum+=a[j]; }
```

- **Pętla zewnętrzna powtarza się n razy**, a w każdej jej iteracji wykonuje się wewnętrzna pętla oraz instrukcja przypisania wartości zmiennym „ i ”, „ j ”, „ sum ”.
- **Pętla wewnętrzna wykonuje się „ i ” razy** dla każdego $i \in \{1, \dots, n-1\}$, a na każdą iterację przypadają dwa przypisania: jedno dla „ sum ”, jedno dla „ j ”.
- **Mamy zatem: $1+3n+2(1+2+\dots+n-1) = 1+3n+n(n-1) = O(n)+O(n^2) = O(n^2)$** przypisań wykonywanych w całym programie.
- **Złożoność asymptotyczna algorytmu jest $O(n^2)$** . Pętle zagnieżdżone mają zwykle większą złożoność niż pojedyncze, jednak nie musi tak być zawsze.

Czas działania pętli „for”

29

- **Przykład 3:** Znajdź najdłuższą podtablicę zawierającą liczby uporządkowane rosnąco.

```
for (i=0; len=1; i<n-1; i++) {  
    for (i1=i2=k=i; k<n-1 && a[k]<a[k+1]; k++,i2++);  
    if(len < i2-i1+1) len=i2-i1+1; }
```

- Jeśli liczby w tablicy są uporządkowane malejąco, to pętla zewnętrzna wykonuje się **$n-1$ razy**, a w każdym jej przebiegu pętla wewnętrzna wykona się tylko **1-raz**.
Złożoność asymptotyczna algorytmu jest więc **$O(n)$** .
- Jeśli liczby w tablicy są uporządkowane rosnąco, to pętla zewnętrzna wykonuje się **$n-1$ razy**, a w każdym jej przebiegu pętla wewnętrzna wykona się **i -razy** dla $i \in \{1, \dots, n-1\}$.
Złożoność asymptotyczna algorytmu jest więc **$O(n^2)$** .

Czas działania pętli „for”

30

- Z reguły dane nie są uporządkowane i ocena złożoności algorytmu jest rzeczą niełatwą ale bardzo istotną.
- Staramy się wyznaczyć złożoność
 - w „przypadku optymistycznym”,
 - w „przypadku pesymistycznym”
 - oraz w „przypadku średnim”
- Często posługujemy się przybliżeniami opartymi o notacje „*wielkie O , Ω i Θ* ”.

Czas działania instrukcji warunkowych

31

Instrukcje warunkową **if-else** zapisuje się w postaci:

```
if (<warunek>
    <blok-if>
else
    <blok-else>
```

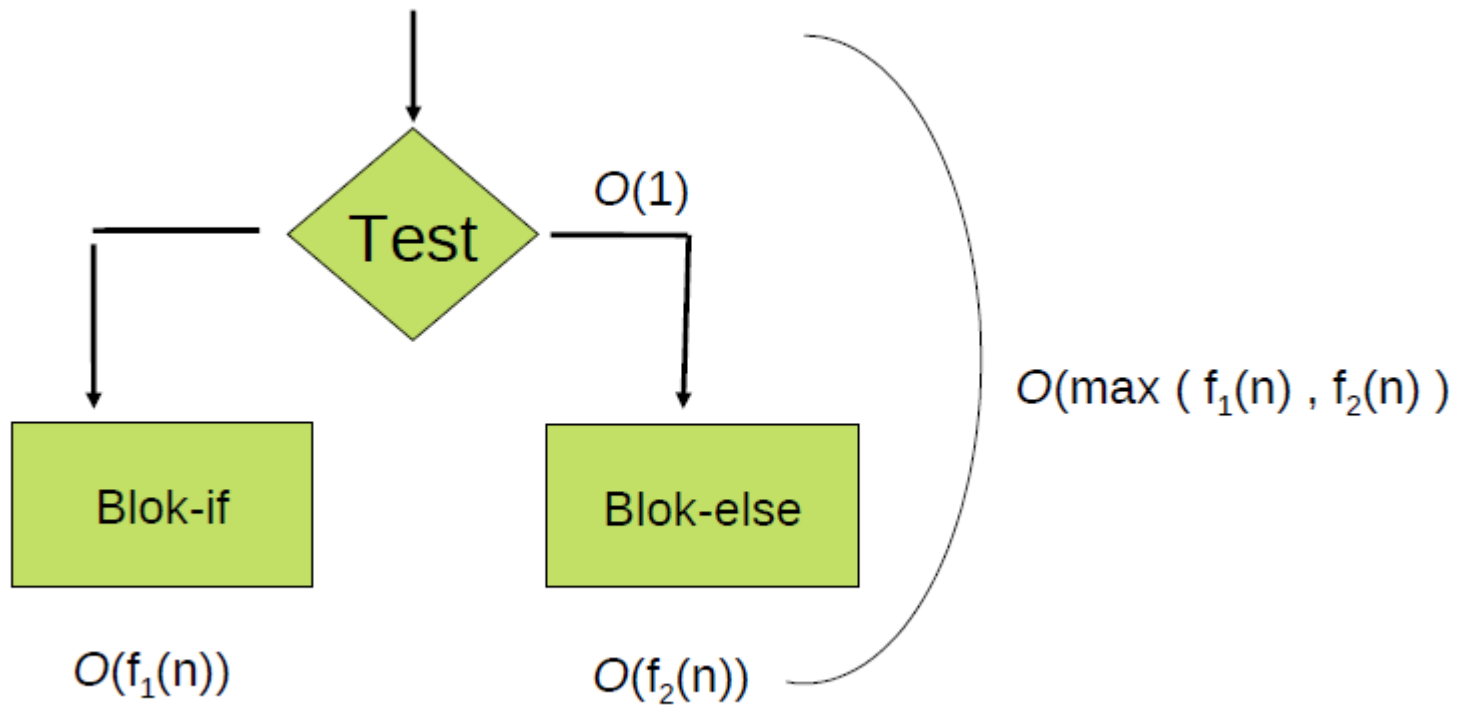
Gdzie

- **<warunek>** jest wyrażeniem które trzeba obliczyć. Warunek niezależnie od tego jak skomplikowany wymaga wykonania stałej liczby operacji (więc czasu $O(1)$) chyba że zawiera wywołanie funkcji, .
- **<blok-if>** zawiera instrukcje wykonywane tylko w przypadku gdy warunek jest prawdziwy, czas działania $f(n)$.
- **<blok-else>** wykonywany jest tylko w przypadku gdy warunek jest fałszywy, czas działania $g(n)$.

Czas działania instrukcji warunkowej należy zapisać jako $O(\max(f(n), g(n)))$

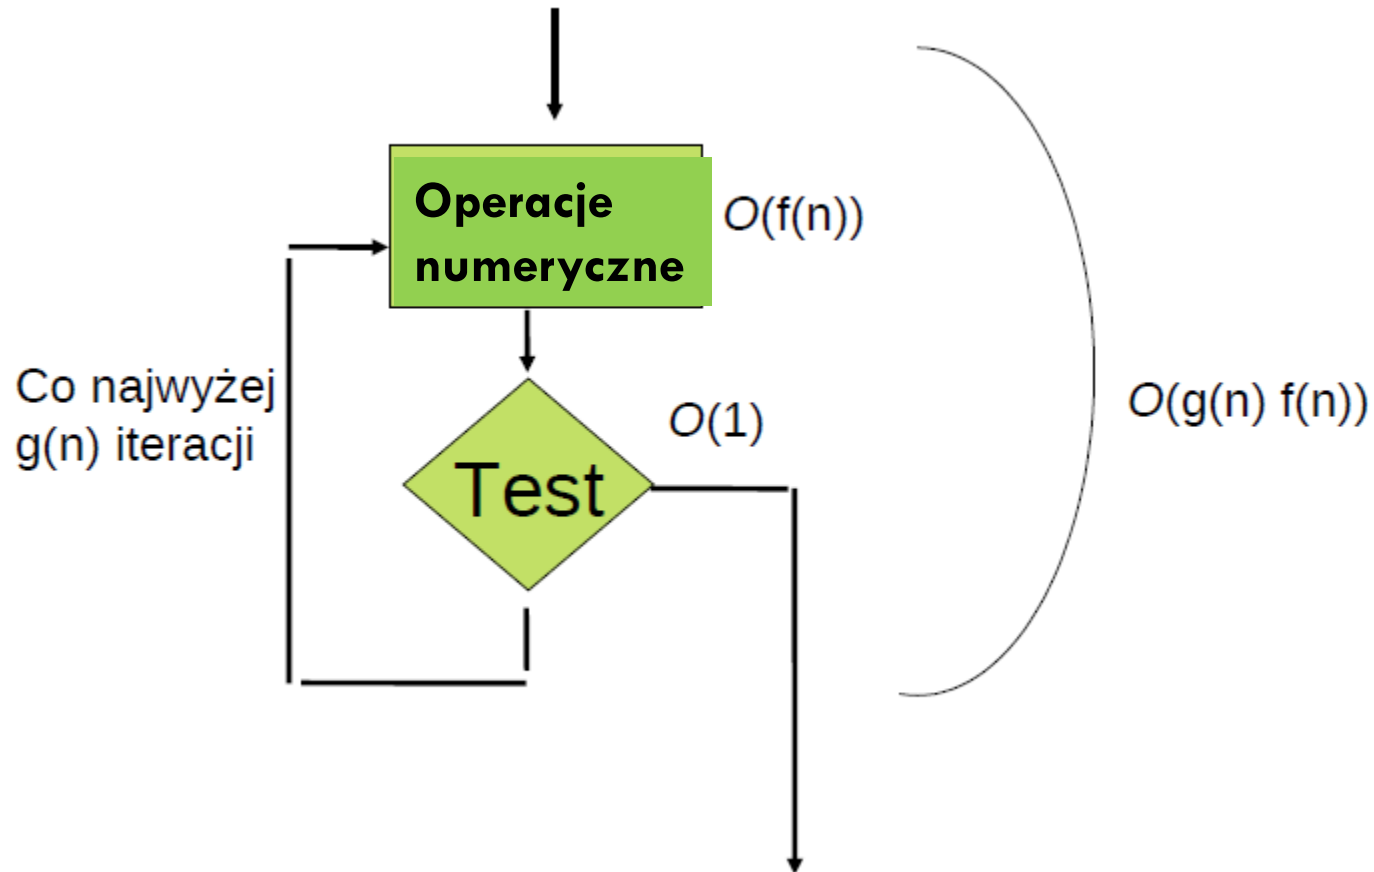
Czas działania instrukcji „if”

32



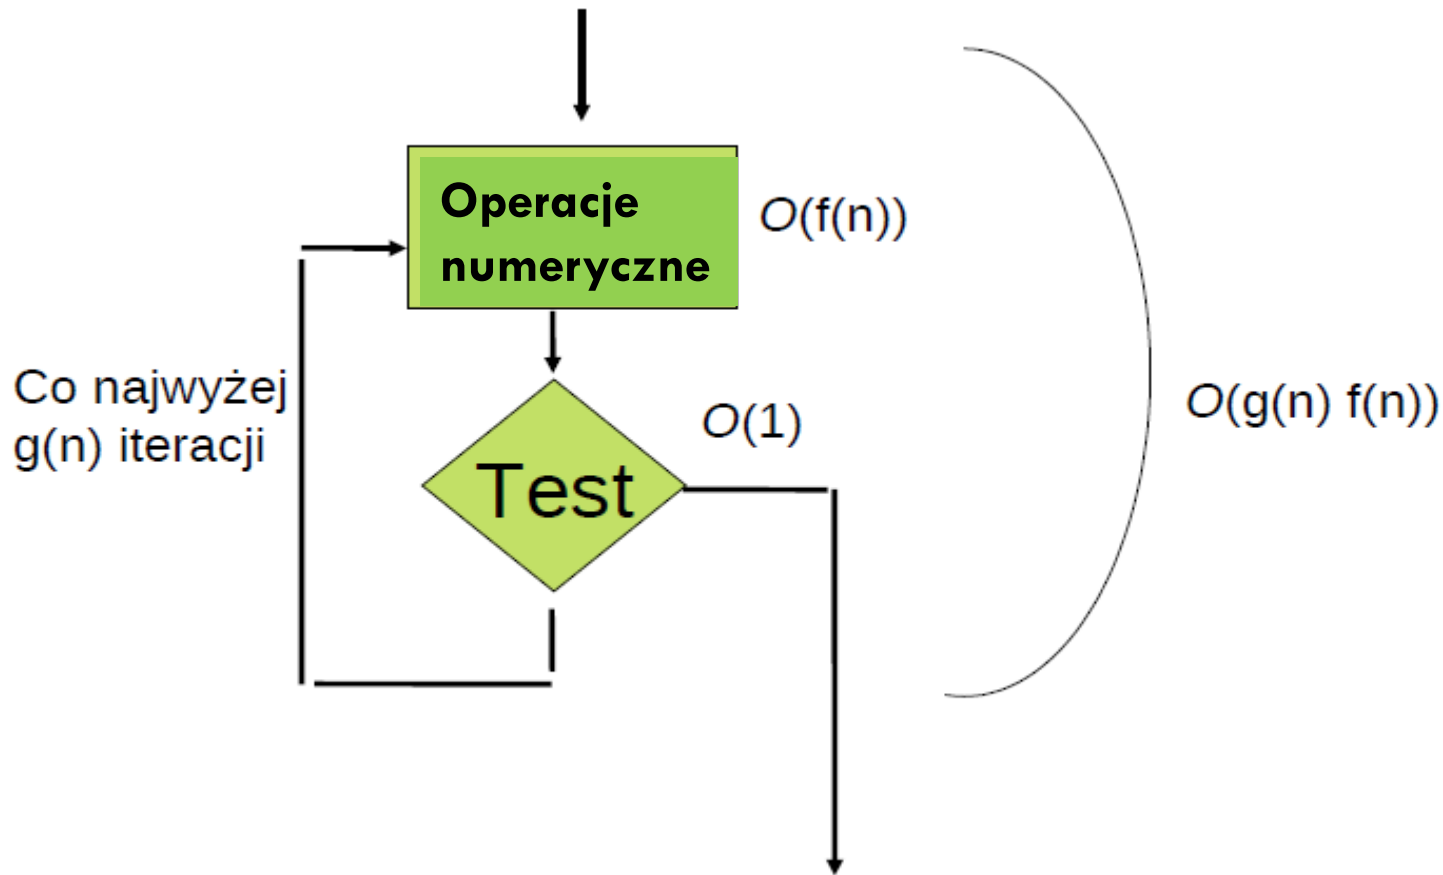
Czas działania instrukcji „while”

33



Czas działania instrukcji „do while”

34



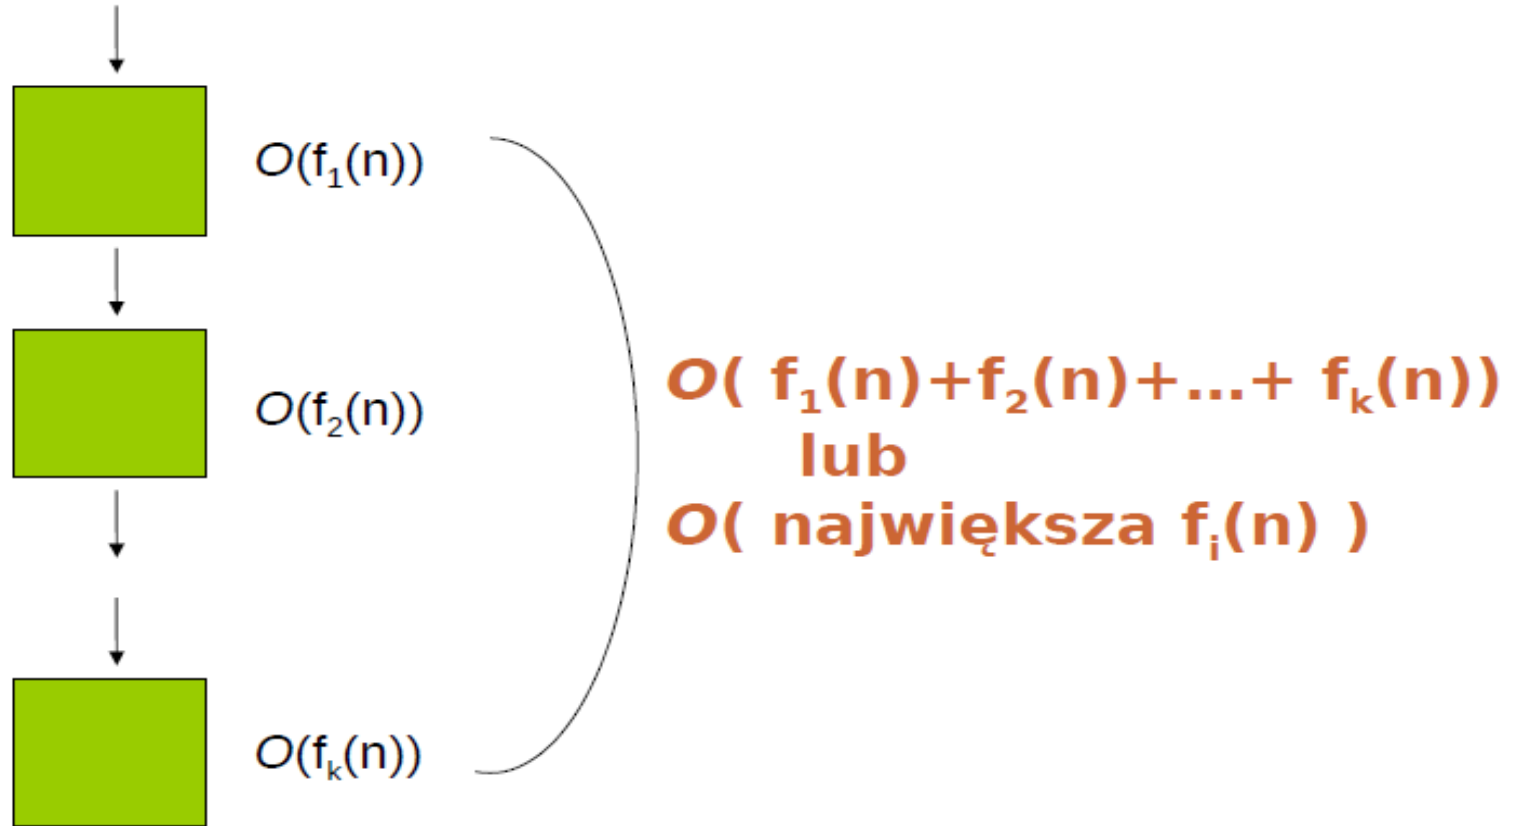
Czas działania bloków

35

- **Sekwencja instrukcji przypisań, odczytów i zapisów, z których każda wymaga czasu $O(1)$, potrzebuje do swojego wykonania łącznego czasu $O(1)$.**
- **Pojawiają się również instrukcje złożone, jak instrukcje warunkowe i pętle.**
 - ▣ **Sekwencję prostych i złożonych instrukcji nazywa się blokiem.**
- **Czas działania bloku obliczymy sumując górne ograniczenia czasów wykonania poszczególnych instrukcji, które należą do tego bloku.**

Czas działania bloku instrukcji

36

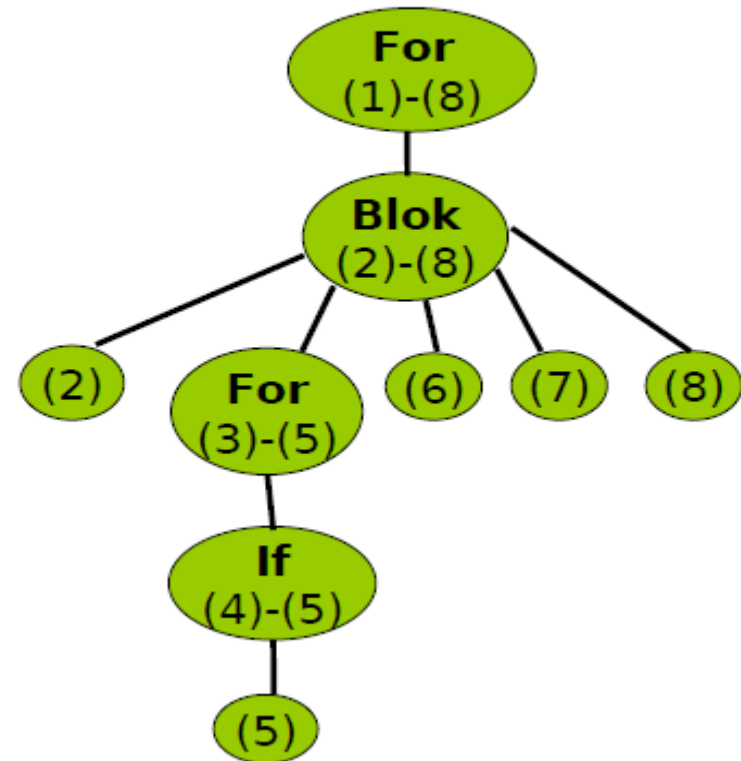


Przykład: „sortowanie przez wybieranie”

37

```
(1) for (i=0; i< n-1; i++ ) {  
(2)   small = i;  
(3)   for (j=i+1; j<n; j++ )  
(4)     if( A[j] < A[small] )  
(5)       small =j;  
(6)   temp = A[small];  
(7)   A[small] = A[i];  
(8)   A[i] = temp; }
```

Drzewo reprezentujące grupowanie instrukcji



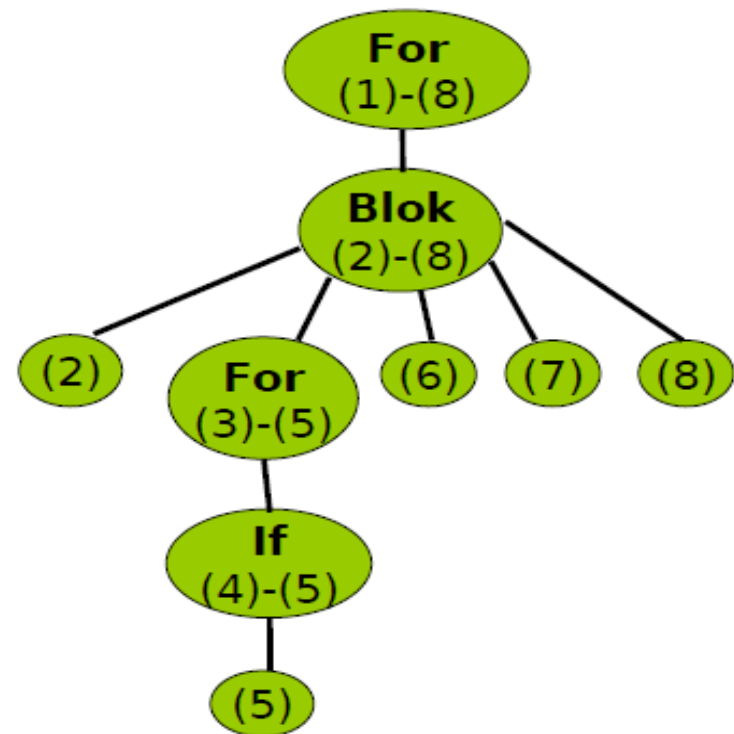
Przykład: „sortowanie przez wybieranie”

38

- Rozpoczynamy analizę „od liścia do korzenia”
 - Każda instrukcja przypisania (liście) wymaga czasu $O(1)$
 - Instrukcja „if” (4-5) wymaga czasu $O(1)$
 - Instrukcja „for” (3)-(5) wymaga czasu $O(n-i-1)$ oraz $i < n$
 - Instrukcja „for” (2)-(8) może być dalej ograniczona przez $O(n-1)$
 - Instrukcja „for” (1)-(8) może być ograniczona przez $O(n(n-1))$

Odrzucając wyraz mniej znaczący otrzymujemy oszacowanie czasu działania jako $O(n^2)$.

Drzewo reprezentujące grupowanie instrukcji



Przybliżone lub precyzyjne ograniczenie

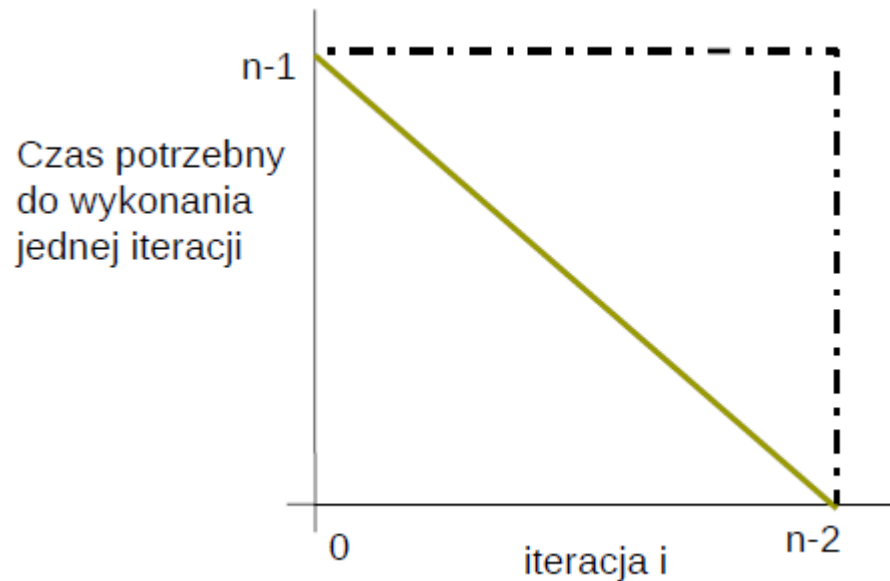
39

- Dotychczas rozważaliśmy szacowanie czasu działania pętli używając ujednoczonego górnego ograniczenia, mającego zastosowanie w każdej iteracji pętli.
- Dla sortowania przez wybieranie, takie przybliżone ograniczenie prowadziło do szacowania czasu wykonania pętli $O(n^2)$.
- Można jednak dokonać bardziej szczegółowej analizy pętli i dokonać sumowania górnych ograniczeń poszczególnych iteracji. Część działania pętli z wartością i zmiennej indeksowej i wynosi $O(n-i-1)$, gdzie i przyjmuje wartości od 0 do $n-2$.
- Górne ograniczenie czasu niezbędne do wykonania wszystkich iteracji wynosi:

$$O\left(\sum_{n=0}^{n-2} (n-i-1)\right) = O(n(n-1)/2)$$

Przybliżone lub precyzyjne ograniczenie

40



- **Górne ograniczenie czasu niezbędne do wykonania wszystkich iteracji wynosi:**

$$O\left(\sum_{n=0}^{n-2} (n-i-1)\right) = O(n(n-1)/2)$$

Efektywność algorytmu

41

□ Czas działania:

- Oznaczamy przez funkcję $T(n)$ liczbę jednostek czasu, które zajmuje wykonanie programu lub algorytmu w przypadku problemu o rozmiarze n .
- Funkcje te nazywamy **czasem działania**. Dość często czas działania zależy od konkretnych danych wejściowych, nie tylko ich rozmiaru. W takim przypadku, funkcje $T(n)$ definiuje się jako **najmniej korzystny przypadek** z punktu widzenia kosztów czasowych. Inną wyznaczaną wielkością jest też **czas średni**, czyli średni dla różnych danych wejściowych.

Nie przejmuj się efektywnością algorytmu...

42

- Istnieją problemy których rozwiązanie za pomocą zasobów komputerowych **jest teoretycznie możliwe, ale praktycznie przekracza możliwości istniejących technologii**. Przykładem takiego problemu jest rozumienie języka naturalnego, przetwarzanie obrazów (do pewnego stopnia oczywiście) czy “inteligentna” komunikacja pomiędzy komputerami a ludźmi na rozmaitych poziomach.
- Kiedy pewne problemy stają się “proste”... Nowa grupa wyzwań, które na razie można sobie tylko próbować wyobrazić, **wytyczy nowe granice możliwości wykorzystania komputerów**.

Uwagi końcowe

43

- **Na wybór najlepszego algorytmu dla tworzonoego programu wpływa wiele czynników, najważniejsze to:**
 - **prostota,**
 - **łatwość implementacji**
 - **efektywność**

- **Do problemu systematycznej analizy czasu działania programu powrócimy jeszcze na wykładzie za kilka tygodni...**

Pytania do wykładu

44

1. **Podaj definicję notacji: „wielkie O”, Ω , Θ .**
2. **Podaj własności notacji „wielkie O”.**
3. **Wymień znane Ci klasy złożoności algorytmu.**
4. **Co to są funkcje niewspółmierne? Podaj przykład.**
5. **Co to jest złożoność obliczeniowa średnia? Uzasadnij pojęcie dla dowolnie wybranego algorytmu.**
6. **Co to jest złożoność obliczeniowa asymptotyczna? Uzasadnij pojęcie dla dowolnie wybranego algorytmu.**