



# Poprawność i złożoność obliczeniowa algorytmów

Piotr Beling

Uniwersytet Łódzki

2020

<http://pbeling.w8.pl>

## **Algorytm** to:

- przepis, sposób postępowania prowadzący do rozwiązania (złożonego) problemu lub osiągnięcia celu,
- ciąg czynności elementarnych, czyli zrozumiałych dla wykonawcy algorytmu kroków.

Wykonawca algorytmu to zazwyczaj człowiek lub komputer.

## Przykłady algorytmów:

- przepis kulinarny,
- algorytmy pisemnego dodawania, odejmowania, mnożenia oraz dzielenia liczb,
- algorytm Euklidesa do wyznaczania największego wspólnego dzielnika (jeden z najstarszych algorytmów, pojawił się w dziele „Elementy” w około 300r. p.n.e.; wciąż używany).

## **Algorytm** to:

- przepis, sposób postępowania prowadzący do rozwiązania (złożonego) problemu lub osiągnięcia celu,
- ciąg czynności elementarnych, czyli zrozumiałych dla wykonawcy algorytmu kroków.

Wykonawca algorytmu to zazwyczaj człowiek lub komputer.

## Przykłady algorytmów:

- przepis kulinarny,
- algorytmy pisemnego dodawania, odejmowania, mnożenia oraz dzielenia liczb,
- algorytm Euklidesa do wyznaczania największego wspólnego dzielnika (jeden z najstarszych algorytmów, pojawił się w dziele „Elementy” w około 300r. p.n.e.; wciąż używany).

**Algorytm** to:

- przepis, sposób postępowania prowadzący do rozwiązania (złożonego) problemu lub osiągnięcia celu,
- ciąg czynności elementarnych, czyli zrozumiałych dla wykonawcy algorytmu kroków.

Wykonawca algorytmu to zazwyczaj człowiek lub komputer.

Przykłady algorytmów:

- przepis kulinarny,
- algorytmy pisemnego dodawania, odejmowania, mnożenia oraz dzielenia liczb,
- algorytm Euklidesa do wyznaczania największego wspólnego dzielnika (jeden z najstarszych algorytmów, pojawił się w dziele „Elementy” w około 300r. p.n.e.; wciąż używany).

**Algorytm** to:

- przepis, sposób postępowania prowadzący do rozwiązania (złożonego) problemu lub osiągnięcia celu,
- ciąg czynności elementarnych, czyli zrozumiałych dla wykonawcy algorytmu kroków.

Wykonawca algorytmu to zazwyczaj człowiek lub komputer.

Przykłady algorytmów:

- przepis kulinarny,
- algorytmy pisemnego dodawania, odejmowania, mnożenia oraz dzielenia liczb,
- algorytm Euklidesa do wyznaczania największego wspólnego dzielnika (jeden z najstarszych algorytmów, pojawił się w dziele „Elementy” w około 300r. p.n.e.; wciąż używany).

**Algorytm** to:

- przepis, sposób postępowania prowadzący do rozwiązania (złożonego) problemu lub osiągnięcia celu,
- ciąg czynności elementarnych, czyli zrozumiałych dla wykonawcy algorytmu kroków.

Wykonawca algorytmu to zazwyczaj człowiek lub komputer.

Przykłady algorytmów:

- przepis kulinarny,
- algorytmy pisemnego dodawania, odejmowania, mnożenia oraz dzielenia liczb,
- algorytm Euklidesa do wyznaczania największego wspólnego dzielnika (jeden z najstarszych algorytmów, pojawił się w dziele „Elementy” w około 300r. p.n.e.; wciąż używany).

**Algorytm** to:

- przepis, sposób postępowania prowadzący do rozwiązania (złożonego) problemu lub osiągnięcia celu,
- ciąg czynności elementarnych, czyli zrozumiałych dla wykonawcy algorytmu kroków.

Wykonawca algorytmu to zazwyczaj człowiek lub komputer.

Przykłady algorytmów:

- przepis kulinarny,
- algorytmy pisemnego dodawania, odejmowania, mnożenia oraz dzielenia liczb,
- algorytm Euklidesa do wyznaczania największego wspólnego dzielnika (jeden z najstarszych algorytmów, pojawił się w dziele „Elementy” w około 300r. p.n.e.; wciąż używany).

Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.



Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.

Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.

Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.

Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.

Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.

Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.

Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.

Dalej zajmujemy się algorytmami wykonywanymi przez komputer.

Specyfikacja takiego algorytmu składa się z opisów:

- wejścia – jakie dane wejściowe są dopuszczalne i w jakim formacie (typy danych, zakresy, itp.);
- wyjścia – jaki wynik zwraca algorytm dla poszczególnych danych wejściowych i w jakim formacie.

**Poprawny algorytm** to taki, który, dla poprawnego wejścia:

- zakończy pracę w skończonym czasie (ma własność stopu),
- i zwróci wynik zgodny ze specyfikacją.

Poprawności algorytmów zazwyczaj dowodzi się:

- indukcyjnie,
- definiując i dowodząc tzw. niezmienniki, które są spełnione na różnych etapach wykonywania algorytmu.



**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Uwaga do pseudokodu:  $|T|$  oznacza długość tablicy  $T$ , zaś jej prawidłowe indeksy to:  $0, 1, \dots, |T|-1$ .

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Uwaga do pseudokodu:  $|T|$  oznacza długość tablicy  $T$ , zaś jej prawidłowe indeksy to:  $0, 1, \dots, |T|-1$ .

Specyfikacja algorytmu:

- wejście: tablica  $T$  i wartość  $e$ .
- wyjście (wynik): liczba równa:
  - najmniejszemu indeksowi tablicy  $T$ , pod którym występuje wartość  $e$ ,
  - albo  $-1$  gdy  $T$  nie zawiera  $e$ .

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Uwaga do pseudokodu:  $|T|$  oznacza długość tablicy  $T$ , zaś jej prawidłowe indeksy to:  $0, 1, \dots, |T|-1$ .

Specyfikacja algorytmu:

- wejście: tablica  $T$  i wartość  $e$ .
- wyjście (wynik): liczba równa:
  - najmniejszemu indeksowi tablicy  $T$ , pod którym występuje wartość  $e$ ,
  - albo  $-1$  gdy  $T$  nie zawiera  $e$ .

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Uwaga do pseudokodu:  $|T|$  oznacza długość tablicy  $T$ , zaś jej prawidłowe indeksy to:  $0, 1, \dots, |T|-1$ .

Poprawność algorytmu:

- algorytm ma własność stopu gdyż jedyna pętla wykona się co najwyżej  $|T|$  razy

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu:

- Wykażemy dwa niezmienniki P oraz K, które są spełnione (i zdefiniowane) we wskazanych miejscach pseudokodu
- P wykażemy indukcyjnie, przy okazji dowodząc K.
- W pierwszej iteracji (dla  $i=0$ ) P jest pusto-spełniony.
- Dalej wykażemy, że jeśli
  - (założenie indukcyjne) P jest spełniony w  $i$ -tej iteracji (czyli  $T[j] \neq e$  dla wszystkich  $j < i$ ),
  - to jest on też spełniony w iteracji  $i + 1$
  - (przy okazji wykażemy K w  $i$ -tej iteracji).

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu:

- Wykażemy dwa niezmienniki P oraz K, które są spełnione (i zdefiniowane) we wskazanych miejscach pseudokodu
- P wykażemy indukcyjnie, przy okazji dowodząc K.
- W pierwszej iteracji (dla  $i=0$ ) P jest pusto-spełniony.
- Dalej wykażemy, że jeśli
  - (założenie indukcyjne) P jest spełniony w  $i$ -tej iteracji (czyli  $T[j] \neq e$  dla wszystkich  $j < i$ ),
  - to jest on też spełniony w iteracji  $i + 1$
  - (przy okazji wykażemy K w  $i$ -tej iteracji).

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu:

- Wykażemy dwa niezmienniki P oraz K, które są spełnione (i zdefiniowane) we wskazanych miejscach pseudokodu
- P wykażemy indukcyjnie, przy okazji dowodząc K.
- W pierwszej iteracji (dla  $i=0$ ) P jest pusto-spełniony.
- Dalej wykażemy, że jeśli
  - (założenie indukcyjne) P jest spełniony w  $i$ -tej iteracji (czyli  $T[j] \neq e$  dla wszystkich  $j < i$ ),
  - to jest on też spełniony w iteracji  $i + 1$
  - (przy okazji wykażemy K w  $i$ -tej iteracji).

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu:

- Wykażemy dwa niezmienniki P oraz K, które są spełnione (i zdefiniowane) we wskazanych miejscach pseudokodu
- P wykażemy indukcyjnie, przy okazji dowodząc K.
- W pierwszej iteracji (dla  $i=0$ ) P jest pusto-spełniony.
- Dalej wykażemy, że jeśli
  - (założenie indukcyjne) P jest spełniony w  $i$ -tej iteracji (czyli  $T[j] \neq e$  dla wszystkich  $j < i$ ),
  - to jest on też spełniony w iteracji  $i + 1$
  - (przy okazji wykażemy K w  $i$ -tej iteracji).



**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu:

- Wykażemy dwa niezmienniki  $P$  oraz  $K$ , które są spełnione (i zdefiniowane) we wskazanych miejscach pseudokodu
- $P$  wykażemy indukcyjnie, przy okazji dowodząc  $K$ .
- W pierwszej iteracji (dla  $i=0$ )  $P$  jest pusto-spełniony.
- Dalej wykażemy, że jeśli
  - (założenie indukcyjne)  $P$  jest spełniony w  $i$ -tej iteracji (czyli  $T[j] \neq e$  dla wszystkich  $j < i$ ),
  - to jest on też spełniony w iteracji  $i + 1$
  - (przy okazji wykażemy  $K$  w  $i$ -tej iteracji).

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu:

- Wykażemy dwa niezmienniki  $P$  oraz  $K$ , które są spełnione (i zdefiniowane) we wskazanych miejscach pseudokodu
- $P$  wykażemy indukcyjnie, przy okazji dowodząc  $K$ .
- W pierwszej iteracji (dla  $i=0$ )  $P$  jest pusto-spełniony.
- Dalej wykażemy, że jeśli
  - (założenie indukcyjne)  $P$  jest spełniony w  $i$ -tej iteracji (czyli  $T[j] \neq e$  dla wszystkich  $j < i$ ),
  - to jest on też spełniony w iteracji  $i + 1$
  - (przy okazji wykażemy  $K$  w  $i$ -tej iteracji).

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu, krok indukcyjny:

- Jeśli znajdzie warunek  $T[i] = e$  to zostanie zwrócony indeks  $i$ , zgodny ze specyfikacją wyjścia ( $T[i] = e$  z warunku, zaś  $T[j] \neq e$  dla wszystkich  $j < i$  z założenia indukcyjnego o P).
- Jeśli warunek  $T[i] = e$  nie znajdzie, to sterowanie osiągnie miejsce niezmiennika K, spełnionego w bieżącej ( $i$ -tej) iteracji na podstawie założenia indukcyjnego (dla  $j < i$ ) oraz niezajścia warunku (dla  $j = i$ ).
- Zaś wprost z K w iteracji  $i$  wynika P w iteracji  $i + 1$ .

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu, krok indukcyjny:

- Jeśli znajdzie warunek  $T[i] = e$  to zostanie zwrócony indeks  $i$ , zgodny ze specyfikacją wyjścia ( $T[i] = e$  z warunku, zaś  $T[j] \neq e$  dla wszystkich  $j < i$  z założenia indukcyjnego o P).
- Jeśli warunek  $T[i] = e$  nie znajdzie, to sterowanie osiągnie miejsce niezmiennika K, spełnionego w bieżącej ( $i$ -tej) iteracji na podstawie założenia indukcyjnego (dla  $j < i$ ) oraz niezajścia warunku (dla  $j = i$ ).
- Zaś wprost z K w iteracji  $i$  wynika P w iteracji  $i + 1$ .

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu, krok indukcyjny:

- Jeśli znajdzie warunek  $T[i] = e$  to zostanie zwrócony indeks  $i$ , zgodny ze specyfikacją wyjścia ( $T[i] = e$  z warunku, zaś  $T[j] \neq e$  dla wszystkich  $j < i$  z założenia indukcyjnego o P).
- Jeśli warunek  $T[i] = e$  nie znajdzie, to sterowanie osiągnie miejsce niezmiennika K, spełnionego w bieżącej ( $i$ -tej) iteracji na podstawie założenia indukcyjnego (dla  $j < i$ ) oraz niezajścia warunku (dla  $j = i$ ).
- Zaś wprost z K w iteracji  $i$  wynika P w iteracji  $i + 1$ .

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):
    for i ← 0, 1, ..., |T|-1:
        // P: T[j] ≠ e dla j = 0, 1, ..., i-1
        if T[i] = e: return i
        // K: T[j] ≠ e dla j = 0, 1, ..., i
    return -1
```

Poprawność algorytmu:

- Wcześniej wykazaliśmy, że gdy w którejkolwiek iteracji znajdzie warunek  $T[i] = e$ , to zostanie zwrócony prawidłowy indeks.
- Jeśli warunek  $T[i] = e$  nigdy nie znajdzie, to pętla przebiegnie przez wszystkie indeksy tablicy, zakończy się, i zostanie zwrócone  $-1$ , zgodne ze specyfikacją wyjścia na podstawie:
- niezmiennika  $K$  w ostatniej iteracji pętli, tj. dla  $i=|T|-1$ ,
- albo, gdy pętla nie wykonała żadnej iteracji, faktu, że tablica jest pusta ( $|T|=0$ ).

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu:

- Wcześniej wykazaliśmy, że gdy w którejkolwiek iteracji znajdzie warunek  $T[i] = e$ , to zostanie zwrócony prawidłowy indeks.
- Jeśli warunek  $T[i] = e$  nigdy nie znajdzie, to pętla przebiegnie przez wszystkie indeksy tablicy, zakończy się, i zostanie zwrócone  $-1$ , zgodne ze specyfikacją wyjścia na podstawie:
  - niezmiennika  $K$  w ostatniej iteracji pętli, tj. dla  $i=|T|-1$ ,
  - albo, gdy pętla nie wykonała żadnej iteracji, faktu, że tablica jest pusta ( $|T|=0$ ).

**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):
    for i ← 0, 1, ..., |T|-1:
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$ 
        if  $T[i] = e$ : return i
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$ 
    return -1
```

Poprawność algorytmu:

- Wcześniej wykazaliśmy, że gdy w którejkolwiek iteracji znajdzie warunek  $T[i] = e$ , to zostanie zwrócony prawidłowy indeks.
- Jeśli warunek  $T[i] = e$  nigdy nie znajdzie, to pętla przebiegnie przez wszystkie indeksy tablicy, zakończy się, i zostanie zwrócone  $-1$ , zgodne ze specyfikacją wyjścia na podstawie:
- niezmiennika  $K$  w ostatniej iteracji pętli, tj. dla  $i = |T| - 1$ ,
- albo, gdy pętla nie wykonała żadnej iteracji, faktu, że tablica jest pusta ( $|T| = 0$ ).



**Przykład:** algorytm wyszukujący wartości  $e$  w tablicy  $T$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        // P:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i-1$   
        if  $T[i] = e$ : return i  
        // K:  $T[j] \neq e$  dla  $j = 0, 1, \dots, i$   
    return -1
```

Poprawność algorytmu:

- Wcześniej wykazaliśmy, że gdy w którejkolwiek iteracji znajdzie warunek  $T[i] = e$ , to zostanie zwrócony prawidłowy indeks.
- Jeśli warunek  $T[i] = e$  nigdy nie znajdzie, to pętla przebiegnie przez wszystkie indeksy tablicy, zakończy się, i zostanie zwrócone  $-1$ , zgodne ze specyfikacją wyjścia na podstawie:
- niezmiennika  $K$  w ostatniej iteracji pętli, tj. dla  $i = |T| - 1$ ,
- albo, gdy pętla nie wykonała żadnej iteracji, faktu, że tablica jest pusta ( $|T| = 0$ ).

Opracowujemy nowe algorytmy aby:

- rozwiązywać nowe, dotychczas nierozwiązane problemy;
- rozwiązywać problemy zużywając przy tym mniej zasobów.

W przypadku wykonywania algorytmu przez komputer, zużywane zasoby to **czas** i **pamięć**.

Cechę algorytmu charakteryzującą ilość używanych przez niego zasobów nazywamy jego **złożonością obliczeniową**, odpowiednio (w zależności od zasobu) **czasową** albo **pamięciową**.

Opracowujemy nowe algorytmy aby:

- rozwiązywać nowe, dotychczas nierozwiązane problemy;
- rozwiązywać problemy zużywając przy tym mniej zasobów.

W przypadku wykonywania algorytmu przez komputer, zużywane zasoby to **czas** i **pamięć**.

Cechę algorytmu charakteryzującą ilość używanych przez niego zasobów nazywamy jego **złożonością obliczeniową**, odpowiednio (w zależności od zasobu) **czasową** albo **pamięciową**.

Opracowujemy nowe algorytmy aby:

- rozwiązywać nowe, dotychczas nierozwiązane problemy;
- rozwiązywać problemy zużywając przy tym mniej zasobów.

W przypadku wykonywania algorytmu przez komputer, zużywane zasoby to **czas** i **pamięć**.

Cechę algorytmu charakteryzującą ilość używanych przez niego zasobów nazywamy jego **złożonością obliczeniową**, odpowiednio (w zależności od zasobu) **czasową** albo **pamięciową**.

Opracowujemy nowe algorytmy aby:

- rozwiązywać nowe, dotychczas nierozwiązane problemy;
- rozwiązywać problemy zużywając przy tym mniej zasobów.

W przypadku wykonywania algorytmu przez komputer, zużywane zasoby to **czas** i **pamięć**.

Cechę algorytmu charakteryzującą ilość używanych przez niego zasobów nazywamy jego **złożonością obliczeniową**, odpowiednio (w zależności od zasobu) **czasową** albo **pamięciową**.

Opracowujemy nowe algorytmy aby:

- rozwiązywać nowe, dotychczas nierozwiązane problemy;
- rozwiązywać problemy zużywając przy tym mniej zasobów.

W przypadku wykonywania algorytmu przez komputer, zużywane zasoby to **czas** i **pamięć**.

Cechę algorytmu charakteryzującą ilość używanych przez niego zasobów nazywamy jego **złożonością obliczeniową**, odpowiednio (w zależności od zasobu) **czasową** albo **pamięciową**.

**Złożoność czasowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- liczbę operacji elementarnych (albo, zazwyczaj, **operacji dominujących**) wykonanych przez algorytm dla tych danych.

**Operacje dominujące** algorytmu to

- wyróżnione operacje elementarne,
- których liczba wykonań jest proporcjonalna do liczby wszystkich operacji wykonanych przez cały algorytm.
- np. mnożenie dla algorytmu potęgowania

Złożoność czasową można by mierzyć za pomocą zegara.

Wtedy wynik zależałby jednak nie tylko od samego algorytmu, ale także od szybkości wykonującego go komputera.

**Złożoność czasowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- liczbę operacji elementarnych (albo, zazwyczaj, **operacji dominujących**) wykonanych przez algorytm dla tych danych.

**Operacje dominujące** algorytmu to

- wyróżnione operacje elementarne,
- których liczba wykonań jest proporcjonalna do liczby wszystkich operacji wykonanych przez cały algorytm.
- np. mnożenie dla algorytmu potęgowania

Złożoność czasową można by mierzyć za pomocą zegara.

Wtedy wynik zależałby jednak nie tylko od samego algorytmu, ale także od szybkości wykonującego go komputera.



**Złożoność czasowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- liczbę operacji elementarnych (albo, zazwyczaj, **operacji dominujących**) wykonanych przez algorytm dla tych danych.

**Operacje dominujące** algorytmu to

- wyróżnione operacje elementarne,
- których liczba wykonań jest proporcjonalna do liczby wszystkich operacji wykonanych przez cały algorytm.
- np. mnożenie dla algorytmu potęgowania

Złożoność czasową można by mierzyć za pomocą zegara.

Wtedy wynik zależałby jednak nie tylko od samego algorytmu, ale także od szybkości wykonującego go komputera.

**Złożoność czasowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- liczbę operacji elementarnych (albo, zazwyczaj, **operacji dominujących**) wykonanych przez algorytm dla tych danych.

**Operacje dominujące** algorytmu to

- wyróżnione operacje elementarne,
- których liczba wykonań jest proporcjonalna do liczby wszystkich operacji wykonanych przez cały algorytm.
- np. mnożenie dla algorytmu potęgowania

Złożoność czasową można by mierzyć za pomocą zegara.

Wtedy wynik zależałby jednak nie tylko od samego algorytmu, ale także od szybkości wykonującego go komputera.

**Złożoność czasowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- liczbę operacji elementarnych (albo, zazwyczaj, **operacji dominujących**) wykonanych przez algorytm dla tych danych.

**Operacje dominujące** algorytmu to

- wyróżnione operacje elementarne,
- których liczba wykonań jest proporcjonalna do liczby wszystkich operacji wykonanych przez cały algorytm.
- np. mnożenie dla algorytmu potęgowania

Złożoność czasową można by mierzyć za pomocą zegara.

Wtedy wynik zależałby jednak nie tylko od samego algorytmu, ale także od szybkości wykonującego go komputera.

**Złożoność czasowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- liczbę operacji elementarnych (albo, zazwyczaj, **operacji dominujących**) wykonanych przez algorytm dla tych danych.

**Operacje dominujące** algorytmu to

- wyróżnione operacje elementarne,
- których liczba wykonań jest proporcjonalna do liczby wszystkich operacji wykonanych przez cały algorytm.
- np. mnożenie dla algorytmu potęgowania

Złożoność czasową można by mierzyć za pomocą zegara.

Wtedy wynik zależałby jednak nie tylko od samego algorytmu, ale także od szybkości wykonującego go komputera.

**Złożoność czasowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- liczbę operacji elementarnych (albo, zazwyczaj, **operacji dominujących**) wykonanych przez algorytm dla tych danych.

**Operacje dominujące** algorytmu to

- wyróżnione operacje elementarne,
- których liczba wykonań jest proporcjonalna do liczby wszystkich operacji wykonanych przez cały algorytm.
- np. mnożenie dla algorytmu potęgowania

Złożoność czasową można by mierzyć za pomocą zegara.

Wtedy wynik zależałby jednak nie tylko od samego algorytmu, ale także od szybkości wykonującego go komputera.

**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.

**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.

**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.



**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.

**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.

**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.

**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.

**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.

**Złożoność pamięciowa** algorytmu to funkcja przyporządkowująca

- rozmiarowi danych wejściowych,
- ilości pamięci (bitów lub słów maszynowych) użytej do wykonania algorytm dla tych danych,
- (domyślnie) nie wliczając w to pamięci użytej do zapisania danych wejściowych i wyjściowych (wyniku).

Przyjmujemy, że obliczenia prowadzone są w tzw. modelu *Word RAM*, zakładającym (w uproszczeniu) operowanie słowami, które:

- mają stałą wielkość (np. 64 bity),
- są na tyle duże, by móc adresować całą pamięć komputera,
- i na których możemy wykonywać podstawowe operacje w stałym czasie.

Współczesne komputery w przybliżeniu realizują ten model.

# Złożoność pesymistyczna, optymistyczna, oczekiwana

Ilość użytych zasobów (czasu lub pamięci) może być różna, dla różnych zestawów danych o tym samym rozmiarze  $n$ .

Dlatego wyróżniamy różne warianty złożoności obliczeniowej:

- **pesymistyczny** – maksymalny, uzyskany dla „najtrudniejszego” zestawu danych o rozmiarze  $n$ ;
- **optymistyczny** – minimalny, uzyskany dla „najłatwiejszego” zestawu danych o rozmiarze  $n$ ;
- **oczekiwany** (średni) – suma złożoności wszystkich zestawów danych rozmiaru  $n$ , ważona prawdopodobieństwami ich wystąpienia na wejściu.  
Często obliczana przy założeniu, że poszczególne zestawy danych są równie prawdopodobne.

Ilość użytych zasobów (czasu lub pamięci) może być różna, dla różnych zestawów danych o tym samym rozmiarze  $n$ .

Dlatego wyróżniamy różne warianty złożoności obliczeniowej:

- **pesymistyczny** – maksymalny, uzyskany dla „najtrudniejszego” zestawu danych o rozmiarze  $n$ ;
- **optymistyczny** – minimalny, uzyskany dla „najłatwiejszego” zestawu danych o rozmiarze  $n$ ;
- **oczekiwany** (średni) – suma złożoności wszystkich zestawów danych rozmiaru  $n$ , ważona prawdopodobieństwami ich wystąpienia na wejściu.  
Często obliczana przy założeniu, że poszczególne zestawy danych są równie prawdopodobne.



Ilość użytych zasobów (czasu lub pamięci) może być różna, dla różnych zestawów danych o tym samym rozmiarze  $n$ .

Dlatego wyróżniamy różne warianty złożoności obliczeniowej:

- **pesymistyczny** – maksymalny, uzyskany dla „najtrudniejszego” zestawu danych o rozmiarze  $n$ ;
- **optymistyczny** – minimalny, uzyskany dla „najłatwiejszego” zestawu danych o rozmiarze  $n$ ;
- **oczekiwany** (średni) – suma złożoności wszystkich zestawów danych rozmiaru  $n$ , ważona prawdopodobieństwami ich wystąpienia na wejściu.  
Często obliczana przy założeniu, że poszczególne zestawy danych są równie prawdopodobne.

Ilość użytych zasobów (czasu lub pamięci) może być różna, dla różnych zestawów danych o tym samym rozmiarze  $n$ .

Dlatego wyróżniamy różne warianty złożoności obliczeniowej:

- **pesymistyczny** – maksymalny, uzyskany dla „najtrudniejszego” zestawu danych o rozmiarze  $n$ ;
- **optymistyczny** – minimalny, uzyskany dla „najłatwiejszego” zestawu danych o rozmiarze  $n$ ;
- **oczekiwany** (średni) – suma złożoności wszystkich zestawów danych rozmiaru  $n$ , ważona prawdopodobieństwami ich wystąpienia na wejściu.  
Często obliczana przy założeniu, że poszczególne zestawy danych są równie prawdopodobne.

# Złożoność pesymistyczna, optymistyczna, oczekiwana

Ilość użytych zasobów (czasu lub pamięci) może być różna, dla różnych zestawów danych o tym samym rozmiarze  $n$ .

Dlatego wyróżniamy różne warianty złożoności obliczeniowej:

- **pesymistyczny** – maksymalny, uzyskany dla „najtrudniejszego” zestawu danych o rozmiarze  $n$ ;
- **optymistyczny** – minimalny, uzyskany dla „najłatwiejszego” zestawu danych o rozmiarze  $n$ ;
- **oczekiwany** (średni) – suma złożoności wszystkich zestawów danych rozmiaru  $n$ , ważona prawdopodobieństwami ich wystąpienia na wejściu.

Często obliczana przy założeniu, że poszczególne zestawy danych są równie prawdopodobne.

# Złożoność pesymistyczna, optymistyczna, oczekiwana

Ilość użytych zasobów (czasu lub pamięci) może być różna, dla różnych zestawów danych o tym samym rozmiarze  $n$ .

Dlatego wyróżniamy różne warianty złożoności obliczeniowej:

- **pesymistyczny** – maksymalny, uzyskany dla „najtrudniejszego” zestawu danych o rozmiarze  $n$ ;
- **optymistyczny** – minimalny, uzyskany dla „najłatwiejszego” zestawu danych o rozmiarze  $n$ ;
- **oczekiwany** (średni) – suma złożoności wszystkich zestawów danych rozmiaru  $n$ , ważona prawdopodobieństwami ich wystąpienia na wejściu.  
Często obliczana przy założeniu, że poszczególne zestawy danych są równie prawdopodobne.

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index( $T$ ,  $e$ ):  
    for  $i \leftarrow 0, 1, \dots, |T|-1$ :  
        if  $T[i] = e$ : return  $i$   
    return  $-1$ 
```

Rozmiar danych wejściowych = wielkość tablicy  $T$ , tj.  $n = |T|$ .

Operacja dominująca: porównanie elementów ( $T[i]=e$ )

- jest wykonywana w każdym przebiegu jedynej pętli,
- więc liczba jej wykonań jest proporcjonalna do liczby wszystkich operacji.

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Rozmiar danych wejściowych = wielkość tablicy  $T$ , tj.  $n = |T|$ .

Operacja dominująca: porównanie elementów ( $T[i]=e$ )

- jest wykonywana w każdym przebiegu jedynej pętli,
- więc liczba jej wykonań jest proporcjonalna do liczby wszystkich operacji.

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Rozmiar danych wejściowych = wielkość tablicy  $T$ , tj.  $n = |T|$ .

Operacja dominująca: porównanie elementów ( $T[i]=e$ )

- jest wykonywana w każdym przebiegu jedynej pętli,
- więc liczba jej wykonań jest proporcjonalna do liczby wszystkich operacji.



## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Rozmiar danych wejściowych = wielkość tablicy  $T$ , tj.  $n = |T|$ .

Operacja dominująca: porównanie elementów ( $T[i]=e$ )

- jest wykonywana w każdym przebiegu jedynej pętli,
- więc liczba jej wykonań jest proporcjonalna do liczby wszystkich operacji.

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Czasowa złożoność obliczeniowa to:

- optymistyczna: 1 porównanie (gdy  $T[0]=e$ );
- pesymistyczna:  $n = |T|$  porównań (gdy  $e$  występuje w  $T$  jedynie na ostatniej pozycji albo wcale);
- oczekiwana:  $\sum_{i=1}^n ip_i + np_{\notin}$  porównań, gdzie:
  - $p_i$  - prawdopodobieństwo, że  $e$  w  $T$  występuje po raz pierwszy na pozycji o indeksie  $i - 1$ ,
  - $p_{\notin}$  - prawdopodobieństwo, że  $e$  nie ma w  $T$ .

Przykładowo, dla  $p_1 = \dots = p_n = 1/n$  i  $p_{\notin} = 0$  otrzymujemy:

$$\sum_{i=1}^n i \frac{1}{n} + n \cdot 0 = \frac{1}{n} \sum_{i=1}^n i = \frac{1}{n} \frac{(1+n)n}{2} = \frac{n+1}{2}.$$

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Czasowa złożoność obliczeniowa to:

- optymistyczna: 1 porównanie (gdy  $T[0]=e$ );
- pesymistyczna:  $n = |T|$  porównań (gdy  $e$  występuje w  $T$  jedynie na ostatniej pozycji albo wcale);
- oczekiwana:  $\sum_{i=1}^n ip_i + np_{\notin}$  porównań, gdzie:
  - $p_i$  - prawdopodobieństwo, że  $e$  w  $T$  występuje po raz pierwszy na pozycji o indeksie  $i - 1$ ,
  - $p_{\notin}$  - prawdopodobieństwo, że  $e$  nie ma w  $T$ .

Przykładowo, dla  $p_1 = \dots = p_n = 1/n$  i  $p_{\notin} = 0$  otrzymujemy:

$$\sum_{i=1}^n i \frac{1}{n} + n \cdot 0 = \frac{1}{n} \sum_{i=1}^n i = \frac{1}{n} \frac{(1+n)n}{2} = \frac{n+1}{2}.$$

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Czasowa złożoność obliczeniowa to:

- optymistyczna: 1 porównanie (gdy  $T[0]=e$ );
- pesymistyczna:  $n = |T|$  porównań (gdy  $e$  występuje w  $T$  jedynie na ostatniej pozycji albo wcale);
- oczekiwana:  $\sum_{i=1}^n ip_i + np_{\notin}$  porównań, gdzie:
  - $p_i$  - prawdopodobieństwo, że  $e$  w  $T$  występuje po raz pierwszy na pozycji o indeksie  $i - 1$ ,
  - $p_{\notin}$  - prawdopodobieństwo, że  $e$  nie ma w  $T$ .

Przykładowo, dla  $p_1 = \dots = p_n = 1/n$  i  $p_{\notin} = 0$  otrzymujemy:

$$\sum_{i=1}^n i \frac{1}{n} + n \cdot 0 = \frac{1}{n} \sum_{i=1}^n i = \frac{1}{n} \frac{(1+n)n}{2} = \frac{n+1}{2}$$

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Czasowa złożoność obliczeniowa to:

- optymistyczna: 1 porównanie (gdy  $T[0]=e$ );
- pesymistyczna:  $n = |T|$  porównań (gdy  $e$  występuje w  $T$  jedynie na ostatniej pozycji albo wcale);
- oczekiwana:  $\sum_{i=1}^n ip_i + np_{\notin}$  porównań, gdzie:
  - $p_i$  - prawdopodobieństwo, że  $e$  w  $T$  występuje po raz pierwszy na pozycji o indeksie  $i - 1$ ,
  - $p_{\notin}$  - prawdopodobieństwo, że  $e$  nie ma w  $T$ .

Przykładowo, dla  $p_1 = \dots = p_n = 1/n$  i  $p_{\notin} = 0$  otrzymujemy:

$$\sum_{i=1}^n i \frac{1}{n} + n \cdot 0 = \frac{1}{n} \sum_{i=1}^n i = \frac{1}{n} \frac{(1+n)n}{2} = \frac{n+1}{2}.$$

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Czasowa złożoność obliczeniowa to:

- optymistyczna: 1 porównanie (gdy  $T[0]=e$ );
- pesymistyczna:  $n = |T|$  porównań (gdy  $e$  występuje w  $T$  jedynie na ostatniej pozycji albo wcale);
- oczekiwana:  $\sum_{i=1}^n ip_i + np_{\notin}$  porównań, gdzie:
  - $p_i$  - prawdopodobieństwo, że  $e$  w  $T$  występuje po raz pierwszy na pozycji o indeksie  $i - 1$ ,
  - $p_{\notin}$  - prawdopodobieństwo, że  $e$  nie ma w  $T$ .

Przykładowo, dla  $p_1 = \dots = p_n = 1/n$  i  $p_{\notin} = 0$  otrzymujemy:

$$\sum_{i=1}^n i \frac{1}{n} + n \cdot 0 = \frac{1}{n} \sum_{i=1}^n i = \frac{1}{n} \frac{(1+n)n}{2} = \frac{n+1}{2}.$$

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Pamięciowa złożoność obliczeniowa: algorytm używa stałej ilości pamięci (1 słowa) do zapamiętania indeksu  $i$ .

**Uwaga:**

- W ogólności potrzebujemy  $\lceil \log_2(n) \rceil$  bitów pamięci by zapisać liczbę z zakresu od 0 do  $n - 1$ . Można by więc argumentować, że pamięciowa złożoność algorytmu to  $\lceil \log_2(n) \rceil$  bitów.
- Ponieważ jednak w założonym modelu *Word RAM* operujemy stałej wielkości słowami na tyle dużymi, by móc adresować całą pamięć komputera, to stałej wielkości są także indeksy dowolnej tablicy mieszczącej się w jego pamięci.

## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Pamięciowa złożoność obliczeniowa: algorytm używa stałej ilości pamięci (1 słowa) do zapamiętania indeksu  $i$ .

### Uwaga:

- W ogólności potrzebujemy  $\lceil \log_2(n) \rceil$  bitów pamięci by zapisać liczbę z zakresu od 0 do  $n - 1$ . Można by więc argumentować, że pamięciowa złożoność algorytmu to  $\lceil \log_2(n) \rceil$  bitów.
- Ponieważ jednak w założonym modelu *Word RAM* operujemy stałej wielkości słowami na tyle dużymi, by móc adresować całą pamięć komputera, to stałej wielkości są także indeksy dowolnej tablicy mieszczącej się w jego pamięci.



## Przykład: algorytm wyszukiwania w tablicy

Rozważmy algorytm zwracający najmniejszy indeks tablicy  $T$ , pod którym występuje wartość  $e$ , albo  $-1$  gdy  $T$  nie zawiera  $e$ :

```
fun find_index(T, e):  
    for i ← 0, 1, ..., |T|-1:  
        if T[i] = e: return i  
    return -1
```

Pamięciowa złożoność obliczeniowa: algorytm używa stałej ilości pamięci (1 słowa) do zapamiętania indeksu  $i$ .

### Uwaga:

- W ogólności potrzebujemy  $\lceil \log_2(n) \rceil$  bitów pamięci by zapisać liczbę z zakresu od 0 do  $n - 1$ . Można by więc argumentować, że pamięciowa złożoność algorytmu to  $\lceil \log_2(n) \rceil$  bitów.
- Ponieważ jednak w założonym modelu *Word RAM* operujemy stałej wielkości słowami na tyle dużymi, by móc adresować całą pamięć komputera, to stałej wielkości są także indeksy dowolnej tablicy mieszczącej się w jego pamięci.

Przybliżone wartości wybranych funkcji:

| $n$    | $\log_2(n)$ | $\sqrt{n}$ | $n \log_2(n)$ | $n^2$     | $2^n$         | $n!$           |
|--------|-------------|------------|---------------|-----------|---------------|----------------|
| 1      | 1           | 1          | 1             | 1         | 1             | 1              |
| 10     | 3           | 3          | 33            | 100       | $10^3$        | $10^6$         |
| 100    | 7           | 10         | 664           | $10^4$    | $10^{30}$     | $10^{158}$     |
| $10^3$ | 10          | 32         | $10^4$        | $10^6$    | $10^{301}$    | $10^{2567}$    |
| $10^4$ | 13          | 100        | $10^5$        | $10^8$    | $10^{3011}$   | $10^{35659}$   |
| $10^5$ | 17          | 316        | $10^6$        | $10^{10}$ | $10^{30103}$  | $10^{456573}$  |
| $10^6$ | 20          | $10^3$     | $10^7$        | $10^{12}$ | $10^{301030}$ | $10^{5565709}$ |
| $10^9$ | 30          | $10^4$     | $10^{10}$     | $10^{18}$ | dużo          | dużo           |

Czas wykonania  $n$  instrukcji przez procesor wykonujący  $10^9$  instrukcji/sekundę (1GHz):

| n         | czas | n         | czas | n         | czas | n         | czas        |
|-----------|------|-----------|------|-----------|------|-----------|-------------|
| $10^9$    | 1s   | $10^{13}$ | 3h   | $10^{16}$ | 116d | $10^{20}$ | 3171r       |
| $10^{11}$ | 2m   | $10^{14}$ | 28h  | $10^{17}$ | 3r   | $10^{30}$ | $10^{13}$ r |
| $10^{12}$ | 17m  | $10^{15}$ | 12d  | $10^{18}$ | 33r  | $10^{50}$ | $10^{33}$ r |

s - sekunda, m - minuta, h - godzina, d - doba, r - rok

## Przykład: który algorytm jest szybszy?

- Porównajmy dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = 2n$ .
- Czy można powiedzieć, że pierwszy z nich jest szybszy?
- A co jeśli jego operacja dominująca wykonuje się (np. 2x) wolniej niż drugiego?
- Albo gdy wykonuje on więcej operacji niedominujących?
- Lub jest uruchomiony na wolniejszym komputerze?
- W związku z powyższymi wątpliwościami, często zasadne jest używanie notacji pomijającej takie szczegóły jak stała 2 we wzorze  $f_2(n) = 2n$ .

## Przykład: który algorytm jest szybszy?

- Porównajmy dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = 2n$ .
- Czy można powiedzieć, że pierwszy z nich jest szybszy?
- A co jeśli jego operacja dominująca wykonuje się (np. 2x) wolniej niż drugiego?
- Albo gdy wykonuje on więcej operacji niedominujących?
- Lub jest uruchomiony na wolniejszym komputerze?
- W związku z powyższymi wątpliwościami, często zasadne jest używanie notacji pomijającej takie szczegóły jak stała 2 we wzorze  $f_2(n) = 2n$ .

## Przykład: który algorytm jest szybszy?

- Porównajmy dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = 2n$ .
- Czy można powiedzieć, że pierwszy z nich jest szybszy?
- A co jeśli jego operacja dominująca wykonuje się (np. 2x) wolniej niż drugiego?
- Albo gdy wykonuje on więcej operacji niedominujących?
- Lub jest uruchomiony na wolniejszym komputerze?
- W związku z powyższymi wątpliwościami, często zasadne jest używanie notacji pomijającej takie szczegóły jak stała 2 we wzorze  $f_2(n) = 2n$ .

## Przykład: który algorytm jest szybszy?

- Porównajmy dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = 2n$ .
- Czy można powiedzieć, że pierwszy z nich jest szybszy?
- A co jeśli jego operacja dominująca wykonuje się (np. 2x) wolniej niż drugiego?
- Albo gdy wykonuje on więcej operacji niedominujących?
- Lub jest uruchomiony na wolniejszym komputerze?
- W związku z powyższymi wątpliwościami, często zasadne jest używanie notacji pomijającej takie szczegóły jak stała 2 we wzorze  $f_2(n) = 2n$ .

## Przykład: który algorytm jest szybszy?

- Porównajmy dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = 2n$ .
- Czy można powiedzieć, że pierwszy z nich jest szybszy?
- A co jeśli jego operacja dominująca wykonuje się (np. 2x) wolniej niż drugiego?
- Albo gdy wykonuje on więcej operacji niedominujących?
- Lub jest uruchomiony na wolniejszym komputerze?
- W związku z powyższymi wątpliwościami, często zasadne jest używanie notacji pomijającej takie szczegóły jak stała 2 we wzorze  $f_2(n) = 2n$ .

## Przykład: który algorytm jest szybszy?

- Porównajmy dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = 2n$ .
- Czy można powiedzieć, że pierwszy z nich jest szybszy?
- A co jeśli jego operacja dominująca wykonuje się (np. 2x) wolniej niż drugiego?
- Albo gdy wykonuje on więcej operacji niedominujących?
- Lub jest uruchomiony na wolniejszym komputerze?
- W związku z powyższymi wątpliwościami, często zasadne jest używanie notacji pomijającej takie szczegóły jak stała 2 we wzorze  $f_2(n) = 2n$ .



## Przykład: który algorytm jest szybszy?

- Porównajmy inne dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = n^2$ .
- Czy można powiedzieć, że pierwszy algorytm jest szybszy?
- Załóżmy, że jego operacja dominująca wykonuje się  $c$  razy wolniej (dla pewnej stałej  $c > 1$ , np.  $c = 1000$ ),
- albo że jest on uruchamiany na  $c$  razy wolniejszym komputerze od drugiego
- i w związku z tym czasy wykonania algorytmów wynoszą odpowiednio  $cn$  oraz  $n^2$  jednostek czasu (np. sekund).
- Pomimo „spowolnienia” pierwszego algorytmu  $c$  razy, wykona się on szybciej od drugiego, gdy tylko dane wejściowe będą dostatecznie duże (konkretnie gdy  $n > c$ ).
- Tym razem pierwszy algorytm jest więc istotnie szybszy od drugiego, przynajmniej w sensie który sformalizujemy dalej.

## Przykład: który algorytm jest szybszy?

- Porównajmy inne dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = n^2$ .
- Czy można powiedzieć, że pierwszy algorytm jest szybszy?
- Załóżmy, że jego operacja dominująca wykonuje się  $c$  razy wolniej (dla pewnej stałej  $c > 1$ , np.  $c = 1000$ ),
- albo że jest on uruchamiany na  $c$  razy wolniejszym komputerze od drugiego
- i w związku z tym czasy wykonania algorytmów wynoszą odpowiednio  $cn$  oraz  $n^2$  jednostek czasu (np. sekund).
- Pomimo „spowolnienia” pierwszego algorytmu  $c$  razy, wykona się on szybciej od drugiego, gdy tylko dane wejściowe będą dostatecznie duże (konkretnie gdy  $n > c$ ).
- Tym razem pierwszy algorytm jest więc istotnie szybszy od drugiego, przynajmniej w sensie który sformalizujemy dalej.

## Przykład: który algorytm jest szybszy?

- Porównajmy inne dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = n^2$ .
- Czy można powiedzieć, że pierwszy algorytm jest szybszy?
- Załóżmy, że jego operacja dominująca wykonuje się  $c$  razy wolniej (dla pewnej stałej  $c > 1$ , np.  $c = 1000$ ),
- albo że jest on uruchamiany na  $c$  razy wolniejszym komputerze od drugiego
- i w związku z tym czasy wykonania algorytmów wynoszą odpowiednio  $cn$  oraz  $n^2$  jednostek czasu (np. sekund).
- Pomimo „spowolnienia” pierwszego algorytmu  $c$  razy, wykona się on szybciej od drugiego, gdy tylko dane wejściowe będą dostatecznie duże (konkretnie gdy  $n > c$ ).
- Tym razem pierwszy algorytm jest więc istotnie szybszy od drugiego, przynajmniej w sensie który sformalizujemy dalej.

## Przykład: który algorytm jest szybszy?

- Porównajmy inne dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = n^2$ .
- Czy można powiedzieć, że pierwszy algorytm jest szybszy?
- Załóżmy, że jego operacja dominująca wykonuje się  $c$  razy wolniej (dla pewnej stałej  $c > 1$ , np.  $c = 1000$ ),
- albo że jest on uruchamiany na  $c$  razy wolniejszym komputerze od drugiego
- i w związku z tym czasy wykonania algorytmów wynoszą odpowiednio  $cn$  oraz  $n^2$  jednostek czasu (np. sekund).
- Pomimo „spowolnienia” pierwszego algorytmu  $c$  razy, wykona się on szybciej od drugiego, gdy tylko dane wejściowe będą dostatecznie duże (konkretnie gdy  $n > c$ ).
- Tym razem pierwszy algorytm jest więc istotnie szybszy od drugiego, przynajmniej w sensie który sformalizujemy dalej.

## Przykład: który algorytm jest szybszy?

- Porównajmy inne dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = n^2$ .
- Czy można powiedzieć, że pierwszy algorytm jest szybszy?
- Załóżmy, że jego operacja dominująca wykonuje się  $c$  razy wolniej (dla pewnej stałej  $c > 1$ , np.  $c = 1000$ ),
- albo że jest on uruchamiany na  $c$  razy wolniejszym komputerze od drugiego
- i w związku z tym czasy wykonania algorytmów wynoszą odpowiednio  $cn$  oraz  $n^2$  jednostek czasu (np. sekund).
- Pomimo „spowolnienia” pierwszego algorytmu  $c$  razy, wykona się on szybciej od drugiego, gdy tylko dane wejściowe będą dostatecznie duże (konkretnie gdy  $n > c$ ).
- Tym razem pierwszy algorytm jest więc istotnie szybszy od drugiego, przynajmniej w sensie który sformalizujemy dalej.

## Przykład: który algorytm jest szybszy?


- Porównajmy inne dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = n^2$ .
- Czy można powiedzieć, że pierwszy algorytm jest szybszy?
- Załóżmy, że jego operacja dominująca wykonuje się  $c$  razy wolniej (dla pewnej stałej  $c > 1$ , np.  $c = 1000$ ),
- albo że jest on uruchamiany na  $c$  razy wolniejszym komputerze od drugiego
- i w związku z tym czasy wykonania algorytmów wynoszą odpowiednio  $cn$  oraz  $n^2$  jednostek czasu (np. sekund).
- Pomimo „spowolnienia” pierwszego algorytmu  $c$  razy, wykona się on szybciej od drugiego, gdy tylko dane wejściowe będą dostatecznie duże (konkretnie gdy  $n > c$ ).
- Tym razem pierwszy algorytm jest więc istotnie szybszy od drugiego, przynajmniej w sensie który sformalizujemy dalej.

## Przykład: który algorytm jest szybszy?

- Porównajmy inne dwa algorytmy, których złożoności czasowe to kolejno  $f_1(n) = n$  i  $f_2(n) = n^2$ .
- Czy można powiedzieć, że pierwszy algorytm jest szybszy?
- Załóżmy, że jego operacja dominująca wykonuje się  $c$  razy wolniej (dla pewnej stałej  $c > 1$ , np.  $c = 1000$ ),
- albo że jest on uruchamiany na  $c$  razy wolniejszym komputerze od drugiego
- i w związku z tym czasy wykonania algorytmów wynoszą odpowiednio  $cn$  oraz  $n^2$  jednostek czasu (np. sekund).
- Pomimo „spowolnienia” pierwszego algorytmu  $c$  razy, wykona się on szybciej od drugiego, gdy tylko dane wejściowe będą dostatecznie duże (konkretnie gdy  $n > c$ ).
- Tym razem pierwszy algorytm jest więc istotnie szybszy od drugiego, przynajmniej w sensie który sformalizujemy dalej.

## Definicja notacji $O$ („jest co najwyżej rzędu”)


Niech  $f : \mathbb{N} \rightarrow \mathbb{R}_+$ ,  $g : \mathbb{N} \rightarrow \mathbb{R}_+$  – funkcje. Mówimy, że  $f$  **jest co najwyżej rzędu**  $g$ , co zapisujemy  $f(n) = O(g(n))$ , gdy istnieją takie stałe  $n_0 \in \mathbb{N}$ , oraz  $c > 0$ , że  $\forall n \geq n_0 : f(n) \leq cg(n)$ .






## Definicja notacji $\Omega$ („jest co najmniej rzędu”)

Niech  $f : \mathbb{N} \rightarrow \mathbb{R}_+$ ,  $g : \mathbb{N} \rightarrow \mathbb{R}_+$  – funkcje. Mówimy, że  $f$  **jest co najmniej rzędu**  $g$ , co zapisujemy  $f(n) = \Omega(g(n))$ , gdy istnieją takie stałe  $n_0 \in \mathbb{N}$ , oraz  $c > 0$ , że  $\forall n \geq n_0 : f(n) \geq cg(n)$ .



## Definicja notacji $\Theta$ („jest dokładnie rzędu”)

Niech  $f : \mathbb{N} \rightarrow \mathbb{R}_+$ ,  $g : \mathbb{N} \rightarrow \mathbb{R}_+$  – funkcje. Mówimy, że  $f$  **jest dokładnie rzędu**  $g$ , co zapisujemy  $f(n) = \Theta(g(n))$ , gdy  $f(n) = O(g(n))$  i równocześnie  $f(n) = \Omega(g(n))$ .



- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.

## Intuicje stojące za notacjami $O$ , $\Omega$ , $\Theta$

- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.

- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.

- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.

- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.

# Intuicje stojące za notacjami $O$ , $\Omega$ , $\Theta$

- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.



- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.

- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.

- $O$ ,  $\Omega$ ,  $\Theta$  opisują asymptotyczne tempo wzrostu funkcji,
- określają jak szybko rośnie funkcja wraz ze wzrostem jej argumentu, ukrywając przy tym pewne szczegóły,
- opisują zachowanie funkcji dla dużych argumentów,  $n \rightarrow +\infty$ .
- Zapisy te mówią, że  $f$  w stosunku do  $g$  rośnie asymptotycznie:
  - $f(n) = O(g(n))$  – nie szybciej,
  - $f(n) = \Omega(g(n))$  – nie wolniej,
  - $f(n) = \Theta(g(n))$  – równie szybko.
- Jeśli  $f(n) = O(g(n))$  i równocześnie nie zachodzi  $f(n) = \Theta(g(n))$ , to  $g$  rośnie asymptotycznie szybciej od  $f$ ,
- wtedy algorytm o złożoności czasowej  $f$ , nawet uruchomiony na wielokrotnie wolniejszym komputerze, wykona się szybciej od  $g$ , gdy tylko dane wejściowe będą dostatecznie duże.

## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**

## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**

## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**

## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**

## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**



## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**

## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**

## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**

## Przykład: wielomiany tego samego stopnia

Niech  $f(n) = 5n^3 + 10n + 4$ . Pokażemy że  $f(n) = \Theta(n^3)$ .

Najpierw dowiedzimy, że  $f(n) = O(n^3)$ .

By to uczynić, wskażemy stałą  $c$  taką, że  $f(n) \leq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \leq 5n^3 + 10n^3 + 4n^3 = 19n^3$ , to wystarczy położyć  $c = 19$ .

Teraz dowiedzimy, że  $f(n) = \Omega(n^3)$ .

W tym celu wystarczy wskazać stałą  $c$  taką, że  $f(n) \geq cn^3$  dla wszystkich  $n \geq 1$ .

Ponieważ  $5n^3 + 10n + 4 \geq 5n^3$ , to wystarczy położyć  $c = 5$ .

Ponieważ  $f(n) = O(n^3)$  i  $f(n) = \Omega(n^3)$ , to  $f(n) = \Theta(n^3)$ .

Analogicznie można pokazać, że **każdy wielomian  $w(n)$  stopnia  $s$  o dodatnim współczynniku przy najwyższej potędze, jest dokładnie rzędu  $n^s$  (tj.  $w(n) = \Theta(n^s)$ ).**

## Przykład: wielomiany różnych stopni

Pokażemy że  $5n^2 = O(n^3)$  i równocześnie, że nie prawdą jest  $5n^2 = \Omega(n^3)$  (czyli nie jest prawdą także  $5n^2 = \Theta(n^3)$ ).

$5n^2 = O(n^3)$  bo dla  $c = 5$  i wszystkich  $n \geq 0$  mamy  $5n^2 \leq cn^3$ .

Dowodzimy, że nie prawdą jest  $5n^2 = \Omega(n^3)$ :

- (przez zaprzeczenie) założmy że  $5n^2 = \Omega(n^3)$  jest prawdą,
- czyli że istnieją stałe  $n_0 \in \mathbb{N}$  oraz  $c > 0$ , takie że:
- $5n^2 \geq cn^3$  dla wszystkich  $n \geq n_0$ .
- Wtedy jednak, dla wszystkich  $n \geq n_0$  musiałoby zachodzić  $5 \geq cn$ , co nie może być prawdą, gdyż  $cn$  dąży do nieskończoności gdy  $n \rightarrow \infty$
- ( $5 \geq cn$  nie zachodzi dla żadnego  $n > \frac{5}{c}$ ).

## Przykład: wielomiany różnych stopni

Pokażemy że  $5n^2 = O(n^3)$  i równocześnie, że nie prawdą jest  $5n^2 = \Omega(n^3)$  (czyli nie jest prawdą także  $5n^2 = \Theta(n^3)$ ).

$5n^2 = O(n^3)$  bo dla  $c = 5$  i wszystkich  $n \geq 0$  mamy  $5n^2 \leq cn^3$ .

Dowodzimy, że nie prawdą jest  $5n^2 = \Omega(n^3)$ :

- (przez zaprzeczenie) założmy że  $5n^2 = \Omega(n^3)$  jest prawdą,
- czyli że istnieją stałe  $n_0 \in \mathbb{N}$  oraz  $c > 0$ , takie że:
- $5n^2 \geq cn^3$  dla wszystkich  $n \geq n_0$ .
- Wtedy jednak, dla wszystkich  $n \geq n_0$  musiałoby zachodzić  $5 \geq cn$ , co nie może być prawdą, gdyż  $cn$  dąży do nieskończoności gdy  $n \rightarrow \infty$
- ( $5 \geq cn$  nie zachodzi dla żadnego  $n > \frac{5}{c}$ ).

## Przykład: wielomiany różnych stopni

Pokażemy że  $5n^2 = O(n^3)$  i równocześnie, że nie prawdą jest  $5n^2 = \Omega(n^3)$  (czyli nie jest prawdą także  $5n^2 = \Theta(n^3)$ ).

$5n^2 = O(n^3)$  bo dla  $c = 5$  i wszystkich  $n \geq 0$  mamy  $5n^2 \leq cn^3$ .

Dowodzimy, że nie prawdą jest  $5n^2 = \Omega(n^3)$ :

- (przez zaprzeczenie) założmy że  $5n^2 = \Omega(n^3)$  jest prawdą,
- czyli że istnieją stałe  $n_0 \in \mathbb{N}$  oraz  $c > 0$ , takie że:
- $5n^2 \geq cn^3$  dla wszystkich  $n \geq n_0$ .
- Wtedy jednak, dla wszystkich  $n \geq n_0$  musiałoby zachodzić  $5 \geq cn$ , co nie może być prawdą, gdyż  $cn$  dąży do nieskończoności gdy  $n \rightarrow \infty$
- ( $5 \geq cn$  nie zachodzi dla żadnego  $n > \frac{5}{c}$ ).

## Przykład: wielomiany różnych stopni

Pokażemy że  $5n^2 = O(n^3)$  i równocześnie, że nie prawdą jest  $5n^2 = \Omega(n^3)$  (czyli nie jest prawdą także  $5n^2 = \Theta(n^3)$ ).

$5n^2 = O(n^3)$  bo dla  $c = 5$  i wszystkich  $n \geq 0$  mamy  $5n^2 \leq cn^3$ .

Dowodziemy, że nie prawdą jest  $5n^2 = \Omega(n^3)$ :

- (przez zaprzeczenie) założmy że  $5n^2 = \Omega(n^3)$  jest prawdą,
- czyli że istnieją stałe  $n_0 \in \mathbb{N}$  oraz  $c > 0$ , takie że:
- $5n^2 \geq cn^3$  dla wszystkich  $n \geq n_0$ .
- Wtedy jednak, dla wszystkich  $n \geq n_0$  musiałoby zachodzić  $5 \geq cn$ , co nie może być prawdą, gdyż  $cn$  dąży do nieskończoności gdy  $n \rightarrow \infty$
- ( $5 \geq cn$  nie zachodzi dla żadnego  $n > \frac{5}{c}$ ).



## Przykład: wielomiany różnych stopni

Pokażemy że  $5n^2 = O(n^3)$  i równocześnie, że nie prawdą jest  $5n^2 = \Omega(n^3)$  (czyli nie jest prawdą także  $5n^2 = \Theta(n^3)$ ).

$5n^2 = O(n^3)$  bo dla  $c = 5$  i wszystkich  $n \geq 0$  mamy  $5n^2 \leq cn^3$ .

Dowodzimy, że nie prawdą jest  $5n^2 = \Omega(n^3)$ :

- (przez zaprzeczenie) założmy że  $5n^2 = \Omega(n^3)$  jest prawdą,
- czyli że istnieją stałe  $n_0 \in \mathbb{N}$  oraz  $c > 0$ , takie że:
  - $5n^2 \geq cn^3$  dla wszystkich  $n \geq n_0$ .
  - Wtedy jednak, dla wszystkich  $n \geq n_0$  musiałoby zachodzić  $5 \geq cn$ , co nie może być prawdą, gdyż  $cn$  dąży do nieskończoności gdy  $n \rightarrow \infty$
  - ( $5 \geq cn$  nie zachodzi dla żadnego  $n > \frac{5}{c}$ ).

## Przykład: wielomiany różnych stopni

Pokażemy że  $5n^2 = O(n^3)$  i równocześnie, że nie prawdą jest  $5n^2 = \Omega(n^3)$  (czyli nie jest prawdą także  $5n^2 = \Theta(n^3)$ ).

$5n^2 = O(n^3)$  bo dla  $c = 5$  i wszystkich  $n \geq 0$  mamy  $5n^2 \leq cn^3$ .

Dowodzimy, że nie prawdą jest  $5n^2 = \Omega(n^3)$ :

- (przez zaprzeczenie) założmy że  $5n^2 = \Omega(n^3)$  jest prawdą,
- czyli że istnieją stałe  $n_0 \in \mathbb{N}$  oraz  $c > 0$ , takie że:
- $5n^2 \geq cn^3$  dla wszystkich  $n \geq n_0$ .
- Wtedy jednak, dla wszystkich  $n \geq n_0$  musiałoby zachodzić  $5 \geq cn$ , co nie może być prawdą, gdyż  $cn$  dąży do nieskończoności gdy  $n \rightarrow \infty$
- ( $5 \geq cn$  nie zachodzi dla żadnego  $n > \frac{5}{c}$ ).

## Przykład: wielomiany różnych stopni

Pokażemy że  $5n^2 = O(n^3)$  i równocześnie, że nie prawdą jest  $5n^2 = \Omega(n^3)$  (czyli nie jest prawdą także  $5n^2 = \Theta(n^3)$ ).

$5n^2 = O(n^3)$  bo dla  $c = 5$  i wszystkich  $n \geq 0$  mamy  $5n^2 \leq cn^3$ .

Dowodzimy, że nie prawdą jest  $5n^2 = \Omega(n^3)$ :

- (przez zaprzeczenie) założmy że  $5n^2 = \Omega(n^3)$  jest prawdą,
- czyli że istnieją stałe  $n_0 \in \mathbb{N}$  oraz  $c > 0$ , takie że:
- $5n^2 \geq cn^3$  dla wszystkich  $n \geq n_0$ .
- Wtedy jednak, dla wszystkich  $n \geq n_0$  musiałoby zachodzić  $5 \geq cn$ , co nie może być prawdą, gdyż  $cn$  dąży do nieskończoności gdy  $n \rightarrow \infty$
- ( $5 \geq cn$  nie zachodzi dla żadnego  $n > \frac{5}{c}$ ).

## Przykład: wielomiany różnych stopni

Pokażemy że  $5n^2 = O(n^3)$  i równocześnie, że nie prawdą jest  $5n^2 = \Omega(n^3)$  (czyli nie jest prawdą także  $5n^2 = \Theta(n^3)$ ).

$5n^2 = O(n^3)$  bo dla  $c = 5$  i wszystkich  $n \geq 0$  mamy  $5n^2 \leq cn^3$ .

Dowodzimy, że nie prawdą jest  $5n^2 = \Omega(n^3)$ :

- (przez zaprzeczenie) założmy że  $5n^2 = \Omega(n^3)$  jest prawdą,
- czyli że istnieją stałe  $n_0 \in \mathbb{N}$  oraz  $c > 0$ , takie że:
- $5n^2 \geq cn^3$  dla wszystkich  $n \geq n_0$ .
- Wtedy jednak, dla wszystkich  $n \geq n_0$  musiałoby zachodzić  $5 \geq cn$ , co nie może być prawdą, gdyż  $cn$  dąży do nieskończoności gdy  $n \rightarrow \infty$
- ( $5 \geq cn$  nie zachodzi dla żadnego  $n > \frac{5}{c}$ ).

- Dla dowolnych  $a > 1$ ,  $b > 1$ , zachodzi  $\log_a(n) = \Theta(\log_b(n))$ .
- Powyższy fakt wynika wprost ze wzoru na zmianę podstawy logarytmu

$$\log_a(n) = \frac{\log_b(n)}{\log_b(a)} = c \log_b(n)$$

dla stałej  $c = 1/\log_b(a)$ .

- Inaczej mówiąc, wszystkie logarytmy (o podstawie większej niż 1) mają takie same asymptotyczne tempo wzrostu.
- Dlatego w asymptotycznych notacjach ( $O$ ,  $\Omega$ ,  $\Theta$ ) pomija się w zapisie podstawy logarytmów, np.  $\log_2(n) = \Theta(\log(n))$ .

- Dla dowolnych  $a > 1$ ,  $b > 1$ , zachodzi  $\log_a(n) = \Theta(\log_b(n))$ .
- Powyższy fakt wynika wprost ze wzoru na zmianę podstawy logarytmu

$$\log_a(n) = \frac{\log_b(n)}{\log_b(a)} = c \log_b(n)$$

dla stałej  $c = 1/\log_b(a)$ .

- Inaczej mówiąc, wszystkie logarytmy (o podstawie większej niż 1) mają takie same asymptotyczne tempo wzrostu.
- Dlatego w asymptotycznych notacjach ( $O$ ,  $\Omega$ ,  $\Theta$ ) pomija się w zapisie podstawy logarytmów, np.  $\log_2(n) = \Theta(\log(n))$ .

- Dla dowolnych  $a > 1$ ,  $b > 1$ , zachodzi  $\log_a(n) = \Theta(\log_b(n))$ .
- Powyższy fakt wynika wprost ze wzoru na zmianę podstawy logarytmu

$$\log_a(n) = \frac{\log_b(n)}{\log_b(a)} = c \log_b(n)$$

dla stałej  $c = 1/\log_b(a)$ .

- Inaczej mówiąc, wszystkie logarytmy (o podstawie większej niż 1) mają takie same asymptotyczne tempo wzrostu.
- Dlatego w asymptotycznych notacjach ( $O$ ,  $\Omega$ ,  $\Theta$ ) pomija się w zapisie podstawy logarytmów, np.  $\log_2(n) = \Theta(\log(n))$ .

- Dla dowolnych  $a > 1$ ,  $b > 1$ , zachodzi  $\log_a(n) = \Theta(\log_b(n))$ .
- Powyższy fakt wynika wprost ze wzoru na zmianę podstawy logarytmu

$$\log_a(n) = \frac{\log_b(n)}{\log_b(a)} = c \log_b(n)$$

dla stałej  $c = 1/\log_b(a)$ .

- Inaczej mówiąc, wszystkie logarytmy (o podstawie większej niż 1) mają takie same asymptotyczne tempo wzrostu.
- Dlatego w asymptotycznych notacjach ( $O$ ,  $\Omega$ ,  $\Theta$ ) pomija się w zapisie podstawy logarytmów, np.  $\log_2(n) = \Theta(\log(n))$ .



Wybrane funkcje wypisane w takiej kolejności, że każda kolejna jest co najmniej (ale nie dokładnie) rzędu poprzedniej:

| funkcja     | nazwy powiązanej złożoności obliczeniowej i przykłady algorytmów o złożoności czasowej takiego rzędu |
|-------------|--|
| 1           | stała; niezależna od wielkości danych wejściowych  |
| $\log(n)$   | logarytmiczna; np. wyszukiwanie binarne  |
| $\sqrt{n}$  |  |
| $n$         | liniowa; np. wyszukiwanie w nieuporządkowanej tablicy  |
| $n \log(n)$ | liniowo-logarytmiczna; np. minimalna złożoność czasowa sortowania przez porównywanie                 |
| $n^2$       | kwadratowa; np. naiwne algorytmy sortowania  |
| $n^3$       | sześcienne   |
| $2^n$       | wykładnicza (o podstawie 2)  |
| $3^n$       | wykładnicza (o podstawie 3)  |
| $n!$        |  |

Ogólnie funkcje (oraz złożoności) postaci  $n^c$  (dla  $c > 0$ ) nazywamy wielomianowymi (mówimy: algorytm wielomianowy; działa w czasie wielomianowym), zaś  $c^n$  (dla  $c > 1$ ) wykładniczymi.

- Thomas H. Cormen, Charles E. Leiserson, Roland L. Rivest, Clifford Stein *Wprowadzenie do algorytmów*
- L. Banachowski, K. Diks, W. Rytter *Algorytmy i struktury danych*, Wydawnictwa Naukowo-Techniczne, 2006.
- K. Diks, A. Malinowski, W. Rytter, T. Waleń *Algorytmy i struktury danych/Wstęp: poprawność i złożoność algorytmu*, WWW:  
[http://wazniak.mimuw.edu.pl/index.php?title=Algorytmy\\_i\\_struktury\\_danych/Wst%C4%99p:\\_poprawno%C5%9B%C4%87\\_i\\_z%C5%82o%C5%BCono%C5%9B%C4%87\\_algorytmu](http://wazniak.mimuw.edu.pl/index.php?title=Algorytmy_i_struktury_danych/Wst%C4%99p:_poprawno%C5%9B%C4%87_i_z%C5%82o%C5%BCono%C5%9B%C4%87_algorytmu)
- M. Sydow *Algorytmy i Struktury Danych*, prezentacje:
  - *Poprawność Algorytmów*, WWW:  
<http://users.pja.edu.pl/~msyd/wyka-pl/correctness1-pl.pdf>
  - *Złożoność Obliczeniowa Algorytmów*, WWW:  
<http://users.pja.edu.pl/~msyd/wyka-pl/complexity2-pl.pdf>