

# Základy algoritmizace

## 10. Složitost a výkon

doc. Ing. Jiří Vokřínek, Ph.D.

Katedra počítačů

Fakulta elektrotechnická

České vysoké učení technické v Praze

# Základy algoritmizace

- Dnes:
  - Složitost algoritmů
  - Složitost a typy úloh
  - Porovnání složitosti
  - Skutečný výkon, profilování

# Algoritmus

- Algoritmus je konečná posloupnost kroků vedoucí k řešení problému
  - Hromadnost a univerzálnost – řešení třídy úloh
  - Determinovanost – jednoznačný výsledek kroku, jak se bude pokračovat
  - Konečnost – skončí po konečném počtu kroků
  - Rezultativnost – vždy vrátí výsledek (třeba chybu)
  - Korektnost – výstup algoritmu je řešením problému (tj. výsledek je správný)
  - Opakovatelnost – stejný vstup vede pokaždé na stejný výstup

# Popis algoritmu

- Definice vstupů
- Definice výstupů
  
- Příklad – Dijkstrův algoritmus
  - Vstup: graf (seznam hran), počáteční a cílový vrchol
  - Výstup: nejkratší cesta z počátečního do koncového vrcholu, délka cesty
  
  - Definice datových struktur vstupů a výstupů
  - Definice pomocných datových struktur při výpočtu
  
- Analýza vlastností algoritmu

# Správnost algoritmu

- Korektní – pro všechna přípustná data vede ke správnému výsledku
- Parciálně správný – pokud skončí, je výsledek správný
- Konečný – pro všechna přípustná data skončí po konečném počtu kroků

- Věta o zastavení – *Halting theorem*

*Neexistuje algoritmus, který by pro libovolné slovo  $w$  a libovolný algoritmus  $A$  rozhodl, zda se  $A$  při vstupu  $w$  zastaví, či ne.*

*Je možné otestovat algoritmus pro všechny přípustné vstupy?*

# Ukazatele kvality algoritmů

- Operační složitost
- Paměťová složitost

## Příklad – sekvenční hledání

```
def searchLinear(array, val):  
    for i in array:  
        elem = array[i]  
        if elem == val: return elem
```

- Nejhorší případ – algoritmus proběhne  $n$  krát
- Paměťová náročnost – řídicí proměnná  $i$

# Ukazatele kvality algoritmů

## Příklad – hledání binárním půlením

```
def binSearch(array, val):  
    l, r = 0, len(array) - 1  
    while r >= l:  
        i = int((l + r) / 2)  
        if val == array[i]: return array[i]  
        if val > array[i]:  
            l = i + 1  
        else:  
            r = i - 1
```

- Nejhorší případ – cyklus proběhne  $\log_2(n)$  krát
- Paměťová náročnost – navíc proměnné  $l$  a  $r$
- Vyhledávací pole musí být uspořádané

# Ukazatele kvality algoritmů

## ■ Příklad – tisk Fibonacciho posloupnosti

```
def fibonacci(n):  
    if n<2: return 1  
    return fibonacci(n-1)+fibonacci(n-2)  
  
def printFib1(n):  
    for i in range(n): print(fibonacci(i))  
  
def printFib2(n):  
    fib = 1  
    fibM1 = 0  
    for i in range(n):  
        print(fib)  
        fibM2 = fibM1  
        fibM1 = fib  
        fib = fibM1 + fibM2
```

*Diskutujte rozdíl složitosti algoritmů*



# Složitost algoritmu

- Časová složitost – doba provádění algoritmu
- Paměťová složitost – rozsah použité paměti
  
- Jak vyjádřit složitost algoritmu?
  - Doba výpočtu – závisí na rychlosti procesoru
  - Počet instrukcí – závisí na hardware počítače
  
- Složitost algoritmu se stanovuje teoretickým rozbořem činnosti algoritmu

*Závisí jen na velikosti vstupních dat*

# Složitost algoritmu

- Doba výpočtu – velikost vstupních dat  $n$
- Složitost algoritmu vyjádříme funkcí

$$T(n) = a \times f(n) + b,$$

kde

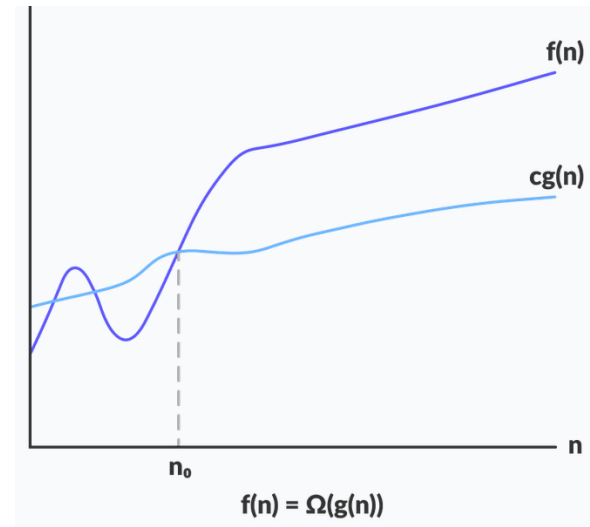
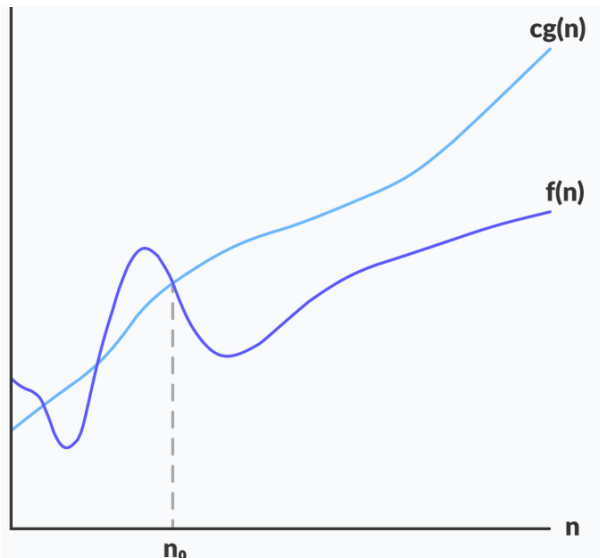
- $a$  je multiplikační konstanta
- $b$  je aditivní konstanta nezávislá na velikosti vstupních dat
- Obvykle je důležitý pouze typ závislosti (tvar funkce  $f(n)$ ), např:
  - Lineární –  $f(n) = n$
  - Polynomiální –  $f(n) = n^2$
  - Exponenciální –  $f(n) = 2^n$
- Efektivní algoritmy mají složitost maximálně polynomiální

# Asymptotická složitost

- Popisuje chování funkce  $T(n)$  pro velká  $n$
- Funkce  $f(n)$  je  $O(g)$ , jestliže existuje  $n_0 \in \mathbb{N}$  a  $c > 0$  takové, že pro všechna  $n \geq n_0$  je  $f(n) \leq cg(n)$

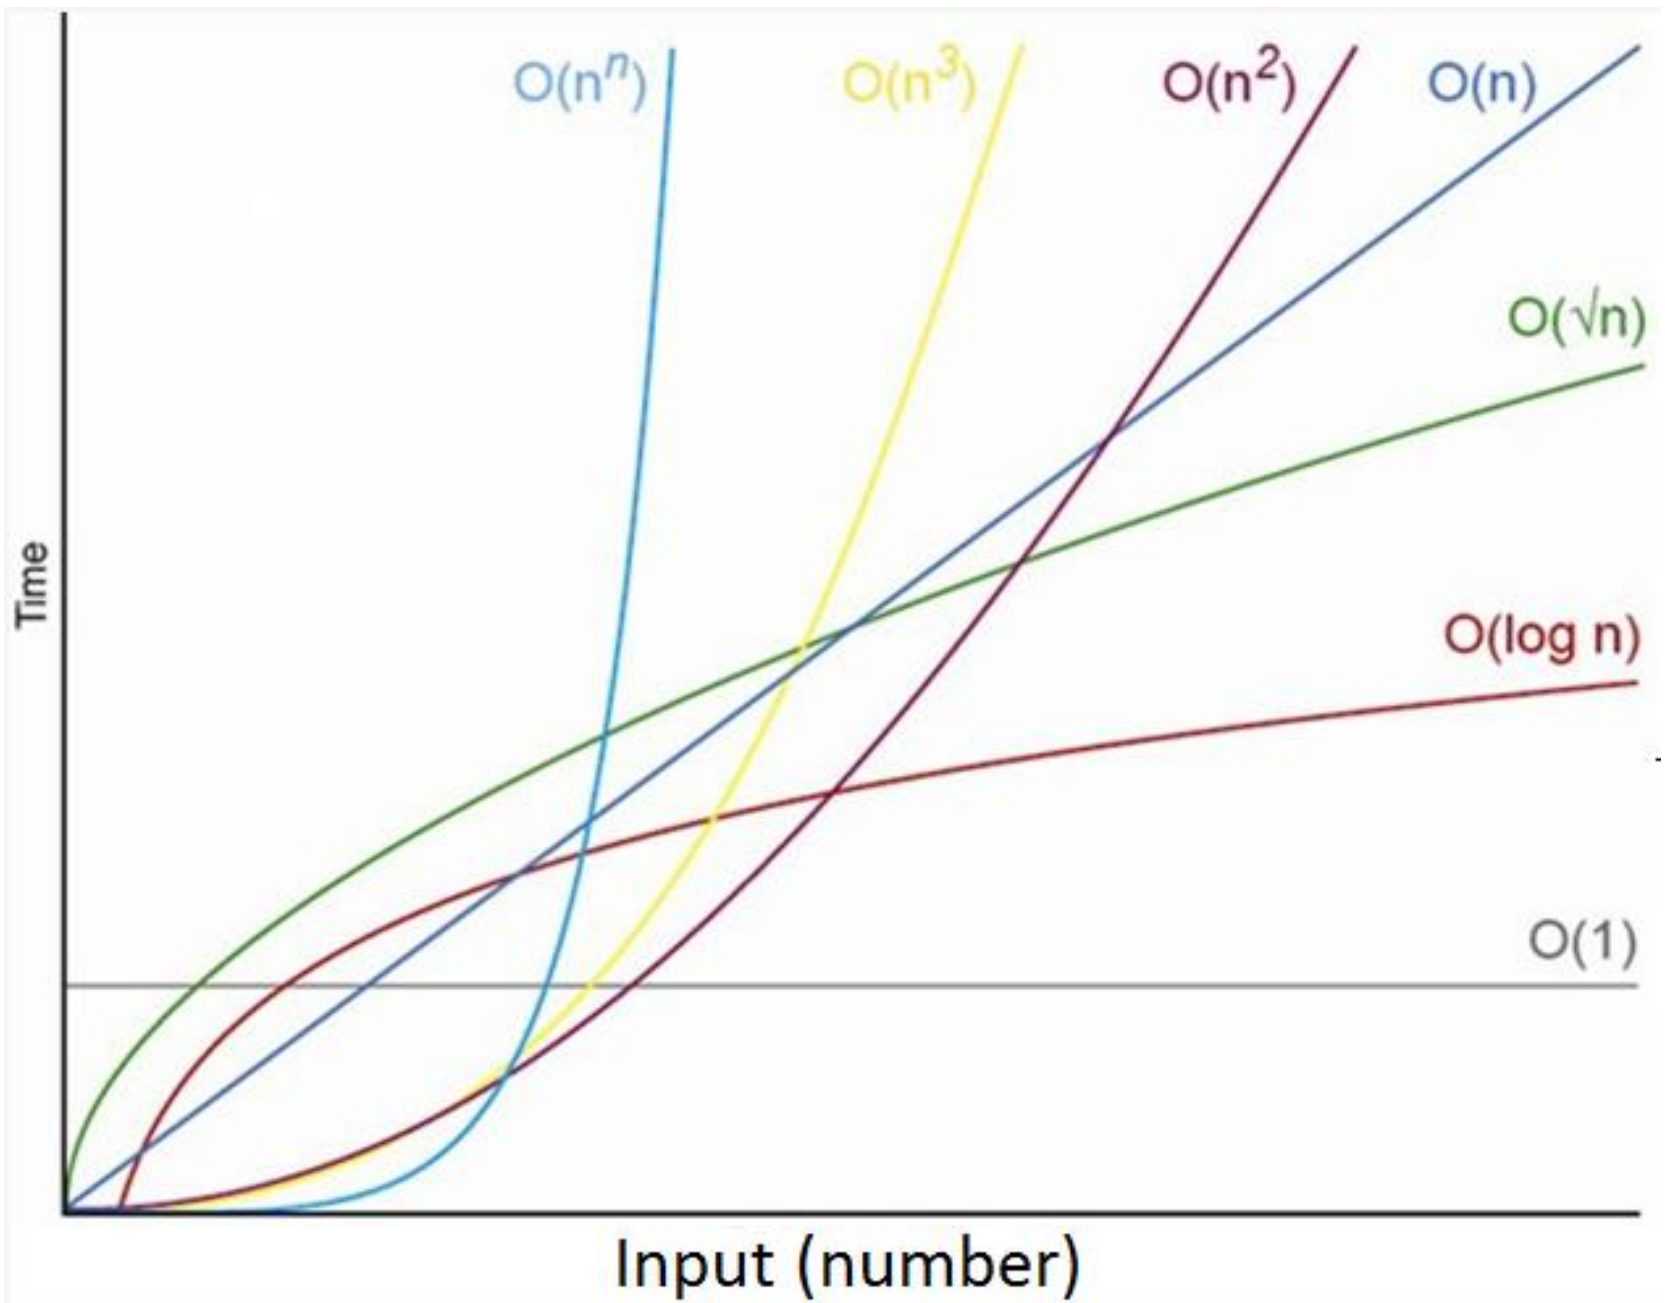
*Funkce  $f$  neroste rychleji než nějaký násobek funkce  $g$*

- Funkce  $f(n)$  je  $\Omega(g)$ , jestliže existuje  $n_0 \in \mathbb{N}$  a  $c > 0$  takové, že pro všechna  $n \geq n_0$  je  $f(n) \geq cg(n)$



# Asymptotická složitost

- Horní odhad složitosti  $T_{worst}(n)$  udává složitost algoritmu v nejhorším případě
- Algoritmus má složitost  $O(f(n))$  pokud funkce  $T_{worst}(n)$  je  $O(f(n))$
- Dolní odhad složitosti  $T_{best}(n)$  je nejkratší čas provedení pro ideální případy vstupních dat
- Střední (průměrný) odhad složitosti  $T_{avg}(n)$  je čas provedení pro „běžné“ případy vstupních dat



<https://randerson112358.medium.com/algorithm-analysis-time-complexity-simplified-cd39a81fec71>

# Asymptotická složitost

- Asymptotická složitost algoritmu  $O(f(n))$  charakterizuje chování algoritmu pro **velká**  $n$
- **Není závislá na**
  - Hardware počítače
  - Programovacím jazyce
  - Překladači
  - Schopnostech programátora (?)

- **Jaká  $n$  jsou velká?**


*Algoritmus s horší složitostí může fungovat lépe pro malé instance*

- **Praktický vliv mají faktory uvedené výše, typ a reprezentace dat, atp.**

# Asymptotická složitost

- Pro každý algoritmus můžeme analyzovat jeho složitost

*Přehled například na <http://bigocheatsheet.com/>*



# Asymptotická složitost

- Pro každý algoritmus můžeme analyzovat jeho složitost

*Přehled například na <http://bigocheatsheet.com/>*

## Array Sorting Algorithms

Algorithm	Time Complexity			Space Complexity
	Best	Average	Worst	Worst
<u>Quicksort</u>	$\Omega(n \log(n))$	$\Theta(n \log(n))$	$O(n^2)$	$O(\log(n))$
<u>Mergesort</u>	$\Omega(n \log(n))$	$\Theta(n \log(n))$	$O(n \log(n))$	$O(n)$
<u>Timsort</u>	$\Omega(n)$	$\Theta(n \log(n))$	$O(n \log(n))$	$O(n)$
<u>Heapsort</u>	$\Omega(n \log(n))$	$\Theta(n \log(n))$	$O(n \log(n))$	$O(1)$
<u>Bubble Sort</u>	$\Omega(n)$	$\Theta(n^2)$	$O(n^2)$	$O(1)$
<u>Insertion Sort</u>	$\Omega(n)$	$\Theta(n^2)$	$O(n^2)$	$O(1)$
<u>Selection Sort</u>	$\Omega(n^2)$	$\Theta(n^2)$	$O(n^2)$	$O(1)$
<u>Tree Sort</u>	$\Omega(n \log(n))$	$\Theta(n \log(n))$	$O(n^2)$	$O(n)$
<u>Shell Sort</u>	$\Omega(n \log(n))$	$\Theta(n(\log(n))^2)$	$O(n(\log(n))^2)$	$O(1)$
<u>Bucket Sort</u>	$\Omega(n+k)$	$\Theta(n+k)$	$O(n^2)$	$O(n)$
<u>Radix Sort</u>	$\Omega(nk)$	$\Theta(nk)$	$O(nk)$	$O(n+k)$
<u>Counting Sort</u>	$\Omega(n+k)$	$\Theta(n+k)$	$O(n+k)$	$O(k)$
<u>Cubesort</u>	$\Omega(n)$	$\Theta(n \log(n))$	$O(n \log(n))$	$O(n)$



# Asymptotická složitost

- Pro každý algoritmus můžeme analyzovat jeho složitost

*Přehled například na <http://bigocheatsheet.com/>*

## Common Data Structure Operations

Data Structure	Time Complexity								Space Complexity
	Average				Worst				Worst
	Access	Search	Insertion	Deletion	Access	Search	Insertion	Deletion	
<u>Array</u>	$\theta(1)$	$\theta(n)$	$\theta(n)$	$\theta(n)$	$O(1)$	$O(n)$	$O(n)$	$O(n)$	$O(n)$
<u>Stack</u>	$\theta(n)$	$\theta(n)$	$\theta(1)$	$\theta(1)$	$O(n)$	$O(n)$	$O(1)$	$O(1)$	$O(n)$
<u>Queue</u>	$\theta(n)$	$\theta(n)$	$\theta(1)$	$\theta(1)$	$O(n)$	$O(n)$	$O(1)$	$O(1)$	$O(n)$
<u>Singly-Linked List</u>	$\theta(n)$	$\theta(n)$	$\theta(1)$	$\theta(1)$	$O(n)$	$O(n)$	$O(1)$	$O(1)$	$O(n)$
<u>Doubly-Linked List</u>	$\theta(n)$	$\theta(n)$	$\theta(1)$	$\theta(1)$	$O(n)$	$O(n)$	$O(1)$	$O(1)$	$O(n)$
<u>Skip List</u>	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$O(n)$	$O(n)$	$O(n)$	$O(n)$	$O(n \log(n))$
<u>Hash Table</u>	N/A	$\theta(1)$	$\theta(1)$	$\theta(1)$	N/A	$O(n)$	$O(n)$	$O(n)$	$O(n)$
<u>Binary Search Tree</u>	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$O(n)$	$O(n)$	$O(n)$	$O(n)$	$O(n)$
<u>Cartesian Tree</u>	N/A	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	N/A	$O(n)$	$O(n)$	$O(n)$	$O(n)$
<u>B-Tree</u>	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(n)$
<u>Red-Black Tree</u>	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(n)$
<u>Splay Tree</u>	N/A	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	N/A	$O(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(n)$
<u>AVL Tree</u>	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(\log(n))$	$O(n)$
<u>KD Tree</u>	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$\theta(\log(n))$	$O(n)$	$O(n)$	$O(n)$	$O(n)$	$O(n)$

# Složitost úlohy

- Úloha má horní odhad složitosti  $f(n)$ , jestliže existuje algoritmus řešící úlohu s časovou složitostí  $O(f(n))$
- Úloha má dolní odhad složitosti  $g(n)$ , jestliže pro každý algoritmus řešící úlohu platí  $T_{worst}(n)$  je  $\Omega(g(n))$
- Algoritmus je optimální pro danou úlohu, jestliže neexistuje jiný algoritmus, který by úlohu řešil v nejhorším případě s menším počtem základních operací
- **Asymptoticky stejná složitost** –  $f(n)$  a  $g(n)$  jsou asymptoticky stejné, pokud

$$\exists c_1, c_2 > 0, \exists n_0 > 0, \forall n \in \mathbb{N}, n > n_0 : 0 \leq c_1 g(n) \leq f(n) \leq c_2 g(n)$$

# Složitost a typy úloh

# Typ a instance úlohy

- Typ úlohy je určen
  - Způsobem, jak je úloha zadána (vstup)
  - Co má být výsledkem (výstup)
  - Jaký je vztah mezi vstupem a výstupem
- **Instance úlohy** je případ úlohy daného typu
- Pro daný typ úlohy hledáme algoritmus, který jej řeší
- Pro instanci úlohy hledáme implementaci algoritmu (výpočet)

# Složitost úloh – P a NP úlohy

- Rozhodovací úloha – řešením je odpověď **ano** nebo **ne**
- Každou optimalizační úlohu lze převést na rozhodovací
- Příklad – obchodní cestující (TSP)
  - Optimalizační verze – nalezněte trasu nejkratší délky
  - Rozhodovací verze – existuje trasa délky menší než  $K$ ?
- **Třída P** – třída všech rozhodovacích úloh  $U$ , pro něž existuje polynomiální algoritmus řešící  $U$
- **Třída NP** – třída všech rozhodovacích úloh  $U$ , pro něž existuje nedeterministický algoritmus pracující v polynomiálním čase
  - Nedeterministická fáze – náhodný řetězec symbolů  $s$
  - Deterministická fáze – deterministický algoritmus má na vstupu instanci úlohy a řetězec  $s$

# NP úlohy

Rozhodovací úloha patří do třídy NP, existuje-li pro ni ověřovací algoritmus s vlastnostmi:

- Vstupem jsou data popisující instanci úlohy délky  $d$  a *certifikát* jehož velikost je polynomiálně omezena  $d$
- Pracuje v polynomiálním čase a vždy dává odpověď „ano“ nebo „nevím“
- Pro instanci úlohy, pro kterou je správná odpověď „ano“ existuje takový certifikát, že ověřovací algoritmus vrátí „ano“
- Pro instanci úlohy, pro kterou je správná odpověď „ne“ dává ověřovací algoritmus vždy „nevím“

# NP úlohy

- Příklad – hledání hamiltonovské kružnice
  - Vstupem je graf
  - Certifikát je kružnice
  - Ověřovací algoritmus testuje, zda-li kružnice opravdu prochází přes všechny vrcholy
- Ověřovací algoritmus může být jednoduchý, ale nalézt certifikát je obtížné
- Důsledek
  - NP úlohy lze ověřit v polynomiálním čase
  - Nevíme zda je lze také v polynomiálním čase vyřešit


# NP úlohy

- Redukce úloh
  - Úloha  $U$  se redukuje na úlohu  $V$ , jestliže existuje algoritmus  $A$ , který pro každou instanci úlohy  $U$  zkontroluje instanci  $A(I)$  úlohy tak, že  $I$  je „ano“ instance  $U$ , právě tehdy když  $A(I)$  je „ano“ instance  $V$
- Polynomiální redukce –  $A$  je polynomiální
- **NP-úplná** (complete) úloha je úloha, která je NP úlohou a každá NP úloha se na ní polynomiálně redukuje
- **NP-C** je třída všech NP-úplných úloh
- **NP-těžká** (hard) úloha je úloha, na kterou se polynomiálně redukuje každá NP-úloha
- Obecně se má za to, že  $P \neq NP$



# Složitost úloh – P a NP úlohy

- **P** – dají se řešit rychle (v rámci možností, viz. „big O“)
- **NP** – dají se rychle ověřit, těžší na řešení
- **NP-C** – jako NP + redukce
- **NP-těžká**
  - Těžko se řeší
  - Těžko se ověřují
  - Redukce



<https://www.baeldung.com/cs/p-np-np-complete-np-hard>

# NP úlohy

- Úlohy ze třídy NP-C jsou z hlediska obtížnosti ekvivalentní
- Existuje-li polynomiální algoritmus, který řeší kteroukoliv úlohu z NP-C, pak  $P = NP$

*Do té doby považujeme NP-C úlohy za „polynomiálně neřešitelné“*

- NP-těžká úloha nemusí být ve třídě NP – může být těžší
  - NP-těžké optimalizační úlohy mohou mít rozhodovací verze ve třídě NP

*Záleží na formulaci úlohy, certifikát požadujeme pouze pro kladnou odpověď*

- Speciální případy NP-těžkých úloh mohou být polynomiální

*Např. watchman route problem, touring polygons problem*

# NP úlohy

- Praktický význam NP úloh
  - Hledání polynomiálního algoritmu?
  - NP-těžké úlohy jsou těžké – proto je nutné volit vhodný kompromis mezi rychlostí nalezení řešení a kvalitou řešení
  - Malé instance NP-těžkých úloh lze řešit metodou hrubé síly (brute force)
  - Aproximace a heuristické algoritmy (AI)
- Paměťová náročnost – třída P SPACE
  - Jestliže existuje deterministický algoritmus řešící úlohu  $U$  a má paměťovou složitost nejhoršího případu  $O(p(n))$  pro nějaký polynom  $p(n)$

$$P \subseteq NP \subseteq PSPACE$$

# Skutečný výkon

# Skutečný výkon programu

- Skutečný výkon programu (implementace, nikoli algoritmu!) závisí na mnoha faktorech:
  - Hardware počítače
  - Programovacím jazyce
  - Překladači
  - Schopnostech programátora
  - Representace dat
- Vstupní data – mohou být předzpracovaná
  - Př. vyhledávání v seřazeném poli
- Vhodná volba pomocných struktur
  - Př. prioritní fronta v hledání nejkratších cest
- Specializace na konkrétní vstup (restrikce úlohy)

# Skutečný výkon programu

- V praxi nás typicky zajímá jak rychle daný program běží v závislosti na ostatní činnosti
- Například:
  - Zpracování log. souboru 1x za den může trvat 10 minut
  - Zpracování 100 log. souborů 2x za den nemůže trvat 10 minut
  - Výpočet reakce robotu pohybujícího se 3m/s za 50ms je pomalý ( $50 \text{ ms} \approx 15 \text{ cm}$ )
- Algoritmus o známé složitosti se dá naprogramovat různě
  - Využití znalosti HW, kompilátoru apod.
  - Efektivní správa paměti, znalost náročnosti systémových volání
  - Měření a optimalizace výkonu v reálných podmínkách (cílové zařízení, reálná vstupní data)

# Pravidlo 80/20

- 80% strojového času je stráveno vykonáváním 20% zdrojového kódu
- Postup optimalizace
  1. Identifikace nejčastěji prováděného kódu
  2. Optimalizace kódu
  3. Ověření správné činnosti

*Podobně pro využití paměti*

- Profilování je porozumění chování programu za běhu

*Identifikace jak dlouho která část programu trvá*
- „Profile“ je množina frekvencí přiřazená pozorovaným událostem za běhu programu

*Profil programu je závislý na konkrétních vstupech*

# Měření času

- Čas běhu programu – reálný, uživatelský, systémový
- Vlastní měření času v programu

*V pythonu knihovna datetime*

- Profiler – nástroj jak získat profil
  - Transparentnost
  - Efektivita
  - Přesnost
- Profilovací techniky
  - Hardwarové – není nutné modifikovat zdrojový kód
  - Softwarové – Profiler příslušně modifikuje kód




# Profilování – plošný profil

Statistics Call Graph

Function	Call Count	Time (ms)	
clear	2145	1800942.9%	1778142.3%
<select.select>	1521	1083425.8%	1083125.8%
__setitem__	78946	1582 3.8%	1529 3.6%
errcheck	149268	1273 3.0%	1273 3.0%
draw	6434	1645 3.9%	747 1.8%
flip	2145	492 1.2%	488 1.2%
normalize	189873	529 1.3%	394 0.9%
set_3d	2145	516 1.2%	339 0.8%
get_region	80288	1124 2.7%	333 0.8%
_set_attribute_data	80288	3233 7.7%	326 0.8%
cast	84556	293 0.7%	293 0.7%
__init__	80288	256 0.6%	256 0.6%
draw	2043	623 1.5%	256 0.6%
collide	14744	283 0.7%	239 0.6%
cube_vertices_new	41516	215 0.5%	215 0.5%
get_region	80288	704 1.7%	201 0.5%
add_block	91402	752 1.8%	186 0.4%
<method 'remove' of 'list' objects>	8194	147 0.3%	147 0.3%
_parse_data	39921	175 0.4%	142 0.3%
draw label	2145	1842 4.4%	139 0.3%

# Profilování – graf volání



# Základy algoritmizace

- Dnes:
  - Složitost algoritmů
  - Složitost a typy úloh
  - Porovnání složitosti
  - Skutečný výkon, profilování

**Příště** přehled programovacích jazyků