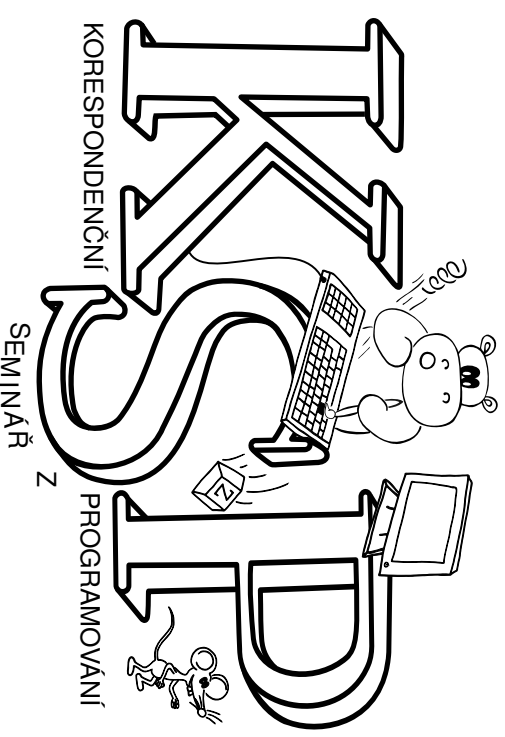


Dokud existují počítače, bude existovat i KSP!





Toužíš po nových vědomostech?

Chceš poznávat nové lidi?

Zajímáš se o počítače?

Láká Tě trocha soutěžení?


Hledáš výzvu pro svou hlavu?



Byla Tvá odpověď alespoň jednou „ano“?

Pak hledáme právě Tebe. Do KSP

se může zapojit každý, tedy i Ty. Otoč list!



**Odpovědi**

**na vaše**

**kousavé**

**otázky**

## Co je KSP?

KSP je Korespondenční seminář z programování. Jak takový seminář funguje? Několikrát za rok vydáváme sérii obsahující různé úlohy a posíláme je řešitelům.

Ti mají několik týdnů na vymyšlení a odevzdání řešení. My je pak opravíme, okomentované a obodované pošleme zpět a zveřejníme autorovská řešení. KSP má dvě kategorie: Z pro začínající řešitele a hlavní kategorii H pro ty zkušenější, kde číhají záložnější úlohy.

## Kdo seminář organizuje?

Organizátoři jsou studenti Matematicko-fyzikální fakulty Univerzity Karlovy v Praze (MFF UK), většinou bývalí řešitelé.

## Co najdu v zadání?

Můžeš řešit teoretické a praktické úlohy. Vždy je důležité vymyslet postup (návod) jak nalézt řešení, například jak může počítač rychle najít nejkratší cestu z Kocourkova do Prač.

Součástí zadání jsou i studijní texty, jejichž přečtení Ti dá nástroje k řešení úloh. Kuchařky jsou krátké texty o různých tématech. Seriál pro zmněnu probere v průběhu roku jedno téma do hloubky.

## Jak úlohy vypadají?

V teoretických úlohách je třeba postup slovně popsat a odevzdat nám ho, my jej pak opravíme a okomentujeme.

V praktických úlohách nejde o popis, ale o výsledek. U úloh (jsou open-data) si stáhneš vstupní data, která zpracuješ. Tebou zvoleným způsobem, nejčastěji programem v libovolném programovacím jazyce. Výstup odevzdáš a hned vidíš, zda je výsledek správný.

## Vymyšlení mi nejde, co s tím?

V KSP-Z je také možné odevzdat praktické úlohy po termínu – ještě týden po zveřejnění slovních popisů řešení lze odevzdávat úlohy za třetího bodu. Teprve poté se objeví i zdrojové kódy.

## Proč mám KSP řešit?

Báhem řešení KSP se naučíš programovat. To se Ti může v životě hodit, obzvlášť pokud se chceš stát programátorem. ;)

Díky KSP můžeš poznat informatiku v celé její kráse – mocné programy, magické datové struktury... prostě to, co se ve škole nedozvíš.

To může být užitečné nejen při řešení matematické olympiády kategorie P. Navíc nejlepší řešitelé zvrme na soustředění, kde můžeš poznat nové kamarády.

Také pokud se staneš úspěšným řešitelem hlavní kategorie, vezmou Te na Matfyz bez přijímaček.

## Hmmm... soustředění?

Jsou dvě, jarní především pro řešitele KSP-Z a podzimní pro řešitele hlavního KSP. Obě jsou týdenní akcí plnou přednášek a zážitků, kterou určitě stojí za to zažít.

## Dostanu i něco hmotnějšího?

Ano, pokud se dostaneš mezi ty nejlepší. Tři nejlepší řešitelé si budou moci vybrat jako odměnu knížku nebo například tričko, hrneček, hrocha.

## Vůbec nevím, jak začít...

Inu, žádný učení z nebe nespadá, chce to studovat a zkoušet. ;) Dobrým odrazovým můstkem může být naše Encyklopedie, jejíž součástí jsou i kuchařky včetně úplných základů.

S výběrem Ti může pomoci i bodování – lehcí úlohy bývají většími za méně bodů.

## Napadá mě jen špatné řešení

Tak prostě odevzdej i to. :) Špatné, pomalé nebo neúplné řešení je lepší než žádné. Za nedokonalá řešení u teoretických úloh hlavy rozhodně netrháme. Naopak, pokusíme se Ti poradit, co zlepšit. U praktických úloh zase bývá několik vstupů malých, takže za ně získáš část bodů i s jednodušším řešením.

## Co když mi něco není jasné?

Klídně se nás ptej. Na dotazy k úlohám se nejvíce hodí naše diskusní fórum. Podrobnosti o fungování semináře nalezneš na webu. A budeš-li mít stále nějakou otázku, čteně mail a jsme na Facebooku.

### Zadání

KSP-Z: <http://ksp.mff.cuni.cz/z/>

KSP-H: <http://ksp.mff.cuni.cz/>

### Studijní texty

<http://ksp.mff.cuni.cz/encyklopedie/>



# Korespondenční Seminář z Programování

32. ročník

KSP

Září 2019

## Milí řešitelé, řešitelky a řešitelčata!

Právě se k vám dostává první číslo jubilejního ročníku KSP – ano, KSP letos slaví 25 let své existence a toto kulaté číslo si určitě zaslouží pozornost.

Letos se můžete těšit v každé z pěti sérií hlavní kategorie na: **5 normálních úloh**, z toho alespoň jedna praktická open-data, **seriál o zpracování dat** jako 6. úlohu a kuchařku na nějaké zajímavé informatické téma hodící se k úlohám dané série.

Do celkového hodového hodnocení se z každé série stále započítává **5 nejlépe vyřešených úloh** (tedy nemusíte vyřešit úplně všechny a i tak můžete dosáhnout na plný počet bodů). Také se vám body za úlohy **připočítávají podle vašeho služebního stáří** – na přesnou definici se podívejte do pravidel na našem webu.



### Odměny & Na Matfyz bez příjímáček

Za úspěšné řešení KSP můžete být **přijati na MFF UK bez přijímacích zkoušek**. Úspěšným řešitelem se stává ten, kdo získá za celý ročník (tj. do kategorie) alespoň 50 % bodů. Za letošní rok přijde získat maximálně 300 bodů, takže hranice pro úspěšné řešitele je 150. Maturovatí pozor, pokud chcete promítnutí využít letos, musíte to stihnout do konce čtvrté série, pátá už bude moc pozdě. Také každému řešiteli, který v tomto ročníku z každé série dostane alespoň 5 bodů, darujeme KSP propisku, blok, plátek a možná i další překvapení.

**Termín série: 21. října 2019 v 8:00**

**Odezváváni:** Přes web na adrese <https://ksp.mff.cuni.cz/submit/>

**Značky úloh:** Lehčí úloha (či její část) vhodná pro začátečníky

Těžká úloha pro zkušené

Úloha, u které doporučujeme začít se do kuchařky

Praktická open-data úloha

Seriálová úloha

**Odměna série:** Každému, kdo vyřeší 4 úlohy alespoň na polovině bodů, pošleme **sladkou odměnu**.

## První série třicátého druhého ročníku KSP

*Hládková loď se po dvou týdnech letu vyloupla z hyperprostoru a její výkonné senzory začaly zaznamenat takle zapadlou hvězdnou soustavu, mezitím co jí z cívek motorů postupně uvažovaná zbytková energie přechodu do normálního prostoru. Na palubě neměla moc velkou posádku – pouhých deset členů – ale to by mělo na tuto misi bohatě stačit.*

*Místní kolonie se před šestnácti dny přestala ozývat, poslední zachycená zpráva hovořila o nějakých technických problémech. Proto taky z Antaranu, nejbližší velké lidské zvláštní, vysílá Helpašťa jako rychlou službu a hládkovou loď, aby zjistila, co se děje.*

*Kapitánka Larsen se otočila na svého komunikačního specialistu, jediné nepozemšťana v posádce: „Začn, vysílá zblázněná něco alespoň na polostředně komunikaci?“ „Zkoumám skypere... moment, něco jsem zachytili... automatická zpráva, ale je nějaká zkomolená, akustm ji vyřlířovat.“*

### 32-1-1 Zkomolené vysílání 9 bodů

Hládková loď Helpaštos zachytila několik zpráv od lidské tomantické zprávy, kde každá z nich byla vysílána dvakrát po sobě, ale zavadou na vysílání obsahuje nějaký signál navíc.

Přesněji řečeno základna chtěla vyslat zprávu X (sestaví se jen z velkých písmen anglické abecedy), a to tak, že ji vysílala dvakrát zopakovanou za sebou, ale do tohoto řetězce se na náhodnou pozici vmislo jedno písmenko navíc. Přihládkem může být původní zpráva ABC a vysílání ABCAMBC.

*Úložkový vstup:* *Úložkový výstup:*

3	ABC
7	ABCAMBC
6	UVWXYZ
9	ABABABBA

*„Mam to!“ zvolal náhle Zar a celá čtyřčlenná posádka mšusku se mu nábrnula za konzolu, na které stáli napsá: **SELHANI SITTU BEHEM IONTOVE BOURE, DUVOO NEZMANY, VETSTINA KOLONISTU UKRYTA VE SKLADU 3. ZADANE O POMOC.***

Lokálně nejlepší řešení je takové, které v aktuálním kroku vybere tu možnost, která nám na tomto místě nejvíce pomůže (bez jakéhokoli ohledu na globální stav). Může to být třeba nejvyšší hodnota, nebo nejkratší cesta v grafu. Pokud ale od hládkového algoritmu chceme, aby nám našel globálně nejlepší řešení, musí naše úloha splnit předpoklad, že si vyberem lokálně nejlepšího řešení nezhoršujeme to globální. Tento předpoklad se nedá formulovat obecně a je nutné se nad ním zamyslet zvlášť u každé úlohy.

### Příklady hládkových algoritmů

První hládkovou úlohou bude (jak jinak) automat na jítlo vracující mince. Automat by měl vracet peníze nazpět tak, aby vrátil daný obnos v co možná nejmenším počtu mincí. Pro náš měnový systém (máme mince hodnot 1, 2, 5, 10, 20 a 50 Kč) lze tuto úlohu řešit hládkovým algoritmem – v každém kroku algoritmu vrátíme tu největší minci, kterou můžeme (tedy pro vrácení 42 Kč to bude 42 = 20 + 20 + 2Kč).

Měnové systémy většiny států jsou postavené tak, aby fungovaly takto pokate, neplatí to ale obecně. Zkusme si vrátit 42 Kč, pokud bytloem měli jen mince hodnoty 20, 10 a 4Kč. Správným řešením je 42 = 20 + 10 + 4 + 4 + 4Kč, hládkový algoritmus by ale zkusil vrátit 42 = 20 + 20 + ... a tedy by selhal.

Dále se velmi často dají hládkovým algoritmem řešit nějaké úlohy přidávání nebo odebrání skupin prvků. Typickým příkladem je třeba rozvržení naplánovaných přednášek do učeben. Setradme si začítky přednášek podle času a postupně bereme jednu za druhou a umisřujeme je do volných učeben s nejmenším číslem.

Tim jsme si určité nic nerozhlili, protože v nějaké učebně přednáška být musí. Určitě budeme potřebovat tolik učeben, kolik je maximálně přednášek v jeden čas, a díky tomu si umístěním přednášky do nějaké učebny nezahlokájeme místo pro jinou přednášku, jelikož nám vždy zbudete dostatek volných učeben.

Kdybychom ale naopak měli pevně zadaný počet učeben a chceli jsme do nich umístit co možná nejvíce přednášek, nejedná se již o úlohu řešitelnou hládkovým algoritmem, v takovém případě je potřeba zvolit nějaký čtyřčíslejší postup.

### Závěr

Doufám, že jste si z tohoto rozsáhlého textu odnesli nějaké nové znalosti a poznatky, které vám pomohou nejen v řešení KSP.

Pokud jste začínajícími řešiteli, zkuste s pomocí kuchařky vyřešit několik lehkých úloh a jejich řešení poslat – nové nabyté znalosti je totiž nejlepší co nejdříve protrainovat. Nic si nedělejte z toho, pokud nappoprvé nevyřešíte všechno, s postupným zkoušením se budou vaše znalosti jen zlepšovat. Zkušenější řešitelé možná v kuchařce nalezní nějaké ujasnění pojmu, či si některé techniky osvěžíli.

A pokud tento text považujete za dobrý, budeme jen rádi, pokud ho doporučíte svým kamarádům a spolužákům, kteří chtějí s programováním začít.

Úvodním kurzem vaření podle kuchařky vás provedl

*Jirka Semčička*



matfyz

KSP pro vás připravují studenti Matematicko-fyzikální fakulty Univerzity Karlovy.

### Webové stránky:

<https://ksp.mff.cuni.cz/>

### E-mail:

[ksp@mff.cuni.cz](mailto:ksp@mff.cuni.cz)

### Diskusní fórum:

<https://ksp.mff.cuni.cz/forum/>

Chcete-li s námi komunikovat bezpečně, můžete si ověřit náš HTTPS certifikát – jeho SHA1 fingerprint je: E9:DB:EE:C6:62:BC:14:DE:09:E4:E8:97:DC:36:0E:87:B3:50:BO:01.



```

do f
  int prostredni = (L+R)/2;
  x = pole[prostredni];
  if (x == hledane)
    printf("pole obsahuje hledane!\n");
  else if (x < hledane)
    L = prostredni + 1;
  else
    R = prostredni;
} while (L < R && x != hledane);
if (x != hledane)
  printf("Hledane není v poli!\n");

```

Ukazka v Pythonu jako funkce vracující index prvku nebo -1, pokud hledané číslo nenalezne:

```

def bin_vyhled(pole, hledane,
              levy_index=0, pravy_index=None):
    if pravy_index is None:
        pravy_index = len(pole)
    while levy_index < pravy_index:
        prostredni = (levy_index +
                    pravy_index) // 2
        x = pole[prostredni]
        if x < hledane:
            levy_index = prostredni + 1
        elif x > hledane:
            pravy_index = prostredni
        else:
            return prostredni
    return -1

```

# Zavolaňi:  
print(bin\_vyhled([1,2,5,7, 8,12,16,42], 1))

### Další aplikace

Další typickou aplikací postupu rozděl a panuj je například třídění posloupnosti pomocí *Mergesortu*. Ten v základě funguje tak, že každou posloupnost, kterou dostane k seřídění, rozdělí na poloviny a každou z nich seřídí rekurzivním zavoláním sebe sama. Zamotávání se zastaví ve chvíli, kdy třídíme posloupnosti délky jedna (a už je z podstaty seřídění). Pak jen v každém kroku ze dvou seříděných menších posloupností vytvoří jejich sléváním seřazenou posloupnost dvojnásobné délky.

Více se o metodě Rozděl a panuj můžete dozvědět ve stejnojmenné knihačce.<sup>16</sup>


### Předpočítané mezivýsledky

Motivací k této kapitole je následující motto: „Proč počítat něco vícekrát, když nám to stačí spočítat jednou a zapamatovat si to?“.

Velmi často se totiž setkáváme s tím, že něco počítáme stále dokola. Jako příklad si můžeme připomenout naši rekurzivní implementaci počítání Fibonacciho čísel zminěnou výše.

Když se podíváme na výpočet čísla  $f_{10}(5)$ , vidíme, že pro něj voláme  $f_{10}(4)$  a  $f_{10}(3)$ ,  $f_{10}(4)$  volá  $f_{10}(3)$  a  $f_{10}(2)$ ,  $f_{10}(3)$  volá  $f_{10}(2)$  a  $f_{10}(1)$  a tak dále. Všimni si, ko-likrát se nám tyhle výpočty opakují? Některá Fibonacciho čísla spočítáme totiž dříve než mnohokrát.

<sup>16</sup> <http://ksp.mff.cuni.cz/viz/kuchariky/rozdel-a-panuj>  
<sup>17</sup> <http://ksp.mff.cuni.cz/viz/kuchariky/dynamicke-programovani>



Kdybychom si je namísto opakovaného počítání nějaké pamatovali, mohli bychom pak odpovědět na dotaz na již vypočtené číslo vyřádnou jako káňka z klobouku v konstantním čase. Zavedením jednoho globálního pole, ve kterém si tyto hodnoty pro jednotlivá  $n$  budeme pamatovat, nám sníží časovou složitost z  $O(2^n)$  na pětkrát  $O(n)$ . Takovému postupu se obecně říká *dynamické programování*.

### Dynamické programování

Nejprve uvedme na pravou váhu výraz „dynamické“ v našem zvu. Nevysvětluje tak úplně podstatu této techniky a jeho historické pozadí je celkem složité, avšak dnes je tento název již tak zažitý, že se už pravděpodobně nezmění.

Slovo „dynamické“ částečně odkazuje na to, že se dynamiky (za běhu programu) postupně stávají řešenými složitějšími problémy, která jsou následně použita pro řešení složitějších. Jeho hlavní podstatou je tedy ukládání a opětovné použití již jednou vypočtených údajů.

Hodí se na tolu, které se dají dělit na podtituly, které jsou si podobné a mohou se opakovat. Výsledky takovýcht podtitulů si poté ukládáme a při dotazu na stejnou podtitulbu vrátíme jen uloženy výsledek a výpočet již nepovádáme.

Pro další prohloubení znalosti můžeme a na našem webu nacházet do další knihačky, tentokrát nesoucí (překvapivě) název Dynamické programování.<sup>17</sup>

### Předhové součty

Velmi často se nám hodí si ještě před samotným výpočtem předpočítat a uložit nějaké hodnoty, které poté použijeme. Představme si například problém nalezení souvislého úseku s největším součtem v nějaké posloupnosti kladných i záporných čísel. Ze to není úplně jednoduchý příklad, si ukážeme na následující posloupnosti:

1, -2, 4, 5, -1, -5, 2, 7

Máme zde dvě ryze kladné souvislé posloupnosti, každou se součtem 9 (4, 5 a 2, 7). Ale přesto je výhodnější vzít i nějaké záporné hodnoty a vytvořit tak souvislou posloupnost o součtu 12 (zakuste ji nalézt).


Mohlo by nás napadnout, že prostě zkusíme vzít všechny možné začátky a všechny možné konce. To nám dáva  $O(n^2)$  možných posloupností (máme  $n$  možných začátků a ke každému z nich řádové  $n$  možných konců), pro každou posloupnost si spočítáme součet (to zvládneme v  $O(n)$ ) a budeme si pamatovat ten největší nalezený. Celý náš postup tak trvá  $O(n^3)$ .

To není pro takhle jednoduchou úlohu zrovna ten nejlepší nástin, zkusme ho zlepšit. Ukážeme si, jak vypočítat sou-

čtyňka je zadána jako seznam energetických hodnot jednotlivých dílků. Spočítejte pro zadanou čtyňku  $s$   $D$  dílky strategii pro prvního kolonistu tak, aby získal dílky dohromady s co největší energetickou hodnotou. Předpokládáme, že druhý kolonista bude vždy hrát optimálně.

Vás algoritmus počítající strategii by zároveň měl dobhatnout v rozumné kratším čase (exponenciální čas vzhledem k  $D$  už je určitě příliš pomalý).

**Příklad:** Pro čtyňku s hodnotami 5, 15, 3, 1 je pro prvního kolonistu nejlepší vzít v prvním tahu dílek s hodnotou 1, i když by mohl vzít i dílek s hodnotou 5 – pokud vezme při prvním tahu dílek s hodnotou 1, tak získá celkově 16, pokud by ale v prvním tahu vzal dílek s hodnotou 5, tak při optimálním třech druhého kolonisty by oděšal nejvyšší s dílky v hodnotě 8.



Během následující hodiny distribuuovali mezi kolonisty několik beček nouzových zásob a mezím se dozvěděli o událostech, které se zde staly – vše začalo nebydla sítou iontovou bouří, během které vysadla komunikace. To by ještě nebylo nic divného, jenže pak začaly jeden po druhém selhávat spolu vůbec nesouvisející systémy základy, a nakonec selhal i několikrát zlobohnouty magnetický štít. Kolonisté se uchýlili do bezpečí krytu pod skladem číslo tři, ale ze sedmačtyřiceti kolonistů jich třináct během bouře zmizelo neznamo kam. Po týžnu vysadli i záložní zdroji budovy (i když podle jejich odhadu měly články vydržet přibližněm třem tři měsíce) a nakonec je objevil už vysadek z Heřfista.

Kapitánka nařídila oběma maršáčkům zabývat přístavní celou arelu základny a spolu s hlavními inženýrem a několika techniký z tříd kolonistů se vydala k hlavní budově základy. Po připojení energetického vedení z Heřfista sice budova ožila, ale jen v nouzovém režimu – zjistili, že centrální počítačové jádro je ugnazně. Nešťastí na základně byla na holografických médiích uskladněna i kopie operačního systému základy. Jenom její instalace chvíli zabere.

### 32-1-4 Instalace OS 9 bodů

Operační systém pro hlavní počítač základy se sestává z velkého počtu instalačních balíčků, které jsou nějakým způsobem rozděleny na čtyři holografických médiích.

Cílem je instalovat všechny balíčky, ale některé balíčky se nedají instalovat, dokud nejsou nainstalované nějaké jiné (například program pro ovládání dvou potřebné knihovny pro ovládání servomotorů). Obecně každý balíček může mít závislost na libovolném (n mulovém) počtu jiných balíčků. Navíc je silbemo, že závislosti nikdy netvoří cyklus (tedy

vždy existuje způsob, jak se dá operační systém nainstalovat).

Máme zadaná čísla  $k_1$  a  $k_2$ , která značí počty instalací balíčků na jednotlivých médiích. Instalaci balíčků jsou rozděleny hezky popořadě, tedy na prvním médiu jsou balíčky s čísly 1, 2, ...,  $k_1$  a na druhém balíčky s čísly  $k_1 + 1$ ,  $k_1 + 2$ , ...,  $k_1 + k_2$ . Celkový počet instalací balíčků je tedy  $k_1 + k_2$ . Dále známe  $Z$  závislosti, tedy např. že balíček 15 závisí na balíčku 38, a ten tedy musí být nainstalován dříve.

V mechanice pro čtení holografických médií může být v jednom chvíli pouze jedno médium.  $Z$  něj můžeme nainstalovat jakékoli balíčky, které už máme nainstalované. Pak musíme médium vyměnit za druhé, abychom mohli pokračovat v instalaci.

Pro zadané závislosti balíčků a jejich rozdělení na instalaci média najděte nejmenší nutný počet prohození instalačních médií, aby se nám povedlo instalovat všechny balíčky.

**Příklad:** Zavedme si značení  $a \rightarrow b$  znamenající, že balíček  $a$  závisí na balíčku  $b$  (tedy balíček  $b$  musí být instalovaný první). Pak pro holografické média s počty balíčků 3 a 3 (tedy média  $\{1, 2, 3\}$  a  $\{4, 5, 6\}$ ) a pro závislosti 2  $\rightarrow$  6, 3  $\rightarrow$  5 a 5  $\rightarrow$  2 potřebujeme 4 kroky: Nejdříve vložíme druhé médium a nainstalujeme balík 6; poté vložíme první médium a nainstalujeme balíky 1 a 2, poté opět vložíme druhé médium a nainstalujeme balíky 4 a 5 a nakonec vložíme opět první médium a nainstalujeme poslední balík 3.

Pro únorřem procesu instalace se povedlo hlavní počítač základy opět naložit. Postupně se začaly připravovat i jednotlivé budovy a po další hodině snhu se rozběhl i hlavní reaktor a základna tak přestala být závislá na „poučném štírě“ od Heřfista. Poškození základy od bouře bylo značné, ale nic neopravitelného. Nic však neuspěchovalo to množství poruch, které se vyskytly současně s bouří.

Například hlavní komunikační anténa se prostě propadla do země a zhorčila se jako už ze stryk, generátor magnetického štítu vybuchl a s pulkov budovy a třeba záložní generator v hlavní budově zmláz úplně.

V troskách budov se povedlo nalézt čtyři oběti bouře, ale po zbylých devíti kolonistech nebylo ani vidu ani slychu. Mluvířáci se tedy rozhodli vykostout do blízkých vrcholků tálnoučech se okolo základy, aby získali větší rozhled.

### 32-1-5 Výhled z vrcholku 10 bodů

Dvojeice mamínáři vystoupa na jeden vrcholček, aby měla co nejlepší rozhled do krajiný. Současný výhled jim ale nestačí a rádi by vystoupali na nějaký vyšší vrcholček – nechtějí však přitom sčít moc nízko.

Můžeme si představit mapu vrcholků jako čtvercovou síť obsahující na každém políčku výšku v metrech. Mezi soušedními políčky se můžeme pohybovat do všech 8 směrů. Máme označené políčko, na kterém jsme, a chceme si naplanovat cestu na nějaké políčko s větší výškou.

Během cesty budeme muset asi projít přes nějaká další políčka, ale chceme, aby minimální výška, ve které se vyskytne, byla co možná nejvyšší (nebo-li chceme maximalizovat minimální výšku, ve které se cestou ocitneme). Pokud takových výšších míst se sečnou minimální výškou během cesty existuje víc, chtěli bychom najít to nejvyšší možné.

Vynyslete algoritmus, který něco takového dosáhne.

*Příklad:* Mějme výšky vrcholů jako v tabulce níže. Nechtějme na vrcholku s výškou 5. Na vrcholku 9 bychom se uměli dostat tak, že bychom naklesli do výšky 2, ale na vrcholky 7 a 8 se umíme dostat tak, že naklesáme jenom do výšky 4 a přejdeme po hřebeni. Zdáná lepší možnost tu neexistuje, takže naše zadání splňuje nejlépe vrcholek s výškou 8, do kterého cestou projdeme přes nejnižší výšku 4. Jedna z možných cest je vyznačena.

```
2 2 1 2 1
2[5]3 7 2
2 1[4]4 1
9 1 1[8]1
```

„Skippere, tedy Droke... naši jsme něco zajímavého. Směrem na jih od základny jsou v písku vidět stopy terénního podovodního transportu. Nejsou vůbec zřejmáke bouří, takže budou maximálně třiřtí dny staré.“

*Kapitánka Loren se pokrčila těžně nad vedleze základny. „My jsme to určitě nebyli, od výpadku nouzového zdroje jsme byli všichni uwezením v tom krytu pod skladem číslo tři.“ odpaňval řekla.*

*Kapitánka se zaujmula a pak vydala rozkaz: ...*

\*\*\*

*Letos experimentujeme s příchodem k ulohám, který můžete sami odložit. Co by podle vás měla kapitánka Loren la Boyd udělat? Zaujmuj se do 7. října v anketě!*

*První díl příběhu pro vás sepsal*

*Jirka Seznáčka*

## 32-1-6 Data na OSMu 16 bodů

Pokud vám připadá už trochu nuda, že v KSP máme jenom úlohy s umělými daty bez nějakého reálného významu, tak jsme právě pro vás připravili tento seriál. Letošní seriál se totiž bude pokoušet ukázat vám práci s různými zajímavými zdroji velkých dat. Zaměříme se taky na různé nástroje – co když se vám data nevejdou do paměti, co když se vám odzpyčovaná data nevejdou ani na disk, jaké je to spustit si program přes noc, abyste ráno zjistili, že spočetl váš výsledek, ale spadl na posledním řádku, ... a podobně.

### Opravné mapy

V prvním dílu se naučíme pracovat s mapami z projektu OpenStreetMap, na což navážeme ještě v dílu druhém. V dalších dílech se pak podíváme na nějaké další zajímavé zdroje dat.

Projekt OpenStreetMap<sup>2</sup> je taková mapová Wikipedie – je to online mapa podobná mapam od Google a nebo Seznamu, akorát ji může editovat každý. Různé je (narozdíl od Wikipedie) značná část dat převzata z jiných zdrojů, ale pořád jsou volně dostupné a můžete tam zanést své oblibné zkratky přes les :)

OSM můžeme využívat jako běžný uživatel a hledat si na <https://osm.org/> třeba kde bude další soustředění. Ale narozdíl od Google nebo Seznamu mapy si můžeme stáhnout i strojeově zpracovatelná zdrojová data a něco si nad nimi spočítat.

To je přesně to, co teď udeláme, protože si přeci chceme něco naprogramovat. Budeme používat data ve formátu XML, která se dají z OSM získat. Tady se pokusíme vysvětlit

<sup>1</sup> <https://poli.ly/#/PvykK7ka>

<sup>2</sup> <https://www.openstreetmap.org/>

<sup>3</sup> <http://ksp.mff.cuni.cz/viz/serial-osm>

strukturu a smysl dat a ukázat nějaké obecné principy. Detailnější technické informace o tom, kde si data stáhnout a jak je načítat, se pak můžete dočíst na webové stránce seriálu.<sup>3</sup>

### Formát dat

Pokud očekáváte, že se nám popis vstříplno formátu pro úlohu vejde na jeden odstavec, tak je na čase si odvyknout. V praxi tomu tak moc často nebude a OSM data nejsou výjimkou.

Nicméně nebude to nic hrozně komplikovaného. V principu datový soubor obsahuje jen tři typy objektů: *vrcholy*, *cesty* a *relace*.

### 1. Vrcholy

Vrcholy (node) jsou nejzákladnější objekty v OSM a jenom omý nesou informace o poloze. Vrchol je zkratka nějaký bod na Zemi zadaný pomocí zeměpisných souřadnic (šifra a délka), ze kterého můžeme konstruovat jiné složitější objekty, například cesty.

Negativnější vlastnosti vrcholů jsou poloha a identifikátor. Polohu najdeme jako souřadnice v atributech `lat` a `lon`, identifikátor je číslo v atributu `id`. Upozorňujeme, že vrchol je na světě přes 5 miliard, takže nestačí 32-bitové celé číslo. Polohu je pro dobrou přesnost také lepší ukládat do 64-bitového desetinného čísla.

Ale vrcholy nemusíme používat jenom pro stavbu složitějších objektů – i on samotný může být nějakým významným. Proto můžou mít vrcholy *tagy* – další informace, které se k nim vážou. Tag je dvojice klíče a hodnoty a může v něm být skoro cokoliv.

Tagy tu opravdu nemáme prostor vysvětlit všechny. Proto bychom vaší program nebude roznášet, můžete třeba ignorovat. Jediná významná ale bývá poměrně intuitivní, uvedeme několik příkladů:

- Tag `name` je jméno objektu (třeba jméno vesnice nebo jméno restaurace).
- Tag `source` značí odkud se data vzala.
- Skupina tagů `addr:street`, `addr:postcode`, `addr:city` a `addr:housenumber` nám říká adresu bodu.

Ukážka reálného bodu z OSM:

```
<node id="2578544869" visible="true" version="4"
  changeSet="71085651"
  timeStamp="2019-06-10T03:14:47Z"
  user="itamas80" uid="1719518"
  lat="50.0435083" lon="14.4031207">
  <tag k="bus" v="yes"/>
  <tag k="highway" v="bus_stop"/>
  <tag k="name" v="Pod Zřehovem"/>
  <tag k="name:de" v="Schwalover Grund"/>
  <tag k="public_transport" v="platform"/>
</node>
```

### 2. Cesty

Cesty (`way`) jsou skupiny bodů. Dalo by říci, že vlastně tvoří hrany grafu, ale v OSM se cesty používají třeba i na vyznačení ploch, vodních toků nebo hranic obcí (pak často mluvíme o *polygonech* namísto o cestách). Cesta tedy není vždy něco, po čem se dá chodit, ale něco co se skládá

```
return b;
```

```
}
V Pythonu:
```

```
def fib2(n):
    if n == 0:
        return 0
    a = 0; b = 1
    while n > 1:
        (a, b) = (b, a+b)
        n = n - 1
    return b
```

Jak vidíte, je i tato funkce elegantní a navíc běhá mnohem rychleji než její rekurzivní varianta. Tato funkce běhá v  $O(n)$ . Kdežto rekurzivní varianta počítala stejné věci mnohokrát dohola (zkusíte si nakreslit nějaký strom volání předchozí funkce, připadne se podívat dopředu do podkapitoly Předpočítané mezivýsledky).

Rekurzivní varianta v tomto případě může běžet až v čase  $O(2^n)$ , což je pro velká  $n$  mnohem pomalejší než  $O(n)$ . Dá se ale celkem lehce rozmyslet úprava rekurzivní varianty, aby běžela také v  $O(n)$ , zkusíte si rozmyslet jak.

### Backtracking

S rekurzí silně souvisí i pojem *backtracking*, česky by se snad dalo říci „metoda pokusu a omylu“. Tímto pojmem označujeme proces, kdy postupně zkoušíme všechny možnosti, jak vyřešit nějaký problém.

Metoda pokusu a omylu se tento proces nazývá proto, že pokud již nemůžeme pokračovat dál (třeba v případě, že v bližším dopředu do slepé uličky), vrátíme se kus zpět a zkoušíme jinou (zahrn nevyzkoušenou) možnost. Takto postupně zkoušíme každou možnost, a buď nalazeme námi hledané řešení, nebo se vrátíme až na výchozí pozici a zkusíme, že řešení neexistuje.

Backtracking bývá často realizován pomocí rekurze, ukážeme si to na příkladu hledání rozkladů zadané čísky na násobky o hodnotách 5 Kč a 3 Kč (všimněte si, že v takto označeném počítačím systému nejde složit třeba částka 7 Kč). Naše funkce dostane jako parametr zbyvajících částek a zkusí rekurzivně provést rozklad na jednořivě násobky.

V jazyce C:

```
bool rozloz(int castka) {
    // Koncová podmínka rekurze
    if (castka == 0) return true;
    else if (castka < 0) return false;
    else if (rozloz(castka-5)) {
        printf(" 5 Kč");
        return true;
    } else if (rozloz(castka-3)) {
        printf(" 3 Kč");
        return true;
    } else return false;
}
```

V Pythonu:

```
def rozloz(castka):
    if castka == 0:
        return True
    elif castka < 0:
        return False
```

```
elif rozloz(castka-5):
```

```
    print(" 5 Kč")
```

```
    return True
```

```
elif rozloz(castka-3):
```

```
    print(" 3 Kč")
```

```
    return True
```

```
else:
```

```
    return False
```

V každém kroku zkoušíme nejdříve použít pětkorunovou minci a zavoláme se na zbylou částku, a když náš rozklad nevyjde, zkoušíme v tomto kroku použít ještě tříkorunou. Takto se rozhodujeme v každém kroku rekurze a připadne se vrátíme z neúspěšných větří výpočtu a zkoušíme další možnost.

Takovým postupem ale vyzkoušíme až exponenciálně mnoho možností ( $O(2^n)$ ), což není moc rychlé. Proto je doporučeným se backtrackingem raději vyhnout, nebo ho nějak chytré vypašit. Je však dobře o backtrackingu vědět, protože existují problémy, které efektivněji řešit neumíme.

### Rozděli a panuj

Jednou ze základních technik je rozdělení složitějšího problému na menší části, které opět můžeme rozdělit na menší a tak dále, dokud se nedostaneme k problémům tak malým, že je už umíme triviálně vyřešit.

### Binární vyhledávání v poli

Představme si, že máme seřazené pole  $n$  prvků a chceme zjistit, jestli se v něm nachází prvek s hodnotou  $k$ . Určitě můžeme projít celé pole v lineárním čase (tím, že budeme brát jeden prvek za druhým a kontrolovat, zda je roven hodnotě  $k$ ), ale to je zbytečně pomalé a nevyužívá toho, že máme pole seřazené.

Můžeme totiž začít s velkým problémem a ten postupně zmenšovat a stále menší a menší. Nejdříve hledáme  $k$  v celém poli. Podíváme se na jeho prostřední prvek:

- Pokud je roven  $k$ , jsme hotovi.
- Je-li větší než  $k$ , víme, že se  $k$  musí nacházet nalevo od něj. Můžeme tedy hledat znovu, ale tentokrát se omezit jen na levou polovinu pole.
- Analogicky, je-li menší než  $k$ , můžeme hledat jen v pravé polovině.

Když tímto postupným dělením problému na menší dojde-me až k poli o velikosti jednoho prvku, stačí tento prvek jenom porovnat, dál už se pole nepokoušíme rozdělovat.

Jelikož se nám každý krokem problém zmenšit na polovinu, maximálně po  $\log n$  krocích se dostaneme na pole velikosti jedna. Řekneme, že algoritmus má *logaritmickou časovou složitost*, psípane  $O(\log n)$ .<sup>15</sup>

Prakticky postup provádíme tak, že si udržujeme levou a pravý okraj aktuálně zpracovávaného úseku a postupně je k sobě přibližujeme.

Ukážka hlavní smyčky v C:

```
int pole[] = {1,2,5,7,12,16,42};
int hledane = 8;
int l = 0, r = 6;
int x;
```

<sup>15</sup> Pokud není řečeno jinak, znamená pro nás v informatice značka  $\log$  *dvouřivý logaritmus*, což je funkce opačná k funkci  $2^n$  a roste o hodnotě pomaleji než funkce lineární. Pro velká  $n$  platí:  $1 < \log n < n$  a například  $\log 2 = 1$ ,  $\log 8 = 3$ ,  $\log 1024 = 10$ .

strom (v každém vrcholu spojový seznam podstromů), nebo velmi pěkně i v poli.

Stačí si pomyšlně doplnit binární strom na *výšňůj* (to je takový, který má všechny své hladiny plné) a pak ho od kořene směrem dolů po hladinách očíslovat (kořen dostane číslo nula, jeho synové čísla jedna a dva, další hladina čísla tři až šest, atd.).

Můžeme si všimnout, že pokud si v takovém očíslování vezmeme jakýkoliv vrchol s číslem (indexem) *i*, jeho synové jsou právě vrcholy s indexy *2i + 1* a *2i + 2*. Do pole může je zapisový binární strom z obrázku výše.

```
index 0 1 2 3 4 5 6 7 8 9 10
hadnota 8 3 12 1 5 9 14 - - 4 7
```

Jak plyne z očíslování, pro úplný binární strom je nutčén v poli elementů a nepřivřované místem. Pokud ale strom úplný nebude, zůstane nám v poli volná místa. Uložení v poli se tedy vyplňti jen pro stromy, které se od úplných příliš neliší.

Speciálním případem binárních stromů jsou pak ještě *binární vyhledávací stromy*, jsou to normální binární stromy, pro něž navíc platí, že ač si vezmeme libovolný vrchol, budou hodnoty vrcholů v jeho levém podstromu menší než hodnota tohoto vrcholu a hodnoty v jeho pravém podstromu naopak větší.

V takovém stromu pak zřídka máme snadno vyhledávat. Budeme ho postupně procházet od kořene a v jednotlivých vrcholech budeme porovnávat hledanou a aktuální hodnotu a podle toho sestupovat do správného podstromu. Podobná technika je detailněji popsána ve druhé části kuchařky, v sekci *Rozděli a panuj!*.

Na složitější datové struktury starější na těchto základech (haldy, intervalové stromy, ...) se můžete podívat do některé z našich dalších kuchařek, na jejichž přehled jsme vás už odkázali o kapitolu výše.

## Část druhá: Programátorské techniky

Tato část by měla sloužit jako rychlý přehled a ukázková různých technik, které se dají použít při řešení úloh z KSPřka, nebo při programování obecně.

### Rekurze

Rekurze je velmi dležitá programátorská technika. V podstatě znamená definování nějaké věci (ať už je to nějaký objekt či postup výpočtu) pomocí sebe sama.

Rekurzivně může být například zadána nějaká datová struktura. Třeba stromy jsou pěkným příkladem rekurzivně definované datové struktury – každý vrchol stromu může mít syny, a každý z těchto synů je sám o sobě strom (tedy i osamocený vrchol bez synů je stromem).

Prakticky je to realizováno tak, že každý vrchol má strom hodnotu a pak ještě seznam ukazatelů vedoucích na další přípatné podstromy. S ukazateli jsme se již potkali a s jejich pomocí jsme si postavili spojový seznam. A přesně tak, spojový seznam je také ve své podstatě rekurzivní datová struktura.

Kromě rekurzivních datových struktur se ale často používáme i s rekurzivním postupem výpočtu nějakého programu, nejčastěji realizovaným ve formě funkce, která volá sama sebe (většinou s jinými parametry, jinak by to asi nemělo smysl), takové funkce se říká *rekurzivní funkce*.

U rekurzivních funkcí je nejdůležitější věc definovat nějakou *koncovou podmínku*, tedy podmínku, při níž už se rekurze zastaví. Jinak by se totiž mohlo stát, že by rekurze běžela donekonečna.

Přesněji rekurze by se i tak v nějakou chvíli zastavila, ale skončila by chybou, protože by jí došla paměť – každé volání funkce si totiž ukládá kus paměti (má si pamatovat, kam se po skončení má vrátit), a pokud má rekurzivní funkce ještě nějaké lokální proměnné, musíme si někde uložit všechny lokální proměnné funkci, z kterých jsme se doposud nevtrátili.

### Rekurzivní funkce a převod na nerekurzivní cyklus

Typickým příkladem rekurzivní funkce je výpočet Fibonacciho čísel. Ta jsou definována tak, že  $f_0 = 1, f_1 = 1$  a *n*-tÉ Fibonacciho číslo je součtem dvou předchozích ( $f_n = f_{n-1} + f_{n-2}$ ). To nám dává posloupnost čísel 0, 1, 1, 2, 3, 5, 8, 13, ... pokračující donekonečna. Pokud toto přepíšeme do programového kódu, tak dostáváme následující zápisy:

V jazyce C:

```
int fib(int n) {
    if (n==0) return 0;
    else if (n==1) return 1;
    else return fib(n-1) + fib(n-2);
}
```

V Pythonu:

```
def fib(n):
    if n == 0:
        return 0
    elif n == 1:
        return 1
    else:
        return fib(n-1) + fib(n-2)
```

Jak vidíme, je přepsání celkem přímočarý. Pokud by se nám však rekurze v nějakém případě neblila, můžeme se každé rekurze zbavit. Rekurzivní volání totiž můžeme šikovně přepsat na nějaký cyklus se *zásobníkem*.

Pak jen v cyklu odeberáme prvky ze zásobníku, dokud není prázdný, a za každé rekurzivní zavolání do zásobníku přidáme parametry, se kterými bydlom naši funkce volali. Tímto postupem převodeme každou rekurzivní funkci na nerekurzivní.

Ještě doplníme poznámku, že ve většině programovacích jazykch každé volání funkce stojí nějaký čas, sice malý, ale když se volání provádí opakovaně, tak se to už nasčítá. Pro reálnou implementaci je tedy nejlepší pokusit se rekurzi převést na nerekurzivní volání, pokud to nějak rozumně jde. Ohkás to jde dokonce i jednodušší a bez zásobníku. Podívejte se na alternativní variantu výpočtu Fibonacciho čísel níže a rozmyslete si, co dělá.

V jazyce C:

```
int fib2(int n) {
    if (n == 0) return 0;
    int a = 0; int b = 1;
    while (n > 1) {
        int pomocna = a + b;
        a = b;
        b = pomocna;
        n--;
    }
}
```

z více bodů. Body jsou naše známé vrcholy, cesta se na ně odkazuje pomocí elementů `<id>`.

Cesty někdy značí plochy a v takovém případě začínají a končí stejným bodem.

Jak ale poznáme reálný význam cesty? Podobně jako vrcholy můžou mít cesty libovolné tagy. Například tag `name` bude obsahovat pravděpodobně jméno ulice a tag `highway` nám řiz svou přítomností říká, že se jedná o nějakou cestu, a jako svoji hodnotu bude mít typ této cesty (tedy jestli je to pěšina nebo dálnice – třeba `highway=1` označuje je chodník pro pěši a `highway=residential` je normální ulice vedoucí k domkům).

Ukázká cesta tvořící uzavřený polygon (v tomto případě nějakou garáž):

```
<way id="695854456" visible="true" version="2"
changeset="38311484"
timestamp="2016-04-05T08:39:44Z"
user="jandak" uid="2169558">
  <nd ref="739135731"/>
  <nd ref="739135841"/>
  <nd ref="739135871"/>
  <nd ref="739135899"/>
  <nd ref="739135731"/>
  <tag k="building" v="garage"/>
  <tag k="building:rulan:type" v="18"/>
  <tag k="ref:rulan:building" v="49847236"/>
  <tag k="source" v="czuk:rulan"/>
</way>
```

### 3. Relace

Posledním typem dat v OSM je *relace* (`relation`). Relace se nevyužívají tak moc jako cesty a vrcholy, ale často také nesou užitečné informace. Relace je vlastně skupina jiných objektů – cest, vrcholů a nebo dalších relací. Například když se podnikáme na tranrajořovou trať, můžeme si všimnout, že koleje jsou v relaci podle toho, jaké linky na nich pravidelně jezdí. Existuje tedy relace pro pravidelné linky hrondané dopravy. Drobný problém je, že se linky není docela často a v mapách jsou tak často neaktvátní nebo nepřesné informace.

Další použití relací jsou velké oblasti, které jsou složeny z mnoha cest – těm říkáme *multipolygony*. Tímto způsobem najdete například zakódované hranice obci nebo měsíských částí, některé lesy a vodní plochy. Hlavní výhodou oproti cestě je, že oblasti můžou být tvořeny několika mnohoúhelníky, případně v sobě můžou mít dny – vodní plochy v sobě můžou mít ostrovy, politické oblasti nejsou vždy souvislé.

Detailněji si multipolygony můžete nashtrdat na OSM Wiki.<sup>4</sup> Aby to nebylo tak komplikované, tak se budeme zabývat jen těmi relacemi, které jsou souvislé a nemají díry. Pak stačí z relace vyřadit všechny cesty, uspořádat je do „rhrnu“ a máme mnohoúhelník. Pozor na to, že typicky nebude konvenxi a může být všechny možné divné tvary.

\*\*\*

Význam všech tagů používaných v mapách si můžete najít na OSM Wiki, například si lze najít všechny možné hodnoty pro tag `highway`.<sup>5</sup>

<sup>4</sup> <https://wiki.openstreetmap.org/wiki/Relation:multipartolygon>

<sup>5</sup> <https://wiki.openstreetmap.org/wiki/Key:highway>

<sup>6</sup> <http://ksp.mff.cuni.cz/viz/serial-osm>

Pokud si chcete prohlédnout kus mapy, trochu vizuálněji, než prohlížením XML souboru v textovém editoru, můžete tak učinit na webu <https://osm.org/>. Přiblížíte si kus mapy, který vás zajímá, a nahoře se přepne do „Edit“ → „Edit with ID“. Tím se dostanete do editoru mapy, ve kterém se dají rozkliknout všechny objekty. Když kliknete na cestu nebo vrchol, v levém panelu se dlele zobrazí seznam všech tagů.

### Úlohy obecně

Úlohy budeme počítat nad několik různými výřezy z OSM. Data z OSM se dají volně stáhnout v různých formátech, nejčastěji jako gzipovaný XML soubor s příponou `.osm.gz`, bzipovaný XML soubor s příponou `.osm.bz2` nebo jako PBF binární soubor s příponou `.pbf`. Servery, ze kterých se dají stáhnout, i nějaké detaily všech formátů a jejich parsování jsme shrnuli na webové stránce seriálu.<sup>6</sup>

Mý v úlohách budeme pracovat s gzipovanými XML soubory, protože práce s XML nám přišla pro účely seriálu výhodnější a protože knihovny pro gzip jsou v programovacích jazycích na lepší úrovni, než knihovny pro práci s bzip2.

Normálně byste si při práci s OSM asi stáhli nějaký poslední týdenní export z nějakého z veřejných serverů, ale abychom si byli jisti, že pracujeme nad stejnými daty (a že zrovna třeba cesta s nějakým ID náhodou nezmizela), tak jsme pro vás vystavili na našem webu konkrétní výřezy tří oblastí:

- Evropa – velká testovací data, asi 43 GB zkomprimovaného XML (392 GB v nekomprimované verzi).
- Brno – malá testovací data, asi 20 MB zkomprimovaného XML (186 MB v nekomprimované verzi).
- Hrodňov – velmi malá data pro ověření vašeho řešení, prozradíme vám u nich výstup našeho řešení.

Doporučujeme si nejdříve řešení otestovat na menším vstupu, protože nad celou Evropou to nedoběhne rychle. Také doporučujeme nepocházet řešením na poslední chvíli, protože by některá řešení nemusela doběhnout (naše omládné řešení třetím úkolu pro celou Evropu běží přes 9 hodin).

Každý úkol od vás budeme chtít vyřešit na malých (Brno) i velkých (Evropa) datech. Za vyřešení **na malých i velkých datech** získáte za úkol **plný počet bodů**, za vyřešení **jenom na malých datech** získáte **polovinu bodů**.

A co nám máte vlastně odevzdat jako řešení? Odevzdávejte prosím zip archiv, který bude obsahovat:

- Krátký slovní popis, jakým způsobem jste přistupovali ke které úloze a třeba jak vám to přišlo těžké.
- Výsledek pro každou úlohu pro malá i velká data (pokud je to jedno číslo, tak se dá klidně napsat do slovního popisu, jestli je to seznam IDček nalezených objektů, tak raději do samostatného textového souboru; obrázky jako obrázky).
- Zdrojový kód programu, který jste použili výpočet pro řešení.

• Popis jak dlouho trvalo úlohy spočítat a na jak výkoném hardwaru (typ, počet jader a frekvence procesoru, množství paměti) – čas se dá změřit třeba vypásmím časů na začátku a na konci programu, případně na Linuxu třeba příkazem `time`.

A nyní už k samotným úkolům a k několika principům velkých dat okolo nich. . .

### Streamové parsování

Občas se nám nakatáná data nevejdou do paměti (třeba v případě našeho velkého výřezu Evropy – pochybujeme, že někdo z nás má v roce 2019 doma stroj s 390GB operární paměti na nekomprimovanou data. . . a ani 45GB ve zkomprimované variantě asi většina z vás do paměti také nemaje). To při zpracování velkých dat není vůbec nešední věc a počkáme se s tím docela často.

Jak si s tím poradit? Nejlepší bude škrzt data jenom projít a cestou zpracovat těch několik věcí, které nás zajímají. Takovému způsobu procházení se říká streamové a třeba na spočítání počtu vrcholů v celé mapě nepotřebujeme sroto žádnou paměť – do paměti vždy načteme jenom jeden XML tag, podíváme se, jestli je to node, a pokud ano, tak přičteme k nějakému počítadlu plus jedna.

Nejlepší je, že se v většině programovacích jazyků dá lehcce vstavit několik streamových zpracování za sebou. To vyzníme právě u našich dat, kde za sebe budeme potřebovat navrstvit streamový „odzipováváč“ a streamové parsovávko XMLka. Pak můžeme našemu programu předložit přímo .osm.gz soubor a když v programu zavoláme funkci na napsávání dalšího XML tagu, tak to může pod kapotou vypadat třeba takto:

- Zavoláme funkci `getNextTag()`
- Funkce `getNextTag()` má u sebe buffer, do kterého postupně plní byty. Dokud buffer neobsahuje celý validní XML tag, tak v cyklu volá funkci `gzip.getnextByte()` a postupně připsuje do bufferu další a další znaky. Ve chvíli, kdy je tag načtený celý, tak ho vrátí a odmazá si ho z bufferu.
- Funkce `gzip.getnextByte()` má u sebe buffer odzipovaných dat, které vrací po jednotlivých bytech. Ve chvíli, kdy je buffer prázdný, tak načte ze souboru na disk další datum, který může „odzipovat“ a opět si tím naplnit buffer.

Ukázka tohoto postupu je v ukázkových programech na stránce s technickými detaily na webu.

### Úkol 1 [3]:

Pojďme si narytět znalosti zkrstít na něčem jednoduchém. Zajímalo by nás, kolik je na mapě unikátních názvů ulic. Přesněji řečeno, najdíte si v Brite a nebo v Evropě všechny ulice, které mají (nepřáznivě) tagy `highway` a `name`. Pak spočítejte, kolik unikátních hodnot `name` se tam vyskytuje (názvy liší se jenom ve velikosti písmen, necht' jsou pro naše účely různé názvy). Toto číslo je řešením úkolu.

Pro Hrochův Týnec naše řešení našlo 16 různých názvů ulic (většně názvy „ávka (zákaz vstupu)“, což je sice dluhý název podle OSM – zákaz vstupu by se měl vyjadřovat jinak – ale v datech je a tak ho počítáme).

Mozná si říkáte, jestli bychom nemohli spočítat, kolik je na mapě ulic (většně těch duplicitních názvů). Samozřejmě mohli, ale není to tak jednoduché – ulice totiž často nejsou jedna cesta, ale je to několik cest se stejným jménem, které jsou akorát spojené v nějakých vrcholech. Někdy jsou ulice rozdělené na více cest bez zadržování divochů, ale někdy se dokonce větví a cyklů a pak už by jednou cestou reprezentovat ani nešlo. Proto je potřeba před počítáním nějaké úsekkapit rozšířte ulice a to není tak jednoduché. Ale rozhodně to není nemožné, tak to kličďte zkusete :)

### Více příčhodů

Občas nám jeden příčhod uteče. Typickým příkladem v OSM je, když potřebujete získat vrcholy cest s nějakým tagem. Dokud ale nemáte nalezené ony cesty, ani nevíte, které vrcholy vás hrdou zajímají. A pamatovat si všechny vrcholy v paměti také nelze. Jak si poradíme s tímto?

Nejlehodnější přístup je asi ztřofový soubor projít vícekrát. Při prvním průchodu si poznamenejme IDka všech objektů, které by nás zajímaly (mohl to být právě vrcholy nějaké cesty), a pak se vrátíme na začátek souboru. Tého operací se většinou říká *seek*, ale ne všechny vrstvy našeho streamového zpracování musí nhlbe operací podporovat (typicky archivování vrstvy mají se seekem problémy kvůli svému vnitřnímu stavu). Ale postup zavříti přívodní soubor, otevřít ho a znovu ho obalit `gzip` streamerem a XML parsorem bude fungovat asi ve všech jazycích.

Při druhém průchodu už poté při načítání objektů můžeme kontrolovat, jestli jsou to pro nás zajímavé objekty a kdyžtak si je uložit do paměti (když těch zajímavých objektů není milharda) nebo je nějak jinak zpracovat.

### Vizualizace

Občas nejlepší způsob, jak se podívat na mapové data, není číst hromadu čísel ze standardního výstupu, ale nakreslit si nějaký obrázek. Ostatně když se díváte třeba na OSM na webu jako uživatel, tak právě vidíte nějaké vyrenderované výsledky. To už je ale docela komplikováno a jak vykreslit mapu, aby byla dobře použitelná, je už více otázka kartografická, než programátorská.

Ale i nějaké mlohem jednodušší vizualizace nám mohou hodně pomoci při zkoumání nějakého aspektu – mnohdy jeden obrázek vyřká za tisíce slov. Pojďme si zkusit nakreslit třeba nějakou *heatmapu*.

*Heatmapa* je obecně znázornění velikosti nějakého jevu v nějaké oblasti (například množství tepla, odtid i ten název). Nejstříšji se vyrábí tak, že si určíte oblast (pro nás to bude vždy celý datový soubor), ten si rozsekáte na stejné velké čtverečky a pak procházíte data a poznamenejáte si, kolik je ve kterém čtverečku věcí, které vás zajímají. Nakonec každý čtvereček bude prezentovat jeden pixel na výsledném obrázku a čím více věcí v odpovídajícím čtverečku, tím tmavší pixel bude.

Při skládání bodů do pixelů obrázku se pravděpodobně objeví te drobné pasy – Země není plakca a souřadnice bodů v OSM jsou souřadnice na elipsoidu. Když je přepočítáme na rovinnu tím naším způsobem, že s nimi počítáme jako se souřadnicemi v rovině, tak dostaneme nějakým způsobem nepřesnou mapu. Dokud kreslime jednoduší diagram pro Československou republiku, tak je to jedno, ale v rámci celé Evropy už je to docela rozdílné.

Ale pro naše použití se teď s touto primitivní projekcí spokojíme – náš program nebudete první, který nebude řešit nějaké komplikované projíctce, a aspoň něco by v výsledném obrázku poznat být mělo i tak. Ale je dobré počítat s tím, že čím severnější oblasti mapa obsahuje, tím je zkrstřená touto projekcí horší.

vnitřně fungují. Protože jediné když budeme vědět, co je jak rychlé a efektivní, budeme schopni psát rychle programy. Ted' již víme, jak reprezentovat nejzákladnější datové struktury v počítači, ale mohl by se nám hodit zástavit se ještě dříve u dalších struktur. Tentokrát je už budeme studovat trochu teoreticky.


### Stromy a grafy v informatice

#### Grafy

S nějakými grafy jste se již možná setkali, ale tento pojem je bohněz docela přetřezovaný. Jedním jeho významem jsou „koláčové grafy“, a jiné další diagramy znázornující nějaký poměr (ať už to jsou výsledky voleb, nebo poměr lidí, kteří sledovali v televizi Večerníček).

Další význam můžeme nalzt v analytické matematice, kde se počkáme s grafy přibude nějakých funkcí. My však máme na mysli ani jedno z výše zmíněných, teď se budeme bavit o *kombinatorických grafech*.

Grafem tedy máme na mysli nějakou množinu objektů, říkáme jim *vrcholy*, a nějaké vztahy mezi nimi. Tyto vztahy nazýváme *hranami* a jsou vyjádřené dvojicemi vrcholů, mezi kterými vedou. Ukážku takového grafu vidíme třeba na následujícím obrázku.



Jako praktickou ukážku grafů si můžeme například představit sílniči síť nějakého státu: vrcholy budou města a hrany budou silnice, které mezi nimi vedou.

Občas se můžete setkat s pojmem *sovinský graf*. Ten znamená jen to, že mezi každými dvěma vrcholy existuje nějaká cesta. Pokud tomu tak není, je graf *nesovinský* a dá se rozložit na několik menších grafů, které již souvislé jsou a říká se jim *komponeuty souvislosti*.

Samotný graf poté můžeme doplnit tím, že si v každém vrcholu nebo na každé hraně budeme pamatovat nějakou hodnotu (například cenu nejlevnějšího benzínu ve městech a délku v kilometrech na silnicích). Pamatoování si hodnot ve vrcholech je docela obvyklá technika a nemá speciální název, ale pokud budeme mít graf, který si pamatuje hodnoty na hranách, budeme o něm mluvit jako o *ohodnoceném grafu*.

Další možnou úpravou je, že každá hrana povede jen jedním směrem (jednosměrné silnice), takovým grafům říkáme *orientované* (pokud pak v orientovaném grafu chceme silnici oběma směry, prostě do něj přidáme dvě hrany, jednu v každém směru).

Poslední, co nám zůstává k praktickému použití grafů, je naučit se, jak je reprezentovat v počítači. Existuje několik možností (v popisoch bude  $n$  značit počet vrcholů,  $m$  počet hran):

<sup>14</sup> <http://ksp.mff.cuni.cz/kuchariky/>

• **Seznam souvislosti** – vrcholy grafu budeme mít uložené v poli a v každém vrcholu budeme mít (spojový) seznam čísel dalších vrcholů, do kterých z aktuálního vrcholu vede hrana. Zabírá místo  $O(n+m)$  a hodí se pro řídké grafy (tedy grafy, kde je  $m$  řádově stejně jako  $n$ ).

• **Maticे souvislosti** – tabulka  $n \times n$ , kde na souřadnicích  $[i, j]$  je jednička (nebo jiná hodnota, v případě ohodnoceného grafu), pokud z  $i$  do  $j$  vede hrana, a nula, pokud tam hrana není (u neorientovaných grafů je navíc matice symetrická – je jedno, jestli vezmeme  $[i, j]$  nebo  $[j, i]$ ). Hodí se pro husté grafy, kde  $m \sim n^2$ .

• **Maticе incidence** – řádky reprezentují vrcholy, sloupce hrany. V každém sloupci jsou právě dvě jedničky – indexy vrcholů, mezi kterými hrana vede. Zabírá však  $O(mn)$  a její použití byva dost neoblíbené, takže je většinou lepší dát přednost jiné reprezentaci grafu. Je ale dobré o ní vědět.


Grafy jsou velmi široké téma. Můžeme hledat jejich minimální kostry, můžeme v nich hledat nejkratší cesty či škrze ně pousřít pod tlakem vodu. Více o nich si tedy můžete přečíst v některé z našich specializovaných grafových kuchatek, které odkazujeme z našeho kuchatekového rozcestníku.<sup>14</sup>

### Stromy

Možná si říkáte, co má informatika u všech elektronů spoletného s lesnictvím? Kripodivnu celkom mnoho a bez stromů bychom se v leectřem připadé jen těžko obešli. Informatické stromy sice nejsou většinou tak zelené, mají ale, na rozdíl od svých dřevnatých sourozenců, mnoho jiných pěkných vlastností.

Strom je vlastně speciálním případem souvislého grafu, který neobsahuje žádnou kružnici (cyklus). To znamená, že mezi každými dvěma vrcholy stromu existuje právě jedna cesta.

Díky této vlastnosti můžeme nějaký zvláštní vrchol prohlásit za *kořen* a strom za něj pomyslně zavěsit (tak, že strom roste od kořene směrem dolů), této operaci se říká *zakorenění*. Pak můžeme mluvit o tom, že z kořene směrem dolů (informatické stromy mají tradičně kořen nahore) vyrůstají nějaké *podstromy*.



Pokud je strom zakoreněný, můžeme v něm mluvit o *hloubce* každého vrcholu, neboli o jeho vzdálenosti od kořene. Hluboká celého stromu je pak nejdelší ze vzdáleností od kořene k nějakému z *listů* (tak říkáme vrcholům, které již nemají žádné syny, tedy vrcholy, které by z nich vyrůstaly). Podle hloubky poté můžeme vrcholy stromu uspořádat do jednotlivých *hladin*.

Velmi často používáme stromy, které jsou nějak pravidelné. Příkladem jsou třeba *binární stromy*, které mají v každém vrcholu maximálně dva syny (říkáme jim *levo* a *pravo podstrom*). Reprezentovat se dají buď obecně jako každý jiný



```

malloc(sizeof(tprevk));
aktualni->dalsi = NULL;
aktualni->predchozi = NULL;
aktualni->hodnota = i;
return aktualni;
}

// Odstrani prvek a vrátí pointer na další
// prvek (vrácení pointeru se hodí při
// odstranění kořene):
tprevk *odstran(tprevk *aktualni) {
    if (aktualni->predchozi != NULL)
        aktualni->predchozi->dalsi =
            aktualni->dalsi;
    if (aktualni->dalsi != NULL)
        aktualni->predchozi =
            aktualni->predchozi;
    tprevk *pomocna = aktualni->dalsi;
    free(aktualni);
    return pomocna;
}

// Vloží a vrátí pointer na nový prvek:
tprevk *vloz_zak(tprevk *aktualni, int i) {
    tprevk *pomocna = aktualni->dalsi;
    aktualni->dalsi = novy(i);
    if (pomocna != NULL)
        pomocna->predchozi = aktualni->dalsi;
    aktualni->dalsi->dalsi = pomocna;
    return aktualni->dalsi;
}

// Použít:
int main(void) {
    tprevk *koren = novy(1);
    tprevk *aktualni = vloz_zak(koren, 2);
    aktualni = koren;
    while (aktualni != NULL) {
        printf("%d\n", aktualni->hodnota);
        aktualni = aktualni->dalsi;
    }
    return 0;
}

```

Zde je ukázka spojových seznamů v Pythonu, kdybychom si je podobně jako v C chtěli naprogramovat sami (Python totiž obsahuje spoustu základních struktur již hotových, podívejte se na modul `namedtuple`):

```

class Prvek:
    def __init__(self, hodnota):
        self.hodnota = hodnota
        self.dalsi = None
        self.predchozi = None

class Spojak:
    def __init__(self):
        self.koren = None

def vypis(self, aktualni):
    if aktualni is not None:
        print(aktualni.hodnota)
        self.vypis(aktualni.dalsi)

def vloz_po(self, prvek, za_prvek = None):
    if za_prvek is not None:
        prvek.dalsi = za_prvek.dalsi

```

```

    prvek.predchozi = za_prvek
    za_prvek.dalsi = prvek
    if prvek.dalsi is not None:
        prvek.dalsi.predchozi = prvek
    if self.koren is None:
        self.koren = prvek
    def odstran(self, prvek):
        if prvek.predchozi is not None:
            prvek.predchozi.dalsi = \
                prvek.dalsi
        if prvek.dalsi is not None:
            prvek.dalsi.predchozi = \
                prvek.predchozi

```

```

# Použít:
prveka = Prvek("A")
prvekb = Prvek("B")
prvekc = Prvek("C")
prvekd = Prvek("D")
seznam = Spojak()
seznam.vloz_po(prvekb)
seznam.vloz_po(prvekd, prvekb)
seznam.vloz_po(prvekc, prvekd)
seznam.vloz_po(prveka, prvekc)
seznam.odstran(prvekc)
seznam.vypis(seznam.koren)

```

### Fronta a zásobník

S použitím spojových seznamů (nebo v jednodušším případě deque) a poli můžeme zkonstruovat dvě velmi užitečné datové struktury, frontu a zásobník.

*Fronta* funguje tak, jak si ji asi každý z nás představuje: ten, kdo se do fronty postaví první, také první přijde na řadu. Trochu jinak si ji můžeme představit jako trubku, do které na jedné straně sypeme nějaké věci a na druhé je odebíráme. Anglicky je též nazývána *FIFO* („*First In, First Out*“).

Praktickou realizaci udeláme jednoduše spojovým seznamem. Budeme si držet dva ukazatele, jeden na začátek seznamu, druhý na konec. Když se objeví nový prvek, který do fronty budeme chtít vložit, přidáme ho na konec, zatímco při odebrání z fronty využijeme druhého ukazatele a vezmeme prvek ze začátku.

Druhou velmi podobnou datovou strukturou je *zásobník*. Jak už ale plyne z anglického názvu *LIFO* („*Last In, First Out*“), funguje spíše jako plhý šuplík: Nahoře do něj přidáváme nové prvky, a když chceme nějaký odebrat, vezmeme také zvrchno. To znamená, že první se na řadu dostane naposledy vložený prvek.

Implementace je velmi obdobná jako u fronty, jen bude ukazatel pouze jeden a bude ukazovat jenom na jeden konec spojového seznamu, konkrétně na poslední prvek.

### Knihovny

Tyto základní struktury už jsou často předpřipravené jako součást určitých *knihoven* v daném jazyce. Knihovna je většinou sbírka nějakých navzájem souvisejících funkcí, které již někdo sepsal a které si můžeme do našeho programu načíst a používat. Ukázkou načtení knihoven můžete vidět například ve výše zmíněném kódu v jazyce C.

Je ale velmi důležité rozumět tomu, jak knihovní funkce

### Úkol 2 [5b]:

Co tak si nakreslit hustotu zastarby? Definice „hustoty zastarby“ bude sice trochu sporná, ale pojďme prostě spočítat počet domů na území a vykreslit to jako obrázek.

Jak na to? Dům je typický důmky čtyřbi, nebo je místo nich jenom jeden bod s adresou, ale tak ty prostě nebudeme počítat. Podle toho jak budeme chtít velké rozlišení si mapu rozdělíme na čtverčekovou mřížku a pro každý čtverček napočítáme počet domů, které jsou uvnitř.

Protože cesta ohraničující dům je tvořena více vrcholůy budeme jako polohu domu pro zjednodušení brát polohu jeho prvního vrcholu. To nám sice může občas dům těsně na hranici jednoho čtverce přesunout do vedlejšího, ale ve větším měřítku se takové chyby vypruňmení.

Pro Brno vytvoře obrázek široký 1000 pixelů, pro Evropu vytvoře obrázek široký 4000 px, vyšší určete proporcionalně. Bavenost si určete sami (šikála ani nemusí být lineární, pokud se vám tak heatmapa bude líbit více, jenom nám v případě nějaké netriviální bavenosti přibalte legendu s vysvětlením, co které odstíny znamenají).

Jestli by se vám mohlo hodit vědět, že v Evropě je na naši mapě OSM zhruba 170 milionů domů – takže si spočítejte, kolik informací o každém domě si můžete pamatovat, aby se se ještě vešli do paměti svého počítače.

Heatmapa Hrochova Tynce by nebyla příliš zajímavá a heatmapa Brna máte za úkol spočítat vy, takže na webu se můžete podívat na heatmapu ČR.

Pokud si právě říkáte, že nemáte tušení, jak pomocí svého obdivného jazyka vytvořit obrázek, tak nezálejte, pravděpodobně to bude docela jednoduché. Nejlepší možností je popsat svůj problém do Googlu a najít na obrázky vhodnou knihovnu (nebo zjistit, že je k dispozici ve standardní knihovně). Pak bude asi jenom potřeba zavolat funkci „vyrob obrázek“ nějaké velikosti a pak mu nastarovat barvy jednotlivých pixelů (a pozor na to, v jakém rohu je počátek souřadnic). Pokud by to mělo rozumně nést, tak můžete zkusit využít textový formát PGM7 Sice bude obrázek obřadně velký, ale je otevřít například v GIMPu a pak uložit jako normální PNG.

### Trocha geometrie

Občas je dobrý nápad umět vybrat mapy jenom body, které leží v nějakém zajímavém území (v řeci OSM řekáme

*v polygonu*), třeba na území nějakého státu (třeba když vytváříme OSM export tohoto státu).

Jak jsme již napsali výše, důkdy jsou oblasti malé, jdou psát jednou cestou (kde poslední a první bod jsou stejné). Ale v případě větších oblastí už není praktické mít cestu s milionem bodů, ale spíše chceme říct, že je oblast ohraničená těmito padesáti čestami.

Takovito větší polygony jsou v OSM popsane relacemi, které právě obsahují ony česty (a občas i nějaký bod, například administrativní bod té oblasti, když jde třeba o město). Pozor na to, že česty na sobě po obvodu nemusí navazovat (mohou být nahodně pomíchané), OSM to nijak nezakazuje a je na programátore, aby si s tím pak poradil.

V OSM může relace představovat také takzvaný *multi-polygon*, který může mít i díry – například rybník s ostrovenem. V takovém případě je to relace mnoha cest, kde některé mají roli *outer* (to jsou normální hranice) a *inner* (to jsou „díry“), ještě se můžete setkat se *superrelacemi*, což jsou relace obsahující relace, které teprve obsahují česty. Ale oběma těmito složitějším případům se zatím vyhneme. V momentě, kdy se nám povede načíst polygon (na což může být potřeba více příchodů), už můžeme aplikovat například kuchařku o geometrii,<sup>8</sup> případně článek z Wikipedie<sup>9</sup> a můžeme dělat zajímavé věci.

### Úkol 3 [8b]:

Pojďme si zkusit najít pitka v následujících oblastech:


- Centrum Brna: ID 434760
- Alpy: ID 2698607

Obě oblasti jsou „slušné“ polygony určene relací, která obsahuje přímo česty a neobsahuje žádné díry.

Zahrň přinejmeny se pozná tak, že má nastavený tag *amenity=drinking-water* (tedy „toto je příko“) a nebo má nastaveno *drinking-water=yes* (což může být například i na veřejném WC, kde mají pítanou vodu). Odevzdejte nám seznam přítek v daných oblastech jako seznamem identifikátorů vrcholů, kde se můžeme napít, na každém řádku jedno číslo.

A to je prozatím vše. Budeme se těšit na vaše řešení a mezitím si pro vás nachystáme další zajímavé věci o OSM do druhé série :-)

*Jirka Schůčka & Stanla Lukáš*



<sup>7</sup> [https://en.wikipedia.org/wiki/Netpbm\\_format](https://en.wikipedia.org/wiki/Netpbm_format)

<sup>8</sup> <http://ksp.mff.cuni.cz/viz/kucharik/geometrie>

<sup>9</sup> [https://en.wikipedia.org/wiki/Point\\_in\\_polygon](https://en.wikipedia.org/wiki/Point_in_polygon)

## Recepty z programátorské kuchyně: Základní algoritmy

Tato naše kucharka je nejzákladnější ze základních a je určena hlavně pro začínající řešitele. To však neznamená, že zkušebenější řešitelé do ní nahlédnout nemohou – třeba na nějakou konkrétní programátorskou techniku, kterou by si potřebovali osvěžit.

V první části kuchyně se seznamíme hlavně se základními principy programování, udáváním dat v počítači a základny rychlé manipulace s nimi. Po přečtení této části bychom měli být schopni převést své myšlenky z hlavy na papír či do počítače a měli bychom vědět, proč je námi zvolený postup rozumný.

Druhá část nás poté seznámí se základními postupy, jak řešit určité konkrétní problémy. Naučíme se například, jak rychle vyhledávat v uspořádané posloupnosti hodnoty nebo jak si pomoci předpočítáním usnadnit řešení těžké úlohy.

Většinu klíčových částí se pokusíme též ilustrovat v podobě zdrojového kódu ve dvou různých jazycích (v nízkootrovněven C, kde je zápis blízký tomu, jak počítač doopravdy pracuje, a v Pythonu, ve kterém se píše o něco příjemněji). Neбудeme ale probírat základny syntaxe těchto jazyků, ty si případně můžete nastudovat jinde.<sup>10</sup>

### Část první: Základní pojmy

#### Algoritmus a program

Pod tajemným slovem *algoritmus* se skrývá jen jiný výraz pro postup. Můžete si to představit jako příkaz od maminčy „Běž do krámu, kup chleba, a když budou mít měkké rohlíky, tak jich vem třacet“.<sup>11</sup>

Takovýto příkaz křídle můžeme nazvat algoritmem, ačkoli to bude asi znit nezvykle – pojem algoritmus se totiž používá hlavně ve světě počítačů. Je to tedy nějaká posloupnost základních příkazů, která řeší nějaký problém. Východ konkrétního programovacího jazyka rozhoduje o tom, jaké základní příkazy budeme mít k dispozici. Většinou jsou ale skoro stejné.

Mezi základní příkazy patří:

- Manipulace s daty v paměti (uložení či načtení hodnoty, detailněji v další kapitole).
- Provedení nějakého symetrického výpočtu ( $(+ - * /)$ ).
- Vyhodnocení nějaké konkrétní podmínky a odpovídající cí větvení programu: *Pokud platí A, tak proved B, jinak proved C*. Přitom B i C mohou být křídle celé *bloky kódu*, tedy libovolně mnoho dalších základních příkazů.
- Operování nějakého příkazu: *Dokud platí A, dělej B*. Takové konstrukci říkáme *cyklus* a podobně jako u podmínky může být B blok kódu, který se celý opakuje.
- Vstup a výstup programu (typický vstup od uživatele z klávesnice či načtení vstupu ze souboru; výstup pak může znamenat vypisání výsledku na obrazovku nebo třeba zapsání dat do souboru).

Z těchto základních stavebních kamenů se skládá každý algoritmus. Programem potom rozumně realizaci algoritmu v nějakém konkrétním programovacím jazyce.

<sup>10</sup> <http://ksp.mff.cuni.cz/study/odkazy.html>

<sup>11</sup> A jako slibuje vychování se tedy vydáme do krámu a koupíme třacet rohlíků. -)   
<sup>12</sup> Pozor, ve světě počítačů se velmi často indexuje od nuly, tedy první prvek má v tomto případě index 0.

U složitějších programů se pak často setkáváme s problémem, že budeme mít nějakou posloupnost příkazů, která se bude pousatí mstí program opakovat, což zbytečně prodlužuje a zneprůhledňuje kód.

Řešením tohoto problému je použití *funkcí*. Funkci si můžeme představit jako nějakou pojmenovanou část programu (s vlastní pamětí), kterou můžeme opakovaně použít tím, že ji v různých částech programu *zavoláme*. Funkci při zavolání předáme parametry (například seznam čísel), které se dostanou do její vnitřní paměti.

Funkce pak na základě obdržovaných parametrů může provést nějaké operace, při kterých pracuje se svojí vnitřní pamětí (můžeme o *lokální* paměti, změny v ní se neprojevují nikde mimo funkci). Na konci nám funkce může vrátit nějaký výsledek. Pokud funkce behem svého běhu změní i nějaká data v *globální* paměti, či provede nějakou globální operaci (například výpis textu na monitor), můžeme pak o funkci s *vedlejšími efekty* (neboli *side-effects*).

Konkrétním příkladem může být funkce, která nám spočítá odmocninu ze zadaného čísla. Ta dostane jako svůj parametr číslo, vnitřní si provede nějaký výpočet, o který se jako uživateli funkce nemusíme starat, a jako výstup nám vrátí spočítanou odmocninu.

#### Reprezentace dat v počítači

Čalkem často si v průběhu výpočtu našeho algoritmu potřebujeme pamatovat nějaké hodnoty. K tomu nám programovací jazyky dávají nástroj s názvem *proměnná*. Ta představuje jakési pojmenované místo v paměti (příbědku), do kterého si můžeme data ukládat a pak je odtud zase načítat.

Typickým příkladem může být počítání součtu čísel, která nám uživatel zadá na vstupní. Na začátku nejdříve do nějakého místa v paměti uložíme hodnotu 0. Poté postupně, jak nám uživatel zadává čísla, tuto proměnnou pokračně přičteme, k její hodnotě přičteme nové zadané číslo a výsledek opět uložíme na stejné místo.

Takovéto použití jedné proměnné je velmi jednoduché (tak jednoduché, že ho takto podrobně do řešení KSPČka nepišete, není to potřeba), ale také celkem omezené. Co když bychom si chtěli pamatovat třeba celou zadanou posloupnost čísel? Mohl by nám stačit vytvořit si spisovitu různě pojmenovaných proměnných, ale nejdle to lépe? Jde.

Jednotlivé proměnné se mohou kombinovat do složitějších konstrukcí, které obecně nazýváme *datovými strukturami*. Zkusíme si ty nejzákladnější představit.

#### Pole

První datovou strukturu, kterou si představíme a která se na výše nastiženou situaci natrhnat hodí, je *pole*. To představuje spisovitu příhrádek (proměnných) naskladaných v paměti za sebou, ke kterým typicky přistupujeme přes jeden společný název pole a jejich pořadové číslo neboli index (jako *MazevPole[0]*, *MazevPole[1]*, ...).<sup>12</sup>

Ve většině základních jazyků je pole jen *statické*, tedy v okamžiku jeho vytváření musíme počítat říd, jak ho chceme

velké. Některé vyšší jazyky ale nabízejí i pole, které se dynamicky zvětšuje, takovou konstrukci si ukážeme ve druhé části kuchyně.

Abychom nebyli omezení jen jedním rozměrem, můžeme si křídle vytvořit pole dvourozměrné (případně obecně *n*-rozměrné). Dvourozměrné pole je vlastně tabulka hodnot, nazýváme ji také někdy *matice*, a může se nám hodit například při reprezentaci různých map (přán budíště) nebo, jak uvidíme níže, pro reprezentaci dalších datových struktur.

U pole již náš smysl přemýšlet, jak dlouho bude která operace trvat. Díky tomu, že jsou jednotlivé prvky v poli naskladané pevně za sebou, je snadné spočítat umístění konkrétní příhrádky. Proto když se počítače zapřemá na obsah příhrádky *pole[42]*, vrátí nám hodnotu ihned.

Tomu budeme říkat *operace v konstantním čase* a budeme znát, že trvá čas  $O(1)$ . Elektrivitu programu totiž nepočítáme v sekundách (protože každý z nás má asi jinak rychlý počítač), ale v počtu základních operací, které musí program řádově vykonat. Více o časové složitosti si můžete přečíst v kuchářce o složitosti,<sup>13</sup> nejdříve však dopornučněme dočíst tuto kucharka.


Přidání nového prvku na konec pole také zvládneme v konstantním čase. Problém je přidání nového prvku někým do prostřed (což se nám typicky stane, pokud budeme chtít udělat hodnoty v poli seřazené a zároveň do něj vkládat nové). V takovém případě se totiž všechny prvky za vkládaným musí posunout o jednu pozici dál, aby se vkládaný prvek vešel na své místo. Taková operace tedy trvá řádově pole délky *N* (jeli pole obsahující *N* prvky) tedy řádově až  $N$  kroků, což zapisujeme jako  $O(N)$  a říkáme, že je to vzhledem k  $N$  *lineární časové složitost*.

To je značná nevyhoda opotí struktury, kterou si ukážeme za chvíli. Určitě ale pole nezavrhneme. Je to základní datová struktura, která nalze použít ve spisovité programě, a jak si ve druhé části kuchyně ukážeme, můžeme ho použít třeba k rychlému hledání hodnoty metodou *binárního vyhledávání*. Nyní ale již silbovaná další datová struktura.

#### Spojový seznam a ukazatel

Pole jsme měli v paměti určené jenom tím, že počítač věděl, kde je jeho začátek a kolik místa v paměti zabírají jeho prvky. Při dotazování na konkrétní index pak podle indexu a podle velikosti prvku počítač přesně věděl kam do paměti se má podívat, aby našel námi požadovaný prvek (to vše zvládá v konstantním čase). Jednotlivé prvky si tedy vůbec nemusely pamatovat, kde se nachází jejich sousedí, protože všechny prvky seděly v paměti za sebou.

Představme si ale teď situaci, kdy by si každý prvek ještě pamatoval pozice sousedů. Pak bychom mohli mít prvky libovolně rozložené v paměti a jen by se na sebe vzájemně odkazovaly (první prvek by tvrdil, že druhý je na pozici *X*, druhý by tvrdil, že třetí je na pozici *Y*, a tak dále).



};


```
// Vytvoří nový prvek:
tprev *novy(int i) {
    prvek *aktualni =
```

kterému říkáme *adresa*. Když si vytváříme nějakou pojmenovanou proměnnou, ta se vlastně odkazuje na určité místo v paměti a na tomto místě v paměti je její hodnota.

Co kdyžby ale hodnota proměnné byla adresa nějakého jiného místa v paměti? Pak takové proměnné říkáme *pointer* a umožňuje nám vytvářet výše popsanou strukturu rozložených prvku v paměti.

*Spojový seznam* je tedy určený svým prvním prvkem (náme v jedné proměnné *pointer* na tento prvek, který se časem nazývá *kořen*, protože z něj „vyrostá“ zbytek struktury) a poté v každého dalšího prvku máme za sebou uloženu hodnotu tohoto prvku a odkaz (*pointer*) na další prvek. Odkazy mezi prvky mohou být i obousměrné, mohou věst dokola (poslední ukazuje na první) či mohou dokonce tvořit nějakou složitější strukturu (pak to ale již nebude čistý spojový seznam).

Pokud *pointer* nemá nikam ukazovat, realizuje se to odkazem tohoto *pointeru* na adresu NULL. To skoro doslovně říká „Nekazujji nikam“.



Co nám takto vystavěná struktura umožňuje v porovnání s polem? Přístup na konkrétní prvek v ní stojí lineárně času, protože ho musíme „prozkoumat“ od prvního prvku (na který máme *pointer*), tedy musíme udělat až  $O(N)$  kroků. Pokud bychom však *pointer* na daný prvek už nějak měli, samozřejmě na něj můžeme přistoupit v konstantním čase.

Naopak přidávání prvku na konkrétní místo (*i* jeřich odebrání) máme v podstatě zadarmo a spojový seznam můžeme rozšiřovat, dokud na něj máme v počítači paměť. Ve chvíli, kdy chceme přidat nový prvek za prvek, na který máme *pointer*, jen šikovně přepojíme ukazatele. Pokud předtím ukazatel vedl  $A \rightarrow B$ , teď povedou  $A \rightarrow C \rightarrow B$  (a při odebrání naopak).

Zde můžete vidět ukázkou *pointeru* a spojových seznamů v jazyce C, kde jsou tyto věci mnohem více nízkootrovně (ale zato rychlejší):

```
#include <stdio.h>
// Průkazy výše načety do programu
// standardní knihovna a funkce z nich.
// Struktura pro prvek obsahující dopředne
// i zpětné odkazy. Zříceně tomuto typu
// budeme říkat "tprev".
typedef struct prvek tprev;
struct prvek {
    int hodnota;
    prvek *dalsi;
    prvek *predchozi;
};
```

<sup>13</sup> <http://ksp.mff.cuni.cz/viz/kucharka/slozitosť>