Korespondenční Seminář z Programování

32. ročník **KSP** **Prosinec 2019**

Milí řešitelé, řešitelky a řešitelčata!

Letošní vánoční číslo KSP, které je zároveň třetím číslem jubilejního 2^5-tého ročníku KSPčka, vám právě přistálo ve vaší schránce nebo na vašem monitoru. Opět jsme si pro vás připravili 5 vypečených úloh (z toho nějaké praktické) a k nim navíc pokračování datového seriálu. Seriál po dvou minulých dílech **opouští OSM a bude si hrát s úplně novými daty – jízdními řády**. Proto se nebojte do seriálu zapojit, i pokud vám OSM data nesedla. A závěrem tohoto čísla je **kuchařka o tocích v sítích**.

Připomínáme, že 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 **přepočítávají podle vašeho služebního stáří** – na přesnou definici se podívejte do pravidel na webu.

Za úspěšné řešení KSP můžete být **přijati na MFF UK bez přijímacích zkoušek**. Úspěšným řešitelem se stává ten, kdo získá za celý ročník (této kategorie) alespoň 50 % bodů. Za letošní rok půjde získat maximálně 300 bodů, takže hranice pro úspěšné řešitele je 150. Maturanti pozor, pokud chcete prominutí 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, placku a možná i další překvapení.

Termín série: **24. února 2020 v 8:00**

Odevzdávání: Přes web na adrese *https://ksp.mff.cuni.cz/submit/*

Značky úloh:
- Lehčí úloha (či její část) vhodná pro začátečníky
- Open-data úloha
- Těžká úloha pro zkušené
- Seriálová úloha
- Úloha, u které doporučujeme začíst se do kuchařky

Odměna série: Každému, kdo **získá více než 3 body ze seriálu**, pošleme **sladkou odměnu**.

Třetí série třicátého druhého ročníku KSP

Na konci minulého dílu jsme opustili Hefaistos s kolonisty na palubě uprostřed základny zasažené iontovou bouří. Postupně se začaly hroutit štítové emitory a bylo to na vašem hlasování, o co by se posádka měla pokusit. Vybrali jste volbu, že se mají pokusit vzlétnout a dosáhnout orbity.

* * *

„Všichni připoutat, nouzový start!“ křikla kapitánka přes vnitřní interkom. „Na můj povel odpojte externí štítové emitory. Hned potom chci maximální výkon do motorů. Tři... dva... jedna... teď!“

Následující sekundu se stala spousta věcí. Nejprve štítový generátor Hefaista dramaticky snížil svůj výkon, aby se vzápětí od trupu oddělily svorky s kabely doposud vedoucími k štítovým emitorům na okraji kolonie. Hned jak zmizela bariéra bránící iontové bouři v postupu, tak se vysokoenergetické částice vrhly do kolonie – blesky začaly tančit po vnějších budovách kolonie a trhat je na kusy. Současně s tím ale pilot Hefaista spustil program nouzového vzestupu na orbitu a atmosférické motory se opřely do okolní země. Devítisettunová loď se začala rychle zvedat.

Nebylo to však dostatečně rychle – přes proud výfukových plynů pronikl jeden z blesků iontové bouře do atmosférického motoru na pravoboku. Motor samotný to sice přežil, ale část řídících obvodů se spálila na škvarek a výboj pronikl i dál do řídící elektroniky a způsobil množství zkratů. Hlavní řídící počítač Hefaista se odmlčel, ale naštěstí měly jednotlivé motory již zadané profily letu a během následujících bouřlivých minut dostaly loď až na oběžnou dráhu.

Potom, co všichni přestali být tlačeni do svých sedaček a naopak se po potemnělém interiéru ochromené lodě začaly vznášet neupevněné předměty, vrhla se posádka hned do zkoumání škod. Prvním krokem bylo izolování vyzkratovaných systémů, aby opět mohli nahodit hlavní počítač.

32-3-1 Zkrat — 12 bodů

Systémy hvězdné lodě Hefaistos jsou ochromené, protože část obvodů byla vyzkratována. Hlavní inženýr potřebuje nahodit počítačové jádro, ale to nelze, dokud existuje spojení počítačového jádra a místa zkratu.

Energetickou síť si můžeme představit jako energetické uzly spojené vodiči (jeden vodič spojuje vždy dva energetické uzly), kde v jednom energetickém uzlu je zkrat a do jiného energetického uzlu je zapojené přímo počítačové jádro.

Hlavní inženýr bude muset přerušit několik vodičů tak, aby neexistovala žádná cesta mezi místem zkratu a počítačovým jádrem. Vodiče jsou ale špatně dostupné, takže by jich chtěl hlavní inženýr přerušit co možná nejméně. Naprogramujte algoritmus, který mu určí, jaké vodiče má přerušit.

Toto je praktická open-data úloha. V odevzdávacím systému si necháte vygenerovat vstupy a odevzdáte příslušné výstupy. Záleží jen na vás, jak výstupy vyrobíte.

Formát vstupu: Na prvním řádku dostanete mezerou oddělená čtyři čísla N, M, z a p udávající počet energetických uzlů, počet vodičů mezi nimi, index energetického uzlu se zkratem a index energetického uzlu s počítačovým jádrem (energetické uzly indexujeme od nuly). Na dalších M řádcích je pak vždy dvojice mezerou oddělených čísel a a b udávající, že mezi energetickými uzly a a b vede vodič.

Formát výstupu: Na první řádek výstupu vypište číslo K udávající kolik nejméně musíme přerušit vodičů, abychom oddělili zkrat a počítačové jádro. Na dalších K řádcích pak vypište indexy vodičů, které musíme přerušit (index vodiče je jeho pořadí na vstupu, indexujeme opět od nuly, na poř-

dí indexů na výstupu nezáleží). Pokud existuje více stejně dobrých řešení, můžete vypsat libovolné z nich.

Ukázkový vstup:

```
9 13 7 2
0 2
4 0
2 3
1 2
1 3
0 1
2 4
3 5
4 6
6 7
6 8
7 5
7 8
```

Ukázkový výstup:

```
2
8
7
```

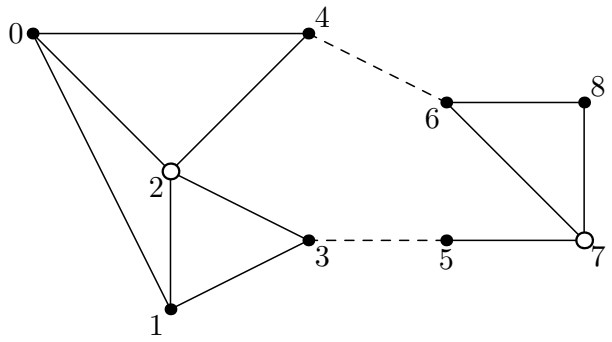

V příkladu výše stačí k oddělení dvou zvýrazněných vrcholů (zkratu a hlavního počítače) přerušit dva vodiče mezi uzly 4-6 a 3-5. Stejně tak by fungovalo i přerušení vodičů 4-6 a 5-7.

Po zprovoznění hlavního počítače a obnovení části systémů (ke spokojenosti žaludku kolonistů i pole umělé gravitace) se na můstku sešla část posádky na poradě.

„Jsme bez hyperprostorového pohonu, řídící obvody jsou na škvarek a nevím, jestli to půjde opravit," oznámil všem hlavní inženýr.

„Nepřišlo vám na té iontové bouři něco divného? A na té základně v horách?" načal diskuzi mariňák Drake. „Skoro jako by tady někdo vyvíjel tajnou zbraň," zapřemýšlel nahlas.

„A když se jim něco nepovedlo a přiletěli jsme my, tak se pokusili zamést stopy..." rozvinula jeho teorii kapitánka. Pak se otočila na komunikačního důstojníka: „Můžeme navázat spojení s velením na Antaraxu?"

Zax zavrtěl hlavou. „Ne, je tu rušení od iontové bouře na planetě, ale díky němu asi nejsme vidět ani my, dokud nezapneme motory. A navíc jsem si všimnul, že někdo mezitím překonfiguroval družice vypuštěné kolonií – změnily své komunikační linky a vytvořily novou síť, do které nejsme zapojení."

„Můžeme je nějak napíchnout?" zapřemýšlela kapitánka. „No když se nám povede odhalit jejich propojení, tak možná ano..." řekl Zax a pustil se do práce.

32-3-2 Hledání konstelace — 12 bodů

Komunikační důstojník Zax by potřeboval odhalit v jaké konstelaci jsou družice na oběžné dráze. Každou družici si můžeme představit jako vrchol a přímé propojení mezi dvojicí družic jako hranu nějakého grafu.

Graf neznáme, ale povedlo se nám zachytit nějaké servisní zprávy – některá by mohla udávat tvar této konstelace.

Přesněji se nám povedlo zachytit posloupnost N čísel, o které si myslíme, že to jsou počty propojů, které každá družice má (v grafové terminologii bychom toto číslo nazvali *stupněm vrcholu*). Nejsme si ale jistí, jestli zachycená posloupnost popisuje nějakou konstelaci – vymyslete proto algoritmus, který pro zadanou posloupnost N čísel (uspořádaných od nejmenšího po největší) rozhodne, jestli tato posloupnost může popisovat nějaký graf.

Můžete k tomu použít znalost **věty o skóre**.[1] Tato věta říká, že posloupnost N čísel $d_1, d_2, \ldots$ popisuje graf s vrcholy o stupních $d_1, d_2, \ldots$ právě tehdy když upravená posloupnost, ze které odebereme největší stupeň d_N a odečteme od d_N zbylých největších stupňů jedničku, také popisuje graf. Jednoduchá představa je, že z původního grafu odebereme vrchol s největším stupněm, který byl spojen s dalšími d_N vrcholy s největším stupněm.

K vyřešení úlohy nepotřebujete znalost důkazu této věty – můžete nám věřit, že platí. Pouhé naivní použití věty v algoritmu ale na moc bodů stačit nebude – chceme od vás algoritmus, který zvládne o zadané posloupnosti rozhodnout, jestli tvoří skóre nějakého grafu, v co nejlepším čase. Plného počtu bodů půjde dosáhnout jen za řešení v lineárním čase vzhledem k velikosti daného grafu, neboli v $\mathcal{O}(N + M)$.

Zatímco se Zax pokoušel nabourat se do družicové konstelace, tak kapitánka debatovala s ředitelem kolonie. Materiál pro stavbu tajné základny (nemluvě o spoustě jiné techniky) musel být na planetu nějak dopraven, a to pravděpodobně na palubě běžných zásobovacích lodí.

Při kopírování hlavního počítače kolonie získali i soubory o různých kontejnerech dopravených na planetu a naopak v tajné základně získali inventární seznam jejich skladu – teď to jenom napasovat na sebe a možná to dá nějaké zajímavé indicie. Kapitánka s ředitelem se dali do identifikace kontejnerů, do kterých by se různé věci nalezené na tajné základně vešly.

32-3-3 Kontejnerové počty — 11 bodů

Kapitánka se ředitelem kolonie by chtěli rychle vyfiltrovat kontejnery, do kterých se vejde předem daná hromada vybavení. Kontejnery jsou kvádry o rozměrech $A \times B \times C$ s maximální délkou strany K.

Protože hromada vybavení nemá žádný hezký pravidelný tvar (různé tyče, zahnuté potrubí, kulaté nádrže, ...), tak se nedá lehce určit, jak velký kontejner je potřeba. Kapitánka s ředitelem si vždycky vezmou pevnou hromadu vybavení a pak zkoumají, do jakého kontejneru by se vešla. Pro zadané A, B a C umí určit (poměrně náročným a zdlouhavým postupem), jestli se vybavení do takového kontejneru vejde, nebo ne.

Protože je ale možných velikostí kontejnerů řádově K^3, tak se jim nechce pro každou kombinaci rozměrů samostatně počítat, jestli se věci vejdou – ocenili by drobnou pomoc.

Ohledně kontejnerů platí jediné pravidlo, a to, že pokud se zadaná hromada vybavení vejde do kontejneru $A \times B \times C$ a tento kontejner se (nějak pravoúhle otočený, šikmé umístění neuznáváme) vejde do druhého kontejneru $A' \times B' \times C'$ (tedy že otočený první kontejner není v žádné ose větší než druhý kontejner), tak se vybavení vejde i do druhého kontejneru.

Například můžeme říci, že pokud se vybavení vejde do kontejneru $5 \times 2 \times 10$, tak se určitě vejde i do kontejneru $2 \times 10 \times 11$. Naopak o kontejneru $9 \times 9 \times 9$ ale nemůžeme prohlásit nic (a budeme se muset zeptat lidské obsluhy).

Vaším úkolem je vymyslet algoritmus, který (pro pevně danou hromadu věcí) nejdříve položí dotazy na nějaké velikosti kontejnerů kapitánce se ředitelem, a pak bude umět správně odpovědět na jakýkoliv dotaz pro $A, B, C \leq K$. Vaším cílem je minimalizovat počet „pomalých" dotazů na ka-

[1] https://cs.wikipedia.org/wiki/Sk%C3%B3re_grafu

pitánku se ředitelem – minimalizujte i multiplikativní konstantu a zkuste dokázat, že na méně dotazů už to nelze.

⇧ **Lehčí varianta (za 7 bodů):** Vyřešte úlohu jenom ve 2D, tedy namísto kvádrů uvažujte pouze obdélníky o rozměru $A \times B$.

Po odečtení kontejnerů, které s jistotou byly rozebrané v kolonii, a kontejnerů, které podle výpočtu byly použity pro materiál na tajné základně, dospěli k tomu, že schází zhruba půl tuctu kontejnerů, které musely být dovezené ještě někam jinam. Materiál v nich by stačil na stavbu zhruba poloviční základny, než byla ona objevená tajná základna v horách. Teď už ji jen najít...

Zaxovi se mezitím povedlo zjistit konfiguraci družicové sítě. Jenom s pomocí manévrovacích trysek se Hefaistos pomalu přesunul k jedné z družic. Když pilot stabilizoval loď dvacet metrů od družice, tak se k ní vydali dva členové posádky ve skafandrech a v domluvenou chvíli jí přerušili napájení. Přesně v tu samou chvíli anténní soustava Hefaista ožila a začala se vydávat za právě odpojenou družici – snad si nikdo ničeho nevšimne.

Poté dopravili družici skrz malý hangár pro servisní raketoplán do nákladního prostoru Hefaista, kde se na ni vrhl hlavní inženýr. Uvnitř těla družice narazil na zajímavou komponentu, která vypadala dost jako prototyp – spousta drátů zapojených do různých konektorů na různých přístrojích. Po chvíli rozebírání si ale s hrůzou uvědomil, že si nedělal poznámky, kam který drát patří...

32-3-4 Zmatek v konektorech — 11 bodů

Hlavní inženýr rozebral zkoumanou družici, ale teď by potřeboval pozapojovat vytažené dráty nazpět. Má teď v ruce spoustu koncovek, ale neví, do kterého konektoru kterou koncovku zapojit. Naštěstí mají koncovky i konektory více různých tvarů, ale nejsou bohužel úplně unikátní. Přesněji každou koncovku lze zapojit do právě dvou různých konektorů.

Vymyslete algoritmus, který pro zadané koncovky (pro každou koncovku dostaneme zadaná čísla právě dvou konektorů, kam pasuje) najde správné zapojení, nebo oznámí, že to nelze. Správné zapojení je takové, kdy je každá koncovka zapojená do právě jednoho konektoru a v žádném konektoru není více než jedna koncovka.

Příklady:

- Koncovky $(1, 2)$ a $(3, 4)$ lze triviálně zapojit třeba tak, že první koncovku zapojíme do konektoru 1 a druhou do konektoru 4.
- Koncovky $(1, 2)$, $(2, 3)$ a $(3, 1)$ lze také správně zapojit.
- Naopak koncovky $(1, 2)$, $(1, 3)$, $(1, 4)$, $(3, 2)$, $(3, 4)$ a $(5, 6)$ správně zapojit nelze.

„Někdo ty satelity upravil kapitáne. Tohle jsem ještě neviděl, ale podle zapojení a komponent bych hádal, že to nějakým způsobem ovládá směrování iontové bouře. Má to celkem velkou energetickou náročnost, ale za chodu to už čerpá energii z iontové bouře. Na detaily se mě neptejte, sám tomu úplně nerozumím," vysvětloval po pár hodinách zkoumání satelitu hlavní inženýr McCormack ostatním.

„Co je ale zajímavé, je, že ve stand-by režimu to musí být extrémně úsporné, aby to zvládlo parazitovat na normálních součástkách satelitu. A to si to každou hodinu posílá docela komplikované zprávy po celé síti..."

32-3-5 Energetická náročnost — 10 bodů

Pro propočty ohledně fungování satelitní sítě je potřeba spočítat její energetickou náročnost ve stand-by režimu. Již jsme zjistili, že satelity jsou pospojované do souvislé sítě ve tvaru stromu a známe energetickou náročnost poslání zprávy mezi propojenými satelity (jinými slovy máme strom s ohodnocenými hranami).

Každou hodinu každý z N satelitů vyšle zprávy všem $N-1$ zbylým satelitům. Zprávy putují po satelitní síti nejkratší cestou a energie spotřebovaná na předání jedné zprávy po nějaké „hraně" odpovídá ohodnocení této hrany. Protože komunikační protokol navazuje nové spojení pro každou zprávu, tak předání k zpráv po hraně ohodnocené „cenou" c stojí celkově $k \cdot c$ jednotek energie.

Nás by zajímala celková spotřebovaná energie když každý ze satelitů vyšle zprávu každému jinému. Vymyslete algoritmus, který to pro zadanou síť zvládne spočítat co nejrychleji.

Příklad: Pro satelitní síť na obrázku níže je celková spotřebovaná energie pro vyslání všech zpráv ze všech 5 satelitů celkem 152 jednotek energie. Zprávy ze satelitu A spotřebují 27 jednotek energie, ze satelitu B také 27 jednotek, ze satelitu C 24 jednotek, ze satelitu D 34 jednotek a ze satelitu E 40 jednotek energie.

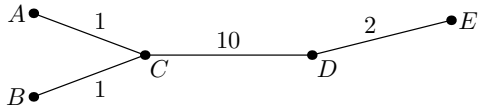

Díky všem indiciím se povedlo posádce Hefaista koncem dne lokalizovat druhou tajnou základnu na planetě. Pokud mohli hádat, tak právě odsud byly kontrolovány iontové bouře a tam sídlil někdo, kdo se rozhodl, že nepotřebuje svědky, kteří vědí příliš mnoho.

Nadsvětelná komunikace s velením na Antaraxu byla pořád blokovaná a následky iontové bouře, které oslepovaly senzory tajemné základny a ukrývaly poničeného Hefaista, postupně slábly. Brzy je odhalí a těžko říci, jaké další akce podniknou k tomu, aby se zbavili svědků. Nyní byla ale karta stále na straně Hefaista, jenom se rozhodnout, co podniknout...

⋆⋆⋆

Opět rozhodněte o tom, jak má příběh pokračovat. Hlasujte do ***10. února*** *v anketě.*[2]

Třetí díl příběhu pro vás sepsal

Jirka Setnička

[2] `https://poll.ly/#/LbjXAbRw`

32-3-6 Jízdní řády — 15 bodů

V tomto dílu se od map přesuneme k dalšímu druhu reálných dat, se kterým se většina z vás v každodenním životě potkává celkem často: jízdním řádům veřejné dopravy. Upozorňujeme, že v tomto dílu seriálu budete používat **jiné datové sady** než v předchozích dvou, podrobněji o nich níže.

Kde vzít data

Dlouho bylo v ČR velmi obtížné až nemožné sehnat data jízdních řádů ve strojově zpracovatelném formátu. V posledních letech se díky úsilí mnoha organizací i jednotlivců situace zlepšuje.

Praha. Nejjednodušší je situace v Praze a okolí, kde jsou k dispozici velmi kvalitně zpracované jízdní řády ve standardním formátu GTFS (o kterém bude řeč níže) pro celou síť Pražské integrované dopravy (PID). Existují dvě verze, jedna publikovaná pražským dopravním podnikem (DPP), druhá organizací ROPID, která má na starost organizaci PID. My se zaměříme na data z ROPIDu,[3] která jsou o něco úplnější, detailnější a lépe strukturovaná. Obsahují informace o všech linkách PID – městských i příměstských, včetně vlaků. Jsou aktualizována denně a obsahují i krátkodobé výluky a omezení provozu.

Zveřejnění těchto dat má zajímavou historii. Jan Cibulka, novinář Českého rozhlasu, si v roce 2013 všiml informací o spojích DPP v Mapách Google. Na základě zákona o svobodném přístupu k informacím (který dává státním úřadům a firmám povinnost na žádost poskytnout informace vztahující se k jejich činnosti) požádal DPP o kopii dat předávaných Googlu. Obdržel GTFS dataset, který následně zveřejnil.

Zpráva se rychle roznesla a od té doby chodil na DPP každý měsíc rostoucí počet žádostí o poskytnutí aktuálních dat, kterým bylo vždy vyhověno, ale všechny žádosti o trvalý přístup k datům byly zamítány. Až v roce 2015 dopravní podnik obrátil (asi je to přestalo bavit vyřizovat) a začal poskytovat údaje pro trvalý přístup k aktuálním jízdním řádům. O něco později pak došlo k oficiálnímu zveřejnění na webu. Verze od ROPIDu je čerstvou novinkou z roku 2019.

Liberec. GTFS data nabízí také Dopravní podnik měst Liberce a Jablonce nad Nisou (DPMLJ). Na rozdíl od pražských dat obsahují pouze MHD v obou městech (plus tramvajovou linku mezi Libercem a Jabloncem) a nikoli příměstské spoje.

Zbytek republiky. Pro linkovou dopravu a MHD v ostatních městech je hlavním zdrojem informací *Celostátní informační systém o jízdních řádech (CIS JŘ)*. Tento systém byl vznikl v roce 2000 jako iniciativa ministerstva dopravy a všichni dopravci ve veřejné linkové dopravě jsou ze zákona povinni nahrávat do něj své jízdní řády.

Provoz tohoto systému byl svěřen společnosti Chaps, která na základě těchto dat provozuje známý vyhledávač spojení IDOS. Ovšem strojově zpracovatelná data o jízdních řádech veřejně k dispozici nebyla a protože Chaps je soukromá firma, zákon o svobodném přístupu k informacím na ni použít nešel. Teprve po několika letech a nátlaku velkých společností (např. Seznam.cz) udělilo ministerstvo provozovateli povinnost data zveřejňovat.

Struktura dat a použité formáty v CIS jsou trochu nezvyklé. K dispozici jsou tři velké balíky dat:

- První obsahuje data o autobusech, linkových i městských, ve formátu JDF (vytvořeném pro potřeby CIS, nikde jinde se nepoužívá).
- Druhý obsahuje informace o trolejbusových a tramvajových provozech napříč celou republikou, také ve formátu JDF.
- Třetí obsahuje informace o vlacích v XML formátu vycházejícím z evropského standardu TAP TSI.

Odkaz na jednotlivé datové soubory najdete na stránce seriálu.[4]

Takže pokud byste chtěli vyhledávat spojení např. v brněnské MHD, musíte si z jednoho balíku vyzobat správné jízdní řády tramvají a trolejbusů, z druhého autobusy a případně ještě z třetího (v úplně jiném formátu) městské vlaky. Ucelené jízdní řády MHD v jednotlivých městech či integrovaných dopravních systémů jednotlivých krajů k dispozici nejsou.

Formát CSV

Nejprve si stručně povíme o formátu CSV (comma-separated values), na kterém jsou založené GTFS i JDF. CSV je jednoduchý formát pro reprezentaci dvourozměrné tabulky textovým souborem. Každý řádek souboru představuje jeden řádek tabulky a jednotlivé sloupce jsou odděleny čárkou (případně jiným znakem, často potkáte třeba středník nebo tabulátor).

Pokud text v nějakém sloupci obsahuje čárku, je uzavřen do uvozovek.

Některé CSV soubory mají na prvním řádku hlavičku s názvy sloupců – potom nezáleží na pořadí sloupců a můžete se orientovat podle názvů. To platí třeba pro GTFS. Naopak JDF obsahuje CSV soubory bez hlavičky, takže musíte vědět, kolikátý sloupec co znamená.

Pokud si chcete CSV soubor manuálně prohlédnout, můžete ho kromě textového editoru otevřít taky většinou tabulkových kalkulátorů, jako např. LibreOffice Calc.

V Pythonu lze CSV soubory načíst pomocí modulu csv[5] – třídy `DictReader` pro soubory s hlavičkami a `reader` pro soubory bez hlaviček.

Formát GTFS

GTFS (General Transit Feed Specification) je formát vytvořený společností Google. Původně byl vytvořen, aby v něm poskytovali dopravci informace o spojích pro vyhledávač spojení v Mapách Google. Ale postupně se z něj stal docela rozšířený standard.

Základní struktura GTFS je tvořena několika typy objektů popsanými níže. Každý objekt má jednoznačný identifikátor (ID), pomocí kterého se na něj můžou jiné objekty odkazovat (a jinak nemá obvykle žádný význam). Pokud jste se někdy potkali s cizími klíči v SQL databázích, tohle je velmi podobný princip.

GTFS balík s jízdními řády (zvaný *feed*) je ZIP archiv plný CSV souborů. Až na pár výjimek každý soubor popisuje

[3] `https://pid.cz/o-systemu/opendata/`

[4] `http://ksp.mff.cuni.cz/viz/serial-jr`

[5] `https://docs.python.org/3/library/csv.html`

objekty určitého typu, jeden na řádek, kde sloupečky jsou jednotlivé vlastnosti. První řádek souboru obsahuje názvy sloupečků.

V GTFS potkáme následující druhy objektů.

Zastávky (`stops.txt`). Každý záznam ve `stops.txt` má jednoznačný identifikátor (`stop_id`), název (`stop_name`) a zeměpisné souřadnice (`stop_lat`, `stop_lon`). Navíc obsahuje parametr `location_type`, kterým je rozlišeno několik druhů záznamů:

- **0: Stanoviště** – tedy konkrétní místo, kde může vozidlo zastavit. Například běžná nepřestupní zastávka je typicky tvořena dvěma stanovišti: na každé straně ulice jedno pro jeden směr. U přestupních uzlů je typicky rozmístěno více stanovišť třeba kolem jedné křižovatky, kde každé má svůj identifikátor, i když typicky sdílí název zastávky. Více stanovišť najdeme taky třeba na autobusových nádražích, kde každé je typicky označené nějakým číslem či písmenem. V přední části každého stanoviště je obvykle umístěna dopravní značka, které se říká *označník* či *zastávkový sloupek*, na které bývají navíc umístěné jízdní řády. Občas se pojem *označník* či *sloupek* přeneseně používá i pro stanoviště jako celek.Stanoviště může obsahovat ve sloupečku `parent_station` ID uzlu (viz dále), ke kterému patří, a ve sloupečku `platform_code` veřejné označení stanoviště v rámci uzlu (např. číslo/písmeno). Zeměpisné souřadnice u stanoviště obvykle udávají přesnou polohu označníku, tedy předního konce stanoviště.
- **1: Stanice nebo uzel** – představuje skupinu stanovišť, které logicky nějak „patří k sobě“. V případě jednoduché nepřestupní zastávky budou uzel tvořit dvě protisměrná stanoviště, v případě přestupního uzlu všechna stanoviště, která jsou soustředěná blízko sebe na jednom místě a lidé mezi nimi běžně přestupují. Uzel může taky seskupovat všechna stanoviště v rámci autobusového či vlakového nádraží společně se zastávkami MHD před nádražím.
- **2: Vchod/východ** – udává pozici vstupu z ulice do prostor stanice, pokud stanoviště není přímo na ulici. Nejčastěji potkáte u vstupů do metra, případně vchodů do nádražní budovy. Opět pomocí `parent_station` přiřazen ke stanici.
- **3: Obecné místo** – popisuje další místa uvnitř stanic, která nejsou ani stanoviště, ani vchody – např. různé vestibuly a chodby. Dá se použít pro navigaci uvnitř stanic společně s `pathways.txt`.
- **4: Nástupní oblast** – popisuje část nástupiště. Dlouhá nástupiště typicky bývají rozdělena na více oblastí. Ve spolupráci s `pathways.txt` se dá použít například k tomu, abyste poznali, že z jednoho konce soupravy metra je to blíž ke konkrétnímu výstupu než druhého a třeba to mohli zohlednit v čase potřebném na přestup.

Zmiňovaný soubor `pathways.txt` popisuje cesty mezi body uvnitř stanic – tedy v zásadě hrany grafu, jehož vrcholy jsou body uvnitř stanic (stanoviště, vchody, obecná místa, nástupní oblasti). Každá hrana obsahuje identifikátory vrcholů na obou koncích (`from_stop_id`, `to_stop_id`), odhadovaný čas chůze v sekundách (`traversal_time`), druh cesty (`pathway_mode`, např. 1=chodba, 2=schody, 4=eskalátor, 5=výtah), příznak obousměrnosti (`is_bidirectional`) a případně informaci o tom, jaký nápis hledat na cedulích, když chce člověk jít daným (`signposted_as`) či opačným (`reversed_signposted_as`) směrem. Standard umožňuje popsat i spoustu dalších věcí, jako například počet schodů či minimální průchodnou šířku, my se omezili na ty, které jsou v datech PID.

Body ve stanicích můžou mít také atribut `level_id` (odkazující se do `levels.txt`) udávající, v jaké úrovni nad/pod zemí se daný bod nachází.

Podívejme se ještě krátce na specifika zastávek v pražských datech. Zastávky povrchové dopravy jsou reprezentovány záznamy typu stanoviště, které *nemají* vyplněný atribut `parent_station`. Sdružení zastávek do uzlů poznáme podle jejich `stop_id`, který má tvar `U`*číslo*`Z`*číslo*`[`*pásmo*`]`, kde první číslo identifikuje uzel a druhé stanoviště v rámci uzlu. Na konci můžou být ještě nějaké znaky upřesňující tarifní pásmo. Podle čísla uzlu můžeme zastávky seskupit do uzlů.

U stanic metra vypadá situace trochu jinak. Každá má dvě stanoviště (pro každý směr jedno, resp. čtyři v případě přestupních stanic), dále k ní existuje záznam typu stanice s identifikátorem `U`*číslo*`S1`, záznamy popisující vstupy (`U`*číslo*`S1E`*číslo*), záznamy popisující vnitřní strukturu stanic (vestibuly a chodby, `U`*číslo*`N`*číslo*). Všechny záznamy patřící k dané stanici metra mají nastavený `parent_station`. Stanice metra typicky sdílí číslo uzlu se zastávkami povrchové dopravy v její blízkosti, ale ty už `parent_station` nastavené nemají.

Železniční stanice jsou popsané jen jedním vrcholem typu stanoviště, nástupiště se nerozlišují.

Trasy spojů (viz níže) se odkazují pouze na `stop_id` typu stanoviště.

Na stránkách ROPIDu je navíc k dispozici podrobný seznam zastávek s detaily, které se do GTFS nevešly. K dispozici je ve formátu JSON (načtete v Pythonu triviálně pomocí modulu `json`) nebo XML. Struktura je dobře zdokumentovaná přímo tam, takže zde nebudeme opakovat.

Vše si ukážeme třeba na příkladu přestupního uzlu U237 Karlovo náměstí, kde uvádíme jen zkrácené identifikátory (např. `Z1` místo `U237Z1P` či `E1` místo `U237S1E1`):

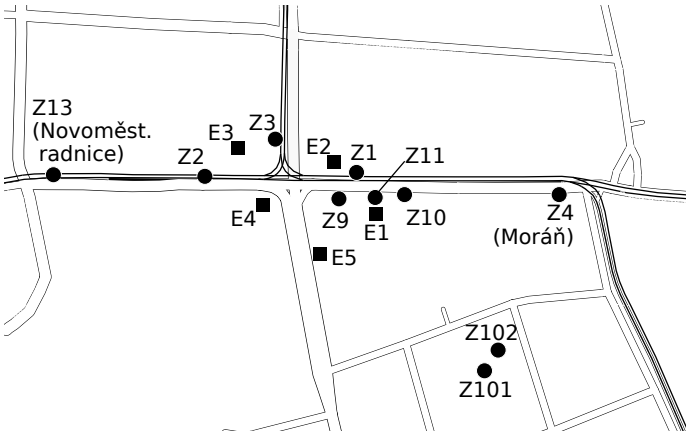

Z1 až Z3 jsou tři tramvajová stanoviště nesoucí název Karlovo náměstí, kde staví tramvaje jedoucí různými směry. Z4 a Z13 jsou tramvajové zastávky o kus dál, které oficiálně pro cestující mají jiné názvy (Moráň a Novoměstská radnice), ale interně jsou považovány za součást stejného uzlu. Obě jsou jednosměrné (staví tam jen tramvaje ve směru od Karlova náměstí), proto mají jen jedno stanoviště. Například linka 22 zastaví v jednom směru na Z3 a pak Z13, v druhém jen na Z2.

Z101 a Z102 jsou stanoviště metra B (pro každý směr jedno). Jejich poloha zhruba odpovídá tomu, kde se pod zemí

skutečně nachází prostředek nástupiště. E1 až E5 jsou vstupy do metra.

Z9, Z11 a Z10 jsou tři autobusová stanoviště ležící u jedné nástupní hrany těsně za sebou, ale každé má svůj označník a staví u něj trochu jiné linky.

K tomuto uzlu patří ještě vstupy do metra (E6 až E8) a tramvajové zastávky (Z5 až Z8) na Palackého náměstí, které už se nám do mapky nevešly. Též nezobrazujeme body popisující vnitřní strukturu stanice metra. Celkem uzel obsahuje 12 stanovišť povrchové dopravy, 2 stanoviště metra, 9 vstupů do metra, 19 pomocných bodů ve stanici metra a 1 záznam pro stanici metra jako celek.

Největší vzdálenost v tomto uzlu je mezi stanovišti Novoměstská radnice a Palackého náměstí, 700 metrů chůze. Na tom je vidět, že příslušnost ke stejnému uzlu je jen velmi hrubým měřítkem toho, mezi kterými stanovišti lze rychle a pohodlně přestoupit.

Spoje (`trips.txt`). Každý spoj popisuje jednu cestu vozidla na nějaké lince z konečné na konečnou v nějakém konkrétním čase. Soubor `trips.txt` obsahuje základní informace o spojích (jeden řádek na spoj): `trip_id` je jednoznačný identifikátor spoje, `route_id` je identifikátor linky, ke které spoj patří, a `service_id` je identifikátor *kalendáře* udávajícího, ve které dny spoj jezdí (např. „pondělí a pátky kromě 24.12.“).

Dále je u každého spoje popsaná jeho trasa – v zásadě posloupnost trojic (identifikátor zastávky, čas příjezdu, čas odjezdu). Každé takovéto trojici budeme říkat jedno *zastavení* daného spoje. Trasy spojů se nachází v samostatném souboru `stop_times.txt`. Každý řádek představuje jedno zastavení nějakého spoje. Obsahuje následující položky:

- `trip_id` – identifikátor spoje
- `stop_sequence` – pořadí toho zastavení na trase spoje (počítá se od jedničky, číslování nemusí být souvislé, na fyzickém pořadí řádek v souboru nezáleží)
- `arrival_time` a `departure_time` – čas příjezdu a odjezdu (textově ve formátu hh:mm:ss, v místní časové zóně), u spojů jedoucích přes půlnoc potkáme časy jako třeba 24:15:00
- `stop_id` – identifikátor zastávky (v případě pražských dat přesněji identifikátor stanoviště)

Všimněte si, že u každého spoje je uvedena jeho kompletní trasa – formát nijak nepředpokládá, že např. všechny spoje na nějaké lince mají stejnou trasu. To ani v praxi mít nemusí: např. některé spoje jedou jen zkrácenou část trasy linky, spoje zatahující do vozovny mají nestandardní trasu, u některých linek je třeba část trasy v jednom směru odlišná od opačného směru atd. I když mají spoje na lince stejnou trasu, často se třeba v různých denních dobách liší jízdní doby (podle intenzity dopravy).

Při hledání spojení je obvykle nejjednodušší zapomenout na to, že nějaké linky existují a pracovat pouze s jednotlivými spoji. Informace o lince se stále hodí, např. k tomu, abychom ji mohli zobrazit uživateli (a ten věděl, do čeho má nastoupit).

Linky (`routes.txt`). U linek nás bude zajímat jen pár základních údajů:

- `route_id` – jednoznačný identifikátor linky
- `route_short_name` – veřejné označení linky, typicky číslo linky (resp. u metra písmeno, můžou se vyskytnout i jiné speciality typu linky H1 pro přepravu vozíčkářů)
- `route_type` – typ vozidla. V PID potkáte: 0=tramvaj, 1=metro, 2=vlak, 3=autobus, 4=přívoz, 7=kolejová lanovka (na Petřín), 800=trolejbus (tohle je lokální konvence, GTFS nemá standardní kód pro trolejbusy)

Kalendáře (`calendar.txt`). Každý kalendář určuje množinu dnů, ve kterých spoje s tímto kalendářem jezdí. Základní vymezení kalendáře je pomocí rozsahu dat, kdy spoje jezdí (od `start_date` do `end_date`) a dnů v týdnu, ve kterých jezdí (sloupečky `monday` až `sunday` obsahující hodnoty 0/1). Navíc lze do kalendáře přidávat výjimky pro konkrétní data (např. státní svátky). Ty jsou uvedené v souboru `calendar_dates.txt`, každý řádek popisuje jednu výjimku: `service_id` je identifikátor kalendáře, na který se vztahuje, `date` je konkrétní datum a `exception_type` je 1=spoje v tento den výjimečně jedou, 2=spoje v tento den výjimečně nejedou (oproti pravidelnému kalendáři).

Specialitou pražských dat je, že jsou vydávána pouze na týden dopředu, takže i výjimky v kalendáři najdete jen pro následující týden.

XML formát pro vlaky

Poznámka: pro vaše pohodlí jsme napsali skript pro převod z XML formátu do GTFS. Skript i výsledné vlakové GTFS najdete na stránkách seriálu. Tedy pokud chcete, můžete tuto kapitolu přeskočit. Ale pokud jste zvědaví, pokračujte dál.

Balík s vlakovými jízdními řády je ZIP archiv plný XML souborů. Každý soubor popisuje jeden spoj a jeho trasu. O zpracování XML už byla řeč v předchozích dílech seriálu, teď to bude trochu jednodušší, protože se vám celý dokument vejde do paměti.

Většinu pro nás důležitých informací se skrývá uvnitř prvku `<CZPTTInformation>`, (který je potomkem kořenového prvku `<CZPTTCISMessage>`). `<CZPTTInformation>` má:

- Jednoho potomka `<PlannedCalendar>` popisujícího, ve které dny vlak jezdí.
- Více potomků `<CZPTTLocation>`, které dohromady popisují trasu vlaku. Každý představuje jeden bod na trase vlaku.

Překvapivě některé základní údaje, jako třeba druh nebo číslo vlaku, jsou uvedené u každého bodu trasy. Existují totiž třeba vlaky, které po cestě změní číslo nebo se promění z rychlíku na osobní vlak, byť jich není mnoho.

Kalendář vlaku. Narozdíl od GTFS se zde vůbec neoperuje s dny v týdnu. Prvek `<ValidityPeriod>` s potomky `<StartDateTime>` a `<EndDateTime>` udává základní rozsah dat, ve kterém vlak jezdí. Data jsou uvedena ve formátu např. `2020-11-01T00:00:00`. Časová složka je vždy `00:00:00` a nenese žádný význam. Obě koncová data jsou včetně. To je trochu matoucí, protože když je `<EndDateTime>` `2020-11-01T00:00:00`, vlak 1.11. ještě naposledy jede, přestože zápis vypadá, jako by provoz o půlnoci končil.

V rámci svého rozsahu platnosti může vlak jet jen v některé dny. To je určeno prvekm `<BitmapDays>`. Ten obsahuje řetězec jedniček a nul stejně dlouhý jako rozsah platnosti vlaku. Přitom k-tý znak tohoto řetězce udává, jestli vlak jede k-tý den svého rozsahu platnosti.

Existují i speciální vlaky, které jedou jen jeden den v roce. Ty mají uvedený ve `<StartDateTime>` datum jízdy, v `<BitmapDays>` řetězec `1` a `<EndDateTime>` úplně chybí.

Některé vlaky mají v určité dny jinou trasu – např. zkrácenou či prodlouženou či vynechávají nějakou zastávku (třeba v chatařské osadě staví jen o víkendech v létě). To tento formát neumí reprezentovat, takže je prostě příslušný vlak uvedený dvakrát (ve dvou různých XML souborech), pokaždé s jinou trasou a rozsahem platnosti, ale stejným číslem.

Trasa vlaku. Trasa vlaku je zapsána posloupností prvků `CZPTTLocation`. Každý z nich udává nějaké místo na trase vlaku (typicky stanici nebo zastávku, ale občas se objeví i nějaká interní provozní místa, např. „Brno hl.n. přednádr.“). Na trase mohou být uvedena nejen místa, kde vlak staví, ale i místa, kterými projíždí. U každého místa je uveden plánovaný čas příjezdu a odjezdu (resp. průjezdu). Narozdíl od GTFS je pořadí bodů na trase dáno jejich pořadím v XML souboru.

Prvek `CZPTTLocation` má následující potomky:

- `<PrimaryLocationName>` – název stanice (či zastávky). Z historických důvodů se některé názvy uvádí zkrácené, např. „Praha Masaryk.n.“ či „Jablonec n.N. dol.n.“
- `<LocationPrimaryCode>` – číslo stanice v číselníku SR 70 (viz níže), pětimístné bez kontrolní číslice. Pomocí něj lze dohledat další informace o stanici, např. plný název či zeměpisné souřadnice. Ve vlakových jízdních řádech se nerozlišují jednotlivá stanoviště (nástupiště, staniční koleje), protože se obvykle přidělují dynamicky za provozu. Kód tedy identifikuje stanici jako celek.
- `<OperationalTrainNumber>` – číslo vlaku platné počínaje touto stanicí (jen číselná část, neobsahuje druh vlaku).
- `<TrafficType>` – druh vlaku (11=osobní, C3=spěšný, C2=rychlík, C1=expres – sem obvykle patří i další vlaky vyšší kvality, např. EC, IC, SC)
- `<CommercialTrafficType>` – číslo vyjadřující tzv. komerční druh vlaku (Os, R, IC, SC, RJ, …), tedy to, co se obvykle uvádí jako součást čísla vlaku (např. „SC 507“). Např. 84=Os, 157=R, 63=IC, 50=EC, … Více hodnot se dá najít na stránkách seriálu.
- `<TimingAtLocation>` udává časy příjezdu a odjezdu. Jeho potomky jsou prvky `<Timing>` s rolí danou atributem `TimingQualifierCode`. `ALA` znamená čas příjezdu a `ALD` čas odjezdu. Některý z nich může chybět, například konečná stanice nemá čas odjezdu. V případě průjezdu či krátkého zastavení bývají oba časy shodné. Časy jsou uvedené ve tvaru `15:00:00.0000000+01:00`. Část `+01:00` je časové pásmo, u nás ho můžeme ignorovat a vše považovat za místní čas.
- `<TrainActivity>` popisuje tzv. „aktivity“ vlaku v daném místě, což znamená např. informace o zastavování vlaku a (ne)čekání na přípoje. Může obsahovat jeden nebo více potomků `<TrainActivityType>`, každý z nich nese číselný kód popisující jednu aktivitu. Důležité kódy: 0001 = vlak v dané stanici zastavuje (pokud není uvedeno, stanici projíždí), 0028 = zastavení jen pro nástup, 0029 = zastavení jen pro výstup (obojí uváděno spolu s 0001). Pokud vlak stanicí projíždí, prvek `<TrainActivity>` může zcela chybět.
- `<ResponsibleRU>` udává kód dopravce vlaku počínaje touto stanicí (ano, i dopravce se může po cestě vlaku změnit, typicky se to stává u mezinárodních vlaků, které na území každé země formálně provozuje jiný dopravce). Seznam dopravců a postup k jeho získání najdete na stránkách seriálu.

Číselník stanic SR 70 je dlouhá tabulka obsahující seznam všech stanic, zastávek a dalších významných míst v české železniční síti, tak trochu obdoba souboru `stops.txt` v GTFS. Dá se stáhnout ze stránek Správy železniční dopravní cesty (SŽDC) ve formátu XLSX, který se dá třeba pomocí LibreOffice zkonvertovat do CSV a pak s ním jde rozumně pracovat. Na stránkách seriálu najdete už zkonvertovaný. Zajímavé sloupečky jsou:

- `SR70` – číselný kód místa. Je to šesticiferné číslo, kde poslední číslice je kontrolní a dá se spočítat z předchozích. V XML jízdních řádech je jen prvních pět číslic, takže při porovnání je třeba poslední číslici zahodit.
- `Tarifní název` – plný název
- `GPS X`, `GPS Y` – zeměpisná délka a šířka

Pokud použijete naše vlakové GTFS, v něm už jsou informace ze SR 70 a číselníku dopravců zahrnuté, takže je nemusíte shánět zvlášť.

Formát JDF aneb celostátní informační chaos

Formát JDF zde popisujeme pro úplnost, kdybyste si třeba chtěli hrát s jízdními řády ve svém oblíbeném městě, ale k řešení úloh ho potřebovat nebudete.

Soubor, který si stáhnete z CIS JŘ, je ZIP archiv, který obsahuje hromadu několik stovek až tisíc vnořených ZIP archivů – pro každou linku jeden. Asi je nechcete rozbalovat ručně jeden po druhém, místo toho doporučujeme v Pythonu modul zipfile,[6] který umí se ZIP soubory zacházet programově. Taky se vám může hodit funkce `os.listdir` pro vypsání obsahu adresáře. Alternativně můžete archivy rozbalit pomocí unixového shellu (o kterém byla řeč v seriálu 27. ročníku),[7] například takovýmto příkazem:

```
for file in *.zip; do
    unzip $file -d $(basename $file .zip)
done
```

Podívejme se nyní na obsah jednoho linkového ZIP archivu. Strukturou se podobá GTFS – obsahuje několik CSV souborů, které popisují např. zastávky nebo spoje. Na rozdíl od GTFS jsou to CSV bez hlavičky, navíc je ještě na konci každého řádku středník. Jsou uložené v kódování CP1250 namísto standardního UTF-8. V Pythonu můžete při otvírání souboru určit kódování takto: `open("soubor.txt", "r", encoding="windows-1250")`. Aktuálně se používají čtyři různé verze JDF: 1.8 až 1.11, které se liší počtem a občas i pořadím sloupců (občas je v nějaké verzi vložen nový sloupec doprostřed, takže všemu za ním se posune číslo sloupce). Dokumentaci k jednotlivým verzím lze najít v metodických pokynech ministerstva dopravy, na které odkazujeme ze stránky seriálu.[8]

Protože načítání takovýchto souborů je velmi nepohodlné, připravili jsme pro vás verzi v našem vlastním formátu „JDF-H“. Ten se liší několika věcmi:

- Všechny CSV soubory mají hlavičky s názvy sloupců
- Soubory mají kódování UTF-8 a unixové konce řádků
- Na konci řádků nejsou středníky
- V ZIP archivu jsou podadresáře místo vnořených ZIPů

[6] `https://docs.python.org/3/library/zipfile.html`
[7] `http://ksp.mff.cuni.cz/viz/27-1-7`
[8] `http://ksp.mff.cuni.cz/viz/serial-jr`

Na stránce seriálu si můžete stáhnout jak výsledné soubory, tak převodní skript.

Podívejme se nyní na některé ze souborů. U sloupců budeme uvádět názvy používané v JDF-H.

Zastavky.txt. V tomto souboru najdete seznam zastávek, které daná linka používá. `CisloZastavky` je identifikátor zastávky, unikátní v rámci dané linky. Pomocí něj se na zastávku odkazují spoje v rámci linky. Zastávky nemají žádné globálně jednoznačné identifikátory. Že více linek staví na téže zastávce, poznáte víceméně jen podle názvu, a to ne úplně spolehlivě, protože názvy zastávek také nejsou jednoznačné.

Sloupce `NazevObce`, `CastObce`, `BlizsiMisto` dohromady určují název zastávky (`BlizsiMisto` je upřesnění místa, třeba `nám.` nebo `žel.st.`). Takovéto rozdělení názvu na tři části je dodržované hlavně v linkové autobusové dopravě, kde jsou stejným způsobem (de facto „jako CSV“) uváděné názvy zastávek i na papírových jízdních řádech a zastávkových označnících. Taky vám přišlo divné, proč názvy autobusových zastávek občas obsahují dvě čárky za sebou (např. „Klatovy„aut.nádr.“)?

V MHD se tato konvence příliš nedodržuje – zastávky mají typicky názvy unikátní v rámci celého města a sloupec `CastObce` se nechává prázdný. Občas ale narazíme na různé nesrovnalosti, nahodilé i systematické. Občas je například název zastávky ve sloupci `CastObce` namísto `BlizsiMisto`. A třeba v plzeňské MHD je dokonce ve sloupci `NazevObce` a ostatní jsou prázdné (poslední příklad). Příklady:

NazevObce	CastObce	BlizsiMisto
Hrochův Týnec		nám.
Ostrava	Vítkovice	Mírové nám.
Praha	Zličín	
Praha	ÚAN Florenc	
Praha		ÚAN Florenc
Praha		Karlovo náměstí
Brno	Královo Pole	nádraží
Brno		Tylova
Brno	Tylova	
Západočeská univerzita		

Problém s párováním zastávek podle názvu je, že názvy obcí a jejich částí nejsou unikátní. Skoro unikátní je kombinace název obce + okres (až na dvě výjimky), ale okresy u zastávek nenajdeme. Taktéž u zastávek nejsou uvedené zeměpisné souřadnice.

Pokud si z JDF vybereme jen MHD v jednom konkrétním městě, asi se můžeme spolehnout na jednoznačnost názvů zastávek. Protože nemáme informace o poloze zastávek, hůře se řeší přestupy. Ale v první aproximaci můžeme prostě dovolit přestupy mezi zastávkami stejného jména a určit nějaký fixní čas na přestup. Pokud bychom chtěli být přesnější, můžeme zkusit získat informace o pozicích zastávek z OpenStreetMap, více o tom později.

V případě linkové dopravy se na jednoznačnost názvů spolehnout nemůžeme. Asi jediná naděje je zkoušet nějak heuristicky párovat zastávky na zastávkové body v OpenStreetMap. Například pokud na trase linky jsou alespoň nějaké zastávky či obce s jednoznačným názvem, můžeme pak u nejednoznačných zastávek vybrat ty, které jsou rozumně blízko těm známým, aby trasa spoje dávala smysl. U vnitrokrajských linek nám navíc může pomoci informace o kraji, kterou lze vyčíst z první číslice šestimístného čísla linky. Má to i další háčky, například v OpenStreetMap pravděpodobně nejsou všechny zastávky, případně můžou mít názvy drobně odlišné od těch používaných v CIS.

V případě názvů obcí se asi dá věřit, že budou ve většině případů stejné v OSM i CIS. Takže jedno možné řešení by mohlo být heuristicky určit jednoznačné identifikátory obcí na trase (podle názvu a v případě nejednoznačností podle blízkosti ke zbytku trasy) a jako zastávky identifikovat trojicí (jednoznačný identifikátor obce, název části obce, upřesnění místa).

Ale přiznávám, že jsem strávil přes dva týdny neúspěšnými pokusy upravit data do použitelné podoby (což je jeden z důvodů zpoždění seriálu, za které se omlouváme).

Linky.txt – tento soubor obsahuje jediný řádek s informacemi o lince. Některé zajímavé sloupce:

- `CisloLinky` – šestimístné, celostátně unikátní. V případě linkových autobusů toto číslo vidíte v jízdním řádu. U městské dopravy je to jen interní identifikátor a veřejné (krátké) číslo linky najdete v souboru `LinExt.txt`.
- `NazevLinky` – lidsky čitelný název linky, např. „Brno – Jihlava – Praha“
- `ICDopravce` – číslo dopravce z `Dopravci.txt`
- `TypLinky` – `A`=městská, `B`=příměstská, `V`=vnitrokrajská, `Z`=mezikrajská, `D`=dálková, `N/P`=mezinárodní
- `DopravniProstredek` – `A`=autobus, `E`=tramvaj, `L`=lanovka, `M`=metro, `P`=přívoz, `T`=trolejbus
- `PlatnostJROd`, `PlatnostJRDo` – platnost jízdního řádu. Linka může mít víc různých verzí, které mají stejné číslo linky, ale liší se platností (každá verze se nachází v samostatném ZIPu). Občas se v datech z nějakého důvodu vyskytnou dvě verze linky s překrývajícím se rozsahem platnosti. V takovém případě není definováno, který má přednost, ale pravděpodobně většinou ten s pozdějším začátkem platnosti.

LinExt.txt (JDF 1.10+) – obsahuje dodatečné informace o lince. `KodDopravy` je identifikátor systému MHD či integrovaného dopravního systému (IDS), ke kterému linka patří. Možné hodnoty nejsou oficiálně zdokumentované, ale vytvořili jsme pro vás seznam, který najdete na stránkách seriálu. Podle tohoto sloupečku lze snadno z JDF vyfiltrovat linky MHD daného města (ve starších verzích JDF možná pomůže filtrovat podle dopravce). `OznaceniLinky` je „krátké“ číslo linky používané v rámci daného systému MHD.

Spoje.txt – popisuje seznam spojů na lince. `CisloSpoje` je pořadové číslo spoje v rámci dané linky. `PevKod1` až `PevKod10` jsou čísla tzv. pevných kódů udávající omezení jízdy spoje (např. „jede v pracovní dny“). Z nějakého neznámého důvodu se tady neuvádějí značky s pevně definovaným konkrétním významem. Namísto toho jsou tady uvedena nějaká zcela obecná čísla, kterým je přiřazen význam v souboru `Pevnykod.txt`. Čísla pevných kódů můžou být na každé lince úplně jiná. Další omezení jízdy spojů můžou být dána časovými kódy, o nich později.

Zasspoje.txt – popisuje trasy jednotlivých spojů. Zajímavé sloupce:

- `CisloSpoje` (ze `Spoje.txt`)
- `CisloZastavky` (ze `Zastavky.txt`)
- `CasPrijezdu`, `CasOdjezdu` – obsahují časový údaj ve formátu *hhmm* (např. `1745`), nebo znak `|`, pokud spoj zastávkou projíždí, nebo znak `>`, pokud spoj kolem zastáv-

ky ani nejede (ale jiné spoje na lince ano). Čas příjezdu může chybět, pokud je stejný jako čas odjezdu.

Geografická data o zastávkách

Jak už jsme zmínili, JDF neobsahuje informaci o zeměpisné poloze zastávek. Tu lze získat z několika míst. Jedním z nich je OpenStreetMap, se kterou jste se seznámili v předchozích dílech seriálu. Popis zastávek v OSM je trochu komplikovaný a existuje více způsobů, jak zastávky reprezentovat v OSM datech. Také v OSM je odhadem jen zhruba polovina českých zastávek, nejlepší pokrytí je ve větších městech.

Dalším zdrojem dat jsou krajské a městské úřady, které často mají vlastní mapu zastávek. Některé z nich je zveřejňují jako otevřená data (například jihočeský a královehradecký kraj, které tímto mají naši poklonu), od jiných se nám je podařilo získat žádostí podle zákona o svobodném přístupu k informacím. Tato data jsou v dost různorodých formátech.

Pokusili jsme se dát dohromady data ze všech dostupných zdrojů a převést je do jednotného formátu, více informací najdete na stránkách seriálu.

Reprezentace pomocí stavového prostoru

(Většina této sekce je převzata z řešení úlohy 28-2-6 Cesta MHD.)[9]

Abychom v jízdních řádech mohli vyhledávat spojení, hodilo by se nám je reprezentovat grafově. Zkusme si tedy vytvořit graf popisující naši síť, takový, že cesty v něm budou odpovídat korektním spojením v daném jízdním řádu. Určitě si nevystačíme s jednoduchým grafem, který má za vrcholy zastávky. Protože na jednu zastávku můžeme během našeho putování přijet víckrát, taková jízda by v našem grafu netvořila cestu, nýbrž sled (mohou se opakovat vrcholy). Se sledy se obvykle špatně pracuje, zkusme to tedy jinak.

Vytvoříme si takzvaný *stavový prostor*. To je graf, jehož vrcholy popisují nějaký stav (situaci), ve kterém se můžeme nacházet, a hrany mezi nimi určují dovolené změny stavu. V našem případě budou stavy dvojice (z, t) popisující „jsem na zastávce z v čase t“.

Aby se nám s časy lépe pracovalo, můžeme je místo hodin, minut a sekund reprezentovat například jedním číslem udávajícím počet minut (resp sekund, dle potřebné přesnosti) od půlnoci místního času. Aktuálně má v ČR pouze pražské metro plánované odjezdy s přesností na sekundy (IDOS vám je neukáže, ale v GTFS jsou a občas se tato přesnost při přestupování opravdu hodí).

V takovéto reprezentaci nelze hledat spojení přes půlnoc, to prozatím zanedbejme.

Jak se takový stav může změnit? Pokud v čase t odjíždí ze z nějaký spoj, jehož nejbližší další zastávka je z', a přijede na ni v čase t', pak určitě ze (z, t) povede hrana do (z', t'). Můžeme se tímto spojem svézt a tím se ocitnout na zastávce z' v čase t', tedy ve stavu (z', t').

Ale nemusíme nastoupit do prvního spoje, který jede. Potřebujeme umět reprezentovat i to, že počkáme na nějaký další. To by se dalo udělat například tak, že vždy ze (z, t) povede hrana do $(z, t + 1)$. Pak bychom ale u každé zastávky museli mít vrcholy pro všechny možné časy, což by bylo neúsporné. Místo toho je vytvoříme jen pro ty časy, kdy v z něco zastavuje. A hrany pak povedou vždy ze (z, t) do (z, t'), kde t' je čas nejbližšího dalšího odjezdu/příjezdu po t.

Ukážeme si to na jednoduchém umělém příkladu, protože skutečné dopravní sítě jsou příliš rozsáhlé a komplikované. Představme si následující dopravní síť s pěti zastávkami označenými A až E:

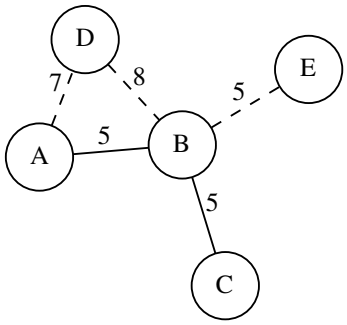

Síť je tvořena dvěma linkami, X (plná čára, jezdí každých 20 minut v trase A–B–C a opačně) a Y (čárkovaná čára, jezdí každých 30 minut v trase A–D–B–E a opačně). Čísla na hranách značí jízdní dobu mezi příslušnými zastávkami.

Část jízdního řádu této sítě pro dobu mezi pátou a šestou hodinou (časy 300 a 360 – počítáme v minutách) by mohla vypadat takto (jeden řádek představuje jeden spoj):

```
A 300 B 305 C 310
A 320 B 325 C 330
A 340 B 345 C 350
C 300 B 305 A 310
C 320 B 325 A 330
C 340 B 345 A 350
A 300 D 307 B 315 E 320
A 330 D 337 B 345 E 350
E 300 B 305 D 313 A 320
E 330 B 335 D 343 A 350
```

Pro tento kousek jízdního řádu bude příslušná část stavového grafu vypadat takto:

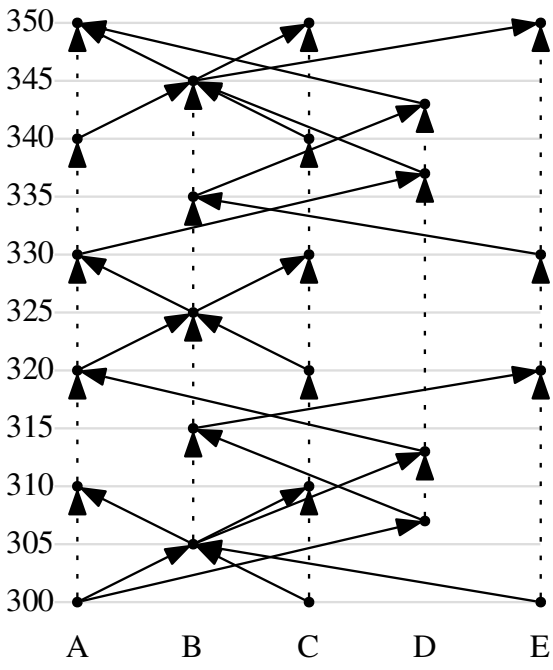

Tečkované hrany odpovídají čekání na zastávce, plné přesunům vozidly.

[9] http://ksp.mff.cuni.cz/viz/28-2-6/reseni

Minimální čas na přestup

Naše reprezentace má jednu podstatnou nevýhodu: dovoluje cesty s nulovým časem na přestup. Můžeme např. v čase 305 přijet linkou X do zastávky B a ve stejný okamžik zase odjet linkou Y do D. To není moc realistické. I přestup v rámci jednoho stanoviště nějakou chvíli trvá a navíc si nejspíš chceme nechat časovou rezervu pro případ zpoždění prvního spoje (přesuny mezi stanovišti a čas potřebný pro ně teď neuvažujeme, k těm se vrátíme později).

Rádi bychom tedy vynutili minimální čas na přestup: pokud přijedeme do zastávky nějakým spojem v čase t, můžeme přestoupit na jiný spoj, pouze pokud odjíždí v čase $t + \lambda$ nebo později, pro nějakou konstantu λ (v principu to nemusí být konstanta, požadovaný čas může záviset třeba na konkrétní zastávce či denní době).

Tady je náš dosavadní stavový prostor neadekvátní. Protože to, kam můžeme pokračovat např. z vrcholu $(B, 305)$ záleží na tom, kudy jsme do něj přijeli. Pokud jsme přijeli z vrcholu $(A, 300)$ spojem linky X, můžeme například pokračovat dál stejným spojem do vrcholu $(C, 310)$. Ale pokud jsme přijeli z $(E, 300)$ linkou Y, do $(C, 310)$ se vydat nemůžeme, protože bychom museli v B přestoupit s nulovou rezervou. To je v přímém rozporu se základním principem stavových prostorů: možné akce jsou vždy jednoznačně určené vrcholem, ve kterém se nacházíme.

Namísto původní hrubé informace „jsem na zastávce z v čase t“ se budeme muset naučit rozlišovat mezi stavy „stojím na zastávce z (venku) v čase t“ a „jsem ve vozidle spoje s, které právě zastavilo na z v čase t“. Tedy stav bude popsán trojicí (z, t, s), kde s je identifikátor spoje nebo „$-$“ reprezentující „stojím venku“.

Zbývá správně natahat hrany. Čekací hrany povedou jen mezi „venkovními“ vrcholy, tedy ze $(z, t, -)$ do $(z, t', -)$, kde t' je opět čas nejbližšího dalšího odjezdu/příjezdu. Zároveň přidáme hrany popisující nástup do vozidla: pro vozidlo spoje s odjíždějící ze z v čase t přidáme hranu $(z, t, -) \to (z, t, s)$. Ještě celkem přímočaré budou hrany popisující cestu ve vozidle: pokud spoj s jede ze z (odj. t) do z' (příj. t'), přidáme hranu $(z, t, s) \to (z', t', s)$.

Hlavní trik spočívá ve hranách popisujících výstup z vozidla. Ty budou mít tvar $(z, t, s) \to (z, t + \lambda, -)$. Můžeme si to představovat tak, že každé vozidlo na zastávku přijede λ minut po tom, co z ní odjede. Případně pokud je to na vás příliš sci-fi, můžete si představit, že vám λ minut trvá vystoupit z vozidla. Každopádně si snadno rozmyslíte, že touto úpravou zařídíme dodržení času na přestup.

Malý kousek nového grafu ukazující přestupy v B okolo času 305 (pro $\lambda = 5$):

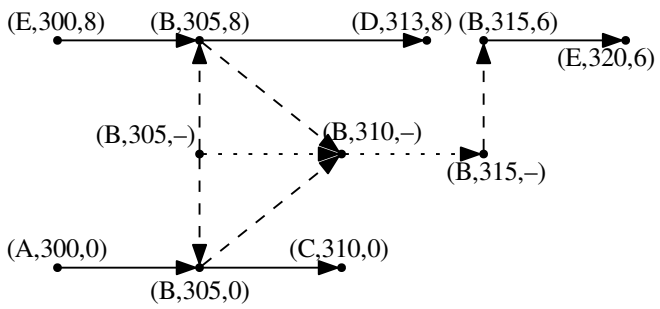

Tečkované hrany jsou opět čekací a plné jízdní, přibyly čárkované nástupní a výstupní. V tomto grafu už se z $(A, 300)$ dostaneme do $(C, 310)$, ale z $(E, 300)$ nikoli. V obou případech si navíc můžeme v B počkat do 315, přestoupit na spoj 6 a pokračovat dál.

Sestrojit takovýto graf by mělo být celkem přímočaré, případně je to popsané v řešení úlohy 28-2-6[10] včetně ukázkového programu. Na stejném místě najdete ukázkovou aplikaci, jak pomocí stavového grafu najít cestu, při které za den strávíte co nejvíc času v dopravních prostředcích.

Pěší přesuny

Při přestupování mezi linkami MHD často musíme dojít pěšky z jedné zastávky na jinou. Často to bývá jiné stanoviště v témže uzlu, ale nemusí to platit vždy.

Pokud máme jízdní řád, který rozlišuje pouze uzly a ne jednotlivá stanoviště, není moc co řešit. Pěší přestupy v rámci máme zajištěné automaticky a musíme jen nastavit dostatečnou minimální dobu na přestup (viz předchozí oddíl). Nevýhoda je, že nemůžeme rozlišit ani přestupy v rámci jednoho stanoviště a mezi různými stanovišti – vždy budeme vyžadovat stejnou dobu na přestup. Co můžeme, je nastavit různou přestupní dobu pro různé uzly, pokud se to hodí. Potenciálně bychom mohli chtít ještě přidat možnost pěšího přesunu mezi dvěma blízkými uzly, ale asi to bude potřeba spíš výjimečně.

O trochu zajímavější je to, pokud rozlišujeme jednotlivá stanoviště. Musíme si odpovědět na dvě otázky: (1) mezi kterými dvojicemi stanovišť uvažovat pěší přesuny, (2) pro každou dvojici určit čas potřebný na přesun.

První otázku můžeme řešit dvěma různými způsoby: pokud máme informace o příslušnosti zastávek k uzlům, můžeme povolit přestupy pouze v rámci jednoho uzlu (a tam uvážit všechny možné dvojice stanovišť). Obecnější řešení je ignorovat uzly a vyjít z geografické polohy stanovišť (pokud ji máme k dispozici). Pak prostě najdeme všechny dvojice stanovišť vzájemně vzdálených méně než nějaká konstanta. Tady můžeme uvažovat velmi hrubý odhad vzdálenosti: například vzdušnou čarou nebo v manhattanské metrice (o ní víc níže).

Algoritmus pro nalezení všech dvojic blízkých bodů byl popsán například v řešení úlohy 31-Z3-4.[11]

Když už máme nějakou dvojici stanovišť, mezi kterými vypadá smysluplně pokoušet se o pěší přesun, rádi bychom odhadli, jak dlouho to bude trvat. První dobrý krok je asi odhadnout vzdálenost, kterou budeme muset ujít. To by se dalo udělat například tak, že budeme hledat trasu mezi stanovišti v mapě – například pomocí dat z OpenStreetMap. To je ale spousta práce.

Ve městech, kde typicky bývá víceméně pravoúhlá síť ulic, lze celkem dobře aproximovat docházkové vzdálenosti pomocí tzv. *manhattanské vzdálenosti*. Pokud máme ve čtvercové síti dva body o souřadnicích (x_1, y_1) a (x_2, y_2), jejich manhattanská vzdálenost je rovna $|x_2 - x_1| + |y_2 - y_1|$ – tedy délka cesty, která by vedla nejdřív jen vodorovně (západovýchodně) a potom jen svisle (severojižně).

Snadno si ale rozmyslíte, že stejně dlouhé jsou i složitější cesty, dokud chodíte jen vodorovně a svisle (ne šikmo) a nevracíte se zpátky. Tedy obě cesty znázorněné tučně na

[10] `http://ksp.mff.cuni.cz/viz/28-2-6/reseni`
[11] `http://ksp.mff.cuni.cz/viz/31-Z3-4/reseni`

následujícím obrázku mají délku 7, a to je manhattanská vzdálenost bodů A a B:

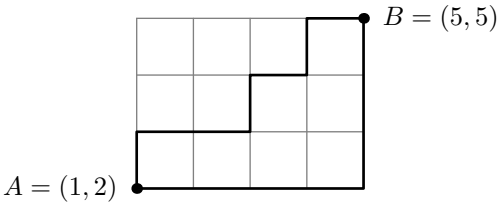

Zatímco manhattanská vzdálenost je celkem dobrým odhadem docházkové vzdálenosti (pouze ve městech a pouze na kratší vzdálenosti), na základě docházkové vzdálenosti není úplně jednoduché odhadnout docházkový čas. Při přestupování ve městě někdy třeba strávíte víc času čekáním na přechodu než samotnou chůzí. A to je věc, která se zohledňuje velmi těžko, protože závisí na intenzitě automobilové dopravy, která navíc závisí na denní době… Asi jediné jednoduché řešení je přidat k odhadnutému docházkovému času dostatečnou rezervu.

Další zradou, na kterou je třeba si dát pozor, jsou různé překážky: jako třeba řeka nebo skok v nadmořské výšce. Ty nepotkáte zas tak často, ale dá se na ně nachytat. Například zastávka metra Vyšehrad (na konci Nuselského mostu) a tramvajová zastávka Svatoplukova (dole v Nuselském údolí) mají manhattanskou vzdálenost pouhých 220 metrů, ale výškový rozdíl 40 metrů a typicky mezi nimi přestupovat nechcete. Zastávky Zlíchov a Dvorce mají manhattanskou vzdálenost 400 m, ale nejkratší pěší spojnice má 2,7 km přes Barrandovský most.

První problém dokážeme vyřešit porovnáním nadmořských výšek obou stanovišť. V minulém díle jsme si ukázali použití výškových dat ze SRTM. Například Praha má vlastní, přesnější výškový model,[12] ale jeho zpracování by bylo na delší povídání. Kdyby vás to zajímalo, poradíme na fóru.

Alternativně oba problémy můžeme z velké části eliminovat tím, že povolíme přestupy pouze v rámci uzlu (ale tím se připravíme potenciálně o nějaké zajímavé nestandardní přestupy).

Výpočet manhattanské vzdálenosti

Pro body ve čtvercové síti je výpočet manhattanské vzdálenosti triviální použitím vzorečku výše. Problém je, že povrch Země není čtvercová mřížka. Pokud chceme nějak geometricky pracovat se zeměpisnými daty, hodí se nejprve souřadnice bodů převést do nějakého pravoúhlého souřadného systému. Nejznámějším takovým je UTM.[13] UTM rozděluje zemský povrch na tzv. zóny – oblasti dost malé na to, aby se na nich neprojevovalo zakřivení povrchu a mohli jsme je pro praktické účely považovat za rovinu.

V každé zóně je pak zavedena pravoúhlá souřadná síť v metrech (tedy každý bod má x-ovou a y-ovou souřadnici udávající vzdálenost v metrech od nějakého referenčního bodu ve východozápadním, resp. severojižním směru). A poštěstilo se nám, že téměř celé Česko je v jedné UTM zóně (33U), takže ani nemusíme řešit nepříjemné přechody mezi zónami. Prostě převedeme zeměpisné souřadnice do UTM a s UTM souřadnicemi můžeme zacházet jako se souřadnicemi bodů v rovině. Můžeme pak spočítat jejich manhattanskou vzdálenost prostým sečtením rozdílů x-ových a y-ových souřadnic, případně jejich vzdálenost vzdušnou čarou pomocí Pythagorovy věty.

Převod zeměpisných souřadnic do UTM je celkem komplikovaný, ale existují různé knihovny, které se o něj postarají. Nejznámější z nich je asi *pyproj*, kterou můžete nainstalovat pomocí správce balíčků *pip*.[14] Pak ji můžete použít třeba následovně:

```
from pyproj import CRS, Transformer
utm = CRS.from_epsg(32633)
wgs = CRS.from_epsg(4326)
na_utm=Transformer.from_crs(wgs,utm).transform
# Nyní můžete zavolat na_utm(sirka, delka)
# a dostanete dvojici utm souradnic
def manhattan(sirka1, delka1, sirka2, delka2):
    x1, y1 = na_utm(sirka1, delka1)
    x2, y2 = na_utm(sirka2, delka2)
    return abs(x1-x2) + abs(y1-y2)
```

Vysvětlení tohoto kódu by bylo nad rámec seriálu, berte jej jako zaklínadlo.

Pěší přesuny a stavový prostor

Když už máme naplánované, mezi kterými dvojicemi stanovišť chceme povolit pěší přesuny, potřebovali bychom je nějak začlenit do našeho stavového grafu.

Problém je, že jedna hrana dokáže popsat pouze přesun v jeden konkrétní okamžik. Tedy když přidáme hranu z vrcholu $(A, t, -)$ do vrcholu $(B, t + \tau, -)$ (kde τ je doba potřebná na přesun), umožníme pěší přesun ze zastávky A na B pouze v čase t a nikdy jindy. Teoreticky pěšky můžeme chodit kdykoliv, takže bychom museli u každé zastávky mít vrcholy pro všechny možné časy a graf by byl neprakticky velký.

Ale snadno si pomůžeme jednoduchým omezením: pěší přesuny provádíme vždy hned po výstupu z vozidla (a čekáme až na cílové zastávce). To nalezené trasy příliš nezmění a graf to dost zjednoduší. Nyní stačí jen projít všechny vrcholy odpovídající příjezdu vozidla na zastávku a pro každý z nich přidat hrany pro všechny možné pěší přesuny z této zastávky v tomto čase (předpokládáme, že délka přesunu je omezená, takže jich nebude mnoho).

Připravili jsme se tím o možnost udělat pěší přesun na úplném začátku trasy (pokud zrovna v tu dobu na výchozí zastávku nic nepřijíždí), kterou by možná bylo vhodné v prohledávacím algoritmu nějak kompenzovat. Zrovna tak jsme se připravili o možnost navázat dva pěší přesuny za sebe a obecně popisovat pěší přesuny na delší vzdálenosti, ale to v našem modelu z principu moc nejde (kdybychom to povolili, různou kombinací pěších přesunů se na každou zastávku dostaneme téměř v libovolném čase, což by opět vedlo k explozivnímu nárůstu počtu vrcholů na zastávku). Pokud bychom chtěli kombinovat delší pěší cesty (případně třeba cesty na kole) s cestami MHD, to už je dost jiná úloha, které se říká *multimodální plánování* a je o dost těžší.

Podobným způsobem můžeme vyřešit i přesuny uvnitř stanic podle `pathways.txt`, ale tam asi potřebujeme umožnit několik přesunů navazujících na sebe (např. z povrchu do vestibulu a z vestibulu na nástupiště).

[12] `http://opendata.praha.eu/dataset/ipr-digitalni_model_povrchu_-_1m`
[13] `https://en.wikipedia.org/wiki/Universal_Transverse_Mercator_coordinate_system`
[14] `http://ksp.mff.cuni.cz/encyklopedie/python-pip.html`

Další rozšíření stavového prostoru

Koncept stavového prostoru je celkem flexibilní a snadno ho rozšíříte o reprezentaci dalších faktů. Například v Praze lidé při nastupování do metra obvykle přemýšlí o tom, na kterou stranu soupravy se postavit, aby v cílové stanici byli co nejblíže výstupu (případně pokud má stanice více výstupů, tomu, který chtějí použít).

I toto lze v našem modelu snadno reprezentovat. Stačí do vrcholů představujících cestu ve spoji metra zakódovat informaci o tom, ve které části soupravy se nacházíme (pro jednoduchost stačí rozlišit přední, prostřední a zadní). Poté i vrchol představující nástupiště rozdělíme na několik částí, mezi kterými povedou hrany ohodnocené dobou potřebnou pro přejití z jedné části nástupiště do jiné (podobně jako u jiných hran pro pěší přesuny si musíme rozmyslet, v jaké časy je přidat, aby jich nebylo moc).

V takto upraveném grafu pokud se vyplatí před příjezdem soupravy metra přesunout na opačný konec nástupiště, takovouto trasu při prohledávání zcela přirozeně najdeme.

Výpočty nad stavovým prostorem

Všechny popsané varianty stavového prostoru tvoří acyklický orientovaný graf (DAG – directed acyclic graph), protože hrany vždy vedou z vrcholu s nižším časem do vrcholu s vyšším časem (případně stejným, ale pokud to uděláte rozumně, mezi vrcholy se stejným časem cyklus taky nevznikne).

DAGy jsou jednou z nejpříjemnějších tříd grafů a spousta věcí se nad nimi nechá spočítat velmi jednoduše v lineárním čase. Jejich nejdůležitější vlastností je, že mají *topologické uspořádání* (o kterém píšeme v naší grafové kuchařce)[15] – tedy pořadí vrcholů takové, že hrany v něm vedou jen zleva doprava.

To nám umožňuje použít techniku zvanou *indukce podle topologického uspořádání*. Často chceme pro všechny vrcholy spočítat nějakou hodnotu (například délku nejkratší cesty z nějakého pevného startovního vrcholu), přičemž umíme pro libovolný vrchol spočítat tuto hodnotu z hodnot jeho předchůdců (vrcholů, ze kterých do něj vede hrana).

Pak si všimneme, že pokud budeme hodnoty postupně počítat v pořadí podle topologického uspořádání, vždy, když narazíme na nějaký vrchol, máme hodnoty pro všechny jeho předchůdce (přímé i nepřímé) už spočítané z předchozích kroků. Často ani nemusíme nejdřív hledat topologické uspořádání a pak podle něj procházet vrcholy – konstrukci topologického uspořádání společně s induktivním výpočtem zvládneme jedním upraveným prohledáním do hloubky (DFS).

Další algoritmy

Existují i jiné algoritmy speciálně navržené na hledání spojení v jízdních řádech, které nepotřebují reprezentací pomocí DAGu. Pro příklad zmíníme algoritmus Raptor,[16] který pracuje po linkách, nikoli po spojích, takže ve většině praktických případů je rychlejší. Ale oproti velmi obecnému přístupu pomocí stavového prostoru nejde tak snadno rozšířit na další aplikace. Jeho popis je nad rámec tohoto seriálu.

Obecně o úlohách

Pro úlohy jsou určené primárně dvě datové sady, které naleznete ve formátu GTFS na stránce seriálu:[17] Pražská integrovaná doprava a české vlaky. Prosím používejte verzi z našich stránek, ať mají všichni stejná data. Samozřejmě budeme rádi, když si vyzkoušíte i jiné datové sady a formáty, iniciativě se meze nekladou.

Podobně jako v předchozích sériích, řešení odevzdávejte ve formě ZIP archivu, který obsahuje:

- Krátký slovní popis, jakým způsobem jste přistupovali ke které úloze a třeba jak vám to přišlo těžké (jako prostý text nebo PDF). Popis by měl obsahovat nějaké zamyšlení nad časovou náročností – formou asymptotické časové složitosti (pokud ji lze v daném případě smysluplně určit) a/nebo naměřené časové náročností na vašem počítači pro různá data. Dále by měl obsahovat stručný popis toho, jak se váš program spouští, jestli má nějaké parametry, případně jakým způsobem mu předat vstup (klidně editací konstant ve zdrojáku) a v jaké podobě. Pokud váš program používá nějaké dodatečné datové sady z jiných zdrojů či méně obvyklé externí knihovny, upozorněte na to včetně odkazu, kde je získat, případně s jakou verzí jste to zkoušeli.
- Výstup, který požaduje zadání dané úlohy, pro každou datovou sadu uvedenou v zadání úlohy. Budeme samozřejmě rádi, pokud se s námi podělíte i o další zajímavé výstupy.
- Zdrojový kód programu, který jste použili pro řešení. Pokud jste zkoušeli více programů či jejich variant, případně použili různé programy pro různá data, zahrňte všechny.

Vaše programy by měly zvládat načíst jízdní řády ve formátu GTFS (v rozbalené podobě, tedy jako adresář s CSV soubory). Podpora jiných formátů je volitelná. Stačí, když ho otestujete na datových sadách uvedených v zadání, ale měl by být psán tak, aby se dalo rozumně čekat, že si do nějaké míry poradí i s jinými.

Abychom měli podobné výstupy, sjednoťme si alespoň trochu přestupní podmínky. Uvažujte minimální dobu na přestup v rámci jednoho stanoviště 2 minuty (zahrnuje i rezervu na zpoždění přijíždějícího spoje). Pro pěší přesuny, pokud budete odhadovat čas na základě vzdálenosti, předpokládejte rychlost 1 m/s (3.6 km/h, zahrnuje nějakou rezervu na přecházení ulic a další zdržení). Tedy pro dvě stanoviště vzdálená 60 metrů uvažujte minutu na přesun plus dvě minuty pevnou časovou rezervu, tedy celkem minimálně tři minuty mezi příjezdem jednoho spoje a odjezdem navazujícího.

Pro odhad vzdálenosti použijte primárně manhattanskou vzdálenost s maximální přestupní vzdáleností 450 metrů. Sofistikovanějším řešením, která například nějak využívají mapová data, se rozhodně nebráníme (a možná si vysloužíi nějaké bonusové body), v takovém případě zkuste trefit parametry, které dávají řádově podobné výsledky.

Pokud se chcete geografickým datům úplně vyhnout, můžete uvažovat pevnou přestupní dobu mezi dvěma zastávkami v rámci uzlu 5 minut (v rámci jednoho stanoviště stále jen dvě minuty), byť možná za trochu méně bodů.

[15] `http://ksp.mff.cuni.cz/viz/kucharky/grafy`
[16] `https://www.microsoft.com/en-us/research/publication/round-based-public-transit-routing/`
[17] `http://ksp.mff.cuni.cz/viz/serial-jr`
[18] `https://metroweb.cz/metro/stanice/linka_c.htm`

V případě metra uvažujte penalizaci 3.5 minuty za přesun mezi výstupem na povrchu a nástupištěm. Můžete to zkusit zpřesnit použitím časů z `pathways.txt`, případně třeba odhadnout na základě hloubky stanice pod povrchem (dá se snadno najít),[18] řekněme 5 s na metr hloubky.

V případě dat, která nerozlišují stanoviště (např. vlaky) uvažujte pevný čas na přestup 10 minut. Kdybyste si chtěli hrát, ještě lepší varianta je uvážit různé časy podle toho, z jakého typu vlaku na jaký přestupujete. Například z rychlíku na osobní vlak potřebujete menší časovou rezervu (protože osobní vlak obvykle počká déle v případě zpoždění), opačným směrem větší. Též by bylo dobré zohlednit, že u některých vlaků je poznámka „vlak nečeká na žádné přípoje“. Vyžadovalo by to trochu upravit konstrukci grafu (protože najednou záleží na tom, jakým spojem dál pojedete), zkuste si rozmyslet jak.

U vlaků nemusíte uvažovat obecné pěší přesuny (byť můžete), ale bylo by dobré přinejmenším ručně přidat ty nejvýznamnější, alespoň Praha hl.n. – Praha Masarykovo n. (řekněme 15 minut).

Zadání úloh

Úkol 1 [5b]: Rádi bychom našli jakési *„dopravní centrum“* – tedy zastávku, ze které se co nejsnáze dostaneme do libovolné jiné.

Jak to definovat formálně? Na vstupu dostanete datum a rozsah možných časů odjezdu (třeba 8:00–9:00). *Korektní spojení* z uzlu x do uzlu y definujeme jako spojení z libovolného stanoviště uzlu x do libovolného stanoviště uzlu y, které z výchozího stanoviště vyjíždí v zadaném časovém intervalu.

Dojezdový čas z uzlu x do y je nejmenší jízdní doba (rozdíl mezi časem odjezdu z x a časem příjezdu do y) nějakého korektního spojení. Pokud spojení začíná nebo končí cestou metrem, musíme připočítat čas potřebný k cestě z povrchu / na povrch. *Excentricita* nějakého uzlu x je maximum z dojezdových časů z x do všech ostatních uzlů. *Centrum* je pak uzel s nejmenší excentricitou.

Vaším úkolem je napsat program, který dostane na vstupu jízdní řád, datum a rozsah časů odjezdu odjezdu a nalezne centrum. Pokud k tomu lze váš algoritmus jednoduše upravit, vypište třeba 10 uzlů s nejmenší excentricitou – ale stačí i jeden.

Vyzkoušejte na datových sadách PID i vlaků. Odjezd uvažujte v pondělí v 8:00–9:00. Ve svém řešení uveďte nalezené centrum spolu s jeho excentricitou. Než začnete, zkuste si tipnout, jak to dopadne.

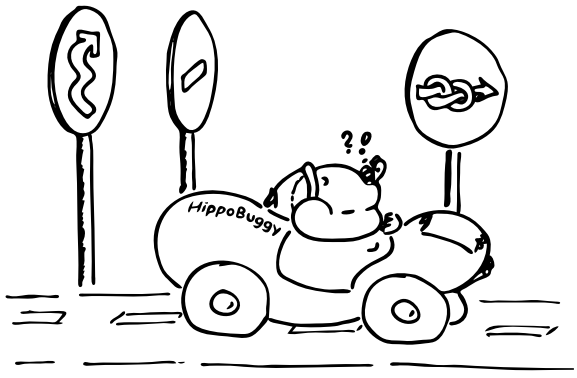

Úkol 2 [5b]: V prvním dílu seriálu[19] byla řeč o *heatmapách* jakožto užitečném způsobu vizualizace geografických dat. V této sérii si taky jednu heatmapu nakreslíte – konkrétně heatmapu dojezdových časů. Na vstupu dostanete jízdní řád, identifikátor výchozího uzlu a datum a povolený rozsah časů odjezdu. Pro každý uzel nakreslete do mapy barevné kolečko, jehož barva odpovídá dojezdovému času (dle definice z předchozího úkolu) z výchozího uzlu do tohoto uzlu.

Dále přidejte druhý režim použití, kdy na vstupu budou dva výchozí uzly a nakreslíte heatmapu rozdílů v dojezdových časech z jednoho a z druhého. Použijte jednu barevnou škálu pro kladné rozdíly – kdy z prvního výchozího uzlu se na dané místo dostanete rychleji než z druhého – a jinou pro záporné.

Pošlete nám obrázky z následujících výchozích stanic pro PID:

- I. P. Pavlova
- Malostranské náměstí
- rozdílový mezi nimi

a z následujících stanic pro vlaky:

- Praha hl.n. + Praha Masarykovo n. (uvažujte odjezdy z obou, jako by to byla jedna stanice)
- Brno hl.n.
- rozdílový mezi nimi

Ve všech případech uvažujte odjezd v pondělí v 8:00–9:00.

Úkol 3 [5b]: Najděte trasu v síti PID, která za 24 hodin (od půlnoci z neděle na pondělí do půlnoci z pondělí na úterý) projede co nejvíc různých linek. Dvě linky považujeme za různé, pokud mají různé `route_short_name`. Můžete používat všechny linky včetně vlakových, příměstských, atd.

Efektivní přesné řešení pravděpodobně neexistuje; můžete použít libovolné aproximace či heuristiky. Hlavním kritériem bodového ohodnocení bude, kolik linek zvládne vaše řešení projet.

Jako výstup odevzdejte itinerář trasy v podobě textového souboru, kde každý řádek popisuje cestu jedním spojem (v pořadí, v jakém je použijete). Na jednom řádku budou následující položky oddělené mezerou:

- identifikátor spoje (`trip_id`)
- v jaké zastávce do spoje nastoupíme (`stop_sequence` v rámci daného spoje)
- v jaké zastávce ze spoje vystoupíme (též `stop_sequence` v rámci daného spoje)

Filip Štědronský

[19] `http://ksp.mff.cuni.cz/viz/32-1-6`

Ukážeme si uměle znějící úlohu, kterou posléze zmatematizujeme, vyřešíme a dokážeme vlastnosti řešení. Nakonec přijdou četná užití, která ozřejmí, proč jsme se snažili.

Látka je lehce pokročilá, takže vězte, že budete potřebovat znát grafy.

Uměle znějící úloha

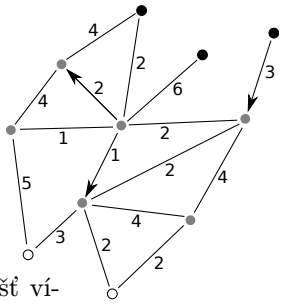

Ruský petrobaron vlastní ropná naleziště na Sibiři a trubky vedoucí do Evropy. Trubky vedou mezi nalezišti, uzlovými body a koncovými body, kde ropu přebírají odběratelé.

Každá trubka může a nemusí mít definováno, kterým směrem jí má téci ropa. Pro každou trubku zvlášť víme, kolik nejvýše jí za hodinu protlačíme.

Naleziště jsou bezedná a mohou posílat neomezená množství ropy. Odběratelé také dokáží neomezená množství ropy z koncových bodů odebírat. Petrobaron čelí problému, jak protlačit danou distribuční sítí co nejvíce ropy za hodinu ze zdrojů k odběratelům.

Zapeklité je to zejména kvůli tomu, že v uzlových bodech nelze ropu hromadit, ani pálit – rozhodně tedy nejde bez rozmyslu přikázat, ať každou trubkou teče maximum, protože bychom poškodili cenná zařízení a v uniklé ropě utopili vše živé.

Zmatematizování

V zadání vidíme graf, který obsahuje orientované i neorientované hrany, kde je nějaká podmnožina vrcholů označená jako zdroje a jiná jako… říkejme tomu třeba stoky.

Abychom měli situaci jednodušší, zbavíme se hned na úvod mnohočetnosti zdrojů a stoků. Přikreslíme si dva nové vrcholy – z nadzdroje budeme posílat ropu do všech zdrojů, do nadstoku budeme posílat ropu ze všech stoků. Kapacitu přikreslených hran pak nastavíme na nekonečno.

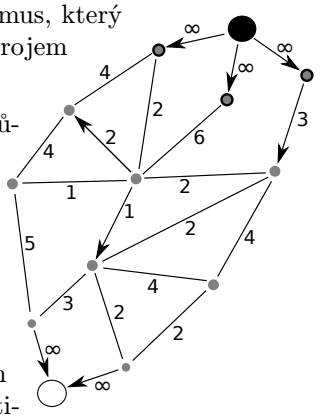

Teď nám stačí vymyslet algoritmus, který řeší problém s právě jedním zdrojem a právě jedním stokem.

Každý vstup totiž popsaným způsobem převedeme, pošleme ho algoritmu a z výstupu prostě jen odstraníme dva přidané vrcholy a připojené hrany.

Podobně se zbavíme neorientovaných hran.

Každou takovou hranu v každém zadání změníme na dvojici protisměrných orientovaných hran se stejnou kapacitou. V algoritmu pak už můžeme počítat jen s hranami orientovanými.

Dostáváme se nyní k nejdůležitějšímu – podmínkám na hledaný tok.

Na vstupu dostáváme ohodnocení hran nezápornými čísly a naším úkolem je sestavit jiné ohodnocení těch samých (všech) hran.

Je důležité, aby se nám to nepletlo – ohodnocení ze vstupu se říká kapacita a značí se $c(e)$, konstruované ohodnocení se jmenuje tok a označujeme ho $f(e)$.

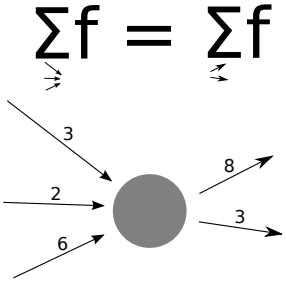

Konstruované ohodnocení se snažíme maximalizovat, ale omezuje nás kapacita a Kirchhoffův zákon.

Tak budeme říkat podmínce na to, že součet toku na hranách, které do vrcholu vstupují, musí být stejný jako součet toku na hranách, které z vrcholu vystupují. Máte-li rádi fyziku nebo berete-li školu vážně, důvod k takovému pojmenování jistě chápete.

Formálně ony dvě podmínky vypadají takto:

$$\forall e \in E : f(e) \leq c(e)$$

$$\forall v \in V \setminus \{z, s\} : \sum_{\overrightarrow{uv} \in E} f(\overrightarrow{uv}) = \sum_{\overrightarrow{vu} \in E} f(\overrightarrow{vu})$$

Kirchhoffova podmínka se samozřejmě netýká ani zdroje, ani stoku – tam nám naopak jde o to ji co nejvíce porušit. Velikost toku je nejsnazší měřit na nich. Budeme ji definovat jako rozdíl mezi součtem odtoků a součtem přítoků ve zdroji.

K zamyšlení

- Nastavit ohodnocení hrany (kapacitu) na skutečné nekonečno v našem programovacím jazyce nemusí jít. Pak se to řeší tím, že se zvolí dostatečně velké číslo. Jak co nejmenší, ale stále bezpečné, rychle ze zadání určit? Stejný problém se řeší třeba v Dijkstrově algoritmu, ale i ve spoustě dalších.
- Neorientované hrany, neboli obousměrné trubky, si zaslouží podrobnější rozbor, než jaký jsme jim věnovali v textu. Jak spolehlivě převedeme řešení algoritmu do původní sítě?
- Vymysleli jsme, jak vyřešit více zdrojů a stoků a jak ošetřit obousměrné trubky. Co kdyby bylo v zadání omezení na průtok vrcholy?
- Umíte dokázat, že je absolutní hodnota rozdílu přítoků a odtoků stejná na zdroji i na stoku? Tedy že bychom mohli velikost toku stejně tak dobře měřit i na stoku?

Řešení

Problém je velmi studovaný a k jeho řešení existují dva velké přístupy, které jsou humorně protikladné. Ten první vezme nulový tok a opatrně ho zlepšuje. Druhý si napíská veliké ohodnocení hran, které ani tokem není, a pak ho opravuje.

Předvedeme si onen první způsob a algoritmus, který se podle svých autorů jmenuje Fordův-Fulkersonův. Bude se nám odteď hodit tvářit se, jako že mezi každými dvěma vrcholy vede oběma směry hrana. Tam, kde ze vstupu nepřišla, si domyslíme jednu s nulovou kapacitou.

Představme si graf, na kterém počítáme tok, a dejme tomu, že už nějaký tok máme – třeba prázdný. Představme si, že jsme ropný magnát a každý rozdíl mezi kapacitou potrubí a jejím využitím (tokem) nás stojí miliony dolarů.

Už jsme se smířili s tím, že každá trubka nemůže být využita na maximum, ale zkusme si vyznačit ty hrany, kde $c(e) \neq f(e)$.

Co když existuje cesta z nadzdroje do nadstoku, která vede pouze po takových hranách?

Můžeme vzít minimum z rozdílů na každé hraně a o toto číslo navýšit tok na každé z nich! Ani kapacitní, ani Kirchhoffovu podmínku to jistě nepoškodí.

Pokud žádnou takovou cestu nevidíme, znamená to, že tok vylepšit nejde? Ne úplně. Představte si následující situaci:

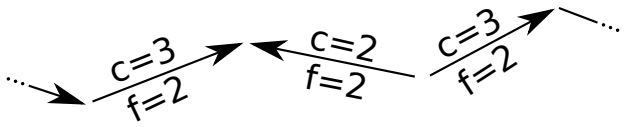

Copak nejde zlepšit? Jde! Není na to první pohled úplně jasné, ale můžeme zlepšovat výsledný tok i tím, že ho na protisměrné části cesty snížíme. Samozřejmě však nesmíme nastavovat tok záporný.

(Je smutné, že si teď trochu kazíme grafovou terminologii – co je to za cestu v orientovaném grafu, která nemusí respektovat orientaci hran?)

Takže jaká je přesně podmínka pro „vyznačení“ hrany $u\vec{v}$? Nastává $f(u\vec{v}) < c(u\vec{v})$ nebo $f(v\vec{u}) > 0$. Potom ji lze zlepšit o $c(u\vec{v}) - f(u\vec{v}) + f(v\vec{u})$.

Hledání všech vhodných („zlepšujících“) cest tedy můžeme dělat prostým prohledáváním do šířky přes vyznačené hrany. Budeme to dělat opakovaně znovu a znovu, až žádnou takovou nenajdeme, a pak vrátíme získaný tok jako výsledek.

Analýza algoritmu

Správnost

Zavolali jsme algoritmus na prázdný tok, ten ho zlepšil do situace, ve které neexistuje zlepšující cesta.

Znamená tato neexistence, že je výsledný tok maximální? Opačná implikace je jasná – maximální tok zlepšit žádným způsobem nepůjde, takže ani přes zlepšující cestičky.

Když zkusíme algoritmus pustit na graf, kde už žádná taková cesta není, můžeme si poznamenat všechny vrcholy, kam jsme se pomocí prohledávání zlepšitelných hran ještě dostali. Tato množina bude jistě obsahovat zdroj (tam jsme začali) a jistě nebude obsahovat stok (to by existovala zlepšující cesta).

Na hranách mezi touto množinou a jejím doplňkem nemůžeme zlepšovat, jinak by se po nich náš program pustil dál a množinu vrcholů, kam se dostal, by rozšířil. Všechny hrany směřující ven tedy mají $f(e) = c(e)$, pro všechny hrany směřující dovnitř platí $f(e) = 0$.

Tyto hrany tvoří *řez* naším grafem. Odvoláme se v tuto chvíli na vaši intuici – tok nemůže být větší než libovolný řez. Z toho už dostáváme, že náš algoritmus našel tok maximální, protože našel také řez, který zaručuje, že nemůže existovat tok větší.

Formálnější předvedení najdete ve skriptíčkách z kombinatoriky.[20]

Časová složitost

Je možné dobu běhu omezit počtem vrcholů a hran? Výše uvedeným postupem na grafu s celočíselnými kapacitami každou nalezenou cestou zvýšíme tok alespoň o jednotku, takže program nebude běžet déle, než je součet všech kapacit. Ale to není moc uspokojivý odhad, protože záleží na ohodnocení.

Pokud budeme hledat cesty skutečně prohledáváním do šířky, bude počet kroků v $\mathcal{O}(nm^2)$, protože se dá ukázat, že se hrany, které při zlepšování cesty tvoří minimum, postupně vzdalují od zdroje. Pak máme $\mathcal{O}(m)$ času k nalezení cesty a m hran, které se nejvýše n-krát mohou vzdálit. Že to tak skutečně je, je lehce zdlouhavé intelektuální cvičení. Nechat si prozradit postup můžete třeba v druhém vydání Introduction to Algorithms na straně 662.

O vylepšení daného postupu si můžete přečíst v kapitole o tocích v knize Průvodce labyrintem algoritmů[21] od Martina Mareše, ukázka druhého přístupu k řešení hledání maximálního toku je tam také.

K zamyšlení

- Důležitou vlastností algoritmu je, že když dostane celočíselné kapacity, vrátí celočíselný tok. Bude se nám to hodit v aplikacích. Dokážete to?
- Rozdíl mezi Fordem-Fulkersonem, který hledá cesty obecným způsobem, a takovým, který to dělá prohledáváním do šířky, je ze složitostního hlediska docela velký, a proto se tomu druhému občas říká Edmondsův-Karpův. Najděte malý graf a nevhodnou posloupnost cest, která způsobí, že F-F poběží skutečně v závislosti na velikosti kapacit.
- Můžete dokonce zkusit využít zlatého řezu k nalezení grafu s reálnými kapacitami, na kterém F-F pro danou (nešikovnou) posloupnost cest nikdy neskončí.
- Skončí algoritmus v konečném čase, jsou-li kapacity čísla racionální?

Užití

Párování v bipartitních grafech

Máme-li za úkol najít na plese co nejvíce tanečnicím tanečníka, kterého znají, stojíme před zásadním a nelehkým úkolem.

Co třeba postavit na základě známosti bipartitní graf mezi partitou tanečníků a partitou tanečnic, přidat zdroj za kluky a stok za holky, tyto k nim připojit hranami s jednotkovou kapacitou, hranám v bipartitním grafu také nastavit jednotkové kapacity a nakonec všechno zorientovat směrem do stoku?

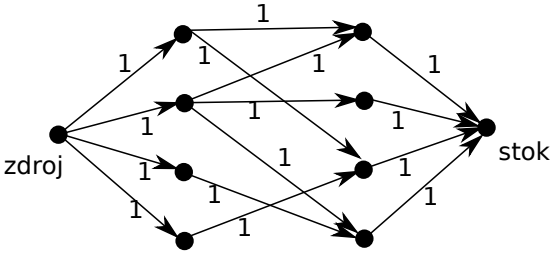

[20] http://kam.mff.cuni.cz/~valla/kg.html

[21] http://pruvodce.ucw.cz/

Maximální celočíselný tok, který na tomto grafu získáme, nám hrany bipartitního grafu rozdělí na nevybrané s tokem 0 a vybrané s tokem 1. Můžou vybrané hrany sdílet tanečníka? Těžko, když do něj teče nejvýše jednotkový tok a musí platit Kirchhoffův zákon. A podobně s tanečnicemi.

Vybrané hrany nám proto vytvoří párování. A protože jsme našli maximální tok, jde o párování největší. Kdyby existovalo párování větší, dokázali bychom z něj zvětšit tok.

Hledání hranově a vrcholově disjunktních cest

Chceme-li se v grafu G dostat z vrcholu u do vrcholu v, může nás zajímat (třeba kvůli spolehlivosti, s jakou se umíme dostat do cíle), kolik mezi nimi existuje cest, které:

- nesdílí hrany, nebo
- nesdílí vrcholy. (Tato podmínka je silnější. Když dvě cesty nesdílí vrcholy, nesdílí hrany.)

Oba tyto problémy lze převést na hledání maximálního toku. V obou případech nastavíme u jako zdroj a v jako stok. V prvním případě nastavíme jednotkové kapacity všem hranám, v druhém navíc všem vrcholům.

Ford-Fulkerson nastavil některým hranám jednotkový tok, některým nulový. Nulové nyní z grafu vyhodíme. Pokud jsme hledali hranově disjunktní cesty, můžeme nyní získat třeba takovýto graf:

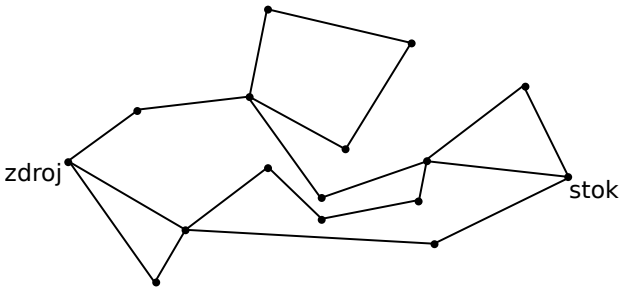

Jak z něj vykřesat kýžený výsledek? Začneme procházet ze zdroje zbylé hrany. Vždy, když se dostaneme do vrcholu, ve kterém už jsme v tom samém průchodu byli, vyhodíme z grafu všechny hrany cyklu, který jsme tímto objevili. (Hodnota toku se tím nezmění.)

Průchodem grafu se vždy můžeme dostat až do stoku (všude jinde budeme moci podle Kirchhoffova zákona jít dál – dost to připomíná úvahu o eulerovských tazích), a[22] protože jsme mezitím agilně odstraňovali cykly, dostali jsme cestu. Vrátíme ji jako jeden výsledek, smažeme její hrany, a pokud ještě tok není nulový, pokračujeme dál.

Počet cest je tedy velikost toku. Podle Mengerovy věty je navíc počet hranově/vrcholově disjunktních cest roven stupni hranové/vrcholové souvislosti grafu – máme tedy nyní algoritmus, který ji najde.

K zamyšlení

- Úvaha nebyla naprosto přímočará kvůli cyklům v nalezeném toku. Říká se jim cirkulace. Je jasné, že v případě hledání hranově disjunktních cest vzniknout mohou. Co v případě vrcholově disjunktních, tedy v situaci, kdy jsme omezili tok vrcholy?
- Nepracuje náhodou neupravený Edmondsův-Karpův algoritmus rychleji, pokud je graf, jak jsme teď opakovaně viděli, ohodnocený toliko nulami a jedničkami?

Dnešní menu servíroval

Lukáš Lánský

[22] `http://ksp.mff.cuni.cz/viz/kucharky/eulerovske-tahy`

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

Webové stránky: *https://ksp.mff.cuni.cz/*
E-mail: *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:B0:01`.