České vysoké učení technické v Praze
Fakulta stavební

155UZPD: Semestrální projekt

MMDOS - Síťové analýzy PID

Únor 2019 Petra Millarová, Michael Kala

1 Cíl projektu

Cílem semestrálního projektu bylo vytvoření konzolové aplikace MMDOS, jež provádí síťové analýzy nad daty PID za využití pgRouting, extenze PostGISu. Uživatel má možnost zadat výchozí a cílovou adresu, aplikace vyhledá nejbližší zastávky hromadné dopravy, provede síťovou analýzu a vrátí nejkratší cestu. Uživateli se poté zobrazí seznam zastávek a linek, které by měl po cestě využít.

2 Data

- Adresní místa RÚIAN Hlavního města Prahy, staženo z Nahlížení do KN (dokumentace: http://vdp.cuzk.cz/vymenny_format/csv/ad-csv-struktura.pdf)
- Síť tras linek Pražské integrované dopravy, staženo z portálu Opendata Hlavního města Prahy (dokumentace: http://www.geoportalpraha.cz/cs/fulltext_geoportal?id=6F576389-385E-4E38-831A-8DE6EFB52C3A#.XErv8stKiV4)
- Zastávky PID - jednotlivé označníky, staženo z portálu Opendata Hlavního města Prahy (dokumentace: http://www.geoportalpraha.cz/cs/fulltext_geoportal?id=63EF19FE-C2FB-4FC2-8C2D-EEBB72C6B81A#.XErxJ8tKiV4)

3 Zpracování dat

3.1 Adresní místa RUIAN

Data byla stažena ve formátu `csv`. Následně pomocí jazyka AWK byl v shellu soubor upraven, aby obsahoval pouze potřebná data (resp. byl vytvořen nový soubor):

```
awk -F \; '{print $11";"$13";"$14";"$15";"$17";"$18}' 20181231_OB_554782_ADR.csv > ruian_adr.csv
```

Ponechány byly sloupce ulice, číslo domovní, číslo orientační, číslo orientační znak (a, b..) a souřadnice x, y v S-JTSK.
Dále byla v databázi na geo102 vytvořena a naplněna tabulka `adr` (včetně geometrie) pomocí dávkového souboru `adr.sql` puštěného pomocí příkazu:

```
psql -h geo102.fsv.cvut.cz -d pgis_uzpd -U uzpd18_a -f adr.sql
```

Obsah dávkového souboru:

```
CREATE TABLE adr(
  gid serial NOT NULL,
  ulice VARCHAR(50),
  c_domovni INTEGER,
  c_orientacni INTEGER,
  co_znak VARCHAR(2),
  y REAL,
  x REAL,
  geom geometry);

\copy adr(ulice, c_domovni, c_orientacni, co_znak, y, x) FROM '../ruian_adr.csv' DELIMITER ';' CSV HEADER encoding 'windows-1250';

UPDATE adr SET geom = ST_GeomFromText('POINT(-'||y||' -'||x||')',5514);

DELETE FROM adr WHERE geom IS NULL;
```

Aby byly názvy ulic importovány správně s diakritikou, bylo třeba nastavit kódování na uvedenou hodnotu `windows-1250`. Zároveň byla pro potřeby projektu z dat vymazána adresní místa bez geometrie.

3.2 Data PID

Data zastávek a tras linek PID byla stažena ve formátu `shp`. Pro import dat do databáze byl využit nástroj PostGISu `shp2pgsql`, jež konvertuje soubory ve formátu `shp` do databázových tabulek. Toto bylo vykonáno pomocí příkazu (v shellu):

```
shp2pgsql -s 5514 -D -I DOP_PID_TRASY_TS_L.shp | psql -h geo102.fsv.cvut.cz -d pgis_uzpd -U uzpd18_a
```

A přímo v databázi byl změněn název vytvořené tabulky:

```
ALTER TABLE dop_pid_trasy_ts_l RENAME TO trasy;
```

Pro potřeby našeho projektu nebyly nutné údaje o nočních linkách, proto byly tyto řádky smazány (soubor `mazani_nocnich.sql`):

```
DELETE FROM trasy
WHERE (l_metro_n IS NULL
```

```
  OR l_tram_n IS NOT NULL
  OR l_bus_n IS NOT NULL
  OR l_lan_n IS NOT NULL
  OR l_vlak_n IS NOT NULL
  OR l_lod_n IS NOT NULL
  AND l_metro IS NULL
  AND l_tram IS NULL
  AND l_bus IS NULL
  AND l_lan IS NULL
  AND l_vlak IS NULL
  AND l_lod IS NULL);
```

Analogicky se postupovalo u zastávek:

```
shp2pgsql -s 5514 -D -I DOP_PID_ZASTAVKY_TS_B.shp| psql -h geo102.fsv.cvut.
    cz -d pgis_uzpd -U uzpd18_a
```

```
ALTER TABLE dop_pid_zastavky_ts_b RENAME TO zastavky;
```

U zastávek byly taktéž smazány řádky obsahující pouze údaje o nočních linkách:

```
DELETE FROM zastavky WHERE zast_denno = 2;
```

Vzhledem k prapodivnosti sloupce `zast_id`, kde se ukázalo, že více zastávek s různými názvy a různým umístěním mají stejné ID, se autoři rozhodli použít sloupec `zast_uzel` jako identifikátor zastávky, protože byla hodnota stejná pro všechny položky se stejným názvem zastávky. Sloupec bylo třeba přetypovat na typ `INTEGER` následujícím příkazem:

```
ALTER TABLE zastavky
ALTER COLUMN zast_uzel_ TYPE INTEGER
USING CAST(zast_uzel_ AS INTEGER);
```

4 Topologie

4.1 Hrany

Vzhledem ke komplikacím zmiňovaným v předchozí kapitole se autoři rozhodli vytvořit topologii bez použití funkce z extenze pgRouting k tomu určené - `pgr_createTopology`. Nejprve byly do tabulky `trasy` přidány sloupce `source` a `target` a vytvořen prostorový index (soubor `topo.sql`):

```
ALTER TABLE trasy ADD COLUMN "source" integer;
ALTER TABLE trasy ADD COLUMN "target" integer;
CREATE INDEX ON trasy USING gist(geom);
```

Následně byl vytvořen skript v Pythonu, který pomocí prostorového dotazu k začátku i konci každé linie v tabulce `trasy` vybral nejbližší bod z tabulky `zastavky` a vrátil ID jeho uzlu, které pak bylo dosazeno do sloupce `source`, případně `target`. Vzhledem k tomu, že geometrickým typem linií v tabulce `trasy` byl `MultiLineString` a funkce `ST_StartPoint()` resp. `ST_EndPoint()` jako argument bere pouze typ `LineString`, bylo třeba mezi těmito typy provést konverzi.

Celý skript (soubor *MMTopology.py*):

```
import psycopg2


# connect to database
conn = psycopg2.connect(host="geo102.fsv.cvut.cz",
            database="pgis_uzpd",
            user="uzpd18_a",
            password="a_uzpd18")

cur = conn.cursor()
cur_s = conn.cursor()
cur_e = conn.cursor()

# Select starting points
cur_s.execute("SELECT DISTINCT ON(t.gid) t.gid, z.zast_uzel_ FROM trasy t,
    zastavky z WHERE ST_DWithin(ST_StartPoint(ST_LineMerge(t.geom)), z.geom,
     500) AND t.zast_id_od = z.zast_id")

# Select end points
cur_e.execute("SELECT DISTINCT ON(t.gid) t.gid, z.zast_uzel_ FROM trasy t,
    zastavky z WHERE ST_DWithin(ST_EndPoint(ST_LineMerge(t.geom)), z.geom,
    500) AND t.zast_id_ka = z.zast_id")

sp = cur_s.fetchone()
ep = cur_e.fetchone()
i = 0

# loop through starting and ending points, update source and target
while sp is not None or ep is not None:
  if sp is not None:
    cur.execute("UPDATE trasy SET source = {} WHERE gid = {}".format(sp[1],
    sp[0]))
  if ep is not None:
    cur.execute("UPDATE trasy SET target = {} WHERE gid = {}".format(ep[1],
    ep[0]))
  sp = cur_s.fetchone()
  ep = cur_e.fetchone()

conn.commit()

cur_s.close()
cur_e.close()
cur.close()

if conn is not None:
  conn.close()
```

Počet řádků v tabulce trasy se pohybuje kolem 85 000, skript běžel několik desítek minut.

4.2 Uzly

Následně byla vytvořena tabulka uzlů pomocí funkce *pgr_createVerticesTable*. Sloupec `the_geom` byl přejmenován na `geom` (soubor `uzly.sql`):

```
SELECT pgr_createVerticesTable('trasy','geom','source','target');
ALTER TABLE trasy_vertices_pgr rename column the_geom to geom;
```

5 Konzolová aplikace

5.1 Popis výpočtu

V jazyce Python byl vytvořen skript (soubor `MMDOS.py`), který na vstup uživatele provádí síťovou analýzu za využití Dijkstrova algoritmu implementovaného v pgRouting jako funkce `pgr_dijkstra`. Postup výpočtu je následující:

1. Zjištění ID nejbližších zastávek od zadaných adres, aplikace umožňuje uživateli zadat následující kombinace údajů o adresách:

   - ulice, č.p./č.o.
   - ulice, č.p.
   - ulice, č.o.
   - ulice

   kdy na základě zadaných údajů je vyhledána adresa jim vyhovující, případně první z adres jim vyhovující.

2. Výpočet nejkratší cesty pomocí Dijstrova algoritmu.

3. Výpis zastávek a linek respektující nejmenší počet přestupů.

   - V tabulce `trasy` jsou pro každý úsek vyjmenovány všechny linky, které na daném úseku poskytují přepravu. Program prochází vytvořenou trasu a vybírá linky s nejmenším počtem přestupů následovně:
     (a) Průchod všech linek projíždějících první zastávkou (resp. úsekem mezi první a druhou zastávkou), výpočet dosahu každé linky (tedy až o kolik zastávek se lze posunout danou linkou).
     (b) Přiřazení čísla linky s nejdelším dosahem (příp. první z linek, které mají shodný nejdelší dosah) k daným zastávkám.
       – Vzhledem k přiřazování čísel linek k počátečním bodům úseků, se číslo linky nepřiřadí k poslední zastávce, do které vybraná linka dosahuje. Toto je využito v dalším kroku.
     (c) Opakování kroku (a) a (b) od první zastávky s nepřiřazeným číslem linky.

5.2 Vytvořené SQL funkce

Pro potřeby konzolové aplikace byly vytvořeny následující SQL funkce (soubor `funkce.sql`):

- Funkce pro zjištění názvu zastávky podle zadaného ID.

```
CREATE OR REPLACE FUNCTION FindStationName(id INTEGER)
RETURNS VARCHAR AS $name$
declare
  name varchar;
BEGIN
  SELECT z.zast_nazev INTO name FROM zastavky z
  WHERE z.zast_uzel_ = id LIMIT 1;
  RETURN name;
END;
$name$ LANGUAGE plpgsql;
```

- Set funkcí pro zjištění ID uzlu zastávky, která je nejblíže zadané adrese. První tři funkce jsou uzpůsobeny na zadání názvu ulice a kombinace čísla orientačního, popisného a nebo obou. Poslední z funkcí umožňuje uživateli zadat jen název ulice, přičemž funkce vrací i adresu, ke které bylo hledání nejbližší zastávky vztaženo. U prvních dvou funkcí není třeba vracet celou adresu, jelikož čísla popisná a orientační jsou dle zákona unikátní v rámci ulice (popisné v rámci části obce).

```
CREATE OR REPLACE FUNCTION FindVertexID(cd INTEGER, co INTEGER, u
    VARCHAR)
RETURNS INTEGER AS $id$
declare
  id integer;
BEGIN
  SELECT v.id INTO id FROM adr a, trasy_vertices_pgr v
  WHERE a.c_domovni = cd
  AND a.c_orientacni = co
  AND a.ulice = u
  ORDER BY (a.geom)<->(v.geom) asc limit 1;
  RETURN id;
END;
$id$ LANGUAGE plpgsql;

CREATE OR REPLACE FUNCTION FindVertexIDcd(cd INTEGER, u VARCHAR)
RETURNS INTEGER AS $id$
declare
  id integer;
BEGIN
  SELECT v.id INTO id FROM adr a, trasy_vertices_pgr v
  WHERE a.c_domovni = cd
  AND a.ulice = u
  ORDER BY (a.geom)<->(v.geom) asc limit 1;
  RETURN id;
END;
$id$ LANGUAGE plpgsql;

CREATE OR REPLACE FUNCTION FindVertexIDori(co INTEGER, u VARCHAR)
RETURNS INTEGER AS $id$
declare
  id integer;
```

```
BEGIN
  SELECT v.id INTO id FROM adr a, trasy_vertices_pgr v
  WHERE a.c_orientacni = co
  AND a.ulice = u
  ORDER BY (a.geom)<->(v.geom) asc limit 1;
  RETURN id;
END;
$id$ LANGUAGE plpgsql;

CREATE OR REPLACE FUNCTION FindVertexIDst(u VARCHAR)
RETURNS TABLE(
id BIGINT,
ul VARCHAR,
cp INTEGER,
co INTEGER
  ) as $$
BEGIN
  RETURN QUERY SELECT v.id, a.ulice, a.c_domovni, a.c_orientacni FROM
    adr a, trasy_vertices_pgr v
  WHERE a.ulice = u
  ORDER BY (a.geom)<->(v.geom) asc limit 1;
 END;
$$
LANGUAGE plpgsql;
```

5.3 Dijskrův algoritmus

Pro výpis nejkratší cesty byl použit následující příkaz:

```
SELECT z.zast_nazev, trasy.l_metro, trasy.l_tram, trasy.l_bus, trasy.l_lan,
    trasy.l_vlak, trasy.l_lod, node
FROM pgr_dijkstra('SELECT gid AS id, source, target, CAST(shape_leng AS
   REAL) AS cost FROM trasy', id_from, id_to)
JOIN (
  SELECT DISTINCT(zastavky.zast_uzel_), zastavky.zast_nazev FROM zastavky
  ) AS z ON node = z.zast_uzel_
LEFT JOIN trasy ON edge = trasy.gid
ORDER BY seq;
```

kde `id_from, id_to` jsou ID počáteční a koncové zastávky.
K tabulce výsledků z výpočtu funkcí `pgr_dijkstra` byla přes sloupec `zast_uzel_` připojena tabulka `zastavky`, ze které byl vypsán název zastávky. Připojena byla též tabulka `trasy` pro zobrazení linek, které daným místem projíždějí. Protože poslední uzel nemá žádnou navazující hranu, ale musí být také vypsán, byl použit `LEFT JOIN`, který zachovává všechny údaje z původní tabulky. Nakonec byl výstup seřazen podle atributu `seq`, jež udává pořadí zastávek v nalezené trase.

5.4 Ukázka aplikace

Aplikace lze spustit spuštěním skriptu `MMDOS.py` (v přílohách).

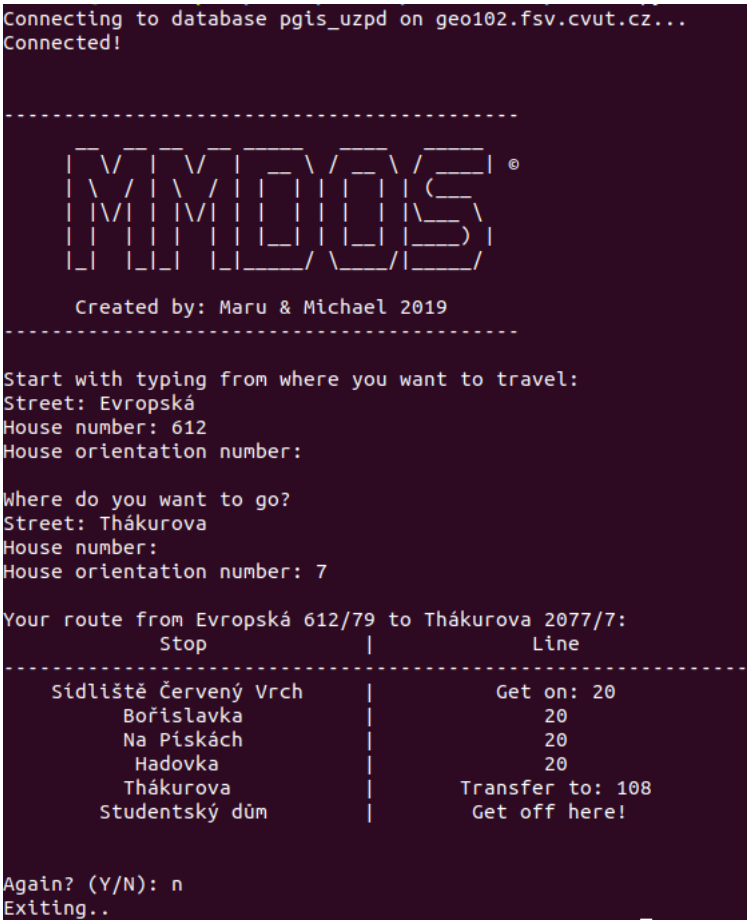

6 Závěr

6.1 Zhodnocení

Byla vytvořena konzolová aplikace pro vyhledávání spojů PID v závislosti na zadané adrese počátečního a cílového místa. Aplikace respektuje nejmenší počet přestupů.
Při zpracování dat se vyskytlo několik problémů, zejména u dat poskytovaných na serveru Opendata, kde docházelo k případům, že několik zastávek mělo stejné "unikátní ID", přestože se nejmenovaly stejně a ani se nenacházely na stejném dopravním uzlu. Stejná ID byla použita v datové sadě s linkami PID u ID počátečních a koncových bodů jednotlivých úseků linek. Toto vyústilo v problém, kdy docházelo k chybnému přiřazení zastávek k příslušným úsekům linek. Tento problém byl vyřešen pomocí prostorového dotazování na nejbližší zastávky k daným bodům.
Dalším problémem byla přítomnost záznamů linek s nočními spoji. To způsobovalo chybné vyhledávání nejkratších tras. Toto bylo vyřešeno vymazáním těchto údajů z tabulky.

6.2 Náměty na vylepšení

- Ocenění tras např. podle typu dopravy - současný model hledá nejkratší trasu bez ohledu na přestupy
- Přidání možnosti nočního cestování
- Přidání jízdních řádů

7 Přílohy

- Import adres do databáze - `adr.sql`
- Mazání údajů o nočních linkách - `mazani_nocnich.sql`
- Topologie tras (přidání sloupců) - `topo.sql`
- Skript pro topologii tras - `MMTopology.py`
- Vytvoření tabulky s uzly - `uzly.sql`
- Skript MMDOS - `MMDOS.py`
- Vytvořené SQL funkce - `funkce.sql`

8 Zdroje

- Nahlížení do KN, aplikace ČÚZK - https://nahlizenidokn.cuzk.cz/
- Portál pro Otevřená data hlavního města Prahy - http://opendata.praha.eu/
- Upload csv tabulky do databáze - http://www.postgresqltutorial.com/import-csv-file-into-posgresql-table/
- Tvorba topologie pomocí pgRouting - http://docs.pgrouting.org/latest/en/pgr_createTopology.html
- Tvorba nové tabulky uzlů - http://docs.pgrouting.org/latest/en/pgr_createVerticesTable.html
- Funkce pro vyhledání nejkratší trasy - http://docs.pgrouting.org/latest/en/pgr_dijkstra.html