




**VIZU  
ALIZ  
ACE  
DAT**



# **7. ZÍSKÁVÁNÍ A ANALÝZA DAT**









**Petr Koubský**

38 mins · Prague · 🌐

Kdo v těchto volbách prohrál opravdu katastrofálně, to jsou datoví analytici. Vůbec to nemyslím jako příspěvek do soutěže o nejsarkastičtější komentář, je to vážná věc sama o sobě. Bude se teď blbě vysvětlovat, že velká data atd., když chroustači dat do jednoho spáchali morální sebevraždu v přímém přenosu. (Nate Silver!!) Garbage in garbage out – pilovali detaily matematických modelů a ignorovali, že do nich cpou zcela nespolehlivé údaje. Život se ukázal zas jednou být složitější než matematika. Otřese to důvěrou v celý obor.

**Hillary Clinton** has an  
**85% chance** to win.

Last updated Tuesday, November 8 at 10:20 PM ET

CHANCE OF WINNING



85%  
Hillary Clinton



15%  
Donald J. Trump

# Chance of winning

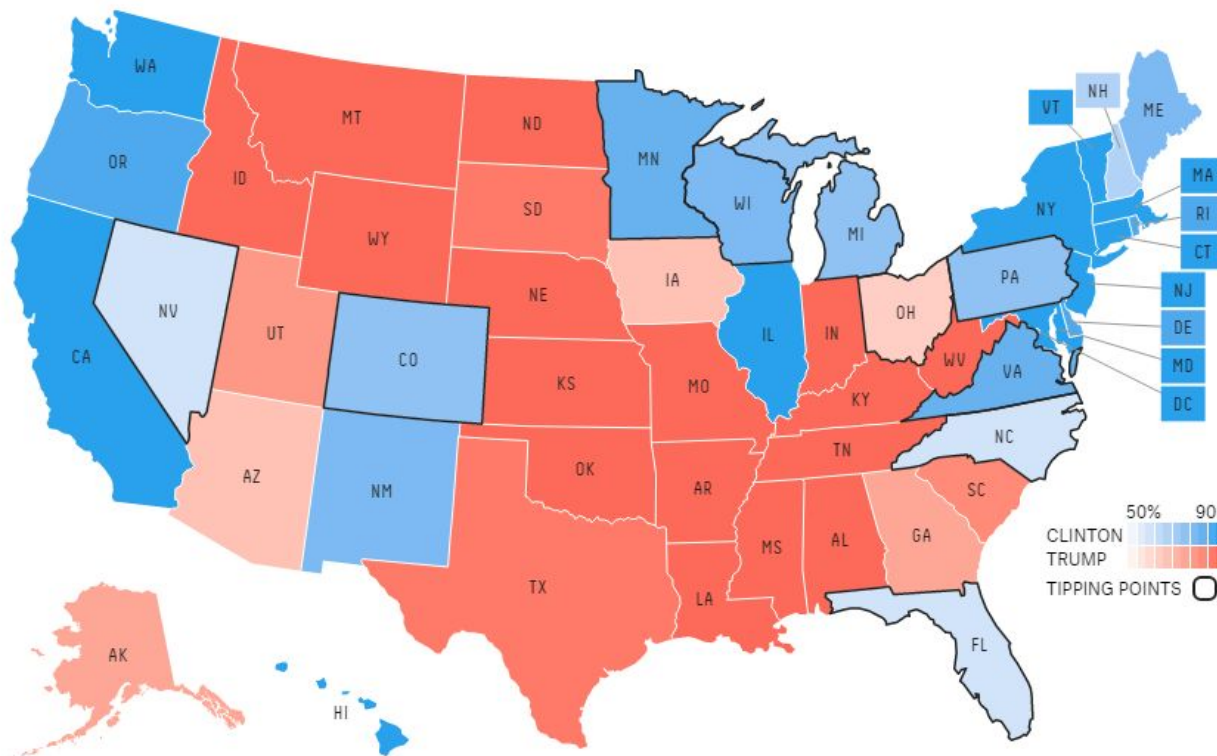


Hillary Clinton

**71.4%**

Donald Trump

**28.6%**





Clinton has **2,586** ways to win

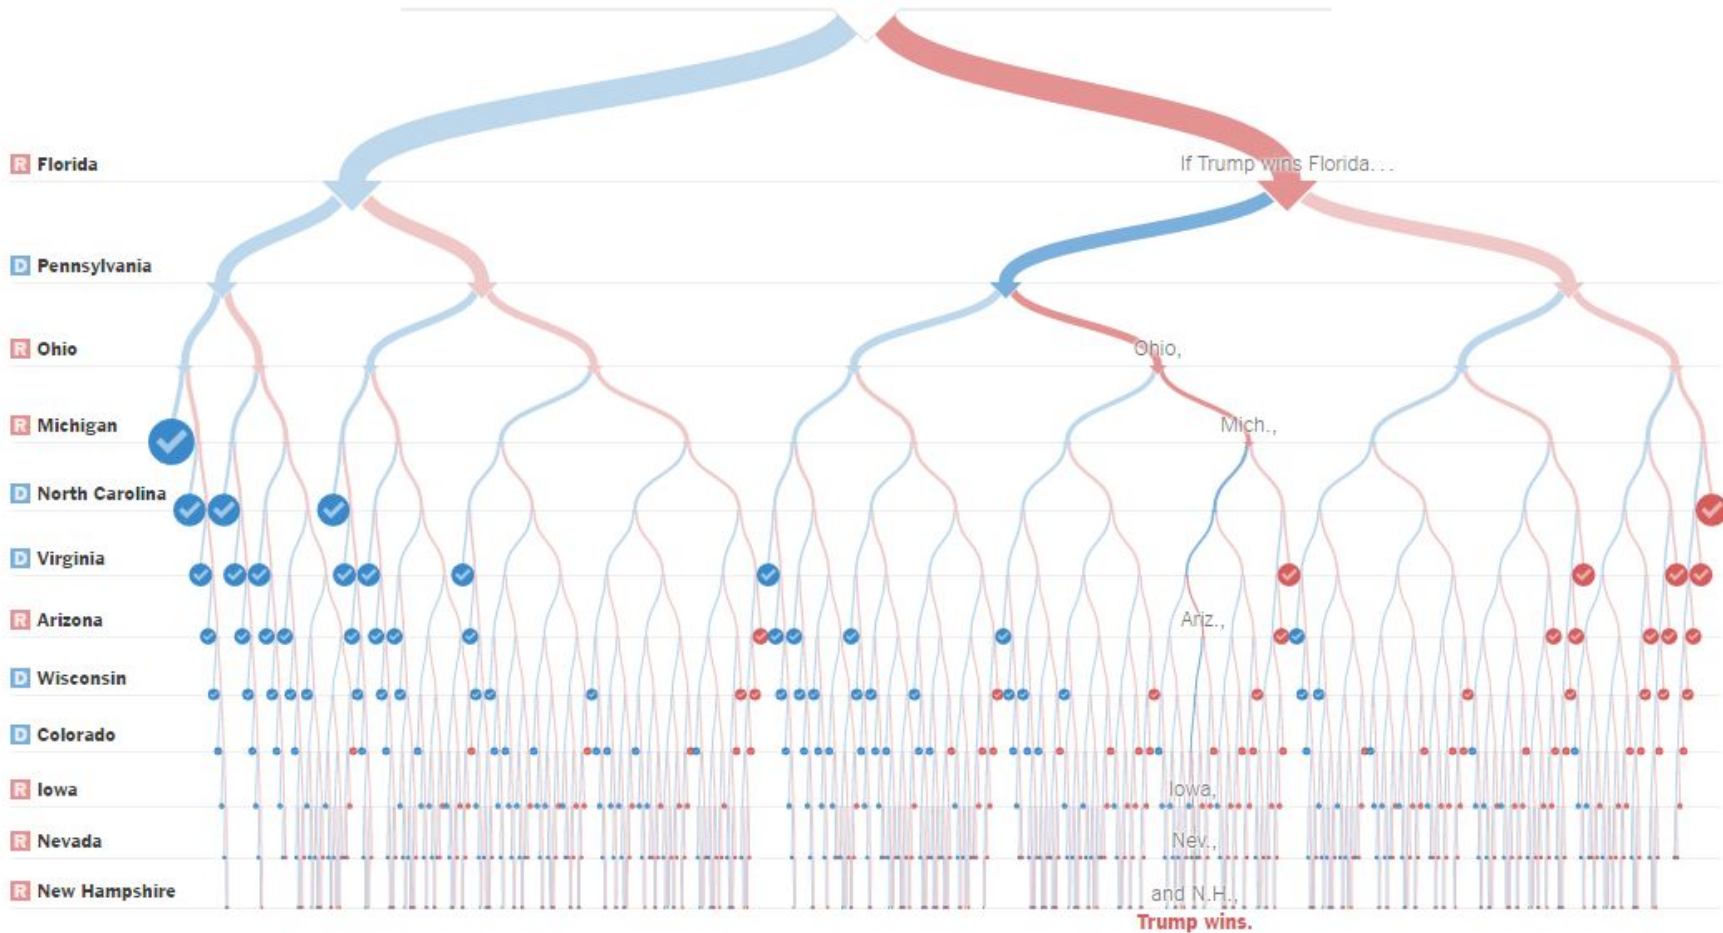
63% of paths

**59** ties


1% of paths

Trump has **1,451** ways to win

35% of paths



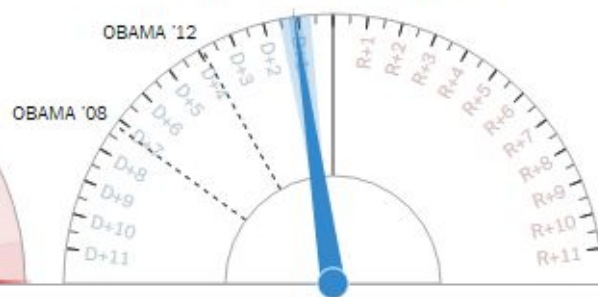
### Win Presidency



**>95% Trump**

FORECAST


### Popular vote margin



**Clinton +1.1**

FORECAST, in pct. points

### Electoral votes

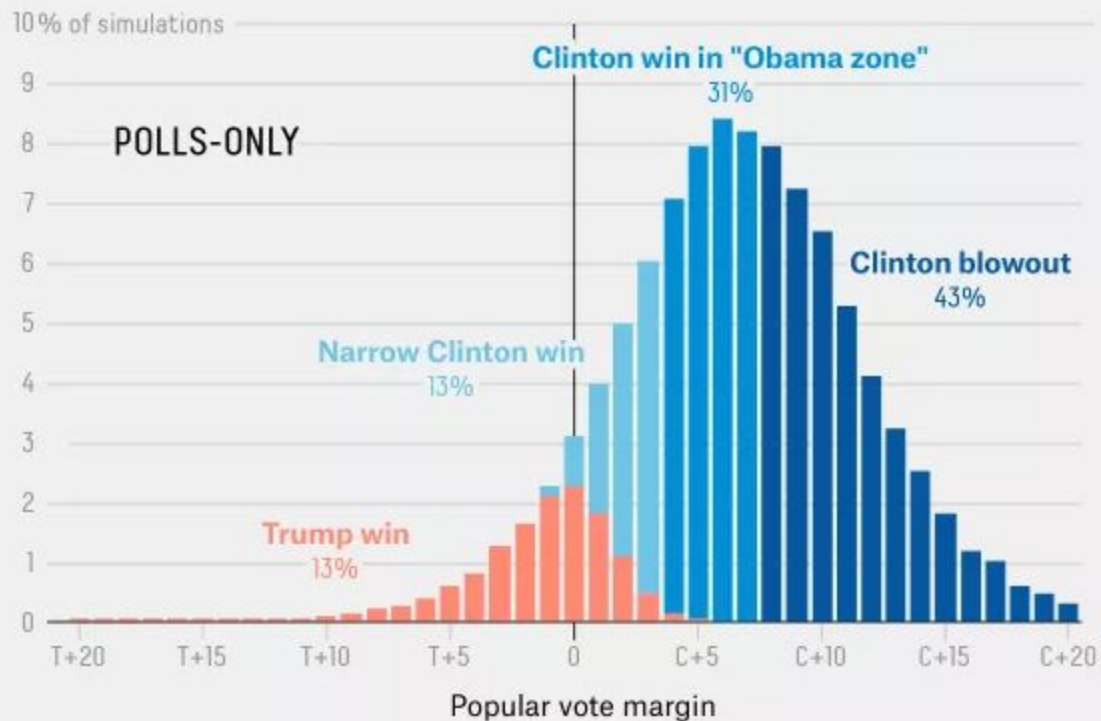


**306 Trump**

FORECAST

## Potential outcomes of the presidential election



Likelihood of scenarios given by 20,000 simulations of the FiveThirtyEight polls-only and polls-plus election forecasts



# Potential outcomes of the presidential election

Likelihood of scenarios given by 20,000 simulations of the FiveThirtyEight polls-only and polls-plus election forecasts





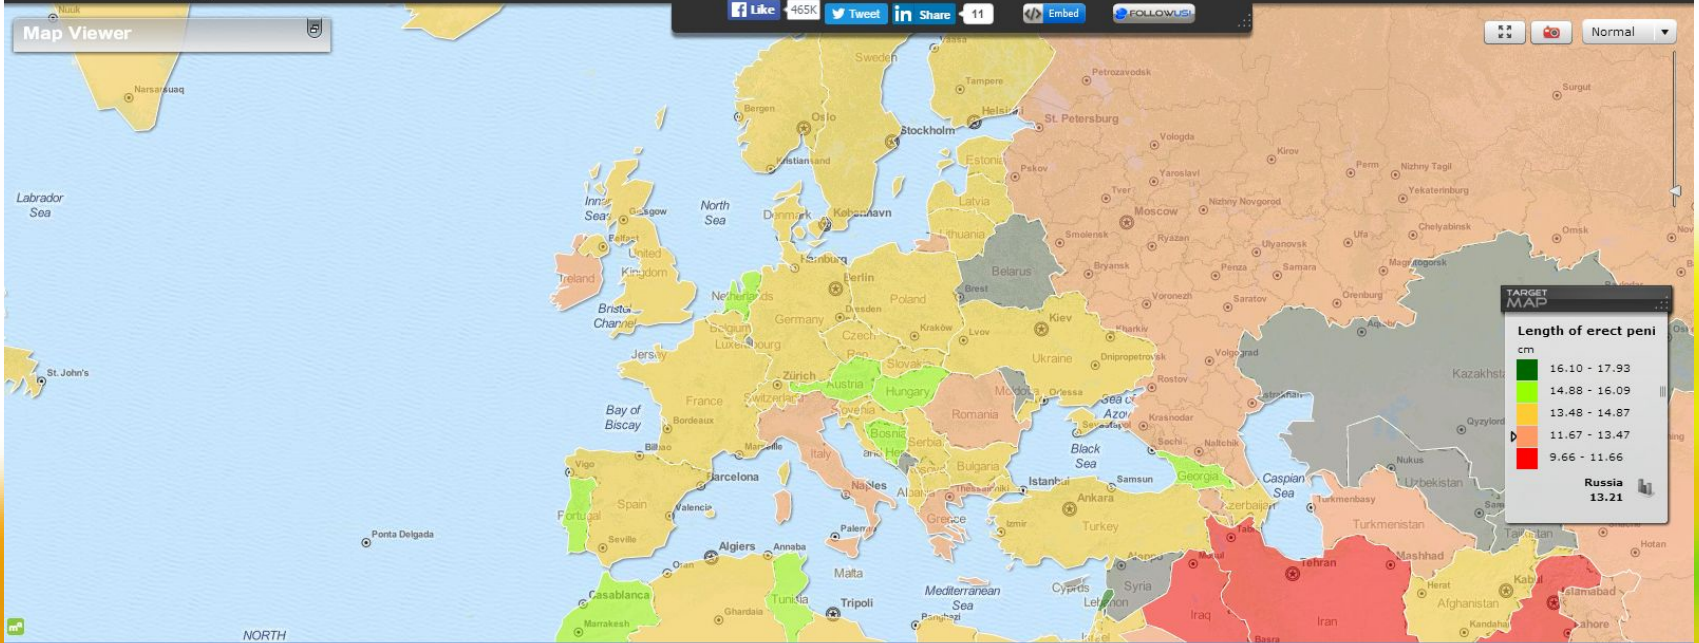


# The Penis Size Worldwide (country)

Map Viewer

[Like](#) 465K [Tweet](#) [Share](#) 11 [Embed](#) [FOLLOW US!](#)

Normal



**TARGET MAP**

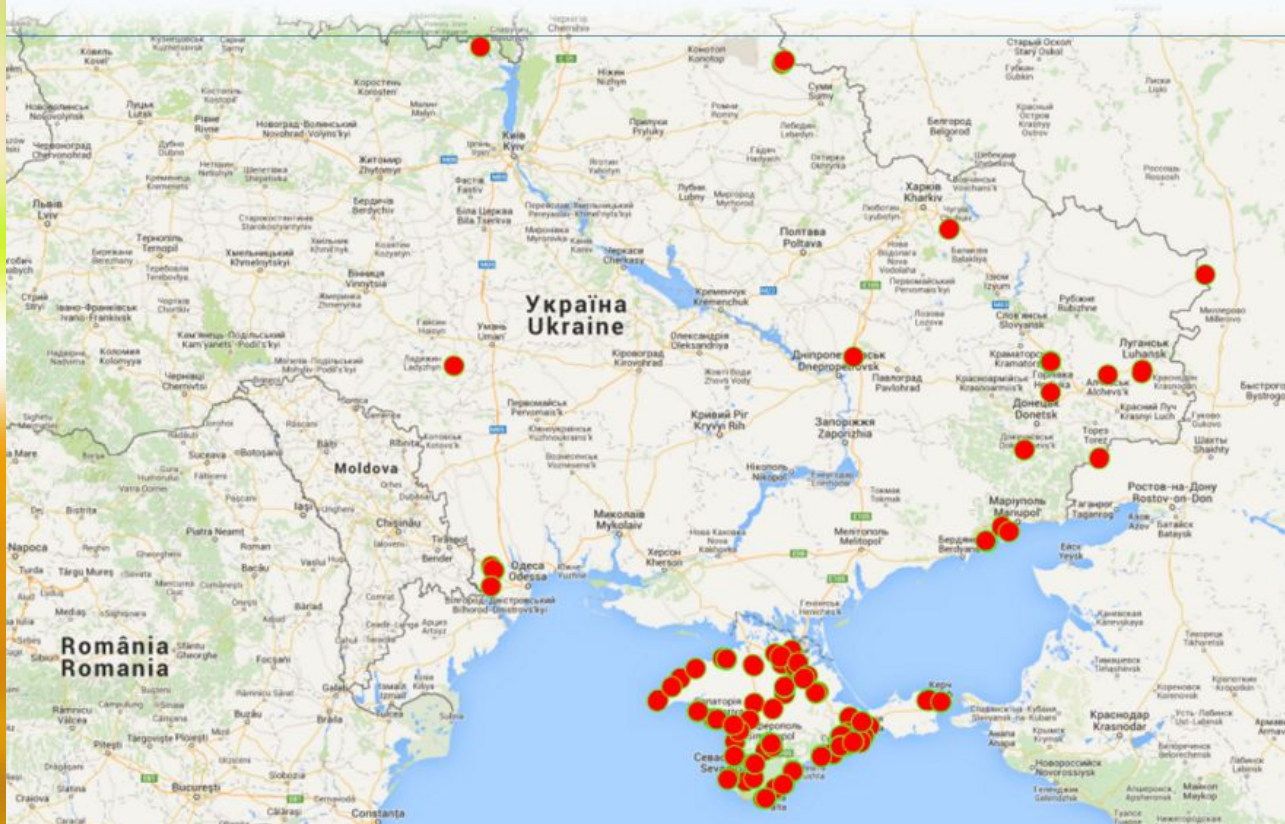
**Length of erect peni**  
cm

- 16.10 - 17.93
- 14.88 - 16.09
- 13.48 - 14.87
- 11.67 - 13.47
- 9.66 - 11.66

**Russia**  
13.21

Country	Continent/Region	Length of erect penis in centimeter (SUM)	Length of erect penis in inches	Circumference of erect penis in centimeter	Circumference of erect penis in inches	Volume (n*pi*r^2*1) in cm3	Method	N
Afghanistan	South Asia	13.69	5.4	11.42	4.5	142	Measured	100
Albania	Europe	14.19	5.6	12.16	4.79	167	Self reported	95
Algeria	Africa	14.83	5.8	10.97	4.32	142	Self reported	738
Angola	Africa	15.73	6.2	13.08	5.15	214.2	Measured	978

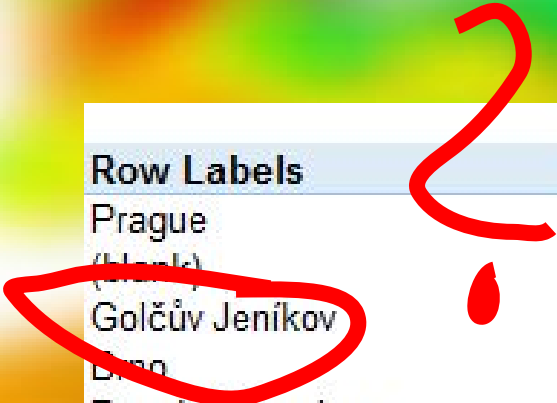
# Ленин street





# Ленин + Ленін street





Row Labels	Sum of Pozadovana ciastka
Prague	20071483
(Blank)	14721728
Golčův Jeníkov	3541500
Brno	2680963
Banska Bystrica	2388960
Košice	1674000

Nebodované cvičení: tabulka **Brno-střed.xls** v úschovně mapuje neobydlené byty v majetku městské části. Pomocí kontingenčních tabulek odpovězte na otázky:

1. O kolik měsíčně Brno-střed na nepronajatých bytech přichází? (Cena nájmu se spočítá jako výměra krát cena za m<sup>2</sup>.)
2. O kolik přichází jen na Bratislavské?
3. Která ulice má průměrně nejdražší nájem?
4. Která ulice má průměrně nejdražší nájem, když nás zajímají nás pouze ulice, kde je aspoň pět nepronajatých bytů?
5. Jaký je mezi volnými byty podíl bytů 2+1? Jaká je průměrná cena nájmu v takovém bytě? (Bonusová otázka: ne průměr, ale medián ceny.)

**ZDROJE**

**DAT**



ZUCHLÖST

KI  
RV  
EI  
AT  
TA



ZUCHLÖST


K  
R  
E  
A  
T  
I  
V  
I  
T  
A




③ RŮČNĚ






RŮCHLOST





 ... KAVA


% ... alko


 ... ČAJ

 ... teplé  
 ... studené

 ... VODA







 ... nachystal mi náčudo

 ... víno

 ... cukr / sladká voda








Každý kruh zvažuje jeden deň od pondělí:

Kruhy končí pátkem a sobotou, což došla množství  
 vypitého alkoholu i) Neděle si bohužel nepamatuji,  
 resp. data nebyla možné sbírat (od rána)

### Legenda



2) teplota

- teplej
- studený

3) množství

o 1 del

4) alkohol/nealko


- nealko
- alko

5) Plast

balení nápoj

Lukáš Eliáš, 425 697

# Colours In Culture



- |                      |                    |                |
|----------------------|--------------------|----------------|
| A Western / American | 1 Anger            | 19 Desire      |
| B Japanese           | 2 Art / Creativity | 20 Earthy      |
| C Hindu              | 3 Authority        | 21 Energy      |
| D Native American    | 4 Bad Luck         | 22 Erotic      |
| E Chinese            | 5 Balance          | 23 Eternity    |
| F Asian              | 6 Beauty           | 24 Evil        |
| G Eastern European   | 7 Calm             | 25 Excitement  |
| H Muslim             | 8 Celebration      | 26 Family      |
| I African            | 9 Children         | 27 Femininity  |
| J South American     | 10 Cold            | 28 Fertility   |
|                      | 11 Compassion      | 29 Flamboyance |
|                      | 12 Courage         | 30 Freedom     |
|                      | 13 Cowardice       | 31 Friendly    |
|                      | 14 Cruelty         | 32 Fun         |
|                      | 15 Danger          | 33 God         |
|                      | 16 Death           | 34 Gods        |
|                      | 17 Decadence       | 35 Good Luck   |
|                      | 18 Deceit          | 36 Gratitude   |

- |                 |                   |                     |
|-----------------|-------------------|---------------------|
| 37 Growth       | 55 Luxury         | 73 Royalty          |
| 38 Happiness    | 56 Marriage       | 74 Self-cultivation |
| 39 Healing      | 57 Modesty        | 75 Strength         |
| 40 Healthy      | 58 Money          | 76 Style            |
| 41 Heat         | 59 Mourning       | 77 Success          |
| 42 Heaven       | 60 Mystery        | 78 Trouble          |
| 43 Holiness     | 61 Nature         | 79 Trust            |
| 44 Illness      | 62 Passion        | 80 Trust            |
| 45 Insight      | 63 Peace          | 81 Unhappiness      |
| 46 Intelligence | 64 Penance        | 82 Virtue           |
| 47 Intuition    | 65 Power          | 83 Warmth           |
| 48 Religion     | 66 Personal power | 84 Wisdom           |
| 49 Jealousy     | 67 Purity         |                     |
| 50 Joy          | 68 Radicalism     |                     |
| 51 Learning     | 69 Rational       |                     |
| 52 Life         | 70 Reliable       |                     |
| 53 Love         | 71 Repels Evil    |                     |
| 54 Loyalty      | 72 Respect        |                     |

- Yellow
- Grey
- Gold
- Silver





K  
R  
E  
A  
T  
I  
V  
I  
T  
A




RUČNĚ

VERĚ



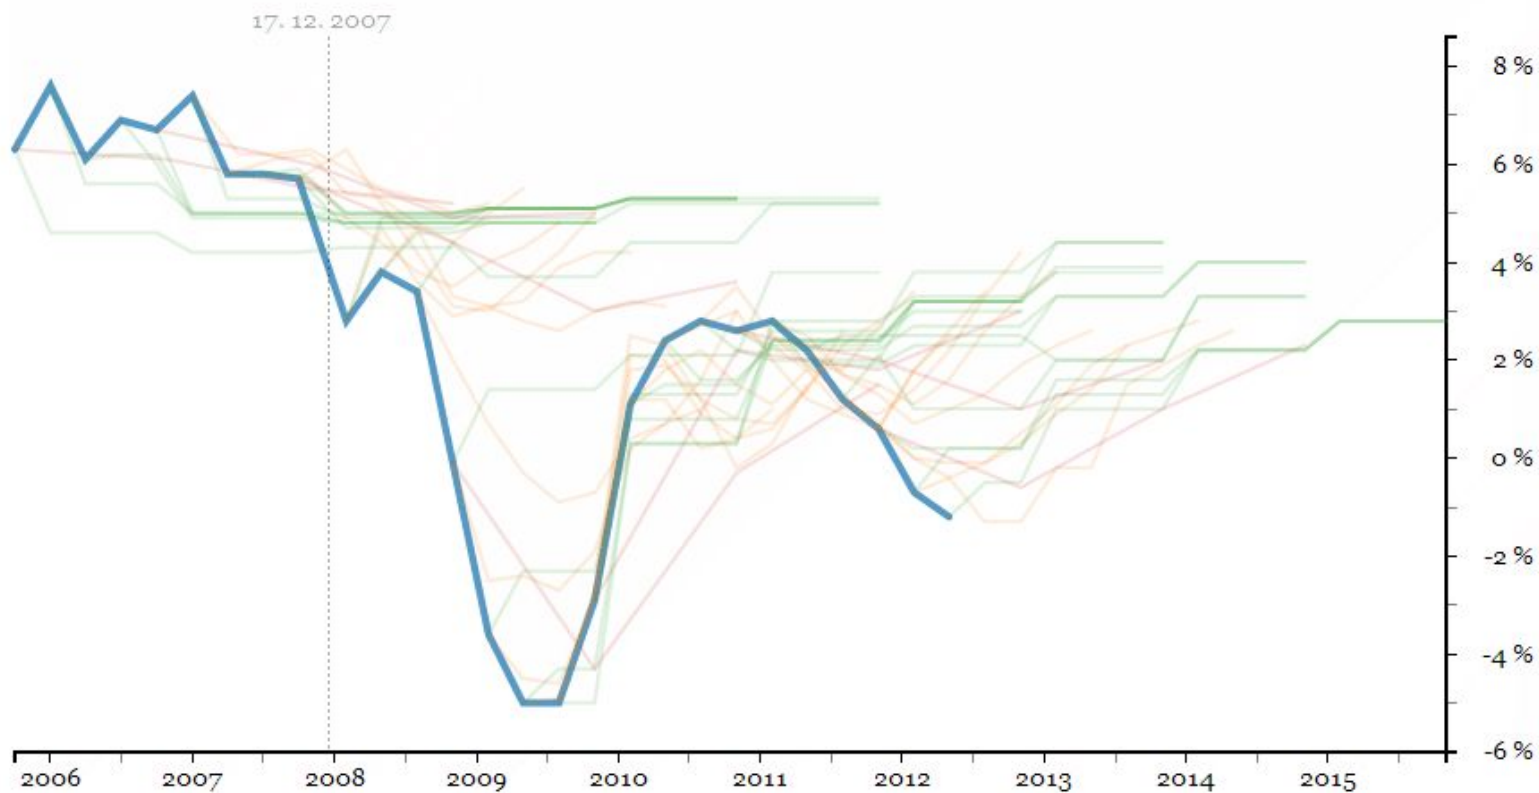
RYCHLOST

ČSÚ



**Institute:**


- Prognóza ČNB
- Prognóza MF
- Prognóza MPSV






ČSÚ

sčítání obyvatel (cenzus)




### VELIKOST OBCE


TAŽENÍM MYŠI VYBERETE ČÁST GRAFU, KTERÁ VÁS ZAJÍMÁ




### VĚKOVÝ PRŮMĚR



### LIDÉ S VYSOKOU ŠKOLOU



### PODÍL NEZAMĚSTNANÝCH



ČSÚ

sčítání obyvatel (cenzus)

ministerstva, kraje, obce, ...

ČSÚ

sčítání obyvatel (cenzus)

ministerstva, kraje, obce, ...

otevřená data: Praha

Stíny Jižního Města

2014-06-15 17:00:00



ČSÚ

sčítání obyvatel (cenzus)

ministerstva, kraje, obce, ...

otevřená data: Praha

apps: VOR, VZ, VášMajetek, mapy.cz

ČSÚ

sčítání obyvatel (cenzus)

ministerstva, kraje, obce, ...

otevřená data: Praha

apps: VOR, VZ, VášMajetek, mapy.cz

tematické databáze: GTD

## Česko se bojí terorismu.

### Evropa přitom prožívá relativně klidné období


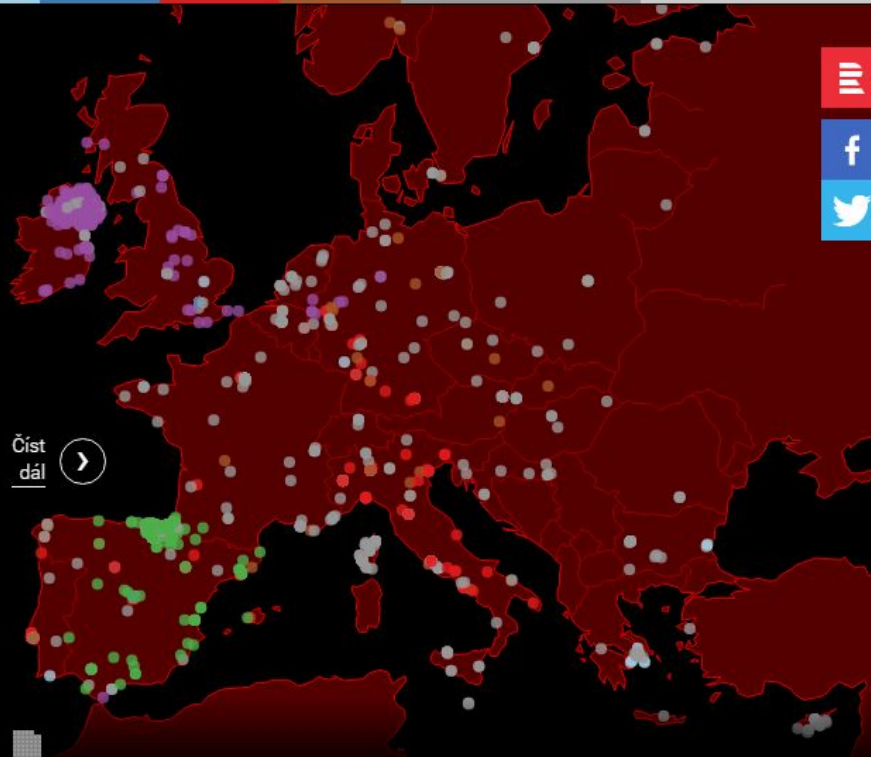
Přesně před čtrnácti lety odstartoval útok na New York a Washington mezinárodní „válku proti terorismu“.

Zmapovali jsme moderní historii teroristických útoků v Evropě a ukázalo se, že jejich obětí dlouhodobě ubývá.

Češi přesto považují terorismus, obvykle ve spojení s imigrací, za největší aktuální hrozbu - ať už pro Českou republiku, nebo pro Evropskou unii. Ukazuje to [výzkum české vlády](#) z ledna i [výzkum agentury STEM](#) z května.

Graf ve spodní části obrazovky znázorňuje, kolik lidí teroristé v jednotlivých letech zabili – jeden čtvereček představuje jednu oběť. Vybarvené jsou podle toho, která teroristická skupina má útok na svědomí. Každý útok je také zakreslený v mapě.

Čist  
dál





ČSÚ

sčítání obyvatel (cenzus)

ministerstva, kraje, obce, ...

otevřená data: Praha

apps: VOR, VZ, VášMajetek, mapy.cz

tematické databáze: GTD

výzkumy, průzkumy, ...

K  
R  
E  
A  
T  
I  
V  
I  
T  
A  
T  
A



③ RUCNĚ

④ ?

⑤ VERĚ



RYCHLOST

**KDYŽ NEVÍTE, PTEJTE SE**

**kolik je agentů StB ve vedení policie?**

**KDYŽ NEVÍTE, PTEJTE SE**

**kolik je agentů StB ve vedení policie?**

**kdo létá na podnikatelské mise s prezidentem?**

# **KDYŽ NEVÍTE, PTEJTE SE**

**kolik je agentů StB ve vedení policie?**

**kdo létá na podnikatelské mise s prezidentem?**



**kde myslivci zastřelí nejvíc srnečků?**

**KDYŽ NEODPOVÍ, ZKUSTE ZÁKON 106**

**...o svobodném přístupu k informacím**

**JAK NA TO:  
OTEVŘETE.CZ**







**zveřejnění platů manažerů  
státních firem:  
povede ke zvýšení nebo  
snížení?**

K  
R  
E  
A  
T  
I  
V  
I  
T  
A  
T  
A



③ RUČNĚ

④ ?

⑤ SCRAP.

⑥ VEŘE

RYCHLOST

# SCRAPOVÁNÍ

# SCRAPOVÁNÍ

využití toho, že HTML je strukturované (tagy)

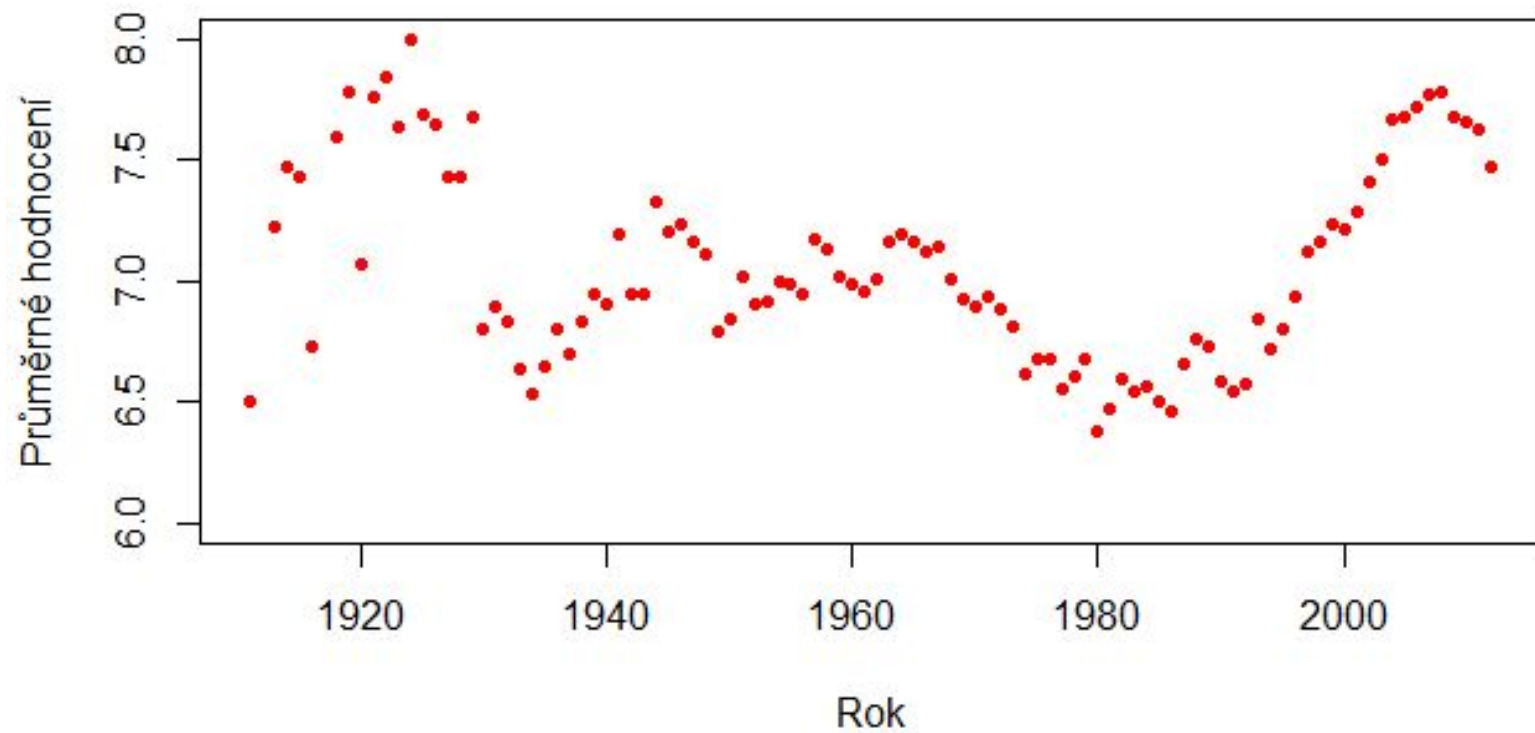
**RO  
BO  
T!**



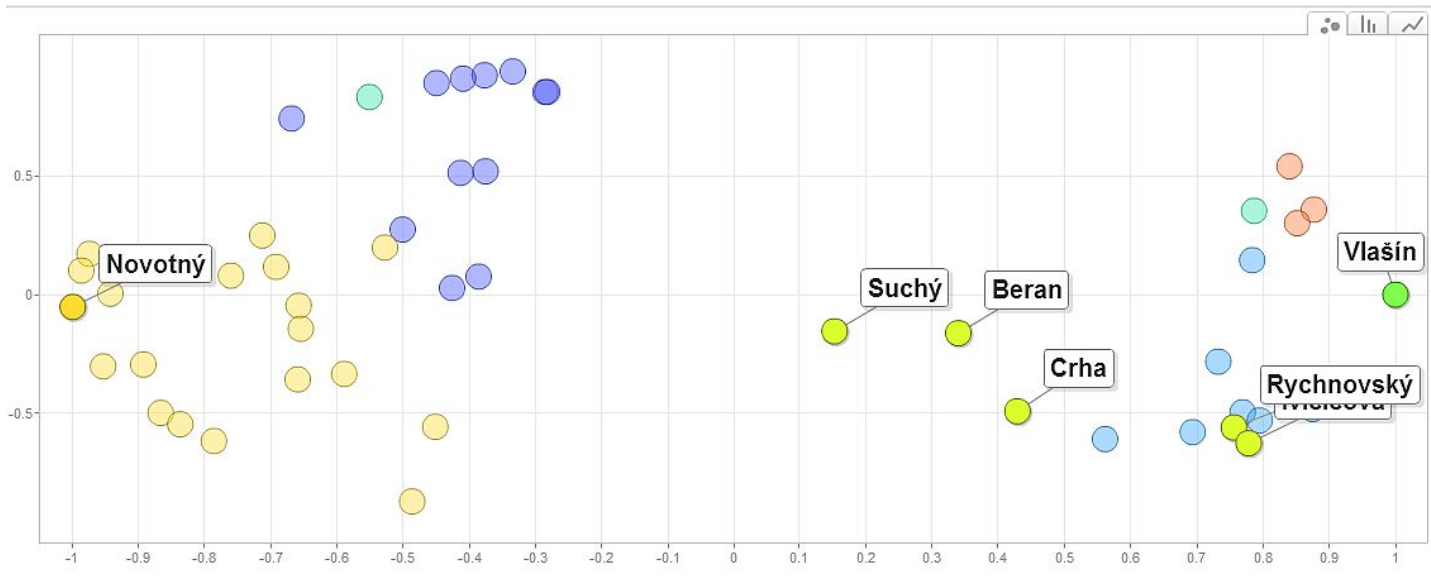
# RO BO T!

```
1 library(RCurl)
2 library(XML)
3 library(stringr)
4
5 linky <- paste("http://www.sdruzeni-sova.cz/seznam-aut-s-podezrenim-na-zasah-do-stavu-tachometru?vi
6
7 df <- read.csv(text="datum-webu, VIN, znacka, model, datum-zaznamu, km-pred, zeme, datum-kontroly, l
8
9 for(i in 1:198) {
10
11   web <- getURL(linky[i], .opts = list(ssl.verifypeer = FALSE), .encoding = "UTF-8")
12   web <- readLines(tc <- textConnection(web)); close(tc)
13
14   datum <- grep("Vozy nalezeny", web)
15   start <- datum
16   datum <- web[datum]
17   datum <- gsub(".*dne ", "", datum)
18   datum <- gsub("</h4>", "", datum)
19
20   for(j in start) {           # pro každé datum
21
22     startaut <- j+16
23
24     while(grep("<td>", web[startaut])) {           # pro každé auto
25
26       datumwebu <- web[j]
27       datumwebu <- gsub(".*dne ", "", datumwebu)
28       datumwebu <- gsub("</h4>", "", datumwebu)
29       datumwebu <- as.character(datumwebu)
30
31       VIN <- web[startaut]
32       VIN <- gsub(".*<td>", "", VIN)
33       VIN <- gsub("</td>", "", VIN)
34       VIN <- as.character(VIN)
35
36       znacka <- web[startaut+1]
37       znacka <- gsub(".*<td>", "", znacka)
38       znacka <- gsub("</td>", "", znacka)
39       znacka <- as.character(znacka)
40
41       model <- web[startaut+2]
42       model <- gsub(".*<td>", "", model)
43       model <- gsub("</td>", "", model)
44       model <- as.character(model)
45
```


## Hodnocení na ČSFD



# Zastupitelstvo 11/2012 až 01/2013







K  
R  
I  
T  
I  
C  
I  
T  
A  
T  
A



 RUČNĚ

 SENZ.

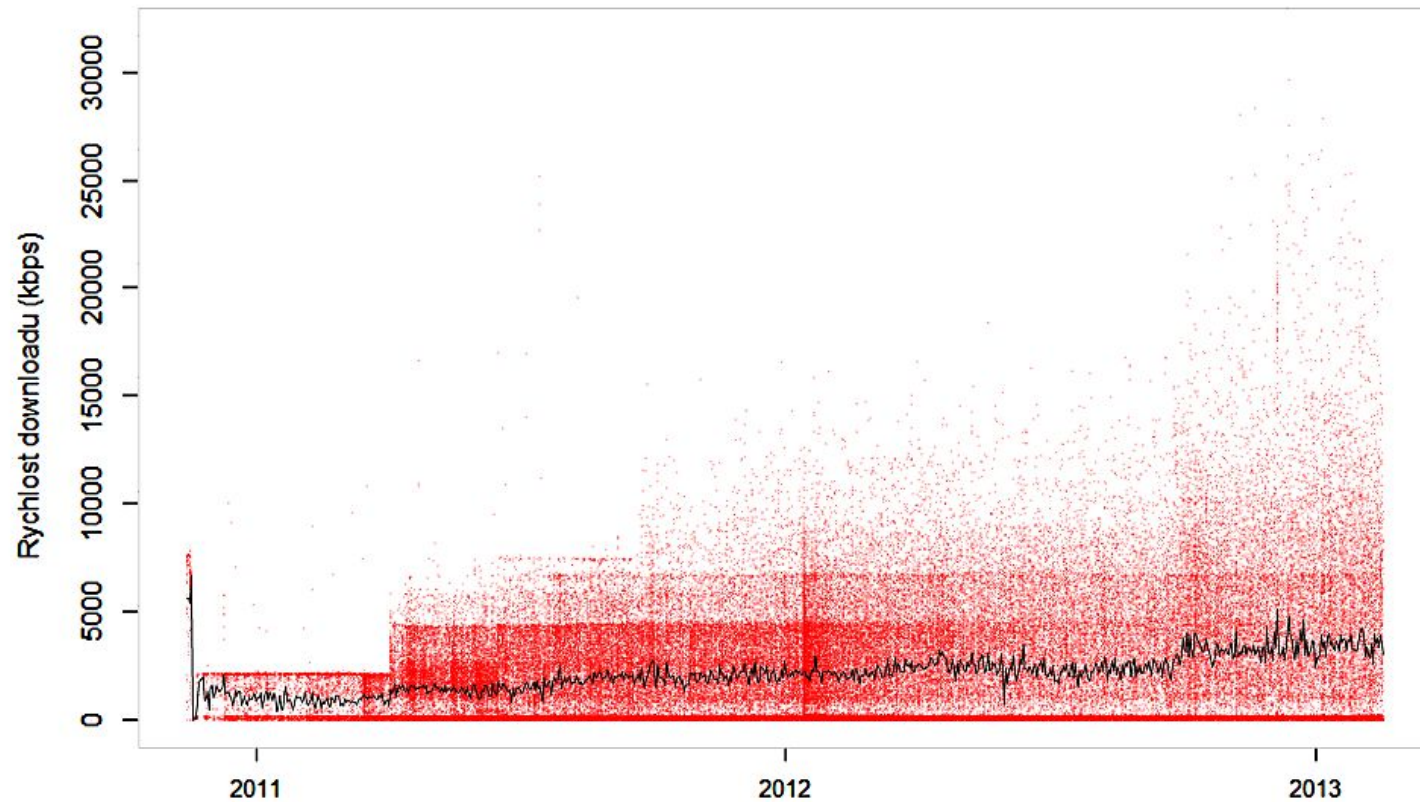
 ?

 SCRAP.

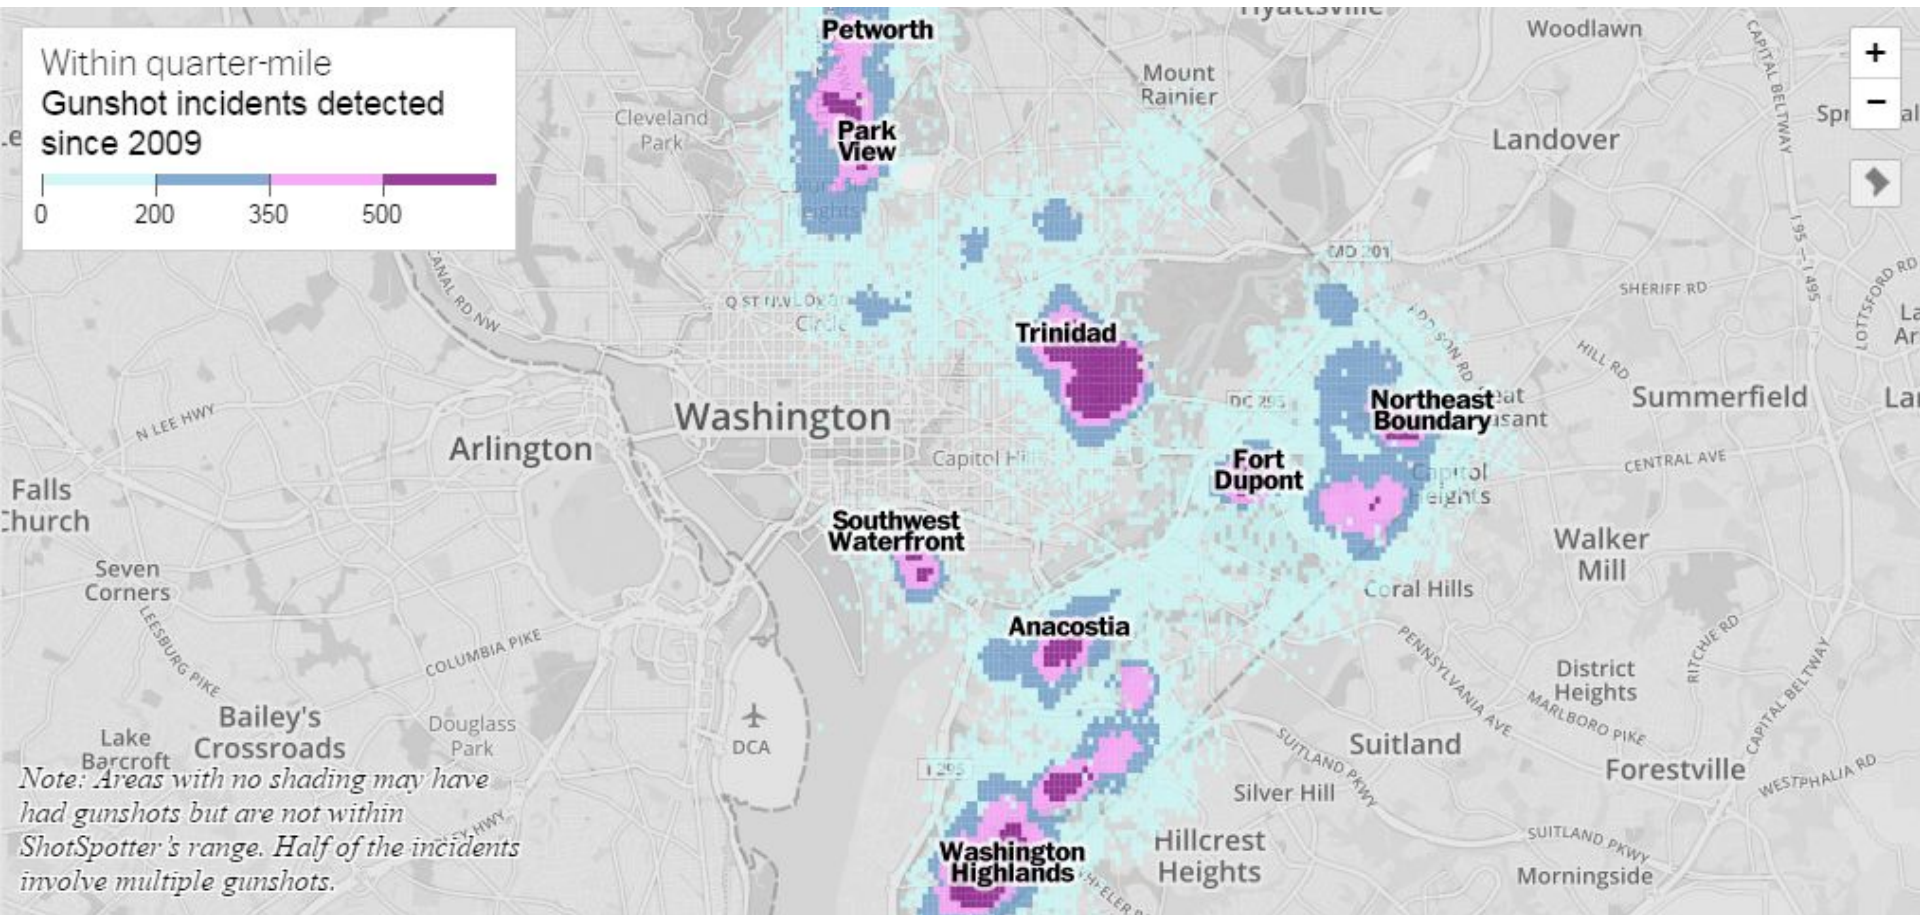
 VĚŘ.

RYCHLOST



## Rychlost připojení u Vodafone



Within quarter-mile  
Gunshot incidents detected  
since 2009



*Note: Areas with no shading may have had gunshots but are not within ShotSpotter's range. Half of the incidents involve multiple gunshots.*



**DÚ**

## čtyři témata, čtyři tabulky

postup:

1. stáhněte si ze studijních materiálů (*přednáška 7, data k DÚ*) a prozkoumejte jednu z tabulek
2. vymyslete a poznamenejte si otázky, které vás k tématu zajímají a v datech na ně je odpověď
3. na svoje otázky najděte a sepište odpovědi
4. objevte kontext: proč to tak je

to celé na 2-3 normostrany (1800 znaků)

do 24.11. (čtvrtek, zadávám to později, tak je později i odevzdání)

data jsou skutečná, v podstatě tak, jak jsem je dostal od zdroje, jen jsem je lépe pojmenoval a zformátoval

dělejte s nimi cokoliv, co vám pomůže odpovědět na otázky (pokud něco neumíte, vygúglejte si to)

pokud k interpretaci potřebujete další data, dohledejte si je  
jakékoliv problémy: [honza.bocek@gmail.com](mailto:honza.bocek@gmail.com)

## TÉMA 1: PŘESTUPKY V BRNĚ

- všechny přestupky, které eviduje městská policie v Brně od června 2013 do poloviny září 2014
- typ přestupku je v původním znění, pokud s ním chcete pracovat, zkuste [www.zakonyprolidi.cz](http://www.zakonyprolidi.cz)
- nechal jsem tam gps souřadnice, pokud byste je někdo chtěli a uměli dát na mapu; není to nutné



## TÉMA 2: STARTOVAČE

- úspěšné i neúspěšné ukočené projekty dvou největších českých kopií Kickstarteru od spuštění doted'
- zatím jsou neveřejné, nechte si je pro sebe
- v každé záložce jeden startovač, každý má data v jiné struktuře
- vše, včetně lokality, zadávají autoři projektů
- pokud je u Hithitu projekt ve více kategoriích, každá má svůj řádek; porad'te si s tím!

## TÉMA 3: ÚMRTNOST V EU

- úmrtnost podle diagnózy v evropských regionech
- standardizovaná (na 100 000 obyv.), průměr za roky 2011 až 2013
- regiony odpovídají evropským státům (NUTS1) a krajům (NUTS2)
- dělení podle pohlaví a podle věku

## TÉMA 4: TERORISMUS

- data z webu Global Terrorism Database
- původní, bez jakýchkoliv změn, od roku 1970 do 2014
- spíš pro drsňáky ( )

