



Projekt ADAM

Systematické zpracování provozních dat

Ladislav Lhotka • ladislav.lhotka@nic.cz • 12. listopadu 2020

Osnova

- cíle projektu, vize
- architektura systému
- sběr a zpracování dat o DNS provozu
- DNS crawler
- servisní databáze a REST API
- nové grafy a statistiky na webu
- další výsledky



Takový průměrný den ...

- 1,2 miliardy DNS dotazů na autoritativní servery
- 300 milionů dotazů na resolversy ODVR
- 5300 operací v registru domény
- 8000 testů pomocí Netmetru
- 2000 přihlášení pomocí mojeID



Cíle projektu, vize

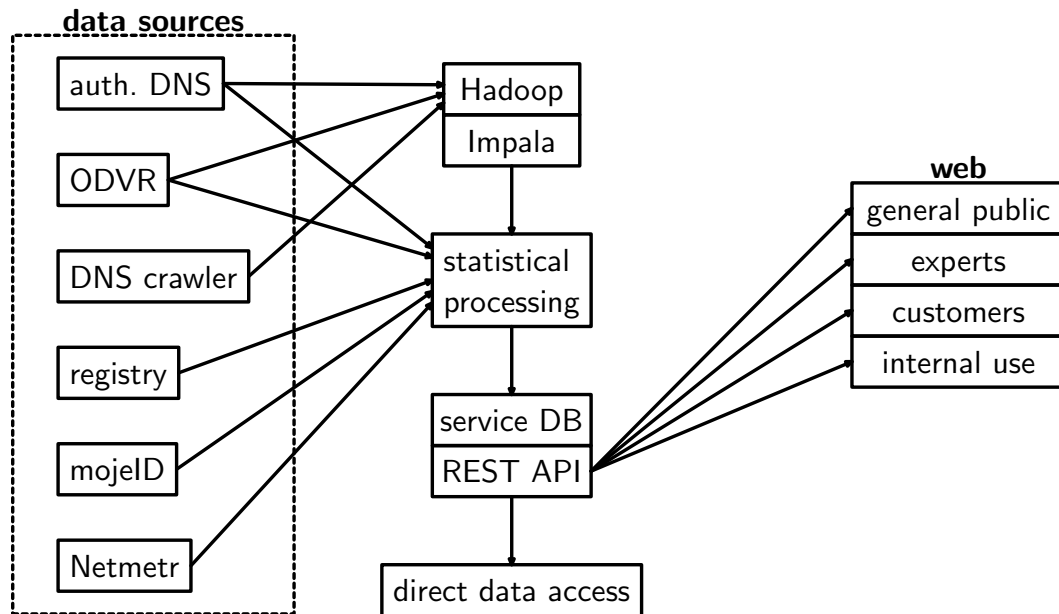
Cílem projektu ADAM (*Advanced DNS Analysis and Monitoring*) je vytvoření robustního a rozšiřitelného systému pro sběr, ukládání, zpracování, analýzu a vizualizaci dat z hlavních služeb provozovaných sdružením CZ.NIC.

Očekává se využití mj. v těchto oblastech:

- monitorování provozu DNS serverů a dalších služeb,
- sledování krátko- i dlouhodobých trendů,
- detekce a analýza anomálií a bezpečnostních incidentů,
- plánování rozvoje infrastruktury,
- grafy a statistiky pro interní použití, členy, zákazníky i odbornou veřejnost.



Architektura systému



Provoz na DNS serverech

Na DNS serverech, které spravuje CZ.NIC, je veškerý DNS provoz ukládán do souborů PCAP. Ty jsou pak pravidelně komprimovány a přenášeny do centrálního úložiště, kde jsou průběžně zpracovávány a údaje o všech DNS transakcích ukládány do Hadoopu.

Nevýhody:

- velké objemy dat (přenášené a uchovávané)
- výkyvy zátěže procesoru ovlivňují časové značky paketů
- část transakcí se nezachytí, zejména TCP



DNS sonda

<https://gitlab.nic.cz/adam/dns-probe>

Software pro monitorování DNS vyvinutý ve spolupráci s FIT VUT Brno. Umožňuje extrahovat DNS dotazy a odpovědi ze živého provozu nebo PCAP souborů (v UDP i TCP), párovat je a exportovat konsolidované záznamy o transakcích.

- záchyt paketů přes raw socket (AF_PACKET) nebo DPDK
- exportní formáty: Apache Parquet nebo a C-DNS [RFC 8616] - až o 70 % menší objem dat
- lepší párování dotazů a odpovědí: o 2-3 % více, u TCP o 50-100 %.



DNS crawler

<https://gitlab.nic.cz/adam/dns-crawler>

Nástroj pro procházení zadaného seznamu domén a získávání dostupných údajů z DNS, ale také z komunikace s webovými a mailovými servery.

Ve spolupráci s CSIRT.CZ procházíme pravidelně všechny domény 2. úrovně pod .cz (<https://www.csirt.cz/cs/dns-crawler>).

Kromě podkladů pro statistiky slouží i ke klasifikaci webových stránek, kontrole dat v DNS a detekci bezpečnostních problémů (webový framework *Nette*).



Servisní databáze

V databázi Apache Hadoop aktuálně udržujeme půl roku provozu, pracujeme na upgradu clusteru s cílem prodloužit uchovávanou historii na jeden rok.

Agregované hodnoty a statistiky ukládáme *servisní databázi* PostgreSQL bez omezení délky historie.

Problém: když se ukáže potřeba nového zpracování originálních dat.



REST API

Nástroj PostgREST vytváří REST API automaticky z tabulek servisní databáze.

Doporučená metoda pro rutinní strojové zpracování dat, integraci do webových stránek apod.

- root endpoint: <https://stats.adam.nic.cz>
- webové rozhraní OpenAPI/Swagger: <https://stats.adam.nic.cz/swagger>
(dokumentace, praktické vyzkoušení)



Statistické zpracování, vizualizace

Po předchozích zkušenostech se snažíme využívat „klasické“ nástroje se širokou základnou uživatelů a celý proces co nejvíce zpřehlednit, automatizovat a zdokumentovat.

Každý výstup (graf, tabulka, statistika) musí být:

1. dostupný ve dvou jazykových verzích (česky a anglicky)
2. kompletně reprodukovatelný
3. snadno modifikovatelný






Zvolené nástroje

- statistický systém *R*
- osvědčené rozšiřující balíky: *tidyverse*, *ggplot2*, *Plotly*, *kableExtra*
- *R Markdown* – literate programming pro *R*
- webové stránky: *flexdashboard*
- internacionalizace *R* kódu: *gettext*
- automatizace: GitLab CI



Nové statistiky na webu



- <https://stats.adam.nic.cz/dashboard/cs>
- Projekt: <https://gitlab.nic.cz/adam/adam-dashboard>
- Chyby, přání: <https://gitlab.nic.cz/adam/adam-dashboard/-/issues>



Zatím jde o provoz v testovacím režimu, chystáme další rozšiřování a úpravy.



Autentizovaný přístup


Část grafů a statistik je určena jen pro specifické uživatele (např. držitele domény nebo registrátora) či jejich skupiny.

Dva způsoby přihlášení uživatele:

1. přes mojeID
2. pomocí speciálního jména a hesla

Autorizace funguje zároveň pro webové stránky i pro REST API. Uživatel si může také vytvořit tokeny pro strojový přístup.

ADAM API access

Login with mojeID 

Remember me

Username:

Password:

Další výsledky

- Výroční domain report: <https://stats.nic.cz/reports/2019>
- ADAM reports: <https://adam.pages.nic.cz/reports/adam>
 1. COVID-19 v doméně .cz
 2. Základní klasifikace domén druhé úrovně pod .cz




Odkazy

1. Apache Hadoop Ecosystem: <https://www.cloudera.com/products/open-source/apache-hadoop.html>
2. flexdashboard: <https://rmarkdown.rstudio.com/flexdashboard>
3. gettext: <https://www.gnu.org/software/gettext>
4. kableExtra: <https://github.com/haozhu233/kableExtra>
5. OpenAPI/Swagger: <https://swagger.io>



6. PostgREST: <https://postgrest.org>
7. R: <https://www.r-project.org>
8. tidyverse, ggplot2: <https://www.tidyverse.org>
9. Plotly R: <https://plotly.com/r/>





Děkuji za pozornost.

Ladislav Lhotka • ladislav.lhotka@nic.cz • <https://adam.nic.cz>

