



PCAP, flow, metadata: Musím si vybrat?

OD DAT KE ZNALOSTEM II.

Analýza síťového toku

28.11.2019

Martin Půlpán
CEO net.pointers s.r.o.

martin.pulpan@pointers.cz

Trust ♦ Expertise ♦ Sensitive approach

POMÁHÁME VÁM BEZPEČNĚ FUNGOVAT



Detekce a reakce na bezpečnostní incidenty v síti i koncových bodech

- Advanced Persistent Threads protection (APT)
- Data/Network visibility and monitoring
- Automated Detection and Response (ADR)

Obrana proti DDoS útokům

- SP/ISP and top Enterprise
- Security Managed Service (MSSP)

Služby s přidanou hodnotou a technická podpora

- On-site cyber-attack simulation, STRESS/PEN testing
- Cloud Based Automated Detection and Metadata Correlation
- Security systems Evaluation and Integration



Security Assessment
Vulnerability Testing



Detection
Prevention



Technology Deployment
Support



Incident Response
Prediction



Training

AGENDA


- Současné komunikační prostředí
- Možnosti identifikace
- Různé pohledy, různé zdroje
- Příklad na konec



KOMUNIKAČNÍ PROSTŘEDÍ

INTERNETOVÝ PROVOZ

- Za posledních 10 let se internetový provoz zdesetinásobil
- Kapacita koncových přípojek roste podobným tempem
- Růst kapacity cloudových uložíšť je ještě intenzivnější



Trendy

- Rychlé připojení koncových stanic
- Rychlé a dostupné cloud služby nabízející virtuální systémy a aplikace
- Rostoucí množství "chytrých zařízení"

IDENTIFIKACE, MONITORING CHOVÁNÍ

Každá identifikace začíná popisem **komunikace**, která je definována **provozem v lokální/WAN síti** a nějakým serverem, koncovou stanicí či místem v internetu...

Efektivní monitoring vychází z rychlé a přesné identifikace sledovaného provozu.

Provozu i komunikačních kanálů stále přibývá

JAKÉ MÁME MOŽNOSTI

➤ Data Flow

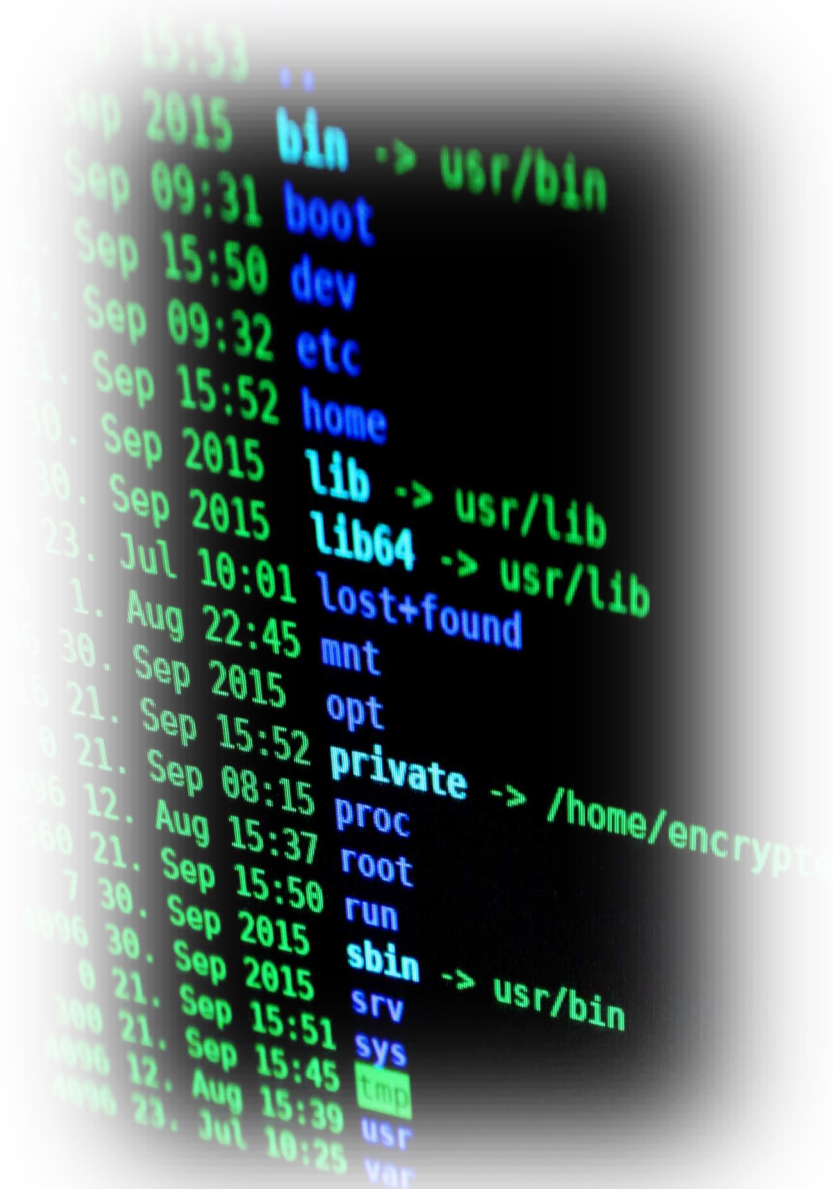
Data Flow - vysoká rychlost zpracování, nižší přesnost identifikace a potvrzení problému

➤ PCAP

PCAP - nízká efektivita zpracování způsobena vysokými nároky na množství zpracovaných dat

➤ Metadata

Metadata - vyšší efektivita zpracovaných dat, akceptovatelná přesnost a flexibilita v zacílení zájmu



```
Sep 15:53 ..
Sep 2015 bin -> usr/bin
Sep 09:31 boot
Sep 15:50 dev
Sep 09:32 etc
Sep 15:52 home
Sep 2015 lib -> usr/lib
Sep 2015 lib64 -> usr/lib
Jul 10:01 lost+found
Aug 22:45 mnt
Sep 2015 opt
Sep 15:52 private -> /home/encrypted
Aug 15:37 proc
Sep 15:50 root
Sep 2015 run
Sep 2015/sbin -> usr/bin
Sep 15:51 srv
Sep 15:45 sys
Aug 15:39 tmp
Jul 10:25 var
```


DATA FLOW

Flow-based standardy:

NetFlow, jFlow, sFlow, IPFIX a další

Zdroje data flow:

- Síťové prvky (routery, switche)
- Specializované sondy, které vzorkují provoz, poskytují statistiky, behaviorální analýzy
- Další bezpečnostní nástroje, které pracují s NetFlow a jeho klony

Výhody:

- Velmi efektivní přehled o tom, co se v síti děje:
 - kdo s kým komunikuje
 - na jakých portech, druh komunikace
 - jak dlouho a jak často
 - kolik dat bylo přeneseno
- Nízké nároky na ukládání historických dat
- Rychlé hledání
- Široká vizibilita přes celou síť

Nevýhody:

- Poskytuje pouze trendová data a změny oproti historii
- Často se používá pouze vzorkování dat, ne plná analýza
- Kvalita NetFlow dat se velmi liší a je závislá na zdroji dat
- Nedostatečné pro Zero Day útoky, APT hrozby a moderní malwarové útoky (ransomware)
- Nedetekuje latentní šíření a skrytou komunikaci
- Nevidí do obsahu komunikace

PCAP

Packet capturing:

Libpcap, pcap-ng – binární formáty s časovým označením a blokovým dělením

Zdroje PCAP:

- Aplikační programy (Wireshark, snort, TCPdump)
- Specializované sondy, které zaznamenávají síťový provoz a poskytují vyhodnocovací nástroje
- Open-source knihovny

Výhody:

- Zaznamenává vše, co projde sítí pro pozdější kontrolu a forenzní vyšetřování
- Plný nebo filtrovaný záznam (úspora místa)
- Účinné proti APT a Zero Day útokům
- Dostatečné pro forenzní vyšetřování – lze přesně vysledovat vektor útoku, zmapovat chování uživatelů, detailně analyzovat vše, co prošlo sítí

Nevýhody:

- Extrémní nároky na ukládání dat (100MB ETH – 1TB – 22 hodin, 10GB ETH – 14 minut)
- Složité je něco najít – vyžaduje to bigdata přístup – hledání jehly v kupce sena
- Nelze použít na realtime monitoring
- Problém je šifrovaný provoz
- Ukládání delšího časového úseku je velmi finančně náročné

METADATA

Metadata

Obsahují informace o přenášených datech, popisují co bylo přeneseno, jakým způsobem, jaký byl charakter informací, co bylo obsahem, odkud, kam a kdy probíhala komunikace a další atributy získané z přenášených relací.

Zdroje METADA:

- › Specializované sondy, které vytvářejí vlastní metadata (hw nebo virtuální)
- › Další síťové bezpečnostní systémy
- › End-point agenti
- › Log management systémy
- › Open-source nástroje
- › a další zdroje z komunikačního prostředí

Výhody:

- › Výrazně menší nároky na ukládání historie komunikace
- › Detekce v reálném čase – lze použít pro aktivní mitigaci a ADR
- › Rychlé hledání a analýzy
- › Účinné proti APT a Zero Day útokům
- › Dostatečné pro rychlé forenzní vyšetřování – lze kombinovat se selektivním PCAPem
- › Lze ukládat i delší historii (i několik let)


Nevýhody:

- › Neexistuje standard – kvalita metadat z různých zdrojů se může výrazně lišit
- › Omezená práce s obsahem komunikace
- › Zašifrovaná data bez dekryptoru nelze tagovat
- › Pro složitější a bohatší tagování je třeba využít externí inteligenci a sandboxing, což může zvýšit náklady

VYTVOŘME SI METADATA ...

- A) můžeme je vytvářet z provozu na sítích, ke kterým máme fyzický nebo rádiový přístup
- B) máme k dispozici API rozhraní k datům, která jsou zpracovávána jinými systémy
- C) Prostřednictvím API rozhraní cloudových služeb
- D) Na základě informací z monitorovacích systémů (face recognition kamery a jiné systémy)

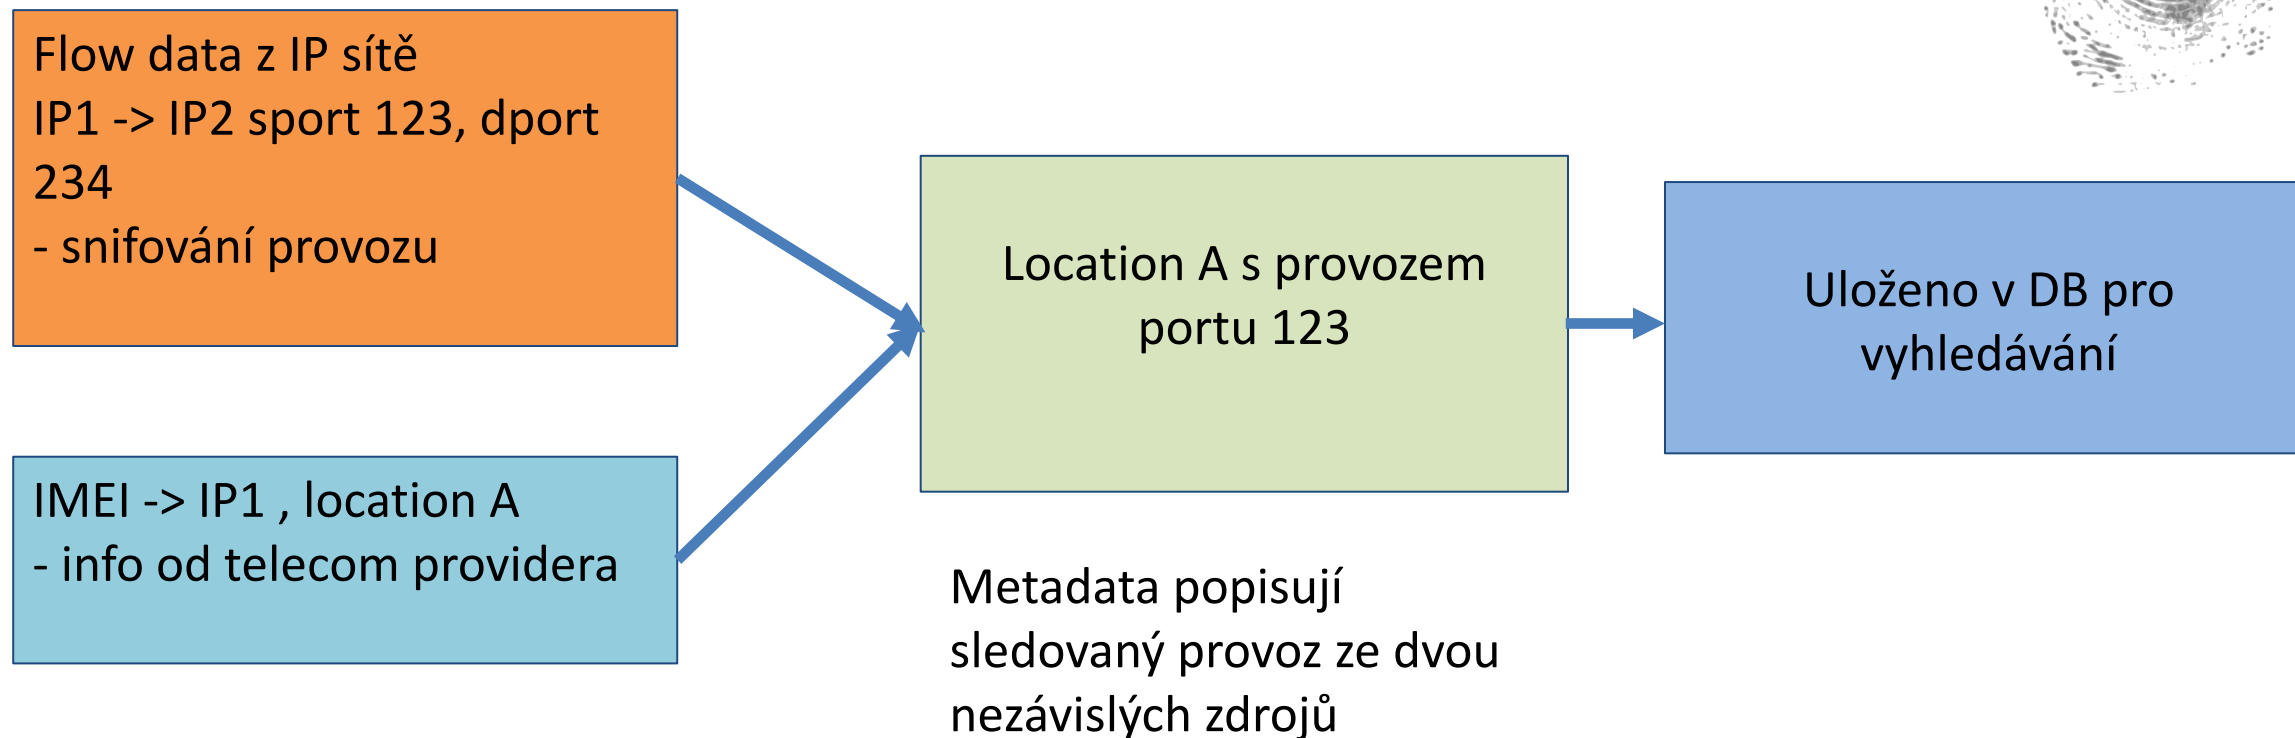
AGREGOVANÁ METADATA



Agregační platformy

- Propojují jednotlivá metadata
- Selektivní analýza
- Vytvářejí vlastní agregovaná metadata
- Používají AI pro detekci určitých paternů
- Modelace vzorců chování
- Vytváření archivů pro další možné zpracování


RŮZNÉ POHLEDY, RŮZNÉ ZDROJE



DATA SCIENCE

Co je to?

- Moderní přístup pro vyhodnocování metadat všech typů
- Vyžaduje kvalitní metadata – vysokou vizibilitu
- Nutností je dostatečně velký časový vzorek
- Vytváří základní model chování a následně hledá anomálie
- Bigdata přístup
- Model lze postupně zpřesňovat
- Zvýšení přesnosti detekce (nad 80%)

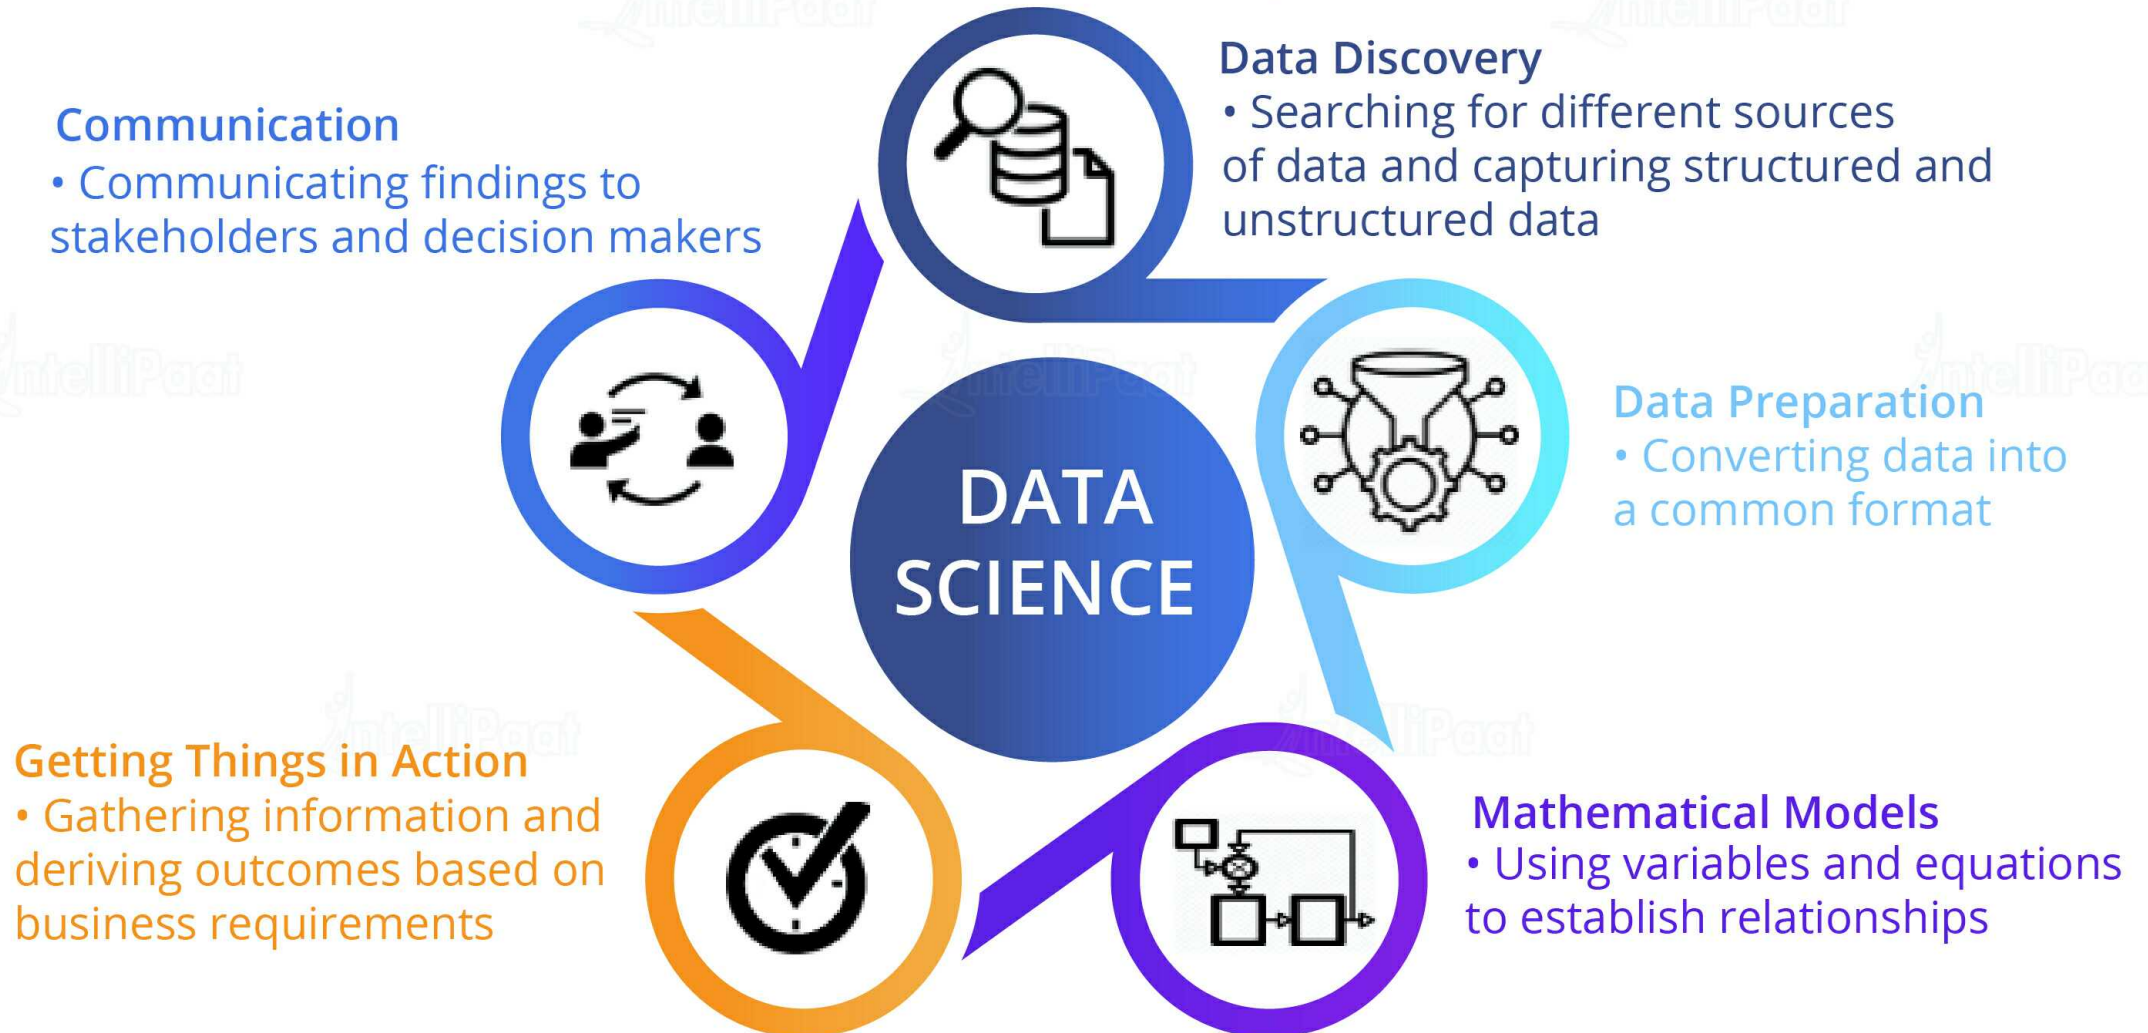


Proč data science?

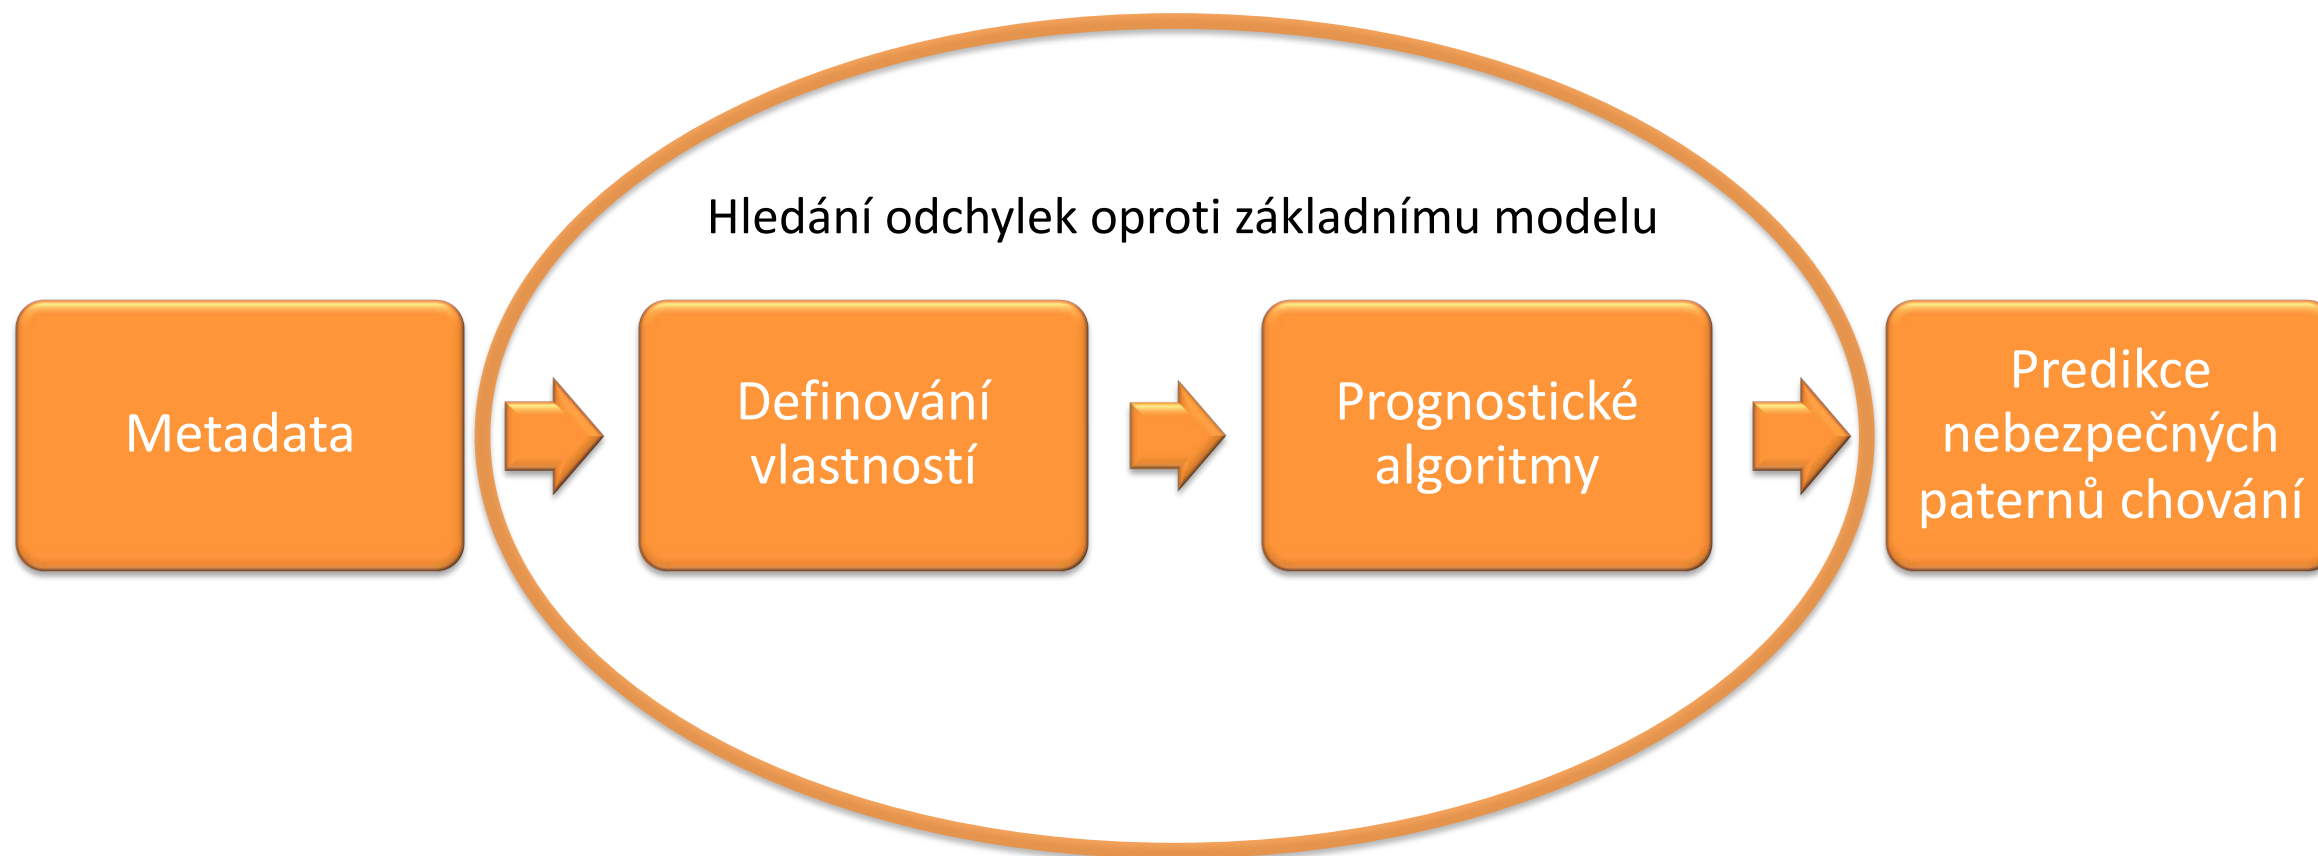
- Příliš mnoho bezpečnostních alertů a limitované lidské zdroje
- Optimalizace nasazení senzorů
- Zpřesnění detekce
- Predikce možných rizik, ještě dříve než nastanou
- Vytvořený model lze pak snadno modifikovat

DATA SCIENCE

Data Science Life Cycle



DATA SCIENCE



Nastavení BASELINE modelu

JE TADY NĚJAKÝ PROBLÉM ?

Máme přístup k fyzické síti

- 85% veškerého provozu je **šifrovaný**

Co s tím:

- v případě, že nás zajímá interní obousměrný provoz

->> **nemám problém**

- v případě, že chci sledovat obousměrný internetový provoz z lokální sítě

->> **můžu mít problém**

Použiji techniku hackerů (man in the middle), kde za pomoci specializovaných zařízení se vůči klientovi tvářím jako legitimní server (*problém je pinning certifikátů*)

Nemáme přístup k síti

- rozhraní k monitorovaným službám musí zpřístupnit provozovatel služby, což může být komplikované získat (zejména u zahraničních subjektů mimo EU).



ŠIFROVANÝ PROVOZ

Jedním z úkolů kybernetické bezpečnosti je zabezpečit integritu spojení - nemožnost vstoupit do probíhajícího provozu

Paradox – který nám komplikuje situaci v případě monitoringu

Má vůbec smysl monitorovat šifrovaný provoz ?

Rozhodně MÁ

Samotné navazování šifrovaného spojení mi prozradí množství užitečných informací:

- ❖ parametry šifrování
- ❖ parametry použitých certifikátů
- ❖ informace o komunikujících klientech
- ❖ informace vycházející ze samotných flow dat (IP, porty, poloha klienta a podobně)
- ❖ informace z dalších jiných zdrojů



NEŠIFROVANÝ PROVOZ

- ❖ **Umíme rozkódovat encapsulovaný provoz** – na aplikační úrovni je provoz analyzován pomocí inspekce protokolů a formátů dat, které jsou známé a nezašifrované
- ❖ **Provoz si můžeme přiblížit** - zajímá nás poloha vzniku provozu, případně linková úroveň provozu, pokud máme technické a legislativní možnosti je mít
- ❖ **Můžeme se selektivně zaměřit na určitý provoz**, na určité komunikační porty, protokoly, obsah, formát či jiné parametry
- ❖ **K selektivně definovanému provozu si mohu připojit full packet capture nástroj**



CO TO ZNAMENÁ V REALITĚ ?

Zadání:

Zajímá mě provoz a jeho charakteristika-profil (četnost, hodina, den v týdnu) pro telefonní číslo +420 xxx xxx xxx na email franta.vomacka@seznam.cz

Vzhledem k tomu, že se jedná o dlouhodobé sledování, nemohu zpracovat veškerý provoz v dané lokalitě

Řešení: Vytvoříme si METADATA

ŘEŠENÍ

Situace:

- snažíme se popsat dlouhodobě chování vybraného uživatele a nemůžeme shromažďovat u daného poskytovatele veškerý provoz

Řešení:

- musíme vybrat a vydefinovat **určitou charakteristiku provozu** a budeme zkoumat a popisovat **jenom tuto část provozu** – vytvořili jsme si tak svoje **metadata**
- zajímají nás veškerá telefonní čísla, které posílají email do lokality BTS123 atd., filtry postupně zpřesňujeme
- analýzou zadání jsme zúžili množství dat, které potřebujeme ukládat, abychom následně z těchto dat vybrali jenom ta, která nás skutečně zajímají

JAK POSTUPOVAT

❖ Definovat si záměr:

- co se snažíme naší aktivitou docílit
- může to být samotné hledání určitých informací
- může to být doplňková informace, která nám obohatí jiný typ hledání

❖ Rozmyslet si konkrétní parametry hledání, výpočty nad hledanými daty

❖ Délka trvání

❖ Zvážit možnosti nástroje, který na hledání použijeme

VYHODNOCENÍ PŘÍKLADU

Na základě porovnání množství provozu procházejícím zmíněnou lokalitou jsme zjistili:

- emailová služba je méně používána než tomu bylo v minulosti, což znamená:

- Jenom 5% provozu byla e-mailová komunikace
- 95% byl jiný provoz, který nás nezajímá = úspora prostoru pro další hledání

Závěr:

Velice jednoduchý příklad **má za cíl demonstrovat, co metadata jsou** a jak je k nim potřeba přistupovat



DOPORUČENÍ

Co je vaším cílem?

- Je potřeba si správně definovat cíle monitoringu, kybernetické obrany ...
- Zvolit správnou strategii, která je rychlá, efektivní a technologicky nejméně náročná, založená na metadatech v kombinaci s data science přístupem.
- Použít vhodné technologické nástroje, které generují hodnotná metadata v kombinaci se selektivním PCAPem.

OTÁZKY?



Děkuji za pozornost!

martin.pulpan@pointers.cz