

Detekce anomálií v počítačové síti

Jan Kohout

Motivace

- Využití v bezpečnosti: Ne vše v síti je legitimní provoz
- Předpokládáme, že alespoň (výrazná) většina provozu je legitimní
- Nežádoucí provoz se nečím od legitimního liší → projeví se jako anomálie
- Použití technik strojového učení

Proč takhle?

"Klasické" metody často spoléhají na databázi známých útoku

- Problém s odhalením neznámých útoků, časté aktualizace

Lze použít i bez inspekce obashu

- Nevadí šifrování obsahu, lze použít i ve velké síti

Problém bývá s přesností detekce - obvykle vyšší míra falešných alarmů

Detekce anomálií

- Obecně: identifikovat data, která se liší od většiny ostatních
- Postup:
 - Zvolit reprezentaci dat (jako n -dimenzionální vektory, časovou řadu,...)
 - Záleží na konkrétní aplikaci
 - Každému vzorku přiřadit hodnotu anomálie
 - Reportovat data s hodnotou anomálie větší než zvolený *práh*

Jak určit hodnotu anomálie? Jak zvolit *práh*?

Pár příkladů:

- Metody založené na vzdálenosti od nejbližších sousedů
 - *Local Outlier Factor (LOF)*
- *One-class SVM*
- Využití odhadu pravděpodobnostní distribuce známých dat
 - Určení anomálie pomocí věrohodnosti vzorku (*log-likelihood*)
- Metody využívající PCA (*Principal Component Analysis*)
- Detekce významné odchylky od predikce časové řady

Náhodné projekce

Používá odhad pravděpodobnosti, n -rozměrnou distribuci nahrazuje k jednorozměrnými distribucemi

- Zvolíme k náhodných vektorů $w_1, \dots, w_k \in R^n$
- Pro $x \in R^n$ určíme hodnotu anomálie:

$$Anom(x) = -\frac{1}{k} \sum_{i=1}^k \log(p_i(w_i^T \cdot x))$$

p_i je odhad pravděpodobnosti výskytu hodnoty $w_i^T \cdot x$, pomocí histogramu dosud pozorovaných hodnot (lze aktualizovat on-line)

[T. Pevný: Anomaly Detection by Bagging]

Principal Component Analysis

Transformace souřadnic, nové souřadnice určeny vlastními vektory kovarianční maticy dat Σ

Matici dat $X \in R^{m \times n}$ (se stř. hodnotou 0):

$$\Sigma = \frac{1}{m-1} X^T X$$

- Významnost komponenty určena rozptylem dat v jejím směru, komponenty jsou seřazeny podle významnosti
- Předpoklad: Pro reprezentaci normálních dat stačí prvních $k < n$ komponent (*normal data sub-space*)

Principal Component Analysis

- Komp. $1, \dots, k$ - podprostor normálních dat
- Komp. $k + 1, \dots, n$ - podprostor anomálních dat

Projekci vzorku $x \in R^n$ lze rozložit na projekci na prostor normálních dat (x') a na prostor anomálních dat (x'')
Hodnotu anomálie můžeme určit např.::

$$Anom(x) = ||x''||^2$$

[Lakhina et al.: Diagnosing Network-Wide Traffic Anomalies]

Principal Component Analysis - příklad

Stav sítě sledujeme v časových krocích, pro každou IP adresu $i \in I$ v čase t držíme $H_{dPr}^\tau(i), H_{sPr}^\tau(i), H_{dIP}^\tau(i), \tau \in \{t-5, \dots, t-1\}$ - entropie zdrojových portů, cílových portů a cílových IP adres → 15-dim. vektor pro každou adresu $i \in I$

Matice dat $X \in R^{|I| \times 15}$ v čase t :

$$X = (H_{dPr}^{t-5}(i), H_{sPr}^{t-5}(i), H_{dIP}^{t-5}(i), \dots, H_{dPr}^{t-1}(i), H_{sPr}^{t-1}(i), H_{dIP}^{t-1}(i)), i \in I$$

Dokáže např. odhalit vertikální/horizontální skenování sítě

[Grill, Pevný: Detecting anomalous network hosts by means of PCA]

Jak stanovit práh?

Různě:

- Někdy je možné určit analyticky podle požadavků na přesnost/spolehlivost detekce
- Přimíchat do dat simulované útoky a práh odhadnout podle jejich hodnot anomálie
- Vždy reportovat $x\%$ dat s nejvyšší hodnotou anomálie