

**Ács Gergely**

BME-HIT

Budapest, 2024.11.28

# **Robusztus Malware Detekció és Diffúziós Modellek Adatvédelme (MILAB)**

**1 Projekt célja**



**2 Igényelt erőforrások**

**3 Környezet kialakítása**

**4 Eredmények**

**5 Tapasztalatok, tervek**

1. Robusztus Malware Detekció
  - A. IoT malware-ek detekciója gépi modellekkel
  - B. Különböző ML alapú megoldások összehasonlítása
  - C. Ezen modellek robusztussága evasion és poisoning támadások ellen
2. Diffúziós modellek adatvédelme
  - A. Cardiotocography (CTG) adatok generálása diffúziós modellekkel
  - B. Ezen modellek adatvédelme



## 1. Első két évben (2022.04-2024.05):

- 2db g2.large
  - 8 GB RAM
  - 4 vCPU
  - 16 GB VRAM
  - 1 TB SSD

## 2. Utolsó fél évben (2024.05-2024.11):

- 1 db g2.xlarge
  - 32 GB VRAM
  - 8 vCPU
  - 1 TB SSD
- Egy darab gépet egyszerűbb volt menedzselni, és két VM esetén az egyre jutó erőforrás túl kevés volt
- GPU használatot elsősorban a diffúziós modellek igényeltek



- Könnyű, de néhány dologra érdemes figyelni
1. /home → 1 TB SSD
    - Miért?
      - Könnyű az adatok migrációja VM-ek között (csak a user és group id-ra kell figyelni)
      - Python virtuális környezet sok helyet igényelhet felhasználónként
        - torch elég nagy, root partíció hamar betelik
        - TMPDIR=~/ beállítása a csomagok (torch) telepítésénél
  2. Nem szabad kernelt frissíteni! (vagy rendszert)
    - A GPU-hoz speciális driver kell amit felülírhatnak a telepített csomagok
    - `AZ apt install /usr/local/share/elkhcloud/nvidia-linux-grid-525_525.125.06_amd64.deb` gyakran megoldja (nálunk nem)



3. Érdeemes egy darab VM-et használni (egyszerűbb)
  - Egy darab publikus IP-t kaptunk, a második gép csak az elsőről érhető el
  - VPN-nel is próbálkoztunk, de egy gép mindig kihasználatlan maradt
- Használat: burst-ös (az utóbbi időben inkább napi használat)
  - Első egy évben ritkábban, miután egy gép lett, utána intenzívebb
    - Két VM egyenként nem volt elég a feladatra
- Ha konkrét feladaton dolgozunk, akkor intenzívebb használat
  - A VM-en futtatunk és fejlesztünk is (Visual Code Remote SSH)
  - Futtatás: ssh + tmux
  - A GPU kihasználtságunk ilyenkor 50-70% körüli, huzamosabb ideig, attól függ hányan használják
    - 2-3 user használja összesen
    - egy user: 25%
- A publikus IP nagyon kényelmessé teszi az elérést

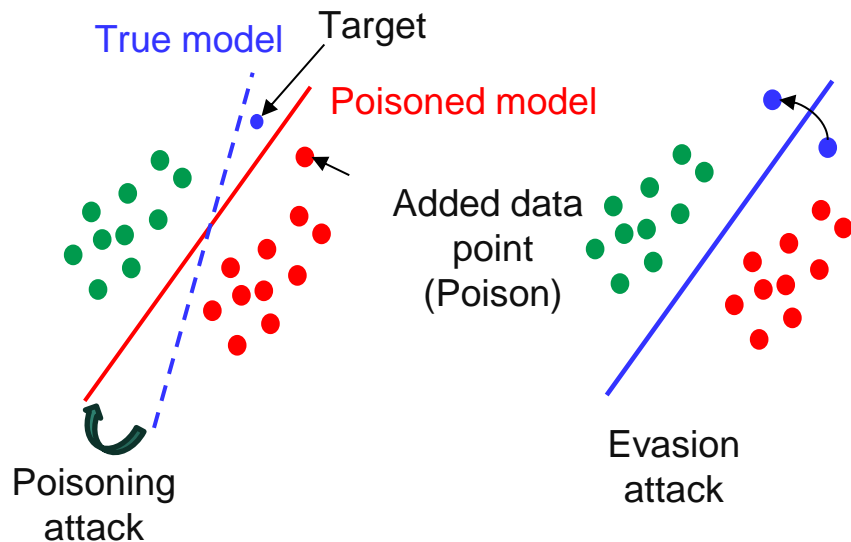


- Malware elemzés
  - Minták: A VM-en nem futtatható ARM és MIPS binárisok
  - Néhány ezer minta, összesen 2-300 MB
  - Feature vektorok tárolása numpy tömbökben
- Diffúziós modellek
  - Publikus CTG adatok
  - Kb. 500 beteg, előfeldolgozás után max 100 000 tanítóminta pytables-ben tárolva
- Minden adat az SSD-n tárolódik a /home könyvtárakban
- Diffúziós modellek: generált adat tárolása csv illetve képek formájában

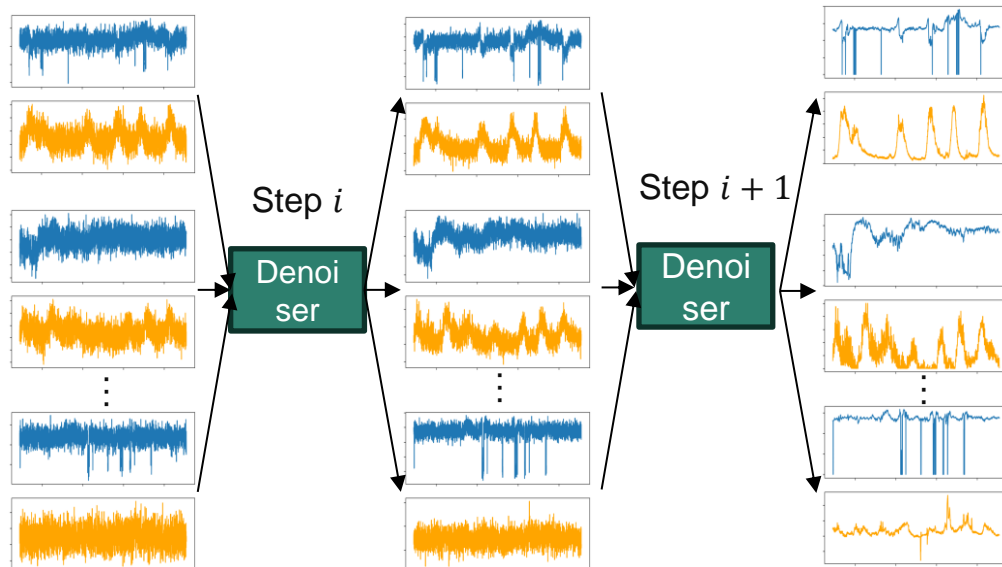




- Különböző ML alapú IoT malware detektorok összehasonlítása
  - Bináris → TLSH → Gépi modell (Random forest, Logistic regression, stb.)
  - >99.9%-os detekciós pontosság
  - Egyszerűbb modellek pontosabbak és kisebb költségűek (IoT-n fontos!)
- ML alapú malware detektorok evasion támadása
  - Különböző evasion technikák tesztelése
    - Benign programok hozzáfűzése
    - Gradiens alapú optimalizáció (módosítások számának minimalizásával)
  - Védekezés: Robusztus tanítás
- ML alapú malware detektorok evasion támadása
  - Gradiens alapú poisoning (Witches' Brew)
  - Folyamatban...

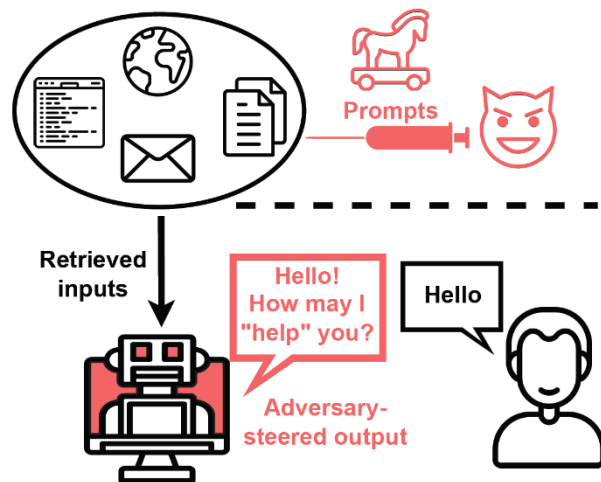


- Diffúziós modellek
  - Latent Diffusion model for CTG generation
    - Diffúziós modellek + VQ-VAE
    - Undersampling → Diffúzió → Super-resolution
- Diffúziós modellek adatvédelme
  - Sikeres membership támadás tervezése és kiértékelése
  - Differentially Private SGD for Diffusion



- N. Neubrandt, L. Buttyan, R. Nagy, Comparative analysis of similarity-based IoT malware detectors, under submission
- J. Sandor and R. Nagy and L. Buttyán, Increasing the Robustness of a Machine Learning-based IoT Malware Detection Method with Adversarial Training, WiseML'23
- E. Glocker, Privacy Analysis of Diffusion-based Cardiotocography Data Generation, TDK, 2024

- A kijelölt feladatokra elég a kapacitás, nem igényelnek komplex modelleket
  - Idősorok diffúziós generálása
  - Malware analízis
- Ezeket a feladatokat folytatjuk 2025 végéig
- Jövőbeni (mostani) projekt: LLM-ek biztonsága
  - Jóval több GPU memória kellene



- Elégedettek vagyunk
  - Könnyen elérhető, gyors, nem volt fennakadás
- Felhasználói támogatás
  - Gyors, segítőkészek
  - Dokumentációk kellően részletesek
- Más rendszerekkel összehasonlítva
  - Nagyobb rendelkezésre állás mint más rendszereknél amit használunk
    - Soha nem volt fennakadás vagy kiesés
  - A számítási kapacitása csak kisebb feladatokra elég
- Min lehetne változtatni?
  - Rendszerfrissítés veszélyeire felhívni a figyelmet

# HUN-REN

Magyar Kutatási Hálózat

<https://hun-ren.hu>