




Säker delning av AI-modeller

Sinna Lindquist

2025 05 08

En presentation om

- Tvärvetenskap
- Teknik
- Juridik
- Hur förklarar man AI?

Att dela en AI-modell



Risker

- Antagonister som vill skada
- Modellen kan "läcka" data
 - Avslöja arbetsmetoder
 - Läckta personuppgifter

Tekniken först

Test i flera steg

- Träna språkmodell
- Attackera (*Membership Inference Attack, MIA*)
- Skydda (*Differential Privacy, DP*)
- Balansgång mellan skydd och prestanda


Typfall – Modelldelning från Polisen till SÄPO

- Modellen är tränad på öppen data
- Träningsdatamängden innehåller personuppgifter
- Modellen som tränas är en NER-modell (*Named Entity Recognition*)
- Modellens användningsområde är inte beskrivet
- Ett fåtal användare, inte för alla

In December 1903 the Royal Swedish Academy of Sciences awarded Marie and Pierre Curie , along with Henri Becquerel , the Nobel Prize in Physics .

DATE ORG PERSON PERSON PERSON WORK_OF_ART

Lagarnas inbördes rangordning



AI-förordningen

- Påminner om att alla berörda parter uppmanas att på lämpligt sätt beakta de 7 etiska principerna för utveckling av frivillig bästa praxis och standarder

- AI-system som klassas som hög risk ska särskilt beakta effekterna för den personliga integriteten, samt beakta barns särskilda rättighetsskydd

- Biometriska personuppgifter lyfts fram som särskilt problematiska, kan bl.a. leda till bias, särskild förbudsreglering i brottsbekämpande verksamhet, art. 5 g och h

- Rätten till integritet och skydd av personuppgifter måste garanteras under AI-systemets hela livscykel

- Förordningen påverkar inte förordning (EU) 2016/680 (genomförd gm brottsdatalagen), art. 2(7)

- Teknisk robusthet och säkerhet
- Integritet och dataförvaltning

Exempel på central lagstiftning

Nationell rätt

Polislagen

Lagen om säkerhetspolisens
behandling av personuppgifter

Polisdatalagen

Brottsdatalagen (EU-direktiv/gäller
ej nationell säkerhet)

EU-rätt (gäller ej nationell säkerhet)

GDPR (undantag i kap 1, art. 8, p. g)


Dataskyddsdirektivet

AI-förordningen (delvis, fr.o.m. feb-25)


EU-domstolens rättspraxis, bl.a. *Tele2*

*Sverige AB & Watson och Digital
Rights Ireland*

Modelldelningsprocess




Hur fungerar en attack?





Vad är en läcka?

$$\text{TPR} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

$$\text{FPR} = \frac{\text{False Positives}}{\text{False Positives} + \text{True Negatives}}$$



Resultat och Slutsatser



Differential Privacy


- Definition

$$P[M(D_1) \in S] \leq \exp(\epsilon) \cdot P[M(D_2) \in S] + \delta$$

Sannolikheten att
garantin inte håller

Mått på garanterad
säkerhet

- Garanti



Resultat av workshopen

”Kan innehålla spår av data”

- Användningen av modellen spelar roll
- Riskanalys – hur ska den göras?
- Förklaringsmodell
 - Vad måste förklaras?’
 - Vad måste fördjupas?

Nästa steg

- Förtydliga förklaringsmodellen
- Problematisera *Säker* ur ett juridiskt perspektiv
- Träna, attackera och skydda en NER-modell
- Verkligt fall: Transkriberingsmodell

Vi som jobbar med det här

AI/ML: linus.kanestad, axel.borg, björn.pelzer

Juridik: anna.wetter.ryde

MDI: sinna.lindquist

@foi.se

TACK!

Andra initiativ

- LeakPro (AI Sweden)
 - Öppet verktyg
 - Test av informationsläckage
 - Samla attackmetoder
- Next Generation Machine Learning Model Exchange
 - NATO IST RTG

