



Di
GES



DECISIONS **LAB**




IL FENOMENO DEL
“DATA POISONING” E
L’IMPORTANZA
DELL’APPRENDIMENTO
DELLA MACCHINA IN
AMBITO IA

Alan Turing

Pioniere dell'intelligenza artificiale che si basava sulla nozione di «macchina universale»

Test di Turing

Metodo per valutare l'intelligenza di una macchina in base alla sua capacità di sostenere una conversazione umana senza essere rilevata come non umana





METODI DEL MACHINE LEARNING

- Apprendimento Supervisionato
- Apprendimento non Supervisionato
- Apprendimento Semi – Supervisionato
- Apprendimento per Rinforzo

ALGORITMI DI MACHINE LEARNING

- Naïve Bayes Classifier
- Regressione Logistica
- K-Nearest Neighbours
- Random Forest
- Support Vector Machine
- Decision Tree

- Decision Tree
- K-Nearest Neighbours
- Support Vector Machine





DATA POISONING

DATA POISONING

Tecnica di attacco che consiste nel manipolare i dati utilizzati per addestrare un modello di machine learning al fine di influenzarne le prestazioni o compromettere la sicurezza del sistema

2 GRUPPI

1. Quelli che mirano a ridurre l'accuratezza complessiva del modello.
 2. Quelli che mirano all'integrità del modello e, in particolare dei dati. Nel caso in cui i dati vengono presi da internet ci possono essere ulteriori tipi di attacchi:
 - a. Split-view poisoning
 - b. Front-running poisoning

FORME DEL DATA POISONING



SOTTO-OBIETTIVI DI AVVELENAMENTO DATI

SOTTO-OBIETTIVI DI AVVELENAMENTO DATI

DENIAL OF SERVICE

L'obiettivo è ridurre le prestazioni di un modello bersaglio nel suo complesso.

ATTACCO BACKDOOR:

L'obiettivo è ridurre le prestazioni o forzare previsioni specifiche ed errate per un input o un insieme di input selezionati.



METODI DI AVVELENAMENTO DEI DATI

Iniezione di dati

Attacco in cui si iniettano nuovi dati all'interno del set di addestramento

Label flipping

Attacco con cui si cambiano le etichette di una quota di dati nel set di addestramento


Per ottimizzare la generazione di input avvelenati è necessario conoscere:

Set di formazione originale

Tipo di modello da avvelenare


Iperparametri del modello

Funzione di perdita utilizzata
per calcolare l'errore di
previsione durante
l'allenamento




ESEMPIO DI ATTACCO DENIAL OF SERVICE

Original model (Acc = 91.50%)



Attacco DoS contro LR


Original model (Acc = 95.00%)



Attacco DoS contro SVM


ESEMPIO DI ATTACCO BACKDOOR

Original classifier (acc = 91.50%)



Attacco BD contro LR

Original classifier (acc = 95.00%)



Attacco BD contro SVM



Adozione di tecniche di rilevamento e filtraggio dei dati dannosi durante il processo di addestramento del modello



Implementazione di controlli per garantire l'integrità e l'autenticità dei dati utilizzati



Adozione di approcci robusti per la sicurezza informatica



Adozione della tecnica di *sanitization*

PROPOSTE PER CONTRASTARE GLI ATTACCHI
ATTACCHI



Cozzupoli Luigi
Cusato Miriam
Dattola Giovanni
Itri Caterina
Logiudice Giorgio

**GRAZIE PER
L'ATTENZIONE**

Moio Maria Carla
Naso Domenico
Pirrottina Marta
Rosato Forti Pietro
Strano Silvia