

# Soluzioni di Deep Learning per la Cyber Security

Francesco La Rosa

Università degli Studi di Messina

*francesco.larosa@unime.it*

Conferenza GARR 2018 - *Data Revolution*

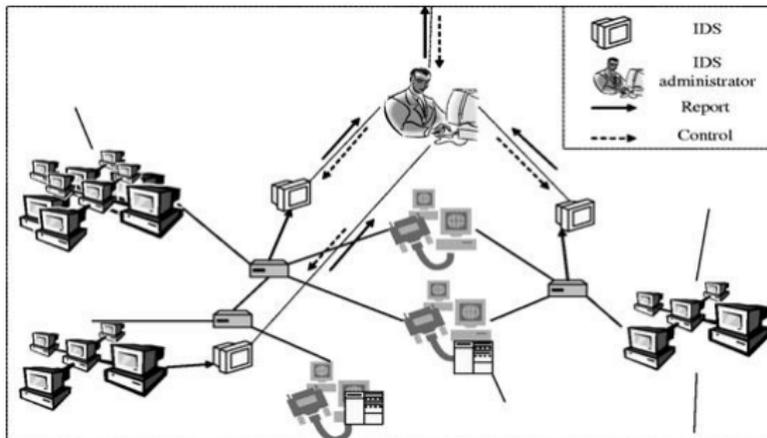
Cagliari, 03 Ottobre 2018

# Agenda

- 1 Introduzione
- 2 Machine Learning e Deep Learning
- 3 Convolutional Neural Networks
- 4 Il Sistema
- 5 Misure Sperimentali
- 6 Conclusioni

# Intrusion Detection System

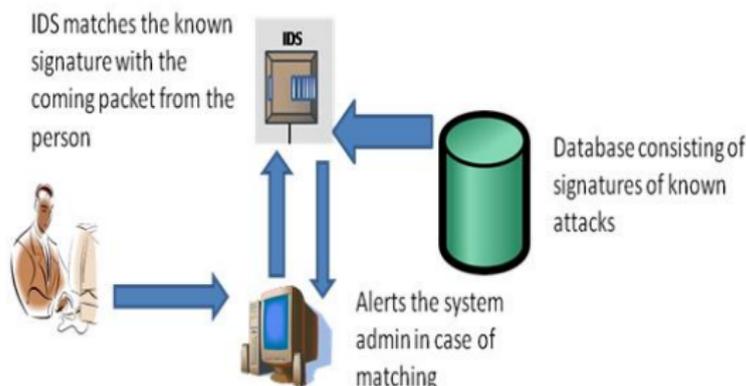
- L'**identificazione** dei vari **attacchi di rete**, in particolare di quelli mai visti in precedenza, è un problema da risolvere con **urgenza**.
- Un componente fondamentale di un'infrastruttura di cyber security è il sistema di Intrusion Detection (**IDS**)
- Possono essere classificati in due categorie:
  - **Host**-based IDS (HIDS)
  - **Network**-based IDS (NIDS)



- I Network Intrusion Detection System (NIDS) esistenti possono essere **classificati** in base al tipo di **analisi del traffico di rete** realizzato:
  - Misuse-based
  - Anomaly-based
  - Hybrid

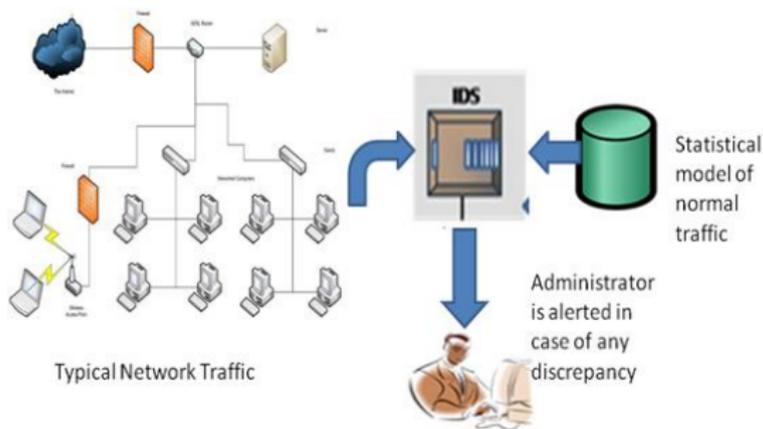
# NIDS misuse-based

- Nota anche come detection basata su firma, il rilevamento dell'abuso è basato sul confronto di eventi registrati con schemi predefiniti di attacco.
- Costituisce l'approccio più utilizzato
- Questo sistema di rilevamento delle intrusioni è lento nel generare un modello e presenta un alto costo in caso di cambiamento dello stesso, rendendo difficile rilevare efficacemente nuovi tipi di attacco emergenti su Internet.



# NIDS anomaly-based

- Le soluzioni anomaly-based si basano su un **modello** del normale comportamento della rete
- Identificano le anomalie come **deviazioni** dal modello
- Sono interessanti per la loro capacità di rilevare attacchi zero-day
- **Elevato tasso** di falsi allarmi
  - **Comportamenti di sistema** precedentemente non riscontrati possono essere classificati come **anomalie**



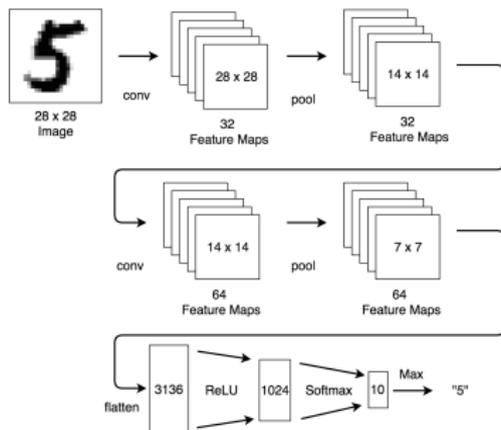
- Diverse sono le **soluzioni proposte** in cui tecniche di **Machine Learning** (ML) sono state applicate al problema dell'intrusion detection [Ford et al., 2014][Buczak et al., 2016]:
  - Support vector machine
  - Algoritmi genetici
  - Fuzzy logic
  - Reti bayesiane
- Il ML si concentra principalmente sulla **classificazione e la discriminazione** in base a caratteristiche note precedentemente apprese per mezzo di dati raccolti per l'addestramento (**learning**)

- Il **Deep Learning** (DL) è un campo di ricerca che ricade nell'ambito del **ML**
- La sua motivazione sta nella creazione di una **rete neurale** che simula il comportamento del cervello umano nell'apprendimento analitico
- Analogamente ai metodi di ML, i metodi di DL si possono classificare in **metodi di apprendimento** supervisionato e apprendimento non supervisionato

- Il DL rende possibile un apprendimento non supervisionato o semi-supervisionato che consente **l'estrazione automatica (ed efficiente) di feature**
- **Algoritmi di DL** comunemente utilizzati:
  - Autoencoders
  - Deep Belief Networks (DBMs)
  - Long Short-Term Memory networks (LSTMs)
  - Convolutional Neural Networks (CNNs)  
[Jia et al., 2017][Wang et al., 2018]

# Convolutional Neural Networks - parte 1

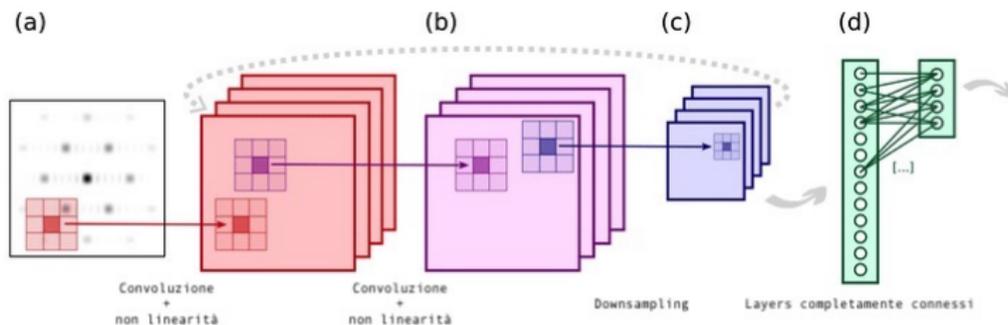
- Le Convolutional Neural Networks (CNNs) sono un tipo specializzato di rete neurale adatta al processamento di dati sotto forma di matrice, come serie temporali e **immagini**
- **Una serie temporale** può essere pensata come un vettore monodimensionale **campionato** ad intervalli regolari
- La tipica architettura di una CNN consiste di un **layer di input ed uno di output** completati da diversi **layer nascosti**



# Convolutional Neural Networks - parte 2

- I **layer nascosti** possono essere dei:

- Convolutional layer
- Pooling layer
- Layer completamente connessi



- Classificatore implementato usando **Tensorflow**
- Tutti gli esperimenti sono stati condotti su un server:
  - S.O.: Ubuntu 64-bit 16.04 LTS
  - CPU: Intel Xeon 3.60GHz
  - RAM: 16 GB
  - **GPU NVIDIA GTX 750**



- Convolutional Neural Network

- **Canali:** 24
- **Kernel** size: 3\*3
- **Step:** 1
- Dati raw acquisiti dalla rete di dimensione fissa pari a **28\*28** elementi (784 bytes)

- Convolutional Neural Network
  - Convolutional layer
  - **Layer di pooling:** 2
    - Max-pooling
    - Size: 2\*2
  - **Rete** completamente connessa: *3 strati nascosti e 5 uscite*
  - Adam **optimizer**:
    - Batch: 60 esempi
    - Funzione di costo: cross-entropy
    - Training time: 0.002
    - Epoche: 50

- Dataset su cui fare benchmark:
  - **DARPA98**
  - KDDCUP99
  - NSLKDD
- Sono dataset ormai datati che seppur non rappresentino in maniera fedele il traffico e i possibili attacchi di una rete moderna, permettono il **confronto tra la soluzione proposta e altre presenti in letteratura.**

# Misure - Parametri utilizzati

## Accuratezza

$$ACC = \frac{TP+TN}{TP+FP+FN+TN}$$

## Detection Rate

$$DR = \frac{TP}{TP+FN}$$

## False Acceptance Rate

$$FAR = \frac{FP}{FP+TN}$$

- **TP**: true positive
- **TN**: true negative
- **FP**: false positive
- **FN**: false negative
- **ACC**: Accuracy
- **DR**: Detection Rate
- **FAR**: False Acceptance Rate

<b>Categoria</b>	<b>Pattern di attacco</b>
DoS	back, land, neptune, pod, smurf, teardrop
Probe	ipsweep, nmap, portsweep, satan
R2L	ftp-write, guess-passwd, imap, multihop, phf, spy, etc.
U2R	buffer-overflow, loadmodeule, perl, rootkit

Table: Categorie degli attacchi

<b>Dataset</b>	<b>Acc%</b>	<b>DR%</b>	<b>FAR</b>
DoS	99.62	99.23	0.03
Probe	99.30	83.43	0.02
R2L	99.75	75.1	0.03
U2R	99.98	67.2	0.03
Totale	99.72	97.82	0.08

**Table:** Le prestazioni del NIDS sul dataset DARPA98

- **Network Intrusion Detection System** basato su una *Convolutional Neural Network*, già adottata con risultati notevoli in ambiti come quelli della Computer Vision e del Natural Language Processing
- **Idea** di base: “convertire la distribuzione di probabilità insita nel flusso di dati acquisito in una sequenza di *immagini* ed impiegare una CNN per classificarle in base al loro contenuto (traffico di rete)”
- **Sviluppi futuri:**
  - Migliorare le prestazioni della rete (CNN) su **dataset sbilanciati**
  - Migliorare le prestazioni del NIDS proposto **combinando** i dati (**raw**) raccolti con **feature tradizionali**



F. Jia and L. Kong (2017)

Intrusion detection algorithm based on convolutional neural network  
*Trans. Beijing Inst. Technol.* 37:1271–1275, 12.



V. Ford and A. Siraj (2014)

Applications of machine learning in cyber security  
*Proceedings of the 27th International Conference on Computer Applications in Industry and Engineering*



A. Buczak and E. Guven (2016)

A survey of data mining and machine learning methods for cyber security intrusion detection  
*IEEE Communications Surveys Tutorials* 18(2):1153–1176.



W. Wang, Y. Sheng, J. Wang, X. Zeng, X. Ye, Y. Huang and M. Zhu (2018)

Hast-ids: Learning hierarchical spatial-temporal features using deep neural networks to improve intrusion detection  
*IEEE Access* 6:1792–1806.

# Soluzioni di Deep Learning per la Cyber Security

Nicola Cannistrà, Fabio Cordaro, Francesco La Rosa,  
Umberto Ruggeri e Riccardo Uccello

Università degli Studi di Messina

Conferenza GARR 2018 - *Data Revolution*

Cagliari, 03 Ottobre 2018

# Grazie