

Domenico Daniele Bloisi

Daniele Nardi



**UNIVERSITÀ DEGLI STUDI  
DELLA BASILICATA**


**DIAG**

Dipartimento di Ingegneria  
informatica, automatica e gestionale  
Antonio Ruberti



**SAPIENZA**  
UNIVERSITÀ DI ROMA





# Detection di lesioni cutanee con tecniche di Deep Learning



Sapienza information-based Technology Innovation Center for Health

# Domenico Daniele Bloisi

- Ricercatore RTD B  
Dipartimento di Matematica,  
Informatica ed Economia  
Università degli Studi della  
Basilicata  
<http://web.unibas.it/bloisi>





# Daniele Nardi

- Professore Ordinario  
Dipartimento di Ingegneria  
Informatica, Automatica e  
Gestionale “Antonio Ruberti”  
Sapienza Università di Roma  
<http://www.diag.uniroma1.it//nardi>

## Canopies



<https://www.ai4eu.eu/>



<https://sciroc.org/>



<https://youtu.be/ji0OmkaWh20>

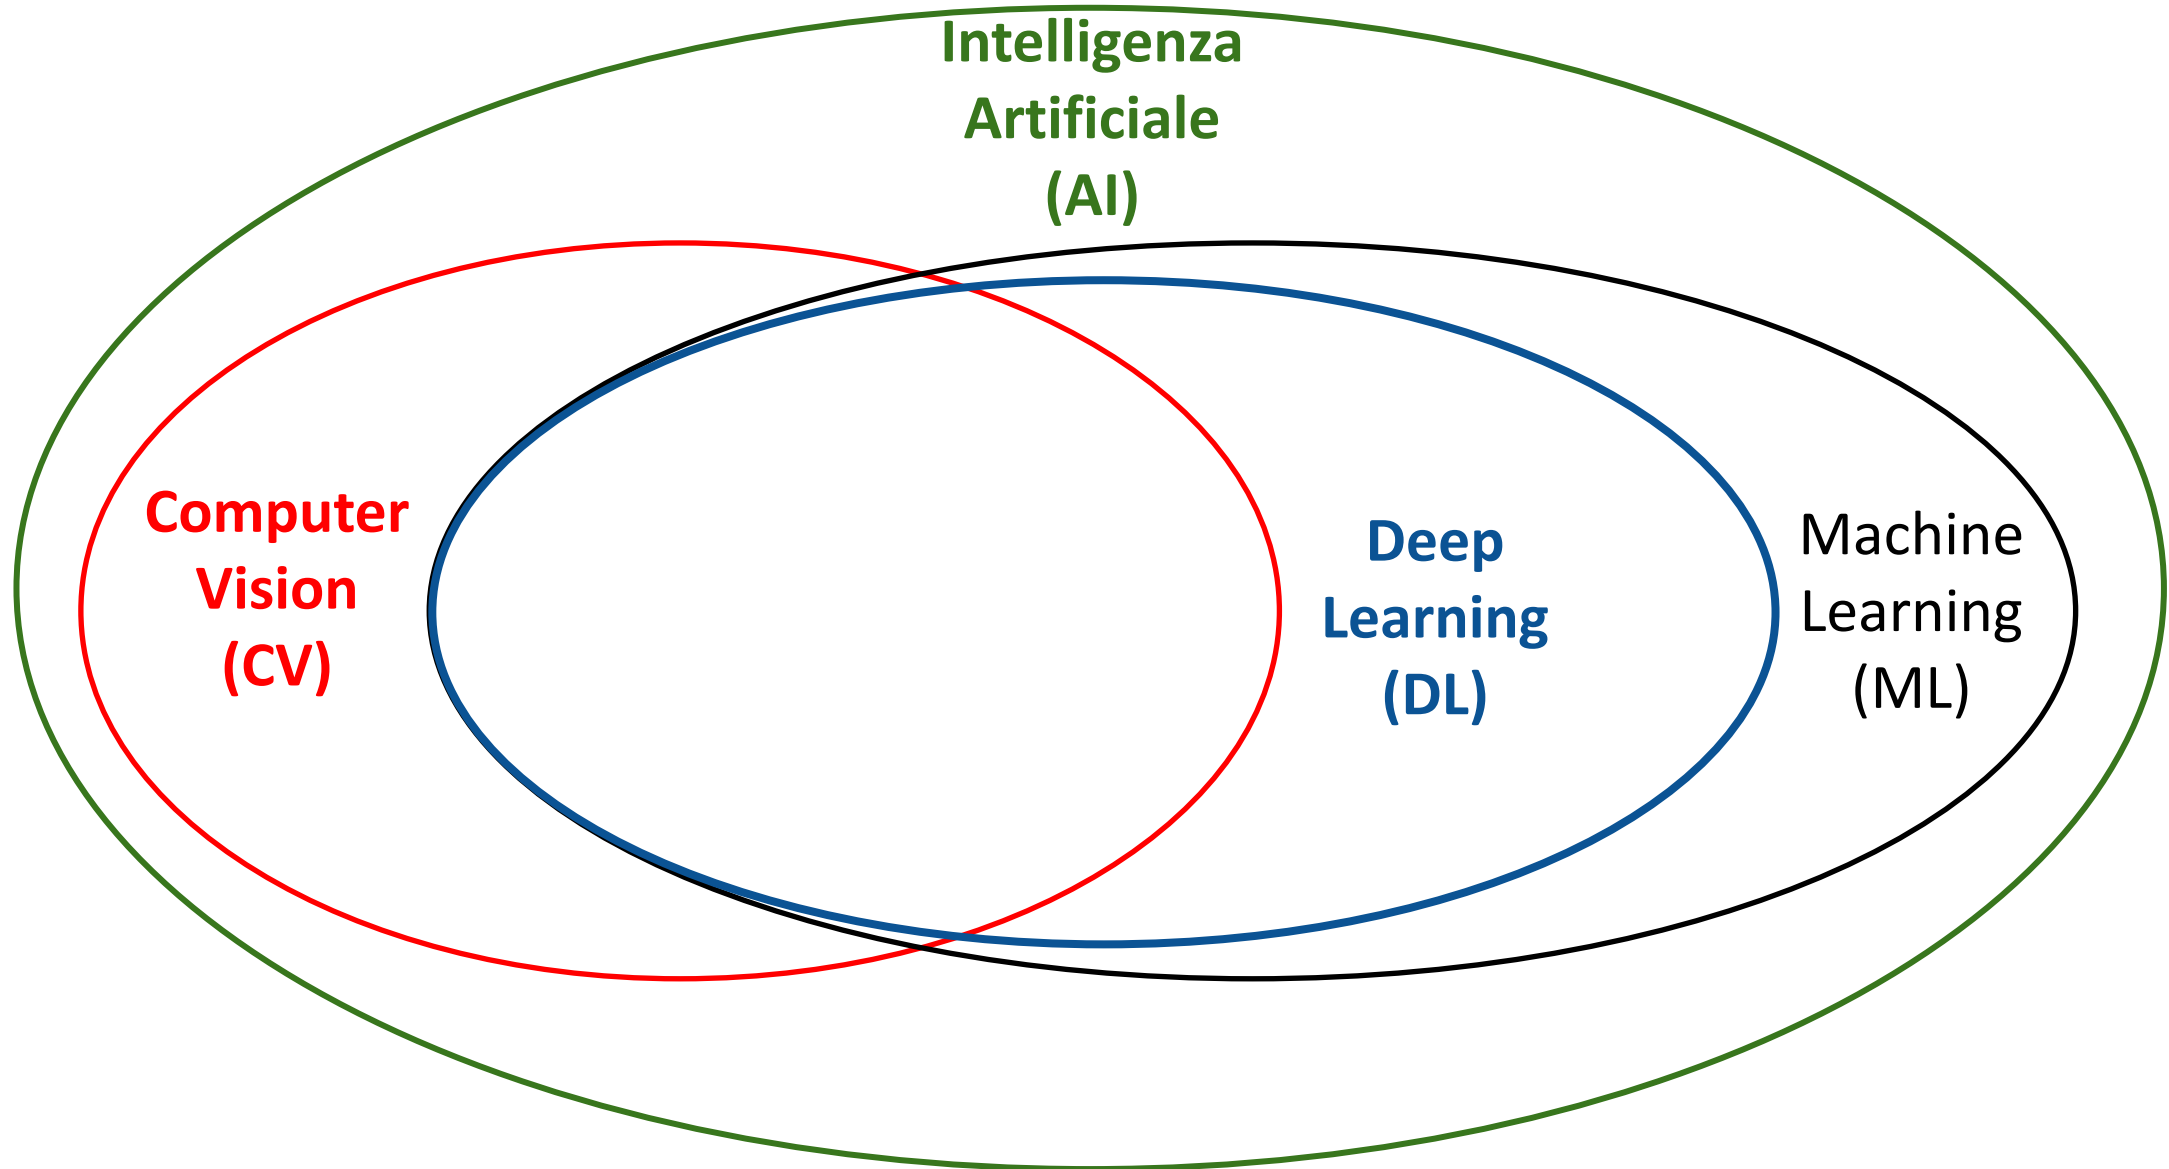
# Outline

---

- Computer Vision, Machine Learning e Deep Learning
- Il Deep Learning applicato alla detection di lesioni cutanee
- Risultati sperimentali
- Conclusioni e sviluppi futuri

# AI, CV, ML, and DL

---



# Computer Vision


---

*“creare sistemi artificiali per*

- *processare*
  - *percepire*
  - *ragionare su*
- dati visuali”*



Photo by [Veronica Benavides](#)  
on [Unsplash](#)



- Immagini
- Video
- ...

- **Instagram:** circa 100 milioni di foto e video caricati al giorno
- **Youtube:** più di 500 ore di video caricate ogni minuto

Source: Justin Johnson

# Machine Learning

---

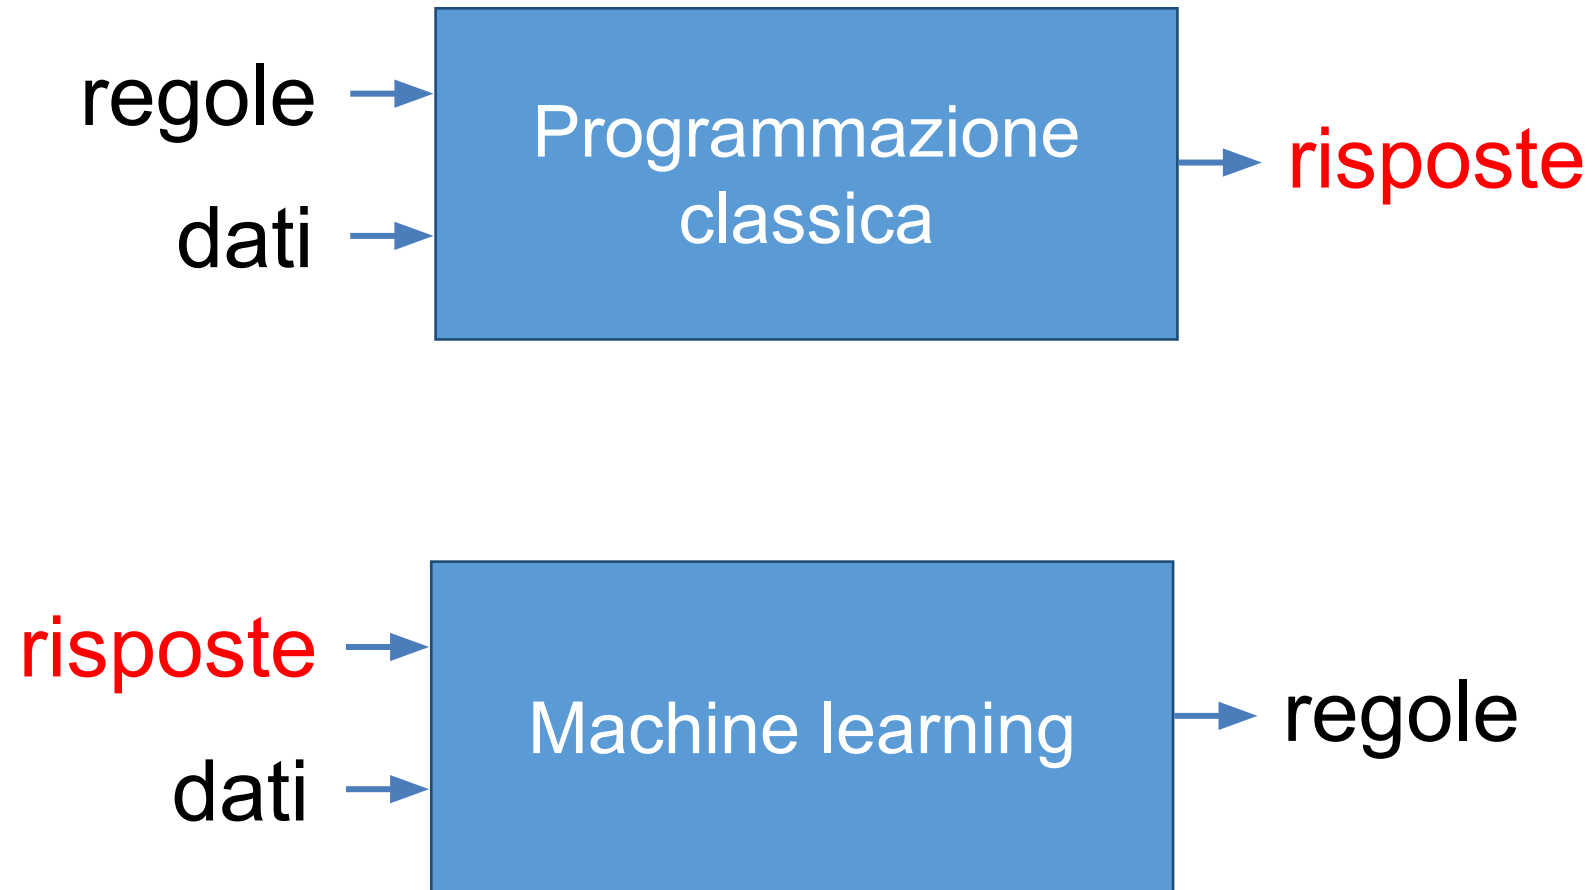
*“creare sistemi artificiali che imparino a risolvere problemi a partire da*

- dati*
- esperienza”*

L'obiettivo del ML è ortogonale rispetto al quello della CV, la quale è interessata a risolvere il problema di interpretare i dati visuali, ma non specifica come deve essere risolto tale problema

# Paradigma del Machine Learning

---






# Tipi di Apprendimento

---

- Un sistema di ML viene **addestrato a svolgere un compito** piuttosto che esplicitamente programmato a svolgerlo
- L'apprendimento può avvenire con diverse modalità:
  - **supervisionato** (supervised learning)
  - **semi-supervisionato** (semi-supervised learning)
  - **per rinforzo** (reinforcement learning)




# Deep Learning


---

*“creare sistemi di apprendimento automatico che abbiano*

- un'architettura gerarchica*
- composta da **molti** strati (layers),*
- in modo da formare una **lunga** (deep) catena di rappresentazioni”*



# Reti Neurali




## Neurone Umano

- ottimizzato per compiti Umani

## Neurone Artificiale


- ottimizzato per compiti di Machine Learning



# Percettrone

---

- Un percettrone prende in ingresso input binari  $x_1, x_2, \dots, x_n$  calcola la somma **pesata** degli input e produce un singolo output **binario** usando una soglia fissa (**threshold**):




$$\text{output} = \begin{cases} 0 & \text{if } \sum_j w_j x_j \leq \text{threshold} \\ 1 & \text{if } \sum_j w_j x_j > \text{threshold} \end{cases}$$

- Il percettrone può essere usato per prendere decisioni: variando i pesi e la soglia possiamo ottenere differenti modelli decisionali

# Percettroni multi-livello

- Reti di percettroni più complesse sono in grado di trattare problemi decisionali più difficili:



- La prima colonna (i.e., il **primo layer**) di percettroni prende decisioni semplici a basso livello pesando direttamente gli input.
- Il **secondo layer** prende decisioni pesando i risultati che arrivano dal primo layer:

Il secondo layer può prendere decisioni ad un livello più alto e più astratto



# Dai perceptroni ai neuroni artificiali

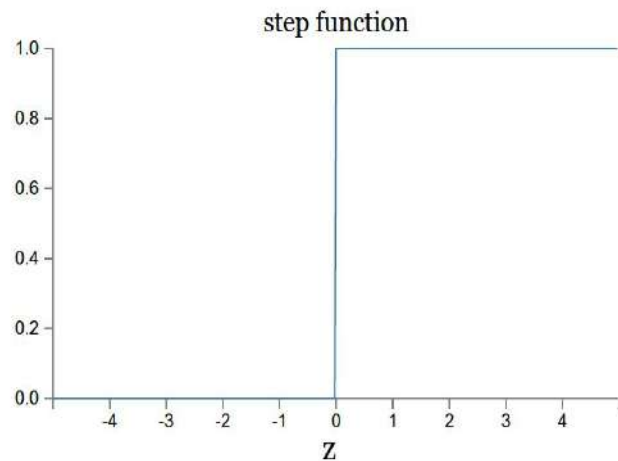
---

- 1) Riscriviamo la somma pesata degli input come un prodotto tra matrici  $w \cdot x$
- 2) Sostituiamo la threshold con un bias  $b$ ,  
con  $b = -threshold$


$$\text{output} = \begin{cases} 0 & \text{if } w \cdot x + b \leq 0 \\ 1 & \text{if } w \cdot x + b > 0 \end{cases}$$

# Neurone Sigmoidale

3) “Smorziamo” l’output usando come **funzione di attivazione** una sigmoide



$$\sigma(z) \equiv \frac{1}{1 + e^{-z}}$$




Con un **neurone sigmoidale** piccoli cambi dei pesi e del bias provocano piccoli cambi dell’output  **Questo permette alla rete di neuroni sigmoidali di *imparare***

# Neurone Artificiale

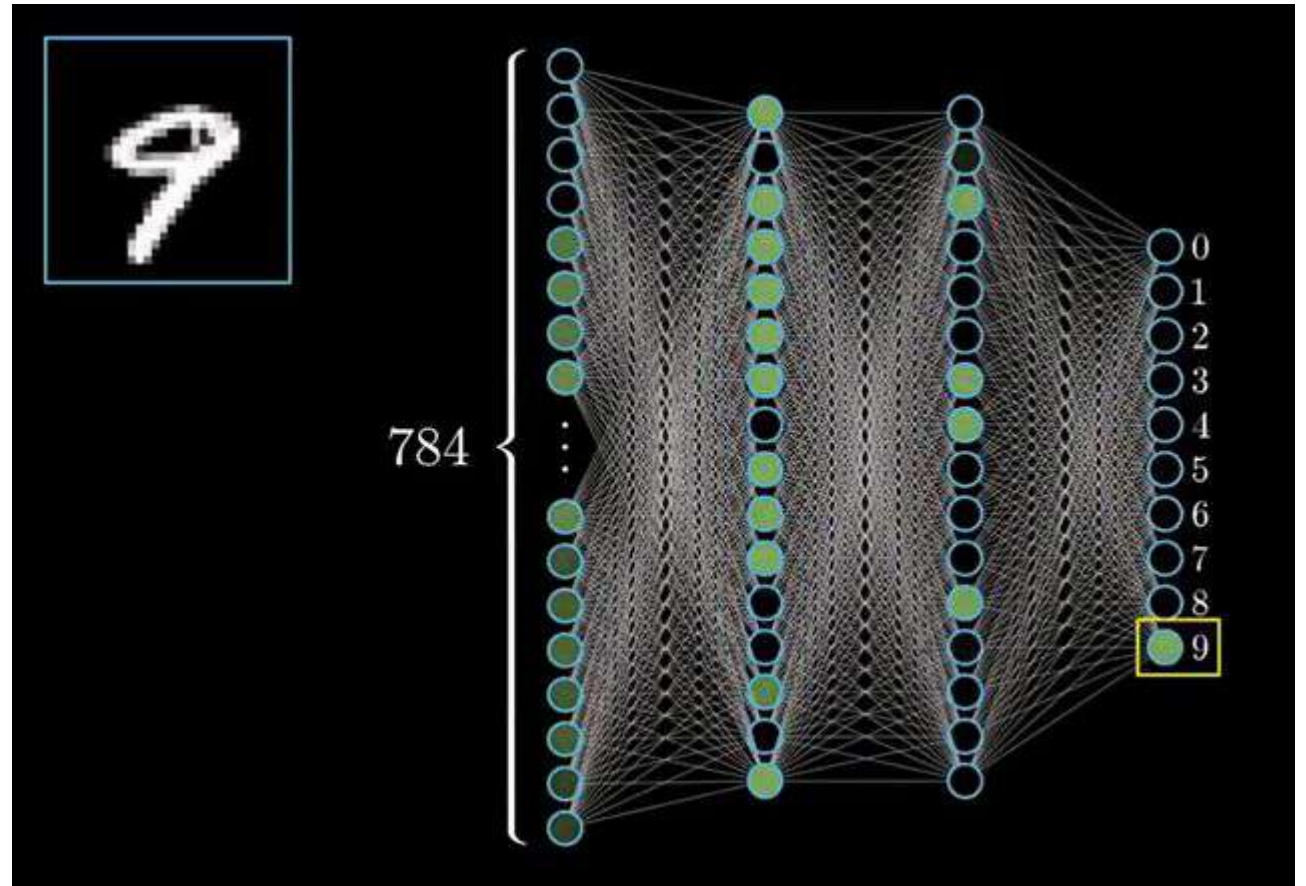
---

- Prende in ingresso input numerici (**X**)
- Ha un peso associato ad ogni input (**w**)
- Ha un **bias** nella forma di input addizionale 1 con peso **b**
- Applica una funzione di attivazione (**f**) alla somma pesata degli input



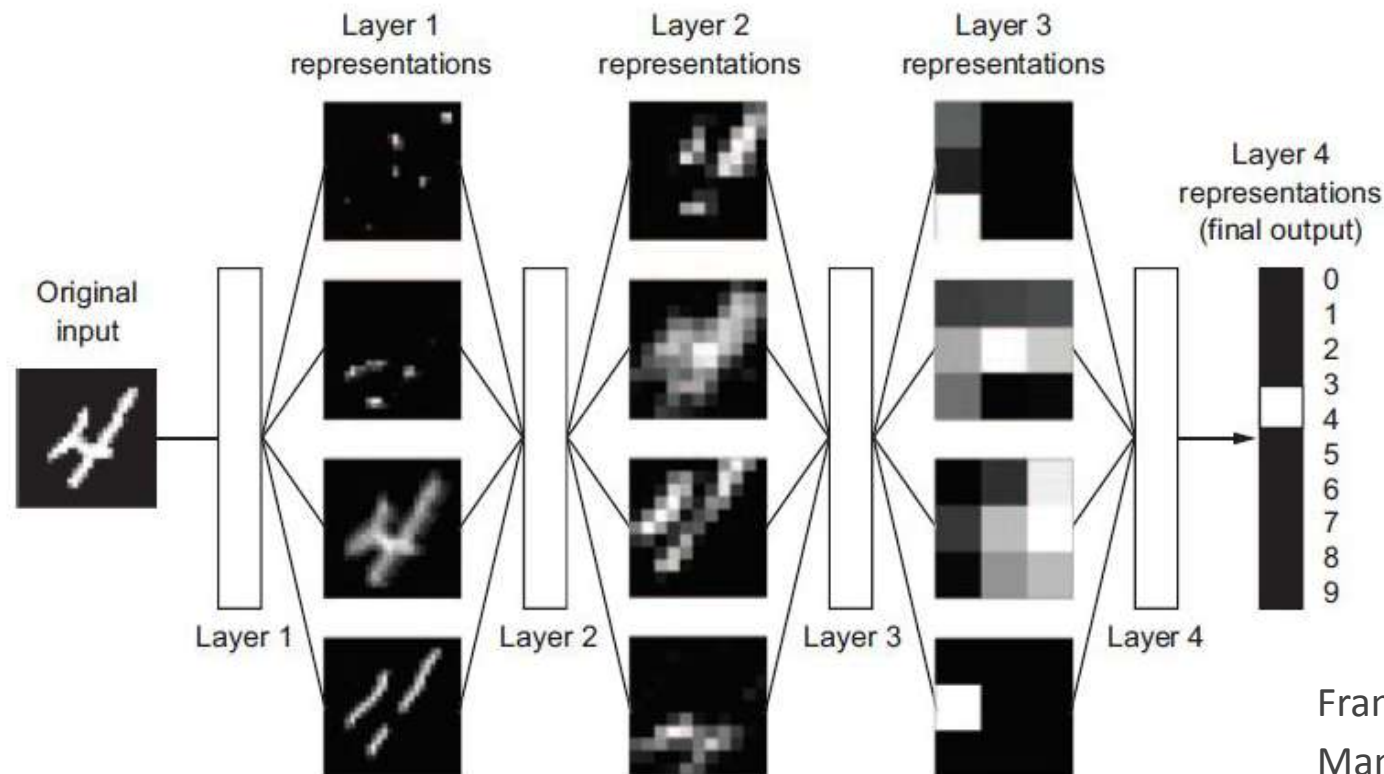
# Deep Neural Networks (DNN)

Reti neurali artificiali organizzate in diversi strati (2 o più), dove ogni strato calcola i valori per quello successivo affinché l'informazione venga elaborata in maniera sempre più completa



# Gerarchia di feature

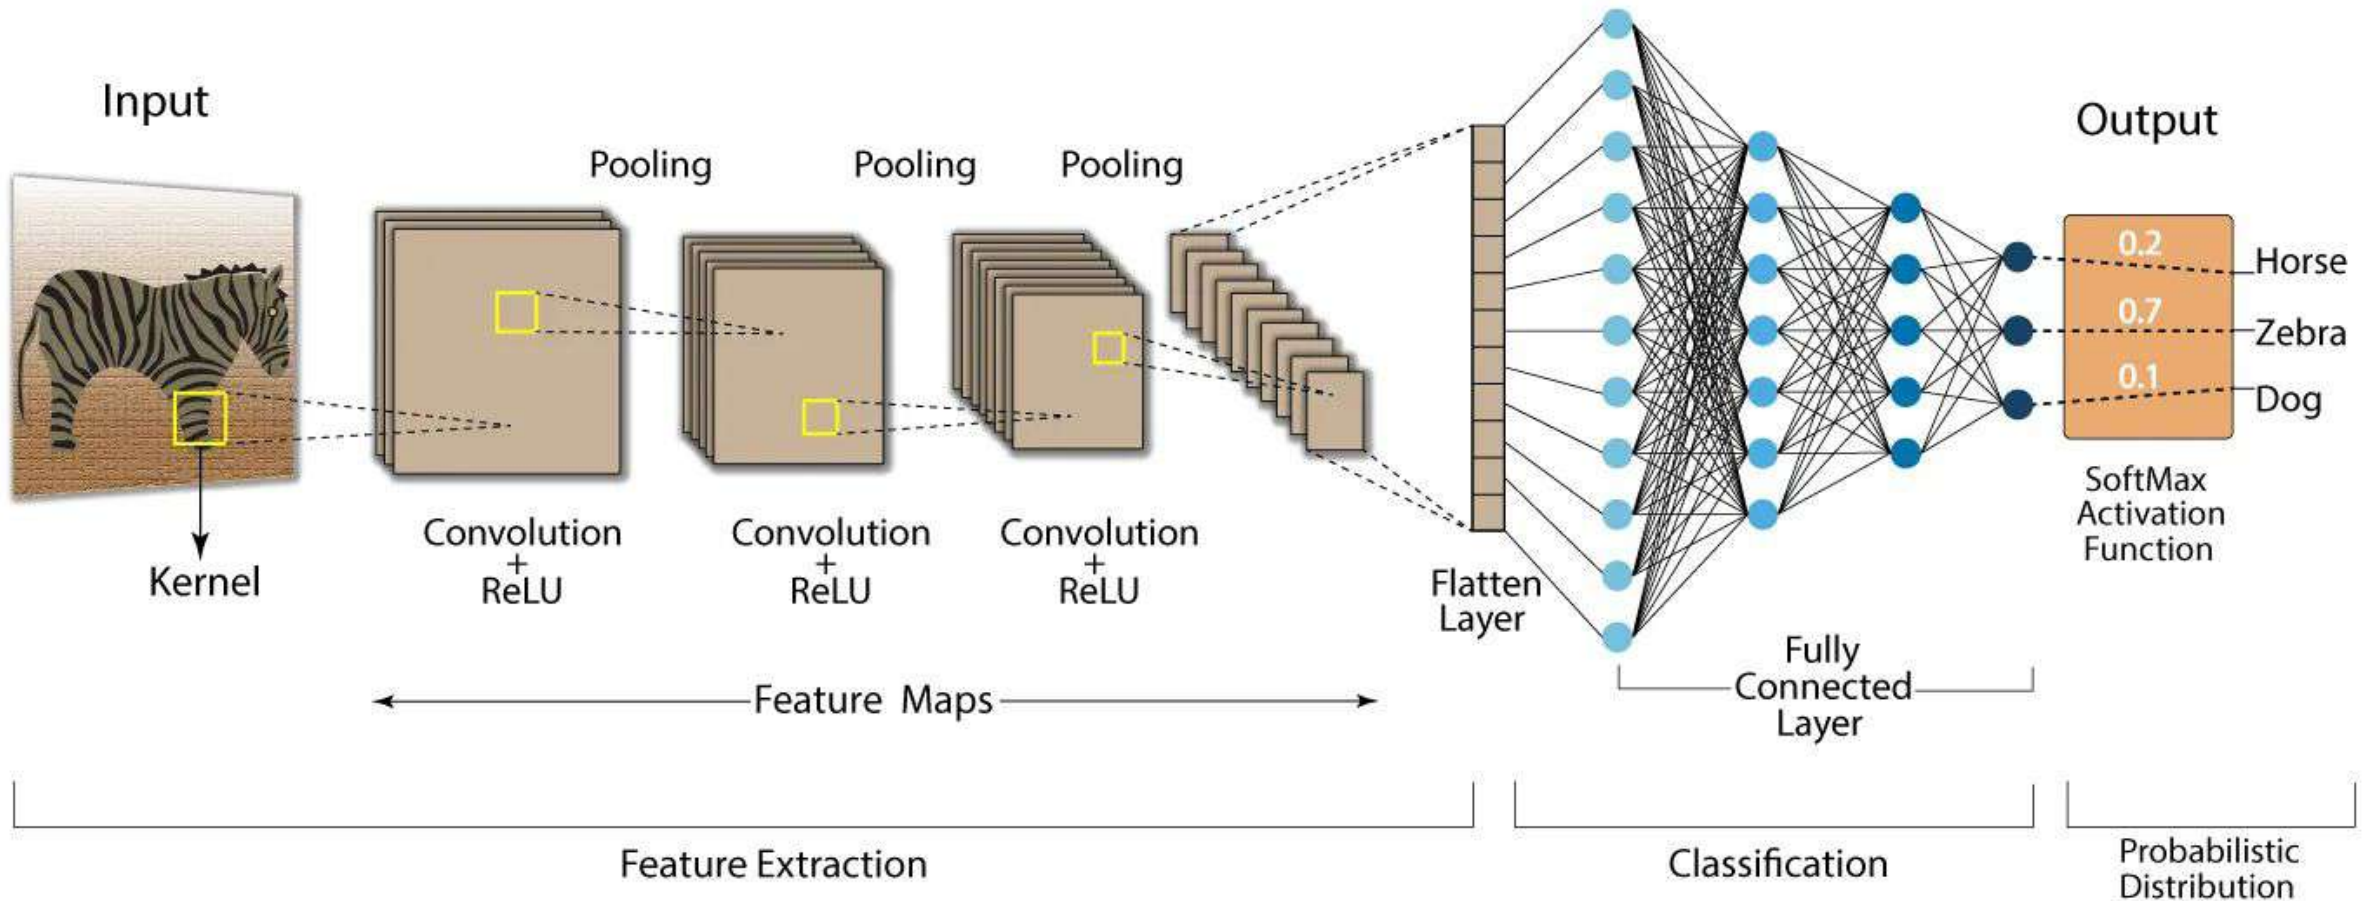
I metodi di Deep Learning hanno l'obiettivo di imparare gerarchie di "feature", dove le feature di alto livello sono formate da composizioni di feature a più basso livello [Glorot and Bengio]





# Reti Convoluzionali Profonde

## Convolution Neural Network (CNN)



# Melanoma e Deep Learning

- E' possibile utilizzare il Deep Learning per migliorare il trattamento del melanoma?
- In che modo?

## Dermoscopia



## Diagnosi precoce



# Dermoscopia

---

- La dermoscopia è una tecnica non-invasiva e a basso costo per la rilevazione precoce del cancro della pelle tramite l'analisi delle **caratteristiche visuali della lesione non distinguibili ad occhio nudo**
- Le immagini dermoscopiche sono generate combinando una illuminazione a basso angolo di incidenza con un ingrandimento ottico ottenuto tramite l'uso di appositi liquidi o luce cross-polarizzata

# Regola ABCDE

---



**A** Molti melanomi sono asimmetrici



**B** I melanomi solitamente presentano bordi irregolari



**C** Il melanoma ha una grande varietà di colori mentre la maggior parte delle lesioni benigne ha un solo colore



**D** In molti casi i melanomi hanno un diametro  $> 6$  mm



**E** A differenza della maggior parte delle lesioni benigne, il melanoma tende a modificarsi nel tempo

# Limiti della Dermoscopia

---

La dermoscopia presenta due grossi limiti:


1. Richiede una lunga e specifica preparazione per il personale medico
2. Anche con un training adeguato, l'analisi visuale rimane soggettiva




# Task dell'analisi di immagini dermoscopiche (DIA)

---

## 1. Segmentazione della lesione




dermoscopic image




binary mask of the lesion

## 2. Individuazione degli attributi della lesione

## 3. Classificazione



benign keratosis




globules

# Problematiche nella DIA


---




pen marks



hairs



reflections



air/oil bubbles

# Tecniche classiche di segmentazione

---

- **Thresholding methods**

un pixel è etichettato come lesione se è più scuro di una certa soglia di colore

- adaptive thresholding
- histogram thresholding
- clustering

- **Edge and contour-based methods**

i bordi della lesione vengono individuati analizzando le discontinuità (i.e., gli edge) nell'immagine dermoscopia


- gradient vector flow (GVF) e mean shift gradient vector flow (MSGVF)
- Expectation Maximization (EM)

- **Region-based methods**

algoritmi che lavorano sull'intera immagine (metodi globali)

- JSEG - quantizzazione del colore e segmentazione spaziale
- Statistical region merging (SRM)
- ASLM

# ASLM



Pennisi, A., Bloisi, D., Nardi, D., Giampetruzzi, A. R., Mondino, C., & Facchiano, A. (2016).

Skin Lesion Image Segmentation Using Delaunay Triangulation for Melanoma Detection. *Computerized Medical Imaging and Graphics*, 52, 89-103.




# Risultati ASLM su PH2

Method	Sensitivity	Specificity	Accuracy	F-measure
JSEG	0.7108	0.9714	$0.8947 \pm 0.0176$	0.7554
SRM	0.1035	0.8757	$0.6766 \pm 0.0346$	0.1218
KPP	0.4147	0.9581	$0.7815 \pm 0.0356$	0.5457
K-means	0.7291	0.8430	$0.8249 \pm 0.0107$	0.6677
Otsu	0.5221	0.7064	$0.6518 \pm 0.0203$	0.4293
Level Set	0.7188	0.8003	$0.7842 \pm 0.0295$	0.6456
ASLM	<b>0.8024</b>	<b>0.9722</b>	<b><math>0.8966 \pm 0.0276</math></b>	<b>0.8257</b>

**PH2 database** composto da 200 immagini dermoscopiche RGB dermoscopic images con una risoluzione di 768×574 pixels e un ingrandimento 20× annotate con ground truth

- 80 common nevi
- 80 dysplastic nevi
- 40 melanomas



# ISIC challenge



Task 1: Lesion Segmentation

Task 2: Lesion Dermoscopic Feature Extraction

Task 3: Lesion Classification

## Training

2000 immagini  
JPEG annotate

## Validation


150 immagini  
JPEG annotate

## Test

600 immagini  
JPEG annotate

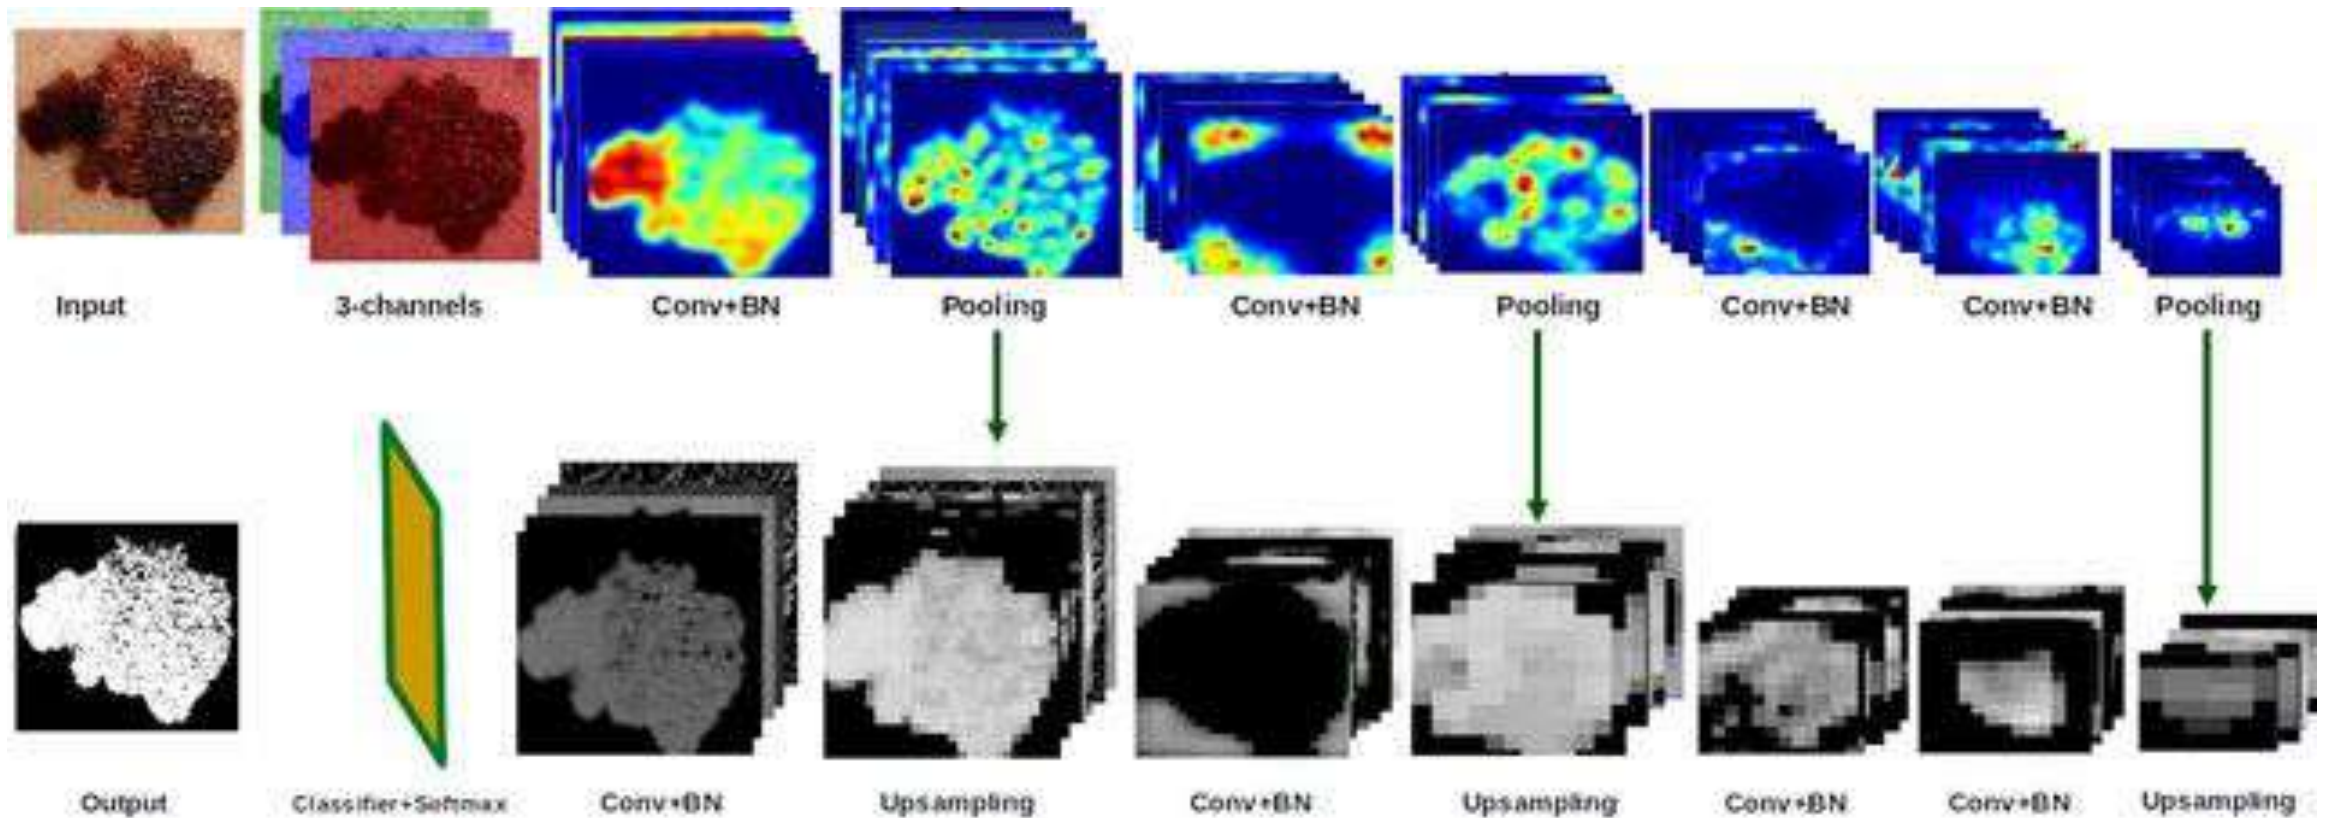
# Tecniche DL di segmentazione

SegNet: A Deep Convolutional Encoder-Decoder Architecture for Robust Semantic Pixel-Wise Labelling






# Feature maps

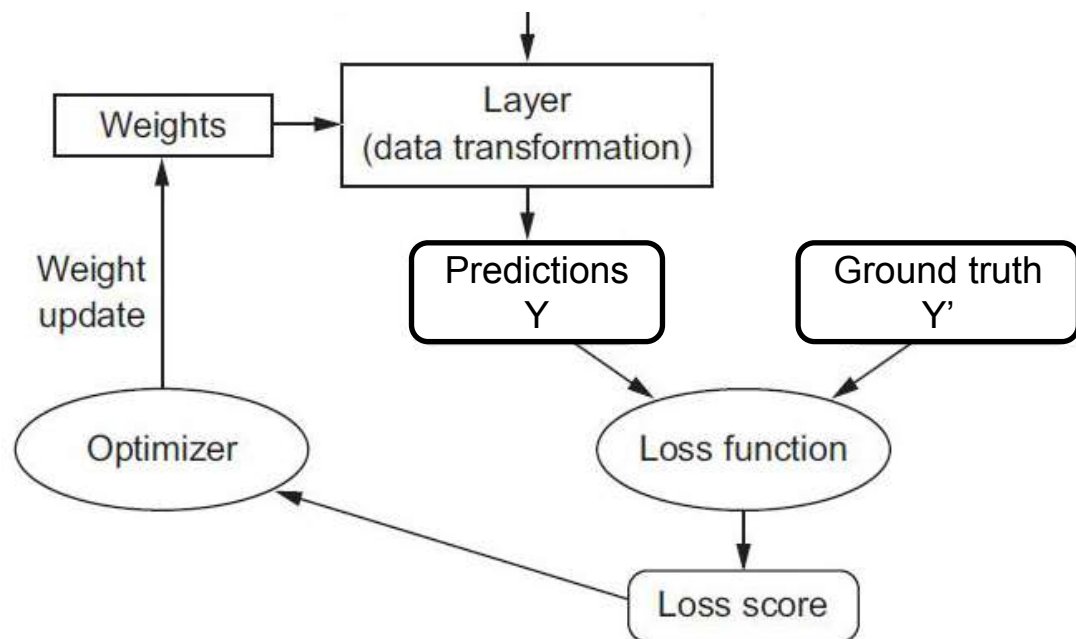


A. Youssef, D. D. Bloisi, M. Muscio, A. Pennisi, D. Nardi and A. Facchiano, "Deep Convolutional Pixel-wise Labeling for Skin Lesion Image Segmentation," *2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, 2018, pp. 1-6.

# Errore di predizione



TP verde  
FP rosso  
FN blu  
TN nero



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

$$Dice = \frac{TP + TP}{(FP + TP) + (TP + FN)}$$

$$JSI = \frac{TP}{TP + FP + FN}$$

# Risultati SegNet su PH2

SKIN LESION SEGMENTATION RESULTS USING 4-LAYERS CNN ON 80 DYSPLASIC NEVI (ATYPICAL MOLES) IMAGES FROM PH<sup>2</sup>

Method	Sensitivity	Specificity	Accuracy	F-measure
ASML	0.86	0.97	0.93	0.87
SegNet	<b>0.96</b>	0.87	0.90	<b>0.88</b>


SEGMENTATION RESULTS USING 4-LAYERS CNN ON 80 MELANOCYTIC NEVI (COMMON HEALTHY LESIONS) FROM PH<sup>2</sup>

Method	Sensitivity	Specificity	Accuracy	F-measure
ASML	0.87	0.97	0.95	0.87
SegNet	<b>0.98</b>	0.89	0.91	<b>0.90</b>

SEGMENTATION RESULTS USING 4-LAYERS CNN ON 40 MELANOMA (MALIGNANT LESIONS) IMAGES FROM PH<sup>2</sup>

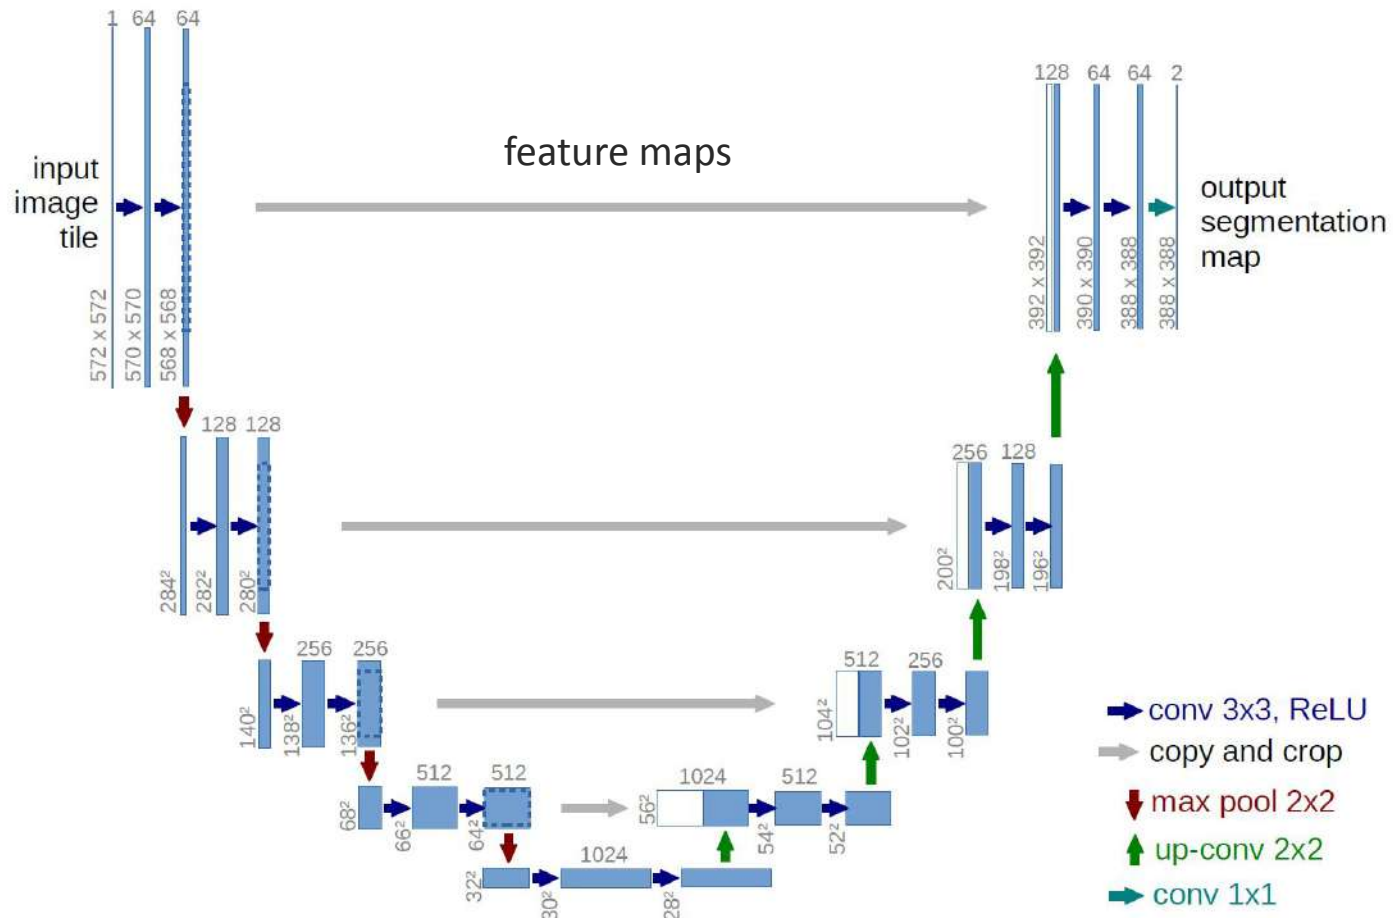
Method	Sensitivity	Specificity	Accuracy	F-measure
ASML	0.54	0.96	0.66	0.65
SegNet	<b>0.83</b>	0.82	<b>0.83</b>	<b>0.82</b>

## Data augmentation



# U-Net

## U-Net: Convolutional Networks for Biomedical Image Segmentation






# Risultati ISIC 2017

La submission risultata vincitrice della Challenge ISIC 2017 ha ottenuto

- Jaccard Index medio pari a 0.765
- Accuracy del 93.4%
- Dice coefficient pari a 0.849

Le maschere con Jaccard Index pari o superiore a 0.8 possono considerarsi corrette ad una ispezione visuale



# Deep Learning per la Dermoscopia

---

- I metodi basati su tecniche di Deep Learning per l'analisi di immagini dermoscopiche (DIA) hanno il potenziale per migliorare i tassi di individuazione precoce del melanoma poiché si sono dimostrati superiori ai dermatologi nella classificazione delle immagini dermoscopiche (Brinker et al., 2019)

# Monitorare l'evoluzione della lesione

---



**A**



**B**



**C**



**D**

La segmentazione dell'area della lesione è il primo passo per creare un sistema di Intelligenza Artificiale che possa comparare quantitativamente e oggettivamente immagini di lesioni scattate in differenti momenti



**E**

A differenza della maggior parte delle lesioni benigne, il melanoma tende a modificarsi nel tempo



# Promuovere la diagnosi precoce

---

- I metodi basati su DL non possono sostituire i dermatologi
- Possono permettere di promuovere la diagnosi precoce
- Migliorano la consapevolezza (empowerment) del paziente coinvolgendolo direttamente nel monitoraggio temporale della lesione

# DIA su Sistemi Embedded

---

Una Graphics processing unit (GPU) è un dispositivo dedicato per accelerare l'elaborazione di immagini




# Vantaggi dei Sistemi Embedded

---

Usare sistemi embedded ha 3 vantaggi:

1. **Privacy.** Le immagini rimangono in locale e non vengono inviate via Internet
2. **Costo.** I sistemi embedded hanno un costo contenuto rispetto ai normali PC
3. **Velocità.** I tempi di risposta sono immediati (bassa latenza)

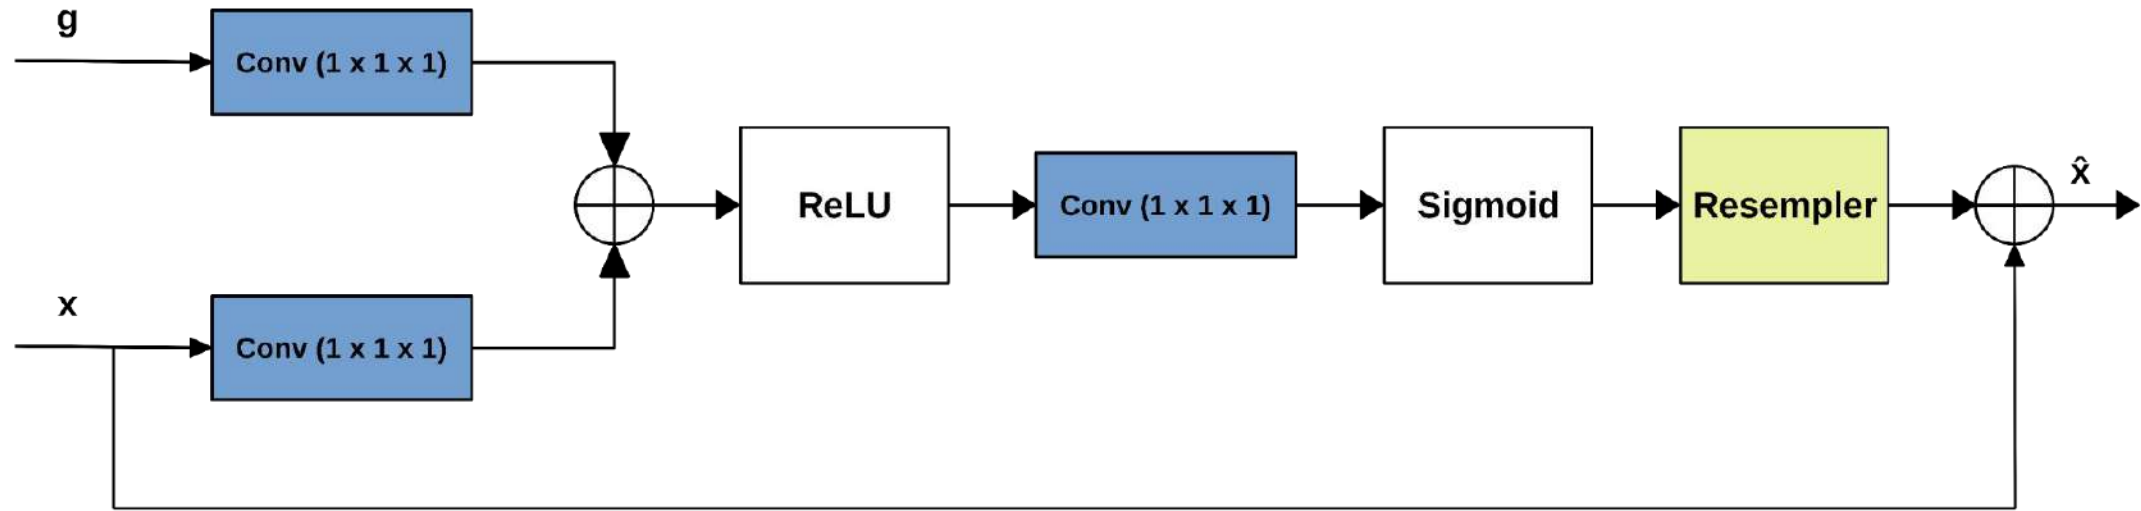
# Attention Squeeze U-Net



- U-Net → più di 30 milioni di parametri
- Squeeze U-Net → 2.5 milioni di parametri

1x1  
convolution

# Attention nelle DNN



Aggiungere un blocco di attenzione prima della concatenazione dell'output permette alla rete di comprendere quali feature sono più rilevanti di altre e conseguentemente di pesarle di più

# Risultati ISIC 2017

Table 1: The results of the networks on the ISIC 2017 test set (600 images).

Network	Dice	Threshold Jaccard
U-Net	0.8965	0.7591
Attention U-Net	0.8766	0.7043
Squeeze U-Net	0.8987	0.7597
Attention Squeeze U-Net	<b>0.9035</b>	<b>0.7758</b>

← Jaccard index con penalizzazione

La submission risultata vincitrice della Challenge ISIC 2017 ha ottenuto

- Jaccard Index medio pari a 0.765
- Dice coefficient pari a 0.849

# Risultati PH2

---

Table 2: Segmentation results on the PH2 data set (200 images).

Network	Dice	Threshold Jaccard
U-Net	0.9083	0.7942
Attention U-Net	0.8984	0.7879
Squeeze U-Net	0.9231	<b>0.8753</b>
Attention Squeeze U-Net	<b>0.9301</b>	0.8533

- ASLM - Dice coefficient pari a 0.82
- SegNet - Dice coefficient pari a 0.87



# Conclusioni e Sviluppi Futuri

---

- I metodi basati da DL per l'analisi delle immagini dermoscopiche hanno il potenziale di migliorare i tassi di detection del melanoma prima che sia troppo tardi
- Tramite il DL è possibile raggiungere risultati di classificazione su immagini dermoscopiche superiori a quelli dei dermatologi (Brinker et al., 2019)
- Il DL può essere un mezzo per promuovere la diagnosi precoce del melanoma in aiuto ai dermatologi (Fourcade and Khonsari, 2019)
- L'uso di sistemi embedded (includendo anche gli smartphone) potrà permettere di coinvolgere maggiormente i pazienti nel monitoraggio temporale delle lesioni

Domenico Daniele Bloisi

Daniele Nardi



**UNIVERSITÀ DEGLI STUDI  
DELLA BASILICATA**


**DIAG**

Dipartimento di Ingegneria  
informatica, automatica e gestionale  
Antonio Ruberti



**SAPIENZA**  
UNIVERSITÀ DI ROMA

# Detection di lesioni cutanee con tecniche di Deep Learning



Sapienza information-based Technology Innovation Center for Health